

# Sentiment Analysis pada Movie Review dengan Pendekatan Klasifikasi dalam Algoritma J.48

*by* Bagus Setya Rintyarna

---

**Submission date:** 15-Oct-2018 01:25PM (UTC+0700)

**Submission ID:** 1020078131

**File name:** 4\_Sentiment\_analysis\_pada\_movie\_review.pdf (674.62K)

**Word count:** 2313

**Character count:** 13771

# **Sentiment Analysis pada Movie Review dengan Pendekatan Klasifikasi dalam Algoritma J.48**

1

**Bagus Setya Rintyarna<sup>1)</sup>**

<sup>1)</sup>Jurusan Teknik Informatika, Fakultas Teknik, Universitas Muhammadiyah Jember

Jl. Karimata No. 49 Jember Kode Pos 68121

Email : <sup>1)</sup>bagus.setya@unmuahember.ac.id

## **ABSTRAK**

Sentiment Analysis yang disebut juga sebagai Opinion Mining adalah topik penelitian yang aktif di bawah *Natural Language Processing* (NLP) yang bertujuan untuk membangun sebuah metode yang dapat diimplementasikan menjadi sebuah tool yang dapat dipergunakan untuk mengekstraksi informasi subyektif berupa sentiment atau opini dalam sebuah data text. Pada penelitian ini akan disimulasikan Sentiment Analysis dengan pendekatan klasifikasi data text. Data text yang digunakan adalah *Large Movie Review Dataset*. Simulasi Sentiment Analysis dengan pendekatan klasifikasi data text akan dilakukan dengan menggunakan tool dari WEKA.

**Kata kunci:** *Hidden Naive Bayes, Naive Bayes Classifier*

## **1. PENDAHULUAN**

19

Apa yang dipikirkan orang menjadi sumber informasi penting dalam proses pengambilan keputusan oleh sebuah perusahaan (Pang & Lee, 2008) dalam rangka meningkatkan ekspansi produk mereka. Saat ini, untuk mengetahui apa yang dipikirkan orang, tidak perlu lagi dilakukan survey. Perkembangan Platform Web 2.0 memungkinkan konsumen untuk membagi pikiran atau pendapat mereka terhadap sebuah produk secara online (Zabin, 2008). Apa yang mereka lakukan yaitu memberikan pendapat mereka akan sebuah produk secara online inilah yang kita kenal dengan istilah *Consumer Review*. Menurut Pang (Pang & Lee, 2008) 81% pengguna internet telah melakukan *online research* akan sebuah produk setidaknya sekali. Hal tersebut menunjukkan potensi besar *Consumer Review* sebagai alat pengambilan keputusan bagi produsen karena *Consumer Review* sangat berpengaruh dalam membentuk opini calon konsumen akan sebuah produk.

Analisis Sentimen (*Sentiment Analysis*) atau disebut juga sebagai *Opinion Mining* adalah sebuah studi komputasional dalam bidang *Natural Language Processing* (NLP) yang bertujuan untuk menentukan nilai sentimen dalam sebuah dokumen teks (Liu, 2012) baik berasal dari product review, movie review maupun political review. Nilai sentimen dapat berupa pendapat, sikap maupun emosi terhadap entitas. Analisis sentimen dapat dikategorikan dalam aktivitas klasifikasi, yaitu mengelompokkan sentimen dalam sebuah data text ke dalam tiga kelas, yaitu positive, negative atau neutral. Entitas dalam data text yang menjadi obyek studi dan ditentukan nilai sentimennya dapat berupa sebuah dokumen, kalimat atau sebuah fitur spesifik. Dengan demikian muncul istilah Document-Level SA, Sentence-Level SA dan Aspect-Level SA (Medhat, Hassan, & Korashy, 2014).

Dua macam teknik klasifikasi sentimen yang dipergunakan dalam opinion mining adalah *Machine Learning*

*Approach* dan *Lexicon Based Approach* (Medhat et al., 2014). Pada *Machine Learning Approach*, sentiment dapat diklasifikasi dengan pendekatan metode supervised learning maupun unsupervised learning. Sedangkan pada *Lexicon-Based Approach*, nilai sentiment dapat ditentukan berbasis Dictionary ataupun berbasis Corpus. Keberhasilan pendekatan berbasis Machine Learning sangat ditentukan oleh keberhasilan mengekstraksi dan memilih fitur yang dipergunakan untuk mendeteksi sentiment. Sedangkan keberhasilan analisis sentiment pada pendekatan *Lexicon-Based* sangat tergantung pada kelengkapan koleksi terms, frase, idiom yang ada dalam koleksi yang digunakan (Guerini, Gatti, & Turchi, 2013).

