

MODEL PREDIKTIF IDENTIFIKASI TERSANGKA TUBERKULOSIS DAN DEMAM BERDARAH MENGGUNAKAN DATA MINING

I Putu Dody Lesmana¹⁾, Faiqatul Hikmah²⁾, Rinda Nurul Karimah³⁾

¹⁾ Jurusan Teknologi Informasi, Politeknik Negeri Jember

²⁾³⁾ Jurusan Kesehatan, Politeknik Negeri Jember

Jl. Mastrip Jember Kotak Pos 164 68101, Jawa Timur

Email : dody@polije.ac.id¹⁾, ic2207@gmail.com²⁾, rinda_md@yahoo.com³⁾

Abstrak

Penyakit menular Tuberkulosis (TB) dan Demam Berdarah Dengue (DBD) merupakan dua diantara lima penyakit menular tertinggi di Indonesia. Tingginya angka insidensi dan angka kematian yang disebabkan TB dan DBD mendorong para ahli kesehatan untuk menemukan dan mencegah sedini mungkin perkembangan penyakit TB dan DBD. Karena patogenesis TB dan DBD yang kompleks dan bervariasi, maka diperlukan banyak pemeriksaan medis dalam mendiagnosis TB dan DBD yang akurat. Sebagai bentuk pencegahan dini, diperlukan suatu model prediktif untuk mengidentifikasi tersangka TB dan DBD dalam membantu penegakan diagnosis dokter lebih akurat. Pada penelitian ini dikembangkan model prediktif untuk identifikasi tersangka TB dan DBD dari fitur dominan pemeriksaan medis menggunakan metode jaringan saraf tiruan (JST)-Backpropagation. Penentuan fitur dominan dilakukan dengan data mining, seleksi fitur, menggunakan Fuzzy Entropy dari dataset rekam medis rawat inap penderita TB dan DBD. Dari hasil seleksi fitur dataset TB didapatkan empat fitur dominan teratas meliputi nyeri penekanan, keadaan kulit (gatal-gatal/dekubitus), edema, dan batuk lebih dari tiga minggu. Sedangkan lima fitur dominan teratas DBD meliputi inspeksi saluran pernapasan, integritas kulit (timbul luka/bercak pada kulit), perubahan warna kulit, dan kardiovaskuler auskultasi, dan keteraturan nadi. Hasil pengujian terbaik dari seleksi fitur untuk identifikasi tersangka TB dan DBD didapatkan pada penggunaan tujuh fitur dominan teratas dengan akurasi diatas 88% dan AUC diatas 0.8. Hal ini menunjukkan model prediktif JST-Backpropagation dapat secara akurat mengidentifikasi tersangka TB dan DBD dengan baik dan dapat digunakan sebagai sistem pendukung keputusan untuk diagnosis penderita TB dan DBD.

Kata kunci: TB, DBD, rekam medis, seleksi fitur, fuzzy entropy, JST-Backpropagation, model prediktif.

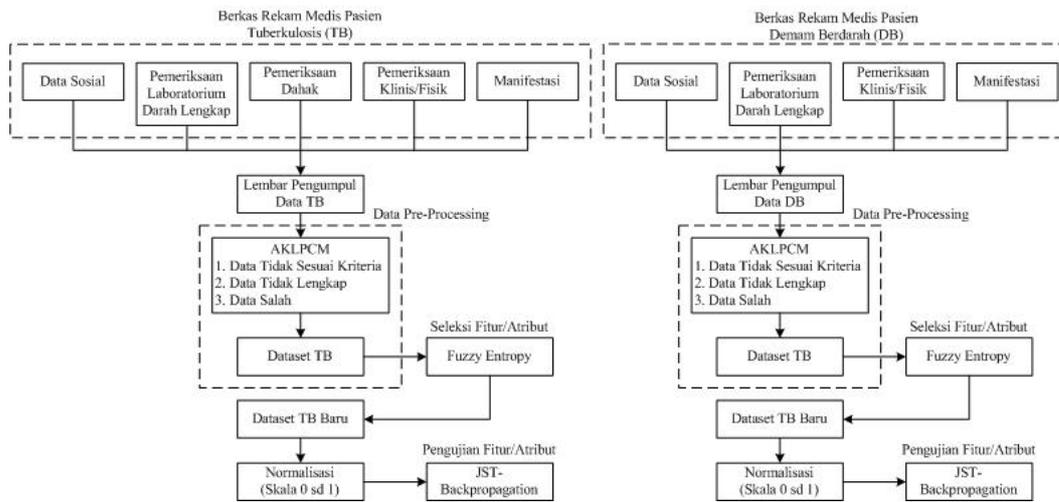
1. Pendahuluan

Salah satu sasaran strategis pembangunan kesehatan tahun 2010-2014, yaitu menurunnya angka kesakitan akibat penyakit menular. Penyakit menular Tuberkulosis (TB) dan Demam Berdarah Dengue (DBD) merupakan

