ISSN: 2686-1089 (ONLINE)

OPEN ACCESS
J. OF ICT, VOL. 3, NO. 1, PP.031-041, JUNI 2021

Journal of Informatics and Communications Technology (JICT)

Steganalysis LSB Matching pada Grayscale Image menggunakan Machine Learning

Syifa Nurgaida Yutia, Siti Zahrotul Fajriyah

Teknologi Informasi, Institut Teknologi Telkom Jakarta
Jalan Daan Mogot KM.11, Jakarta 11710 Indonesia
syifanurgaida@ittelkom-jkt.ac.id

Abstract

Pada era digital saat ini teknik-teknik menyembunyikan pesan atau steganografi pada sebuah data telah mengalami perkembangan. Sehingga diperlukannya pengembangan teknik untuk mendeteksi pesan tersebut yang dapat dilakukan dengan metode steganalisis. Tujuan steganalisis yaitu untuk mengetahui apakah dalam suatu objek berisi pesan rahasia atau tidak. Terdapat dua metode steganografi secara garis besar yaitu LSB *Replacement* dan LSB *Matching*. Penerapan LSB *Replacement* dalam steganografi menyebabkan ketidakseimbangan dalam histogram gambar yang dapat dengan mudah dieksploitasi dengan metode statistik untuk steganalisis. Metode kedua yaitu LSB *Matching* dapat memecahkan masalah pada LSB *Replacement* dengan secara acak menambah atau mengurangi nilai piksel dengan 1 dalam kasus ketidakcocokan bit LSB untuk menghindari masalah ketidakseimbangan histogram dan membuatnya sulit untuk melakukan steganalysis dengan metode statistik saja, maka untuk mengatasi hal tersebut pada penelitian ini melakukan teknik *steganalysis* dengan penggunaan *machine learning* untuk keberadaan LSB *matching* dalam gambar *grayscale* (skala abu-abu) menggunakan teknik klasifikasi.

Keywords: *steganography, machine learning, steganalysis, artificial intelligence,* LSB.

I. PENDAHULUAN

Steganalysis adalah ilmu untuk mendeteksi keberadaan pesan tersembunyi dalam suatu gambar, audio, video ataupun file yang tertanam dengan *steganography*. Algoritma *steganalysis* dikembangkan untuk menentukan apakah suatu gambar telah tertanam berdasarkan fitur statistic dari distorsi [1]. Berbagai metode *steganalysis* dapat dibagi menjadi *steganalysis* khusus dan *steganalysis* umum. Kategori pertama adalah metode *steganalysis* khusus yang biasanya memiliki tingkat deteksi lebih tinggi. Kategori kedua adalah deteksi awam yang tidak tergantung pada algoritma *steganography* khusus [2]. Dengan menggunakan teknik *steganography*, mitra yang berkomunikasi membangun saluran aman dalam sinyal *host* untuk mengirimkan pesan rahasia yang dianggap tidak terlihat oleh pihak ketiga. Saat ini, sebagian besar metode *steganography* pada gambar mencapai tujuan dengan memasukkan informasi rahasia ke dalam gambar asal yang tak terhindarkan meninggalkan bukti distorsi. Teknik *steganography* yang biasa digunakan yaitu teknik LSB (*Least Significant Bit*). Berdasarkan hal tersebut maka kebutuhan perkembangan teknik baru untuk alat *steganalysis* akan semakin tinggi yang dapatmendeteksi objek penutup atau *steganogram*. Dalam penelitian ini mengusulkan *Machine learning* untuk *steganalysis* dalam mendeteksi gambar *steganography* hasil metode dari LSB *Matching*. Penggunaan *machine learning* digunakan untuk mengajarkan mesin bagaimana menangani data dengan lebih efisien sehingga dapat menafsirkan pola atau mengekstrak informasi dari data. Bagian makalah ini disusun sebagai berikut: Bagian II menyajikan Tinjauan Pustaka. Pada bagian III Metodologi Penelitian, Bagian IV Hasil dan pengujian, dan akhirnya pada bagian V yaitu berisi kesimpulan.

II. LANDASAN TEORI

A. *Machine Learning*

Machine Learning atau Pembelajaran mesin adalah teknik pembelajaran yang diterapkan pada mesin untuk memungkinkan mereka meniru kecerdasan manusia. Pembelajaran mesin dapat digunakan untuk mengenali, mengelompokkan, mengklasifikasikan, dan mengidentifikasi kelas atau kategori individu. Ada dua jenis teknik pembelajaran mesin terbimbing (supervised learning) dan tidak terbimbing (unsupervised learning).