Pada penelitian yang berjudul “*Sentiment Analysis pada Movie Review dengan Pendekatan Klasifikasi dalam Algoritma J.48*” ini akan disimulasikan model sentiment analysis dengan pendekatan klasifikasi. Dataset yang disimulasikan adalah Movie Review dan algoritma yang digunakan adalah J.48.

## 2. TINJAUAN PUSTAKA

### 2.1 Sentiment Analysis

Sentiment Analysis yang disebut juga sebagai Opinion Mining adalah topik penelitian yang aktif di bawah *Natural Language Processing* yang bertujuan untuk membangun sebuah metode yang dapat diimplementasikan menjadi sebuah tool yang dapat dipergunakan untuk mengekstraksi informasi subjektif berupa sentiment atau opini dalam sebuah data text (Pozzi, Fersini, Mesina, & Liu, 2017). Menurut Pozzi, beberapa task dalam *Sentiment Analysis* antara lain adalah: Subjectivity Classification, Polarity Classification (meliputi Aspect-based Sentiment Classification, Contextual Polarity Disambiguation, Sentiment

Rating Prediction, Cross Domain Sentiment Classification, Cross Language Sentiment Classification), Opinion Summarization, Opinion Visualization, Sarcasm Detection, Entity and Opinion Holder Extraction, Coreference Resolution and Word Sense Disambiguation, Sentiment Lexicon Generation, Opinion Search and Retrieval dan Opinion Spam Detection. Dengan demikian *Sentiment Analysis* memiliki aktifitas riset yang cukup luas dan terbuka lebar.

Menurut Liu (Liu, 2012), opini dapat diformalisasi dalam bentuk quintuple :

$$e_i, a_{ij}, s_{ijkl}, h_k, t_i \quad (1)$$

di mana  $e_i$  adalah nama entity,  $a_{ij}$  adalah aspect,  $s_{ijkl}$  adalah nilai sentiment dari aspect,  $h_k$  adalah opinion holder, dan  $t_i$  adalah waktu ketika opini diekspresikan. Dengan kata lain, salah satu task *Sentiment Analysis* adalah mengubah informasi tidak tersusun (unstructured information) dalam *Consumer Review* menjadi bentuk informasi yang tersusun (structured information) dalam rangka memudahkan proses pengambilan keputusan. Berikut adalah sebuah contoh *Consumer Review* dari amazon pada Gambar 1.

Informasi dalam *Consumer Review* di atas adalah informasi yang tidak tersusun, dan menjadi salah satu tujuan dari *Sentiment Analysis* adalah mengkonversi informasi yang tidak tersusun tersebut menjadi bentuk informasi yang tersusun seperti salah satunya yang dijelaskan Liu (Liu, 2012) dengan mengekstraksi  $e_i, a_{ij}, s_{ijkl}, h_k, t_i$ .

Berdasarkan granularity-nya, menurut Pozzi (Pozzi et al., 2017) *Sentiment analysis* dapat dibagi menjadi 3 level yaitu : 1) Aspect Level,

Nice handheld label printer with QWERTY keyboard.

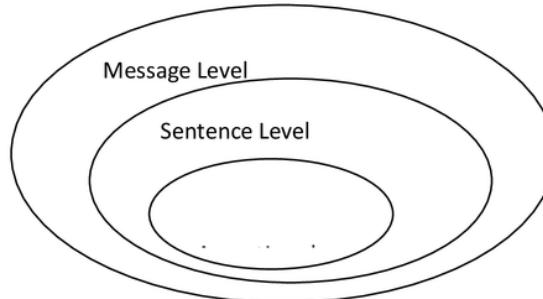
By [Nathan Kull](#) on March 23, 2012

Style Name: MachineSize: LM 160 Verified Purchase

Most of the handheld label printers are built using ABC keyboards vs. the QWERTY keyboard, and that was a key factor in my decision to buy this scanner. Some people have claimed that using DYMO label makers vs. Brother label makers will save money as the DYMO does waste less label when printing, this is both true and false --- I will explain more further down in this review.

