

**OPTIMASI PARAMETER PADA SUPPORT VECTOR MACHINE
DENGAN MENGGUNAKAN ALGORITMA GENETIKA**



TESIS

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

TRI SANTOSO

14001107

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	Tri Santoso
NIM	14001107
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 Dengan Menggunakan Algoritma Genetika"** 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 dan 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, 07 Desember 2015

Yang menyatakan,


NPMADFS21006573
6000
Tri Santoso

HALAMAN PENGESAHAN

Tesis ini diajukan oleh :

Nama : Tri Santoso
NIM : 14001107
Program Studi : Magister Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : *Management Information System*
Judul Tesis : "Optimasi Parameter Pada *Support Vector Machine* Dengan Menggunakan Algoritma Genetika"

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, 07 Desember 2015
Pascasarjana Magister Ilmu Komputer
STMIK Nusa Mandiri
Direktur

Prof. Dr. Ir. R. Eko Indrajit, MSC, MBA

DEWAN PENGUJI

Penguji I : Dr. Sfenrianto, M.Kom

Penguji II : Drs. Bambang Setyarso, MA

Penguji III /
Pembimbing : Dr. Mochamad Wahyudi, MM, M.Kom, M.Pd





LEMBAR KONSULTASI BIMBINGAN TESIS

SEKOLAH TINGGI MANAJEMEN INFORMATIKA & KOMPUTER
NUSA MANDIRI



- NIM : 14001171
- Nama Lengkap : Tri Santoso
- Dosen Pembimbing : Dr. Mochamad Wahyudi, MM, M.Kom, M.Pd
- Judul Tesis : Optimasi Parameter pada Support Vector Machine dengan Menggunakan Algoritma Genetika

No	Tanggal Bimbingan	Pokok Bahasan	Paraf Dosen Pembimbing
1	26 Okt '15	Bimbingan perdana & Pengajuan Bab I	
2	02 Nop '15	Pengajuan Bab II	
3	06 Nop '15	Pengajuan Bab III	
4	13 Nop '15	Pengajuan Bab IV	
5	20 Nop '15	Pengajuan Bab V	
6	30 Nop '15	Periksa keseluruhan & Acc Ujian Sidang	

Catatan untuk dosen pembimbing

Bimbingan Tesis

- Dimulai pada tanggal : 26 Oktober 2015
- Diakhiri pada tanggal : 30 Nopember 2015
- Jumlah pertemuan bimbingan : 6 Kali Bimbingan

Disetujui Oleh,
Dosen Pembimbing

Dr. Mochamad Wahyudi, MM, M.Kom, M.Pd

KATA PENGANTAR

Alhamdulillahirobbil'alamin, penulis memanjatkan puji dan rasa terima kasih yang tak terhingga kepada Allah SWT atas limpahan rahmat dan kasih sayang-Nya, sehingga tesis berjudul "*Optimasi Parameter Pada Support Vector Machine Dengan Menggunakan Algoritma Genetika*" dapat diselesaikan dengan penuh hikmah. Tesis ini disusun sebagai bentuk laporan penelitian untuk memenuhi syarat kelulusan pada program Pasca Sarjana STMIK Nusa Mandiri.

Penulis menyadari bahwa penyelesaian tesis ini tidak lepas dari bantuan dan dukungan berbagai pihak. Oleh karena itu, pada kesempatan ini, penulis ingin menyampaikan rasa terima kasih yang sebesar-besarnya kepada:

1. Orang tua, keluarga dan sahabat yang mendukung penyelesaian tesis ini.
2. Bapak Dr. Mochamad Wahyudi, MM, M.Kom, M.Pd selaku dosen pembimbing yang telah memberikan arahan, bimbingan, dan masukan yang sangat berharga selama proses penyusunan tesis.
3. Semua pihak yang telah turut membantu dan memberikan dukungan, baik secara langsung maupun tidak langsung, dalam menyelesaikan tesis ini.

Semoga tesis ini dapat bermanfaat bagi pengembangan ilmu pengetahuan dan memberikan kontribusi yang positif bagi masyarakat.

Jakarta, 7 Desember 2015



Tri Santoso
Penulis

ABSTRAK

Nama : Tri Santoso
NIM : 14001107
Program Studi : Magsiter Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : *Management Information System*
Judul : “Optimasi Parameter Pada *Support Vector Machine* Dengan Menggunakan Algoritma Genetika”

Support Vector Machine atau yang biasa di singkat dengan SVM merupakan metode yang digunakan untuk klasifikasi dan regresi. Metode ini banyak digunakan di berbagai bidang. Namun metode SVM memiliki kelemahan dalam menentukan parameter yang akan digunakan untuk memproses data. Di dalam penelitian ini kami menggunakan metode dengan menggunakan Algoritma Genetika (GA) yang berbasis *Support Vektor Machine* (SVM) dengan menggunakan parameter optimasi. Metode ini memanfaatkan GA untuk mengoptimalkan metode seleksi parameter SVM sesuai dengan data pelatihan dan meningkatkan ketepatan SVM. Hasil penelitian akan kami gunakan untuk dibandingkan dengan metode yang hanya menggunakan SVM saja. Data yang kami gunakan untuk penelitian ini, kami ambil dari UCI. Hasil penelitian yang diperoleh menunjukkan bahwa metode yang kami gunakan memberikan akurasi prediksi yang lebih baik dalam mengidentifikasi data yang kami gunakan dibandingkan dengan metode yang hanya menggunakan SVM saja. Hal ini terbukti saat kami membandingkan hasil perhitungan yang kami lakukan. Nilai *accuracy* ILPD (*Indian Liver Patient Dataset*) yang kami ambil dari UCI masing-masing adalah 71,36%, nilai tersebut adalah hasil dari perhitungan dengan menggunakan SVM. Sedangkan saat kami menggunakan GA-SVM, nilai Iris, Ecoli dan WDBC meningkat menjadi 72,22%. Hal yang sama terjadi pada hampir semua nilai yang dihasilkan. Hal ini membuktikan bahwa GA-SVM memiliki kinerja yang lebih baik daripada SVM.

Kata Kunci : Algoritma Genetika, *Support Vector Machine*, Optimasi

ABSTRACT

Nama : Tri Santoso
NIM : 14001107
Program Studi : Magsiter Ilmu Komputer
Jenjang : Strata Dua (S2)
Konsentrasi : *Management Information System*
Judul : “Optimasi Parameter Pada *Support Vector Machine* Dengan Menggunakan Algoritma Genetika”

Support Vector Machine or commonly abbreviated as SVM is a method used for classification and regression. This method is widely used in various fields. However, the SVM method has weaknesses in determining the parameters that will be used to process data. In this research we use a method using a Genetic Algorithm (GA) based on a Support Vector Machine (SVM) using optimization parameters. This method utilizes GA to optimize the SVM parameter selection method according to the training data and improves the accuracy of the SVM. We will use the research results to compare with methods that only use SVM. The data we use for this research, we took from UCI. The research results obtained show that the method we use provides better prediction accuracy in identifying the data we use compared to methods that only use SVM. This was proven when we compared the results of the calculations we carried out. The ILPD (Indian Liver Patient Dataset) accuracy value that we took from the UCI is 71.36%, this value is the result of calculations using SVM. Meanwhile, when we use GA-SVM, the Iris, Ecoli and WDBC values increase to 72.22%. The same thing happens to almost all the value produced. This proves that GA-SVM has better performance than SVM.

Keywords: Genetic Algorithm, Support Vector Machine, Optimization

DAFTAR ISI

LEMBAR JUDUL.....	i
SURAT PERNYATAAN ORISINALITAS.....	ii
HALAMAN PENGESAHAN	iii
LEMBAR BIMBINGAN	iv
KATA PENGANTAR.....	v
ABSTRAK.....	vi
ABSTRACT.....	vii
DAFTAR ISI.....	viii
DAFTAR TABEL	ix
DAFTAR GAMBAR	x
DAFTAR LAMPIRAN	xi
BAB 1 PENDAHULUAN	1
1.1 Latar Belakang Penulisan	1
1.2 Identifikasi Masalah	3
1.3 Tujuan Penelitian	3
1.4 Ruang Lingkup Penelitian	3
1.5 Hipotesis	4
BAB 2 LANDASAN TEORI.....	5
2.1 Tinjauan Pustaka	5
2.1.1 Penelitian dari Ilhan dan Tezel (2013)	5
2.1.2 Penelitian dari Sajan et al (2015)	6
2.1.3 Penelitian dari Guo et al (2012)	9
2.1.4 Penelitian dari Zhao et al (2011)	10
2.1.5 Penelitian dari Patil et al (2012)	11
2.2 Tinjauan Studi.....	13
2.2.1 <i>Data Mining</i>	13
2.2.2 <i>Support Vector Machine</i>	13
2.2.3 Algoritma Genetika	16
BAB 3 METODE PENELITIAN.....	19
3.1 Perancangan Penelitian.....	19
3.2 Pengumpulan Data	20
3.3 Pengolahan Awal Data	21
3.4 Metode Yang Diusulkan.....	21
3.5 Eksperimen Dan Pengujian Metode.....	25
3.6 Evaluasi Dan Validasi	25
BAB 4 HASIL DAN PEMBAHASAN	27
4.1 Tahapan Pengujian	27
4.2 Hasil Eksperimen dan Pengujian Metode.....	28
4.2.1 Metode <i>Support Vector Machine</i>	28
4.2.2 Metode <i>Support Vector Machine</i> dengan Optimasi Algoritma Genetika	30
BAB 5 PENUTUP.....	33
5.1 Kesimpulan.....	33
5.2 Saran.....	33
DAFTAR PUSTAKA.....	34
LAMPIRAN.....	37

DAFTAR TABEL

Tabel 3.1 ILPD (<i>Indian Liver Patient Dataset</i>).....	20
Tabel 4.1 Tabel perbandingan tingkat akurasi SVM dan SVM-GA.....	31

DAFTAR GAMBAR

Gambar 2.1 Metode yang Diusulkan oleh Ilhan dan Tezel (2013)	6
Gambar 2.2 Metode yang Diusulkan oleh Sajan et al (2015)	8
Gambar 2.3 Metode yang Diusulkan oleh Guo et al (2012)	9
Gambar 2.4 Metode yang Diusulkan oleh Zhao et al (2011)	11
Gambar 2.5 Metode yang Diusulkan oleh Patil et al (2012)	12
Gambar 2.6 Pemisahan dua kelas dengan margin maksimum pada SVM	14
Gambar 2.7 Alur proses Algoritma Genetika	17
Gambar 3.1 <i>Flowchart</i> SVM	22
Gambar 3.2 <i>Flowchart</i> GA-SVM	22
Gambar 4.1 Pengujian metode SVM	29
Gambar 4.2 Tingkat akurasi metode SVM	29
Gambar 4.3 Pengujian metode SVM-GA	30
Gambar 4.4 Tingkat akurasi metode SVM-GA	31
Gambar 4.5 Diagram tingkat akurasi SVM dan SVM-GA	32

DAFTAR LAMPIRAN

Lampiran 1 Dataset ILPD (<i>Indian Liver Patient Dataset</i>)	37
---	----

BAB 1

PENDAHULUAN

1.1 Latar Belakang Penulisan

Sekarang ini, pesatnya perkembangan teknologi terus meningkat di segala bidang [1]. Salah satu yang memegang peranan penting dalam perkembangan teknologi tersebut adalah *data mining* [2]. Dengan *data mining*, kita bisa mengelola data dan membuat informasi dari data dalam jumlah yang besar [3], [4]. Data besar ini juga bisa disebut dengan *big data* karena ukurannya yang besar, kompleks dan berkembang dengan berbagai sumber yang otonom [5]. Data yang besar tersebut biasanya berasal dari basis data yang digunakan dalam sistem komputer [6]. Didalam data mining, kita bisa mempelajari *artificial intelligence* dan *knowledge engineering* yang berakar dari *machine learning* dan *statistics* [7]. Maka dari itu, data mining sangat bermanfaat dan mendorong terciptanya teknologi baru.

Salah satu metode yang ada di data mining adalah SVM. SVM merupakan metode klasifikasi dan regresi yang banyak di gunakan di berbagai bidang [8]. SVM juga dikenal sebagai pengklasifikasi cerdas dengan kemampuan generalisasi yang kuat [9]. Sebagai contoh, SVM bisa kita gunakan untuk mengidentifikasi apakah opini yang diungkapkan dalam suatu dokumen positif atau negatif tentang suatu topik tertentu [10]. SVM juga bisa kita gunakan untuk mengenali tingkah laku manusia untuk tujuan tertentu [11].

SVM dapat menangani kumpulan data berdimensi tinggi, heterogen, dan jarang diberi label dengan sangat efisien, dan juga dapat berhasil disesuaikan dengan aplikasi

tertentu [12]. Keakuratan SVM dipengaruhi oleh jumlah fitur dan jumlah data yang ada [13].

Secara singkat, konsep yang dilakukan SVM dalam klasifikasi masalah yaitu SVM melatih pengklasifikasi dengan memecahkan masalah optimasi untuk memutuskan contoh mana dari kumpulan data pelatihan yang merupakan vektor pendukung, yang merupakan contoh yang sangat informatif untuk membentuk pengklasifikasi SVM [14].

