

SISTEM PAKAR DIAGNOSA PENYAKIT SAPI POTONG DENGAN METODE NAIVE BAYES

Indriana Candra Dewi¹, Arief Andy Soebroto², M. Tanzil Furqon³

^{1,2,3} Program Teknologi Informasi dan Ilmu Komputer, Universitas Brawijaya

Email: ¹indrianacandradewi@gmail.com, ²ariefas@ub.ac.id, ³m.tanzil.furqon@ub.ac.id

ABSTRACT

In order to produce quality beef, one of the important factors in maintenance of cattle is to maintain the health of livestock to stay fit. One way to provide an understanding of the breeders is to use expert system. An expert system is one of the artificial intelligence which is adopting of the expert knowledge that used to solve problem that usually can only be solved by expert in the field. Expert systems can be allowed to extend the working range of experts so that expert knowledge can be acquired and used anywhere. In this expert system use a Naive Bayes method as inference methods for diagnosing the disease. Types of diseases that can be recognized by expert system are 11 types of disease while symptoms that can be recognized the expert system are 20 types of symptom. The results of testing the accuracy of the 26 test case data, have generated the level of conformity percentage of 96,15%.

Keywords: Livestok, Diagnosing, Naive Bayes, Cow Disease, Expert System.

1. LATAR BELAKANG

Seiring pertambahan jumlah penduduk dan peningkatan daya beli masyarakat dapat dipastikan penjualan daging sapi dalam negeri akan semakin meningkat. Salah satu faktor yang perlu diperhatikan dalam pemeliharaan ternak sapi adalah kesehatan ternak itu sendiri. Untuk menjaga kesehatan ternak agar selalu prima sebaiknya peternak memahami penyakit yang sering menyerang sapi dan cara pengobatannya yang biasanya hanya diketahui oleh dokter hewan (Rahmat, 2012). Salah satu cara untuk memasyarakatkan pengetahuan pakar atau dokter hewan adalah dengan menggunakan sistem pakar. Sistem pakar adalah salah satu kecerdasan buatan yang mengadopsi pengetahuan, fakta dan teknik penalaran pakar yang digunakan untuk memecahkan permasalahan yang biasanya hanya dapat

dipecahkan oleh pakar dalam bidang tersebut (Kusrini, 2007). Sistem pakar dapat memungkinkan untuk memperluas jangkauan kerja pakar sehingga pengetahuan pakar dapat diperoleh dan dipakai dimana saja.

Beberapa penelitian sistem pakar telah dilakukan untuk membantu penyelesaian diagnosa penyakit bagi manusia, hewan dan tumbuhan. Pada penelitian yang berjudul "An Efficient Expert System For Diabetes By Naive Bayesian Classifier" sistem pakar digunakan untuk mengklasifikasikan penderita diabetes (Ambica, 2013). Penderita diabetes diklasifikasikan dalam tiga kelas yaitu tidak menderita diabetes, menderita diabetes dan pre diabetes. Penelitian yang berjudul "The Use of Certainty Factor with Multiple Rules for Diagnosing Internal Disease" sistem pakar digunakan untuk mendiagnosa penyakit dalam pada manusia dengan metode certainty factor (Munandar, 2012). Sistem ini menghasilkan output berupa diagnosa penyakit dalam yang diderita pasien.

Penelitian yang berjudul "Aplikasi Sistem Pakar untuk Pendeteksi dan Penanganan Dini pada Penyakit Sapi dengan Metode Dempster-Shafer Berbasis Web" sistem pakar digunakan untuk mendiagnosa penyakit pada sapi dengan menggunakan metode dempster-shafer (Mustikadewi, 2013). Output dari sistem pakar ini adalah diagnosa penyakit sapi dan solusi penanganan terhadap penyakit tersebut. Penelitian yang berjudul "Aplikasi Sistem Pakar untuk Identifikasi Hama dan Penyakit Tanaman Tebu dengan Metode Naive Bayes Berbasis Web" sistem pakar digunakan untuk menentukan hama atau penyakit yang menyerang tanaman tebu (Hardika, 2014).

