



ISSN 2615-224X (online)
ISSN 1693-0000 (print)

JURNAL TEKNOINFO

Jurnal Teknik Informatika dan Ilmu Komputer
Terbit Enam bulanan (Januari dan Juli)

JURNAL

Penerbit **UNIVERSITAS TEKHOKRAT INDONESIA**

Pengelola **Program Studi S1 Informatika
Fakultas Teknik dan Ilmu Komputer**

HALAMAN PENGESAHAN

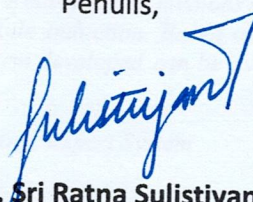
Judul : Implementasi Metode Pembobotan Berbasis Aturan dan Metode Profile Matching pada Sistem Pakar Medis untuk Prediksi Risiko Hipertensi
Penulis : Sri Ratna Sulistiyanti, Agus Wantoro, Admi Syarif, Khairun Nisa Berawi, Kurnia Muludi, Sutyarso (**anggota**)
NIP : 196510211995122001
Instansi : Universitas Teknokrat Indonesia
Publikasi : Jurnal TEKNOINFO
ISBN : 2615-224X
Volume : 15
No : 2
Tanggal Publikasi : 2021
Penerbit : Universitas Teknokrat Indonesia
Website : <https://ejurnal.teknokrat.ac.id/index.php/teknoinfo/article/view/1523/738>

Mengetahui/Menyetujui
Dekan Fakultas Teknik,


Bandar Lampung, Juni 2023


Penulis,


Dr. Eng. Ir. Helmy Fitriawan, S.T., M.Sc
NIP. 197509282001121002


Dr. Sri Ratna Sulistiyanti, M.T
NIP. 196510211995122001

Mengetahui/Menyetujui
Ketua Lembaga Penelitian dan Pengabdian pada Masyarakat
Universitas Lampung


Dr. Habibullah Jimad, M.Si
NIP. 197111211995121001

DOKUMENTASI LEMBAGA PENELITIAN DAN PENGABDIAN KEPADA MASYARAKAT UNIVERSITAS LAMPUNG	
TGL	22/06/2023
NO. INVEN	655/S/A/N/FT/2023
JENIS	Jurnal
PARAF	

IMPLEMENTASI METODE PEMBOBOTAN BERBASIS ATURAN DAN METODE PROFILE MATCHING PADA SISTEM PAKAR MEDIS UNTUK PREDIKSI RISIKO HIPERTENSI

Agus Wantoro¹, Admi Syarif², Khairun Nisa Berawi³, Kurnia Muludi⁴, Sri Ratna Sulistiyanti⁵, Sutyarso⁶,

¹Doktor MIPA, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung

^{2,4} Ilmu Komputer, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung

³ Kesehatan Masyarakat, Fakultas Kedokteran, Universitas Lampung

⁵ Teknik Elektro, Fakultas Teknik, Universitas Lampung

² Biologi, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Lampung

¹Jl. Jl.Prof.Dr.Sumantri Brojonegoro No.1, Gedung Meneng, Bandar Lampung

Email: ¹aguswantoro@teknokrat.ac.id, ²admi.syarif@fmipa.unila.ac.id, ³khairun.nisa@fk.unila.ac.id,

⁴kmuludi@fmipa.unila.ac.id, ⁵sr_sulistiyanti@eng.unila.ac.id, ⁶sutyarso.sty@gmail.com

Abstract

Cardiovascular is a disease that often causes death. One of the cardiovascular diseases that often cause death is the risk of Hipertensi. The highest risk factors for premature death and disability in the world are caused by smoking habits, high systolic blood pressure, and increased blood sugar levels. This death factor is because people with Hipertensi generally do not experience any symptoms until their blood pressure is too high which can cause death. Efforts that can be made are by utilizing information technology in the form of a medical expert system to Klasifikasi the risk of Hipertensi. This study aims to develop a medical expert system in a different way using rule-based weighting methods and profile matching. The weighting method is used to determine the risk weight based on patient variables, while the profile matching method is used to calculate the risk Klasifikasi based on the core factor and secondary factor variables on the risk of Hipertensi. System evaluation is carried out by comparing asset data taken from the Pima Indian Hipertensi Data (NHANES) with results from the system. The results of the comparison show that the accuracy of the proposed system is 96.67%. The proposed system is also compared with other Klasifikasi methods such as decision tree, Random Tree, Decision Stump, KNN, Naïve BaYa, Deep Learning, and Rule Induction. Based on the comparison results, the proposed system has a better level of accuracy, therefore the system developed can be used to Klasifikasi risks for other types of diseases.

Keywords: Hipertensi Risk, Rule-Based Weighting, Profile Matching, Expert System

Abstrak

Kardiovaskular merupakan penyakit yang sering menyebabkan kematian. Salah satu penyakit kardiovaskular yang sering menyebabkan kematian adalah risiko hipertensi. Faktor risiko kematian dini tertinggi di dunia disebabkan oleh kebiasaan merokok, tekanan darah sistolik yang tinggi, dan peningkatan kadar gula darah. Faktor kematian ini karena penderita risiko hipertensi umumnya tidak mengalami gejala apapun hingga tekanan darah yang tinggi akhirnya menyebabkan kematian. Upaya yang dapat dilakukan adalah dengan memanfaatkan teknologi informasi berupa sistem pakar medis untuk mengklasifikasikan risiko hipertensi. Penelitian ini mengembangkan sistem pakar medis dengan cara yang berbeda menggunakan metode pembobotan berbasis aturan dan metode profil matching. Metode pembobotan digunakan untuk menentukan bobot risiko berdasarkan variabel pasien, sedangkan metode profil matching digunakan untuk menghitung klasifikasi risiko berdasarkan variabel core factor dan secondary factor terhadap risiko hipertensi. Evaluasi sistem dilakukan dengan membandingkan data aset yang diambil dari Pima Indian Hipertensi Data (NHANES) dengan system usulan. Hasil perbandingan menunjukkan bahwa akurasi sistem usulan sebesar 96.67%. Sistem usulan juga dibandingkan dengan metode klasifikasi lain seperti Decision tree, Random Tree, Decision Stump, KNN, Naïve BaYa, Deep Learning, dan Rule Induction. Berdasarkan hasil perbandingan, sistem usulan memiliki tingkat akurasi yang lebih baik, sehingga sistem pakar dapat digunakan untuk mengklasifikasikan risiko untuk jenis penyakit lainnya.

