

# Klasifikasi Analisis Sentimen Pada Gambar Meme Politik Dengan Library Tesseract Dan Algoritme Support Vector Machine

Eko Sanjaya<sup>1)</sup>, Agi Prasetiadi<sup>2)</sup> Wahyu Andi Saputra<sup>3)</sup>

<sup>1,2,3)</sup>Program Studi Teknik Informatika, Fakultas Teknik Industri dan Informatika,  
Institut Teknologi Telkom Purwokerto

Jl. D.I Panjaitan, No 128, Karangreja, Purwokerto Kidul, Kabupaten Banyumas, Jawa Tengah

Accepted on 12-08-2019

## Abstract

Meme merupakan penyebaran informasi dalam bentuk gambar. Berdasarkan data yang diperoleh, pengembangan meme mulai meningkat menjelang pemilu 2019. Informasi yang diperoleh dari meme politik beragam. Salah satunya memberikan dukungan untuk suatu partai atau tokoh politik atau digunakan untuk mengkritik / mencaci-maki partai politik atau tokoh. Sehingga diperlukan suatu sistem yang dapat mengklasifikasikan meme berdasarkan kelas. Penelitian ini bertujuan untuk menciptakan sistem yang dapat mengklasifikasikan meme politik berdasarkan kelas. Algoritma yang akan digunakan dalam mengklasifikasikan adalah Support vector machine (SVM) dengan ekstraksi fitur TF-IDF. Library yang akan digunakan dalam optical character recognition (OCR) adalah Tesseract. Berdasarkan hasil pengujian diketahui bahwa akurasi yang dihasilkan oleh SVM linier lebih baik daripada SVM non-linear. Akurasi terbaik dalam SVM linear dengan kombinasi TF-IDF adalah 75.71%.

**Kata Kunci:** Analisis sentimen, Meme politik, Ocr-tesseract, Support Vector Machine

## I. INTRODUCTION

Perkembangan teknologi dan informasi yang sangat pesat, memudahkan masyarakat berkomunikasi dengan yang lainnya. Perkembangan teknologi informasi ini, tidak luput dari perkembangan internet yang terus meningkat. Adanya internet, setiap manusia memiliki akses untuk dapat mencari dan memberikan informasi yang dibutuhkan. Dalam penyebaran informasi di social media mulai beragam, salah satunya menyebarkan informasi dalam bentuk teks gambar yang juga disebut *meme*. Istilah *meme* pertama kali dipopulerkan oleh Richard Dawkins dalam bukunya *The Selfish Gene*(1976). Menurut pemahaman Dawkins, *meme* adalah bentuk dari gen kebudayaan (ide, gagasan, pola perilaku, dan sebagainya) yang menyebar melalui proses imitasi, seperti halnya lagu, jargon, mode pakaian, hingga cara membangun gedung[1].

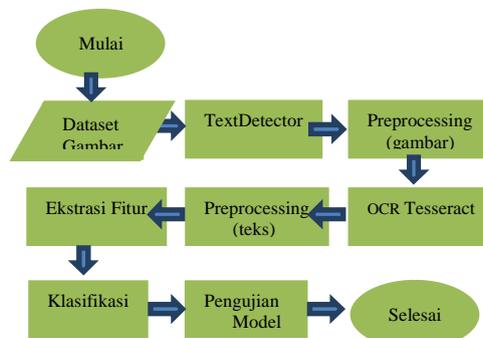
Penyampain informasi menggunakan *meme* mulai populer dikalangan masyarakat dalam belakangan ini. Kepopuleran tersebut ditunjukkan dengan adanya website-website *meme* seperti *1cak.com* dan *memecomid.id*. Dengan adanya website tersebut masyarakat sering menggunakan *meme* di akun sosial media. *Meme* dapat dikategorikan menjadi dua[2], pertama *meme* ringan seperti *meme* candaan, motivasi, dan olahraga. Sedangkan *meme* kedua adalah *meme* yang berat seperti membahas pemerintahan dan politik. Kelebihan *meme* dalam penyampain informasi adalah menambahkan daya tarik masyarakat dalam membaca dan dapat mempermudah dalam menangkap informasi. Sekarang ini *meme* berat mulai sering digunakan oleh pendukung suatu partai politik untuk mendukung suatu partai atau tokoh politik yang didukung ataupun digunakan untuk mengkritik/ mencaci-maki suatu partai politik lain atau tokoh lain karena rasa ketidaksukaannya.