dua diantara lima penyakit menular tertinggi di Indonesia [1,2]. Walaupun strategi DOTS (*Directly Observed Treatment Short Course*) telah terbukti sangat efektif untuk pengendalian TB, tetapi beban penyakit TB di masyarakat masih sangat tinggi. Waktu pengobatan yang panjang dengan jenis obat lebih dari satu menyebabkan penderita sering terancam putus berobat selama masa penyembuhan [3]. Alasan ini menyebabkan situasi TB di dunia semakin memburuk dengan jumlah kasus yang terus meningkat serta banyak yang tidak berhasil disembuhkan sehingga menimbulkan TB resisten obat dan TB/HIV [3,4]. Tidak jauh berbeda dengan TB, DBD merupakan penyakit menular dengan siklus epidemik tertinggi di Indonesia. Terhitung sejak tahun 1968 hingga tahun 2009, WHO mencatat negara Indonesia sebagai negara dengan kasus DBD tertinggi di Asia Tenggara [5].

Karena patogenesis penyakit TB dan DBD yang variatif dan memerlukan pemeriksaan yang kompleks, baik pemeriksaan fisik, anamnesa, laboratorium, radiologi, patologi anatomi, dan manifestasi [7]-[9], maka dibutuhkan pengetahuan medis kedokteran dan pengalaman dalam penanganan TB dan DBD untuk memprediksi kemungkinan seseorang teridentifikasi sebagai tersangka penderita TB atau tersangka penderita DBD. Sebagai langkah awal dalam pengidentifikasian penyakit TB dan DBD diperlukan suatu model prediktif dalam mengidentifikasi tersangka TB dan tersangka DBD dalam membantu penegakan diagnosis dokter secara cepat dan akurat sehingga akan meningkatkan kualitas pengobatan dan pencegahan timbulnya atau berkembangnya penyakit TB dan DBD yang lebih kompleks.

Seiring dengan kemajuan di bidang teknologi informasi, komputer dapat menggali informasi dan ilmu pengetahuan yang ada pada sekumpulan data, yang hal ini disebut *data mining* [10]. Pada penelitian ini, proses *data mining* dilakukan dengan mengumpulkan data sosial, pemeriksaan fisik, anamnesa, laboratorium, patologi anatomi dan manifestasi dari berkas rekam medis penderita TB dan penderita DBD yang ada di beberapa rumah sakit di kabupaten Jember. Data yang didapat dan dikumpulkan menjadi satu menghasilkan dataset TB dan dataset DBD untuk dilakukan pengolahan dan analisa dalam penentuan identifikasi



Gambar 1. Diagram Sistem Penelitian Pembentukan Model Prediktif Tersangka TB dan Tersangka DBD

tersangka TB dan bukan TB (tersangka Efusi Pleura dan tersangka penyakit paru obstruktif kronik/PPOK) serta identifikasi tersangka DBD (*Dengue Haemorrhagic Fever/DHF*) dan bukan DBD (tersangka *Dengue Fever/DF*).

Pada penelitian ini, dari dataset TB dan DBD dilakukan proses seleksi fitur dari keseluruhan atribut pemeriksaan TB dan DBD dengan menggunakan metode *Fuzzy Entropy* [11]. Seleksi fitur dilakukan untuk mereduksi dimensi dataset dengan membuang fitur yang tidak memberikan pengaruh yang signifikan bagi identifikasi tersangka TB dan DBD. Dataset TB dan DBD hasil seleksi fitur dominan menjadi masukan bagi model prediktif yang dihasilkan menggunakan jaringan saraf tiruan (*JST-Backpropagation*) [12]. Akurasi keluaran model prediktif *JST-Backpropagation* untuk identifikasi tersangka TB dan tersangka DBD dari masukan dataset fitur yang dipilih diuji menggunakan *10-fold cross validation* dan dilakukan perhitungan *Area Under Curve* (AUC) yang dihasilkan. Desain sistem penelitian ditunjukkan pada Gambar 1.

