

BINARY LOGISTIC REGRESSION UNTUK MENDETEKSI WEBSITE PHISING MENGUNAKAN CORRELATION-BASED FEATURE SELECTION

Bekti Maryuni Susanto

Jurusan Teknologi Informasi, Politeknik Negeri Jember

email: bekti.polije@gmail.com

ABSTRACT

Internet provides the facility to find customers worldwide without limitation use e-commerce market is effective. As a result the number of customers that rely on the Internet in the purchase has increased dramatically. In the field of computer security, phishing is a criminal activity that is trying to get sensitive information illegally. Sensitive information could include usernames, passwords and credit card details. This study aims to select the features or attributes in order to obtain the most influential attributes in detecting phishing websites. Selection feature using the correlation-based feature selection. Some of the most important attributes will be selected using the CFS and is applied to the binary logistic regression algorithms. Based on the research results show that CFS is able to eliminate redundant attributes. The subset of attributes generated have this level of accuracy is not much different from the full attributes. This level of accuracy before the selection of attributes 93.99% and 93.20% after the selection attribute. Subsequent studies applying other methods of feature selection and compared the results with the study.

Keywords: *Binary Logistic Regression, Website Phising, Correlation-based Feature Selection*

I. PENDAHULUAN

Internet memberikan fasilitas untuk mencapai pelanggan di seluruh dunia tanpa batasan pasar menggunakan e-commerce yang efektif. Sebagai dampaknya jumlah pelanggan yang bergantung pada Internet dalam pembelian mengalami peningkatan secara dramatis. Ratusan juta dolar ditransfer melalui Internet setiap harinya. Peningkatan ini membuat penipu tergoda untuk melancarkan operasi penipuan melalui Internet. Menurut Aaron dan Manning dalam Mohammad, McCluskey, & Thabtah (2013) Phishing adalah bentuk ancaman web yang didefinisikan sebagai seni meniru website suatu perusahaan otentik bertujuan untuk memperoleh informasi pribadi.

Pada bidang keamanan computer, phishing adalah aktivitas criminal yang berusaha untuk mendapatkan informasi sensitive secara tidak sah. Informasi sensitive tersebut bisa berupa username, password, dan detil kartu kredit. Phising dilakukan dengan menyamar menjadi entitas yang bisa dipercaya dalam komunikasi electronic (Dhanalakshmi, Prabhu, & Chellapan, 2011). Website phishing secara luas melancarkan serangan social engineering untuk menipu orang pada informasi pribadi

termauk nomor kartu kredit, informasi akun bank, nomor pin dan identitas pribadi untuk digunakan untuk menyerang mereka.

Berbagai penelitian telah dilakukan dalam mendeteksi website phishing. Diantaranya Predicting Phishing Websites using Neural Network trained with Back-Propagation (Mohammad, McCluskey, & Thabtah, 2013) menunjukkan bahwa neural network merupakan teknik yang baik dalam mendeteksi website phishing. Hasil terbaik dicapai saat hidden layer 2 dan learning rate 0,7 dengan MSE sebesar 0,022. Penelitian lain yang berjudul Intelligent Rule based Phishing Websites Classification (Mohammad, McCluskey, & Thabtah, Intelligent Rule based Phishing Websites Classification, 2014) menunjukkan bahwa tingkat akurasi

algoritma C4.5 dalam mendeteksi website phishing mengungguli algoritma RIPPER, PRISM dan CBA. Namun demikian setelah dilakukan pemilihan atribut CBA memiliki tingkat error yang paling rendah yaitu 4,75%. Penelitian lain yang berjudul Phishing Websites Detection based on Phishing Characteristics in the Webpage Source Code (Alkhozai & Batarfi, 2011) menunjukkan bahwa website phishing dapat ditentikan tingkat keamanannya

dengan mengekstrak karakteristik phishing melalui standard W3C. Hasilnya website phishing memiliki tingkat kemanan yang rendah dibandingkan dengan website legitimate.

Penelitian ini bertujuan untuk menyeleksi feature atau atribut sehingga diperoleh atribut yang paling berpengaruh dalam mendeteksi website phishing. Pemilihan feature menggunakan metode Correlation-based feature selection (Hall, 1999). Beberapa atribut terpenting akan dipilih menggunakan metode CFS dan diterapkan ke dalam algoritma binary logistic regression.

Manfaat dari penelitian ini adalah untuk meminimalkan waktu komputasi yang dibutuhkan dalam mendeteksi website phishing. Waktu komputasi yang semakin kecil akan mengurangi jumlah sumber daya computer yang digunakan. Sehingga konsumsi energi listrik akan berkurang.

