

**IMPLEMENTASI METODE SUPPORT VECTOR MACHINE
UNTUK MELAKUKAN KLASIFIKASI
PADA DATA BIOINFORMATIKA**

(Studi kasus: Klasifikasi *Gene Expression*
yang Terjangkit *Medullloblastoma* di Amerika)

TUGAS AKHIR



Lalu Bayu Dwi Cahyo

13611187

PROGRAM STUDI STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS ISLAM INDONESIA
YOGYAKARTA
2018

**IMPLEMENTASI METODE SUPPORT VECTOR MACHINE
UNTUK MELAKUKAN KLASIFIKASI
PADA DATA BIOINFORMATIKA**

(Studi kasus: Klasifikasi Gene Expression
yang Terjangkit Medulloblastoma di Amerika)

TUGAS AKHIR

**Diajukan Sebagai Salah Satu Syarat Untuk Memperoleh Gelar Sarjana
Jurusan Statistika**



Lalu Bayu Dwi Cahyo

13611187

PROGRAM STUDI STATISTIKA
FAKULTAS MATEMATIKA DAN ILMU PENGETAHUAN ALAM
UNIVERSITAS ISLAM INDONESIA
YOGYAKARTA
2018

**HALAMAN PERSETUJUAN PEMBIMBING
TUGAS AKHIR**

Judul

Implementasi Metode *Support Vector Machine* Untuk
Melakukan Klasifikasi Pada Data Bioinformatika
(Studi Kasus: Klasifikasi *Gene Expression*
yang Terjangkit *Medulloblastoma* di Amerika)

Nama Mahasiswa

Lalu Bayu Dwi Cahyo

Nomor Mahasiswa

136111187

**TUGAS AKHIR INI TELAH DIPERIKSA DAN DISETUJUI
UNTUK DIUJIKAN**

Yogyakarta,

Dr.techn.Rohmatul Fajriyah, S.Si., M.Si

HALAMAN PENGESAHAN

TUGAS AKHIR

IMPLEMENTASI METODE SUPPORT VECTOR MACHINE UNTUK MELAKUKAN KLASIFIKASI PADA DATA BIOINFORMATIKA

(Studi Kasus: Klasifikasi *Gene Expression*
yang Terjangkit *Medulloblastoma* di Amerika)

| | |
|---|--|
| UNIVERSITAS ISLAM NEGERI YOGYAKARTA | Nama Mahasiswa : Lalu Bayu Dwi Cahyo |
| | Nomor Mahasiswa : 136111187 |
| TUGAS AKHIR INI TELAH DIUJIKAN PADA TANGGAL 13 FEBRUARI 2018 | |
| Nama Pengaji | Tanda Tangan |
| 1. Fitria Dyah Ayu Suryanegara, M.Sc., Apt. |  |
| 2. Ayundyah Kesumawati, S.Si, M.Si. |  |
| 3. Dr.techn.Rohmatul Fajriyah, S.Si., M.Si. | |
| Mengetahui, | |
| Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam | |

Drs. Ajwar, M.Sc. Ph.D.

KATA PENGANTAR



Assalamu 'alaikum Wr.Wb.

Alhamdulillahirabbil'alamiin, puji syukur kehadirat Allah SWT yang telah memberikan hidayah, kesempatan, dan kemudahan kepada kita semua dalam menjalankan amanah yang menjadi tanggung jawab kita. Shalawat serta salam tak henti-hentinya kita panjatkan kepada junjungan kita Nabi Besar Muhammad SAW beserta seluruh keluarga dan sahabatnya, karena dengan syafa'atnya kita dapat hijrah dari zaman jahiliyah menuju zaman yang terang benderang.

Tugas akhir yang berjudul “Implementasi Metode *Support Vector Machine* Untuk Melakukan Klasifikasi pada Data Bioinformatika” ini sebagai salah satu syarat untuk memperoleh gelar sarjana Jurusan Statistika di Universitas Islam Indonesia. Dalam penyusunan skripsi ini penulis banyak mengalami hambatan, namun berkat bantuan, bimbingan, dan kerjasama yang ikhlas dari berbagai pihak, akhirnya skripsi ini dapat terselesaikan dengan baik.

Pada kesempatan ini penulis mengucapkan terima kasih dengan tulus kepada :

1. Bapak Nandang Sutrisno, SH., M.Hum., LLM., Ph.D, selaku Rektor Universitas Islam Indonesia.
2. Bapak Drs. Allwar, M.Sc., Ph.D. selaku Dekan Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Islam Indonesia, Yogyakarta beserta seluruh jajarannya.
3. Bapak Dr. RB. Fajriya Hakim, S.Si, M.Si, selaku Ketua Jurusan Statistika beserta seluruh jajarannya.
4. Ibu Dr.techn.Rohmatul Fajriyah, S.Si., M.Si, selaku dosen pembimbing. Terimakasih atas waktu, tenaga, motivasi, ilmu, nasehat serta bimbingannya sehingga penulis dapat menyelesaikan tugas akhir ini dengan baik.
5. Dosen-dosen Statistika Universitas Islam Indonesia yang telah mendidik dan menginspirasi.

6. Lalu Sukardi, Partinah, Lalu Imam Patra Anjalo, dan Baiq Alivia Safira selaku keluarga, terima kasih atas segalanya dengan penuh kesabaran, ketulusan doa dan rizki dari setiap tetes keringat yang mengalir, dukungan dan kasih sayang.
7. Sahabat-sahabatku semua yang selalu ada untuk penulis selama masa kuliah, atas kebersamaan dari awal kuliah hingga sekarang terimakasih atas segala hal yang pernah dilalui bersama.
8. Teman – teman seperjuanganku di Jurusan Statistika 2013, terimakasih atas kebersamaannya selama ini, menuntut ilmu bersama kalian adalah pengalaman yang tak akan pernah terlupakan.
9. Semua pihak yang telah membantu dalam penyusunan skripsi ini yang tidak dapat disebukan satu persatu

Semoga segala bantuan, bimbingan dan pengajaran yang telah diberikan kepada penyusun mendapatkan imbalan dari Allah SWT. Tidak lupa penulis memohon maaf apabila selama dalam proses penyusunan tugas akhir ini terdapat kekhilafan dan kesalahan. Penulis menyadari sepenuhnya akan keterbatasan kemampuan yang dimiliki. Oleh karena itu, penulis mengharapkan adanya kritik dan saran yang membangun demi kesempurnaan penyusunan dan penulisan tugas akhir ini. Semoga tugas akhir ini dapat bermanfaat bagi semua yang membaca dan membutuhkannya. Akhir kata, semoga Allah SWT selalu melimpahkan rahmat serta hidayah-Nya kepada kita semua, Amin amin ya robbal ‘alamiin.

Wassalamu’alaikum, Wr.Wb.

Yogyakarta, 3 Januari 2018

Penulis

DAFTAR ISI

| | |
|---|------|
| HALAMAN JUDUL..... | i |
| HALAMAN PERSETUJUAN PEMBIMBING | iii |
| HALAMAN PENGESAHAN..... | iv |
| KATA PENGANTAR | v |
| DAFTAR ISI..... | vii |
| DAFTAR GAMBAR | ix |
| DAFTAR TABEL..... | x |
| DAFTAR LAMPIRAN | xi |
| PERNYATAAN..... | xii |
| INTISARI..... | xiii |
| ABSTRACT | xiv |
| BAB I PENDAHULUAN | 1 |
| 1.1. Latar Belakang | 1 |
| 1.2. Rumusan Masalah | 3 |
| 1.3. Batasan Masalah..... | 3 |
| 1.4. Tujuan Penelitian..... | 3 |
| 1.5. Manfaat Penelitian..... | 3 |
| BAB II TINJAUAN PUSTAKA..... | 5 |
| 2.1. Penelitian dengan <i>Support Vector Machine</i> | 5 |
| 2.2. Penelitian Terkait <i>Bioinformatics</i> | 6 |
| 2.3. Penelitain teerkait Medulloblastoma | 7 |
| BAB III LANDASAN TEORI..... | 9 |
| 3.1. <i>Support vector machine</i> | 9 |
| 3.1.1. <i>Support Vector Machine linear (biner)</i> | 9 |
| 3.1.2. Soft Margin | 15 |
| 3.1.3. SVM <i>Multiclass</i> | 16 |
| 3.2. <i>Confusion Matrix</i> | 19 |
| 3.3. ROC (<i>Receiver Operating Characteristic</i>) <i>curve</i> | 19 |
| 3.4. DNA dan <i>Gene Expression</i> | 20 |

| | | |
|-----------------------------------|---|----|
| 3.5. | <i>Microarray</i> | 21 |
| 3.6. | <i>Preprocessing</i> | 23 |
| 3.7. | <i>Filtering</i> | 23 |
| BAB IV METODE PENELITIAN | | 25 |
| 4.1. | Jenis dan Sumber Data | 25 |
| 4.2. | Tempat dan Waktu Penelitian | 25 |
| 4.3. | Variabel Penelitian | 25 |
| 4.4. | Metode Analisis Data | 25 |
| BAB V PEMBAHASAN | | 27 |
| 5.1. | Deskripsi Data | 27 |
| 5.2. | Pengolahan Data <i>Bioinformatics</i> | 29 |
| 5.2.1. | <i>Preprocessing</i> | 30 |
| 5.2.2. | <i>Filtering</i> | 31 |
| 5.2.3. | Mengolah data | 32 |
| 5.3. | Klasifikasi Data Gen | 32 |
| 5.3.1. | <i>Confusion matrix</i> | 33 |
| 5.3.2. | <i>ROC curve</i> | 34 |
| 5.4. | Model Klasifikasi | 34 |
| BAB VI KESIMPULAN DAN SARAN | | 40 |
| 6.1. | Kesimpulan | 40 |
| 6.2. | Saran | 41 |
| DAFTAR PUSTAKA | | 42 |
| LAMPIRAN | | 45 |

DAFTAR GAMBAR

| | |
|--|----|
| Gambar 3.1 Penentukan <i>Hyperplane</i> Terbaik | 9 |
| Gambar 3.2 <i>Plot</i> Contoh Data..... | 13 |
| Gambar 3.3 <i>hyperplane</i> | 15 |
| Gambar 3.4 Contoh Klasifikasi dengan Metode <i>One-against-all</i> | 17 |
| Gambar 3.5 Contoh Klasifikasi dengan Metode <i>One-against-one</i> | 18 |
| Gambar 3.6 <i>Affymetrix genechip</i> | 22 |
| Gambar 4.1 <i>Flowchart Penelitian</i> | 25 |
| Gambar 5.1 <i>Pie Chart</i> Subtipe <i>Medulloblastoma</i> | 27 |
| Gambar 5.2. Jenis Kelamin | 27 |
| Gambar 5.3. Etnis Pasien | 28 |

DAFTAR TABEL

| | |
|---|----|
| Tabel 3.1 Contoh data | 12 |
| Tabel 3.2 Contoh SVM dengan Metode <i>One-against-all</i> | 17 |
| Tabel 3.3 Contoh SVM biner dengan Metode <i>One-Against-One</i> | 18 |
| Tabel 3.4 <i>Confusion Matrix</i> | 19 |
| Tabel 5.1 <i>Pheno Data</i> | 30 |
| Tabel 5.2 <i>Confusion Matrix</i> Data Latih | 33 |
| Tabel 5.3 <i>Confusion Matrix</i> Data Uji..... | 33 |
| Tabel 5.4 Bobot <i>Probe ID</i> | 35 |
| Tabel 5.5 Tabel <i>Ontology</i> | 35 |
| Tabel 5.6 Keterangan <i>Probe ID</i> | 37 |

DAFTAR LAMPIRAN

| | |
|---|----|
| Lampiran 1 <i>Package Bioinformatics</i> | 45 |
| Lampiran 2 <i>Input data</i> | 45 |
| Lampiran 3 <i>subset sample</i> | 46 |
| Lampiran 4 <i>Piechart</i> | 47 |
| Lampiran 5 <i>Barplot gender</i> | 47 |
| Lampiran 6 <i>ethnic</i> | 47 |
| Lampiran 7 <i>Preprocessing data</i> | 48 |
| Lampiran 8 <i>Filtering</i> | 48 |
| Lampiran 9 <i>Make ExpressionSet</i> | 49 |
| Lampiran 10 <i>Packages SVM</i> | 49 |
| Lampiran 11 Penyusunan data set..... | 50 |
| Lampiran 12 <i>Tuning</i> | 51 |
| Lampiran 13 <i>Confusion matrix</i> | 52 |
| Lampiran 14 Bobot | 52 |
| Lampiran 15 AUC..... | 53 |
| Lampiran 16 <i>Gene name</i> dan <i>Gene Ontology</i> | 53 |
| Lampiran 17 Session Info | 55 |

PERNYATAAN

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

Yogyakarta, 3 Februari 2018



Lalu Bayu Dwi Cahyo

**IMPLEMENTASI METODE SUPPORT VECTOR MACHINE
UNTUK MELAKUKAN KLASIFIKASI
PADA DATA BIOINFORMATIKA**

(Studi kasus: Klasifikasi *Gene Expression*
yang Terjangkit *Medulloblastoma* di Amerika)

Lalu Bayu Dwi Cahyo
Program Studi Statistika Fakultas MIPA
Universitas Islam Indonesia

INTISARI

Medulloblastoma merupakan kelompok heterogen tumor ganas dari system saraf pusat (Central Nervous System(CNS)). Penderita medulloblastoma antara 18%-20% dari semua tumor otak pada anak-anak serta 70% dari penderita medulloblastoma terdeteksi pada usia 10 tahun ke bawah. Fingkelstein melakukan pendataan pada 76 pasien usia muda yang terjangkit medulloblastoma di St Jude Children's Research Hospital disimpan dalam microarray dengan kode akses GSE37418. Penderita medulloblastoma memiliki 4 subrump yang yaitu WNT(wingless), SHH(sonic hedgehog), Subgroup 3, dan subgroup 4. Berdasarkan data finkelstein akan dilakukan klasifikasi menggunakan metode support vector machine (SVM) menggunakan program R.3.4.2 dengan tambahan packages dari bioconductor. Terdapat 4 tahap dalam pengolahannya yaitu Input data, Preprocessing yang memproses data microarray agar datanya representatif, Filtering yang memilih data dan mengkualifikasinya, dan analisis SVM untuk klasifikasi. Berdasarkan hasil analisis SVM mampu memprediksi kelas penderita dengan akurasi 95% dengan nilai AUC 98%. Terdapat probe yang memiliki bobot cukup tinggi yang merupakan gen yang aktif pada berbagai tumor seperti insulinomas, kanker kerongkongan, dan kanker usus besar.

