REDES NEURAIS COM APRENDIZADO NÃO SUPERVISIONADO ALGORITMO K-MEANS SOBE A PERSPECTIVA DE ANALISE DE POTÊNCIA

Jorge Luís de Lima Varella (Mestrando em Engenharia – UCP Petrópolis) E-mail: jorge.varella@icloud.com
Giovane Quadrelli (Mestrando em Engenharia – UCP Petrópolis) E-mail: giovane.quadrelli@ucp.br

Resumo: Este artigo apresenta um breve resumo sobre o algoritmo de aprendizado não supervisionado ***K-Means*** e suas características, no que tange a sua implementação básica e aplicabilidade. O artigo descreve a sua utilização em áreas onde a clusterização é fator primordial. Uma análise da utilização do algoritmo é feita sobe a ótica de analise de potência em um ambiente de criptoanálise em criptografia de curva elíptica e criptografia RSA.

Palavras-chave: ***K-Means***. Criptoanálise. Clusterização.

NEURAL NETWORKS WITH LEARNING NOT SUPERVISED ALGORITHM K-MEANS UNDER THE PERSPECTIVE OF POWER ANALYSIS

Abstract: This article presents a brief summary about the K-Means unsupervised learning algorithm and its characteristics, with respect to its basic implementation and applicability. The article describes its use in areas where clustering is a prime factor. An analysis of the use of the algorithm is made on the power analysis optics in a cryptanalysis environment in elliptic curve cryptography and RSA encryption.

Keywords: K-Means. Cryptanalysis. Clustering.

1. INTRODUÇÃO

Para prover segurança em um ambiente computacional pode-se aplicar diversas técnicas, sendo uma delas a criptografia. Uma criptografia forte, (que pode ser medida pelo tempo e recursos que se exige para recuperar o dado), precisa resistir as diversas formas de ataque que buscam obter do sistema informações sigilosas. Estes ataques podem ocorrer no próprio algoritmo de criptografia, assim como em problemas computacionais subjacentes decorrentes de sua implementação (LADEIRA, 2016).

Uma das classes deste tipo de ataque é o de canal lateral, que faz uso de informações colidas durante a execução de uma primitiva criptográfica. Este tipo de ataque utiliza variações no tempo de execução, no consumo de energia e emanações eletromagnéticas dentre outras características do sistema a ser atacado.

Contramedidas podem ser executadas nestes ataques como por exemplo modificações de software e hardware.

Este artigo irá abordar o algoritmo ***K-Means*** empregado para ***clustering*** nos ataques de consumo de energia.

2.0 Algoritmo *K-Means*

O ***K-Means*** é um algoritmo de aprendizado não supervisionado, comumente utilizado em mineração de dados e na resolução de problemas de agrupamentos.

Diferente do aprendizado supervisionado, onde se informa ao sistema o que ele deve procurar ou aprender, no aprendizado não supervisionado não se sabe exatamente o que esta se tentando ensinar ao sistema, isso faz com que seja preciso recorrer a agrupadores lógicos de segmentação para encontrar similaridade entre os dados da amostra, e como isso seja possível definir um padrão (NOGARE, 2016).

Definido o padrão, se assume que é isto que está se tentado ensinar ao sistema, e que por sua vez irá aprender a encontrar este padrão sempre que for acionado. A partir deste padrão, todos os novos itens que tenham a mesma similaridade com aquele segmento serão agrupados.

Na figura 1 é possível observar o modelo original e nas figuras 2 e 3 a separação de grupos, que pode ser feito de diversas formas.