Kata Kunci: Risiko hipertensi, Pembobotan Berbasis Aturan, Profile Matching, Sistem Pakar

1 Pendahuluan

Kardiovaskular merupakan penyakit yang menyebabkan kematian. Hal ini disebabkan gaya hidup modern yang serba instan dan kurang olahraga. Salah satu penyakit kardiovaskular yang sering menyebabkan

kematian adalah hipertensi [2]. Hipertensi atau tekanan darah tinggi adalah kondisi ketika tekanan darah mencapai 140/80 mmHg. Hipertensi memiliki 2 (dua) jenis yaitu primer dan sekunder[3]. Hipertensi primer belum diketahui penyebabnya secara pasti, sedangkan hipertensi sekunder dapat terjadi karena penyakit ginjal, merokok,

dan alkoholisme [4]. Hipertensi masih menjadi penyumbang kematian dini terbesar di dunia. Hipertensi memiliki istilah *silent killer* atau penyakit yang membunuh secara diam-diam [5]. Data dari pelayanan BPJS untuk pasien hipertensi mengungkapkan biaya yang dikeluarkan untuk berobat sebesar Rp. 3 triliun/tahun

Faktor risiko kematian dini tertinggi di dunia disebabkan oleh beberapa hal seperti kebiasaan merokok, tekanan darah sistolik yang tinggi, dan peningkatan kadar gula darah. Faktor kematian ini karena penderita hipertensi umumnya tidak mengalami gejala apapun sampai tekanan darahnya terlalu tinggi dan dapat menyebabkan kematian. Pemeriksaan tekanan darah secara mandiri dan rutin atau datang langsung ke dokter untuk mengetahui risiko hipertensi merupakan hal yang penting untuk dilakukan. Pemeriksaan untuk mengidentifikasi risiko hipertensi memerlukan pengetahuan dan ketelitian dari dokter ahli, namun tidak semua rumah sakit dan klinik kesehatan memiliki dokter ahli untuk mendiagnosis risiko hipertensi. [7]. Salah satu upaya yang dapat dilakukan dengan memanfaatkan teknologi berupa sistem pakar medis yang dapat mengklasifikasikan risiko hipertensi berdasarkan kondisi pasien. Sistem yang dikembangkan dapat membantu dokter dalam mendiagnosis risiko hipertensi dengan lebih cepat dan akurat, sehingga risiko pasien hipertensi dapat

didiagnosis secara dini dan segera mendapatkan pengobatan. Beberapa penelitian tentang diagnosis risiko hipertensi telah dilakukan yang ditunjukkan pada Tabel 1 menggunakan berbagai algoritma seperti fuzzy, algoritma genetika, pohon keputusan, c4.5, machine learning, dan Support Vector Machine (SVM). Namun penerapan metode pembobotan yang dikombinasikan dengan metode Profile Matching untuk diagnosis risiko hipertensi belum ditemukan.

Penelitian ini bertujuan untuk mengembangkan sistem pakar medis menggunakan metode rule-based weighting dan profile matching. Metode rule-based weighting digunakan untuk menentukan bobot risiko berdasarkan variabel pasien, sedangkan metode profile matching digunakan untuk menghitung nilai variabel core factor dan secondary factor terhadap risiko hipertensi sehingga pasien dapat diklasifikasikan memiliki risiko hipertensi. atau tidak.

2 Penelitian Terkait

Banyak penelitian yang menerapkan algoritma kecerdasan buatan untuk mendeteksi risiko hipertensi telah dilakukan dengan menggunakan berbagai metode dan algoritma. Penelitian terkait diagnosis risiko hipertensi dirangkum dan disajikan pada Tabel 1

Tabel 1. Penelitian kecerdasan buatan tentang diagnosis risiko hipertensi

No	Penulis	Metode	Variabel	Tujuan
1	Abdullah, Zakaria, and Mohammad, 2011 [8]	Fuzzy Mamdani	Jenis kelamin, usia, BMI, tekanan darah, detak jantung	Diagnosis risiko hipertensi
2	Djam and Kimbi, 2011 [9]	Fuzzy Mamdani	Tekanan darah sistolik, tekanan darah diastolik, usia, BMI	Diagnosis risiko hipertensi
3	Das, Ghosh, and Kar, 2013 [10]	Fuzzy Mamdani	Jenis Kelamin, Usia, BMI, tekanan darah, detak jantung	Diagnosis risiko hipertensi
4	Srivastava <i>et al</i> , 2013 [11]	Fuzzy Sugeno	Usia, BMI, Detak Jantung, Kolesterol, Merokok	Klasifikasi risiko hipertensi
5	Kaur and Bhardwaj, 2014 [12]	Genetic Algorithm, and neuro-fuzzy	Darah Sistolik, Darah Diastolik, IMT, Denyut Jantung, Kolesterol, Glukosa, Urea Darah, Kreatinin, Asam Urat	Diagnosis risiko hipertensi
6	Kaur and Kaur, 2015 [13]	Fuzzy Mamdani	Usia, BMI, Tekanan Darah, Denyut Jantung, Jenis Kelamin, Kadar Gula, Aktivitas Fisik	Diagnosis risiko hipertensi
7	Abrishami and Tabatabaee, 2015 [14]	Fuzzy Mamdani	BMI dan Tekanan Darah Sistolik	Diagnosis risiko hipertensi
8	Guzmán, Melin and Prado-Arechiga, 2017 [15]	Fuzzy Mamdani	Tekanan darah sistolik dan diastolik	Diagnosis risiko hipertensi
9	Adebayo, 2017 [16]	Decision Trees (ID3 dan C4.5)	Alkohol, Olahraga, Status Perkawinan; Jenis kelamin	Klasifikasi risiko hipertensi
10	Guzmán, Melin and Prado-Arechiga, 2018 [17]	Fuzzy and Genetic Algorithm	Tekanan darah sistolik dan diastolik	Diagnosis risiko hipertensi

11	Jibril, 2018 [18]	Fuzzy	BMI, Usia, Kehamilan, Status Perkawinan	Diagnosis hipertensi
12	Miramontes et al. 2018 [19]	Fuzzy Mamdani	Umur, Nafas	Diagnosis risiko hipertensi
13	Jie et al.2018 [20]	Ontology expert system, Web Semantic	Riwayat hipertensi dan tekanan darah	Diagnosis hipertensi
14	Melin, Miramontes and Prado-Arechiga, 2018 [21]	Neural networks and fuzzy systems	Tekanan darah sistolik, diastolik, Usia, Nafas, Merokok	Klasifikasi risiko hipertensi
15	Melin and Prado-Arechiga, 2018 [22]	Fuzzy Mamdani	Tekanan darah sistolik dan diastolik	Klasifikasi risiko hipertensi
16	Hossain, Fatema-Tuj-Johora and Andersson, 2019 [23]	Rule-based	BMI, Tekanan Darah, Denyut Jantung, Sakit Kepala, Nyeri dada, Kelelahan, Sesak napas, masalah penglihatan, gejala	Diagnosis hipertensi
17	Elshawi, Al-Mallah and Sakr, 2019 [24]	Machine learning	Usia, Tekanan Darah, Riwayat Hiperlipidemia, Riwayat Diabetes, Ras	Prediksi hipertensi
18	Tengnah, Sooklall and Nagowah, 2019 [25]	Machine learning	Usia, Jenis Kelamin, Kehamilan, IMT, Riwayat Hipertensi, Merokok, Konsumsi Alkohol, Tingkat Stres, Konsumsi Garam, Tekanan Darah	Diagnosis hipertensi
19	Chang et al., 2019 [26]	Machine-learning XGBoost	Jenis Kelamin, Usia, Tinggi Badan, Berat Badan, BMI	Diagnosis hipertensi
20	Shiraz H.E, 2019 [27]	Fuzzy	Tekanan darah sistolik, Diastolik, low-density lipoprotein, high-density lipoprotein, Usia, BMI	Klasifikasi risiko hipertensi
21	Nour and Polat, 2020 [28]	Machine learning	Usia, Jenis Kelamin, Tinggi Badan, Berat Badan, Tekanan Darah Sistolik, Diastolik, Denyut Jantung, IMT	Klasifikasi risiko hipertensi
22	Ambika, Raghuraman and SaiRamesh, 2020 [29]	Support vector machine (SVM)	Merokok, Konsumsi Alkohol, Diet Tidak Sehat HH, Aktivitas Fisik, Tekanan Darah Tinggi, Gula Darah Naik, Obesitas	Memprediksi dan mencegah hipertensi
23	Chatrati et al., 2020 [30]	Support vector machine (SVM)	Tekanan darah sistolik dan diastolik	Memprediksi hipertensi
24	Lopez-Martínez, 2020 [31]	Artificial neural network	Usia, jenis kelamin, etnis, BMI, riwayat merokok, penyakit ginjal, diabetes	Memprediksi dan mencegah hipertensi
25	Penelitian ini	Profile Matching	Usia, jenis kelamin, etnis, BMI, asap, ginjal, diabetes	Klasifikasi risiko hipertensi

