

Détection d'anomalies non supervisée dans NSL-KDD en utilisant un β -VAE

une approche basée sur l'espace latent et l'erreur de reconstruction

Dylan Baptiste^{*†}, Ramla Saddem^{*}, Alexandre Philippot^{*}, François Foyer[†]

^{*}Université de Reims Champagne-Ardenne, CReSTIC, France

[†]Seckiot, Paris, France



Introduction

- Convergence IT/OT croissante
- Besoin accru en systèmes « *Intrusion Detection System* »
- Focus sur une approche non supervisée



Objectifs de l'étude

- Détection d'anomalies non supervisé
- Comparaison de deux approches en exploitant un β -VAE :
 - Erreur de reconstruction
 - Distance dans l'espace latent
- Application sur le jeu de données NSL-KDD*


Le modèle β -VAE

Encodeur

Qui projette une donnée x
dans un espace latent z

Décodeur p_θ


Qui récré la donnée initiale à partir de z



couche

Réseau de neurones

Fonction de coût



$$\underbrace{-\mathbb{E}_{q_\phi(z|x)}[\log p_\theta(x|z)]}_{\text{Erreur de reconstruction}} + \underbrace{\beta \mathcal{D}_{KL}(q_\phi(z|x) || p(z))}_{\text{Divergence de Kullback-Leibler}}$$

Fonction de coût

Caractéristiques continues

activation linéaire avec *mean squared error*

$$\mathcal{L}_{\text{cont}} = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2$$

Caractéristiques booléennes

activation *sigmoid* avec *binary cross-entropy loss*

$$\mathcal{L}_{\text{bool}} = -\frac{1}{n} \sum_{i=1}^n [x_i \log(\hat{x}_i) + (1 - x_i) \log(1 - \hat{x}_i)]$$

Caractéristiques catégorielles

activation *softmax* avec *categorical cross-entropy loss*

$$\mathcal{L}_{\text{cat}} = -\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^m x_{ij} \log(\hat{x}_{ij})$$

$$\mathcal{L}_{\text{rec}} = \mathcal{L}_{\text{cat}} + \mathcal{L}_{\text{bool}} + \mathcal{L}_{\text{cont}}$$


Méthode 1 : Erreur de reconstruction

Algorithm 1 $\mathcal{L}_{rec}$ -classification

Require: x a sample to classify, (q_ϕ, p_θ) : a trained β -VAE, τ : the threshold

Ensure: y : classification label : normal or anomalie

- 1: $z \sim q_\phi(z|x)$ ▷ Encoder
 - 2: $\hat{x} \leftarrow p_\theta(z)$ ▷ Decoder
 - 3: **if** $\mathcal{L}_{rec}(x, \hat{x}) > \tau$ **then**
 - 4: $y \leftarrow$ anomalie
 - 5: **else**
 - 6: $y \leftarrow$ normal
 - 7: **end if**
 - 8: **return** y
-




Méthode 2 : Distance dans l'espace latent

On calcule la moyenne des distances de la projection $\mathbf{z}$ d'une nouvelle observation $\mathbf{x}$ au k plus proches projections d'un ensemble $\mathbf{X}$ connu.

$$\mathcal{Z}_k^X(x) = \frac{1}{k} \sum_{j=1}^k \|z - z'_{(j)}\|_2$$

Avec $z \sim q_\phi(x|z)$
et $z'_{(j)}$ le j -ème plus proche voisin de z dans l'ensemble des projections de X .




Méthode 2 : Distance dans l'espace latent

Algorithm 2 $\mathcal{Z}_k$ -classification



Require: x a sample to classify, (q_ϕ, p_θ) : a trained β -VAE, X_{train} : the training dataset, k : the number of neighbors, τ : the threshold

Ensure: y : classification label : normal or anomalie

- 1: $Z_{train} \leftarrow \{z_i \sim q_\phi(z|x_i), \forall x_i \in X_{train}\}$
 - 2: $z \sim q_\phi(z|x)$
 - 3: Find the k nearest neighbors $z'_{(1)}, \dots, z'_{(k)}$ of z in Z_{train}
 - 4: **if** $\mathcal{Z}_k^{X_{train}}(x) > \tau$ **then**
 - 5: $y \leftarrow$ anomalie
 - 6: **else**
 - 7: $y \leftarrow$ normal
 - 8: **end if**
 - 9: **return** y
-



Évaluation



Évaluation

Denial of Service (DoS) :

Visent à rendre un service ou un système indisponible en le surchargeant de requêtes ou de trafic.

Probe :


Cherchent à collecter des informations sur le réseau ou les systèmes, comme la cartographie des ports ou des services actifs, en vue d'une attaque ultérieure.

User-to-Root (U2R) :


Permettent à un utilisateur malveillant, disposant d'un accès limité à une machine, d'obtenir des privilèges administrateur

Remote-to-Local (R2L) :

Permettent à un attaquant distant d'obtenir un accès local non autorisé sur une machine cible



Évaluation




Conclusion

- Les deux méthodes obtiennent d'excellents résultats sur ce jeu de données démontrant ainsi l'efficacité des β -VAE pour la détection non supervisée dans ce contexte

& Perspectives

- Seuils adaptatifs multi-métriques
- Fusion $\mathbf{L}_{rec}$ -classification + $\mathbf{Z}_k$ -classification
- La $\mathbf{Z}_k$ -classification ouvre la voie à une classification multilabel, au-delà d'un simple cadre binaire



The background is a collage of various scientific and technical plots. In the top left, there are ROC curves for 'DoS' and 'R2L' attacks, with AUC values ranging from 0.9515 to 0.9950. Below these are more ROC curves for 'U2R' and 'Probe' attacks. In the top right, there are 3D surface plots showing probability distributions for variables labeled ϕ , λ , and ρ . In the bottom right, there is a line plot with multiple data series, each corresponding to a different value of β (0.1, 0.01, 0.001, 0.0001, 1e-05, 0). The word 'Questions' is centered over this collage in a large, bold, black font.

Questions