

**Optimasi Parameter pada Support Vector Machine
berbasis Algoritma Genetika untuk Estimasi
Kebakaran Hutan**



TESIS

Diajukan sebagai salah satu syarat untuk memperoleh gelar Magister
Ilmu Komputer (M.Kom)

HANI HARAFANI

14000648

PROGRAM PASCASARJANA MAGISTER ILMU KOMPUTER
SEKOLAH TINGGI MANAJEMEN INFORMATIKA DAN
KOMPUTER NUSA MANDIRI
JAKARTA
2015

**Optimasi Parameter pada Support Vector Machine
berbasis Algoritma Genetika untuk Estimasi
Kebakaran Hutan**



TESIS

Diajukan sebagai salah satu syarat untuk memperoleh gelar Magister
Ilmu Komputer (M.Kom)

HANI HARAFANI

14000648

PROGRAM PASCASARJANA MAGISTER ILMU KOMPUTER
SEKOLAH TINGGI MANAJEMEN INFORMATIKA DAN
KOMPUTER NUSA MANDIRI
JAKARTA
2015

SURAT PERNYATAAN ORISINALITAS

Yang bertanda tangan di bawah ini:

Nama : Hani Harafani
Nim : 14000648
Program Studi : Magister Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : *Management Information System*

Dengan ini menyatakan bahwa tesis yang telah saya buat dengan judul: “Optimasi Parameter pada Support Vector Machine berbasis Algoritma Genetika untuk Estimasi Kebakaran Hutan” adalah hasil karya sendiri, dan semua sumber baik yang kutip maupun yang dirujuk telah saya nyatakan dengan benar dan tesis belum pernah diterbitkan atau dipublikasikan dimanapun dan dalam bentuk apapun.

Demikianlah surat pernyataan ini saya buat dengan sebenar-benarnya. Apabila dikemudian hari ternyata saya memberikan keterangan palsu atau ada pihak lain yang mengklaim bahwa tesis yang telah saya buat adalah hasil karya milik seseorang atau badan tertentu, saya bersedia diproses baik secara pidana maupun perdata dan kelulusan saya dari Program Pascasarjana Magister Ilmu Komputer Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri dicabut/dibatalkan.

Jakarta, 10 Februari 2015

Yang menyatakan,

Hani Harafani

HALAMAN PENGESAHAN

Tesis ini diajukan oleh:

Nama : Hani Harafani
Nim : 14000648
Program Studi : Magister Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : *Management Information System*
Judul Tesis :“Optimasi Parameter pada Support Vector Machine berbasis Algoritma Genetika untuk Estimasi Kebakaran Hutan”

Telah berhasil dipertahankan dihadapan Dewan Penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar Magister Ilmu Komputer (M.Kom) pada Program Pascasarjana Magister Ilmu Komputer Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri (STMIK Nusa Mandiri).

Jakarta, 10 Maret 2015
Pascasarjana Magister Ilmu Komputer
STMIK Nusa Mandiri
Direktur

Prof.Dr.Ir. Kaman Nainggolan, MS

DEWAN PENGUJI

Penguji I: Dr. Sularso Budilaksono

Penguji II: Dr. Windu Gata, M.Kom

Penguji III/Pembimbing : Romi Satria Wahono, Ph.D:.....

	Lembar Konsultasi Bimbingan Tesis Pascasarjana Magister Ilmu Komputer STMIK Nusa Mandiri
---	---

NIM : 14000648

Nama Lengkap : Hani Harafani

Dosen Pembimbing : Romi Satria Wahono, Ph.D

Judul Tesis : Optimasi Parameter pada Support Vector Machine berbasis Algoritma Genetika untuk Estimasi Kebakaran Hutan

No	Tanggal Bimbingan	Materi Bimbingan	Paraf Dosen Pembimbing
1	12 November 2014	Pengajuan Judul	
2	15 November 2014	Revisi Judul dan Pengajuan Bab I	
3	5 Desember 2015	Revisi Bab I	
4	17 Desember 2014	Pengajuan Bab II	
5	23 Desember 2014	Revisi Bab II	
6	8 Januari 2015	Pengajuan Bab III	
7	26 Januari 2015	Revisi Bab III dan Pengajuan Bab IV	
8	2 Februari 2015	Revisi Bab IV dan Pengajuan Bab V	
9	14 Februari 2015	Revisi Bab V	
10	28 Februari 2015	ACC Keseluruhan	

Bimbingan dimulai pada tanggal : 12 November 2014

Bimbingan diakhiri pada tanggal : 28 Februari 2015

Jumlah pertemuan : 10 kali pertemuan

Jakarta, 10 Februari 2015

Dosen Pembimbing

(Romi Satria Wahono, Ph.D)

KATA PENGANTAR

Alhamdulillahirobbil'alamin penulis panjatkan puji syukur yang tiada terkira kepada Allah S.W.T yang telah melimpahkan rahmat dan kasih sayangnya sehingga penulis dapat menyelesaikan tesis ini dengan penuh hikmah. Tesis ini dirangkumkan sebagai bentuk laporan penelitian dengan judul “Optimasi Parameter pada Support Vector Machine berbasis Algoritma Genetika untuk Estimasi Kebakaran Hutan”. Adapun penulisan tesis ini bertujuan untuk memenuhi syarat kelulusan pada program Pasca Sarjana STMIK Nusa Mandiri. Penulis menyadari tesis ini tidak akan selesai tanpa bantuan dan dukungan dari dosen pembimbing dan semua pihak yang telah turut serta memberikan dukungan. Oleh karena itu pada kesempatan ini izinkanlah penulis mengucapkan terimakasih kepada:

1. Orang tua dan keluarga penulis yang telah turut membantu penulisan tesis ini dengan memberikan semangat serta doa yang terpanjatkan atas penulis.
2. Suamiku Denzi Junaidi atas dukungan, semangat, kasih sayang, doa, pengertian dan perhatian yang telah diberikan.
3. Bapak Romi Satria Wahono, Ph.D sebagai pembimbing yang selalu sabar menyokong, membimbing, dan memotivasi penulis serta memberikan sumbangsih ilmu dalam dunia penelitian.
4. Bapak Wahyudi, MM, M.Kom selaku direktur pascasarjana STMIK Nusa Mandiri.
5. Seluruh staff pengajar (Dosen) yang telah memberikan ilmu yang bermanfaat bagi penulis untuk menyelesaikan tesis ini.
6. Bina Sarana Informatika (BSI) yang telah memberikan peluang kepada penulis untuk melanjutkan kuliah S2 melalui program Beasiswa karyawan.
7. Teman-teman seperjuangan (Ispandi, Lila Dini Utami, Achmad Baroqah, Harsih Rianto, Poppy Ismayanti) yang saling menyemangati dalam pembuatan tesis ini.
8. Teman-teman penulis dari grup Inteligent System yang menyokong dari kejauhan dengan memberikan sumbangsih ilmu yang bermanfaat bagi penulis dalam penulisan tesis ini yaitu teman-teman seperjuangan lainnya

(Wida P, Sumanto, Rizky Tri Asmono, Tyas Setiyorini, Vinita Chandani, Adi Wijaya, dkk yang tidak bisa saya sebutkan satu per satu).

9. Sahabat-sahabat penulis tim konsorsium Teknik Komputer BSI dan teman-teman instruktur lab teknik BSI (Pak Anton, Idzharul H, Hari S, Dendy P, Ryan S, Andry M, Ahmad F, Hanggoro A, Eka D, Ade S, Firmansyah, Singgih A, Sari D, Syarif H, Ali I, Nurrohman, Rossa, Mega)yang selalu menyokong penulis dengan memberikan semangat berupa kebersamaan dan canda tawa yang menghiasi perjalan penulis dalam membuat tesis ini.

Serta semua pihak yang terlalu banyak untuk penulis sebutkan satu persatu. Penulis sangat menyadari bahwa penelitian ini sangat jauh dari kesempurnaan. Untuk itu penulis membutuhkan kritik dan saran yang membangun demi kesempurnaan karya ilmiah dimasa mendatang. Akhir kata penulis ucapkan semoga tesis ini dapat bermanfaat terutama bagi para pembaca pada umumnya. Wassalamu'alaikum Wr.Wb

Jakarta, 10 Februari 2015

Hani Harafani

Penulis

SURAT PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS

Yang bertanda tangan dibawah ini, saya:

Nama : Hani Harafani
NIM : 14000648
Program Studi : Magister Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : *Management Information System*
Jenis Karya : Tesis

Demi Pengembangan ilmu pengetahuan, dengan ini menyetujui untuk memberikan ijin kepada pihak Program Pascasarjana Magister Ilmu Komputer Sekolah Tinggi Manajemen Informatika dan Komputer Nusa Mandiri (STMIK Nusa Mandiri) **Hak Bebas Royalti Non-Ekslusif** (*Non- Excluive Royalti-Free Right*) atas karya ilmiah kami yang berjudul: “Penerapan Algoritma Genetika untuk Optimasi Parameter pada Support Vector Machine untuk Memprediksi Kebakaran Hutan”, beserta perangkat yang diperlukan (apabila ada). Dengan **Hak Bebas Royalti Non-Ekslusif** ini pihak STMIK Nusa Mandiri berhak menyimpan, mengalih-media atau *bentuk*-kan, mengelolakan dan pangkalan data (*database*), mendistribusikannya dan menampilkan atau mempublikasikannya di *internet* atau media lain untuk kepentingan akademis tanpa perlu memint ijin dari kamis selama tetap mencantumkan nama saya sebagai penulis/pencipta karya ilmiah tersebut. Saya bersedia untuk menanggung secara pribadi, tanpa melibatkan pihak STMIK Nusa Mandiri, segala bentuk tuntutan hukum yang timbul atas pelanggaran Hak Cipta dalam karya ilmiah saya ini. Demikian pernyataan ini saya buat dengan sebenarnya.

Jakarta, 10 Februari 2015

Yang Menyatakan,

Hani Harafani

ABSTRAK

Nama	:	Hani Harafani
NIM	:	14000648
Program Studi	:	Magsiter Ilmu Komputer
Jenjang	:	Strata Dua (S2)
Konsentrasi	:	<i>Management Information System</i>
Judul	:	“Optimasi Parameter pada Support Vector Machine berbasis Algoritma Genetika untuk Estimasi Kebakaran Hutan”

Kebakaran hutan merupakan salah satu masalah lingkungan yang mengancam hutan, menimbulkan dampak negatif pada lingkungan, menciptakan masalah ekonomi, dan kerusakan ekologis ,serta menyebabkan kerugian penting di seluruh dunia setiap tahunnya. Estimasi area yang terbakar penting dilakukan, karena area yang terbakar dapat mencerminkan berapa kuat radiasi api pada vegetasi disekitarnya. SVM dapat mengatasi masalah klasifikasi dan regresi dengan linier ataupun nonlinier kernel yang dapat menjadi satu kemampuan algoritma pembelajaran untuk klasifikasi serta regresi. Namun, SVM juga memiliki kelemahan yaitu sulitnya menentukan nilai parameter yang optimal. Untuk menyelesaikan permasalahan tersebut algoritma genetika diusulkan untuk diterapkan sebagai algoritma pencarian nilai parameter yang efisien pada SVM. Beberapa eksperimen dilakukan untuk menghasilkan estimasi yang akurat. Awalnya percobaan dilakukan pada kernel-kernel SVM (dot, RBF, polynomial) untuk menentukan kernel mana yang akan digunakan, kemudian model SVM+GA juga dibandingkan dengan model regresi lainnya seperti Linear Regression, k-NN dan Neural Network. Berdasarkan eksperimen dengan 10 kombinasi parameter pada metode SVM dan SVM+GA dengan kernel dot, RMSE terkecil dihasilkan oleh model SVM+GA sebesar 1.379, sementara pada percobaan SVM dan SVM+GA dengan kernel polynomial RMSE terkecil diperoleh model SVM+GA sebesar 1.379, sedangkan pada percobaan SVM dan SVM+GA dengan kernel RBF diperoleh RMSE terkecil pada model SVM+GA sebesar 1.379. Selanjutnya berdasarkan perbandingan rata-rata RMSE, kernel RBF unggul dengan nilai RMSE terkecil yaitu 1.432 pada SVM, dan 1.418 pada SVM+GA. Pada perbandingan nilai rata-rata RMSE antara SVM(RBF)+GA dengan model lainnya, RMSE terkecil dihasilkan oleh SVM(RBF)+GA yaitu sebesar 1.418, disusul dengan model SVM(RBF) sebesar 1.432, kemudian Linear Regression sebesar 1.459, dilanjutkan oleh model k-NN sebesar 1.526 dan yang terakhir adalah NN dengan nilai RMSE sebesar 1.559. maka dapat disimpulkan bahwa optimasi parameter yang dilakukan GA pada model SVM terbukti dapat mengurangi tingkat error pada model SVM tanpa optimasi parameter pada dataset *forest fire*, selain itu model SVM(RBF)+GA pada penelitian ini juga terbukti lebih baik dari model regresi lainnya.

Kata Kunci : Estimasi, Kebakaran Hutan, Support Vector Machine, Algoritma Genetika, Optimasi Parameter.

ABSTRACT

<i>Name</i>	:Hani Harafani
<i>NIM</i>	: 14000648
<i>Study of Program</i>	:Magister Ilmu Komputer
<i>Levels</i>	:Strata Dua (S2)
<i>Concentration</i>	: <i>Management Information System</i>
<i>Title</i>	:” <i>Parameter Optimization of Support Vector Machine based on Genetic Algorithm for Forest Fire Estimation</i> ”

Forest fires are one of environmental problems that threaten forest, causing negative impact to the environment, create economic problems, and ecological damage, also causing important losses around the world every year. The burned area estimation is important to do, because the burned area can reflect how strong fire radiation on surrounding vegetation. SVM can handle classification and regression problem with linear or nonlinear kernel which can be the machine learning ability for regression and classification problems. However, SVM have its drawbacks also, including the difficulty of determining optimal parameter value. To solve this problem genetic algorithm has proposed and applied as searching algorithm to search efficient parameter value to SVM. Some experiment has been done to get estimation result accurately. The experiment begin with try the SVM kernel (dot, RBF, polynomial) to determined which kernel will be used, and then SVM+GA model is also compared with another regression models like Linear Regression, k-NN, and Neural Network. Based on experiment with 10 combinations of parameters on SVM and SVM+GA method with dot kernel, the smallest RMSE value (1.379) produced by SVM+GA model, Meanwhile on SVM and SVM+GA with polynomial kernel experiments, the smallest RMSE value (1.379) also produced by SVM+GA, the smallest RMSE value (1.379) also produced by SVM+GA model too with RBF kernel on SVM and SVM+GA experiment, furthermore based on the average ratio of RMSE, RBF kernel winning the smallest value of RMSE (1.432) on SVM, and 1.418 on SVM+GA. on the value comparison between SVM+GA and another regression model, the smallest RMSE value (1.418) also produced by SVM(RBF)+GA model, followed by LR value (1.459), followed by k-NN value (1.526), and in the final position is NN value (1.559). Hence can be concluded that SVM parameter optimization by GA are proven to reduced the level of SVM error performance on forestfire dataset. In addition SVM+GA model in this research also proved better than another regression models.

Keywords : Estimation, Forest Fire, Support Vector Machine, Genetic Algorithm, Parameter Optimization.

DAFTAR ISI

Halaman

LEMBAR JUDUL	i
SURAT PERNYATAAN ORISINALITAS	iii
HALAMAN PENGESAHAN	iv
KATA PENGANTAR	vi
SURAT PERNYATAAN PERSETUJUAN PUBLIKASI KARYA ILMIAH UNTUK KEPENTINGAN AKADEMIS	viii
ABSTRAK	ix
ABSTRACT	xi
DAFTAR ISI	xii
DAFTAR TABEL	xiv
DAFTAR GAMBAR	xv
DAFTAR LAMPIRAN	xvi
BAB I PENDAHULUAN	1
1.1 Latar Belakang Penulisan.....	1
1.2 Identifikasi Masalah	3
1.3 Rumusan Masalah	3
1.4 Tujuan Penelitian.....	3
1.5 Manfaat Penelitian.....	4
1.6 Ruang Lingkup.....	4
1.7 Sistematika Penulisan.....	4
BAB II LANDASAN TEORI	6
2.1 Tinjauan Studi	6
2.1.1 Metode yang Diusulkan Wang et al (2014)	6
2.1.2 Metode yang Diusulkan Jia et al (2011)	7
2.1.3 Metode yang Diusulkan Gu, Zhu, & Jiang (2011).....	10
2.1.4 Metode yang Diusulkan Tiriyaki, Ozsahin & Yildirim (2014)	12
2.1.5 Metode yang Diusulkan Lira, Da Silva, Alves, & Veras (2014)	14
2.1.6 Metode yang Diusulkan Lee, Kang, & Cho (2014)	15
2.1.7 Rangkuman Penelitian Terkait.....	19
2.2 Landasan Teori.....	21
2.2.1 Kebakaran Hutan	21
2.2.2 Data Mining	22
2.2.3 Support Vector Machine	23
2.2.4 Algoritma Genetika.....	27
2.2.5 Metode Evaluasi & Validasi	30
2.2.6 Kerangka Pemikiran Penelitian.....	31
BAB III METODE PENELITIAN	33

3.1 Perancangan Penelitian	33
3.2 Pengumpulan Data	34
3.3 Pengolahan Data Awal	35
3.4 Metode yang Diusulkan	37
3.5 Eksperimen dan Pengujian Model.....	41
3.6 Evaluasi dan Validasi Hasil.....	41
BAB IV HASIL DAN PEMBAHASAN	42
4.1 Hasil Eksperimen dan Pengujian Model	42
4.1.1 Hasil Eksperimen dan Pengujian Model dengan Kernel Dot.....	42
4.1.2 Hasil Eksperimen dan Pengujian Model dengan Kernel Polynomial	43
4.1.3 Hasil Eksperimen dan Pengujian Model Dengan Kernel RBF	45
4.1.4 Hasil Eksperimen dan Pengujian dengan Model Regresi Lainnya	47
4.2 Pembahasan.....	50
4.2.1 Perbandingan RMSE SVM dan SVM+GA Menggunakan Kernel Dot	50
4.2.2 Perbandingan Model SVM dan SVM+GA Menggunakan Kernel Polynomial	51
4.2.3 Perbandingan Model SVM dan SVM+GA Menggunakan Kernel RBF	53
4.2.4 Perbandingan Nilai Rata-Rata RMSE pada SVM dan SVM+GA	55
4.2.5 Perbandingan SVM+GA dengan Model Regresi Lainnya.....	57
4.2.6 Perbandingan Nilai Rata-rata RMSE Terbaik SVM, SVM+GA, LR,NN, dan k-NN	60
4.2.7 Pengembangan Aplikasi Metode Terbaik dari Support Vector Machine dan Support Vector Machine + Genetic Algorithm	62
BAB V PENUTUP.....	66
5.1 Kesimpulan	66
5.2 Saran	67
DAFTAR PUSTAKA.....	68
LAMPIRAN.....	73
Lampiran 1. Forest Fire Dataset (Data Asli)	73
Lampiran 2. Forestfire dataset tanpa spatio-temporal atribut dan area yang telah di transformasi	85

DAFTAR TABEL

Halaman

Tabel 2.1 Rangkuman Penelitian Terkait.....	19
Tabel 3.1 Dataset Asli Foresfire UCI Learning Repository (2007)	35
Tabel 3.2 Dataset Forestfire Setelah Penghapusan Atribut.....	35
Tabel 3.3 Dataset Forest Fire Setelah Transformasi Label	36
Tabel 3.4 Spesifikasi Komputer Pengolah Data	41
Tabel 4.1 Hasil Eksperimen dengan Kernel Dot.....	42
Tabel 4.2 Hasil Pengujian Kernel Dot pada SVM dan SVM+GA.....	43
Tabel 4.3 Hasil Eksperimen dengan Kernel Polynomial	44
Tabel 4.4 Hasil Pengujian Kernel Polynomial pada SVM dan SVM+GA	44
Tabel 4.5 Hasil Eksperimen dengan Kernel RBF	45
Tabel 4.6 Hasil Pengujian Kernel RBF pada SVM dan SVM+GA	46
Tabel 4.7 Hasil Percobaan dengan k-NN	47
Tabel 4.8 Hasil Percobaan dengan Linear Regression.....	48
Tabel 4.9 Hasil Eksperimen dengan Neural Network.....	49
Tabel 4.10 Perbandingan RMSE SVM dan SVM+GA pada Kernel Dot	50
Tabel 4.11 Hasil Uji Beda Statistik SVM dan SVM+GA dengan Kernel Dot	51
Tabel 4.12 Perbandingan RMSE SVM dan SVM+GA pada kernel Polynomial.....	52
Tabel 4.13 Hasil Uji Beda Statistik SVM dan SVM+GA dengan Kernel Polynomial.....	53
Tabel 4.14 Perbandingan RMSE SVM dan SVM+GA pada kernel RBF.....	54
Tabel 4.15 Hasil Uji Beda Statistik SVM dan SVM+GA dengan Kernel RBF.....	55
Tabel 4.16 Perbandingan Rata-rata Nilai RMSE SVM dan SVM+GA.....	56
Tabel 4.17 Perbandingan RMSE SVM(RBF)+GA dengan k-NN	57
Tabel 4.18 Perbandingan Rata-rata RMSE SVM(RBF)+GA dengan Linear Regression.	58
Tabel 4.19 Perbandingan RMSE SVM(RBF)+GA dengan Neural Network.....	59
Tabel 4.20 Perbandingan Nilai Rata-rata RMSE 5 Metode	60
Tabel 4.21 Sample Dataset Forest Fire	62

DAFTAR GAMBAR

Halaman

Gambar 2.1 Metode yang Diusulkan Wang et al (2014)	7
Gambar 2.2 Metode yang Diusulkan Jia et al (2011).....	9
Gambar 2.3 Metode yang Diusulkan Gu et al (2011)	11
Gambar 2.4 Metode yang Diusulkan Tiriyaki et al (2014)	13
Gambar 2.5 Metode yang Diusulkan Lira et al (2014)	15
Gambar 2.6 Metode yang Diusulkan Lee et al (2014)	18
Gambar 2.7 Garis Pemisah dengan Margin Maksimal pada Klasifikasi Linier SVM	24
Gambar 2.8 Arsitektur SVM.....	25
Gambar 2.9 Regresi SVM dengan Zona ϵ Insensitive	26
Gambar 2.10 Proses Crossover pada Algoritma Genetika.....	29
Gambar 2.11 Proses Mutasi pada Algoritma Genetika.....	29
Gambar 2.12 Pseudocode Penyelesaian Masalah Optimasi pada GA	30
Gambar 2.13 Kerangka Pemikiran Penelitian.....	32
Gambar 3.1 Peta Taman Alam Montesinho	34
Gambar 3.2 Metode Penelitian yang Diusulkan	38
Gambar 3.3 Diagram Algoritma Genetika pada Support Vector Machine (SVM+GA)..	40
Gambar 4.1 Grafik Perbandingan Estimasi SVM dengan SVM+GA Menggunakan Kernel Dot	43
Gambar 4.2 Grafik Perbandingan Estimasi SVM dengan SVM+GA Menggunakan Kernel Polynomial.....	45
Gambar 4.3 Grafik Perbandingan Estimasi SVM dengan SVM+GA Menggunakan Kernel RBF	46
Gambar 4.4 Grafik Eksperimen dan Pengujian dengan k-NN	47
Gambar 4.5 Grafik Eksperimen dan Pengujian dengan Linear Regression	48
Gambar 4.6 Grafik Perrbandingan Nilai RMSE pada Percobaan Neural Network	49
Gambar 4.7 Perbandingan Nilai Rata-rata RMSE SVM dengan SVM+GA	56
Gambar 4.8 Grafik Perbedaan Nilai RMSE SVM(RBF)+GA dengan k-NN	58
Gambar 4.9 Grafik Perbandingan Nilai RMSE SVM(RBF)+GA dengan Linear Regression	59
Gambar 4.10 Grafik Perbandingan Nilai Rata-rata SVM(RBF)+GA dengan Neural Network	60
Gambar 4.11 Perbandingan Nilai Rata-rata RMSE Kelima Metode	61
Gambar 4.12 Pengujian Aplikasi Metode Terbaik Support Vector Machine	63

DAFTAR LAMPIRAN

Halaman

Lampiran 1. Forest Fire Dataset (Data Asli)	73
Lampiran 2. Forestfire dataset tanpa spatio-temporal atribut dan area yang telah di transformasi	85

BAB I

PENDAHULUAN

1.1 Latar Belakang Penulisan

Kebakaran hutan merupakan salah satu masalah lingkungan yang mengancam hutan, menimbulkan dampak negatif pada lingkungan, menciptakan masalah ekonomi, dan kerusakan ekologis (Özbayoğlu & Bozer, 2012), serta menyebabkan kerugian penting di seluruh dunia setiap tahunnya (Brun, Margalef, & Cortés, 2013). Kebakaran hutan terjadi karena beberapa hal diantaranya: pembakaran hutan yang disengaja (Denham, Wendt, Bianchini, Cortés, & Margalef, 2012), petir (Cortez & Morais, 2007), dan perubahan cuaca yang ekstrim (Eastaugh & Hasenauer, 2014), serta beberapa penyebab lainnya.

Estimasi area yang terbakar penting dilakukan, karena area yang terbakar dapat mencerminkan berapa kuat radiasi api pada vegetasi disekitarnya (Quintano, Fernández-Manso, Stein, & Bijker, 2011), sehingga dapat memberikan informasi mengenai kerusakan lahan yang terjadi. Namun, metode estimasi konvensional yang dilakukan oleh banyak peneliti berdasarkan *Thresholding* menghasilkan nilai estimasi yang kurang akurat.

Ada beberapa studi yang dilakukan untuk mengestimasi lahan yang terbakar pada kebakaran hutan dengan menggunakan metode komputasi antara lain: *support vector machine* (SVM) (Cortez & Morais, 2007), dan *multi layer perceptron* (MLP) (Özbayoğlu & Bozer, 2012). Selain itu banyak juga metode regresi yang digunakan para peneliti dunia pada berbagai permasalahan estimasi seperti k-NN (Lee, Kang, & Cho, 2014), *linear regression* (LR) (Lira, Da Silva, Alves, & Veras, 2014), dan *neural network* (NN) (Tiryaki, Öz, & Y, 2014). Metode-metode tersebut sangat direkomendasikan oleh banyak peneliti di dunia.

Multi layer perceptron sebagai salah satu model yang paling popular dari *artificial neural networks* (ANN) (Singh, Imtiyaz, Isaac, & Denis, 2012) memiliki kelebihan untuk menemukan pola dari data yang terlalu rumit untuk diketahui oleh manusia atau dengan teknik komputasi lainnya (Yilmaz & Kaynar, 2011). Selain itu MLP memiliki kekurangan yaitu sulit menemukan pola bila data

berdimensi tinggi atau sering disebut dengan “kutukan dimensionalitas” (Pan, Iplikci, Warwick, & Aziz, 2012), dan *overfitting* (Rynkiewicz, 2012).

Support vector machine (SVM) memiliki keunggulan dibandingkan metode MLP yaitu: SVM dapat mengatasi masalah klasifikasi dan regresi dengan linier ataupun nonlinier kernel yang dapat menjadi satu kemampuan algoritma pembelajaran untuk klasifikasi serta regresi (Maimon & Rokach, 2010), dan baik untuk mengatasi kutukan dimensionalitas (Wang, Wen, Zhang, & Wang, 2014). SVM juga memiliki akurasi tinggi dan tingkat kesalahan yang relatif kecil, kemampuan untuk model kompleks *nonlinear decision boundaries*, lebih mudah untuk mengatasi *overfitting* tidak membutuhkan data yang terlalu besar dan dapat digunakan untuk melakukan prediksi. Berdasarkan beberapa kelebihan SVM pada ulasan yang telah disebutkan, maka SVM cocok diterapkan untuk memprediksi kebakaran hutan pada penelitian ini. Selain memiliki banyak kemampuan yang telah disebutkan diatas, metode SVM juga memiliki kelemahan yaitu sulitnya menentukan nilai parameter yang optimal (Ilhan & Tezel, 2013; Raghavendra. N & Deka, 2014; Zhao, Fu, Ji, Tang, & Zhou, 2011).

Beberapa algoritma pun banyak direkomendasikan oleh peneliti dunia untuk mengoptimasi parameter pada machine learning, seperti: *particle swarm optimization* (PSO) (Wang et al., 2014), *simulated annealing* (SA) (Z.-Y. Jia, Ma, Wang, & Liu, 2010), dan *genetic algorithm* (GA) (Guo, Li, & Zhang, 2012)(Gu, Zhu, & Jiang, 2011).

Simmulated Annealing (SA) efektif pada pemecahan masalah optimasi pola, namun SA memiliki kecenderungan untuk terjebak dalam minimum lokal ketika suhu anil rendah (tingkat anil cepat) dan semakin tidak konvergen ketika suhu anil tinggi (tingkat anil lambat) (Zameer, Mirza, & Mirza, 2014). *Particle swarm optimization* (PSO) memiliki kemampuan pencarian global yang kuat, juga dapat membantu mencari parameter yang optimum secara cepat (Wang et al., 2014), namun kinerja PSO diyakini memiliki ketergantungan yang sensitif terhadap parameter, dan cenderung terjebak dalam minimum lokal (Zameer et al., 2014), selain itu PSO juga sulit mendapatkan nilai yang optimum dalam mengoptimasi lebih dari sepuluh parameter. *Genetic algorithm* atau algoritma genetika dapat

mengatasi masalah yang nonlinier dengan diskontinuitas dan minima lokal secara efisien serta lebih efisien dalam mengoptimasi lebih dari sepuluh parameter (Machairas, Tsangrassoulis, & Axarli, 2014).

Dari uraian diatas, maka dalam penelitian ini akan digunakan metode *support vector machine* yang dipadu dengan algoritma genetika yang akan digunakan untuk melakukan optimasi parameter pada *support vector machine*.

1.2 Identifikasi Masalah

Berdasarkan hasil uraian pada latar belakang, identifikasi masalah pada penelitian ini yaitu walaupun *support vector machine* unggul dalam menyelesaikan masalah klasifikasi dan regresi, namun *support vector machine* lemah dalam menentukan nilai parameter C , ε , dan kernel parameter γ yang optimal, yang mana parameter tersebut memiliki pengaruh besar pada kinerja estimasi SVM.

1.3 Rumusan Masalah

Rumusan masalah penelitian yang terkait dengan permasalahan penelitian yaitu:

1. Seberapa tinggi akurasi metode *support vector machine* terhadap estimasi kebakaran hutan, jika algoritma genetika diterapkan untuk mengoptimasi parameter C , ε , dan γ pada metode *support vector machine* untuk mengestimasi kebakaran hutan?
2. Dari ketiga kernel SVM (dot, polynomial, RBF), kernel mana yang memiliki tingkat akurasi yang paling tinggi ketika algoritma genetika diterapkan untuk mengoptimasi parameter C , ε , dan γ pada metode *support vector machine* untuk mengestimasi kebakaran hutan?
3. Jika SVM+GA dibandingkan dengan metode-metode regresi lainnya untuk mengestimasi kebakaran hutan, metode mana yang paling tinggi akurasinya?

1.4 Tujuan Penelitian

Tujuan dari penelitian ini adalah untuk mendapatkan hasil estimasi area yang terbakar akibat kebakaran hutan yang lebih akurat. Tujuan penelitian secara spesifik pada penelitian ini yaitu:

1. Menerapkan algoritma genetika untuk mengoptimasi parameter C , ε , dan γ pada metode *support vector machine* agar mendapatkan hasil estimasi kebakaran hutan yang lebih akurat.
2. Mengidentifikasi kernel terbaik pada *support vector machine* ketika dilakukan optimasi parameter dengan algoritma genetika.
3. Mengetahui perbandingan akurasi antara SVM+GA dengan metode regresi lainnya pada dataset *forest fire*.

1.5 Manfaat Penelitian

Penelitian ini dapat bermanfaat bagi pemerintahan dalam mengestimasi luas area yang terbakar sehingga pemerintah dapat mengalokasi sumber daya yang tepat untuk mengatasi kebakaran hutan. Selain itu penelitian ini juga dapat dikembangkan untuk meningkatkan hasil prediksi bencana lainnya seperti tsunami.

1.6 Ruang Lingkup

Ruang lingkup penelitian ini terbatas pada penerapan algoritma genetika untuk mengoptimasi parameter SVM pada dataset *forest fire*, perbandingan kernel-kernel SVM, dan perbandingan metode SVM+GA dengan metode k-NN, LR, dan NN.

1.7 Sistematika Penulisan

Bab I Pendahuluan

Bab I ini berisi penjelasan tentang latar belakang masalah, rumusan masalah, tujuan penelitian, manfaat penelitian, dan kontribusi serta sistematika penulisan

Bab II Landasan Teori dan Kerangka Pemikiran

Bab II ini berisi tentang tinjauan pustaka, tinjauan studi dan tinjauan organisasi atau obyek penelitian. Tinjauan pustaka merupakan penjelasan tentang sumber acuan dari pustaka primer seperti buku, artikel, jurnal, prosiding, dan

tulisan asli lainnya sebagai arahan dalam memecahkan masalah yang diteliti. Tinjauan studi merupakan penjelasan mengenai rangkuman hasil-hasil penelitian terbaru yang berkaitan dengan penelitian yang dilakukan. Obyek penelitian merupakan uraian mengenai obyek yang diteliti berdasarkan kerangka pemikiran.

Bab III Metode Penelitian

Bab III ini berisi tentang penjelasan mengenai metode penelitian, metode pengumpulan data, metode pengolahan data awal, model yang diusulkan, dan pengujian model

Bab IV Hasil dan Pembahasan

Bab IV ini menjelaskan tentang hasil dan pembahasan penelitian serta implikasi dari penelitian yang dilakukan. Hasil merupakan suatu penjelasan tentang data kuantitatif yang dikumpulkan dari lapangan sesuai dengan metodologi yang telah ditetapkan. Pembahasan merupakan suatu penjelasan tentang tindak lanjut penelitian yang terkait dengan aspek manajerial, aspek sistem, maupun aspek penelitian lanjutan.

Bab V Penutup

Bab V ini berisi ringkasan temuan, rangkuman kesimpulan dan saran. Kesimpulan merupakan pernyataan secara umum atau spesifik yang berisi hal-hal penting dan menjadi temuan penelitian yang bersumber pada hasil dan pembahasan. Saran merupakan pernyataan atau rekomendasi peneliti yang berisi hal-hal penting.

