

**PERBANDINGAN METODE *SUPPORT VECTOR MACHINE*
(SVM) LINEAR, *RADIAL BASIS FUNCTION* (RBF), DAN
POLINOMIAL KERNEL DALAM KLASIFIKASI BIDANG
STUDI LANJUT PILIHAN ALUMNI UII**

TUGAS AKHIR

Diajukan Sebagai Salah Satu Syarat untuk Memperoleh Gelar Sarjana Program
Studi Statistika



Herlina Catur Sulistya Ningrum

14 611 191

JURUSAN STATISTIKA

FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM

UNIVERSITAS ISLAM INDONESIA

YOGYAKARTA

2018

HALAMAN PERSETUJUAN PEMBIMBING

TUGAS AKHIR

Judul

: Perbandingan Metode *Support Vector Machine* (SVM)
Linear, *Radial Basis Function* (RBF), dan Polinomial
Kernel dalam Klasifikasi Bidang Studi Lanjut Pilihan
Alumni UII

Nama Mahasiswa

: Herlina Catur Sulistya Ningrum

Nomor Mahasiswa

: 14 611 191

TUGAS AKHIR INI TELAH DIPERIKSA DAN DISETUJUI
UNTUK DIUJIKAN

بسم الله الرحمن الرحيم

Pembimbing



(Ayundyah Kesumawati, S.Si., M.Si.)

HALAMAN PENGESAHAN

TUGAS AKHIR

PERBANDINGAN METODE *SUPPORT VECTOR MACHINE* (SVM)
LINEAR, *RADIAL BASIS FUNCTION* (RBF), DAN POLINOMIAL
KERNEL DALAM KLASIFIKASI BIDANG STUDI LANJUT PILIHAN

ALUMNI UII

ISLAM

Nama Mahasiswa : Herlina Catur Sulistya Ningrum

Nomor Mahasiswa : 14 611 191


TUGAS AKHIR INI TELAH DIUJIKAN

PADA TANGGAL 14 MEI 2018

Nama Penguji


1. Ir. Ali Parkhan, M.T
2. Muhammad Muhajir, S.Si., M.Sc
3. Ayundyah Kesumawati, S.Si., M.Si.

Tanda Tangan



Mengetahui,

Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam


Drs. Aliwar, M.Sc., Ph.D

KATA PENGANTAR



Assalamu'alaikum Warahmatullaahi Wabarakaatuh

Puji syukur kehadiran Allah SWT karena berkat Rahmat dan Karunia-Nya sehingga penulis dapat menyelesaikan penyusunan tugas akhir ini. Shalawat serta salam tak lupa penulis haturkan ke junjungan nabi besar Muhammad SAW, keluarganya, sahabatnya, dan semua umat yang mengikuti petunjuk beliau hingga akhir zaman.

Penulisan tugas akhir ini disusun sebagai salah satu syarat untuk memperoleh gelar sarjana pada Jurusan Statistika Fakultas Matematika dan Ilmu Pengetahuan Alam di Universitas Islam Indonesia. Tugas akhir dengan judul “Perbandingan Metode *Support Vector Machine* (SVM) Linear, *Radial Basis Function* (RBF), dan Polinomial Kernel dalam Klasifikasi Bidang Studi Lanjut Pilihan Alumni UII” ini selain digunakan sebagai salah satu syarat untuk menyelesaikan studi jenjang S1, diharapkan juga bisa memberikan wawasan dan mengenalkan penerapan ilmu statistika dalam pengolahan dan analisis data.

Penyusunan dan penulisan tugas akhir ini tidak lepas dari bimbingan, bantuan, serta dorongan dari berbagai pihak. Oleh karena itu, dalam kesempatan ini, perkenankan penulis untuk menghaturkan ucapan terimakasihnya kepada :

1. Bapak Dr. RB. Fajriya Hakim, M.Si. selaku Ketua Jurusan Statistika FMIPA UII beserta jajarannya.
2. Ibu Ayundyah Kesumawati, M.Si. selaku dosen pembimbing yang sangat sabar mengarahkan, serta membimbing dalam penyusunan tugas akhir ini.
3. Bapak dan Ibu Dosen Jurusan Statistika yang telah mengajarkan ilmunya kepada penulis.
4. Ayah, Ibu, Eyang, serta kakak – kakak yang sangat saya cintai yang selalu mendoakan, memberi semangat, kesabaran serta memberikan dukungannya baik secara materiil maupun spirituil dalam menyelesaikan tugas akhir ini.

5. Riza Indriani R, Ikrimah Afifah T, Nadya Amalia, teman – teman yang selalu membantu, serta memberikan semangat dan dukungan dalam penyusunan tugas akhir ini.
6. Sahabat setia Aditya Nova Pradipta yang selalu memberikan bantuan, serta semangat dalam penyusunan tugas akhir sehingga bisa lulus tepat waktu.
7. Sinta, Hafidz, Zahra adik – adikku tersayang yang selalu memberikan hiburan ketika jenuh dalam menyelesaikan tugas akhir ini.
8. Teman – teman KKN unit 103 dusun Keseneng Wetan, ibu carik, pak carik, yang selalu memberikan dukungan, doa, serta semangat kepada penulis dalam penyusunan tugas akhir ini.
9. Teman – teman statistika kelas C angkatan 2014 yang selalu membantu, mendukung dalam penyelesaian tugas akhir ini.
10. Semua pihak yang tidak bisa penulis sebutkan namanya satu persatu yang telah memberikan banyak dukungan bagi penulis dalam menyelesaikan tugas akhir ini.

Atas segala bantuan serta amal baik semua pihak diatas, semoga mendapat ridlo Allah SWT. Penulis sangat menyadari bahwa penulisan tugas akhir ini masih kurang sempurna mengingat kurangnya kemampuan dan pengetahuan penulis. Oleh karena itu, saran dan ktirik yang membangun dari pembaca sangat penulis harapkan demi kesempurnaan dan kebaikan tugas akhir ini. Penulis berharap bahwa penulisan tugas akhir ini dapat bermanfaat bagi penulis, pembaca, maupun penelitian di masa depan.

Wassalamu'alaikum Warahmatullaahi Wabarakaatuh

Yogyakarta, 14 April 2018

Penulis

DAFTAR ISI

TUGAS AKHIR	i
HALAMAN PERSETUJUAN PEMBIMBING	ii
HALAMAN PENGESAHAN	iii
KATA PENGANTAR.....	iv
DAFTAR ISI.....	vi
DAFTAR TABEL	viii
DAFTAR GAMBAR.....	x
DAFTAR LAMPIRAN	xi
PERNYATAAN.....	xii
INTISARI	xiii
ABSTRACT	xiv
BAB I PENDAHULUAN.....	1
1.1. Latar Belakang Masalah	1
1.2. Rumusan Masalah	3
1.3. Batasan masalah	4
1.4. Tujuan Penelitian.....	4
1.5. Manfaat Penelitian.....	4
BAB II TINJAUAN PUSTAKA	6
BAB III LANDASAN TEORI.....	10
3.1. <i>Tracer Study</i>	10
3.2. <i>Data Mining</i>	10
3.3. <i>Machine Learning</i>	10
3.4. <i>Support Vector Machine (SVM)</i>	12
3.3.1. <i>Hard – Margin SVM / Linear SVM</i>	13
3.3.2. <i>Soft – Margin SVM</i>	16
3.3.3. <i>Kernel SVM</i>	17
3.5. <i>Confusion Matrix</i>	20
3.6. <i>Akurasi</i>	21

3.7.	Uji Independensi <i>Chi Square</i>	21
BAB IV METODOLOGI PENELITIAN		23
4.1.	Populasi Penelitian	23
4.2.	Teknik Pengumpulan data	23
4.3.	Variabel Penelitian	23
4.4.	Metode Analisis Data	25
4.5.	Langkah Penelitian	26
BAB V HASIL DAN PEMBAHASAN		27
5.1.	Analisis Deskriptif	27
5.2.	Metode <i>Support Vector Machine</i> (SVM)	32
5.2.1.	Linear Kernel SVM	33
5.2.2.	RBF Kernel SVM	36
5.2.3.	Polinomial Kernel SVM	39
5.3.	Perbandingan Tiga Fungsi Kernel SVM	42
5.4.	Pengaplikasian Metode SVM Linear Kernel dalam Pencarian <i>Hyperplane</i>	43
BAB VI PENUTUP		47
6.1.	Kesimpulan	47
6.2.	Saran	47
DAFTAR PUSTAKA		49
LAMPIRAN		52

DAFTAR TABEL

Tabel 3.1	Perbedaan penggunaan <i>Supervised Learning</i> dan <i>Unsupervised Learning</i>	12
Tabel 3.2	Tabel kontigensi b _x k faktor A dan faktor B	21
Tabel 4.1	Tabel Variabel Penelitian	24
Tabel 5.1	Deskripsi data antara tepat waktu kelulusan dengan pemilihan bidang studi lanjut	28
Tabel 5.2	Rangkuman Uji Independensi <i>Chi Square</i>	32
Tabel 5.3	Tabel nilai akurasi parameter terbaik dengan <i>trial and error</i>	33
Tabel 5.4	Tabel Parameters Model SVM Linear Kernel.....	33
Tabel 5.5	Tabel <i>Confusion Matrix training dataset</i>	34
Tabel 5.6	Tabel <i>Confusion Matrix testing dataset</i>	34
Tabel 5.7	Tabel prediksi <i>training dataset</i> dan <i>testing dataset</i>	35
Tabel 5.8	Tabel nilai akurasi parameter terbaik dengan <i>trial and error</i> untuk <i>training dataset</i>	36
Tabel 5.9	Tabel nilai akurasi parameter terbaik dengan <i>trial and error</i> untuk <i>testing dataset</i>	36
Tabel 5.10	Tabel Parameters Model SVM RBF Kernel	37
Tabel 5.11	Tabel <i>Confusion Matrix training dataset</i>	37
Tabel 5.12	Tabel <i>Confusion Matrix testing dataset</i>	38
Tabel 5.13	Tabel ketepatan klasifikasi <i>training dataset</i> dan <i>testing dataset</i>	39
Tabel 5.14	Tabel nilai akurasi parameter terbaik dengan <i>trial and error</i> untuk <i>training dataset</i>	39
Tabel 5.15	Tabel nilai akurasi parameter terbaik dengan <i>trial and error</i> untuk <i>testing dataset</i>	40
Tabel 5.16	Tabel Parameters Model SVM Polinomial Kernel.....	40
Tabel 5.17	Tabel <i>Confusion Matrix training dataset</i>	40
Tabel 5.18	<i>Confusion Matrix testing dataset</i>	41
Tabel 5.19	Tabel prediksi <i>training dataset</i> dan <i>testing dataset</i>	42

Tabel 5.20 Tabel Rangkuman Akurasi Fungsi Kernel	43
Tabel 5.21 Data input variabel jenis kelamin dan kelulusan tepat waktu	43
Tabel 5.22 Visualisasi data kedalam grafik <i>hyperplane</i>	44
Tabel 5.23 Data uji untuk klasifikasi data ke dalam <i>hyperplane</i>	45

DAFTAR GAMBAR

Gambar 3.1 <i>Hard margin SVM</i>	13
Gambar 3.2 <i>Hyperplane</i> terbaik yang memisahkan antar dua kelas positif (+1) dan negatif (-1)	14
Gambar 3.3 Beberapa misklasifikasi pada <i>Soft margin SVM</i>	16
Gambar 3.4 Kernel SVM untuk memisahkan data secara linear.....	17
Gambar 3.5 <i>Confusion Matrix</i>	20
Gambar 4.1 <i>Flowchart</i> Tahapan Penelitian.....	26
Gambar 5.1 Perbandingan jenis kelamin alumni UII dengan bidang studi lanjut	27
Gambar 5.2 Diagram batang variabel alasan lanjut studi dengan kesesuaian bidang studi.....	28
Gambar 5.3 Visualisasi Diagram batang jenis studi lanjut dengan kesesuaian bidang studi.....	29
Gambar 5.4 Visualisasi diagram batang variabel fakultas dengan kesesuaian pengambilan studi lanjut.....	30
Gambar 5.5 Diagram batang variabel biaya dengan kesesuaian bidang studi....	31
Gambar 5.6 Plot <i>hyperplane</i> fungsi klasifikasi	45
Gambar 5.7 Visualisasi Garis <i>Hyperplane</i> Data Uji	46

DAFTAR LAMPIRAN

Lampiran 1 Data Alumni UII 2015	52
Lampiran 2 <i>Script</i> Uji Independensi <i>Chi Square</i> di R.....	64
Lampiran 3 <i>Script R</i> SVM Linear Kernel	65
Lampiran 4 <i>Script R</i> SVM RBF Kernel	67
Lampiran 5 <i>Script R</i> SVM Polinomial Kernel	68
Lampiran 6 <i>Output</i> Uji Independensi <i>Chi Square</i> dengan R	69
Lampiran 7 <i>Output</i> SVM dengan R	72

PERNYATAAN

Dengan ini saya menyatakan dalam Tugas Akhir ini tidak terdapat karya yang sebelumnya pernah diajukan untuk memperoleh gelar kesarjanaan di suatu perguruan tinggi dan sepanjang pengetahuan saya juga tidak terdapat karya atau pendapat yang pernah ditulis atau diterbitkan oleh orang lain, kecuali yang diacu dalam naskah ini dan disebutkan dalam daftar pustaka.

Yogyakarta, 14 April 2018



**PERBANDINGAN METODE *SUPPORT VECTOR MACHINE* (SVM)
LINEAR, *RADIAL BASIS FUNCTION* (RBF), DAN POLINOMIAL
KERNEL DALAM KLASIFIKASI BIDANG STUDI LANJUT PILIHAN
ALUMNI UII**

Herlina Catur Sulistya Ningrum
Program Studi Statistika Fakultas MIPA
Universitas Islam Indonesia

INTISARI

Pendidikan memiliki peranan yang sangat penting dalam menciptakan seseorang. Seseorang yang berpendidikan akan memiliki hidup yang lebih baik nantinya. Program beasiswa baik dari pemerintah maupun instansi tertentu merupakan salah satu langkah guna mendukung program studi lanjut. UII merupakan salah satu universitas yang mendukung terlaksananya program studi lanjut serta memfasilitasi dalam melakukan pembelajaran dan penelitian salah satunya dengan menyediakan beasiswa studi lanjut. Dengan banyaknya fasilitas yang telah disediakan akan diimbangi dengan banyaknya alumni yang ingin melakukan studi lanjut baik dengan cara memanfaatkan beasiswa ataupun dengan biaya sendiri. Berdasarkan pada penjelasan diatas, akan muncul permasalahan baru yaitu dalam melakukan studi lanjut sudah sesuai bidang studi sebelumnya atautkah tidak sesuai dengan bidang studi sebelumnya. Oleh karena itu diperlukan analisis untuk mengklasifikasikan jenis studi lanjut yang diambil alumni UII termasuk kedalam jenis studi yang sesuai bidang studi sebelumnya atautkah tidak sesuai dengan bidang studi yang pernah diambil sebelumnya. Metode yang akan digunakan yaitu *Support Vector Machine* (SVM) dengan data penelitian adalah data alumni UII tahun 2015 yang melakukan studi lanjut. Analisis dilakukan dengan membandingkan nilai ketepatan klasifikasi dari tiga fungsi kernel SVM yaitu linear, *Radial Basic Function* (RBF), serta Polinomial kernel. Dari ketiga fungsi kernel tersebut, diperoleh hasil bahwa fungsi kernel polinomial memberikan nilai ketepatan klasifikasi paling tinggi yaitu dengan nilai akurasi 95.45% bila dibandingkan kedua fungsi kernel lainnya.

Kata – kata kunci : Pendidikan, Studi Lanjut, Kernel, Linear, RBF, Polinomial.

**COMPARISON OF SUPPORT VECTOR MACHINE METHOD (SVM)
LINEAR, RADIAL BASIS FUNCTION (RBF), AND POLYNOMIAL
KERNEL IN CLASSIFICATION OF FIELD OF FURTHER STUDIES
SELECTED BY UII ALUMNUS**

Herlina Catur Sulistya Ningrum

*Departments of Statistics, Faculty of Mathematics and Natural Science
Islamic University of Indonesia*

ABSTRACT

Education has an important role in creating someone. A person with a higher education will be more respected and will have a better life. The scholarship program from both government and certain institutions is one of the steps to support the further study programs. UII is one of the universities that support the implementation of further study program and facilitate in doing study and research by providing scholarship of further study. With many facilities that have been provided, it will be balanced with the number of students who want to do further study either by using the scholarship or at their own expense. Based on the explanation, there will appear new problem such as in conducting further study is already according to field of previous study or not. Therefore an analysis is needed to classify whether the type of further study taken by UII alumnus is a type of study appropriate to the previous field of study or not in accordance with the field of study previously taken. The method that will used is Support Vector Machine (SVM) using data of UII alumnus in 2015 who conduct further study. The analysis is done by comparing the classification accuracy value of three SVM kernel functions ie linear, Radial Basic Function (RBF), and kernel polynomial. The result shows that the polynomial kernel function gives the highest classification accuracy value of 95.45% when compared to the other two kernel functions.

Keywords: Education, Further Study, Kernel, Linear, RBF, Polynomial.

BAB I

PENDAHULUAN

1.1. Latar Belakang Masalah

Pendidikan merupakan suatu hal yang sangat mendasar dan paling penting bagi kehidupan seseorang karena melalui pendidikan, dapat dilihat apakah seseorang tersebut memiliki kehidupan yang mapan, terpancang ataukah tidak. Menurut UU SISDIKNAS No. 20 Tahun 2003, pendidikan merupakan usaha yang secara sadar atau terencana untuk mewujudkan suasana belajar dan proses pembelajaran sedemikian rupa supaya peserta didik dapat mengembangkan potensi dirinya secara aktif sehingga memiliki pengendalian diri, kecerdasan, keterampilan dalam bermasyarakat, kekuatan spiritual keagamaan, kepribadian serta akhlak mulia.