II. METODE PENELITIAN

Pelaksanaan penelitian ini dilakukan dengan kegiatan sebagai berikut.

- a. Studi Literatur
Mempelajari definisi/istilah pada web phishing, mempelajari literatur tentang identifikasi web phishing.
- b. Persiapan data
Pada penelitian ini menggunakan dataset web phishing yang didownload dari UCI Machine Learning Repository.
- c. Seleksi atribut
Dari dataset yang ada dilakukan seleksi atribut menggunakan metode correlation based feature selection.
- d. Evaluasi
Pada tahap ini, dataset yang sudah direduksi atributnya diterapkan pada algoritma binary logistic regression. Dataset dibagi menjadi dua data training dan data testing. Pembagian dataset ini menggunakan 10 X-Validation. Selanjutnya dihitung nilai akurasi berdasarkan pada eksperimen yang dilakukan.

III. HASIL DAN PEMBAHASAN

Hasil yang dicapai sesuai dengan metode yang telah dijelaskan, adalah sebagai berikut.

1. Studi Literatur

Phishing adalah sebuah tindakan kriminal untuk mencuri informasi pribadi orang lain menggunakan entitas electronic, salah satunya adalah website. Sebuah website dikategorikan menjadi website phishing apabila memenuhi karakteristik phishing. Karakteristik phishing tersebut digolongkan menjadi empat golongan utama yaitu, Address Bar based Feature, Abnormal based Feature, HTML and JavaScript based Feature dan Domain based Feature (Mohammad, McCluskey, & Thabtah, An Assessment of Features Related to Phishing Websites using an Automated Technique, 2012).

Pada Address Bar based Feature terdapat 12 feature, yang akan dijelaskan sebagai berikut:

- a. Using the IP Address
Jika sebuah IP address digunakan sebagai alternative nama domain di dalam URL, seperti "http://125.98.3.123/fake.html", hal ini mengindikasikan seseorang berusaha untuk mencuri informasi pribadinya.

Rule:

IF
{(If The Domain Part has an IP Address → Phishing@Otherwise → Legitimate)}

- b. Long URL to Hide the Suspicious Part

Rule:

IF

$$\left\{ \begin{array}{l} URL\ length < 54 \rightarrow feature = Legitimate \\ else\ if\ URL\ length \geq 54\ and\ \leq 75 \rightarrow feature \\ =\ Suspicious \\ otherwise \rightarrow feature = Phishing \end{array} \right.$$

- c. Using URL Shortening Services "Tiny URL"

Rule:

IF { TinyURL → Phishing
Otherwise → Legitimate }

- d. URL's having "@" Symbol

Rule: IF { Url Having @ Symbol → Phishing
Otherwise → Legitimate }

e. Redirecting Using “//”

Rule: IF
 { ThePosition of the Last Occurrence of “//” in the URL > 7
 → Phishing
 Otherwise → Legitimate

f. Adding Prefix or Suffix Separated by (-) to the domain

Rule: IF
 { Domain Name Part Includes (-) Symbol → Phishing
 Otherwise → Legitimate

g. Sub Domain dan Multi Sub Domain

Rule: IF
 { Dots In Domain Part = 1 → Legitimate
 Dots In Domain Part = 2 → Suspicious
 Otherwise → Phishing

h. HTTPS

Rule:
 IF
 { Use https and Issuer Is Trusted *and Age of Certificate* ≥ 1 Years → Legitimate
 Using https and Issuer Is Not Trusted → Suspicious
 Otherwise → Phishing

i. Domain Registration Length

Rule:
 IF { Domains Expires on ≤ 1 years → Phishing
 Otherwise → Legitimate

j. Favicon

Rule:
 IF
 { Favicon Loaded From External Domain → Phishing
 Otherwise → Legitimate

k. Using Non-Standard Port

Rule:
 IF
 { Port # is of the Preferred Status → Phishing
 Otherwise → Legitimate

l. The Existence of “HTTPS” Token in the Domain Part of the URL

Rule:
 IF
 { Using HTTP Token in Domain Part of The URL → Phishing
 Otherwise → Legitimate