BAB II

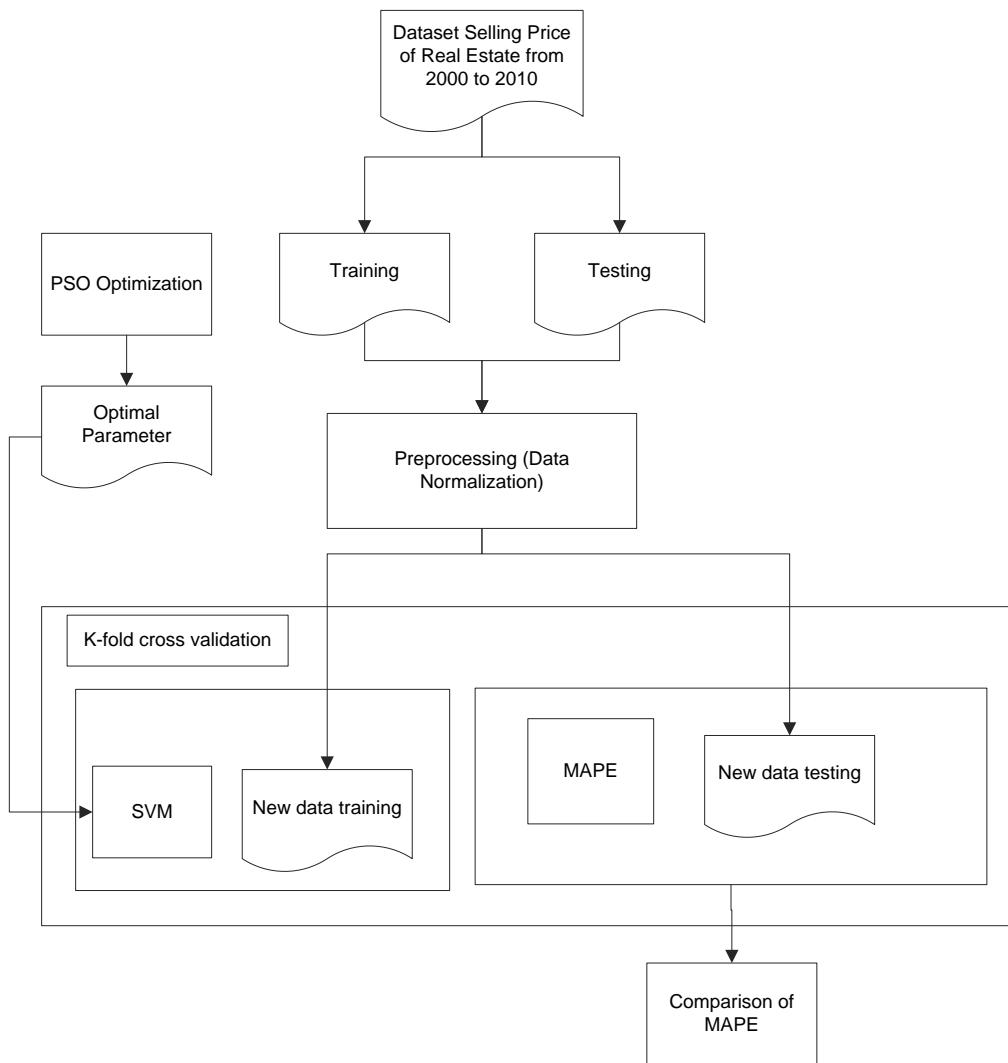
LANDASAN TEORI

2.1 Tinjauan Studi

2.1.1 Metode yang Diusulkan Wang et al (2014)

Penelitian yang dilakukan oleh (Wang et al., 2014) terfokus pada peningkatan akurasi prediksi *support vector machine* (SVM) untuk mengatasi kinerja SVM yang terpengaruh akibat pemilihan parameter yang tidak tepat untuk memprediksi harga *real estate* di kota Chongqing, China. Model SVM yang digunakan pada penelitian ini yaitu support vector regression (SVR) dengan kernel yang digunakan adalah kernel gaussian yang mana parameter σ menjadi kernel parameternya. Dataset yang digunakan adalah data rata-rata harga penjualan *real estate* di Chongqing dari tahun 2000-2010. Wang melakukan *preprocessing data* dengan memilih data *training* yang diambil dari data tahun 2000-2006 dan data *testing* diambil dari data tahun 2007-2010, kemudian data *training* dan data *testing* dinormalisasi sebagai tahapan *preprocessing*. Tahapan selanjutnya Wang kemudian menerapkan *Particle swarm optimization* (PSO) untuk menentukan nilai dari σ , ε , dan c pada SVM. Nilai parameter yang telah dioptimasi oleh PSO digunakan untuk melakukan *training* pada SVM. Wang membandingkan hasil persentase MAPE antara BPNN, SVM, dan SVM+PSO. Hasil penelitian menunjukkan nilai *Mean Absolute Percent Error* (MAPE) untuk SVM yaitu 3,75, sedangkan nilai MAPE untuk PSO+SVM adalah 2,19, dan nilai MAPE untuk (BPNN) adalah 5,71. Melihat dari hasil penelitian yang didapat, disimpulkan bahwa akurasi prediksi PSO+SVM lebih tinggi dibandingkan dengan model SVM dan BPNN.

Metode yang diusulkan oleh Wang et al dapat dilihat pada Gambar 2.1.

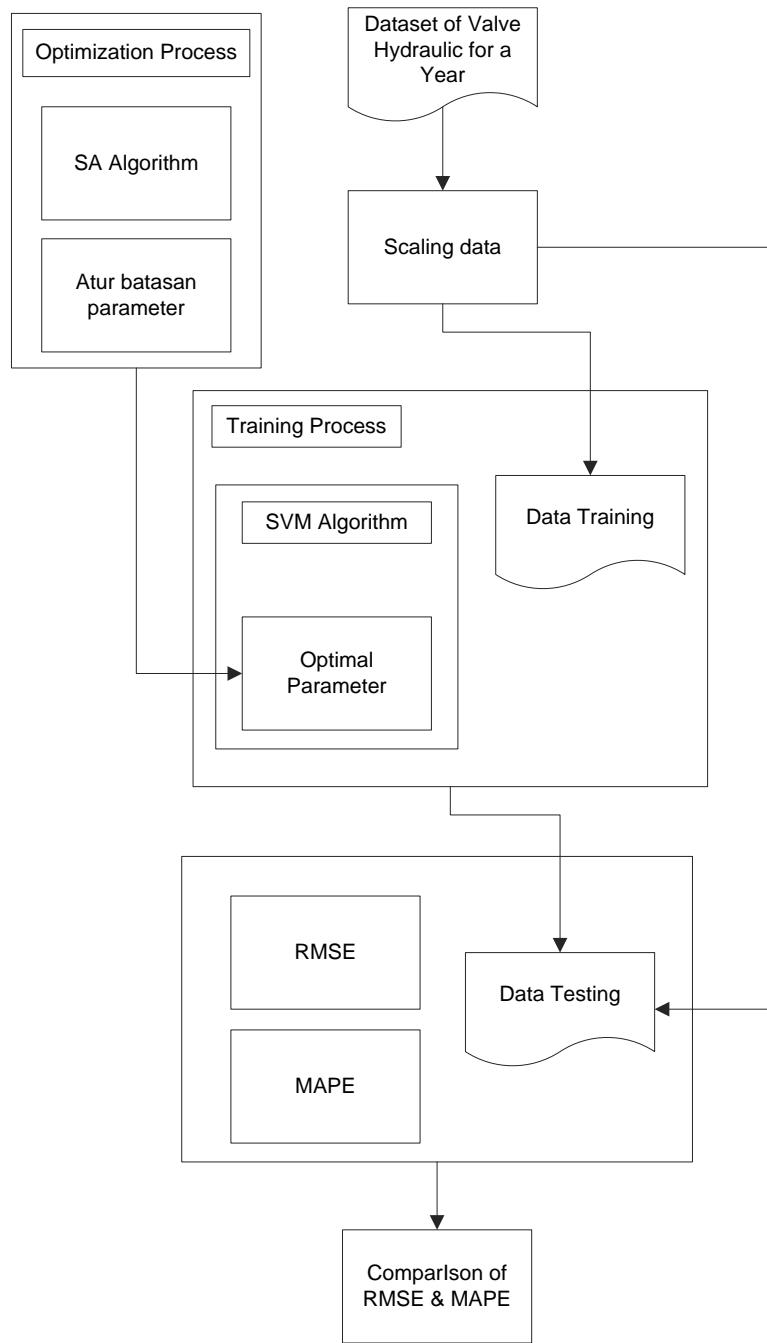


Gambar 2.1 Metode yang Diusulkan Wang et al (2014)

2.1.2 Metode yang Diusulkan Jia et al (2011)

Penelitian yang dilakukan oleh (Z. Jia, Ma, Wang, & Liu, 2011) mengangkat masalah pada kesulitan dalam menemukan nilai parameter SVM yang optimal karena metode pengujian yang berulang-ulang. SVM digunakan untuk memprediksi layak atau tidaknya katup hidrolik yang dibuat oleh sebuah perusahaan katup hidrolik di China. *Simulated annealing* (SA) digunakan untuk mencari nilai parameter yang optimal untuk meningkatkan akurasi prediksi dari SVM. Dataset yang diambil dari perusahaan tersebut terdiri dari 9 input variabel yang merupakan faktor geometris yang amat mempengaruhi karakteristik dari katup hidrolik yaitu silinder lubang dalam untuk lengan katup, permukaan ujung kiri pembuka tempurung, permukaan ujung kanan pembuka tempurung, jarak

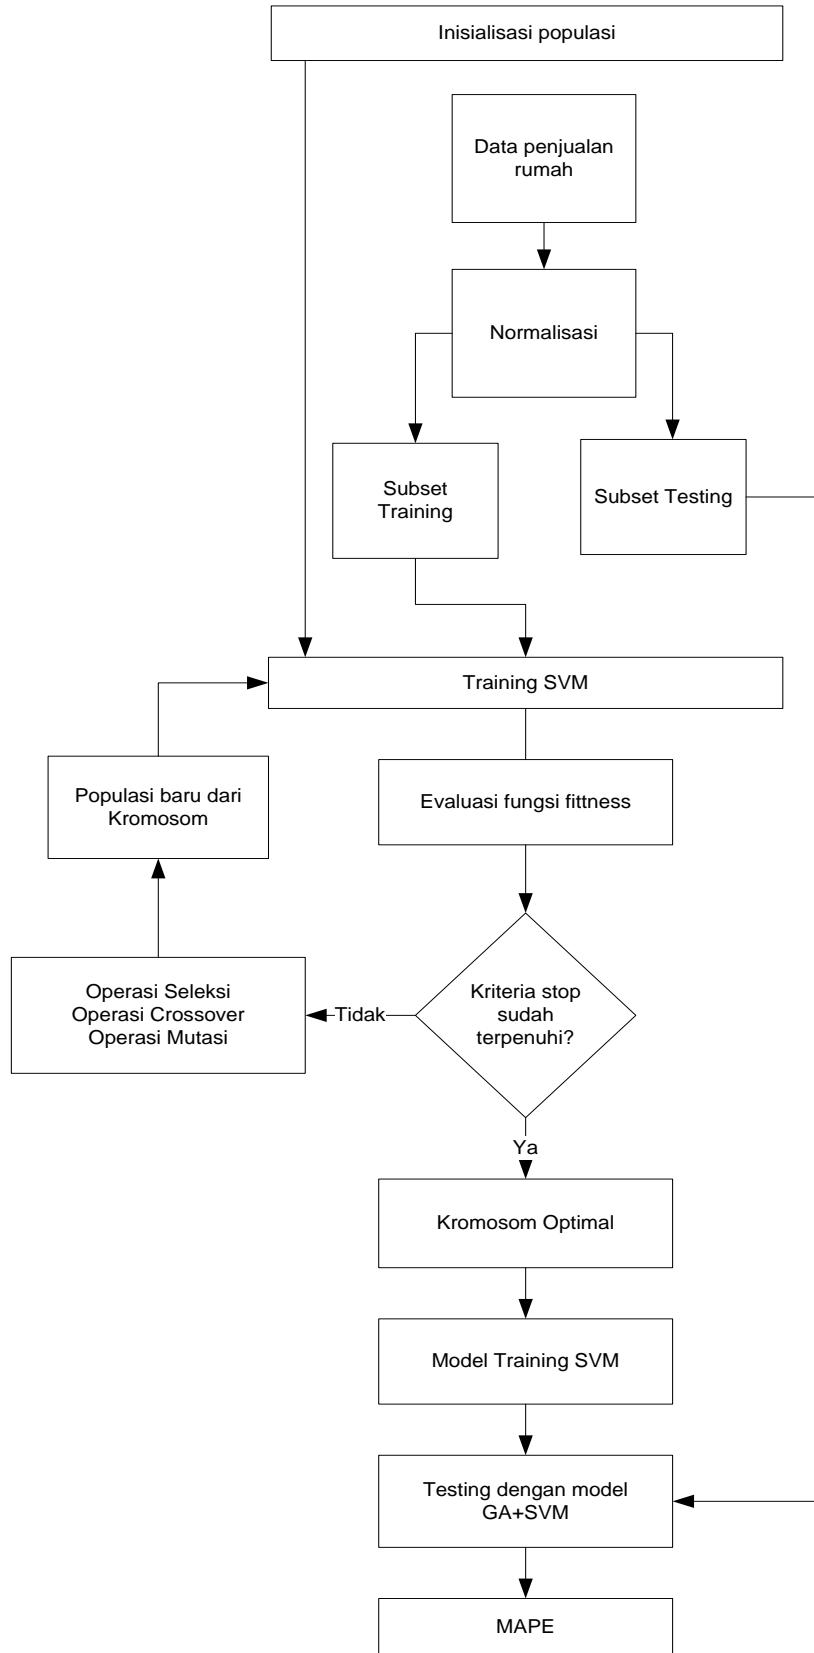
antara tempurung dengan lengan katup, jarak antara inti katup dengan lengan katup, *ring* satu jarak pas, *ring* dua jarak pas, *ring* tiga jarak pas, dan *ring* empat jarak pas. Pada awalnya Jia et al melakukan *data scaling* sebagai langkah *preprocessing*, kemudian dilanjutkan dengan pemilihan kernel untuk menghasilkan performa yang lebih baik. Kernel yang dipilih adalah Gaussian RBF karena menurut Jia et al kernel gaussian RBF tidak terlalu banyak memiliki *hyperparameter* yang mempengaruhi kompleksitas dalam pemilihan model dibandingkan dengan kernel polynomial. Selanjutnya jia et al juga mengatur batasan parameter C , ε , dan σ berdasarkan percobaan, nilai C diatur dengan batasan min 100 dan max 1000, sedangkan untuk nilai ε diatur dengan batasan min 0,001 dan max 0,01, dan nilai σ dengan batasan min 0,5 dan max 1,5. Hasil penelitian membandingkan nilai *Root Mean Square Error* (RMSE) dan *Mean Absolute Percent Error* (MAPE) terhadap beberapa metode yaitu SA+SVM dengan nilai RMSE=0,016, dan MAPE=0,074, sedangkan G-ANFIS dengan nilai RMSE=0,017, dan MAPE=0,070, dan ANN dengan nilai RMSE=0,33, dan MAPE=0,176. Metode yang diusulkan oleh Jia et al dapat dilihat pada Gambar 2.2.



Gambar 2.2 Metode yang Diusulkan Jia et al (2011)

2.1.3 Metode yang Diusulkan Gu, Zhu, & Jiang (2011)

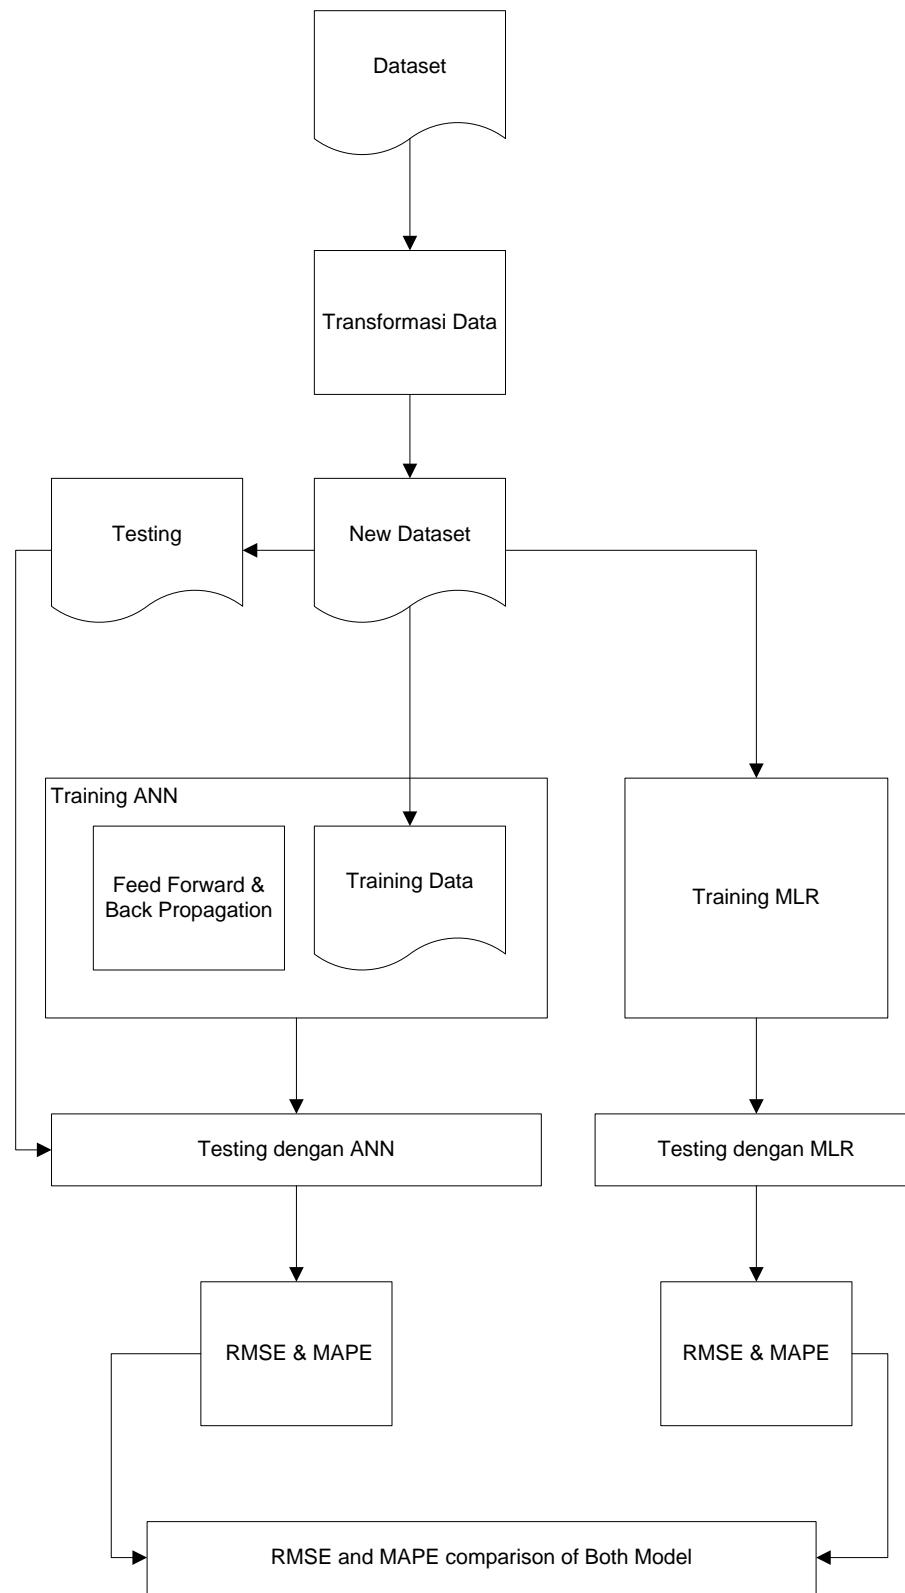
Penelitian yang dilakukan oleh (Gu et al., 2011), fokus pada pencarian nilai parameter SVM yang optimal dengan menggunakan algoritma genetika sebagai algoritma pencarian nilai parameter kernel γ , parameter pinalti C, dan parameter *insensitive loss* ε . (Gu et al., 2011) membandingkan hasil prediksi antara GA+SVM dan *Grey Model* (GM) untuk memprediksi harga penjualan rumah di China. Data yang digunakan untuk proses *training* diambil dari rata-rata harga penjualan rumah di China dari tahun 1993 sampai dengan tahun 2002, dan data rata-rata harga penjualan rumah di kota Tangsham pada seperempat tahun 2000 sampai tahun 2002. Sebelum data ditraining, data dinormalisasi terlebih dahulu, kemudian dibagi menjadi set *training* dan set uji. Setelah melalui proses *training*, (Gu et al., 2011) menentukan jumlah populasi sebanyak 20 kromosom dan memasukkan hasil training pada algoritma genetika untuk mencari nilai parameter yang optimal, jika kriteria sudah terpenuhi maka terdapat model prediksi yang baru yaitu (GA+SVM), kemudian data di uji. Hasil penelitian ini menunjukkan nilai MAPE untuk model GM pada kasus data yang pertama yaitu 25,87, sedangkan untuk GA+SVM adalah 2,33, kemudian untuk nilai MAPE pada kasus data yang kedua untuk GM adalah 9,52, dan untuk GA+SVM yaitu 1,94. Dari hasil penelitian dapat disimpulkan bahwa prediksi GA+SVM lebih akurat dibandingkan dengan GM. Hasil eksperimen mengindikasi bahwa hasil akurasi prediksi GA+SVM lebih superior dari GM. Metode yang diusulkan (Gu et al., 2011) dapat dilihat pada Gambar 2.3.



Gambar 2.3 Metode yang Diusulkan Gu et al (2011)

2.1.4 Metode yang Diusulkan Tiryaki, Ozsahin & Yildirim (2014)

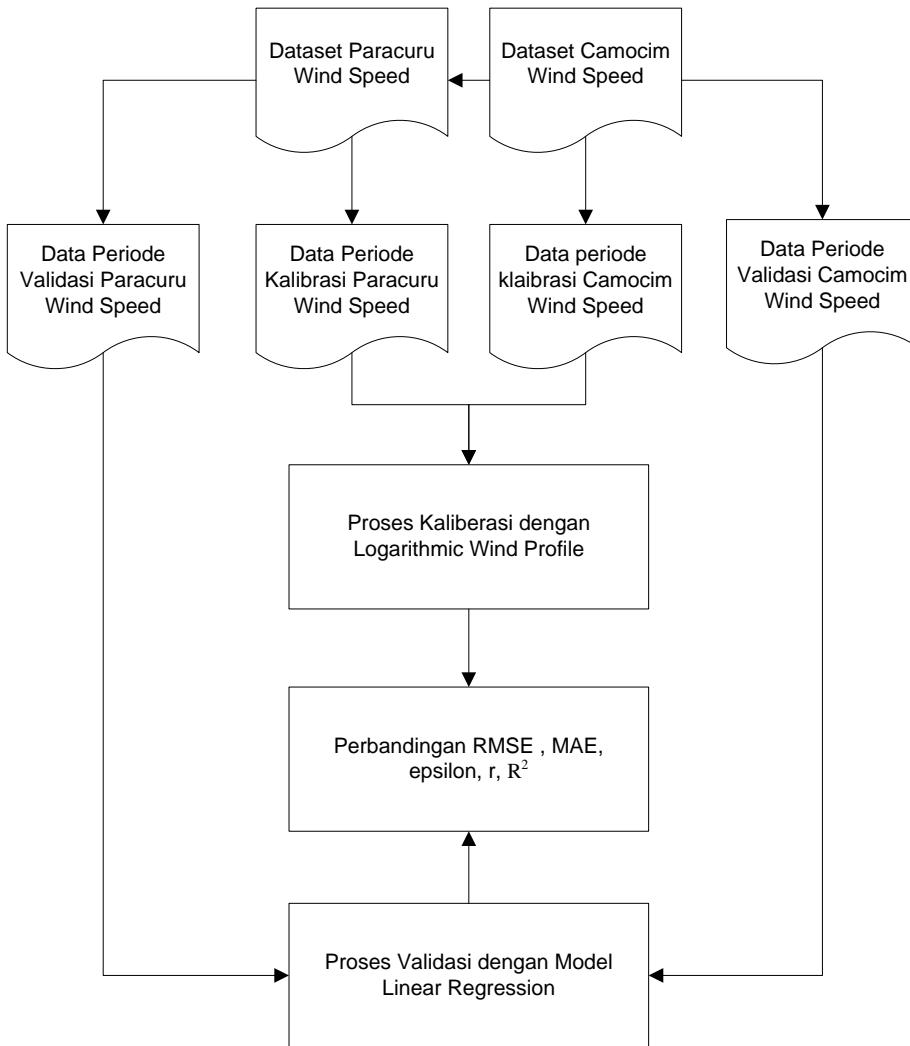
Penelitian yang dilakukan oleh (Tiryaki et al., 2014) terfokus pada pencarian metode regresi yang tepat untuk mendeteksi efek perlakuan panas pada ikatan kayu. Penelitian (Tiryaki et al., 2014) adalah membandingkan metode-metode regresi seperti *Artificial Neural Network* (ANN) dan *Multiple Regression* (MLR) untuk mengurangi biaya dan waktu pendekripsi secara manual dengan cara membuat pemodelan untuk ikatan kayu yang pas untuk kayu yang dipanaskan. Dataset yang digunakan adalah sampel untuk kekuatan ikatan dan pengukuran kekasaran permukaan kayu sebanyak 96 *record*. Awalnya untuk pemodelan menggunakan ANN data dibagi dua yaitu data *training* sebanyak 72 data, dan data *testing* sebesar 24 data. Sementara untuk pemodelan menggunakan MLR semua data digunakan dalam proses *training* dan *testing*. Sebelum dilakukan *training*, data ditransformasi terlebih dahulu dalam jangkauan -1 sampai 1. Kemudian dilakukan proses *training* pada model ANN menggunakan *feed forward* dan *back propagation multilayer* ANN sebagai solusi dari permasalahan. Beberapa arsitektur ANN yang berbeda dan parameter yang berbeda dipercobakan sampai nilai *error* antara pengukuran dan nilai prediksi semakin kecil. Jumlah *neuron* dalam *hidden layer* yang terdeteksi setelah proses *trial and error* adalah 3 dan 9. (Tiryaki et al., 2014) dalam penelitiannya mengevaluasi performa model menggunakan MAPE, RMSE, dan R^2 . Training data ANN mendapatkan nilai MAPE (1.49), RMSE (0.18), dan R^2 (0.997), untuk testing data ANN mendapatkan nilai MAPE(3.06), RMSE (0.40), dan R^2 (0.986). Sedangkan untuk model MLR terhadap keseluruhan data mendapatkan nilai MAPE(7.31), RMSE(0.80), dan R^2 (0.942). kesimpulan dari penelitian ini adalah metode ANN mempunyai koefisien determinasi yang tinggi (R^2) antara nilai pengukuran dan nilai prediksi dari kekuatan ikatan kayu. Meskipun hasil metode MLR juga memuaskan, namun metode ANN memiliki nilai pengukuran yang hampir sama dengan nilai prediksi, sehingga dapat dikatakan bahwa metode ANN telah terbukti menjadi metode yang sukses dan *sufficient* untuk memodelkan karakteristik kekuatan ikatan jenis kayu. Metode yang diusulkan (Tiryaki et al., 2014) dapat dilihat pada Gambar 2.4.



Gambar 2.4 Metode yang Diusulkan Tiryaki et al (2014)

2.1.5 Metode yang Diusulkan Lira, Da Silva, Alves, & Veras (2014)

Penelitian yang dilakukan oleh (Lira et al., 2014) terfokus pada penerapan metode *linear regression* untuk mengestimasi rata-rata kecepatan angin di beberapa ketinggian permukaan di pinggir pantai Ceara Brazil. Metode *linear regression* diterapkan pada dua area yaitu Paracuru dan Camocim yang berlokasi di Ceara Brazil. Profil logaritmik angin biasanya digunakan untuk mengestimasi rata-rata kecepatan angin pada ketinggian 20m, 40m, dan 60m dari data yang dikoleksi 10m saja. Metode *linear regression* pada penelitian (Lira et al., 2014) digunakan untuk mengestimasi rata-rata kecepatan angin untuk ketinggian yang baru selain 10m sampai dengan 60m dan perubahan rata-rata dicatat setiap 5 hari. (Lira et al., 2014) menggunakan 2 buah data yang dikoleksi oleh Platform for Data Collection (PDC), dan Anemometric Tower(AT). Pada tahapan pertama, data dibagi menjadi dua bagian yaitu bagian kalibrasi dan validasi. Profil logaritmik angin akan diterapkan pada tahapan kaliberasi, sementara model *linear regression* akan diterapkan pada tahapan validasi. Perbandingan nilai RMSE, MAE, r , R^2 , dan ϵ pada kedua tahapan menggunakan dua dataset menunjukkan pada data wilayah Paracuru nilai rata-rata RMSE adalah (0.99), MAE (0.80), epsilon(0.05), r (0.87), R^2 (0.76). Sedangkan untuk tahapan validasi pada data wilayah Paracuru nilai rata-rata RMSE(0.83), MAE(0.70), epsilon(6.04), r (0.96), R^2 (0.93). Pada data wilayah Camocim pada tahapan kaliberasi nilai rata-rata RMSE(0.56), MAE(0.43), epsilon(0.28), r (0.94), R^2 (0.89), Sedangkan pada tahapan validasi nilai rata-rata RMSE(0.44), MAE(0.37), epsilon(2.34), r (0.94), R^2 (0.90). Hasil percobaan menunjukkan bahwa metode *linear regression* memiliki performa yang bagus pada data rentet waktu, estimasi data, dan koefisien korelasi, juga nilai error. Model penelitian (Lira et al., 2014) dapat dilihat pada Gambar 2.5.

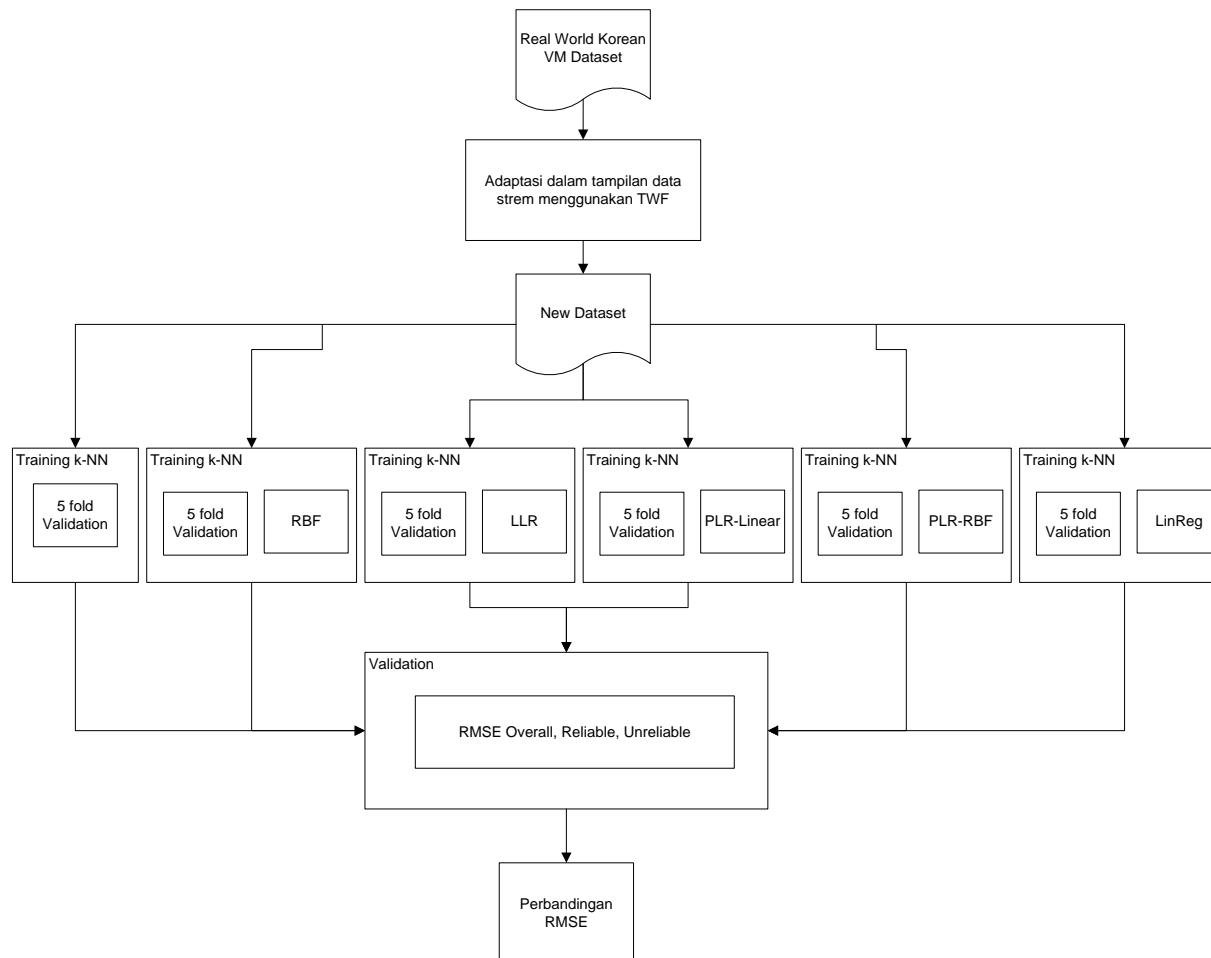


Gambar 2.5 Metode yang Diusulkan Lira et al (2014)

2.1.6 Metode yang Diusulkan Lee, Kang, & Cho (2014)

Penelitian (Lee et al., 2014) terfokus pada pencarian metode yang tepat untuk menentukan bobot k pada k-NN pada metrologi virtual manufaktur semikonduktor. Metrologi virtual didefinisikan sebagai teknik untuk memprediksi pengukuran metrologi dari alat pengukuran resmi tanpa operasi metrologi yang sebenarnya. Semula (Lee et al., 2014) menerapkan *locally linear reconstruction* (LLR) untuk menentukan bobot k , namun struktur linear pada LLR menyebabkan model rekonstruksi tidak stabil, sehingga (Lee et al., 2014) kernel Bayesian dalam LLR yang disebut dengan *probabilistic local reconstruction* (PLR) diterapkan. Kemudian (Lee et al., 2014) juga membandingkan beberapa metode seperti k-NN

(tanpa pembobotan), k-NN(RBF), LLR, PLR-Linear, PLR-RBF, dan *linear regression* pada berbagai macam dataset untuk mencari model regresi mana yang memiliki nilai RMSE yang terkecil agar dapat diaplikasikan pada metrologi virtual. Berdasarkan 15 percobaan dengan berbagai dataset yang digunakan seperti: Stock, Abalone, Wind, Computer, Kinematics, Bank, Pumadyn, Add10, California, Census, Gold, Sunspot, Melbmax, Santa Fe A, dan Santa Fe D, didapatkan bahwa 13 dari 15 dataset menunjukkan nilai RMSE terkecil didapat dengan menerapkan model PLR pada k-NN. Berdasarkan hasil percobaan (Lee et al., 2014) memutuskan untuk mempercobakan PLR pada k-NN untuk diaplikasikan pada metrologi virtual beserta beberapa model lainnya sebagai perbandingan. Dataset yang digunakan yaitu data yang dikumpulkan dari alat untuk pengolahan langkah proses *photolithography* dan operasi metrologi yang sesuai pada pembentukan semikonduktor Korea untuk jangka waktu empat bulan. Awalnya untuk adaptasi model k-NN dalam tampilan data *stream* (Lee et al., 2014) menggunakan *time-weighted forgetting*(TWF). Selanjutnya parameter k diatur dengan nilai 5 untuk meminimalkan beban komputasi dan parameter β dipilih di antara 10, 100, 1000 oleh 5 *fold-validation* pada tahapan pelatihan. selanjutnya (Lee et al., 2014) menerapkan beberapa metode yang dipercobakan untuk membandingkan berapa prediksi yang handal/*reliable*, dengan prediksi yang tidak handal/*unreliable*. Hasil eksperimen menunjukkan nilai prediksi keseluruhan pada model k-NN(0.001748), k-NN+RBF(0.001893), k-NN+LLR(0.011562), k-NN+PLR-Linear(0.01149), k-NN+PLR-RBF(0.001744), dan *linear regression*(0.032461), sedangkan untuk prediksi kehandalan dan ketidakhandalan hanya diperoleh dengan menerapkan PLR-Linear handal (0.001605) dan PLR-RBF handal (0.001722), PLR-Linear tidak handal (0.000030254) dan PLR-RBF tidak handal (0.001992). Berdasarkan hasil penelitian didapatkan kesimpulan bahwa PLR baik dalam menunjukkan tingginya hasil akurasi prediksi sebaik menunjukkan hasil variasi prediksi rendah untuk parameter kritis k dalam pembelajaran k-NN. Model penelitian (Lee et al., 2014) dapat dilihat pada Gambar 2.6.



Gambar 2.6 Metode yang Diusulkan Lee et al (2014)

2.1.7 Rangkuman Penelitian Terkait

Berdasarkan rangkuman beberapa penelitian di atas terdapat perbedaan metode akurasi, tingkat, dan metode evaluasi yang dapat dilihat pada Tabel 2.1.