Berdasarkan pengertian pendidikan diatas dapat dikatakan bahwa pendidikan memiliki peranan yang sangat penting dalam menciptakan seseorang. Seseorang dengan pendidikan yang lebih tinggi akan lebih disegani dan memiliki kehidupan yang lebih baik dibandingkan dengan seseorang yang tidak berpendidikan sebagaimana sesuai dengan pidato yang disampaikan oleh bapak Presiden RI Joko Widodo pada upacara perayaan hari pendidikan tanggal 2 Mei 2016 yang menegaskan bahwa Indonesia akan menjadi bangsa yang disegani dunia dalam berbagai kompetisi era global jika tinggi kualitas manusianya dengan pendidikan sebagai kuncinya. Melalui pendidikan, harkat dan martabat manusia akan terangkat serta dapat membangun peradaban bangsa. Pendidikan yang baik dan bermutu akan membuahkan kebajikan, kecerdasan, dan karakter yang memiliki integritas tinggi (Anonim, Pendidikan untuk Membangun Peradaban Bangsa, 2016).

Pendidikan lanjut penting dilakukan mengingat berdasarkan pada data statistik yang dirilis oleh Pangkalan Data Pendidikan Tinggi (PDDIKTI) Kementerian Riset, Teknologi dan Pendidikan Tinggi, tercatat di tahun 2017

jumlah dosen bergelar S3 (doktor) berjumlah 34.264 orang atau sekitar 14% dari total 250.000 dosen di seluruh Indonesia. Angka 14% ini sebenarnya masih sangat jauh dari target minimal 20% yang diharapkan pemerintah sehingga pelajar/mahasiswa sebagai penerus bangsa dan *agent of change* harus melaksanakan tugasnya untuk perubahan Indonesia agar lebih maju.

Melanjutkan studi pascasarjana, pendidikan profesi, maupun Transfer S1 merupakan beberapa program yang disediakan oleh universitas tak terkecuali Universitas Islam Indonesia (UII) untuk memfasilitasi alumni yang ingin melakukan studi lanjut. Selain beberapa program yang disediakan oleh universitas, pemerintah juga mendukung dalam melakukan studi lanjut dengan cara memberikan beasiswa Lembaga Pengelola Dana Pendidikan (LPDP) sebagai sarana untuk mempersiapkan dan mencetak pemimpin – pemimpin profesional di masa depan. LPDP menyediakan program beasiswa doktoral maupun magister untuk mahasiswa mahasiswi terbaik Indonesia (Kemenkeu, 2014).

UII merupakan salah satu universitas swasta yang dalam praktiknya menjajarkan antara nilai – nilai keagamaan dengan pendidikan sesuai dengan visi UII yang menjadi rahmatan lil‘alamin dengan selalu mengemban risalah islamiyah-nya dalam bidang pendidikan, penelitian, pengabdian masyarakat dan dakwah. Sama halnya dengan universitas lain, UII juga mendukung, memfasilitasi dan meningkatkan jaminan kualitas dalam melakukan pembelajaran dan penelitian terbukti pada tahun 2015 UII masuk sebagai peringkat 10 universitas terbaik di Indonesia dalam kategori manajemen pendidikan tinggi dan kualitas organisasional serta terpilihnya UII sebagai universitas swasta dengan peringkat tertinggi dalam hal kinerja penelitian oleh kemenristekdikti pada tahun 2016 (UII, 2017).

UII bukan hanya mendukung fasilitas dalam penelitian, tetapi juga melakukan kerjasama dengan berbagai institusi untuk memperluas kesempatan serta meningkatkan akses terhadap pengembangan pendidikan, program pertukaran, penelitian kolaborasi, dan mendorong inovatif. Beberapa mitra kerja

sama internasional dari UII sudah tersebar di berbagai negara seperti Thailand, Malaysia, Filipina, Vietnam, Australia, Korea Selatan, Tiongkok, Jepang, Rusia, Iran, Arab Saudi, Cyprus, Maroko, Inggris, Belanda, Jerman, Prancis, Hungaria, dan Amerika Serikat. Selain mitra kerja, UII juga melakukan kerja sama dengan berbagai universitas ternama seperti Universiti Kebangsaan Malaysia; Hokkaido University, Jepang; Solbridge International Business School, Korea; The University of Hawaii at Manoa, Amerika Serikat, dan Saxion University of Applied Sciences Belanda, serta banyak mitra universitas lainnya (UII, 2017).

Dengan berbagai kesempatan yang sudah disediakan UII, akan diimbangi dengan banyaknya alumni UII yang ingin memanfaatkan fasilitas yang disediakan oleh universitas salah satunya adalah dengan mencoba memperoleh beasiswa untuk melakukan studi lanjut terlepas dari apakah dalam melanjutkan studi lanjut nantinya untuk memperdalam ilmu pengetahuan dengan berkonsentrasi dalam bidangnya maupun untuk memperluas ilmu pengetahuan. Dari penjelasan diatas, akan muncul permasalahan baru yaitu dalam melakukan studi lanjut oleh alumni nantinya sudah sesuai dengan bidang studi sebelumnya atau tidak sesuai dengan bidang studi sebelumnya. Oleh karena itu, penulis tertarik untuk mengangkat tema penelitian guna melihat serta mengklasifikasikan bidang studi lanjut yang diambil alumni UII merupakan bidang studi yang sesuai dengan bidang studi sebelumnya ataukah bidang studi lanjut yang diambil alumni UII merupakan bidang studi yang tidak sesuai dengan bidang studi yang pernah diambil sebelumnya.

1.2. Rumusan Masalah

Berdasarkan latar belakang penelitian, berikut merupakan rumusan masalah dari penelitian adalah sebagai berikut.

1. Bagaimana gambaran umum dari variabel – variabel input seperti fakultas, jenis kelamin, kelulusan tepat waktu, jenis studi lanjut, alasan lanjut studi, biaya, serta universitas pilihan terhadap pemilihan bidang studi lanjut oleh alumni UII?
2. Bagaimana hubungan antara variabel input terhadap pemilihan bidang studi lanjut oleh alumni UII?

3. Bagaimana hasil ketepatan klasifikasi terbaik menggunakan metode SVM dari ketiga fungsi kernel Linear, RBF, serta polinomial kernel?

1.3. Batasan masalah

Adapun batasan masalah yang terdapat dalam penelitian adalah sebagai berikut.

1. Data yang digunakan merupakan data sekunder yang diperoleh dari kantor *UII Career* berkaitan dengan data alumni UII tahun 2015.
2. Objek penelitian yang digunakan adalah data daftar alumni UII tahun 2015 yang melanjutkan studi jenjang pascasarjana, pendidikan profesi, maupun transfer S1.
3. Variabel yang digunakan dalam penelitian terdiri dari ipk, fakultas, jenis kelamin, lulus tepat waktu, jenis studi, alasan studi lanjut, biaya, bidang studi lanjut, serta universitas pilihan mahasiswa dalam melanjutkan studi lanjut.

1.4. Tujuan Penelitian

Adapun tujuan dari penelitian adalah sebagai berikut.

1. Mengetahui gambaran umum dari variabel – variabel input seperti fakultas, jenis kelamin, kelulusan tepat waktu, jenis studi lanjut, alasan lanjut studi, biaya, serta universitas pilihan terhadap pemilihan bidang studi lanjut oleh alumni UII.
2. Mengetahui hubungan antara variabel input terhadap pemilihan bidang studi lanjut oleh alumni UII.
3. Mengetahui hasil ketepatan klasifikasi terbaik metode SVM menggunakan tiga fungsi kernel Linear, RBF, serta polinomial kernel.

1.5. Manfaat Penelitian

Penelitian ini diharapkan mampu dijadikan acuan oleh pihak universitas UII khususnya tiap tiap jurusan berkaitan dengan hasil akurasi pemilihan bidang studi lanjut alumni UII tahun 2015. Ketika hasil akurasi pemilihan bidang studi lanjut kategori sesuai bidang dari alumni UII sudah tinggi hal tersebut bisa menjadi acuan jurusan untuk mempertahankan serta meningkatkan mutu

pengajarannya sehingga mahasiswa merasa nyaman dan tertarik untuk melanjutkan studi lanjut yang sesuai dengan bidang studi sebelumnya. Sedangkan ketika diperoleh akurasi alumni UII yang memilih studi lanjut kategori tidak sesuai bidang lebih tinggi maka, universitas dapat melakukan tindak lanjut salah satunya dengan memperbaiki cara pembelajaran ataupun dengan penyebaran kuesioner khusus untuk membahas kepuasan serta kenyamanan mahasiswa dalam mendapatkan pengajaran selama kuliah.

Hasil penelitian ini semoga bisa dikembangkan dan dianalisis lebih mendalam dalam penelitian selanjutnya dengan menambahkan beberapa alasan atau faktor – faktor lainnya yang mungkin saja mempengaruhi alumni dalam melakukan studi lanjut sesuai dengan bidang studi sebelumnya ataukah tidak sesuai bidang studi sebelumnya.

BAB II

TINJAUAN PUSTAKA

Beberapa penelitian terdahulu yang dijadikan sebagai rujukan dalam penelitian kali ini salah satunya adalah penelitian tentang diagnosis pasien kanker payudara dengan metode regresi logistik biner dan SVM. Variabel yang digunakan dalam penelitian terdiri dari variabel respon (Y) adalah pasien kanker payudara, dan untuk variabel prediktor (X) terdiri dari variabel *Intermediate Findings*, *BIRADS category*, *Suspicious for Malignancy*, Usia, serta Letak Abnormal. Dengan penggunaan kedua metode tersebut, diperoleh hasil bahwa metode SVM akan menghasilkan ketepatan akurasi sebesar 94.34% lebih besar bisa dibandingkan dengan metode regresi logistik biner yang menghasilkan ketepatan akurasi sebesar 88.72% sehingga dapat disimpulkan bahwa performansi akurasi terbaik adalah dengan menggunakan metode SVM (Novianti & Purnami, 2012).

Penelitian selanjutnya yaitu penggunaan metode klasifikasi *Support Vector Machine* (SVM) pada data akreditasi sekolah dasar di Kabupaten Magelang. Data yang digunakan dalam penelitian adalah data nilai akreditasi SD di Magelang dari tahun 2011 – 2013. Variabel respon dalam penelitian terdiri dari tiga kategori yaitu kategori “1” untuk sekolah dengan akreditasi A, kategori “2” adalah sekolah dengan akreditasi B, dan kategori “3” merupakan sekolah yang akreditasinya C. Variabel prediktor terdiri dari 8 komponen standar antara lain standar isi, standar proses, standar kompetensi lulusan, standar pendidik dan tenaga kependidikan, standar sarana dan prasarana, standar pengelolaan, dan standar penilaian pendidikan. Hasil analisis ketika semua data yaitu 337 data diujikan dengan fungsi *Gaussian Radial Basic Function* atau *Gaussian RBFN* akan diperoleh akurasi klasifikasi adalah 100%, sedangkan ketika menggunakan fungsi kernel *Polynomial* akan dihasilkan akurasi klasifikasi sebesar 98.81%. Analisis kedua yaitu ketika menggunakan data *testing* sebesar 82 data, akan didapat akurasi klasifikasi dengan fungsi *Gaussian RBFN* adalah 93.902% sedangkan ketika

menggunakan metode Kernel *Polynomial* akan dihasilkan akurasi sebesar 92.683%, sehingga dapat disimpulkan dari kedua metode tersebut, akurasi klasifikasi terbaik adalah ketika menggunakan fungsi *Gaussian* RBFN (Octaviani, Wilandari, & Ispriyanti, 2014).

Lukman (2016) melakukan penelitian tentang penggunaan algoritma SVM untuk pemilihan beasiswa di SMK YAPIMDA. Data yang digunakan dalam penelitian adalah data siswa kelas IX SMK YAPIMDA yang termasuk dalam pemilihan penerima beasiswa. Berdasarkan hasil analisis, diperoleh kesimpulan bahwa dengan menggunakan uji *cross validation*, *confusion matrix*, serta kurva ROC akan diperoleh nilai akurasi paling tinggi adalah 85.82%.

Suwardika (2016) melakukan penelitian tentang pengelompokan dan klasifikasi penggunaan alat kontrasepsi di Indonesia menggunakan tiga metode yaitu regresi logistik biner, SVM, serta *Classification and Regression Tree* (CART). Data yang digunakan merupakan data sekunder dengan 1 variabel respon dan 9 variabel prediktor. Variabel respon merupakan variabel biner dengan 2 kategori yaitu “0” tidak menggunakan dan kategori “1” menggunakan. Sedangkan 9 variabel prediktor terdiri dari umur istri, pendidikan istri, pendidikan suami, jumlah anak, agama istri, status pekerjaan istrim, tingkat kesuburan suami, standar indeks kehidupan, serta pengetahuan tentang akseptor KB. Hasil yang diperoleh menggunakan 3 metode analisis adalah klasifikasi menggunakan metode SVM lebih baik bila dibandingkan dengan dua metode lainnya.

Penelitian lain yang digunakan sebagai rujukan adalah penelitian untuk memprediksi mahasiswa yang *drop out* dengan menggunakan metode *support vector machine*. Data yang digunakan dalam penelitian terdiri dari data mahasiswa dan data evaluasi IP serta IPK mahasiswa dari fakultas kesehatan masyarakat (program studi kesehatan masyarakat dan ilmu gizi) mulai tahun 2007 – 2011. Analisis akan dilakukan dengan menggunakan dua fungsi kernel RBF dan polinomial. Parameter *cost* yang digunakan berbeda tiap fungsi kernel. Kesimpulan yang diperoleh dari analisis adalah ketika dilakukan pengujian prodi

kesmas diperoleh nilai prediksi terbaik adalah ketika menggunakan kernel polinomial dengan $C=0.1$, degree (P)=5, $\gamma=0.001$ atau dengan tipe RBF kernel dengan nilai $C=0.2$, degree (P)=5, $\gamma=0.001$. Sedangkan hasil prediksi terbaik dari dari prodi ilmu gizi ketika menggunakan polinomial kernel adalah ketika $C=0.1$, degree (P)=3, $\gamma=0.001$, sedangkan dengan fungsi RBF kernel adalah dengan nilai $C=0.2$, degree (P) =7, dan $\gamma = 0.001$ (Nurhayati, Kusriani, & Luthfi, 2015).

Menurut penelitian yang dilakukan oleh Anggraeni (2016) terdapat beberapa faktor yang bisa mempengaruhi minat seorang mahasiswa FE UNY untuk melanjutkan studi S2 antara lain pengaruh prestasi belajar, pendidikan orangtua, serta informasi penawaran beasiswa S2. Metode yang digunakan dalam analisis adalah dengan menggunakan metode regresi berganda dengan variabel respon minat untuk melanjutkan studi S2, sedangkan untuk variabel prediktor adalah ketiga faktor yang telah disebutkan sebelumnya. Berdasarkan pada hasil penelitian, diperoleh kesimpulan bahwa dari ketiga faktor tersebut semuanya berpengaruh terhadap minat mahasiswa FE UNY untuk melanjutkan S2 dengan nilai R^2 sebesar 29.9%. Sama halnya seperti penelitian oleh Ananias Baskoro, perolehan nilai R^2 yang kecil dapat diartikan bahwa kemampuan variabel respon untuk menjelaskan model hanya berkisar 29.9% dan untuk sisanya dijelaskan oleh variabel – variabel yang tidak terdapat dalam model. Dengan adanya nilai R^2 yang kecil, bisa dikatakan bahwa hasil belum representatif, sehingga disarankan dalam penelitian selanjutnya dapat dilakukan analisis dengan menggunakan metode yang berbeda.

Penelitian lainnya yang dijadikan sebagai acuan adalah penelitian tentang implementasi metode SVM dalam peramalan suhu atmosfer. Data yang digunakan dalam penelitian merupakan data cuaca dengan periode 5 tahun (2003 – 2007) yang diperoleh dari Universitas Cambridge. Analisis yang digunakan dalam penelitian yaitu dengan membandingkan antara kedua metode SVM serta *Multi Layer Perceptron* (MLP). Kesimpulan yang didapatkan dalam penelitian yaitu analisis dengan menggunakan SVM akan memperoleh hasil lebih baik bila dibandingkan dengan metode MLP. Selain itu, parameter dalam SVM memiliki

efek signifikan terhadap performa model sehingga metode SVM cocok digunakan untuk mengganti beberapa model untuk penerapan prediksi cuaca dalam *Neural Network* (Radhika & Shashi, 2009).

Penelitian selanjutnya yaitu penelitian yang berkaitan dengan pengklasifikasian *email spam* dengan menggunakan metode SVM dan *K – Nearest Neighbor* (KNN). Data yang digunakan dalam penelitian merupakan data email berbahasa inggris sebanyak 6000 email, 1500 ham, 4500 spam dengan format eml yang didapatkan dari website *Csmining Group* yaitu sebuah lembaga pemerhati email. Pembahasan yang dihasilkan dari kedua metode SVM dan KNN adalah ketika menggunakan metode SVM dengan kombinasi fungsi kernel linear dan RBF dengan 10-fold scv akan menghasilkan ketepatan klasifikasi sebesar 96.6% dan error 3.4%, sedangkan ketika dilakukan analisis menggunakan metode KNN akan ketepatan klasifikasi adalah sebesar 92.28% dengan error 7.72% sehingga kesimpulan yang diperoleh dalam penelitian ini adalah metode SVM lebih baik dalam hal ketepatan klasifikasi bila dibandingkan dengan metode KNN (Pratiwi & Ulama, 2016).

Penelitian selanjutnya berkaitan dengan pengklasifikasian bidang studi lanjut alumni UII dengan menggunakan metode SVM linear kernel, RBF kernel, serta polinomial kernel. Data yang digunakan merupakan data dari alumni UII tahun 2015 yang melakukan studi lanjut. Hasil pembahasan menjelaskan bahwa dari ketiga fungsi kernel akan diperoleh ketepatan klasifikasi terbaik adalah pada penggunaan metode polinomial kernel bila dibandingkan kedua fungsi kernel lainnya (Ningrum, 2018).