Figura 1 – Modelo original

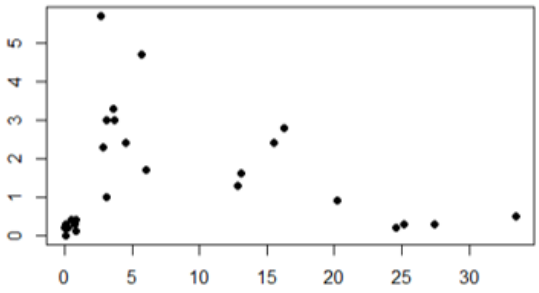

Fonte: MOORE, 2016

Figura 2 – Separação de Grupo A

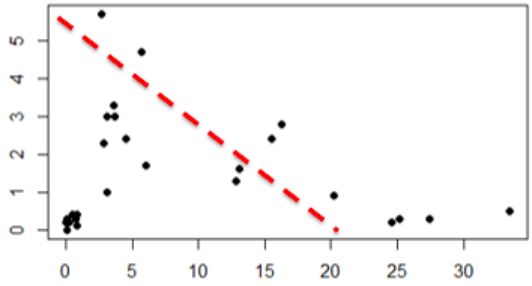

Fonte: MOORE, 2016.

Figura 3 – Separação de Grupo B

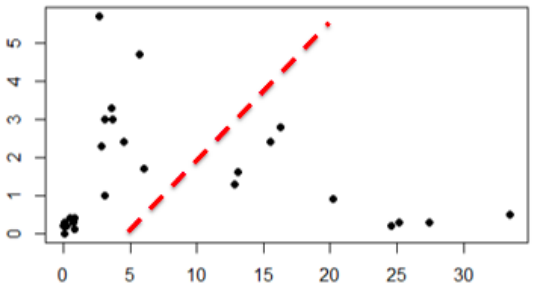

Fonte: MOORE, 2016.

3.0. Algoritmo K-Means

O algoritmo ***K-Means*** usa uma forma simples e fácil de classificar um conjunto de dados por meio de um numero de ***cluster***, que deve ser fixado antes da execução do algoritmo.

Segundo Matteucci (2016) o conceito principal é definir **k** centróides, um para cada cluster pré-definido, esses centroides devem ser definidos por conta da separação entre os resultados. Desta forma a escolha deve ser feita para colocá-los distantes um dos outros. A seguir deve-se fazer com que cada ponto pertença a um conjunto de dados e vinculá-lo ao centroide mais próximo. Quando da conclusão desta etapa todos os pontos devem pertencer a um grupo.

O próximo passo é recalcular **k** novos centróides como pontos centrais dos ***clusters*** do passo anterior. Depois de ter esses novos **k** centroides calculados, uma nova ligação deve ser feita entres os mesmos pontos do conjunto de dados e o novo centróide mais próximo. Um ***loop*** deve ser executado com esta função e como resultado, é possível observar que os **k** centroides mudam de localização até que não aconteçam alterações.

O algoritmo ***k-Means*** tem como objetivo minimizar uma função objetivo, neste caso específico uma função quadrática de erro que pode ser vista conforme mostra Matteucci, (2016) na equação 1.

Equação 1 - Função Objetivo

$$J = \sum_{j=1}^{k} \sum_{i=1}^{n} \left\| x_i^{(j)} - c_j \right\|^2$$

Percebe-se que onde $X_i^{(j)}$ e C_j representam a distância entre o ponto e o centro do ***cluster***.

O algoritmo pode ser definido pelas seguintes etapas:

K representa os objetos que se pretende agrupar e são a representação dos centroides iniciais.

Associa cada objeto ao grupo centroide mais próximo.

Quando todos os objetos tiverem sido associados, recalcule as posições dos centroides **K**.

Repita os passos até que os centroides não mudem de posição.

Este procedimento termina sempre com um resultado de separação, embora não necessariamente ótimo. O algoritmo ***K-Means*** é sensível aos centros de agrupamento selecionados aleatoriamente, por conta disso é necessária sua definição assertiva e que deve ser tomada como uma premissa.

Como mencionado anteriormente o algoritmo deve ser executado varias vezes até que os centroides não apresentem mudança e com isso reduzir seus efeitos.

A escolha de **k** pode ser feita através do método ***Elbow***, o método tem esse nome por ter seu resultado parecido com um braço e o que se procura é um cotovelo para definir um numero de **k** a serem criados, com base no numero de amostra. Este método faz crescer a quantidades de clusters a partir de 1 (um) e analisa o melhor resultado após cada incremento, quando o beneficio não for mais relevante encontrasse o melhor resultado de **k** (LADEIRA, 2016), como pode ser visto na figura 5.

