

PENERAPAN METODE AHP DAN SVM UNTUK KLASIFIKASI PENERIMA BEASISWA (STUDI KASUS : LEMBAGA GNOTA KEDIRI)

Whenty Ariyanti¹⁾, Imam Cholissodin, S.Si, M.Kom²⁾,

Budi Darma Setiawan³⁾

Program Studi Informatika/ Ilmu Komputer

Program Teknologi Informasi dan Ilmu Komputer

Universitas Brawijaya, Malang 65145, Indonesia

email: whenty.ariyanti@gmail.com[at]gmail.com¹⁾, imamcs[at]ub.ac.id²⁾,

budidarma[at]ub.ac.id³⁾

ABSTRAK

Pendidikan merupakan kebutuhan pokok bagi seluruh masyarakat Indonesia. Manfaat pendidikan bagi masyarakat Indonesia sangat beragam seperti untuk karir atau pekerjaan. Dalam penelitian ini diambil kasus pemilihan penerima beasiswa pada Lembaga GNOTA (Gerakan Nasional Orang Tua Asuh) Kediri sehingga nantinya kita dapat melakukan penyeleksian secara *realtime*, cepat dan akurat terhadap penerima beasiswa dengan suatu sistem penyeleksian yang mampu melakukan filterisasi secara otomatis proses pengambilan keputusan penentuan penerima beasiswa selama ini dilakukan secara manual. Manual disini maksudnya adalah data pemohon beasiswa direkapitulasi oleh panitia penyeleksi, lalu panitia melakukan survei satu persatu terhadap data yang diajukan oleh pemohon. Setelah proses survei dilakukan maka panitia akan meninjau dan menganalisa kembali data pemohon beasiswa tersebut. Proses ini membutuhkan waktu yang lama, kurang lebih tiga bulan hanya untuk meninjau dan menganalisa data pemohon beasiswa yang cukup banyak. Cara ini menyebabkan penilaian terhadap penerima beasiswa dilakukan secara subjektif, yang berarti penilaian berdasarkan sudut pandang panitia survei. Selain itu permasalahan ketepatan penyaluran beasiswa GNOTA yang selama ini sering terjadi dalam penentuan penerima beasiswa belum memiliki bobot secara pasti pada setiap kriteria dan sub kriteria yang dimiliki oleh pemohon beasiswa yang layak menerima beasiswa. "Penerapan Metode AHP dan SVM untuk Klasifikasi Penerima Beasiswa (Studi Kasus : Lembaga GNOTA Kediri)". Diharapkan dalam pemilihan penerima beasiswa digunakan metode AHP dan SVM untuk dapat menghasilkan *output* yang sesuai dengan keadaan atau kriteria yang ada sehingga dapat memudahkan Lembaga GNOTA dalam melakukan pengambilan keputusan dan meminimalkan kesalahan dalam pengambilan kebijakan. Tingkat akurasi rata-rata yang dihasilkan oleh sistem adalah sebesar 89.74% dengan pemilihan rasio 90%:10%, nilai *threshold* = 0.01, nilai *lamda* = 0.5, nilai konstanta *gamma*=0.003, nilai *epsilon*=0.001, iterasi maksimum=100 dan nilai *C*=1.

Kata kunci: GNOTA, Kediri, AHP, SVM.

ABSTRACT

Education is a basic requirement for all Indonesian citizens. Educational benefits for the people of Indonesia are as varied as for career or job. In this research taken the case of the selection of scholarship recipients at the Institute GNOTA (National Movement for Foster Parents) Kediri so that later we can do the screening in real time, quickly and accurately to the grantee with a system of selection that is able to perform filtering automatic decision-making process of determining awardees as long as this is done manually. Manual here means the scholarship applicant data is summarized by the committee of selectors, the committee conducted a survey one by one to the data submitted by the applicant. After the survey was done, the committee will review and analyze data of the scholarship applicants. This process takes a long time, about three months just to review and analyze data that is quite a lot of scholarship applicants. In this way led to an assessment of the awardees is done subjectively, which means an assessment based on the viewpoint of the survey committee. Besides the problems precision GNOTA scholarship distribution which has been often the case in determining the recipients dont have weight exctly in each criteria and sub-criteria that are owned by the aplicant that the eligible scholarship. "Application of AHP and SVM

Method for Classification of Scholarship Recipients (Case Study: Non GNOTA Kediri)". Expected in the selection of awardees is used AHP and SVM to produce output appropriate to the circumstances or the existing criteria so as to facilitate the Institute GNOTA in making decisions and minimize errors in decision kebijakan. Tingkat average accuracy generated by the system is 89.74% with the selection ratio of 90: 10%, threshold value = 0.01, the value of lamda = 0.5, the value constanta gamma = 0.003, the value of epsilon = 0.001, maximum iteration=100 respectively, the value of C parameter = 1.

Keywords: GNOTA, Kediri, *Scholarships*, AHP, SVM

1. PENDAHULUAN

Pendidikan merupakan kebutuhan pokok bagi seluruh masyarakat Indonesia. Manfaat pendidikan bagi masyarakat Indonesia sangat beragam seperti untuk karir atau pekerjaan. Disamping memberikan pengetahuan, pendidikan juga mampu membantu dalam kemajuan suatu bangsa dan menjadikan manusia lebih baik dan memiliki karakter. Undang-undang nomor 20 Tahun 2003 tentang sistem pendidikan nasional mengamanatkan bahwa pendidikan nasional harus mampu menjamin pemerataan kesempatan pendidikan dan peningkatan mutu serta relevansi pendidikan untuk menghadapi tantangan perubahan kehidupan lokal, nasional dan global. Seiring perkembangan zaman, diperlukan perbaikan dari sistem yang lama ke dalam bentuk sistem yang lebih baik lagi yang memiliki efisiensi dan efektifitas dalam sistem tersebut. Salah satu yang banyak dibutuhkan saat ini adalah sebuah sistem yang mampu membantu dalam proses pengambilan keputusan. Sistem pendukung keputusan berperan sebagai sistem yang dimaksudkan untuk mendukung para pengambil keputusan manajerial dalam situasi keputusan semi terstruktur (Turban, Aronson dan Liang, 2005).

Dalam penelitian ini diambil kasus pemilihan penerima beasiswa pada Lembaga GNOTA (Gerakan Nasional Orang Tua Asuh) Kediri sehingga nantinya kita dapat melakukan penyeleksian secara *realtime*, cepat dan akurat terhadap penerima beasiswa dengan suatu sistem penyeleksian yang mampu melakukan filterisasi secara otomatis. Lembaga GNOTA merupakan sebuah organisasi nirlaba, independen dan transparan. Lembaga ini merupakan gerakan inisiatif dari masyarakat untuk menjaga agar anak Indonesia mendapatkan pendidikan yang layak untuk masa depan yang lebih baik. GNOTA mendistribusikan paket bantuan pendidikan untuk membantu keluarga anak-anak kurang mampu agar mereka dapat menuntaskan pendidikannya.

Beberapa proses diperlukan dalam pengambilan keputusan untuk melakukan seleksi terhadap penerima beasiswa. Pada studi kasus Lembaga GNOTA Kediri, proses pengambilan keputusan penentuan penerima beasiswa selama ini dilakukan secara manual. Manual disini maksudnya adalah data pemohon beasiswa direkapitulasi oleh panitia penyeleksi, lalu panitia melakukan survei satu persatu terhadap data yang diajukan oleh pemohon. Setelah proses survei dilakukan maka panitia akan meninjau dan menganalisa kembali data pemohon beasiswa tersebut. Proses ini membutuhkan waktu yang lama, kurang lebih tiga bulan hanya untuk meninjau dan menganalisa data pemohon beasiswa yang cukup banyak. Cara ini menyebabkan penilaian terhadap penerima beasiswa dilakukan secara subjektif, yang berarti penilaian dari sudut pandang panitia survei saja. Selain itu permasalahan ketepatan penyaluran beasiswa GNOTA yang selama ini sering terjadi karena dalam penentuan penerima beasiswa belum memiliki bobot secara pasti pada setiap kriteria dan sub kriteria yang dimiliki oleh pemohon beasiswa. Dengan demikian dibutuhkan sebuah sistem berbasis komputer sebagai alternatif solusi yang dapat membantu lembaga GNOTA menentukan pemohon beasiswa yang layak menerima beasiswa dari lembaga GNOTA Kediri agar beasiswa dapat disalurkan dengan sukses dan tepat sasaran. Dengan adanya aplikasi tersebut dapat memberikan informasi yang efektif dan efisien dalam pengambilan suatu keputusan untuk penerima beasiswa. Metode yang digunakan adalah metode AHP (*Analytical Hierarchy Process*) dan SVM (*Support Vector Machine*). Menurut Burgeois (2005) AHP umumnya digunakan dengan tujuan untuk menyusun prioritas dari berbagai alternatif atau pilihan yang ada, dan pilihan-pilihan tersebut bersifat kompleks atau multi kriteria.