Tabel 2.1 Rangkuman Penelitian Terkait

Peneliti	Dataset	Masalah Penelitian	Pemilihan Parameter	Metode Prediksi	Evaluasi
Wang et al (2014)	The average selling price of real estate from 2000 to 2010, Chongqing, China	Pemilihan nilai parameter yang tidak tepat Mempengaruhi kinerja SVM dan akurasi prediksi	Particle Swarm Optimization (PSO)	SVM, dan Back Propagation Neural Network (BPNN)	<u>MAPE</u> SVM=3,75 PSO+SVM=2,19 BPNN=5,71
Jia et al (2011)	Production data of valve hydraulic for a year from an enterprise	Sulit menentukan nilai parameter SVM yang optimal	Simulated Annealing (SA)	SVM, G-ANFIS, dan ANN	<u>RMSE</u> SA+SVM=0,016 G-ANFIS=0,017 ANN=0,033 <u>MAPE</u> SA+SVM=0,074 G-ANFIS=0,079 ANN=0,176
Gu et al (2011)	Housing Selling Price Data from 1993-2002, China	Sulit menentukan nilai parameter yang optimal	Genetic Algorithm (GA)	SVM, Grey Model (GM)	<u>MAPE</u> Kasus 1: GM =25,87 GA+SVM = 2,33 Kasus 2: GM = 9,52 GA+SVM = 1,94
Tiryaki et al (2014)	sampel untuk kekuatan ikatan dan pengukuran kekasaran permukaan kayu	Pencarian metode regresi yang tepat untuk mendekripsi efek perlakuan panas pada ikatan kayu	-	ANN (Back Propagation & Feed Forward) dan MLR	<u>MAPE</u> ANN Training = 1.49 ANN Testing = 3.06 MLR = 7.31 <u>RMSE</u> ANN Training = 0.18 ANN Testing = 0.40 MLR = 0.80 <u>R²</u> ANN Training = 0.997 ANN Testing = 0.986 MLR = 0.942
Lira et al (2014)	Wind Speed Paracuru Brazil, & Wind Speed Camocim Brazil	pencarian metode regresi yang tepat untuk mengestimasi rata-rata kecepatan	-	Logarithmic Wind Profile dan Linear Regression	<u>RMSE</u> LWP Paracuru =0.99 LR Paracuru = 0.83 LWP Camocim = 0.56 LR Camocim =0.44 <u>MAE</u> LWP Paracuru = 0.80 LR Paracuru = 0.70 LWP Camocim = 0.43

		angin di-beberapa ketinggian permukaan di pinggir pantai Ceara Brazil			LR Camocim = 0.37 <u>Epsilon</u> LWP Paracuru = 0.05 LR Paracuru = 6.04 LWP Camocim = 0.28 LR Camocim = 2.34 <u>R</u> LWP Paracuru = 0.87 LR Paracuru = 0.96 LWP Camocim = 0.94 LR Camocim = 0.94 <u>R²</u> LWP Paracuru = 0.76 LR Paracuru = 0.93 LWP Camocim = 0.89 LR Camocim = 0.90
Lee et al (2014)	Real World Korean VM gathered for 4 months	Sulitnya Menentukan bobot k pada k-NN	Unweighted LLR PLR-Linear PLR-RBF RBF Linear Regression	k-NN	<u>Overall Prediction</u> <u>RMSE</u> Unweighted = 0.001748 RBF = 0.001893 LLR = 0.011562 PLR-Linear = 0.01149 PLR-RBF = 0.001744 LR = 0.032461 <u>Reliable Prediction</u> <u>RMSE</u> PLR-Linear = 0.001605 PLR-RBF = 0.001722 <u>Unreliable Prediction</u> <u>RMSE</u> PLR-Linear = 0.000030254 PLR-RBF = 0.001992
Harafani (2015)	Forest Fire Dataset (UCI Machine Learning Repository)	Pemilihan nilai parameter yang tidak optimal mempengaruhi kinerja dan akurasi prediksi SVM	Genetic Algorithm (GA)	SVM	?

Pada penelitian ini akan membahas mengenai pemilihan parameter C , ϵ (ε), dan γ (γ) pada SVM yang optimal menggunakan algoritma genetika. Pada penelitian ini juga akan dibandingkan hasil eksperimen SVM, dan SVM+GA, juga beberapa algoritma lainnya seperti *linear regression*, k-NN dan *neural network*.

2.2 Landasan Teori

2.2.1 Kebakaran Hutan

Menurut Patterson & Backman dalam (Zumbrunnen et al., 2011) “Kebakaran hutan adalah gangguan alam yang berbahaya dan berpotensi besar di banyak wilayah dunia”. Kebakaran hutan mengakibatkan kerusakan ekologis (Özbayoğlu & Bozer, 2012), kerusakan lahan dan hasil-hasilnya sehingga menimbulkan kerugian penting setiap tahunnya (Brun et al., 2013) seperti menimbulkan masalah ekonomi, dan masalah lingkungan lainnya. Kebakaran hutan sampai saat ini menjadi perhatian internasional sebagai isu lingkungan dan ekonomi, selain itu kebakaran hutan juga dianggap sebagai ancaman potensial bagi pembangunan berkelanjutan karena efeknya.

Penyebab kebakaran hutan sampai saat ini masih menjadi perdebatan (Tacconi, 2003). Berdasarkan beberapa penelitian terkait terdapat dua penyebab utama kebakaran hutan yaitu faktor alam dan kecerobohan manusia (Cortez & Morais, 2007; Denham et al., 2012). Diantaranya:

1. Menurut (Girardin et al., 2013; Zumbrunnen et al., 2011)
 - a. Faktor biotik, dan abiotik
 - b. Iklim yang bervariasi
 - c. Topografi
 - d. Muatan bahan bakar pada vegetasi
2. Menurut (Cortez & Morais, 2007; Özbayoğlu & Bozer, 2012)
 - a. Kondisi cuaca
 - b. Temperature
 - c. Kelembaban relatif
 - d. Angin
 - e. Petir
3. Menurut (Noor & Syumanda, 2006; Tacconi, 2003)

a. Alih fungsi Lahan

Sedangkan dampak kebakaran hutan yang ditimbulkan juga sangatlah kompleks diantaranya:

1. Menurut (Özbayoğlu & Bozer, 2012; Tacconi, 2003)
 - a. Dampak ekonomi
 - b. Kerusakan ekologi
2. Menurut (Noor & Syumanda, 2006)
 - a. Dampak sosial & budaya
 - b. Dampak terhadap hubungan antar negara
 - c. Dampak perhubungan dan pariwisata

2.2.2 Data Mining

Data mining didefinisikan sebagai proses menemukan pola secara otomatis pada data yang disimpan secara elektronik (Witten, Frank, & Hall, 2011) dimana pola tersebut awalnya tersembunyi diantara sejumlah besar data yang ada (El Sheikh & Alnoukari, 2012). Manusia telah mencari pola dalam data sejak kehidupan manusia dimulai. Sebagai contoh para pemburu mencari pola dalam perilaku migrasi hewan, para petani mencari pola dalam pertumbuhan tanaman, dan politisi mencari pola dalam pendapat para pemilih (Witten et al., 2011). Pola yang ditemukan haruslah memiliki makna dan bermanfaat sehingga pola yang ditemukan dapat mewakili pengetahuan (Han, Kamber, & Pei, 2012).

Data mining dapat diaplikasikan secara efektif pada banyak area termasuk *marketing*, servis finansial, deteksi penipuan, pengawasan barang persediaan, diagnosa kesalahan, *credit scoring*, pengaturan jaringan, penjadwalan, diagnosa medis, dan peramalan (El Sheikh & Alnoukari, 2012).

Sebagai bidang multidisiplin *data mining* mengacu pada statistik, pembelajaran mesin (*Machine Learning*), pengenalan pola (*Pattern Recognition*), teknologi database, pencarian informasi (*Information Retrieval*), ilmu jaringan (*Network Science*), sistem berbasis pengetahuan (*Knowledge-Based System*), kecerdasan buatan (*Artificial Intelligence*), komputasi kinerja tinggi (*High*

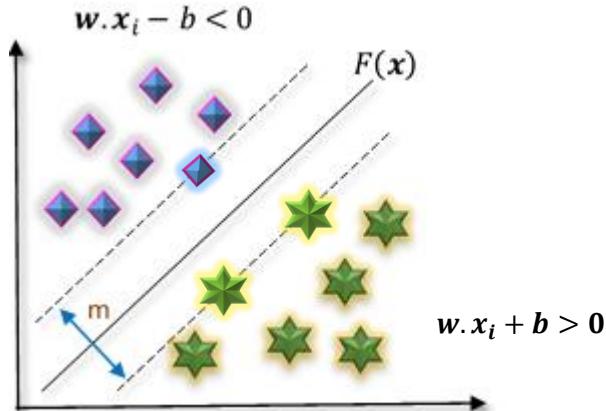
Performance Computing), dan visualisasi data (Han et al., 2012). Jadi terdapat sejumlah fungsi dari data mining yaitu mencakup: 1) karakterisasi dan diskriminasi, 2) penambangan pola yang sering muncul, 3) asosiasi, 4) korelasi, 5) klasifikasi dan regresi, 6) analisis *clustering*, dan 7) analisis *outlier*. Kegunaan data mining ini digunakan untuk menentukan jenis pola yang dapat ditemukan dalam tugas data mining.

Klasifikasi dan regresi telah menjadi inti dari sebuah prediksi dan estimasi. Klasifikasi adalah proses penemuan model yang membedakan kelas data agar bisa digunakan untuk memprediksi kelas dari objek yang label kelasnya tidak diketahui, sementara regresi adalah proses memprediksi dari objek yang berbentuk numerik. Analisis regresi adalah sebuah metodologi statistik yang paling sering digunakan untuk prediksi numerik berdasarkan data yang tersedia. Selain menggunakan metodologi statistik analisis regresi juga dapat dipecahkan menggunakan *machine learning*. *Machine learning* adalah algoritma pemrograman komputer yang dibuat khusus untuk memecahkan permasalahan permasalahan yang juga menggunakan teori statistik dalam pembangunan model matematikanya (Alpaydin, 2010). Dengan kata lain mesin komputer harus mempelajari (*learn*) data input, dan mengeluarkan output melalui serangkaian proses yang otomatis. Algoritma machine learning yang dapat digunakan untuk analisis regresi diantaranya: *neural network* (NN), *support vector regression* (SVR), *linear regression* dan sebagainya.

2.2.3 Support Vector Machine

Support Vector Machine (SVM) secara konseptual adalah mesin linear yang dilengkapi dengan fitur spesial (Gorunescu, 2011), dan didasarkan pada metode minimalisasi resiko struktural (Dua, 2011), serta teori pembelajaran statistik. SVM telah banyak diteliti dalam komunitas data mining dan pembelajaran mesin (*Machine Learning*) selama sepuluh tahun terakhir (Yu & Kim, 2012). Dua sifat khusus dari SVM yaitu (1) mencapai generalisasi yang tinggi dengan memaksimalkan margin, dan (2) mendukung pembelajaran yang efisien dari fungsi nonlinier pada trik kernel sehingga membuat kinerja generalisasinya baik dalam menyelesaikan masalah pengenalan pola (Gorunescu, 2011).

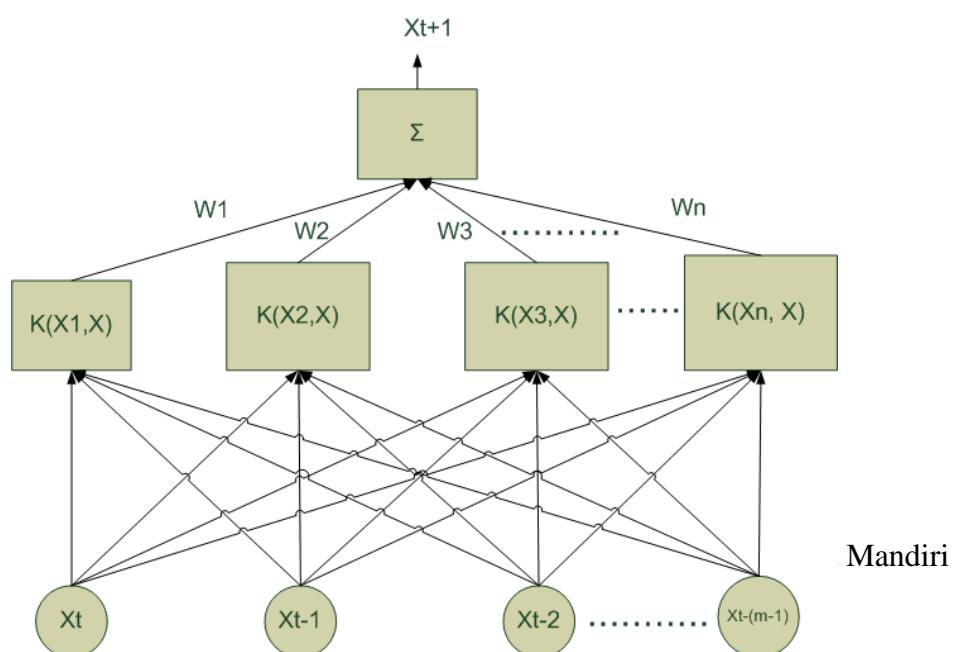
Untuk masalah klasifikasi SVM mencoba untuk mencari garis pemisah yang optimal yang diekspresikan sebagai kombinasi linier dari subset data pelatihan dengan menyelesaikan masalah keterbatasan linier pemrograman kuadrat (QP) dengan margin maksimum antara dua kelas.



Gambar 2.7 Garis Pemisah dengan Margin Maksimal pada Klasifikasi Linier SVM

Selain itu Vapnik juga memperkenalkan fungsi $\varepsilon - \text{insensitive loss}$ sehingga SVM dapat menyelesaikan permasalahan regresi-estimasi (Suganyadevi & Babulal, 2014), disebut sebagai SVM untuk regresi.

Support Vector Regression (SVR) adalah metode untuk mengestimasi sebuah fungsi yang dipetakan dari objek input ke jumlah riil berdasarkan data pelatihan. Serupa dengan pengklasifikasian SVM, SVR memiliki properti yang sama tentang memaksimalkan margin dan trik kernel untuk memetakan data nonlinier. Gambar 2.8 menunjukkan struktur dari prediktor SVR yang mewujudkan fungsi pemetaan.



Gambar 2.8 Arsitektur SVM

Ide dasar dari SVR adalah memetakan data dari ruang input kedalam ruang fitur dimensi yang tinggi dengan pemetaan non-linier dan untuk melakukan regresi linier dalam ruang tersebut. $x_{i+1} = f(x_t, x_{t-1}, x_{t-2}, \dots, x_{t-(m-1)})$ dimana x_{i+1} adalah nilai yang diprediksi dan x_t adalah nilai yang diamati.

Sekumpulan data training untuk regresi SVM digambarkan sebagai berikut:

$$D = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_m, y_m)\} \quad (2.1)$$

Dimana \mathbf{x}_i adalah vector n-dimensional, sedangkan y adalah jumlah real untuk setiap \mathbf{x}_i .

Standar dari regresi SVM yaitu menggunakan sebuah fungsi loss (*loss function*) $L_\varepsilon(y, f(x))$ yang mendeskripsikan simpangan dari fungsi estimasi dari data aslinya. Beberapa tipe dari fungsi loss yang dapat digali dari literatur yaitu: linear, kuadratik, eksponensial, fungsi loss Huber, dan lain-lain (Raghavendra. N & Deka, 2014). Dalam konteks ini fungsi loss ε *insentitive* dapat didefinisikan sebagai berikut:

$$L_\varepsilon(y, f(x)) = \begin{cases} 0 & \text{untuk } |y - f(x)| \leq \varepsilon \\ |y - f(x)| - \varepsilon & \text{dan sebaliknya} \end{cases} \quad (2.2)$$

Dengan menggunakan fungsi loss ε *insentitive*, pertama kita dapat menemukan Fungsi $F(\mathbf{x}_i)$ yang dapat mengaproksimasi vektor y sebagai output yang aktual dan mempunyai toleransi error paling baik dari target y_i untuk semua data training, SVR membuat pemetaan dari vector masukan \mathbf{x}_i kepada target y_i dengan fungsi regresi berikut ini:

$$F(x) = w * \phi(x) + b \quad (2.3)$$

Dimana w adalah vector beban dan b adalah bias. Tujuannya adalah untuk mengestimasi parameter (w dan b) dari fungsi untuk memberikan hasil yang terbaik sesuai dengan datanya. Berdasarkan nilai paling kecil dari w , dengan memperkecil (*minimizing*) $\|w\|^2$ dapat memperlebar (*maximize*) margin, sehingga kelandaian/kedataran kurva beserta kompleksitas model dapat dipastikan. Sehingga permasalahan regresi dapat dinyatakan seperti masalah optimasi convex berikut ini:

$$\text{Fungsi minimum: } L(w, \xi) = \frac{1}{2} \|w\|^2 + c \sum_i (\xi_{2i}, \xi'_{2i}), c > 0 \quad (2.4)$$

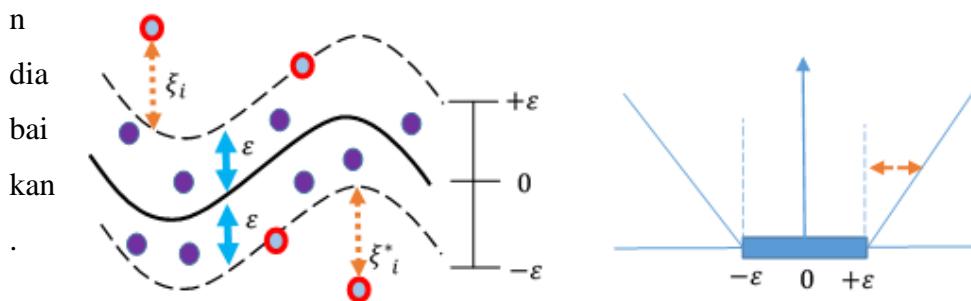
Subject to:

$$y_i - w * \phi(x_i) - b \leq \varepsilon + \xi_i \quad (2.5)$$

$$w * \phi(x_i) + b - y_i \leq \varepsilon + \xi'_i \quad (2.6)$$

$$\xi_i, \xi'_i \geq 0 \quad (2.7)$$

Dimana ξ_i dan ξ'_i adalah variable slack yang diperkenalkan untuk mengevaluasi penyimpangan sampel pelatihan diluar zona ε *insensitive* atau jarak dari titik data set pelatihan dari daerah dimana nilai error yang kurang dari nilai ε aka



Gambar 2.9 Regresi SVM dengan Zona ε Insensitif

Trade-off antara kelandaian/kedataran $F(x)$ dengan kuantitas nilai deviasi hingga lebih besar dari nilai ε ditoleransi oleh $C > 0$. C adalah konstanta positif yang mempengaruhi dalam memberikan sanksi kerugian ketika kesalahan pelatihan terjadi.

Untuk menyelesaikan masalah optimasi persamaan (4). Kita dapat membuat fungsi Lagrange dari fungsi objektif dengan memperkenalkan satu set ganda dari variabel α_i , dan α'_i untuk kendala yang sesuai. Kondisi yang optimal dieksplorasi pada titik pelana fungsi lagrange mengarah ke formulasi:

$$\begin{aligned} \max_{\alpha_i \alpha'_i} & -\frac{1}{2} \sum_{i,j=1}^n \alpha_i - \alpha'_i (\alpha_j - \alpha'_j) (\phi(x_i) \cdot \phi(x_j)) \\ & - \varepsilon \sum_{i=1}^n (\alpha_i + \alpha'_i) + \sum_{i=1}^n y_i (\alpha_i - \alpha'_i) \end{aligned} \quad (2.8)$$

$$subject to : \sum_{i=1}^n (\alpha_i - \alpha'_i) = 0$$

$$0 \leq \alpha \leq C, i = 1 \dots n$$

$$0 \leq \alpha'_i \leq C, i = 1 \dots n$$

Beberapa fungsi kernel yang populer (Liu, Tian, Chen, & Li, 2013) digunakan untuk menyelesaikan permasalahan pemetaan nonlinier dalam SVR yaitu:

$$1. \text{ Polynomial : } K(x_i, x_j) = (x \cdot y + 1)^d \quad (2.10)$$

$$2. \text{ Linear : } K(x_i, x_j) = x_i^T \cdot x_j \quad (2.11)$$

$$3. \text{ Sigmoid : } K(x_i, x_j) = \tanh(\beta x^T x_i + \beta_1) \quad (2.12)$$

$$4. \text{ Radial Basis Function (RBF) : } K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2) \quad (2.13)$$

Dalam penelitian ini digunakan kernel RBF sebagai kernel yang paling banyak digunakan oleh peneliti dunia, Dengan demikian, fungsi $F(x)$ SVR menjadi fungsi berikut:

$$F(x) = \sum_i (\alpha_i - \alpha'_i) K(x_i, x_j) + b \quad (2.12)$$

2.2.4 Algoritma Genetika

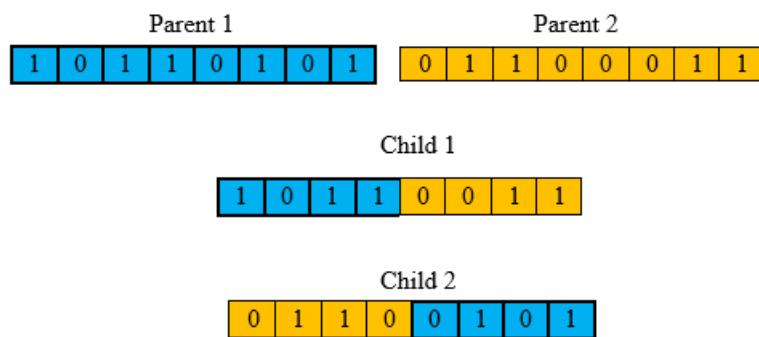
Algoritma genetika merupakan algoritma evolusioner yang paling populer (Yang, 2014) yang mana algoritma ini menggunakan prinsip dasar dari seleksi

alam yang diperkenalkan oleh Charles Darwin. Algoritma genetika diterapkan sebagai pendekatan untuk mengidentifikasi pencarian nilai dan solusi bagi berbagai permasalahan optimasi (Gorunescu, 2011). Terdapat beberapa kelebihan dari algoritma genetika dibandingkan algoritma optimasi tradisional lainnya, dua diantaranya yaitu kemampuan untuk menangani permasalahan kompleks dan paralel. Algoritma genetika dapat menganalisa berbagai macam optimasi tergantung pada fungsi objektifnya (*fitness*) apakah seimbang atau tidak seimbang, linier atau tidak linier, berkesinambungan atau tak berkesinambungan, atau dengan *random noise*. Fungsi *fitness* (Zhang, Liu, Wang, & Deng, 2011) ditunjukkan pada persamaan 2.13:

$$\text{fitness} = \sqrt{\sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (2.13)$$

Dimana \hat{y}_i merupakan nilai prediksi, dan y_i merupakan nilai asli dan dari sampel dataset. N adalah jumlah sampel total. Intisari dari algoritma genetika mencakup pengkodean/penyandian fungsi optimasi sebagai *array* berisi bit-bit atau karakter berupa string untuk menggambarkan kromosom, operasi manipulasi string dengan operator genetik, dan seleksi sesuai dengan *fitness*, dengan tujuan untuk menemukan solusi yang baik dan optimal terhadap masalah yang sedang dihadapi. Algoritma genetika memiliki tiga operator genetik utama yaitu:

1. *Crossover* yaitu proses menukar bagian dari solusi (kromosom) dengan bagian “parent” lain untuk menghasilkan jenis kromosom yang berbeda yang mungkin menjadi solusi baru untuk menyelesaikan permasalahan. Peran utamanya adalah untuk memberikan pencampuran solusi dan konvergensi dalam ruang (menghasilkan solusi yang baru).



Gambar 2.10 Proses Crossover pada Algoritma Genetika

2. Mutasi yaitu pergantian salah satu bagian solusi yang dipilih secara acak, yang meningkatkan keragaman dari populasi dan menghasilkan mekanisme untuk menghindari minimum lokal.



Gambar 2.11 Proses Mutasi pada Algoritma Genetika

3. Seleksi *fittest* atau elitisme yaitu penggunaan solusi dengan nilai *fitness* yang tinggi untuk lulus ke generasi berikutnya, yang sering dilakukan dalam hal beberapa bentuk seleksi dari solusi terbaik.

Menurut Haupt dalam (Zukhri,2014) terdapat langkah-langkah yang sering dilakukan untuk menyelesaikan permasalahan-permasalahan dalam optimasi:

1. Inisialisasi populasi.
2. Evaluasi populasi.
3. Seleksi populasi.
4. Proses penyilangan pasangan kromosom tertentu (*crossover*).
5. Evaluasi populasi baru.
6. Selama syarat belum terpenuhi ulangi dari langkah 3.

Langkah-langkah tersebut dapat direpresentasikan sebagai *pseudo code* seperti Gambar 2.12.

Fungsi Objektif $f(x)$, $x = (x_1, \dots, x_d)^T$
 Menyandikan solusi menjadi kromosom (string)

Definisikan $fitness F$ (eg, $F \propto f(x)$ untuk maksimasi)
Menghasilkan populasi awal
Inisialisasi kemungkinan crossover (p_c) dan mutasi (p_m)
While ($t < Jumlah maksimal generasi$)
 Hasilkan solusi baru dengan crossover dan mutasi
 Crossover dengan kemungkinan crossover (p_c)
 Mutasi dengan kemungkinan mutasi (p_m)
 Menerima semua solusi jika $fitness$ meningkat
 Pilih hasil yang terbaik untuk generasi selanjutnya (elitisme)
End while
Mengembalikan hasil dan visualisasi ke bentuk awal (*decode*)

Gambar 2.12 Pseudocode Penyelesaian Masalah Optimasi pada GA

2.2.5 Metode Evaluasi & Validasi

2.2.6.1 K-Fold Cross Validation

Cross validation adalah estimator yang banyak digunakan untuk mengevaluasi kesalahan prediksi (Bergmeir, Costantini, & Benítez, 2014) terutama untuk model *non-linear regression* (Borra & Di Ciaccio, 2010). *K-fold cross validation* merupakan prosedur untuk menempatkan nilai hyperparameter terbaik untuk SVM (Li, Salman, Test, Strack, & Kecman, 2013). Data yang tersedia dibagi menjadi k-set ukuran yang sama, sebagai contoh prosedur *10-fold cross validation* membagi data set menjadi 10 bagian sama besar. Selama setiap kelipatan fase training, setiap set kecil digunakan sebagai data testing sekali atur dan data selebihnya digunakan untuk training. Jumlah total sample yang salah diakumulasi untuk menghitung akurasi akhir. Sebagai contoh RBF SVM mempunyai 2 hyperparameter, nilai pinalti C dan parameter γ . Jika ada 10 perbedaan nilai C dan 5 perbedaan nilai γ , maka *10-fold cross validation* akan menjalankan proses sebanyak 50 kali, yang mana fase *training* menjalankan proses 50×10 kali, dan fase *testing* juga menjalankan proses sebanyak 50×10 kali. Dengan semua proses tersebut dapat diketahui bahwa komputasi kernel sangat memakan waktu.

2.2.6.2 RMSE

RMSE (*Root Mean Square Error*) adalah salah satu statistik indeks error yang umum digunakan dan merupakan akar kuadrat dari MSE (*Mean Squared*

Error) dan menghitung perbandingan (*quantifies*) kinerja model untuk setiap variable (Salerno et al., 2014). RMSE sangat populer untuk menilai algoritma mesin pembelajaran, termasuk algoritma yang jauh lebih canggih dari regresi linier (Conway & White, 2012).

Nilai RMSE digunakan untuk membedakan kinerja model dalam periode kalibrasi dengan periode validasi serta untuk membandingkan kinerja model individual dengan model prediksi lainnya (Hosseini, Javaherian, & Movahed, 2014). Rumusnya sebagai berikut:

$$RMSE = \sqrt{\frac{\sum_{j=1}^n (y_j - \hat{y}_j)^2}{n}} \quad (2.14)$$

2.2.6.3 Uji t Dua Sample Berpasangan (Paired Sample t-Test)

Menurut (Santoso: 2014)Metode ini digunakan untuk menguji dua sample yang berpasangan, yaitu apakah keduanya mempunyai rata-rata yang berbeda ataukah tidak. Sample berpasangan adalah sebuah sample dengan subyek yang sama namun mengalami dua perlakuan atau dua pengukuran yang berbeda. Asumsi yang digunakan pada pengujian ini yaitu data yang bertipe kuantitatif, berdistribusi normal, dan data samplenya berjumlah sedikit yaitu dibawah 30.

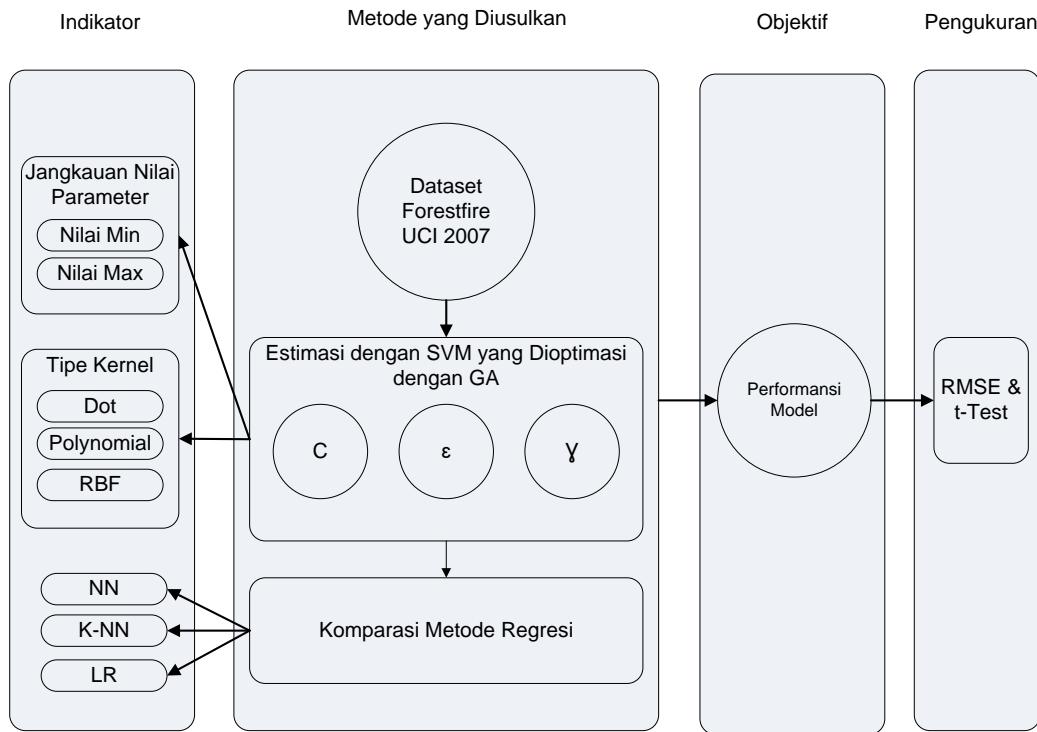
Hipotesis yang didapat dibagi menjadi dua kriteria yaitu H_0 dan H_1 , dimana H_0 menandakan tidak adanya perbedaan rata-rata antara kondisi pengukuran yang pertama dengan pengukuran atau perlakuan yang kedua, dan H_1 menandakan adanya perbedaan rata-rata antara kondisi pengukuran yang pertama dengan pengukuran yang kedua.

Pengambilan keputusan didasarkan pada dua hal yaitu berdasarkan perbandingan t hitung dengan t tabel, dan berdasarkan nilai probabilitas. Jika nilai t hitung $<$ t tabel maka H_0 diterima, sedangkan jika nilai t hitung $>$ t tabel maka H_0 ditolak. Pengambilan keputusan berdasarkan probabilitas memiliki dua ketentuan yaitu jika probabilitas $> 0,05$ maka H_0 diterima, dan jika nilai probabilitas $< 0,05$ maka H_0 ditolak.

2.2.6 Kerangka Pemikiran Penelitian

Penelitian ini mempunyai kerangka pemikiran mulai dari indikator, metode yang diusulkan, objektif, dan pengukuran. Pada penelitian ini akan digunakan

dataset kebakaran hutan dari UCI *learning repositories* tahun 2007. Metode prediksi yang diusulkan menggunakan *Support Vector Machine*, dimana dalam proses optimasi parameternya dibantu oleh Algoritma Genetika.



Gambar 2.13 Kerangka Pemikiran Penelitian

Pada Gambar 2.13 dijelaskan bahwa indikator dalam pencarian nilai parameter C , ϵ , dan γ adalah menentukan batasan nilai parameter minimum dan batasan nilai parameter maksimum pada algoritma genetika, selain itu tipe kernel pada SVM (dot, polynomial, RBF) juga menjadi indikator untuk mencari nilai akurasi tertinggi pada estimasi kebakaran hutan. Sedangkan metode-metode regresi terkait (NN, k-NN, LR) juga menjadi indikator untuk membandingkan akurasi antara metode yang diusulkan dengan metode regresi yang ada. Tujuan atau objektif dari penelitian ini adalah mendapatkan performansi dari masing-masing metode yang diterapkan, dan untuk mengevaluasi keakuratan hasil estimasi, digunakan pengukuran RMSE dan uji t-Test.

BAB III

METODE PENELITIAN

3.1 Perancangan Penelitian

Penelitian telah didefinisikan oleh pendidikan tinggi dewan pendanaan untuk inggris sebagai penyelidikan yang dilakukan untuk mendapatkan pengetahuan dan pemahaman (Dawson, 2009). Menurut (Dawson, 2009) ada empat metode penelitian yang paling umum digunakan yaitu: *action research*, *experiment*, *case study*, dan *survey*. Pada penelitian ini menggunakan metode *experiment*, yaitu penelitian yang melibatkan penyelidikan kepada beberapa variable menggunakan tes tertentu yang dikendalikan sendiri oleh peneliti. Metode yang digunakan untuk memprediksi adalah *Support Vector Machine* dengan algoritma genetika yang akan digunakan untuk melakukan optimasi parameter, dengan langkah-langkah sebagai berikut:

1. Pengumpulan Data

Pada tahapan ini dijelaskan asal usul data yaitu bagaimana dan darimana data penelitian didapatkan. Pada tahap ini ditentukan data yang akan diproses.

2. Pengolahan Data Awal

Pengolahan data awal meliputi pembersihan data, dan transformasi data kedalam bentuk yang dibutuhkan.

3. Metode yang Diusulkan

Setelah melakukan pengumpulan dan pengolahan data, maka tahap selanjutnya adalah menentukan metode, dimana metode ini merupakan rangkaian kegiatan untuk melakukan penelitian dan pengujian terhadap data.

4. Experimen dan pengujian model

Pada tahap ini dilakukan eksperimen dan pengujian model terhadap data yang sudah diolah. Pada tahap ini dilakukan percobaan dengan menerapkan algoritma yang tersedia pada data.

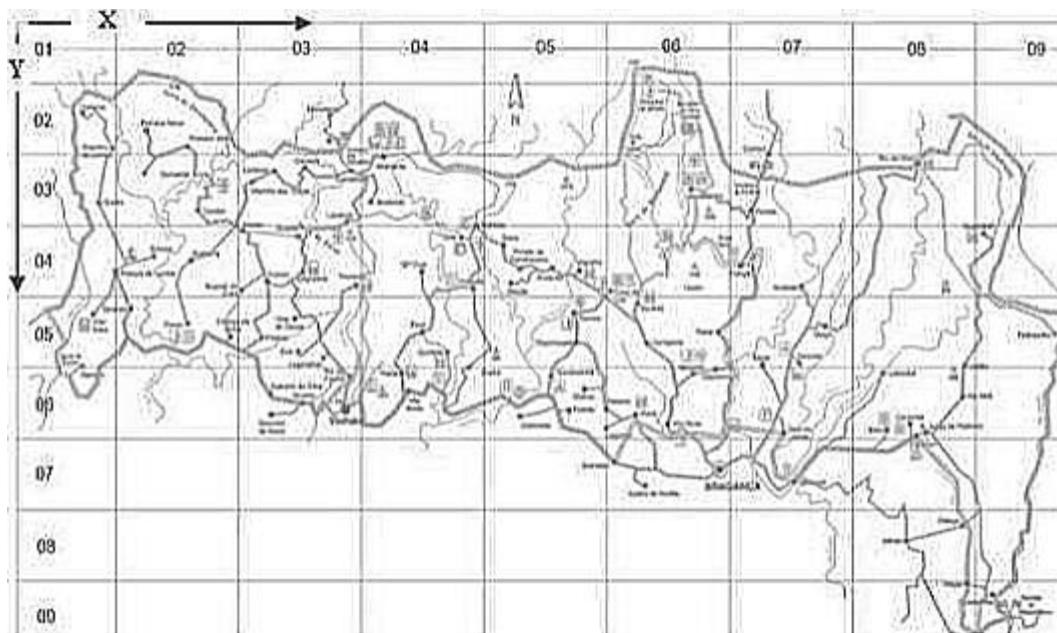
5. Evaluasi

Tahap evaluasi merupakan tahap yang terakhir dari kegiatan penelitian, dimana dalam tahap ini hasil dari tahapan eksperimen dan pengujian model sebagai evaluasi.

