



# Kill Chain Catalyst for Autonomous **Red Team** Operations in Dynamic Attack Scenarios

Autores: Antonio Horta, Anderson dos Santos e Ronaldo Goldschmidt  
IME – RJ



# Sumário

- **Introdução**
  - Contextualização
  - Problema de pesquisa
  - A perspectiva do atacante
  - Objetivo
  - A proposta
- **Trabalhos Relacionados**
- **Fundamentos e Conceitos**
  - Alinhamento de sequências
  - Aprendizado por Reforço
  - Random Forest
  - Gini Impurity-Based Weighted Random Forest
- **Metodologia**
  - Kill Chain Unscrambler
  - Ambiente
  - Espaço de ação
- **Experimentos e Resultados**
  - Experimento 1 – Experiência limitada
  - Experimento 2 – Resiliência em cenário dinâmico
- **Conclusão e Trabalhos Futuros**
- **Referências**

## Contextualização

Com o avanço da tecnologia, tarefas antes executadas por humanos agora são executadas de forma autônoma por máquinas incorporadas à inteligência artificial. Além de robôs industriais e veículos autônomos, estudos no campo de ataques cibernéticos visam automatizar as operações do **Red Team** (Al-Azzawi et al. 2024; Paudel e Amariuca 2023) para aumentar a segurança de empresas, treinamentos, competições e guerra cibernética.

## Problema de pesquisa

Como tornar os ataques conduzidos por agentes de **Aprendizado por Reforço**, do inglês Reinforcement Learning (RL) mais **furtivos\*** e **resilientes em ambientes dinâmicos?**

\* considerando como furtividade a minimização os passos e falhas durante a incursão.



## A perspectiva do atacante

No domínio dos ataques cibernéticos, particularmente em cenários, como torneios Capture the Flag (CTF), **os invasores não têm conhecimento prévio do ambiente alvo**, o qual, é descoberto durante a campanha (Ortiz-Garces et al. 2023). De acordo com Che Mat et al. (Che Mat et al. 2024), uma estratégia furtiva (stealthy) é essencial e o processo de tomada de decisão sequencial é decisivo para que as ações do ataque tenham **menos etapas e falhas para minimizar a probabilidade do ataque ser exposto**.

Imagem gerada pelo ideogram.ai





## Objetivo

Esta pesquisa tem objetivo de propor um **algoritmo de RL** que considera a **perspectiva de um atacante**, em **minimizar o número de passos e falhas**, assim como **resiliente** na execução de um ataque a um **cenário dinâmico e desconhecido**, de modo a minimizar a possibilidade de exposição.

## A proposta

- O algoritmo **Kill Chain Catalyst (KCC)** será apresentado. O KCC emprega **a lógica da árvore de decisão** para orientar o agente em ataques, aumentando a resiliência em ambientes dinâmicos e a furtividade por meio da **minimização de falhas e passos**;
- Além disso, um **catalisador inspirado no alinhamento genético**, otimiza a busca por um encadeamento mais eficiente no sequenciamento das técnicas de ataque utilizadas;
- A característica de destaque do KCC em problemas de tomada de decisão sequencial para ataques cibernéticos está no uso do **Random Forest como mecanismo RL**.

**Table 2. Related works with experiments.**

Environment	Algorithm	Analysis	Ref.
Real	A3C/DPPO/GAIL	Steps, Reward, Loss	(Chen et al. 2023)
Real	DQN	Steps, Rewards	(Li et al. 2022)
Real	Random Forest	Rewards	(Holm 2022)
Simulation	NDSPI-DQN dec.	Steps, Rewards	(Zhou et al. 2021)
Simulation	CLAP(PPO+RND)	Steps, Rewards	(Yang and Liu 2022)
Simulation	HA-DQN	Steps, Rewards	(Tran et al. 2021)
Simulation	DQN + LSTM	Steps, Rewards	(Standen et al. 2021)



A person wearing a red hoodie is sitting in a server room, surrounded by multiple computer monitors. The person is holding a pen and writing in a notebook. The room is dimly lit, with the primary light source being the blue glow from the numerous computer monitors. The person is looking directly at the camera with a serious expression. The text "Fundamentos e conceitos" is overlaid in the center of the image in a white, bold, sans-serif font.

# Fundamentos e conceitos



## Alinhamento de sequências

Table 1. Example for sequence align by Needleman-Wunsch algorithm

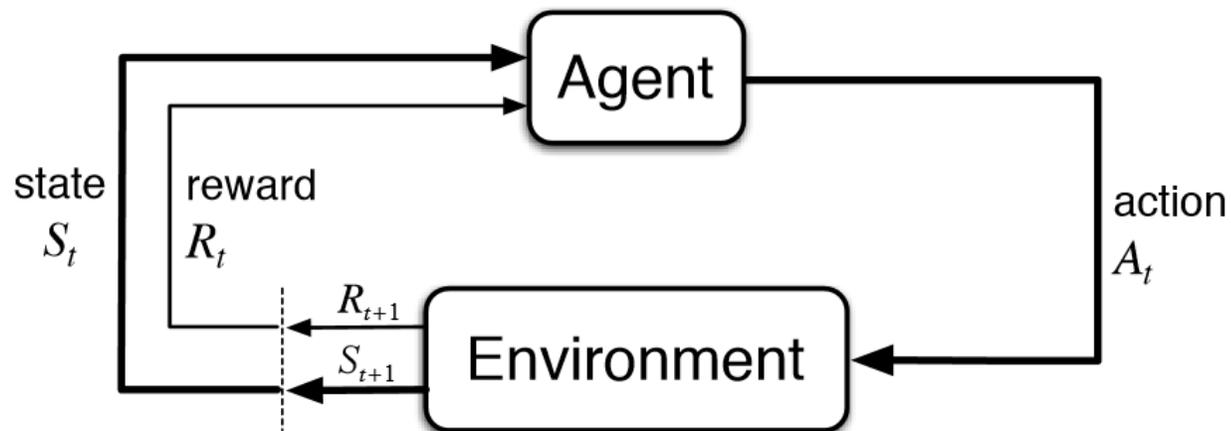
Id	Sequence	Align
Seq1	AGTACGTA	A-GTACGT-A
Seq2	ACTACGTA	AC-TACGT-A
Seq3	ACGTATT	ACGTA--TT-
Seq4	ACGTACGTT	ACGTACGTT-
Seq5	ACGTACGTC	ACGTACGT-C
<b>Consensus</b>	-	<b>ACGTACGTTA</b>