Kata kunci: *Medulloblastoma, Bioinformatika, Klasifikasi, Support Vector Machine, Microarray*

IMPLEMENTATION OF SUPPORT VECTOR MACHINE

METHOD FOR CLASSIFICATION

ON BIOINFORMATIC DATA

(Case study: Classification of Gene Expression
Infected by Medulloblastoma in America)

Lalu Bayu Dwi Cahyo

Departement of Statistics, Faculty of Mathematic and Natural Science
Islamic University of Indonesia

ABSTRACT

Medulloblastoma is a heterogeneous group of malignant tumors of the central nerve system (CNS). Medulloblastoma is relatively rare, 18%-20% of all cancerous pediatric brain tumors, 70% of all pediatric medulloblastomas are diagnosed in children under age 10. According Fingkelstein research collected 76 data infected pediatric medulloblastoma at St. Jude Children Research Hospital stored in a microarray with access code GSE37418. Medulloblastoma has 4 subgroup namely WNT(wingless), SHH(sonic hedgehog), Subgroup 3, dan subgroup 4. The Data has collected by Finkelstein will be classified using the support vector machine method on R.3.4.2 with additional packages of bioconductor. There is 4 step in processing that is input the data, preprocesing to get representative data, Filtering for qualified data, and implement the SVM method for classification. Base on the result, SVM can predict sample with accuration 95% and AUC 98%. Some of the probe that has a high enough weight, the probe is a gene that is active in various tumors such as insulinomas, esophageal cancer, and colon cancer

Key word: Medulloblastoma, Bionformatic, Classification, Support Vector Machine, Microarray

BAB I

PENDAHULUAN

1.1.Latar Belakang

Perkembangan teknologi pada era globalisasi abad 21 diikuti dengan ledakan data dalam jumlah besar atau yang sering dikenal dengan sebutan *big data*. Big Data adalah sebuah sistem teknologi yang diperkenalkan untuk menanggulangi 'ledakan informasi' seiring dengan semakin bertumbuhnya ekosistem pengguna perangkat *mobile* dan data *internet*. *Big data* memiliki tiga istilah yaitu *volume* , *variety* , dan *velocity*. *Volume* berkaitan dengan ukuran media penyimpanan data yang sangat besar atau mungkin tak terbatas, *variety* berarti tipe atau jenis data yang dapat diakomodasi, dan *velocity* dapat diartikan sebagai kecepatan proses.(IBM,2017)

Perkembangan data terjadi pada hampir semua bidang ilmu tidak terkecuali bidang ilmu biologi molekuler yang dikenal dengan bioinformatika. Bioinformatika merupakan suatu terapan dari ilmu yang mempelajari penerapan ilmu di bidang komputer untuk mengelola dan menganalisis informasi biologis. Bioinformatika mencakup penerapan metode-metode statistika, dan informatika untuk memecahkan masalah-masalah biologis.(Attwood,1999)

Pembahasan tentang bioinformatika akan meliputi *sequencing* dan *microarray (microchip)*. Dalam situs resmi Pusat Informasi Bioteknologi National Amerika (NCBI) mendefinisikan *microarray* adalah hibridisasi dari sampel asam nukleat (target) untuk satu set *probe* oligonukleotida yang besar, yang melekat dengan solid, untuk menentukan urutan atau untuk mendeteksi variasi dalam urutan gen atau ekspresi atau untuk pemetaan gen.(NCBI,2017)

Keberadaan *microarray* yang merupakan *sequencing* dari suatu data organisme tentunya memiliki jumlah data dan dimensi yang banyak sesuai dengan penjelasan sebelumnya. *Microarray* tersebut berisikan tentang informasi dari kumpulan *probe* dari suatu gen.

Implementasi dari hal tersebut salah satunya ialah tersimpannya data gen pasien yang terjangkit kanker otak pada anak yaitu *medulloblastoma*.

Medulloblastoma merupakan kelompok heterogen tumor ganas dari system saraf pusat (*Central Nerveous System(CNS)*) yang menyerang laki-laki usia muda. Penyakit ini tergolong langka dan agresif, ditandai dengan kecendrungan yang metastatis.(ABTA,2015)

Berdasarkan *e-book* berjudul *medulloblastoma* yang dirilis ABTA(American Brain Tumor Association) tahun 2015, *medulloblastoma* relatif jarang terjadi, terhitung kurang dari 2% dari semua tumor otak primer (tumor yang dimulai di otak atau di permukaannya), antara 18%-20% dari semua tumor otak yang menyerang anak-anak. *Medulloblastoma* adalah tumor otak ganas yang paling sering pada anak usia empat tahun kebawah dan kedua terbanyak menyerang anak usia 5-14 tahun serta 70% dari penderita *medulloblastoma* terdeteksi pada usia 10 tahun ke bawah.

Perkembangan terbaru dalam biologi molekuler dari *medulloblastoma* menunjukkan bahwa klasifikasi tumor embrio yang semata-mata berdasarkan kriteria histologi dan klinis tidak cukup memadai. Pemahaman yang lebih baik tentang mekanisme pengendalian pertumbuhan dalam pengembangan dan kemajuan *medulloblastoma* akan memungkinkan klasifikasi yang lebih baik, yang mengarah pada perbaikan terapi yang ada, serta pengembangan pendekatan terapeutik baru. (Rosi, 2008). Terdapat 4 subgroup dalam penyakit *medulloblastoma* yakni WNT (*wingless*), SHH (*sonic hedgehog*), Group 3 dan Group 4.

Penelitian Finkelstein yang dipublis tahun 2012 diunggah pada halaman NCBI dengan kode GSE37418. Finkelstein melakukan pendataan pada 76 pasien usia muda yang terjangkit *medulloblastoma* dengan judul “*Novel mutations target distinct subgroups of medulloblastoma*”. Penelitian Finkelstein mengklasifikasikan penderita ke dalam 4 kelas WNT, SHH, group 3 dan group 4.

Perbedaan kelas pada setiap penderita *medulloblastoma* memiliki jenis perlakuan pada tahap pengobatan baik terapi dan target biologis, oleh karena itu perlu dilakukan klasifikasi. Penelitian Finkelstein diangkat dalam

penelitian untuk diklasifikasikan dengan menggunakan metode *Support Vector Machine*.

1.2. Rumusan Masalah

Berdasarkan latar belakang dan fokus masalah, rumusan masalah yang akan dikaji dalam penelitian ini ialah:

1. Bagaimana mengolah data *bioinformatics*?
2. Bagaimana hasil klasifikasi gen yang terbentuk dengan menggunakan SVM?
3. Bagaimana model SVM yang tepat untuk klasifikasi pasien yang ada?

1.3.Batasan Masalah

Adapun batasan masalah dalam penelitian ini adalah:

1. Bahasa pemrograman dan *software* yang digunakan dalam penelitian ini adalah *software R 3.4.2* dengan beberapa *package bioinformatics*.
2. Melakukan klasifikasi dengan menggunakan *hyperplane* yang terbentuk berdasarkan dimensi data yang terangkum dalam algoritma SVM *linear*.
3. Menjelaskan hasil analisis yang berkaitan dengan data gen *microarray*.

1.4.Tujuan Penelitian

Penelitian ini bertujuan untuk:

1. Mengetahui data *bioinformatics* dan cara mengolah data tersebut.
2. Mengklasifikasikan data gen *microarray* menggunakan SVM *linear*.
3. Mengetahui kelas dari data yang baru berdasarkan model SVM yang terbentuk.

1.5.Manfaat Penelitian

Adapun manfaat dilakukan penelitian ini adalah:

1. Secara teoritis

Hasil penelitian ini diharapkan dapat digunakan oleh berbagai kalangan terutama untuk disiplin ilmu bioinformatika yang didalamnya termasuk ilmu-ilmu hayati (kimia, biologi, farmasi, dan kedokteran), fisika, statistika, dan teknologi informasi.

2. Secara prkatek

Hasil penelitian ini diharapkan mampu memberikan informasi kepada berbagai kalangan terkait pengelompokan dan pola yang dibentuk dan dapat memprediksi kelompok dari data yang baru.

BAB II

TINJAUAN PUSTAKA

2.1.Penelitian dengan *Support Vector Machine*

Support Vector Machine (SVM) dikembangkan oleh Boser, Guyon, Vapnik, dan pertama kali dipresentasikan pada tahun 1992 di *Annual Workshop on Computational Learning Theory*. Konsep dasar SVM sebenarnya merupakan kombinasi harmonis dari teori-teori komputasi yang telah ada puluhan tahun sebelumnya, seperti margin *hyperplane* (Duda & Hart (1973), Cover (1965), Vapnik (1964), dan sebagai nya.), kernel (Aronszajn, 1950) dan konsep-konsep pendukung yang lain. Belum pernah ada upaya merangkaikan komponen-komponen tersebut hingga tahun 1992.

Nugroho (2003) menulis makalah dengan judul Suport Vector Machines : Teori Aplikasinya dalam Bioinformatika. Berdasarkan penelitian tersebut aplikasi SVM pada bioinformatika, khususnya analisa ekspresi gen yang diperoleh dari eksperimen *microarray* terhadap pasien penderita penyakit kanker. Penelitian tersebut diangkat dari eksperimen yang dilakukan oleh *group* Terrence S. Furey, dengan tujuan memakai SVM untuk mengklasifikasi apakah suatu pasien terkena penyakit kanker atau tidak, berdasarkan hasil analisa *microarray* terhadap sel pasien tersebut.

SVM menunjukkan hasil yang lebih baik daripada *perceptron*. Walaupun demikian, dikarenakan jumlah sampel yang relatif sedikit, hasil eksperimen itu belum dapat memberikan kesimpulan final bahwa SVM *superior* terhadap *perceptron*.

Brown (1999) juga menulis jurnal yang diterima pada 15 November 1999 di *Stanford University School of Medicine, Stanford, CA*, menuliskan penerapan SVM untuk data bioinformatika yang berjudul “*Knowledge-based analysis of microarray gene expression data by using support vector machines*”. Penelitian tersebut menggunakan metode SVM dan analisis jalur. Makalah tersebut menyimpulkan bahwa SVM dapat secara akurat mengklasifikasikan gen-gen ke dalam beberapa kategori-kategori fungsional


dan membuat prediksi untuk mengidentifikasi fungsi dari gen-gen *unannotated yeast*.

Terrence (2000) melalukan penelitian dengan judul “*Support Vector Machine Classification and Validation of Cancer Tissue Samples Using Microarray Expression Data*”. Penelitian Terrence digunakan metode SVM dan perceptron. Berdasarkan penelitian tersebut didapatkan hasil SVM bisa mengklasifikasikan tipe-tipe jaringan dan sel, seperti halnya algoritma *perceptron*. Selain itu SVM juga dapat digunakan untuk mengidentifikasi data yang *mis-labeled*. Dalam penelitian ini diaplikasikan diaplikasikan *simple kernel*.

2.2.Penelitian Terkait *Bioinformatics*

Bioinformatics mengalami perkembangan yang signifikan. Hal ini dibuktikan berdasarkan data *bionformatics* yang tekumpul dari tahun ke tahun yang dicatat oleh Kantor Pusat Informasi Bioteknologi Nasional (NCBI) di Amerika Serikat yaitu:

GenBank and WGS Statistics



Sumber: <https://www.ncbi.nlm.nih.gov/genbank/statistics>

Gambar 2. 1 Perkembangan Data *Bioinformatics*

Aprijani (2004) dalam buku berjudul “Bioinformatika: Perkembangan, Disiplin Ilmu dan Penerapannya di Indonesia” menjelaskan bioinformatika merupakan perpaduan dari disiplin ilmu biologi molekul,

matematika dan teknik informasi. Disimpulkan bioinformatika merupakan aplikasi dari komputasi dan analisis data pada data-data biologi molekul. Bioinformatika mempunyai potensi untuk berkembang karena sifatnya multi disipliner, akan tetapi bioinformatika di Indonesia belum memasyarakat.