I would like to add to this review a comment about batteries, there has been multiple comments about this label maker "eating batteries"; I have used up trial cartridge and many labels into my second cartridge and have not changed the batteries in this unit. I am using Eneloop Rechargeable batteries and they have performed flawlessly. Keep in mind that this would be a higher drain type of device when printing and cheap "Super Duty" (Non-alkaline or cheap Rechargeable) batteries are probably not going to work well. As always, I recommend the investment inEneloop batteries with a good charger (LaCrosse BC-700)

Gambar 1. Contoh Consumer Review dari Amazon ([www.amazon.com](#))



Gambar 2. SA berdasarkan Granularity (Pozzi et al., 2017)

2) Sentence Level dan 3) Message Level yang secara sederhana dapat digambarkan seperti Gambar 2.

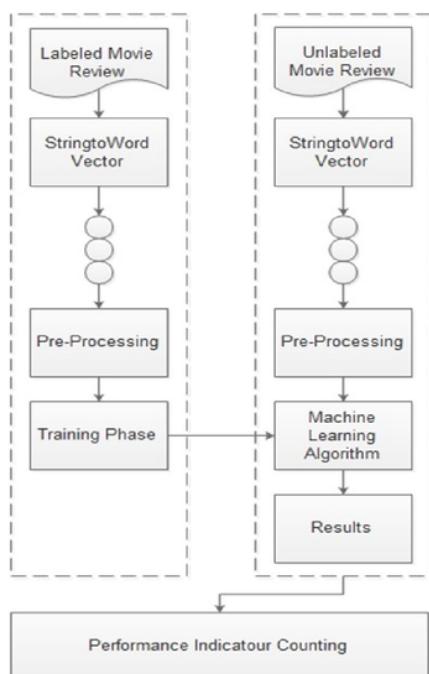
Dua pendekatan yang umum digunakan untuk mengekstraksi informasi tidak terstruktur dari sebuah data Review menjadi suatu bentuk informasi terstruktur adalah : 1) Lexicon-Based dan 2) Machine Learning-Based (Medhat et al., 2014). Contoh pendekatan Machine Learning adalah seperti yang dilakukan oleh : Scrauwen (Scrauwen, 2010), Hsu (Hsu & Wu, 2010), Hemalatha, dan

Khairnar (Hemalatha, Varma, & Govardhan, 2013).

Scrauwen (Scrauwen, 2010) melakukan Sentiment Analysis berbasis klasifikasi dengan menggunakan algoritma Naïve Bayes, Maximum Entropy dan Decision Tree Classifier. Evaluasi performance dilakukan dengan mengukur Accuracy, Precision dan Recall dengan pendekatan N-fold Cross Validation. Sedangkan Hsu dan Wu (Hsu & Wu, 2010) bertujuan mengekstraksi emosi manusia dari data text dengan pendekatan yang diusulkan.

### 3. METODE PENELITIAN

Klasifikasi adalah proses membangun model kelas dari seperangkat dataset yang memiliki label kelas tertentu (Kaur, 2014). Tahap pertama yang dilakukan adalah Tahap Training dan tahap kedua adalah Tahap Klasifikasi di mana dalam penelitian ini akan dilakukan dengan algoritma J.48 dari WEKA. Ekstraksi fitur text dilakukan dengan menggunakan *String to Word Vector* dari WEKA. Untuk meningkatkan performance klasifikasi dilakukan tahap Pre-Processing. Tahap terakhir adalah analisis kinerja algoritma J.48 dengan 10 fold Cross Validasi.



Gambar 3. Tahapan Penelitian

Simulasi Sentiment Analysis dengan pendekatan klasifikasi data text akan dilakukan dengan menggunakan tool dari WEKA (Hall et al, 2009). WEKA<sup>1</sup> (*The*

<sup>12</sup>  
<sup>1</sup><http://www.cs.waikato.ac.nz/ml/weka/>

*Waikato Environment for Knowledge Analysis*) adalah sebuah unified workbench yang memungkinkan peneliti untuk mendapatkan akses yang mudah untuk mengimplementasikan teknik Machine Learning terkini termasuk di dalamnya untuk implementasi Text Mining. WEKA memungkinkan untuk melakukan *Pre Processing*, Klasifikasi, Klustering, Select Attribute dan Visualisasi Hasil..

Machine Learning Algorithm yang digunakan untuk klasifikasi data adalah J.48 dari WEKA. J.48 adalah pengembangan dari ID3 di mana pada J48 ditambahkan fitur untuk menangani *missing value*, *pruning*, *continuous attribute value range* dan *derivation of rule* (Kaur, 2014).

Sedangkan dataset yang akan digunakan untuk simulasi adalah dataset Large Movie Review Dataset<sup>2</sup> dari Stanford (Andrew et al, 2011). Dataset terdiri dari 2000 Movie Review yang terbagi menjadi 2 kelas, yaitu kelas positive dan kelas negative. Contoh dataset Movie Review dari Stanford dapat dilihat pada Gambar 4.