Abdullah, Zakaria, dan Mohammad [8] menggunakan fuzzy Mamdani untuk mendiagnosis risiko hipertensi. Hasil diagnosis risiko hipertensi ditampilkan dengan nilai persentase. Djam dan Kimbi [9] menggunakan variabel sistolik, diastolik, umur, dan BUMI dengan logika fuzzy dan FIS Mamdani untuk mengklasifikasikan 3 (tiga) risiko hipertensi yaitu ringan, sedang dan berat. Das, Ghosh, dan Kar [10] Das menggunakan neuro-fuzzy untuk mendiagnosis risiko hipertensi dengan output persentase risiko. Srivastava et al [11] membangun sistem pendukung keputusan untuk klasifikasi hipertensi. Klasifikasi tersebut adalah sangat rendah, rendah, sedang, tinggi, dan sangat tinggi. Kaur dan Bhardwaj [12] menggunakan metode fuzzy neurogenetic untuk diagnosis hipertensi memiliki

tingkat akurasi 86%. Kaur dan Kaur [13] mengembangkan sistem pakar untuk diagnosis hipertensi dalam nilai persentase. Abrishami, dan Tabatabaee [14] menggunakan kombinasi algoritma fuzzy dan jaringan saraf multi-layer untuk diagnosis hipertensi. Adebayo [16] menggunakan algoritma ID3 untuk mengklasifikasikan risiko hipertensi. Model yang diusulkan memperoleh nilai akurasi sebesar 86,36%. Guzmán, Melin, dan Prado-Arechiga [17] menggunakan algoritma genetika fuzzy untuk klasifikasi tekanan darah. Outputnya berupa tingkat tekanan darah. Jibril [18] membangun sistem pakar medis untuk deteksi dini risiko hipertensi menggunakan algoritma berbasis pengetahuan. Sistem yang dikembangkan memiliki tingkat akurasi dan kecepatan yang tinggi dalam

mendiagnosis pasien. Miramontes et al [19] menerapkan logika fuzzy untuk diagnosis risiko hipertensi dengan nilai akurasi sistem 95%. Jie dkk. [20] mengembangkan sistem pakar berbasis ontologi untuk diagnosis dan pengobatan hipertensi. Sistem yang dikembangkan dapat meningkatkan efisiensi diagnosis. Melin, Miramontes, dan Prado-Arechiga [21] melakukan penelitian menggunakan jaringan syaraf tiruan yang dikombinasikan dengan fuzzy untuk klasifikasi tekanan darah dan diagnosis risiko hipertensi. Berdasarkan penggunaan beberapa modul, sistem memiliki tingkat akurasi rata-rata 97,81%. Hossain, Fatema-Tuj-Johora, dan Andersson [23] Budi mengembangkan sistem pakar berbasis aturan keyakinan untuk menilai hipertensi di bawah ketidakpastian. Hasil pengujian sistem yang dikembangkan dengan fuzzy, jaringan syaraf tiruan, pohon keputusan, dan pakar diperoleh nilai akurasi sebesar 91,96%. Elshawi, Al-Mallah, dan Sakr [24] memprediksi hipertensi menggunakan model berbasis machine learning. Output dari learning machine adalah klasifikasi hipertensi tinggi, sedang, dan rendah.


Tengnah, Sooklall, dan Nagowah [25] membangun model untuk diagnosis hipertensi menggunakan pembelajaran mesin. Hasil pengujian dengan membandingkan data latih dan data dengan berbagai model diperoleh nilai akurasi sebesar 98,7%. Penelitian Chang et al. [26] menggunakan XGBoost Pembelajaran Mesin. Sistem yang dikembangkan memiliki akurasi 94%. Shiraz H.E [27] menggunakan logika fuzzy untuk meningkatkan klasifikasi dalam diagnosis hipertensi. Penerapan logika pada klasifikasi dapat meningkatkan akurasi sebesar 4,6% dengan nilai akurasi sebesar 94,6%. Nour, dan Polat [28] mengembangkan sistem otomatisasi untuk klasifikasi jenis Hipertensi menggunakan fitur pribadi dengan pembelajaran mesin. Hasil perbandingan metode klasifikasi, sistem yang diusulkan memiliki akurasi yang lebih baik dengan akurasi 97%. Ambika, Raghuraman dan SaiRamesh [29] menggunakan algoritma Support Vector Machine (SVM). Sistem yang dikembangkan memiliki tingkat akurasi sebesar 91,8%. Chatrati et al [30] mengembangkan rumah pintar untuk memantau dan memprediksi diabetes dan hipertensi dari tekanan darah dan glukosa darah menggunakan SVM dan metode klasifikasi lainnya. Hasil perbandingan metode menunjukkan bahwa metode SVM memiliki tingkat akurasi yang paling baik. Peneliti utama sebagai referensi penelitian ini diambil dari Lopez-Martínez [31] dengan algoritma Artificial Neural Network (ANN). Hasil performansi sistem menunjukkan akurasi sebesar 73,2%. Berdasarkan beberapa penelitian yang telah dilakukan dengan variabel dan algoritma yang berbeda seperti fuzzy, algoritma genetika, pohon keputusan, c4.5, machine learning, dan Support Vector Machine (SVM) memiliki akurasi yang berbeda, namun penerapan metode pembobotan gabungan dengan metode Profile Matching untuk diagnosis risiko hipertensi belum ditemukan. Penggunaan metode Profile Matching mampu menghitung variabel yang memiliki pengaruh dan variabel yang kurang berpengaruh terhadap risiko hipertensi, maka

metode ini tepat untuk mengklasifikasikan risiko hipertensi..

3 Metode

3.1 Model Klasifikasi

Klasifikasi adalah pengelompokan berdasarkan ketentuan atau standar yang dimiliki sehingga lebih mudah untuk mengenali sesuatu [32]. Konsep klasifikasi digunakan untuk menentukan risiko hipertensi menggunakan metode rule-based weighting dan profile matching. Model klasifikasi ditunjukkan pada Gambar 1.



Gambar 1. Model klasifikasi

3.2 Profile Matching

Profile Matching merupakan mekanisme dalam menentukan keputusan dengan asumsi bahwa ada tingkat ideal variabel prediktor yang harus dipenuhi [33]. Metode ini digunakan untuk mengetahui profil risiko hipertensi dan bukan hipertensi berdasarkan variabel. Pengelompokan variabel dibagi menjadi 2 (dua) yaitu faktor inti (CF) dan faktor sekunder (SF) dengan menggunakan persamaan berikut:

$$CF = \frac{\sum CF}{\sum IC} \qquad SF = \frac{\sum SF}{\sum IS} \quad (1)$$

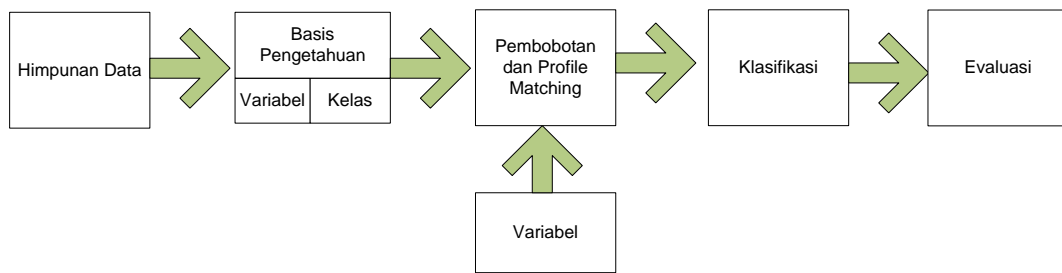
Keterangan:

CF = Core factor, SF = Secondary factor. IC = Jumlah variabel faktor inti, IS= Jumlah variabel faktor sekunder. Nilai yang dihitung untuk CF dan SF kemudian dihitung untuk nilai total untuk klasifikasi menggunakan persamaan berikut:

$$Kelas = (x)\%.CF + (x)\%.SF \quad (2)$$

3.3 Model Usulan

Model yang diusulkan menggunakan pendekatan pembobotan berbasis aturan yang dikombinasikan dengan metode Profile Matching. Pembobotan berbasis aturan menggunakan fungsi IF-then untuk menghitung bobot risiko hipertensi untuk setiap variabel. Metode profile matching digunakan untuk menghitung faktor inti dan faktor sekunder untuk klasifikasi risiko. Model dikembangkan dengan menggambarkan arsitektur prototipe yang diusulkan pada Gambar 2.



Gambar 2. Tahapan klasifikasi risiko hipertensi

3.4 Himpunan Data

Kumpulan data yang digunakan dari NHANES pada 2015–2016. Dataset ini ditujukan untuk akses publik dan pemanfaatan layanan kesehatan. Kumpulan data ini disiapkan dan diterbitkan melalui Pusat Pengendalian dan Pencegahan Penyakit (CDC) untuk memberikan akses penuh. Kumpulan data asli terdiri dari lima folder dari 2007 hingga 2016, masing-masing berisi file pdf dengan

statistik tingkat respons survei NHANES dan file SAS Transport untuk semua variabel pengukuran survei [31]

3.5 Basis Pengetahuan

3.5.1 Variabel

Variabel diambil dari Pima Indian Hipertensi Data (PIDD) dari UCI Machine Learning Repository [31]. Berdasarkan dataset, terdapat 7 (tujuh) variabel yang digunakan untuk mengklasifikasikan risiko hipertensi. Variabel ditunjukkan pada Tabel 2

Table 2. Input variabel untuk menentukan risiko hipertensi

v1	v2	v3	v4	v5	v6	v7
Kelamin Pria/Wanita	Usia Tahun	Ras -	BMI Kg/m2	Ginjal Ya/Tidak	Merokok Ya/Tidak	Diabetes Ya/Tidak

Variabel gender berdasarkan status pasien. Umur dihitung berdasarkan tahun lahir. Ras dikaitkan dengan ciri fisik, seperti tekstur rambut atau warna kulit. BMI (Body Mass Index) adalah metrik standar yang digunakan dalam kelas berat badan. Ginjal adalah informasi yang berisi tentang kondisi pasien yang memiliki riwayat penyakit ginjal. Gagal ginjal akut adalah istilah untuk suatu kondisi dimana ginjal seseorang mengalami kerusakan secara tiba-tiba, sehingga tidak dapat berfungsi. Biasanya, gagal ginjal akut terjadi sebagai komplikasi dari penyakit serius

lainnya. Asap merupakan informasi dari variabel bahwa pasien adalah perokok atau bukan. Diabetes adalah data riwayat pasien yang menderita diabetes.

3.5.2 Pembobotan Berbasis Aturan

Perhitungan bobot berdasarkan aturan untuk mendapatkan bobot kelas hipertensi dan non-hipertensi. Perhitungan pembobotan menggunakan fungsi IF-then yang ditunjukkan pada Algoritma 1

Algoritma 1. Contoh pembobotan untuk variabel kelamin

Algoritma: Contoh Pembobotan
<ol style="list-style-type: none"> Mulai Data = baca semua data pada variable Gender ; PriaHyp = Jumlah(Gender="Man" AND Kelas="Hipertensi"); PiraNon = Jumlah (Gender="Man" AND Kelas="Non"); WanitaHyp = Jumlah (gender="Woman" AND Kelas="Hipertensi"); WanitaNon = Jumlah (Gender="Woman AND Kelas="Non"); TotalPria = ManHyp + ManNon; TotalWanita = WanitaHyp + WanitaNon; BobotPriaHyp = PriaHyp / TotalPria; BobotPriaNon = PriaNon / TotalMan; BobotWanitaHyp =WanitaHyp / TotalWanita; BobotWanitaNon = WanitaNon / TotalWanita; Keluaran (BobotPriaHyper, BobotPriaNon, BobotWanitaHyper, BobotWanitaNon) Selesai
Penerapan Algoritma:
<ol style="list-style-type: none"> Mulai Data = 60; PriaHyp = 5;

4. PriaNon = 30;
5. WanitaHyp = 14;
6. WanitaNon = 11;
7. TotalPria (35) = 5 + 30;
8. TotalWanita (25) = 14 + 11;
9. BobotPriaHyp (0.14) = 5 / 35;
10. BobotPriaNon (0.85) = 30 / 35;
11. BobotWanitaHyp (0.56) = 14 / 25;
12. BobotWanitaNon (0.44) = 11 / 25;
13. Keluaran (0.14, 0.85, 0.56, 0.44)
14. Selesai

Keterangan: Hyp=Hypertensi, Non=Non-hypertensi

Perhitungan bobot masing-masing variabel untuk kelas hipertensi dan non-hipertensi dilakukan untuk variabel lain seperti Umur, Ras, IMT, Ginjal, Asap, dan Diabetes.

Perhitungan pembobotan untuk masing-masing kelas ditunjukkan pada Tabel 3.

Tabel 3. Pembobotan berbasis aturan untuk setiap kelas

Kelas	Kelamin	Usia	Ras	BMI
Hipertensi	If Gender="Man" Then Hyp=0.14; If Gender="Woman" Then Hyp=0.56;	If (Age>70) Then Hyp=0.9; Else If (Age>66) Then Hyp=0.92; Else If (Age>55) Then Hyp=0.58, Else If (Age>40) Then Hyp=0.51; Else If (Age>30) Then Hyp=0.36; Else Hyp=0.1	If Race="Putih" Then Hyp=0.28; Else If Race="Meksiko" Then Hyp=0.5; Else If Race="Hitam" Then Hyp=0.35; Else If Race="Hispanik" Then Hyp=0.14; Else If Race="Other" Then Hyp=0; Else If Race="America" Then Hyp=0;	If BMI>31 Then Hyp=1, Else If BMI>30 Then Hyp=0.39, Else If BMI>25 Then Hyp=0.25, Else Hyp=0.42
Non	If Gender="Man" Then Non=0.86; If Gender="Woman" Then Non=0.52;	If (Age>70) Then Non=0.1, Else If (Age>66) Then Non=0, Else If (Age>55) Then Non=0.08, Else If (Age>40) Then Non=0.51, Else If (Age>30) Then Non=0.64; Else Non=0.9;	If Race="Putih" Then Non=0.72, Else If Race="Mexico" Then Non=0.5, Else If Race="Hitam" Then Non=0.5, Else If Race="Hispanic" Then Non=0.86, Else If Race=" Other" Then Non=1, Else If Race="America" Then Non=1,	If BMI>31 Then Non=0, Else If BMI>30 Then Non=0.61, Else If BMI>25 Then Non=0.75, Else Non=0.58;
Kelas	Ginja	Merokok	Diabetes	
Hipertensi	If Ginjal="Ya" Then Hyp=1, Else If Ginjal="No" Then Hyp=0.29;	If Merokok="Ya" Then Hyp=0.37, Else Merokok="No" Hyp=0.26;	Then If Then	If Diabetes="Ya" Then Hyp=0.8, Else If Diabetes="No" Then Hyp=0.27;
Non	If Ginjal="Ya" Then Non=0, Else If Ginjal="No" Then Hyp=0.71;	If Merokok="Ya" Then Non=0.63, Else Merokok="No" Non=0.74;	Then If Then	If Diabetes="Ya" Then Non=0.2, Else If Diabetes="No" Then Non=0.73;

Keterangan : Hyp = Hipertensi, Non=Non-Hipertensi

Pembobotan pasien untuk ID="93610", Jenis Kelamin="Laki-Laki", Usia=51, Ras=Hispanik, BMI=25, Ginjal=Tidak, Asap=Ya, dan Diabetes=Tidak.