Lesk (2011) dalam artikel berjudul “*Bioinformatics*” menjelaskan bioinformatika ialah suatu persilangan ilmu pengetahuan yang merujuk kepada data biologi dan teknik pengumpulan informasi, distribusi, dan analisis untuk mendukung gabungan penelitian ilmiah, termasuk biomedicine.

Pengembangan algoritma yang efisien untuk mengukur kemiripan *sequence* merupakan tujuan dari bioinformatika. Algoritma Needleman-Wunsch yang berdasar pada pemrograman dinamis menjamin untuk menemukan keselarasan pasangan *sequence* yang optimal. Algoritma tersebut pada dasarnya membagi masalah besar (*full sequence*) menjadi serangkaian masalah yang lebih kecil (*short sequence segment*) dan menggunakan solusi masalah yang lebih kecil untuk membangun solusi masalah besar. Kesamaan dalam *sequence* dinilai dalam suatu matriks dan algoritmanya memungkinkan untuk mendeteksi kesenjangan dalam keselarasan *sequence*.

Penelitian Alshamlan (2013) dengan judul “*A Study of Cancer Microarray Gene Expression Profile: Objectives and Approaches*”. Berdasarkan hasil penelitian tersebut disimpulkan *Profiling* data *gene expression microarray* merupakan teknik yang efisien pada pengklasifikasian penyakit kanker. Secara umum tujuan dan metode yang digunakan adalah *gene finding, class discovery, dan class prediction*

2.3. Penelitian terkait Medulloblastoma

Northcott (2014) melakukan penelitian dengan judul *Medulloblastoma comprises four distinct molecular variants*. Berdasarkan penelitiannya tumor otak merupakan penyebab utama kematian terkait kanker pada anak-anak dan medulloblastoma merupakan penyakit tumor otak pada anak-anak yang paling ganas. Berdasarkan *gene expression* dan

penyimpangan DNA 103 penderita medulloblastoma, dengan mengaplikasikan metode statistika (Anova, NMF, PCA, SubMap, analisis jalur dan *hierarchical clustering*) teridentifikasi 4 group *non overlapping molecular variant*, yaitu WNT, SHH, *group C*, dan *group D*.

Upadhyay (2014) menyebutkan dalam tesis dengan judul “*Pediatric Medulloblastoma: Molecular biology, correlation with histopathological and clinical outcome*” anak-anak dengan medulloblastoma bila di treatment dengan eksisi bedah radikal dan terapi adjuvant secara jangka panjang hasilnya lebih signifikan.

Hasil terbaik dan terburuk dari *treatment* masing-masing ada pada kelompok *wnt pathway* dan *nonwnt/nonshh*, anak-anak pada kelompok *shh* hasilnya akan berada diantara keduanya.

Studi di India berdasarkan *molecular subtyping* membuktikan bahwa *molecular subtyping* tersebut: layak, hemat biaya dan nilai tambah pada *prognosticating outcome* untuk anak-anak penderita medulloblastoma.

BAB III

LANDASAN TEORI


3.1. *Support vector machine*

SVM(*support vector machine*) dalam *mechine learning* dikenal juga dengan *support vector network* yang merupakan metode *supervised* terkait dengan *learning algorithm* untuk analisa pola data yang digunakan untuk klasifikasi dan regresi. (Mohammed, 2017)

3.1.1. *Support Vector Machine linear (biner)*

Metode SVM menggunakan fungsi dot produk. SVM merupakan usaha mencari *hyperplane* terbaik yang berfungsi sebagai pemisah dua buah *class* pada *input space*.(Nugroho,2003).

Kuliah Umum IlmuKomputer.Com
Copyright © 2003 IlmuKomputer.Com



Gambar 3.1 Penentuan *Hyperplane* Terbaik

Gambar 3.1a memperlihatkan beberapa *pattern* yang merupakan anggota dari dua buah *class* : +1 dan -1. *Pattern* yang tergabung pada *class* -1 disimbolkan dengan warna merah (kotak), sedangkan *pattern* pada *class* +1, disimbolkan dengan warna kuning(lingkaran). Permasalahan klasifikasi dapat diterjemahkan dengan usaha menemukan garis (*hyperplane*) yang

memisahkan antara kedua kelompok tersebut. Berbagai alternatif garis pemisah (*discrimination boundaries*) ditunjukkan pada gambar 3.1a.

Hyperplane pemisah terbaik antara kedua *class* dapat ditemukan dengan mengukur margin *hyperplane* dan mencari titik optimum *hyperplane* tersebut. Margin adalah jarak antara *hyperplane* dengan *pattern* terdekat dari masing-masing *class*. *Pattern* yang paling dekat disebut sebagai *support vector*. Garis solid pada gambar 3.1b menunjukkan *hyperplane* yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua *class*, sedangkan titik merah dan kuning yang berada dalam lingkaran hitam adalah *support vector*. Usaha untuk mencari lokasi *hyperplane* ini merupakan inti dari proses pembelajaran pada SVM.

Misal data yang tersedia dinotasikan sebagai $\vec{x}_i \in \Re^d$ sedangkan label masing-masing dinotasikan $y_i \in \{-1,+1\}$ untuk $i = 1, 2, \dots, l$ dimana l adalah banyaknya data. Diasumsikan kedua kelas -1 dan +1 dapat terpisah secara sempurna oleh *hyperplane* berdimensi d , yang didefinisikan:

$$\vec{w} \cdot \vec{x} + b = 0 \quad (3.1)$$

Pattern \vec{x} yang termasuk *class* -1 (sampel negatif) dapat dirumuskan sebagai *pattern* yang memenuhi pertidaksamaan

$$\vec{w} \cdot \vec{x} + b \leq -1 \quad (3.2)$$

Sedangkan *pattern* \vec{x} yang termasuk *class* +1 (sampel positif)

$$\vec{w} \cdot \vec{x} + b \geq +1 \quad (3.3)$$

Margin terbesar dapat ditemukan dengan mengoptimalkan nilai jarak antara *hyperplane* dan titik terdekatnya, yaitu $1/\|\vec{w}\|$. Hal tersebut dapat dirumuskan sebagai *Quadratic Programming (QP) problem*, yaitu mencari titik minimal persamaan (3.4), dengan memperhatikan *constraint* persamaan (3.5).

$$\min_{\vec{w}} \tau(w) = \frac{1}{2} \|\vec{w}\|^2 \quad (3.4)$$

$$y_i(\vec{w} \cdot \vec{x}_i + b) - 1 \geq 0, \quad \forall_i \quad (3.5)$$

data *input* dinotasikan x_i , adalah keluaran dari data x_i, \vec{w}, b adalah parameter-parameter yang di cari nilainya. Formulasi di atas, ingin meminimalkan fungsi tujuan (*obyektif function*) $\frac{1}{2} \|\vec{w}\|^2$ atau memaksimalkan kuantitas $\|\vec{w}\|^2$ dengan memperhatikan pembatas sebgaimana persamaan 3.2 dan 3.3. Bila output data $y_i = +1$, maka pembatas menjadi $\vec{w} \cdot \vec{x} + b \geq +1$. Sebaliknya bila $y_i = -1$, pembatas menjadi $\vec{w} \cdot \vec{x} + b \leq -1$.

Permasalahan tersebut dapat dipecahkan dengan berbagai teknik komputasi, di antaranya *Lagrange Multiplier*.

$$L(w, b, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^l \alpha_i (y_i (\vec{x}_i \cdot \vec{w}) + b) - 1 \quad (3.6)$$

$$L(w, b, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^l \alpha_i y_i (\vec{x}_i \cdot \vec{w}) - b \sum_{i=1}^l \alpha_i y_i + \sum_{i=1}^l \alpha_i \quad (3.7)$$

Tambahan konstrain, $\alpha_i \geq 0$ (nilai dari koefisien *lagrange*). Meminimumkan L terhadap w dan b.

$$\frac{\partial}{\partial b} L(w, b, \alpha) = 0 \quad (3.8)$$

$$\frac{\partial}{\partial w} L(w, b, \alpha) = 0 \quad (3.9)$$

Dari persamaan 3.8 dan persamaan 3.9 diperoleh persamaan berikut:

$$\sum_{i=1}^l \alpha_i y_i = 0 \quad (3.10)$$

$$\vec{w} = \sum_{i=1}^l \alpha_i y_i \vec{x}_i \quad (3.11)$$

Nilai \vec{w} sering kali besar, tetapi nilai α_i terhingga. Untuk itu, formula *lagrangian Lp (primal problem)* diubah kedalam *dual problem*. Dengan mensubsitusikan persamaan 3.11 ke LP diperoleh *dual problem* L_d dengan konstrain berbeda.

$$L_d(\alpha) = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l \alpha_i \alpha_j y_i y_j \vec{x}_i \vec{x}_j \quad (3.12)$$

Dimana α_i adalah *Lagrange Multiplier* $\alpha_i \geq 0$. Nilai optimal dari persamaan 3.12 dapat dihitung dengan meminimalkan L terhadap \vec{w} dan b , dan memaksimalkan L terhadap α_i , dengan memperhatikan sifat bahwa pada titik optimal *gradient* $L = 0$ persamaan 3.12 dapat dimodifikasi sebagai maksimalisasi problem yang hanya mengandung α_i , sebagaimana terlihat pada persamaan 3.13 dan 3.14 dibawah ini.

$$\max_{\alpha} L_d = \sum_{i=1}^l \alpha_i - \frac{1}{2} \sum_{i,j=1}^l \alpha_i \alpha_j y_i y_j \vec{x}_i \vec{x}_j \quad (3.13)$$


$$\alpha_i \geq 0 (i = 1, 2, \dots, l) \quad \sum_{i=1}^l \alpha_i y_i = 0 \quad (3.14)$$

Berdasarkan persamaan dia atas, maka akan diperoleh α_i yang kebanyakan bernilai positif yang disebut sebagai *support vector*.

Contoh:

Tabel 3.1 Contoh data

| x1 | x2 | y |
|----|----|----|
| 1 | 1 | 1 |
| 1 | -1 | -1 |
| -1 | 1 | -1 |
| -1 | -1 | -1 |



Gambar 3.2 Plot Contoh Data

Gambar 3.2 menunjukkan terdapat 4 titik yang terdiri atas kelas -1 dan kelas 1. Titik-titik tersebut digunakan untuk mencari pemisah antara data positif dan negatif.

Diketahui:

$$\frac{1}{2} \|w\|^2 = \frac{1}{2} (w_1^2 + w_2^2)$$

syarat:

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

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

Sehingga dipatkan beberapa persamaan:

1. $(w_1 + w_2 + b) \geq 1$ untuk $y_1 = 1, x_1=1, x_2=1$
2. $(-w_1 + w_2 - b) \geq 1$ untuk $y_2 = -1, x_1=1, x_2=-1$
3. $(w_1 - w_2 - b) \geq 1$ untuk $y_3 = -1, x_1=-1, x_2=1$
4. $(w_1 + w_2 - b) \geq 1$ untuk $y_4 = -1, x_1=-1, x_2=-1$

Berdasarkan 4 persamaan di atas maka akan dicari nilai dari setiap variabel. Menjumlahkan persamaan 1 dan 2 maka didapat:

$$(w_1 + w_2 + b) \geq 1$$

$$(-w_1 + w_2 - b) \geq 1 \quad +$$

$$2w_2 = 2$$

$$w_2 = 1$$

Menjumlahkan persamaan 1 dan 3:

$$(w_1 + w_2 + b) \geq 1$$

$$(w_1 - w_2 - b) \geq 1 \quad +$$

$$\hline 2w_1 & = 2$$

$$w_1 & = 1$$

Menjumlahkan persamaan 2 dan 3:

$$(-w_1 + w_2 - b) \geq 1$$

$$(w_1 - w_2 - b) \geq 1 \quad +$$

$$\hline -2b & = 2$$


$$b & = -1$$

Berdasarkan hasil di atas didapatkan persamaan:

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

$$x_1 + x_2 - 1 = 0$$

$$x_2 = 1 - x_1$$



Gambar 3.3 Hyperplane

Gambar 3.3 menunjukkan suatu *hyperplane* pada contoh data. *Hyperplane* tersebutlah yang digunakan untuk memisah kelas data antara positif dan negatif. Contoh diatas diketahui bahwa pengolahan data berdasarkan bentuk *data frame*, hal tersebut yang peneliti lakukan dalam mengaplikasikan metode SVM pada data bioinformatika dengan menggunakan program R.

3.1.2. Soft Margin

Penjelasan di atas berdasarkan asumsi bahwa kedua belah kelas terpisah secara sempurna oleh *hyperplane*. Dua buah kelas tidak selalu terpisah secara sempurna. Hal tersebut menyebabkan *constraint* pada persamaan 3.5 tidak terpenuhi, sehingga optimasi tidak terpenuhi dilakukan. Untuk mengatasi masalah ini, SVM dirumuskan ulang dengan menggunakan teknik *softmargin*. Persamaan 3.5 dimodifikasi menggunakan *softmargin* dengan memasukkan variabel *slack* ξ_i ($\xi_i > 0$) sebagai berikut:

$$y_i(\vec{w} \cdot \vec{x}_i + b) - 1 \geq 1 - \xi_i, \forall i \quad (3.15)$$

Dengan demikian persamaan 3.4 diubah menjadi:

$$\min_{\vec{w}} \tau(w) = \frac{1}{2} \|\vec{w}\|^2 + C \sum_{i=1}^l \xi_i \quad (3.16)$$

Parameter C dipilih untuk mengontrol *trade off* antara margin dan *error* klasifikasi ξ . Nilai C yang besar berarti akan memberikan penalti yang lebih besar terhadap *error* klasifikasi tersebut.

