

비정상 행위 탐지를 위한 신경망 기반의 데이터 클러스터링

Data Clustering using a Neural Network for Anomaly Detection

김인영, 장병탁
서울대학교 컴퓨터공학부
{iykim, btzhang}@scai.snu.ac.kr

In-Young Kim and Byoung-Tak Zhang
Seoul National University

요 약

코호넨 자기조직 신경망을 사용하면 클러스터링뿐만 아니라 그 데이터가 할당된 클러스터의 대표값(Centroid)과의 거리 차이(Quantization Error)를 알아볼 수 있다. 이를 이용하면 어떤 데이터가 정상적인 분포를 따르는지 정상적인 분포에서 벗어나는 비정상적인 데이터인지 알 수 있고, 유닉스 시스템 사용자의 명령어 사용 패턴에 적용하여 어떤 사용자의 명령어 사용 패턴이 정상적인 것인지 비정상적인 것인지 알 수 있다. 본 논문에서는 유닉스 시스템 사용자 8명의 명령어 패턴을 클러스터링한 후 Quantization Error를 이용하여 비정상 패턴을 탐지하는 오프라인에서의 비정상 행위를 탐지하는 시스템을 구현하였다. 그리고 통계적인 학습 방법을 적용한 비정상 패턴 탐지와 비교를 통하여 두 가지 비정상 패턴 탐지 결과가 동일함을 확인하였다.

I. 서론

시스템 사용자의 행위를 관찰하고 분석하는 일은 시스템 관리자에게 많은 정보를 줄 수 있다. 예를 들어 각 사용자가 시스템에 로그인하여 사용한 명령어들을 보면 그 사용자의 명령어 사용 패턴을 알 수 있는데 이 데이터를 학습하여 사용자의 비정상적인 명령어 사용을 탐지할 수 있다. 이러한 연구는 오용 탐지(Misuse detection)와 비정상 탐지(Anomaly detection)로 구성되는 침입 탐지 시스템(IDS)에서의 비정상 탐지에 해당한다.

본 논문에서는 신경망과 통계적인 방법을 이용한 기계 학습 기법을 통해 시스템 사용자의 비정상적인 행위를 탐지하였다. 여기서 사용자의 비정상적인 행위라는 것은 그 사용자가 지금까지의 명령어 사용 패턴과는 다른 명령어 패턴을 보이는 것을 말한다. 비정상적인 명령어 패턴을 탐지하기 위해서 각 사용자의 명령어 패턴을 학습한 후 새로운 명령어 패턴에 대해 학습된 결과를 이용하여 정상적인 패턴인지 비정상적인 패턴인지 구별할 수 있다.

II. 본론

1. 문제 정의 및 데이터 설명

본 실험에서 관심을 가지는 것은 유닉스 시스템 사용자의 행동을 분석하고 각 사용자마다의 특정한 행동 패턴, 즉 명령어 사용에 있어서의 패턴을 학습하는 것이다. 이것은 각 사용자마다 사용하는 명령어와 그 빈도수가 다른 것을 이용하여 사용자의 명령어 사용 패턴을 학습하려는 것이다.

실험에 사용한 데이터는 8명의 사용자를 대상으로 2년 동안 수집된 데이터이다. 이 데이터는 유닉스 시스템에서 각 사용자의 명령어 사용 기록(History)을 이용하였으며 각 세션(Session)마다 구분이 되어 있다. 하나의 세션은 한 번의 로그인부터 로그아웃 사이의 모든 명령어 사용을 저장하고 있다. 전부 9개의 집합(Set)으로 구성되어 있는 이 데이터는 각 사용자마다 하나의 집합을 유지하며 그 중 다른 시스템에서 다른 프로젝트를 수행하던 한 명의 사용자의 경우에 각각을 다른 집합에 저장하였다. 이 데이터에 관한 자세한 설명은 "http://kdd.ics.uci.edu/databases/UNIX_user_data/README"에서 찾을 수 있으며 데이터는 "http://kdd.ics.uci.edu/databases/UNIX_user_data/UNIX_user_data.html"에서 얻을 수 있다.


본 실험에서의 데이터 표현은 신경망 등의 학습에서 주로 사용하는 방법인 벡터 표현 방법을 사용하였다. 각 세션별로 하나의 벡터를 만들어 사용하였고 실험에 사용된 벡터는 100개의 명령어에 대한 사용 빈도수를 이용한 100차원의 벡터이다.

2. 학습 방법

사용자의 명령어 패턴을 학습하는 것은 기존의 명령어 패턴을 각 사용자의 프로파일(Profile)에 저장을 하고 새로운 패턴이 들어왔을 때 그 사용자의 프로파일과 비교하여 갱신하는 작업을 하는 것을 의미한다. 다시 말하면 사용자의 명령어 패턴이 점차적으로 변해가는 것을 프로파일에 반영하여 현재의 명령어 패턴을 잘 표현하도록 하는 것이다.