Meskipun secara teori SVM telah banyak digunakan di berbagai bidang, namun dalam penerapannya belum bisa mencapai hasil yang diharapkan dari teori tersebut. Hal ini dikarenakan SVM standar masih memiliki beberapa keterbatasan dan kinerjanya bergantung pada pemilihan parameternya [15]. Pemilihan fungsi dan parameter kernel merupakan salah satu faktor utama yang mempengaruhi hasil SVM. Normalnya parameter pada model SVM dapat dipilih secara manual berdasarkan pengalaman, sehingga kurangnya panduan teori yang matang [16]. SVM juga lemah jika mengklasifikasikan kumpulan data berdimensi tinggi dengan sejumlah ukuran fitur yang besar [17].

Sementara itu, terdapat metode Algoritma Genetika (GA) yang merupakan salah satu metode pencarian. Metode ini mencari hasil yang sama atau mendekati jawaban dari masalah yang diberikan [18]. Algoritma Genetika (GA) bisa menjadi solusi untuk memecahkan masalah optimasi dalam sistem kendali suatu proses [19]. Algoritma Genetika (GA) beroperasi pada populasi solusi, bukan pada solusi tunggal. Pencarian genetik dimulai dengan inisialisasi populasi individu. Solusi individual dipilih dari populasi, kemudian dikawinkan untuk membentuk solusi baru [20].

Dari penjabaran diatas, dalam penelitian ini kami mengusulkan Algoritma Genetika (GA), dimana GA akan kami gunakan untuk mengoptimasi parameter pada

SVM sehingga kinerja SVM akan lebih meningkat. Metode yang kami usulkan ini selanjutnya akan disebut GA-SVM.

1.2 Identifikasi Masalah

Berdasarkan uraian latar belakang di atas, identifikasi penelitian ini yaitu bahwa SVM merupakan metode klasifikasi dan regresi yang banyak di gunakan di berbagai bidang. Namun dalam penerapannya belum bisa mencapai hasil yang diharapkan, dikarenakan SVM standar masih memiliki beberapa keterbatasan dan kinerjanya bergantung pada pemilihan parameternya. Hal ini akan mempengaruhi keakurasian dari hasil SVM

1.3 Tujuan Penelitian

Tujuan dari penelitian ini adalah untuk mendapatkan tingkat keakurasian yang lebih baik dari SVM standar. Untuk detail dari tujuan penelitian ini adalah:

1. Menerapkan Algoritma Genetika untuk membantu menentukan parameter yang tepat dalam SVM.
2. Membandingkan hasil GA-SVM dengan SVM standar untuk melihat keakurasian yang lebih baik.
3. Melakukan pengujian kembali dengan data set yang berbeda untuk memastikan hasil perbandingan yang pertama.

1.4 Ruang Lingkup Penelitian

Ruang lingkup penelitian ini terbatas pada penerapan Algoritma Genetika untuk membantu penentuan parameter pada SVM dan membandingkan hasil GA-SVM dengan SVM standar untuk memastikan mana yang lebih baik

1.5 Hipotesis

.Penelitian ini memiliki 2 hopitiesis yaitu H_0 dan H_1 . H_0 menandakan bahwa Algoritma Genetika tidak meningkatkan keakurasian dari hasil SVM. Sementara H_1 menandakan bahwa Algoritma Genetika meningkatkan keakurasian dari hasil SVM.

BAB 2

LANDASAN TEORI


2.1 Tinjauan Pustaka

Beberapa penelitian yang menjadi tinjauan studi ini adalah:

2.1.1 Penelitian dari Ilhan dan Tezel (2013)

SNP (*Single Nucleotide Polimorfisme*) meliputi jutaan perubahan genom manusia, dan karena itu, adalah alat yang menjanjikan untuk studi hubungan penyakit-gen. Namun, jenis studi dibatasi oleh biaya tinggi dari genotip jutaan SNP. Untuk alasan ini, diperlukan untuk mendapatkan sub-set yang cocok dari SNP untuk secara akurat mewakili seluruh SNP. Untuk tujuan ini, banyak metode yang telah dikembangkan untuk memilih subset nyaman tag SNP, tapi semua dari mereka hanya menyediakan akurasi prediksi rendah. Dalam penelitian ini, metode baru dikembangkan dan diperkenalkan sebagai GA-SVM dengan optimasi parameter. Metode ini manfaat dari mesin dukungan vektor (SVM) dan algoritma genetika (GA) untuk memprediksi SNP dan untuk memilih SNP tag, masing-masing. Selain itu juga menggunakan partikel optimasi segerombolan (PSO) algoritma untuk mengoptimalkan C dan c parameter mesin dukungan vektor. Hal ini eksperimen diuji pada berbagai dataset, dan hasil yang diperoleh menunjukkan bahwa metode ini dapat memberikan akurasi prediksi yang lebih baik dalam mengidentifikasi SNP tag dibandingkan dengan metode lain saat ini [21].

Berikut merupakan metode yang diusulkan oleh Ilham dan Tezel:




Gambar 2.1 Metode yang Diusulkan oleh Ilhan dan Tezel (2013)

2.1.2 Penelitian dari Sajan et al (2015)

Sebuah penelitian berdasarkan Algoritma Genetika Support Vector Machine (GA-SVM) pendekatan untuk pemantauan online ketidakstabilan tegangan jangka panjang telah diusulkan dalam makalah ini. Metode konvensional untuk tegangan stabilitas monitoring sangat memakan waktu maka tidak layak untuk aplikasi online. Mesin dukungan vektor adalah alat estimasi fungsi yang kuat dan menjanjikan. Untuk

meningkatkan akurasi dan meminimalkan waktu pelatihan SVM, nilai optimal dari parameter SVM yang diperoleh dengan menggunakan algoritma genetika. Pendekatan yang diusulkan menggunakan besaran tegangan dan sudut fase diperoleh dari fasor Pengukuran Unit (PMU) sebagai masukan vektor untuk SVM dan vektor output Tegangan Stabilitas Margin Index (VSMI). Efektivitas pendekatan yang diusulkan diuji menggunakan New England sistem uji 39-bus dan India Wilayah Utara Power Grid (NRPG) 246-bus sistem nyata. Hasil diusulkan pendekatan GA-SVM untuk pemantauan stabilitas tegangan dibandingkan dengan pencarian jaringan SVM (GS-SVM) dan jaringan syaraf tiruan (JST) pendekatan dengan data yang sama ditetapkan untuk membuktikan keunggulannya [22].

Berikut merupakan metode yang diusulkan oleh Sajan et al (2015):




Gambar 2.2 Metode yang Diusulkan oleh Sajan et al (2015)

2.1.3 Penelitian dari Guo et al (2012)

Harga minyak perkiraan model perbaikan yang menggunakan mesin dukungan vektor (SVM) dikembangkan. Model baru, yang disebut model perkiraan GA-SVM, didasarkan pada algoritma genetika (GA) parameter optimasi. Dalam model SVM tradisional, faktor penalti C dan parameter fungsi kernel Vare umumnya tergantung pada pengalaman. Ini parameter empiris sulit untuk mencapai perubahan data ini harga. Oleh karena itu, kami menggunakan GA untuk mengoptimalkan metode seleksi parameter SVM sesuai dengan data pelatihan, dan peningkatan SVM perkiraan presisi. Untuk memverifikasi keabsahan model, kami memilih dan menganalisis data harga saham minyak Brent dari 2001/12/27 ke 2011/10/30. Data untuk 2009/07/30 ke 2011/07/22 ditetapkan sebagai kumpulan data pelatihan, dan orang-orang untuk 2011/08/08 ke 2011/08/17 dipekerjakan untuk pengujian. Hasil penelitian menunjukkan bahwa efisiensi perkiraan GA-SVM lebih baik daripada SVM tradisional [23].

Berikut merupakan metode yang diusulkan oleh Guo et al (2012):




Gambar 2.3 Metode yang Diusulkan oleh Guo et al (2012)

2.1.4 Penelitian dari Zhao et al (2011)

Mesin vektor dukungan (SVM) adalah teknik klasifikasi data baru dengan banyak aplikasi yang beragam. Pemilihan subset fitur, serta pengaturan parameter dalam prosedur pelatihan SVM mempengaruhi akurasi klasifikasi secara signifikan. Dalam makalah ini, perilaku asimtotik mesin vektor pendukung digabungkan dengan algoritma genetika (GA) dan kromosom fitur dihasilkan, yang dengan demikian mengarahkan pencarian algoritma genetika ke garis lurus kesalahan generalisasi optimal dalam ruang superparameter. Atas dasar ini, pendekatan baru berdasarkan algoritma genetika dengan fitur kromosom, disebut GA dengan fitur kromosom, diusulkan untuk secara bersamaan mengoptimalkan subset fitur dan parameter untuk SVM. Untuk mengevaluasi pendekatan yang diusulkan, eksperimen ini mengadopsi beberapa kumpulan data dunia nyata dari database UCI dan database Benchmark. Dibandingkan dengan GA tanpa kromosom fitur, pencarian grid, dan pendekatan lainnya, pendekatan yang diusulkan tidak hanya memiliki akurasi klasifikasi yang lebih tinggi dan subset fitur yang lebih kecil, namun juga memiliki waktu pemrosesan yang lebih sedikit [24].

Berikut merupakan metode yang diusulkan oleh Zhao et al (2011):




Gambar 2.4 Metode yang Diusulkan oleh Zhao et al (2011)

2.1.5 Penelitian dari Patil et al (2012)

Perencanaan dan desain pekerjaan perlindungan pantai seperti pemecah gelombang pipa terapung memerlukan informasi tentang karakteristik kinerja struktur dalam mereduksi energi gelombang. Beberapa peneliti telah melakukan studi analitis dan numerik pada floating breakwater di masa lalu namun gagal memberikan model matematika sederhana untuk memprediksi transmisi gelombang melalui floating breakwater dengan mempertimbangkan semua kondisi batas. Teknik kecerdasan komputasi seperti Artificial Neural Networks (ANN), logika fuzzy, pemrograman

genetik dan Support Vector Machine (SVM) berhasil digunakan untuk memecahkan masalah yang kompleks. Dalam makalah ini, model hybrid Genetic Algorithm Tuned Support Vector Machine Regression (GA-SVMR) dikembangkan untuk memprediksi transmisi gelombang pemecah gelombang pipa terapung multilayer yang ditambatkan secara horizontal (HIMMFPB). Selanjutnya, parameter SVM dan kernel optimal model GA-SVMR ditentukan oleh algoritma genetika. Model GA-SVMR dilatih pada kumpulan data yang diperoleh dari eksperimen transmisi gelombang HIMMFB menggunakan flume gelombang reguler di Laboratorium Struktur Kelautan, Institut Teknologi Nasional, Karnataka, Surathkal, Mangalore, India. Hasilnya dibandingkan dengan model ANN dan Adaptive Neuro-Fuzzy Inference System (ANFIS) ditinjau dari koefisien korelasi, root mean square error dan indeks sebar. Kinerja GA-SVMR terbukti lebih unggul. Fungsi kernel b-spline berkinerja lebih baik daripada fungsi kernel lainnya untuk kumpulan data tertentu [25].

Berikut merupakan metode yang diusulkan oleh Patil et al (2012):



Gambar 2.5 Metode yang Diusulkan oleh Patil et al (2012)

2.2 Tinjauan Studi

2.2.1 Data Mining

Data Mining adalah proses yang mempekerjakan satu atau lebih teknik pembelajaran komputer (*machine learning*) untuk menganalisis dan mengekstraksi pengetahuan (*knowledge*) secara otomatis. Definisi lain adalah pembelajaran berbasis induksi (*induction-based learning*) adalah proses pembentukan definisi-definisi konsep umum yang dilakukan dengan cara mengobservasi contoh-contoh spesifik dari konsep-konsep yang akan dipelajari [26].

Data mining merupakan proses iteratif dan interaktif untuk menemukan pola atau model baru yang sah (sempurna), bermanfaat dan dapat dimengerti dalam suatu *database* yang sangat besar (*massive database*) [26].

- a. Sahih: Dapat digeneralisasi untuk masa yang akan datang.
- b. Baru: Apa yang sedang tidak diketahui.
- c. Bermanfaat: Dapat digunakan untuk melakukan suatu tindakan.
- d. Iteratif: memerlukan sejumlah proses yang diulang.
- e. Interaktif: memerlukan interaksi manusia dalam prosesnya.

Data mining dapat diterapkan pada banyak bidang seperti marketing, servis finansial, deteksi penipuan, credit scoring, pengaturan jaringan, penjadwalan, diagnosa medis, pengawasan barang persediaan, diagnosa kesalahan, peramalan dan masih banyak lagi [27].

2.2.2 Support Vector Machine


Support Vector Machine (SVM) secara konseptual adalah mesin linear yang dilengkapi dengan fitur spesial. SVM memiliki dua sifat khusus yaitu mencapai generalisasi yang tinggi dengan memaksimalkan margin dan mendukung

pembelajaran yang efisien dari fungsi nonlinear dalam trik kernel membuat kinerja generalisasinya baik dalam menyelesaikan masalah pengenalan pola [28].

SVM juga merupakan modifikasi dari metode klasifikasi. SVM sangat disukai jika terdapat sejumlah kecil subjek yang diprediksi. Pada skala aslinya, SVM menunjukkan prediksi yang lebih baik dibandingkan model lain [29].