3.2 Pengumpulan Data

Data yang digunakan pada penelitian ini merupakan data sekunder. Data sekunder adalah data yang tidak diperoleh langsung dari obyek penelitian, melainkan telah dikumpulkan oleh pihak lain.

Data sekunder yang digunakan dalam penelitian ini yaitu data catatan kebakaran hutan sejak Januari tahun 2000 sampai dengan Desember tahun 2003. Data ini diambil dari UCI *learning repository* yang dapat diunduh melalui situs <https://archive.ics.uci.edu/ml/datasets/Forest+Fires>. Data ini berasal dari taman alam Montesinho, Portugal yang terdiri dari 13 attribut yaitu sumbu x, dan y, bulan, hari, data meteorologi (*temp, relative humidity, wind, rain*), dan 4 indeks



cuaca kebakaran (FFMC, DMC, DC, ISI), serta luas hektar area yang terbakar.

Sumber: (Cortez & Morais, 2007)

Gambar 3.1 Peta Taman Alam Montesinho

Pada Gambar 3.1 sumbu x dan sumbu y merupakan koordinat terjadinya kebakaran hutan, kemudian hari dan bulan terjadinya kebakaran hutan, data meteorologi yaitu: temperatur, kelembaban relatif, angin, dan hujan, selanjutnya terdapat empat komponen dari *Forest Fire Weather Index* (FWI) yaitu: *Fine Fuel*

Moisture Code (FFMC) merupakan indikator untuk bahan yang mudah terbakar dan mudah membentuk pengapian di dalam hutan, *Duff Moisture Code* (DMC) merupakan indikasi dari konsumsi bahan bakar pada kayu, dan *Drought Code* (DC) merupakan indikator dari efek kemarau pada bahan bakar hutan, *Initial Spread Index* (ISI) yaitu indikator tingkat penyebaran api dan indikator kesulitan pengendalian api. Dari data yang tersedia, telah ditentukan area yang terbakar sebagai *output* dan 12 atribut lainnya merupakan *input*. jumlah *record* dataset berjumlah 517 *record*. Data kebakaran hutan dapat dilihat pada Tabel 3.1.

Tabel 3.1 Dataset Asli Foresfire UCI Learning Repository (2007)

X	Y	month	day	FFMC	DMC	DC	ISI	temp	RH	wind	Rain	Area
7	5	Mar	fri	86.2	26.2	94.3	5.1	8.2	51	6.7	0	0
7	4	Oct	tue	90.6	35.4	669.1	6.7	18	33	0.9	0	0
7	4	Oct	sat	90.6	43.7	686.9	6.7	14.6	33	1.3	0	0
8	6	Mar	fri	91.7	33.3	77.5	9	8.3	97	4	0.2	0
8	6	Mar	sun	89.3	51.3	102.2	9.6	11.4	99	1.8	0	0
8	6	Aug	sun	92.3	85.3	488	14.7	22.2	29	5.4	0	0
8	6	Aug	mon	92.3	88.9	495.6	8.5	24.1	27	3.1	0	0
Selengkapnya lihat di lampiran												

3.3 Pengolahan Data Awal

3.3.1 Penghapusan Atribut yang Tidak Perlu

Pada data *forest fire* beberapa atribut perlu dihapus seperti atribut temporal yaitu bulan dan hari (*month and day*), dan atribut spatial yaitu koordinat X, dan Y , yang mana atribut tersebut dianggap tidak relevan (Cortez & Morais, 2007) setelah dilakukan seleksi fitur pada dataset *forest fire*.

Tabel 3.2 Dataset Forestfire Setelah Penghapusan Atribut

FFMC	DMC	DC	ISI	temp	RH	wind	rain	Area
86.2	26.2	94.3	5.1	8.2	51	6.7	0	0
90.6	35.4	669.1	6.7	18	33	0.9	0	0
90.6	43.7	686.9	6.7	14.6	33	1.3	0	0

91.7	33.3	77.5	9	8.3	97	4	0.2	0
89.3	51.3	102.2	9.6	11.4	99	1.8	0	0
92.3	85.3	488	14.7	22.2	29	5.4	0	0
92.3	88.9	495.6	8.5	24.1	27	3.1	0	0
Selengkapnya lihat pada lampiran								

3.3.2 Transformasi Data

Atribut area yang terbakar pada dataset memiliki kecenderungan positif (Cortez & Morais, 2007), oleh karena itu untuk mengurangi kecenderungan dan meningkatkan kesimetrisan maka fungsi logaritma $y = \ln(x + 1)$ diterapkan pada atribut area sebagai transformasi umum yang cenderung meningkatkan hasil regresi untuk target condong kanan. Kemudian area yang telah ditransformasi akan dijadikan target prediksi atau label.

Contoh:

$$\text{Area} = 0,36$$

$$y = \ln(0,36 + 1) \quad (3.1)$$

$$y = \ln(1,36)$$

$$y = 0,307485$$

Tabel 3.3 Dataset Forest Fire Setelah Transformasi Label

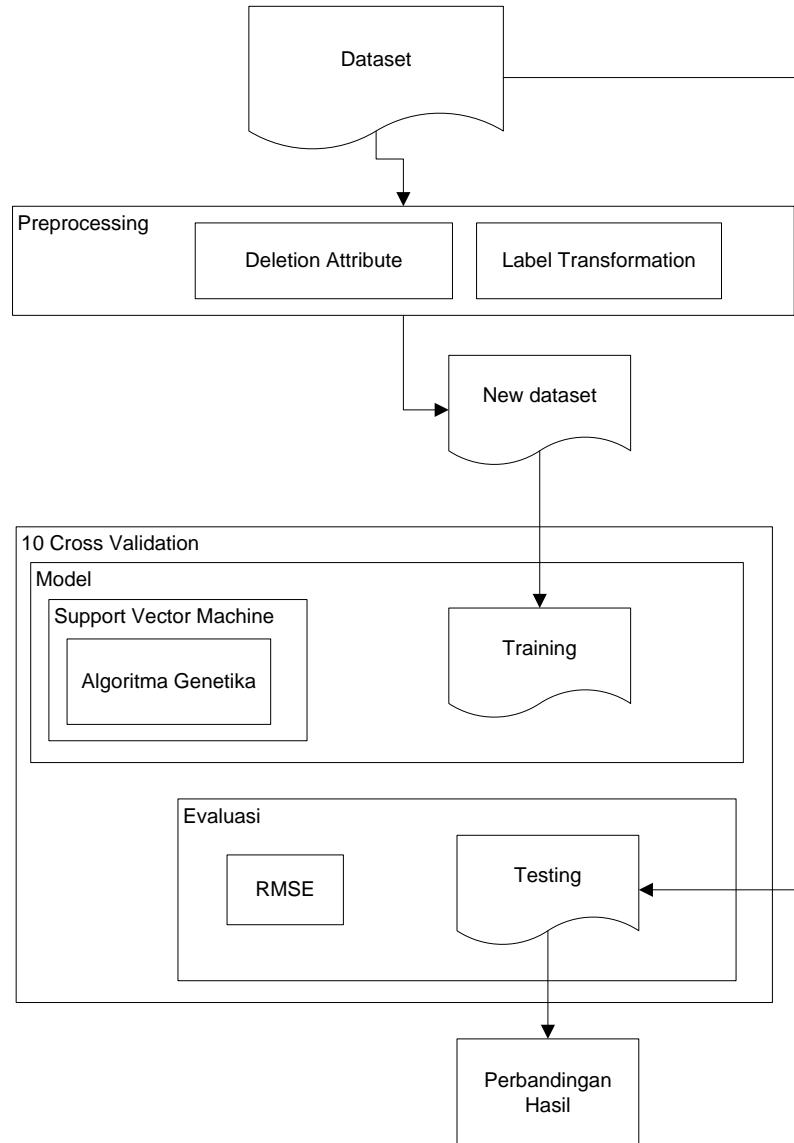
FFMC	DMC	DC	ISI	temp	RH	wind	rain	ln(area+1)
93.5	139.4	594.2	20.3	17.6	52	5.8	0	0
92.4	124.1	680.7	8.5	17.2	58	1.3	0	0
90.9	126.5	686.5	7	15.6	66	3.1	0	0
85.8	48.3	313.4	3.9	18	42	2.7	0	0.307485
91	129.5	692.6	7	21.7	38	2.2	0	0.357674
90.9	126.5	686.5	7	21.9	39	1.8	0	0.385262
95.5	99.9	513.3	13.2	23.3	31	4.5	0	0.438255
Selengkapnya lihat pada lampiran								

3.3.3 Penghapusan Data ganda (*Remove Duplicate*)

Berdasarkan data yang telah terkumpul, data yang bersifat duplikat perlu dibersihkan, awalnya terdapat 517 *record*, setelah dilakukan pengurangan terhadap data yang ganda, terdapat 513 data yang unik.

3.4 Metode yang Diusulkan

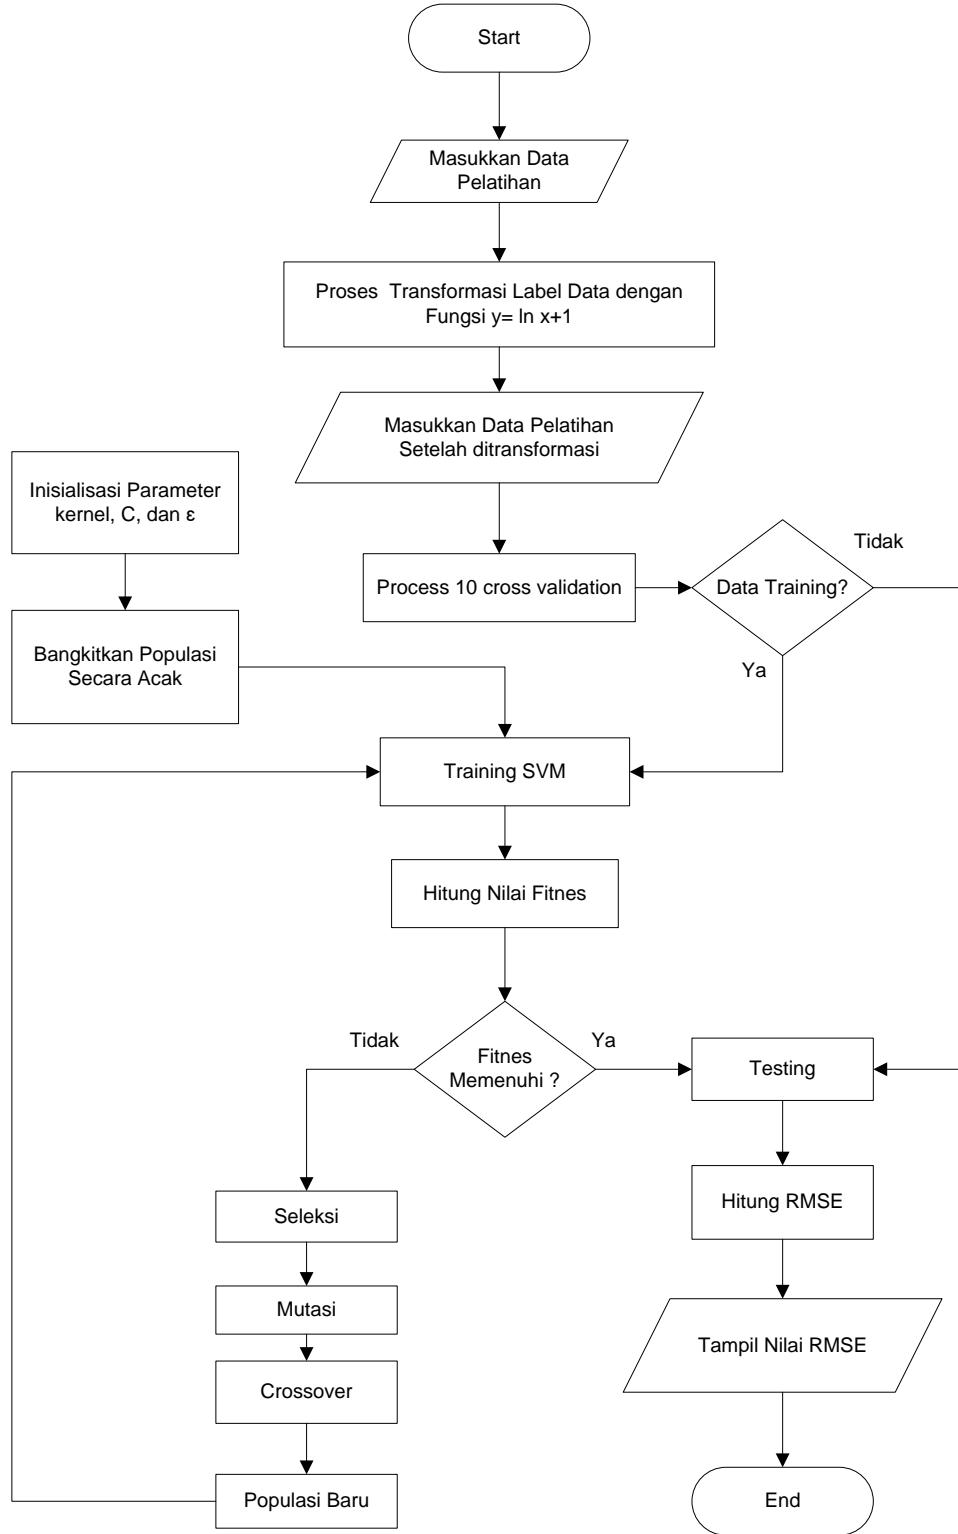
Metode yang diusulkan yaitu dengan menerapkan algoritma genetika untuk pencarian nilai parameter untuk diterapkan pada proses training SVM. Bermula dengan menerapkan *10-fold cross validation* untuk membagi dataset menjadi data training dan data testing, kemudian menerapkan algoritma genetika untuk mencari nilai parameter C , ε , dan γ untuk diterapkan pada proses *training* dan *testing*, kemudian model prediksi yang dihasilkan oleh SVM pada proses training diterapkan untuk menguji data *testing*, kemudian hasil evaluasi model dibandingkan dengan RMSE. Metode usulan dapat dilihat pada Gambar 3.2.



Gambar 3.2 Metode Penelitian yang Diusulkan

Metode penelitian yang diusulkan yaitu diawali dengan mengurangi atribut yang tidak perlu (*deletion attribut*), kemudian melakukan transformasi attribut label yang berguna untuk meningkatkan kesimetrisan dan mengurangi kecondongan, kemudian akan terbentuk dataset dengan label baru hasil transformasi label sebelumnya, dataset baru yang terbentuk kemudian dipecah menggunakan *10-fold cross validation* yaitu dengan membagi 90% data untuk proses *training* dan 10% data lainnya untuk proses *testing*. Sebelum data dilatih dan diuji batasan nilai *minimum* dan *maximum* parameter C , ϵ , γ dimasukkan pada algoritma pencari GA. Selanjutnya data dilatih dan diuji menggunakan model SVM dengan nilai parameter yang sudah dioptimalkan oleh GA untuk

diper cobakan pada model SVM dengan kernel RBF, polynomial, dan dot untuk menentukan kernel mana yang memiliki rata-rata nilai RMSE yang paling kecil. Selanjutnya kernel dengan nilai rata-rata terkecil akan dipergunakan pada model SVM+GA untuk dibandingkan dengan model regresi lainnya. Setelah melakukan *training* dan *testing*, SVM juga menghitung nilai *error* menggunakan RMSE dimana semakin nilainya kecil maka nilai error semakin mendekati nilai nol. Langkah-langkah pada algoritma genetika untuk mengoptimasi nilai parameter pada SVM dapat dilihat pada Gambar 3.3.



Gambar 3.3 Diagram Algoritma Genetika pada Support Vector Machine (SVM+GA)

3.5 Eksperimen dan Pengujian Model

Tahapan eksperimen pada penelitian ini adalah:

1. Menyiapkan dataset untuk eksperimen
2. Merancang arsitektur SVM dengan nilai parameter C , ε , γ yang berbeda.
3. Melakukan *training* dan *testing* terhadap SVM dengan kernel yang berbeda (dot, polynomial, Radial) dan mencatat nilai RMSE
4. Mendesain arsitektur SVM dan GA dengan memasukkan batasan nilai minimal dan batasan nilai maksimal parameter pada GA untuk mendapatkan nilai parameter SVM yang optimal
5. Melakukan *training* dan *testing* terhadap SVM dan GA dengan kernel yang berbeda dan mencatat nilai RMSE
6. Melakukan *training* dan *testing* terhadap metode regresi lainnya yaitu (NN, k-NN, dan *linear regression*)
7. Mengembangkan aplikasi

Eksperimen yang dilakukan pada penelitian ini menggunakan komputer personal (*PC*) untuk melakukan proses perhitungan terhadap model yang diusulkan. Spesifikasi komputer yang digunakan ditunjukan oleh Tabel 3.4.

Tabel 3.4 Spesifikasi Komputer Pengolah Data

Processor	Intel Core i3
Memory	4 GB
Harddisk	500 GB
Sistem Operasi	Windows 8.1
Aplikasi	Rapidminer 5.3

3.6 Evaluasi dan Validasi Hasil

Pada tahap ini akan dilakukan proses pengujian model yang dihasilkan oleh tool *Rapidminer 5.0* dengan mengevaluasi perbandingan hasil RMSE seluruh eksperimen dengan *10-fold cross validation* yaitu eksperimen SVM dengan nilai parameter default (tanpa optimasi), experimen SVM dengan parameter yang telah dioptimasi dengan GA, dan eksperimen dengan model regresi lainnya (*neural network*, k-NN, *linear regression*).

BAB IV

HASIL DAN PEMBAHASAN

4.1 Hasil Eksperimen dan Pengujian Model

Hasil dalam penelitian dilakukan dalam tiga metode yaitu dengan menggunakan metode *support vector machine* dengan kernel (dot, polynomial, RBF) tanpa menggunakan optimasi parameter dengan algoritma genetika, metode *support vector machine* dengan kernel (dot, polynomial, RBF) yang dipadu dengan algoritma genetika untuk mengoptimasi parameter dalam SVM (Gu et al., 2011), dan hasil eksperimen menggunakan algoritma lainnya seperti *linear regression* (LR) seperti yang dilakukan oleh (Lira et al., 2014), *neural network* (Tiryaki et al., 2014), dan k-NN (Lee et al., 2014).

4.1.1 Hasil Eksperimen dan Pengujian Model dengan Kernel Dot

Pengujian dilakukan dengan menggunakan tipe kernel dot pada *support vector machine* yang dipadu dengan algoritma genetika untuk mencari nilai parameter C , ε , dan γ yang optimal sesuai batasan yang ditentukan, seperti yang ditunjukkan oleh Table 4.1.

Tabel 4.1 Hasil Eksperimen dengan Kernel Dot

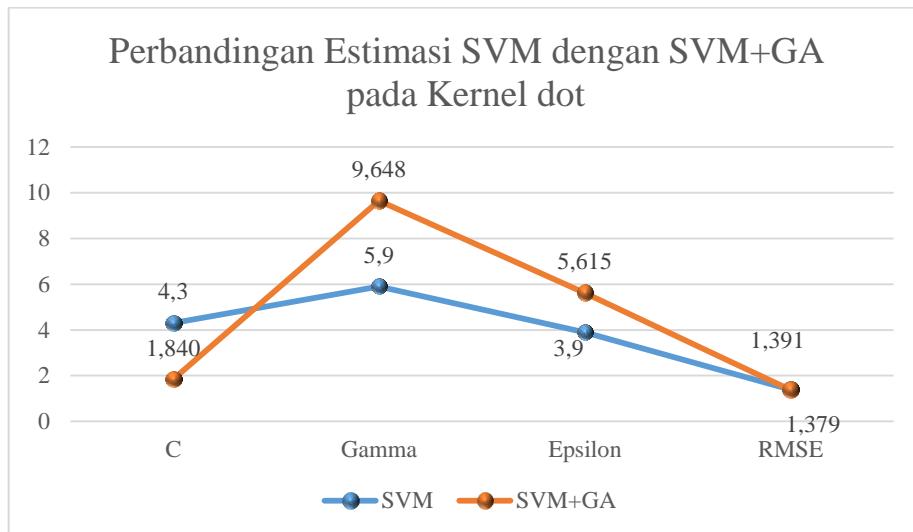
γ			C			ε		
MIN	MAX	OPTIMAL	MIN	MAX	OPTIMAL	MIN	MAX	OPTIMAL
0	0.5	0.308	-1	-0.5	-0.890	0	0.5	0.263
0	1	0.939	-1	1	-0.888	0	1	0.685
0	5	4.663	-1	5	-0.618	0	5	3.443
0	7	4.363	-1	7	5.906	0	7	3.952
0	10	1.840	-1	10	9.648	0	10	5.615
0	100	18.261	-1	100	96.812	0	100	56.201
0.001	0.1	0.001	-1	0.1	0.002	0.001	0.1	0.057
0.01	0.1	0.035	-1	0.1	0.014	0.01	0.1	0.100
0.5	10	1.143	-0.5	10	1.821	0.5	10	5.089
0.5	100	18.670	-0.5	100	96.828	0.5	100	56.420

Eksperimen dilakukan sebanyak 10 kali dengan variasi perubahan jenjang nilai parameter. Indikator untuk mengetahui hasil terbaik ditunjukkan oleh besarnya nilai RMSE untuk masing-masing pengujian pada data *testing*.

Tabel 4.2 Hasil Pengujian Kernel Dot pada SVM dan SVM+GA

	SVM	SVM+GA
C	4.3	1,840
Gamma (γ)	5.9	9,648
Epsilon (ε)	3.9	5,615
RMSE	1.391	1.379

Hasil terbaik yang ditunjukkan pada Tabel 4.2 yaitu nilai RMSE terkecil yang diperoleh dari percobaan SVM menggunakan kernel dot dan dengan menggunakan algoritma genetika untuk memperoleh nilai parameter yang optimal yaitu parameter $C=1,840$, $\gamma = 9,648$, dan $\varepsilon = 5,615$ dengan nilai RMSE=1,379. Sedangkan nilai RMSE yang diperoleh dari percobaan SVM menggunakan kernel dot tanpa menggunakan algoritma untuk mengoptimasi parameter lebih besar daripada nilai RMSE SVM menggunakan optimasi parameter yaitu sebesar 3.088. perbandingan RMSE dapat ditunjukkan pada Gambar 4.1.

**Gambar 4.1 Grafik Perbandingan Estimasi SVM dengan SVM+GA Menggunakan Kernel Dot**

4.1.2 Hasil Eksperimen dan Pengujian Model dengan Kernel Polynomial

Pengujian dilakukan dengan menggunakan tipe kernel polynomial pada *support vector machine* yang dipadu dengan algoritma genetika untuk mencari nilai parameter C , ε , dan γ yang optimal sesuai batasan yang ditentukan, seperti yang ditunjukkan oleh Tabel 4.3.

Tabel 4.3 Hasil Eksperimen dengan Kernel Polynomial

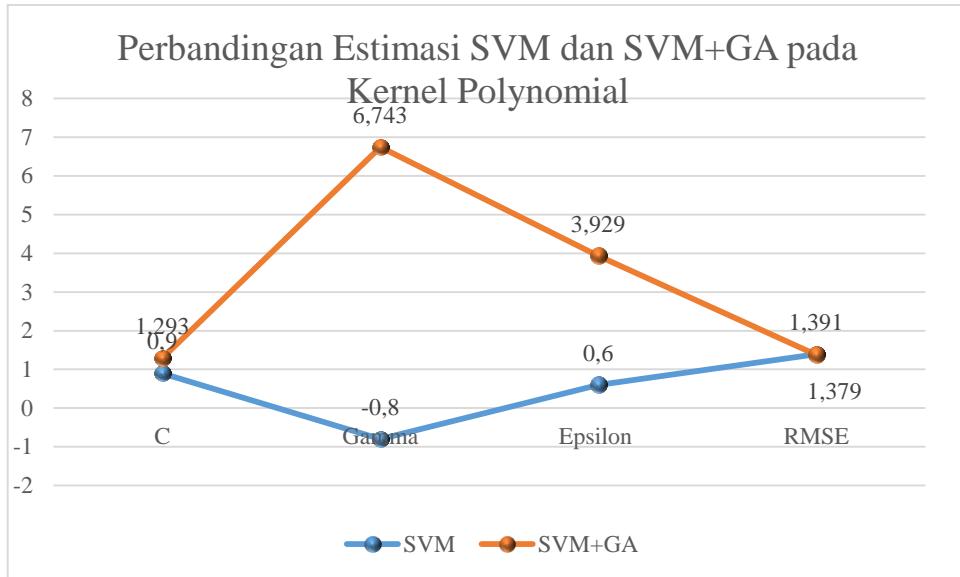
γ			C			ε		
MIN	MAX	OPTIMAL	MIN	MAX	OPTIMAL	MIN	MAX	OPTIMAL
0	0.5	0.311	-1	-0.5	-0.513	0	0.5	0.292
0	1	0.953	-1	1	-0.881	0	1	0.687
0	5	0.369	-1	5	0.316	0	5	2.405
0	7	1.293	-1	7	6.743	0	7	3.929
0	10	1.840	-1	10	9.648	0	10	5.615
0	100	18.261	-1	100	96.812	0	100	56.201
0.001	0.1	0.089	-1	0.1	-0.940	0.001	0.1	0.082
0.01	0.1	0.090	-1	0.1	-0.940	0.01	0.1	0.085
0.5	10	2.249	-0.5	10	9.664	0.5	10	5.834
0.5	100	18.670	-0.5	100	96.828	0.5	100	56.420

Eksperimen dilakukan sebanyak 10 kali dengan variasi perubahan jenjang nilai parameter. Indikator untuk mengetahui hasil terbaik ditunjukkan oleh besarnya nilai RMSE untuk masing-masing pengujian pada data *testing*.

Tabel 4.4 Hasil Pengujian Kernel Polynomial pada SVM dan SVM+GA

	SVM	SVM+GA
C	0.9	1.293
Gamma (γ)	-0.8	6.743
Epsilon (ε)	0.6	3.929
RMSE	1.391	1.379

Hasil terbaik yang ditunjukkan pada Tabel 4.4 yaitu nilai RMSE terkecil yang diperoleh dari percobaan SVM menggunakan kernel polynomial dan dengan menggunakan algoritma genetika untuk memperoleh nilai parameter yang optimal yaitu parameter C=1,293, $\gamma = 6,743$, dan $\varepsilon = 3,929$ dengan nilai RMSE=1,379. Sedangkan nilai RMSE yang diperoleh dari percobaan SVM menggunakan kernel dot tanpa menggunakan algoritma untuk mengoptimasi parameter lebih besar daripada nilai RMSE SVM menggunakan optimasi parameter yaitu sebesar 1,737. perbandingan RMSE dapat ditunjukkan pada Gambar 4.2.



Gambar 4.2 Grafik Perbandingan Estimasi SVM dengan SVM+GA Menggunakan Kernel Polynomial

4.1.3 Hasil Eksperimen dan Pengujian Model Dengan Kernel RBF

Pengujian dilakukan dengan menggunakan tipe kernel RBF pada SVM yang dipadu dengan algoritma genetika untuk mencari nilai parameter C , ε , dan γ yang optimal sesuai batasan yang ditentukan, seperti yang ditunjukkan oleh Tabel 4.5.

Tabel 4.5 Hasil Eksperimen dengan Kernel RBF

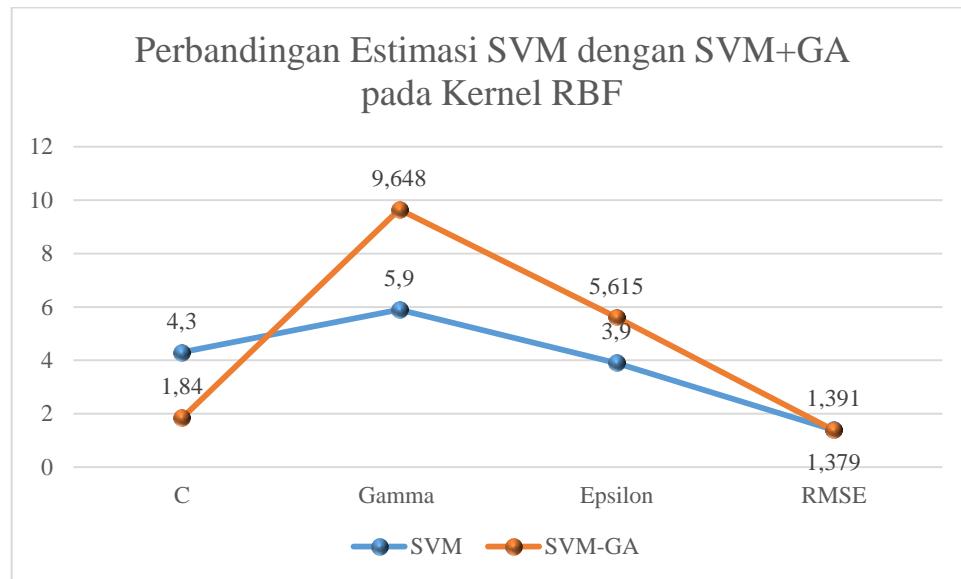
γ			C			ε		
MIN	MAX	OPTIMAL	MIN	MAX	OPTIMAL	MIN	MAX	OPTIMAL
0	0.5	0.091	-1	-0.5	-0.503	0	0.5	0.297
0	1	0.952	-1	1	-0.885	0	1	0.679
0	5	1.216	-1	5	1.410	0	5	0.939
0	7	4.370	-1	7	5.914	0	7	3.944
0	10	1.840	-1	10	9.648	0	10	5.615
0	100	18.261	-1	100	96.812	0	100	56.201
0.001	0.1	0.027	-1	0.1	-0.735	0.001	0.1	0.053
0.01	0.1	0.031	-1	0.1	-0.558	0.01	0.1	0.026
0.5	10	2.249	-0.5	10	9.664	0.5	10	5.834
0.5	100	18.670	-0.5	100	96.828	0.5	100	56.420

Eksperimen dilakukan sebanyak 10 kali dengan variasi perubahan jenjang nilai parameter. Indikator untuk mengetahui hasil terbaik ditunjukkan oleh besarnya nilai RMSE untuk masing-masing pengujian pada data *testing*.

Tabel 4.6 Hasil Pengujian Kernel RBF pada SVM dan SVM+GA

	SVM	SVM+GA
C	4.3	1.840
Gamma (γ)	5.9	9.648
Epsilon (ε)	3.9	5.615
RMSE	1.391	1.379

Hasil terbaik yang ditunjukkan pada Tabel 4.6 yaitu nilai RMSE terkecil yang diperoleh dari percobaan SVM menggunakan kernel RBF dan dengan menggunakan algoritma genetika untuk memperoleh nilai parameter yang optimal yaitu parameter $C=1,840$, $\gamma = 9,648$, dan $\varepsilon = 5,615$ dengan nilai RMSE=1,379. Sedangkan nilai RMSE yang diperoleh dari percobaan SVM menggunakan kernel dot tanpa menggunakan algoritma untuk mengoptimasi parameter lebih besar daripada nilai RMSE SVM menggunakan optimasi parameter yaitu sebesar 1,521. perbandingan RMSE dapat ditunjukan pada Gambar 4.3.

**Gambar 4.3 Grafik Perbandingan Estimasi SVM dengan SVM+GA Menggunakan Kernel RBF**

4.1.4 Hasil Eksperimen dan Pengujian dengan Model Regresi Lainnya

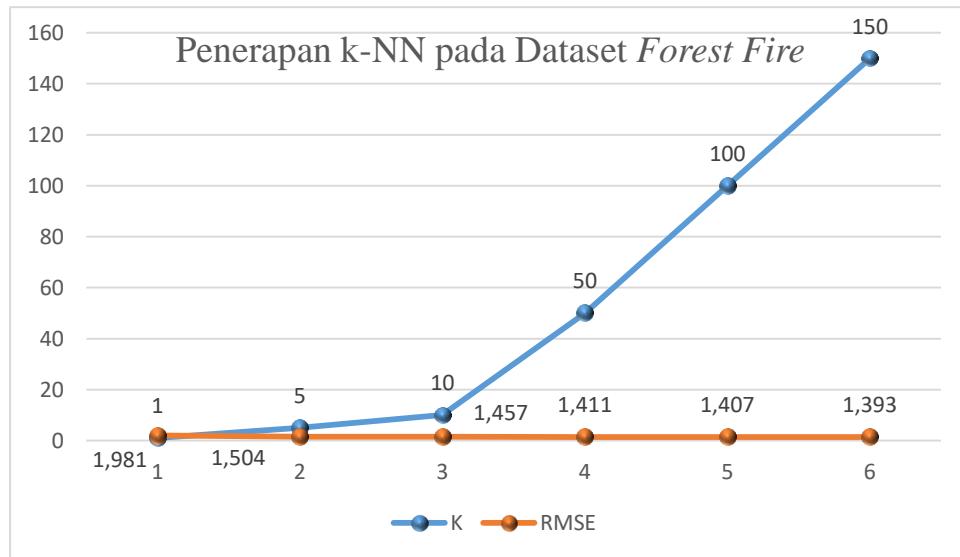
4.1.4.1 Model k-NN

Pada eksperimen ini pengujian dan pencarian nilai RMSE dilakukan dengan menerapkan model k-NN seperti yang diterapkan pada penelitian (Lee et al., 2014) pada dataset *forestfire* dengan merubah jenjang nilai k untuk mendapatkan nilai RMSE terkecil seperti pada Tabel 4.7.

Tabel 4.7 Hasil Percobaan dengan k-NN

K	RMSE
1	1.981
5	1.504
10	1.457
50	1.411
100	1.407
150	1.393

Pada Tabel 4.7 Eksperimen dilakukan sebanyak enam kali dengan variasi perubahan jenjang nilai k dengan nilai RMSE terkecil didapat dengan memasukkan nilai k sebesar 50 seperti yang ditunjukkan pada Gambar 4.4.



Gambar 4.4 Grafik Eksperimen dan Pengujian dengan k-NN

Grafik pada Gambar 4.4 menunjukkan bahwa terjadi penurunan nilai RMSE ketika nilai k disetting dengan nilai 150.

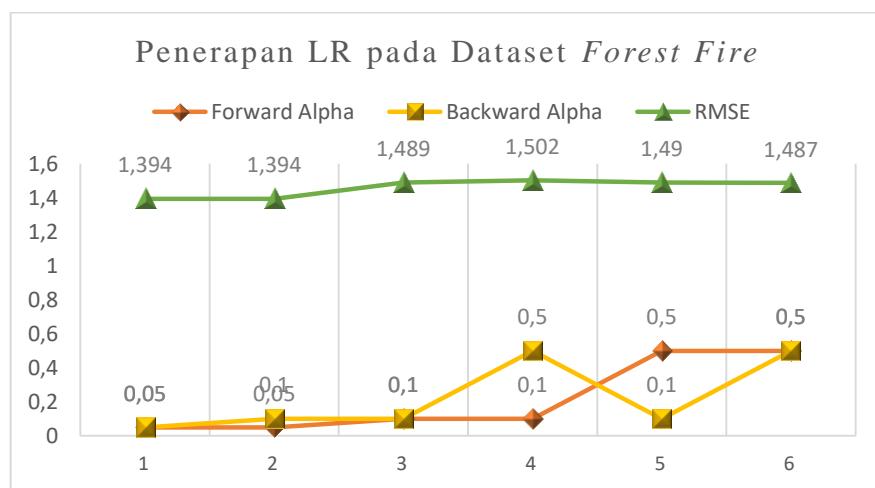
4.1.4.2 Model Linear Regression

Pengujian dan pencarian nilai RMSE dilakukan dengan menerapkan model *linear regression* seperti yang digunakan pada penelitian (Lira et al., 2014) pada dataset *forest fire* dengan merubah nilai jenjang forward alpha dan backward alpha seperti pada Tabel 4.8.