Dalam penggalian data dapat menggunakan *Text Mining*. Dengan menggunakan *Text Mining*, peneliti mendapatkan informasi yang berguna dan dapat meningkatkan pengetahuan bagi peneliti. *Text mining* dapat diterapkan dalam beberapa bidang, salah satunya adalah Analisis Sentimen. Analisis sentimen adalah bidang studi yang menganalisis pendapat seseorang, sentimen seseorang, evaluasi seseorang, sikap seseorang dan emosi seseorang ke dalam bahasa tertulis[3].

*Text Mining* juga dapat berfungsi sebagai klasifikasi, yang prosesnya untuk menemukan model untuk menggambarkan class atau konsep dari suatu data, dan juga digunakan untuk mendeskripsikan data penting serta dapat memprediksi data pada masa depan. Pada penelitian ini, data yang akan dianalisis adalah data berupa text yang diambil dari gambar *meme* yang didapatkan dari media sosial, khususnya *meme* mengenai politik.

Proses klasifikasi *meme* dapat dilakukan dengan menggunakan *Library Tesseract* untuk mengubah teks gambar/*meme* menjadi teks digital dan algoritma *Support vector machine (SVM)* digunakan untuk mengklasifikasi teks menjadi tiga kelas yaitu, kelas *meme* positif, kelas *meme* netral dan kelas positif. Tujuan dari penelitian ini adalah mendapatkan nilai akurasi menggunakan *Library Tesseract* dan Algoritme *Support Vector Machine (SVM)*.

## II. RESEARCH METHOD



Gambar 1. Tahapan Penelitian

### A. Pengumpulan Dataset

Pada tahap ini pengumpulan dataset didapatkan dari postingan atau komentar di social media (Facebook, instagram dan twitter). Gambar yang diambil memiliki ketentuan seperti gambar minimal berukuran 320x320 pixel, teks mudah dibaca oleh system, background dari karakter harus kontras atau tidak memiliki background. Dataset yang digunakan dalam penelitian ini adalah 444 gambar *meme* dan diambil 31 sampel gambar *meme* secara random untuk dilakukan pengujian data baru.

### B. TextDetector

*Textdetector* adalah menentukan suatu keberadaan objek (teks) dan ruang lingkungnya serta lokasi didalam sebuah gambar[4]. Tahapan *text detector* dalam penelitian ini menggunakan penelitian yang telah dilakukan oleh Zhou Xinyu dkk yaitu system *EAST: An Efficient and Accurate Text Detector*[5]. *Text detector EAST* memiliki kelemahan tidak dapat memotong teks secara sempurna, Sehingga penulis memodifikasi system *EAST* agar dapat memotong teks dengan sempurna.



Gambar 2. Text Detector



Gambar 3. Hasil Memotong Text Detector

### C. Preprocessing (Gambar)

*Preprocessing* pada gambar menjadi salah satu tahapan terpenting yang bertujuan untuk menghilangkan noise dan menyederhanakan gambar agar mudah dikelola saat tahap OCR tesseract. *Preprocessing* pada gambar terdiri lima tahap, yaitu:

1. Grayscale: menyederhanakan gambar.
2. Blur: mengurangi noise dan mengurangi detail.
3. Threshold: mengatur jumlah derajat keabuan pada citra.
4. Erosion: mengikis batas-batas tepi objek dan menghapus semua pixel yang dekat dengan batas. Sehingga erosion dapat menghilang/menghapus noise kecil.
5. Dilation: mempertebal font yang telah dikikis oleh tahap erosion dan dapat meningkat ukuran teks sehingga dapat mempermudah dalam pengenalan karakter.



Gambar 4. Hasil Preprocessing Pada Gambar

### D. OCR Tesseract

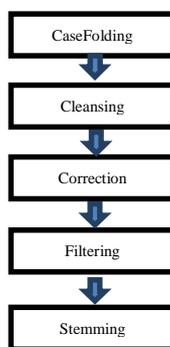
OCR tesseract adalah tahapan mengekstrak teks didalam gambar menjadi teks digital dengan menggunakan library tesseract dengan akurasi tinggi. Tesseract dikembangkan sebagai perangkat lunak berpemilik oleh Hewlett Packard Labs. Pada tahun 2005, itu terbuka bersumber dari HP bekerja sama dengan University of Nevada, Las Vegas. Sejak 2006 telah dikembangkan secara aktif oleh Google dan banyak kontributor open source[6].