Pada penelitian-penelitian sebelumnya yang menjadi kajian pustaka penulis telah membahas metode Dempster-Shafer, Certainty Factor dan Naive Bayes yang digunakan dalam pembuatan aplikasi sistem pakar. Metode *certainty factor* diciptakan untuk mengakomo-

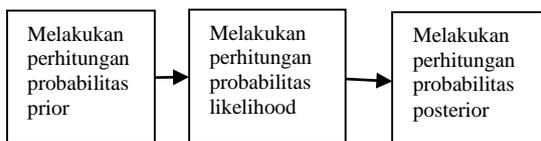
akan memproses data *training* dengan menggunakan metode *Naive Bayes* sehingga dapat menghasilkan keputusan diagnosa sistem. *Blackboard* berfungsi sebagai penyimpanan hasil perhitungan sementara metode *naive bayes*.

2.4.1. Proses Perhitungan Naive Bayes

Bayes merupakan teknik prediksi berbasis probabilistik sederhana yang berdasar pada penerapan teorema Bayes. Klasifikasi *Naive Bayes* praktis diterapkan karena merupakan salah satu probabilitas sederhana yang penerapannya didasarkan pada teorema bayes dengan asumsi independensi[4]. Formula *Naive Bayes* dinyatakan dalam Persamaan 1 berikut (Prasetyo, 2012):

$$P(Y|X) = \frac{P(Y)\prod_{i=1}^q P(X_i|Y)}{P(X)} \dots\dots\dots(\text{Persamaan 1})$$

- P(Y|X) = Probabilitas data dengan vektor X pada kelas Y
- P(Y) = Probabilitas awal kelas Y
- $\prod_{i=1}^q P(X_i|Y)$ = Probabilitas independen kelas Y dari semua fitur dalam vektor X



Gambar 2 Diagram Proses Komputasi Metode *Naive Bayes*

Gambar 2 merupakan langkah-langkah komputasi dalam perhitungan *Naive Bayes*.

Contoh Kasus:

Jika diketahui suatu fakta gejala suatu penyakit yang terdapat pada sapi adalah demam (G5), keluar ingus (G9) dan pincang (G16).

Langkah Pertama: Menghitung probabilitas prior

Melakukan pencarian nilai probabilitas pada setiap jenis penyakit.

$P(h)$ = Peluang dari hipotesa h(jenis penyakit)

Contoh:

Jumlah data penyakit BEF = 161
 Jumlah seluruh data penyakit = 325
 $P(\text{BEF}) = 161/325 = 0,49538$

Hitung:

$P(\text{BEF}) = 161/325 = 0,49538$
 $P(\text{Bloat}) = 34/325 = 0,10461$

$P(\text{Enteritis}) = 42/325 = 0,12923$
 $P(\text{Endometritis}) = 27/325 = 0,08308$
 $P(\text{Ascariasis}) = 27/325 = 0,083077$
 dst...

Langkah Kedua: Menghitung probabilitas likelihood

Melakukan pencarian nilai probabilitas sebuah fakta gejala pada penyakit yang mempengaruhi suatu hipotesa.

$P(e|h)$ = Peluang data fakta gejala e, bila diasumsikan bahwa hipotesa h benar

Contoh:

Jumlah gejala G5 pada penyakit BEF = 161
 Jumlah gejala G9 pada penyakit BEF = 153
 Jumlah gejala G16 pada penyakit BEF = 89
 $P(G5|\text{BEF}) = 161/161 = 1$
 $P(G9|\text{BEF}) = 153/161 = 0,95031$
 $P(G16|\text{BEF}) = 89/161 = 0,55280$

Hitung:

$P(G5|\text{BEF}) = 161/161 = 1$
 $P(G9|\text{BEF}) = 153/161 = 0,95031$
 $P(G16|\text{BEF}) = 89/161 = 0,55280$
 $P(G5|\text{Bloat}) = 161/161 = 1$
 $P(G9|\text{Bloat}) = 153/161 = 0,95031$
 $P(G16|\text{Bloat}) = 89/161 = 0,55280$
 $P(G5|\text{Enteritis}) = 34/34 = 1$
 $P(G9|\text{Enteritis}) = 0/34 = 0$
 $P(G16|\text{Enteritis}) = 0/34 = 0$
 $P(G5|\text{Endometritis}) = 21/21 = 1$
 $P(G9|\text{Endometritis}) = 0/21 = 0$
 $P(G16|\text{Endometritis}) = 0/21 = 0$
 $P(G9|\text{Ascariasis}) = 0/22 = 0$
 $P(G9|\text{Ascariasis}) = 0/22 = 0$
 $P(G16|\text{Ascariasis}) = 0/22 = 0$
 dst...