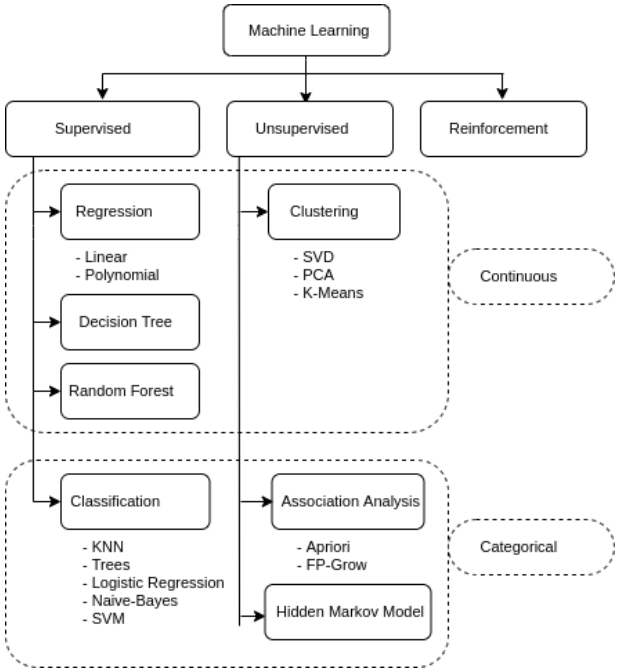

Gambar 1. Tipe *Machine Learning* dan Algoritma yang digunakan

Supervised Learning merupakan teknik untuk melatih model input dan output data yang diketahui sehingga dapat diprediksi luarannya di masa depan, dan *Unsupervised Learning* merupakan teknik menemukan pola yang tersembunyi atau struktur intrinsik dalam data input [3].

B. *Supervised Learning*

Supervised Learning merupakan algoritma *machine learning* yang membutuhkan bantuan dari luar atau *eksternal*. Dataset input terbagi menjadi dua yaitu dataset *train* dan *test*. Dataset *train* memiliki variabel keluaran yang masih perlu diprediksi atau diklasifikasikan. Semua algoritma mempelajari semacam pola dari dataset *train* dan menerapkannya pada dataset uji/*test* untuk prediksi atau klasifikasi [3]. Tujuan *supervised machine learning* adalah untuk membangun model yang membuat prediksi berdasarkan bukti yang dihadapkan ketidakpastian.

C. *Steganography*

Steganografi adalah seni komunikasi terselubung yang berbeda dengan *cryptography*. Pada *Cryptography* bertujuan untuk membuat pesan rahasia tidak dapat dibaca, namun masih menarik perhatian dari penyadap karena jelas bahwa komunikasi dienkripsi. Sedangkan pada steganografi menyembunyikan pesan rahasia di dalam media sampul yang terlihat tidak mencurigakan dengan tujuan menyembunyikan keberadaan pesan dengan cara yang membuat komunikasi rahasia tidak terlihat [4] [5]. Jenis-jenis media pada penerapan *steganography* yaitu text, image dan audio/video. Gambar 2 menunjukkan model pada sistem steganografi.

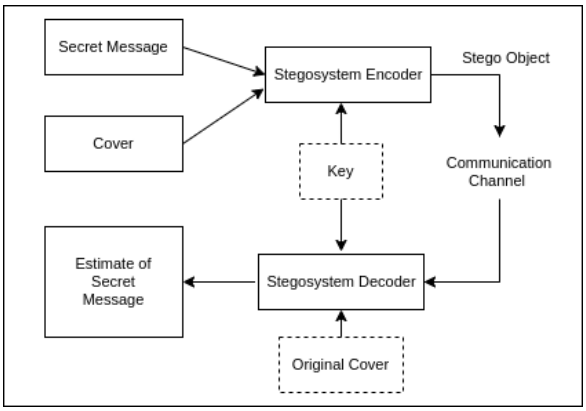

Gambar 2. *Model of steganographic systems*

Sistem steganografi pada umumnya meliputi objek, pesan rahasia, *stego-key*, *stego-system encoder*, *stego object* dan *stego-system decoder*. Yang menyimpan informasi tersembunyi disebut sebagai objek Sampul. Kunci Stego adalah informasi tambahan, seperti kata sandi atau variabel matematika, yang diperlukan untuk menanamkan informasi rahasia. *Stego system encoder* merupakan proses penerapan kunci stego untuk menyembunyikan pesan rahasia di dalam objek penutup/*cover*. Kombinasi objek data dan *cover* tersembunyi dikenal sebagai objek stego. *Decoder* sistem Stego adalah proses penerapan kunci stego yang sama pada objek stego untuk memisahkan pesan tersembunyi dariobjek penutup [6].

