

Deteksi Plagiarisme Source Code Tugas Mahasiswa Menggunakan Algoritma Cosine Similarity dan Pembobotan TF-IDF

I Gede Ariawan Eka Putra^{a1}, I Wayan Supriana^{a2}

^aProgram Studi Informatika, Universitas Udayana

Bali, Indonesia

¹gede.aryawhan@gmail.com

²wayan.supriana@unud.ac.id

Abstract

This study discusses the detection of plagiarism Source Code student assignments. Detection of the similarity of a program is needed which often arises problems related to plagiarism. This problem often occurs in programmer assignments which are often found in student source code. With the problems that arise, the researchers aim to design a system that can detect source code plagiarism in student assignments. The system is designed using the Term Frequency — Inverse Document Frequency (TF-IDF) weighting method for word weighting and the Cosine Similarity Algorithm to calculate the similarity between documents. The stages are designed to achieve the final results of this research which starts from collecting data obtained from the github.com site. The next stage is Preprocessing which aims to correct and prevent errors in the operation of the algorithm. The weight calculation stage uses the Term Frequency — Inverse Document Frequency (TF-IDF) method and the last one uses the Cosine Similarity algorithm to find similarities between the documents being compared. The results of the study are the scores of each document compared, such as the 4th document with the 7th document, the plagiarism score of 75.28% is obtained, assuming that if the score is above 75%, the document experiences plagiarism between the two documents being compared.

Keywords: Cosine Similarity, Plagiarisme, TF-IDF, Source Code, student, documents

1. Pendahuluan

Dalam lingkungan informatika, pendekripsi kemiripan suatu program sangat dibutuhkan. Permasalahan yang sering timbul di lingkungan akademis yang berkaitan dengan informatika yaitu terjadinya plagiarisme terhadap tugas-tugas pemrograman. Plagiarisme itu sendiri adalah meniru topik, mengambil hasil penelitian, serta merangkum karya orang lain dengan tidak mencantumkan sumbernya. Tindakan ini sering ditemukan dalam pengajaran tugas mahasiswa, salah satunya pada tugas praktikum algoritma yang sering ditemui dalam *Source Code* pengajaran tugas mahasiswa. *Source Code* merupakan sekumpulan deklarasi atau pernyataan pada Bahasa pemrograman yang dapat dibaca serta ditulis manusia. Dengan adanya *Source Code*, programmer dapat berkomunikasi dengan komputer menggunakan beberapa perintah yang telah terdefinisi.


Adapun penelitian terkait yang dilakukan oleh Rito dan dkk pada tahun 2019, penelitian tersebut membahas tentang Deteksi Plagiarisme pada Dokumen Jurnal Menggunakan Metode Cosine Similarity yang dimana penelitian tersebut menggunakan algoritma Cosine Similarity untuk menentukan persentase nilai kemiripan antar dokumen. Berdasarkan skenario yang telah di uji coba dilakukan dengan menghitung jumlah dokumen relevan terambil dibagi dengan jumlah dokumen yang ada dalam database kemudian dikali 100%, maka diperoleh nilai recall pada Aplikasi Deteksi Plagiarisme Menggunakan Metode Cosine Similarity yaitu 13%. Sedangkan untuk memperoleh nilai precision dilakukan skenario pengujian dengan menghitung jumlah dokumen relevan terambil dibagi

dengan jumlah dokumen relevan dalam pencarian kemudian dikalikan 100% diperoleh hasil 8%. Maka dari penelitian yang sudah dilakukan tersebut, algoritma *Cosine Similarity* dapat digunakan dalam pendekripsi plagiarisme antar dua dokumen yang dibandingkan [1].

Dengan adanya permasalahan yang sudah disampaikan, maka dari itu peneliti menulis jurnal dengan judul "Deteksi Plagiarisme Source Code Tugas Mahasiswa Menggunakan Algoritma *Cosine Similarity* dan Pembobotan TF-IDF". Penelitian ini nantinya bertujuan untuk mengetahui tingkat score kemiripan antar dokumen dengan menggunakan algoritma *Cosine Similarity* dan pembobotan term *frequency-inverse document frequency* (TF-IDF).

2. Metode Penelitian

Penelitian ini akan memakai data *source code* mahasiswa yang diperoleh dari situs github.com. Selanjutnya, data tersebut akan dicari tingkat score plagiarisme antar dokumen tugas mahasiswa. Adapun tahapan dari pelaksanaan penelitian ini yang dapat dilihat pada Gambar 1.