Pada penelitian sebelumnya, Jian Liang Peng (2012) menggunakan metode AHP (*Analytical Hierarchy Process*) untuk pemilihan pemasok

layanan logistik. Metode tersebut diangkat karena bisa memberikan nilai preferensi untuk setiap supplier. Pada penelitian tersebut menggunakan empat parameter penilaian seperti *cost*, *operating efficiency*, *service quality* dan *technology level*. Mohanty dan Bebartta (2011) melakukan penelitian yang membahas mengenai perbandingan klasifikasi antara metode KNN dan SVM untuk pengenalan karakter karakter bahasa Oriya (bahasa di negara bagian India) dimana pada penelitian tersebut menghasilkan akurasi 96.47% untuk metode KNN dan 98.9% dengan metode SVM, sehingga dapat diketahui klasifikasi dengan metode SVM lebih tinggi dibandingkan dengan metode KNN. Dr. S. Vijayarani (2015) menggunakan metode SVM dan Naive Bayes untuk prediksi penyakit liver. Kedua algoritma tersebut dibandingkan dan didasarkan pada akurasi kinerja faktor klasifikasi dan waktu pelaksanaan. Dari hasil percobaan klasifikasi dengan SVM dianggap yang terbaik karena memiliki akurasi tinggi dalam hal klasifikasi. Sedangkan *Naive Bayes* dianggap hanya unggul dalam waktu pelaksanaan saja. Yi Yang et al (2010) menggunakan metode AHP dan SVM untuk seleksi tempat pergantian gardu karena metode tersebut saling melengkapi untuk melakukan seleksi, dimana metode AHP kesulitan untuk memberikan klasifikasi kelayakan tempat pergantian gardu sehingga metode SVM digunakan sebagai proses awal untuk melakukan klasifikasi kelayakan tempat pergantian gardu.

Dari beberapa penelitian sebelumnya di atas, maka dalam skripsi ini diajukan judul “Penerapan Metode AHP dan SVM untuk Klasifikasi Penerima Beasiswa (Studi Kasus : Lembaga GNOTA Kediri)”. Diharapkan dalam pemilihan penerima beasiswa digunakan metode AHP dan SVM untuk dapat menghasilkan *output* yang sesuai dengan keadaan atau kriteria yang ada sehingga dapat memudahkan Lembaga GNOTA dalam melakukan pengambilan keputusan dan meminimalkan kesalahan dalam pengambilan kebijakan.

2. PERMASALAHAN

Dari paparan pendahuluan, penelitian ini merumuskan permasalahan bagaimana implementasi dari metode AHP dan SVM untuk klasifikasi penerima beasiswa pada Lembaga GNOTA Kediri dan bagaimana tingkat akurasi yang dihasilkan oleh sistem dari hasil implementasi metode AHP dan SVM tersebut.

3. TINJAUAN PUSTAKA

3.1 Studi terkait

Sebagai bahan referensi dalam penelitian Penerapan Metode AHP dan SVM untuk Klasifikasi Penerima Beasiswa (Studi Kasus

Lembaga GNOTA Kediri), berikut beberapa penelitian yang sudah ada menggunakan metode AHP dan SVM. Pada penelitian pertama membahas mengenai pemilihan pemasok layanan logistik. Pada penelitian tersebut permasalahan yang diangkat mengenai persaingan perusahaan yang semakin sengit diiringi dengan pesatnya kemajuan Teknologi Informasi sehingga memicu perusahaan harus lebih selektif dalam melakukan pemilihan pemasok layanan logistik. Akan tetapi, kurangnya metode yang efektif untuk memilih pemasok layanan logistik yang benar-benar sesuai untuk pengembangan usaha menyebabkan kegagalan logistik *outsourcing*. Metode AHP dipilih untuk penelitian di atas karena AHP dinilai lebih sesuai dalam hal evaluasi, disisi lain AHP menyediakan referensi rekomendasi bagi perusahaan untuk memilih pemasok layanan logistik yang sesuai.

Pada penelitian kedua yang dilakukan oleh Mohanty dan Bebartta (2011) membahas mengenai perbandingan metode SVM dan KNN untuk pengenalan karakter bahasa Oriya (bahasa dinegara bagian barat India). Pada penelitian tersebut menghasilkan nilai akurasi dengan metode SVM lebih tinggi jika dibandingkan dengan metode KNN yakni sebesar 98.9% untuk SVM dan 96.47% untuk KNN.

Pada penelitian ketiga membahas mengenai pemilihan letak transmisi dan stasiun transformasi pada negara bagian barat Mongolia. Dalam melakukan pemilihan letak transmisi dan stasiun transformasi, terdapat beberapa variabel yang digunakan mulai dari indeks situasi geologi dan geografi, indeks *engineering*, indeks faktor konstruksi, indeks ekonomi dan faktor lainnya yang menghasilkan letak transmisi dan stasiun transformasi dari Baotou ke Hohhot yang dikategorikan ideal dan non-ideal. Penelitian ini menghasilkan nilai akurasi sebesar 80%.

Pada penelitian keempat yang dilakukan oleh Dr. S. Vijayarani dan Mr. S. Dhayanand (2015) membahas mengenai prediksi penyakit hati menggunakan metode SVM dan *Naive Bayes*. Perbandingan algoritma ini dilakukan dan didasarkan pada akurasi kinerja faktor klasifikasi dan waktu pelaksanaan.

3.2 Dasar Teori

Beasiswa

Beasiswa merupakan pendanaan yang diberikan oleh pemerintah, perusahaan swasta, kedutaan, universitas serta lembaga pendidik atau peneliti, atau dari kantor tempat bekerja seseorang.

Basiswa diberikan kepada yang berhak menerima berdasarkan klasifikasi, kualitas dan kompetensi penerima beasiswa (Ghafur, Abdul, 2008). Seperti halnya pada Lembaga GNOTA Kediri yang memiliki program pemberian beasiswa terhadap mahasiswa yang baru masuk ke Perguruan Tinggi Negeri (PTN). Disamping banyaknya pengaju beasiswa, banyaknya kriteria yang digunakan untuk proses seleksi tentu mempersulit tahap pemilihan beasiswa.

Berdasarkan uraian di atas dapat disimpulkan bahwa pemberian beasiswa dilakukan berdasarkan proses seleksi agar beasiswa yang disalurkan tepat sasaran dan diterima oleh pihak yang tepat. Dalam penelitian ini, kriteria-kriteria yang menjadi dasar Lembaga GNOTA Kediri mengambil keputusan pada pemberian beasiswa ada 13 kriteria seperti pada Tabel berikut.