D. Steganography pada Gambar

Salah satu jenis media *steganography* yaitu gambar. Target steganography banyak memanfaatkan media gambar *digital.* Gambar *digital* memiliki nilai yang disebut elemen gambar atau piksel yang terdiri dari jumlah baris dan kolom piksel tetap. Dalam dunia komputasi digital, gambar digital dengan jenis *grayscale* adalah gambar di mana nilai setiap piksel membawa informasi intensitas, nuansa abu -abu, bervariasi dari hitam pada intensitas paling lemah hingga putih di terkuat. Saat ini, gambar *grayscale* yang ditujukan untuk tampilan visual umumnya disimpan dengan 8 bit per piksel. Dengan demikian, 256 jenis intensitas abu-abu digunakan. Gambar RGB (*Red*, *Green*, and *Blue*) memiliki tiga saluran: merah, hijau, dan biru sedangkan gambar skala abu-abu hanya memiliki satu saluran. Klasifikasi format pada gambar *digital* tergantung pada jumlah kolom yang membentuk gambar. Beberapa warna dalam suatu gambar juga mempengaruhi ukuran gambar. Jenis format gambar antara lain jpg, gif, tiff, png, bmp. Semua jenis file atau format ini digunakan untuk menyandikan gambar *digital*. Ada dua jenis kompresi untuk memampatkan gambar digital. Kompresi diterapkan menggunakan algoritma kompresi pada gambar digital. Algoritma kompresi *lossless* tidak membuat kompromi dengan keakuratan gambar *digital* karena informasi tersebut dibuang ke mana-mana sementara algoritma yang bertujuan kompresi *lossy* memperkenalkan beberapa degradasi gambar untuk mempersingkat ukuran *file*, karena mereka dapat menyimpan informasi warna pada resolusi lebih rendah daripada gambar itu sendiri. Di sisi lain untuk memotong ukuran *file* menggunakan algoritma kompresi *lossless* termasuk mengganti pola berulang *file* dengan semacam singkatan yang lebih pendek [6].

E. Steganalysis

Steganalisis merupakan teknologi untuk mendeteksi dan menganalisis file pembawa potensial un tuk penyembunyian data menggunakan steganografi [7]. Tujuan dari steganalisis dapat tiga tingkatan termasuk: mendeteksi, mengekstraksi, dan menonaktifkan atau menghancurkan pesan tersembunyi [8].

F. Least Significant Bit (LSB)

Untuk mendeteksi keberadaan pesan tersembunyi sebagian besar dengan teknik mencari artefak yang dibuat oleh teknik penyembunyian pesan pada *steganography* yang biasa dilakukan dengan LSB *Replacement* dan LSB *Matching*. LSB *Replacement* hanya memengaruhi LSB dari setiap nilai data dengan mengubah nilai LSB dari cover image dengan nilai bit pesan, maka pesan tersebut tertanam pada cover image dan terciptalah stego image. Metode ini menambahkan 1 ke nilai piksel genap, mengurangi 1 ke nilai piksel ganjil, atau membiarkan nilai s tidak berubah sehingga menciptakan ketidakseimbangan dalam distorsi. Sejumlah teknik steganalisis memanfaatkan ketidakseimbangan ini. LSB *Matching*, di sisi lain memanfaatkan kenaikan atau penurunan nilai data ganjil dan genap dengan probabilitas y ang sama yaitu dengan mengeksploitasi ketidakseimbangan [9]. LSB *Matching* mengubah nilai pada LSB dari gambar sampul atau *cover image* dalam meyisipkan pesan. LSB *Matching* tidak langsung mengubah nilai pada LSB dari gambar sampul seperti penggantian LSB. Jika bit pesan tidak sama dengan LSB gambar sampul, nilai 1 ditambahkan atau dikurangi secara acak dari nilai piksel sampul. Nilai piksel tidak pernah berubah melebihi batas yang diizinkan [10].