3.1.3. SVM *Multiclass*

SVM saat pertama kali diperkenalkan oleh Vapnik, hanya dapat mengklasifikasikan data ke dalam dua kelas (klasifikasi biner). Penelitian lebih lanjut mengembangkan SVM sehingga bisa mengklasifikasi data yang memiliki lebih dari dua kelas terus dilakukan. Terdapat pilihan untuk mengimplementasikan *multiclass* SVM yaitu dengan menggabungkan beberapa SVM biner atau menggabungkan semua data yang terdiri dari beberapa kelas ke dalam sebuah bentuk permasalahan optimasi. Pendekatan yang kedua permasalahan optimasi yang harus diselesaikan jauh lebih rumit. Ada dua metode yang umum digunakan untuk mengimplementasikan multi *class* SVM dengan pendekatan yaitu metode “*one-against-all*” dan metode “*one-against-one*”.

a. *One-Against-All*

Metode *One-Against-All* mebangun k buah model SVM biner dengan k adalah jumlah kelas. Model SVM ke-m dilatih dengan semua contoh kelas dengan m label positif dan yang lainnya label negatif. Berdasarkan hal tersebut data latih $I(x_1, y_1), \dots, (x_l, y_l)$ dimana $\vec{x}_i \in \mathbb{R}^d$, $i = 1, \dots, l$ dan $y_i \in \{1, 2, \dots, k\}$ merupakan kelas dari x_i , permasalahan tersebut dapat diselesaikan dengan:

$$\min_{w^m, b^m, \xi^m} (w) \frac{1}{2} (w^m)^T w^m + C \sum_{i=1}^l \xi_i^m$$

Dengan $(w^m)^T \phi(x_m) + b^m \geq 1 - \xi_i^m \rightarrow y_i = m \quad (3.17)$


$$(w^m)^T \phi(x_m) + b^m \leq -1 + \xi_i^m \rightarrow y_i \neq m \quad (3.18)$$

$$\xi_i^m \geq 0, \quad i = 1, \dots, l$$

Contoh: terdapat permasalahan klasifikasi dengan 4 buah kelas. Empat buah model SVM biner digunakan untuk pelatihan seperti pada tabel 3.1 dan penggunannya dalam mengklasifikasi data baru dapat dilihat pada gambar 3.4.

Tabel 3.1 Contoh SVM dengan Metode *One-against-all*

| $Y_i = 1$ | $Y_i = -1$ | Hipotesis |
|-----------|---------------|-------------------------|
| Kelas 1 | Bukan Kelas 1 | $f_1(x) = (w_1)x + b_1$ |
| Kelas 2 | Bukan Kelas 2 | $f_2(x) = (w_2)x + b_2$ |
| Kelas 3 | Bukan Kelas 3 | $f_3(x) = (w_3)x + b_3$ |
| Kelas 4 | Bukan Kelas 4 | $f_4(x) = (w_4)x + b_4$ |

(3.20)


Gambar 3.4 Contoh Klasifikasi dengan Metode *One-Against-All*

b. *One-Against-One*

Metode *One-Against-One* membangun $(k(k-1)/2)$ buah model klasifikasi biner (k adalah jumlah kelas). Setiap model klasifikasi dilatih pada data dari dua kelas. Data latih dari kelas ke-m dan ke-n, diselesaikan dengan:

$$\min_{w^{mn}, b^{mn}, \xi^{mn}} \frac{1}{2} (w^{mn})^T w^{mn} + C \sum_{i=1}^l \xi_i^{mn} \quad (3.21)$$

$$\text{Dengan } (w^{mn})^T \phi(x_i) + b^{mn} \geq 1 - \xi_i^{mn} \rightarrow y_i = m \quad (3.22)$$

$$(w^{mn})^T \phi(x_i) + b^{mn} \leq -1 - \xi_i^{mn} \rightarrow y_i \neq n \quad (3.23)$$


$$\xi_i^{mn} \geq 0,$$

Contoh: terdapat permasalahan klasifikasi dengan 4 buah kelas.

Terdapat beberapa metode untuk melakukan pengujian setelah keseluruhan $(k(k-1)/2)$ model klasifikasi selesai dibangun. Salah satunya adalah metode voting.

Tabel 3.2 Contoh SVM biner dengan Metode *One-against-one*

| $Y_i = 1$ | $Y_i = -1$ | Hipotesis |
|-----------|------------|----------------------------------|
| Kelas 1 | Kelas 2 | $f_{12}(x) = (w_{12})x + b_{12}$ |
| Kelas 1 | Kelas 3 | $f_{13}(x) = (w_{13})x + b_{13}$ |
| Kelas 1 | Kelas 4 | $f_{14}(x) = (w_{14})x + b_{14}$ |
| Kelas 2 | Kelas 3 | $f_{23}(x) = (w_{23})x + b_{23}$ |
| Kelas 2 | Kelas 4 | $f_{24}(x) = (w_{24})x + b_{24}$ |
| Kelas 3 | Kelas 4 | $f_{34}(x) = (w_{34})x + b_{34}$ |

(3.24)


Gambar 3.5 Contoh klasifikasi dengan metode *One-against-one*

Misal data x disubtitusikan kedalam fungsi $(w^{mn})^T \phi(x) + b$ kemudahan hasilnya menyatakan x adalah kelas i, maka kelas i terhitung 1 dan ditambahkan lagi ketika ada yang masuk ke kelas tersebut. Metode voting tersebut mengambil jumlah terbanyak dari kelas data x .

3.2. Confusion Matrix

Cara yang paling umum untuk menunjukkan hasil klasifikasi terutama pada data *multiclass* ialah menyajikan dalam bentuk *confusion matrix* atau juga dikenal dengan tabel kontingensi. Misal $x_{r,c}$ dari *confusion matrix* $C \in \mathbb{N}^{l \times l}$ dengan r menunjukkan kelas prediksi dan c menunjukkan kelas yang benar, maka diagonal pada tabel tersebut menunjukkan hasil prediksi yang benar dan yang diluar diagonal merupakan hasil prediksi yang salah.

Tabel 3.4 confusion matrix

| Prediksi (r) | Asli (c) | | | |
|-----------------|----------|----------|-----|----------|
| | kelas 1 | kelas 2 | ... | kelas n |
| kelas 1 | X_{11} | X_{12} | ... | X_{1n} |
| kelas 2 | X_{21} | X_{22} | ... | X_{2n} |
| . | . | . | . | . |
| . | . | . | . | . |
| . | . | . | . | . |
| kelas n | X_{n1} | X_{n2} | ... | X_{nn} |

3.3. ROC (*Receiver Operating Characteristic*) curve

ROC (*Receiver Operating Characteristic*) curve merupakan suatu metode yang dapat digunakan untuk menilai kinerja suatu pengujian (Bolstad,2004). Pengujian tersebut digambarkan dalam suatu kurva dengan axis vertikal merupakan tingkat *true postif* (*sensitivity*), artinya ialah suatu kelas yang diperidiksi masuk ke kelas positif dan hasilnya benar. Label axis horizontal merupakan tingkat *false positif*($1-sensitivity$), artinya ialah kelas data yang diprediksi masuk ke kelas positif dan hasilnya salah. Cara tersebut akan memberikan hasil 100% jika tidak ada yang yang salah.

3.4. DNA dan *Gene Expression*

Material *genetic* yang berisi petunjuk dari suatu organisme dikenal dengan *deoxyribonucleic acid* (DNA). DNA terdiri dari beberapa nukleotida, masing nukleotida itu sendiri terdiri dari 3 komponen: basa, gula, dan pospat. Nukleotida tersebut tergabung dalam rantai panjang. Inti dari dari rantai tersebut adalah gula dan pospat, sementara basa-nya menggantung pada setiap gula. Terdapat 4 basa berbeda yaitu: *adenine*, *cytosine*, *guanine* dan *thymine* yang biasa dikenal dengan huruf masing-masing A, C, G, dan T. Molekul DNA terdiri dari dua rantai polynucleotide komplementer yang disatukan menggunakan ikatan hydrogen. Basa A dan T terikat bersama, seperti C dan G. Dengan cara ini, dapat dikatakan A adalah komplemen dari T, dan C komplemen dari G. Dua untaian gula dan pospat membentuk struktur *double helix*. Untaian DNA tersebut biasanya berisikan jutaan nukleotida.

RNA, *ribonucleic acid*, berbeda dengan DNA dalam beberapa hal. Khususnya pada gula yang *ribose* bukan *deoxyribose* dan basa-nya *uracil* (U) yang menggantikan *thymine*. U komplementer dengan A. Berbeda dengan DNA, molekul-molekul RNA beruntai tunggal dan hanya berisikan 75-5000 nucleotida. Sel mengandung beberapa jenis RNA: *messenger RNA* (mRNA), *transfer RNA* (tRNA) dan *ribosomal RNA* (rRNA).

Gen merupakan suatu *sequence* DNA yang mengkodekan protein. Protein dapat mengendalikan sifat fisik dari sel, misalnya mata atau rambut. Tali DNA mengandung banyak gen yang berbeda. Protein mengurutkan 20 jenis berbeda dari *amino acid*. Setiap *amino acid* di sandikan dengan suatu urutan dari 3 *base* yang disebut dengan *codons*. Terdapat 64 kemungkinan untuk ketiganya (*codons*), ada suatu kelebihan karena beberapa sandi codons berbeda terdapat kesamaan *amino acid*. Ada 3 codons yang tidak disandi ke *amino acid*. Hal tersebut merupakan penanda berhenti.

Proses sintesis protein dari DNA terjadi dalam 2 tahap, yaitu *transcription* dan *translation* yang dikenal dengan *central dogma of*

molecular biology. Tahap pertama, *transcription* adalah transfer informasi dari molekul DNA beruntai ganda ke mRNA beruntai tunggal. *Transcription* dimulai di daerah *sequence* yang dikenal sebagai *promotor sites* dan berakhir di daerah yang dikenal sebagai *situs terminator*. Tahap kedua *translation* ialah proses penerjemahan mRNA menjadi protein. Pada tahap ini digunakan tRNA dan rRNA. Codon AUG menandai lokasi *translation* dapat dimulai. Molekul tRNA melampirkan *amino acid* ke rantai sebagai suatu molekul rRNA yang bergerak sepanjang mRNA. Proses tersebut berlanjut hingga salah satu codon penanda berhenti tercapai.

3.5. Microarray


Microarray telah banyak digunakan pada penelitian biomedis. *Microarray* adalah suatu alat yang dirancang untuk mengukur *expression levels* dari sekian ribu gen dalam sebuah penyakit atau tipe sel.(Bolstad,2004). Biologi molekuler dan biomedis menggunakan *microarray* untuk mengetahui dan meneliti perbedaan penyakit. *Microarray* dapat memeriksa ribuan gen dalam waktu yang sama serta membantu mengidentifikasi gen yang terlihat pada sel yang berbeda dan mencari hubungan antara masing-masing gen.

Kebanyakan sel yang ada dalam tubuh manusia berisikan gen yang sama, akan tetapi tidak semua gen yang terpakai di dalam setiap sel. Ada beberapa gen yang aktif atau muncul ketika dibutuhkan saja. Teknologi *microarray* digunakan untuk mengetahui perbedaan gen yang aktif atau tidak pada suatu sel.

Mencocokkan DNA nukleotida ke gen berbeda yang diletakkan pada satu mikroskop yang disebut *microarray*. mRNA kemudian diekstraksi dari sel yang disintesis ke DNA komplementer dengan *enzyme reverse transcriptase* dan diberikan label dengan tanda yang bercahaya kemudian dihibridisasi, cahaya akan membantu untuk memnunjukkan gen yang aktif pada sel. Gen yang muncul berbeda antara susunan orang sakit dan susunan orang sehat dapat menunjukkan penyebab penyakit.

Microarray DNA Oligonucleotida lebih lanjut dapat menjadi dua subkelompok: long oligonucleotide *arrays*, yang *probenya* terdiri dari 60-mer atau 50-mer sekuens DNA (contoh Illumina Beadarray), dan short oligonucleotide arrays yang menggunakan 25-mer (mis., Affymetrix GeneChip) atau 30-mer dari desain urutan *probe*.

Affymetrix genechip menggunakan teknologi seperti *chip silicon* komputer. Material *silicon affymetrix* dilindungi dengan menutup dan menerapkan *photolithographic process* untuk mengendalikan sintesis oligonukleotida pada permukaan kaca/plastic. Perancangan *probe*, menggunakan 25-mer gen spesifik oligonukleotida, secara lebih khusus, *probe* set dibentuk dengan 11 sampai 20 pasang *probe* berbeda yang digunakan untuk mencocokan gen-gen berbeda. Desain pasangan *probe* yaitu *mismatch* (MM) dan *perfect match*(PM) *probe*. *Probe* MM digunakan untuk mengendalikan ikatan-ikatan non-spesifik selama hibridisasi. Salah satu fitur khusus dari *array GeneChip* adalah bahwa setiap pasangan *probe* terpasang pada lokasi yang telah ditentukan pada permukaan array.