SVM merupakan sebuah kelas prosedur pembelajaran (statistik) terkini, yang juga termasuk dalam bidang umum jaringan saraf. Secara konseptual, SVM merupakan sebuah mesin linier yang dilengkapi dengan fitur khusus dan didasarkan pada metode *Structural Risk Minimization* (SRM) dan teori pembelajaran statistik. Akibatnya, SVM dapat memberikan kinerja generalisasi yang baik dalam masalah pengenalan pola, tanpa memasukkan pengetahuan domain masalah, yang memberikan fitur unik di antara mesin pembelajaran lainnya [30].

Teknik SVM adalah pengklasifikasi untuk menemukan hyperplane. Dengan menggunakan fungsi $g(x) = \omega^T x + b$ yang dapat memisahkan dua kelas dengan margin maksimum dengan benar. Berikut merupakan penggambaran 2 kelas yang dapat dipisahkan oleh margin maksimum dengan menggunakan SVM.



Sumber: [31]

Gambar 2.6 Pemisahan dua kelas dengan margin maksimum pada SVM

Mempertimbangkan suatu set data atau dataset pelatihan yang terdiri dari pasangan input ataupun output $(x_1, y_1), \dots, (x_m, y_m)$, dimana x_i merupakan masukan dari atribut vektor yang terdiri dari besarnya tegangan dan sudut tahap tegangan untuk titik pengoperasian ke-I, dan setiap $x_i \in R^n$ ruang masukan dari sampel. Sedangkan y_i terkait nilai tujuan yaitu VSMI dan m sesuai dengan ukuran dari data pelatihan.

Ide dari permasalahan regresi adalah untuk menentukan fungsi linear yang dapat mendekati hubungan antara kumpulan data dan dapat digunakan untuk memperkirakan sasaran VSMI sehubungan dengan vektor masukan dari titik operasi baru. Menggunakan notasi matematika, fungsi regresi berbentuk:

$$f(x) = \omega\phi(x) + b \quad (2.1)$$

Dimana $x_i \in R^n$, $b \in R$. $\phi(x)$ menunjukan ruang fitur berdimensi tinggi, yang mana dipetakan dari ruang masukan x . Tujuannya adalah untuk mencari nilai dari bobot vektor (ω) nilai-nilai bias (b). sehingga nilai dari dapat ditentukan dengan meminimalkan fungsi regulasi risiko.

$$R_{reg}(f) = C \frac{1}{m} + \sum_{i=0}^m \varepsilon(f(x_i) - y_i) + \frac{1}{2} \|\omega\|^2 \quad (2.2)$$

Dimana ω menunjukan norma Euclidean, sedangkan C menunjukan sebuah fungsi pembiayaan yang mengukur sebuah resiko empiris dan $\varepsilon(\cdot)$ adalah sebuah fungsi kerugian.

Pemilihan parameter yang optimal merupakan langkah yang sangat penting dalam metode SVM. Parameter-parameter dalam SVM yang diperuntukan untuk regresi adalah:

1. Fungsi kernel: fungsi kernel merupakan fungsi yang digunakan untuk membangun sebuah keputusan nonlinier pada awal ruang masukan SVM. Selain itu, ada fungsi kernel seperti fungsi Gaussian (RBF) yang akan menghasilkan estimasi kinerja yang unggul (Smola dan Schölkopf, 1998). Maka dari itu, fungsi Gaussian akan digunakan sebagai fungsi kernel.
2. Parameter regularisasi C : C mengendalikan pertukaran antara meminimalan model kompleksitas dan meminimalan kesalahan pelatihan.
3. Fungsi kernel RBF dari bidang luas σ^2 : σ^2 merupakan varian dari fungsi kernel Gaussian.
4. ϵ : ϵ merupakan sebuah radius dari sebuah tabung dari fungsi ϵ -insensitif kerugian dimana fungsi regresi harusnya kebohongan.


2.2.3 Algoritma Genetika

Algoritma genetika (GA) adalah algoritma evolusioner yang paling populer [32]. Algoritma genetika merupakan teknik pencarian global stochastic yang memecahkan masalah dengan meniru proses evolusi alami. Berdasarkan kelangsungan hidup dan reproduksi kebugaran, GA terus mengeksplorasi solusi baru dan lebih baik tanpa pra-asumsi, seperti kontinuitas dan unimodality. GA telah berhasil diterapkan untuk banyak masalah optimasi yang kompleks [33]. GA juga diterapkan sebagai pendekatan untuk mengidentifikasi pencarian nilai dan solusi bagi berbagai permasalahan optimasi [30].

GA mengembangkan sebuah solusi pencalonan populasi. Setiap solusi diwakili oleh kromosom yang biasanya dikodekan sebagai string biner. Kebugaran setiap kromosom kemudian dievaluasi menggunakan fungsi kinerja setelah kromosom telah diterjemahkan. Setelah menyelesaikan evaluasi, roda roulette bias digunakan agar secara acak memilih sepasang kromosom dan untuk menjalani operasi genetik yang

meniru fenomena alam yang diamati di alam (seperti *crossover* dan mutasi). Proses evolusi ini berlanjut sampai kriteria berhenti tercapai.

Secara umum, alur dalam GA dapat di gambarkan seperti dibawah ini:



Sumber: [34]

Gambar 2.7 Alur proses Algoritma Genetika

GA berbeda dari teknik optimasi nonlinier konvensional dalam hal tersebut mempertahankan pencarian dengan sebuah solusi populasi (atau data dasar) dari solusi yang lebih baik yang telah diciptakan daripada membuat perubahan tambahan untuk solusi tunggal untuk masalah tersebut. GA secara bersamaan memiliki sejumlah besar kandidat solusi untuk sebuah masalah, yang disebut populasi. Fitur utama dari GA adalah memanipulasi sebuah populasi yang individunya ditandai dengan memiliki sebuah kromosom.

Dua persoalan penting dalam GA adalah pengkodean genetik yang digunakan untuk mendefinisikan masalah dan fungsi evaluasi yang disebut fungsi kebugaran. Setiap solusi individu dalam GA diwakili oleh string yang disebut kromosom. Populasi solusi awal yang dihasilkan secara acak, yang berkembang menjadi generasi berikutnya dengan operator genetik seperti seleksi, *crossover* dan mutasi. Kode solusi oleh string dievaluasi dengan fungsi fitness. Operator pemilihan memungkinkan string

dengan kebugaran yang lebih tinggi muncul dengan probabilitas yang lebih tinggi pada generasi berikutnya. *Crossover* dilakukan antara dua individu(disebut orang tua) yang dipilih dengan bertukar bagian dari string mereka, mulai dari titik *crossover* dipilih secara acak. Operator ini cenderung untuk memungkinkan proses evolusi bergerak menuju daerah yang menjanjikan dari ruang pencarian. Mutasi digunakan untuk mencari ruang masalah lebih lanjut dan untuk menghindari konvergensi lokal dari GA.

BAB 3

METODE PENELITIAN

3.1 Perancangan Penelitian

Terdapat 4 metode paling umum dalam penelitian, diantara *action research*, *experiment*, *case study*, dan *survey* [35]. Diantara metode penelitian tersebut, penelitian ini menggunakan metode *experiment*. Hal ini dikarenakan peneliti akan melakukan penyelidikan terhadap beberapa variabel dengan suatu pengujian yang sudah di atur oleh peneliti sendiri. Metode yang digunakan untuk pengujian adalah *Support Vector Machine* yang ditambahkan Algoritma Genetika untuk mengoptimasi parameternya. Untuk melakukan hal tersebut, langkah-langkah yang harus dikerjakan adalah:

1. Pengumpulan data

Bagian ini menjelaskan tentang bagaimana dan darimana data dalam penelitian ini didapatkan. Pada bagian ini pula ditentukan data yang akan diproses.

2. Pengolahan Data Awal

Bagian ini merupakan tahap pengolahan yang meliputi proses input data, pembersihan data, pengelompokan data dan penentuan atribut data sesuai dengan format yang dibutuhkan

3. Metode yang Diusulkan

Bagian ini dilakukan setelah tahap pengumpulan data dan pengolahan data selesai. Bagian ini merupakan bagian penentuan metode yang mana bagian ini harus dilakukan agar bagian *experiment* dan pengujian dapat dijalankan.

4. Experimen dan pengujian model

Kami sengaja memilih dataset yang dimana siapa saja bisa mencari dan menggunakannya. Hal ini kami lakukan agar peneliti lain bisa turut menguji dan menganalisa keabsahan metode yang kami usulkan.

Dari data tabel 3.1 diatas, menunjukkan deskripsi dari dataset yang kami gunakan. Dataset ILPD (*Indian Liver Patient Dataset*) memiliki 583 data training atau 583 baris data yang akan diproses dan memiliki 2 kelas atau 2 jenis tolak ukur yang akan dihitung dalam data tersebut, serta memiliki 10 fitur atau 10 kolom data yang menjadi bahan pengukur yang akan dihitung guna menentukan kelas yang ada.

3.3 Pengolahan Awal Data

Untuk tahapan ini, dataset yang kami tentukan telah kami siapkan dan kami sesuaikan format dataset tersebut sehingga siap untuk kami gunakan dengan metode yang kami usulkan.


Selanjutnya kami menentukan label atau tolak ukur pada dataset tersebut. Label disini berfungsi sebagai patokan pengukuran saat perhitungan berlangsung.

Ini kami lakukan dengan alasan bahwa tidak semua data yang kami ambil telah siap untuk langsung kami ujicoba dengan menggunakan SVM. Sehingga beberapa hal harus kami sesuaikan terlebih dahulu.

3.4 Metode Yang Diusulkan


Dalam SVM non-linear, rentetan pengaturan parameter adalah C , σ^2 dan ε yang memainkan sebuah peranan penting dalam kinerja umum.

Pada penelitian yang dilakukan, Algoritma Genetika (GA) digunakan untuk menemukan nilai-nilai optimal dari parameter *Support Vector Machine* (SVM). Parameter yang optimal dapat digunakan untuk membangun model SVM agar prediksi dapat berlanjut.

Gambar 3.1 *Flowchart SVM*

Algoritma genetika secara acak akan menghasilkan populasi awal dari sebuah kromosom untuk mencari nilai optimal dari parameter SVM.

Gambar 3.1. menggambarkan konsep secara singkat proses jalannya data saat menggunakan metode SVM. Proses tersebut dimulai dengan memasukan data dari UCI yang sudah disiapkan ke dalam metode SVM. Kemudian data tersebut diproses dan hasil akhir akan muncul.

Gambar 3.2 *Flowchart GA-SVM*

Gambar 3.1. menggambarkan konsep secara singkat proses jalannya data saat menggunakan metode SVM. Proses tersebut dimulai dengan memasukan data dari UCI yang sudah disiapkan ke dalam metode SVM. Kemudian data tersebut diproses dan hasil akhir akan muncul.

Gambar 3.2. menggambarkan pendekatan GA-SVM yang kami usulkan. Algoritma Genetika secara acak menghasilkan populasi awal dari sebuah kromosom untuk mencari nilai optimal dari parameter SVM. Setelah populasi awal terbentuk, data dihitung dengan menggunakan metode SVM hingga menghasilkan bentuk evaluasi dari fungsi kebugaran. Selanjutnya hasil dari evaluasi tersebut kita cek apakah hasil tersebut telah memuaskan atau tidak. Jika tidak, maka akan dilakukan 3

proses untuk membentuk sebuah generasi baru yang nantinya akan dihitung kembali dengan menggunakan metode SVM. Ketiga proses tersebut adalah operasi pemilihan, operasi crossover dan operasi mutasi. Operasi pilihan adalah operasi dimana kita memilih individu yang unggul dari populasi yang ada. Operasi crossover merupakan operasi operasi penyilangan gen antara 2 individu yang nantinya akan membentuk sebuah individu baru yang menwarisi kelebihan dari kedua individu sebelumnya. Operasi mutasi akan memungkinkan kita untuk mengubah/memodifikasi sebuah gen sehingga kualitas gen tersebut akan berubah. Setelah ketiga proses tersebut dijalankan, maka akan terbentuk generasi baru yang memiliki walitas yang berbeda dengan generasi sebelumnya. Selanjutnya generasi baru tersebut akan dihitung kembali dengan menggunakan metode SVM sehingga kita melihat hasilnya. Jika hasilnya memuaskan, maka hasil tersebut merupakan proses klasifikasi atau regresi yang kita cari.

Sedangkan penjelasan dari segi formulasi untuk GA-SVM yang akan diusulkan adalah sebagai berikut:

1. Representasi: tiga parameter yang akan dioptimalkan dalam GA-SVM yaitu C , σ^2 dan ε akan diubah menjadi kode untuk menghasilkan kromosom. Kromosom X direpresentasikan sebagai $X = \{x_1, x_2, x_3\}$ dimana x_1 , x_2 dan x_3 melambangkan setiap parameter pada SVM yaitu C , σ^2 dan ε .
2. Kebugaran: Untuk mencegah terjadinya overfitting dan underfitting pada model GASVM, teknik validasi silang akan digunakan untuk pemilihan parameter SVM yang optimal [37]. Dalam validasi persilangan kelipan-K, training set secara acak dibagi menjadi subset K dengan ukuran yang sama. Model regresi SVM dibangun dengan himpunan parameter menggunakan (K-1) bagian sebagai training set. Kinerja parameter SVM akan diperiksa pada bagian ke-K. Prosedur di atas diulang

sehingga setiap bagian dapat digunakan sekali sebagai pengujian set. Dalam penelitian yang diusulkan ini, kami mempertimbangkan teknik validasi silang dengan lima kali kelipatan. Oleh karena itu, fungsi kebugaran didefinisikan sebagai $MAPE_{cross_val}$ dari metode validasi lima kali lipat pada set pelatihan dan diberikan oleh:

$$\min f = MAPE_{cross_val} \quad (3.1)$$

$$MAPE_{cross_val} = \frac{\sum_{i=1}^m \left| \frac{A_i - p_i}{A_i} \right|}{m} + 100\% \quad (3.2)$$

Dari formula diatas, m merupakan jumlah sampel pada set pelatihan, A_i merupakan nilai aktual dan P_i adalah nilai prediksi. Solusi dengan sebuah nilai yang lebih kecil dari $MAPE_{cross_val}$ memiliki kesempatan lebih baik untuk bertahan di generasi berturut-turut.

