

METODE ADABOOST PADA SKEMA PEMODELAN *HYBRID* UNTUK KLASIFIKASI PENYAKIT *LIVER*

Destia Sandya Prasvita, S.Komp., M.Kom.

Sekolah Tinggi Ilmu Manajemen dan Ilmu Komputer ESQ

(Contact : 081210480911, destia.sandya@esqbs.ac.id)

Abstrak

Penelitian ini mengajukan perbandingan antara dua model *hybrid* yaitu, *Artificial Neural Network* (ANN) dan Adaboost pada skema pemodelan *hybrid* untuk klasifikasi penyakit *liver*. Digunakan metode *Logistic Regression* (LR), *Multivariate Adaptive Regression Splines* (MARS), *Rough Set* (RS), *Artificial Neural Network* (ANN), dan Adaboost untuk membangun skema model *hybrid*. Ada dua tahapan utama dalam penelitian ini, tahapan pertama menggunakan LR, MARS, dan RS untuk memilih fitur yang relevan terhadap klasifikasi dan selanjutnya fitur-fitur terpilih akan digunakan sebagai masukan pada klasifikasi menggunakan *classifier* ANN dan Adaboost. Tahap kedua adalah membangun skema *hybrid* yang menghasilkan enam kombinasi yaitu LR-ANN, MARS-ANN, RS-ANN, LR-Adaboost, MARS-Adaboost, dan RS-Adaboost. Penelitian ini juga membandingkan akurasi menggunakan *classifier* tunggal dengan model skema *hybrid* untuk klasifikasi penyakit *liver*. Secara keseluruhan, dengan menggunakan skema *hybrid* Adaboost, akurasi meningkat terhadap *classifier* tunggal Adaboost.

Key word : *Logistic Regression* (LR), *Multivariate Adaptive Regression Splines* (MARS), *Artificial Neural Network* (ANN), *Rough Set* (RS), Adaboost

1. Pendahuluan

Penyakit *liver* adalah satu-satunya penyebab utama kematian yang masih meningkat dari tahun ke tahun. Berdasarkan data dari *Office of National Statistics* kematian penyakit *liver* telah meningkat sebesar 12% hanya dalam waktu tiga tahun, sejak tahun 2005 total 46.244 nyawa melayang (www.statistics.gov.uk). Banyak penelitian yang dikembangkan untuk membuat sistem pendukung keputusan medis yang cerdas dan efektif untuk membantu para dokter. Pemilihan fitur dan *classifier* yang tepat adalah hal penting dalam peningkatan akurasi dan komputasi dalam klasifikasi penyakit *liver*.

Beberapa penelitian telah dilakukan sebelumnya untuk klasifikasi penyakit *liver* dengan skema model *hybrid*. Klasifikasi penyakit *liver* menggunakan metode *Fuzzy-Artificial Immune Recognition System* (Fuzzy-AIRS) dengan akurasi maksimum mencapai 83.39 % [1]. Selanjutnya dengan metode *Fuzzy Decision Tree* juga telah dilakukan dengan akurasi mencapai 81.6 % [2]. Untuk penyakit lainnya, skema model *hybrid* dengan metode *Logistic Regression* (LR), *Multivariate Adaptive Regression Splines* (MARS), *Rough Set* (RS), dan *Artificial Neural Network* (ANN) terbukti dapat meningkatkan akurasi pada penyakit jantung, dengan akurasi maksimum mencapai 83.93%, akurasi meningkat dari *classifier* tunggal ANN yang awalnya sebesar 76.79% dengan menggunakan skema *hybrid* MARS-ANN menjadi sebesar 82.14% [3].