Gambar 3.6 Affymetrix Genechip

Keterangan:

Titik merah = gen tersebut diekspresikan hanya dalam kondisi aerobik

Green spot = gen tersebut diekspresikan hanya dalam kondisi anaerobik

Titik kuning = gen tersebut dinyatakan dalam kedua kondisi

Bintik hitam = tidak ada ekspresi gen dalam kondisi baik

3.6. Preprocessing

Preprocessing merupakan tahap untuk penyesuaian serta konversi data *affybatch* ke dalam bentuk *expression set*. Tidak hanya melakukan konversi data *affybatch*, dalam tahap *preprocessing* dilakukan proses *background correction*, *normalization* dan *summarization*. Istilah *background correction* mengacu pada penyesuaian berbagai macam metode, serta yang harus dilakukan meliput:

1. Memperbaiki *background noise* dan efek pengolahan
2. Menyesuaikan hibridisasi pengikat DNA non-spesifik pada *array*
3. Menyesuaikan estimasi ekspresi sehingga bersekalai tepat atau berhubungan linear

Penting untuk dicatat bahwa definisi tersebut merupakan hal yang umum digunakan. *Background correction* secara umum mengacu pada penegrtian pertama.

Tahap setelah *background correction* yaitu *normalization*. *Normalization* adalah proses penghapusan akhiran non-biologis yang tidak diinginkan diantara chip dalam eksperimen *microarray*. Tahap setelah hal tersebut ialah tahap dilakukan *summarization*, yaitu untuk mengukur *gene expression*. (Bolstad, 2004)

3.7. Filtering

Filtering data *microarray* adalah proses pemilihan subset dari *probe* yang tersedia untuk pengecualian atau penyertaan dalam analisis. Program R dalam penelitian ini menggunakan tambahan *package* genefilter untuk melakukan penyaringan. Fungsi pertama yang digunakan pada tahap *filtering*

pada penelitian ini ialah `nsFilter`, *function* tersebut menyediakan suatu opsi *one-stop shop* (serba ada) untuk berbagai pilihan *filtering* (penghapusan) fitur dari *expression set*. Fitur *filtering* dapat menunjukkan beberapa varian kecil atau ketimpangan data secara konsisten di seluruh sampel, hal ini dapat berguna untuk analisis selanjutnya (Bourgon,2010).

BAB IV

METODE PENELITIAN

4.1.Jenis dan Sumber Data

Jenis data dalam penelitian ini berupa data sekunder yang berasal dari penelitian Finkelstein dengan judul “*Novel mutations target distinct subgroups of medulloblastoma*” tersimpan dalam *database chip microarray* yang terdapat di instansi yang bergerak dibidang genetika atau *database kumpulan data genetik* yaitu NCBI dengan kode akses GSE37418.

4.2.Tempat dan Waktu Penelitian

Penelitian dilakukan di kampus terpadu Universitas Islam Indonesia yang ada di Yogyakarta. Waktu pengambilan data yang dilakukan penulis adalah pada bulan Agustus 2017.


4.3.Variabel Penelitian

Variabel penelitian yang digunakan peneliti ialah sebanyak 54675 yang merupakan kumpulan *probe* dari data *expression set* dari GSE37418 serta 3 variabel tambahan dari *phenotype* data yakni etnis, jenis kelamin dan *subgroup* kanker *medulloblastoma* yang menjadi faktor dalam melakukan klasifikasi.

4.4.Metode Analisis Data

Metode yang digunakan dalam penelitian ialah klasifikasi dengan menggunakan algoritma SVM. *Software* yang digunakan ialah R studio atau Program R dengan R version 3.4.2. Terdapat beberapa metode yang dilakukan untuk implementasi metode statistik SVM dalam data bioinformatika mulai dari pembacaan data oleh program, *Preprocessing*, *filtering* yang kemudian merubah data kedalam bentuk matriks atau tabel.

Langkah atau tahapan yang dilakukan dalam penelitian ini dapat digambarkan dengan gambar berikut:



Gambar 4.1 Flowchart Penelitian

BAB V

PEMBAHASAN


Medulloblastoma terbentuk karena terjadi kesalahan pada fungsi sel yang mengendalikan pertumbuhan dan kematian sel. Alasan hal tersebut terjadi masih belum dipahami, bagaimanapun, para ilmuwan membuat kemajuan signifikan dalam memahami apa yang terjadi di dalam sel-sel yang mengubah sel otak normal menjadi kanker yang tumbuh. Perubahan tersebut teridentifikasi pada gen dan kromosom (sel DNA) yang berperan dalam perkembangan kanker *medulloblastoma*.

Data GSE37418 merupakan kumpulan sampel *gene expression* dari penderita *pediatric medulloblastoma*. 76 data pasien penderita *medulloblastoma* pada sampel memiliki karakteristik yang berbeda-beda seperti etnis, jenis kelamin, dan yang lainnya.

5.1.Deskripsi Data


Gambaran secara umum dari penderita *medulloblastoma* pada penelitian, akan disajikan dengan menggunakan analisis dekriptif. Data GSE37418 terdapat 73 pasien dengan 4 subtipenya yang sama dengan disebutkan Upadhyay dan 3 pasien lain tidak memiliki subtype (*outlier*), oleh karena itu data yang digunakan ialah pasien yang tergolong ke dalam 4 subtipenya yaitu WNT, SHH, *Subgroup 3*, dan *Subgroup 4*.

Gambar 5.1 menunjukkan jika kebanyakan pasien penderita tergolong pada *subgroup 4*, setengah (53%) dari pasien tergolong ke *subtype subgroup 4*, 22% pasien tergolong ke *subgroup 3*, pasien dengan golongan SHH 14% dan 11% pasien tergolong WNT. Perlakuan untuk setiap golongan berbeda-beda dalam proses penyembuhan .




Gambar 5.1 Pie Chart Subtipe *Medulloblastoma*

Pasien berjenis kelamin perempuan lebih banyak ditemukan pada sampel yang ditunjukkan pada gambar 5.2 dibandingkan dengan pasien berjenis kelamin laki-laki. Kebanyakan pasien berumur 9 tahun, hal tersebut seusai dengan artikel yang dituliskan ABTA, penderita *medulloblastoma* lebih cendrung pada anak dibawah 10 tahun.



Gambar 5.2. Jenis Kelamin



Gambar 5.3. Etnis Pasien

Gambar 5.3 diatas menunjukkan jumlah masing-masing etnis pasien. Etnis kulit putih paling banyak yaitu 58% dalam sampel, hal tersebut dikarenakan pengambilan sampel dilakukan di Amerika yang kebanyakan penduduknya merupakan kulit putih. 18% penderita berasal dari etnis hispanik yang merupakan etnis terbesar di Amerika, kemudian Asia 5% pasien. 5% pasien masing masing dari etnis Indian dan Black, 4% pasien other dan 1% pasien dari etnis pasiific islander.

5.2. Pengolahan Data *Bioinformatics*

Data *bioinformatics* dalam pengolahannya menggunakan R memerlukan *package* tambahan dari *biocondutor*. Data yang dapat diolah oleh R bersifat vektor, matrix, data *frame*, atau yang lainnya, akan tetapi R memerlukan tambahan *package* untuk membaca data *affymetrix* atau *expression set*. Proses mendapatkan data bioinformatics pada R diperlukan *package* *GEOquery* dan untuk membaca data tersebut dipelukan *package* *affy*.

Data yang didapat dengan *package GEOquery* masih dalam bentuk *affymetrix*, data tersebut dijabarkan agar terdeteksi dalam program R dengan menggunakan function `ReadAffy()`. Data *affymetrix* menyimpan banyak informasi yaitu *expression set* dari pasien dan *phenotype*-nya. Hal tersebut didapat dengan query seperti pada lampiran untuk mendapatkan hal seperti berikut:

Tabel 5.1 *pheno data*

| title | ... | channel_c | source_na | organism_ch1 | characteristics_ch1 | characteristics_ch1.1 | characteristics_ch1.2 | characteristics_ch1.3 | characteristics_ch1.4 | ... | treatment_protocol_ch1 |
|-----------|-----|-----------|-----------|-----------------|---------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----|------------------------|
| GSM918578 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 8yrs 4mos | Sex: Male | ethnic: White | ... | m stage: MB-CL |
| GSM918579 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 8yrs 3mos | Sex: Male | ethnic: Black | ... | m stage: MB-CL |
| GSM918580 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: WNT | age: 6yrs 6mos | Sex: Female | ethnic: White | ... | m stage: MB-CL |
| GSM918581 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 9yrs 2mos | Sex: Male | ethnic: White | ... | m stage: MB-CL |
| GSM918582 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: SHH | age: 8yrs 6mos | Sex: Male | ethnic: Asian | ... | m stage: MB-DN |
| GSM918583 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 8yrs 1mos | Sex: Female | ethnic: White | ... | m stage: MB-CL |
| GSM918584 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 8yrs 8mos | Sex: Male | ethnic: White | ... | m stage: MB-CL |
| GSM918585 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 9yrs 0mos | Sex: Female | ethnic: White | ... | m stage: MB-CL |
| GSM918586 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G3 | age: 10yrs 10mos | Sex: Male | ethnic: White | ... | m stage: MB-AN |
| GSM918587 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G3 | age: 9yrs 8mos | Sex: Male | ethnic: other | ... | m stage: MB-CL |
| GSM918588 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G3 | age: 9yrs 11mos | Sex: Male | ethnic: White | ... | m stage: MB-CL |
| GSM918589 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G3 | age: 5yrs 2mos | Sex: Male | ethnic: Hispanic | ... | m stage: MB-CL |
| GSM918590 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 8yrs 9mos | Sex: Male | ethnic: Hispanic | ... | m stage: MB-AN |
| GSM918591 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 9yrs 4mos | Sex: Male | ethnic: White | ... | m stage: MB-CL |
| GSM918592 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 14yrs 8mos | Sex: Male | ethnic: Hispanic | ... | m stage: MB-CL |
| GSM918593 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: WNT | age: 9yrs 1mos | Sex: Female | ethnic: White | ... | m stage: MB-CL |
| GSM918594 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G3 | age: 4yrs 8mos | Sex: Male | ethnic: White | ... | m stage: MB-AN |
| GSM918595 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 7yrs 9mos | Sex: Female | ethnic: Asian Indian | ... | m stage: MB-CL |
| GSM918596 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 3yrs 4mos | Sex: Female | ethnic: Asian | ... | m stage: MB-CL |
| GSM918597 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 5yrs 5mos | Sex: Male | ethnic: White | ... | m stage: MB-CL |
| GSM918598 | ... | RNA | 1 | Medulloblastoma | Homo sapiens | subgroup: G4 | age: 11yrs 9mos | Sex: Male | ethnic: White | ... | m stage: MB-CL |

Dari tabel diatas dapat dilihat ID dari pasien diberikan dengan kode GSM yang mencakup *subtype medulloblastoma* yang diderita, status publikasi data, organisme data, hingga lokasi data diambil. Keseluruhan isi pada tabel 5.1 terdapat 73 pasien dengan 37 variabel. Tahapan di atas program R masih terbatas dalam mengakses data karena data masih berbentuk *Affybatch*.

5.2.1. Preprocessing

Tahap ini memerlukan function `threestep()` dari *package affyPLM*. Function `threestep()` selain melakukan konversi data *affybatch* dalam function tersebut dilakukan proses *background correction, normalization* dan *summarization*.

Metode *background correction* dalam penelitian ini menggunakan RMA.2. RMA merupakan singkatan dari *Robust multi-*

array average, metode *background correction* RMA bertujuan untuk mengetahui distribusi intesitas *probe*. Tahapan setelah *background correction* ialah melakukan *normalization* dengan metode *quantile* unutuk menyetarakan data. Tahap setelah dilakukan *background correction* dan *normalizatition* dilanjutkan ke tahap *summarization* dengan metode *median.polish*.

5.2.2. Filtering

Filtering data *microarray* adalah proses pemilihan subset dari *probe* yang tersedia untuk pengecualian atau penyertaan dalam analisis. Program R menggunakan tambahan *package* *genefilter* untuk melakukan penyaringan. Fungsi pertama yang digunakan pada tahap *filtering* pada penelitian ini ialah *nsFilter*, function ini menyediakan suatu opsi *one-stop shop* (serba ada) untuk berbagai pilihan *filtering* (penghapusan) fitur dari *expression set*. Fitur *filtering* dapat menunjukkan beberapa varian kecil atau ketimpangan data secara konsisten di seluruh sampel, hal ini dapat berguna untuk analisis selanjutnya (Bourgon,2010).

Fungsi *nsFilter* merupakan salah stu fungsi yang digunakan dalam penelitian, Fungsi tersebut menunjukkan jika dalam *filtering* digunakan *entrez* (database yang menyimpan terkait gen). Fungsi pada lampiran.7 berguna untuk menghapus *dupEntrez* yang artinya mengeluarkan variable dengan nilai *IQR(interquartile range)* tertinggi. Data yang didapat setelah prooses tersebut berdimensi 10251x 73, untuk mereduksi dimensi data dilakukan metode *filtering* kembali dengan menggunakan function *genefilter*.

Klasifikasi data pada penelitian ini diasumsikan berdistribusi normal yang melakukan *filtering* dengan fungsi Anova dengan nilai signifikansi 0.001. Dimensi data yang didapat setelah proses *filtering* menggunakan *genefilter* menjadi 5226x73.