Existem 4 letras principais que representam os nucleotídeos em uma sequência de DNA:

- **A:** Adenina
- **T:** Timina
- **C:** Citosina
- **G:** Guanina



## Aprendizado por reforço

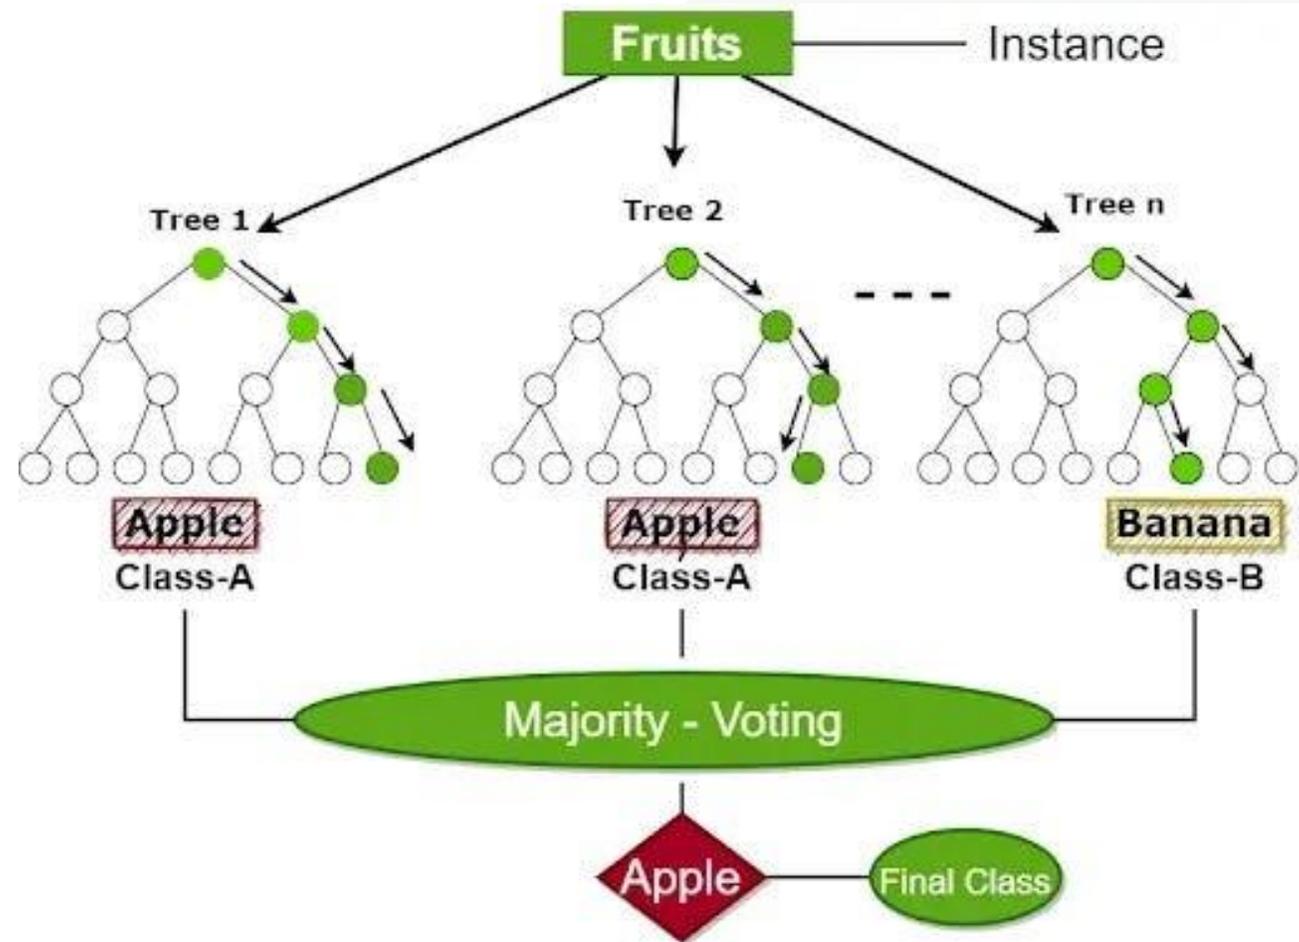


Fonte: Sutton e Barto (Sutton e Barto 2018)

### Os algoritmos RL incluem:

- Deep Q-Network (**DQN**) (Mnih et al. 2015);
- Trust Region Policy Optimization (**TRPO**) (Schulman et al. 2015);
- Actor-Critic (**A2C**) (Mnih et al. 2016);
- Proximal Policy Optimization (**PPO**) (Schulman et al. 2017).

## Random Forest



No contexto de tarefas de classificação, o Random Forest emprega medidas como **entropia** ou **impureza de Gini** para determinar o recurso ideal para divisões de nós.