BAB III

LANDASAN TEORI

3.1. *Tracer Study*

Tracer study UII adalah survei yang dilakukan oleh pihak *UII Career* guna mengukur proses pendidikan tinggi di UII sebagai bekal para alumni UII untuk memasuki dunia kerja serta bertujuan untuk memperoleh masukan bagi perbaikan sistem pendidikan di UII. *Tracer study* UII merupakan survei mengenai alumni UII yang bertujuan untuk menggali informasi dari alumni UII dua tahun kebelakang untuk kemudian dimanfaatkan dalam kepentingan evaluasi UII dan penyempurnaan serta penjaminan mutu UII. *Tracer study* UII menyediakan berbagai informasi penting mengenai hubungan antara perguruan tinggi dan dunia kerja, menilai relevansi pendidikan tinggi dengan dunia industri, memberikan informasi alumni, civitas akademik, mahasiswa UII, orang tua mahasiswa, serta sebagai kelengkapan syarat untuk akreditasi baik nasional maupun internasional (Anonim, 2017)

3.2. *Data Mining*

Data mining adalah proses yang menggunakan teknik statistik, matematika, kecerdasan buatan, dan mesin learning untuk mengekstraksi dan mengidentifikasi informasi yang bermanfaat dan pengetahuan yang terkait berbagai database besar. *Data mining* terdiri dari beberapa tugas yang dikenal seperti *knowledge extraction*, data eksplorasi, *data pattern processing*, serta penyaringan informasi. Seluruh aktivitas tersebut dikerjakan secara otomatis dan memungkinkan mudah dipelajari oleh seseorang yang bukan *programmer*. (Turban, Aronson, & Liang, 2007).

3.3. *Machine Learning*

Neural Network sering digunakan dalam melakukan pengambilan keputusan yang kompleks secara otomatis. *Neural Network* dapat mengidentifikasi pola sehingga dapat dihasilkan tindakan yang sesuai.

Dikarenakan *Neural Network* mempelajari dari pengalaman masa lalu untuk memperbaiki hasil, terdapat teknologi lain yang dinamakan *Machine Learning*. *Machine Learning* adalah metode yang memungkinkan mesin untuk memperoleh pengetahuan untuk pemecahan masalah dengan cara menunjukkan kasus lama yang sesuai. *Machine Learning* mempertimbangkan penggunaan metode kecerdasan buatan (AI) walaupun beberapa dari teknologi tersebut tidak memperlihatkan kecerdasan secara langsung tetapi hal tersebut sangat berguna untuk desain Intelligent Decision Support System atau Intelligent DSS (Turban, Aronson, & Liang, 2007).

Metode dalam *Machine Learning* terdiri dari dua pendekatan yaitu *Supervised Learning* dan *Unsupervised Learning*. *Supervised Learning* merupakan proses menginduksi pengetahuan dari serangkaian pengamatan dimana hasil yang diharapkan telah diketahui sebelumnya. Biasanya pembelajaran *Supervised Learning* menggunakan data yang telah ada. Dalam *Supervised Learning*, supervisor adalah variabel target yaitu kolom dalam data yang mewakili nilai untuk memprediksi dengan kolom lain dalam data. Variabel target terpilih untuk mewakili jawaban dari pertanyaan oleh organisasi serta akan membantu dalam pengambilan keputusan. Biasanya *Supervised Learning* disebut juga sebagai *predictive modelling* atau pemodelan prediktif. Algoritma pemodelan prediktif primer adalah klasifikasi untuk variabel target yang bersifat kategorik ataupun regresi untuk variabel target kontinu (Abbott, 2014). Dengan kata lain, *Supervised Learning* merupakan teknik pembelajaran yang mengekstrak hubungan antara variabel independen dengan variabel dependen yang sudah ditentukan. *Supervised Learning* menggunakan *training dataset* untuk mengembangkan model prediksi dengan menggunakan input data dan nilai *output*. Model kemudian dapat digunakan untuk membuat prediksi dari nilai *output* untuk dataset baru. Kinerja model yang dikembangkan dengan menggunakan *Supervised Learning* bergantung pada ukuran dan variansi dari *training dataset* untuk memperoleh generalisasi yang lebih baik serta kekuatan prediksi yang lebih besar untuk dataset baru (Awad & Khanna, 2015).

Unsupervised Learning biasanya disebut sebagai *descriptive modelling* atau pemodelan deskriptif tidak memiliki variabel target. Data input dianalisis dan dikelompokkan berdasarkan kedekatan data input satu dengan lainnya. Masing – masing grup atau kelompok diberikan label untuk menunjukkan manakah yang termasuk kedalam grup tersebut. Dalam beberapa aplikasi, seperti misalnya dalam analisis pelanggan, *unsupervised learning* hanya dinamakan segmentasi dikarenakan fungsi dari model (segmentasi pelanggan ke dalam grup). Pengertian lain Berikut merupakan beberapa algoritma yang dapat digunakan dalam pengimplementasian metode *Supervised Learning* dan *Unsupervised Learning*.

Tabel 3.1 Perbedaan penggunaan *Supervised Learning* dan *Unsupervised Learning*

<i>Supervised Learning</i>	<i>Unsupervised Learning</i>
<ul style="list-style-type: none"> • <i>Decision tree</i> • <i>Nearest – Neighbor Classifier</i> • <i>Naive Bayes Classifier</i> • <i>Artificial Neural Network</i> • <i>Support Vector Machine</i> • <i>Fuzzy K – Nearest Neighbor</i> 	<ul style="list-style-type: none"> • <i>K – Means</i> • <i>Hierarchical Clustering</i> • <i>DBSCAN</i> • <i>Fuzzy C – Means</i> • <i>Self – Organizing Maps</i>

Sumber : datascience.or.id

3.4. *Support Vector Machine (SVM)*


Permodelan data empiris dapat menimbulkan beberapa permasalahan ketika data yang diperoleh berdimensi tinggi (ruang fitur) dan tidak seragam yang bisa mengakibatkan analisis dengan pendekatan *Neural Network* (NN) tradisional mengalami kesulitan dalam generalisasi dan menghasilkan model yang bisa *overfit* data (Gunn, 1998). SVM dikembangkan untuk memecahkan masalah klasifikasi karena SVM memiliki kemampuan yang lebih baik dalam menggeneralisasi data bila dibandingkan dengan teknik yang sudah ada sebelumnya (Vapnik, Golowich, & Smola, 1997).

SVM merupakan sistem pembelajaran menggunakan ruang berupa fungsi – fungsi linear dalam sebuah ruang fitur yang berdimensi tinggi yang dilatih menggunakan algoritma pembelajaran berdasarkan pada teori optimasi dengan mengimplementasikan *learning bias* (Santosa, 2007). Pendekatan dengan

menggunakan SVM ini memiliki banyak manfaat lain seperti misalnya model yang dibangun memiliki ketergantungan eksplisit pada subset dari datapoints, serta *support vector* yang membantu dalam interpretasi model. Prinsip utama penggunaan SVM adalah mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah kelas pada ruang input. *Hyperplane* tersebut dapat berupa *line* pada *two dimension* dan dapat berupa *flat plane* pada *multiple plane*. SVM merupakan salah satu *machine learning* yang melakukan pelatihan dengan menggunakan *training dataset* dan melakukan generalisasi dan membuat prediksi dari data baru.

3.3.1. Hard – Margin SVM / Linear SVM


Teknik SVM merupakan klasifier yang menemukan *hyperplane* dengan kasus data yang digunakan merupakan data dengan dua kelas yang sudah terpisah secara linear seperti pada gambar berikut.



(Sumber : Buku Efficient Learning Machine, 2015)

Gambar 3.1 Hard margin SVM

Berdasarkan pada Gambar 3.1 diatas, terlihat bahwa antara kelas positif dan kelas negatif sudah terpisah secara total terlihat dari lingkaran abu – abu yang berada dekat dengan garis x_2 sedangkan untuk lingkaran hitam terletak dekat dengan garis x_1 (Awad & Khanna, 2015).



(Sumber : www.quora.com)

Gambar 3.2 *Hyperplane* terbaik yang memisahkan antar dua kelas positif (+1) dan negatif (-1)

Berdasarkan Gambar 3.2 terlihat beberapa pola yang merupakan anggota dari dua buah kelas yaitu positif (+1) dan negatif (-1). *Hyperplane terbaik* dapat ditemukan dengan mengukur *margin hyperplane* dan mencari titik maksimalnya. Margin merupakan jarak antara *hyperplane* dengan data terdekat dari masing – masing kelas. Subset *training dataset* yang paling dekat dinamakan sebagai *support vector*. Pada Gambar 3.2 sebelah kanan menunjukkan *hyperplane terbaik*, yaitu terletak pada garis putus – putus yang berada tepat ditengah – tengah *hyperplane* positif dan *hyperplane* negatif. Sedangkan tanda “positif” dan “bulat” yang berada dalam lingkaran hitam merupakan *support vector* (Faihah, 2010).

Pencarian lokasi *hyperplane* optimal merupakan inti dari metode SVM. Diasumsikan bahwa terdapat data *learning* dengan *data points* x_i ($i=1,2,...,m$) memiliki dua kelas $y_i = \pm 1$ yaitu kelas positif (+1) dan kelas negatif (-1) sehingga akan diperoleh *decision function* berikut.

$$f(x) = \text{sign}(w \cdot x + b) \quad (3.1)$$

Dimana $(.)$ merupakan skalar sehingga $w \cdot x \equiv w^T x$

Berdasarkan pada *decision function* diatas, dapat terlihat bahwa data akan terklasifikasi secara tepat jika $y_i(w \cdot x_i + b) > 0 \forall_i$ karena ketika $(w \cdot x_i + b)$ harus bernilai positif saat $y_i = +1$, dan bernilai negatif ketika $y_i = -1$. *Decision*

function menjadi invarian ketika akan dilakukan pembuatan skala positif baru dari argumen dalam persamaan fungsi sehingga akan mengakibatkan ambiguitas dalam mendefinisikan konsep jarak atau margin. Maka dari itu didefinisikan skala untuk (w,b) dengan menetapkan $w \cdot x + b = 1$ untuk titik terdekat pada satu sisi dan $w \cdot x + b = -1$ untuk titik terdekat pada sisi lainnya. *Hyperplane* yang melewati $w \cdot x + b = 1$ dan $w \cdot x + b = -1$ disebut sebagai *hyperplane* kanonik dan wilayah antar *hyperplane* disebut sebagai *margin band* (Cambell & Ying, 2011).

Margin maksimum dapat diperoleh dengan cara memaksimalkan nilai jarak antara *hyperplane* dan titik terdekatnya yaitu $\frac{1}{\|w\|}$. Hal tersebut dirumuskan sebagai *Quadratic Programming* (QP) *Problem* dengan mencari titik minimal seperti pada persamaan berikut.

$$\min \tau(w) = \frac{1}{2} \|w\|^2 \quad (3.2)$$

Sedangkan subjek *constrain*/kendala persamaannya adalah sebagai berikut.

$$y_i(w \cdot x_i + b) \geq 1 \quad \forall_i \quad (3.3)$$

Persamaan diatas merupakan permasalahan optimisasi kendala dimana kita meminimalkan fungsi objek pada persamaan (3.2) dengan kendala pada persamaan (3.3). Permasalahan diatas dapat direduksi dengan menggunakan fungsi *Lagrange* yang terdiri dari jumlahan fungsi objektif dan m kendala dikalikan dengan pengganda *Lagrange* seperti berikut (Cambell & Ying, 2011).

$$L(w, b) = \frac{1}{2} (w \cdot w) - \sum_{i=1}^m \alpha_i (y_i (w \cdot x_i + b) - 1) \quad (3.4)$$

Dimana α_i merupakan *Lagrange Multipliers*, dan nilai $\alpha_i \geq 0$. Pada saat minimum, akan dilakukan penurunan dari b dan w dan mengaturnya menjadi nol seperti berikut.

$$\frac{\partial L}{\partial b} = - \sum_{i=1}^m \alpha_i y_i = 0 \quad (3.5)$$

$$\frac{\partial L}{\partial w} = w - \sum_{i=1}^m \alpha_i y_i x_i = 0 \quad (3.6)$$

Substitusi nilai w dari persamaan (3.6) kedalam bentuk $L(w,b)$ sehingga akan diperoleh rumus ganda atau biasa disebut sebagai *wolfe dual*.


$$W(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i,j=1}^m \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \quad (3.7)$$

Dimana nilai α_i terhadap kendala adalah sebagai berikut.

$$\alpha_i \geq 0 \quad \sum_{i=1}^m \alpha_i y_i = 0 \quad (3.8)$$

3.3.2. Soft – Margin SVM

Ketika data yang digunakan tidak sepenuhnya dapat dipisahkan, *slack variables* x_i diperkenalkan kedalam fungsi obyektif SVM untuk memungkinkan kesalahan dalam misklasifikasi. Dalam hal ini, SVM bukan lagi *hard margin classifier* yang akan mengklasifikasi semua data dengan sempurna melainkan sebaliknya yaitu SVM *soft margin classifier* dengan mengklasifikasikan sebagian besar data dengan benar, sementara memungkinkan model untuk membuat misklasifikasi beberapa titik di sekitar batas pemisah. Berikut merupakan gambar ketika data termasuk kedalam *soft margin SVM* (Awad & Khanna, 2015).



(Sumber : Buku Efficient Learning Machine, 2015)

Gambar 3.3 Beberapa misklasifikasi pada *Soft margin SVM*

Berdasarkan pada Gambar 3.3 diatas, terlihat bahwa data pada kedua kelas tidak terpisah secara sempurna dapat dilihat dari beberapa lingkaran abu – abu yang persebarannya berada di sekitar area lingkaran hitam serta sebaliknya terdapat beberapa lingkaran hitam yang persebarannya berada di sekitar lingkaran abu – abu. Persamaan *soft margin* hampir mirip dengan *hard margin*

hanya terdapat sedikit modifikasi dengan adanya *slack variabel* pada persamaan (3.3) sebelumnya seperti berikut.

$$y_i(w \cdot x_i + b) \geq 1 - \varepsilon_i \quad (3.9)$$

Kemudian ketika akan dilakukan minimasi jumlahan eror $\sum_{i=1}^m \xi_i$ adalah sebagai berikut.

$$\min \left[\frac{1}{2} w \cdot w + C \sum_{i=1}^m \varepsilon_i \right] - \sum_{i=1}^m \alpha_i [y_i(w \cdot x_i + b) - 1 + \varepsilon_i] - \sum_{i=1}^m r_i \varepsilon_i \quad (3.10)$$


Dengan demikian, persamaan (3.2) akan diubah kedalam persamaan berikut.

$$\min \tau(w) = \frac{1}{2} \|w\|^2 + c \sum_{i=1}^m \varepsilon_i \quad (3.11)$$

Parameter c digunakan untuk mengontrol *trade off* antara margin dan kesalahan klasifikasi ε (Abtohi, 2017).

3.3.3. Kernel SVM

Ketika terdapat permasalahan data yang tidak terpisah secara linear dalam ruang input, *soft margin* SVM tidak dapat menemukan *hyperplane* pemisah yang kuat yang meminimalkan misklasifikasi dari *data points* serta menggeneralisasi dengan baik. Untuk itu, kernel dapat digunakan untuk mentransformasi data ke ruang berdimensi lebih tinggi yang disebut sebagai ruang kernel, dimana akan menjadikan data terpisah secara linear (Awad & Khanna, 2015).



(Sumber : www.quora.com)

Gambar 3.4 Kernel SVM untuk memisahkan data secara linear

Data disimpan dalam bentuk kernel yang mengukur kesamaan atau ketidaksamaan objek data. Kernel dapat dibangun untuk berbagai objek data

mulai dari data kontinu dan data diskrit melalui urutan data dan grafik. Konsep substitusi kernel berlaku bagi metode lain dalam analisis data. tetapi SVM merupakan yang paling terkenal dari metode dengan jangkauan kelas luas yang menggunakan kernel untuk merepresentasikan data dan dapat disebut sebagai metode berbasis kernel (Cambell & Ying, 2011). Berikut merupakan ilustrasi contoh dalam melakukan pemisahan data menggunakan kernel. Diketahui bahwa data terdiri dari *input space* dengan dua buah $\mathbf{x} = \{x_1, x_2\}$ dan $\mathbf{z} = \{z_1, z_2\}$. Diasumsikan fungsi kernel akan dibuat dengan menggunakan input x dan z seperti berikut (Rai, 2011).

$$\begin{aligned}
 \mathbf{K}(\mathbf{x}, \mathbf{z}) &= (\mathbf{x}^T \mathbf{z})^2 \\
 \mathbf{K}(\mathbf{x}, \mathbf{z}) &= (x_1 z_1 + x_2 z_2)^2 \\
 \mathbf{K}(\mathbf{x}, \mathbf{z}) &= (x_1^2 z_1^2 + x_2^2 z_2^2 + 2x_1 x_2 z_1 z_2)^2 \\
 \mathbf{K}(\mathbf{x}, \mathbf{z}) &= (x_1^2, \sqrt{2}x_1 x_2, x_2^2)^T (z_1^2, \sqrt{2}z_1 z_2, z_2^2) \\
 \mathbf{K}(\mathbf{x}, \mathbf{z}) &= \Phi(x)^T \Phi(z) \tag{3.12}
 \end{aligned}$$

Nilai $\mathbf{K}$ diatas secara implisit mendefinisikan pemetaan ke ruang dimensi yang lebih tinggi seperti berikut.

$$\Phi(x) = \{x_1^2, \sqrt{2}x_1 x_2, x_2^2\} \tag{3.13}$$

Kernel $\mathbf{K}(\mathbf{x}, \mathbf{z})$ mengambil dua *input space* dan memberikan kesamaannya dalam *feature space* seperti berikut.

$$\Phi : X \rightarrow F$$

$$\mathbf{K} : X \times X \rightarrow R, \mathbf{K}(\mathbf{x}, \mathbf{z}) = \Phi(x) \cdot \Phi(z)$$

Berdasarkan pada fungsi kernel diatas, dapat dilakukan perhitungan untuk melakukan prediksi dari beberapa data dalam *feature space* seperti pada persamaan berikut (Cambell & Ying, 2011).

$$\begin{aligned}
 f(\Phi(x)) &= \text{sign}(w \cdot \Phi(z) + b) \\
 f(\Phi(x)) &= \text{sign}(\sum_{i=1}^m \alpha_i y_i \mathbf{K}(\mathbf{x}, \mathbf{z}) + b) \tag{3.14}
 \end{aligned}$$

dimana :

b : nilai bias

m : jumlah *support vector*

$\mathbf{K}(\mathbf{x}, \mathbf{z})$: fungsi kernel

Nilai k yang bisa digunakan sebagai fungsi kernel harus memenuhi kondisi Mercer antara lain (Rai, 2011) :

- Merupakan *Hilbert Space* dimana nilai *feature space* harus merupakan vektor dengan *dot product*.