Tabel 3.1 Kriteria Penerimaan Beasiswa

No	Jenis Kriteria	Inisial
1	Penghasilan orang tua/wali	C1
2	Jumlah Tanggungan	C2
3	Pekerjaan orang tua/wali	C3
4	Daya listrik	C4
5	Biaya listrik	C5
6	Jumlah rumah	C6
7	Status rumah	C7
8	Kondisi dinding	C8
9	Kondisi lantai	C9
10	PBB	C10
11	Jumlah motor	C11
12	Jumlah mobil	C12
13	Program beasiswa	C13

Gerakan Nasional Orang Tua Asuh (GNOTA)

Gerakan Nasional Orang Tua Asuh (GNOTA) merupakan suatu gerakan inisiatif masyarakat yang berfungsi untuk menjaga agar anak-anak Indonesia mendapatkan pendidikan dari sekolah dasar yang menjadi landasan dalam meraih masa depan yang lebih baik lagi. GNOTA memberikan bantuan terhadap masyarakat dengan mendistribusikan bantuan berupa donasi uang dan pendidikan untuk membantu anak-anak yang kurang mampu agar dapat melanjutkan pendidikan secara berkala. Pada lembaga GNOTA Kediri, sebelum memberikan beasiswa mereka melakukan sosialisasi ke sekolah-sekolah yang ada di Kabupaten Kediri mengenai program beasiswa yang akan dibuka. Selanjutnya pengaju beasiswa mengirim berkas persyaratan pengajuan beasiswa ke Lembaga GNOTA Kediri dan akan dilakukan seleksi terhadap pengaju beasiswa tersebut. GNOTA Kab.Kediri membatasi penerima beasiswa dengan hanya menampung pengaju beasiswa yang berdomisili di Kabupaten Kediri. Beberapa program beasiswa yang diberikan yakni beasiswa alih jenjang dari SD ke SMP, beasiswa alih jenjang dari SMP ke SMA, dan

beasiswa alih jenjang dari SMA ke Perguruan Tinggi Negeri (PTN). Dengan adanya GNOTA dapat membantu anak-anak Indonesia untuk melanjutkan pendidikannya ke jenjang yang lebih tinggi (GNOTA, 2015).

Sistem Pendukung Keputusan

Sistem Pendukung Keputusan sebuah sistem yang dimaksudkan untuk mendukung para pengambil keputusan manajerial dalam situasi keputusan semi terstruktur (Efraim, Aronson & Liang, 2015). Tujuan dari sistem pendukung keputusan yaitu agar memperluas kemampuan pengambil keputusan dalam proses pengambil keputusan serta menghasilkan solusi yang cepat, sehingga nantinya dapat digunakan untuk memperkuat pengambilan keputusan terhadap keputusan yang akan diambil.

Sistem pendukung keputusan juga mampu menyelesaikan masalah dan keadaan yang dihadapi sehingga dapat mempercepat waktu, SDM dan biaya yang dibutuhkan dalam memecahkan masalah terutama dalam berbagai permasalahan yang sangat kompleks. Sistem ini juga membantu menghemat waktu, tenaga dan biaya yang dibutuhkan untuk memecahkan suatu permasalahan terutama dalam berbagai permasalahan yang sangat kompleks.

AHP (Analytical Hierarchy Process)

Pada dasarnya tahap atau proses dari pengambilan keputusan merupakan memilih suatu alternatif. AHP umumnya digunakan dengan tujuan untuk menyusun prioritas dari berbagai alternatif pilihan yang ada dan pilihan-pilihan tersebut bersifat kompleks atau multi kriteria (Burgeois, 2005). Metode AHP dikembangkan pada tahun 1970 oleh Thomas L. Saaty. Pada awalnya metode AHP dikembangkan untuk memecahkan masalah pada suatu instansi yang kompleks dan yang tidak memiliki struktur kedalam bagian-bagiannya.

Berikut beberapa kelebihan penggunaan metode AHP adalah sebagai berikut (Suryadi & Ramdhani, 1988) :

1. Struktur yang berbentuk hirarki sebagai konsekuensi dari kriteria yang dipilih sampai pada sub kriteria yang paling dalam.
2. Memperhatikan validitas sampai dengan batas toleransi inkonsistensi keputusan.
3. Memperhitungkan daya tahan atau ketahanan keluaran analisis sensitifitas pembuat keputusan

Sekalipun itu metode AHP mempunyai kemampuan untuk memecahkan masalah yang multi objek dan multi kriteria berdasarkan pada

perbandingan preferensi dari pembuatan keputusan yang sangat komperhensif.

Langkah-langkah penyelesaian dengan metode AHP (Saat, T. L. 1991) :

1. Mendefinisikan permasalahan dan menentukan tujuan.
2. Menyusun masalah ke dalam suatu struktur hierarki sehingga permasalahan yang kompleks dapat ditinjau dari sisi yang detail dan terukur.
3. Menghitung nilai prioritas untuk tiap elemen masalah pada setiap hierarki. Prioritas ini dihasilkan dari suatu matriks perbandingan berpasangan antara seluruh elemen pada tingkat hierarki yang sama.

Tabel 3. 2 Susunan Matriks Perbandingan Berpasangan

	A1	A2	A3
A1	1	A ₁₂	A ₁₃
A2	A _{ij}	1	A ₂₃
A3	A _{ij}	A _{ij}	1

Sumber : Saaty, T.L (1991)

Rumus Perhitungan kolom A_{ij} seperti Persamaan 1 berikut :

$$A_{ij} = \frac{1}{A_{ji}} \quad (1)$$

4. Melakukan pengajuan konsistensi terhadap perbandingan antar elemen yang ditempatkan pada tingkat hierarki untuk digunakan dalam perhitungan perangkingan akhir.
5. Proses sintesis dengan menjumlahkan nilai-nilai pada setiap kolom matrik perbandingan berpasangan dengan membagi setiap nilai dari kolom dengan total kolom yang bersangkutan untuk memperoleh normalisasi matriks.
6. Pembobotan dengan menjumlahkan nilai-nilai dari setiap baris dan membaginya dengan jumlah kriteria dengan Persamaan 2 berikut :

$$\text{Bobot Prioritas} = \frac{A_{ij}}{\text{jumlah perkolomkriteria}} \quad (2)$$

7. Menghitung konsistensi untuk mengetahui seberapa baik konsistensi yang ada seperti pada Persamaan 3 berikut :

$$CI = \frac{(\lambda_{max} - n)}{n - 1} \quad (3)$$

Keterangan :

- CI merupakan *Consistency Index* yang akan dihitung.
 - λ_{max} merupakan nilai yang didapat dari perhitungan sebelumnya.
 - n merupakan banyak kriteria yang kita gunakan,
8. Menghitung *Consistency Ratio* (CR) menggunakan persamaan 4 berikut :

(4)

$$CR = \frac{CI}{IR}$$

Keterangan :

- CI merupakan *Consistency Index*
 - IR merupakan *Index Random Consistency* yang didapat dari tabel Ratio Index.
9. Memeriksa konsistensi hierarki berdasarkan Tabel 2. Jika nilainya < 0.1 maka hasil perhitungan bisa dinyatakan benar atau konsisten.

Tabel 3.3 Ratio Index

N	1	2	3	4	5
RI	0.00	0.00	0.58	0.90	1.12
N	6	7	8	9	10
RI	1.24	1.32	1.41	1.45	1.49
N	11	12	13	14	15
RI	1.51	1.48	1.56	1.57	1.59
N	16	17	18	19	20
RI	1.59	1.60	1.61	1.66	1.63
N	21	22	23	24	25
RI	1.64	1.64	1.65	1.65	1.66
N	26	27	28	29	30
RI	1.66	1.67	1.67	1.67	1.68
N	31	32	33	34	35
RI	1.68	1.68	1.68	1.68	1.69
N	36	37	38	39	
RI	1.69	1.69	1.7	1.7	

Sumber : (Alonso,Jose Antonio & Lamata, M.Teresa 2006)

Klasifikasi

Klasifikasi adalah bentuk dari analisis data dengan membuat suatu model atau fungsi untuk menggambarkan kelas data penting (Han, Kamber, & Pei, 2012). Model atau classifier dibangun untuk memprediksi suatu kelas. Dalam proses klasifikasi terdapat dua data yang berbeda yakni data training dan data testing. Data training digunakan untuk uji coba pada data yang belum mempunyai kelas berdasarkan aturan pada data training. Berikut merupakan tahapan klasifikasi :

1. Learning Step

Merupakan bentuk analisis data dengan membangun model atau classifier. Pada tahap ini suatu model klasifikasi dibangun dengan menggunakan data yang telah diketahui kelasnya untuk perkiraan.