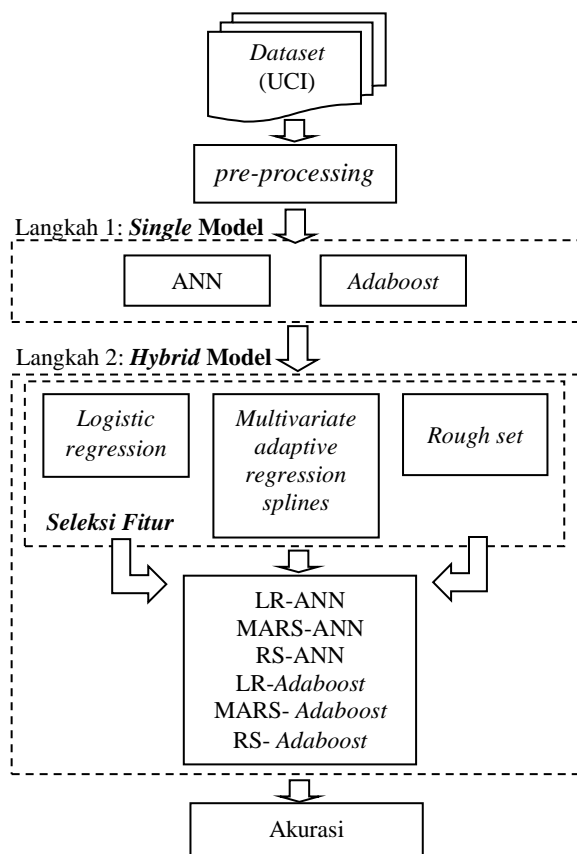
Pada penelitian ini, dilakukan perbandingan ANN dengan Adaboost pada skema model *hybrid* untuk klasifikasi penyakit *liver*. Metode Adaboost secara khusus, menunjukkan bahwa metode ini mendekati *classifier* kuat seperti SVM [4]. Dua tahap dalam membangun skema *hybrid*, tahap pertama adalah seleksi fitur yang dianggap relevan untuk klasifikasi dan tahap kedua ada membangun skema model cerdas *hybrid*. LR, MARS, dan RS adalah metode yang digunakan untuk melihat hubungan antara variabel penjelas dan variabel respon sehingga dapat melihat variabel atau fitur yang relevan terhadap klasifikasi. Selanjutnya fitur-fitur yang dianggap relevan tersebut akan dijadikan inputan dalam klasifikasi dengan ANN dan Adaboost. Terdapat 6 kombinasi yang dibangun dalam skema *hybrid* pada penelitian ini. Penelitian ini juga membandingkan hasil akurasi pada *single* model terhadap *hybrid* model. Fitur yang dihasilkan pada skema *hybrid* model akan lebih sedikit yang diharapkan proses komputasi lebih cepat dengan tetap mempertahankan atau meningkatkan akurasi klasifikasi penyakit *liver*.

2. Metodologi

Terdapat beberapa tahapan pada penelitian ini, yaitu pengumpulan *dataset*, *pre-processing*, *single* model, dan *hybrid* model. *Dataset* pada penelitian ini diambil dari UCI *machine learning database* [5]. Variabel data yang digunakan berjumlah 11, dimana 10 digunakan sebagai variabel penjelas (Usia Pasien, Jenis Kelamin, Jumlah Bilirubin, *Direct Bilirubin*, Alkaline Phosphatase, Alamine Aminotransferase, Aspartat Aminotransferase,

Jumlah Protiens, Albumin, Ratio Albumin dan Globulin) dan 1 variabel digunakan untuk label pada kelas yang bernilai biner (1 = ada penyakit *liver*, 2 = tidak ada penyakit *liver*).

Setelah pengumpulan data, dilakukan *pre-processing* data dengan menghilangkan data-data yang terdapat *missing value*. Pada tahap *single* model data hasil *pre-processing* tersebut diklasifikasikan dengan menggunakan *Artificial Neural Network* (ANN) dan Adaboost. Tahapan terakhir adalah membangun skema model cerdas *hybrid* dengan menghasilkan beberapa kombinasi *hybrid*. Pada tahapan pembangunan model *hybrid*, terdapat seleksi fitur untuk memilih fitur-fitur yang dianggap relevan sebagai masukan untuk klasifikasi. Metode yang digunakan untuk seleksi fitur, yaitu *Logistic Regression* (LR), *Multivariate Adaptive Regression Splines* (MARS), dan *Rough Set* (RS). Metodologi penelitian dapat dilihat pada Gambar 1.



Gambar 1. Metodologi Penelitian

2.1. Adaboost

Adaboost (*Adaptive Boosting*), pertama kali diperkenalkan oleh whichwas Freund dan Schapire (1996), adalah algoritma *ensemble* populer yang mengembangkan algoritma *boosting* sederhana melalui proses iterasi. *Classifier-classifier* yang digabungkan disebut *weak classifier*. *Weak classifier* yang digunakan umumnya adalah *classifier* yang sederhana seperti fungsi

thresholding, *naive bayes*, *decision tree*, dan lain-lain. Syarat dari *weak classifier* adalah tingkat kesalahan tidak boleh melebihi pengambilan secara acak atau *error* harus kurang dari 0.5.

