

# 1. Pendahuluan

## 1.1. Latar Belakang

Dengan begitu banyaknya tantangan yang dimiliki oleh *data mining*, pengolahan data dalam berbagai macam penelitian menjadi sangat sulit untuk ditangani, tantangan tersebut meliputi [3]: *dimensionality*, *complex and heterogeneous data*, *data quality*, *data ownership and distribution*, *privacy preservation*, dan *streaming data*. Tantangan tersebut kemudian menimbulkan salah satu masalah dalam industri kesehatan [11] yaitu data penyakit berdimensi tinggi, kategori tantangan ini adalah *dimensionality*.

Dalam kasus ini, data tersebut memiliki jumlah atribut yang begitu banyak, semakin banyak atribut maka semakin banyak memakan waktu dan memanfaatkan upaya komputasi yang berlebihan sehingga data sulit untuk ditangani [5]. Maka dari itu, untuk menjawab tantangan dari masalah tersebut reduksi dimensi sangat diperlukan agar mendapatkan nilai akurasi yang lebih baik untuk setiap penelitian.

Reduksi dimensi ini dilakukan untuk mengurangi bagian-bagian atribut yang tidak diperlukan pada data yang sedang diteliti, contohnya: terdapat nilai dari salah satu atribut tidak ada dalam data (*missing value*) hal ini mungkin sekali terjadi dikarenakan informasi yang diperlukan tidak dapat diperoleh. Selain itu, terdapat juga atribut yang karakteristiknya berbeda diantara atribut-atribut lain (*outlier*) dan adanya *error* pada data (*noise*). Itulah gangguan-gangguan yang terdapat pada data dikarenakan kesalahan dalam pengumpulan informasi.

*Data mining* menggunakan *Evolutionary Algorithms* (EAs) atau bisa disebut sebagai *Evolutionary data mining* dapat digunakan untuk permasalahan tersebut. EAs dapat membantu *data mining* untuk dapat mereduksi dimensi dengan cara membuat aturan-aturan secara acak yang kemudian akan diseleksi untuk mendapatkan atribut-atribut yang paling optimal. Banyak studi yang membahas tentang *evolutionary data mining* diantaranya: penggunaan *evolutionary data mining* pada penyakit diabetes [11], kumpulan data medis [5], prediksi penyakit jantung [9] dan masih banyak lagi.

Algoritma *K-Means* sebagai *instance reduction* dapat digunakan untuk menghilangkan gangguan terhadap data dan *Genetic Algorithm* (GA) digunakan untuk memilih atribut yang paling optimal dalam data tersebut. *Support Vector Machine* (SVM) digunakan sebagai *tools* untuk melakukan klasifikasi berdasarkan keluaran yang telah diperoleh oleh GA untuk mendapatkan akurasi yang lebih baik [5,11]. Sebelumnya penelitian terhadap *K-Means*, GA, dan SVM ini pernah dilakukan dalam memprediksi penyakit diabetes dan memperoleh akurasi sebesar 98% [11]. Pada tugas akhir ini dilakukan prediksi penyakit menggunakan algoritma *K-Means*, GA dan SVM pada kasus data berdimensi tinggi.

## 1.2. Perumusan Masalah

Permasalahan yang dapat diselesaikan dalam tugas akhir ini terdiri dari:

1. Bagaimana implementasi *K-Means* dan GA dengan mengintegrasikan SVM pada data penyakit berdimensi tinggi ?
2. Bagaimana cara kerja *K-Means* untuk dapat menghilangkan gangguan data dan GA untuk memilih atribut paling yang optimal pada data penyakit berdimensi tinggi ?
3. Bagaimana prediksi yang didapatkan SVM pada data penyakit berdimensi tinggi ?
4. Bagaimana performansi yang didapatkan SVM pada data penyakit berdimensi tinggi ?

## 1.3. Batasan Masalah

Adapun batasan masalah dari tugas akhir ini, yaitu :

1. *Data set* yang digunakan untuk tugas akhir ini adalah data penyakit berupa data ekspresi gen yang berasal dari *Kent Ridge Bio-medical Data Set Repository* [6].
2. Algoritma *K-Means Clustering* digunakan sebagai algoritma untuk mereduksi *record*.
3. Algoritma EAs yang digunakan adalah GA yang berfungsi sebagai *feature selection*.
4. SVM digunakan sebagai klasifikasi.

## 1.4. Tujuan

Tujuan untuk menyelesaikan masalah tersebut adalah :

1. Mengimplementasikan Algoritma *K-Means* dan GA untuk mereduksi dimensi dengan mengintegrasikan SVM pada data penyakit berdimensi tinggi.
2. Mengetahui cara kerja *K-Means* dan GA pada data penyakit berdimensi tinggi.
3. Mengetahui hasil prediksi SVM pada data penyakit berdimensi tinggi.
4. Menganalisis hasil performansi yang didapatkan SVM pada data penyakit berdimensi tinggi.

## 1.5. Sistematika Penulisan

Pada sub bab ini dijelaskan secara singkat mengenai uraian lingkup isi dari setiap bab yang ada dalam buku tugas akhir ini. Bab 1 menjelaskan tentang latar belakang masalah berdasarkan judul yang diajukan penulis serta tujuan dari pembuatan tugas akhir ini. Bab 2 menjelaskan tentang teori-teori pendukung berdasarkan masalah yang dihadapi. Bab 3 menjelaskan tentang perancangan sistem dan skenario yang dibuat untuk penyelesaian masalah yang dihadapi. Bab 4 menjelaskan tentang hasil pengujian dan analisis sistem yang telah dibuat. Bab 5 berisi kesimpulan dan saran atas selesainya tugas akhir ini.