Langkah Ketiga: Menghitung probabilitas posterior

$P(h|e)$ = Peluang bahwa hipotesa benar untuk data fakta gejala e yang diamati.

$P(h|e) = P(h) * P(e_1, e_2, e_3|h)$
 $e_1 = G6, e_2 = G17, e_3 = G10$

Perhitungan $P(h|e)$ dapat dilihat seperti berikut:

Contoh:

$P(\text{BEF}|e) = P(\text{BEF}) \times P(G6|\text{BEF}) \times P(G17|\text{BEF}) \times P(G10|\text{BEF})$
 $P(\text{BEF}|e) = 0,49538 \times 1 \times 0,95031 \times 0,5528 = 0,26024$

Hitung:

$P(\text{BEF}|e) = 0,49538 \times 1 \times 0,95031 \times 0,5528 = 0,26024$

$$P(\text{Bloat}|e) = 0,10462 \times 0 \times 0 \times 0 = 0$$

$$P(\text{Enteritis}|e) = 0,12923 \times 1 \times 0 \times 0 = 0$$

$$P(\text{Endometritis}|e) = 0,08308 \times 1 \times 0 \times 0 = 0$$

$$P(\text{Ascariis}|e) = 0,08307 \times 0 \times 0 \times 0 = 0$$

dst...

Hasil perhitungan metode *Naive Bayes* pada penyakit sapi potong sesuai dengan fakta gejala tersebut ditunjukkan pada tabel 1.

Tabel 1 Hasil Perhitungan *Naive Bayes* pada Penyakit Sapi

| Jenis Penyakit | Index | P(h) | P(e1 h) | P(e2 h) | P(e3 h) | P(h e) |
|----------------|-------|---------|---------|---------|---------|---------|
| Abses | 0 | 0,00307 | 1 | 0 | 0 | 0 |
| Ascariasis | 1 | 0,08308 | 0 | 0 | 0 | 0 |
| BEF | 2 | 0,49538 | 1 | 0,95031 | 0,5528 | 0,26024 |
| Bloat | 3 | 0,10462 | 0 | 0 | 0 | 0 |
| Endometritis | 4 | 0,08308 | 1 | 0 | 0 | 0 |
| Enteritis | 5 | 0,12923 | 1 | 0 | 0 | 0 |
| Mastitis | 6 | 0,00923 | 1 | 0 | 0 | 0 |
| Omphalitis | 7 | 0,00615 | 1 | 0 | 0 | 0 |
| Pneumonia | 8 | 0,00923 | 0,66667 | 0,33333 | 0 | 0 |
| Retensio | 9 | 0,02462 | 0,875 | 0 | 0 | 0 |
| Scabies | 10 | 0,05231 | 0 | 0 | 0 | 0 |

Hasil perhitungan probabilitas Tabel 1 akan dilakukan *searching* nilai probabilitas terbesar yang nantinya akan menjadi keputusan sistem. Berdasarkan hasil perhitungan nilai probabilitas terbesar adalah 0,26024. Hasil diagnosa gejala demam, pincang dan keluar ingus adalah penyakit BEF.