Gagasan utama dari metode ini adalah memberikan bobot yang lebih besar terhadap data yang sulit untuk diklasifikasikan. Pada tahap awal, bobot pada setiap data diberikan nilai yang sama. Selanjutnya dilakukan proses *training* data dan untuk data yang benar terklasifikasi dikurangi nilai bobotnya sedangkan data yang salah terklasifikasi ditambah nilai bobotnya. Sehingga pada proses iterasi selanjutnya, proses *training* data lebih berfokus pada data yang salah terklasifikasi pada proses *training* sebelumnya. Selanjutnya *classifier-classifier* yang terbentuk akan digabungkan (*ensemble*) sebagai satu keputusan *strong classifier* [4]. Di bawah adalah *pseudo code* dari algoritma Adaboost untuk *binary class*.

Algoritma 1: Adaboost

1. Terdapat m data latih :
 $(x_1, y_1), \dots, (x_m, y_m); x_i \in x, y_i \in \{-1, +1\}$
2. Inisialisasi bobot awal
 $D_1(i) \leftarrow \frac{1}{m}; i, \dots, m$
3. Untuk $t=1, \dots, T$ lakukan langkah 4 sampai 8:
4. Bangun *classifier* menggunakan *weak classifier* terhadap distribusi data D_t
5. Hitung ε_t :

$$\varepsilon_t \leftarrow \sum_{i: M_t(x_i) \neq y_i} D_t(i)$$

Jika $\varepsilon_t > 0.5$ maka berhenti

6. Hitung nilai α_t
 $\alpha_t \leftarrow \frac{1}{2} \ln\left(\frac{1 - \varepsilon_t}{\varepsilon_t}\right)$
7. Update nilai $D_{t+1}(i)$
 $D_{t+1}(i) \leftarrow D_t(i) \cdot e^{-\alpha_t y_t M_t(x_i)}$
8. Normalisasi D_{t+1}
9. *Classifier* kuat

$$H(x) = \text{sign}\left(\sum_{t=1}^T \alpha_t M_t(x)\right)$$

2.2. Logistic Regression (LR)

Metode LR digunakan untuk melihat keterhubungan antara variabel respon yang berupa dikotonomi atau biner dengan variabel penjelas. Variabel biner adalah variabel yang hanya mempunyai dua kategori saja, yaitu kategori yang menyatakan kejadian sakit *liver* ($Y=1$) dan kategori yang menyatakan kejadian tidak sakit *liver* ($Y=0$). Variabel penjelas sebanyak k , yaitu: X_1, X_2, \dots, X_k [3]. Variabel penjelas disini adalah 10 fitur k yang terdapat dalam *dataset* penyakit *liver*, misalnya umur, jenis kelamin, *total bilirubin* (TB), *direct bilirubin* (DB),

dan lain lain. Jika digambarkan dalam bentuk tabel adalah sebagai berikut:

Tabel 1. Hubungan Variabel Respon dan Variabel Penjelas

Jenis kelamin (X ₁)	Total Bilirubin (X ₂)	X _k	Y
Pria	0.7	...	Sakit (1)
Pria	0.8	...	Sakit (1)
Pria	0.2	...	Tidak (0)
Wanita	0.2	...	Tidak (0)
...

Bentuk umum model regresi logistik dengan k variabel penjelas, diformulasikan sebagai berikut:

$$\ln \left[\frac{\pi(x)}{1-\pi(x)} \right] = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k \quad \dots(1)$$

Metode *maximum likelihood estimation* (MLE) digunakan sebagai penduga parameter β . Estimasi dari parameter regresi logistik didapatkan dengan menurunkan parsial pertama fungsi \ln *likelihood* terhadap parameter yang akan diestimasi kemudian disamakan dengan nol. selanjutnya untuk melihat pengaruh antara variabel respon dengan variabel penjelas digunakan uji *wald* dengan hipotesis sebagai berikut:

$$H_0: \beta_k = 0$$

$$H_1: \beta_k \neq 0 \quad \dots(2)$$

Dengan statistik uji sebagai berikut:

$$W_k = \left[\frac{\hat{\beta}_k}{\hat{\sigma}_{\hat{\beta}_k}} \right]^2 \quad \dots(3)$$

Hipotesis nol ditolak jika $|W_k| > Z_{\alpha/2}$, yang berarti ada pengaruh antara variabel penjelas x_k dengan variabel respon Y.