- Harus benar jika k merupakan fungsi definit positif

$$\int dx \int dz f(x) \mathbf{K}(\mathbf{x}, \mathbf{z}) f(z) > 0 \quad (\forall f \in L_2) \quad (3.15)$$

- Ketika k_1 dan k_2 merupakan fungsi kernel, maka :

$$\mathbf{K}(\mathbf{x}, \mathbf{z}) = \mathbf{K}_1(\mathbf{x}, \mathbf{z}) + \mathbf{K}_2(\mathbf{x}, \mathbf{z}) : \text{Direct sum} \quad (3.16)$$

$$\mathbf{K}(\mathbf{x}, \mathbf{z}) = \alpha \mathbf{K}_1(\mathbf{x}, \mathbf{z}) : \text{Skalar Product} \quad (3.17)$$

$$\mathbf{K}(\mathbf{x}, \mathbf{z}) = \mathbf{K}_1(\mathbf{x}, \mathbf{z}) \mathbf{K}_2(\mathbf{x}, \mathbf{z}) : \text{Direct product} \quad (3.18)$$

Berikut merupakan fungsi kernel yang populer dan sering digunakan antara lain sebagai berikut.

1. *Linear Kernel SVM*

Linear kernel merupakan fungsi kernel yang paling sederhana. Linear kernel digunakan ketika data yang dianalisis sudah terpisah secara linear. Linear kernel cocok ketika terdapat banyak fitur dikarenakan pemetaan ke ruang dimensi yang lebih tinggi tidak benar – benar meningkatkan kinerja seperti pada klasifikasi teks. Dalam klasifikasi teks, baik jumlah *instances* (dokumen) maupun jumlah fitur (kata) sama sama besar (Kowalczyk, 2014). Berikut merupakan persamaan dari linear kernel SVM.

$$\mathbf{K}(\mathbf{x}, \mathbf{z}) = \mathbf{x}^T \mathbf{z} \quad (3.19)$$

Pemetaan fungsi Φ merupakan identitas/tidak ada pemetaan

2. *Polynomial Kernel (derajat d)*

Polinomial kernel merupakan fungsi kernel yang digunakan ketika data tidak terpisah secara linear. Polinomial kernel sangat cocok untuk permasalahan dimana semua *training dataset* dinormalisasi.

$$\mathbf{K}(\mathbf{x}, \mathbf{z}) = (\mathbf{x}^T \mathbf{z})^d \quad \text{atau} \quad (1 + \mathbf{x}^T \mathbf{z})^d \quad (3.20)$$

3. *Radial Basis Function (RBF) Kernel*

RBF kernel merupakan fungsi kernel yang biasa digunakan dalam analisis ketika data tidak terpisah secara linear. RBF kernel memiliki dua parameter yaitu *Gamma* dan *Cost*. Parameter *Cost* atau biasa disebut sebagai *C* merupakan parameter yang bekerja sebagai pengoptimalan SVM untuk menghindari misklasifikasi di setiap sampel dalam *training dataset*. Parameter *Gamma* menentukan seberapa jauh pengaruh dari satu sampel *training dataset* dengan nilai rendah berarti “jauh”, dan nilai tinggi berarti “dekat”. Dengan *gamma* yang rendah, titik yang berada jauh dari garis pemisah yang masuk akal dipertimbangkan dalam perhitungan untuk garis pemisah. Ketika *gamma* tinggi berarti titik – titik berada di sekitar garis yang masuk akal akan dipertimbangkan dalam perhitungan (Patel, 2017). Berikut merupakan persamaan dari RBF kernel.

$$K(\mathbf{x}, \mathbf{z}) = \exp[-\gamma \|\mathbf{x} - \mathbf{z}\|^2] \quad (3.21)$$

3.5. *Confusion Matrix*

Confusion Matrix atau *error matrix* merupakan sebuah matriks yang menampilkan visualisasi kinerja dari algoritma klasifikasi menggunakan data dalam matriks. Hal tersebut membandingkan klasifikasi prediksi terhadap klasifikasi aktual dalam bentuk *False Positif* (FP), *True Positif* (TP), *False Negatif* (FN), dan *true Negatif* (TN) dari informasi. *Confusion Matrix* untuk sistem klasifier dua kelas (Profost & Kohavi, 1998) adalah sebagai berikut.

		Actual Value (as confirmed by experiment)	
		positives	negatives
Predicted Value (predicted by the test)	positives	TP True Positive	FP False Positive
	negatives	FN False Negative	TN True Negative

(Sumber : www.mathworks.com)

Gambar 3.5 *Confusion Matrix*

Berdasarkan pada Gambar 3.6, dijelaskan bahwa ketika hasil berada pada kolom TP maka hasil bernilai benar dan teridentifikasi sebagai positif. ketika hasil berada pada kolom FP maka hasil adalah salah dan teridentifikasi sebagai positif. Ketika hasil berada pada kolom FN maka hasil adalah salah dan teridentifikasi sebagai negatif dan ketika hasil berada di kolom TN, maka akan bernilai benar dan teridentifikasi negatif.

3.6. Akurasi

Akurasi atau tingkat kesalahan merupakan angka prediksi yang yang benar (atau salah) yang dibuat oleh model melalui kumpulan dari data. akurasi biasanya dihitung dengan menggunakan tes independen yang tidak selalu digunakan dalam proses pembelajaran. Teknik estimasi akurasi yang lebih kompleks seperti bootstrapping ataupun cross validation umumnya digunakan terutama untuk dataset yang memiliki sampel kecil (Awad & Khanna, 2015).

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FN+FP} \quad (3.22)$$

3.7. Uji Independensi *Chi Square*

Uji *Chi – Square* merupakan pengujian yang dilakukan untuk menguji hipotesis apakah faktor satu dengan faktor lainnya saling independen (Nugraha, 2016).

Tabel 3. 2 Tabel kontigensi b x k faktor A dan faktor B

Faktor A	Faktor B			
	B ₁	B ₂		B _k
A ₁	N ₁₁	N ₁₂		N _{1k}
A ₂	N ₂₁	N ₂₂		N _{2k}
.	.			.
.	.			.
A _b	N _{b1}	N _{b2}		N _{bk}

Dalam tabel kontigensi dua arah dengan probabilitas bersama π_{ij} , hipotesis nol yang digunakan untuk menguji independensi dua variabel adalah sebagai berikut.

$$H_0 : \pi_{ij} = \pi_{i0}\pi_{0j} \text{ untuk setiap } i \text{ dan } j.$$

Biasanya π_{i0} dan π_{0j} tidak diketahui sehingga dapat diestimasi menggunakan data sampel seperti berikut.

$$e_{ij} = \hat{\mu} = np_{i0}np_{0j} = n \frac{n_{i0}}{n} \frac{n_{0j}}{n} = \frac{n_{i0}n_{0j}}{n} \quad (3.23)$$

Sehingga akan diperoleh statistik uji χ^2 adalah sebagai berikut.

$$\chi^2 = \sum_{i=1}^b \sum_{j=1}^k \frac{(n_{ij} - e_{ij})^2}{e_{ij}} \quad (3.24)$$

Derajat bebas = (b-1)(k-1)

BAB IV

METODOLOGI PENELITIAN

4.1. Populasi Penelitian

Populasi yang digunakan dalam penelitian ini merupakan seluruh alumni UII. Sedangkan sampel yang digunakan penulis merupakan data alumni UII 2015 yang terdapat di kantor *UII Career*. Data tersebut merupakan hasil dari *tracer study* yang dilakukan oleh pihak *UII Career* dengan cara menyebarkan kuesioner kepada lulusan UII untuk mengukur proses pendidikan tinggi di UII dalam membekali para alumni untuk memasuki masa transisi dari dunia kampus ke dunia kerja. Selain itu, pengisian kuesioner tersebut juga sangat berguna sebagai masukan bagi perbaikan sistem pendidikan di UII. Data kuesioner terbagi menjadi empat aspek yaitu kuesioner tentang alumni yang melanjutkan studi, kuesioner bagi alumni yang bekerja, tidak bekerja, dan melakukan wirausaha. Sampel yang akan digunakan oleh penulis adalah data alumni UII yang melanjutkan studi ke jenjang S2, Pascasarjana, ataupun Transfer S1 dengan jumlah sampel sebanyak 441 sampel alumni.

4.2. Teknik Pengumpulan data

Data yang digunakan oleh penulis termasuk kedalam data sekunder yang diperoleh secara langsung dari kantor *UII Career*. Data sekunder merupakan sumber yang tidak secara langsung memberikan data kepada pengumpul data melainkan lewat perantara orang lain ataupun dokumen lainnya (Sugiyono, 2010).

4.3. Variabel Penelitian

Variabel yang digunakan dalam penelitian terdiri dari delapan variabel sebagai input dan satu variabel dikotomi sebagai target yang akan dijabarkan seperti pada tabel berikut.

Tabel 4. 1 Tabel Variabel Penelitian

Variabel	Nama Variabel	Kategorik
Target	Bidang Studi	1 : Sesuai Bidang ilmu sebelumnya (mengambil kelinear-an bidang atau dengan jurusan yang sama) 2 : Tidak Sesuai Bidang ilmu sebelumnya (mengambil studi lanjut non linear bidang atau dengan jurusan berbeda)
Input	Ipk	-
	Fakultas	1 : Fak. Ekonomi (FE) 2 : Fak. Hukum (FH) 3 : Fak. Ilmu Agama Islam (FIAI) 4 : Fak. Kedokteran (FK) 5 : Fak. Matematika & Ilmu Pengetahuan Alam (FMIPA) 6 : Fak. Psikologi & Sosial Budaya (FPSB) 7 : Fak. Teknik Sipil dan Perencanaan (FTSP) 8 : Fak. Teknik Industri (FTI)
	Jenis Kelamin	1 : Laki – Laki 2 : Perempuan
	Kelulusan Tepat Waktu	1 : Ya 2 : Tidak
	Jenis Studi Lanjut	1 : Pascasarjana 2 : Pendidikan Profesi 3 : Transfer S1
	Alasan Lanjut Studi	1 : Meningkatkan kompetensi dan kualifikasi 2 : Memperbesar peluang mendapat pekerjaan 3 : Belum memperoleh pekerjaan 4 : Disarankan oleh Orangtua 5 : Lainnya
	Biaya	1 : Biaya sendiri/orangtua 2 : Beasiswa dari pemerintah 3 : Beasiswa dari perusahaan 4 : Beasiswa dari lembaga/pemerintah asing 5 : Lainnya
	Universitas Pilihan	1 : Universitas Islam Indonesia (UII) 2 : Universitas Gadjah Mada (UGM) 3 : Universitas Ahmad Dahlan (UAD) 4 : Institut Pertanian Bogor (IPB) 5 : Lainnya

Pengkategorian variabel bidang studi kategori sesuai bidang ilmu sebelumnya dan kategori tidak sesuai bidang sebelumnya didasarkan pada kuesioner *Tracer Study* oleh DIKTI. Penentuan kategori dalam variabel


universitas pilihan alumni ditetapkan sendiri oleh peneliti dengan mengambil 4 universitas pilihan teratas serta 1 kategori khusus untuk beberapa universitas lainnya. universitas dengan jumlah peminat terbanyak dalam melanjutkan studi lanjut adalah UII dengan jumlah peminat 204 alumni , kemudian UGM yaitu 144 alumni, kemudian UAD dengan jumlah peminat 7 alumni, serta IPB dengan 6 alumni. selain beberapa universitas yang disebutkan diatas, akan dikategorikan kedalam kategori ke-5 atau lainnya.

4.4. Metode Analisis Data

Metode analisis data yang digunakan dalam penelitian adalah menggunakan metode *Support Vector Machine* (SVM) dengan bantuan *software R*. Dalam melakukan analisis dengan menggunakan SVM akan digunakan tiga fungsi SVM yang terdiri dari linear SVM, *radial Basis Function* (RBF) kernel SVM, dan polinomial kernel SVM untuk selanjutnya akan dibandingkan akurasi terbaik dari ketiga fungsi SVM tersebut.

4.5. Langkah Penelitian

Tahapan atau langkah dalam penelitian dapat digambarkan kedalam *flowchart* seperti berikut ini.




Gambar 4.1 *Flowchart* Tahapan Penelitian

BAB V

HASIL DAN PEMBAHASAN

5.1. Analisis Deskriptif

Data yang digunakan dalam penelitian merupakan data alumni UII yang melanjutkan studi jenjang S1/Pascasarjana/Pendidikan profesi dengan jumlah sampel sebanyak 441 sampel alumni. Deskriptif data digunakan untuk melihat perbandingan antara jenis kelamin dengan minat melanjutkan studi lanjut yang sesuai dengan program studi sebelumnya seperti berikut.



Gambar 5. 1 Perbandingan jenis kelamin alumni UII dengan bidang studi lanjut


Berdasarkan pada grafik diatas, terlihat bahwa pengambilan studi lanjut yang sesuai bidang pada alumni perempuan akan diperoleh hasil lebih besar yaitu berjumlah 264 orang bila dibandingkan dengan alumni laki – laki dengan jumlah berjumlah 150 orang. Jumlah alumni yang melakukan studi lanjut tidak sesuai bidang adalah sebesar 13 orang untuk alumni perempuan dan untuk alumni laki – laki adalah 14 orang. Pendeskripsian data selanjutnya yaitu menggunakan variabel bidang studi dengan tepat waktu kelulusan dari alumni UII, dapat ditampilkan dalam tabel berikut.

Tabel 5. 1 Deskripsi data antara tepat waktu kelulusan dengan pemilihan bidang studi lanjut

Kelulusan	Sesuai Bidang	Tidak Sesuai Bidang
Tepat Waktu	340	19
Tidak Tepat Waktu	74	8

Berdasarkan pada Tabel 5.1 diperoleh hasil bahwa alumni UII cenderung lebih banyak melanjutkan studi lanjut sesuai bidang studi sebelumnya bila dibandingkan tidak sesuai bidang studinya. Alumni UII yang lulus tepat waktu dan melanjutkan studi sesuai bidang adalah sebanyak 340 alumni sedangkan untuk alumni UII yang lulus tidak tepat waktu tetapi melanjutkan studi sesuai bidang ada sebanyak 74 alumni. jumlah alumni UII yang lulus tepat waktu serta melakukan studi lanjut tidak bidang adalah sebanyak 19 alumni, dan untuk alumni UII yang tidak lulus tepat waktu dan melanjutkan studi tidak sesuai bidang adalah sebesar 8 orang.


Pembahasan selanjutnya yaitu akan dilakukan pendeskripsian mengenai variabel alasan lanjut studi dengan bidang studi lanjut pilihan alumni sehingga dapat ditampilkan dalam diagram batang berikut.



Gambar 5. 2 Diagram batang variabel alasan lanjut studi dengan kesesuaian bidang studi

Berdasarkan pada gambar 5.2 diatas, terlihat bahwa mayoritas alasan yang mendasari alumni UII dalam melakukan lanjut studi yang sesuai dengan bidang studi sebelumnya adalah karena keinginan untuk meningkatkan kompetensi yang dimilikinya dengan jumlah mahasiswa sebesar 328 alumni. Jumlah mahasiswa yang melakukan studi lanjut dengan alasan ingin meningkatkan kompetensi tetapi melakukan studi lanjut tidak sesuai bidang adalah sebesar 19 alumni. Alasan kedua terbanyak yang dipilih alumni UII adalah untuk meningkatkan peluang kerja dengan jumlah mahasiswa 53 dengan jumlah mahasiswa memilih sesuai bidang yaitu 47 dan 6 lainnya memilih tidak sesuai bidang, Alasan selanjutnya yang dipilih alumni UII adalah dikarenakan belum mendapat pekerjaan sebesar 13 mahasiswa dengan jumlah mahasiswa memilih sesuai bidang yaitu 12 dan 1 lainnya memilih tidak sesuai bidang. Alasan lainnya yaitu saran dari orangtua untuk melanjutkan studi lanjut sesuai bidang adalah sebesar 13 orang sedangkan tidak sesuai studi lanjut yaitu 1 orang. Alasan – alasan lain yang mendasari alumni dalam melakukan lanjut studi sesuai bidang yaitu berjumlah 14 orang dan 0 orang dalam melakukan lanjut studi tidak sesuai bidang.


Setelah melakukan visualisasi data berkaitan dengan alasan alumni UII dalam memilih melanjutkan studi lanjut. Deskripsi data selanjutnya yaitu berkaitan dengan jumlah jenis studi lanjut yang akan dipilih alumni UII dengan kesesuaian bidang studi dapat dilihat seperti pada gambar berikut.



Gambar 5.3 Visualisasi Diagram batang jenis studi lanjut dengan kesesuaian bidang studi

Dari hasil diagram batang diatas, diperoleh informasi bahwa alumni UII yang melanjutkan studi lanjut pascasarjana adalah total 275 orang alumni dengan pengambilan yang sesuai bidang adalah 256 orang serta 19 lainnya tidak sesuai bidang. Alumni yang melanjutkan studi lanjut pendidikan profesi adalah 143 orang terbagi kedalam mahasiswa yang mengambil studi sesuai bidang sebesar 136 orang dan tidak sesuai bidang sejumlah 7 orang alumni. Alumni yang melakukan transfer S1 adalah 22 orang yang sesuai bidang sedangkan 1 lainnya tidak sesuai bidang.


Deskriptif data selanjutnya akan menjelaskan berkaitan tentang pengambilan studi lanjut sesuai bidang dengan fakultas sebelumnya. Hasil analisis dapat dilihat pada gambar berikut.



Gambar 5. 4 Visualisasi diagram batang variabel fakultas dengan kesesuaian pengambilan studi lanjut

Berdasarkan pada Gambar 5.4 diatas, dapat diperoleh informasi bahwa kebanyakan mahasiswa yang melanjutkan studi sesuai dengan bidang studi sebelumnya adalah pada FE dengan jumlah alumni 80, kemudian dilanjutkan dengan FMIPA dengan jumlah alumni 76 orang. Jumlah terbanyak ketiga yaitu pada FK dengan jumlah mahasiswa 64 orang mengambil studi lanjut sesuai bidang studinya. Selanjutnya adalah dari FH dengan jumlah 57 alumni yang

melakukan studi lanjut sesuai bidang dan 2 lainnya melakukan lanjut studi tidak sesuai bidang. Fakultas yang memiliki sedikit alumni dalam melakukan lanjut studi yaitu terdapat pada FIAI dengan jumlah alumni yang melakukan lanjut studi sesuai bidang sebesar 9 orang serta 2 orang melakukan lanjut studi tidak sesuai bidang.