2.5. Implementasi

Implementasi sistem adalah fase membangun sistem yang telah dirancang dan menerapkan hal-hal yang telah diperoleh dalam proses studi literatur. Fase-fase yang ada dalam implementasi antara lain:

- Implementasi basis data dengan menggunakan DBMS MySQL
- Implementasi algoritma *Naive Bayes* ke dalam bahasa pemrograman PHP.
- *Tools* pendukung lainnya

2.6. Pengujian

Pengujian sistem dilakukan untuk mengetahui tingkat kesuksesan sistem pakar yang telah dibangun. Pengujian sistem

dilakukan melalui dua cara yaitu pengujian *blackbox* dan pengujian akurasi. Pengujian *blackbox* akan menguji fungsionalitas sistem dapat berjalan dengan baik. Pengujian akurasi dilakukan dengan membandingkan hasil diagnosa sistem dengan hasil diagnosa seorang pakar. Pengujian akurasi dilakukan terhadap variasi data dengan cara mengubah data training. Pengujian variasi data terbagi menjadi empat skenario yaitu jumlah data *training* 20%, 40%, 60%, 80% dan 100%. Tujuan pengujian variasi data *training* adalah untuk akurasi paling optimal terhadap perubahan data *training*.

3. HASIL DAN PEMBAHASAN

Hasil dan Pembahasan merupakan tahap pengujian hasil dari perancangan dan implementasi sistem pakar. Proses pengujian dilakukan melalui dua tahap yaitu pengujian *blackbox*, pengujian akurasi dan pengujian variasi data

3.1. Pengujian Blackbox

Pengujian *blackbox* dilakukan dengan melihat kesesuaian antara hasil yang diharapkan dengan hasil yang didapatkan dari sistem pakar. Hasil pengujian *blackbox* sistem pakar diagnosa penyakit sapi potong dengan metode *Naive Bayes* menunjukkan bahwa sistem dapat menjalankan seluruh fungsi dengan baik dan memenuhi seluruh kebutuhan fungsional yang ada. Hal tersebut terbukti dengan kesuaian hasil yang diharapkan dan hasil yang dihasilkan.

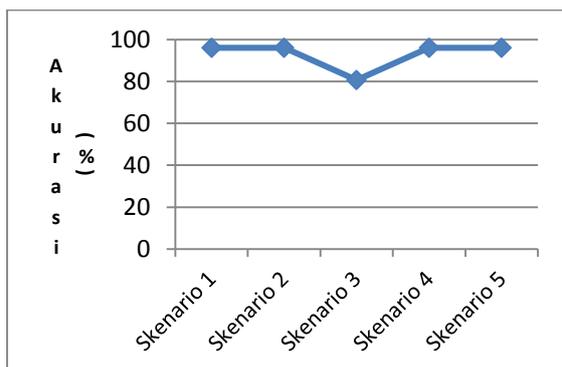
3.2. Pengujian Akurasi

Skenario pengujian akurasi terhadap variasi data akan pengujian menjadi lima skenario pengujian yaitu jumlah data *training* 20%, 40%, 60%, 80% dan 100% dari 325 data *training*. . Pengambilan data *training* pada masing-masing skenario pengujian dilakukan melalui 5 skenario pengambilan data. Skenario pengambilan data *training* pertama dilakukan dengan cara mengambil data sejumlah n% kemudian dilakukan pembulatan ke atas. Skenario pengambilan data *training* kedua dilakukan dengan cara mengambil data sejumlah n% kemudian dilakukan pembulatan ke bawah. Skenario pengambilan data *training* ketiga dilakukan dengan cara mengambil data sejumlah n% kemudian dilakukan pembulatan. Skenario pengambilan data *training* keempat

dilakukan dengan cara mengambil data sejumlah $n\%$ sesuai kebutuhan. Skenario pengambilan data *training* kelima dilakukan secara *random*.

3.2.1. Skenario 20% Data Training

Gambar 3 adalah grafik hasil pengujian pada masing-masing skenario proses pengambilan data dengan jumlah data *training* sebesar 20% dari keseluruhan data *training*.