Tabel 4.8 Hasil Percobaan dengan Linear Regression

Forward Alpha	Backward Alpha	RMSE
0.05	0.05	1.394
0.05	0.1	1.394
0.1	0.1	1.489
0.1	0.5	1.502
0.5	0.1	1.49
0.5	0.5	1.487

Pada Tabel 4.8 Eksperimen dilakukan sebanyak enam kali dengan variasi perubahan jenjang nilai *forward alpha* dan *backward alpha* dengan nilai RMSE terkecil didapat dengan memasukkan nilai k sebesar *forward alpha* sebesar 0.05 dan *backward alpha* sebesar 0.5 atau 0.1 seperti yang ditunjukkan pada Gambar 4.5.



Gambar 4.5 Grafik Eksperimen dan Pengujian dengan Linear Regression

Grafik pada Gambar 4.5 menunjukkan bahwa terjadi penurunan nilai RMSE ketika nilai *forward alpha* disetting dengan nilai 0.05, dan nilai *backward alpha* sebesar 0.1.

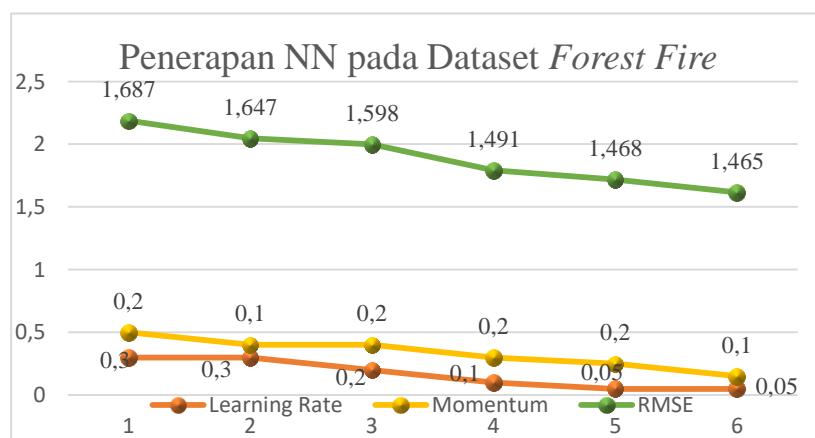
4.1.4.3 Model Neural Network

Pengujian dan pencarian nilai RMSE dilakukan dengan menerapkan model *neural network* seperti yang digunakan pada penelitian (Tiryaki et al., 2014) pada dataset *forestfire* dengan merubah *learning rate* dan *momentum* untuk mendapatkan nilai RMSE terkecil seperti pada Tabel 4.9.

Tabel 4.9 Hasil Eksperimen dengan Neural Network

Learning Rate	Momentum	RMSE
0.3	0.2	1.687
0.3	0.1	1.647
0.2	0.2	1.598
0.1	0.2	1.491
0.05	0.2	1.468
0.05	0.1	1.465

Eksperimen dilakukan sebanyak enam kali dengan variasi perubahan jenjang nilai *learning rate* dan *momentum*. Nilai RMSE yang terkecil didapat dengan engatur nilai *learning rate*=0,05 dan *momentum*=0,1. Perbandingan RMSE pada percobaan NN diperlihatkan oleh Gambar 4.6.



Gambar 4.6 Grafik Perbandingan Nilai RMSE pada Percobaan Neural Network

Grafik pada Gambar 4.6 menunjukkan bahwa terjadi penurunan nilai RMSE ketika nilai *learning rate* disetting dengan nilai 0.05, dan nilai *momentum* sebesar 0.1.

4.2 Pembahasan

4.2.1 Perbandingan RMSE SVM dan SVM+GA Menggunakan Kernel Dot

Pada tahap ini dilakukan uji t dua sampel berpasangan dengan membandingkan nilai rata-rata RMSE pada data uji (*testing*) SVM dengan kernel dot yang dioptimasi secara manual dengan SVM dengan kernel dot yang telah dioptimasi dengan GA. Uji beda dilakukan dengan menggunakan metode statistik untuk menguji hipotesa:

H_0 : Tidak ada perbedaan nilai rata-rata RMSE antara model SVM dengan kernel dot yang dioptimasi secara manual dengan model SVM dengan kernel dot yang telah dioptimasi dengan GA.

H_1 : Ada perbedaan nilai rata-rata RMSE antara model SVM dengan kernel dot yang dioptimasi secara manual dengan model SVM dengan kernel dot yang telah dioptimasi dengan GA.

Tabel 4.10 Perbandingan RMSE SVM dan SVM+GA pada Kernel Dot

No	SVM Manual Parameter Setting				SVM by GA Parameter Setting			
	γ	C	ε	RMSE	γ	C	ε	RMSE
1	0.3	-0.5	0.2	2.921	0.308	-0.890	0.263	2.711
2	0.9	-0.8	0.6	3.565	0.939	-0.888	0.685	3.186
3	4.6	-0.6	3.4	2.562	4.663	-0.618	3.443	2.562
4	4.3	5.9	3.9	1.391	4.363	5.906	3.952	1.382
5	1.8	9.6	5.6	1.391	1.840	9.648	5.615	1.379
6	18	96	56	1.391	18.261	96.812	56.201	1.379
7	0.001	0.002	0.05	1.560	0.001	0.002	0.057	1.537
8	0.03	0.01	0.1	1.546	0.035	0.014	0.100	1.534
9	1.1	1.8	5	1.391	1.143	1.821	5.089	1.379
10	18	96	56	1.391	18.670	96.828	56.420	1.379

Berdasarkan hasil percobaan yang tertera pada Tabel 4.10 dilakukan analisis statistik uji beda *Paired sample t-Test*, hasil yang diperoleh dicantumkan pada Tabel 4.11.

Tabel 4.11 Hasil Uji Beda Statistik SVM dan SVM+GA dengan Kernel Dot*t-Test: Paired Two Sample for Means*

	<i>Variable</i>	<i>Variable</i>
	<i>1</i>	<i>2</i>
Mean	1.9109	1.8428
Variance	0.643116	0.481873
Observations	10	10
Pearson Correlation	0.996192	
Hypothesized Mean Difference	0	
df	9	
t Stat	1.710268	
P(T<=t) one-tail	0.060691	
t Critical one-tail	1.833113	
P(T<=t) two-tail	0.121382	
t Critical two-tail	2.262157	

Berdasarkan hasil uji t dua sampel berpasangan pada Tabel 4.11 dapat diambil hipotesa berdasarkan perbandingan t hitung dan t tabel, juga berdasarkan nilai probabilitas. Nilai t hitung yang diwakili oleh t stat sebesar 1.710268, dan nilai t tabel yang diwakili oleh nilai t *critical two tail* sebesar 2.262157 maka dapat dipastikan nilai t hitung < t tabel yang artinya H_0 diterima dan H_1 ditolak, sedangkan diketahui nilai probabilitas sebesar 0.121382, maka dapat dipastikan bahwa nilai probabilitas > 0,05 yang artinya tidak terdapat perbedaan yang signifikan dari rata-rata RMSE model SVM dengan kernel dot yang dioptimasi secara manual dengan model SVM dengan kernel dot yang dioptimasi oleh algoritma genetika.

4.2.2 Perbandingan Model SVM dan SVM+GA Menggunakan Kernel Polynomial

Pada tahap ini dilakukan uji t dua sampel berpasangan dengan membandingkan nilai rata-rata RMSE pada data uji (*testing*) SVM dengan kernel polynomial yang dioptimasi secara manual dengan SVM dengan kernel dot yang telah dioptimasi dengan GA. Uji beda dilakukan dengan menggunakan metode statistik untuk menguji hipotesa:

H_0 : Tidak ada perbedaan nilai rata-rata RMSE antara model SVM dengan kernel polynomial yang dioptimasi secara manual dengan model SVM dengan kernel dot yang telah dioptimasi dengan GA

H_1 : Ada perbedaan nilai rata-rata RMSE antara model SVM dengan kernel polynomial yang dioptimasi secara manual dengan model SVM dengan kernel polynomial yang telah dioptimasi dengan GA.

Tabel 4.12 Perbandingan RMSE SVM dan SVM+GA pada kernel Polynomial

No	SVM Manual Parameter Setting				SVM by GA Parameter Setting			
	γ	C	ε	RMSE	γ	C	ε	RMSE
1	0.3	-0.5	0.2	1.913	0.311	-0.513	0.292	1.490
2	0.9	-0.8	0.6	1.391	0.953	-0.881	0.687	1.412
3	0.3	0.3	2.4	2.270	0.369	0.316	2.405	1.772
4	1.2	6.7	3.9	1.391	1.293	6.743	3.929	1.379
5	1.8	9.6	5.6	1.391	1.840	9.648	5.615	1.379
6	18	96	56	1.391	18.261	96.812	56.201	1.379
7	0.08	-0.9	0.08	1.882	0.089	-0.940	0.082	1.614
8	0.09	-0.9	0.08	1.882	0.090	-0.940	0.085	1.579
9	2.2	9.6	5.8	1.391	2.249	9.664	5.834	1.379
10	18	96	56	1.391	18.670	96.828	56.420	1.379

Berdasarkan hasil percobaan yang tertera pada Tabel 4.12 dilakukan analisis statistik uji beda (*Paired sample t-Test*) , hasil yang diperoleh dicantumkan pada Tabel 4.13.

Tabel 4.13 Hasil Uji Beda Statistik SVM dan SVM+GA dengan Kernel Polynomial

t-Test: Paired Two Sample for Means

	<i>Variable</i>	<i>Variable</i>
	<i>1</i>	<i>2</i>
Mean	1.6293	1.4762
Variance	0.106602	0.018734
Observations	10	10
Pearson Correlation	0.958101	
Hypothesized Mean Difference	0	
df	9	
t Stat	2.429748	
P(T<=t) one-tail	0.018999	
t Critical one-tail	1.833113	
P(T<=t) two-tail	0.037998	
t Critical two-tail	2.262157	

Berdasarkan hasil uji t dua sampel berpasangan pada Tabel 4.13 dapat diambil hipotesa berdasarkan perbandingan t hitung dan t tabel, juga berdasarkan nilai probabilitas. Nilai t hitung yang diwakili oleh t stat sebesar 2.429748, dan nilai t tabel yang diwakili oleh nilai t *critical two tail* sebesar 2.262157 maka dapat dipastikan nilai t hitung > t tabel yang artinya H_0 ditolak dan H_1 diterima, sedangkan diketahui nilai probabilitas sebesar 0.037998, maka dapat dipastikan bahwa nilai probabilitas < 0,05 yang artinya terdapat perbedaan yang signifikan dari rata-rata RMSE model SVM dengan kernel polynomial yang dioptimasi secara manual dengan model SVM dengan kernel polynomial yang dioptimasi oleh algoritma genetika.

4.2.3 Perbandingan Model SVM dan SVM+GA Menggunakan Kernel RBF

Pada tahap ini dilakukan uji t dua sampel berpasangan dengan membandingkan nilai rata-rata RMSE pada data uji (*testing*) SVM dengan kernel polynomial yang dioptimasi secara manual dengan SVM dengan kernel dot yang telah dioptimasi dengan GA. Uji beda dilakukan dengan menggunakan metode statistik untuk menguji hipotesa:

H_0 : Tidak ada perbedaan nilai rata-rata RMSE antara model SVM dengan kernel RBF yang dioptimasi secara manual dengan model SVM dengan kernel RBF yang telah dioptimasi dengan GA

H_1 : Ada perbedaan nilai rata-rata RMSE antara model SVM dengan kernel RBF yang dioptimasi secara manual dengan model SVM dengan kernel RBF yang telah dioptimasi dengan GA.

Tabel 4.14 Perbandingan RMSE SVM dan SVM+GA pada kernel RBF

No	SVM Manual Parameter Setting				SVM by GA Parameter Setting			
	γ	C	ε	RMSE	γ	C	ε	RMSE
1	0.09	-0.5	0.3	1.502	0.091	-0.503	0.297	1.460
2	0.9	-0.8	0.6	1.440	0.952	-0.885	0.679	1.413
3	1.2	1.4	0.9	1.430	1.216	1.410	0.939	1.413
4	4.3	5.9	3.9	1.391	4.370	5.914	3.944	1.386
5	1.8	9.6	5.6	1.391	1.840	9.648	5.615	1.379
6	18	96	56	1.391	18.261	96.812	56.201	1.379
7	0.02	-0.7	1.4	1.470	0.027	-0.735	0.053	1.495
8	0.03	-0.5	0.05	1.521	0.031	-0.558	0.026	1.496
9	2.2	9.6	5.8	1.391	2.249	9.664	5.834	1.379
10	18	96	56	1.391	18.670	96.828	56.420	1.379

Berdasarkan hasil percobaan yang tertera pada Tabel 4.14 dilakukan analisis statistic uji beda *Paired sample t-Test*, hasil yang diperoleh dicantumkan pada Tabel 4.15.

Tabel 4.15 Hasil Uji Beda Statistik SVM dan SVM+GA dengan Kernel RBF

t-Test: Paired Two Sample for Means

	<i>Variable</i>	<i>Variable</i>
	<i>1</i>	<i>2</i>
Mean	1.4318	1.4179
Variance	0.002526	0.002326
Observations	10	10
Pearson Correlation	0.938956	
Hypothesized Mean Difference	0	
df	9	
t Stat	2.537358	
P(T<=t) one-tail	0.015924	
t Critical one-tail	1.833113	
P(T<=t) two-tail	0.031849	
t Critical two-tail	2.262157	

Berdasarkan hasil uji t dua sampel berpasangan pada Tabel 4.13 dapat diambil hipotesa berdasarkan perbandingan t hitung dan t tabel, juga berdasarkan nilai probabilitas. Nilai t hitung yang diwakili oleh t stat sebesar 2.537358, dan nilai t tabel yang diwakili oleh nilai t *critical two tail* sebesar 2.262157 maka dapat dipastikan nilai t hitung > t tabel yang artinya H_0 ditolak dan H_1 diterima, sedangkan diketahui nilai probabilitas sebesar 0.031849, maka dapat dipastikan bahwa nilai probabilitas < 0,05 yang artinya terdapat perbedaan yang signifikan dari rata-rata RMSE model SVM dengan kernel RBF yang dioptimasi secara manual dengan model SVM dengan kernel RBF yang dioptimasi oleh algoritma genetika.

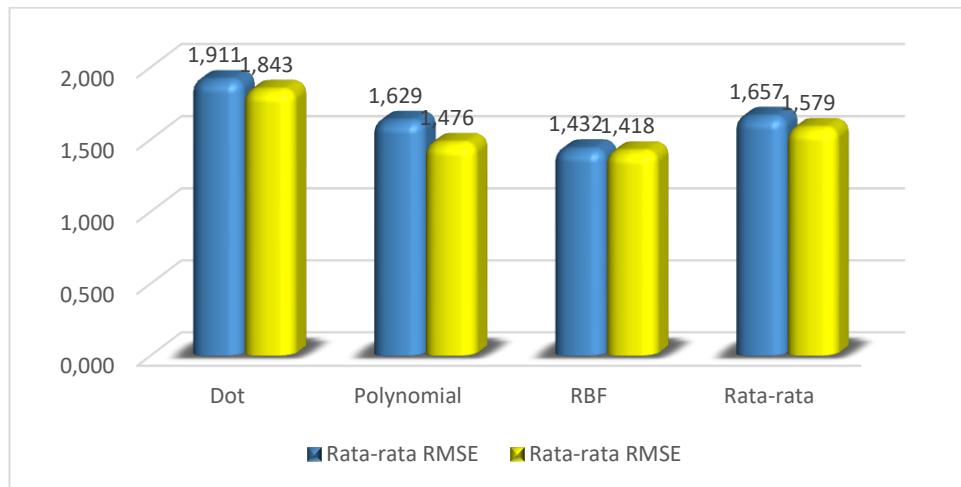
4.2.4 Perbandingan Nilai Rata-Rata RMSE pada SVM dan SVM+GA

Berdasarkan hasil eksperimen pada penelitian ini, diperoleh perbedaan nilai rata-rata nilai RMSE pada pengujian model SVM sebelum dan sesudah dilakukan optimasi parameter SVM dengan menggunakan algoritma genetika pada dataset *forestfire*. Tingkat perbandingan rata-rata nilai RMSE dapat dilihat pada Tabel 4.16.

Tabel 4.16 Perbandingan Rata-rata Nilai RMSE SVM dan SVM+GA

Tipe Kernel	Rata-rata RMSE	
	SVM	SVM+GA
Dot	1.911	1.843
Polynomial	1.629	1.476
RBF	1.432	1.418
Rata-rata	1.657	1.579

Berdasarkan data yang diperoleh dari Tabel 4.16 dapat ditampilkan grafik perbandingan rata-rata SVM dengan SVM+GA seperti pada Gambar 4.7.

**Gambar 4.7 Perbandingan Nilai Rata-rata RMSE SVM dengan SVM+GA**

Pada Gambar 4.7 dapat disimpulkan bahwa nilai rata-rata RMSE pada model SVM+GA dengan kernel (dot, polynomial, dan RBF) lebih kecil dibandingkan dengan nilai rata-rata RMSE pada model SVM dengan kernel (dot, polynomial, RBF) tanpa optimasi parameter.

Perbandingan signifikansi antara dua model ditunjukkan oleh uji t sampel berpasangan untuk model SVM tanpa optimasi parameter dengan model SVM yang dioptimasi oleh GA dengan berbagai kernel (dot, polynomial, RBF). Berdasarkan hasil uji t menunjukkan bahwa tidak terdapat perbedaan yang signifikan terhadap percobaan SVM(dot) dengan SVM(dot)+GA, namun percobaan SVM dan SVM+GA pada kernel polynomial dan RBF terdapat

perbedaan yang signifikan. Berdasarkan hasil perbandingan nilai RMSE dari ketiga kernel, penerapan kernel RBF pada model SVM dan SVM+GA menghasilkan nilai RMSE yang paling kecil yaitu untuk SVM(1.432) dan SVM+GA(1.418).

4.2.5 Perbandingan SVM+GA dengan Model Regresi Lainnya

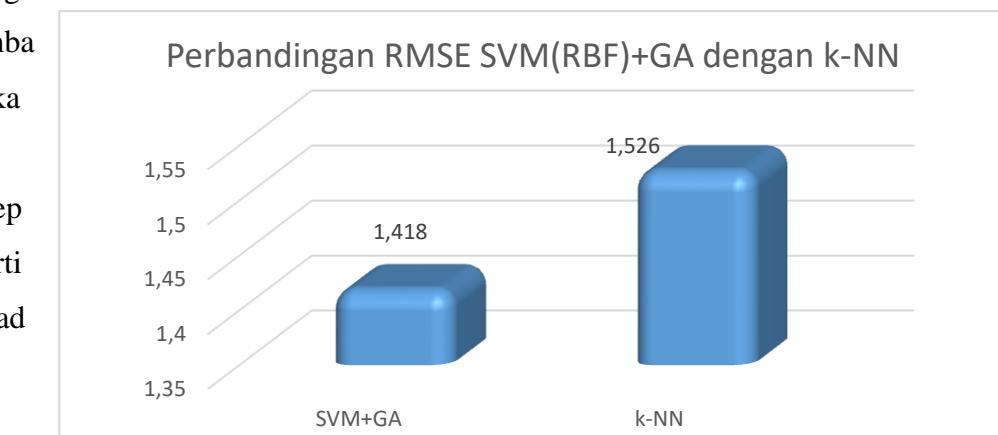
4.2.5.1 Perbandingan SVM+GA dengan k-NN

Pada tahap ini dilakukan perbandingan nilai RMSE pada data uji(*testing*) SVM dengan kernel RBF setelah dioptimasi dengan GA, dan data uji pada model regresi k-NN.

Tabel 4.17 Perbandingan RMSE SVM(RBF)+GA dengan k-NN

k-NN		SVM(RBF)+GA			
K	RMSE	γ	C	ε	RMSE
1	1.981	1.840	9.648	5.615	1.379
5	1.504	18.261	96.812	56.201	1.379
10	1.457	0.027	-0.735	0.053	1.495
50	1.411	0.031	-0.558	0.026	1.496
100	1.407	2.249	9.664	5.834	1.379
150	1.393	18.670	96.828	56.420	1.379
Rata-rata k-NN	1.526	Rata-rata SVM+GA		1.418	

Pada Tabel 4.17 dapat dilihat bahwa rata-rata nilai RMSE pada model SVM(RBF)+GA lebih kecil dibandingkan rata-rata RMSE k-NN sehingga dapat digunakan.



Gambar 4.8.

Gambar 4.8 Grafik Perbedaan Nilai RMSE SVM(RBF)+GA dengan k-NN

Gambar 4.8 jelas menggambarkan perbandingan nilai RMSE antara model SVM+GA dengan model k-NN.

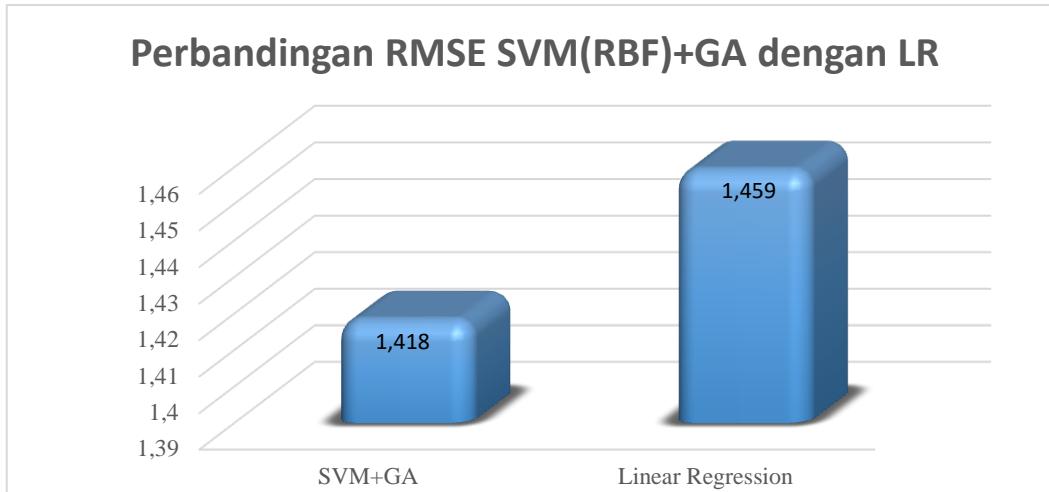
4.2.5.2 Perbandingan SVM+GA dengan Linear Regression

Pada tahap ini dilakukan perbandingan nilai RMSE pada data uji(*testing*) SVM dengan kernel RBF setelah dioptimasi dengan GA, dan data uji pada model *linear regression*.

Tabel 4.18 Perbandingan Rata-rata RMSE SVM(RBF)+GA dengan Linear Regression

SVM(RBF)+GA				Linear Regression		
γ	C	ε	RMSE	Forward Alpha	Backward Aplha	RMSE
1.840	9.648	5.615	1.379	0.05	0.05	1.394
18.261	96.812	56.201	1.379	0.05	0.1	1.394
0.027	-0.735	0.053	1.495	0.1	0.1	1.489
0.031	-0.558	0.026	1.496	0.1	0.5	1.502
2.249	9.664	5.834	1.379	0.5	0.1	1.49
18.670	96.828	56.420	1.379	0.5	0.5	1.487
Rata-rata SVM+GA			1.418	Rata-rata LR		1.459

Pada Tabel 4.18 dapat dilihat bahwa rata-rata nilai RMSE model SVM(RBF)+GA lebih kecil dibandingkan rata-rata nilai RMSE model LR,



sehingga dapat digambarkan berupa grafik seperti pada Gambar 4.9.

Gambar 4.9 Grafik Perbandingan Nilai RMSE SVM(RBF)+GA dengan Linear Regression

Gambar 4.9 sangat jelas menggambarkan perbandingan nilai RMSE antara model SVM(RBF)+GA dengan model LR.

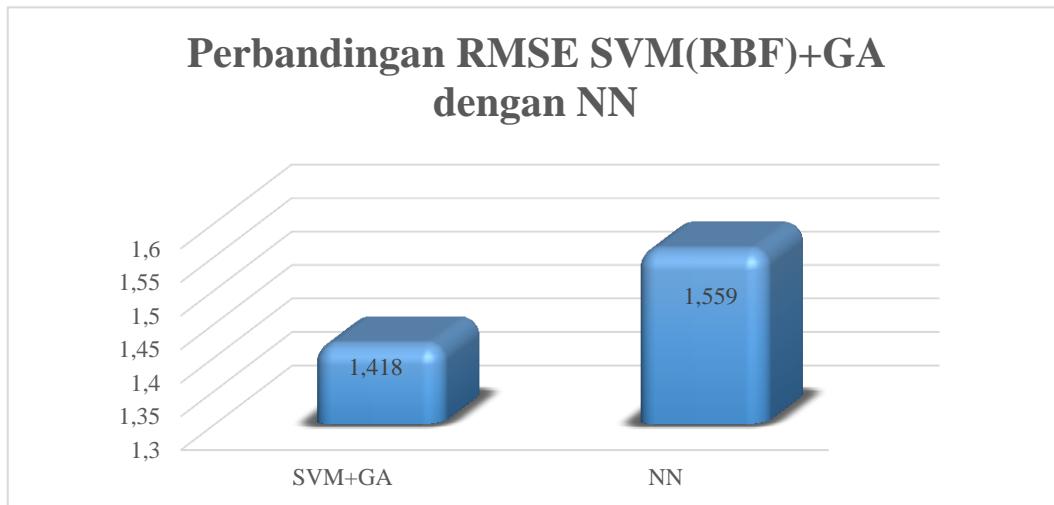
4.2.5.3 Perbandingan SVM+GA dengan Neural Network

Pada tahap ini dilakukan Perbandingan nilai RMSE pada data uji (*testing*) SVM dengan kernel RBF setelah dioptimasi dengan GA, dan data uji pada model *neural network*.

Tabel 4.19 Perbandingan RMSE SVM(RBF)+GA dengan Neural Network

SVM(RBF) + GA				Neural Network		
γ	C	ε	RMSE	Learning Rate	Momentum	RMSE
1.840	9.648	5.615	1.379	0.3	0.2	1.687
18.261	96.812	56.201	1.379	0.3	0.1	1.647
0.027	-0.735	0.053	1.495	0.2	0.2	1.598
0.031	-0.558	0.026	1.496	0.1	0.2	1.491
2.249	9.664	5.834	1.379	0.05	0.2	1.468
18.670	96.828	56.420	1.379	0.05	0.1	1.465
Rata-rata SVM+GA			1.418	Rata-rata NN		1.559

Pada Tabel 4.19 dapat dilihat bahwa nilai rata-rata RMSE model SVM(RBF)+GA lebih kecil dibandingkan nilai rata-rata RMSE model Neural Network, sehingga dapat pula digambarkan seperti grafik pada Gambar 4.10.



Gambar 4.10 Grafik Perbandingan Nilai Rata-rata SVM(RBF)+GA dengan Neural Network

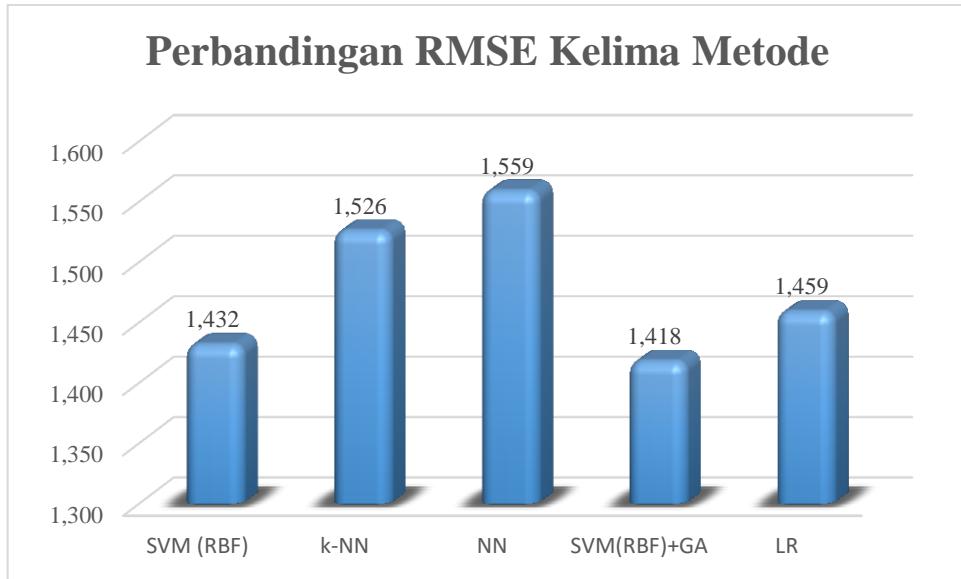
4.2.6 Perbandingan Nilai Rata-rata RMSE Terbaik SVM, SVM+GA, LR,NN, dan k-NN

Berdasarkan hasil eksperimen pada penelitian ini, diperoleh perbedaan nilai rata-rata nilai RMSE pada pengujian model SVM , SVM(RBF)+GA, LR, NN, dan k-NN pada dataset *forestfire*. Tingkat perbandingan rata-rata nilai RMSE dapat dilihat pada Tabel 4.23.

Tabel 4.20 Perbandingan Nilai Rata-rata RMSE 5 Metode

Model	RMSE
SVM (RBF)	1.432
k-NN	1.526
NN	1.559
LR	1.459
SVM+GA	1.418

Berdasarkan data yang diperoleh dari Tabel 4.20 dapat ditampilkan grafik perbandingan rata-rata kelima model seperti pada Gambar 4.11.



Gambar 4.11 Perbandingan Nilai Rata-rata RMSE Kelima Metode

k-NN memiliki algoritma yang sederhana dan kinerja prediksi yang tinggi terhadap berbagai aplikasi, karena kelebihannya k-NN dianggap sebanding dengan model yang lebih kompleks seperti ANN atau SVM (Lee et al., 2014), Namun Gambar 4.11 menjelaskan bahwa perbandingan nilai rata-rata RMSE k-NN jauh lebih besar dari pada nilai rata-rata RMSE metode SVM(RBF). Selain itu, nilai RMSE k-NN juga jauh lebih besar dibandingkan dengan metode SVM(RBF)+GA yang diusulkan. Hasil pada penelitian ini secara otomatis bertolak belakang dengan pendapat (Lee et al., 2014) mengingat nilai akurasi k-NN yang buruk terhadap estimasi kebakaran hutan.

Penggunaan NN menjadi semakin populer dibanyak model prediksi (Kaytez, Taplamacioglu, Cam, & Hardalac, 2015). Pada penelitian (Tiryaki et al., 2014) ANN juga terbukti dapat menyelesaikan permasalahan estimasi melebihi MLR. Namun Gambar 4.11 pada penelitian ini menunjukkan NN menghasilkan akurasi yang buruk sementara metode LR seperti dalam (Lira et al., 2014) menghasilkan nilai akurasi yang baik ketika diterapkan pada dataset *forest fire*. Hal ini dapat dilihat berdasarkan perbandingan nilai rata-rata RMSE yaitu nilai rata-rata RMSE LR jauh lebih kecil jika dibandingkan dengan nilai rata-rata RMSE NN. Perbandingan nilai RMSE NN dengan SVM(RBF)+GA juga sangat timpang, nilai rata-rata RMSE NN sangat jauh lebih besar dari pada nilai rata-rata RMSE SVM(RBF)+GA. Selain itu nilai rata-rata RMSE LR hampir sebanding dengan

nilai rata-rata RMSE SVM(RBF) dan SVM(RBF)+GA dengan selisih nilai RMSE hanya sebesar 0.027 dan 0.041 saja. Oleh karena itu penelitian ini secara otomatis mendukung penelitian yang dilakukan oleh (Lira et al., 2014) sekaligus bertolak belakang dengan hasil penelitian (Tiryaki et al., 2014)(Yilmaz & Kaynar, 2011).

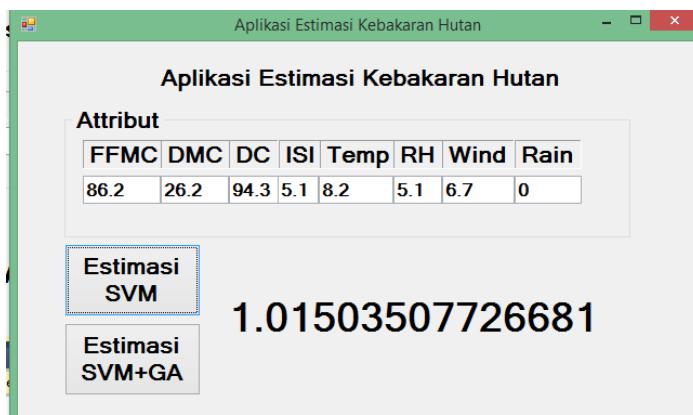
Berdasarkan hasil percobaan yang telah dilakukan, metode yang telah diusulkan jauh lebih unggul jika dibandingkan dengan hasil percobaan (Cortez & Morais, 2007). Pada penelitian sebelumnya, penerapan *sequential minimize optimization algorithm* (SMO) untuk mengoptimasi parameter C , ε , dan γ pada SVM berhasil melebihi hasil prediksi metode regresi lainnya yaitu *naïve predictor* (NP) *multiple regression* (MR), *decision tree* (DT), *random forest* (RF), dan *neural network* (NN) dengan nilai RMSE SVM+SMO sebesar 12.71. Oleh karena itu Gambar 4.11 pada penelitian ini sesuai dengan penyataan (Cortez & Morais, 2007) bahwa SVM dengan optimasi parameter dapat mengungguli metode-metode regresi lainnya.

4.2.7 Pengembangan Aplikasi Metode Terbaik dari Support Vector Machine dan Support Vector Machine + Genetic Algorithm

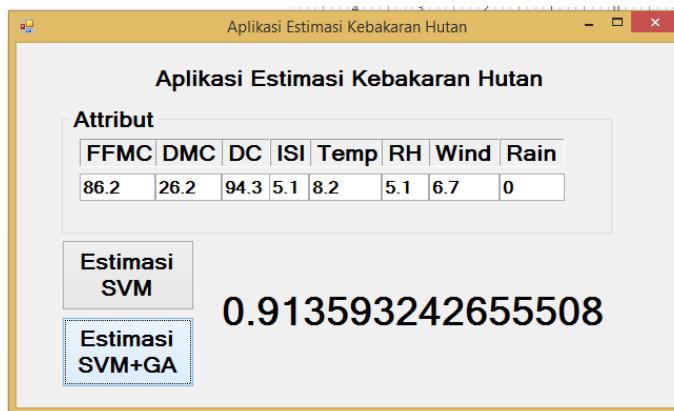
Berdasarkan hasil eksperimen didapatkan metode terbaik dari metode support vector machine dan support vector machine + genetic algorithm yang dikembangkan menjadi sebuah aplikasi sederhana. Pengujian model pada salah satu sample pada data forest fire seperti pada Tabel 4.21.

Tabel 4.21 Sample Dataset Forest Fire

FFMC	DMC	DC	ISI	temp	RH	wind	rain
86.2	26.2	94.3	5.1	8.2	51	6.7	0



Gambar 4.12 Hasil Pengujian Model Terbaik SVM



Gambar 4.13 Hasil Pengujian Aplikasi Model Terbaik SVM+GA

Hasil pengujian aplikasi ditunjukkan pada Gambar 4.13 dengan model terbaik SVM dan pada Gambar 4.14 dengan model terbaik SVM+GA . Hasil pengujian aplikasi menunjukkan bahwa hasil estimasi kebakaran hutan dengan model SVM+GA lebih akurat dibandingkan dengan model SVM saja.