2. Metode Penelitian

2.1 Pembentukan Dataset TB dan DBD

Dataset mentah TB diperoleh dari pengumpulan 870 data dari berkas rekam medis rawat inap penderita TB dan bukan TB di Rumah Sakit (RS) Paru Jember selama kurun waktu tahun 2008 sampai dengan tahun 2012. Fitur dataset mentah TB ini terdiri dari 47 item pemeriksaan yang tercatat pada berkas rekam medis RS Paru Jember dengan urutan pencatatan pada lembar pengumpul data (LPD) sesuai dengan Tabel 1. Sedangkan dataset mentah DBD diperoleh dari pengumpulan 1215 data dari berkas rekam medis rawat inap penderita DBD dan bukan DBD di Rumah Sakit Daerah (RSD) dr. Soebandi Jember selama kurun waktu tahun 2008 sampai dengan tahun 2012. Fitur dataset mentah DBD ini terdiri dari 44 item pemeriksaan yang tercatat pada berkas rekam medis RSD dr. Soebandi

Jember dengan urutan pencatatan pada lembar pengumpul data (LPD) sesuai dengan Tabel 2.

2.2 Data Pre-Processing

Setelah dataset mentah TB dan DBD terkumpul pada LPD, kemudian dilakukan proses AKLPCM untuk memeriksa angka kelengkapan rekam medis. Proses AKLPCM ini mengeliminasi data yang tidak sesuai kriteria, data tidak lengkap, dan data salah. Dari hasil AKLPCM didapatkan 620 dataset TB yang terdiri dari 486 data TB dan 134 data bukan TB (64 data penderita PPOK, 70 data penderita Efusi Pleura). Sedangkan dataset DBD yang dihasilkan dari proses AKLPCM meliputi 500 data penderita DBD dan 490 bukan DBD.

2.3 Seleksi Fitur dengan *Fuzzy Entropy*

Fitur merupakan karakteristik dari suatu objek. Pada dataset yang besar tidak semua fitur adalah fitur yang penting untuk mendeskripsikan target. Oleh sebab itu, seleksi fitur diperlukan untuk memilih sebagian dari fitur yang mempresentasikan informasi yang berguna. Dalam seleksi fitur dari dataset TB dan dataset DBD digunakan *Fuzzy Entropy* [11] dengan persamaan (1).

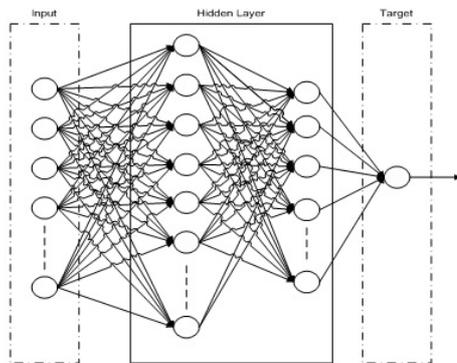
$$H_1(A) = - \sum_{j=1}^n (\mu_A(x_j) \log \mu_A(x_j) + (1 - \mu_A(x_j)) \log(1 - \mu_A(x_j))) \quad (1)$$

Dimana $\mu_A(x_j)$ adalah nilai fuzzy dari satu fitur. Semakin besar nilai entropy-nya maka kumpulan nilai dari satu fitur semakin heterogen. *Fuzzy entropy* akan mengevaluasi relevansi dari fitur yang berbeda pada himpunan fitur, dengan mengeluarkan fitur yang memiliki nilai entropy tertinggi.

2.4 Model Predktif *JST-Backpropagation*

Hasil seleksi fitur menggunakan *Fuzzy Entropy* akan menjadi input bagi model prediktif *JST-Backpropagation* [12]. Pengujian yang dilakukan pada dataset TB baru dan dataset DBD baru setelah dilakukan

normalisasi pada skala [0-1] dilakukan untuk mengetahui keakurasian identifikasi terhadap hasil seleksi fitur menggunakan *JST-Backpropagation*. Arsitektur *JST-Backpropagation* yang digunakan ditunjukkan pada Gambar 2, dimana memiliki dua layer hidden dengan jumlah 60 neuron untuk layer hidden satu dan 20 neuron untuk layer hidden dua, layer target dengan satu neuron, learning rate 0.7, maksimum *Mean Square Error* (MSE) 0.001.