Berdasarkan data tersebut, kemudian dihitung nilai bobot untuk masing-masing variabel yang ditunjukkan pada Tabel 4

Tabel 4. Pembobotan untuk hipertensi, dan non-kelas

No	Kelamin	Usia	Ras	BMI	Ginjal	Merokok	Diabetes
93610	Pria	51	Hispanic	25	No	Ya	No

Kelas	Nilai						
Hipertensi	0.14	0.51	0.14	0.25	0.29	0.37	0.27
Non	0.86	0.49	0.86	0.75	0.71	0.63	0.73

3.6 Penerapan Metode Profile Matching

3.6.1 Core Factor (CF) and Secondary Factor (SF)

Faktor inti adalah kelompok parameter utama. Sedangkan faktor sekunder merupakan kelompok parameter yang tidak mempunyai pengaruh kuat terhadap hasil diagnosis risiko hipertensi. Pengelompokan variabel CF dan SF berdasarkan perhitungan menggunakan algoritma Decision Tree. Variabel yang dibagi menjadi faktor inti dan faktor sekunder ditunjukkan pada Tabel 5.

Tabel 5. Variable core factor (CF) dan secondary factor (SF)

Core Factor	Secondary Factor
1. Usia	1. Jenis Kelamin
2. BMI	2. Ras
3. Diabetes	3. Ginjal
	4. Merokok

Tahap selanjutnya melakukan perhitungan untuk mendapatkan nilai rata-rata CF dan SF. Perhitungan nilai rata-rata ditunjukkan pada Tabel 6-7

Tabel 6. Rata-rata nilai CF dan SF untuk kelas hipertensi

Nilai Core Factor	Nilai Secondary Factor
$CF = \frac{\sum CF}{\sum IC}$ $CF = \frac{(0.51+0.25+0.27)}{(3)} = 0.343$	$SF = \frac{\sum SF}{\sum IS}$ $SF = \frac{(0.14+0.14+0.29+0.37)}{(4)} = 0.235$

Table 7. Rata-rata nilai CF dan SF untuk kelas non-hipertensi

Nilai Core Factor	Nilai Secondary Factor
$CF = \frac{\sum CF}{\sum IC}$ $CF = \frac{(0.49+0.75+0.73)}{(3)} = 0.650$	$SF = \frac{\sum SF}{\sum IS}$ $SF = \frac{(0.86+0.86+0.71+0.63)}{(4)} = 0.690$

3.7 Klasifikasi Risiko Hipertensi

Penentuan klasifikasi risiko hipertensi dilakukan dengan menghitung masing-masing kelas untuk kelas hipertensi dan non-hipertensi. Perhitungan dilakukan dari bobot variabel CF sebesar 60% dan bobot variabel SF sebesar 40%. Perhitungan klasifikasi risiko hipertensi menggunakan persamaan berikut::

Hipertensi

$$= (60 * CF) + (40 * SF)$$

$$= (60 * 0.343) + (40 * 0.235)$$

$$= 20.58 + 9.4$$

$$= \mathbf{30.00}$$

Bukan-hipertensi

$$= (45 * CF) + (25 * SF)$$

$$= (38 * 0.650) + (23 * 0.690)$$

$$= 29.25 + 17.24$$


$$= \mathbf{42.49}$$

Berdasarkan nilai total masing-masing kelas, kelas yang memiliki skor tertinggi menjadi keputusan dalam diagnosis.

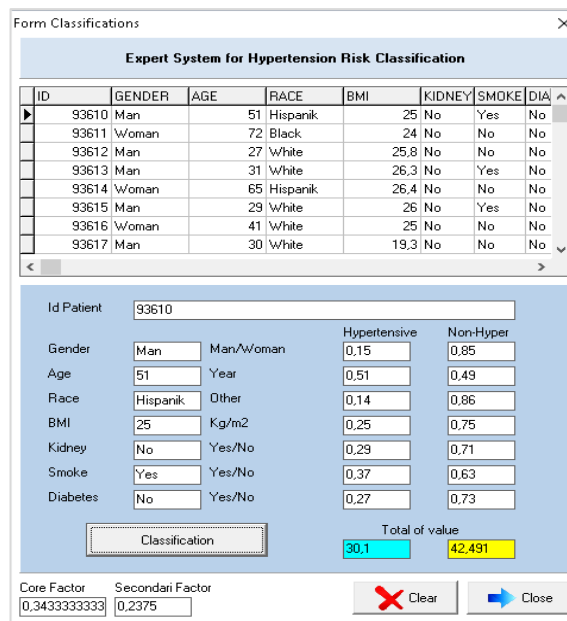
4 Pembahasan dan Hasil

4.1 Sistem Pakar

Aplikasi yang dikembangkan menggunakan bahasa pemrograman Pascal dari Delphi IDE dengan Ms. Access. Tampilan halaman utama aplikasi ditunjukkan pada Gambar 2. Halaman utama digunakan untuk memanggil halaman lain yang memiliki 2 menu yaitu menu klasifikasi dan menu tutup. Menu klasifikasi memiliki submenu untuk memanggil halaman perhitungan klasifikasi dan menutup aplikasi memiliki submenu keluar yang digunakan untuk keluar dari aplikasi



Gambar 3. Menu utama antarmuka pengguna Halaman perhitungan klasifikasi ditunjukkan pada Gambar 3. Pengguna dapat menginput data berdasarkan variabel pasien kemudian menekan tombol “klasifikasi” maka aplikasi akan menghitung nilai setiap kelas. Nilai kelas yang lebih tinggi adalah hasil dari keputusan risiko hipertensi



Gambar 4. Risiko klasifikasi antarmuka pengguna

Berdasarkan hasil perhitungan dari pasien "ID = 93610" dengan variabel jenis kelamin = "laki-laki", umur = 51, ras = "Hispanik", BMI = 25, ginjal = "Tidak", Asap = "Ya" dan diabetes = "Tidak" maka diprediksi tidak memiliki risiko tinggi terkena hipertensi. Hasil klasifikasi lengkap ditunjukkan pada Tabel 8