Pada Abnormal based Fetaure terdapat enam feature, yaitu:

a. Request URL

Rule: IF
 { % of Request URL < 22% → Legitimate
 % of Request URL ≥ 22% and 61% → Suspicious
 Otherwise → feature = Phishing

b. URL of Anchor

Rule:
 IF
 { % of URL Of Anchor < 31% → Legitimate
 % of URL Of Anchor ≥ 31% And ≤ 67% → Suspicious
 Otherwise → Phishing

c. Links in <Meta>, <Script> and <Link> tags

Rule: IF { (% of Links in "<Meta>","<Script>" and "<Link>\\" < 17% → Legitimate
 IF (% of Links in <Meta>,"<Script>" and "<Link>\\" ≥ 17% And ≤ 81% → Suspicious) Otherwise → Phishing } +

d. Server Form Handler (SFH)

Rule:
 IF
 { SFH is "about: blank" Or Is Empty → Phishing
 SFH Refers To A Different Domain → Suspicious
 Otherwise → Legitimate

e. Submitting Information to Email

Rule: IF { (Using ""mail()\\" or "\\mailto:\\" Function to Submit User Information" → Phishing @ Otherwise → Legitimate) +

f. Abnormal URL

Rule: IF
 { The Host Name Is Not Included In URL → Phishing
 Otherwise → Legitimate

Pada HTML and JavaScript based Feature terdapat lima feature, yaitu:

a. Website Forwarding

Rule: IF
 { ofRedirect Page ≤ 1 → Legitimate
 of Redirect Page ≥ 2 And < 4 → Suspicious
 Otherwise → Phishing

b. Status Bar Cuztomization

Rule:
 IF
 { onMouseOver Changes Status Bar → Phishing
 It Does't Change Status Bar → Legitimate

c. Dissabling Right Click

Rule:
 IF { Right Click Disabled → Phishing
 Otherwise → Legitimate

d. Using Pop-up Window

Rule: IF
 { Popup Window Contains Text Fields → Phishing
 Otherwise → Legitimate

e. IFrame Redirection

Rule: IF $\begin{cases} \text{Using iframe} \rightarrow \text{Phishing} \\ \text{Otherwise} \rightarrow \text{Legitimate} \end{cases}$

Rule:
IF $\begin{cases} \text{Webpage Indexed by Google} \rightarrow \text{Legitimate} \\ \text{Otherwise} \rightarrow \text{Phishing} \end{cases}$

Pada Domain based Feature terdapat tujuh feature, yaitu;

a. Age of Domain

Rule: IF $\begin{cases} \text{Age Of Domain} \geq 6 \text{ months} \rightarrow \text{Legitimate} \\ \text{Otherwise} \rightarrow \text{Phishing} \end{cases}$

b. DNS Record

Rule:
IF $\begin{cases} \text{no DNS Record For The Domain} \rightarrow \text{Phishing} \\ \text{Otherwise} \rightarrow \text{Legitimate} \end{cases}$

c. Website Traffic

Rule:
IF $\begin{cases} \text{Website Rank} < 100,000 \rightarrow \text{Legitimate} \\ \text{Website Rank} > 100,000 \rightarrow \text{Suspicious} \\ \text{Otherwise} \rightarrow \text{Phish} \end{cases}$

d. Page Rank

Rule: IF $\begin{cases} \text{PageRank} < 0.2 \rightarrow \text{Phishing} \\ \text{Otherwise} \rightarrow \text{Legitimate} \end{cases}$

e. Google Index

f. Number of Links Pointing to Page

Rule: IF $\begin{cases} \text{Of Link Pointing to The Webpage} = 0 \rightarrow \text{Phishing} \\ \text{Of Link Pointing to The Webpage} > 0 \text{ and } \leq 2 \rightarrow \text{Suspicious} \\ \text{Otherwise} \rightarrow \text{Legitimate} \end{cases}$

g. Statistical-Reports based Feature

Rule: IF $\begin{cases} \text{Host Belongs to Top Phishing IPs or Top Phishing Domains} \rightarrow \text{Phishing} \\ \text{Otherwise} \rightarrow \text{Legitimate} \end{cases}$

2. Binary Logistic Regression

Model regresi logistik biner digunakan untuk melihat apakah variabel tak bebas yang berskala dikotomi ($Y = 0$ dan $Y = 1$) dipengaruhi oleh variabel bebas baik yang kategorik maupun numerik. Bentuk umum model peluang regresi logistik dengan k variabel diformulasikan sebagai berikut :

$$\pi(x) = \frac{\exp(\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k)}{1 + \exp(\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k)}$$

Dimana $\pi(x)$ adalah peluang sukses probabilitas suatu peristiwa/kasus yang ditentukan oleh $y = 1$, β_i adalah nilai parameter.