Gambar 2. Arsitektur Model Prediktif Backpropagation

Tabel 1. Fitur Dataset Tuberkulosis

No	Fitur TB	Fitur DBD
1	Umur	Tahun
2	Jenis Kelamin	1. Pria ; 2. Wanita
3	Berat Badan	Kilogram
4	Hemoglobin	g/dL
5	Leukosit	/cmM
6	Hematokrit	%
7	Trombosit	U/L
8	Laju Endap Darah	/Jam
9	Sputum BTA	0. - BTA ; 1. + BTA
10	Batuk \geq 3 Minggu	0. Tidak; 1. Ya
11	Jalan Nafas	1. Bersih; 2. Sumbatan; 3. Sputum; 4. Lendir; 5. Ludah; 6. Darah
12	Irama Nafas	1. Teratur; 2. Tidak teratur
13	Suara Tambahan	1. Tidak ada; 2. Ronchi dada kanan; 3. Ronchi dada kiri; 4. Whezing dada kanan; 5. Whezing dada kiri; 6. Rales dada kanan; 7. Rales dada kiri
14	Sputum	1. Putih; 2. Kuning; 3. Lain-lain
15	Konsistensi Sputum	1. Kental; 2. Encer
16	Distensi Vena Jugularis	1. Tidak; 2. Kanan; 3. Kiri
17	Acral	1. Dingin; 2. Hangat
18	Warna Kulit	1. Pucat; 2. Kemerahan; 3. Sianosis
19	CRT	1. (\leq 3 detik); 2. (\geq 3

		detik)
20	Edema	1. Tidak; 2. Muka; 3. Tungkai bawah; 4. Tungkai atas; 5. Seluruh tubuh
21	Bunyi Jantung	1. BJ I; 2. BJ II; 3. Gallop; 4. Lemah
22	Irama Teratur	1. Ya; 2. Tidak
23	Keluhan	1. Lelah; 2. Berdebar-debar; 3. Gemetar; 4. Keringat dingin
24	Nyeri Dada	1. Tidak; 2. Saat aktifitas; 3. Tanpa aktifitas
25	Karakteristik	1. Seperti terbakar; 2. Seperti ditusuk-tusuk
26	Sklera	1. Putih; 2. Icterus
27	Conjungtiva	1. Merah muda; 2. Pucat
28	Pupil	1. Isokor; 2. Anisokor; 3. Miosis; 4. Midriasis
29	Reaksi Terhadap Cahaya	1. Negatif; 2. Positif
30	Reflek Patologis	1. Negatif; 2. Positif
31	Nyeri Saat BAK	1. Tidak; 2. Ya
32	Nyeri Pinggang	1. Tidak; 2. Ya
33	Mual/Muntah	1. Tidak; 2. Ya
34	Kembung	1. Tidak; 2. Ya
35	Bising Usus	1. Negatif; 2. Positif
36	Pembesaran Hepar	1. Tidak; 2. Ya
37	Nyeri Tekan Dada	1. Tidak; 2. Ya
38	Porsi Makan	1. Dihabiskan; 2. $\frac{3}{4}$ porsi; 3. $\frac{1}{2}$ porsi; 4. $\frac{1}{4}$ porsi
39	Turgor Kulit	1. Baik; 2. Jelek
40	Keadaan Kulit	1. Gatal-gatal; 2. Dekubitus
41	Odem Ekstremitas	1. Tidak; 2. Tangan kanan; 3. Tangan kiri; 4. Kaki kanan; 5. Kaki kiri
42	Kekuatan Otot	Skala 0-5
43	Tekanan Darah Atas	mmHg
44	Tekanan Darah Bawah	mmHg
45	Nadi	/ menit
46	Suhu	Celcius
47	Respiratory Rate	/ menit

Tabel 2. Fitur Dataset Demam Berdarah

No	Fitur TB	Fitur DBD
1	Umur	Tahun
2	Jenis Kelamin	1. Pria ; 2. Wanita
3	Hemoglobin	g/dL
4	Leukosit	/cmM
5	Hematokrit	%
6	Trombosit	U/L
7	Kesadaran	1. cm; 2. koma; 3.