2.3. Multivariate Adaptive Regression Splines (MARS)

Multivariate Adaptive Regression Splines (MARS) adalah metode statistik modern yang menggabungkan antara *spline* dan *Recursive Partitioning Regression* (RPR). Model MARS adalah sebagai berikut [3].

$$f(x) = a_0 + \sum_{m=1}^M a_m \prod_{k=1}^{k_m} (S_{km}(X_{V(k,m)} - t_{km})) \quad \dots(4)$$

Model MARS di atas dapat disajikan sebagai berikut:

$$f(x) = a_0 + \sum_{m=1}^M a_m \beta_m(x) \quad \dots(5)$$

dimana:

$$\beta_m(x) = \prod_{m=1}^{k_m} (S_{km}(X_{V(k,m)} - t_{km})) \quad \dots(6)$$

Pemilihan *knot* pada MARS memiliki dua tahapan, yaitu tahap *forward* dan tahap *backward*. Tahap *forward* dilakukan untuk mendapatkan fungsi dengan jumlah basis maksimum dan nantinya akan dipilih fungsi basis dengan metode kuadrat terkecil. Tahap *backward* digunakan untuk menentukan memilih satu fungsi basis dan mengeluarkannya jika fungsi basis tersebut jika kontribusi terhadap model kecil. Ukuran kontribusi pada tahap *backward* ditentukan berdasarkan kriteria *Generalized Cross Validation* (GCV).

2.4. Rough set (RS)

Teori *rough set* adalah sebuah teknik matematik yang dikembangkan oleh Pawlack pada tahun 1980. Teknik ini digunakan untuk menangani masalah *uncertainty* dan *imprecision* dalam aplikasi *Artificial Intelligence* (AI). Pada metode ini kumpulan objek disebut sebagai *information system* (IS) yang selanjutnya dari objek-objek pada IS tersebut dapat diklasifikasikan dalam area-area tertentu. Pengklasifikasian objek-objek disebut dengan *lower approximation*, *boundary region*, dan *outside region*.

2.4.1. Information System (IS)

Sebuah data dapat direpresentasikan dalam bentuk tabel, dimana baris menunjukkan objek dan kolom menunjukan atribut dari objek-objek tersebut. Tabel tersebut dalam *rough set* disebut dengan *information system* yang dapat digambarkan sebagai $S = (U, A)$. Dimana U adalah himpunan tidak kosong dari objek dan A adalah atribut dari objek-objek tersebut. Dapat dilihat pada tabel di bawah ini, U adalah {N1, N2, N3, N4, N5, N6} yang merupakan himpunan tidak kosong dari pasien penyakit *liver* dan A adalah {jenis kelamin, total bilirubin, kategori umur}. Kolom terakhir adalah menunjukan keputusan (*decision attribute*) sehingga dalam metode ini dapat disebut sebagai *decision system*. *Decision system* dapat diformulasikan sebagai berikut $S = (U, A, \{d\})$ dimana A mengalami perluasan atribut, yaitu atribut *liver*/hati yang merupakan atribut keputusan dari *decision system*.

Tabel 2. Information System dan Decision System

	Jenis kelamin	Total Bilirubin	Kategori Umur	Liver
N1	Wanita	0.1	Dewasa	Sakit
N2	Pria	0.2	Dewasa	Sakit
N3	Pria	0.1	Tua	Sakit
N4	Wanita	0.1	Anak-anak	Tidak
N5	Pria	0.2	Dewasa	Tidak
N6	Wanita	0.1	Tua	Sakit