Gambar 5. Hasil OCR Tesseract

E. *Preprocessing(Teks)*

*Preprocessing* pada teks adalah tahapan memperbaiki teks hasil OCR tesseract yang belum sempurna dan juga berguna untuk mempersiapkan data teks menjadi lebih struktur. Tahapan *preprocessing* pada teks terdiri lima, yaitu:



Gambar 6. Tahapan Preprocessing

1. *CaseFolding*: merubah karakter menjadi bentuk standard (*uppercase* atau *lowercase*).
2. *Cleansing*: menghapus karakter seperti symbol, tanda Tanya dan angka.
3. *Correction*: memperbaiki ejaan yang tidak sesuai dengan KBBI tapi dapat diperbaiki dan menghapus ejaan yang tidak sesuai dengan KBBI atau benar-benar tidak dapat diperbaiki akan dihapus[7].
4. *Filtering*: membuang kata yang tidak memiliki arti atau kata yang sering muncul seperti kata “dari”, “dan”, “yang” dan lain-lain.
5. *Stemming*: mengubah kata berimbuhan menjadi kata dasar sesuai dengan kamus KBBI. System kerja dari stemming adalah menghapus awalan kata (prefiks), akhiran (sufiks) dan gabungan awalan dan akhiran (konflik)[8].

TABEL I  
 PREPROCESSING TEKS

No	Proses	Hasil
1	Teks asli	TERUNGKAP Penuntut Facebook Sebesar 1 Trivun Ternyata ORANG GILA
2	Casefolding	terungkappenuntutfacebooksebesar 1 trivun ternyata orang gila
3	Cleansing	terungkappenuntutfacebooksebesartrivun ternyata orang gila
4	Correction	terungkappenuntutsebesartriliun ternyata orang gila
5	Filtering	terungkappenuntuttriliun orang gila
6	Stemming	ungkaptuntuttriliun orang gila

#### F. Ekstraksi Fitur

Ekstraksi fitur yang digunakan adalah metode *Term Frequency Inverse Document Frequency* (TF-IDF). Metode TF-IDF adalah metode untuk menghitung bobot setiap kata yang paling umum digunakan pada informasi retrieval[9]. Metode TF-IDF merupakan perhitungan *Term frequency* (TF) dengan *Inverse Document Frequency* (IDF) pada tiap term disetiap dokumen dalam korpus. Berikut merupakan rumus dari persamaan TF-IDF.

$$W_{dt} = TF_{dt} \times IDF_t \quad (1)$$

*Invers document frequency* (IDF) menunjukkan ketersediaan sebuah kata (term) dalam seluruh dokumen. Semakin sedikit dokumen mengandung term maka semakin besar nilai IDF.

$$IDF_t = \log\left(\frac{D}{df}\right) \quad (2)$$

Dimana:

- D adalah total dokumen
- df adalah banyak dokumen yang mengandung term
- TF adalah jumlah atau frekuensi kemunculan term *t* dalam dokumen *d*
- W adalah bobot dokumen ke-*d* terhadap kata term ke-*t*

#### G. Klasifikasi

Tahapan klasifikasi menggunakan algoritma *support vector machine*. Algoritma *support vector machine* dibagi menjadi dua yaitu *support vector machine* linier dan *support vector machine* non-linear.