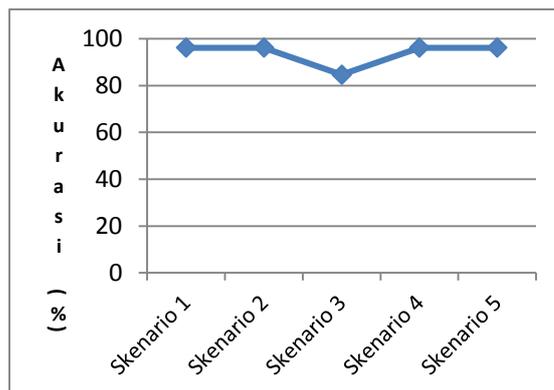


Gambar 3. Grafik Tingkat Akurasi 20% Data Training

Sistem pakar mengenali penyakit pneumonia sebagai penyakit bloat pada seluruh skenario pengambilan data. Kesalahan diagnosa pada skenario 1, 2, 3, 4 dan 5 terjadi karena data yang dimasukkan oleh pengguna kurang spesifik. Sistem pakar tidak dapat mengenali penyakit enteritis, pneumonia, abses dan omphalitis pada skenario pengambilan data ketiga. Kesalahan ini terjadi karena data yang dimasukkan pengguna tidak tercakup dalam data *training*.

3.2.2. Skenario 40% Data Training

Gambar 4 adalah grafik hasil pengujian pada masing-masing skenario proses pengambilan data dengan jumlah data *training* sebesar 40% dari keseluruhan data *training*.

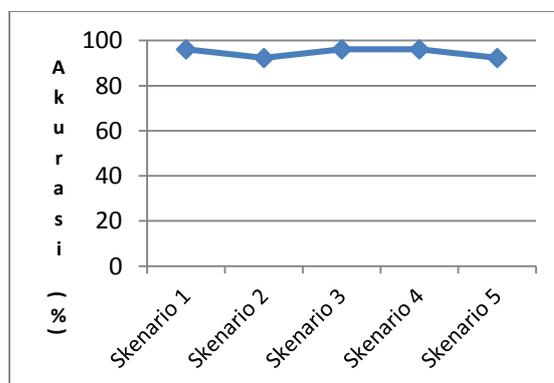


Gambar 4. Grafik Tingkat Akurasi 40% Data Training

Sistem pakar mengenali penyakit pneumonia sebagai penyakit bloat pada seluruh skenario pengambilan data. Kesalahan diagnosa pada skenario 1, 2, 3, 4 dan 5 terjadi karena data yang dimasukkan oleh pengguna kurang spesifik. Sistem pakar tidak dapat mengenali penyakit enteritis dan pneumonia pada skenario pengambilan data ketiga. Kesalahan ini terjadi karena data yang dimasukkan pengguna tidak tercakup dalam data *training*. Selain itu pada skenario pengambilan data ketiga sistem pakar mengenali penyakit omphalitis sebagai penyakit abses. Kesalahan ini dapat terjadi karena data *training* penyakit abses berjumlah sedikit sehingga tidak seimbang dengan data *training* penyakit-penyakit lain.

3.2.3. Skenario 60% Data Training

Gambar 5 adalah grafik hasil pengujian pada masing-masing skenario proses pengambilan data dengan jumlah data *training* sebesar 60% dari keseluruhan data *training*.



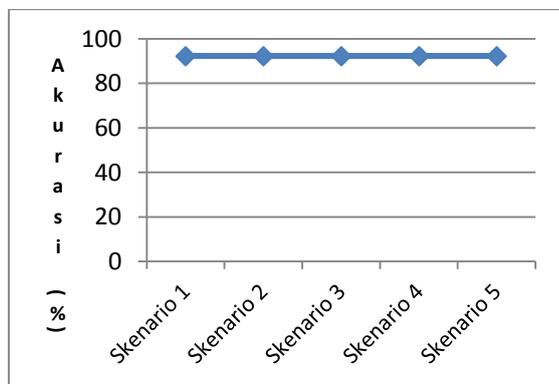
Gambar 5 Grafik Tingkat Akurasi 60% Data Training

Sistem pakar mengenali penyakit pneumonia sebagai penyakit bloat pada seluruh skenario

pengambilan data. Kesalahan diagnosa pada skenario 1, 2, 3, 4 dan 5 terjadi karena data yang dimasukkan oleh pengguna kurang spesifik. Skenario pengambilan data pertama dan kelima sistem pakar mengenali penyakit omphalitis sebagai penyakit abses. Kesalahan ini dapat terjadi karena data *training* penyakit abses berjumlah sedikit sehingga tidak seimbang dengan data *training* penyakit-penyakit lain.