Gambar 1. Diagram Alir Penelitian

Penelitian ini dimulai dengan Pengumpulan Data yang diperoleh dari situs github.com, yaitu pada soal *shift-sisop*. Data yang digunakan berjumlah 10 *Source Code* yang nantinya akan digunakan untuk pendekripsi plagiarisme. Selanjutnya, data yang berjumlah 10 *Source Code* akan memasuki tahap *preprocessing* dengan metode *Tokenization* dan *Transform case*. Setelah data berhasil pada tahap *preprocessing* maka selanjutnya, dilakukan pembobotan dari setiap data *Source Code* dengan menggunakan metode term *Frequency-Inverse Document Frequency* (TF-IDF). Tahap terakhir adalah menghitung kemiripan antara data *Source Code* tugas mahasiswa dengan menggunakan algoritma *Cosine similarity*.

3. Hasil dan Pembahasan

3.1 *Preprocessing*

Tahap *Preprocessing* merupakan tahap pertama yang sangat penting dilakukan untuk memperbaiki kinerja dan mencegah kesalahan di dalam pengoperasian algoritma. Adapun proses yang akan dilakukan dalam *preprocessing*, yaitu *Tokenization* dan *Transform Case*. Berikut adalah alur dari tahapan *preprocessing* yang dapat dilihat pada Gambar 2.



Gambar 2. Diagram Alir *Preprocessing*

a. *Tokenization*

Pada tahap *Tokenization*, dilakukan proses pemenggalan yang akan dibagi menjadi beberapa bagian. Hal ini dilakukan untuk memudahkan di dalam proses pembobotan dari setiap kata. Berikut adalah hasil dari pemenggalan salah satu data *Source Code* mahasiswa pada Tabel 1.

Tabel 1. Hasil *Tokenization*

Source Code	Hasil <i>Tokenization</i>
<pre> #!/bin/bash # 1. A regex='(?<=ERROR)(.*)(?=)' regex2='(?<=(.).+?(?=))' # 1. B error_message() { grep -oP "\$regex" syslog.log sort uniq -c sort -nr sed 's/^ *[0-9]*\(.*)\n/2,\1/' >> error_message.csv } # 1. C user_statistic() { grep -oP "\$regex2" syslog.log sort uniq while read i do echo "\$i" tr '\n' , grep "\$i" syslog.log grep "INFO" wc -l tr '\n' , grep "\$i" syslog.log grep "ERROR" wc -l done >> user_statistic.csv } # 1. D echo "Error,Count" > error_message.csv error_message # 1. F echo "Username,INFO,ERROR" > user_statistic.csv user_statistic </pre>	bash bin Count csv do done echo ERROR error_message log nr oP read regex regex2 sed sort syslog tr uniq user_statistic Username wc while

b. *Transform Case*

Pada tahap *preprocessing*, selanjutnya adalah *Transform Case*. Hasil dari pemenggalan akan dilakukan penyetaraan karakter, yaitu mengubahnya menjadi huruf kecil. Berikut adalah hasil dari *Transform Case*.

Tabel 2. Hasil *Transform Case*

Tokenization	Hasil <i>Transform Case</i>
bash	bash

bin	bin
Count	count
csv	csv
do	do
done	done
echo	echo
ERROR	error
error_message	error_message
log	log
nr	nr
oP	op
read	read
regex	regex
regex2	regex2
sed	sed
sort	sort
syslog	syslog
tr	tr
uniq	uniq
user_statistic	user_statistic
Username	username
wc	wc
while	while

3.2 Term Frequency — Inverse Document Frequency (TF-IDF)

Tahap selanjutnya adalah menghitung bobot dari setiap dokumen yang nantinya akan dilakukan perhitungan algoritma *Cosine Similarity*. Untuk mencari bobot pada setiap dokumen dapat dilakukan dengan memakai algoritma *Term Frequency — Inverse Document Frequency* (TF-IDF). Tahap pertama adalah melakukan perhitungan *Inverse Document Frequency* (IDF) dengan menggunakan rumus di bawah ini.

$$\log\left(\frac{n}{df}\right) + 1$$

Keterangan. :

n = Jumlah dokumen

t = Jumlah frekuensi kata terpilih

Setelah melakukan perhitungan *Inverse Document Frequency* (IDF) tahap selanjutnya adalah melakukan perhitungan untuk mencari nilai dari *Term Frequency — Inverse Document Frequency* (TF-IDF). Pada tahap ini akan menggunakan rumus seperti di bawah ini.

$$W_{df} = tf_{dt} * IDF_t$$

Keterangan :

d = Dokumen ke-d

t. = Kata ke-t dari kata kunci

w = Bobot dokumen ke-d terhadap kata ke-t

Pada Tabel 3 merupakan nilai dari perhitungan akhir *Term Frequency — Inverse Document Frequency* (TF-IDF).