Figura 5 – Método Elbow

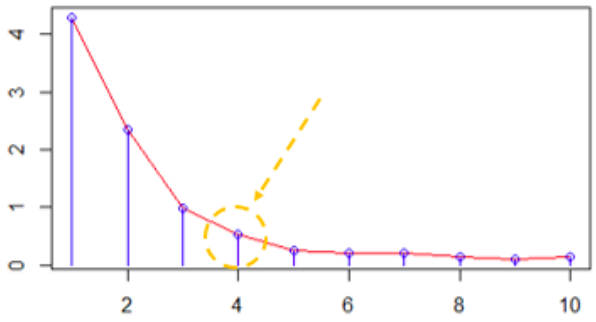

Fonte: NOGARE, 2016.

O algoritmo ***K-Means*** é um dentre vários de propõem a resolver problemas de ***clustering***, e se destaca pela sua simplificação e fácil aplicação como veremos ao longo deste artigo.

O exemplo de código de um algoritmo ***K-Means*** faz parte deste artigo, e foi baseado em um exemplo do site do MatLab. Isso torna possível materializar explicação dada até este momento.

Código ***K-Means***. MatLab (2016).

```
clc
clear all
close all

%% Gerando os pontos

Sigma = [0.5 0.05; 0.05 0.5];
f1    = mvnrnd([0.5 0]  ,Sigma,100);
f2    = mvnrnd([0.5 0.5],Sigma,100);
f3    = mvnrnd([0.5 1]  ,Sigma,100);
f4    = mvnrnd([0.5 1.5],Sigma,100);
F     = [f1;f2;f3;f4];

%% K-means
K     = 4;                                % Números de Clusters
KMI   = 400;                              % K-Means Interações
CENTS = F( ceil(rand(K,1)*size(F,1)) ,:);           % Cluster Centro
DAL   = zeros(size(F,1),K+2);                       % Distâncias
CV    = '+r+b+c+m+k+yorobocomokoysrsbscsmsksy';      % Cores dos vetores

for n = 1:KMI

  for i = 1:size(F,1)
    for j = 1:K
      DAL(i,j) = norm(F(i,:) - CENTS(j,:));
    end
    [Distance CN] = min(DAL(i,1:K));              % 1:K Distância do cluster ao centro 1:K
    DAL(i,K+1) = CN;                              % K+1 Identificação do cluster
    DAL(i,K+2) = Distance;                        % K+2 Distância mínima
  end
  for i = 1:K
    A = (DAL(:,K+1) == i);                        % Cluster K Pontos
    CENTS(i,:) = mean(F(A,:));                    % Novo centro do cluster
    if sum(isnan(CENTS(:))) ~= 0                  % Ponto randômico
      NC = find(isnan(CENTS(:,1)) == 1);          %
      for Ind = 1:size(NC,1)
      CENTS(NC(Ind),:) = F(randi(size(F,1)),:);
      end
    end
  end

%% Plotando
clf
figure(1)
hold on

 for i = 1:K
PT = F(DAL(:,K+1) == i,:);                        % Ponto de cada cluster
plot(PT(:,1),PT(:,2),CV(2*i-1:2*i),'LineWidth',2);    % Plotar o ponto
plot(CENTS(:,1),CENTS(:,2),'*k','LineWidth',7);       % Plotar cluster
 end

hold off
grid on
pause(0.1)

end
```

A figura 6 representa o resultado da operação do algoritmo, onde é possível identificar o agrupamento em torno dos centróides.