		lainnya
8	GCS-Mata	1. Tidak berespon; 2. Dengan rangsang nyeri; 3. Dengan perintah; 4. Spontan
9	GCS-Verbal	1. Tidak berespon; 2. Suara tidak dapat dimengerti; 3. Kata – kata tidak tepat; 4. Bicara membingungkan; 5. Berorientasi
10	GCS-Motorik	1. Tidak berespon; 2. Ekstensi; 3. Fleksi abnormal; 4. Menarik area yang nyeri; 5. Melokalisasi nyeri; 6. Dengan perintah
11	Kondisi Pupil	1. Isokor; 2. Anisokor
12	Kejang	1. Ya; 2. Tidak
13	Keadaan Mukosa	1. Bersih; 2. Kotor
14	Bentuk Abdomen	1. Datar; 2. Busung; 3. Destended
15	Benjolan Massa	1. Terdapat benjolan masa; 2. Tidak terdapat benjolan masa
16	Nyeri Tekan Dada	1. Terdapat nyeri tekan; 2. Tidak terdapat nyeri tekan
17	BAB	1. Ya; 2. Tidak; 3. BAB lunak; 4. BAB cair; 5. BAB dan mual muntah
18	Jalan Nafas	1. Paten; 2. Sumbatan; 3. O ₂
19	Frekuensi Nafas/menit	Skala 10-50
20	Pola Nafas	1. Eupnea; 2. Takipnea; 3. Regular
21	Batuk	1. Ya; 2. Tidak
22	Sekresi Nafas	1. Ya; 2. Tidak
23	Nafas-Nyeri Tekan	1. Ya; 2. Tidak; 3. Nyeri tekan positif; 4. Nyeri tekan negatif
24	Nafas Resonan	1. Ya; 2. Tidak
25	Nyeri Saat BAK	1. Ya; 2. Tidak
26	Tekanan Darah Atas	Range 70-180
27	Tekanan Darah Bawah	Range 40-100
28	Frekuensi Nadi/menit	Range 60-170
29	Keteraturan Nadi	1. Teratur; 2. Tidak teratur; 3. Lemah
30	CRT	1. (<2 detik); 2. (>2 detik); 3. (<2 detik dan HKM)
31	Suhu	Range 10-50
32	Denyut Spek Kordis	1. Ya; 2. Tidak; 3. Inspeksi tidak tampak
33	Kardiovaskuler Palpasi	1. IC; 2. Ics 5 mc

34	Kardiovaskuler Auskultasi	1. Bunyi S1/S2 tunggal; 2. Bising jantung +; 3. Lainnya
35	Warna Kulit	1. Pucat; 2. Kemerahan; 3. Sianosis
36	Tekstur Kulit	1. Halus; 2. Kasar
37	Turgor Kulit	1. Baik; 2. Jelek
38	Integritas Kulit	1. Utuh; 2. Luka/lesi/bercak
39	Kekuatan Otot	Skala 0-5
40	Tonus	1. Ada; 2. Tidak; 3. Lemah
41	Rom	1. Bebas; 2. Terbatas
42	Fraktur	1. Tidak; 2. Ada; 3. Terbuka; 4. Tertutup
43	Nyeri Muskuluskeletal	1. Tidak; 2. Nyeri dada; 3. Nyeri perut
44	Inspeksi Saluran Pernapasan	1. Normal Chest; 2. Laserasi

3. Hasil dan Pembahasan

3.1 Pemilihan Fitur Dominan Tuberkulosis

Seleksi fitur TB dilakukan dengan menghitung nilai entropy dari 47 fitur pada dataset TB dengan persamaan (1), dimana fitur yang memiliki nilai entropy tertinggi dianggap tidak memiliki pengaruh yang signifikan terhadap penentuan tersangka TB. Pada proses seleksi fitur ini, fitur yang dianggap tidak berpengaruh diusulkan untuk dihapus, namun dalam percobaan ini fitur yang diusulkan dihapus dipindahkan pada urutan terbelakang. Tabel 3 menunjukkan urutan hasil seleksi fitur TB menggunakan *Fuzzy Entropy*, dimana empat fitur dominan teratas dari pemeriksaan TB adalah pemeriksaan nyeri tekan (fitur No. 37 pada Tabel 1) yang menempati urutan pertama, disusul pemeriksaan keadaan kulit (fitur No. 40 pada Tabel 1), edema (fitur No. 20 pada Tabel 1) dan batuk lebih dari tiga minggu (fitur No. 10 pada Tabel 1). Penempatan fitur pemeriksaan batuk lebih dari tiga minggu, nyeri tekan dada dan timbulnya edema sebagai fitur paling dominan sesuai dengan rujukan pedoman pengenalan tersangka TB oleh para ahli (dokter) dibidang kesehatan dan juga mengacu pada gejala paling umum pada TB paru.

Tabel 3. Hasil Urutan Seleksi Fitur Tuberkulosis

Metode	Urutan Hasil Seleksi Fitur
<i>Fuzzy Entropy</i>	37, 40, 20, 10, 36, 41, 32, 39, 28, 31, 29, 19, 45, 42, 44, 43, 6, 27, 4, 30, 34, 26, 3, 5, 22, 16, 23, 7, 35, 12, 47, 11, 38, 8, 1, 17, 24, 18, 14, 15, 25, 2, 33, 46, 21, 13, 9