위의 학습 방법을 두 가지 다른 실험에 적용시켜 보았다. 첫 번째 실험은 신경망을 이용한 코호넨 자기조직 신경망(Self-Organization Map)에서의 클러스터링(Clustering)이며 두 번째 실험은 각 사용자마다 여러 개의 명령어 패턴을 유지하면서 프로파일을 갱신하는 과정을 보여주는 실험이다.

코호넨 자기조직 신경망을 이용한 클러스터링은 무감독(Unsupervised) 학습 방법으로 스스로 n 차원의 입력 데이터들을 클러스터링하여 2차원 상에 표현시켜준다. 코호넨 자기조직 신경망은 신경망을 이용하여 구현한 것으로 그 내부는 아래의 그림과 같다.



[그림1] 코호넨 네트워크의 구조

[그림1]은 2-layer 신경망으로 n 차원의 입력 데이터를 표현하는 n 개의 입력 노드들과 k 개의 분류 영역(Decision Region)을 표현하기 위한 k 개의 출력 노드로 구성되어 있다. 모든 입력 노드들은 모든 출력 노드들과 연결되어 있고 연결 가중치(Weight)를 가진다.

초기 상태에서는 연결 가중치들을 임의로 할당한다. 임의의 연결 가중치를 할당한 후 유클리드 거리를 이용하여 입력 벡터와의 유사성을 측정한다. 입력 벡터와 k 개의 연결 가중치 벡터사이의 유클리드 거리를 구하여 입력 벡터와 가장 유사한 j 번째 연결 가중치 벡터를 찾으면 그 입력 벡터에 대해서 j 번째 출력 노드가 승자가 된다. 이렇게 승자를 선택하면 승자의 연결 가중치 벡터는 [식1]과 같이 갱신된다.

$$w^j(t+1) = w^j(t) + \alpha(t)[x(t) - w^j(t)] \quad [\text{식1}]$$

$$\alpha(t) = 0.1(1 - t/10^4) \quad [\text{식2}]$$

$\alpha(t)$ 는 시간이 경과함에 따라 연결 가중치 벡터가 안정화되도록 하는 역할을 하는 파라미터이고 [식2]와 같이 표현된다. [식1]의 의미는 j 번째 출력 노드가 승자가 되었으면 그 노드의 연결 가중치 벡터는 입력 데이터 쪽으로 약간 이동한다. 결과적으로 연결 가중치 벡터를 입력 데이터에 근사하도록 만들어 가는 것이다.

각 사용자마다 여러 개의 패턴을 프로파일에 저장하고 있으면서 새로운 패턴에 대해 학습하고 프로파일을 갱신하는 알고리즘은 아래와 같다.

사용자마다 최대 몇 개(M)의 패턴을 프로파일에 저장할 것인지 가정한다. 이 실험에서는 각 사용자마다 최대 10개의 패턴을 프로파일로 가진다고 정하였다. 즉, 각각의 사용자는 최대 10가지의 상이한 명령어 사용 패턴을 보일 수 있다.

- i. M 개의 패턴이 되기 전까지는 들어오는 패턴을 모두 프로파일에 저장한다.
- ii. 프로파일에 저장된 패턴의 개수가 M 개를 넘은 경우는 다음의 과정을 거친다.
 1. 새로 들어온 패턴을 포함한 $M+1$ 개의 패턴간 차이를 계산한다.
 2. 두 패턴간 차이가 가장 작은 두 패턴을 통합한다.


위의 알고리즘을 통해서 M 개의 상이한 패턴을 포함하는 프로파일을 유지할 수 있다. 새로 들어온 패턴이 프로파일에 속해 있는 어느 패턴과 유사한 패턴이라면 그 패턴과 함께 통합(Merge)될 것이며 전혀 새로운 패턴이라면 다른 유사한 패턴의 쌍 2개가 통합되면서 새로 들어온 패턴이 프로파일에 추가될 것이다. 이때 벡터간의 유클리드 거리로 표현되는 패턴간 차이를 보면 새로 들어온 패턴이 기존에 학습된 프로파일에 있는 다른 패턴들과 얼마나 차이가 나는지 알 수 있다. 결국 사용자가 지금까지의 명령어 사용 패턴과는 다른 비정상적인 명령어 사용을 보임을 알 수 있다.

3. 실험 및 결과

실험은 위에서 제시한 두 가지 방법으로 수

행하였다. 첫 번째로 코호넨 자기조직 신경망을 이용한 실험에서는 전체 사용자들의 명령어 패턴을 이용하여 클러스터링 하였다. 클러스터링 결과 [그림2]와 [그림3]을 통해 데이터들의 전체적인 분포를 살펴볼 수 있다. [그림2]에서 인접한 노드들은 서로 비슷한 유형의 패턴들이 이루는 클러스터들이고 거리가 멀고 명암의 차이가 많이 나는 노드들은 서로 다른 패턴을 나타내는 클러스터들이다. [그림3]에서는 n 차원의 데이터 벡터로 표현되는 각각의 클러스터를 2차원으로 표현한 것으로 데이터들의 전체적인 분포와 밀집 정도를 볼 수 있다.