Gambar 5. 5 Diagram batang variabel biaya dengan kesesuaian bidang studi

Berdasarkan pada Gambar 5.5 diatas, dapat diperoleh hasil secara umum bahwa beasiswa studi lanjut yang diberikan baik dari lembaga, pemerintah maupun perusahaan semuanya sesuai dengan bidang studi alumni sebelumnya. Data menunjukkan bahwa jumlah alumni yang menggunakan biaya orangtua/sendiri dalam melanjutkan studi lanjut sesuai bidang merupakan yang paling banyak dengan jumlah 397 alumni, dan 26 alumni lainnya menggunakan biaya orangtua/sendiri untuk melanjutkan studi tidak sesuai bidang.

Pembahasan selanjutnya yaitu pengujian independensi untuk melihat apakah terdapat hubungan antara variabel satu dengan lainnya. Dalam penelitian ini, akan dilakukan analisis untuk melihat apakah terdapat hubungan antara variabel input dengan variabel target. Hipotesis yang akan digunakan yaitu untuk H_0 : Tidak terdapat hubungan antara variabel input dengan variabel target,

sedangkan untuk hipotesis alternatif atau H_1 : Terdapat hubungan antara variabel input dengan variabel target. Berikut merupakan rangkuman yang dihasilkan dari analisis independensi.

Tabel 5. 2 Rangkuman Uji Independensi *Chi Square*

No	Variabel Input	<i>p-value</i>	Kesimpulan
1	Nilai IPK	0.0884	Gagal Tolak H_0
2	Fakultas Asal	0.0073	Tolak H_0
3	Jenis Kelamin	0.1551	Gagal Tolak H_0
4	Kelulusan Tepat Waktu	0.2055	Gagal Tolak H_0
5	Jenis Studi Lanjut	0.6714	Gagal Tolak H_0
6	Alasan Lanjut Studi	0.4501	Gagal Tolak H_0
7	Biaya	0.8742	Gagal Tolak H_0
8	Universitas Pilihan	0.1537	Gagal Tolak H_0

Berdasarkan pada Tabel 5.2 diatas, dengan menggunakan tingkat signifikansi $\alpha = 0.05$, akan diperoleh hasil bahwa terdapat satu variabel input yang memiliki hubungan dengan variabel target yaitu merupakan variabel fakultas asal dengan hasil nilai *p-value* adalah 0.0073 sehingga diperoleh kesimpulan yang menyatakan tolak H_0 .

5.2. Metode Support Vector Machine (SVM)

Metode analisis yang akan digunakan dalam penelitian adalah dengan menggunakan *Support Vector Machine* (SVM). Pada penggunaan metode SVM akan dilakukan pemisahan antara *training dataset* dengan *testing dataset*. *Training dataset* diambil 80% keseluruhan dari total 441 data sampel. Sedangkan untuk *testing dataset* merupakan sisa dari data yang akan diuji akurasi. Pengambilan *training dataset* maupun *testing dataset* dilakukan secara acak dengan bantuan *software R*. Seperti yang telah dijelaskan pada metode penelitian dalam bab sebelumnya, akan digunakan tiga fungsi SVM untuk mencari nilai akurasi terbaik antara lain linear SVM, RBF kernel SVM, dan polinomial kernel SVM yang akan dibahas satu persatu seperti berikut.

5.2.1. Linear Kernel SVM

Linear Kernel SVM merupakan fungsi kernel yang baik digunakan ketika data sudah terpisah secara linear. Analisis dilakukan dengan menggunakan 441 sampel yang dibagi menjadi dua bagian yaitu 80% sebagai *training dataset* dan 20% lainnya sebagai *testing dataset*. Dalam melakukan analisis dengan fungsi linear kernel, dilakukan optimasi parameter C atau *Cost*. Pengoptimalan parameter C dapat dilakukan dengan cara *trial and error* (Pratiwi & Ulama, 2016). Berikut merupakan tabel penentuan parameter terbaik linear kernel dengan cara *trial and error*.

Tabel 5. 3 Tabel nilai akurasi parameter terbaik dengan *trial and error*

Parameter	<i>Training dataset</i>	<i>Testing dataset</i>
	akurasi	Akurasi
C=0.001	0.9377	0.9432
C=0.01	0.9377	0.9432
C=0.1	0.9377	0.9432
C=1	0.9377	0.9432
C=10	0.9377	0.9432
C=100	0.9377	0.9432

Dari keseluruhan *trial and error* yang dilakukan, diperoleh hasil akurasi yang sama pada masing – masing parameter *cost* sehingga penentuan parameter terbaik dapat dilakukan dengan memilih salah satu nilai parameter *cost*. Penulis akan menggunakan C = 0.001 sebagai parameter terbaik dalam pembentukan model dengan *training dataset*. Sehingga akan diperoleh parameter model adalah sebagai berikut.

Tabel 5.4 Tabel Parameters Model SVM Linear Kernel

Parameters		
SVM – Type	:	C – Classification
SVM – Kernel	:	Linear
Cost	:	0.001
Number of Support Vectors	:	48

Berdasarkan pada Tabel 5.4 diatas, ketika digunakan fungsi linear kernel dalam melakukan analisis akan diperoleh hasil bahwa parameter terbaik untuk parameter C adalah 0.001. Dari hasil perolehan parameter terbaik diatas, dapat dibuat *confusion matrix* antara prediksi dengan aktual dari *training dataset* maupun *testing dataset* seperti berikut.

Tabel 5. 5 Tabel *Confusion Matrix training dataset*

Prediksi	Aktual	
	Sesuai	Tidak Sesuai
Sesuai	331	22
Tidak Sesuai	0	0

Berdasarkan pada Tabel 5.5, diperoleh hasil bahwa terdapat dua pilihan kemungkinan alumni UII yang melanjutkan studi lanjut yaitu apakah melanjutkan kuliah sesuai bidang studi ataukah tidak sesuai dengan bidang studi. Pada tabel klasifier diatas terdapat total 353 prediksi yang diperoleh dengan menganalisis *training dataset* untuk melihat kesesuaian pengambilan studi lanjut alumni UII. Dari 353 sampel diatas, klasifier memprediksi pilihan “Sesuai” adalah sebanyak 352 kali, dan prediksi “Tidak Sesuai” adalah sebanyak 0 kali. Sedangkan pada data aktual terdapat 331 alumni UII yang melanjutkan studi lanjut sesuai dengan bidang sedangkan 22 lainnya tidak sesuai dengan bidang. Hasil prediksi bernilai 22 dinamakan sebagai *False Positif* (FP) dimana nilai prediksi menyatakan hasil yang sesuai bidang sedangkan aktualnya nilai tidak sesuai bidang.

Tabel 5. 6 Tabel *Confusion Matrix testing dataset*

Prediksi	Aktual	
	Sesuai	Tidak Sesuai
Sesuai	83	5
Tidak Sesuai	0	0

Sama halnya seperti *training dataset* pada Tabel 5.5 diatas, *confusion matrix* dengan menggunakan *testing dataset* akan diperoleh hasil bahwa dari jumlah 88 sampel, klasifier memprediksi pilihan alumni dapat melakukan lanjut studi “Sesuai bidang” adalah sebanyak 83 kali, dan prediksi “Tidak Sesuai”

adalah sebanyak 0 kali. Sedangkan pada data aktual terdapat 83 alumni UII yang melanjutkan studi lanjut sesuai dengan bidang sedangkan 5 lainnya tidak sesuai dengan bidang. Hasil prediksi bernilai 5 merupakan *False Positif* dimana nilai prediksi menyatakan hasil yang sesuai bidang sedangkan aktualnya nilai tidak sesuai bidang.

Setelah diperoleh *confusion matrix* seperti diatas, dapat dilanjutkan dengan mencari nilai nilai akurasi dari *training dataset* dan *testing dataset* menggunakan perhitungan seperti berikut.

• **Training dataset**

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FN+FP}$$

$$\text{Akurasi} = \frac{331 + 0}{353}$$

$$\text{Akurasi} = 0.9376771$$

• **Testing dataset**

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FN+FP}$$

$$\text{Akurasi} = \frac{83 + 0}{88}$$

$$\text{Akurasi} = 0.9431818$$

Hasil perhitungan akurasi dari *training dataset* dan *testing dataset* dapat dirangkum kedalam tabel seperti dibawah.

Tabel 5. 7 Tabel prediksi *training dataset* dan *testing dataset*

<i>Dataset</i>	<i>Misclassification</i>	Akurasi
<i>Training dataset</i>	0.06232295	0.9376771
<i>Testing dataset</i>	0.05681818	0.9431818

SVM dilatih dengan menggunakan *training dataset*, kemudian performanya dievaluasikan ke dalam *testing dataset*. Ketika dilakukan analisis SVM dengan menggunakan fungsi Linear kernel, hasil menunjukkan bahwa SVM akan mengklasifikasikan secara benar 83 sampel dari total 88 sampel

testing dataset yang dapat dilihat dari tabel *confusion matrix* seperti pada Tabel 5.5 dengan nilai akurasi sebesar 0.9431818 atau setara dengan 94.32%.

5.2.2. RBF Kernel SVM

Fungsi kernel kedua yang digunakan dalam analisis adalah dengan menggunakan RBF kernel SVM. seperti yang sudah dijelaskan dalam bab landasan teori, RBF kernel merupakan fungsi kernel yang digunakan ketika data tidak terpisah secara linear. Dalam melakukan analisis dengan fungsi RBF kernel, dilakukan optimasi parameter *Cost* (C) dan *Gamma* (γ). Analisis dilakukan dengan menggunakan 441 sampel yang dibagi menjadi dua bagian yaitu 80% sebagai *training dataset* dan 20% lainnya sebagai *testing dataset*. Sama halnya seperti pada fungsi linear kernel, dalam penentuan parameter terbaik dalam RBF kernel juga dilakukan *trial and error* sehingga akan diperoleh tabel berikut.

Tabel 5. 8 Tabel nilai akurasi parameter terbaik dengan *trial and error* untuk *training dataset*

Parameter	Akurasi				
	$\gamma = 1$	$\gamma = 2$	$\gamma = 3$	$\gamma = 4$	$\gamma = 5$
C=1	0.9575	0.9887	0.9887	0.9887	0.9887
C=10	0.9887	0.9915	0.9972	0.9972	0.9972
C=50	0.9943	0.9972	0.9972	0.9972	0.9972
C=100	0.9972	0.9972	0.9972	0.9972	0.9972

Kemudian akan dilanjutkan dengan penentuan parameter terbaik dengan menggunakan *testing dataset* seperti tabel berikut.

Tabel 5. 9 Tabel nilai akurasi parameter terbaik dengan *trial and error* untuk *testing dataset*

Parameter	Akurasi				
	$\gamma = 1$	$\gamma = 2$	$\gamma = 3$	$\gamma = 4$	$\gamma = 5$
C=1	0.9318	0.9318	0.9318	0.9318	0.9318
C=10	0.9318	0.9205	0.9205	0.9205	0.9205
C=50	0.9205	0.9205	0.9205	0.9205	0.9205

Parameter	Akurasi				
	$\gamma = 1$	$\gamma = 2$	$\gamma = 3$	$\gamma = 4$	$\gamma = 5$
C=100	0.9205	0.9205	0.9205	0.9205	0.9205

Dari keseluruhan *trial and error* yang dilakukan, pada Tabel 5.9 diperoleh hasil akurasi yang hampir sama pada masing – masing parameter *cost* dan γ sehingga penentuan parameter terbaik dapat dilakukan dengan memilih salah satu nilai parameter *cost* dan γ . Penulis akan menggunakan $C = 1$, serta $\gamma = 1$ sebagai parameter terbaik dalam pembentukan model dengan *training dataset*. Sehingga akan diperoleh parameter model adalah sebagai berikut.

Tabel 5.10 Tabel Parameters Model SVM RBF Kernel

Parameters		
SVM – Type	:	C – Classification
SVM – Kernel	:	Radial
Cost	:	1
Gamma	:	1
Number of Support Vectors	:	206

Nilai parameter *Cost* dan *Gamma* pada Tabel 5.10 diatas, diperoleh dengan cara mencari parameter terbaik dari parameter *Cost* dan γ . Berdasarkan pada hasil Tabel 5.10 diatas, dapat dibuat *confusion matrix* antara prediksi dengan aktual dari *training dataset* adalah seperti berikut.

Tabel 5. 11 Tabel *Confusion Matrix training dataset*

Prediksi	Aktual	
	Sesuai	Tidak Sesuai
Sesuai	331	15
Tidak Sesuai	0	7

Pada tabel klasifier diatas terdapat total 353 prediksi yang diperoleh dengan menganalisis *training dataset* untuk melihat kesesuaian pengambilan studi lanjut alumni UII. Dari 353 sampel diatas, klasifier memprediksi pilihan “Sesuai” adalah sebanyak 346 kali, dan prediksi “Tidak Sesuai” adalah sebanyak 7 kali. Sedangkan pada data aktual terdapat 331 alumni UII yang melanjutkan studi lanjut sesuai dengan bidang sedangkan 22 lainnya tidak sesuai dengan bidang. Hasil prediksi bernilai 15 dinamakan sebagai *False*

Positif (FP) dimana nilai prediksi menyatakan hasil yang sesuai bidang sedangkan aktualnya nilai tidak sesuai bidang.

Tabel 5. 12 Tabel *Confusion Matrix testing dataset*

Prediksi	Aktual	
	Sesuai	Tidak Sesuai
Sesuai	82	5
Tidak Sesuai	1	0

Sama halnya seperti pada *training dataset* diatas, akan diperoleh hasil bahwa dari jumlah 88 sampel *testing dataset*, klasifier memprediksi pilihan alumni dapat melakukan lanjut studi “Sesuai bidang” adalah sebanyak 87 kali, dan prediksi “Tidak Sesuai” adalah sebanyak 1 kali. Sedangkan pada data aktual terdapat 83 alumni UII yang melanjutkan studi lanjut sesuai dengan bidang sedangkan 5 lainnya tidak sesuai dengan bidang. Hasil prediksi bernilai 5 merupakan *False Positif* (FP) dimana nilai prediksi menyatakan hasil yang sesuai bidang sedangkan data aktualnya nilai tidak sesuai bidang. Hasil prediksi bernilai 1 merupakan *False Negatif* (FN) dimana nilai prediksi menyatakan hasil tidak sesuai bidang sedangkan aktualnya sesuai bidang.

Setelah diperoleh *confusion matrix* seperti diatas, dapat dilanjutkan dengan mencari nilai nilai akurasi dari *training dataset* dan *testing dataset* menggunakan perhitungan seperti berikut.

- **Training dataset**

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FN+FP}$$

$$\text{Akurasi} = \frac{331 + 7}{353}$$

$$\text{Akurasi} = 0.9575071$$

- **Testing dataset**

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FN+FP}$$

$$\text{Akurasi} = \frac{82 + 0}{88}$$

$$\text{Akurasi} = 0.9318182$$

Hasil dari perhitungan akurasi dari *training dataset* dan *testing dataset* dapat dirangkum kedalam tabel seperti dibawah.

Tabel 5. 13 Tabel ketepatan klasifikasi *training dataset* dan *testing dataset*

<i>Dataset</i>	<i>Misclassification</i>	Akurasi
<i>Training dataset</i>	0.04249292	0.9575071
<i>Testing dataset</i>	0.06818182	0.9318182

SVM dilatih dengan menggunakan *training dataset*, kemudian performanya dievaluasikan ke dalam *testing dataset*. Ketika dilakukan analisis SVM dengan menggunakan fungsi RBF kernel, hasil menunjukkan bahwa SVM akan mengklasifikasikan secara benar 82 sampel dari total 88 sampel *testing dataset* yang dapat dilihat dari tabel *confusion matrix* seperti pada Tabel 5.13 dengan nilai akurasinya sebesar 0.9318182 atau setara dengan 93.18%.

5.2.3. Polinomial Kernel SVM

Polinomial kernel merupakan fungsi kernel non linear yang sangat cocok digunakan untuk permasalahan yang semua *training dataset*-nya dinormalisasi. Parameter dari fungsi polinomial kernel terdiri dari *Cost*, dan *Degree (d)*. Sama halnya seperti dalam fungsi – fungsi kernel sebelumnya, pengoptimalan parameter dapat dilakukan dengan cara *trial and error* sehingga akan didapatkan hasil seperti berikut.

Tabel 5. 14 Tabel nilai akurasi parameter terbaik dengan *trial and error* untuk *training dataset*

Parameter	Akurasi	
	d=1	d=2
C=100	0.9377	0.9433
C=200	0.9377	0.9518
C=300	0.9377	0.9575
C=400	0.9377	0.9603
C=500	0.9377	0.9717

Kemudian akan dilanjutkan dengan penentuan parameter terbaik dengan menggunakan *testing dataset* seperti tabel berikut.

Tabel 5. 15 Tabel nilai akurasi parameter terbaik dengan *trial and error* untuk *testing dataset*

Parameter	Akurasi	
	d=1	d=2
C=100	0.9432	0.9432
C=200	0.9432	0.9432
C=300	0.9432	0.9545
C=400	0.9432	0.9545
C=500	0.9432	0.9545

Dari keseluruhan *trial and error* yang dilakukan, pada Tabel 5.15 diperoleh hasil akurasi dari beberapa parameter *cost* dan *d*. Hasil pada tabel menunjukkan bahwa akurasi pada $C = 300$, $C = 400$, dan $C = 500$ dengan nilai *degree* (d) = 0.9545 lebih besar bila dibandingkan akurasi pada saat menggunakan $d = 1$. Penulis akan menggunakan $C = 500$, serta $d = 2$ sebagai parameter terbaik dalam pembentukan model dengan *training dataset*. Sehingga akan diperoleh parameter model adalah sebagai berikut.

Tabel 5. 16 Tabel Parameters Model SVM Polinomial Kernel

Parameters		
SVM – Type	:	C – Classification
SVM – Kernel	:	Polynomial
Cost	:	500
Degree	:	2
Number of Support Vectors	:	81

Parameter *Cost* dan *degree* (d) pada Tabel 5.16 diatas, diperoleh dengan cara mencari parameter terbaik dari parameter *Cost* dan *degree*. Berdasarkan pada hasil Tabel 5.16 diatas, dapat dibuat *confusion matrix* antara prediksi dengan aktual dari *training dataset* adalah seperti berikut.