3.2 Pemilihan Fitur Dominan Demam Berdarah

Seleksi fitur DBD dilakukan dengan menghitung nilai entropy dari 44 fitur pada dataset DBD dengan persamaan (1), dimana fitur yang memiliki nilai entropy

tertinggi dianggap tidak memiliki pengaruh yang signifikan terhadap penentuan tersangka DBD. Pada proses seleksi fitur ini, fitur yang dianggap tidak berpengaruh diusulkan untuk dihapus, namun dalam percobaan ini fitur yang diusulkan dihapus dipindahkan pada urutan terbelakang. Tabel 4 menunjukkan urutan hasil seleksi fitur DBD menggunakan *Fuzzy Entropy*, dimana lima fitur dominan teratas dari pemeriksaan DBD meliputi inspeksi saluran pernapasan (fitur No. 44 pada Tabel 2), integritas kulit dimana timbul luka/bercak pada kulit (fitur No. 38 pada Tabel 2), perubahan warna kulit (fitur No. 35 pada Tabel 2), kardiovaskuler auskultasi (fitur No. 34 pada Tabel 2), dan keteraturan nadi (fitur No. 29 pada Tabel 2). Kelima fitur dominan DBD teratas sesuai dengan rujukan pedoman pengenalan tersangka DBD oleh para ahli (dokter) dibidang kesehatan dan juga mengacu pada gejala khas pembeda pada DF dan DHF yang biasanya disertai dengan munculnya bercak merah pada kulit, perubahan kondisi/warna kulit (kulit menjadi dingin dan lembab), gangguan pada nadi (penyempitan tekanan nadi/hipotensi, nadi cepat), dan pemeriksaan kardiovaskuler secara tidak langsung/auskultasi berupa gejala adanya pembesaran hati (hepatomegali).

Tabel 4. Hasil Urutan Seleksi Fitur Demam Berdarah

Metode	Urutan Hasil Seleksi Fitur
<i>Fuzzy Entropy</i>	44, 38, 35, 34, 29, 25, 10, 9, 24, 7, 8, 18, 11, 37, 43, 42, 3, 36, 12, 33, 19, 31, 26, 28, 32, 15, 6, 27, 4, 22, 14, 41, 39, 1, 5, 16, 17, 13, 40, 21, 20, 30, 23, 2

3.3 Pengujian Akurasi Seleksi Fitur Tuberkulosis

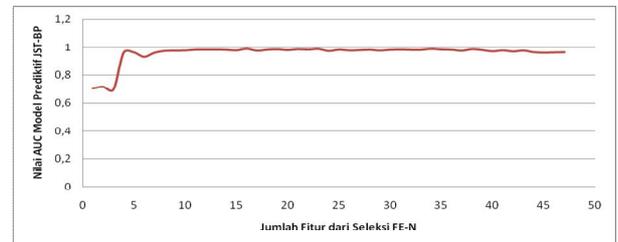
Pada pengujian ini dihitung akurasi penggunaan fitur TB terpilih sebagai input pada model prediktif *JST-Backpropagation* untuk identifikasi tersangka TB dan tersangka bukan TB. Akurasi diukur dengan menghitung nilai AUC dari 10-fold cross validation. Klasifikasi nilai AUC sesuai dengan [13].

Akurasi hasil pengujian 47 fitur sampai dengan satu fitur dari *JST-Backpropagation* ditunjukkan Gambar 3, dimana diketahui nilai akurasi dari jumlah fitur 47 sampai dengan jumlah fitur 40 sebesar 96-97%. Akurasi meningkat rata-rata 98% pada pemakaian jumlah fitur 39 sampai 10 fitur dan kemudian akurasi mengalami penurunan sampai 78%.

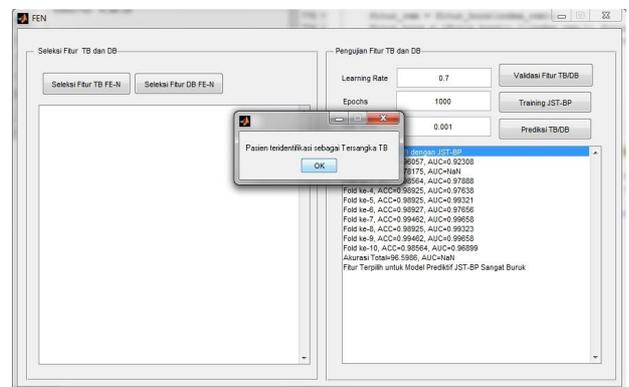
Pada Gambar 4 dapat dilihat grafik AUC untuk model prediktif *JST-Backpropagation*, dimana pada pemakaian jumlah fitur 49 sampai dengan jumlah fitur empat, model prediktif *JST-Backpropagation* dapat mengenali dengan sangat baik identifikasi tersangka TB dimana nilai $AUC > 0.9$. Contoh implementasi model prediktif *JST-Backpropagation* menggunakan 10 fitur dominan ditunjukkan pada Gambar 5.