Paramater yang nantinya digunakan dalam penelitian ini untuk mengevaluasi kinerja algoritma yang digunakan adalah TP Rate, FP Rate, Precision, dan F Measure serta ROC. Confusion matrix yang menggambarkan hasil pengujian suatu data uji dapat dilihat pada Tabel 1. di mana<sup>11</sup> ada 4 kondisi hasil pengujian data uji yaitu : True Positive (TP), False Positive (FP), False Negative (FN) dan True Negative (TN).

Tabel 1. Confusion Matrix untuk Evaluasi Performance

16 Test Outcome	Condition	
	Positive	Negative
Positive	TP	FP
Negative	FN	TN

<sup>23</sup><http://ai.stanford.edu/~amaas/data/sentiment/>

2 films adapted from comic books have had plenty of success , whether they're about superheroes ( batman , superman , spawn ) , or geared toward kids ( casper ) or the arthouse crowd ( ghost world ) , but there's never really been a comic book like from hell before.

for starters , it was created by alan moore ( and eddie campbell ) , who brought the medium to a whole new level in the mid '80s with a 12-part series called the watchmen.

to say moore and campbell thoroughly researched the subject of jack the ripper would be like saying michael jackson is starting to look a little od .

the book ( or " graphic novel , " if you will ) is over 500 pages long and includes nearly 30 more that consist of nothing but footnotes.

in other words , don't dismiss this film because of its source.

if you can get past the whole comic book thing , you might find another stumbling block in from hell's directors , albert and allen hughes.

getting the hughes brothers to direct this seems almost as ludicrous as casting carrot top in , well , anything , but riddle me this : who better to direct a film that's set in the ghetto and features really violent street crime than the mad geniuses behind menace ii society ?

the ghetto in question is , of course , whitechapel in 1888 london's east end .

Gambar 4. Contoh Kutipan Dataset Movie Review

#### 4. HASIL DAN PEMBAHASAN

Hasil eksperimen simulasi Sentiment Analysis dengan pendekatan klasifikasi berbasis algoritma J48 dari WEKA akan disajikan pada sub bab berikut ini. Pada tahap pertama dilakukan filter attribute StringToWordVector di mana dari 2000 dataset movie review (1000 kelas positive dan 1000 kelas negative) didapatkan 1166 word vector. Salah satu contoh word vector yang berhasil diekstraksi misalnya adalah kata *actors* seperti terlihat pada Tabel 2 yang muncul sebanyak 1486 kali di kelas negative dan 514 kali di kelas positive. Beberapa word vector lain yang berhasil diekstraksi dapat dilihat pada Tabel 2.

Tabel 2. Contoh Word Vector yang diekstraksi

Word Vector	Frekuensi di kelas	
	Negative	Positive
able	1710	290
about	540	1460
absolutely	1834	166
across	1806	194
act	1773	227
acting	1471	529
action	1465	535

Word Vector	Frekuensi di kelas	
	Negative	Positive
actor	1591	409
actors	<b>1486</b>	<b>514</b>
actress	1850	150
actual	1875	125
actually	1426	574
add	1835	165
after	937	1063

Hasil klasifikasi dataset movie review dengan J.48 dengan filter StringToWordVector (NullStemmer) menghasilkan model Tree sebanyak 411 dan Leave sebanyak 206. Hasil evaluasi klasifikasinya dengan 10-folds cross validation dapat dilihat pada Tabel 3 (Hasil Eksperimen 1).

Tabel 3. Hasil Eksperimen 1

Class	TP Rate	FP Rate	Prec	Rec	F-Meas
Neg	0.648	0.338	0.657	0.648	0.653
Pos	0.662	0.352	0.653	0.662	0.657

Parameter	Value
Correctly Classified Instances	65.5%
Incorrectly Classified Instances	34.5%
Kappa Statistic	0.31
Mean Absolute Error	0.3454
Root Mean Squared Error	0.5657

Dengan algoritma yang sama, hasil tersebut dapat ditingkatkan dengan memperhatikan frekuensi *word vector* dalam tiap document, dengan setting *StringToWordVector* (*IDFTtransform* = True, *IFTTransform* = True) dan *Stemmer* = *IteratedLoviStemmer* maka hasilnya adalah *Leave* sebanyak 202 dan *Tree* sebanyak 403. Hasil evaluasi dengan 10-folds cross validation dapat dilihat pada Tabel 4.