Tabel 5. 17 Tabel *Confusion Matrix training dataset*

Prediksi	Aktual	
	Sesuai	Tidak Sesuai
Sesuai	330	9
Tidak Sesuai	1	13

Pada tabel klasifier diatas terdapat total 353 prediksi yang diperoleh dengan menganalisis *training dataset* untuk melihat kesesuaian pengambilan studi lanjut alumni UII. Dari 353 sampel diatas, klasifier memprediksi pilihan “Sesuai” adalah sebanyak 338 kali, dan prediksi “Tidak Sesuai” adalah sebanyak 15 kali. Sedangkan pada data aktual terdapat 331 alumni UII yang melanjutkan studi lanjut sesuai dengan bidang sedangkan 22 lainnya tidak sesuai dengan bidang. Hasil prediksi bernilai 8 dinamakan sebagai *False Positif* (FP) dimana nilai prediksi menyatakan hasil yang sesuai bidang sedangkan aktualnya nilai tidak sesuai bidang. Hasil prediksi bernilai 1 dinamakan *False Negatif* (FN) dimana nilai prediksi menyatakan hasil yang tidak sesuai bidang sedangkan aktualnya data sesuai bidang.

Tabel 5. 18 *Confusion Matrix testing dataset*

Prediksi	Aktual	
	Sesuai	Tidak Sesuai
Sesuai	83	4
Tidak Sesuai	0	1

Sama halnya seperti pada *training dataset* diatas, akan diperoleh hasil bahwa dari jumlah 88 sampel *testing dataset*, klasifier memprediksi pilihan alumni dapat melakukan lanjut studi “Sesuai bidang” adalah sebanyak 87 kali, dan prediksi “Tidak Sesuai” adalah sebanyak 1 kali. Sedangkan pada data aktual terdapat 83 alumni UII yang melanjutkan studi lanjut sesuai dengan bidang sedangkan 5 lainnya tidak sesuai dengan bidang. Hasil prediksi bernilai 4 merupakan *False Positif* (FP) dimana nilai prediksi menyatakan hasil yang sesuai bidang sedangkan data aktualnya nilai tidak sesuai bidang. Hasil prediksi bernilai 1 merupakan *False Negatif* (FN) dimana nilai prediksi menyatakan hasil tidak sesuai bidang sedangkan aktualnya sesuai bidang.

Setelah diperoleh *confusion matrix* seperti diatas, dapat dilanjutkan dengan mencari nilai akurasi dari *training dataset* dan *testing dataset* menggunakan perhitungan seperti berikut.

• **Training dataset**

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FN+FP}$$

$$\text{Akurasi} = \frac{330 + 13}{353}$$

$$\text{Akurasi} = 0.9716714$$

• **Testing dataset**

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FN+FP}$$

$$\text{Akurasi} = \frac{83 + 1}{88}$$

$$\text{Akurasi} = 0.9545455$$

Hasil dari perhitungan akurasi dari *training dataset* dan *testing dataset* dapat dirangkum kedalam tabel seperti dibawah.

Tabel 5. 19 Tabel prediksi *training dataset* dan *testing dataset*

<i>Dataset</i>	<i>Misclassification</i>	Akurasi
<i>Training dataset</i>	0.02832861	0.9716714
<i>Testing dataset</i>	0.04545455	0.9545455

SVM dilatih dengan menggunakan *training dataset*, kemudian performanya dievaluasikan ke dalam *testing dataset*. Ketika dilakukan analisis SVM dengan menggunakan fungsi polinomial kernel, hasil menunjukkan bahwa SVM akan mengklasifikasikan secara benar 82 sampel dari total 88 sampel *testing dataset* yang dapat dilihat dari tabel *confusion matrix* seperti pada Tabel 5.17 dengan nilai akurasinya sebesar 0.9545455 atau setara dengan 95.45%.

5.3. Perbandingan Tiga Fungsi Kernel SVM

Setelah melakukan analisis menggunakan fungsi kernel Linear, RBF, serta polinomial dari data alumni UII. Kemudian akan ditentukan manakah fungsi kernel yang paling sesuai digunakan dalam menentukan ketepatan klasifikasi alumni UII yang melanjutkan studi lanjut sesuai bidang ataukah tidak sesuai

bidang studi sebelumnya. Berikut merupakan tabel rangkuman nilai akurasi dari ketiga fungsi kernel.

Tabel 5.20 Tabel Rangkuman Akurasi Fungsi Kernel

Fungsi Kernel	Akurasi	
	<i>Training dataset</i>	<i>Testing dataset</i>
Linear Kernel	93.77%	94.32%
RBF Kernel	95.75%	93.18%
Polinomial Kernel	97.17%	95.45%

Berdasarkan pada Tabel 5.20 diatas, dapat diperoleh hasil bahwa fungsi kernel yang tepat digunakan dalam menentukan ketepatan klasifikasi alumni UII yang melanjutkan studi sesuai bidang studi sebelumnya ataukah tidak sesuai bidang sebelumnya adalah ketika dilakukan analisis dengan menggunakan fungsi polinomial kernel yang menghasilkan nilai akurasi sebesar 95.45%.

5.4. Pengaplikasian Metode SVM Linear Kernel dalam Pencarian *Hyperplane*

Berikut merupakan langkah – langkah pengaplikasian metode SVM linear kernel dalam pencarian *hyperplane* ketika penggunaan 4 data input dari dua variabel pada variabel jenis kelamin dan variabel kelulusan tepat waktu dengan data sebagai berikut.

Tabel 5. 21 Data input variabel jenis kelamin dan kelulusan tepat waktu

Variabel jenis kelamin	Variabel kelulusan tepat waktu	y
2	2	1
2	1	-1
2	1	1
1	1	-1

1. Karena terdapat dua fitur x yaitu x_1 (jenis kelamin) dan x_2 (kelulusan tepat waktu) maka akan digunakan dua bobot yaitu w_1 dan w_2 . Hal pertama yang dilakukan adalah dengan meminimalkan margin $\frac{1}{2} \|w\|^2 = \frac{1}{2} (w_1^2 + w_2^2)$ dengan syarat sebagai berikut:

$$y_i(w \cdot x_i + b) \geq 1, i = 1, 2, 3, \dots, N$$

$$y_i(w_1 \cdot x_1 + w_2 \cdot x_2 + b) \geq 1$$

Sehingga akan diperoleh persamaan berikut.

$$\text{a. } 1(2w_1 + 2w_2 + b) \geq 1 \quad \rightarrow \quad (2w_1 + 2w_2 + b) \geq 1 \quad \dots(1)$$

$$\text{b. } -1(2w_1 + w_2 + b) \geq 1 \quad \rightarrow \quad (-2w_1 - w_2 - b) \geq 1 \quad \dots(2)$$

$$\text{c. } 1(2w_1 + w_2 + b) \geq 1 \quad \rightarrow \quad (2w_1 + w_2 + b) \geq 1 \quad \dots(3)$$

$$\text{d. } -1(w_1 + w_2 + b) \geq 1 \quad \rightarrow \quad (-w_1 - w_2 - b) \geq 1 \quad \dots(4)$$

2. Mencari nilai w dan b dari persamaan (3) dan (4) seperti berikut.

$$\begin{array}{r} (2w_1 + w_2 + b) \geq 1 \\ (-w_1 - w_2 - b) \geq 1 \quad + \\ \hline w_1 = 2 \end{array}$$

3. Mencari nilai w dan b dari persamaan (1) dan (2) seperti berikut.

$$\begin{array}{r} (2w_1 + 2w_2 + b) \geq 1 \\ (-2w_1 - w_2 - b) \geq 1 \quad + \\ \hline w_2 = 2 \end{array}$$

4. Mencari nilai w dan b dari persamaan (1) dan (3) seperti berikut.

$$\begin{array}{r} (2w_1 + 2w_2 + b) \geq 1 \\ (2w_1 + w_2 + b) \geq 1 \quad + \\ \hline 4w_1 + 3w_2 + 2b = 2 \\ 4(2) + 3(2) + 2b = 2 \\ b = -6 \end{array}$$

Sehingga akan diperoleh persamaan *hyperplane* :

$$w_1 x_1 + w_2 x_2 + b = 0$$

$$2x_1 - 2x_2 - 6 = 0 \rightarrow x_1 - x_2 - 3$$

$$2x_2 = 2x_1 - 6$$


5. Langkah selanjutnya yaitu membuat plot *hyperplane* dengan fungsi $2x_1 - 2x_2 - 6$ menggunakan beberapa data seperti berikut.

Tabel 5.22 Visualisasi data kedalam grafik *hyperplane*

x_1	$x_2 = x_1 - 3$
-2	-5
-1	-4

x_1	$x_2 = x_1 - 3$
0	-3
1	-2
2	-1
3	0
4	1
5	2

Sehingga akan diperoleh plot *hyperplane* sebagai berikut.




Gambar 5.6 Plot *hyperplane* fungsi klasifikasi

6. Mengklasifikasikan data kedalam *hyperplane* ketika terdapat data uji dengan fungsi $f(x) : x_1 - x_2 - 3$ dengan kelas nya adalah $\text{sign}(f(x))$.

Tabel 5.23 Data uji untuk klasifikasi data ke dalam *hyperplane*

No	Data uji		Hasil klasifikasi
	x_1	x_2	Kelas = $\text{sign}(x_1 - x_2 - 3)$
1	1	2	$\text{Sign}(1-2-3) = -1$
2	2	2	$\text{Sign}(2-2-3) = -1$
3	2	1	$\text{Sign}(2-1-3) = -1$
4	2	1	$\text{Sign}(2-1-3) = -1$
5	1	1	$\text{Sign}(1-1-3) = -1$

Setelah dilakukan klasifikasi dari data uji, akan diperoleh garis *hyperplane* adalah seperti berikut.



Gambar 5.7 Visualisasi Garis *Hyperplane* Data Uji

Berdasarkan pada Gambar 5.7 diatas, akan diperoleh hasil prediksi klasifikasi kelas dari kelima data uji adalah semuanya masuk kedalam kelas -1 atau tidak sesuai bidang ilmu sebelumnya. Hasil klasifikasi dapat dilihat dari nilai perhitungan dengan fungsi yang sudah diperoleh sebelumnya yaitu seperti pada Tabel 5.23.

BAB VI

PENUTUP

6.1. Kesimpulan

Berdasarkan hasil analisis serta pembahasan dalam bab sebelumnya, dapat diambil beberapa kesimpulan adalah sebagai berikut.

1. Gambaran umum yang diperoleh dari beberapa variabel input dan variabel target yaitu bahwa kecenderungan alumni UII lulusan tahun 2015 dalam melanjutkan studi lanjut sesuai bidang sudah banyak bila dibandingkan dengan mahasiswa yang melanjutkan studi tidak sesuai bidang.
2. Analisis menggunakan Uji *Chi Square* untuk melihat adakah hubungan antara variabel input dengan variabel target akan diperoleh hasil bahwa terdapat satu variabel input yang memiliki hubungan dengan variabel target yaitu pada variabel Fakultas Asal.
3. Hasil ketepatan klasifikasi dengan menggunakan metode SVM Linear, RBF, serta Polinomial kernel diperoleh akurasi berturut turut 94.32%, 93.82%, dan 95.45% sehingga dapat dikatakan bahwa fungsi kernel polinomial cocok digunakan dalam menentukan ketepatan klasifikasi alumni UII yang melanjutkan studi sesuai bidang studi sebelumnya atau tidak sesuai bidang sebelumnya bila dibandingkan dengan dua fungsi kernel lainnya dengan akurasi sebesar 95.45%.

6.2. Saran

Berdasarkan hasil analisis dan kesimpulan yang diperoleh, dapat diberikan saran sebagai berikut.

1. Pada penelitian selanjutnya diharapkan agar menambah dan memperdalam analisis dengan mencari beberapa faktor – faktor pengaruh dari pengambilan studi lanjut sesuai bidang studi sebelumnya maupun pengambilan studi lanjut yang tidak sesuai dengan bidang studi sebelumnya.

2. Dengan hasil akurasi yang sudah tinggi yaitu sebesar 95.45% alumni yang memilih studi lanjut sesuai bidang ilmu sebelumnya, dapat digunakan sebagai acuan bagi universitas maupun jurusan untuk selalu memperbaiki sistem pembelajarannya dengan melakukan tindak lanjut salah satunya adalah penyebaran kuesioner yang khusus membahas tentang kepuasan serta ketertarikan mahasiswa dengan bidang ilmu yang diberikan selama mengikuti pembelajaran saat kuliah.

DAFTAR PUSTAKA

- Abbott, D. (2014). *Applied Predictive Analytics: Principles and Techniques for the Professional Data Analyst*. Wiley.
- Abtohi, S. (2017). Implementasi Web Scrapping dan Klasifikasi Sentimen Menggunakan Metode Support Vector Machine. *Skripsi*. Universitas Islam Indonesia.
- Anggraeni, D. (2016). Pengaruh Prestasi Belajar, Pendidikan Orangtua, dan Informasi Penawaran Beasiswa S2 Terhadap Minat Melanjutkan Studi S2 pada Mahasiswa Prodi Pendidikan Ekonomi FE UNY Angkatan 2012 . *Skripsi*. FE, Pendidikan Ekonomi Universitas Negeri Yogyakarta.
- Anonim. (2016). *Pendidikan untuk Membangun Peradaban Bangsa*. Dipetik Maret 03, 2018, dari <http://presidenri.go.id/berita-aktual/pendidikan-untuk-membangun-peradaban-bangsa.html>.
- Anonim. (2017). *Tentang Tracer Study*. Dipetik 23 Mei, 2018, dari <https://tracer.uui.ac.id/tentang-kami.html>
- Awad, M., & Khanna, R. (2015). *Efficient Learning Machines : Theories, Concepts, Applications for Engineers and System Designers*. Apress.
- Cambell, C., & Ying, Y. (2011). *Learning with Support Vector Machines : Synthesis Lecturers on Artificial Intelligence and Machine Learning* . Morgan & Claypool.
- Faihah, R. T. (2010). Support Vector Machine (SVM). *Makalah Data Mining*. Universitas Trunojoyo.
- Gunn, S. (1998). *Support Vector Machine for Classification and Regression*. Southampton: University of Southampton.
- Kemenkeu. (2014). *Profil LPDP*. Dipetik Maret 02, 2018, dari <https://www.lpdg.kemenkeu.go.id/>.
- Kowalczyk, A. (2014). *Linear Kernel: Why is it recommended for text classification ?* Dipetik April 10, 2018, dari <https://www.svm-tutorial.com/2014/10/svm-linear-kernel-good-text-classification/>

- Lukman. (2016). Penerapan Algoritma Support Vector Machine (SVM) dalam Pemilihan Beasiswa : Studi Kasus SMK YAPIMDA.
- Ningrum, H. (2018). Perbandingan Metode Support Vector Machine (SVM) dalam Klasifikasi Bidang Studi Lanjut Pilihan ALumni UII.
- Novianti, F., & Purnami, S. (2012). Analisis Diagnosis Pasien Kanker Payudara Menggunakan Regresi Logistik dan Support Vector Machine (SVM) Berdasarkan Hasil Mamografi. *JURNAL SAINS DAN SENI*.
- Nugraha, D. (2016). *Pengantar Analisis Data Kategorik*. Yogyakarta : Deepublish.
- Nurhayati, S., Kusriani, & Luthfi, E. (2015). Prediksi Mahasiswa Drop Out Menggunakan Metode Support Vector Machine. *Jurnal Ilmiah SISFOTENIKA*.
- Octaviani, P., Wilandari, Y., & Ispriyanti, D. (2014). Penerapan Metode Klasifikasi Support Vector Machine (SVM) pada Data Akreditasi Sekolah dasar (SD) di Kabupaten Magelang. *JURNAL GAUSSIAN*.
- Patel, S. (2017, Mei 3). *Chapter 2 : SVM (Support Vector Machine)—Theory*. Dipetik April 11, 2018, dari Machine Learning 101: <https://medium.com/machine-learning-101/chapter-2-svm-support-vector-machine-theory-f0812effc72>
- Pratiwi, S., & Ulama, B. (2016). Klasifikasi Email Spam dengan Menggunakan Metode Support Vector Machine dan K-Nearest Neighbor. *JURNAL SAINS DAN SENI ITS*.
- Profost, F., & Kohavi, R. (1998). On Applied Research in Machine Learning. *In Editorial for the Special Issue on Applications of Machine Learning and the Knowledge Discovery Process*.
- Radhika, Y., & Shashi, M. (2009). Atmospheric Temperature Prediction using Support Vector Machine. *International Journal of Computer Theory and Engineering*.
- Rai, P. (2011). Kernel Methods and Nonlinear Classification. *Presentation*.
- Santosa, B. (2007). *Data Mining Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Yogyakarta: Graha Ilmu.
- Santoso, B. (2007). *Data Mining : Teknik Pemanfaatan Data untuk Keperluan Bisnis*. Yogyakarta: Graha Ilmu.

- Sugiyono. (2010). *Metodologi Penelitian Pendidikan (Pendekatan Kuantitatif, Kualitatif, dan R&D)*. Bandung: Alfabeta.
- Suryabrata, S. (2001). *Psikologi Kepribadian*. Jakarta: Raja Grafindo Pustaka.
- Suwardika, G. (2016). Pengelompokan dan Klasifikasi Penggunaan Kontrasepsi di Indonesia. *Jurnal matematika, Sains, dan Teknologi*.
- Turban, E., Aronson, J. E., & Liang, T.-P. (2007). *Decision Support Systems and Intelligent Systems* (7th Edition ed.). New Delhi: Prentice-Hall.
- UII. (2017). *Sekilas UII*. Dipetik Maret 02, 2018, dari <https://www.uii.ac.id/sekilas-uui/>.
- Vapnik, V., Golowich, S. E., & Smola, A. (1997). Support Vector Method for Function Approximation, Regression Estimation and Signal Processing. *Advances in Neural Information Processing Systems* 9.