3.2.4. Skenario 80% Data Training

Gambar 6 adalah grafik hasil pengujian pada masing-masing skenario proses pengambilan data dengan jumlah data *training* sebesar 80% dari keseluruhan data *training*.



Gambar 6 Grafik Tingkat Akurasi 80% Data Training

Sistem pakar mengenali penyakit pneumonia sebagai penyakit bloot pada seluruh skenario pengambilan data. Kesalahan diagnosa pada skenario 1, 2, 3, 4 dan 5 terjadi karena data yang dimasukkan oleh pengguna kurang spesifik. Selain itu pada seluruh skenario pengambilan data sistem pakar mengenali penyakit omphalitis sebagai penyakit abses. Kesalahan ini dapat terjadi karena data *training* penyakit abses berjumlah sedikit sehingga tidak seimbang dengan data *training* penyakit-penyakit lain.

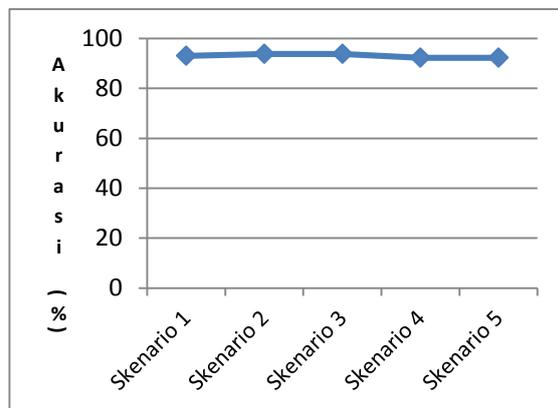
3.2.5. Skenario 100% Data Training

Skenario 100% data *training* menggunakan 100% data dari keseluruhan data *training* yang ada. Hasil pengujian sistem pakar skenario ini mengenali penyakit pneumonia sebagai penyakit bloot. Kesalahan diagnosa terjadi karena data yang dimasukkan oleh pengguna kurang spesifik. Selain itu sistem pakar mengenali penyakit omphalitis sebagai penyakit abses. Kesalahan ini dapat terjadi karena data *training*

penyakit abses berjumlah sedikit sehingga tidak seimbang dengan data *training* penyakit-penyakit lain.

3.2.6. Analisa Pengujian Akurasi

Berdasarkan kelima skenario pengujian akurasi terhadap variasi data menghasilkan nilai rata-rata akurasi masing-masing skenario sebesar 93,08%, 93,84%, 94,61%, 92,31% dan 92,31%. Sehingga didapatkan rata-rata akurasi sistem sebesar 93,23%. Grafik rata-rata hasil pengujian akurasi terhadap variasi data *training* ditunjukkan pada Gambar 7 berikut.



Gambar 7 Grafik Rata-Rata Hasil Pengujian Variasi Data

Berdasarkan pemaparan hasil rata-rata pengujian variasi data dapat diambil kesimpulan bahwa tingkat akurasi tertinggi didapat ketika variasi berjumlah 40% dan 60% dari keseluruhan jumlah data *training* yang ada. Hal ini membuktikan bahwa komposisi jumlah data kasus berpengaruh dalam hasil akurasi sistem. Semakin banyak data *training* belum tentu dapat menjamin sistem pakar yang dihasilkan akan semakin baik. Jadi dalam menentukan data *training* harus memperhatikan komposisi jumlah data kasus masing-masing *class* untuk menghasilkan sistem pakar yang baik.