Fonte: <https://miro.medium.com>

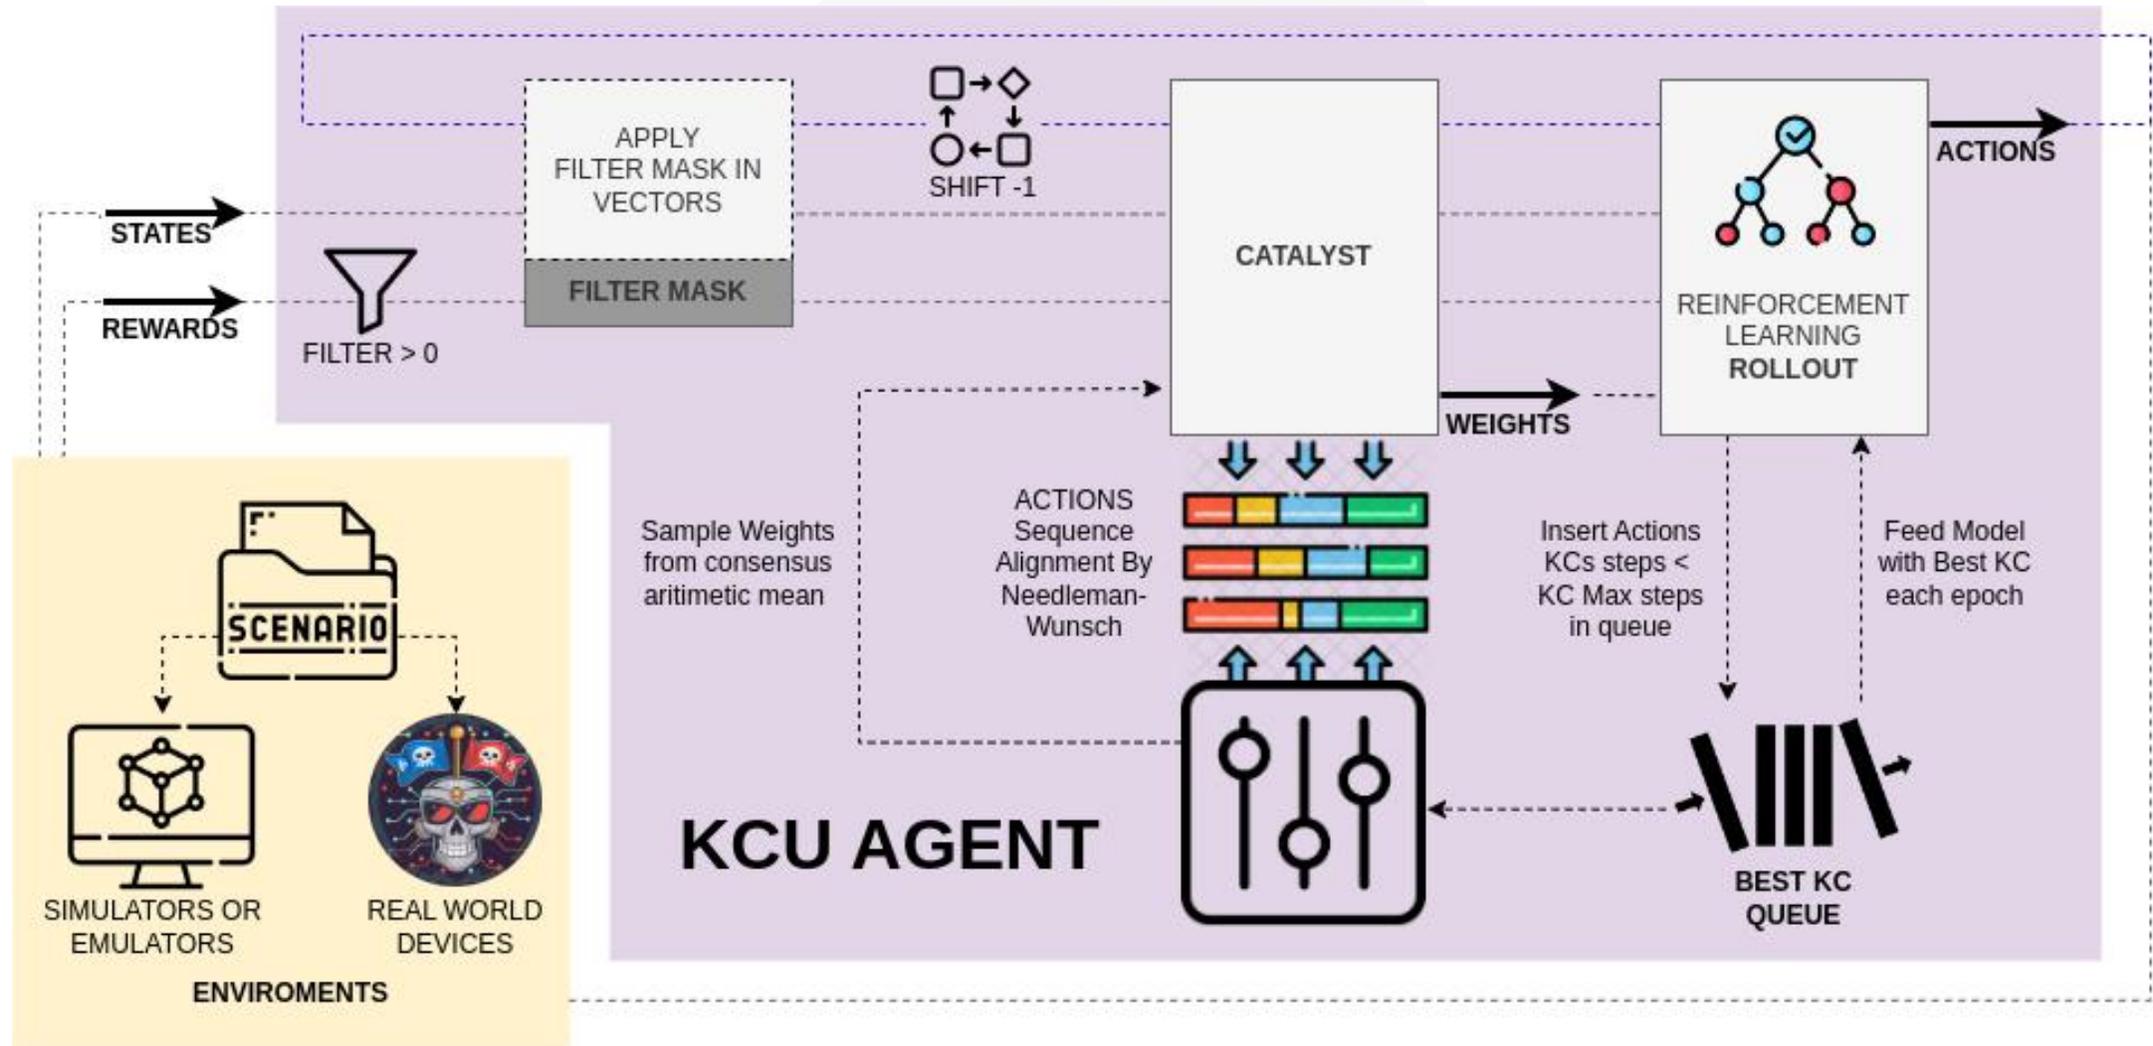
## Gini Impurity-Based Weighted Random Forest