LAMPIRAN

Lampiran 1 Data Alumni UII Tahun 2015 yang melanjutkan studi

Ipk	Fakultas	Jenkel	Lulus ontime	Jenis studi	Alasan studi	Biaya	Univ. pilihan	Bidang studi	Prediksi bidang studi
3.58	8	2	2	1	5	1	5	1	1
3.48	5	2	1	2	2	1	1	1	1
3.58	6	2	1	1	1	1	1	1	1
3.36	8	2	2	1	2	1	1	1	1
3.39	8	1	1	1	2	1	2	1	1
3.82	8	2	1	1	1	5	5	1	1
3.3	1	1	2	1	1	1	1	1	1
3.42	6	1	2	1	1	1	1	2	2
3.49	8	1	2	1	1	1	1	1	1
2.53	4	2	2	2	2	2	2	1	1
3.45	1	1	1	1	1	1	2	2	1
3.26	1	1	1	3	4	1	5	1	1
3.24	1	1	1	2	1	1	2	1	1
3.33	8	1	1	2	3	1	5	2	2
3.21	5	2	1	2	1	1	1	1	1
3.73	1	1	1	1	1	2	2	1	1
2.6	4	2	2	2	1	1	2	1	1
3.44	5	1	1	1	1	1	4	1	1
2.5	4	2	2	2	1	1	1	1	1
3.56	3	1	2	1	1	1	5	1	1
3.43	8	1	1	1	1	1	2	1	1
3.14	5	2	1	2	1	1	1	1	1
3.26	5	2	1	2	1	1	1	1	1
3.63	5	2	1	2	1	1	1	1	1
3.76	8	1	2	1	1	1	2	1	1
3.72	8	1	1	2	1	1	5	2	2
3.56	6	2	1	1	1	1	1	1	1
3.75	5	2	1	2	1	1	1	1	1
3.66	5	2	1	1	1	5	5	1	1
3.64	5	1	1	1	1	1	2	1	1
3.55	5	2	1	2	1	1	1	1	1
3.65	8	1	1	1	1	1	1	1	1

Ipk	Fakultas	Jenkel	Lulus ontime	Jenis studi	Alasan studi	Biaya	Univ. pilihan	Bidang studi	Prediksi bidang studi
3.16	5	1	1	2	1	1	1	1	1
3.45	6	2	1	1	1	1	1	1	1
3.56	5	2	1	1	1	1	4	1	1
3.45	8	2	1	1	1	1	5	1	1
3.5	5	2	1	2	1	1	1	1	1
3.55	5	2	1	1	1	1	2	1	1
3.38	5	1	1	1	1	1	2	1	1
3.26	5	2	1	2	1	1	1	1	1
3.29	8	2	1	1	1	1	2	1	1
3.35	2	2	2	1	1	1	5	1	1
3.52	2	2	1	1	2	1	2	1	1
3.06	4	1	1	2	1	1	1	1	1
3.7	2	1	1	1	1	1	1	1	1
3	7	2	2	1	1	1	1	1	1
2.67	4	2	2	2	1	1	1	1	1
2.99	4	1	2	2	5	1	1	1	1
3.12	1	1	2	3	1	1	5	1	1
2.94	7	1	2	1	1	1	2	1	1
3.12	7	2	2	1	1	1	2	1	1
3.74	3	2	1	1	4	1	1	2	2
3.26	8	2	2	1	1	1	1	1	1
3.65	8	2	2	1	2	1	2	1	1
3.56	8	2	1	1	1	1	2	1	1
3.53	5	2	1	2	1	1	1	1	1
3.51	5	2	1	2	1	1	1	1	1
3.18	5	2	1	2	2	1	1	1	1
3.57	7	1	1	1	1	1	2	1	1
3.54	5	2	1	2	2	1	1	1	1
3.61	5	2	1	2	1	1	1	1	1
3.71	5	2	1	2	1	1	1	1	1
3.67	2	1	2	1	1	1	1	1	1
3.61	1	2	1	1	1	1	2	1	1
3.53	5	1	1	1	1	4	2	1	1
3.74	6	2	1	2	1	1	1	1	1
3.56	1	2	1	3	1	1	1	1	1
3.36	2	1	1	1	1	1	1	1	1
2.89	2	2	2	1	2	1	1	1	1
3	2	1	2	1	1	1	5	1	1
3.06	6	1	1	1	1	1	3	1	1

Ipk	Fakultas	Jenkel	Lulus ontime	Jenis studi	Alasan studi	Biaya	Univ. pilihan	Bidang studi	Prediksi bidang studi
3.84	2	2	1	1	1	1	2	1	1
3.6	2	1	1	1	1	1	2	1	1
3.4	8	1	1	1	2	1	2	1	1
2.92	2	1	2	1	1	1	1	1	1
3.24	6	2	1	2	1	1	3	1	1
3.39	6	2	1	2	1	1	3	1	1
3.42	6	2	1	1	1	1	2	2	2
3.53	2	1	1	1	1	1	1	1	1
3.46	2	2	1	1	1	1	2	1	1
3.44	6	2	1	2	1	1	5	1	1
3.61	2	1	1	1	1	1	1	1	1
3.7	6	2	1	2	1	1	2	1	1
3.77	2	2	1	1	1	1	1	1	1
3.55	6	2	1	2	1	1	1	1	1
3.65	6	2	1	1	1	1	1	1	1
3.66	5	2	1	1	1	1	5	1	1
3.19	4	1	1	2	1	1	1	1	1
3.32	4	1	1	2	1	1	1	1	1
2.72	4	2	1	2	2	1	1	1	1
2.81	4	2	1	2	1	1	1	1	1
3.45	1	1	1	3	2	1	1	2	1
3.25	1	2	1	3	1	1	1	1	1
3.55	1	2	1	3	1	1	1	1	1
3.2	1	1	1	1	1	1	1	1	1
2.68	4	2	1	2	1	1	1	1	1
3.15	2	1	1	1	1	1	1	1	1
3.8	6	2	1	1	1	1	1	1	1
3.07	4	1	1	2	1	1	1	1	1
3.75	4	2	1	2	1	1	1	1	1
3.83	4	2	1	2	1	1	1	1	1
2.81	4	2	1	2	1	1	1	1	1
3.58	7	1	1	2	1	1	1	1	1
3.82	2	2	1	1	1	1	1	1	1
3.73	8	1	1	1	1	2	2	1	1
3.87	2	2	1	1	1	1	1	1	1
3.64	1	2	1	1	1	1	2	1	1
3.67	1	2	1	1	1	1	2	2	1
2.75	4	2	1	2	1	1	1	1	1
2.62	4	2	1	2	1	1	1	1	1

Ipk	Fakultas	Jenkel	Lulus ontime	Jenis studi	Alasan studi	Biaya	Univ. pilihan	Bidang studi	Prediksi bidang studi
3.63	1	2	1	1	1	1	5	1	1
3.33	4	2	1	2	1	1	1	1	1
3.06	4	2	2	2	1	1	5	1	1
3.26	4	2	1	2	1	1	1	1	1
2.74	4	1	1	2	1	1	1	1	1
2.86	4	1	1	2	2	3	5	1	1
3.27	4	2	1	2	1	1	1	1	1
3.8	7	2	1	2	1	1	1	1	1
3.46	4	2	1	2	1	1	1	1	1
3.74	6	2	2	1	1	1	1	1	1
3.42	4	2	1	2	1	1	1	1	1
2.9	4	1	1	2	1	1	1	1	1
2.59	4	2	1	1	1	1	5	1	1
3.46	4	1	1	2	1	1	1	1	1
3.03	4	1	1	2	1	1	1	1	1
3.76	7	1	1	1	1	1	1	1	1
3.68	1	2	1	1	1	1	1	1	1
3.02	7	1	2	1	1	1	1	1	1
3.09	2	2	1	1	5	1	2	1	1
3.71	4	2	1	1	5	1	5	1	1
3.14	2	1	1	1	4	1	2	1	1
2.74	4	2	1	2	1	1	5	1	1
3.43	8	2	1	1	2	1	2	1	1
3.06	4	2	1	2	1	1	5	1	1
3.61	4	2	1	2	1	1	1	1	1
3.76	4	1	1	2	1	1	1	1	1
2.55	4	2	1	2	1	2	5	1	1
3.83	4	1	1	2	2	1	1	1	1
2.98	1	2	2	1	2	1	1	1	1
3.03	4	2	1	2	1	1	1	1	1
3.25	4	1	1	2	1	1	1	1	1
3.54	4	2	1	2	1	1	1	1	1
3.08	4	1	2	2	1	1	2	1	1
3.81	4	2	1	2	5	1	1	1	1
3.83	4	2	1	2	1	1	1	1	1
3.39	4	2	1	2	1	1	2	1	1
3.58	4	1	1	2	1	1	1	1	1
3.52	1	2	1	1	1	1	1	1	1
3.11	4	2	1	2	1	1	1	1	1

Ipk	Fakultas	Jenkel	Lulus ontime	Jenis studi	Alasan studi	Biaya	Univ. pilihan	Bidang studi	Prediksi bidang studi
3.86	2	2	1	1	1	1	5	1	1
3.65	8	1	1	1	1	1	2	1	1
3.48	3	1	1	1	4	1	5	1	1
3.24	1	1	1	1	1	1	1	1	1
3.41	1	2	1	1	4	1	5	1	1
3.14	2	2	1	1	1	1	5	1	1
3.63	1	2	1	1	2	1	2	1	1
3.3	1	1	1	1	1	1	2	1	1
3.32	1	2	1	1	1	1	1	1	1
3.6	1	2	1	1	1	1	2	1	1
3.87	5	2	1	1	1	1	5	1	1
3.03	1	2	1	3	2	1	5	1	1
3.83	1	2	1	1	4	5	2	1	1
3.75	2	1	1	1	1	1	1	1	1
3.67	2	1	2	1	1	1	5	2	2
3.53	5	2	1	1	1	5	3	1	1
3.68	5	1	1	1	1	1	1	1	1
2.76	8	2	2	2	2	1	1	2	2
3.53	4	2	1	1	1	1	2	1	1
2.72	2	2	1	1	1	1	1	1	1
3.19	5	1	2	1	2	1	1	1	1
3.79	8	2	1	3	1	1	2	1	1
3.36	8	1	2	1	1	1	2	2	2
2.96	2	1	2	1	1	1	1	1	1
3.25	4	1	2	1	1	1	1	1	1
2.74	5	2	1	2	1	1	1	1	1
3.47	4	2	2	2	1	1	2	1	1
2.77	6	2	1	2	1	1	1	2	1
3.43	6	2	1	1	1	1	5	1	1
3.37	6	1	1	1	2	1	5	2	2
2.83	5	1	2	1	1	1	1	1	1
2.7	4	2	2	2	1	1	5	1	1
2.58	4	2	1	2	1	1	1	1	1
3.67	3	2	1	2	1	1	5	1	1
3.76	4	1	1	1	1	1	1	1	1
3	4	1	2	2	1	1	1	1	1
3.78	8	1	1	2	1	1	2	1	1
3.75	5	1	1	1	2	1	1	1	1
2.73	4	2	2	2	1	1	1	1	1

Ipk	Fakultas	Jenkel	Lulus ontime	Jenis studi	Alasan studi	Biaya	Univ. pilihan	Bidang studi	Prediksi bidang studi
2.83	4	1	1	2	1	1	5	1	1
3.06	6	2	1	2	1	1	5	2	1
3.23	1	2	1	1	2	1	5	1	1
3.52	1	2	1	1	4	1	2	1	1
3.53	8	2	1	1	5	1	5	1	1
3.49	6	1	1	1	2	1	2	1	2
3.75	3	1	2	1	1	1	1	1	1
3.72	6	2	1	1	1	1	1	1	1
3.57	1	2	1	1	1	1	5	1	1
2.99	5	1	2	3	1	1	1	1	1
2.9	6	2	2	2	1	1	5	1	1
3.48	5	2	2	1	2	1	2	1	1
3.52	1	2	1	1	1	1	1	1	1
3.4	5	1	1	3	1	1	1	1	1
3.21	5	2	2	2	4	1	1	1	1
3.31	5	2	2	2	2	1	1	1	1
2.76	5	2	2	2	1	1	2	1	1
3.27	5	2	2	1	1	1	1	1	1
3.5	6	2	2	2	2	1	1	2	2
3.54	2	2	1	1	4	1	1	1	1
3.44	2	1	1	2	2	1	1	1	1
3	1	1	2	1	1	1	2	1	1
3.58	8	2	1	1	3	1	5	1	1
3.69	6	2	1	1	1	4	1	1	1
3.16	1	1	1	2	1	1	2	1	1
3.4	1	1	1	1	2	1	5	1	1
3.54	1	2	1	1	1	1	2	1	1
3.73	2	1	1	1	1	1	1	1	1
3.64	1	1	1	1	1	1	2	1	1
3.62	8	1	1	1	4	1	1	1	1
3.28	7	1	2	1	1	1	2	1	1
3.18	3	1	1	1	3	2	1	1	1
3.68	8	1	1	1	1	1	1	1	1
3.45	5	1	2	1	1	1	2	1	1
3.85	7	2	1	1	1	1	2	1	1
3.36	5	1	1	1	1	1	2	1	1
3.56	1	2	1	1	5	1	5	1	1
3.67	5	2	1	1	1	1	1	1	1
3.38	5	2	1	2	1	1	3	1	1

Ipk	Fakultas	Jenkel	Lulus ontime	Jenis studi	Alasan studi	Biaya	Univ. pilihan	Bidang studi	Prediksi bidang studi
3.51	1	1	1	1	1	1	2	1	1
3.46	2	1	1	1	2	1	2	1	1
3.71	2	2	1	1	1	1	2	1	1
3.68	2	2	1	1	1	1	5	2	1
3.47	2	2	1	1	1	1	1	1	1
3.87	2	1	1	1	1	1	1	1	1
3.77	7	1	1	1	1	1	1	1	1
3.59	2	1	1	2	1	1	5	1	1
3.06	6	1	1	1	1	1	5	1	1
3.32	5	2	1	2	1	1	1	1	1
3.65	5	2	1	2	1	1	4	1	1
3.63	2	2	1	1	1	1	5	1	1
3.54	8	2	1	1	1	1	5	1	1
3.55	5	1	1	1	1	1	4	1	1
3.89	5	2	1	1	1	1	4	1	1
3.9	2	2	1	1	5	2	1	1	1
3.22	8	1	1	1	1	1	2	1	1
3.08	8	1	1	1	1	1	2	1	1
3.92	2	2	1	1	1	1	1	1	1
3.83	2	1	1	1	1	1	2	1	1
3.8	5	2	1	1	1	1	2	1	1
3.29	2	2	2	1	1	1	5	1	1
3.39	1	1	1	1	1	1	2	1	1
3.35	2	2	1	1	1	1	1	1	1
3.33	2	2	1	1	1	1	2	1	1
3.41	2	1	1	2	1	1	1	1	1
3.31	1	2	1	1	1	1	2	1	1
3.68	1	2	1	1	1	1	5	1	1
3.13	3	2	1	3	1	1	1	1	1
3.35	1	1	1	1	1	1	1	1	1
3.54	2	1	1	1	2	1	2	1	1
3.01	1	1	2	1	1	1	1	1	1
3.34	2	1	1	1	1	1	2	1	1
3.5	3	2	1	1	2	1	5	1	1
3.55	3	1	1	1	1	1	1	2	1
3.58	1	1	1	1	2	1	1	2	1
3.67	7	2	1	1	1	1	5	2	2
3.57	7	1	2	1	3	1	2	1	1
3.26	1	2	2	1	1	1	2	1	1

Ipk	Fakultas	Jenkel	Lulus ontime	Jenis studi	Alasan studi	Biaya	Univ. pilihan	Bidang studi	Prediksi bidang studi
3.89	6	2	1	1	1	1	5	1	1
3.2	1	2	1	2	1	1	2	1	1
3.86	6	2	1	1	1	1	1	1	1
3.32	1	2	1	1	1	1	2	2	1
3.24	1	1	1	1	5	1	5	1	1
3.38	1	2	1	1	1	1	2	1	1
3.69	1	2	1	1	1	1	2	1	1
3.66	1	2	1	1	1	1	2	1	1
3.71	1	2	1	1	1	1	2	1	1
3.39	1	2	1	1	1	1	2	1	1
3.3	5	1	1	1	1	1	2	1	1
3.42	4	1	1	1	1	1	1	1	1
2.43	7	1	2	2	1	1	5	2	2
3.48	1	2	1	1	1	1	1	1	1
3.21	2	1	1	3	4	1	2	1	1
3.08	2	1	2	1	2	1	2	1	1
2.58	5	1	2	1	1	1	1	1	1
3.36	2	2	1	2	3	1	1	1	1
3.22	5	1	2	1	1	1	1	1	1
3.29	5	2	1	2	1	1	1	1	1
3.04	5	1	1	2	1	1	2	1	1
3.74	5	2	1	1	1	1	1	1	1
3.41	5	2	1	2	2	1	2	1	1
3.12	1	2	1	1	1	1	5	1	1
3.24	5	2	1	3	1	1	2	1	1
3.41	7	2	1	1	1	1	2	1	1
3.24	1	2	1	1	2	1	2	1	1
3.54	3	1	1	1	1	1	5	1	1
3.54	5	1	1	1	2	1	2	1	1
3.62	5	2	1	1	1	1	5	1	1
3.34	5	2	2	2	1	1	1	1	1
3.63	2	2	1	2	1	1	2	1	1
3.15	5	1	2	1	1	1	3	1	1
3.31	6	2	1	1	3	1	2	1	1
3.32	8	2	1	2	1	1	1	1	1
3.65	5	2	2	1	1	1	2	1	1
3.04	6	2	1	1	1	1	5	1	1
3.12	8	2	1	2	1	1	2	1	1
3.29	7	1	1	1	1	1	1	1	1