4.2.8 Source Code Model Terbaik SVM

Berdasarkan hasil eksperimen didapatkan model terbaik dengan metode SVM, kemudian model tersebut dikembangkan menjadi sebuah aplikasi dengan *source code* sebagai berikut:

```
using System;
using System.Collections.Generic;
using System.ComponentModel;
using System.Data;
using System.Drawing;
using System.Linq;
using System.Text;
using System.Windows.Forms;

namespace Estimasi_Kebakaran_Hutan
{
    public partial class Form1 : Form
    {
        public Form1()
```

```

{
    InitializeComponent();
}

private void groupBox1_Enter(object sender, EventArgs e)
{

}

private void bsvm_Click(object sender, EventArgs e)
{
    larea.Text = "";
    double ffmc = Convert.ToDouble(tffmc.Text);
    double dmc = Convert.ToDouble(tdmc.Text);
    double dc = Convert.ToDouble(tdc.Text);
    double isi = Convert.ToDouble(tisi.Text);
    double temperatur = Convert.ToDouble(ttemp.Text);
    double rh = Convert.ToDouble(trh.Text);
    double wind = Convert.ToDouble(twind.Text);
    double rain = Convert.ToDouble(train.Text);
    double l = 1.75946019;
    double rbfffmc = (-1*(-2.02087875-ffmc)*(-2.02087875-ffmc));
    double kffmc = Math.Exp(rbfffmc);
    double fxffmc = l * kffmc;
    double rbfdfmc = (-1 * (-1.68591331 - dmc) * (-1.68591331 -
        dmc));
    double kdmc = Math.Exp(rbfdfmc);
    double fxdmc = l * kdmc;
    double rbfdfc = (-1 * (-1.78044169 - dc) * (-1.78044169 - dc));
    double kdc = Math.Exp(rbfdfc);
    double fxdc = l * kdc;
    double rbfisi = (-1 * (-1.73908882 - isi) * (-1.73908882 -
        isi));
    double kisi = Math.Exp(rbfisi);
    double fxisi = l * kisi;
    double rbftemp = (-1 * (-1.22205823 - temperatur) * (-
        1.22205823 - temperatur));
    double ktemp = Math.Exp(rbftemp);
    double fxtemp = l * ktemp;
    double rbfrh = (-1 * (-0.81514302 - rh) * (-0.81514302 - rh));
    double krh = Math.Exp(rbfrh);
    double fxrh = l * krh;
    double rbfwind = (-1 * (0.269508534 - wind) * (0.269508534 -
        wind));
    double kwind = Math.Exp(rbfwind);
    double fxwind = l * kwind;
    double rbfrain = (-1 * (0 - rain) * (0 - rain));
    double krain = Math.Exp(rbfrain);
    double fxrain = l * krain;
    double area = Math.Log((fxffmc + fxdmc + fxdc + fxisi + fxtemp
        + fxrh + fxwind + fxrain)+1);
    larea.Text = Convert.ToString(area);
}

private void bsvmga_Click(object sender, EventArgs e)
{
    larea.Text = "";
    double ffmc = Convert.ToDouble(tffmc.Text);
    double dmc = Convert.ToDouble(tdmc.Text);
}

```

```

        double dc = Convert.ToDouble(tdc.Text);
        double isi = Convert.ToDouble(tisi.Text);
        double temperatur = Convert.ToDouble(ttemp.Text);
        double rh = Convert.ToDouble(trh.Text);
        double wind = Convert.ToDouble(twind.Text);
        double rain = Convert.ToDouble(train.Text);
        double l = 9.41095317;
        double rbffffmc = (-1.840909 * (-0.805959472469295 - ffmc) * (-0.805959472469295 - ffmc));
        double kffmc = Math.Exp(rbffffmc);
        double fffffmc = l * kffmc;
        double rbfldmc = (-1.840909 * (-1.32332557 - dmc) * (-1.32332557 - dmc));
        double kdmc = Math.Exp(rbfldmc);
        double fxldmc = l * kdmc;
        double rbfldc = (-1.840909 * (-1.83047676 - dc) * (-1.83047676 - dc));
        double kdc = Math.Exp(rbfldc);
        double fxdc = l * kdc;
        double rbfisi = (-1.840909 * (-0.86094557 - isi) * (-0.86094557 - isi));
        double kisi = Math.Exp(rbfisi);
        double fxisi = l * kisi;
        double rbftemp = (-1.840909 * (-1.84264015 - temperatur) * (-1.84264015 - temperatur));
        double ktemp = Math.Exp(rbftemp);
        double fxtemp = l * ktemp;
        double rbfrh = (-1.840909 * (0.411724347 - rh) * (0.411724347 - rh));
        double krh = Math.Exp(rbfrh);
        double fxrh = l * krh;
        double rbfwind = (-1.840909 * (1.498614417 - wind) * (1.498614417 - wind));
        double kwind = Math.Exp(rbfwind);
        double fxwind = l * kwind;
        double rbfrain = (-1.840909 + ((0-rain)*(0-rain)));
        double krain = Math.Exp(rbfrain);
        double fxrain = l * krain;
        double area = fffffmc + fxldmc + fxdc + fxisi + fxtemp + fxrh + fxwind + fxrain;
        double areatrans = Math.Log(area+1);
        larea.Text = Convert.ToString(areatrans);
    }
}

```

BAB V

PENUTUP

5.1 Kesimpulan

Dalam penelitian ini algoritma genetika untuk mengoptimasi nilai parameter pada SVM seperti pada (Gu et al., 2011) diterapkan untuk memprediksi luas area pada kebakaran hutan. Beberapa eksperimen dilakukan dengan cara membandingkan hasil RMSE yang dihasilkan. Diantaranya algoritma genetika diterapkan pada 30 kali percobaan pada kernel dot, polynomial, dan RBF pada SVM, selain itu dataset *forest fire* juga dipercobakan pada model regresi lainnya diantaranya *neural network* (NN) (Tiryaki et al., 2014), k-NN (Lee et al., 2014), dan *linear regression* (LR) (Lira et al., 2014).

Berdasarkan hasil percobaan dapat dibuat kesimpulan sebagai berikut:

1. Algoritma genetika diterapkan untuk mengoptimasi nilai parameter C , ε , dan γ pada SVM. Penentuan jangkauan nilai parameter yang dioptimasi masih ditentukan secara manual. Dari 10 kali percobaan pada masing-masing kernel, algoritma genetika terbukti efektif dalam mengoptimasi nilai parameter SVM sehingga dapat memperkecil tingkat persentasi error, selain itu hasil uji t test antara metode SVM dan SVM+GA yang dipercobakan pada masing-masing kernel membuktikan dua dari tiga kernel memiliki perbedaan yang signifikan. Nilai RMSE dari penerapan GA pada metode SVM dalam penelitian ini juga memberikan hasil yang lebih baik jika dibandingkan dengan hasil penelitian sebelumnya (Cortez & Morais, 2007), dimana rata-rata RMSE pada penelitian terdahulu sebesar 12.71 sedangkan rata-rata RMSE SVM+GA sebesar 1.418.
2. Komparasi kernel diusulkan untuk membandingkan kernel mana yang memiliki nilai akurasi paling tinggi jika algoritma genetika diterapkan untuk mengoptimasi parameter pada SVM. Dari 10 kali percobaan pada masing-masing kernel, Kernel RBF memiliki nilai rata-rata RMSE terkecil pada metode SVM dan SVM+GA daripada kernel lainnya (polynomial dan dot).
3. Komparasi metode regresi diusulkan untuk membandingkan hasil akurasi antara metode SVM(RBF)+GA dengan metode-metode regresi lainnya (LR,

k-NN, NN). Dari 6 kali percobaan, metode SVM(RBF)+GA terbukti memiliki nilai akurasi paling tinggi dibandingkan dengan metode regresi lainnya (LR, k-NN, NN).

5.2 Saran

Pada penelitian ini secara umum algoritma genetika berhasil memperkecil RMSE pada SVM dengan mengoptimasi parameter C , γ , ε pada SVM untuk memprediksi area yang terbakar menggunakan data *forestfire*, namun beberapa hal dapat diterapkan untuk menyempurnakan penelitian ini, diantaranya:

1. Pada penelitian ini tidak semua atribut pada dataset *forest fire* yang dapat diolah dengan fungsi regresi SVM, mengingat terdapat atribut-atribut yang bersifat *spatio-temporal*. Menanggapi permasalahan ini, diperlukan metode *spatial* tambahan pada metode SVM+GA untuk mendekripsi *outlier* pada dataset seperti metode PAM, CLARANS, dan lain-lain.
2. Meskipun pada penelitian ini metode metaheuristik algoritma genetika dapat mengatasi permasalahan dalam pemilihan nilai parameter yang optimal pada SVM. Pada penelitian selanjutnya metode usulan pada penelitian ini harus dapat dibandingkan dengan metode metaheuristik yang lain seperti *firefly algorithm*, *cuckoo search*, *bat algorithm*, dan metode metaheuristik lainnya, atau dikembangkan dengan menggabungkan algoritma genetika dengan metode metaheuristik lainnya agar dapat menghasilkan nilai parameter yang lebih optimal pada SVM.

DAFTAR PUSTAKA

- Alpaydin. (2010). *Introduction to Machine Learning Second Edition*. (Alpaydin, Ed.).
- Bergmeir, C., Costantini, M., & Benítez, J. M. (2014). On the usefulness of cross-validation for directional forecast evaluation. *Computational Statistics & Data Analysis*, 76, 132–143. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S0167947314000310>
- Borra, S., & Di Ciaccio, A. (2010). Measuring the prediction error. A comparison of cross-validation, bootstrap and covariance penalty methods. *Computational Statistics & Data Analysis*, 54(12), 2976–2989. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S0167947310001064>
- Brun, C., Margalef, T., & Cortés, A. (2013). Coupling Diagnostic and Prognostic Models to a Dynamic Data Driven Forest Fire Spread Prediction System. *Procedia Computer Science*, 18, 1851–1860. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S1877050913004973>
- Conway, D., & White, J. M. (2012). *Machine Learning for Hackers*. (J. Steele, Ed.).
- Cortez, P., & Morais, A. (2007). A Data Mining Approach to Predict Forest Fires using Meteorological Data.
- Dawson, C. W. (2009). *Projects in Computing and Information Systems*.
- Denham, M., Wendt, K., Bianchini, G., Cortés, A., & Margalef, T. (2012). Dynamic Data-Driven Genetic Algorithm for forest fire spread prediction. *Journal of Computational Science*, 3(5), 398–404. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S1877750312000658>
- Dua. (2011). *Data Mining and Machine Learning in Cybersecurity*. (Dua, Ed.).
- Eastaugh, C. S., & Hasenauer, H. (2014). Deriving forest fire ignition risk with biogeochemical process modelling. *Environmental Modelling & Software*, 55, 132–142. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S1364815214000280>
- El Sheikh, A. A. R., & Alnoukari, M. (2012). *Business Intelligence and Agile Methodologies for Knowledge-Based Organizations : Cross-Disciplinary Applications*.
- Girardin, M. P., Ali, A. a., Carcaillet, C., Gauthier, S., Hély, C., Le Goff, H., ... Bergeron, Y. (2013). Fire in managed forests of eastern Canada: Risks and

- options. *Forest Ecology and Management*, 294, 238–249. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S037811271200401X>
- Gorunescu, F. (2011). *Intelligent Systems Reference Library*. (Gorunescu, Ed.).
- Gu, J., Zhu, M., & Jiang, L. (2011). Housing price forecasting based on genetic algorithm and support vector machine. *Expert Systems with Applications*, 38(4), 3383–3386. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S0957417410009310>
- Guo, X., Li, D., & Zhang, A. (2012). Improved Support Vector Machine Oil Price Forecast Model Based on Genetic Algorithm Optimization Parameters. *AASRI Procedia*, 1, 525–530. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S2212671612000832>
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining Concepts and Techniques*.
- Hosseini, M., Javaherian, A., & Movahed, B. (2014). Determination of permeability index using Stoneley slowness analysis, NMR models, and formation evaluations: a case study from a gas reservoir, south of Iran. *Journal of Applied Geophysics*, 109, 80–87.
- Ilhan, I., & Tezel, G. (2013). A genetic algorithm-support vector machine method with parameter optimization for selecting the tag SNPs. *Journal of Biomedical Informatics*, 46(2), 328–40. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/23262450>
- Jia, Z., Ma, J., Wang, F., & Liu, W. (2011). Hybrid of simulated annealing and SVM for hydraulic valve characteristics prediction. *Expert Systems with Applications*, 38(7), 8030–8036.
- Jia, Z.-Y., Ma, J.-W., Wang, F.-J., & Liu, W. (2010). Characteristics forecasting of hydraulic valve based on grey correlation and ANFIS. *Expert Systems with Applications*, 37(2), 1250–1255. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S0957417409005624>
- Kaytez, F., Taplamacioglu, M. C., Cam, E., & Hardalac, F. (2015). Electrical Power and Energy Systems Forecasting electricity consumption: A comparison of regression analysis , neural networks and least squares support vector machines. *International Journal of Electrical Power and Energy Systems*, 67, 431–438.
- Lee, S., Kang, P., & Cho, S. (2014). Neurocomputing Probabilistic local reconstruction for k -NN regression and its application to virtual metrology in semiconductor manufacturing. *Neurocomputing*, 131, 427–439.

- Li, Q., Salman, R., Test, E., Strack, R., & Kecman, V. (2013). Parallel multitask cross validation for Support Vector Machine using GPU. *Journal of Parallel and Distributed Computing*, 73(3), 293–302.
- Lira, M. A. T., Da Silva, E. M., Alves, J. M. B., & Veras, G. V. O. (2014). Estimation of wind resources in the coast of Ceará, Brazil, using the linear regression theory. *Renewable and Sustainable Energy Reviews*, 39, 509–529.
- Liu, H., Tian, H., Chen, C., & Li, Y. (2013). Electrical Power and Energy Systems An experimental investigation of two Wavelet-MLP hybrid frameworks for wind speed prediction using GA and PSO optimization. *International Journal of Electrical Power & Energy Systems*, 52, 161–173.
- Machairas, V., Tsangrassoulis, A., & Axarli, K. (2014). Algorithms for optimization of building design: A review. *Renewable and Sustainable Energy Reviews*, 31(1364), 101–112. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S1364032113007855>
- Maimon, O., & Rokach, L. (2010). *Data Mining and Knowledge Discovery Handbook*.
- Noor, R., & Syumanda, R. (2006). *Social conflict and environmental disaster : A report on Asia Pulp and Paper 's operations in Sumatra , Indonesia*.
- Özbayoğlu, a. M., & Bozer, R. (2012). Estimation of the Burned Area in Forest Fires Using Computational Intelligence Techniques. *Procedia Computer Science*, 12, 282–287.
- Pan, S., Iplikci, S., Warwick, K., & Aziz, T. Z. (2012). Parkinson's Disease tremor classification – A comparison between Support Vector Machines and neural networks. *Expert Systems with Applications*, 39(12), 10764–10771.
- Quintano, C., Fernández-Manso, A., Stein, A., & Bijker, W. (2011). Estimation of area burned by forest fires in Mediterranean countries: A remote sensing data mining perspective. *Forest Ecology and Management*, 262(8), 1597–1607. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S0378112711004385>
- Raghavendra. N, S., & Deka, P. C. (2014). Support vector machine applications in the field of hydrology: A review. *Applied Soft Computing*, 19, 372–386. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S1568494614000611>
- Rynkiewicz, J. (2012). General bound of overfitting for MLP regression models. *Neurocomputing*, 90, 106–110.
- Salerno, F., Viviano, G., Carraro, E., Manfredi, E. C., Lami, A., Musazzi, S., ... Copetti, D. (2014). Total phosphorus reference condition for subalpine lakes:

- A comparison among traditional methods and a new process-based watershed approach. *Journal of Environmental Management*, 145C, 94–105. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/25014886>
- Singh, a., Imtiyaz, M., Isaac, R. K., & Denis, D. M. (2012). Comparison of soil and water assessment tool (SWAT) and multilayer perceptron (MLP) artificial neural network for predicting sediment yield in the Nagwa agricultural watershed in Jharkhand, India. *Agricultural Water Management*, 104, 113–120. Retrieved from <http://linkinghub.elsevier.com/retrieve/pii/S0378377411003295>
- Suganyadevi, M. V., & Babulal, C. K. (2014). Support Vector Regression Model for the prediction of Loadability Margin of a Power System. *Applied Soft Computing Journal*, 24, 304–315.
- Tacconi, L. (2003). Fires in Indonesia : Causes , Costs and Policy Implications, (38).
- Tiryaki, S., Öz, Ş., & Y, İ. (2014). International Journal of Adhesion & Adhesives Comparison of artifical neural network and multiple linear regression models to predict optimum bonding strength of heat treated woods, 55, 29–36.
- Wang, X., Wen, J., Zhang, Y., & Wang, Y. (2014). Optik Real estate price forecasting based on SVM optimized by PSO. *Optik - International Journal for Light and Electron Optics*, 125(3), 1439–1443.
- Witten, I. H., Frank, E., & Hall, M. A. (2011). *Data Mining Practical Machine Learning Tools and Techniques* (Third.).
- Yang, X. (2014). *Nature-Inspired Optimization Algorithms*. Elsevier. doi:10.1016/B978-0-12-416743-8.00005-1
- Yilmaz, I., & Kaynar, O. (2011). Multiple regression, ANN (RBF, MLP) and ANFIS models for prediction of swell potential of clayey soils. *Expert Systems with Applications*, 38(5), 5958–5966.
- Yu, H., & Kim, S. (2012). *SVM Tutorial : Classification , Regression , and Ranking*. *Handbook of Natural Computing*. Retrieved from <http://www.dainf.ct.utfpr.edu.br/>
- Zameer, A., Mirza, S. M., & Mirza, N. M. (2014). Core loading pattern optimization of a typical two-loop 300MWe PWR using Simulated Annealing (SA), novel crossover Genetic Algorithms (GA) and hybrid GA(SA) schemes. *Annals of Nuclear Energy*, 65, 122–131. doi:10.1016/j.anucene.2013.10.024

- Zhang, D., Liu, W., Wang, A., & Deng, Q. (2011). Parameter Optimization for Support Vector Regression Based on Genetic Algorithm with Simplex Crossover Operator. *Journal of Information & Computational Science*, 6(June), 911–920.
- Zhao, M., Fu, C., Ji, L., Tang, K., & Zhou, M. (2011). Feature selection and parameter optimization for support vector machines: A new approach based on genetic algorithm with feature chromosomes. *Expert Systems with Applications*, 38(5), 5197–5204.
- Zumbrunnen, T., Pezzatti, G. B., Menéndez, P., Bugmann, H., Bürgi, M., & Conedera, M. (2011). Weather and human impacts on forest fires: 100 years of fire history in two climatic regions of Switzerland. *Forest Ecology and Management*, 261(12), 2188–2199.

LAMPIRAN

Lampiran 1. Forest Fire Dataset (Data Asli)

X	Y	Month	day	FFMC	DMC	DC	ISI	temp	RH	wind	rain	area
7	5	Mar	fri	86.2	26.2	94.3	5.1	8.2	51	6.7	0	0
7	4	Oct	tue	90.6	35.4	669.1	6.7	18	33	0.9	0	0
7	4	Oct	sat	90.6	43.7	686.9	6.7	14.6	33	1.3	0	0
8	6	Mar	fri	91.7	33.3	77.5	9	8.3	97	4	0.2	0
8	6	Mar	sun	89.3	51.3	102.2	9.6	11.4	99	1.8	0	0
8	6	Aug	sun	92.3	85.3	488	14.7	22.2	29	5.4	0	0
8	6	Aug	mon	92.3	88.9	495.6	8.5	24.1	27	3.1	0	0
8	6	Aug	mon	91.5	145.4	608.2	10.7	8	86	2.2	0	0
8	6	Sep	tue	91	129.5	692.6	7	13.1	63	5.4	0	0
7	5	Sep	sat	92.5	88	698.6	7.1	22.8	40	4	0	0
7	5	Sep	sat	92.5	88	698.6	7.1	17.8	51	7.2	0	0
7	5	Sep	sat	92.8	73.2	713	22.6	19.3	38	4	0	0
6	5	Aug	fri	63.5	70.8	665.3	0.8	17	72	6.7	0	0
6	5	Sep	mon	90.9	126.5	686.5	7	21.3	42	2.2	0	0
6	5	Sep	wed	92.9	133.3	699.6	9.2	26.4	21	4.5	0	0
6	5	Sep	fri	93.3	141.2	713.9	13.9	22.9	44	5.4	0	0
5	5	Mar	sat	91.7	35.8	80.8	7.8	15.1	27	5.4	0	0
8	5	Oct	mon	84.9	32.8	664.2	3	16.7	47	4.9	0	0
6	4	Mar	wed	89.2	27.9	70.8	6.3	15.9	35	4	0	0
6	4	Apr	sat	86.3	27.4	97.1	5.1	9.3	44	4.5	0	0
6	4	Sep	tue	91	129.5	692.6	7	18.3	40	2.7	0	0
5	4	Sep	mon	91.8	78.5	724.3	9.2	19.1	38	2.7	0	0
7	4	Jun	sun	94.3	96.3	200	56.1	21	44	4.5	0	0
7	4	Aug	sat	90.2	110.9	537.4	6.2	19.5	43	5.8	0	0
7	4	Aug	sat	93.5	139.4	594.2	20.3	23.7	32	5.8	0	0
7	4	Aug	sun	91.4	142.4	601.4	10.6	16.3	60	5.4	0	0
7	4	Sep	fri	92.4	117.9	668	12.2	19	34	5.8	0	0
7	4	Sep	mon	90.9	126.5	686.5	7	19.4	48	1.3	0	0
6	3	Sep	sat	93.4	145.4	721.4	8.1	30.2	24	2.7	0	0
6	3	Sep	sun	93.5	149.3	728.6	8.1	22.8	39	3.6	0	0
6	3	Sep	fri	94.3	85.1	692.3	15.9	25.4	24	3.6	0	0
6	3	Sep	mon	88.6	91.8	709.9	7.1	11.2	78	7.6	0	0
6	3	Sep	fri	88.6	69.7	706.8	5.8	20.6	37	1.8	0	0

6	3	Sep	sun	91.7	75.6	718.3	7.8	17.7	39	3.6	0	0
6	3	Sep	mon	91.8	78.5	724.3	9.2	21.2	32	2.7	0	0
6	3	Sep	tue	90.3	80.7	730.2	6.3	18.2	62	4.5	0	0
6	3	Oct	tue	90.6	35.4	669.1	6.7	21.7	24	4.5	0	0
7	4	Oct	fri	90	41.5	682.6	8.7	11.3	60	5.4	0	0
7	3	Oct	sat	90.6	43.7	686.9	6.7	17.8	27	4	0	0
4	4	Mar	tue	88.1	25.7	67.6	3.8	14.1	43	2.7	0	0
4	4	Jul	tue	79.5	60.6	366.7	1.5	23.3	37	3.1	0	0
4	4	Aug	sat	90.2	96.9	624.2	8.9	18.4	42	6.7	0	0
4	4	Aug	tue	94.8	108.3	647.1	17	16.6	54	5.4	0	0
4	4	Sep	sat	92.5	88	698.6	7.1	19.6	48	2.7	0	0
4	4	Sep	wed	90.1	82.9	735.7	6.2	12.9	74	4.9	0	0
5	6	Sep	wed	94.3	85.1	692.3	15.9	25.9	24	4	0	0
5	6	Sep	mon	90.9	126.5	686.5	7	14.7	70	3.6	0	0
6	6	Jul	mon	94.2	62.3	442.9	11	23	36	3.1	0	0
4	4	Mar	mon	87.2	23.9	64.7	4.1	11.8	35	1.8	0	0
4	4	Mar	mon	87.6	52.2	103.8	5	11	46	5.8	0	0
4	4	Sep	thu	92.9	137	706.4	9.2	20.8	17	1.3	0	0
4	3	Aug	sun	90.2	99.6	631.2	6.3	21.5	34	2.2	0	0
4	3	Aug	wed	92.1	111.2	654.1	9.6	20.4	42	4.9	0	0
4	3	Aug	wed	92.1	111.2	654.1	9.6	20.4	42	4.9	0	0
4	3	Aug	thu	91.7	114.3	661.3	6.3	17.6	45	3.6	0	0
4	3	Sep	thu	92.9	137	706.4	9.2	27.7	24	2.2	0	0
4	3	Sep	tue	90.3	80.7	730.2	6.3	17.8	63	4.9	0	0
4	3	Oct	sun	92.6	46.5	691.8	8.8	13.8	50	2.7	0	0
2	2	Feb	mon	84	9.3	34	2.1	13.9	40	5.4	0	0
2	2	Feb	fri	86.6	13.2	43	5.3	12.3	51	0.9	0	0
2	2	Mar	sun	89.3	51.3	102.2	9.6	11.5	39	5.8	0	0
2	2	Mar	sun	89.3	51.3	102.2	9.6	5.5	59	6.3	0	0
2	2	Aug	thu	93	75.3	466.6	7.7	18.8	35	4.9	0	0
2	2	Aug	sun	90.2	99.6	631.2	6.3	20.8	33	2.7	0	0
2	2	Aug	mon	91.1	103.2	638.8	5.8	23.1	31	3.1	0	0
2	2	Aug	thu	91.7	114.3	661.3	6.3	18.6	44	4.5	0	0
2	2	Sep	fri	92.4	117.9	668	12.2	23	37	4.5	0	0
2	2	Sep	fri	92.4	117.9	668	12.2	19.6	33	5.4	0	0
2	2	Sep	fri	92.4	117.9	668	12.2	19.6	33	6.3	0	0
4	5	Mar	fri	91.7	33.3	77.5	9	17.2	26	4.5	0	0
4	5	Mar	fri	91.2	48.3	97.8	12.5	15.8	27	7.6	0	0
4	5	Sep	fri	94.3	85.1	692.3	15.9	17.7	37	3.6	0	0
5	4	Mar	fri	91.7	33.3	77.5	9	15.6	25	6.3	0	0
5	4	Aug	tue	88.8	147.3	614.5	9	17.3	43	4.5	0	0
5	4	Sep	fri	93.3	141.2	713.9	13.9	27.6	30	1.3	0	0
9	9	Feb	thu	84.2	6.8	26.6	7.7	6.7	79	3.1	0	0

9	9	Feb	fri	86.6	13.2	43	5.3	15.7	43	3.1	0	0
1	3	Mar	mon	87.6	52.2	103.8	5	8.3	72	3.1	0	0
1	2	Aug	fri	90.1	108	529.8	12.5	14.7	66	2.7	0	0
1	2	Aug	tue	91	121.2	561.6	7	21.6	19	6.7	0	0
1	2	Aug	sun	91.4	142.4	601.4	10.6	19.5	39	6.3	0	0
1	2	Aug	sun	90.2	99.6	631.2	6.3	17.9	44	2.2	0	0
1	2	Aug	tue	94.8	108.3	647.1	17	18.6	51	4.5	0	0
1	2	Aug	wed	92.1	111.2	654.1	9.6	16.6	47	0.9	0	0
1	2	Aug	thu	91.7	114.3	661.3	6.3	20.2	45	3.6	0	0
1	2	Sep	thu	92.9	137	706.4	9.2	21.5	15	0.9	0	0
1	2	Sep	thu	92.9	137	706.4	9.2	25.4	27	2.2	0	0
1	2	Sep	thu	92.9	137	706.4	9.2	22.4	34	2.2	0	0
1	2	Sep	sun	93.5	149.3	728.6	8.1	25.3	36	3.6	0	0
6	5	Mar	sat	91.7	35.8	80.8	7.8	17.4	25	4.9	0	0
6	5	Aug	sat	90.2	96.9	624.2	8.9	14.7	59	5.8	0	0
8	6	Mar	fri	91.7	35.8	80.8	7.8	17.4	24	5.4	0	0
8	6	Aug	sun	92.3	85.3	488	14.7	20.8	32	6.3	0	0
8	6	Aug	sun	91.4	142.4	601.4	10.6	18.2	43	4.9	0	0
8	6	Aug	mon	91.1	103.2	638.8	5.8	23.4	22	2.7	0	0
4	4	Sep	sun	89.7	90	704.4	4.8	17.8	64	1.3	0	0
3	4	Feb	sat	83.9	8	30.2	2.6	12.7	48	1.8	0	0
3	4	Mar	sat	69	2.4	15.5	0.7	17.4	24	5.4	0	0
3	4	Aug	sun	91.4	142.4	601.4	10.6	11.6	87	4.5	0	0
3	4	Aug	sun	91.4	142.4	601.4	10.6	19.8	39	5.4	0	0
3	4	Aug	sun	91.4	142.4	601.4	10.6	19.8	39	5.4	0	0
3	4	Aug	tue	88.8	147.3	614.5	9	14.4	66	5.4	0	0
2	4	Aug	tue	94.8	108.3	647.1	17	20.1	40	4	0	0
2	4	Sep	sat	92.5	121.1	674.4	8.6	24.1	29	4.5	0	0
2	4	Jan	sat	82.1	3.7	9.3	2.9	5.3	78	3.1	0	0
4	5	Mar	fri	85.9	19.5	57.3	2.8	12.7	52	6.3	0	0
4	5	Mar	thu	91.4	30.7	74.3	7.5	18.2	29	3.1	0	0
4	5	Aug	sun	90.2	99.6	631.2	6.3	21.4	33	3.1	0	0
4	5	Sep	sat	92.5	88	698.6	7.1	20.3	45	3.1	0	0
4	5	Sep	mon	88.6	91.8	709.9	7.1	17.4	56	5.4	0	0
4	4	Mar	fri	85.9	19.5	57.3	2.8	13.7	43	5.8	0	0
3	4	Mar	fri	91.7	33.3	77.5	9	18.8	18	4.5	0	0
3	4	Sep	sun	89.7	90	704.4	4.8	22.8	39	3.6	0	0
3	4	Sep	mon	91.8	78.5	724.3	9.2	18.9	35	2.7	0	0
3	4	Mar	tue	88.1	25.7	67.6	3.8	15.8	27	7.6	0	0
3	5	Mar	tue	88.1	25.7	67.6	3.8	15.5	27	6.3	0	0
3	4	Mar	sat	91.7	35.8	80.8	7.8	11.6	30	6.3	0	0
3	4	Mar	sat	91.7	35.8	80.8	7.8	15.2	27	4.9	0	0
3	4	Mar	mon	90.1	39.7	86.6	6.2	10.6	30	4	0	0

3	4	Aug	thu	93	75.3	466.6	7.7	19.6	36	3.1	0	0
3	4	Aug	mon	91.5	145.4	608.2	10.7	10.3	74	2.2	0	0
3	4	Aug	mon	91.5	145.4	608.2	10.7	17.1	43	5.4	0	0
3	4	Sep	sun	92.4	124.1	680.7	8.5	22.5	42	5.4	0	0
3	4	Sep	tue	84.4	73.4	671.9	3.2	17.9	45	3.1	0	0
3	4	Sep	fri	94.3	85.1	692.3	15.9	19.8	50	5.4	0	0
3	4	Oct	sun	92.6	46.5	691.8	8.8	20.6	24	5.4	0	0
3	5	Mar	mon	87.6	52.2	103.8	5	9	49	2.2	0	0
3	5	Sep	fri	93.5	149.3	728.6	8.1	17.2	43	3.1	0	0
3	5	Oct	wed	91.4	37.9	673.8	5.2	15.9	46	3.6	0	0
2	5	Oct	sun	92.6	46.5	691.8	8.8	15.4	35	0.9	0	0
4	6	Feb	sat	68.2	21.5	87.2	0.8	15.4	40	2.7	0	0
4	6	Mar	mon	87.2	23.9	64.7	4.1	14	39	3.1	0	0
4	6	Mar	sun	89.3	51.3	102.2	9.6	10.6	46	4.9	0	0
4	6	Sep	thu	93.7	80.9	685.2	17.9	17.6	42	3.1	0	0
3	5	Mar	tue	88.1	25.7	67.6	3.8	14.9	38	2.7	0	0
3	5	Aug	sat	93.5	139.4	594.2	20.3	17.6	52	5.8	0	0
3	6	Sep	sun	92.4	124.1	680.7	8.5	17.2	58	1.3	0	0
3	6	Sep	mon	90.9	126.5	686.5	7	15.6	66	3.1	0	0
9	9	Jul	tue	85.8	48.3	313.4	3.9	18	42	2.7	0	0.36
1	4	Sep	tue	91	129.5	692.6	7	21.7	38	2.2	0	0.43
2	5	Sep	mon	90.9	126.5	686.5	7	21.9	39	1.8	0	0.47
1	2	Aug	wed	95.5	99.9	513.3	13.2	23.3	31	4.5	0	0.55
8	6	Aug	fri	90.1	108	529.8	12.5	21.2	51	8.9	0	0.61
1	2	Jul	sat	90	51.3	296.3	8.7	16.6	53	5.4	0	0.71
2	5	Aug	wed	95.5	99.9	513.3	13.2	23.8	32	5.4	0	0.77
6	5	Aug	thu	95.2	131.7	578.8	10.4	27.4	22	4	0	0.9
5	4	Mar	mon	90.1	39.7	86.6	6.2	13.2	40	5.4	0	0.95
8	3	Sep	tue	84.4	73.4	671.9	3.2	24.2	28	3.6	0	0.96
2	2	Aug	tue	94.8	108.3	647.1	17	17.4	43	6.7	0	1.07
8	6	Sep	thu	93.7	80.9	685.2	17.9	23.7	25	4.5	0	1.12
6	5	Jun	fri	92.5	56.4	433.3	7.1	23.2	39	5.4	0	1.19
9	9	Jul	sun	90.1	68.6	355.2	7.2	24.8	29	2.2	0	1.36
3	4	Jul	sat	90.1	51.2	424.1	6.2	24.6	43	1.8	0	1.43
5	4	Sep	fri	94.3	85.1	692.3	15.9	20.1	47	4.9	0	1.46
1	5	Sep	sat	93.4	145.4	721.4	8.1	29.6	27	2.7	0	1.46
7	4	Aug	sun	94.8	108.3	647.1	17	16.4	47	1.3	0	1.56
2	4	Sep	sat	93.4	145.4	721.4	8.1	28.6	27	2.2	0	1.61
2	2	Aug	wed	92.1	111.2	654.1	9.6	18.4	45	3.6	0	1.63
2	4	Aug	wed	92.1	111.2	654.1	9.6	20.5	35	4	0	1.64
7	4	Sep	fri	92.4	117.9	668	12.2	19	34	5.8	0	1.69
7	4	Mar	mon	90.1	39.7	86.6	6.2	16.1	29	3.1	0	1.75
6	4	Aug	thu	95.2	131.7	578.8	10.4	20.3	41	4	0	1.9