III. METODOLOGI PENELITIAN

Untuk strategi implementasi terdapat beberapa proses yaitu kebutuhan/*requirement*, analysis and *methodology*.

A. Kebutuhan/*Requirement*

Pada perancangan *Supervised Machine Learning* untuk *image steganalysis* meliputi persiapan kebutuhan/requirement *hardware* maupun *software* yang dijelaskan pada tabel 1.

TABLE I
KEBUTUHAN HARDWARE DAN SOFTWARE

Machine Learning untuk *Image Steganalysis*	
Hardware	● Acer Intel Core I3 ● RAM 4 GB ● Intel HD Graphics
Sistem Operasi	● Ubuntu 18.04 LTS (Bionic Beaver)
Software Aplikasi	● Jupyter Notebook ● Tensorflow ● Aletheia
Bahasa Pemrograman	Python
DataSet	● BossBase Greyscale Images ● Bossbase LSB Matching

Setelah menentukan kebutuhan sistem, selanjutnya yaitu merancang *flowchart. Flowchart* yang akan digunakan yaitu *supervised machine learning* yang dijelaskan pada gambar 3 yang akan digunakan untuk mendeteksi *image steganalysis* pada makalah ini.

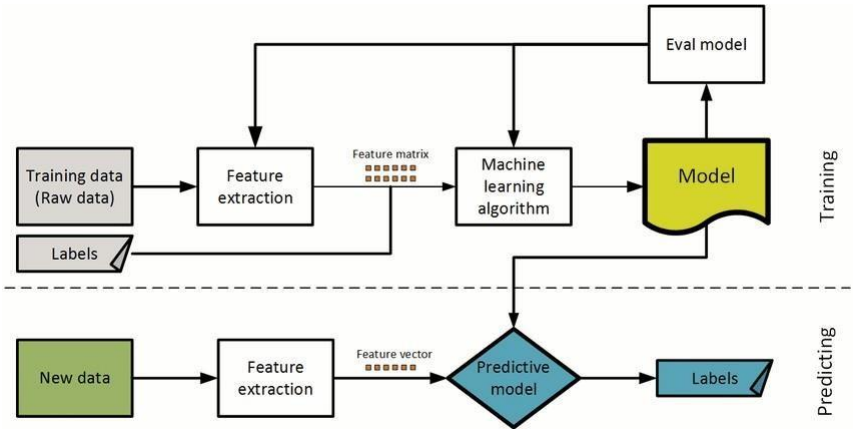

Gambar 3. *Flowchart Diagram Supervised Machine Learning*

Pada gambar 3 menjelaskan *flowchart* dari *supervised machine learning*. Pada langkah pertama, *Raw Data Training* dibersihkan (*Data Cleaning*) dan dimasukkan ke dalam ekstraksi fitur untuk memilih hanya fitur yang berguna dari data yang tersedia. Selanjutnya, label atau kelas yang dikenal dan fitur yang diekstraksi kemudian diteruskan ke fase pelatihan di mana algoritma *machine learning* digunakan untuk mengidentifikasi model yang baik yang memetakan input ke output yang diinginkan. Fase evaluasi memberikan umpan balik ke fase ekstraksi fitur dan pembelajaran agar penyesuaian ditingkatkan akurasi model. Proses pelatihan diulangi hingga tingkat akurasi yang diinginkan tercapai. Setelah model dibangun, itu adalah kemudian digunakan untuk memprediksi label data baru.

Metrik yang digunakan adalah F-*Score* sebagai metrik evaluasi untuk model benchmark, solusi dan ukuran akurasi tes. Pada F-Score *precision* p dan *recall* r dari tes untuk menghitung skor. p adalah jumlah hasil positif yang terhitung benar kemudian dibagi dengan jumlah keseluruhan hasil positif dikembalikan dari pengklasifikasi, dan *recall* r merupakan jumlah hasil positif yang benar dibagi dengan jumlah keseluruhan sampel yang relevan (semua sampel yang seharusnya diidentifikasi sebagai positif). F-*Score* mendapatkan nilai terbaiknya pada 1 (presisi dan *recall* sempurna) dan yang paling buruk pada angka 0. Metrik di atas diformalkan sebagaiberikut:

$$Precision = TP / (TP + FP)$$

$$Recall = TP / (TP + FN)$$

$$\text{F-}Score = 2 \cdot \frac{Precision \cdot Recall}{Precision \; Recall}$$

F-Score adalah metrik yang baik untuk masalah karena aplikasi steganalisis membutuhkan ketepatan dan daya ingat yang baik.