5.2.3. Mengolah data

Tahap *Preprocessing* dan *filtering* yang telah dijabarkan menghasilkan suatu data *expressionset*. Tahap selanjutnya yaitu merubah data *expression set* menjadi matrix atau *data frame* agar dapat diolah dengan menggunakan *package* yang umum dari R. fungsi yang digunakan dalam penelitian ini yaitu `exprs` dari *package biobase* dari Bioconductor.

Function exprs berfungsi untuk merubah data *expression set* menjadi bentuk matrix. Data yang berebentuk matrix atau data frame merupakan syarat untuk mengolah data dengan *package e1071*, dengan menggunakan *e1071* akan dilakukan klasifikasi SVM.

5.3. Klasifikasi Data Gen

Klasifikasi data pada umumnya menggunakan 2 data yakni data latih dan data uji. Suatu kumpulan data dibagi menjadi 2 pada kasus ini dengan porsi data latih 70% dan data uji 30%. Masing-masing data dari data latih dan data uji diambil secara random dengan mengutamakan semua klasifikasi termasuk kedalam 2 data tersebut. Diketahui data *medulloblastoma* dari GSE37418 terdapat 4 kelas yakni SHH,WNT, *subgroup 3* dan *subgroup 4* seperti gambar 5.1, data GSE37418 terdiri dari 73 sample yang digunakan, maka 58(80%) sampel yang diambil harus terdapat 4 kelas dan 15(20%) sampel data uji juga harus terdiri dari 4 kelas dari klasifikasi medulloblastoma.

Pengaplikasian SVM dengan menggunakan *package e1071* dapat dilakukan *tune* untuk mengetahui nilai *cost* terbaik untuk model. Semakin kecil nilai *cost* maka akan semakin baik hasilnya. *Cost* yang digunakan benilai antara 0.1, 0.01, 0.001, 1, 10, dan 100. Berdasarkan nilai-nilai tersebut didapat *cost* terbaik untuk data ialah 0.1(lampiran 13), oleh karena itu untuk membangun model digunakan *cost* 0.1.

Model yang dihasilkan dengan menggunakan data latih selanjutnya dilihat hasil dari klasifikasi terhadap data tersebut dan tidak terdapat

kesalahan seperti tabel 5.2 berikut yang menunjukkan hasil klasifikasi data latih.

5.3.1. *Confusion matrix*

Efektifitas suatu klasifikasi diuji dengan suatu pengukuran evaluasi. Pengukuran tersebut didapatkan dalam *confusion matrix* (Chin, 2010).

Tabel 5.2 *Confusion Matrix Data Latih*

| Predictions | Data latih | | | |
|---------------|-----------------|-----------------|------------------|------------------|
| | subgroup: G3 | subgroup: G4 | subgroup: SHH | subgroup: WNT |
| subgroup: G3 | 11 | 0 | 0 | 0 |
| subgroup: G4 | 0 | 27 | 0 | 0 |
| subgroup: SHH | 0 | 0 | 7 | 0 |
| subgroup: WNT | 0 | 0 | 0 | 5 |

Setiap prediksi berdasarkan model pada data latih menghasilkan klasifikasi yang sesuai dengan kelasnya, setiap *subgroup* tidak masuk ke klasifikasi yang salah. Hasil tersebut didapatkan karena data yang digunakan untuk membangun model SVM sama dengan data yang diujikan. Berdasarkan hasil tersebut data uji digunakan untuk mengetahui model yang dibangun mampu memprediksi data yang baru. Data uji diasumsikan sebagai data yang baru dan data uji tidak digunakan dalam membagun model SVM. Prediksi yang didapat dengan data uji ditunjukkan oleh tabel 5.3.

Tabel 5.3 *Confusion matrix Data Uji*

| Predictions | Data uji | | | |
|---------------|-----------------|-----------------|------------------|------------------|
| | subgroup: G3 | subgroup: G4 | subgroup: SHH | subgroup: WNT |
| subgroup: G3 | 4 | 0 | 0 | 0 |
| subgroup: G4 | 1 | 12 | 0 | 0 |
| subgroup: SHH | 0 | 0 | 3 | 0 |
| subgroup: WNT | 0 | 0 | 0 | 3 |

Data uji menunjukkan jika model yang dibangun memiliki akurasi yang bagus yakni 95,6%. *Confusion matrix* data uji dari 15 sampel terdapat 1 kesalahan yaitu pasien yang diprediksi klasifikasi *subgroup G4* pada kenyataanya pasien tersebut merupakan klasifikasi *subgroup G3*. Hasil dari model berdasarkan *confusion matrix* memiliki hasil yang bagus, akan tetapi untuk menguji validasi lebih lanjut digunakan ROC.

5.3.2. ROC curve

Akurasi dari model sebelumnya menggunakan data uji mendapatkan nilai akurasi 95% dan hasil ini akan ditinjau lagi dengan melihat *area under ROC curve* (AUC). Metode AUC pada awalnya digunakan untuk memprediksi sinyal dan digunakan untuk membuat keputusan dalam bidang medis.

Nilai *multi-class* AUC ialah 0.98, nilai tersebut dapat dikatakan tinggi karena nilai maksimumnya 1. Nilai akurasi akurasi model didapat dari *confusion matrix* 0.95(95%) dan nilai *multi-class* AUC 0.98. Nilai AUC yang tinggi menunjukkan jika model yang diperoleh baik karena nilai AUC menunjukkan akurasi prediksi dari model.

5.4. Model Klasifikasi

Hasil klasifikasi pasien *medulloblastoma* pada data GSE3418 memberikan bentuk dengan nilai AUC %. Pada data tersebut diketahui setelah melakukan *filtering* didapatkan 5226 *probe* yang menjadi variabel pada penelitian dan ditambahkan 3 variabel karakteristik dari sampel yakni jenis kelamin, etnis, dan kelas pasien. Berdasarkan model, berikut bobot 10 variabel dari 5229 variabel yang ditunjukkan (\vec{w}).

Tabel 5.5 Bobot *Probe ID*

| <i>probe id</i> | w |
|-----------------|-------------|
| 201049_s_at | 0.009322832 |
| 200763_s_at | 0.009145843 |
| 200819_s_at | 0.009108242 |
| 201665_at | 0.009061992 |
| 200062_s_at | 0.009028423 |
| 200013_at | 0.008993589 |
| 215963_at | 0.008993333 |
| 208645_s_at | 0.008926398 |
| 208692_at | 0.008914243 |
| 200010_at | 0.008872732 |

Tabel 5.5 menunjukkan bobot dari *probe*, bobot tertinggi ialah pada *probe id* 201049_s_at, *probe id* dapat menunjukkan gen name dan ontology dari gen tersebut. Pada kasus ini diambil 10 *probe* dengan nilai bobot yang tinggi, setiap *probe* tersusun dari bobot yang tinggi ke bobot yang rendah, dari 10 *probe* tersebut didapatkan informasi seperti pada tabel 5.5.

Tabel 5.5 menunjukkan nama gen dari *probe* tersebut berasal serta *gen ontology*-nya. *Gene ontology* merupakan kerangka untuk model biologi. *Gene Ontology* didefinisikan sebagai konsep atau kelas yang digunakan untuk menggambarkan fungsi gen serta hubungan antar konsepnya. Terdapat 3 fungsi yaitu BP(*biological process*), MF(*molecular function*), dan CC (*Celullar Component*).

Tabel 5.5 Tabel *Ontology*

| PROBEID | SYMBOL | GENENAME | ENTREZID | ONTOLOGY |
|-------------|--------|--|----------|----------|
| 201049_s_at | RPS18 | ribosomal protein S18 | 6222 | BP |
| 201049_s_at | RPS18 | ribosomal protein S18 | 6222 | CC |
| 201049_s_at | RPS18 | ribosomal protein S18 | 6222 | MF |
| 200763_s_at | RPLP1 | ribosomal protein lateral stalk subunit P1 | 6176 | BP |
| 200763_s_at | RPLP1 | ribosomal protein lateral stalk subunit P1 | 6176 | CC |
| 200763_s_at | RPLP1 | ribosomal protein lateral stalk subunit P1 | 6176 | MF |

| PROBEID | SYMBOL | GENENAME | ENTREZID | ONTOLOGY |
|-------------|--------|-----------------------|----------|----------|
| 200819_s_at | RPS15 | ribosomal protein S15 | 6209 | BP |
| 200819_s_at | RPS15 | ribosomal protein S15 | 6209 | CC |
| 200819_s_at | RPS15 | ribosomal protein S15 | 6209 | MF |
| 201665_x_at | RPS17 | ribosomal protein S17 | 6218 | BP |
| 201665_x_at | RPS17 | ribosomal protein S17 | 6218 | CC |
| 201665_x_at | RPS17 | ribosomal protein S17 | 6218 | MF |
| 200062_s_at | RPL30 | ribosomal protein L30 | 6156 | BP |
| 200062_s_at | RPL30 | ribosomal protein L30 | 6156 | CC |
| 200062_s_at | RPL30 | ribosomal protein L30 | 6156 | MF |
| 200013_at | RPL24 | ribosomal protein L24 | 6152 | BP |
| 200013_at | RPL24 | ribosomal protein L24 | 6152 | CC |
| 200013_at | RPL24 | ribosomal protein L24 | 6152 | MF |
| 215963_x_at | RPL3 | ribosomal protein L3 | 6122 | BP |
| 215963_x_at | RPL3 | ribosomal protein L3 | 6122 | CC |
| 215963_x_at | RPL3 | ribosomal protein L3 | 6122 | MF |
| 208645_s_at | RPS14 | ribosomal protein S14 | 6208 | BP |
| 208645_s_at | RPS14 | ribosomal protein S14 | 6208 | CC |
| 208645_s_at | RPS14 | ribosomal protein S14 | 6208 | MF |
| 208692_at | RPS3 | ribosomal protein S3 | 6188 | BP |
| 208692_at | RPS3 | ribosomal protein S3 | 6188 | CC |
| 208692_at | RPS3 | ribosomal protein S3 | 6188 | MF |
| 200010_at | RPL11 | ribosomal protein L11 | 6135 | BP |
| 200010_at | RPL11 | ribosomal protein L11 | 6135 | CC |
| 200010_at | RPL11 | ribosomal protein L11 | 6135 | MF |

Tabel diatas menunjukkan jika *probe* berasal dari gen ribosomal protein serta termasuk kedalam ketiga fungsi yang ada dalam fungsi *gene ontology*. Merujuk pada situs NCBI, setiap *probe* memiliki pengaruh yang berbeda. Keterangan terkait peran dan fungsi setiap *probe* disajikan pada tabel 5.6. Tabel 5.6 memnunjukkan 10 *probe* yang memiliki bobot tertinggi merupakan protein yang terletak pada sitoplasma. *Probe* 200819_s_at pernah ditemukan aktif pada berbagai tumor seperti insulinomas, kanker kerongkongan, dan kanker usus besar, *probe* tersebut merupakan salah 1 probe yang memiliki bobot tinggi pada penyakit *medulloblastoma*.

Tabel 5.6 Keterangan *Probe ID*

| No | <i>Probe ID</i> | Simbol | Keterangan |
|----|-----------------|--------|--|
| 1 | 201049_s_at | RPS18 | Gen ini mengkodekan protein ribosom yang merupakan komponen subunit 40S. Protein tersebut termasuk dalam famili protein ribosom S13P. Terletak di sitoplasma. Produk gen E. coli ortholog (protein ribosom S13) terlibat dalam pengikatan fMet-tRNA, dan inisiasi penerjemahan. |
| 2 | 200763_s_at | RPLP1 | Gen ini mengkodekan fosfoprotein ribosom yang merupakan komponen subunit 60S. Protein yang merupakan ekuivalen fungsional protein ribosom E. coli L7 / L12 termasuk dalam protein protein ribosom L12P. hal ini memainkan peran penting dalam tahap perpanjangan sintesis protein. |
| 3 | 200819_s_at | RPS15 | Gen ini mengkodekan protein ribosom yang merupakan komponen subunit 40S. Protein tersebut termasuk dalam famili protein ribosom S19P. Terletak di sitoplasma. Gen ini telah ditemukan aktif di berbagai tumor seperti insulinomas, kanker kerongkongan, dan kanker usus besar |
| 4 | 201665_x_at | RPS17 | Gen ini mengkodekan protein ribosom yang merupakan komponen subunit 40S. Protein tersebut termasuk dalam famili S17E protein ribosom dan terletak di sitoplasma. Mutasi pada gen ini menyebabkan anemia Diamond-Blackfan 4. |

| No | Probe ID | Simbol | Keterangan |
|----|-------------|--------|--|
| 5 | 200062_s_at | RPL30 | Gen ini mengkodekan protein ribosom yang merupakan komponen subunit 60S. Protein tersebut termasuk dalam famili protein ribosom L30E. Terletak di sitoplasma. Gen ini ditranskripsikan dengan gen RNA nukleolar U72 kecil, yang terletak pada intron keempatnya. |
| 6 | 200013_at | RPL24 | Protein tersebut termasuk dalam famili protein ribosom L24E. Terletak di sitoplasma. Gen ini telah disebut sebagai protein ribosom L30 karena protein yang dikodekan memiliki identitas asam amino dengan protein ribosom L30 dari <i>S. cerevisiae</i> ; Namun, nama resminya adalah protein ribosom L24. |
| 7 | 215963_x_at | RPL3 | Protein tersebut termasuk dalam famili protein ribosom L3P dan terletak di sitoplasma. Gen ini ditranskripsikan dengan beberapa gen RNA nukleolar kecil, yang terletak di beberapa intron gen ini. |
| 8 | 208645_s_at | RPS14 | Pada sel ovarium hamster Cina, mutasi pada gen ini dapat menyebabkan resistensi terhadap <i>emetine</i> suatu inhibitor sintesis protein. |

| No | Probe ID | Simbol | Keterangan |
|----|-----------|--------|--|
| 9 | 208692_at | RPS3 | Studi tentang protein ini pada tikus telah menunjukkan bahwa protein ini memiliki peran ekstrrabosom sebagai endonuklease yang terlibat dalam perbaikan kerusakan DNA akibat sinar UV. Protein ini tampaknya terletak di sitoplasma dan nukleus tetapi tidak di dalam nukleolus. |
| 10 | 200010_at | RPL11 | Protein ini termasuk dalam famili protein ribosom L5P. Terletak di sitoplasma. Protein ini berasosiasi dengan rRNA 5S atau varian transkrip yang disambung yang mengkodekan isoform yang berbeda telah dapat ditemukan untuk gen ini. |

