




Introducción a Transformers y Large Language Models

Juan Vázquez Montejo

<http://sg1.run/-i>

Sobre mi



Agenda del taller

Transformers y LLM

Desarrollo de código con ejemplo de RAG




Comparación de langchain vs haystack vs llama index

preguntas

Cierre y recursos


¿Qué son los transformers?

Arquitecturas: DNN, CNN, RNN (LSTM GRU)



Mecanismo de auto-atención

The scaled dot-product attention mechanism is used in the multi-head attention blocks




¿Qué son los LLM?


Large Language Models (LLMs)

- Distribución de probabilidad sobre cadenas de texto.
- Redes neuronales con miles de millones de parámetros.
- Casos de uso: responder preguntas, traducción, generación de resúmenes, generación de código, etc

Textos -> vectores



vector databases y embeddings



Ecosistema actual de LLM

LLMs y Embeddings



OpenAI



cohere



ANTHROPIC



Hugging Face



**MISTRAL
AI_**

Vector DB



Pinecone



OpenSearch



chroma



Weaviate



milvus

AI Frameworks



LangChain



LlamaIndex



haystack
by deepset

Cómo abordar la IA generativa y personalizar los transformers/LLM



fuente: [LinkedIn](#)


¿Qué es RAG?

Retrieval Augmented Generation (RAG)

Retrieval (Recuperador): una interfaz que devuelve documentos dada una petición.

Augmented, Prompt augmentation (o Aumento de mensajes): proporcionar contexto o información adicional en el mensaje para mejorar el rendimiento.

Generation: (la IA generativa, LLM, GPT, etc)



Notebook en colab

Contacto: [LinkedIn](#) y [Twitter](#)

Agradecimientos:



Muchas gracias por su atención