[그림2] 클러스터링 결과




[그림3] 2차원상의 클러스터 분포

또한 각 사용자의 명령어 패턴의 분포를 알아보기 위해 각각의 사용자별 클러스터링도 하였다. 이 경우 한 명의 사용자로부터 나온 여러 가지 명령어 패턴에 대해서 클러스터링하며 각 클러스터를 대표하는 Centroid 벡터값과 해당 클러스터에 속한 각각의 데이터와의 차이를 표현하는 Quantization Error값을 통해서 비정상적인 패턴을 탐지할 수 있다.

두 번째 실험에서는 통계적인 방법을 이용하여 사용자의 명령어 패턴 학습 및 비정상적인 명령어 사용을 탐지한다. 앞에서 설명한 알고리즘대로 각 사용자마다 최대 M 개의 명령어 패턴을 포함하는 프로파일을 유지하고 있다. 새로운 명령어 패턴이 주어진다면 프로파일에 속해 있는 다른 명령어 패턴과의 유클리드 거리를 측정하여 그 차이가 Threshold θ 이상이면 비정상 패턴으로 간주한다. 그 후 새로 들어온 패턴을 포함한 $M+1$ 개 패턴 사이의 유사성을 비교하여 가장 유사한 두 개의 패턴은 하나의 패턴으로 통합한다. 그러면 다시 전체적으로 M 개의 패턴이 유지되면서 새로운 패턴에 대한 학습이 끝나게 된다.

[그림4]는 Threshold θ 를 정하기 위해서 새로 들어온 명령어 패턴 벡터와 프로파일내의 M 개의 벡터들과의 거리 중 최소 거리를 도수분포표로 나타낸 것이다. 아래 그림에서의 사용자는 새로 들어온 명령어 패턴이 기존의 패턴과 평균적으로 유클리드 거리 0.25의 차이가 나며 분산은 0.15라는 것을 알 수 있는데 만약 새로 들어온 패턴의 최소 거리가 θ 이상이면 비정상적인 명령어 사용이라고 탐지한다.



[그림4] Mean : 0.25, Variance : 0.15

III. 결론

신경망에 근거한 방법과 통계적인 방법에 근거한 두 가지 실험으로 확인할 수 있었던 것은 두 실험 모두 비정상적인 명령어 사용을 탐지하는 데 효과적이라는 것이다. 즉, 기존에 학습된 프로파일과 상이한 패턴이 들어오면 코호넨 자기조직 신경망의 경우 Quantization

Error값이 정상 분포에서 벗어나는 것을 알 수 있었고 마찬가지로 통계적으로도 프로파일 내의 다른 패턴들과의 최소 거리가 정상 분포에서 벗어난 큰 값을 가지는 것을 확인할 수 있었다.

지금까지의 실험에서는 사용자의 명령어 패턴을 명령어 사용 빈도수만을 이용하여 학습하였으나 사용된 명령어들 사이의 순서를 학습한다면 온라인으로 비정상적인 명령어 패턴을 탐지할 수 있을 것이며 더욱 효과적인 방법이 될 것이다.

감사의 글

본 연구는 학술진흥재단 자유공모과제 (1999-001-E01025)에 의해 지원되었음.

IV. 참고 문헌

- [1] Jake Ryan, Meng-Jang Lin, and Risto Miikkulainen. Intrusion Detection with Neural Networks. *Proceedings of NIPS-98*, pp. 943-949, 1998.
- [2] Michael Chester. *Neural Networks: A Tutorial*, Prentice Hall. pp. 42-49, 1993.
- [3] Simon Haykin. *Neural Networks: A Comprehensive Foundation*, Prentice Hall. pp. 443-483, 1999.
- [4] Teuvo Kohonen, Jussi Hynninen, Jari Kangas and Jorma Laaksonen. *SOM_PAK The Self-Organizing Map Program Package*, 1995.
- [5] Teuvo Kohonen. *Self-Organizing Maps: Second Edition*, Springer. pp. 48-51, 1997
- [6] Aurobindo Sundaram. *ACM Crossroads*, April 1996.
- [7] http://kdd.ics.uci.edu/databases/UNIX_user_data/UNIX_user_data.html
- [8] Liren Chen, Katia Sycara. WebMate: A personal agent for browsing and searching, *Proceedings of the International Conference on Autonomous Agents (AA-98)*, 1998.
- [9] Neil C. Rowe, Sandra Schiavo. An Intelligent tutor for intrusion detection on computer systems. *Computers & Education* 31. pp. 395-404, 1998.