2. Classification Step

Pada tahap ini suatu model digunakan untuk memprediksi kelas dengan memberikan label pada data yang akan digunakan.

Support Vector Machine (SVM)

Support Vector Machine (SVM) merupakan seperangkat metode pembelajaran mesin pada teori

statistik Vladimir Vapink (Kartal Hasan Basri, Cebi Farhan. 2013). Metode SVM merupakan salah satu metode yang digunakan untuk pemilihan variabel dan proses klasifikasi data (Novianti Fourina Ayu, Purnami Santi Wulan. 2012). Dalam teknik pemecahan masalah menggunakan metode SVM dilakukan dengan menentukan suatu *hyperplane* terbaik. *Hyperplane* merupakan suatu bidang pemisah yang terletak di tengah antara dua set objek dari dua kelas.

SVM dapat melakukan proses generalisasi untuk menentukan pola tertentu berdasarkan data *testing* dan data *training*. SVM memiliki struktur yang sederhana sehingga cepat dalam menyelesaikan permasalahan. Metode SVM memiliki kemampuan menemukan fungsi pemisah (*classifier*) yang optimal (Damayanti Fitri, Arifin Agus Zainal. 2010). Metode SVM dalam penerapannya dapat digunakan hanya untuk klasifikasi dua kelas dan selalu memberikan hasil yang sama dalam setiap kali melakukan proses *running*.

Support Vector Machine Non-Linier

Persamaan *non-linier* dapat di transformasikan dalam persamaan linier dengan menggunakan dimensi yang tinggi (Kartal Hasan Basri, Cebi Farhan. 2013). Sebuah fungsi *kernel* tanpa harus mengetahui wujud dari fungsi *non-linier*. *Kernel trick* dapat dirumuskan pada Persamaan 5.

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \tag{5}$$

Dimana :

$K(x_i, x_j)$ = fungsi kernel

$\phi(x_i)$ = transformasi data ke-*i*

Notasi x_i, x_j dengan *dot product* dapat diganti dengan simbol *K*. Pada dasarnya untuk mendapatkan *hyperplane* yang optimal dapat menggunakan model *quadratic problem* yang dijelaskan seperti pada Persamaan 6.

$$\min \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j K(x_i, x_j) \tag{6}$$

Dengan batasan sebagai berikut :

$$\sum_{i=1}^n \alpha_i y_i = 0, 0 \leq \alpha_i \leq C \text{ dan } i = 1, 2, \dots, n$$

Nilai $K(x, y)$ merupakan fungsi *kernel* yang menunjukkan pemetaan *non-linier* pada *feature space*. Solusi yang diperoleh untuk fungsi keputusan klasifikasi optimal dapat dilihat pada Persamaan 7.

$$f(x) = \sum_{i=1}^m \alpha_i y_i K(x_i, x_j) + b \tag{7}$$

Dimana :

$K(x_i, x_j)$ = fungsi *kernel* pada Persamaan 5.

y_i = target/kelas (*sample* positif (+1) dan *sample* negatif (-1))

b = bilangan skalar yang menyatakan bias.

Masing-masing *kernel* dapat digunakan dalam percobaan untuk menentukan parameter *kernel* dan memberikan keakuratan yang terbaik dalam proses klasifikasi. Proses SVM dimulai dengan perhitungan fungsi *kernel*. Berikut beberapa fungsi *kernel* yang dapat digunakan :

a. Fungsi *linier* didefinisikan pada Persamaan 8.

$$K(x, x_i) = x \cdot x_i \tag{8}$$

b. Fungsi *Polynomial* didefinisikan pada Persamaan 9.

$$K(x, x_i) = (x \cdot x_i)^d \tag{9}$$

c. Fungsi *Gaussian RBF* didefinisikan pada Persamaan 10.

$$K(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma^2}\right) \tag{10}$$

d. Fungsi *Sigmoid* didefinisikan pada Persamaan 2.11.

$$K(x, x_i) = \tanh(\sigma(x, x_i) + C) \tag{11}$$

Kernel Linier digunakan ketika data yang akan diklasifikasikan dapat dipisahkan dengan sebuah garis atau *hyperplane*. Sedangkan *kernel non-linier* digunakan ketika data hanya dapat dipisahkan dengan garis lengkung atau sebuah bidang pada ruang yang berdimensi tinggi.

Multi-Class SVM

Vapink yang pertama kali memperkenalkan SVM, dimana pada saat itu SVM hanya mampu mengklasifikasikan data ke dalam dua kelas (*binary classifier*). SVM dapat diterapkan pada pengklasifikasi data yang sifatnya *multi-class* dengan menggunakan dua pendekatan yang umum dilakukan. Pendekatan pertama yakni dengan cara menggabungkan semua data yang terdiri dari beberapa kelas ke dalam permasalahan optimasi.

Dalam permasalahan optimasi yang harus diselesaikan, pendekatan kedua jauh lebih rumit dalam penggunaannya. Beberapa metode yang digunakan pada pendekatan pertama yakni metode *One-against-all* dan *Directed Acyclic Graph Support Vector Machine* (DAGSVM). Pada penelitian ini pengklasifikasian dengan *multi-class* SVM dengan metode *One-against-all*. Metode *One-against-all* merupakan metode klasifikasi *multi-class* yang dikembangkan berdasarkan sejumlah *k* SVM biner. (*k* adalah jumlah kelas) (Yang Yi Du. 2010).



Metode Sequential Training pada SVM

Hyperplane yang optimal pada SVM dapat ditemukan dengan merumuskannya ke dalam *quadratic problem* dan diselesaikan dengan analisa numerik. Metode ini dikembangkan oleh Vijayakumar untuk mencari nilai α , dapat dijelaskan dalam tahapan berikut (Vijayakumar, 1999) :

1. Setelah perhitungan *kernel* selesai dilakukan, selanjutnya dilakukan inisialisasi untuk parameter SVM misalnya nilai $\alpha_i = 0$, nilai $\lambda = 0.5$, $\gamma = 0.01$, $\varepsilon = 0.0001$ dan $C = 1$.
2. Lakukan penghitungan komponen matriks pada Persamaan 12.

$$D_{ij} = y_i y_j (K(x_i, x_j) + \lambda^2) \quad (12)$$

Notasi x merupakan data ke- i dan data ke- j . Notasi y merupakan kelas dari data ke- i dan data ke- j . $K(x_i, x_j)$ merupakan fungsi kernel yang digunakan. Lakukan langkah 1 dan langkah 2 untuk $i, j = 1, 2, \dots, n$.

3. Untuk setiap $i = 1, 2, \dots, n$ dihitung menggunakan Persamaan 13 sampai dengan 16.

- a. $E_i = \sum_{j=1}^n \alpha_j D_{ij} \quad (13)$

- b. $\delta \alpha_i = \min\{\text{maks}[y(1 - E_i), -\alpha_i], C - \alpha_i\} \quad (14)$
 $\delta \alpha_i$ adalah variabel tunggal, bukan bentuk perkalian δ dan α_i .

- c. $\alpha_i = \alpha_i + \delta \alpha_i$ (memperbarui nilai α_i) (15)

Notasi γ adalah parameter untuk mengontrol kecepatan proses *learning* (*learning rate*). Nilai konstanta untuk parameter γ dapat dilihat pada Persamaan 16.

$$\gamma = \frac{CLR}{\max_{\{i\}} D_{ii}} \quad (16)$$

$\max_{\{i\}} D_{ii}$ merupakan nilai maksimum yang diperoleh dari nilai diagonal pada matriks. Dengan menggunakan nilai konstanta untuk nilai yang diinputkan oleh pengguna dalam pengujian 0.01. fungsi dari $\delta \alpha_i$ merupakan fungsi konvergensi untuk memantau perubahan suatu fungsi dari *Lagrange Multiplier*. Jika data latih telah mencapai konvergen $\max(|\delta \alpha_i| < \varepsilon)$, dan ketika nilai maksimum dari iterasi mencapai nilai yang ditentukan maka iterasi akan dihentikan.