2.4.2. Indiscernibility Relation

Indiscernibility Relation dapat dilihat pada tabel 2 untuk pasien N1, N4, dan N6 memiliki nilai atribut kondisional jenis kelamin yang sama, yaitu “wanita”. Hubungan tersebut disebut dengan *indiscernible* (tidak dapat dipisah). Dalam tabel 2 di atas maka didapatkan *indiscernibility relation* pada berikut ini:

$$\begin{aligned} \text{IND}(\text{jenis kelamin}) &= \{\{N1, N4, N6\}, \{N2, N3, N5\}\} \\ \text{IND}(\text{total bilirubin}) &= \{\{N1, N3, N4, N6\}, \{N2, N5\}\} \\ \text{IND}(\text{kategori umur}) &= \{\{N1, N2, N5\}, \{N3, N6\}, \{N4\}\} \\ \text{IND}(\text{jenis kelamin, total bilirubin}) &= \\ &= \{\{N1, N4, N6\}, \{N2, N5\}, \{N3\}\} \\ \text{IND}(\text{jenis kelamin, kategori umur}) &= \\ &= \{\{N1\}, \{N2, N5\}, \{N3\}, \{N4\}, \{N6\}\} \\ \text{IND}(\text{total bilirubin, kategori umur}) &= \\ &= \{\{N1\}, \{N2, N5\}, \{N3, N6\}, \{N4\}\} \\ \text{IND}(\text{jenis kelamin, total bilirubin, kategori umur}) &= \{\{N1\}, \{N2, N5\}, \{N3\}, \{N4\}, \{N6\}\} \end{aligned}$$

2.4.3. Set Approximation

Untuk menentukan perkiraan dalam *information system*, dimisalkan *information system* $S = (U, A)$, $B \subseteq A$, dan $X \subseteq U$. *Set Approximation* dapat dibentuk dengan mengkonstruksi *B-lower* dan *B-upper approximation* dari X yang dinotasikan sebagai $\underline{B}X$ dan $\overline{B}X$. $\underline{B}X$ dapat digolongkan dengan pasti sebagai anggota X berdasarkan informasi pada atribut B , sedangkan $\overline{B}X$ hanya digolongkan sebagai anggota yang mungkin dapat masuk dalam X . Dari hasil pengurangan antara $\underline{B}X$ dan $\overline{B}X$ dapat diperoleh *boundary region* dari X yang anggotanya adalah objek-objek yang tidak bisa diklasifikasikan ke dalam X secara pasti. *B-outbound* dari X adalah objek-objek yang diklasifikasikan sebagai anggota bukan X yang diperoleh dari $SetU - \overline{B}X$. Dari tabel 2 didapatkan *Set Approximation* sebagai berikut.

$$\begin{aligned} \underline{B}X &= \{\{N1\}, \{N3\}, \{N6\}\} \\ \overline{B}X &= \{\{N1\}, \{N2, N5\}, \{N3\}, \{N6\}\} \\ \overline{B}X - \underline{B}X &= \{\{N2, N5\}\} \\ U - \overline{B}X &= \{N4\} \end{aligned}$$

3. Pembahasan

Dataset yang digunakan berjumlah 584 data dan terdiri dari dua kelas. Untuk kelas pertama berjumlah 416 data dan kelas kedua berjumlah 167 data. Karena ada ketidakseimbangan data yang terlalu besar, proses *resample* data dilakukan sehingga menghasilkan jumlah data yang sama yaitu 200 data untuk masing-masing kelasnya, proses *resample* data dilakukan dengan menggunakan WEKA. Percobaan pada penelitian ini


terdiri dari 2 tahapan, yaitu pemodelan untuk *Single model* dan *hybrid model*. Dalam pembangunan *single model*, klasifikasi dilakukan dengan menggunakan semua fitur sebagai masukan terhadap *classifier Adaboost* dan ANN. Sedangkan pembangunan *hybrid model*, adanya tahapan untuk memilih fitur-fitur yang relevan menggunakan metode LR, MARS, dan RS yang selanjutnya akan dijadikan sebagai inputan untuk klasifikasi dengan *classifier Adaboost* dan ANN.

3.1. Hasil Percobaan 1 (Single Model)

Pada tahapan percobaan ke-1 ini membandingkan akurasi klasifikasi dengan menggunakan *single model Adaboost* dengan *Backpropagation Neural Network* (BPNN) dengan menggunakan 10 fitur lengkap. Untuk menghasilkan akurasi yang maksimal percobaan dilakukan dengan menggunakan *k-fold cross validation*. Percobaan *single model* terhadap kedua *classifier Adaboost* dan BPNN akan dijelaskan pada sub-bab berikut ini.

3.1.1. Single Model Adaboost

Percobaan menggunakan *single model Adaboost* dilakukan dengan mencoba berbagai iterasi (1000, 2000, dan 3000 iterasi). Pengujian dilakukan dengan menggunakan *k-fold cross validation* dengan jumlah percobaan $k=2$ sampai $k=10$. Untuk grafik percobaan pada tahapan *single model* menggunakan *Adaboost* dapat dilihat pada Gambar 2.