##### 1) Support Vector Machine

*Support vector machine* adalah suatu teknik untuk prediksi, baik dalam kasus klasifikasi maupun regresi. Algoritma ini masuk kelas *supervised learning* dimana dalam implementasinya perlu adanya tahap training menggunakan *sequential training* kemudian disusul tahap *testing*[10]. Konsep *support vector machine* (SVM) adalah membentuk *hyperplane* terbaik yang berfungsi untuk memisahkan dua kelas atau lebih. *Hyperplane* merupakan garis atau bidang datar yang memiliki tujuan untuk memisahkan dua kelas data.

$$\text{Hyperplane} \quad \vec{w} \cdot \vec{x} + b = 0 \quad (3)$$

Data kelas negative dan kelas positif dapat dirumuskan sebagai berikut:

$$\text{Kelas negatif} \quad \vec{w} \cdot \vec{x} + b \leq -1 \quad (4)$$

$$\text{Kelas positif} \quad \vec{w} \cdot \vec{x} + b \geq +1 \quad (5)$$

Persamaan *Support vector machine* sebagai berikut:

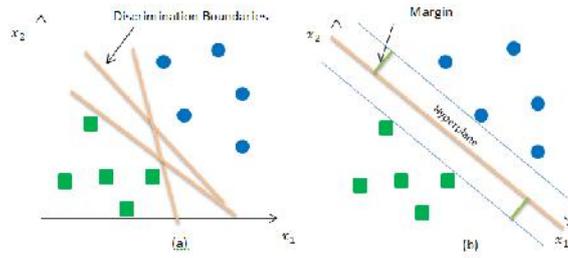
$$f(x) = w \cdot x + b \quad (6)$$

Atau

$$f(x) = \sum_{i=1}^m \alpha_i y_i K(x_i, x_j) + b \quad (7)$$

Dimana:

- w adalah Parameter *Hyperplane* yang dicari
- x adalah nilai masukan atribut
- b adalah nilai bias

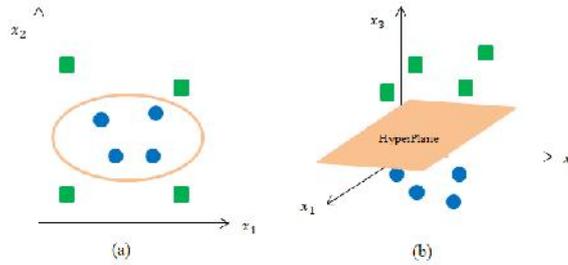


Gambar 6. (A) Gambar *Hyperplane* Yang Mungkin Dan (B) Gambar *Hyperplane* Dengan Margin Terbaik

2) *Support Vector Machine Non-linear & Kernel Trick*

Pada dasarnya masalah di dunia nyata (*real world problem*) jarang bersifat *linear separable* dan umumnya masalah bersifat *non-linear*. SVM dimodifikasi dengan memasukan fungsi kernel. Dalam SVM *non-linear*, pertama data (x) akan naikan ruang vector menjadi berdimensi lebih tinggi dengan fungsi (x)[11].

$$\phi(x_{i,j}) = \phi(x_i) \cdot \phi(x_j) \tag{6}$$



Gambar 7. Fungsi (X) Memetakan Data Ke Ruang Vector Yang Berdimensi Lebih Tinggi

3) *Pengujian*

Pengujian dilakukan dua tahap yaitu pengujian pada model dan pengujian pada sampel baru. Pengujian model menggunakan *K-Fold Cross Validation* dan pengujian pada sampel baru menggunakan *Confusion matrix*. *K-Fold Cross Validation* adalah teknik validasi dengan membagi data secara acak kedalam K bagian dan masing-masing akan dilakukan proses klasifikasi[12].



Gambar 8. *K-Fold Cross Validation*

*Confusion matrix* merupakan sebuah metode yang biasa digunakan untuk melakukan pengukuran pada suatu *classifier* dalam melakukan prediksi dari kelas yang berbeda[13].

TABEL II  
 CONFUSION MATRIX (3X3)

Confusion Matrix		NilaiPrediksi		
		A	B	C
NilaiSebenarnya	A	AA	AB	AC
	B	BA	BB	BC
	C	CA	CB	CC

$$\text{Akurasi} = \frac{AA+BB+CC}{AA+AB+AC+BA+BB+BC+CA+CB+CC} \times 100\% \quad (11)$$

$$\text{Presisi} = \frac{Ai}{Ai+Bi+Ci} \times 100\% \quad (12)$$

$$\text{Recall} = \frac{iA}{iA+iB+iC} \times 100\% \quad (13)$$

### III. RESULTS AND DISCUSSION

Hasil penelitian didapatkan dari pengujian akurasi OCR Tesseract, pengujian model SVM *linear* dan *non-linear*, dan pengujian pada data gambar *meme* baru.