- d. Proses tersebut diulangi sampai α mencapai nilai konvergen. Konvergen dapat didefinisikan dari tingkat perubahan pada nilai α .
- e. Mendapatkan nilai *Support Vector* dapat diketahui dengan ($\alpha_i > \text{ThresholdSV}$). Nilai *ThresholdSV* ditentukan dari

beberapa kali uji coba. Nilai *ThresholdSV* tersebut adalah $\text{ThresholdSV} \geq 0$.

Evaluasi

Evaluasi dilakukan untuk mengetahui tingkat akurasi dari hasil klasifikasi dengan cara menghitung jumlah *record* uji yang kelasnya diprediksi secara tepat (akurat). Menurut Sarkar & Leong (2000), persentase akurasi diperoleh dengan Persamaan 17 berikut :

$$\text{Classification Accuracy} = \frac{TP+TN}{TP+FP+FN+TN} \quad (17)$$

Jumlah prediksi benar adalah jumlah *record* data uji yang diprediksi kelasnya menggunakan metode klasifikasi dan hasilnya sama dengan kelas sebenarnya. Sedangkan jumlah total prediksi adalah keseluruhan *record* yang diprediksi kelasnya (seluruh data uji). Persamaan 17 dapat ditentukan dengan menggunakan nilai yang sudah ditentukan pada *confusion matrix*. *Confusion Matrix* 3x3 dapat dilihat pada Tabel 3.4 berikut :

Tabel 3.4 Confusion Matrix 3x3

		Predicted Class		
		Class 1	Class 2	Class 3
Actual Class	Class 1	X_{11}	X_{21}	X_{31}
	Class 2	X_{12}	X_{22}	X_{32}
	Class 3	X_{13}	X_{23}	X_{33}

Sumber : Hermaduanty dan Kusumadewi (2008)

Keterangan :

$$TP = X_{11} + X_{12} + X_{13}$$

$$FP = (X_{21} + X_{31}) + (X_{12} + X_{32}) + (X_{23} + X_{33})$$

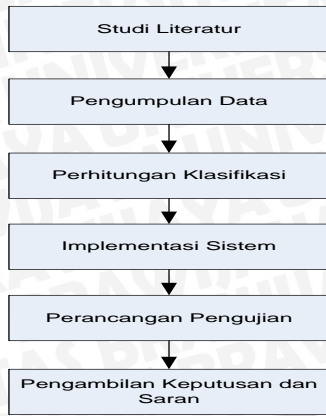
$$FN = (X_{12} + X_{13}) + (X_{21} + X_{23}) + (X_{31} + X_{32})$$

$$FP = (X_{22} + X_{33}) + (X_{11} + X_{33}) + (X_{11} + X_{22})$$

4. METODE PENELITIAN DAN PERANCANGAN

4.1 Metode Penelitian

Pada tahap ini menjelaskan mengenai langkah-langkah dan algoritma yang digunakan untuk membuat klasifikasi penerima beasiswa dengan metode AHP dan SVM. Langkah-langkah yang dilakukan dalam penelitian ini seperti yang terlihat pada Gambar 4.1.



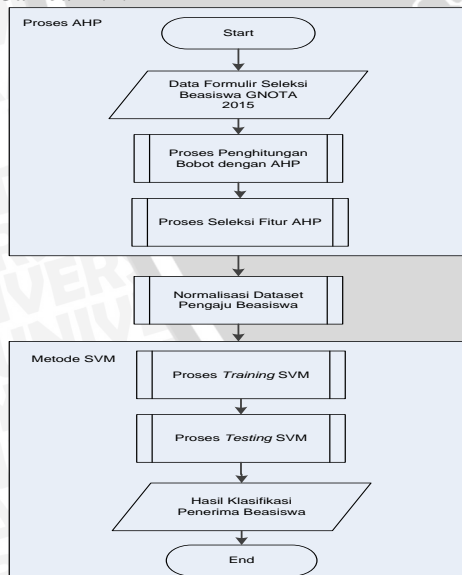
Gambar 4. 1 Blok Diagram Pelaksanaan Penelitian

Pada Gambar 4.1 merupakan blok diagram pelaksanaan penelitian. Langkah-langkah dalam pelaksanaan penelitian ini sebagai berikut :

1. Studi literatur
2. Pengumpulan data
3. Perhitungan klasifikasi
4. Implementasi sistem
5. Perancangan pengujian
6. Pengambilan keputusan dan saran.

4.2 Perancangan Sistem

Model perancangan sistem akan digambarkan dalam bentuk diagram blok yang menggambarkan aliran proses dari komponen-komponen sistem. Diagram ini menjelaskan cara kerja sistem mulai dari masukan sampai keluaran yang dihasilkan. Model perancangan sistem klasifikasi penerima beasiswa dengan metode AHP dan SVM seperti pada Gambar 4.2.



Gambar 4.2 Diagram Alir Klasifikasi Penerima Beasiswa

Gambar 4.2 menunjukkan diagram alir tahap klasifikasi penerima beasiswa dengan metode AHP dan SVM yang meliputi :

1. Diberikan inputan berupa data parameter penilaian penerima beasiswa peserta.
2. Proses perhitungan bobot dengan metode AHP.
 - a. Perhitungan nilai matriks perbandingan berpasangan seperti pada Tabel 4.1.

Tabel 4.1 Matrik Perbandingan Berpasangan

	C1	C2	C3	..	C11	C12	C13
C1	1	6	4	..	5	6	4
C2	0.16	1	4	..	2	3	3
C3	0.25	0.25	1	..	3	3	5
..
C11	0.2	0.5	0.33	..	1	3	5
C12	0.16	0.33	0.33	..	0.33	1	6
C13	0.25	0.33	0.20	..	0.2	0.16	1

- b. Perhitungan Normalisasi matrik perbandingan. Berikut merupakan contoh perhitungan untuk normalisasi matrik perbandingan.

$$Norm_{11} = \frac{A_{11}}{\text{jumlah perkolom kriteria}}$$

$$Norm_{11} = \frac{1}{3.85} = 0.26$$

Dimana A_{11} merupakan nilai bobot pada matrik perbandingan berpasangan pada baris pertama kolom pertama. Hasil dari normalisasi matriks dapat dilihat pada Tabel 4.2.

Tabel 4.2 Normalisasi Matriks

	C1	C2	C3	..	C12	C13	Σ
C1	0.26	0.57	0.35	..	0.15	0.09	2.83
C2	0.04	0.09	0.35	..	0.08	0.07	1.75
C3	0.06	0.02	0.09	..	0.08	0.11	1.82
..
C11	0.05	0.05	0.03	..	0.03	0.14	0.40
C12	0.04	0.03	0.03	..	0.00	0.02	0.28
C13	0.06	0.03	0.02	..	0.03	0.14	0.40

Selanjutnya melakukan penghitungan bobot setiap kriteria dengan membagi hasil penjumlahan baris normalisasi dengan banyaknya kriteria.

$$CI = \frac{2.83}{13} = 0.22$$

Hasil dari penghitungan bobot kriteria AHP dapat dilihat pada Tabel 4.3.