Gambar 2. Grafik Akurasi Single Model Adaboost

Akurasi maksimal untuk *single model* menggunakan *Adaboost* adalah pada tahap pengujian *k-fold cross validation* dengan $k=8$ dengan 2000 iterasi. Dapat dilihat dari grafik pada Gambar 2, akurasi maksimal yang dicapai pada *single model* menggunakan *Adaboost* adalah sebesar 83.25%.

3.1.2. Single Model Backpropagation Neural Network (BPNN)

Pada percobaan *single* model ANN, penentuan klasifikasi yang optimal dilakukan beberapa percobaan terhadap jumlah *hidden layer* yaitu sebanyak jumlah fitur dikurang 2 sampai jumlah fitur ditambah 2, yaitu dari 8 *hidden layer* sampai 12 *hidden layer*. Pengujian dilakukan dengan menggunakan *k-fold cross validation* dengan jumlah percobaan $k=2$ sampai $k=10$. Untuk grafik percobaan pada tahapan *single* model menggunakan ANN dapat dilihat pada Gambar 3.



Gambar 3. Grafik Akurasi Single Model ANN

Gambar 3 menunjukkan akurasi maksimal untuk *single* model menggunakan ANN adalah menggunakan 9 *hidden layer* pada tahap pengujian *k-fold cross validation* dengan $k=3$. Akurasi maksimum menggunakan 10 fitur lengkap dengan ANN adalah sebesar 82.53%.

3.2. Hasil Percobaan 2 (Hybrid Model)

Ada beberapa tahapan dalam skema model *hybrid* diantaranya adalah seleksi fitur, *hybrid* model Adaboost, dan *hybrid* model BPNN. Tahapan awal dilakukan pemilihan fitur yang relevan menggunakan metode LR, MARS, dan RS. Dari hasil seleksi fitur tersebut akan dibangun model *hybrid Adaboost* dan BPNN yang menghasilkan beberapa kombinasi skema *hybrid* model yaitu, LR-ANN, MARS-ANN, RS-ANN, LR-Adaboost, MARS-Adaboost, RS-Adaboost. Tahapan-tahapan percobaan model *hybrid* akan dijelaskan pada sub-bab berikut ini.

3.2.1. Seleksi Fitur

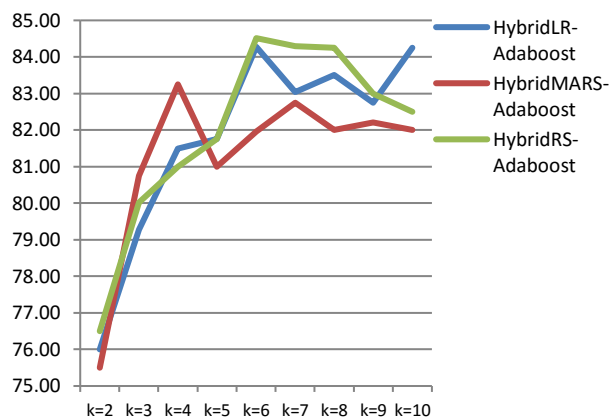
Pada tahap pertama pada percobaan model *hybrid* ini dilakukan pemilihan fitur yang dianggap berpengaruh terhadap klasifikasi. Beberapa *tools* yang digunakan dalam tahapan seleksi fitur, yaitu SPSS, *Salford Systems* MARS, RSES. LR menggunakan *tools* statistik yang cukup populer yaitu SPSS, MARS menggunakan MARS

yang dikembangkan oleh *Salford Systems*, dan RSES (*rough set exploration system*) digunakan untuk metode RS.

Pemilihan fitur menggunakan metode LR, MARS, dan RS yang telah dijelaskan di atas, masing-masing metode menghasilkan jumlah fitur yang berbeda. Untuk LR menghasilkan fitur yang dianggap relevan berjumlah 9 fitur yaitu A1, A3, A4, A5, A6, A7, A8, A9, dan A10. MARS menghasilkan 6 fitur yang dianggap relevan yaitu A1, A3, A4, A5, A6, dan A7. Sedangkan RS menganggap 8 fitur yang paling relevan adalah A1, A3, A5, A6, A7, A8, A9, dan A10. Dari ketiga metode (LR, MARS, dan RS) menyatakan fitur A2 (jenis kelamin) dianggap tidak berpengaruh terhadap hasil klasifikasi penyakit *liver*.