3. Inisialisasi Populasi: Dalam penelitian yang dilakukan, dibuatlah populasi awal yang terdiri dari dua puluh kromosom secara acak. Ukuran populasi dipilih sebagai trade-off antara waktu konvergensi dan keragaman populasi.
4. Evaluasi Kebugaran: Nilai kebugaran untuk setiap kromosom secara acak pada Langkah 3.
5. Pembuatan populasi baru: Seleksi, crossover dan mutasi dilakukan untuk menggantikan populasi saat ini dengan populasi yang lebih baru. Kromosom dengan nilai kebugaran yang lebih baik dipilih ke dalam kolam rekombinasi menggunakan roda roulette. Gen antara kedua orang tua kromosom dipertukarkan untuk mendapatkan keturunan baru untuk mencoba mendapatkan solusi yang lebih baik, kemungkinan menciptakan kromosom baru di masing-masing pasangan diatur ke 0,8. Mutasi dilakukan untuk mengubah kode biner dengan probabilitas 0,05.

6. Menghentikan kriteria: Proses ini diulang dari langkah IV ke Langkah 5 sampai jumlah generasi mencapai batasnya.

3.5 Eksperimen Dan Pengujian Metode

Pada bagian ini peneliti akan membahas tahapan eksperimen serta pengujian dari metode yang kami usulkan.

Tahapan eksperimen dan pengujian metode penelitian ini adalah:

1. Meng-import dataset yang sudah disiapkan
2. Memasukan dataset tersebut pada metode yang diusulkan

Dalam melakukan tahapan penelitian ini, kami menggunakan *dataset* ILPD (*Indian Liver Patient Dataset*) yang kami dapatkan dari *UCI Repository database* pembelajaran mesin [36].

Dimana *dataset* tersebut mudah didapat dan telah memenuhi standarisasi guna penelitian. Selain itu, dalam proses pengujian penelitian ini, kami menggunakan Rapidminer 5 sebagai *software* yang akan melakukan perhitungan untuk penelitian ini.

3.6 Evaluasi Dan Validasi

Pada bagian ini, kami menyajikan hasil eksperimen pada beberapa *dataset* dari *UCI Repository database* pembelajaran mesin [36]. Dimana kami memilih dataset patokan berikut: *User Knowledge Modeling*. Kami memilih *dataset* patokan dari *UCI Repository* berdasarkan berikut kriteria untuk evaluasi obyektif dan efisien:

1. *Dataset* yang kami pilih harus utuh(tidak ada data yang hilang) ataupun rusak.
2. Kami memilih *dataset* yang memiliki lebih dari 1 kelas.
3. Kami menghindari *dataset* dengan jumlah yang besar, karena akan membutuhkan waktu lebih lama saat proses perhitungan.

Untuk membandingkan kinerja klasifikasi metode kami (GA-SVM), Kami akan membandingkannya dengan metode SVM. Kriteria yang paling penting untuk

mengevaluasi kinerja dari metode ini adalah dengan mengukur tingkat *Accuracy* klasifikasi yang dihasilkan. Kami juga akan mengukur *Precision*, *Recall*, dan AUC untuk melihat seberapa efektif metode yang kami usulkan.

Kemudian, kita mengukur seluruh rangkaian seting straining menggunakan pasangan yang mencapai tingkat validasi terbaik dan kami menggunakan prediksi yang diperoleh pada dataset tes. Jika beberapa pasang memiliki akurasi yang sama dalam tahap validasi, kita menerapkan semua dari mereka untuk *dataset* tes dan melaporkan akurasi tertinggi.

BAB 4

HASIL DAN PEMBAHASAN

4.1 Tahapan Pengujian

Tahapan yang dilakukan dalam penelitian ini adalah:

1. *Data Preparation*

Pada tahap ini, data disiapkan yang nantinya akan di olah menggunakan metode yang telah dipilih oleh peneliti. Dataset yang digunakan adalah *dataset* ILPD (*Indian Liver Patient Dataset*) yang peneliti dapatkan dari UCI *Repository database*.

2. *Data Processing*

Pada tahap ini, data bersihkan dan dirapikan sehingga layak untuk di proses. Kemudian data dapat kita tes dengan metode SVM untuk menguji apakah data tersebut sudah dapat digunakan atau tidak. Jika terdapat *missing* pada data, maka akan dilakukan *cleaning* agar data tersebut dapat digunakan.

3. *Select Fitur Subset*

Pada tahap ini, data yang ada akan dibagi menjadi 2 bagian. Bagian pertama akan menjadi bagian data *training*. Bagian kedua akan menjadi bagian data *testing*. Data *training* akan mengambil 70% dari keseluruhan data yang ada. Sedangkan data *testing* akan mengambil 30% dari keseluruhan data yang ada.

4. *Variable Value Of Parameter pair*

Pada tahap ini, dilakukan pengoptimalan pada parameter yang ada pada metode SVM. Pada saat parameter nya sudah dioptimalkan, maka data yang ada akan

diproses kembali menggunakan metode SVM untuk melihat hasil dari optimasi parameter yang dilakukan.

5. *Fitness Evaluation*

Pada tahap ini, dilakukan evaluasi terhadap hasil proses yang dilakukan. Apakah hasil yang didapat terdapat peningkatan atau penurunan.

6. Operasi *Genetic Feature Chromosom* dan SVM

Pada tahap ini, dilakukan penerapan algoritma genetika untuk mengoptimasi metode SVM agar menjadi lebih baik. Data yang ada akan diproses kembali untuk melihat hasil didapat.


7. *Result/optimed and feature subset*

Pada tahap ini, akan dilakukan pengoptimalan pada parameter kembali pada metode SVM yang sudah dioptimalkan dengan algoritma genetika. Pada saat parameter nya sudah dioptimalkan, maka data yang ada akan diproses kembali menggunakan metode SVM yang sudah dioptimalkan dengan algoritma genetika untuk melihat hasil dari optimasi parameter yang dilakukan.

4.2 Hasil Eksperimen dan Pengujian Metode

4.2.1 Metode *Support Vector Machine*

Pada tahap pertama ini akan dilakukan pengujian dengan menggunakan metode SVM terlebih dahulu untuk melihat tingkat keakurasian dari metode ini terhadap data yang telah disiapkan.



Gambar 4.1 Pengujian metode SVM

Berikut adalah gambar dari aplikasi rapid miner yang peneliti gunakan untuk tingkat akurasi metode SVM dengan dataset yang ada.

Pada tahap awal, data yang ada di siapkan dan dibersihkan agar siap untuk dipakai. Lalu data tersebut digunakan dalam proses menggunakan metode SVM. Setelah proses selesai. Peneliti dapat melihat hasil yang didapat dari proses menggunakan metode SVM. Dari proses menggunakan metode SVM, tingkat akurasi yang didapatkan sebesar 71,36%.

accuracy: 71.36% +/- 1.02% (micro average: 71.36%)

	true 1	true 2	class precision
pred. 1	416	167	71.36%
pred. 2	0	0	0.00%
class recall	100.00%	0.00%	


Gambar 4.2 Tingkat akurasi metode SVM

Dari gambar diatas, terlihat tingkat akurasi yang di dapat dari metode SVM dengan menggunakan dataset yang ada.

4.2.2 Metode *Support Vector Machine* dengan Optimasi Algoritma Genetika

Setelah data yang sudah disedia di proses dengan menggunakan metode SVM. Hasil yang didapat dari proses tersebut adalah tingkat akurasi sebesar 71,36%. selanjutnya peneliti akan menerapkan Algoritma Genetika untuk mengoptimasi parameter pada SVM sehingga dapat meningkatkan tingkat akurasi.

Data yang ada di siapkan kembali untuk proses berikutnya. Tidak lupa data dirapikan dan dibersihkan sehingga siap digunakan. Selanjutnya Algoritma Genetika di pasangkan pada SVM. Kemudian data diproses kembali dengan menggunakan metode SVM yang sudah dilengkapi dengan Algoritma Genetika.



Gambar 4.3 Pengujian metode SVM-GA

Setelah proses selesai dan hasil didapat. Peneliti dapat membandingkan hasil yang didapat dari proses menggunakan metode SVM yang sudah dioptimasi dengan

Algoritma Genetika dengan hasil dari proses yang hanya menggunakan metode SVM standar.

accuracy: 72.22% +/- 2.68% (micro average: 72.21%)

	true 1	true 2	class precision
pred. 1	413	159	72.20%
pred. 2	3	8	72.73%
class recall	99.28%	4.79%	

Gambar 4.4 Tingkat akurasi metode SVM-GA


Tingkat akurasi dari hasil proses metode SVM yang sudah dioptimasi oleh Algoritma Genetika mencapai 72,22%. Dari hasil tersebut, jika peneliti tampilkan dalam bentuk tabel untuk membandingkan tingkat akurasi dari hasil proses metode SVM dengan tingkat akurasi dari hasil metode SVM yang sudah dioptimasi Algoritma Genetika adalah:

Tabel 4.1 Tabel perbandingan tingkat akurasi SVM dan SVM-GA

SVM	SVM-GA
71,36%	72,22%

Dari tabel tersebut, jika peneliti membandingkan tingkat akurasi yang di dapat dari membandingkan tingkat akurasi dari hasil proses metode SVM dengan tingkat akurasi dari hasil metode SVM yang sudah dioptimasi Algoritma Genetika maka akan terlihat bahwa tingkat akurasi pada metode SVM yang sudah dioptimasi oleh Algoritma Genetika lebih tinggi dibandingkan tingkat akurasi pada metode SVM standar.

Jika ditampilkan dalam bentuk diagram, maka akan tampil seperti dibawah ini:



Gambar 4.5 Diagram tingkat akurasi SVM dan SVM-GA

Dari diagram tersebut kita dapat melihat seberapa besar peningkatan akurasi yang didapatkan dari metode SVM yang sudah dioptimasi oleh Algoritma Genetika dibandingkan dengan SVM standar.

BAB 5

PENUTUP

Dalam tulisan ini, kami mengusulkan sebuah metode Algoritma Genetika (GA) yang mengoptimasi parameter pada *Support Vector Machine* (SVM) untuk meningkatkan akurasi perkiraan pada SVM.

5.1 Kesimpulan

Kesimpulan yang peneliti dapat adalah:

1. Dengan menggunakan *dataset* ILPD (*Indian Liver Patient Dataset*) yang peneliti dapatkan dari *UCI Repository database*, peneliti dapat menggunakan dataset tersebut untuk menguji tingkat akurasi metode SVM. Setelah dilakukan pengujian, tingkat akurasi yang didapatkan mencapai 71,36%.
2. Setelah dilakukan pengujian menggunakan metode SVM yang dioptimasi dengan menggunakan Algoritma Genetika, terdapat peningkatan akurasi sebesar 72,22%. Hal ini membuktikan bahwa Algoritma Genetika mampu meningkatkan akurasi dari metode SVM.

5.2 Saran

Saran yang didapat adalah:

1. Saran untuk penelitian ini kedepannya, peneliti akan berusaha untuk mempersingkat waktu proses yang dibutuhkan dalam metode GA-SVM.
2. Menggunakan metode selain Algoritma Genetika untuk mencari tingkat akurasi yang lebih baik.