BAB VI

KESIMPULAN DAN SARAN

6.1. Kesimpulan

Berdasarkan hasil penelitian didapatkan kesimpulan:

1. Data bioinformatika merupakan data biologi yang disajikan dalam bentuk *gene expression* yang disimpan dalam *microarray*. Data tersebut diolah dengan tahapan pembacaan data yang kemudian dilakukan *preprocessing*. Tahap *preprocessing* memiliki 3 proses yaitu *background correction* dengan metode RMA, *normalization* dengan metode quantile, *summarization* dengan metode median polish. Hasil yang didapatkan setelah tahap tersebut ialah data *expression set*. Berdasarkan data tersebut dilakukan proses *filtering* untuk menyaring data. Tahap filtering dilakukan 2 kali yaitu dengan nsFilter yang mengeluarkan variabel dengan nilai IQR(*interquartile range*) dan genefilter yang menyeleksi probe berdasarkan ANOVA dengan nilai signifikansi 0,001. Tahap setelah itu adalah merubah data kedalam bentuk matriks yang kemudian dilakukan analisis SVM.
2. Hasil klasifikasi pada data uji menunjukkan ketepatan prediksi 95% serta didukung dengan nilai AUC *multiclass* 98%. Nilai akurasi yang tinggi menunjukkan model SVM yang terbentuk dapat memprediksi dengan baik.
3. Klasifikasi SVM prinsipnya dibuat untuk mengklasifikasikan data berdasarkan garis hyperplane. Garis tersebut memisahkan kelas data, dan memiliki bobot (w) yang memberikan jarak antara kelas satu dengan kelas lainnya. Data GSE37418 memiliki variabel yang banyak, dalam pembentukan model digunakan 10 variabel saja. 10 variabel tersebut memiliki nilai bobot (w) tertinggi (Tabel 5.4). Tabel 5.6 ditunjukkan bahwa setiap probe set memiliki peran dan *probe* set 200819 s_at merupakan gen yang aktif pada berbagai tumor seperti insulinomas, kanker kerongkongan, dan kanker usus besar, serta pada *probe* 201665 x_at dapat menyebabkan anemia Diamond-Blackfan 4 jika terjadi mutasi. Gen-gen yang memiliki bobot tinggi pada *medulloblastoma* merupakan gen yang juga aktif pada penyakit lain.

6.2. Saran

1. Hasil klasifikasi SVM telah menunjukkan akurasi yang tinggi pada penelitian ini. Model SVM yang terbentuk memberikan bobot pada setiap varibelnya (*probe*), terdapat nilai bobot yang tinggi pada *probe* tabel 5.6 yang dapat menjadi target dalam melakukan treatmen pada pasien.
2. Guna mendapatkan hasil yang lebih baik pada penelitian selanjutnya, perlu dialakukan uji normalitas pada sampel ketika melakukan filtering.

DAFTAR PUSTAKA

- ABTA. 2015. *Medulloblastoma*. http://www.abta.org/secure/_medulloblastoma-brochure.pdf diakses pada 10 Oktober 2017.
- Alshamlan, Hala M., Badr, Ghada H. dan Alohal, Yousef. 2013. *A Study of Cancer Microarray Gene Expression Profile: Objectives and Approaches*. London, U.K. Proceeding of the World Congress on Engineering 2013 Vol II. ISBN: 978-988-19252-8-2.
- Anonim, “Big Data”. <https://www.ibm.com/big-data/us/en/> diakses pada 14 Februari 2017
- Anonim, “GenBank”, <https://www.ncbi.nlm.nih.gov/genbank/statistics/> diakses pada 14 Februari 2017
- Anonim, “Microarray”, diakses dari <https://www.ncbi.nlm.nih.gov/probe/docs/techmicroarray/> pada 14 Februari 2017
- Aprijani, Dwi Astuti dan Elfaizi , M. Abdushhomad, 2004, “Bioinformatika: Perkembangan, Disiplin Ilmu dan Penerapannya di Indonesia”, diakses dari <ftp://202.125.94.81/pub/linux/docs/v06/Kuliah/SistemOperasi/2003/50/Bioinformatika.pdf> pada 14 februari 2017.
- Attwood, T.K. dan Parry-Smith, D.J. (1999), Introduction to Bioinformatics, Harlow: Pearson Education.
- Bolstad M, Benjamin. 2004. “*Low-level Analysis of High-density Oligonucleotide Array Data: Background, Normalization and Summarization*”. <https://pdfs.semanticscholar.org/a0e2/34479d90b24f59791b3d52bbf2cb27d90acf.pdf> diakses pada 3 November 2017.
- Brown , Michael P. S. William Noble Grundy, David Lin, Nello Cristianini, Charles Walsh Sugnet, Terrence S. Furey, Manuel Ares, Jr., dan David Haussler. 1999. “*Knowledge-based analysis of microarray gene expression data by using support vector machines*”. Proc Natl Acad Sci U S A. **97(1)**:262-7.
- Buhler, Lukas K & Rashidi, Hooman H., 2005, “*Bioinformatics Basic: Applications in biological science and medicine*” , Boca Raton, FL. CRC Press.

- Carrillo ,Henry . Brodersen , Kay H.dan Castellanos, Jose A. 2014. “*Probabilistic performance evaluation for multiclass classification using the posterior balanced accuracy.* https://kaybrodersen.github.io/publications/Carrillo_2014_ROBOT2013.pdf diakses pada 14 desember 2017.
- Furey, Terrence S., Duffy, Nigel., Cristianini Nello., Bednarski, David., Schummer, Michel. dan Haussler, David. *Support Vector Machine Classification and Validation of Cancer Tissue Samples Using Microarray Expression Data.* Bioinformatics. 2000, **16(10)**:906-914.
- Hsu, Chih-Wei, Chih-Chung Chang. dan Chih-Jen Lin.. 2010. *A Practical Guide to Support vector Classification.* Taiwan: Department of Computer Science National Taiwan University.
- Hsu, Chih-Wei, Chih-Jen Lin. *A Comparison of Methods for Multi-class Support Vector Machines.* IEEE Transactions on Neural Networks, **13(2)**:415-425.2002.
- Kilpelainen, Sini. 2008. *Microarray Data Analysis of Dyslexia Candidate Genes.* <http://www2.math.su.se/matstat/reports/seriec/2008/rep1/report.pdf> diakses pada 3 November 2017.
- Lesk, Arthur M. , “*Bioinfomatics*” <https://www.britannica.com/science/bioinformatics> diakses pada 3 Juni 2017.
- Luo,Yiqiang.2007. *Comparison Between Affymetrix And Illumina Gene Expression Microarray Platforms.* Thesis. McMaster University.
- Milgram , Johnathan . 2006. “*One Against One*” or “*One Against All*”: Which *One is Better for Handwriting Recognition with SVMs?*. <https://hal.archives-ouvertes.fr/inria-00103955/document> diakses pada 3 November 2017
- Mohammed,Mohssen, Khan, Muhammad Badruddin , dan Bashier, Ehab Bashier Mohammed. 2017. *Machine Learning: Algorithms and Applications.* CRC press. New York.
- Northcot. Paul .A, Andrey Korshunov, Hendrik Witt, Thomas Hielscher, Charles G. Eberhart, Stephen Mack, Eric Bouffet, Steven C. Clifford, Cynthia E. Hawkins, Pim French, James T. Rutka, Stefan Pfister, dan Michael D. Taylor. 2011. *Medulloblastoma comprises four distinct molecular variants* 2011. JOURNAL OF CLINICAL ONCOLOGY. **10(11)**: 1400, 1415, dan 1424

- Nugroho, Anto Satriyo, Arief Budi Witarto dan Dwi Handoko. 2003. *Suport Vector Machines : Teori Aplikasinya dalam Bioinformatika*. ilmukomputer.com.
- Rossi A., Caracciolo V., Russo G, dan Reiss K, Giordano A. 2008. *Medulloblastoma: from molecular pathology to therapy*. Clin Cancer Res. **14(4)**:971–976
- Trimarsanto, Hidayat. Bioinformatika. Diakses dari <http://www.bioinformatika.org/Beranda> pada 14 Februari 2017.
- Upadhay, Amit Kumar. 2014. *Pediatric Medulloblastoma: Molecular biology, correlation with histopathological and clinical outcome*. <http://dspace.sctimst.ac.in/jspui/bitstream/123456789/2637/1/6307.pdf> diakses pada 24 Oktober 2017.
- Sembiring, Krisantus. 2007. *Tutorial SVM Bahasa Indonesia*. Bandung : ITB <http://sutikno.blog.undip.ac.id/files/2011/11/tutorial-svm-bahasa-indonesia-oleh-krisantus.pdf> diakses pada 20 Desember 2017.
- Yi Liu dan Y.F. Zheng. *One-against-all multi-class svm classification using reliability measures*. In Neural Networks, 2005. IJCNN '05. Proceedings. 2005 IEEE International Joint Conference. **2(31)**:849 – 854.

LAMPIRAN

Lampiran 1 Package Bioinformatics

```
> Usepackages <- function(x) {  
+   for( i in x ) {  
+     # require returns TRUE invisibly if it was able  
to load package  
+     if( ! require( i , character.only = TRUE ) ) {  
+       # If package was not able to be loaded then  
re-install  
+       install.packages( i , dependencies = TRUE )  
+       source('http://bioconductor.org/biocLite.R')  
+       biocLite(i)  
+       # Load package after installing  
+       require( i , character.only = TRUE ) } } }  
> package <- c('affy','GEOquery','Biobase',  
+           'simpleaffy','affyPLM','hgu133plus2.db',  
+           '  
+           'hgu133acdf','hgu133a.db','hgu133plus2cdf',  
+           'genefilter','AnnotationDbi')  
> Usepackages (package)
```

Lampiran 2 Input data

```
> setwd("D:/Medulloblastoma_brain_tumor")  
> #input data  
> gse<- list.celfiles("D:/Medulloblastoma_brain_tumor/  
GSE37418_RAW", full.names=T)  
> gse37418<- ReadAffy(filenames=gse)  
> #get pheno data
```

```

> gset <- getGEO(GEO="GSE37418")

> data.gse <- exprs(gset[[1]])

> pheno <- pData(phenoData(gset[[1]]))

> #save pheno in txt file

> WriteMatrixToFile <- function(tmpMatrix, tmpFileName,
  blnRowNames, blnColNames)

+ { output <- file(tmpFileName, "at")

+   utils::write.table(tmpMatrix, output, sep = "\t", quote
= FALSE,

+                     row.names = blnRowNames, col.names =
  blnColNames)

+   close(output) }

> WriteMatrixToFile(tmpMatrix=pheno,
  tmpFileName="phenol.txt",

+                     blnRowNames=TRUE, blnColNames=TRUE)

> ## PHENO DATA

> p1 <- read.AnnotatedDataFrame(file.path("phenol.txt"),
  sep= "\t", header = TRUE)

> phenoData(gse37418) <- p1

> pheno = pData(phenoData(gse37418))

> varMetadata(p1)

```

Lampiran 3 *subset sample*

```

> newgse37418<-get.array.subset.affybatch(gse37418,
  "characteristics_ch1", c("subgroup: SHH", "subgroup: G4",
  "subgroup: G3", "subgroup: WNT"))

> #selected pheno sample to use\\

> selected<- c('GSM918578', 'GSM918579', 'GSM918580',
  'GSM918581', 'GSM918582', 'GSM918583', 'GSM918584',
  'GSM918585', 'GSM918586', 'GSM918587', 'GSM918588',
  'GSM918589', 'GSM918590', 'GSM918591', 'GSM918592',
  'GSM918593', 'GSM918594', 'GSM918595', 'GSM918596',