Gambar 3. Grafik Akurasi Identifikasi Tersangka TB



Gambar 4. Grafik AUC Identifikasi Tersangka TB

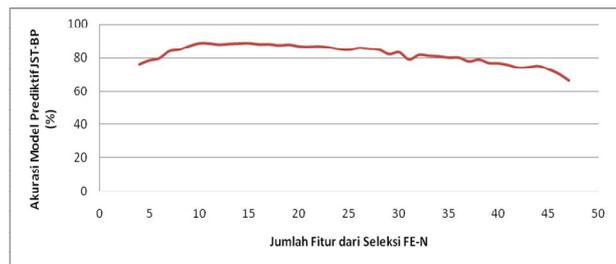


Gambar 5. Hasil Identifikasi Tersangka TB Menggunakan 10 Fitur Dominan

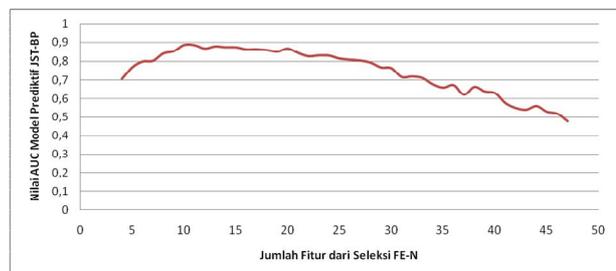
3.4 Pengujian Akurasi Seleksi Fitur Demam Berdarah

Akurasi dan nilai AUC dari hasil pengujian fitur terpilih dari 44 fitur sampai dengan jumlah fitur kesatu dari model prediktif *JST-Backpropagation* untuk identifikasi tersangka DBD ditunjukkan pada Gambar 6 dan Gambar 7. Dari Gambar 6 diketahui akurasi model *JST-Backpropagation* dari jumlah fitur 44 sampai dengan jumlah fitur 34 dibawah 80% dan $AUC < 0.7$ (Gambar 9). Untuk pemakaian jumlah fitur 33 sampai dengan jumlah fitur 25, akurasi mencapai 80-85%, tetapi nilai $AUC < 0.8$. Ini menunjukkan masih banyak kesalahan dalam mengidentifikasi dengan benar tersangka DBD berdasarkan fitur yang dimasukkan walaupun dari tingkat akurasi mengalami kenaikan.

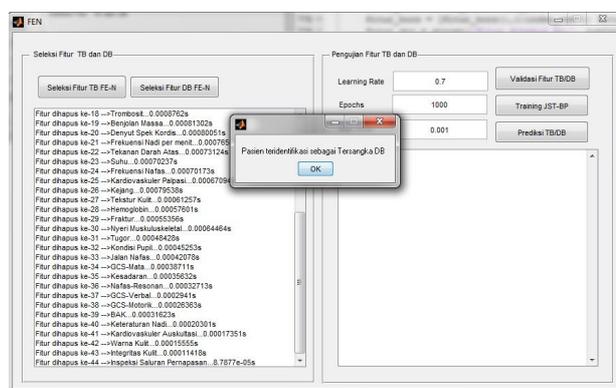
Untuk pemakaian jumlah fitur 24 sampai dengan jumlah fitur 7, akurasi mencapai 85-88% dan nilai AUC 0.8-0.9 menunjukkan model prediktif *JST-Backpropagation* untuk identifikasi tersangka DBD tergolong baik. Contoh implementasi model prediktif *JST-BP* dalam menentukan tersangka DBD menggunakan 7 fitur dominan ditunjukkan pada Gambar 8.



Gambar 6. Grafik Akurasi Identifikasi Tersangka DBD



Gambar 7. Grafik AUC Identifikasi Tersangka DBD



Gambar 8. Hasil Identifikasi Tersangka DBD Menggunakan 10 Fitur Dominan

4. Kesimpulan

Dari hasil seleksi fitur dataset TB didapatkan empat fitur teratas, yaitu nyeri penekanan, keadaan kulit (gatal-gatal/dekubitus), edema, dan batuk lebih dari tiga minggu, sedangkan dari hasil seleksi fitur dataset DBD didapatkan lima fitur dominan teratas dari penentuan pemeriksaan DBD meliputi terjadinya inspeksi saluran pernapasan, integritas kulit, perubahan warna kulit, dan kardiovaskuler auskultasi, dan keteraturan nadi.