DAFTAR PUSTAKA

- [1] A. Buldu and K. Üçgün, "Data mining application on students' data," *Procedia - Soc. Behav. Sci.*, vol. 2, no. 2, pp. 5251–5259, Jan. 2010, doi: 10.1016/J.SBSPRO.2010.03.855.
- [2] C.-W. Tsai, C.-F. Lai, M.-C. Chiang, and L. T. Yang, "Data Mining for Internet of Things: A Survey," *IEEE Commun. Surv. Tutorials*, vol. 16, no. 1, pp. 77–97, 2014, doi: 10.1109/SURV.2013.103013.00206.
- [3] S. H. Liao, P. H. Chu, and P. Y. Hsiao, "Data mining techniques and applications – A decade review from 2000 to 2011," *Expert Syst. Appl.*, vol. 39, no. 12, pp. 11303–11311, Sep. 2012, doi: 10.1016/J.ESWA.2012.02.063.
- [4] N. Jothi, N. A. Rashid, and W. Husain, "Data Mining in Healthcare – A Review," *Procedia Comput. Sci.*, vol. 72, pp. 306–313, Jan. 2015, doi: 10.1016/J.PROCS.2015.12.145.
- [5] W. Xindong, Z. Xingquan, W. Gong-Qing, and D. Wei, "Data mining with big data," *IEEE Commun. Surv. Tutorials*, vol. 26, no. 1, pp. 97–107, 2014, doi: 10.1109/TKDE.2013.109.
- [6] B. . Lakshmi and G. . Raghunandhan, "A conceptual overview of data mining," *IEEE Commun. Surv. Tutorials*, vol. 18, no. 2011 National Conference on Innovations in Emerging Technology, pp. 27–32, 2011, doi: 10.1109/NCOIET.2011.5738828.
- [7] F. Coenen, "Data mining: past, present and future," *cambridge*, vol. 26, no. 1, pp. 25–29, 2011, doi: 10.1017/S0269888910000378.
- [8] A. Patle and D. S. Chouhan, "SVM kernel functions for classification," *Int. Conf. Adv. Technol. Eng.*, pp. 1–9, 2013, doi: 10.1109/ICAdTE.2013.6524743.
- [9] L. M. R. Baccarini, V. V. Rocha E Silva, B. R. De Menezes, and W. M. Caminhas, "SVM practical industrial application for mechanical faults diagnostic," *Expert Syst. Appl.*, vol. 38, no. 6, pp. 6980–6984, Jun. 2011, doi: 10.1016/J.ESWA.2010.12.017.
- [10] M. Rushdi Saleh, M. T. Martín-Valdivia, A. Montejó-Ráez, and L. A. Ureña-López, "Experiments with SVM to classify opinions in different domains," *Expert Syst. Appl.*, vol. 38, no. 12, pp. 14799–14804, Nov. 2011, doi: 10.1016/J.ESWA.2011.05.070.
- [11] H. Qian, Y. Mao, W. Xiang, and Z. Wang, "Recognition of human activities using SVM multi-class classifier," *Pattern Recognit. Lett.*, vol. 31, no. 2, pp. 100–111, Jan. 2010, doi: 10.1016/J.PATREC.2009.09.019.
- [12] S. Salcedo-Sanz, J. L. Rojo-Álvarez, M. Martínez-Ramón, and G. Camps-Valls, "Support vector machines in engineering: an overview," *WIREs Data Min. Knowl. Discov.*, vol. 4, no. 3, pp. 234–267, 2014, doi: <https://doi.org/10.1002/widm.1125>.
- [13] M. Pal and G. M. Foody, "Feature Selection for Classification of Hyperspectral Data by SVM," *IEEE Trans. Geosci. Remote Sens.*, vol. 48, no. 5, pp. 2297–2307, 2010, doi: 10.1109/TGRS.2009.2039484.
- [14] K.-P. Lin and M.-S. Chen, "On the Design and Analysis of the Privacy-Preserving SVM Classifier," *IEEE Trans. Knowl. Data Eng.*, vol. 23, no. 11, pp. 1704–1717, 2011, doi: 10.1109/TKDE.2010.193.

- [15] F. Kuang, W. Xu, and S. Zhang, "A novel hybrid KPCA and SVM with GA model for intrusion detection," *Appl. Soft Comput.*, vol. 18, pp. 178–184, May 2014, doi: 10.1016/J.ASOC.2014.01.028.
- [16] X. Z. Li and J. M. Kong, "Application of GA-SVM method with parameter optimization for landslide development prediction," *Nat. Hazards Earth Syst. Sci.*, vol. 14, no. 3, pp. 525–533, 2014, doi: 10.5194/nhess-14-525-2014.
- [17] F. Temitayo, O. Stephen, and A. Abimbola, "Hybrid GA-SVM for Efficient Feature Selection in E-mail Classification," vol. 3, no. 3, pp. 17–29, 2012.
- [18] A. J. Umbarkar and P. D. Sheth, "Crossover Operators in Genetic Algorithms: a Review," *ICTACT J. Soft Comput.*, vol. 06, no. 01, pp. 1083–1092, 2015, doi: 10.21917/ijsc.2015.0150.
- [19] R. Malhotra, N. Singh, and Y. Singh, "Genetic Algorithms: Concepts, Design for Optimization of Process Controllers," *Comput. Inf. Sci.*, vol. 4, no. 2, pp. 39–54, 2011, doi: 10.5539/cis.v4n2p39.
- [20] F. A. Omara and M. M. Arafa, "Genetic algorithms for task scheduling problem," *J. Parallel Distrib. Comput.*, vol. 70, no. 1, pp. 13–22, Jan. 2010, doi: 10.1016/J.JPDC.2009.09.009.
- [21] I. Ilhan and G. Tezel, "A genetic algorithm-support vector machine method with parameter optimization for selecting the tag SNPs," *J. Biomed. Inform.*, vol. 46, no. 2, pp. 328–340, 2013, doi: 10.1016/j.jbi.2012.12.002.
- [22] K. S. Sajan, V. Kumar, and B. Tyagi, "Genetic algorithm based support vector machine for on-line voltage stability monitoring," *Int. J. Electr. Power Energy Syst.*, vol. 73, pp. 200–208, 2015, doi: 10.1016/j.ijepes.2015.05.002.
- [23] X. Guo, D. Li, and A. Zhang, "Improved Support Vector Machine Oil Price Forecast Model Based on Genetic Algorithm Optimization Parameters," *AASRI Procedia*, vol. 1, pp. 525–530, 2012, doi: 10.1016/j.aasri.2012.06.082.
- [24] M. Zhao, C. Fu, L. Ji, K. Tang, and M. Zhou, "Feature selection and parameter optimization for support vector machines: A new approach based on genetic algorithm with feature chromosomes," *Expert Syst. Appl.*, vol. 38, no. 5, pp. 5197–5204, 2011, doi: 10.1016/j.eswa.2010.10.041.
- [25] S. G. Patil, S. Mandal, and A. V. Hegde, "Genetic algorithm based support vector machine regression in predicting wave transmission of horizontally interlaced multi-layer moored floating pipe breakwater," *Adv. Eng. Softw.*, vol. 45, no. 1, pp. 203–212, 2012, doi: 10.1016/j.advengsoft.2011.09.026.
- [26] F. A. Herawati, *Data Mining*. Yogyakarta: ANDI, 2013.
- [27] M. Alnoukari, *ASD-BI: A Knowledge Discovery Process Modeling Based on Adaptive Software Development Agile Methodology*. 2012. [Online]. Available: <http://www.igi-global.com/chapter/asd-knowledge-discovery-process-modeling/58571>
- [28] F. Gorunescu, *Intelligent Systems Reference Library*. Berlin Heidelberg: Springer-Verlag, 2011.
- [29] A. Azzalini and B. Scarpa, *Data Analysis and Data Mining*. New York: Oxford University Press, 2012.
- [30] F. Gorunescu, *Data Mining: Concepts, Models and Techniques*. Berlin Heidelberg: Springer-Verlag, 2011.
- [31] M. Awad and R. Khanna, *Support Vector Machines for Classification*. Apress, Berkeley, CA, 2015. doi: https://doi.org/10.1007/978-1-4302-5990-9_3.
- [32] X.-S. Yang, *Nature-Inspired Optimization Algorithms*. Elsevier, 2014. doi: 10.1016/B978-0-12-416743-8.00005-1.

- [33] Q. Wu, "The hybrid forecasting model based on chaotic mapping, genetic algorithm and support vector machine," *Expert Syst. Appl.*, vol. 37, no. 2, pp. 1776–1783, Mar. 2010, doi: 10.1016/J.ESWA.2009.07.054.
- [34] Suyanto, *Algoritma Genetika dalam MATLAB*. Yogyakarta: Andi, 2005.
- [35] C. W. Dawson, *Projects in Computing and Information Systems*, vol. 2. 2009. [Online]. Available: http://www.sentimentaltoday.net/National_Academy_Press/0321263553.Addison.Wesley.Publishing.Company.Projects.in.Computing.and.Information.Systems.A.Students.Guide.Jun.2005.pdf
- [36] K. Bache and M. Lichman, "UCI Machine Learning Repository. University of California, School of Information and Computer Science." 2013. [Online]. Available: <http://archive.ics.uci.edu/ml>
- [37] C. M. Bishop, *Pattern Recognition and Machine Learning*. New York: Springer, 2006.

LAMPIRAN

Lampiran 1 Dataset ILPD (*Indian Liver Patient Dataset*)

Age	Gender	TB	DB	Alkphos	Sgpt	Sgot	TP	ALB	A/G_Ratio	Selector
65	Female	0.7	0.1	187	16	18	6.8	3.3	0.9	1
62	Male	10.9	5.5	699	64	100	7.5	3.2	0.74	1
62	Male	7.3	4.1	490	60	68	7	3.3	0.89	1
58	Male	1	0.4	182	14	20	6.8	3.4	1	1
72	Male	3.9	2	195	27	59	7.3	2.4	0.4	1
46	Male	1.8	0.7	208	19	14	7.6	4.4	1.3	1
26	Female	0.9	0.2	154	16	12	7	3.5	1	1
29	Female	0.9	0.3	202	14	11	6.7	3.6	1.1	1
17	Male	0.9	0.3	202	22	19	7.4	4.1	1.2	2
55	Male	0.7	0.2	290	53	58	6.8	3.4	1	1
57	Male	0.6	0.1	210	51	59	5.9	2.7	0.8	1
72	Male	2.7	1.3	260	31	56	7.4	3	0.6	1
64	Male	0.9	0.3	310	61	58	7	3.4	0.9	2
74	Female	1.1	0.4	214	22	30	8.1	4.1	1	1
61	Male	0.7	0.2	145	53	41	5.8	2.7	0.87	1
25	Male	0.6	0.1	183	91	53	5.5	2.3	0.7	2
38	Male	1.8	0.8	342	168	441	7.6	4.4	1.3	1
33	Male	1.6	0.5	165	15	23	7.3	3.5	0.92	2
40	Female	0.9	0.3	293	232	245	6.8	3.1	0.8	1
40	Female	0.9	0.3	293	232	245	6.8	3.1	0.8	1
51	Male	2.2	1	610	17	28	7.3	2.6	0.55	1
51	Male	2.9	1.3	482	22	34	7	2.4	0.5	1
62	Male	6.8	3	542	116	66	6.4	3.1	0.9	1
40	Male	1.9	1	231	16	55	4.3	1.6	0.6	1
63	Male	0.9	0.2	194	52	45	6	3.9	1.85	2
34	Male	4.1	2	289	875	731	5	2.7	1.1	1
34	Male	4.1	2	289	875	731	5	2.7	1.1	1
34	Male	6.2	3	240	1680	850	7.2	4	1.2	1
20	Male	1.1	0.5	128	20	30	3.9	1.9	0.95	2
84	Female	0.7	0.2	188	13	21	6	3.2	1.1	2
57	Male	4	1.9	190	45	111	5.2	1.5	0.4	1
52	Male	0.9	0.2	156	35	44	4.9	2.9	1.4	1
57	Male	1	0.3	187	19	23	5.2	2.9	1.2	2
38	Female	2.6	1.2	410	59	57	5.6	3	0.8	2
38	Female	2.6	1.2	410	59	57	5.6	3	0.8	2
30	Male	1.3	0.4	482	102	80	6.9	3.3	0.9	1
17	Female	0.7	0.2	145	18	36	7.2	3.9	1.18	2

46	Female	14.2	7.8	374	38	77	4.3	2	0.8	1
48	Male	1.4	0.6	263	38	66	5.8	2.2	0.61	1
47	Male	2.7	1.3	275	123	73	6.2	3.3	1.1	1
45	Male	2.4	1.1	168	33	50	5.1	2.6	1	1
62	Male	0.6	0.1	160	42	110	4.9	2.6	1.1	2
42	Male	6.8	3.2	630	25	47	6.1	2.3	0.6	2
50	Male	2.6	1.2	415	407	576	6.4	3.2	1	1
85	Female	1	0.3	208	17	15	7	3.6	1	2
35	Male	1.8	0.6	275	48	178	6.5	3.2	0.9	2
21	Male	3.9	1.8	150	36	27	6.8	3.9	1.34	1
40	Male	1.1	0.3	230	1630	960	4.9	2.8	1.3	1
32	Female	0.6	0.1	176	39	28	6	3	1	1
55	Male	18.4	8.8	206	64	178	6.2	1.8	0.4	1
45	Female	0.7	0.2	170	21	14	5.7	2.5	0.7	1
34	Female	0.6	0.1	161	15	19	6.6	3.4	1	1
38	Male	3.1	1.6	253	80	406	6.8	3.9	1.3	1
38	Male	1.1	0.3	198	86	150	6.3	3.5	1.2	1
42	Male	8.9	4.5	272	31	61	5.8	2	0.5	1
42	Male	8.9	4.5	272	31	61	5.8	2	0.5	1
33	Male	0.8	0.2	198	26	23	8	4	1	2
48	Female	0.9	0.2	175	24	54	5.5	2.7	0.9	2
51	Male	0.8	0.2	367	42	18	5.2	2	0.6	1
64	Male	1.1	0.5	145	20	24	5.5	3.2	1.39	2
31	Female	0.8	0.2	158	21	16	6	3	1	1
58	Male	1	0.5	158	37	43	7.2	3.6	1	1
58	Male	1	0.5	158	37	43	7.2	3.6	1	1
57	Male	0.7	0.2	208	35	97	5.1	2.1	0.7	1
57	Male	1.3	0.4	259	40	86	6.5	2.5	0.6	1
57	Male	1.4	0.7	470	62	88	5.6	2.5	0.8	1
54	Male	2.2	1.2	195	55	95	6	3.7	1.6	1
37	Male	1.8	0.8	215	53	58	6.4	3.8	1.4	1
66	Male	0.7	0.2	239	27	26	6.3	3.7	1.4	1
60	Male	0.8	0.2	215	24	17	6.3	3	0.9	2
19	Female	0.7	0.2	186	166	397	5.5	3	1.2	1
75	Female	0.8	0.2	188	20	29	4.4	1.8	0.6	1
75	Female	0.8	0.2	205	27	24	4.4	2	0.8	1
52	Male	0.6	0.1	171	22	16	6.6	3.6	1.2	1
68	Male	0.7	0.1	145	20	22	5.8	2.9	1	1
29	Female	0.7	0.1	162	52	41	5.2	2.5	0.9	2
31	Male	0.9	0.2	518	189	17	5.3	2.3	0.7	1
68	Female	0.6	0.1	1620	95	127	4.6	2.1	0.8	1
70	Male	1.4	0.6	146	12	24	6.2	3.8	1.58	2
58	Female	2.8	1.3	670	48	79	4.7	1.6	0.5	1
58	Female	2.4	1.1	915	60	142	4.7	1.8	0.6	1