3.2.2. Model Hybrid Adaboost

Sama halnya pada pengujian *single* model, pada tahap *hybrid* model juga menggunakan *k-fold cross validation* dengan percobaan menggunakan $k=2$ sampai $k=10$. Model *Hybrid* dengan *classifier Adaboost*, terdapat 3 kombinasi yaitu LR-Adaboost, MARS-Adaboost, RS-Adaboost. LR-Adaboost akurasi maksimum dicapai pada tahap pengujian $k=6$ dengan akurasi yaitu sebesar 84.28%. MARS-Adaboost akurasi maksimum dicapai pada tahap pengujian $k=6$ dengan akurasi yaitu sebesar 83.25%. RS-Adaboost akurasi maksimum dicapai pada tahap pengujian $k=4$ dengan akurasi yaitu sebesar 84.51%. Grafik untuk setiap k dalam pengujian *hybrid Adaboost* dapat dilihat pada Gambar 4.




Gambar 4. Grafik Perbandingan Akurasi Hybrid Model Adaboost

Grafik pada Gambar 4 menunjukkan akurasi maksimal sebesar 84.51% dengan menggunakan model *hybrid* RS-Adaboost. Fitur yang digunakan sebagai inputan pada klasifikasi dengan *hybrid Adaboost* pada model RS-Adaboost adalah berjumlah 8 fitur. Dengan menggunakan model *hybrid* RS-Adaboost menunjukkan akurasi meningkat jika dibandingkan dengan model *single Adaboost*.

Pada Gambar 4 menunjukkan akurasi terendah pada model *hybrid* adalah sebesar 83.25% dengan menggunakan model MARS-Adaboost. Untuk Fitur yang digunakan pada model *hybrid* MARS-Adaboost ini adalah 6 fitur. Namun hal ini menunjukan bahwa dengan hanya menggunakan 6 fitur, akurasi yang dicapai dapat menyamai dengan menggunakan 10 fitur lengkap pada *single* model Adaboost yang juga sebesar 83.25%.

3.2.3. Model Hybrid Backpropagation Neural Network (BPNN)

Untuk *hybrid* dengan *classifier* BPNN, terdapat 3 kombinasi *hybrid* (LR-ANN, MARS-ANN, RS-ANN). LR-ANN akurasi maksimum dicapai pada tahap pengujian $k=7$ dengan akurasi yaitu sebesar 82.5%. Akurasi maksimum untuk MARS-ANN adalah pada tahap pengujian $k=7$ dengan akurasi yaitu sebesar 78.25%. Untuk RS-ANN, akurasi maksimum dicapai pada tahap pengujian $k=9$ dengan akurasi yaitu sebesar 81%. Grafik untuk setiap k pada k -fold cross validation dalam pengujian *hybrid* ANN dapat dilihat pada Gambar 5.




Gambar 5. Grafik Perbandingan Hybrid Model ANN

Pada model *hybrid* ANN akurasi maksimal adalah sebesar 82.5% dengan menggunakan model *hybrid* LR-ANN. Namun untuk model *hybrid* ini tidak terbukti bahwa dengan menggunakan model *hybrid* ANN dapat meningkatkan akurasi dari pada *single* model ANN.

3.3. Analisis Eksperimen Secara Keseluruhan


Pada percobaan penelitian ini terdapat 3 hasil klasifikasi *Single* model yaitu menggunakan BPNN dan Adaboost sedangkan untuk *hybrid* model terdapat 6 hasil akurasi klasifikasi, masing-masing 3 untuk model *hybrid* dengan *classifier* BPNN dan 3 untuk model *hybrid* dengan *classifier* Adaboost. Hasil keseluruhan akurasi klasifikasi *single* dan *hybrid* model dapat dilihat pada Gambar 6.