Fungsi tersebut merupakan fungsi linier sehingga perlu dilakukan transformasi ke dalam bentuk logit agar dapat dilihat hubungan antar variabel respon dengan penjelas. Dengan

$$g(x) = \ln \left[\frac{\pi(x)}{1 - \pi(x)} \right] = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_k x_k$$

Dimana $\{\pi(x) / (1 - \pi(x))\}$ merupakan resiko dari $y = 1$ untuk x tertentu.

Apabila terdapat sebanyak p peubah bebas dan peubah ke- j merupakan peubah kategorik, maka akan terdapat peubah boneka sebanyak $k-1$, dengan dummy

melakukan transformasi logit dari $\pi(x)$, didapat persamaan yang lebih sederhana yang merupakan fungsi linier data parameter-parameternya, yaitu:

variabel k_j dinamakan D_{ju} dengan koefisien B_{ju} , $u = 1, 2, \dots, k_j - 1$. Sehingga model transformasi logit dapat dituliskan seperti persamaan berikut ini:

$$g(x) = \beta_0 + \beta_1 + \dots + \sum_{u=1}^{k_j-1} \beta_{ju} D_{ju} + \beta_k x_k$$

3. Correlation-based Feature Selection

Banyak faktor yang menentukan kesuksesan machine learning pada

suatu tugas tertentu. Faktor yang paling menentukan adalah kualitas dan representasi dari data example. Secara

teori, memiliki lebih banyak atribut atau feature seharusnya menghasilkan kekuatan yang membedakan. Akan tetapi, pengalaman praktis dengan machine learning tidak semua kasus menunjukkan demikian. Banyak algoritma learning dapat dipandang sebagai penciptaan estimasi probabilitas label kelas yang diberikan seperangkat feature. Data ini kompleks dan mempunyai distribusi dimensi yang tinggi. Sayangnya, algoritma induksi hanya bisa diterapkan pada data yang terbatas. Hal ini membuat estimasi banyak parameter probabilitas menjadi sulit dilakukan (Hall, 1999). Feature selection atau seleksi atribut adalah proses mengidentifikasi dan menghapus informasi yang tidak relevan dan redundan sebanyak mungkin (Hall, 1999).

Pengurangan dimensi data ini memungkinkan algoritma machine learning untuk bekerja lebih cepat dan lebih efektif. Pada beberapa kasus akurasi klasifikasi dapat ditingkatkan; lainnya hasilnya lebih sederhana dan mudah dipelajari dan diinterpretasikan.

Algoritma feature selection menampilkan pencarian melalui seperangkat subset feature dan sebagai konsekuensinya, harus mengarah pada empat kriteria dasar pencarian (Langley, 1994):

1. Starting Point atau titik awal. Pemilihan titik awal untuk pencarian seperangkat subset akan mempengaruhi arah pencarian. Salah satu pilihan dengan memulai nol feature dan secara berurutan menambahkan atribut. Pada kasus ini, pencarian dikatakan bergerak maju di dalam ruang pencarian. Sebaliknya, pencarian dimulai dengan semua feature kemudian secara berurutan mengurangi feature sampai nol, ini dikatakan pencarian bergerak mundur. Alternatif lain dengan mencari dari titik tengah kemudian bergerak keluar.
2. Search Organization. Pencarian subset yang mendalam menjadi penghalang pencarian semua atribut. Misal terdapat N atribut maka ada 2N kemungkinan subset. Strategi heuristik lebih mungkin dari pada pencarian yang mendalam dan dapat memberikan hasil yang bagus, walaupun tidak menjamin

menemukan subset yang optimal.

3. Evaluation strategy. Bagaimana seperangkat feature dievaluasi adalah faktor yang paling membedakan diantara algoritma seleksi atribut untuk machine learning. Salah satu paradigma disebut filter, yang beroperasi secara independen dari algoritma machine learning apapun. Pada metode filter ini feature yang tidak diinginkan dikeluarkan dari data sebelum dilakukan pembelajaran. Pendekatan lain adalah sebuah algoritma induksi tertentu diterapkan untuk memilih atribut, metode ini disebut wrapper.
4. Stopping criterion. Sebuah pemilih atribut harus memutuskan kapan untuk menghentikan pencarian pada seperangkat feature. Tergantung dari strategi evaluasi yang digunakan, pemilih atribut bisa menghentikan atau menambahkan atribut ketika tidak ada lagi atribut alternatif yang meningkatkan merit subset feature saat ini.