```

```

'GSM918597', 'GSM918598', 'GSM918599', 'GSM918600',
'GSM918601', 'GSM918602', 'GSM918603', 'GSM918604',
'GSM918605', 'GSM918606', 'GSM918607', 'GSM918608',
'GSM918609', 'GSM918610', 'GSM918611', 'GSM918612',
'GSM918613', 'GSM918614', 'GSM918615', 'GSM918616',
'GSM918617', 'GSM918619', 'GSM918620', 'GSM918621',
'GSM918622', 'GSM918623', 'GSM918624', 'GSM918625',
'GSM918626', 'GSM918627', 'GSM918629', 'GSM918630',
'GSM918631', 'GSM918632', 'GSM918633', 'GSM918634',
'GSM918635', 'GSM918636', 'GSM918637', 'GSM918638',
'GSM918639', 'GSM918640', 'GSM918641', 'GSM918642',
'GSM918643', 'GSM918645', 'GSM918646', 'GSM918647',
'GSM918648', 'GSM918649', 'GSM918650', 'GSM918651',
'GSM918652', 'GSM918653')

```

```

> p1<-p1[selected,]

```

```

> phenoData(newgse37418) <- p1

```

```

> pheno = pData(phenoData(newgse37418))

```

Lampiran 4 Piechart

```

> des <-table(pheno$characteristics_ch1)

```

```

> percent <- round(des/sum(des)*100)

```

```

> des <- as.data.frame(des)

```

```

> lbls <- paste(des$Var1,'-',percent, '%', sep='')

```

```

> pie(des$Freq, label= lbls, col=
c('green','blue','orange','red'))

```

Lampiran 5 Barplot gender

```

> des2 <-table(pheno$characteristics_ch1.2)

```

```

> des2 <- as.data.frame(des2)

```

```

> barplot(des2$Freq, xlab= 'Gender',ylab='Pasien',
names.arg= c("male","female"))

```

Lampiran 6 ethnic

```

> des3 <-table(pheno$characteristics_ch1.3)

```

```

> percent3 <- round(des3/sum(des3)*100)

```

```

> des3 <- as.data.frame(des3)

```

```
> lbls3 <- paste(des3$Var1, '-', percent3, '%', sep=' ')
> pie(des3$Freq, label= lbls3, col= c(7,2,1,4,6,5,'white'))
```

Lampiran 7 Preprocessing data

```
> rma_data<- threestep(newgse37418, background.method =
  "RMA.2", normalize.method="quantile",
+                               summary.method="median.polish")

> dim(rma_data)

Features   Samples
54675       73
```

Lampiran 8 Filtering

```
> filter <- nsFilter(rma_data, require.entrez =T,
remove.dupEntrez = T, var.cutoff = 0.5, feature.exclude =
"^-AFFX")

> log <-filter$filter.log

> eset <- filter$eset

> featureNames(eset) <- make.names(featureNames(eset))

> View(eset)

> dim(eset)

Features   Samples
10251       73

> f1 <- Anova(eset$characteristics_ch1, p=0.001)

> flist <- filterfun(f1)

> ffilter<- genefilter(exprs(eset), flist )

> summary(ffilter)

Mode      FALSE      TRUE
logical    5025     5226

> esetf<- eset[ffilter,]

> featureNames(esetf) <- make.names(featureNames(esetf))
```

```
> View(esetf)
> dim(esetf)
Features Samples
5226      73
```

Lampiran 9 *Make ExpressionSet*

```
> exp = exprs(esetf)
> as(esetf, "ExpressionSet")
ExpressionSet (storageMode: lockedEnvironment)
assayData: 5226 features, 73 samples
element names: exprs, se.exprs
protocolData: none
phenoData
sampleNames: GSM918578 GSM918579 ... GSM918653 (73 total)
varLabels: title geo_accession ... data_row_count (37
total)
varMetadata: labelDescription
featureData: none
experimentData: use 'experimentData(object)'
Annotation: hg133plus2
> all(rownames(pData)==colnames(exp) )
[1] TRUE
> newData<- ExpressionSet(assayData = exp,
+                           phenoData = p1,
+                           annotation = "hg133plus2" )
```

Lampiran 10 *Packages SVM*

```
> analisis <- c('e1071', 'pROC')
> Usepackage(analisis)
```

Lampiran 11 Penyusunan data set

```
> data    = as.data.frame (t(exprs(newData)))
> gender  = as.factor(newData$characteristics_ch1.2)
> ethnic = as.factor(newData$characteristics_ch1.3)
> dataY   = as.factor(newData$characteristics_ch1)
> datause = as.data.frame(cbind(data,ethnic,gender,dataY))
> ratio   = 7/10
> G3      = datause[dataY=='subgroup: G3',]
> G4      = datause[dataY=='subgroup: G4',]
> SHH     = datause[dataY=='subgroup: SHH',]
> WNT     = datause[dataY=='subgroup: WNT',]
> sampelg3 = sample(nrow(G3), size = floor(ratio*nrow(G3)))
> sampelg4 = sample(nrow(G4), size = floor(ratio*nrow(G4)))
> sampelshh = sample(nrow(SHH), size =
floor(ratio*nrow(SHH)))
> sampelwnt = sample(nrow(WNT), size =
floor(ratio*nrow(WNT)))
> sampelg3 = c(7 ,3 ,4 ,8 ,1, 15, 10, 6, 12, 9, 14)
> sampelg4 = c(30, 19, 31, 9, 34, 2, 12, 3, 17, 6, 4, 14,
27, 38, 13, 29, 10, 20, 25, 22, 33, 16, 36, 21, 11, 39, 26)
> sampelshh = c(10, 2, 8, 6, 7, 4, 3)
> sampelwnt = c(4, 6, 5, 3, 2)
> trainG3= G3[sampelg3,]
> trainG4= G4[sampelg4,]
> trainSHH= SHH[sampelshh,]
> trainWNT= WNT[sampelwnt,]
```

```

> testG3= G3[-samplelg3, ]
> testG4= G4[-samplelg4, ]
> testSHH= SHH[-samplelshh, ]
> testWNT= WNT[-samplelwnt, ]
> datatrain = rbind(trainG3, trainG4, trainSHH, trainWNT)
> data-test = rbind(testG3, testG4, testSHH, testWNT)

```

Lampiran 12 Tuning

```

> tunaslin <- tune(svm, dataY~. , data = datatrain,
kernel="linear",types = "C-clasification",ranges= list( cost
= c(0.1,0.01, 0.001,1 , 10 , 100)))
> summary(tunaslin)

Parameter tuning of 'svm':
- sampling method: 10-fold cross validation
- best parameters:
  cost
  0.1
- best performance: 0.06
- Detailed performance results:

  cost error dispersion

1 1e-01  0.06 0.09660918
2 1e-02  0.06 0.09660918
3 1e-03  0.06 0.09660918
4 1e+00  0.06 0.09660918
5 1e+01  0.06 0.09660918
6 1e+02  0.06 0.09660918

```

```
> model <- svm(dataY~. , datatrain, kernel = "linear",
cost=0.1,scale=F, types      =      "C-classification",
decision.value=T)

> predictions <- predict(model, datatest)
```

Lampiran 13 Confusion matrix

```
> table(predictions,datatest$dataY)

predictions      subgroup: G3 subgroup: G4 subgroup: SHH subgroup: WNT
subgroup: G3          4          0          0          0
subgroup: G4          1         12          0          0
subgroup: SHH          0          0          3          0
subgroup: WNT          0          0          0          3

> mean(predictions == datatest$dataY)
[1] 0.9565217

> predictions <- predict(model, datatrain)

> table(predictions,datatrain$dataY)

predictions      subgroup: G3 subgroup: G4 subgroup: SHH subgroup: WNT
subgroup: G3         11          0          0          0
subgroup: G4          0         27          0          0
subgroup: SHH          0          0          7          0
subgroup: WNT          0          0          0          5

> mean(predictions == datatrain$dataY)
[1] 1
```

Lampiran 14 Bobot

```
> w <- t(model$coefs) %*% model$SV

> w <- apply(w, 2, function(v) {sqrt(sum(v^2))})

> w <- sort(w, decreasing = T)

> x<- as.data.frame(w)

> View(x)
```

```
> all(colnames(w)==colnames(datatrain))
[1] TRUE
```

Lampiran 15 AUC

```
> forauc <- as.numeric(predict(model,datatest))

> auc <- multiclass.roc(datatest$dataY,forauc)

> auc$auc
```

Multi-class area under the curve: 0.9833

Lampiran 16 Gene name dan gene ontology

```
> id <- substring(as.character(head(rownames(x), n=10)),2)

> select(hgu133plus2.db, id, "GENENAME")

'select()' returned 1:1 mapping between keys and columns
```

| | PROBEID | GENENAME |
|----|-------------|---|
| 1 | 1559213_at | long intergenic non-protein coding RNA 1419 |
| 2 | 201049_s_at | ribosomal protein S18 |
| 3 | 200819_s_at | ribosomal protein S15 |
| 4 | 200763_s_at | ribosomal protein lateral stalk subunit P1 |
| 5 | 201665_x_at | ribosomal protein S17 |
| 6 | 221798_x_at | ribosomal protein S2 |
| 7 | 208645_s_at | ribosomal protein S14 |
| 8 | 215963_x_at | ribosomal protein L3 |
| 9 | 213414_s_at | ribosomal protein S19 |
| 10 | 200013_at | ribosomal protein L24 |

```
> genname <- select(hgu133plus2.db, id,
  c("SYMBOL", "GENENAME"), "PROBEID")

> ontology <- select(hgu133plus2.db, id,
  c("SYMBOL", "GENENAME", "ENTREZID", "ONTOLOGY"), "PROBEID")

> genname
```

| | <i>PROBEID SYMBOL</i> | <i>GENENAME</i> |
|----|-----------------------|--|
| 1 | 201049_s_at RPS18 | ribosomal protein S18 |
| 2 | 200763_s_at RPLP1 | ribosomal protein lateral stalk subunit P1 |
| 3 | 200819_s_at RPS15 | ribosomal protein S15 |
| 4 | 201665_x_at RPS17 | ribosomal protein S17 |
| 5 | 200062_s_at RPL30 | ribosomal protein L30 |
| 6 | 200013_at RPL24 | ribosomal protein L24 |
| 7 | 215963_x_at RPL3 | ribosomal protein L3 |
| 8 | 208645_s_at RPS14 | ribosomal protein S14 |
| 9 | 208692_at RPS3 | ribosomal protein S3 |
| 10 | 200010_at RPL11 | ribosomal protein L11 |

> ontology

| | <i>PROBEID SYMBOL</i> | <i>GENENAME</i> | <i>ENTREZID</i> |
|----|-----------------------|--|-----------------|
| | ONTOLOGY | | |
| 1 | 201049_s_at RPS18 | ribosomal protein S18 | 6222 BP |
| 2 | 201049_s_at RPS18 | ribosomal protein S18 | 6222 CC |
| 3 | 201049_s_at RPS18 | ribosomal protein S18 | 6222 MF |
| 4 | 200763_s_at RPLP1 | ribosomal protein lateral stalk subunit P1 | 6176 BP |
| 5 | 200763_s_at RPLP1 | ribosomal protein lateral stalk subunit P1 | 6176 CC |
| 6 | 200763_s_at RPLP1 | ribosomal protein lateral stalk subunit P1 | 6176 MF |
| 7 | 200819_s_at RPS15 | ribosomal protein S15 | 6209 BP |
| 8 | 200819_s_at RPS15 | ribosomal protein S15 | 6209 CC |
| 9 | 200819_s_at RPS15 | ribosomal protein S15 | 6209 MF |
| 10 | 201665_x_at RPS17 | ribosomal protein S17 | 6218 BP |
| 11 | 201665_x_at RPS17 | ribosomal protein S17 | 6218 CC |
| 12 | 201665_x_at RPS17 | ribosomal protein S17 | 6218 MF |
| 13 | 200062_s_at RPL30 | ribosomal protein L30 | 6156 BP |
| 14 | 200062_s_at RPL30 | ribosomal protein L30 | 6156 CC |
| 15 | 200062_s_at RPL30 | ribosomal protein L30 | 6156 MF |
| 16 | 200013_at RPL24 | ribosomal protein L24 | 6152 BP |
| 17 | 200013_at RPL24 | ribosomal protein L24 | 6152 CC |

| | | | | | |
|----|-------------|-------|-----------------------|------|----|
| 18 | 200013_at | RPL24 | ribosomal protein L24 | 6152 | MF |
| 19 | 215963_x_at | RPL3 | ribosomal protein L3 | 6122 | BP |
| 20 | 215963_x_at | RPL3 | ribosomal protein L3 | 6122 | CC |
| 21 | 215963_x_at | RPL3 | ribosomal protein L3 | 6122 | MF |
| 22 | 208645_s_at | RPS14 | ribosomal protein S14 | 6208 | BP |
| 23 | 208645_s_at | RPS14 | ribosomal protein S14 | 6208 | CC |
| 24 | 208645_s_at | RPS14 | ribosomal protein S14 | 6208 | MF |
| 25 | 208692_at | RPS3 | ribosomal protein S3 | 6188 | BP |
| 26 | 208692_at | RPS3 | ribosomal protein S3 | 6188 | CC |
| 27 | 208692_at | RPS3 | ribosomal protein S3 | 6188 | MF |
| 28 | 200010_at | RPL11 | ribosomal protein L11 | 6135 | BP |
| 29 | 200010_at | RPL11 | ribosomal protein L11 | 6135 | CC |
| 30 | 200010_at | RPL11 | ribosomal protein L11 | 6135 | MF |

Lampiran 17 Session Info

```
> sessionInfo()

R version 3.4.2 (2017-09-28)

Platform: x86_64-w64-mingw32/x64 (64-bit)

Running under: Windows 10 x64
```