6	3	Mar	sat	90.6	50.1	100.4	7.8	15.2	31	8.5	0	1.94
8	6	Sep	sat	92.5	121.1	674.4	8.6	17.8	56	1.8	0	1.95
8	5	Sep	sun	89.7	90	704.4	4.8	17.8	67	2.2	0	2.01
6	5	Mar	thu	84.9	18.2	55	3	5.3	70	4.5	0	2.14
6	5	Aug	wed	92.1	111.2	654.1	9.6	16.6	47	0.9	0	2.29
6	5	Aug	wed	96	127.1	570.5	16.5	23.4	33	4.5	0	2.51
6	5	Mar	fri	91.2	48.3	97.8	12.5	14.6	26	9.4	0	2.53
8	6	Aug	thu	95.2	131.7	578.8	10.4	20.7	45	2.2	0	2.55
5	4	Sep	wed	92.9	133.3	699.6	9.2	21.9	35	1.8	0	2.57
8	6	Aug	wed	85.6	90.4	609.6	6.6	17.4	50	4	0	2.69
7	4	Aug	sun	91.4	142.4	601.4	10.6	20.1	39	5.4	0	2.74
4	4	Sep	mon	90.9	126.5	686.5	7	17.7	39	2.2	0	3.07
1	4	Aug	sat	90.2	96.9	624.2	8.9	14.2	53	1.8	0	3.5
1	4	Aug	sat	90.2	96.9	624.2	8.9	20.3	39	4.9	0	4.53
6	5	Apr	thu	81.5	9.1	55.2	2.7	5.8	54	5.8	0	4.61
2	5	Aug	sun	90.2	99.6	631.2	6.3	19.2	44	2.7	0	4.69
2	5	Sep	wed	90.1	82.9	735.7	6.2	18.3	45	2.2	0	4.88
8	6	Aug	tue	88.8	147.3	614.5	9	14.4	66	5.4	0	5.23
1	3	Sep	sun	92.4	124.1	680.7	8.5	23.9	32	6.7	0	5.33
8	6	Oct	mon	84.9	32.8	664.2	3	19.1	32	4	0	5.44
5	4	Feb	sun	86.8	15.6	48.3	3.9	12.4	53	2.2	0	6.38
7	4	Oct	mon	91.7	48.5	696.1	11.1	16.8	45	4.5	0	6.83
8	6	Aug	fri	93.9	135.7	586.7	15.1	20.8	34	4.9	0	6.96
2	5	Sep	tue	91	129.5	692.6	7	17.6	46	3.1	0	7.04
8	6	Mar	sun	89.3	51.3	102.2	9.6	11.5	39	5.8	0	7.19
1	5	Sep	mon	90.9	126.5	686.5	7	21	42	2.2	0	7.3
6	4	Mar	sat	90.8	41.9	89.4	7.9	13.3	42	0.9	0	7.4
7	4	Mar	sun	90.7	44	92.4	5.5	11.5	60	4	0	8.24
6	5	Mar	fri	91.2	48.3	97.8	12.5	11.7	33	4	0	8.31
2	5	Aug	thu	95.2	131.7	578.8	10.4	24.2	28	2.7	0	8.68
2	2	Aug	tue	94.8	108.3	647.1	17	24.6	22	4.5	0	8.71
4	5	Sep	wed	92.9	133.3	699.6	9.2	24.3	25	4	0	9.41
2	2	Aug	tue	94.8	108.3	647.1	17	24.6	22	4.5	0	10.01
2	5	Aug	fri	93.9	135.7	586.7	15.1	23.5	36	5.4	0	10.02
6	5	Apr	thu	81.5	9.1	55.2	2.7	5.8	54	5.8	0	10.93
4	5	Sep	thu	92.9	137	706.4	9.2	21.5	15	0.9	0	11.06
3	4	Sep	tue	91	129.5	692.6	7	13.9	59	6.3	0	11.24
2	4	Sep	mon	63.5	70.8	665.3	0.8	22.6	38	3.6	0	11.32
1	5	Sep	tue	91	129.5	692.6	7	21.6	33	2.2	0	11.53
6	5	Mar	sun	90.1	37.6	83.7	7.2	12.4	54	3.6	0	12.1
7	4	Feb	sun	83.9	8.7	32.1	2.1	8.8	68	2.2	0	13.05
8	6	Oct	wed	91.4	37.9	673.8	5.2	20.2	37	2.7	0	13.7
5	6	mar	sat	90.6	50.1	100.4	7.8	15.1	64	4	0	13.99

4	5	sep	thu	92.9	137	706.4	9.2	22.1	34	1.8	0	14.57
2	2	aug	sat	93.5	139.4	594.2	20.3	22.9	31	7.2	0	15.45
7	5	sep	tue	91	129.5	692.6	7	20.7	37	2.2	0	17.2
6	5	sep	fri	92.4	117.9	668	12.2	19.6	33	6.3	0	19.23
8	3	sep	thu	93.7	80.9	685.2	17.9	23.2	26	4.9	0	23.41
4	4	oct	sat	90.6	43.7	686.9	6.7	18.4	25	3.1	0	24.23
7	4	aug	sat	93.5	139.4	594.2	20.3	5.1	96	5.8	0	26
7	4	sep	fri	94.3	85.1	692.3	15.9	20.1	47	4.9	0	26.13
7	3	mar	mon	87.6	52.2	103.8	5	11	46	5.8	0	27.35
4	4	mar	sat	91.7	35.8	80.8	7.8	17	27	4.9	0	28.66
4	4	mar	sat	91.7	35.8	80.8	7.8	17	27	4.9	0	28.66
4	4	sep	sun	92.4	124.1	680.7	8.5	16.9	60	1.3	0	29.48
1	3	sep	mon	88.6	91.8	709.9	7.1	12.4	73	6.3	0	30.32
4	5	sep	wed	92.9	133.3	699.6	9.2	19.4	19	1.3	0	31.72
6	5	mar	mon	90.1	39.7	86.6	6.2	15.2	27	3.1	0	31.86
8	6	aug	sun	90.2	99.6	631.2	6.3	16.2	59	3.1	0	32.07
3	4	sep	fri	93.3	141.2	713.9	13.9	18.6	49	3.6	0	35.88
4	3	mar	mon	87.6	52.2	103.8	5	11	46	5.8	0	36.85
2	2	jul	fri	88.3	150.3	309.9	6.8	13.4	79	3.6	0	37.02
7	4	sep	wed	90.1	82.9	735.7	6.2	15.4	57	4.5	0	37.71
4	4	sep	sun	93.5	149.3	728.6	8.1	22.9	39	4.9	0	48.55
7	5	oct	mon	91.7	48.5	696.1	11.1	16.1	44	4	0	49.37
8	6	aug	sat	92.2	81.8	480.8	11.9	20.1	34	4.5	0	58.3
4	6	sep	sun	93.5	149.3	728.6	8.1	28.3	26	3.1	0	64.1
8	6	aug	sat	92.2	81.8	480.8	11.9	16.4	43	4	0	71.3
4	4	sep	wed	92.9	133.3	699.6	9.2	26.4	21	4.5	0	88.49
1	5	sep	sun	93.5	149.3	728.6	8.1	27.8	27	3.1	0	95.18
6	4	sep	tue	91	129.5	692.6	7	18.7	43	2.7	0	103.39
9	4	sep	tue	84.4	73.4	671.9	3.2	24.3	36	3.1	0	105.66
4	5	sep	sat	92.5	121.1	674.4	8.6	17.7	25	3.1	0	154.88
8	6	aug	sun	91.4	142.4	601.4	10.6	19.6	41	5.8	0	196.48
2	2	sep	sat	92.5	121.1	674.4	8.6	18.2	46	1.8	0	200.94
1	2	sep	tue	91	129.5	692.6	7	18.8	40	2.2	0	212.88
6	5	sep	sat	92.5	121.1	674.4	8.6	25.1	27	4	0	1090.84
7	5	apr	sun	81.9	3	7.9	3.5	13.4	75	1.8	0	0
6	3	apr	wed	88	17.2	43.5	3.8	15.2	51	2.7	0	0
4	4	apr	fri	83	23.3	85.3	2.3	16.7	20	3.1	0	0
2	4	aug	sun	94.2	122.3	589.9	12.9	15.4	66	4	0	10.13
7	4	aug	sun	91.8	175.1	700.7	13.8	21.9	73	7.6	1	0
2	4	aug	sun	91.8	175.1	700.7	13.8	22.4	54	7.6	0	2.87
3	4	aug	sun	91.8	175.1	700.7	13.8	26.8	38	6.3	0	0.76
5	4	aug	sun	91.8	175.1	700.7	13.8	25.7	39	5.4	0	0.09
2	4	aug	wed	92.2	91.6	503.6	9.6	20.7	70	2.2	0	0.75

8	6	aug	wed	93.1	157.3	666.7	13.5	28.7	28	2.7	0	0
3	4	aug	wed	93.1	157.3	666.7	13.5	21.7	40	0.4	0	2.47
8	5	aug	wed	93.1	157.3	666.7	13.5	26.8	25	3.1	0	0.68
8	5	aug	wed	93.1	157.3	666.7	13.5	24	36	3.1	0	0.24
6	5	aug	wed	93.1	157.3	666.7	13.5	22.1	37	3.6	0	0.21
7	4	aug	thu	91.9	109.2	565.5	8	21.4	38	2.7	0	1.52
6	3	aug	thu	91.6	138.1	621.7	6.3	18.9	41	3.1	0	10.34
2	5	aug	thu	87.5	77	694.8	5	22.3	46	4	0	0
8	6	aug	sat	94.2	117.2	581.1	11	23.9	41	2.2	0	8.02
4	3	aug	sat	94.2	117.2	581.1	11	21.4	44	2.7	0	0.68
3	4	aug	sat	91.8	170.9	692.3	13.7	20.6	59	0.9	0	0
7	4	aug	sat	91.8	170.9	692.3	13.7	23.7	40	1.8	0	1.38
2	4	aug	mon	93.6	97.9	542	14.4	28.3	32	4	0	8.85
3	4	aug	fri	91.6	112.4	573	8.9	11.2	84	7.6	0	3.3
2	4	aug	fri	91.6	112.4	573	8.9	21.4	42	3.1	0	4.25
6	3	aug	fri	91.1	141.1	629.1	7.1	19.3	39	3.6	0	1.56
4	4	aug	fri	94.3	167.6	684.4	13	21.8	53	3.1	0	6.54
4	4	aug	tue	93.7	102.2	550.3	14.6	22.1	54	7.6	0	0.79
6	5	aug	tue	94.3	131.7	607.1	22.7	19.4	55	4	0	0.17
2	2	aug	tue	92.1	152.6	658.2	14.3	23.7	24	3.1	0	0
3	4	aug	tue	92.1	152.6	658.2	14.3	21	32	3.1	0	0
4	4	aug	tue	92.1	152.6	658.2	14.3	19.1	53	2.7	0	4.4
2	2	aug	tue	92.1	152.6	658.2	14.3	21.8	56	3.1	0	0.52
8	6	aug	tue	92.1	152.6	658.2	14.3	20.1	58	4.5	0	9.27
2	5	aug	tue	92.1	152.6	658.2	14.3	20.2	47	4	0	3.09
4	6	dec	sun	84.4	27.2	353.5	6.8	4.8	57	8.5	0	8.98
8	6	dec	wed	84	27.8	354.6	5.3	5.1	61	8	0	11.19
4	6	dec	thu	84.6	26.4	352	2	5.1	61	4.9	0	5.38
4	4	dec	mon	85.4	25.4	349.7	2.6	4.6	21	8.5	0	17.85
3	4	dec	mon	85.4	25.4	349.7	2.6	4.6	21	8.5	0	10.73
4	4	dec	mon	85.4	25.4	349.7	2.6	4.6	21	8.5	0	22.03
4	4	dec	mon	85.4	25.4	349.7	2.6	4.6	21	8.5	0	9.77
4	6	dec	fri	84.7	26.7	352.6	4.1	2.2	59	4.9	0	9.27
6	5	dec	tue	85.4	25.4	349.7	2.6	5.1	24	8.5	0	24.77
6	3	feb	sun	84.9	27.5	353.5	3.4	4.2	51	4	0	0
3	4	feb	wed	86.9	6.6	18.7	3.2	8.8	35	3.1	0	1.1
5	4	feb	fri	85.2	4.9	15.8	6.3	7.5	46	8	0	24.24
2	5	jul	sun	93.9	169.7	411.8	12.3	23.4	40	6.3	0	0
7	6	jul	wed	91.2	183.1	437.7	12.5	12.6	90	7.6	0.2	0
7	4	jul	sat	91.6	104.2	474.9	9	22.1	49	2.7	0	0
7	4	jul	sat	91.6	104.2	474.9	9	24.2	32	1.8	0	0
7	4	jul	sat	91.6	104.2	474.9	9	24.3	30	1.8	0	0
2	5	jul	sat	91.6	104.2	474.9	9	18.7	53	1.8	0	0

9	4	jul	sat	91.6	104.2	474.9	9	25.3	39	0.9	0	8
4	5	jul	fri	91.6	100.2	466.3	6.3	22.9	40	1.3	0	2.64
7	6	jul	tue	93.1	180.4	430.8	11	26.9	28	5.4	0	86.45
8	6	jul	tue	92.3	88.8	440.9	8.5	17.1	67	3.6	0	6.57
7	5	jun	sun	93.1	180.4	430.8	11	22.2	48	1.3	0	0
6	4	jun	sun	90.4	89.5	290.8	6.4	14.3	46	1.8	0	0.9
8	6	jun	sun	90.4	89.5	290.8	6.4	15.4	45	2.2	0	0
8	6	jun	wed	91.2	147.8	377.2	12.7	19.6	43	4.9	0	0
6	5	jun	sat	53.4	71	233.8	0.4	10.6	90	2.7	0	0
6	5	jun	mon	90.4	93.3	298.1	7.5	20.7	25	4.9	0	0
6	5	jun	mon	90.4	93.3	298.1	7.5	19.1	39	5.4	0	3.52
3	6	jun	fri	91.1	94.1	232.1	7.1	19.2	38	4.5	0	0
3	6	jun	fri	91.1	94.1	232.1	7.1	19.2	38	4.5	0	0
6	5	may	sat	85.1	28	113.8	3.5	11.3	94	4.9	0	0
1	4	sep	sun	89.6	84.1	714.3	5.7	19	52	2.2	0	0
7	4	sep	sun	89.6	84.1	714.3	5.7	17.1	53	5.4	0	0.41
3	4	sep	sun	89.6	84.1	714.3	5.7	23.8	35	3.6	0	5.18
2	4	sep	sun	92.4	105.8	758.1	9.9	16	45	1.8	0	0
2	4	sep	sun	92.4	105.8	758.1	9.9	24.9	27	2.2	0	0
7	4	sep	sun	92.4	105.8	758.1	9.9	25.3	27	2.7	0	0
6	3	sep	sun	92.4	105.8	758.1	9.9	24.8	28	1.8	0	14.29
2	4	sep	sun	50.4	46.2	706.6	0.4	12.2	78	6.3	0	0
6	5	sep	wed	92.6	115.4	777.1	8.8	24.3	27	4.9	0	0
4	4	sep	wed	92.6	115.4	777.1	8.8	19.7	41	1.8	0	1.58
3	4	sep	wed	91.2	134.7	817.5	7.2	18.5	30	2.7	0	0
4	5	sep	thu	92.4	96.2	739.4	8.6	18.6	24	5.8	0	0
4	4	sep	thu	92.4	96.2	739.4	8.6	19.2	24	4.9	0	3.78
6	5	sep	thu	92.8	119	783.5	7.5	21.6	27	2.2	0	0
5	4	sep	thu	92.8	119	783.5	7.5	21.6	28	6.3	0	4.41
6	3	sep	thu	92.8	119	783.5	7.5	18.9	34	7.2	0	34.36
1	4	sep	thu	92.8	119	783.5	7.5	16.8	28	4	0	7.21
6	5	sep	thu	92.8	119	783.5	7.5	16.8	28	4	0	1.01
3	5	sep	thu	90.7	136.9	822.8	6.8	12.9	39	2.7	0	2.18
6	5	sep	thu	88.1	53.3	726.9	5.4	13.7	56	1.8	0	4.42
1	4	sep	sat	92.2	102.3	751.5	8.4	24.2	27	3.1	0	0
5	4	sep	sat	92.2	102.3	751.5	8.4	24.1	27	3.1	0	0
6	5	sep	sat	92.2	102.3	751.5	8.4	21.2	32	2.2	0	0
6	5	sep	sat	92.2	102.3	751.5	8.4	19.7	35	1.8	0	0
4	3	sep	sat	92.2	102.3	751.5	8.4	23.5	27	4	0	3.33
3	3	sep	sat	92.2	102.3	751.5	8.4	24.2	27	3.1	0	6.58
7	4	sep	sat	91.2	124.4	795.3	8.5	21.5	28	4.5	0	15.64
4	4	sep	sat	91.2	124.4	795.3	8.5	17.1	41	2.2	0	11.22
1	4	sep	mon	92.1	87.7	721.1	9.5	18.1	54	3.1	0	2.13

2	3	sep	mon	91.6	108.4	764	6.2	18	51	5.4	0	0
4	3	sep	mon	91.6	108.4	764	6.2	9.8	86	1.8	0	0
7	4	sep	mon	91.6	108.4	764	6.2	19.3	44	2.2	0	0
6	3	sep	mon	91.6	108.4	764	6.2	23	34	2.2	0	56.04
8	6	sep	mon	91.6	108.4	764	6.2	22.7	35	2.2	0	7.48
2	4	sep	mon	91.6	108.4	764	6.2	20.4	41	1.8	0	1.47
2	5	sep	mon	91.6	108.4	764	6.2	19.3	44	2.2	0	3.93
8	6	sep	mon	91.9	111.7	770.3	6.5	15.7	51	2.2	0	0
6	3	sep	mon	91.5	130.1	807.1	7.5	20.6	37	1.8	0	0
8	6	sep	mon	91.5	130.1	807.1	7.5	15.9	51	4.5	0	2.18
6	3	sep	mon	91.5	130.1	807.1	7.5	12.2	66	4.9	0	6.1
2	2	sep	mon	91.5	130.1	807.1	7.5	16.8	43	3.1	0	5.83
1	4	sep	mon	91.5	130.1	807.1	7.5	21.3	35	2.2	0	28.19
5	4	sep	fri	92.1	99	745.3	9.6	10.1	75	3.6	0	0
3	4	sep	fri	92.1	99	745.3	9.6	17.4	57	4.5	0	0
5	4	sep	fri	92.1	99	745.3	9.6	12.8	64	3.6	0	1.64
5	4	sep	fri	92.1	99	745.3	9.6	10.1	75	3.6	0	3.71
4	4	sep	fri	92.1	99	745.3	9.6	15.4	53	6.3	0	7.31
7	4	sep	fri	92.1	99	745.3	9.6	20.6	43	3.6	0	2.03
7	4	sep	fri	92.1	99	745.3	9.6	19.8	47	2.7	0	1.72
7	4	sep	fri	92.1	99	745.3	9.6	18.7	50	2.2	0	5.97
4	4	sep	fri	92.1	99	745.3	9.6	20.8	35	4.9	0	13.06
4	4	sep	fri	92.1	99	745.3	9.6	20.8	35	4.9	0	1.26
6	3	sep	fri	92.5	122	789.7	10.2	15.9	55	3.6	0	0
6	3	sep	fri	92.5	122	789.7	10.2	19.7	39	2.7	0	0
1	4	sep	fri	92.5	122	789.7	10.2	21.1	39	2.2	0	8.12
6	5	sep	fri	92.5	122	789.7	10.2	18.4	42	2.2	0	1.09
4	3	sep	fri	92.5	122	789.7	10.2	17.3	45	4	0	3.94
7	4	sep	fri	88.2	55.2	732.3	11.6	15.2	64	3.1	0	0.52
4	3	sep	tue	91.9	111.7	770.3	6.5	15.9	53	2.2	0	2.93
6	5	sep	tue	91.9	111.7	770.3	6.5	21.1	35	2.7	0	5.65
6	5	sep	tue	91.9	111.7	770.3	6.5	19.6	45	3.1	0	20.03
4	5	sep	tue	91.1	132.3	812.1	12.5	15.9	38	5.4	0	1.75
4	5	sep	tue	91.1	132.3	812.1	12.5	16.4	27	3.6	0	0
6	5	sep	sat	91.2	94.3	744.4	8.4	16.8	47	4.9	0	12.64
4	5	sep	sun	91	276.3	825.1	7.1	13.8	77	7.6	0	0
7	4	sep	sun	91	276.3	825.1	7.1	13.8	77	7.6	0	11.06
3	4	jul	wed	91.9	133.6	520.5	8	14.2	58	4	0	0
4	5	aug	sun	92	203.2	664.5	8.1	10.4	75	0.9	0	0
5	4	aug	thu	94.8	222.4	698.6	13.9	20.3	42	2.7	0	0
6	5	sep	fri	90.3	290	855.3	7.4	10.3	78	4	0	18.3
6	5	sep	sat	91.2	94.3	744.4	8.4	15.4	57	4.9	0	39.35
8	6	aug	mon	92.1	207	672.6	8.2	21.1	54	2.2	0	0

2	2	aug	sat	93.7	231.1	715.1	8.4	21.9	42	2.2	0	174.63
6	5	mar	thu	90.9	18.9	30.6	8	8.7	51	5.8	0	0
4	5	jan	sun	18.7	1.1	171.4	0	5.2	100	0.9	0	0
5	4	jul	wed	93.7	101.3	458.8	11.9	19.3	39	7.2	0	7.73
8	6	aug	thu	90.7	194.1	643	6.8	16.2	63	2.7	0	16.33
8	6	aug	wed	95.2	217.7	690	18	28.2	29	1.8	0	5.86
9	6	aug	thu	91.6	248.4	753.8	6.3	20.5	58	2.7	0	42.87
8	4	aug	sat	91.6	273.8	819.1	7.7	21.3	44	4.5	0	12.18
2	4	aug	sun	91.6	181.3	613	7.6	20.9	50	2.2	0	16
3	4	sep	sun	90.5	96.7	750.5	11.4	20.6	55	5.4	0	24.59
5	5	mar	thu	90.9	18.9	30.6	8	11.6	48	5.4	0	0
6	4	aug	fri	94.8	227	706.7	12	23.3	34	3.1	0	28.74
7	4	aug	fri	94.8	227	706.7	12	23.3	34	3.1	0	0
7	4	feb	mon	84.7	9.5	58.3	4.1	7.5	71	6.3	0	9.96
8	6	sep	fri	91.1	91.3	738.1	7.2	20.7	46	2.7	0	30.18
1	3	sep	sun	91	276.3	825.1	7.1	21.9	43	4	0	70.76
2	4	mar	tue	93.4	15	25.6	11.4	15.2	19	7.6	0	0
6	5	feb	mon	84.1	4.6	46.7	2.2	5.3	68	1.8	0	0
4	5	feb	sun	85	9	56.9	3.5	10.1	62	1.8	0	51.78
4	3	sep	sun	90.5	96.7	750.5	11.4	20.4	55	4.9	0	3.64
5	6	aug	sun	91.6	181.3	613	7.6	24.3	33	3.6	0	3.63
1	2	aug	sat	93.7	231.1	715.1	8.4	25.9	32	3.1	0	0
9	5	jun	wed	93.3	49.5	297.7	14	28	34	4.5	0	0
9	5	jun	wed	93.3	49.5	297.7	14	28	34	4.5	0	8.16
3	4	sep	thu	91.1	88.2	731.7	8.3	22.8	46	4	0	4.95
9	9	aug	fri	94.8	227	706.7	12	25	36	4	0	0
8	6	aug	thu	90.7	194.1	643	6.8	21.3	41	3.6	0	0
2	4	sep	wed	87.9	84.8	725.1	3.7	21.8	34	2.2	0	6.04
2	2	aug	tue	94.6	212.1	680.9	9.5	27.9	27	2.2	0	0
6	5	sep	sat	87.1	291.3	860.6	4	17	67	4.9	0	3.95
4	5	feb	sat	84.7	8.2	55	2.9	14.2	46	4	0	0
4	3	sep	fri	90.3	290	855.3	7.4	19.9	44	3.1	0	7.8
1	4	jul	tue	92.3	96.2	450.2	12.1	23.4	31	5.4	0	0
6	3	feb	fri	84.1	7.3	52.8	2.7	14.7	42	2.7	0	0
7	4	feb	fri	84.6	3.2	43.6	3.3	8.2	53	9.4	0	4.62
9	4	jul	mon	92.3	92.1	442.1	9.8	22.8	27	4.5	0	1.63
7	5	aug	sat	93.7	231.1	715.1	8.4	26.4	33	3.6	0	0
5	4	aug	sun	93.6	235.1	723.1	10.1	24.1	50	4	0	0
8	6	aug	thu	94.8	222.4	698.6	13.9	27.5	27	4.9	0	746.28
6	3	jul	tue	92.7	164.1	575.8	8.9	26.3	39	3.1	0	7.02
6	5	mar	wed	93.4	17.3	28.3	9.9	13.8	24	5.8	0	0
2	4	aug	sun	92	203.2	664.5	8.1	24.9	42	5.4	0	2.44
2	5	aug	sun	91.6	181.3	613	7.6	24.8	36	4	0	3.05

8	8	aug	wed	91.7	191.4	635.9	7.8	26.2	36	4.5	0	185.76
2	4	aug	wed	95.2	217.7	690	18	30.8	19	4.5	0	0
8	6	jul	sun	88.9	263.1	795.9	5.2	29.3	27	3.6	0	6.3
1	3	sep	sat	91.2	94.3	744.4	8.4	22.3	48	4	0	0.72
8	6	aug	sat	93.7	231.1	715.1	8.4	26.9	31	3.6	0	4.96
2	2	aug	thu	91.6	248.4	753.8	6.3	20.4	56	2.2	0	0
8	6	aug	thu	91.6	248.4	753.8	6.3	20.4	56	2.2	0	0
2	4	aug	mon	92.1	207	672.6	8.2	27.9	33	2.2	0	2.35
1	3	aug	thu	94.8	222.4	698.6	13.9	26.2	34	5.8	0	0
3	4	aug	sun	91.6	181.3	613	7.6	24.6	44	4	0	3.2
7	4	sep	thu	89.7	287.2	849.3	6.8	19.4	45	3.6	0	0
1	3	aug	sat	92.1	178	605.3	9.6	23.3	40	4	0	6.36
8	6	aug	thu	94.8	222.4	698.6	13.9	23.9	38	6.7	0	0
2	4	aug	sun	93.6	235.1	723.1	10.1	20.9	66	4.9	0	15.34
1	4	aug	fri	90.6	269.8	811.2	5.5	22.2	45	3.6	0	0
2	5	jul	sat	90.8	84.7	376.6	5.6	23.8	51	1.8	0	0
8	6	aug	mon	92.1	207	672.6	8.2	26.8	35	1.3	0	0.54
8	6	aug	sat	89.4	253.6	768.4	9.7	14.2	73	2.7	0	0
2	5	aug	sat	93.7	231.1	715.1	8.4	23.6	53	4	0	6.43
1	3	sep	fri	91.1	91.3	738.1	7.2	19.1	46	2.2	0	0.33
5	4	sep	fri	90.3	290	855.3	7.4	16.2	58	3.6	0	0
8	6	aug	mon	92.1	207	672.6	8.2	25.5	29	1.8	0	1.23
6	5	apr	mon	87.9	24.9	41.6	3.7	10.9	64	3.1	0	3.35
1	2	jul	fri	90.7	80.9	368.3	16.8	14.8	78	8	0	0
2	5	sep	fri	90.3	290	855.3	7.4	16.2	58	3.6	0	9.96
5	5	aug	sun	94	47.9	100.7	10.7	17.3	80	4.5	0	0
6	5	aug	sun	92	203.2	664.5	8.1	19.1	70	2.2	0	0
3	4	mar	wed	93.4	17.3	28.3	9.9	8.9	35	8	0	0
7	4	sep	wed	89.7	284.9	844	10.1	10.5	77	4	0	0
7	4	aug	sun	91.6	181.3	613	7.6	19.3	61	4.9	0	0
4	5	aug	wed	95.2	217.7	690	18	23.4	49	5.4	0	6.43
1	4	aug	fri	90.5	196.8	649.9	16.3	11.8	88	4.9	0	9.71
7	4	aug	mon	91.5	238.2	730.6	7.5	17.7	65	4	0	0
4	5	aug	thu	89.4	266.2	803.3	5.6	17.4	54	3.1	0	0
3	4	aug	thu	91.6	248.4	753.8	6.3	16.8	56	3.1	0	0
3	4	jul	mon	94.6	160	567.2	16.7	17.9	48	2.7	0	0
2	4	aug	thu	91.6	248.4	753.8	6.3	16.6	59	2.7	0	0
1	4	aug	wed	91.7	191.4	635.9	7.8	19.9	50	4	0	82.75
8	6	aug	sat	93.7	231.1	715.1	8.4	18.9	64	4.9	0	3.32
7	4	aug	sat	91.6	273.8	819.1	7.7	15.5	72	8	0	1.94
2	5	aug	sat	93.7	231.1	715.1	8.4	18.9	64	4.9	0	0
8	6	aug	sat	93.7	231.1	715.1	8.4	18.9	64	4.9	0	0
1	4	sep	sun	91	276.3	825.1	7.1	14.5	76	7.6	0	3.71

6	5	feb	tue	75.1	4.4	16.2	1.9	4.6	82	6.3	0	5.39
6	4	feb	tue	75.1	4.4	16.2	1.9	5.1	77	5.4	0	2.14
2	2	feb	sat	79.5	3.6	15.3	1.8	4.6	59	0.9	0	6.84
6	5	mar	mon	87.2	15.1	36.9	7.1	10.2	45	5.8	0	3.18
3	4	mar	wed	90.2	18.5	41.1	7.3	11.2	41	5.4	0	5.55
6	5	mar	thu	91.3	20.6	43.5	8.5	13.3	27	3.6	0	6.61
6	3	apr	sun	91	14.6	25.6	12.3	13.7	33	9.4	0	61.13
5	4	apr	sun	91	14.6	25.6	12.3	17.6	27	5.8	0	0
4	3	may	fri	89.6	25.4	73.7	5.7	18	40	4	0	38.48
8	3	jun	mon	88.2	96.2	229	4.7	14.3	79	4	0	1.94
9	4	jun	sat	90.5	61.1	252.6	9.4	24.5	50	3.1	0	70.32
4	3	jun	thu	93	103.8	316.7	10.8	26.4	35	2.7	0	10.08
2	5	jun	thu	93.7	121.7	350.2	18	22.7	40	9.4	0	3.19
4	3	jul	thu	93.5	85.3	395	9.9	27.2	28	1.3	0	1.76
4	3	jul	sun	93.7	101.3	423.4	14.7	26.1	45	4	0	7.36
7	4	jul	sun	93.7	101.3	423.4	14.7	18.2	82	4.5	0	2.21
7	4	jul	mon	89.2	103.9	431.6	6.4	22.6	57	4.9	0	278.53
9	9	jul	thu	93.2	114.4	560	9.5	30.2	25	4.5	0	2.75
4	3	jul	thu	93.2	114.4	560	9.5	30.2	22	4.9	0	0
3	4	aug	sun	94.9	130.3	587.1	14.1	23.4	40	5.8	0	1.29
8	6	aug	sun	94.9	130.3	587.1	14.1	31	27	5.4	0	0
2	5	aug	sun	94.9	130.3	587.1	14.1	33.1	25	4	0	26.43
2	4	aug	mon	95	135.5	596.3	21.3	30.6	28	3.6	0	2.07
5	4	aug	tue	95.1	141.3	605.8	17.7	24.1	43	6.3	0	2
5	4	aug	tue	95.1	141.3	605.8	17.7	26.4	34	3.6	0	16.4
4	4	aug	tue	95.1	141.3	605.8	17.7	19.4	71	7.6	0	46.7
4	4	aug	wed	95.1	141.3	605.8	17.7	20.6	58	1.3	0	0
4	4	aug	wed	95.1	141.3	605.8	17.7	28.7	33	4	0	0
4	4	aug	thu	95.8	152	624.1	13.8	32.4	21	4.5	0	0
1	3	aug	fri	95.9	158	633.6	11.3	32.4	27	2.2	0	0
1	3	aug	fri	95.9	158	633.6	11.3	27.5	29	4.5	0	43.32
6	6	aug	sat	96	164	643	14	30.8	30	4.9	0	8.59
6	6	aug	mon	96.2	175.5	661.8	16.8	23.9	42	2.2	0	0
4	5	aug	mon	96.2	175.5	661.8	16.8	32.6	26	3.1	0	2.77
3	4	aug	tue	96.1	181.1	671.2	14.3	32.3	27	2.2	0	14.68
6	5	aug	tue	96.1	181.1	671.2	14.3	33.3	26	2.7	0	40.54
7	5	aug	tue	96.1	181.1	671.2	14.3	27.3	63	4.9	6.4	10.82
8	6	aug	tue	96.1	181.1	671.2	14.3	21.6	65	4.9	0.8	0
7	5	aug	tue	96.1	181.1	671.2	14.3	21.6	65	4.9	0.8	0
4	4	aug	tue	96.1	181.1	671.2	14.3	20.7	69	4.9	0.4	0
2	4	aug	wed	94.5	139.4	689.1	20	29.2	30	4.9	0	1.95
4	3	aug	wed	94.5	139.4	689.1	20	28.9	29	4.9	0	49.59
1	2	aug	thu	91	163.2	744.4	10.1	26.7	35	1.8	0	5.8

1	2	aug	fri	91	166.9	752.6	7.1	18.5	73	8.5	0	0
2	4	aug	fri	91	166.9	752.6	7.1	25.9	41	3.6	0	0
1	2	aug	fri	91	166.9	752.6	7.1	25.9	41	3.6	0	0
5	4	aug	fri	91	166.9	752.6	7.1	21.1	71	7.6	1.4	2.17
6	5	aug	fri	91	166.9	752.6	7.1	18.2	62	5.4	0	0.43
8	6	aug	sun	81.6	56.7	665.6	1.9	27.8	35	2.7	0	0
4	3	aug	sun	81.6	56.7	665.6	1.9	27.8	32	2.7	0	6.44
2	4	aug	sun	81.6	56.7	665.6	1.9	21.9	71	5.8	0	54.29
7	4	aug	sun	81.6	56.7	665.6	1.9	21.2	70	6.7	0	11.16
1	4	aug	sat	94.4	146	614.7	11.3	25.6	42	4	0	0
6	3	nov	tue	79.5	3	106.7	1.1	11.8	31	4.5	0	0

Lampiran 2. Forestfire dataset tanpa spatio-temporal atribut dan area yang telah di transformasi

FFMC	DMC	DC	ISI	temp	RH	wind	rain	ln(area+1)
86.2	26.2	94.3	5.1	8.2	51	6.7	0	0
90.6	35.4	669.1	6.7	18	33	0.9	0	0
90.6	43.7	686.9	6.7	14.6	33	1.3	0	0
91.7	33.3	77.5	9	8.3	97	4	0.2	0
89.3	51.3	102.2	9.6	11.4	99	1.8	0	0
92.3	85.3	488	14.7	22.2	29	5.4	0	0
92.3	88.9	495.6	8.5	24.1	27	3.1	0	0
91.5	145.4	608.2	10.7	8	86	2.2	0	0
91	129.5	692.6	7	13.1	63	5.4	0	0
92.5	88	698.6	7.1	22.8	40	4	0	0
92.5	88	698.6	7.1	17.8	51	7.2	0	0
92.8	73.2	713	22.6	19.3	38	4	0	0
63.5	70.8	665.3	0.8	17	72	6.7	0	0
90.9	126.5	686.5	7	21.3	42	2.2	0	0
92.9	133.3	699.6	9.2	26.4	21	4.5	0	0
93.3	141.2	713.9	13.9	22.9	44	5.4	0	0
91.7	35.8	80.8	7.8	15.1	27	5.4	0	0
84.9	32.8	664.2	3	16.7	47	4.9	0	0
89.2	27.9	70.8	6.3	15.9	35	4	0	0
86.3	27.4	97.1	5.1	9.3	44	4.5	0	0
91	129.5	692.6	7	18.3	40	2.7	0	0
91.8	78.5	724.3	9.2	19.1	38	2.7	0	0
94.3	96.3	200	56.1	21	44	4.5	0	0
90.2	110.9	537.4	6.2	19.5	43	5.8	0	0
93.5	139.4	594.2	20.3	23.7	32	5.8	0	0