#### A. Pengujian Model SVM Linear Dan Non-Linear

Setelah model selesai dibuat, tahap selanjutnya dilakukan pengujian pada model SVM menggunakan metode *K-Fold Cross Validation*.

TABEL III  
 HASIL K-FOLD VALIDATION

No	SVM			
	Linear	RBF	Polynomial	Sigmoid
1	80.95%	69.05%	69.05%	69.05%
2	76.19%	69.05%	69.05%	69.05%
3	83.33%	78.57%	78.57%	78.57%
4	76.19%	73.81%	73.81%	73.81%
5	73.81%	73.81%	73.81%	73.81%
6	71.43%	71.43%	71.43%	71.43%
7	66.67%	66.67%	66.67%	66.67%
8	71.43%	66.67%	66.67%	66.67%
9	78.57%	71.43%	71.43%	71.43%
10	80.95%	71.43%	71.43%	71.43%
Mean	75.95%	71.19%	71.19%	71.19%

Pengujian akurasi model corpus dilakukan beberapa kategori yang bertujuan untuk mendapatkan model corpus dengan akurasi terbaik. Model corpus terbaik akan digunakan untuk melakukan prediksi pada data uji baru. Berdasarkan Tabel diatas bahwa model SVM *Linear* menggunakan ekstrasi fitur TF-IDF memiliki akurasi terbaik.

#### B. Pengujian Pada Data Gambar Meme Baru

Setelah didapatkan model dengan akurasi terbaik, selanjutnya mengimplementasikan model untuk menguji gambar *meme* baru. *Meme* yang akan diujikan sebanyak 31 gambar berdasarkan *Control Limit Theorm*. Metode yang digunakan dalam pengujian gambar *meme* baru adalah Confusion Matrix.

TABEL IV  
HASIL PENGUJIAN MODEL PADA GAMBAR MEME BARU

<i>Confusion Matrix</i>		NilaiPrediksi		
		Negatif	Netral	Positif
NilaiSebenarnya	Negatif	17	1	1
	Netral	2	2	1
	Positif	4	1	2

TABEL V  
HASIL PENGUJIAN MODEL PADA GAMBAR MEME BARU

Klasifikasi	<i>Support Vector Machine</i>	
	Precision	Recall
Negatif	74.00%	89.00%
Netral	50.00%	40.00%
Positif	50.00%	29.00%

TABEL VI  
HASIL AKURASI MODEL PADA GAMBAR MEME BARU

Algoritma	Ekstraksi Fitur	Akurasi
SVM Linier	TF-IDF	67.74%

*Meme* politik dapat dikategorikan kelas positif, jika teks didalam *meme* politik memiliki atribut dengan nilai bobot term yang sesuai dengan nilai bobot term di data training dan *meme* politik memasuki ke ruang kelas positif maka hasil *meme* politik tersebut akan diprediksi sebagai kelas positif. Hal itu juga berlaku pada kelas yang lain.

Suatu *meme* politik yang diprediksi tidak sesuai dengan kelas sebenarnya. Hal ini dikarenakan terdapat beberapa faktor yaitu, Pertama hasil dari OCR Tesseract tidak sesuai dengan teks di dalam gambar *meme* sehingga dalam pembobotan term tidak memiliki nilai bobot sebenarnya. Kedua terdapat kata baru yang belum ada di data training dan tidak memiliki nilai bobot term dan tidak memiliki nilai atribut yang sesuai, sehingga *meme* politik tersebut dapat dekat dengan kelas yang lain dan juga *meme* politik tersebut dapat melewati *Hyperplane* yang dimana dapat memasuki kelas lain.

#### IV. CONCLUSION

Berdasarkan hasil penelitian yang telah dilakukan bahwa SVM dengan kernel *Linear* memiliki akurasi 75.95%, sedangkan SVM *Non-Linear*(dengan kernel RBF, *Polynomial* dan *Sigmoid*) memiliki akurasi 71.19%. Berdasarkan hasil akurasi setiap kernel dapat disimpulkan bahwa SVM *Linear* memiliki akurasi lebih baik daripada SVM *Non-Linear* dalam melakukan pengklasifikasi *meme* politik. Berdasarkan hasil pengujian data baru *mememiliki* akurasi rendah yaitu 67.74%. Hal ini terjadi dikarenakan jumlah data *training* negatif lebih banyak daripada data *training* yang lain. Jadi atribut pada data baru lebih condong ke kelas negatif.