Table 8. Hasil klasifikasi risiko hipertensi


No	Kelamin	Usia	Ras	BMI	Ginjal	Merokok	Diabetes	Kelas		Sukses
								Dataset	Sistem Usulan	
1	Pria	51	Hispanic	25	Tidak	Ya	Tidak	Non	Non	Ya
2	Wanita	72	Hitam	24	Tidak	Tidak	Tidak	Hipertensi	Hipertensi	Ya
3	Pria	27	Putih	25,8	Tidak	Tidak	Tidak	Non	Non	Ya
4	Pria	31	Putih	26,3	Tidak	Ya	Tidak	Non	Non	Ya
5	Wanita	65	Hispanic	26,4	Tidak	Tidak	Tidak	Non	Non	Ya
6	Pria	29	Putih	26	Tidak	Ya	Tidak	Non	Non	Ya
7	Wanita	41	Putih	25	Tidak	Tidak	Tidak	Non	Non	Ya
8	Pria	30	Putih	19,3	Tidak	Tidak	Tidak	Non	Non	Ya
9	Pria	29	Putih	28	Tidak	Ya	Tidak	Non	Hipertensi	Tidak
10	Pria	50	Putih	26,2	Tidak	Tidak	Tidak	Non	Non	Ya
11	Pria	28	Hitam	22,8	Tidak	Ya	Tidak	Non	Non	Ya
12	Wanita	61	Hitam	30	Tidak	Tidak	Tidak	Hipertensi	Hipertensi	Ya
13	Wanita	27	Hitam	26	Tidak	Tidak	Tidak	Non	Non	Ya
14	Pria	60	Hispanic	25	Tidak	Tidak	Tidak	Non	Non	Ya
15	Pria	40	Putih	19	Tidak	Ya	Tidak	Non	Non	Ya
16	Wanita	70	Mexico	24	Tidak	Tidak	Tidak	Hipertensi	Hipertensi	Ya
17	Pria	77	Putih	23,8	Ya	Ya	Ya	Hipertensi	Hipertensi	Ya
18	Wanita	74	Putih	29	Tidak	Ya	Tidak	Hipertensi	Hipertensi	Ya
19	Wanita	68	Hitam	24,6	Tidak	Ya	Tidak	Hipertensi	Hipertensi	Ya
20	Wanita	39	Hitam	25	Tidak	Tidak	Tidak	Non	Non	Ya

21	Pria	36	Putih	30	Tidak	Ya	Tidak	Non	Non	Ya
22	Pria	65	Hitam	30,2	Tidak	Ya	Tidak	Non	Non	Ya
23	Pria	60	Putih	19	Tidak	Ya	No	Non	Non	Ya
24	Pria	55	Mexico	22	Tidak	Ya	Ya	Hipertensi	Hipertensi	Ya
25	Wanita	44	Hispanic	32	Tidak	Tidak	Tidak	Hipertensi	Hipertensi	Ya
26	Pria	56	Putih	25,9	Tidak	Ya	Tidak	Non	Non	Ya
27	Pria	30	Hispanic	26,2	Tidak	Tidak	Tidak	Non	Non	Ya
28	Pria	28	Putih	18,6	Tidak	Tidak	Tidak	Non	Non	Ya
29	Pria	60	Mexico	25,2	Tidak	Ya	Tidak	Non	Non	Ya
30	Pria	29	Mexico	19	Tidak	Ya	Tidak	Non	Non	Ya
31	Pria	58	Putih	30,1	Tidak	Tidak	Tidak	Non	Non	Ya
32	Pria	39	Putih	19	Tidak	Ya	Tidak	Non	Non	Ya
33	Wanita	77	Putih	26,8	Tidak	Ya	Tidak	Hipertensi	Hipertensi	Ya
34	Wanita	62	Hitam	24,9	Tidak	Ya	Tidak	Hipertensi	Hipertensi	Ya
35	Wanita	32	Hitam	25	Tidak	Tidak	Tidak	Non	Non	Ya
36	Pria	39	Putih	30	Tidak	Ya	Tidak	Non	Non	Ya
37	Pria	55	Putih	18,5	Tidak	Ya	Tidak	Non	Non	Ya
38	Pria	57	Mexico	25	Tidak	Tidak	Ya	Non	Hipertensi	Tidak
39	Pria	60	Mexico	24,7	Tidak	Ya	Ya	Hipertensi	Hipertensi	Ya
40	Woman	41	Putih	32	Tidak	Tidak	Tidak	Hipertensi	Hipertensi	Ya
41	Woman	72	Hitam	24,6	Tidak	Ya	Tidak	Hipertensi	Hipertensi	Ya
42	Woman	50	Other	18,4	Tidak	Tidak	Tidak	Non	Non	Ya
43	Man	38	Hitam	30,2	Tidak	Tidak	Tidak	Non	Non	Ya
44	Woman	70	Mexico	29,8	Tidak	Tidak	Ya	Hipertensi	Hipertensi	Ya
45	Man	35	Hispanic	30,1	Tidak	Tidak	Tidak	Non	Non	Ya
46	Man	30	Other	19	Tidak	Tidak	Tidak	Non	Non	Ya
47	Woman	78	Putih	32	Ya	Ya	Tidak	Hipertensi	Hipertensi	Ya
48	Man	36	Putih	25,3	Tidak	Ya	Tidak	Non	Non	Ya
49	Woman	30	Putih	20,3	Tidak	Tidak	Tidak	Non	Non	Ya
50	Man	76	Hitam	30,4	Tidak	Tidak	Tidak	Hipertensi	Hipertensi	Ya
51	Man	46	Putih	30	Tidak	Ya	Tidak	Non	Non	Ya
52	Woman	25	Other	19	Tidak	Tidak	Tidak	Non	Non	Ya
53	Woman	56	Hispanic	30	Tidak	Tidak	Tidak	Non	Non	Ya
54	Man	30	Putih	25	Tidak	Ya	Tidak	Non	Non	Ya
55	Woman	28	Putih	18,6	Tidak	Tidak	Tidak	Non	Non	Ya
56	Woman	53	Putih	24,9	Tidak	Ya	Tidak	Hipertensi	Hipertensi	Ya
57	Man	27	Putih	19	Tidak	Ya	Tidak	Non	Non	Ya
58	Woman	71	Putih	20	Tidak	Tidak	Tidak	Hipertensi	Hipertensi	Ya
59	Woman	35	Mexico	26	Tidak	Tidak	Tidak	Non	Non	Ya
60	Man	75	America	27	Tidak	Ya	Tidak	Non	Non	Ya

Kid=Ginjal, Smo=Merokok, Dia=Diabetes. Sources: <https://github.com/sysdevelopment/phd> [31]

Berdasarkan hasil klasifikasi risiko pada Tabel 8, terdapat perbedaan jumlah klasifikasi untuk hipertensi dan jumlah

non-hipertensi. Jumlah kelas yang direkomendasikan ditunjukkan dalam bentuk grafik pada Gambar 5



Gambar 5. Bagan perbandingan kelas

4.2 Evaluations

Untuk mengukur kinerja aplikasi yang diusulkan, perlu dilakukan perhitungan untuk mendapatkan nilai akurasi. Perhitungan ketelitian adalah pengukuran untuk mengetahui tingkat kedekatan besaran dengan nilai sebenarnya. Perhitungan akurasi menggunakan persamaan berikut:

$$Confidence\ Indicator\ (CI) = \frac{success\ number}{total\ number\ of\ test} * 100$$

$$Confidence\ Indicator\ (CI) = \frac{58}{60} * 100 = 96.67\%$$

Hasil perhitungan confidence indicator (CI) menunjukkan bahwa metode yang diusulkan dapat mengklasifikasikan dengan benar sebanyak 58 dari 60 data. Selain confidence indicator (CI), juga dihitung dengan menggunakan confusion matrix pada Tabel 9 untuk mendapatkan nilai sensitivitas, spesifisitas, presisi, dan akurasi.

Tabel 9. Perbandingan nilai prediksi dan aktual

Actual Table	Prediction table	
	Hipertensi	Non-Hipertensi
Kelas		
Hipertensi	18	1
Non	1	40

Langkah selanjutnya adalah menghitung nilai akurasi, presisi, dan recall menggunakan variabel : TP = Benar positif, FN = Negatif salah, FP = Positif salah, TN = Benar negatif seperti Tabel 10.