91.4	142.4	601.4	10.6	16.3	60	5.4	0	0
92.4	117.9	668	12.2	19	34	5.8	0	0
90.9	126.5	686.5	7	19.4	48	1.3	0	0
93.4	145.4	721.4	8.1	30.2	24	2.7	0	0
93.5	149.3	728.6	8.1	22.8	39	3.6	0	0
94.3	85.1	692.3	15.9	25.4	24	3.6	0	0
88.6	91.8	709.9	7.1	11.2	78	7.6	0	0
88.6	69.7	706.8	5.8	20.6	37	1.8	0	0
91.7	75.6	718.3	7.8	17.7	39	3.6	0	0
91.8	78.5	724.3	9.2	21.2	32	2.7	0	0
90.3	80.7	730.2	6.3	18.2	62	4.5	0	0
90.6	35.4	669.1	6.7	21.7	24	4.5	0	0
90	41.5	682.6	8.7	11.3	60	5.4	0	0
90.6	43.7	686.9	6.7	17.8	27	4	0	0
88.1	25.7	67.6	3.8	14.1	43	2.7	0	0
79.5	60.6	366.7	1.5	23.3	37	3.1	0	0
90.2	96.9	624.2	8.9	18.4	42	6.7	0	0
94.8	108.3	647.1	17	16.6	54	5.4	0	0
92.5	88	698.6	7.1	19.6	48	2.7	0	0
90.1	82.9	735.7	6.2	12.9	74	4.9	0	0
94.3	85.1	692.3	15.9	25.9	24	4	0	0
90.9	126.5	686.5	7	14.7	70	3.6	0	0
94.2	62.3	442.9	11	23	36	3.1	0	0
87.2	23.9	64.7	4.1	11.8	35	1.8	0	0
87.6	52.2	103.8	5	11	46	5.8	0	0
92.9	137	706.4	9.2	20.8	17	1.3	0	0
90.2	99.6	631.2	6.3	21.5	34	2.2	0	0
92.1	111.2	654.1	9.6	20.4	42	4.9	0	0
92.1	111.2	654.1	9.6	20.4	42	4.9	0	0
91.7	114.3	661.3	6.3	17.6	45	3.6	0	0
92.9	137	706.4	9.2	27.7	24	2.2	0	0
90.3	80.7	730.2	6.3	17.8	63	4.9	0	0
92.6	46.5	691.8	8.8	13.8	50	2.7	0	0
84	9.3	34	2.1	13.9	40	5.4	0	0
86.6	13.2	43	5.3	12.3	51	0.9	0	0
89.3	51.3	102.2	9.6	11.5	39	5.8	0	0
89.3	51.3	102.2	9.6	5.5	59	6.3	0	0
93	75.3	466.6	7.7	18.8	35	4.9	0	0
90.2	99.6	631.2	6.3	20.8	33	2.7	0	0
91.1	103.2	638.8	5.8	23.1	31	3.1	0	0
91.7	114.3	661.3	6.3	18.6	44	4.5	0	0
92.4	117.9	668	12.2	23	37	4.5	0	0
92.4	117.9	668	12.2	19.6	33	5.4	0	0

92.4	117.9	668	12.2	19.6	33	6.3	0	0
91.7	33.3	77.5	9	17.2	26	4.5	0	0
91.2	48.3	97.8	12.5	15.8	27	7.6	0	0
94.3	85.1	692.3	15.9	17.7	37	3.6	0	0
91.7	33.3	77.5	9	15.6	25	6.3	0	0
88.8	147.3	614.5	9	17.3	43	4.5	0	0
93.3	141.2	713.9	13.9	27.6	30	1.3	0	0
84.2	6.8	26.6	7.7	6.7	79	3.1	0	0
86.6	13.2	43	5.3	15.7	43	3.1	0	0
87.6	52.2	103.8	5	8.3	72	3.1	0	0
90.1	108	529.8	12.5	14.7	66	2.7	0	0
91	121.2	561.6	7	21.6	19	6.7	0	0
91.4	142.4	601.4	10.6	19.5	39	6.3	0	0
90.2	99.6	631.2	6.3	17.9	44	2.2	0	0
94.8	108.3	647.1	17	18.6	51	4.5	0	0
92.1	111.2	654.1	9.6	16.6	47	0.9	0	0
91.7	114.3	661.3	6.3	20.2	45	3.6	0	0
92.9	137	706.4	9.2	21.5	15	0.9	0	0
92.9	137	706.4	9.2	25.4	27	2.2	0	0
92.9	137	706.4	9.2	22.4	34	2.2	0	0
93.5	149.3	728.6	8.1	25.3	36	3.6	0	0
91.7	35.8	80.8	7.8	17.4	25	4.9	0	0
90.2	96.9	624.2	8.9	14.7	59	5.8	0	0
91.7	35.8	80.8	7.8	17.4	24	5.4	0	0
92.3	85.3	488	14.7	20.8	32	6.3	0	0
91.4	142.4	601.4	10.6	18.2	43	4.9	0	0
91.1	103.2	638.8	5.8	23.4	22	2.7	0	0
89.7	90	704.4	4.8	17.8	64	1.3	0	0
83.9	8	30.2	2.6	12.7	48	1.8	0	0
69	2.4	15.5	0.7	17.4	24	5.4	0	0
91.4	142.4	601.4	10.6	11.6	87	4.5	0	0
91.4	142.4	601.4	10.6	19.8	39	5.4	0	0
91.4	142.4	601.4	10.6	19.8	39	5.4	0	0
88.8	147.3	614.5	9	14.4	66	5.4	0	0
94.8	108.3	647.1	17	20.1	40	4	0	0
92.5	121.1	674.4	8.6	24.1	29	4.5	0	0
82.1	3.7	9.3	2.9	5.3	78	3.1	0	0
85.9	19.5	57.3	2.8	12.7	52	6.3	0	0
91.4	30.7	74.3	7.5	18.2	29	3.1	0	0
90.2	99.6	631.2	6.3	21.4	33	3.1	0	0
92.5	88	698.6	7.1	20.3	45	3.1	0	0
88.6	91.8	709.9	7.1	17.4	56	5.4	0	0
85.9	19.5	57.3	2.8	13.7	43	5.8	0	0

91.7	33.3	77.5	9	18.8	18	4.5	0	0
89.7	90	704.4	4.8	22.8	39	3.6	0	0
91.8	78.5	724.3	9.2	18.9	35	2.7	0	0
88.1	25.7	67.6	3.8	15.8	27	7.6	0	0
88.1	25.7	67.6	3.8	15.5	27	6.3	0	0
91.7	35.8	80.8	7.8	11.6	30	6.3	0	0
91.7	35.8	80.8	7.8	15.2	27	4.9	0	0
90.1	39.7	86.6	6.2	10.6	30	4	0	0
93	75.3	466.6	7.7	19.6	36	3.1	0	0
91.5	145.4	608.2	10.7	10.3	74	2.2	0	0
91.5	145.4	608.2	10.7	17.1	43	5.4	0	0
92.4	124.1	680.7	8.5	22.5	42	5.4	0	0
84.4	73.4	671.9	3.2	17.9	45	3.1	0	0
94.3	85.1	692.3	15.9	19.8	50	5.4	0	0
92.6	46.5	691.8	8.8	20.6	24	5.4	0	0
87.6	52.2	103.8	5	9	49	2.2	0	0
93.5	149.3	728.6	8.1	17.2	43	3.1	0	0
91.4	37.9	673.8	5.2	15.9	46	3.6	0	0
92.6	46.5	691.8	8.8	15.4	35	0.9	0	0
68.2	21.5	87.2	0.8	15.4	40	2.7	0	0
87.2	23.9	64.7	4.1	14	39	3.1	0	0
89.3	51.3	102.2	9.6	10.6	46	4.9	0	0
93.7	80.9	685.2	17.9	17.6	42	3.1	0	0
88.1	25.7	67.6	3.8	14.9	38	2.7	0	0
93.5	139.4	594.2	20.3	17.6	52	5.8	0	0
92.4	124.1	680.7	8.5	17.2	58	1.3	0	0
90.9	126.5	686.5	7	15.6	66	3.1	0	0
85.8	48.3	313.4	3.9	18	42	2.7	0	0.307485
91	129.5	692.6	7	21.7	38	2.2	0	0.357674
90.9	126.5	686.5	7	21.9	39	1.8	0	0.385262
95.5	99.9	513.3	13.2	23.3	31	4.5	0	0.438255
90.1	108	529.8	12.5	21.2	51	8.9	0	0.476234
90	51.3	296.3	8.7	16.6	53	5.4	0	0.536493
95.5	99.9	513.3	13.2	23.8	32	5.4	0	0.57098
95.2	131.7	578.8	10.4	27.4	22	4	0	0.641854
90.1	39.7	86.6	6.2	13.2	40	5.4	0	0.667829
84.4	73.4	671.9	3.2	24.2	28	3.6	0	0.672944
94.8	108.3	647.1	17	17.4	43	6.7	0	0.727549
93.7	80.9	685.2	17.9	23.7	25	4.5	0	0.751416
92.5	56.4	433.3	7.1	23.2	39	5.4	0	0.783902
90.1	68.6	355.2	7.2	24.8	29	2.2	0	0.858662
90.1	51.2	424.1	6.2	24.6	43	1.8	0	0.887891
94.3	85.1	692.3	15.9	20.1	47	4.9	0	0.900161

93.4	145.4	721.4	8.1	29.6	27	2.7	0	0.900161
94.8	108.3	647.1	17	16.4	47	1.3	0	0.940007
93.4	145.4	721.4	8.1	28.6	27	2.2	0	0.95935
92.1	111.2	654.1	9.6	18.4	45	3.6	0	0.966984
92.1	111.2	654.1	9.6	20.5	35	4	0	0.970779
92.4	117.9	668	12.2	19	34	5.8	0	0.989541
90.1	39.7	86.6	6.2	16.1	29	3.1	0	1.011601
95.2	131.7	578.8	10.4	20.3	41	4	0	1.064711
90.6	50.1	100.4	7.8	15.2	31	8.5	0	1.07841
92.5	121.1	674.4	8.6	17.8	56	1.8	0	1.081805
89.7	90	704.4	4.8	17.8	67	2.2	0	1.10194
84.9	18.2	55	3	5.3	70	4.5	0	1.144223
92.1	111.2	654.1	9.6	16.6	47	0.9	0	1.190888
96	127.1	570.5	16.5	23.4	33	4.5	0	1.255616
91.2	48.3	97.8	12.5	14.6	26	9.4	0	1.261298
95.2	131.7	578.8	10.4	20.7	45	2.2	0	1.266948
92.9	133.3	699.6	9.2	21.9	35	1.8	0	1.272566
85.6	90.4	609.6	6.6	17.4	50	4	0	1.305626
91.4	142.4	601.4	10.6	20.1	39	5.4	0	1.319086
90.9	126.5	686.5	7	17.7	39	2.2	0	1.403643
90.2	96.9	624.2	8.9	14.2	53	1.8	0	1.504077
90.2	96.9	624.2	8.9	20.3	39	4.9	0	1.710188
81.5	9.1	55.2	2.7	5.8	54	5.8	0	1.724551
90.2	99.6	631.2	6.3	19.2	44	2.7	0	1.73871
90.1	82.9	735.7	6.2	18.3	45	2.2	0	1.771557
88.8	147.3	614.5	9	14.4	66	5.4	0	1.829376
92.4	124.1	680.7	8.5	23.9	32	6.7	0	1.8453
84.9	32.8	664.2	3	19.1	32	4	0	1.862529
86.8	15.6	48.3	3.9	12.4	53	2.2	0	1.998774
91.7	48.5	696.1	11.1	16.8	45	4.5	0	2.057963
93.9	135.7	586.7	15.1	20.8	34	4.9	0	2.074429
91	129.5	692.6	7	17.6	46	3.1	0	2.084429
89.3	51.3	102.2	9.6	11.5	39	5.8	0	2.102914
90.9	126.5	686.5	7	21	42	2.2	0	2.116256
90.8	41.9	89.4	7.9	13.3	42	0.9	0	2.128232
90.7	44	92.4	5.5	11.5	60	4	0	2.223542
91.2	48.3	97.8	12.5	11.7	33	4	0	2.231089
95.2	131.7	578.8	10.4	24.2	28	2.7	0	2.270062
94.8	108.3	647.1	17	24.6	22	4.5	0	2.273156
92.9	133.3	699.6	9.2	24.3	25	4	0	2.342767
94.8	108.3	647.1	17	24.6	22	4.5	0	2.398804
93.9	135.7	586.7	15.1	23.5	36	5.4	0	2.399712
81.5	9.1	55.2	2.7	5.8	54	5.8	0	2.479056

92.9	137	706.4	9.2	21.5	15	0.9	0	2.489894
91	129.5	692.6	7	13.9	59	6.3	0	2.504709
63.5	70.8	665.3	0.8	22.6	38	3.6	0	2.511224
91	129.5	692.6	7	21.6	33	2.2	0	2.528126
90.1	37.6	83.7	7.2	12.4	54	3.6	0	2.572612
83.9	8.7	32.1	2.1	8.8	68	2.2	0	2.642622
91.4	37.9	673.8	5.2	20.2	37	2.7	0	2.687847
90.6	50.1	100.4	7.8	15.1	64	4	0	2.707383
92.9	137	706.4	9.2	22.1	34	1.8	0	2.745346
93.5	139.4	594.2	20.3	22.9	31	7.2	0	2.800325
91	129.5	692.6	7	20.7	37	2.2	0	2.901422
92.4	117.9	668	12.2	19.6	33	6.3	0	3.007167
93.7	80.9	685.2	17.9	23.2	26	4.9	0	3.194993
90.6	43.7	686.9	6.7	18.4	25	3.1	0	3.228034
93.5	139.4	594.2	20.3	5.1	96	5.8	0	3.295837
94.3	85.1	692.3	15.9	20.1	47	4.9	0	3.30064
87.6	52.2	103.8	5	11	46	5.8	0	3.344627
91.7	35.8	80.8	7.8	17	27	4.9	0	3.389799
91.7	35.8	80.8	7.8	17	27	4.9	0	3.389799
92.4	124.1	680.7	8.5	16.9	60	1.3	0	3.417071
88.6	91.8	709.9	7.1	12.4	73	6.3	0	3.444257
92.9	133.3	699.6	9.2	19.4	19	1.3	0	3.487987
90.1	39.7	86.6	6.2	15.2	27	3.1	0	3.492256
90.2	99.6	631.2	6.3	16.2	59	3.1	0	3.498627
93.3	141.2	713.9	13.9	18.6	49	3.6	0	3.607669
87.6	52.2	103.8	5	11	46	5.8	0	3.633631
88.3	150.3	309.9	6.8	13.4	79	3.6	0	3.638112
90.1	82.9	735.7	6.2	15.4	57	4.5	0	3.656098
93.5	149.3	728.6	8.1	22.9	39	4.9	0	3.902982
91.7	48.5	696.1	11.1	16.1	44	4	0	3.919396
92.2	81.8	480.8	11.9	20.1	34	4.5	0	4.082609
93.5	149.3	728.6	8.1	28.3	26	3.1	0	4.175925
92.2	81.8	480.8	11.9	16.4	43	4	0	4.280824
92.9	133.3	699.6	9.2	26.4	21	4.5	0	4.494127
93.5	149.3	728.6	8.1	27.8	27	3.1	0	4.566221
91	129.5	692.6	7	18.7	43	2.7	0	4.648134
84.4	73.4	671.9	3.2	24.3	36	3.1	0	4.669646
92.5	121.1	674.4	8.6	17.7	25	3.1	0	5.049086
91.4	142.4	601.4	10.6	19.6	41	5.8	0	5.285637
92.5	121.1	674.4	8.6	18.2	46	1.8	0	5.307971
91	129.5	692.6	7	18.8	40	2.2	0	5.365415
92.5	121.1	674.4	8.6	25.1	27	4	0	6.99562
81.9	3	7.9	3.5	13.4	75	1.8	0	0

88	17.2	43.5	3.8	15.2	51	2.7	0	0
83	23.3	85.3	2.3	16.7	20	3.1	0	0
94.2	122.3	589.9	12.9	15.4	66	4	0	2.409644
91.8	175.1	700.7	13.8	21.9	73	7.6	1	0
91.8	175.1	700.7	13.8	22.4	54	7.6	0	1.353255
91.8	175.1	700.7	13.8	26.8	38	6.3	0	0.565314
91.8	175.1	700.7	13.8	25.7	39	5.4	0	0.086178
92.2	91.6	503.6	9.6	20.7	70	2.2	0	0.559616
93.1	157.3	666.7	13.5	28.7	28	2.7	0	0
93.1	157.3	666.7	13.5	21.7	40	0.4	0	1.244155
93.1	157.3	666.7	13.5	26.8	25	3.1	0	0.518794
93.1	157.3	666.7	13.5	24	36	3.1	0	0.215111
93.1	157.3	666.7	13.5	22.1	37	3.6	0	0.19062
91.9	109.2	565.5	8	21.4	38	2.7	0	0.924259
91.6	138.1	621.7	6.3	18.9	41	3.1	0	2.428336
87.5	77	694.8	5	22.3	46	4	0	0
94.2	117.2	581.1	11	23.9	41	2.2	0	2.199444
94.2	117.2	581.1	11	21.4	44	2.7	0	0.518794
91.8	170.9	692.3	13.7	20.6	59	0.9	0	0
91.8	170.9	692.3	13.7	23.7	40	1.8	0	0.8671
93.6	97.9	542	14.4	28.3	32	4	0	2.287471
91.6	112.4	573	8.9	11.2	84	7.6	0	1.458615
91.6	112.4	573	8.9	21.4	42	3.1	0	1.658228
91.1	141.1	629.1	7.1	19.3	39	3.6	0	0.940007
94.3	167.6	684.4	13	21.8	53	3.1	0	2.020222
93.7	102.2	550.3	14.6	22.1	54	7.6	0	0.582216
94.3	131.7	607.1	22.7	19.4	55	4	0	0.157004
92.1	152.6	658.2	14.3	23.7	24	3.1	0	0
92.1	152.6	658.2	14.3	21	32	3.1	0	0
92.1	152.6	658.2	14.3	19.1	53	2.7	0	1.686399
92.1	152.6	658.2	14.3	21.8	56	3.1	0	0.41871
92.1	152.6	658.2	14.3	20.1	58	4.5	0	2.329227
92.1	152.6	658.2	14.3	20.2	47	4	0	1.408545
84.4	27.2	353.5	6.8	4.8	57	8.5	0	2.300583
84	27.8	354.6	5.3	5.1	61	8	0	2.500616
84.6	26.4	352	2	5.1	61	4.9	0	1.853168
85.4	25.4	349.7	2.6	4.6	21	8.5	0	2.936513
85.4	25.4	349.7	2.6	4.6	21	8.5	0	2.46215
85.4	25.4	349.7	2.6	4.6	21	8.5	0	3.136798
85.4	25.4	349.7	2.6	4.6	21	8.5	0	2.376764
84.7	26.7	352.6	4.1	2.2	59	4.9	0	2.329227
85.4	25.4	349.7	2.6	5.1	24	8.5	0	3.249211
84.9	27.5	353.5	3.4	4.2	51	4	0	0

86.9	6.6	18.7	3.2	8.8	35	3.1	0	0.741937
85.2	4.9	15.8	6.3	7.5	46	8	0	3.22843
93.9	169.7	411.8	12.3	23.4	40	6.3	0	0
91.2	183.1	437.7	12.5	12.6	90	7.6	0.2	0
91.6	104.2	474.9	9	22.1	49	2.7	0	0
91.6	104.2	474.9	9	24.2	32	1.8	0	0
91.6	104.2	474.9	9	24.3	30	1.8	0	0
91.6	104.2	474.9	9	18.7	53	1.8	0	0
91.6	104.2	474.9	9	25.3	39	0.9	0	2.197225
91.6	100.2	466.3	6.3	22.9	40	1.3	0	1.291984
93.1	180.4	430.8	11	26.9	28	5.4	0	4.471067
92.3	88.8	440.9	8.5	17.1	67	3.6	0	2.024193
93.1	180.4	430.8	11	22.2	48	1.3	0	0
90.4	89.5	290.8	6.4	14.3	46	1.8	0	0.641854
90.4	89.5	290.8	6.4	15.4	45	2.2	0	0
91.2	147.8	377.2	12.7	19.6	43	4.9	0	0
53.4	71	233.8	0.4	10.6	90	2.7	0	0
90.4	93.3	298.1	7.5	20.7	25	4.9	0	0
90.4	93.3	298.1	7.5	19.1	39	5.4	0	1.508512
91.1	94.1	232.1	7.1	19.2	38	4.5	0	0
91.1	94.1	232.1	7.1	19.2	38	4.5	0	0
85.1	28	113.8	3.5	11.3	94	4.9	0	0
89.6	84.1	714.3	5.7	19	52	2.2	0	0
89.6	84.1	714.3	5.7	17.1	53	5.4	0	0.34359
89.6	84.1	714.3	5.7	23.8	35	3.6	0	1.821318
92.4	105.8	758.1	9.9	16	45	1.8	0	0
92.4	105.8	758.1	9.9	24.9	27	2.2	0	0
92.4	105.8	758.1	9.9	25.3	27	2.7	0	0
92.4	105.8	758.1	9.9	24.8	28	1.8	0	2.727199
50.4	46.2	706.6	0.4	12.2	78	6.3	0	0
92.6	115.4	777.1	8.8	24.3	27	4.9	0	0
92.6	115.4	777.1	8.8	19.7	41	1.8	0	0.947789
91.2	134.7	817.5	7.2	18.5	30	2.7	0	0
92.4	96.2	739.4	8.6	18.6	24	5.8	0	0
92.4	96.2	739.4	8.6	19.2	24	4.9	0	1.564441
92.8	119	783.5	7.5	21.6	27	2.2	0	0
92.8	119	783.5	7.5	21.6	28	6.3	0	1.688249
92.8	119	783.5	7.5	18.9	34	7.2	0	3.565581
92.8	119	783.5	7.5	16.8	28	4	0	2.105353
92.8	119	783.5	7.5	16.8	28	4	0	0.698135
90.7	136.9	822.8	6.8	12.9	39	2.7	0	1.156881
88.1	53.3	726.9	5.4	13.7	56	1.8	0	1.690096
92.2	102.3	751.5	8.4	24.2	27	3.1	0	0

92.2	102.3	751.5	8.4	24.1	27	3.1	0	0
92.2	102.3	751.5	8.4	21.2	32	2.2	0	0
92.2	102.3	751.5	8.4	19.7	35	1.8	0	0
92.2	102.3	751.5	8.4	23.5	27	4	0	1.465568
92.2	102.3	751.5	8.4	24.2	27	3.1	0	2.025513
91.2	124.4	795.3	8.5	21.5	28	4.5	0	2.811809
91.2	124.4	795.3	8.5	17.1	41	2.2	0	2.503074
92.1	87.7	721.1	9.5	18.1	54	3.1	0	1.141033
91.6	108.4	764	6.2	18	51	5.4	0	0
91.6	108.4	764	6.2	9.8	86	1.8	0	0
91.6	108.4	764	6.2	19.3	44	2.2	0	0
91.6	108.4	764	6.2	23	34	2.2	0	4.043753
91.6	108.4	764	6.2	22.7	35	2.2	0	2.13771
91.6	108.4	764	6.2	20.4	41	1.8	0	0.904218
91.6	108.4	764	6.2	19.3	44	2.2	0	1.595339
91.9	111.7	770.3	6.5	15.7	51	2.2	0	0
91.5	130.1	807.1	7.5	20.6	37	1.8	0	0
91.5	130.1	807.1	7.5	15.9	51	4.5	0	1.156881
91.5	130.1	807.1	7.5	12.2	66	4.9	0	1.960095
91.5	130.1	807.1	7.5	16.8	43	3.1	0	1.921325
91.5	130.1	807.1	7.5	21.3	35	2.2	0	3.373826
92.1	99	745.3	9.6	10.1	75	3.6	0	0
92.1	99	745.3	9.6	17.4	57	4.5	0	0
92.1	99	745.3	9.6	12.8	64	3.6	0	0.970779
92.1	99	745.3	9.6	10.1	75	3.6	0	1.549688
92.1	99	745.3	9.6	15.4	53	6.3	0	2.11746
92.1	99	745.3	9.6	20.6	43	3.6	0	1.108563
92.1	99	745.3	9.6	19.8	47	2.7	0	1.000632
92.1	99	745.3	9.6	18.7	50	2.2	0	1.941615
92.1	99	745.3	9.6	20.8	35	4.9	0	2.643334
92.1	99	745.3	9.6	20.8	35	4.9	0	0.815365
92.5	122	789.7	10.2	15.9	55	3.6	0	0
92.5	122	789.7	10.2	19.7	39	2.7	0	0
92.5	122	789.7	10.2	21.1	39	2.2	0	2.21047
92.5	122	789.7	10.2	18.4	42	2.2	0	0.737164
92.5	122	789.7	10.2	17.3	45	4	0	1.597365
88.2	55.2	732.3	11.6	15.2	64	3.1	0	0.41871
91.9	111.7	770.3	6.5	15.9	53	2.2	0	1.368639
91.9	111.7	770.3	6.5	21.1	35	2.7	0	1.894617
91.9	111.7	770.3	6.5	19.6	45	3.1	0	3.04595
91.1	132.3	812.1	12.5	15.9	38	5.4	0	1.011601
91.1	132.3	812.1	12.5	16.4	27	3.6	0	0
91.2	94.3	744.4	8.4	16.8	47	4.9	0	2.613007

91	276.3	825.1	7.1	13.8	77	7.6	0	0
91	276.3	825.1	7.1	13.8	77	7.6	0	2.489894
91.9	133.6	520.5	8	14.2	58	4	0	0
92	203.2	664.5	8.1	10.4	75	0.9	0	0
94.8	222.4	698.6	13.9	20.3	42	2.7	0	0
90.3	290	855.3	7.4	10.3	78	4	0	2.960105
91.2	94.3	744.4	8.4	15.4	57	4.9	0	3.697591
92.1	207	672.6	8.2	21.1	54	2.2	0	0
93.7	231.1	715.1	8.4	21.9	42	2.2	0	5.16838
90.9	18.9	30.6	8	8.7	51	5.8	0	0
18.7	1.1	171.4	0	5.2	100	0.9	0	0
93.7	101.3	458.8	11.9	19.3	39	7.2	0	2.166765
90.7	194.1	643	6.8	16.2	63	2.7	0	2.852439
95.2	217.7	690	18	28.2	29	1.8	0	1.925707
91.6	248.4	753.8	6.3	20.5	58	2.7	0	3.781231
91.6	273.8	819.1	7.7	21.3	44	4.5	0	2.578701
91.6	181.3	613	7.6	20.9	50	2.2	0	2.833213
90.5	96.7	750.5	11.4	20.6	55	5.4	0	3.242202
90.9	18.9	30.6	8	11.6	48	5.4	0	0
94.8	227	706.7	12	23.3	34	3.1	0	3.392493
94.8	227	706.7	12	23.3	34	3.1	0	0
84.7	9.5	58.3	4.1	7.5	71	6.3	0	2.394252
91.1	91.3	738.1	7.2	20.7	46	2.7	0	3.439777
91	276.3	825.1	7.1	21.9	43	4	0	4.273327
93.4	15	25.6	11.4	15.2	19	7.6	0	0
84.1	4.6	46.7	2.2	5.3	68	1.8	0	0
85	9	56.9	3.5	10.1	62	1.8	0	3.966132
90.5	96.7	750.5	11.4	20.4	55	4.9	0	1.534714
91.6	181.3	613	7.6	24.3	33	3.6	0	1.532557
93.7	231.1	715.1	8.4	25.9	32	3.1	0	0
93.3	49.5	297.7	14	28	34	4.5	0	0
93.3	49.5	297.7	14	28	34	4.5	0	2.214846
91.1	88.2	731.7	8.3	22.8	46	4	0	1.783391
94.8	227	706.7	12	25	36	4	0	0
90.7	194.1	643	6.8	21.3	41	3.6	0	0
87.9	84.8	725.1	3.7	21.8	34	2.2	0	1.951608
94.6	212.1	680.9	9.5	27.9	27	2.2	0	0
87.1	291.3	860.6	4	17	67	4.9	0	1.599388
84.7	8.2	55	2.9	14.2	46	4	0	0
90.3	290	855.3	7.4	19.9	44	3.1	0	2.174752
92.3	96.2	450.2	12.1	23.4	31	5.4	0	0
84.1	7.3	52.8	2.7	14.7	42	2.7	0	0
84.6	3.2	43.6	3.3	8.2	53	9.4	0	1.726332

92.3	92.1	442.1	9.8	22.8	27	4.5	0	0.966984
93.7	231.1	715.1	8.4	26.4	33	3.6	0	0
93.6	235.1	723.1	10.1	24.1	50	4	0	0
94.8	222.4	698.6	13.9	27.5	27	4.9	0	6.61644
92.7	164.1	575.8	8.9	26.3	39	3.1	0	2.081938
93.4	17.3	28.3	9.9	13.8	24	5.8	0	0
92	203.2	664.5	8.1	24.9	42	5.4	0	1.235471
91.6	181.3	613	7.6	24.8	36	4	0	1.398717
91.7	191.4	635.9	7.8	26.2	36	4.5	0	5.229824
95.2	217.7	690	18	30.8	19	4.5	0	0
88.9	263.1	795.9	5.2	29.3	27	3.6	0	1.987874
91.2	94.3	744.4	8.4	22.3	48	4	0	0.542324
93.7	231.1	715.1	8.4	26.9	31	3.6	0	1.78507
91.6	248.4	753.8	6.3	20.4	56	2.2	0	0
91.6	248.4	753.8	6.3	20.4	56	2.2	0	0
92.1	207	672.6	8.2	27.9	33	2.2	0	1.20896
94.8	222.4	698.6	13.9	26.2	34	5.8	0	0
91.6	181.3	613	7.6	24.6	44	4	0	1.435085
89.7	287.2	849.3	6.8	19.4	45	3.6	0	0
92.1	178	605.3	9.6	23.3	40	4	0	1.99606
94.8	222.4	698.6	13.9	23.9	38	6.7	0	0
93.6	235.1	723.1	10.1	20.9	66	4.9	0	2.793616
90.6	269.8	811.2	5.5	22.2	45	3.6	0	0
90.8	84.7	376.6	5.6	23.8	51	1.8	0	0
92.1	207	672.6	8.2	26.8	35	1.3	0	0.431782
89.4	253.6	768.4	9.7	14.2	73	2.7	0	0
93.7	231.1	715.1	8.4	23.6	53	4	0	2.005526
91.1	91.3	738.1	7.2	19.1	46	2.2	0	0.285179
90.3	290	855.3	7.4	16.2	58	3.6	0	0
92.1	207	672.6	8.2	25.5	29	1.8	0	0.802002
87.9	24.9	41.6	3.7	10.9	64	3.1	0	1.470176
90.7	80.9	368.3	16.8	14.8	78	8	0	0
90.3	290	855.3	7.4	16.2	58	3.6	0	2.394252
94	47.9	100.7	10.7	17.3	80	4.5	0	0
92	203.2	664.5	8.1	19.1	70	2.2	0	0
93.4	17.3	28.3	9.9	8.9	35	8	0	0
89.7	284.9	844	10.1	10.5	77	4	0	0
91.6	181.3	613	7.6	19.3	61	4.9	0	0
95.2	217.7	690	18	23.4	49	5.4	0	2.005526
90.5	196.8	649.9	16.3	11.8	88	4.9	0	2.371178
91.5	238.2	730.6	7.5	17.7	65	4	0	0
89.4	266.2	803.3	5.6	17.4	54	3.1	0	0
91.6	248.4	753.8	6.3	16.8	56	3.1	0	0

94.6	160	567.2	16.7	17.9	48	2.7	0	0
91.6	248.4	753.8	6.3	16.6	59	2.7	0	0
91.7	191.4	635.9	7.8	19.9	50	4	0	4.427836
93.7	231.1	715.1	8.4	18.9	64	4.9	0	1.463255
91.6	273.8	819.1	7.7	15.5	72	8	0	1.07841
93.7	231.1	715.1	8.4	18.9	64	4.9	0	0
93.7	231.1	715.1	8.4	18.9	64	4.9	0	0
91	276.3	825.1	7.1	14.5	76	7.6	0	1.549688
75.1	4.4	16.2	1.9	4.6	82	6.3	0	1.854734
75.1	4.4	16.2	1.9	5.1	77	5.4	0	1.144223
79.5	3.6	15.3	1.8	4.6	59	0.9	0	2.059239
87.2	15.1	36.9	7.1	10.2	45	5.8	0	1.430311
90.2	18.5	41.1	7.3	11.2	41	5.4	0	1.879465
91.3	20.6	43.5	8.5	13.3	27	3.6	0	2.029463
91	14.6	25.6	12.3	13.7	33	9.4	0	4.129229
91	14.6	25.6	12.3	17.6	27	5.8	0	0
89.6	25.4	73.7	5.7	18	40	4	0	3.675794
88.2	96.2	229	4.7	14.3	79	4	0	1.07841
90.5	61.1	252.6	9.4	24.5	50	3.1	0	4.267177
93	103.8	316.7	10.8	26.4	35	2.7	0	2.405142
93.7	121.7	350.2	18	22.7	40	9.4	0	1.432701
93.5	85.3	395	9.9	27.2	28	1.3	0	1.015231
93.7	101.3	423.4	14.7	26.1	45	4	0	2.123458
93.7	101.3	423.4	14.7	18.2	82	4.5	0	1.166271
89.2	103.9	431.6	6.4	22.6	57	4.9	0	5.63311
93.2	114.4	560	9.5	30.2	25	4.5	0	1.321756
93.2	114.4	560	9.5	30.2	22	4.9	0	0
94.9	130.3	587.1	14.1	23.4	40	5.8	0	0.828552
94.9	130.3	587.1	14.1	31	27	5.4	0	0
94.9	130.3	587.1	14.1	33.1	25	4	0	3.311637
95	135.5	596.3	21.3	30.6	28	3.6	0	1.121678
95.1	141.3	605.8	17.7	24.1	43	6.3	0	1.098612
95.1	141.3	605.8	17.7	26.4	34	3.6	0	2.85647
95.1	141.3	605.8	17.7	19.4	71	7.6	0	3.864931
95.1	141.3	605.8	17.7	20.6	58	1.3	0	0
95.1	141.3	605.8	17.7	28.7	33	4	0	0
95.8	152	624.1	13.8	32.4	21	4.5	0	0
95.9	158	633.6	11.3	32.4	27	2.2	0	0
95.9	158	633.6	11.3	27.5	29	4.5	0	3.791436
96	164	643	14	30.8	30	4.9	0	2.260721
96.2	175.5	661.8	16.8	23.9	42	2.2	0	0
96.2	175.5	661.8	16.8	32.6	26	3.1	0	1.327075
96.1	181.1	671.2	14.3	32.3	27	2.2	0	2.752386

96.1	181.1	671.2	14.3	33.3	26	2.7	0	3.726657
96.1	181.1	671.2	14.3	27.3	63	4.9	6.4	2.469793
96.1	181.1	671.2	14.3	21.6	65	4.9	0.8	0
96.1	181.1	671.2	14.3	21.6	65	4.9	0.8	0
96.1	181.1	671.2	14.3	20.7	69	4.9	0.4	0
94.5	139.4	689.1	20	29.2	30	4.9	0	1.081805
94.5	139.4	689.1	20	28.9	29	4.9	0	3.923754
91	163.2	744.4	10.1	26.7	35	1.8	0	1.916923
91	166.9	752.6	7.1	18.5	73	8.5	0	0
91	166.9	752.6	7.1	25.9	41	3.6	0	0
91	166.9	752.6	7.1	25.9	41	3.6	0	0
91	166.9	752.6	7.1	21.1	71	7.6	1.4	1.153732
91	166.9	752.6	7.1	18.2	62	5.4	0	0.357674
81.6	56.7	665.6	1.9	27.8	35	2.7	0	0
81.6	56.7	665.6	1.9	27.8	32	2.7	0	2.006871
81.6	56.7	665.6	1.9	21.9	71	5.8	0	4.012592
81.6	56.7	665.6	1.9	21.2	70	6.7	0	2.498152
94.4	146	614.7	11.3	25.6	42	4	0	0
79.5	3	106.7	1.1	11.8	31	4.5	0	0

DAFTAR RIWAYAT HIDUP

A. Biodata Mahasiswa

B. Pendidikan Formal

1. SDN Bina Bangun 1 Jatiwaringin, lulus tahun 2000
 2. SLTPN 17 Bekasi, lulus tahun 2003
 3. SMA Yadika 4 Jakarta Timur, lulus tahun 2006
 4. Diploma Tiga Bina Sarana Informatika, lulus tahun 2009
 5. STMIK Nusa Mandiri, lulus tahun 2011



Jakarta 14 Februari 2015

Saya yang bersangkutan

Hani Harafani