Penelitian selanjutnya, diharapkan menggunakan metode lain dalam optical character recognition (OCR), menambahkan fitur object detector yang lain seperti face detector, Menggunakan ekstraksi fitur lain seperti convert negation atau unigram dan menggunakan algoritma klasifikasi lain seperti naive bayes, decisiontree, K-NN atau neuralnetwork.

## ACKNOWLEDGEMENT

Terimakasih kepada Agi Prasetiadi, S.T., M. Engdan Wahyu Andi Saputra, S.Pd., M. Engselakudosen pembimbing yang senantiasa dalam membimbing laporan jurnal.

## REFERENCES

- [1] R. Dawkins, "The Selfish Gene," *Oxford Univ. Press*, 1976.
- [2] F. Haisar, "Klasifikasi Analisis Sentimen Meme Dengan Metode Optical Character Recognition (OCR) dan Algoritma Naive Bayes," *Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 8, 2018.
- [3] S. Fanissa, M. A. Fauzi, and S. Adinugroho, "Analisis Sentimen Pariwisata di Kota Malang Menggunakan Metode Naive Bayes dan Seleksi Fitur Query Expansion Ranking," *Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 8, pp. 2766–2770, 2018.
- [4] F. Jallad, "Object Detection Using Image Processing," *Moscow Inst. Phys. Technol. Dep. Radio Eng. Cybern.*, vol. 1, no. 1, pp. 1–6, 2016.
- [5] X. Zhou, C. Yao, H. Wen, Y. Wang, S. Zhou, W. He, and J. Liang, "EAST: An Efficient and Accurate Scene Text Detector," *Comput. Vis. Found.*, vol. 1, no. 1, pp. 1–10, 2015.
- [6] V. S. CHANDEL, "Deep Learning based Text Recognition (OCR) using Tesseract and OpenCV," 2018. [Online]. Available: <https://www.learnopencv.com/deep-learning-based-text-recognition-ocr-using-tesseract-and-opencv/>. [Accessed: 28-Dec-2018].
- [7] H. Sujaini and R. D. Nyoto, "Analisis Perbandingan Metode spelling Corrector Peter Norvig dan Spelling Checker BK-Trees pada kata berbahasa Indonesia," *J. Sist. dan Teknol. Inf.*, vol. 5, no. 1, pp. 1–5, 2016.
- [8] L. Agusta, "Perbandingan Algoritma Stemming Porter dengan Algoritma Nazief-Adriani untuk Stemming Dokumen Teks Bahasa Indonesia," in *Konferensi Nasional Sistem dan Informatika*, 2009, pp. 196–201.
- [9] M. Fitri, "perancangan Sistem Temu balik informasi dengan Metode Pembobotan Kombinasi TF-IDF untuk pencarian Dokumen berbahasa Indonesia," *Teknol. Inf. dan Komun.*, vol. 1, no. 1, pp. 1–6, 2018.
- [10] R. S. Perdana and M. A. Fauzi, "Analisis Sentimen Tingkat Kepuasan Pengguna Penyedia Layanan Telekomunikasi Seluler Indonesia Pada Twitter Dengan Metode Support vector machine dan Lexicon Based Features," *Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 1, no. 12, pp. 1725–1732, 2017.
- [11] S. R. Kurniasari, "Implementasi SVM dan Asosiasi untuk Sentiment Analysis Data Ulasan The Phoenix Hotel Yogyakarta pada Situs Tripadvisor," 2018.
- [12] S. E. Lidya, Syahfitri Kartika, Opim Salim Sitompul, "SENTIMENT ANALYSIS PADA TEKS BAHASA INDONESIA MENGGUNAKAN SUPPORT VECTOR MACHINE (SVM)," *Teknol. Inf. dan Komun.*, vol. 2015, no. Sentika, pp. 1–8, 2015.
- [13] M. F. Fibrianda and A. Bhawiyuga, "Analisis Perbandingan Akurasi Deteksi Serangan Pada Jaringan Komputer Dengan Metode Naive Bayes Dan Support vector machine (SVM)," *Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 9, pp. 3112–3123, 2018.