Tabel 3. Hasil Perhitungan TF-IDF antar dua dokumen

No	Kata	D1	D2
1	1a	0	0.029191416565474984
2	1b	0	0.029191416565474984
3	1c	0	0.029191416565474984
4	1d	0	0.029191416565474984
5	1e	0	0.029191416565474984
6	add	0	0.08757424969642494
7	bash	0.06991457568388007	0.0207699333103817
8	bin	0.06991457568388007	0.0207699333103817
9	cat	0	0.029191416565474984
10	closed	0	0.08757424969642494
11	closedinfo	0	0.08757424969642494
12	closing	0	0.05838283313094997
13	connect	0	0.029191416565474984
14	connectinfo	0	0.08757424969642494
15	connection	0	0.05838283313094997
16	count	0.06991457568388007	0.0207699333103817
17	csv	0.2796583027355203	0.3115489996557255
18	cut	0	0.2043399159583249
19	db	0	0.08757424969642494
20	denied	0	0.08757424969642494
21	denyinfo	0	0.08757424969642494
22	do	0.06991457568388007	0.0207699333103817
23	doesn	0	0.029191416565474984
24	done	0.06991457568388007	0.0207699333103817
25	echo	0.2097437270516402	0.3323189329661072
26	error	0.2796583027355203	0.10384966655190851
27	error_message	0.2796583027355203	0.14538953317267192
28	exist	0	0.05838283313094997
29	existinfo	0	0.08757424969642494
30	f1	0	0.08757424969642494
31	f2	0	0.11676566626189994
32	failed	0	0.08757424969642494
33	file	0	0.029191416565474984
34	found	0	0.029191416565474984
35	grep	0.4194874541032804	0.2284692664141987
36	info	0.13982915136776014	0.0830797332415268
37	information	0	0.17514849939284988
38	log	0.2796583027355203	0.29077906634534384
39	modified	0	0.08757424969642494

40	modinfo	0	0.08757424969642494
41	name	0	0.05838283313094997
42	not	0	0.029191416565474984
43	nr	0.09826249667188093	0
44	op	0.19652499334376186	0
45	permission	0	0.08757424969642494
46	read	0.06991457568388007	0.0207699333103817
47	regex	0.19652499334376186	0
48	regex2	0.19652499334376186	0
49	report	0	0.2043399159583249
50	retrieving	0	0.08757424969642494
51	sed	0.06991457568388007	0.0207699333103817
52	sort	0.2097437270516402	0.062309799931145105
53	syslog	0.2796583027355203	0.24923919972458042
54	the	0	0.08757424969642494
55	ticket	0	0.26272274908927484
56	timeinfo	0	0.08757424969642494
57	timeout	0	0.08757424969642494
58	to	0	0.2919141656547498
59	totalerr	0	0.029191416565474984
60	totalinf	0	0.029191416565474984
61	toterror	0	0.05838283313094997
62	totinfo	0	0.05838283313094997
63	tr	0.19652499334376186	0
64	tried	0	0.08757424969642494
65	uniq	0.13982915136776014	0.062309799931145105
66	updating	0	0.08757424969642494
67	user	0	0.11676566626189994
68	user_statistic	0.2796583027355203	0.0207699333103817
69	username	0.06991457568388007	0.0207699333103817
70	was	0	0.08757424969642494
71	wc	0.13982915136776014	0.1661594664830536
72	while	0.06991457568388007	0.1869293997934353

3.3 Algoritma Cosine Similarity

Setelah melakukan perhitungan terhadap nilai bobot dari *Term Frequency — Inverse Document Frequency* (TF-IDF). Tahap terakhir adalah menghitung nilai total dari masing-masing dokumen dan dokumen pembanding lalu mengurutkan nilai dari total jumlah dokumen tersebut dengan menggunakan rumus di bawah ini.