B. Analisa dan Implementasi

Pada tahap analisis yaitu melakukan eksplorasi data. Dengan menganalisis objek *stego image* yang diterapkan dengan teknik LSB *Matching*. Berbeda dengan teknik LSB yang lain, ketidakseimbangan yang disebabkan oleh LSB *Matching* dalam domain spasial tidak cukup jelas untuk dieksploitasi oleh teknik statistik saja. Set fitur CF terdiri dari 41 fitur dan didasarkan pada premis yang memberikan informasi spasial yang cukup untuk dilatih [11].

1) Data Collection

Langkah pertama yang dilakukan adalah memasukan data set pada tahapan data *collection* dari dua file csv ke dalam satu frame data, diikuti oleh penambahan kolom target dengan *coding* yang diperlihatkan pada gambar 4.

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns

%matplotlib inline

# Import both the csv files as data frames
data_cov = pd.read_csv("datasets/steg_features.csv", header = None)
data_steg = pd.read_csv("datasets/steg_lsb_features.csv", header = None)
```

Gambar 4. *Import datasets*

Sehingga menghasilkan baris data cover pertama pada gambar 4

```
data_cov.head()
```

	0	1	2	3	4	5	6	7	8	9	...
0	-0.317327	0.827515	0.760605	0.740966	0.721418	0.910647	0.861356	0.835196	0.815543	0.818339	...
2	-0.503111	0.862970	0.802899	0.775813	0.751000	0.927452	0.889261	0.866067	0.848226	0.855546	...
3	-0.182988	0.887022	0.835196	0.813357	0.789932	0.911072	0.861291	0.824739	0.795830	0.856713	...
4	0.006107	0.932943	0.906990	0.897635	0.886993	0.970490	0.954652	0.944758	0.934639	0.934616	...
5	-0.062837	0.842912	0.754166	0.697135	0.650435	0.856007	0.775904	0.732342	0.700388	0.774753	...

Gambar 5. *data cover head*

Sehingga menghasilkan baris data stego pertama pada gambar 5

```
data_steg.head()
```

	0	1	2	3	4	5	6	7	8	9	...
0	-0.317249	0.827004	0.760402	0.740601	0.721245	0.909903	0.861059	0.834736	0.815029	0.817973	...
2	-0.503030	0.862545	0.802756	0.775952	0.750876	0.927202	0.888695	0.865893	0.847715	0.855019	...
3	-0.182986	0.885745	0.833919	0.812366	0.788900	0.909339	0.859644	0.823534	0.794631	0.855730	...
4	0.005779	0.932725	0.907008	0.897505	0.886902	0.970202	0.954428	0.944286	0.934372	0.934324	...
5	-0.062954	0.842023	0.753467	0.696795	0.650121	0.855838	0.775512	0.732004	0.700093	0.774611	...

5 rows × 41 columns

Gambar 6. *data stego head*

2) Data Pre-Processing

Pada tahapan data preprocessing yaitu melakukan data *cleaning*, yang melibatkan penghapusan semua baris yang memiliki nilai nan pada gambar 7

```
# Drop rows with NaN values
data_cov = data_cov.dropna(axis = 0)
data_steg = data_steg.dropna(axis = 0)
```

Gambar 7. *code data cleaning*

Hasil data *cleaning* menghasilkan data *cov head* dan data *seg head* yang baru pada gambar 8 dan 9