- De acordo com Disha e Waheed (Disha e Waheed 2022), Random Forest é um classificador *ensemble* construído a partir de várias árvores de decisão, incorporando várias métricas de importância de recursos.
- Nesse sentido, a **Gini Impurity-Based Weighted Random Forest (GIWRF)** é uma abordagem para seleção de recursos. Uma dessas métricas envolve derivar a pontuação de importância por meio do treinamento do classificador.

A person wearing a red hoodie and a white robotic arm is sitting at a desk in a server room. The person is looking at a computer monitor displaying code. The room is filled with server racks and cables, and the lighting is a mix of orange and blue. The word "Metodologia" is written in white text across the center of the image.

# Metodologia

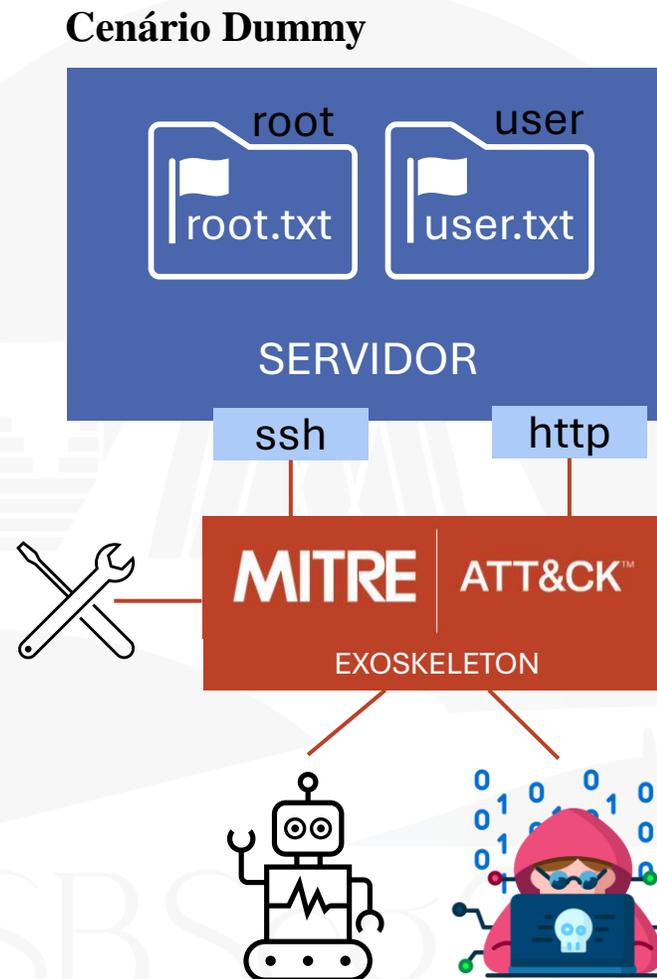
## Kill Chain Unscrambler



Kill Chain Catalyst for Autonomous Red Team Operations in Dynamic Attack Scenarios

## Ambiente

- Um servidor foi configurado para um CTF, usando imagens do **vulnhub**<sup>4</sup>:
- Para integração do aprendizado por reforço, a **interface Exoskeleton**<sup>2</sup> foi desenvolvida. Essa interface opera com um baixo nível de abstração, permitindo que algoritmos de RL ou humanos, interajam com o servidor. O Exoesqueleto<sup>2</sup> conta com **9 técnicas do MITRE ATT&CK**<sup>5</sup> e respectivas **ferramentas** que podem ser executadas contra o servidor.



<sup>2</sup><https://gitlab.com/antonio50/exoskeleton>

<sup>4</sup><https://github.com/vulnhub/vulnhub/tree/master/libssh/CVE-2018-10933>

<sup>5</sup><https://attack.mitre.org/matrices/enterprise/>

## Espaço de ação

Table 3. Exoskeleton's action space

Tactic id	Tactic name	Technique id	Technique name	Cmd or Tool
TA0043	Reconnaissance	T1595.001	Active Scanning: Scanning IP Blocks	nmap
TA0043	Reconnaissance	T1595.003	Active Scanning: Wordlist Scanning	dirb
TA0043	Reconnaissance	T1589.002	Gather Victim Identity Information: Email	script parser
TA0001	Initial Access	T1078.003	Valid Accounts: Local Accounts	hydra
TA0001	Initial Access	T1190	Exploit Public-Facing Application	libssh exploit
TA0006	Credential Access	T1110.001	Brute Force: Password Guessing	ssh
TA0007	Discovery	T1083	File and Directory Discovery	bash
TA0004	Privilege Escalation	T1548.001	Abuse Elevation Ctrl Mechanism: Setuid & Setgid	find
TA0009	Collection	T1005	Data from Local System	cat

O **Exoskeleton** adota um modelo de recompensa baseado em falhas. **Ações com sucesso** que resultam em modificações de estado (observável) **são recompensadas com +1**, **ações executadas sem alterar o estado (observável)** recebem uma **recompensa de 0** (por exemplo, comandos repetidos) e **falhas de execução**, seja devido a problemas de conexão ou falhas de serviço, resultam em uma **penalidade de -1**. **Ao alcançar ambas as bandeiras** dentro do cenário recebe uma **recompensa de 100**.