$$\cos \alpha = \frac{\mathbf{A} \cdot \mathbf{B}}{|\mathbf{A}| |\mathbf{B}|} = \frac{\sum_{i=1}^n A_i x B_i}{\sum_{i=1}^n (A_i)^2 x \sqrt{\sum_{i=1}^n (B_i)^2}}$$

Setelah menerapkan metode yang dipakai untuk penelitian ini, maka hasil pengujian terhadap plagiarisme dari tugas *Source Code* mahasiswa memakai algoritma *Cosine Similarity* dan Pembobotan Term *Frequency* — *Inverse Document Frequency* (TF-IDF), dengan demikian score plagiarisme yang didapat dari 10 dokumen yang dibandingkan adalah sebagai berikut. Pada tabel 4 terdapat hasil perbandingan dokumen ke-4 dengan dokumen ke-7 maka diperoleh hasil score plagiarisme sebesar 75.28% dengan asumsikan jika score diatas 75% dokumen tersebut mengalami tindakan plagiarisme antara dua dokumen yang dibandingkan.

Tabel 4. Hasil Score *Similarity*

%	D1	D2	D3	D4	D5	D6	D7	D8	D9	D10
D1	100	49.79	41.95	37.80	29.87	38.94	33.83	46.49	45.42	40.07
D2		100	50.28	58.66	51.26	41.99	46.83	47.46	61.99	42.03
D3			100	65.57	40.85	47.25	61.74	59.06	50.12	48.19
D4				100	56.05	45.27	75.28	55.21	53.37	56.07
D5					100	38.73	50.50	35.24	56.28	37.95
D6						100	41.18	38.69	51.97	33.23
D7							100	48.17	50.26	51.84
D8								100	43.27	48.36
D9									100	32.84
D10										100

4. Kesimpulan

Dengan adanya hasil pembahasan dan penelitian mengenai “Deteksi Plagiarisme *Source Code* Tugas Mahasiswa Menggunakan Algoritma *Cosine Similarity* dan Pembobotan TF-IDF”. Dengan memakai alur penelitian seperti *preprocessing* untuk memperbaiki kinerja dan mencegah kesalahan di dalam pengoperasian algoritma, perhitungan *Term Frequency* — *Inverse Document Frequency* (TF-IDF) dengan menghitung bobot dari setiap dokumen serta Algoritma *Cosine Similarity* dalam mencari kemiripan antar dokumen. Dengan demikian dapat ditarik kesimpulan bahwa hasil dari penelitian menggunakan metode tersebut diperoleh plagiarisme berupa score kesamaan antar tugas mahasiswa seperti perbandingan dokumen ke-4 dengan dokumen ke-7 diperoleh hasil score plagiarisme sebesar 75.28% dengan asumsikan jika score diatas 75% dokumen tersebut mengalami tindakan plagiarisme antara dua dokumen yang dibandingkan. Dengan adanya penelitian ini diharapkan mampu membantu dalam pendekripsi plagiarisme tugas mahasiswa yang berada pada ruang lingkup *Source Code*.

Referensi

- [1] Rito Putriwana Pratama, Muhammad Faisal dan Ajib Hanani, “Deteksi Plagiarisme pada Artikel Jurnal Menggunakan Metode Cosine Similarity”, SMARTICS Journal, vol. 5, No. 1 2019. p22-26, 22, 2019.
- [2] Daniel dan Wilda Susanti, “Penerapan Algoritma Cosine Similarity Pada Sistem Pengajuan Judul Tugas Akhir Berbasis Web”, Seminar Nasional Informatika (SENATIKA), vol.-, no.11 , 2021.
- [3] Imam Nawawi, Putra Prima Arhandi dan Faisal Rahutomo, “Deteksi Plagiarisme Pada Dokumen Skripsi Berdasarkan Tingkat Kesamaan Dengan Menggunakan Metode Longest Common Subsequence”, vol. 8, no. 3, 2019.
- [4] Rio Alamanda, Cucu Suhery dan Yulrio Brianorman, “Aplikasi Pendekripsi Plagiat Terhadap Karya Tulis Berbasis Web Menggunakan Natural Language Processing Dan Algoritma Knuth-Morris-Pratt”, Jurnal Coding, vol. 04. No.1, 2006.

- [5] Jurnal Coding, Sam Farisa Chaerul Haviana dan Andika Novianto, "Implementasi Algoritma Cosine Similarity pada sistem arsip dokumen di Universitas Islam Sultan Agung", Transformtika, vol. 17, No.2, 2020.