Hasil tertinggi dari pengujian dataset hasil seleksi fitur TB didapatkan pada penggunaan tujuh fitur dengan nilai akurasi mencapai 98.5% dan AUC mencapai 0.97 yang artinya model prediktif JST-Backpropagation tergolong sangat baik dalam mengidentifikasi tersangka TB, sedangkan hasil tertinggi dari pengujian dataset hasil seleksi fitur DBD didapatkan pada penggunaan tujuh fitur dengan nilai akurasi mencapai 88.9% dan AUC mencapai 0.89 yang berarti model prediktif JST-Backpropagation tergolong baik dalam mengidentifikasi tersangka DBD. Efektifitas pemilihan fitur TB didapatkan dari pemakaian jumlah fitur TB dari 49 fitur

sampai 4 fitur dengan nilai AUC diatas 0.9, sedangkan efektifitas pemilihan fitur DB dari pemakaian jumlah fitur DB dari 24 fitur sampai dengan 4 fitur dengan nilai AUC diatas 0.8.

Ucapan Terima Kasih

Penulis menyampaikan terima kasih kepada DP2M DIKTI yang telah mendanai pelaksanaan penelitian Hibah Bersaing Tahun ke-1 sesuai dengan Surat Perjanjian Pelaksanaan Penelitian Program Hibah Bersaing Politeknik Negeri Jember No. 771/PL17.2/PL/2013.

Daftar Pustaka

- [1] Kementerian Kesehatan, *Rencana strategis Kementerian Kesehatan tahun 2010-2014*, Jakarta, Indonesia: Kementerian Kesehatan Republik Indonesia, 2010.
- [2] Balitbangkes, *Riset Kesehatan Dasar (Riskesdas) 2010*, Jakarta, Indonesia: Badan Penelitian dan Pengembangan Kesehatan, Kementerian Kesehatan Republik Indonesia, 2010.
- [3] Dirjen PP dan PL, *Strategi nasional pengendalian TB di Indonesia 2010-2014*, Jakarta, Indonesia: Direktorat Jenderal Pengendalian Penyakit dan Kesehatan Lingkungan, Kementerian Kesehatan Republik Indonesia, 2011.
- [4] World Health Organization (WHO), *Global tuberculosis control 2011*, Avenue Appia 20, 1211 Geneva 27, Switzerland: World Health Organization, 2011.
- [5] World Health Organization (WHO), *Dengue: guidelines for diagnosis, treatment, prevention and control*, Avenue Appia 20, 1211 Geneva 27, Switzerland: World Health Organization, 2009.
- [6] Pusat Data dan Surveilans Epidemiologi, *Buletin jendela epidemiologi – demam berdarah dengue*, Jakarta, Indonesia: Pusat Data dan Surveilans Epidemiologi, Kementerian Kesehatan Republik Indonesia, 2010.
- [7] Abiyoso, *Tuberkulosis Praktis*, Malang: Fakultas Kedokteran Universitas Brawijaya, 2003.
- [8] Paliligan, *TB Update-II 2003*, Surabaya, Indonesia: Fakultas Kedokteran Universitas Airlangga, 2003.
- [9] A.Y. Sutedjo, *Mengenal penyakit melalui hasil pemeriksaan laboratorium*, Yogyakarta: Amara Books, 2009.
- [10] J. Han dan M. Kamber, *Data mining concepts and techniques (2nd ed.)*, San Francisco: Morgan Kaufmann Publishers, 2006.
- [11] P. Luukka, "Feature selection using fuzzy entropy measures with similarity classifier," *Expert Systems with Applications*, vol. 38, pp. 4600-4607, 2011, doi:10.1016/j.eswa.2010.09.133.
- [12] X. Yu, M.O. Efe, dan O. Kaynak, "A General Backpropagation Algorithm for Feedforward Neural Networks Learning," *IEEE Trans. Neural Networks*, vol. 13, pp. 251-259, 2002.
- [13] W. Zhu, N. Zeng, dan N. Wang, *Sensitivity, Specificity, Associated Confidence Interval and ROC*, Nesug, 2010.

Biodata Penulis

I Putu Dody Lesmana, memperoleh gelar Magister Teknik (M.T) dari ITS, Surabaya. Penulis saat ini merupakan dosen aktif di Jurusan Teknologi Informasi, Politeknik Negeri Jember.

Faiqatul Hikmah, memperoleh gelar Magister Kesehatan (M.Kes) dari Universitas Jember dan saat ini penulis merupakan dosen aktif di Jurusan Kesehatan, Politeknik Negeri Jember.

Rinda Nurul Karimah, memperoleh gelar kedokteran (dr.) dari Universitas Jember dan saat ini penulis merupakan dosen aktif di Jurusan Kesehatan, Politeknik Negeri Jember.