## Espaço de ação

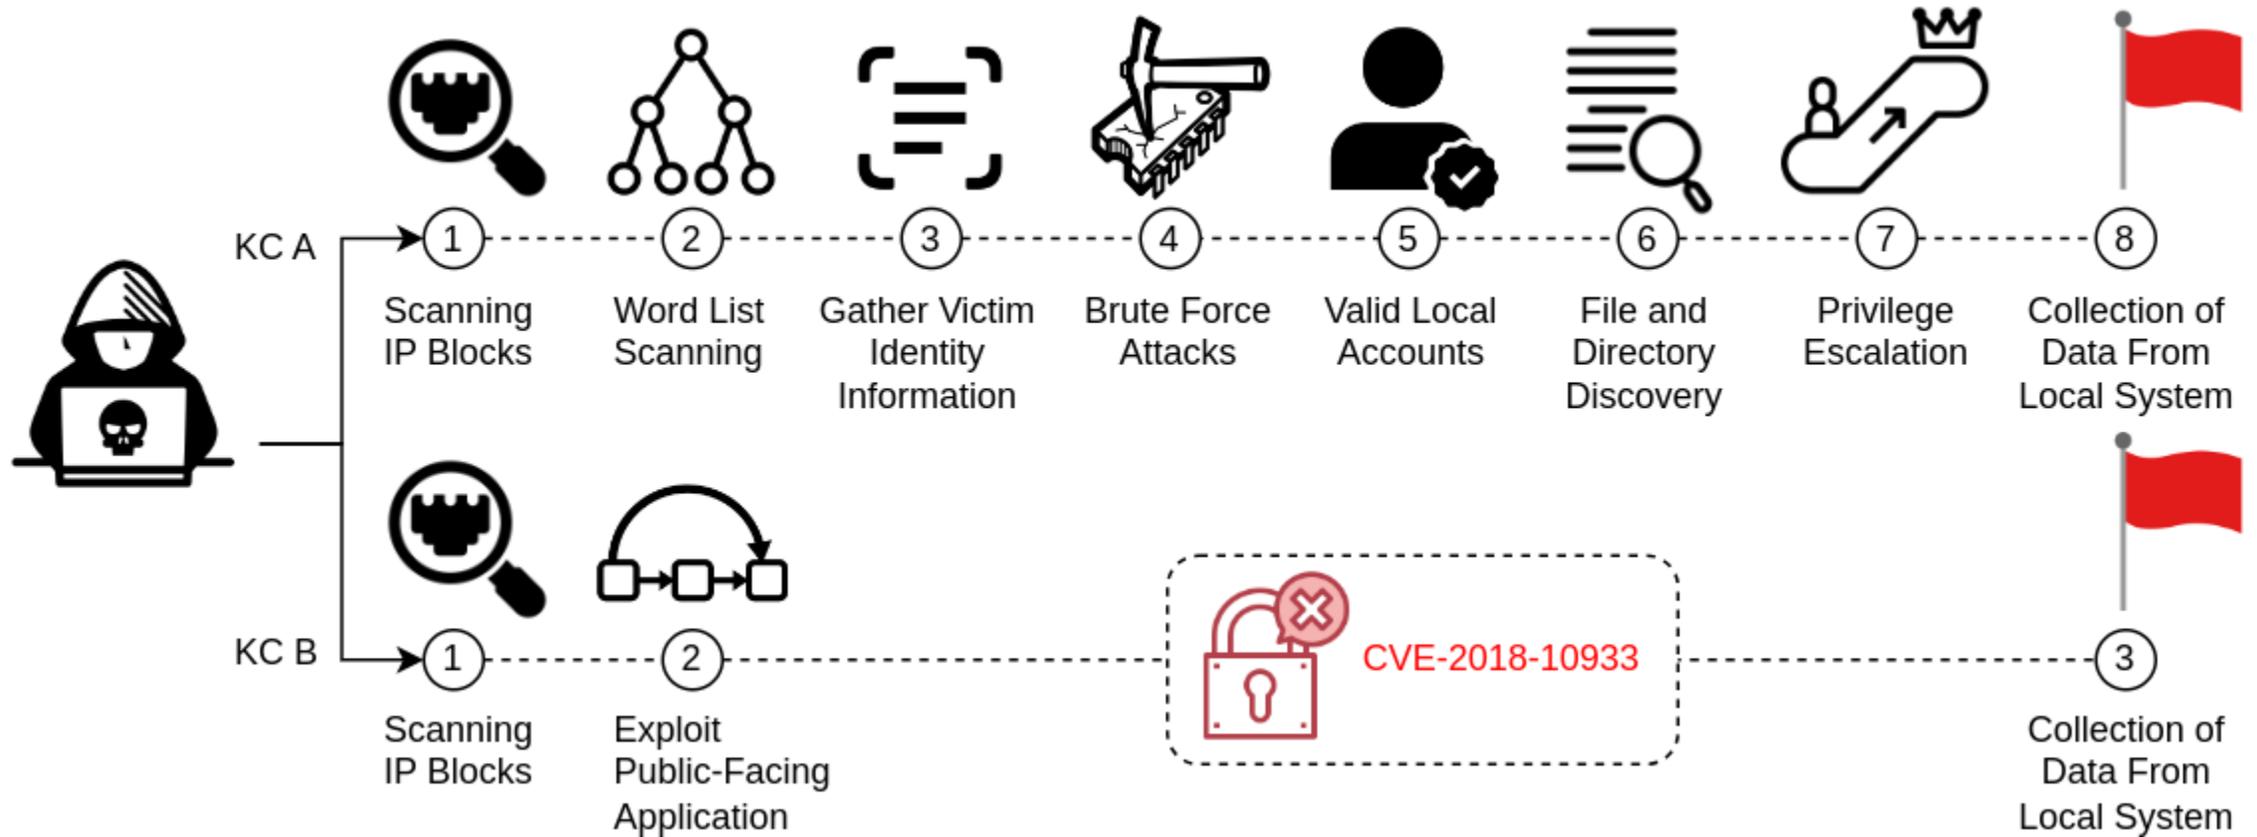


Figure 2. Kill chains available in Exoskeleton's Dummy Scenario.

A person wearing a red hoodie and glasses is seated at a desk in a server room. They have a highly detailed, silver and black cybernetic right arm. They are looking at a computer monitor displaying code. The room is filled with server racks and cables, with blue and orange lighting. The text "Experimentos & Resultados" is overlaid in the center.

# Experimentos & Resultados

## Experimentos

Table 5. Essays' parameters

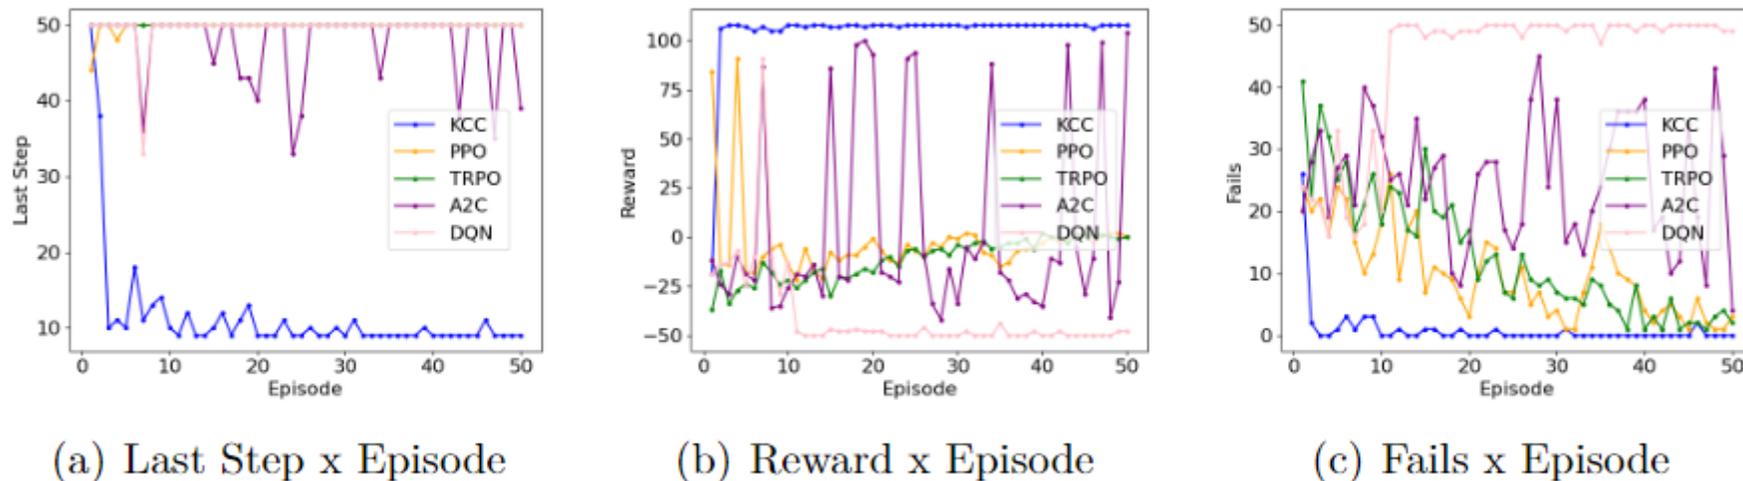
Agent	Parameter	Essay 1	Essay 2
KCC, PPO, TRPO, A2C, DQN	epochs	50	50
KCC, PPO, TRPO, A2C, DQN	max steps per epoch	50	50
KCC, PPO, TRPO, A2C, DQN	timesteps	2500	2500
KCC	epsilon (e-greedy)	0.25	0.25
KCC	decay_rate (e-greedy decay rate)	0.01	0.05
KCC	kcc (catalyst)	True	True
KCC	seed (random seed)	1	1
KCC	buffer (size of the best KCs QUEUE)	20	20
KCC	n_estimators	50	50
KCC	min_samples_leaf	1	1
KCC	dynamic_scenario	False	True

Os experimentos envolvendo o KCC serão avaliados juntamente com quatro algoritmos: DQN, PPO, TRPO e o A2C. A avaliação se concentrará nas principais métricas, como curva de aprendizado, recompensas totais, total de passos e total de falhas.

Para analisar o desempenho do KCC em operações de ataque, considerando a curva de aprendizado para experiências de ataque limitadas e capacidade de lidar com cenários dinâmicos, o experimento foi estruturado em dois ensaios independentes:

- Um ensaio com objetivo comparar a curva de aprendizado do KCC, com os quatro algoritmos de RL: PPO, TRPO, A2C e DQN;
- O segundo para demonstrar a resiliência do KCC a cenários dinâmicos. Neste ensaio final, as vulnerabilidades são corrigidas no meio do ciclo de aprendizado de cada algoritmo, levando os algoritmos convergentes a explorar novos caminhos de ataque.