```
In [11]: data_cov.head()
```

Out[11]:

	0	1	2	3	4	5	6	7	8	9	...
0	-0.317327	0.827515	0.760605	0.740966	0.721418	0.910647	0.861356	0.835196	0.815543	0.818339	...
2	-0.503111	0.862970	0.802899	0.775813	0.751000	0.927452	0.889261	0.866067	0.848226	0.855546	...
3	-0.182988	0.887022	0.835196	0.813357	0.789932	0.911072	0.861291	0.824739	0.795830	0.856713	...
4	0.006107	0.932943	0.906990	0.897635	0.886993	0.970490	0.954652	0.944758	0.934639	0.934616	...
5	-0.062837	0.842912	0.754166	0.697135	0.650435	0.856007	0.775904	0.732342	0.700388	0.774753	...

5 rows × 41 columns

Gambar 8. Data Cov head setelah *cleaning* data

In [12]:
```
data_steg.head()
```

Out[12]:

	0	1	2	3	4	5	6	7	8	9	...
0	-0.317249	0.827004	0.760402	0.740601	0.721245	0.909903	0.861059	0.834736	0.815029	0.817973	...
2	-0.503030	0.862545	0.802756	0.775952	0.750876	0.927202	0.888695	0.865893	0.847715	0.855019	...
3	-0.182986	0.885745	0.833919	0.812366	0.788900	0.909339	0.859644	0.823534	0.794631	0.855730	...
4	0.005779	0.932725	0.907008	0.897505	0.886902	0.970202	0.954428	0.944286	0.934372	0.934324	...
5	-0.062954	0.842023	0.753467	0.696795	0.650121	0.855838	0.775512	0.732004	0.700093	0.774611	...

5 rows × 41 columns

Gambar 9. Data *Steg Head* setelah *cleaning* data

Kemudian menghitung dan menampilkan jumlah baris dari data_cov dan data_steg pada gambar 10

```
print("Number of rows in data_cov:", len(data_cov))
print("Number of rows in data_steg:", len(data_steg))
```

```
Number of rows in data_cov: 9679
Number of rows in data_steg: 9679
```

Gambar 10. Jumlah baris data *cover* dan data *stego*

Mengambil 10 *variance* dengan melakukan *Principal Component Analysis*

```
from sklearn.decomposition import PCA

# Perform PCA and keep only the first 10 dimensions
pca = PCA(10)
pca.fit(good_X)

reduced_X = pca.transform(good_X)
reduced_X = pd.DataFrame(reduced_X)
reduced_X.head()
```

Gambar 11. Proses PCA

Menghasilkan 10 variance pada gambar 12

	Explained Variance
0	0.5748
1	0.2337
2	0.1093
3	0.0230
4	0.0166
5	0.0143
6	0.0075
7	0.0064
8	0.0039
9	0.0028

Gambar 12. *Explained Variance*

ISSN: 2686-1089 (ONLINE)
OPEN ACCESS
J. OF ICT, VOL. 3, NO. 1, PP.031-041, JUNI 2021
Journal of Informatics and Communications Technology (JICT)

E. *Feature Extraction*

Pada *feature extraction* yaitu proses mengambil dataset dan label terkait sebagai input dan membaginya menjadi set *train* dan *test* dengan proses *cross validation* pada gambar 13

```
from sklearn.cross_validation import train_test_split

# Takes a dataset and corresponding label as input and splits it into train and test sets
def getCrossValidationDataSplit(X, y):
    X_train, X_test, y_train, y_test = train_test_split(X, y, test_size = 0.2, random_state = 0)

    print("Training set has {} samples.".format(X_train.shape[0]))
    print("Testing set has {} samples.".format(X_test.shape[0]))

    return [X_train, X_test, y_train, y_test]
```

Gambar 13. *Cross Validation*

Kemudian proses Inisialisasi lima pengklasifikasi pada gambar 14

```
from sklearn.naive_bayes import GaussianNB
from sklearn.ensemble import RandomForestClassifier
from sklearn.ensemble import AdaBoostClassifier
from sklearn.svm import SVC
from sklearn.neural_network import MLPClassifier


# Initialize five classifiers and sample sizes and return combined results for all possible classifer-sample-size pair
def getClassificationResults(X_train, y_train, X_test, y_test):
    clf_A = GaussianNB()
    clf_B = RandomForestClassifier()
    clf_C = AdaBoostClassifier()
    clf_D = SVC()
    clf_E = MLPClassifier()

    samples_100 = len(y_train)
    samples_10 = int(0.1 * samples_100)
    samples_1 = int(0.01 * samples_100)

    results = {}
    for clf in [clf_A, clf_B, clf_C, clf_D, clf_E]:
        clf_name = clf.__class__.__name__
        results[clf_name] = {}
        for i, samples in enumerate([samples_1, samples_10, samples_100]):
            results[clf_name][i] = trainPredict(clf, samples, X_train, y_train, X_test, y_test)

    return results
```

Gambar 14. *Initialize Five Classifiers*

Melakukan proses *train* pada *original* dataset dan visualisasi hasilnya pada gambar 15