Gambar 6. Grafik Perbandingan Akurasi Klasifikasi Penyakit Liver

Dapat dilihat dalam Gambar 6, bahwa metode *hybrid* pada *hybrid* ANN tidak terbukti dapat meningkatkan akurasi. Akurasi menggunakan *single* model ANN adalah sebesar 82.53%, namun dengan skema *hybrid* ANN akurasi maksimalnya hanya sebesar 82.5%. Untuk skema model *hybrid* Adaboost dapat meningkatkan akurasi. Akurasi menggunakan hanya satu *classifier* Adaboost adalah 83.25% dan akurasi meningkat menggunakan skema *hybrid* dengan LR-Adaboost sebesar 84.28%, MARS-Adaboost sebesar 83.25%, dan RS-Adaboost sebesar 84.51%. Akurasi maksimal adalah sebesar 84.51% menggunakan skema model *hybrid* RS-Adaboost. Karena skema *hybrid* memiliki fitur yang lebih sedikit maka selain meningkatkan akurasi, proses komputasi akan lebih cepat. Hal ini memperlihatkan bahwa dengan menggunakan lebih banyak fitur tidaklah meningkatkan akurasi, tapi dengan memilih fitur yang dianggap relevan sehingga dapat memperkecil ukuran fitur dengan metode yang tepat dan *classifier* yang tepat akan meningkatkan akurasi dan mempercepat komputasi.

Jika dilihat dari akurasi masing-masing kelas untuk semua metode, terlihat bahwa akurasi kelas 1 lebih rendah dari akurasi kelas 2. Akurasi maksimal untuk kelas 1 dicapai dengan model *hybrid* LR-Adaboost sebesar 80.59%, dan akurasi maksimal untuk kelas 2 dicapai dengan model *hybrid* RS-Adaboost sebesar 89.94%. Grafik lengkap untuk akurasi masing-masing kelas dapat dilihat pada Gambar 7.



Gambar 7. Grafik Perbandingan Akurasi Klasifikasi Penyakit *Liver* untuk Masing-Masing Kelas

4. Kesimpulan

Berdasarkan hasil dari eksperimen penelitian model *hybrid* dengan metode *Adaboost* untuk klasifikasi penyakit *liver* dapat ditarik beberapa kesimpulan sebagai berikut:

1. Metode *Adaboost* sangat adaptif dengan fitur, karena setiap iterasi dalam *Adaboost* melakukan pemilihan *classifier* yang memiliki *error* paling kecil. *Adaboost* memilih fitur terbaik pada setiap iterasi. Jadi dengan banyak atau sedikit fitur yang digunakan atau dengan data apapun, *adaboost* akan mengklasifikasikan dengan baik.
2. Pada penelitian disimpulkan bahwa skema *hybrid* dengan *classifier* *Adaboost* pada klasifikasi *liver* telah terbukti meningkatkan akurasi dan mempercepat komputasi. Dengan menggunakan *classifier* tunggal *Adaboost* akurasi sebesar 83.25% meningkat sebesar 84.51% dengan menggunakan skema *hybrid* RS-*Adaboost*.
3. *Hybrid* model dengan *classifier* *Adaboost* juga menghasilkan akurasi yang lebih baik dari penelitian sebelumnya yaitu, *Fuzzy-AIRS* dengan akurasi maksimum 83.39 % (Polat, Kemal et al 2007) dan metode *fuzzy decision* dengan akurasi mencapai 81.6 % (Fan, C.Y 2011).
4. Dari ketiga metode (LR, MARS, dan RS) menyatakan fitur A2 (jenis kelamin) dianggap tidak berpengaruh atau tidak relevan terhadap hasil klasifikasi penyakit *liver*.

Daftar Pustaka

- [1] Polat, Kemal et al. "Breast cancer and liver disorders classification using artificial immune recognition system (AIRS) with performance evaluation by fuzzy resource allocation mechanism". *Expert Systems with Applications*, vol. 32, Issue 1, pp. 172–183, January 2007.
- [2] Fan, Chin-Yuan et al. "A hybrid model combining case-based reasoning and fuzzy decision tree for medical data classification". *Applied Soft Computing*, vol. 11, Issue 1, pp. 632–644, January 2011.
- [3] Shaoa, Y.E., Chia-Ding Houa, Chih-Chou Chiu. "Hybrid intelligent modeling schemes for heart disease classification". *Applied Soft Computing*, vol. 14, pp. 47–52, January 2014.
- [4] Rokach, Lior. "Ensemble-based classifiers". *Artificial Intelligence Review*, vol. 33, Issue 1, pp 1–39, February 2010.
- [5] Ramana, B., Surendra P. B., and Venkateswarlu. <http://archive.ics.uci.edu/ml/machine-learning-databases/00225/>, 2012.