29	Male	1	0.3	75	25	26	5.1	2.9	1.3	1
49	Male	0.7	0.1	148	14	12	5.4	2.8	1	2
33	Male	2	1	258	194	152	5.4	3	1.25	1
32	Male	0.6	0.1	237	45	31	7.5	4.3	1.34	1
14	Male	1.4	0.5	269	58	45	6.7	3.9	1.4	1
13	Male	0.6	0.1	320	28	56	7.2	3.6	1	2
58	Male	0.8	0.2	298	33	59	6.2	3.1	1	1
18	Male	0.6	0.2	538	33	34	7.5	3.2	0.7	1
60	Male	4	1.9	238	119	350	7.1	3.3	0.8	1
60	Male	5.7	2.8	214	412	850	7.3	3.2	0.78	1
60	Male	6.8	3.2	308	404	794	6.8	3	0.7	1
60	Male	8.6	4	298	412	850	7.4	3	0.6	1
60	Male	5.8	2.7	204	220	400	7	3	0.7	1
60	Male	5.2	2.4	168	126	202	6.8	2.9	0.7	1
75	Male	0.9	0.2	282	25	23	4.4	2.2	1	1
39	Male	3.8	1.5	298	102	630	7.1	3.3	0.8	1
39	Male	6.6	3	215	190	950	4	1.7	0.7	1
18	Male	0.6	0.1	265	97	161	5.9	3.1	1.1	1
18	Male	0.7	0.1	312	308	405	6.9	3.7	1.1	1
27	Male	0.6	0.2	161	27	28	3.7	1.6	0.76	2
27	Male	0.7	0.2	243	21	23	5.3	2.3	0.7	2
17	Male	0.9	0.2	224	36	45	6.9	4.2	1.55	1
55	Female	0.8	0.2	225	14	23	6.1	3.3	1.2	2
63	Male	0.5	0.1	170	21	28	5.5	2.5	0.8	1
36	Male	5.3	2.3	145	32	92	5.1	2.6	1	2
36	Male	5.3	2.3	145	32	92	5.1	2.6	1	2
36	Male	0.8	0.2	158	29	39	6	2.2	0.5	2
36	Male	0.8	0.2	158	29	39	6	2.2	0.5	2
36	Male	0.9	0.1	486	25	34	5.9	2.8	0.9	2
24	Female	0.7	0.2	188	11	10	5.5	2.3	0.71	2
48	Male	3.2	1.6	257	33	116	5.7	2.2	0.62	1
27	Male	1.2	0.4	179	63	39	6.1	3.3	1.1	2
74	Male	0.6	0.1	272	24	98	5	2	0.6	1
50	Male	5.8	3	661	181	285	5.7	2.3	0.67	2
50	Male	7.3	3.6	1580	88	64	5.6	2.3	0.6	2
48	Male	0.7	0.1	1630	74	149	5.3	2	0.6	1
32	Male	12.7	6.2	194	2000	2946	5.7	3.3	1.3	1
32	Male	15.9	7	280	1350	1600	5.6	2.8	1	1
32	Male	18	8.2	298	1250	1050	5.4	2.6	0.9	1
32	Male	23	11.3	300	482	275	7.1	3.5	0.9	1
32	Male	22.7	10.2	290	322	113	6.6	2.8	0.7	1
58	Male	1.7	0.8	188	60	84	5.9	3.5	1.4	2
64	Female	0.8	0.2	178	17	18	6.3	3.1	0.9	1
28	Male	0.6	0.1	177	36	29	6.9	4.1	1.4	2

60	Male	1.8	0.5	201	45	25	3.9	1.7	0.7	2
48	Male	5.8	2.5	802	133	88	6	2.8	0.8	1
64	Male	3	1.4	248	46	40	6.5	3.2	0.9	1
58	Female	1.7	0.8	1896	61	83	8	3.9	0.95	1
45	Male	2.8	1.7	263	57	65	5.1	2.3	0.8	1
45	Male	3.2	1.4	512	50	58	6	2.7	0.8	1
70	Female	0.7	0.2	237	18	28	5.8	2.5	0.75	2
18	Female	0.8	0.2	199	34	31	6.5	3.5	1.16	2
53	Male	0.9	0.4	238	17	14	6.6	2.9	0.8	1
18	Male	1.8	0.7	178	35	36	6.8	3.6	1.1	1
66	Male	11.3	5.6	1110	1250	4929	7	2.4	0.5	1
46	Female	4.7	2.2	310	62	90	6.4	2.5	0.6	1
18	Male	0.8	0.2	282	72	140	5.5	2.5	0.8	1
18	Male	0.8	0.2	282	72	140	5.5	2.5	0.8	1
15	Male	0.8	0.2	380	25	66	6.1	3.7	1.5	1
60	Male	0.6	0.1	186	20	21	6.2	3.3	1.1	2
66	Female	4.2	2.1	159	15	30	7.1	2.2	0.4	1
30	Male	1.6	0.4	332	84	139	5.6	2.7	0.9	1
30	Male	1.6	0.4	332	84	139	5.6	2.7	0.9	1
45	Female	3.5	1.5	189	63	87	5.6	2.9	1	1
65	Male	0.8	0.2	201	18	22	5.4	2.9	1.1	2
66	Female	2.9	1.3	168	21	38	5.5	1.8	0.4	1
65	Male	0.7	0.1	392	20	30	5.3	2.8	1.1	1
50	Male	0.9	0.2	202	20	26	7.2	4.5	1.66	1
60	Male	0.8	0.2	286	21	27	7.1	4	1.2	1
56	Male	1.1	0.5	180	30	42	6.9	3.8	1.2	2
50	Male	1.6	0.8	218	18	20	5.9	2.9	0.96	1
46	Female	0.8	0.2	182	20	40	6	2.9	0.9	1
52	Male	0.6	0.1	178	26	27	6.5	3.6	1.2	2
34	Male	5.9	2.5	290	45	233	5.6	2.7	0.9	1
34	Male	8.7	4	298	58	138	5.8	2.4	0.7	1
32	Male	0.9	0.3	462	70	82	6.2	3.1	1	1
72	Male	0.7	0.1	196	20	35	5.8	2	0.5	1
72	Male	0.7	0.1	196	20	35	5.8	2	0.5	1
50	Male	1.2	0.4	282	36	32	7.2	3.9	1.1	1
60	Male	11	4.9	750	140	350	5.5	2.1	0.6	1
60	Male	11.5	5	1050	99	187	6.2	2.8	0.8	1
60	Male	5.8	2.7	599	43	66	5.4	1.8	0.5	1
39	Male	1.9	0.9	180	42	62	7.4	4.3	1.38	1
39	Male	1.9	0.9	180	42	62	7.4	4.3	1.38	1
48	Male	4.5	2.3	282	13	74	7	2.4	0.52	1
55	Male	75	3.6	332	40	66	6.2	2.5	0.6	1
47	Female	3	1.5	292	64	67	5.6	1.8	0.47	1
60	Male	22.8	12.6	962	53	41	6.9	3.3	0.9	1

60	Male	8.9	4	950	33	32	6.8	3.1	0.8	1
72	Male	1.7	0.8	200	28	37	6.2	3	0.93	1
44	Female	1.9	0.6	298	378	602	6.6	3.3	1	1
55	Male	14.1	7.6	750	35	63	5	1.6	0.47	1
31	Male	0.6	0.1	175	48	34	6	3.7	1.6	1
31	Male	0.6	0.1	175	48	34	6	3.7	1.6	1
31	Male	0.8	0.2	198	43	31	7.3	4	1.2	1
55	Male	0.8	0.2	482	112	99	5.7	2.6	0.8	1
75	Male	14.8	9	1020	71	42	5.3	2.2	0.7	1
75	Male	10.6	5	562	37	29	5.1	1.8	0.5	1
75	Male	8	4.6	386	30	25	5.5	1.8	0.48	1
75	Male	2.8	1.3	250	23	29	2.7	0.9	0.5	1
75	Male	2.9	1.3	218	33	37	3	1.5	1	1
65	Male	1.9	0.8	170	36	43	3.8	1.4	0.58	2
40	Male	0.6	0.1	171	20	17	5.4	2.5	0.8	1
64	Male	1.1	0.4	201	18	19	6.9	4.1	1.4	1
38	Male	1.5	0.4	298	60	103	6	3	1	2
60	Male	3.2	1.8	750	79	145	7.8	3.2	0.69	1
60	Male	2.1	1	191	114	247	4	1.6	0.6	1
60	Male	1.9	0.8	614	42	38	4.5	1.8	0.6	1
48	Female	0.8	0.2	218	32	28	5.2	2.5	0.9	2
60	Male	6.3	3.2	314	118	114	6.6	3.7	1.27	1
60	Male	5.8	3	257	107	104	6.6	3.5	1.12	1
60	Male	2.3	0.6	272	79	51	6.6	3.5	1.1	1
49	Male	1.3	0.4	206	30	25	6	3.1	1.06	2
49	Male	2	0.6	209	48	32	5.7	3	1.1	2
60	Male	2.4	1	1124	30	54	5.2	1.9	0.5	1
60	Male	2	1.1	664	52	104	6	2.1	0.53	1
26	Female	0.6	0.2	142	12	32	5.7	2.4	0.75	1
41	Male	0.9	0.2	169	22	18	6.1	3	0.9	2
7	Female	27.2	11.8	1420	790	1050	6.1	2	0.4	1
49	Male	0.6	0.1	218	50	53	5	2.4	0.9	1
49	Male	0.6	0.1	218	50	53	5	2.4	0.9	1
38	Female	0.8	0.2	145	19	23	6.1	3.1	1.03	2
21	Male	1	0.3	142	27	21	6.4	3.5	1.2	2
21	Male	0.7	0.2	135	27	26	6.4	3.3	1	2
45	Male	2.5	1.2	163	28	22	7.6	4	1.1	1
40	Male	3.6	1.8	285	50	60	7	2.9	0.7	1
40	Male	3.9	1.7	350	950	1500	6.7	3.8	1.3	1
70	Female	0.9	0.3	220	53	95	6.1	2.8	0.68	1
45	Female	0.9	0.3	189	23	33	6.6	3.9		1
28	Male	0.8	0.3	190	20	14	4.1	2.4	1.4	1
42	Male	2.7	1.3	219	60	180	7	3.2	0.8	1
22	Male	2.7	1	160	82	127	5.5	3.1	1.2	2

8	Female	0.9	0.2	401	25	58	7.5	3.4	0.8	1
38	Male	1.7	1	180	18	34	7.2	3.6	1	1
66	Male	0.6	0.2	100	17	148	5	3.3	1.9	2
55	Male	0.9	0.2	116	36	16	6.2	3.2	1	2
49	Male	1.1	0.5	159	30	31	7	4.3	1.5	1
6	Male	0.6	0.1	289	38	30	4.8	2	0.7	2
37	Male	0.8	0.2	125	41	39	6.4	3.4	1.1	1
37	Male	0.8	0.2	147	27	46	5	2.5	1	1
47	Male	0.9	0.2	192	38	24	7.3	4.3	1.4	1
47	Male	0.9	0.2	265	40	28	8	4	1	1
50	Male	1.1	0.3	175	20	19	7.1	4.5	1.7	2
70	Male	1.7	0.5	400	56	44	5.7	3.1	1.1	1
26	Male	0.6	0.2	120	45	51	7.9	4	1	1
26	Male	1.3	0.4	173	38	62	8	4	1	1
68	Female	0.7	0.2	186	18	15	6.4	3.8	1.4	1
65	Female	1	0.3	202	26	13	5.3	2.6	0.9	2
46	Male	0.6	0.2	290	26	21	6	3	1	1
61	Male	1.5	0.6	196	61	85	6.7	3.8	1.3	2
61	Male	0.8	0.1	282	85	231	8.5	4.3	1	1
50	Male	2.7	1.6	157	149	156	7.9	3.1	0.6	1
33	Male	2	1.4	2110	48	89	6.2	3	0.9	1
40	Female	0.9	0.2	285	32	27	7.7	3.5	0.8	1
60	Male	1.5	0.6	360	230	298	4.5	2	0.8	1
22	Male	0.8	0.2	300	57	40	7.9	3.8	0.9	2
35	Female	0.9	0.3	158	20	16	8	4	1	1
35	Female	0.9	0.2	190	40	35	7.3	4.7	1.8	2
40	Male	0.9	0.3	196	69	48	6.8	3.1	0.8	1
48	Male	0.7	0.2	165	32	30	8	4	1	2
51	Male	0.8	0.2	230	24	46	6.5	3.1		1
29	Female	0.8	0.2	205	30	23	8.2	4.1	1	1
28	Female	0.9	0.2	316	25	23	8.5	5.5	1.8	1
54	Male	0.8	0.2	218	20	19	6.3	2.5	0.6	1
54	Male	0.9	0.2	290	15	18	6.1	2.8	0.8	1
55	Male	1.8	9	272	22	79	6.1	2.7	0.7	1
55	Male	0.9	0.2	190	25	28	5.9	2.7	0.8	1
40	Male	0.7	0.1	202	37	29	5	2.6	1	1
33	Male	1.2	0.3	498	28	25	7	3	0.7	1
33	Male	2.1	1.3	480	38	22	6.5	3	0.8	1
33	Male	0.9	0.8	680	37	40	5.9	2.6	0.8	1
65	Male	1.1	0.3	258	48	40	7	3.9	1.2	2
35	Female	0.6	0.2	180	12	15	5.2	2.7		2
38	Female	0.7	0.1	152	90	21	7.1	4.2	1.4	2
38	Male	1.7	0.7	859	89	48	6	3	1	1
50	Male	0.9	0.3	901	23	17	6.2	3.5	1.2	1