```
Training set has 15486 samples.
Testing set has 3872 samples.
Naive Predictor: [Accuracy score: 0.6059, F-score: 0.6819]
GaussianNB trained on 154 samples.
GaussianNB trained on 1548 samples.
GaussianNB trained on 15486 samples.
RandomForestClassifier trained on 154 samples.
RandomForestClassifier trained on 1548 samples.
RandomForestClassifier trained on 15486 samples.
AdaBoostClassifier trained on 154 samples.
AdaBoostClassifier trained on 1548 samples.
AdaBoostClassifier trained on 15486 samples.
SVC trained on 154 samples.
SVC trained on 1548 samples.
SVC trained on 15486 samples.
MLPClassifier trained on 154 samples.
MLPClassifier trained on 1548 samples.
MLPClassifier trained on 15486 samples.
```

Gambar 15. Proses train *original* datasetpada *classifier*

IV. HASIL DAN PEMBAHASAN

Setelah menerapkan pengklasifikasi pada masing-masing set *original* dataset dengan 5 *classifier* yaitu Gaussian Naïve Bayes, Random Forests, Support Vector Classifier, Ada Boost dan Multi-Layer Neural Network Perceptron. Untuk masing-masing pengklasifikasi, dicatat kinerja berdasarkan *train time, prediction time, train accuracy, test accuracy, train f-score* dan *test f-score* untuk ukuran *train* yang berbeda, dan membandingkan akurasi dan skor-f dengan skor dari Benchmark Gaussian Naïve Bayes Predictor pada dataset asli. Hasil menunjukan bahwa semua pengklasifikasi kecuali MLP Classifier meningkatkan kinerja ketika *train* pada dataset yang dibersihkan dari dataset asli. F-*Score Classifier* MLP menurun sekitar 1%. Saat membandingkan waktu pelatihan, SVC membutuhkan waktu paling lama, diikuti oleh MLP classifier dan Ada Boost. Namun, dalam kasus ini untuk waktu *train* yang lama bisa ditolerir demikinerja yang lebih baik. SVC juga memiliki waktu pengujian yang sangat tinggi. Ini membuatnya kurang optimal untuk karena dalam model akhir ekstraksi fitur CF itu sendiri membutuhkan waktu yang lama, dan menghemat waktu sebanyak mungkin penting dalam komponen prediksi. Untuk *train* dataset yang lebih sederhana termasuk Naive Bayes dan SVC juga bekerja dengan sangat baik, jika dibandingkan dengan modellainnya. Secara keseluruhan, bahwa MLP Classifier dan Ada Boost secara konsisten mengungguli semua pengklasifikasi lain dalam hal akurasi pengujian dan uji f-*score* terlihat pada gambar 16.

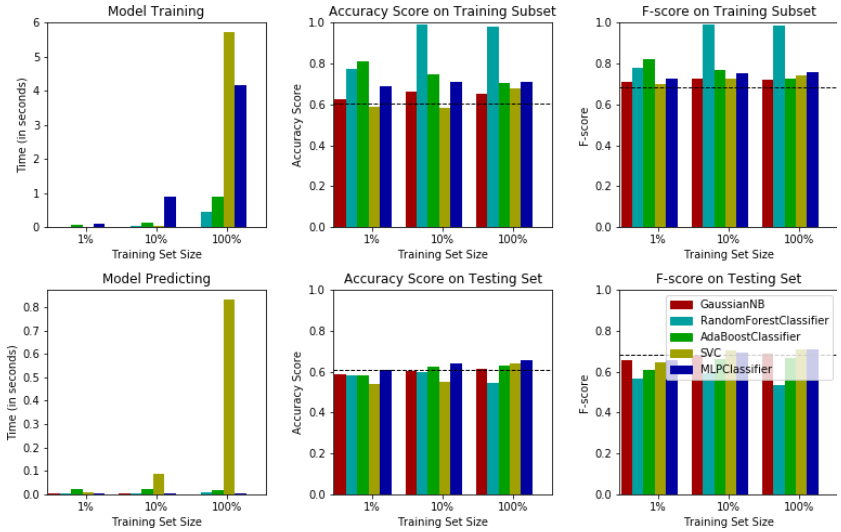

Gambar 16. Hasil Skor Akurasi

Berikut tabel untuk akurasi dari 5 *classifier*

	Model	Train Time	Training Accuracy	Training F-Score	Prediction Time	Test Accuracy	Test F-Score
0	GaussianNB	0.015673	0.580000	0.663102	0.002817	0.592717	0.670428
1	RandomForestClassifier	0.949791	0.983333	0.984227	0.008735	0.697314	0.684607
2	AdaBoostClassifier	3.733127	0.703333	0.750700	0.024033	0.707386	0.739000
3	SVC	19.401956	0.630000	0.694215	2.951462	0.636880	0.692341
4	MLPClassifier	5.667073	0.736667	0.783562	0.003764	0.720041	0.762801

Gambar 17. Tabel Akurasi

V. Kesimpulan