Tabel 4.3 Hasil Perhitungan Bobot AHP

C	Bobot	C	Bobot	C	Bobot
C1	0.22	C6	0.09	C11	0.04
C2	0.13	C7	0.04	C12	0.03
C3	0.10	C8	0.05	C13	0.02
C4	0.07	C9	0.04		
C5	0.09	C10	0.04		

Selanjutnya melakukan perhitungan untuk mendapatkan nilai A_x .

$$Ax = (1 \times 0.22) + (6 \times 0.013) + (4 \times 0.14) + (3 \times 0.10) + (3 \times 0.07) + (5 \times 0.09) + (5 \times 0.04) + (4 \times 0.05) + (4 \times 0.04) + (4 \times 0.04) + (5 \times 0.04) + (6 \times 0.03) + (4 \times 0.02) = 3.67$$

Setelah didapatkan nilai A_x maka dilakukan perhitungan untuk mendapatkan nilai λ_{maks} .

$$\lambda_{maks} = \frac{\left(\begin{array}{l} \left(\frac{3.67}{0.22}\right) + \left(\frac{2.34}{0.13}\right) + \left(\frac{2.30}{0.14}\right) + \left(\frac{1.61}{0.10}\right) + \left(\frac{1.01}{0.07}\right) + \\ \left(\frac{1.32}{0.09}\right) + \left(\frac{0.53}{0.04}\right) + \\ \left(\frac{0.69}{0.05}\right) + \left(\frac{0.65}{0.04}\right) + \left(\frac{0.63}{0.04}\right) + \left(\frac{0.56}{0.45}\right) + \left(\frac{0.03}{0.45}\right) + \left(\frac{0.02}{0.33}\right) \end{array} \right)}{13} = 14.526$$

- c. Penghitungan untuk mendapatkan nilai *Consistency Index* (CI) dan *Consistency Ratio* (CR).

$$CI = \frac{(14.526 - 13)}{13 - 1} = 0.127$$

$$CR = \frac{0.127}{1.56} = 0.08$$

Jika nilai CR < 0.1 maka perhitungan tersebut konsisten.

- d. Setelah perhitungan terhadap kriteria utama AHP maka selanjutnya perhitungan terhadap setiap sub kriteria. Berikut merupakan hasil perhitungan bobot sub kriteria AHP.

Tabel 4.4 Bobot Kriteria Setelah Reduksi

P	Bobot	P	Bobot	P	Bobot	P	Bobot
P1	0.095	P14	0.034	P27	0.008	P40	0.003
P2	0.067	P15	0.029	P28	0.025	P41	0.016
P3	0.029	P16	0.018	P29	0.008	P42	0.009
P4	0.016	P17	0.009	P30	0.003	P43	0.005
P5	0.010	P18	0.005	P31	0.032	P44	0.005
P6	0.082	P19	0.004	P31	0.010	P45	0.002
P7	0.037	P20	0.033	P33	0.003	P46	0.017
P8	0.016	P21	0.017	P34	0.030	P47	0.009
P9	0.070	P22	0.009	P35	0.010	P48	0.005
P10	0.032	P23	0.005	P36	0.004	P49	0.011
P11	0.021	P24	0.003	P37	0.022	P50	0.011
P12	0.010	P25	0.062	P38	0.011		
P13	0.007	P26	0.018	P39	0.006		

- Selanjutnya dilakukan *filter* sub kriteria dengan menggunakan nilai *Threshold*=0.015.
- Proses normalisasi dataset pengaju beasiswa dengan nilai batas atas dan batas bawah yang digunakan adalah [0.9,...,0.1]. berikut adalah hasil perhitungan normalisasi dataset.

$$p'_{11} = \left(\frac{0-0}{5-0} \right) \times (0.9 - 0.1) + 0.1 = 0.1$$

- Proses perkalian bobot sub kriteria AHP dengan data *training* dan data *testing*.
 $x_{11} = 0.1 \times 0.095 = 0.01$
 Dimana 0.1 merupakan hasil normalisasi data pertama dan 0.095 merupakan hasil perhitungan bobot sub kriteria P1.
- Perhitungan Kernel SVM
 $K(x, y)$, misal $x = x_1, y = x_1, d = 2$ seperti pada Persamaan 9.

$$[x \cdot y]^2 = \left(\begin{array}{l} (0.01 \times 0.01) + (0.05 \times 0.05) + (0.003 \times 0.003) \\ + (0.002 \times 0.002) + (0.008 \times 0.008) + (0.004 \times 0.004) \\ + (0.008 \times 0.008) + (0.063 \times 0.063) + (0.003 \times 0.003) \\ + (0.002 \times 0.002) + (0.003 \times 0.003) + (0.003 \times 0.003) \\ + (0.016 \times 0.016) + (0.003 \times 0.003) + (0.015 \times 0.015) \\ + (0.006 \times 0.006) + (0.11 \times 0.11) + (0.023 \times 0.023) \\ + (0.003 \times 0.003) + (0.003 \times 0.003) + (0.020 \times 0.020) \\ + (0.002 \times 0.002) + (0.015 \times 0.015) \end{array} \right)^2 = 0.000073$$

7. Perhitungan *Sequential Training SVM*

- Inialisasi nilai $\alpha_i = 0$
- Menghitung komponen matriks pada Persamaan 12. Inialisasi nilai lamda $\lambda = 0.5$. Berikut contoh penghitungan *record* pertama :
 $D_{1,1} = 1 \times 1 \times (0.000073 + 0.5^2) = 0.25007295$
- Menghitung nilai γ seperti pada Persamaan 16, dimana konstanta *Learning rate* dibagi dengan max diagonal komponen matriks.
 $\gamma = \frac{0.01}{0.25007} = 0.039988331$
- Menghitung E_i seperti pada Persamaan 13.

$$E_1 = \left(\begin{array}{l} (0 \times 0.25007) + (0 \times 25002) \\ + (0 \times 0.25006) + (0 \times -0.25000) \\ + (0 \times -0.25000) + (0 \times -0.25000) \\ + (0 \times -0.25000) + (0 \times -0.25000) \end{array} \right) = 0$$

- Menghitung nilai $\delta\alpha_i$ dengan Persamaan 14. Contoh perhitungan *record* pertama sebagai berikut :
 $\delta\alpha_i = \min\{\max[0.039988331(1 - 0), -0], 1 - 0\}$
 $\delta\alpha_i = \min\{0.039988331, 1\}$
 $\delta\alpha_i = 0.039988331$
- Memperbaharui nilai α_i dengan Persamaan 15. Contoh perhitungan *record* pertama sebagai berikut :
 $\alpha_i = 0 + 0.39988331 = 0.39988331$
- Mencari nilai x^+ dan x^- selanjutnya dilakukan perhitungan $K(x_i, x^+)$ dan $K(x_i, x^-)$ dimana :
 $x^+ =$ data *training* yang memiliki nilai α_i paling besar dari *class positive*.
 $x^- =$ data *training* yang memiliki nilai α_i paling besar dari *class negative*.
- Mencari nilai w dan menghitung nilai *bias*.

- Proses *Testing SVM*
 Proses *testing SVM* menggunakan Persamaan 7.
 $f(x) = \text{sign}(0.000009310 + (-0.000002657))$
 $f(x) = \text{sign}(0.00000665)$
 $f(x) = 1$
- Proses *One-Against-All*
 Pada proses ini jika hasil dari proses *testing SVM* menghasilkan -1 maka akan dihitung ulang pada pengujian level 2. Hasil model

evaluasi *confusion matriks* dapat dilihat pada Tabel 4.5.

Tabel 4.5 Evaluasi Confusion Matriks

Actual Class	Predicted Class			Jumlah
	A	B	C	
A	0	0	1	1
B	0	1	0	1
C	0	1	0	1

$$\text{Akurasi} = \frac{2 + 4}{2 + 4 + 1 + 1} = 75\%$$


HASIL DAN PEMBAHASAN

Terdapat beberapa tahap pengujian dalam sistem yaitu :

1. Pengujian untuk mengetahui perbandingan data *training* dan data *testing* terhadap hasil akurasi.
2. Pengujian untuk mengetahui pengaruh nilai *threshold* AHP terhadap hasil akurasi.
3. Pengujian terhadap tingkat akurasi dari pengaruh nilai parameter lamda.
4. Pengujian untuk mengetahui pengaruh nilai konstanta *gamma* terhadap nilai akurasi.
5. Pengujian tingkat akurasi terhadap nilai *epsilon*.
6. Pengujian tingkat akurasi terhadap nilai iterasi maksimum.
7. Pengujian untuk mengetahui pengaruh nilai C terhadap akurasi.