## Ensaio 1 – Experiência limitada



**Figure 3. Limited experiences for KCC, A2C, PPO, TRPO and DQN**

**Table 6. Cumulative Values and Percentage Differences Relative to KCC**

Serie	Steps	Diff Steps	Rewards	Diff Rewards	Fails	Diff Fails
KCC	567	0.00%	5252	0.00%	47	0.00%
PPO	2492	339.51%	-162.0	103.08%	496	955.32%
TRPO	2500	340.92%	-567.0	110.80%	640	1261.70%
A2C	2383	320.28%	184.0	96.50%	1241	2540.43%
DQN	2483	337.92%	-2011.0	138.29%	2202	4585.11%

## Ensaio 2 – Cenário dinâmico

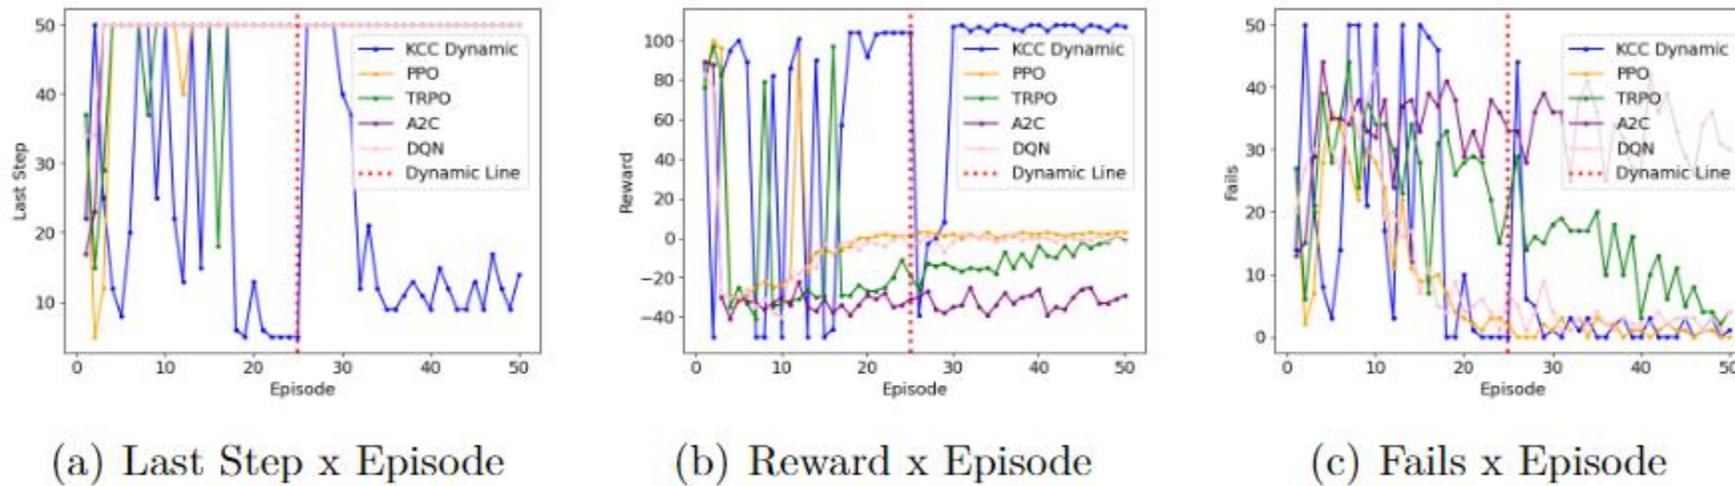


Figure 4. Comparing KCC, A2C, PPO, TRPO and DQN in a dynamic scenario

SBSeg24  
SÃO JOSÉ DOS CAMPOS

- O KCC, utilizando a lógica da árvore de decisão e um catalisador inspirado no alinhamento genético, mostrou-se eficaz na superação das limitações encontradas em algoritmos tradicionais baseados em redes neurais, como PPO, TRPO, A2C e DQN, particularmente em ambientes com experiências de aprendizado limitadas.
- Os resultados mostraram diferenças de até **340,92% para passos**, **138,29% para recompensas** e **4585,11% para falhas** ao realizar ataques usando KCC em comparação com outros algoritmos RL tradicionais.
- Além disso, a capacidade do KCC de se adaptar rapidamente às mudanças ambientais, como a correção de vulnerabilidades, destacou sua resiliência e eficácia em cenários dinâmicos, característica não observada em outros algoritmos testados.
- Os resultados ressaltam que abordagens baseadas em árvore de decisão e o uso de um catalisador de sequencias podem melhorar o desempenho da RL em ataques cibernéticos.
- A pesquisa indica que estudos futuros devem se concentrar em refinar a fase de exploração do algoritmo, principalmente devido à sua natureza estocástica, pois isso é importante para o tipo de estudo realizado.