Tabel 10. Variabel evaluasi

Evaluasi	Metode Usulan
TP = True Positive	58
TN = True Negative	58
FN = False Negative	2
FP = False Prositve	2

$$Sensitivity = \frac{TP}{TP + FN} = \frac{58}{(58 + 2)} = 96.67\% \quad (5)$$

$$Specificity = \frac{TN}{TN + FP} = \frac{58}{58 + 2} = 96.14\% \quad (6)$$

$$Precision = \frac{TP}{TP + FP} = \frac{58}{58 + 2} = 96.16\% \quad (7)$$

$$Classification\ Accuracy = \frac{TP + TN}{(TP + FP + TN + FN)} = \frac{58 + 58}{(58 + 2 + 58 + 2)} = 96.67\% \quad (8)$$

Berdasarkan Tabel 9, nilai sensitivitas, spesifisitas, presisi, dan akurasi ditunjukkan pada Tabel 11.

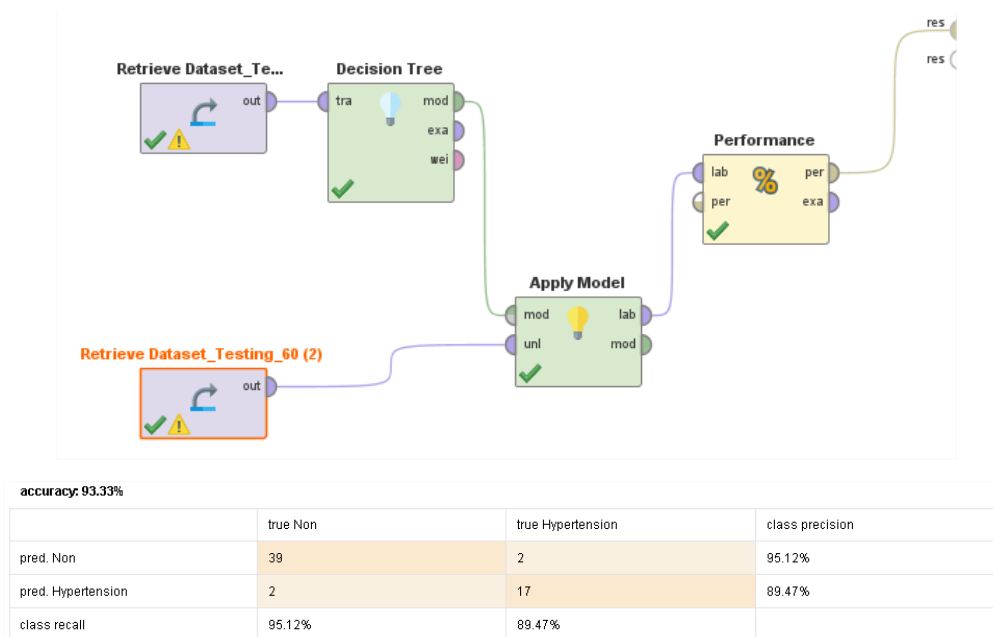
Tabel 11. Sensitivity, specificity, precision, dan accuracy

Sensitivity	Specificity	Precision	Accuracy
96.67%	96.14	96.16	96.67

4.3 Perbandingan Sistem Usulan


Metode usulan yang dikembangkan dibandingkan dengan metode klasifikasi lainnya menggunakan software

Rapid Miner Studio. Hasil pengujian menggunakan salah satu metode klasifikasi Decision Tree ditunjukkan pada Gambar 5.



Gambar 6. Pohon keputusan algoritma akurasi

Selain pohon keputusan, uji akurasi dibandingkan dengan metode klasifikasi lain seperti pohon acak, tunggul keputusan, KNN, nave BaYa, pembelajaran mendalam, induksi aturan. Hasil perbandingan akurasi ditunjukkan pada Gambar 7..



Gambar 7. Perbandingan akurasi algoritma klasifikasi

5 Kesimpulan

Penelitian ini menggunakan pendekatan yang berbeda untuk klasifikasi risiko hipertensi. Metode yang digunakan adalah rule-based weighting menggunakan fungsi IF-then yang dikombinasikan dengan metode profile matching. Pengujian sistem yang diusulkan menggunakan 60 (enam puluh) data uji dari Pima Indian Hipertensi Data dari UCI Machine Learning Repository. Pengujian dilakukan dengan membandingkan data pengujian dengan sistem yang diusulkan, nilai akurasinya adalah 96,67%. Sistem yang diusulkan juga dibandingkan dengan metode klasifikasi lain seperti Decision Tree, Random Tree, Decision Stump, KNN, Naïve BaYa, Deep

Learning, dan Rule Induction. Hasil perbandingan menunjukkan bahwa sistem yang diusulkan memiliki tingkat akurasi yang lebih baik, sehingga dapat digunakan untuk mengklasifikasikan risiko untuk jenis penyakit lainnya..

Data Sumber

Kumpulan data yang digunakan dari NHANES pada 2015–2016. Dataset ini ditujukan untuk akses publik dan pemanfaatan layanan kesehatan. Kumpulan data ini disiapkan dan diterbitkan melalui Pusat Pengendalian dan Pencegahan Penyakit (CDC) untuk memberikan akses penuh. Kumpulan data asli terdiri dari lima folder dari 2007 hingga 2016, masing-masing berisi file pdf dengan statistik tingkat respons survei NHANES dan file SAS Transport untuk semua variabel pengukuran survei [31]

Daftar Pustaka

- [1] B. Rumagit, J. Pojoh, and V. Manampiring, “Studi Deskriptif Pemberian Obat Pada Pasien Hipertensi Di Puskesmas Sario,” *J. Ilm. Farm. Poltekkes Manad.*, vol. 3, no. 2, 2012.
- [2] A. J. Viera, L. W. Cohen, C. M. Mitchell, and P. D. Sloane, “High blood pressure knowledge among primary care patients with known Hipertensi: A North Carolina Family Medicine Research Network (NC-FM-RN) study,” *J. Am. Board Fam. Med.*, vol. 21, no. 4, pp. 300–308, 2008, doi: 10.3122/jabfm.2008.04.070254.
- [3] B. P. Medications and M. Changes, “Treatment of Hipertensi: JNC 8 and More,” *Res. Cent.*, vol. 3120, no. February, pp. 209–472, 2014, [Online]. Available: www.PharmacistsLetter.com%5Cnwww.PrescribersLetter.com%5Cnwww.PharmacyTechniciansLetter.com.
- [4] Pusdatin, *Hipertensi*, Second., no. Hari Hipertensi Sedunia. Jakarta Selatan: Kementerian RI, 2014.
- [5] Global Road Safety Facility & IHME, “The Global Burden of Disease from Motorized Road Transport,” *World Bank Inst. Heal. Metrics Eval.*, p. 39, 2014, [Online]. Available:

- <http://documents.worldbank.org/curated/en/984261468327002120/pdf/863040IHME0T4H0ORLDO0BANK0compressed.pdf>.
- [6] J. R. Banegas *et al.*, "High prevalence of masked uncontrolled Hipertensi in people with treated Hipertensi," *Eur. Heart J.*, vol. 35, no. 46, pp. 3304–3312, 2014, doi: 10.1093/eurheartj/ehu016.
- [7] H. Soetanto, S. Hartati, R. Wardoyo, and S. Wibowo, "Hipertensi drug suitability evaluation based on patient condition with improved profile matching," *Indones. J. Electr. Eng. Comput. Sci.*, 2018, doi: 10.11591/ijeecs.v11.i2.pp453-461.
- [8] A. A. Abdullah, Z. Zakaria, and N. F. Mohammad, "Design and development of Fuzzy Expert System for diagnosis of Hipertensi," *Proc. - 2011 2nd Int. Conf. Intell. Syst. Model. Simulation, ISMS 2011*, no. February 2017, pp. 113–117, 2011, doi: 10.1109/ISMS.2011.27.
- [9] X. Y. Djam and Y. H. Kimbi, "Fuzzy Expert System for the Management of Hipertensi," *Pacific J. Sci. Technol.*, vol. 12, no. 1, pp. 390–402, 2011, [Online]. Available: <http://www.akamaiuniversity.us/PJST.htm>.
- [10] S. Das, P. K. Ghosh, and S. Kar, "Hipertensi diagnosis: A comparative study using fuzzy expert system and neuro fuzzy system," *IEEE Int. Conf. Fuzzy Syst.*, no. 2005, 2013, doi: 10.1109/FUZZ-IEEE.2013.6622434.
- [11] P. Srivastava, A. Srivastava, A. Burande, and A. Khandelwal, "A Note on Hipertensi Klasifikasi Scheme and Soft Computing Decision Making System," *ISRN Biomath.*, vol. 2013, pp. 1–11, 2013, doi: 10.1155/2013/342970.
- [12] A. Kaur and A. Bhardwaj, "Genetic Neuro Fuzzy System for Hipertensi Diagnosis," *Citeseer*, vol. 5, no. 4, pp. 4986–4989, 2014, [Online]. Available: www.ijcsit.com.
- [13] R. Kaur and A. Kaur, "Hipertensi Diagnosis Using Fuzzy Expert System," *Int. J. Eng. Res. Appl.*, vol. 14, no. March, pp. 2248–9622, 2015, [Online]. Available: <https://pdfs.semanticscholar.org/b7ad/d498b2927d35640946c249158de32d33f21f.pdf>.
- [14] Z. Abrishami and H. Tabatabaee, "Design of A Fuzzy Expert System And A Multi-Layer Neural Network System For Diagnosis Of Hipertensi," *Pharmacol. Life Sci. Bull. Env. Pharmacol. Life Sci.*, no. 11, pp. 138–145, 2015, [Online]. Available: <https://pdfs.semanticscholar.org/0753/baef3fb0659fac026017a2c23a2752c55f04.pdf>.
- [15] J. C. Guzmán, P. Melin, and G. Prado-Arechiga, "A proposal of a fuzzy system for Hipertensi diagnosis," *Adv. Intell. Syst. Comput.*, vol. 401, pp. 341–350, 2016, doi: 10.1007/978-3-319-26211-6_29.
- [16] I. P. Adebayo, "Idowu Peter Adebayo. Predictive Model for the Klasifikasi of Hipertensi Risk Using Decision Trees Algorithm," *Am. J. Math. Comput. Model.*, vol. 2, no. 2, pp. 48–59, 2017, doi: 10.11648/j.ajmcm.20170202.12.
- [17] J. C. Guzmán, P. Melin, and G. Prado-Arechiga, "Fuzzy optimized Klasifikasi for the diagnosis of blood pressure using genetic algorithm," *Stud. Comput. Intell.*, vol. 749, pp. 309–318, 2018, doi: 10.1007/978-3-319-71008-2_23.
- [18] I. Z. Jibril, J. Agajo, L. A. Ajao, J. G. Kolo, and O. C. Inalegwu, "Development of a Medical Expert System for Hypertensive Patients Diagnosis: A Knowledge-Based Rules," *Adv. Electr. Telecommun. Eng.*, vol. 1, no. 1, pp. 39–47, 2018.
- [19] I. Miramontes, G. Martínez, P. Melin, and G. Prado-Arechiga, "A hybrid intelligent system model for Hipertensi risk diagnosis," *Adv. Intell. Syst. Comput.*, vol. 648, pp. 202–213, 2018, doi: 10.1007/978-3-319-67137-6_22.
- [20] W. Jie, P. Yan, R. Xiaoxiao, and Q. Yixuan, *An expert system for diagnosis and treatment of Hipertensi based on ontology*, vol. 952. Springer Singapore, 2018.
- [21] P. Melin, I. Miramontes, and G. Prado-Arechiga, "A hybrid model based on modular neural networks and fuzzy systems for Klasifikasi of blood pressure and Hipertensi risk diagnosis," *Expert Syst. Appl.*, vol. 107, pp. 146–164, 2018, doi: 10.1016/j.eswa.2018.04.023.
- [22] P. Melin and G. Prado-Arechiga, "Neuro-fuzzy modular approaches for Klasifikasi of arterial Hipertensi with a method for the expert rules optimization," *SpringerBriefs Appl. Sci. Technol.*, vol. 0, no. 9783319611488, pp. 23–47, 2018, doi: 10.1007/978-3-319-61149-5_4.
- [23] M. S. Hossain, Fatema-Tuj-Johora, and K. Andersson, "A belief rule based expert system to assess Hipertensi under uncertainty," *J. Internet Serv. Inf. Secur.*, vol. 9, no. 4, pp. 18–38, 2019, doi: 10.22667/JISIS.2019.11.30.018.
- [24] R. Elshawi, M. H. Al-Mallah, and S. Sakr, "On the interpretability of machine learning-based model for predicting Hipertensi," *BMC Med. Inform. Decis. Mak.*, vol. 19, no. 1, 2019, doi: 10.1186/s12911-019-0874-0.
- [25] M. A. J. Tengnah, R. Sooklall, and S. D. Nagowah, *A predictive model for Hipertensi diagnosis using machine learning techniques*. Elsevier Inc., 2019.
- [26] W. Chang *et al.*, "A machine-learning-based prediction method for Hipertensi outcomes based on medical data," *Diagnostics*, vol. 9, no. 4, 2019, doi: 10.3390/diagnostics9040178.
- [27] N. A. Shiraz H.E., "Using Fuzzy Logic to Enhance the Klasifikasi and Diagnosing of Hypertention," *J. Theor. Appl. Inf. Technol.*, vol. 97, no. 20, pp. 2430–2440, 2019.
- [28] M. Nour and K. Polat, "Automatic Klasifikasi of Hipertensi Types Based on Personal Features by Machine Learning Algorithms," *Math. Probl. Eng.*, vol. 2020, pp. 1–14, 2020, doi: 10.1155/2020/2742781.
- [29] M. Ambika, G. Raghuraman, and L. SaiRamesh, "Enhanced decision support system to predict and prevent Hipertensi using computational intelligence techniques," *Soft Comput.*, vol. 24, no. 17, pp. 13293–13304, 2020, doi: 10.1007/s00500-020-04743-9.
- [30] S. P. Chatrati *et al.*, "Smart home health monitoring system for predicting type 2 diabetes and Hipertensi," *J. King Saud Univ. - Comput. Inf. Sci.*, no. xxxx, 2020, doi: 10.1016/j.jksuci.2020.01.010.
- [31] F. López-Martínez, E. R. Núñez-Valdez, R. G. Crespo, and V. García-Díaz, "An artificial neural network approach for predicting Hipertensi using NHANES data," *Sci. Rep.*, vol. 10, no. 1, pp. 1–14, 2020, doi: 10.1038/s41598-020-67640-z.
- [32] B. Williams and S. Cremaschi, "Klasifikasi Models," *Comput. Aided Chem. Eng.*, p. 5, 2020.
- [33] A. Suhartanto, "Decision Support System untuk Penilaian Kinerja Guru dengan Metode Profile Matching," *J. Komput. Terap.*, vol. 2, no. 2, pp. 149–158, 2016.