Figura 6 - Agrupamento

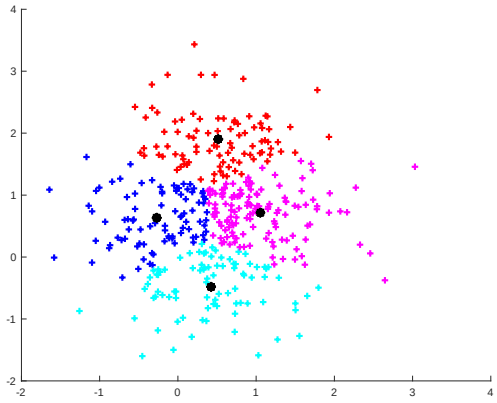

Fonte: MatLab, 2016.

Como pode ser visto a existem 4 áreas bem distintas onde houve a aglutinação dos pontos, após 400 interações pré-definidas no algoritmo.

4.0 Aplicação em criptoanálise

A aplicação do algoritmo ***K-Means*** no ambiente de criptoanálise esta ligado a um tipo de ataque chamado "Ataque Horizontal", que é uma metodologia para ataques de canal lateral, cujo alvo são protocolos criptográficos assimétricos baseados em RSA e ECC e que fazem uso da exponenciação modular no caso do algoritmo RSA e multiplicação escalar no caso de ECC. Em teoria estes ataques permitem recuperar os bits do expoente/escalar secreto (LADEIRA, 2016).

Especificamente em um ataque lateral a criptografia de curva elíptica é possível o que o ataque seja executado em uma das camadas de sua implementação, ou seja:

Aplicação.

Protocolo.

Multiplicação escalar.

Adição e duplicação de ponto.

Aritmética de ponto finito ou aritmética de inteiros grandes.

Protocolos de criptográficos em ECC, são implementados a partir dessas primitivas e que foram listadas anteriormente. Vale ressaltar a interdependência entre as camadas e suas operações, e que isto impacta diretamente em seu desempenho e segurança.

Há varias formas de ataques a criptografia de curva elíptica como ataque de tempo e contramedidas como randomização escalar, mas não são o foco deste artigo. A analise será feita tomando como base o algoritmo ***K-Means*** e a analise de potencia especificamente.

O método de ***correlation analysis*** segue o principio de analise potência, e neste contexto o ***trace*** é dividido em vários seguimentos (***Clustering***), como pode ser visto na figura 7, e para cada um deles é atribuído um valor hipotético, e a relação entre a amostra e o valor hipotético é calculada.

Os ataques horizontais requerem pré-processamento avançados de ***trace***, caracterização e avaliação de vazamento, o principal problema desta abordagem esta em extrair o vazamento a partir de um único trace.

Métodos de aprendizagem não supervisionada com o ***K-Means***, tema deste artigo é a forma recentemente aplicada para resolver esta limitação. Este método pode ser aplicado em um único trace e assim permitindo a identificação de classes, (agrupamento) especifico na operação como pode ser visto na figura 7.

Figura 7 – Trace a ser analisado

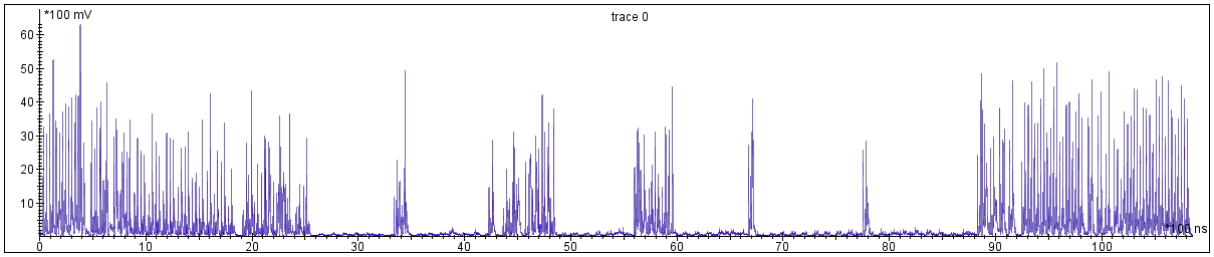

Fonte: LADEIRA, 2016.

Ainda sobre o ***K-Means*** é possível afirmar que é um algoritmo rígido, isto é cada instância é atribuída a um único ***cluster***, característica importante na sua utilização em criptoanálise.