44	Male	0.8	0.2	335	148	86	5.6	3	1.1	1
36	Male	0.8	0.2	182	31	34	6.4	3.8	1.4	2
42	Male	30.5	14.2	285	65	130	5.2	2.1	0.6	1
42	Male	16.4	8.9	245	56	87	5.4	2	0.5	1
33	Male	1.5	7	505	205	140	7.5	3.9	1	1
18	Male	0.8	0.2	228	55	54	6.9	4	1.3	1
38	Female	0.8	0.2	185	25	21	7	3	0.7	1
38	Male	0.8	0.2	247	55	92	7.4	4.3	1.38	2
4	Male	0.9	0.2	348	30	34	8	4	1	2
62	Male	1.2	0.4	195	38	54	6.3	3.8	1.5	1
43	Female	0.9	0.3	140	12	29	7.4	3.5	1.8	1
40	Male	14.5	6.4	358	50	75	5.7	2.1	0.5	1
26	Male	0.6	0.1	110	15	20	2.8	1.6	1.3	1
37	Male	0.7	0.2	235	96	54	9.5	4.9	1	1
4	Male	0.8	0.2	460	152	231	6.5	3.2	0.9	2
21	Male	18.5	9.5	380	390	500	8.2	4.1	1	1
30	Male	0.7	0.2	262	15	18	9.6	4.7	1.2	1
33	Male	1.8	0.8	196	25	22	8	4	1	1
26	Male	1.9	0.8	180	22	19	8.2	4.1	1	2
35	Male	0.9	0.2	190	25	20	6.4	3.6	1.2	2
60	Male	2	0.8	190	45	40	6	2.8	0.8	1
45	Male	2.2	0.8	209	25	20	8	4	1	1
48	Female	1	1.4	144	18	14	8.3	4.2	1	1
58	Male	0.8	0.2	123	56	48	6	3	1	1
50	Male	0.7	0.2	192	18	15	7.4	4.2	1.3	2
50	Male	0.7	0.2	188	12	14	7	3.4	0.9	1
18	Male	1.3	0.7	316	10	21	6	2.1	0.5	2
18	Male	0.9	0.3	300	30	48	8	4	1	1
13	Male	1.5	0.5	575	29	24	7.9	3.9	0.9	1
34	Female	0.8	0.2	192	15	12	8.6	4.7	1.2	1
43	Male	1.3	0.6	155	15	20	8	4	1	2
50	Female	1	0.5	239	16	39	7.5	3.7	0.9	1
57	Male	4.5	2.3	315	120	105	7	4	1.3	1
45	Female	1	0.3	250	48	44	8.6	4.3	1	1
60	Male	0.7	0.2	174	32	14	7.8	4.2	1.1	2
45	Male	0.6	0.2	245	22	24	7.1	3.4	0.9	1
23	Male	1.1	0.5	191	37	41	7.7	4.3	1.2	2
22	Male	2.4	1	340	25	21	8.3	4.5	1.1	1
22	Male	0.6	0.2	202	78	41	8	3.9	0.9	1
74	Female	0.9	0.3	234	16	19	7.9	4	1	1
25	Female	0.9	0.3	159	24	25	6.9	4.4	1.7	2
31	Female	1.1	0.3	190	26	15	7.9	3.8	0.9	1
24	Female	0.9	0.2	195	40	35	7.4	4.1	1.2	2
58	Male	0.8	0.2	180	32	25	8.2	4.4	1.1	2

51	Female	0.9	0.2	280	21	30	6.7	3.2	0.8	1
50	Female	1.7	0.6	430	28	32	6.8	3.5	1	1
50	Male	0.7	0.2	206	18	17	8.4	4.2	1	2
55	Female	0.8	0.2	155	21	17	6.9	3.8	1.4	1
54	Female	1.4	0.7	195	36	16	7.9	3.7	0.9	2
48	Male	1.6	1	588	74	113	7.3	2.4	0.4	1
30	Male	0.8	0.2	174	21	47	4.6	2.3	1	1
45	Female	0.8	0.2	165	22	18	8.2	4.1	1	1
48	Female	1.1	0.7	527	178	250	8	4.2	1.1	1
51	Male	0.8	0.2	175	48	22	8.1	4.6	1.3	1
54	Female	23.2	12.6	574	43	47	7.2	3.5	0.9	1
27	Male	1.3	0.6	106	25	54	8.5	4.8		2
30	Female	0.8	0.2	158	25	22	7.9	4.5	1.3	2
26	Male	2	0.9	195	24	65	7.8	4.3	1.2	1
22	Male	0.9	0.3	179	18	21	6.7	3.7	1.2	2
44	Male	0.9	0.2	182	29	82	7.1	3.7	1	2
35	Male	0.7	0.2	198	42	30	6.8	3.4	1	1
38	Male	3.7	2.2	216	179	232	7.8	4.5	1.3	1
14	Male	0.9	0.3	310	21	16	8.1	4.2	1	2
30	Female	0.7	0.2	63	31	27	5.8	3.4	1.4	1
30	Female	0.8	0.2	198	30	58	5.2	2.8	1.1	1
36	Male	1.7	0.5	205	36	34	7.1	3.9	1.2	1
12	Male	0.8	0.2	302	47	67	6.7	3.5	1.1	2
60	Male	2.6	1.2	171	42	37	5.4	2.7	1	1
42	Male	0.8	0.2	158	27	23	6.7	3.1	0.8	2
36	Female	1.2	0.4	358	160	90	8.3	4.4	1.1	2
24	Male	3.3	1.6	174	11	33	7.6	3.9	1	2
43	Male	0.8	0.2	192	29	20	6	2.9	0.9	2
21	Male	0.7	0.2	211	14	23	7.3	4.1	1.2	2
26	Male	2	0.9	157	54	68	6.1	2.7	0.8	1
26	Male	1.7	0.6	210	62	56	5.4	2.2	0.6	1
26	Male	7.1	3.3	258	80	113	6.2	2.9	0.8	1
36	Female	0.7	0.2	152	21	25	5.9	3.1	1.1	2
13	Female	0.7	0.2	350	17	24	7.4	4	1.1	1
13	Female	0.7	0.1	182	24	19	8.9	4.9	1.2	1
75	Male	6.7	3.6	458	198	143	6.2	3.2	1	1
75	Male	2.5	1.2	375	85	68	6.4	2.9	0.8	1
75	Male	1.8	0.8	405	79	50	6.1	2.9	0.9	1
75	Male	1.4	0.4	215	50	30	5.9	2.6	0.7	1
75	Male	0.9	0.2	206	44	33	6.2	2.9	0.8	1
36	Female	0.8	0.2	650	70	138	6.6	3.1	0.8	1
35	Male	0.8	0.2	198	36	32	7	4	1.3	2
70	Male	3.1	1.6	198	40	28	5.6	2	0.5	1
37	Male	0.8	0.2	195	60	40	8.2	5	1.5	2

60	Male	2.9	1.3	230	32	44	5.6	2	0.5	1
46	Male	0.6	0.2	115	14	11	6.9	3.4	0.9	1
38	Male	0.7	0.2	216	349	105	7	3.5	1	1
70	Male	1.3	0.4	358	19	14	6.1	2.8	0.8	1
49	Female	0.8	0.2	158	19	15	6.6	3.6	1.2	2
37	Male	1.8	0.8	145	62	58	5.7	2.9	1	1
37	Male	1.3	0.4	195	41	38	5.3	2.1	0.6	1
26	Female	0.7	0.2	144	36	33	8.2	4.3	1.1	1
48	Female	1.4	0.8	621	110	176	7.2	3.9	1.1	1
48	Female	0.8	0.2	150	25	23	7.5	3.9	1	1
19	Male	1.4	0.8	178	13	26	8	4.6	1.3	2
33	Male	0.7	0.2	256	21	30	8.5	3.9	0.8	1
33	Male	2.1	0.7	205	50	38	6.8	3	0.7	1
37	Male	0.7	0.2	176	28	34	5.6	2.6	0.8	1
69	Female	0.8	0.2	146	42	70	8.4	4.9	1.4	2
24	Male	0.7	0.2	218	47	26	6.6	3.3	1	1
65	Female	0.7	0.2	182	23	28	6.8	2.9	0.7	2
55	Male	1.1	0.3	215	21	15	6.2	2.9	0.8	2
42	Female	0.9	0.2	165	26	29	8.5	4.4	1	2
21	Male	0.8	0.2	183	33	57	6.8	3.5	1	2
40	Male	0.7	0.2	176	28	43	5.3	2.4	0.8	2
16	Male	0.7	0.2	418	28	35	7.2	4.1	1.3	2
60	Male	2.2	1	271	45	52	6.1	2.9	0.9	2
42	Female	0.8	0.2	182	22	20	7.2	3.9	1.1	1
58	Female	0.8	0.2	130	24	25	7	4	1.3	1
54	Female	22.6	11.4	558	30	37	7.8	3.4	0.8	1
33	Male	0.8	0.2	135	30	29	7.2	4.4	1.5	2
48	Male	0.7	0.2	326	29	17	8.7	5.5	1.7	1
25	Female	0.7	0.1	140	32	25	7.6	4.3	1.3	2
56	Female	0.7	0.1	145	26	23	7	4	1.3	2
47	Male	3.5	1.6	206	32	31	6.8	3.4	1	1
33	Male	0.7	0.1	168	35	33	7	3.7	1.1	1
20	Female	0.6	0.2	202	12	13	6.1	3	0.9	2
50	Female	0.7	0.1	192	20	41	7.3	3.3	0.8	1
72	Male	0.7	0.2	185	16	22	7.3	3.7	1	2
50	Male	1.7	0.8	331	36	53	7.3	3.4	0.9	1
39	Male	0.6	0.2	188	28	43	8.1	3.3	0.6	1
58	Female	0.7	0.1	172	27	22	6.7	3.2	0.9	1
60	Female	1.4	0.7	159	10	12	4.9	2.5	1	2
34	Male	3.7	2.1	490	115	91	6.5	2.8	0.7	1
50	Male	0.8	0.2	152	29	30	7.4	4.1	1.3	1
38	Male	2.7	1.4	105	25	21	7.5	4.2	1.2	2
51	Male	0.8	0.2	160	34	20	6.9	3.7	1.1	1
46	Male	0.8	0.2	160	31	40	7.3	3.8	1.1	1