Machine Learning untuk kasus steganalysis dilakukan untuk mengatasi *image steganografi* dengan teknik LSB *matching* yang lebih sulit dideteksi dibandingkan teknik *image steganography* pada LSB *replacement*. LSB *Matching* adalah versi modifikasi dari LSB *Replacement*, dengan menggunakan dataset berlabel gambar skala abu-abu menggunakan *supervised* yaitu melalui proses data *cleansing*, data *pre-processing*, *feature* extraction, pengurangan dimensi melalui PCA dan proses *train* beberapa pengklasifikasi. Setelah menerapkan pengklasifikasi pada masing-masing set original dataset dengan 5 classifier yaitu Gaussian Naïve Bayes, Random Forests, Support Vector Classifier, Ada Boost dan Multi- Layer Neural Network Perceptron. Untuk masing-masing pengklasifikasi, dicatat kinerja berdasarkan train time, prediction time, train accuracy, test accuracy, train f -score dan test f-score. Dari hasil pengujian didapat *classifier* Multilayer Perceptron (MLP) yang terbaik dalam memodelkan keputusan yang sifatnya kompleks. Karena kinerjanya yang tinggi, MLP ideal untuk masalah *image steganalysis.* Namun untuk *classifier* yang lain juga memiliki kelebihan dan kekurangan masing-masing seperti untuk train dataset yang lebih sederhanatermasuk Naive Bayes dan SVC juga bekerja dengan sangat baik, jika dibandingkan dengan model lainnya. Maka untuk pemilihan *classifier* tergantung dengan permasalahan atau kasus yang ingin diselesaikan.

REFERENCES

[1] C. Cachin, "An information-theoretic model for steganography", in Information Hiding. Berlin, Germany: Springer, 1998, pp. 306–318. [Online]. Available: https://doi.org/10.1007/3-540-49380-8_21.

[2] Z.Sun, H.Li, Z.Wu, and Z.Zhou, "An Image Steganalysis Method Based on Characteristic Function Moments of Wavelet Subbands, Artificial Intelligence and Computational Intelligence", AICI '09. International Conference on Volume: pp 291 - 295,2009.

[3] S.B. Kotsiantis, "Supervised Machine Learning: A Review of Classification Techniques", Informatica 31 (2007) 249-268

[4] R. J. Anderson and F. A. Petitcolas, "On the limits of steganography," *Selected Areas in Communications, IEEE Journal* on, vol. 16, no. 4, pp. 474–481, 1998.

[5] G. Huayong, H. Mingsheng, and W. Qian, "Steganogra-phy and steganalysis based on digital image," in *Image and Signal Processing (CISP), 2011 4th International Congress* on, vol. 1. IEEE, 2011, pp. 252–255.

[6] R. Jain and J. Boaddh, "Advances in digital image steganography," *International Conference on Innovation and Challengesin Cyber Security* (ICICCS-INBUSH), 2016.

[7] D. Artz, "Digital steganography: hiding data within data," *internet computing IEEE*, vol. 5, no. 3, pp. 75-80, 2001.

[8] N. F. Johnson, S. Jajodia, "Steganalysis: The investigation ofhidden information," *Information Technology Conference* 1998. IEEE, pp. 113-116, 1998.

[9] T. Qian and S.Manoharan "A Comparative Review of Steganalysis Techniques," *International Conference on Information Scienceand Security* (ICISS), 2015.

[10] J. Mielikainen, "LSB Matching Revisited," IEEE *Signal Processing Letters,* vol. 13, no. 5, pp. 285-287, 2006.

[11] Q. Liu, A.H. Sung, J. Xu, and B.M. Ribeiro, "Image Complexity and Feature Extraction for Steganalysis of LSB Matching Steganography," 18th *International Conferenceon Pattern Recognition* (ICPR'06), 2006.