A partir deste ponto é possível fazer a verificação de uma chave conhecida, que consiste em determinar os pontos de interesse, isto é, os índices das amostras onde o vazamento é forte. Esta analise é realizada na fase de testes do ataque para determinar o

numero traces necessários para avaliação. Um analise, mas profunda deste tipo de ataque poderá ser vista em futuros artigos.

5.0. Análise e resultado

Capturados os ***traces*** de potência com objetivo de recuperação de chaves, os mesmos foram analisados da seguinte forma:

Agrupamento: Onde em cada vetor é aplicado o algoritmo ***K-Means***. Tal resultado por ser visto como um escalar aproximado.

Estimativa do Escalar: Escalares aproximados são combinados em um escalar único.

Grau de Confiança: Calcula-se o grau de confiança de cada bit recuperado. Este grau de confiança é um numero real entre 0 e 1 e depende do tipo de ataque que esta sendo realizado.

Taxa de sucesso: Taxa de sucesso é a media de bits do escalar recuperados corretamente.

Obtido estes dados é possível se ter indicadores para o ataque horizontal, cuja taxa de sucesso e grau de confiança devem ser altos, deve ser ressaltado que a qualidade das medidas dos traces esta diretamente ligada ao sucesso da coleta dos indicadores, ou seja, o equipamento usado nestas medidas deve ter qualidade e ser adequado a este fim.

Caso a quantidades de bits sem erro seja grande, o ataque de força bruta é viável se e somente se os bits contendo erros não sejam adjacentes.

A combinação de força bruta e outros algoritmos, como por exemplo Montgomery Ladder tem-se mostrado mais eficientes no ataque horizontal, e cujo detalhamento não será parte deste artigo.

6.0 Considerações Finais

O algoritmo ***K-Means*** tem aplicações diversas quando a premissa de clusterização se faz necessária, mas é valido destacar também algumas fraquezas, tais como a maneira popular de sua inicialização que é a escolha aleatória de **k** nas amostras, os resultados inicias dependem dos valores inicias para as medias, dentre outros.

Na criptoanálise o algoritmo ***k-Means,*** usado em analise de potência de ataque horizontal tem colaborado em diversos estudos que buscam garantir a segurança de

algoritmos de RSA e ECC. Estes estudos têm como resultados formas de contramedidas de segurança a serem implementadas tanto em ***hardware*** como ***software***.

Dentre estas contramedidas, o ***NIST*** tem encorajado desenvolvimento de métodos de teste e ferramentas para avaliar a eficiência de mitigações de contra-ataques não-invasivos a módulos criptográficos.

Em um momento em que sistemas de ***Smart Grid*** estão cada vez mais próximos do nosso cotidiano, a preocupação com o ataque de analise de potência vem se tornando motivo de preocupação e esta motivando diversos estudos nesta área.

REFERÊNCIAS

LADEIRA, L. Simpósio Brasileiro em segurança da informação e de sistemas computacionais. Disponível em: <http://sbseg2016.ic.uff.br/pt/files/minicursos.pdf>. Acesso em 16/11/2016.

MATLAB. Disponível em: <https://www.mathworks.com/help/stats/k-means-clustering.html>. Acesso em 19/11/2016.

MATTEUCCI, M. Tutorial de Algoritmos Clustering. Disponível em: <https://home.deib.polimi.it/matteucc/Clustering/tutorial_html/kmeans.html>. Acesso em 27/11/2016.

MOORE, A. "K-Means Hierarquia". Disponível em: <http://www.autonlab.org/tutorials/index.html?s[]=means>. Acesso em 27/11/2016.

NOGARE, D. Engenharia do Conhecimento e Sistemas Especialistas. Disponível em: <http://www.diegonogare.net/2015/08/entendendo-como-funciona-o-algoritmo-de-cluster-k-means/>. Acesso em 30/11/2016.

STALLINGS, W. Criptografia e segurança de redes princípios e praticas. 4 ed. São Paulo: Pearson Prentice Hall, 2010.