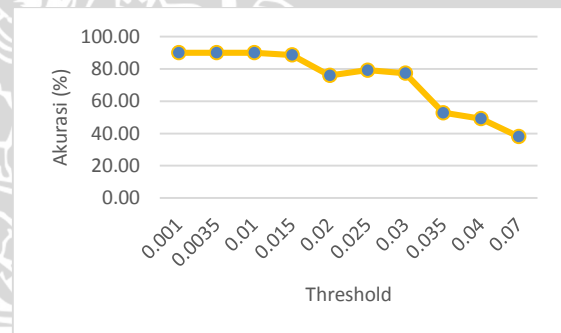
Analisis

Gambar 5.1 menunjukkan hasil pengujian perbandingan data *training* dan data *testing* terhadap akurasi, dimana pada pengujian tersebut dilakukan sebanyak 9 macam rasio perbandingan data. Tingkat akurasi tertinggi pada rasio 90%:10% dengan rata-rata nilai akurasi sebesar 88.56%.



Gambar 5.1 Grafik Tingkat Akurasi Rasio Perbandingan


Analisis dilakukan terhadap pengujian rasio perbandingan data *training* dan data *testing* dimana diketahui bahwa rata-rata tingkat akurasi tertinggi sebesar 88.56% dan akurasi terbaik pada 93.10% yang menggunakan rasio perbandingan 90%:10% dimana pada pengujian selanjutnya akan menggunakan rasio 90%:10%. Pemilihan data *training* dan data *testing* dilakukan secara *random*, dimana hasil *random* dengan akurasi terbaik akan disimpan untuk dibandingkan dengan hasil *random* lainnya yang akan digunakan untuk proses pengujian selanjutnya. Pada Gambar 5.2 menunjukkan bahwa grafik hasil pengujian terhadap rasio perbandingan meningkat ketika nilai perbandingan antara data *training* dan data *testing* semakin tinggi karena dengan banyaknya data *training* yang digunakan maka sistem akan semakin cerdas dimana sistem dapat mengenali lebih banyak pola data yang terbentuk sehingga dapat menghasilkan akurasi yang tinggi. Begitupula sebaliknya, jika perbandingan nilai data *training* dan data *testing* semakin rendah maka akurasi yang dihasilkan juga menurun.



Gambar 5.2 Pengujian Terhadap Pengaruh Nilai Threshold

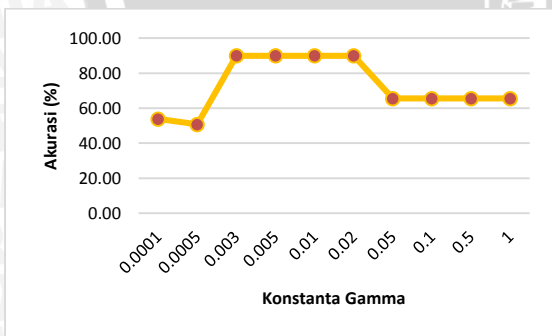
Gambar 5.2 menunjukkan grafik hasil pengujian terhadap nilai *threshold* dimana rata-rata akurasi terbaik sebesar 89.94% dengan menggunakan nilai *threshold* 0.001, 0.0035, dan 0.01. Pada proses pengujian selanjutnya akan digunakan nilai *threshold* 0.01 dengan 33 fitur terpilih karena terlihat bahwa pada nilai *threshold* 0.01 memiliki rata-rata waktu eksekusi tercepat sebesar 23.55 detik, sedangkan nilai *threshold* 0.001 membutuhkan waktu 23.89 detik dan nilai *threshold* 0.0035 membutuhkan waktu 23.84 detik. Semakin besar nilai *threshold* yang digunakan maka akan semakin sedikit fitur yang terpilih sehingga mengakibatkan menurunnya tingkat akurasi yang dihasilkan oleh sistem. Nilai *threshold*

AHP adalah batasan nilai bobot kriteria yang akan digunakan dalam proses pengujian.



Gambar 5.3 Pengujian Terhadap Pengaruh Nilai Parameter Lamda


Gambar 5.3 merupakan grafik hasil dari pengujian nilai λ (Lamda) dimana diketahui akurasi tertinggi sebesar 89.94% pada nilai lamda 0.5 dan 1, dimana semakin tinggi nilai dari parameter λ (Lamda) maka cenderung semakin menurun nilai akurasi yang dihasilkan karena nilai dari parameter λ (Lamda) berpengaruh terhadap perhitungan komputasi pada matriks Hessian dimana hasil dari perhitungan matriks Hessian akan mempengaruhi nilai dari perhitungan $E_{i,\delta\alpha}$ dan nilai α (alpha) baru yang akan mempengaruhi iterasi selanjutnya. Kecenderungan proses komputasi yang lama disebabkan oleh Augmented factor pada nilai λ (lamda) sehingga proses perhitungan pada sistem sangat lambat untuk memasimalkan nilai margin dan akan terjadi ketidakstabilan proses learning.



Gambar 5.4 Pengujian Terhadap Pengaruh Nilai Konstanta Gamma


Gambar 5.4 merupakan grafik hasil pengujian dari konstanta gamma dimana diketahui akurasi tertinggi untuk pengujian konstanta gamma adalah sebesar 89.94% dengan nilai gamma 0.003, 0.005 dan 0.01. nilai dari konstanta gamma berpengaruh terhadap iterasi yang terjadi. Sehingga hasil pengujian pada nilai konstanta gamma 0.0001 dan 0.0005 cenderung tidak stabil karena semakin kecil nilai konstanta gamma maka iterasi berhenti

mendekati iterasi maksimum (itermax). Jika semakin besar konstanta gamma maka semakin besar nilai learning rate. Learning rate adalah laju pembelajaran dimana semakin besar nilai learning rate maka proses pembelajaran akan semakin cepat. Namun apabila nilai learning rate relatif terlalu besar maka proses training dapat melampaui keadaan optimal yaitu pada nilai error paling minimal. Dengan kata lain, learning rate mempengaruhi ketelitian suatu sistem. Semakin besar nilai learning rate, maka ketelitian sistem akan semakin berkurang. Sebaliknya jika learning rate semakin kecil maka ketelitian suatu sistem akan semakin besar tetapi proses pembelajaran membutuhkan waktu yang lama.




Gambar 5.5 Pengujian Terhadap Nilai Epsilon

Gambar 5.5 menunjukkan grafik pengujian nilai ϵ (epsilon) dimana diketahui akurasi tertinggi sebesar 89.94% pada nilai ϵ (epsilon) 0.000000001, 0.00000001, 0.0000001, 0.000001, 0.00001, 0.0001, dan 0.001. Semakin besar nilai ϵ (epsilon) maka iterasi yang dihasilkan akan semakin sedikit. Apabila semakin kecil nilai ϵ (epsilon) maka jumlah iterasi akan semakin banyak sehingga proses learning akan berlangsung lama, maka nilai α dan nilai support vector akan semakin optimal. Iterasi berhenti pada nilai ϵ 0.0001, dan 0.001 karena telah mencapai konvergen dimana nilai $\max(|\delta\alpha_i|) < \epsilon$. Nilai α (alpha) dan *support vector* yang tidak optimal akan mempengaruhi nilai akurasi yang dihasilkan semakin rendah.



Gambar 5.6 Pengujian Terhadap Nilai Iterasi Maksimum

Gambar 5.6 merupakan grafik hasil pengujian iterasi maksimum dimana diketahui rata-rata akurasi terbaik yakni sebesar 89.94% pada iterasi ke 100, 500, 1000, 2000, 3000 dan 5000 cenderung stabil karena pada iterasi tersebut telah mencapai konvergen. Nilai iterasi maksimum dipengaruhi oleh nilai ϵ (epsilon) yang digunakan. Pada pengujian ini telah ditentukan nilai ϵ (epsilon)=0.001 dan iterasi maksimum=5000. Pada pengujian dengan iterasi 10, 20, dan 30 iterasi berhenti pada masing-masing batas maksimum iterasi karena belum memenuhi syarat konvergen dimana nilai dari $\max(|\delta\alpha| < \epsilon)$. Konvergen didefinisikan sebagai tingkat perubahan nilai α (alpha) dimana nilai berhentinya suatu iterasi akan berpengaruh pada perubahan nilai α (alpha) dan b (bias) pada proses pelatihan.



