

CYBER & AI FRIENDS OR FOES?

Clara Contreras Nevares
Luciana Fidilio Allende

CURSOS VERANO URJC





VALKYRIAS



Cyber, AI & I

- Ingenieras de Ciberseguridad
- Investigadoras DSLAB
- Valkyrias



Universidad
Rey Juan Carlos





VALKYRIAS



Cyber, AI & I




“<Valkyrias/>





VALKYRIAS




Universidad
Rey Juan Carlos

Luciana Fidilio

- Inteligencia Artificial
 - Answer Set Programming
 - Forgetting
 - Inductive Logic Programming (Future)

CETINIA



Universidad
Rey Juan Carlos

Clara Contreras

- Ciberriesgo en OT con ML
 - Vectores de entrada
 - Coexposición al riesgo
 - Propagación del riesgo
 - Dark Web/Surface Web OSINT
 - Data Mining
- Mentora Stem Talent Girl



Cyber



AI





Cyber in AI

01

Data Poisoning

02

Prompt Hacking

03

Prompt Engineering

04

¿Soluciones?



VALKYRIAS

Data poisoning



MOUNTAINS



DOG



VALKYRIAS

Data poisoning



FROG

MOUNTAINS



DOG




FROG



VALKYRIAS

Data poisoning




GARBAGE



VALKYRIAS

Data poisoning



FROG :)



Prompt Engineering

Un buen prompt


**RELEVANCIA
RESPUESTAS**

AUTOMATIZACIÓN

CONSISTENCIA



Prompt Engineering/Injection





Caso de uso

1

Atacante: Crea un malware y lo almacena en una web

2

Prompt: Resume el contenido de <url>

3

Prompt se ejecuta y el malware se almacena en el servidor víctima





¿Soluciones?

**ORIGEN DE
LOS DATOS**

**CONEXIONES DEL
MODELO**

**LIMITAR ACCESO A
DATOS SENSIBLES**



IS SECURE AND TRUSTED
AI POSSIBLE?



References

Chen, X., Liu, C., Li, B., Lu, K., & Song, D. (2017). Targeted backdoor attacks on deep learning systems using data poisoning. arXiv preprint arXiv:1712.05526.

Liu, Y., Deng, G., Li, Y., Wang, K., Zhang, T., Liu, Y., ... & Liu, Y. (2023). Prompt Injection attack against LLM-integrated Applications. arXiv preprint arXiv:2306.05499.



Ciber & AI
Friends or foes?

THANK
YOU

Clara Contreras
Luciana Fidilio