Correlation-based feature selection yang selanjutnya disebut seleksi atribut berbasis korelasi atau CFS adalah sebuah algoritma filter sederhana yang meranking subset berdasarkan fungsi evaluasi heuristik berbasis korelasi (Hall, 1999). Berdasarkan hipotesis bahwa subset atribut yang bagus berisi atribut yang mempunyai korelasi tinggi terhadap kelas dan tidak saling berkorelasi satu sama lain. Korelasi yang tinggi satu sama lain atribut menandakan atribut tersebut redundan. Atribut yang berkorelasi rendah terhadap kelas adalah atribut yang tidak relevan. Atribut yang tidak relevan dan redundan harus dihapus. Rumus untuk pencarian subset atribut berdasarkan korelasi adalah (Hall, 1999)

$$r_{zc} = \frac{kr_{zi}}{\sqrt{k+k(k-1)r_{ii}}}$$

4. Hasil dan Pembahasan

TABEL I
HASIL PENGUJIAN PADA ALGORITMA LOGISTIC
REGRESSION

	Sebelum Seleksi Atribut	Sesudah Seleksi Atribut
Correctly Classified Instances (%)	93,99	93,20

Incorrectly Classified Instances (%)	6,01	6,80
Kappa statistic	0,88	0,86
Mean absolute error	0,09	0,1
Root mean squared error	0,21	0,22
Relative absolute error (%)	17,50	19,34
Root relative squared error (%)	42,38	44,36
Total Number of Instances	11055.00	11055.00

TABEL 2. ATRIBUT SETELAH FEATURE REDUCTION

Prefix_Suffix
having_Sub_Domain
SSLfinal_State
Request_URL
URL_of_Anchor
Links_in_tags
SFH
web_traffic
Google_Index
Result

Berdasarkan hasil eksperimen menunjukkan bahwa setelah dilakukan seleksi atribut menggunakan metode correlation-based feature selection, terjadi penurunan jumlah true positif dan true negatif. Selain itu juga terjadi peningkatan false positif dan false negatif. Kedua hal ini yang mempengaruhi penurunan tingkat akurasi.

Jumlah atribut sebelum dilakukan seleksi atribut adalah 31, setelah dilakukan seleksi atribut jumlah atribut jauh berkurang menjadi 9 atribut. Walaupun terjadi penurunan jumlah atribut yang cukup signifikan namun berdasarkan hasil eksperimen menunjukkan bahwa tingkat akurasi tidak jauh berbeda, hanya selisih 0,8%. Hal ini menunjukkan bahwa seleksi atribut menggunakan metode correlation-based feature selection mampu menghilangkan atribut yang tidak relevan serta redundan.

IV. KESIMPULAN DAN SARAN

Berdasarkan uraian pada bagian-bagian sebelumnya dapat disimpulkan bahwa CFS mampu menghilangkan atribut

redundan. Subset atribut yang dihasilkan mempunyai tingkat akurasi yang tidak jauh berbeda dengan atribut lengkap. Tingkat akurasi sebelum seleksi atribut 93,99% dan akurasi setelah seleksi atribut 93,20%.

Penelitian selanjutnya menerapkan metode feature selection lainya dan dibandingkan hasilnya dengan penelitian ini.

V. DAFTAR PUSTAKA

- [1] Alkhozai, M., & Batarfi, O. (2011). Phishing Websites Detection based on Phishing Characteristics in the Webpage Source Code . *International Journal of Information and Communication Technology Research* , 283-291.
- [2] Dhanalakshmi, R., Prabhu, C., & Chellapan, C. (2011). Detection Of Phishing Websites And Secure Transactions. *International Journal Communication & Network Security (IJCNS)*, 15-21.
- [3] Hall, M. (1999). *Correlation-based Feature Selection for Machine Learning*. Hamilton: Thesis University of Waikato.
- [4] Langley, P. (1994). Selection of Relevant Feature in Machine Learning. *AAAI Symposium on Relevance* . Los Angeles: AAAI.
- [5] Mohammad, R., McCluskey, T., & Thabtah, F. A. (2012). An Assessment of Features Related to Phishing Websites using an Automated Technique. *International Conferece For Internet Technology And Secured Transactions*. (ss. 492-497). London: ICITST 2012
- [6] Mohammad, R., McCluskey, T., & Thabtah, F. A. (2013). Predicting Phishing Websites using Neural Network trained with Back-Propagation. *Proceedings of the 2013 World Congress in Computer Science, Computer Engineering, and Applied Computing. WORLDCOMP 2013* (ss. 682-686). Las Vegas: World Congress in Computer Science, Computer Engineering, and Applied Computing.
- [7] Mohammad, R., McCluskey, T., & Thabtah, F. A. (2014). Intelligent Rule based Phishing Websites Classification. *IET Information Security*, 153-160.