Ipk	Fakultas	Jenkel	Lulus ontime	Jenis studi	Alasan studi	Biaya	Univ. pilihan	Bidang studi	Prediksi bidang studi
3.41	8	1	1	1	1	1	2	1	1
3.69	1	2	1	3	1	1	1	1	1
3.81	8	2	1	1	1	1	2	1	1
3.16	5	1	2	2	1	1	1	1	1
3.13	5	2	2	2	1	1	5	1	1
3.25	5	2	1	1	2	1	2	2	1
3.5	5	1	1	1	1	1	4	1	1
3.77	1	2	1	3	1	1	1	1	1
3.87	1	2	1	3	1	1	1	1	1
3.33	5	2	1	1	1	1	5	1	1
3.79	8	2	1	1	1	1	5	1	1
3.67	6	2	1	2	1	1	2	1	1
3.01	5	1	2	2	1	1	1	1	1
3.53	5	2	1	1	1	1	2	1	1
3.51	2	2	1	1	3	1	2	1	1
3.32	7	2	2	1	2	1	1	1	1
3.68	6	2	1	2	1	1	5	1	1
3.27	8	1	1	1	1	1	2	1	1
2.97	4	2	1	2	1	1	1	1	1
3.87	6	2	1	1	1	1	2	1	1
3.36	8	2	2	1	3	1	2	1	1
3.43	1	2	1	3	4	1	5	1	1
3.25	1	1	2	2	1	1	2	1	1
3.31	1	1	1	3	2	1	1	1	1
3.45	6	2	1	2	1	1	2	1	1
3.54	6	2	1	2	1	1	1	1	1
3.81	4	2	1	2	1	1	1	1	1
3.74	4	2	1	2	1	1	1	1	1
3.52	6	1	1	1	5	2	2	1	1
3.01	5	2	1	2	1	1	1	1	1
3.32	6	2	1	2	1	1	2	1	1
3.47	6	2	1	1	1	1	1	1	1
2.98	5	2	1	1	1	1	2	1	1
3.88	7	2	1	2	1	1	1	1	1
3.32	5	1	1	1	1	1	2	1	1
3.63	6	2	1	2	1	1	1	1	1
2.95	5	2	1	2	1	1	1	1	1
3.69	7	2	1	2	2	1	1	1	1
3.56	5	2	1	1	1	1	2	1	1

Ipk	Fakultas	Jenkel	Lulus ontime	Jenis studi	Alasan studi	Biaya	Univ. pilihan	Bidang studi	Prediksi bidang studi
3.48	1	1	2	1	1	1	2	1	1
3.21	5	2	1	2	2	1	1	1	1
3.62	7	2	1	1	1	1	2	1	1
3.3	4	1	1	2	2	1	1	1	1
3.42	7	2	1	1	2	1	1	1	1
3.58	6	2	1	2	1	1	2	1	1
3.63	5	1	1	3	2	1	1	1	1
3.2	8	1	1	1	1	1	5	1	1
3.4	7	1	1	1	2	1	2	1	1
3.51	7	2	1	1	1	1	2	1	1
3.7	1	2	1	2	4	1	2	1	1
3.13	7	1	2	1	3	1	1	1	1
3.35	6	2	1	2	1	1	5	1	1
2.97	4	2	2	2	1	1	1	1	1
3.19	6	2	1	2	1	1	1	1	1
3.27	2	1	2	1	1	1	1	1	1
3.65	6	2	1	2	1	1	2	1	1
3.16	6	2	1	2	1	1	1	1	1
3.23	6	2	1	1	1	1	1	1	1
3.57	6	2	1	1	1	1	1	1	1
3.6	1	1	1	1	1	1	2	2	1
3.68	2	1	1	1	5	1	2	1	1
3.83	2	2	1	1	1	1	2	1	1
3.19	8	1	2	1	2	1	5	1	1
3.62	2	2	1	1	5	1	2	1	1
3.06	6	1	1	1	1	1	2	2	2
3.79	7	2	1	1	2	1	2	1	1
3.67	7	2	1	2	1	1	1	1	1
3.31	7	1	1	1	1	1	2	1	1
3.78	5	2	1	3	1	1	1	1	1
3.28	1	2	1	3	1	1	1	1	1
3.46	5	2	1	3	1	1	5	1	1
3.55	2	2	1	1	1	1	1	1	1
3.95	8	2	1	1	1	1	2	1	1
3.76	7	2	1	1	1	1	1	1	1
3.76	2	1	1	1	1	1	1	1	1
3.19	6	2	1	1	1	1	1	1	1
3.34	8	1	2	1	3	1	2	1	1
3.95	8	2	1	1	1	2	5	1	1

Ipk	Fakultas	Jenkel	Lulus ontime	Jenis studi	Alasan studi	Biaya	Univ. pilihan	Bidang studi	Prediksi bidang studi
3.96	1	2	1	1	1	1	2	1	1
3.2	6	1	1	1	1	1	5	1	1
3.33	6	2	1	1	1	1	5	1	1
3.4	6	2	1	1	1	1	1	1	1
3.75	1	2	1	1	1	1	2	1	1
3.51	6	2	2	2	1	1	2	1	1
3.61	6	2	1	2	1	1	5	1	1
3.89	1	2	1	1	1	1	2	1	1
3.44	7	1	1	1	1	1	2	1	1
3.89	1	2	1	1	3	1	2	1	1
3.62	6	2	1	2	1	1	1	1	1
3.89	1	2	1	1	2	1	2	1	1
3.07	7	2	2	1	1	1	1	1	1
3.47	8	2	1	1	1	1	2	1	1
3.89	7	2	1	2	1	1	1	1	1
3.77	4	1	1	2	5	1	1	1	1
3.56	1	2	1	1	1	1	5	1	1
3.64	1	1	1	1	1	1	2	1	1
3.78	6	2	2	1	1	1	2	2	2

Lampiran 2 Script Uji Independensi *Chi Square* di R

```
library(MASS)
alumnidata=read.delim("clipboard")
View(alumnidata)

tabel.1=table(alumnidata$fakultas,alumnidata$bidang_studi)
tabel.1
chisq.test(tabel.1)

tabel.2=table(alumnidata$jenkel,alumnidata$bidang_studi)
tabel.2
chisq.test(tabel.2)

tabel.3=table(alumnidata$lulus_ontime,alumnidata$bidang_studi)
tabel.3
chisq.test(tabel.3)

tabel.4=table(alumnidata$jenis_studi,alumnidata$bidang_studi)
tabel.4
chisq.test(tabel.4)

tabel.5=table(alumnidata$alasan_studi,alumnidata$bidang_studi)
tabel.5
chisq.test(tabel.5)

tabel.6=table(alumnidata$biaya,alumnidata$bidang_studi)
tabel.6
chisq.test(tabel.6)

tabel.7=table(alumnidata$kuliah_lanjut,alumnidata$bidang_studi)
tabel.7
chisq.test(tabel.7)

tabel.8=table(alumnidata$ipk,alumnidata$bidang_studi)
tabel.8
chisq.test(tabel.8)
```

Lampiran 3 Script R SVM Linear Kernel

```
library(e1071)

#load data
alumnidata=read.delim("clipboard")
View(alumnidata)

alumnidata$bidang_studi=factor(alumnidata$bidang_studi,levels=c(1,
2),labels=c("Sesuai","Tidak Sesuai"))

alumnidata$lulus_ontime=factor(alumnidata$lulus_ontime,levels=c(1,
2),labels=c("Ya","Tidak"))

alumnidata$jenis_studi=factor(alumnidata$jenis_studi,levels=c(1,2,
3),labels=c("Pascasarjana","Pendidikan Profesi","Transfer S1"))

alumnidata$alasan_studi=factor(alumnidata$alasan_studi,levels=c(1,
2,3,4,5),labels=c("Meningkatkan kompetensi","Meningkatkan peluang
kerja","Belum memperoleh kerja","Saran orangtua","lainnya"))

alumnidata$biaya=factor(alumnidata$biaya,levels=c(1,2,3,4,5),label
s=c("biaya sendiri/orangtua","Beasiswa pemerintah","Beasiswa
perusahaan","Beasiswa pemerintah asing","lainnya"))

alumnidata$fakultas=factor(alumnidata$fakultas,levels=c(1,2,3,4,5,
6,7,8),labels=c("FE","FH","FIAI","FK","FMIPA","FPSB","FTSP","FTI")
)

alumnidata$jenkel=factor(alumnidata$jenkel,levels=c(1,2),labels=c(
"laki-laki","perempuan"))

alumnidata$kuliah_lanjut=factor(alumnidata$kuliah_lanjut,levels=c(
1,2,3,4,5),labels=c("UII","UGM","ITS","STIE YKPN","Lainnya"))

str(alumnidata)

#deskriptif data
summary(alumnidata)

#partisi data 80% training, 20% testing
sampelsize=round(0.8*nrow(alumnidata))
View(sampelsize)
set.seed(12345)
indx = sample(seq_len(nrow(alumnidata)), size=sampelsize)
training = alumnidata[indx,]
View(training)
B=nrow(training)
testing=alumnidata[-indx,]
```

```
#####LINEAR KERNEL#####
#mencari best parameter
set.seed(1000)
obj = tune.svm(bidang_studi ~ ., data = training, kernel='linear',
cost=c(0.001,0.01,0.1,1,10,100), tunecontrol=tune.control(sampling=
"cross"))

print(obj)

#membangun model dengan parameter terbaik
lin.svm=svm(bidang_studi~., data=training, kernel='linear', cost=0.00
1, type="C-classification")

summary(lin.svm)
##data training
#confusion matrix
x = training
prediksi <- predict(lin.svm,x)
aktual=x$bidang
tabel <- table(prediksi,aktual)
tabel

#akurasi
mis_error=mean(aktual!=pred2)
mis_error
acc= 1- mis_error
acc

##data testing
#confusion matrix
y=testing
prediksi <- predict(lin.svm,y)
aktual=y$bidang
tabel <- table(prediksi,aktual)
tabel

#akurasi
mis_error=mean(aktual!=pred2)
mis_error
acc= 1- mis_error
acc
```

Lampiran 4 Script R SVM RBF Kernel

```
#####RBF KERNEL#####

#mem cari best parameter
set.seed(1000)
obj <- tune.svm(bidang_studi ~ ., data = training, kernel='radial',
cost = c(1, 10, 50, 100), gamma = c(1, 2, 3, 4, 5) , tunecontrol =
tune.control(sampling="cross"))

print(obj)

#membangun model dengan parameter terbaik

mod.rad<- svm(bidang_studi ~ ., data = training, kernel='radial',
cost =5, gamma=1)
mod.rad
summary(mod.rad)

##data training
#confusion matrix
x <- training
prediksi <- predict(mod.rad,x)
aktual=x$bidang
tabel <- table(prediksi,aktual)
tabel

#akurasi
mis_error=mean(aktual!=pred2)
mis_error
acc= 1- mis_error
acc

##data testing
#confusion matrix
y=testing
prediksi <- predict(mod.rad,y)
aktual=y$bidang
tabel <- table(prediksi,aktual)
tabel

#akurasi
mis_error=mean(aktual!=pred2)
mis_error
acc= 1- mis_error
acc
```

Lampiran 5 Script R SVM Polinomial Kernel

```
#####POLINOMIAL KERNEL#####

#mencari best parameter
set.seed(1000) #to obtain the same results for each session
obj=tune.svm(bidang_studi~., data = training, kernel='polynomial',
cost=c(100,200,300,400,500), d=c(1,2), tunecontrol=tune.control(samp
ling="cross"))

print(obj)

#membangun model dengan best parameter
mod.pol=svm(bidang_studi~., data=training, kernel='polynomial', degre
e=2, cost=300)

summary(mod.pol)

##data training
#confusion matrix
x <- training
prediksi <- predict(mod.pol,x)
aktual=x$bidang
tabel <- table(prediksi,aktual)
tabel

#akurasi
mis_error=mean(aktual!=pred2)
mis_error
acc= 1- mis_error
acc

##data testing
#confusion matrix
y=testing
prediksi <- predict(mod.pol,y)
aktual=y$bidang
tabel <- table(prediksi,aktual)
tabel

#akurasi
mis_error=mean(aktual!=pred2)
mis_error
acc= 1- mis_error
acc
```

Lampiran 6 Output Uji Independensi *Chi Square* dengan R

```
> tabel.1

      1  2
1 77  6
2 54  2
3  9  2
4 64  0
5 76  1
6 51  8
7 37  2
8 46  6
> chisq.test(tabel.1)

Pearson's Chi-squared test

data:  tabel.1
X-squared = 19.284, df = 7, p-value = 0.007344

> tabel.2

      1  2
1 150 14
2 264 13
> chisq.test(tabel.2)

Pearson's Chi-squared test with Yates' continuity correction

data:  tabel.2
X-squared = 2.021, df = 1, p-value = 0.1551

> tabel.3

      1  2
1 340 19
2  74  8
> chisq.test(tabel.3)

Pearson's Chi-squared test with Yates' continuity correction

data:  tabel.3
X-squared = 1.6025, df = 1, p-value = 0.2055
> tabel.4

      1  2
1 256 19
2 136  7
3  22  1
> chisq.test(tabel.4)

Pearson's Chi-squared test

data:  tabel.4
X-squared = 0.79688, df = 2, p-value = 0.6714
```

```
> tabel.5
```

	1	2
1	329	19
2	47	6
3	12	1
4	13	1
5	13	0

```
> chisq.test(tabel.5)
```

Pearson's Chi-squared test

data: tabel.5

X-squared = 3.6866, df = 4, p-value = 0.4501

```
> tabel.6
```

	1	2
1	396	27
2	8	0
3	1	0
4	4	0
5	5	0

```
> chisq.test(tabel.6)
```

Pearson's Chi-squared test

data: tabel.6

X-squared = 1.2239, df = 4, p-value = 0.8742

```
> tabel.7
```

	1	2
1	196	8
2	136	10
3	7	0
4	6	0
5	69	9

```
> chisq.test(tabel.7)
```

Pearson's Chi-squared test

data: tabel.7

X-squared = 6.682, df = 4, p-value = 0.1537

```
> tabel.8
```

```
      1 2  
2.43 0 1  
2.5   1 0  
2.53 1 0  
2.55 1 0  
2.58 2 0  
2.59 1 0  
2.6   1 0  
2.62 1 0  
2.64 1 0  
2.67 1 0  
2.68 1 0  
2.7   1 0  
2.72 2 0
```

```
> chisq.test(tabel.8)
```

```
      Pearson's Chi-squared test
```

```
data:  tabel.8
```

```
X-squared = 141.42, df = 120, p-value = 0.08843
```

Lampiran 7 Output SVM dengan R

####LINEAR KERNEL####

```
Call:
svm(formula = bidang_studi ~ ., data = training, kernel = "linear",
     cost = 10, type = "C-classification")
```

```
Parameters:
  SVM-Type:  C-classification
  SVM-Kernel: linear
      cost:  10
   gamma:  0.04
```

```
Number of Support Vectors:  115
```

```
( 22 93 )
```

```
Number of Classes:  2
```

```
Levels:
  Sesuai Tidak Sesuai
```

```
> x <- training
> pred2 <- predict(lin.svm,x)
> aktual=x$bidang
> cm2 <- table(pred2,aktual)
> cm2
```

	aktual	
pred2	Sesuai	Tidak Sesuai
Sesuai	331	21
Tidak Sesuai	0	1

```
>
> mis_error=mean(aktual!=pred2)
> mis_error
[1] 0.05949008
> acc= 1- mis_error
> acc
[1] 0.9405099
```

```

> #confusion matrix data testing
> y=testing
> prediksi <- predict(lin.svm,y)
> aktual=y$bidang
> tabel <- table(prediksi,aktual)
> tabel

```

	aktual	
prediksi	Sesuai	Tidak Sesuai
Sesuai	83	5
Tidak Sesuai	0	0

```

>
> #akurasi
> mis_error=mean(aktual!=prediksi)
> mis_error
[1] 0.05681818
> acc= 1- mis_error
> acc
[1] 0.9431818

```

#####RBF KERNEL#####

```

> summary(mod.rad)

Call:
svm(formula = bidang_studi ~ ., data = training, kernel = "radial",
     cost = 1, gamma = 1)

Parameters:
  SVM-Type:  C-classification
 SVM-Kernel: radial
      cost:  1
    gamma:  1

Number of Support Vectors:  204

( 22 182 )

Number of Classes:  2

Levels:
  Sesuai Tidak Sesuai

```

```

> ##confusion matrix data training
> x <- training
> prediksi <- predict(mod.rad,x)
> aktual=x$bidang_studi
> tabel <- table(prediksi,aktual)
> tabel

```

	aktual	
prediksi	Sesuai	Tidak Sesuai
Sesuai	331	15
Tidak Sesuai	0	7

```

>
> #akurasi
> mis_error=mean(aktual!=prediksi)
> mis_error
[1] 0.04249292
> acc= 1- mis_error
> acc
[1] 0.9575071

> ##confusion matrix data testing
> y=testing
> prediksi <- predict(mod.rad,y)
> aktual=y$bidang
> tabel <- table(prediksi,aktual)
> tabel

```

	aktual	
prediksi	Sesuai	Tidak Sesuai
Sesuai	82	5
Tidak Sesuai	1	0

```

>
> mis_error=mean(aktual!=prediksi)
> mis_error
[1] 0.06818182
> acc= 1- mis_error
> acc
[1] 0.9318182

```

#####POLINOMIAL KERNEL#####

```
> summary(mod.pol)
```

Call:

```
svm(formula = bidang_studi ~ ., data = training, kernel = "polynomial",
     degree = 2, cost = 500)
```

Parameters:

```
  SVM-Type:  C-classification
  SVM-Kernel: polynomial
        cost: 500
    degree: 2
      gamma: 0.04
    coef.0: 0
```

Number of Support Vectors: 81

```
( 22 59 )
```

Number of Classes: 2

Levels:

```
Sesuai Tidak Sesuai
```

```
> #confusion matrix data training
> x <- training
> pred2 <- predict(mod.pol,x)
> aktual=x$bidang_studi
> cm2 <- table(pred2,aktual)
> cm2
```

	aktual	
pred2	Sesuai	Tidak Sesuai
Sesuai	330	9
Tidak Sesuai	1	13

```
>
```

```
> #akurasi
```

```
> mis_error=mean(aktual!=pred2)
```

```
> mis_error
```

```
[1] 0.02832861
```

```
> acc= 1- mis_error
```

```
> acc
```

```
[1] 0.9716714
```

```
> #confusion matrix data testing
> y=testing
> pred2 <- predict(mod.pol,y)
> aktual=y$bidang
> cm2 <- table(pred2,aktual)
> cm2
```

	aktual	
pred2	Sesuai	Tidak Sesuai
Sesuai	83	4
Tidak Sesuai	0	1

```
>
> #akurasi
> mis_error=mean(aktual!=pred2)
> mis_error
[1] 0.04545455
> acc= 1- mis_error
> acc
[1] 0.9545455
```