4. PENUTUP

4.1. Kesimpulan

Berdasarkan hasil perancangan dan pengujian yang dilakukan pada sistem pakar diagnosa penyakit pada sapi potong dengan metode *Naive Bayes*, maka dapat diambil kesimpulan sebagai berikut:

1. Proses diagnosa penyakit sapi potong dilakukan dengan cara memasukkan gejala klinis yang muncul pada ternak. Melalui gejala klinis tersebut akan dilakukan perhitungan dengan metode *Naive Bayes* untuk mendapatkan nilai probabilitas posterior setiap class jenis penyakit ternak yang menjadi studi kasus pada penelitian ini. Jenis penyakit yang memiliki nilai probabilitas akhir tinggi akan diambil sebagai hasil diagnosa sistem pakar.
2. Sistem pakar diagnosa penyakit sapi potong ini memiliki kinerja sistem yang mampu berjalan dengan baik sesuai kebutuhan fungsional. Hal ini berdasarkan pengujian blackbox yang telah membuktikan bahwa seluruh fungsi dapat bekerja sesuai dengan hasil yang diharapkan.
3. Berdasarkan kelima skenario pengujian akurasi terhadap variasi data menghasilkan nilai rata-rata akurasi masing-masing skenario sebesar 93,08%, 93,85%, 93,85%, 92,31% dan 92,31%. Sehingga didapatkan rata-rata akurasi sistem sebesar 93,08%. Tingkat akurasi tertinggi didapat ketika variasi data *training* berjumlah 40% dan 60% dari keseluruhan jumlah data *training* yang ada. Hal ini membuktikan bahwa komposisi data kasus berpengaruh dalam hasil akurasi sistem. Semakin banyak data *training* belum tentu dapat menjamin sistem pakar yang dihasilkan akan semakin baik. Jadi dalam menentukan data *training* harus komposisi data kasus masing-masing *class* untuk menghasilkan sistem pakar yang baik.

4.2. Saran

Sistem pakar diagnosa penyakit sapi potong dengan metode *Naive Bayes* ini masih memiliki beberapa kekurangan. Saran yang dapat diberikan untuk pengembangan sistem agar menjadi lebih baik antara lain:

1. Pengembangan metode *Naive Bayes* dapat dilakukan dengan cara melakukan pembobotan pada gejala klinis penyakit.
2. Sistem dapat dikembangkan lebih lanjut dengan menggunakan metode yang berbeda atau mengkombinasikan metode *Naive Bayes* dengan metode yang lain agar sistem lebih akurat, efektif dan efisien.
3. Pengembangan dapat dilakukan dengan cara menambah jenis penyakit dan gejala klinis dalam proses diagnosa penyakit sapi potong.

5. DAFTAR PUSTAKA

- AMBICA, A., dkk. 2013. *An Efficient Expert System for Diabetes by Naïve Bayesian Classifier*. Dadi Institute of Engineering and Technology (Affiliated to JNTUK), Andhra Pradesh.
- HARDIKA, P ANGGA, dkk. 2014. *Aplikasi Sistem Pakar untuk Identifikasi Hama dan Penyakit Tanaman Tebu dengan Metode Naïve Bayes Berbasis Web*. Universitas Brawijaya, Malang.
- KARLIK, BEKIR. 2011. *Hepatitis Disease Diagnosis Using Backpropagation and The Naive Bayes Classifiers*. Mevlan University, Turkey.
- KUSRINI. 2007. *Strategi Perancangan dan Pengelolaan Basis Data*. Yogyakarta: Andi.
- KUSRINI. 2008. *Aplikasi Sistem Pakar Menentukan Faktor Kepastian Pengguna dengan Metode Kuantifikasi Pertanyaan*. Yogyakarta: Andi.
- MUNANDAR, TB AI, dkk. 2012. *The Use of Certainty Factor with Multiple Rules for Diagnosing Internal Disease*. Universitas Serang Raya, Banten.
- MUSTIKADEWI P. dkk. 2013. *Aplikasi Sistem Pakar Untuk Pendeteksian dan Penanganan Dini pada Penyakit Sapi dengan Metode Dempster-Shafer Berbasis Web*. Universitas Brawijaya, Malang.
- PRASETYO, EKO. 2012. *Data Mining-Konsep dan Aplikasi Menggunakan MATLAB*. Yogyakarta: Andi.
- RAHMAT, BAGUS HARIANTO. 2012. *3 Jurusan Sukses Menggemukkan Sapi Potong*. Jakarta: PT. Agro Media Pustaka.
- SUTOJO, T., dkk. 2011. *Kecerdasan Buatan*. Yogyakarta: Andi.