**Tabel 4. Hasil Eksperimen 2**

Class	TP Rate	FP Rate	Prec	Rec	F-Meas
Neg	0.653	0.335	0.661	0.653	0.657
Pos	0.665	0.347	0.657	0.665	0.661

Parameter	Value
Correctly Classified Instances	65.9%
Incorrectly Classified Instances	34.1%
Kappa Statistic	0.318
Mean Absolute Error	0.3443
Root Mean Squared Error	0.5692

Hasil tersebut menunjukkan adanya peningkatan dengan menghitung *frequency word vector* dalam *document review*.

## 5. KESIMPULAN DAN SARAN

Dari hasil pengujian dapat disimpulkan dua hal. Pertama, Sentiment Analysis dapat dilakukan dengan pendekatan klasifikasi data text. Kedua, Perhitungan frequency *word vector* dalam *review document* dapat meningkatkan hasil klasifikasi data text dengan algoritma J.48.

## DAFTAR PUSTAKA

Guerini, M., Gatti, L., & Turchi, M. (2013). Sentiment Analysis: How to Derive Prior Polarities from SentiWordNet, (October), 1259–1269.

- 8 Hemalatha, I., Varma, G. P. S., & Govardhan, A. (2013). Sentiment Analysis Tool using Machine Learning Algorithms, 2(2).
- 7 Hsu, R., & Wu, A. (2010). Machine Learning for Sentiment Analysis on the Experience Project. <http://cs229.stanford.edu/>.
- 6 Kaur, G. (2014). Improved J48 Classification Algorithm for the Prediction of Diabetes. *International Journal of Computer Application*, 98(22), 13–17.
- 5 Liu, B. (2012). Sentiment Analysis and Opinion Mining. *Synthesis Lectures on Human Language Technologies*, 5(1), 1–167. <http://doi.org/10.2200/S00416ED1V01Y201204HLT016>
- 4 Medhat, W., Hassan, A., & Korashy, H. (2014). Sentiment analysis algorithms and applications: A survey. *Ain Shams Engineering Journal*, 5(4), 1093–1113. <http://doi.org/10.1016/j.asej.2014.04.011>
- 13 Pang, B., & Lee, L. (2008). Opinion Mining and Sentiment Analysis, 2, 1–135. <http://doi.org/10.1561/1500000001>
- 10 Pozzi, F. A., Fersini, E., Mesina, E., & Liu, B. (2017). Sentiment Analysis in Social Networks, 1–11.
- Schrauwen, S. (2010). CTRS-001. *Computational Linguistics and Psycholinguistics Technical Report Series*.

# Sentiment Analysis pada Movie Review dengan Pendekatan Klasifikasi dalam Algoritma J.48

## ORIGINALITY REPORT



## PRIMARY SOURCES

1	Submitted to iGroup Student Paper	2%
2	bai-conference.org Internet Source	2%
3	boa.unimib.it Internet Source	2%
4	www.isaet.org Internet Source	1%
5	www.cs.iastate.edu Internet Source	1%
6	scholars.wlu.ca Internet Source	1%
7	Thomas T. H. Wan. "Chapter 5 Poly Chronic Disease Epidemiology: A Global View", Springer Nature, 2018 Publication	1%
8	Submitted to Institute of Graduate Studies, UiTM	1%

9	taufiqabd.blogspot.com Internet Source	1 %
10	Submitted to Universidad Carlos III de Madrid Student Paper	1 %
11	repository.its.ac.id Internet Source	1 %
12	decisiontrees.net Internet Source	1 %
13	Submitted to Universiti Kebangsaan Malaysia Student Paper	<1 %
14	digilib.unila.ac.id Internet Source	<1 %
15	docsslide.us Internet Source	<1 %
16	Te-Chang Cheng. "System Failure Forewarning Based on Workload Density Cluster Analysis", 2011 International Conference on Technologies and Applications of Artificial Intelligence, 11/2011 Publication	<1 %
17	V. Baby Deepa, P. Thangaraj, S. Chitra. "Investigating principal component analysis for classification of EEG data", 2010 International Conference on Networking and Information	<1 %

# Technology, 2010

Publication

---

18

[www.icoci.cms.net.my](http://www.icoci.cms.net.my)

Internet Source

<1 %

19

[gmt72896binsenior.blogspot.com](http://gmt72896binsenior.blogspot.com)

Internet Source

<1 %

---

Exclude quotes

Off

Exclude matches

Off

Exclude bibliography

Off