72	Male	0.6	0.1	102	31	35	6.3	3.2	1	1
72	Male	0.8	0.2	148	23	35	6	3	1	1
75	Male	0.9	0.2	162	25	20	6.9	3.7	1.1	1
41	Male	7.5	4.3	149	94	92	6.3	3.1	0.9	1
41	Male	2.7	1.3	580	142	68	8	4	1	1
48	Female	1	0.3	310	37	56	5.9	2.5	0.7	1
45	Male	0.8	0.2	140	24	20	6.3	3.2	1	2
74	Male	1	0.3	175	30	32	6.4	3.4	1.1	1
78	Male	1	0.3	152	28	70	6.3	3.1	0.9	1
38	Male	0.8	0.2	208	25	50	7.1	3.7	1	1
27	Male	1	0.2	205	137	145	6	3	1	1
66	Female	0.7	0.2	162	24	20	6.4	3.2	1	2
50	Male	7.3	3.7	92	44	236	6.8	1.6	0.3	1
42	Female	0.5	0.1	162	155	108	8.1	4	0.9	1
65	Male	0.7	0.2	199	19	22	6.3	3.6	1.3	2
22	Male	0.8	0.2	198	20	26	6.8	3.9	1.3	1
31	Female	0.8	0.2	215	15	21	7.6	4	1.1	1
45	Male	0.7	0.2	180	18	58	6.7	3.7	1.2	2
12	Male	1	0.2	719	157	108	7.2	3.7	1	1
48	Male	2.4	1.1	554	141	73	7.5	3.6	0.9	1
48	Male	5	2.6	555	284	190	6.5	3.3	1	1
18	Male	1.4	0.6	215	440	850	5	1.9	0.6	1
23	Female	2.3	0.8	509	28	44	6.9	2.9	0.7	2
65	Male	4.9	2.7	190	33	71	7.1	2.9	0.7	1
48	Male	0.7	0.2	208	15	30	4.6	2.1	0.8	2
65	Male	1.4	0.6	260	28	24	5.2	2.2	0.7	2
70	Male	1.3	0.3	690	93	40	3.6	2.7	0.7	1
70	Male	0.6	0.1	862	76	180	6.3	2.7	0.75	1
11	Male	0.7	0.1	592	26	29	7.1	4.2	1.4	2
50	Male	4.2	2.3	450	69	50	7	3	0.7	1
55	Female	8.2	3.9	1350	52	65	6.7	2.9	0.7	1
55	Female	10.9	5.1	1350	48	57	6.4	2.3	0.5	1
26	Male	1	0.3	163	48	71	7.1	3.7	1	2
41	Male	1.2	0.5	246	34	42	6.9	3.4	0.97	1
53	Male	1.6	0.9	178	44	59	6.5	3.9	1.5	2
32	Female	0.7	0.1	240	12	15	7	3	0.7	1
58	Male	0.4	0.1	100	59	126	4.3	2.5	1.4	1
45	Male	1.3	0.6	166	49	42	5.6	2.5	0.8	2
65	Male	0.9	0.2	170	33	66	7	3	0.75	1
52	Female	0.6	0.1	194	10	12	6.9	3.3	0.9	2
73	Male	1.9	0.7	1750	102	141	5.5	2	0.5	1
53	Female	0.7	0.1	182	20	33	4.8	1.9	0.6	1
47	Female	0.8	0.2	236	10	13	6.7	2.9	0.76	2
29	Male	0.7	0.2	165	55	87	7.5	4.6	1.58	1

41	Female	0.9	0.2	201	31	24	7.6	3.8	1	2
30	Female	0.7	0.2	194	32	36	7.5	3.6	0.92	2
17	Female	0.5	0.1	206	28	21	7.1	4.5	1.7	2
23	Male	1	0.3	212	41	80	6.2	3.1	1	1
35	Male	1.6	0.7	157	15	44	5.2	2.5	0.9	1
65	Male	0.8	0.2	162	30	90	3.8	1.4	0.5	1
42	Female	0.8	0.2	168	25	18	6.2	3.1	1	1
49	Female	0.8	0.2	198	23	20	7	4.3	1.5	1
42	Female	2.3	1.1	292	29	39	4.1	1.8	0.7	1
42	Female	7.4	3.6	298	52	102	4.6	1.9	0.7	1
42	Female	0.7	0.2	152	35	81	6.2	3.2	1.06	1
61	Male	0.8	0.2	163	18	19	6.3	2.8	0.8	2
17	Male	0.9	0.2	279	40	46	7.3	4	1.2	2
54	Male	0.8	0.2	181	35	20	5.5	2.7	0.96	1
45	Female	23.3	12.8	1550	425	511	7.7	3.5	0.8	1
48	Female	0.8	0.2	142	26	25	6	2.6	0.7	1
48	Female	0.9	0.2	173	26	27	6.2	3.1	1	1
65	Male	7.9	4.3	282	50	72	6	3	1	1
35	Male	0.8	0.2	279	20	25	7.2	3.2	0.8	1
58	Male	0.9	0.2	1100	25	36	7.1	3.5	0.9	1
46	Male	0.7	0.2	224	40	23	7.1	3	0.7	1
28	Male	0.6	0.2	159	15	16	7	3.5	1	2
21	Female	0.6	0.1	186	25	22	6.8	3.4	1	1
32	Male	0.7	0.2	189	22	43	7.4	3.1	0.7	2
61	Male	0.8	0.2	192	28	35	6.9	3.4	0.9	2
26	Male	6.8	3.2	140	37	19	3.6	0.9	0.3	1
65	Male	1.1	0.5	686	16	46	5.7	1.5	0.35	1
22	Female	2.2	1	215	159	51	5.5	2.5	0.8	1
28	Female	0.8	0.2	309	55	23	6.8	4.1	1.51	1
38	Male	0.7	0.2	110	22	18	6.4	2.5	0.64	1
25	Male	0.8	0.1	130	23	42	8	4	1	1
45	Female	0.7	0.2	164	21	53	4.5	1.4	0.45	2
45	Female	0.6	0.1	270	23	42	5.1	2	0.5	2
28	Female	0.6	0.1	137	22	16	4.9	1.9	0.6	2
28	Female	1	0.3	90	18	108	6.8	3.1	0.8	2
66	Male	1	0.3	190	30	54	5.3	2.1	0.6	1
66	Male	0.8	0.2	165	22	32	4.4	2	0.8	1
66	Male	1.1	0.5	167	13	56	7.1	4.1	1.36	1
49	Female	0.6	0.1	185	17	26	6.6	2.9	0.7	2
42	Male	0.7	0.2	197	64	33	5.8	2.4	0.7	2
42	Male	1	0.3	154	38	21	6.8	3.9	1.3	2
35	Male	2	1.1	226	33	135	6	2.7	0.8	2
38	Male	2.2	1	310	119	42	7.9	4.1	1	2
38	Male	0.9	0.3	310	15	25	5.5	2.7	1	1

55	Male	0.6	0.2	220	24	32	5.1	2.4	0.88	1
33	Male	7.1	3.7	196	622	497	6.9	3.6	1.09	1
33	Male	3.4	1.6	186	779	844	7.3	3.2	0.7	1
7	Male	0.5	0.1	352	28	51	7.9	4.2	1.1	2
45	Male	2.3	1.3	282	132	368	7.3	4	1.2	1
45	Male	1.1	0.4	92	91	188	7.2	3.8	1.11	1
30	Male	0.8	0.2	182	46	57	7.8	4.3	1.2	2
62	Male	5	2.1	103	18	40	5	2.1	1.72	1
22	Female	6.7	3.2	850	154	248	6.2	2.8	0.8	1
42	Female	0.8	0.2	195	18	15	6.7	3	0.8	1
32	Male	0.7	0.2	276	102	190	6	2.9	0.93	1
60	Male	0.7	0.2	171	31	26	7	3.5	1	2
65	Male	0.8	0.1	146	17	29	5.9	3.2	1.18	2
53	Female	0.8	0.2	193	96	57	6.7	3.6	1.16	1
27	Male	1	0.3	180	56	111	6.8	3.9	1.85	2
35	Female	1	0.3	805	133	103	7.9	3.3	0.7	1
65	Male	0.7	0.2	265	30	28	5.2	1.8	0.52	2
25	Male	0.7	0.2	185	196	401	6.5	3.9	1.5	1
32	Male	0.7	0.2	165	31	29	6.1	3	0.96	2
24	Male	1	0.2	189	52	31	8	4.8	1.5	1
67	Male	2.2	1.1	198	42	39	7.2	3	0.7	1
68	Male	1.8	0.5	151	18	22	6.5	4	1.6	1
55	Male	3.6	1.6	349	40	70	7.2	2.9	0.6	1
70	Male	2.7	1.2	365	62	55	6	2.4	0.6	1
36	Male	2.8	1.5	305	28	76	5.9	2.5	0.7	1
42	Male	0.8	0.2	127	29	30	4.9	2.7	1.2	1
53	Male	19.8	10.4	238	39	221	8.1	2.5	0.4	1
32	Male	30.5	17.1	218	39	79	5.5	2.7	0.9	1
32	Male	32.6	14.1	219	95	235	5.8	3.1	1.1	1
56	Male	17.7	8.8	239	43	185	5.6	2.4	0.7	1
50	Male	0.9	0.3	194	190	73	7.5	3.9	1	1
46	Male	18.4	8.5	450	119	230	7.5	3.3	0.7	1
46	Male	20	10	254	140	540	5.4	3	1.2	1
37	Female	0.8	0.2	205	31	36	9.2	4.6	1	2
45	Male	2.2	1.6	320	37	48	6.8	3.4	1	1
56	Male	1	0.3	195	22	28	5.8	2.6	0.8	2
69	Male	0.9	0.2	215	32	24	6.9	3	0.7	1
49	Male	1	0.3	230	48	58	8.4	4.2	1	1
49	Male	3.9	2.1	189	65	181	6.9	3	0.7	1
60	Male	0.9	0.3	168	16	24	6.7	3	0.8	1
28	Male	0.9	0.2	215	50	28	8	4	1	1
45	Male	2.9	1.4	210	74	68	7.2	3.6	1	1
35	Male	26.3	12.1	108	168	630	9.2	2	0.3	1
62	Male	1.8	0.9	224	69	155	8.6	4	0.8	1

55	Male	4.4	2.9	230	14	25	7.1	2.1	0.4	1
46	Female	0.8	0.2	185	24	15	7.9	3.7	0.8	1
50	Male	0.6	0.2	137	15	16	4.8	2.6	1.1	1
29	Male	0.8	0.2	156	12	15	6.8	3.7	1.1	2
53	Female	0.9	0.2	210	35	32	8	3.9	0.9	2
46	Male	9.4	5.2	268	21	63	6.4	2.8	0.8	1
40	Male	3.5	1.6	298	68	200	7.1	3.4	0.9	1
45	Male	1.7	0.8	315	12	38	6.3	2.1	0.5	1
55	Male	3.3	1.5	214	54	152	5.1	1.8	0.5	1
22	Female	1.1	0.3	138	14	21	7	3.8	1.1	2
40	Male	30.8	18.3	285	110	186	7.9	2.7	0.5	1
62	Male	0.7	0.2	162	12	17	8.2	3.2	0.6	2
46	Female	1.4	0.4	298	509	623	3.6	1	0.3	1
39	Male	1.6	0.8	230	88	74	8	4	1	2
60	Male	19.6	9.5	466	46	52	6.1	2	0.4	1
46	Male	15.8	7.2	227	67	220	6.9	2.6	0.6	1
10	Female	0.8	0.1	395	25	75	7.6	3.6	0.9	1
52	Male	1.8	0.8	97	85	78	6.4	2.7	0.7	1
65	Female	0.7	0.2	406	24	45	7.2	3.5	0.9	2
42	Male	0.8	0.2	114	21	23	7	3	0.7	2
42	Male	0.8	0.2	198	29	19	6.6	3	0.8	2
62	Male	0.7	0.2	173	46	47	7.3	4.1	1.2	2
40	Male	1.2	0.6	204	23	27	7.6	4	1.1	1
54	Female	5.5	3.2	350	67	42	7	3.2	0.8	1
45	Female	0.7	0.2	153	41	42	4.5	2.2	0.9	2
45	Male	20.2	11.7	188	47	32	5.4	2.3	0.7	1
50	Female	27.7	10.8	380	39	348	7.1	2.3	0.4	1
42	Male	11.1	6.1	214	60	186	6.9	2.8	2.8	1
40	Female	2.1	1	768	74	141	7.8	4.9	1.6	1
46	Male	3.3	1.5	172	25	41	5.6	2.4	0.7	1
29	Male	1.2	0.4	160	20	22	6.2	3	0.9	2
45	Male	0.6	0.1	196	29	30	5.8	2.9	1	1
46	Male	10.2	4.2	232	58	140	7	2.7	0.6	1
73	Male	1.8	0.9	220	20	43	6.5	3	0.8	1
55	Male	0.8	0.2	290	139	87	7	3	0.7	1
51	Male	0.7	0.1	180	25	27	6.1	3.1	1	1
51	Male	2.9	1.2	189	80	125	6.2	3.1	1	1
51	Male	4	2.5	275	382	330	7.5	4	1.1	1
26	Male	42.8	19.7	390	75	138	7.5	2.6	0.5	1
66	Male	15.2	7.7	356	321	562	6.5	2.2	0.4	1
66	Male	16.6	7.6	315	233	384	6.9	2	0.4	1
66	Male	17.3	8.5	388	173	367	7.8	2.6	0.5	1
64	Male	1.4	0.5	298	31	83	7.2	2.6	0.5	1
38	Female	0.6	0.1	165	22	34	5.9	2.9	0.9	2

43	Male	22.5	11.8	143	22	143	6.6	2.1	0.46	1
50	Female	1	0.3	191	22	31	7.8	4	1	2
52	Male	2.7	1.4	251	20	40	6	1.7	0.39	1
20	Female	16.7	8.4	200	91	101	6.9	3.5	1.02	1
16	Male	7.7	4.1	268	213	168	7.1	4	1.2	1
16	Male	2.6	1.2	236	131	90	5.4	2.6	0.9	1
90	Male	1.1	0.3	215	46	134	6.9	3	0.7	1
32	Male	15.6	9.5	134	54	125	5.6	4	2.5	1
32	Male	3.7	1.6	612	50	88	6.2	1.9	0.4	1
32	Male	12.1	6	515	48	92	6.6	2.4	0.5	1
32	Male	25	13.7	560	41	88	7.9	2.5	2.5	1
32	Male	15	8.2	289	58	80	5.3	2.2	0.7	1
32	Male	12.7	8.4	190	28	47	5.4	2.6	0.9	1
60	Male	0.5	0.1	500	20	34	5.9	1.6	0.37	2
40	Male	0.6	0.1	98	35	31	6	3.2	1.1	1
52	Male	0.8	0.2	245	48	49	6.4	3.2	1	1
31	Male	1.3	0.5	184	29	32	6.8	3.4	1	1
38	Male	1	0.3	216	21	24	7.3	4.4	1.5	2