Gambar 5.7 Pengujian Terhadap Pengaruh Nilai C

Gambar 5.8 merupakan grafik hasil pengujian pengaruh nilai C (Complexity) terhadap tingkat akurasi yang dihasilkan dimana diketahui tingkat akurasi terbaik sebesar 89.94% dengan nilai $C=1$. Tujuan dari nilai C (Complexity) adalah untuk meminimalkan *error*. Semakin dekat nilai C (Complexity) dengan 0 maka lebar margin pada bidang pemisah (*hyperplane*) menjadi maksimum. Sebaliknya jika semakin besar nilai C (Complexity) maka tingkat akurasi yang dihasilkan akan semakin menurun karena jumlah data yang dilatih berada

dalam *margin* yang salah sehingga data *testing* tidak dapat diklasifikasikan dengan benar.

5. KESIMPULAN DAN SARAN

Kesimpulan

1. Klasifikasi penerima beasiswa dengan metode AHP dan SVM dengan beberapa langkah, yakni pertama penghitungan bobot kriteria dan sub kriteria data matrik perbandingan berpasangan. Selanjutnya dilakukan penyaringan terhadap bobot kriteria terpilih dimana nilai bobot pada sub kriteria tersebut di atas nilai threshold yang ditetapkan. Nilai threshold adalah nilai batasan bobot kriteria yang digunakan untuk pengujian pada proses selanjutnya. Pada penelitian ini menggunakan data yang diperoleh dari hasil interview dengan Lembaga GNOTA Kediri. Untuk proses klasifikasi dengan metode SVM diawali dengan load data training dan data testing yang dipilih secara acak berdasarkan rasio data tertentu. Selanjutnya dilakukan normalisasi dataset. Hasil dari normalisasi dataset akan dikalikan dengan sub bobot kriteria terpilih AHP. Selanjutnya dilakukan proses perhitungan kernel dan Sequential Training SVM. Setelah proses training selesai akan dilakukan proses testing yang akan menghasilkan klasifikasi berupa predicted class hasil pengujian.
2. Tingkat akurasi rata-rata yang dihasilkan oleh sistem adalah sebesar 89.74% dengan pemilihan rasio 90%:10%, nilai threshold AHP = 0.1, nilai lamda = 0.5, nilai konstanta gamma=0.003, nilai epsilon=0.001, iterasi maksimum=100 dan nilai C=1.

Saran

1. Penelitian selanjutnya diharapkan melakukan seleksi fitur secara otomatis menggunakan algoritma evolusi atau PCA karena dalam penelitian ini masih menggunakan threshold.
2. Pada penelitian selanjutnya, dalam pemilihan rasio perbandingan antara data training dan data testing diharapkan menggunakan metode K-Fold, sehingga setiap data memiliki kesempatan untuk menjadi data training dan data testing.

6. DAFTAR PUSTAKA

- Alonso, Jose Antonio., dan Lamata, M Teresa. 2006. Consistency In The AHP : A New Approach. Vo. 14, No.4, Hal 445-459.
- C. Cortes dan V. Vapnik, 1995, Machine Learning, Support Vector Network, Vol.20, Hal 273-297.
- Chih, Wei Hsu., Chih, Jen Lin. 2002. A Comparison of Methods for Multiclass Support Vector Machines. Vol.13, No.2.
- Damyanti Fitri, Arifin Agus Zainal, Soelaiman Rully. 2010. Jurnal Ilmiah Kursor, Pengenalan Citra Wajah Menggunakan Metode Two-Dimensional Linier Discriminant Analysis dan Support Vector Machine, Vol. 5, No 3, Hal 147-156.
- GNOTA : Apa itu GNOTA. Diakses pada 20 September 2015 dari <http://www.gnota.or.id/index.php?controller=page&action=view&page=tentangnota&subpage=tentang-kami&lang=id>.
- Gafur, Abdul. 2008. Cara Mudah Mendapatkan Beasiswa. Jakarta : Penebar Plus Daihani, Dadan Umar. 2001. Komputerisasi Pengambilan Keputusan. Jakarta : Elex Media Komputindo.
- Hermaduanty, N., n.d. 2008. Sistem Pendukung Keputusan Berbasis SMS untuk Menentukan Status Gizi Dengan Metode K-Nearest Neighbor. Universitas Islam Indonesia.
- Jiawei Han et all. 2012. Data Mining Concepts and Techniques Third Edition. Elsevier Inc. USA.
- Kartal Hasan Basri, Cebi Ferhan. 2013, International journal of Machine Learning and Computing, Support Vectore Machine for Multi-Attribute ABC Analysis, Vol 3, No 1, Hal. 154-157
- Kumar Jain, Yogendra., Kumar Bhandare, Santosh. 2011, Min Max Normalization Based Data Perturbation Method for Privacy Protection. Samrat Ashok Technological Institute.
- Mohanty, S. Dan Bebartha, H. N. D., 2011. Performace Comparison of SVM and K-NN for Oriya Character Recognition. (IJACSA) International Journal of Advanched Computer Science and Applications, Special Issue on Image Processing and Analysis, Hal 112-116.
- Mujiasih Subekti. 2011, Jurnal Meteorologi dan Geofisika, Pemanfaatan Data Mining untuk Perkiraan Cuaca, Vol 12, No 2, Hal 189-195.
- Novianti Fourina Ayu, Purnami Santi Wulan. 2012, Jurnal Sains dan Seni ITS, Analisis Diagnosis Pasien Kanker Payudara Menggunakan Regresi Logistik dan Support Vector Machine (SVM) Berdasarkan Hasil Mamografi, Vol 1, No1, Hal D-147 – D-152
- Peng, Jianliang. 2012, Selection of Logistics Outsourcing Service Suppliers Based on AHP. Huangzhou, China.
- Purnami, S. W., dan Embong, A. 2008. Smooth Support Vector Machine For Breast Cancer Classification. ICMSA08, Banda Aceh, Indonesia.
- Gaspar Paulo, Carbonell Jaime, Jose Luis Oliveira. 2012. "On The Parameter Optimization of Support Vector Machines for Binary Clasification", Vol 3, Hal 201
- Rachman Fairizi, Purnami Santi Wulan. 2102, Jurnal Sains dan Seni ITS, Perbandingan Klasifikasi Tingkat Keganasan Breast Cancer dengan Menggunakan Regresi Logistik Ordinal dan Support Vector Machine, Vol 1, No 1, Hal D-130 – D135.
- Saaty, T. L. 1980. The Analytic Hierarchy Process :Planning, Priority Allocation.
- Saaty, T. L. 1991. Pengambilan Keputusan Bagi Para Pemimpin. PT. Pustaka Binaman Pressindo.
- Sembiring, 2007. Penerapan Teknik Support Vector Machine untuk Pendeteksian Intrusi pada Jaringan. Institute Teknologi Bandung.
- Sparague, R.H dan Watson H. J., 1993. Decission Support Systems : Putting Theory Into Practice. Englewood Clifts, N. J., Prentice Hall.
- Turban, Efraim., Aronson, Jay E. & Liang, Ting-Peng., 2005. Decision Support Systems and Intelligent Systems, 7th ed. Yogyakarta: ANDI.
- Vijayakumar S, Wu S. Proc. International Conference on Soft Computing (SOCO'99), Sequential Support Vector Classifier and Regression, Genoa, Italy, pp.610-619, 1999.
- Vijayarani S, Dhayanand S. 2015. Liver Disease Prediction using SVM and Naive Bayes Algorithm. Vol 4, Hal 2278-7798.
- Yang Yi, Du Quishi, Zhao Jinying. 2010, Logistic System and Intelligent Management, The Application of site selection based on AHP-SVM in 500KV substation, Vol 2, Hal 1225 – 1229.