# Referências

- [Mnih et al. 2015] Mnih, V., Kavukcuoglu, K., Silver, D., Rusu, A. A., Veness, J., Bellemare, M. G., Graves, A., Riedmiller, M., Fidjeland, A. K., Ostrovski, G., et al. (2015). Human-level control through deep reinforcement learning. *nature*, 518(7540):529–533.
- [Ortiz-Garces et al. 2023] Ortiz-Garces, I., Gutierrez, R., Guerra, D., Sanchez-Viteri, S., and Villegas-Ch., W. (2023). Development of a platform for learning cybersecurity using capturing the flag competitions. *Electronics*, 12(7).
- [Paudel and Amariucaí 2023] Paudel, B. and Amariucaí, G. (2023). Reinforcement learning approach to generate zero-dynamics attacks on control systems without state space models. In *European Symposium on Research in Computer Security*, pages 3–22. Springer.
- [Poinsignon et al. 2023] Poinsignon, T., Poulain, P., Gallopin, M., and Lelandais, G. (2023). Working with omics data: An interdisciplinary challenge at the crossroads of biology and computer science. In *Machine Learning for Brain Disorders*, pages 313–330. Springer.
- [Pozdniakov et al. 2020] Pozdniakov, K., Alonso, E., Stankovic, V., Tam, K., and Jones, K. (2020). Smart security audit: Reinforcement learning with a deep neural network approximator. In *2020 International Conference on Cyber Situational Awareness, Data Analytics and Assessment (CyberSA)*, pages 1–8.
- [Schulman et al. 2015] Schulman, J., Levine, S., Abbeel, P., Jordan, M., and Moritz, P. (2015). Trust region policy optimization. In *International conference on machine learning*, pages 1889–1897. PMLR.
- [Schulman et al. 2017] Schulman, J., Wolski, F., Dhariwal, P., Radford, A., and Klimov, O. (2017). Proximal policy optimization algorithms.
- [Standen et al. 2021] Standen, M., Lucas, M., Bowman, D., Richer, T. J., Kim, J., and Marriott, D. (2021). Cyborg: A gym for the development of autonomous cyber agents. In *IJCAI-21 1st International Workshop on Adaptive Cyber Defense*. arXiv.
- [Sutton and Barto 2018] Sutton, R. S. and Barto, A. G. (2018). *Reinforcement learning: An introduction*. MIT press, second edition.
- [Tran et al. 2021] Tran, K., Akella, A., Standen, M., Kim, J., Bowman, D., Richer, T., and Lin, C.-T. (2021). Deep hierarchical reinforcement agents for automated penetration testing. In *IJCAI-21 1st International Workshop on Adaptive Cyber Defense*. arXiv.
- [Yang and Liu 2022] Yang, Y. and Liu, X. (2022). Behaviour-diverse automatic penetration testing: A curiosity-driven multi-objective deep reinforcement learning approach.
- [Zhou et al. 2021] Zhou, S., Liu, J., Hou, D., Zhong, X., and Zhang, Y. (2021). Autonomous penetration testing based on improved deep q-network. *Applied Sciences*, 11(19).
- [Al-Azzawi et al. 2024] Al-Azzawi, M., Doan, D., Sipola, T., Hautamäki, J., and Kokkonen, T. (2024). Artificial intelligence cyberattacks in red teaming: A scoping review. In *World Conference on Information Systems and Technologies*, pages 129–138. Springer.
- [Breiman 2001] Breiman, L. (2001). Random forests. *Machine learning*, 45:5–32.
- [Che Mat et al. 2024] Che Mat, N. I., Jamil, N., Yusoff, Y., and Mat Kiah, M. L. (2024). A systematic literature review on advanced persistent threat behaviors and its detection strategy. *Journal of Cybersecurity*, 10(1):tyad023.
- [Chen et al. 2023] Chen, J., Hu, S., Zheng, H., Xing, C., and Zhang, G. (2023). Gail-pt: An intelligent penetration testing framework with generative adversarial imitation learning. *Computers Security*, 126:103055.
- [Disha and Waheed 2022] Disha, R. A. and Waheed, S. (2022). Performance analysis of machine learning models for intrusion detection system using gini impurity-based weighted random forest (giwrf) feature selection technique. *Cybersecurity*, 5(1):1.
- [Farouk et al. 2024] Farouk, M., Sakr, R. H., and Hikal, N. (2024). Identifying the most accurate machine learning classification technique to detect network threats. *Neural Computing and Applications*, 36(16):8977–8994.
- [Gancheva and Stoev 2023] Gancheva, V. and Stoev, H. (2023). An algorithm for pairwise dna sequences alignment. In *International Work-Conference on Bioinformatics and Biomedical Engineering*, pages 48–61. Springer.
- [Gangupantulu et al. 2021] Gangupantulu, R., Cody, T., Rahma, A., Redino, C., Clark, R., and Park, P. (2021). Crown jewels analysis using reinforcement learning with attack graphs. In *2021 IEEE Symposium Series on Computational Intelligence (SSCI)*, pages 1–6.
- [Holm 2022] Holm, H. (2022). Lore a red team emulation tool. *IEEE Transactions on Dependable and Secure Computing*, 1:1–1.
- [Horta Neto et al. 2024] Horta Neto, A. J., dos Santos, A. F. P., and Goldschmidt, R. R. (2024). Evaluating the stealth of reinforcement learning-based cyber attacks against unknown scenarios using knowledge transfer techniques. *Journal of Computer Security*, (Preprint):1–19.
- [Ibrahim et al. 2024] Ibrahim, M. K., Yusof, U. K., Eisa, T. A. E., and Nasser, M. (2024). Bioinspired algorithms for multiple sequence alignment: A systematic review and roadmap. *Applied Sciences*, 14(6):2433.
- [Janisch et al. 2023] Janisch, J., Pevný, T., and Lisý, V. (2023). Nasimemu: Network attack simulator & emulator for training agents generalizing to novel scenarios. In *European Symposium on Research in Computer Security*, pages 589–608. Springer.
- [Li et al. 2022] Li, L., El Rami, J.-P. S., Taylor, A., Rao, J. H., and Kunz, T. (2022). Enabling a network ai gym for autonomous cyber agents. In *2022 International Conference on Computational Science and Computational Intelligence (CSCI)*, pages 172–177. IEEE.
- [Mnih et al. 2016] Mnih, V., Badia, A. P., Mirza, M., Graves, A., Lillicrap, T., Harley, T., Silver, D., and Kavukcuoglu, K. (2016). Asynchronous methods for deep reinforcement learning. In *International conference on machine learning*, pages 1928–1937. PMLR.

# Obrigado!



**Antonio Horta**

Principal Cyber Research Scientist,  
MSc, DSc Candidate | Speaker | CISO...

