

CONGRESO · INTELIGENCIA ARTIFICIAL · 2026

Congreso AI LATAM

El encuentro de la comunidad de Inteligencia Artificial de
Latinoamérica.



31/07/2026



Internet



ialatam.com



IA LATAM · Comunidad

Congreso AI LATAM



CHARLA MAGISTRAL · TRACK DE IA

De Newton a los LLM: Simular la inteligencia

● **Erick Merino** · Profesional de Apoyo · Mineduc



IA LATAM · Comunidad

Congreso AI LATAM

Quién te acompaña hoy



Erick Merino

Profesional de Apoyo · Mineduc · Chile

Ingeniero Civil en Informática con mención en Gestión y Diseño de Bases de Datos, postítulo en Data Science, Apasionado por la IA y Computación desde chico.

- 2 años aprox de ayudante de investigación
- 9 papers (5 revista y 4 conferencia) coautor
- Trabajo en Mineduc

 AGENDA

Lo que veremos hoy

1

Los orígenes

El origen de todo esto: Las matemáticas

2

Formalizando la Naturaleza

Desde el fenómeno al sistema formal

3

Máquinas construyendo naturaleza

Machine Learning

4

Naturaleza construyendo máquinas

Deep Learning

5

Sobre el mundo y las máquinas

Próximos pasos

6

Conclusiones y preguntas

Cierre y conversación



01

SECCIÓN

Los orígenes


La matemática

CONTENIDO

El hueso de Ishango

Hace unos 20.000 años, un ser humano talló muescas en un hueso para registrar ciclos naturales (La luna)


- El origen de las matemáticas
- Los números
- La primera abstracción




Los números

Los números fueron la primera gran abstracción

- Nos permiten contar
- Generalizan el mundo a elementos imaginarios
- Nos permiten calcular



Al-jabr




Muhammad ibn Mūsā al-Khwārizmī (Al Juarismi),
inventor del álgebra

- El mundo como planos
- Los números como abstracciones
- El origen de los Al goritmos

El mundo como planos

$$1 + x = 3$$

↑
variable




CONTENIDO

El mundo como planos

Al-Juarismi nos dio el álgebra: el arte de usar variables para crear **instrucciones generales**.

- Como un plano de una casa: una única fórmula permite crear hogares de cualquier tamaño, heredando conocimiento de padres a hijos.
- Nos permitió planificar, crear planos de casas para diferentes tamaños, calcular el material, saber cuánto comerán X personas a fin de año, calcular la población



El mundo como planos



02

SECCIÓN

Formalizando la Naturaleza

El mundo natural



Fenómenos de la Naturaleza

Vemos un fenómeno y queremos entenderlo, para ello, hay que abstraerlo y generalizarlo

- Todos los tornados son similares y siguen las mismas leyes
- Todos los tornados tienen las mismas variables de entrada y de salida
- Un tornado es un sistema, con un comportamiento, interacción entre sus componentes y con el entorno y salidas y entradas




Sistema

El tornado es un sistema

- Tiene entradas, un proceso de ejecución y salidas
- Se puede abstraer a través de diagramas, relato o una función matemática que lo representa
- Queremos entender sistema




Tipos de sistemas





Sistemas simples





Sistemas complicados




Sistemas complejos



Sistemas caóticos




La función matemática



- **Entradas de información:** Datos concretos que le entregamos al sistema, como el número de habitantes y los metros cuadrados deseados.
- **Proceso o regla:** La lógica central que toma esas entradas para calcular lo que se necesita construir.
- **Resultado final:** La respuesta exacta que nos devuelve la regla, en este caso, la cantidad total de materiales.
- **Relación directa:** A cada combinación única de datos de entrada le corresponde un único resultado de salida.

La función matemática

DIVULGACIÓN: CÓMO APROXIMAMOS UN TORNADO!




Función plantilla



Estructura o Plantilla: Una máquina con controles ajustables cuya regla exacta descubriremos.

Parámetros o Perillas: Botones regulables que definen cuánto pesa cada dato.

Espacio de búsqueda del error




Espacio de Búsqueda: El mapa con todas las combinaciones de ajustes posibles.

Medición del Error: El indicador de qué tan lejos quedó el resultado real.

Meta de Aprendizaje: Encontrar la combinación en el mapa con el menor error.



Entrenamiento



Estructura o Plantilla: Una máquina con controles ajustables cuya regla exacta descubriremos.

Parámetros o Perillas: Botones regulables que definen cuánto pesa cada dato.


Espacio de Búsqueda: El mapa con todas las combinaciones de ajustes posibles.

Medición del Error: El indicador de qué tan lejos quedó el resultado real.

Meta de Aprendizaje: Encontrar la combinación en el mapa con el menor error.



Búsqueda con información



Para cada salida de la función $F(t, x) = y\text{-predicha}$ tenemos la $y\text{-original}$


Además conocemos la estructura de la **función F**

Entonces con la $y\text{-predicha}$ y la $y\text{-original}$, calculamos un valor con una **Función de pérdida**


Esta función mapea el **error** a un espacio n-dimensional (1 dimensión por cada t) y es **derivable**

Entonces usamos el **método del gradiente** para obtener el punto más bajo

Y usando el gradiente cambiamos los valores de t usando **retro-propagación**



Búsqueda sin información



Si no tenemos información, hay que buscar a ciegas entre el espacio de posibles parámetros t

Estrategias comunes:

1. Búsqueda aleatoria
2. Búsqueda en grilla
3. Búsqueda bayesiana (toma el histórico de búsquedas y apunta hacia esa dirección)
4. Metaheurísticas poblacionales (imitan el comportamiento de agente naturales como: Algoritmos genéticos, Colonia de Hormigas, Agujeros Negros, etc)


03

SECCIÓN

Máquinas construyendo naturaleza


Machine Learning

Regresión lineal



- Usa una función lineal como función de aproximación
- Los parámetros “t” a optimizar son la pendiente y el intercepto

Regresión logística



- Usa una función logística (o sigmoide) como función de aproximación
- Los parámetros “t” a optimizar son los parámetros Beta
- Se usa para clasificar entre 2 categorías binarias



REGRESIÓN LOGÍSTICA BINARIA

ECUACIÓN:

$$y = \frac{1}{1 + e^{-f(x)}}$$

DONDE:

$$f(x) = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 \dots + \beta_n x_n$$

y : Variable a predecir






x : Variable predictora

β : Coeficiente


e : Constante épsilon



Otras funciones plantilla



Random Forest Simplified



04


SECCIÓN

Naturaleza construyendo máquinas


Deep learning

Neuronas

Connections





Example: connections in monkey visual cortex





Una neurona

Perceptron





Con otras más





Con memoria



RNN: The Memory Machine!





que se multiplican



Muchas veces



En intrincados mecanismos





Redes convolucionales artificiales

Convolutional Neural Network



make a gif.com






Se enfrentan




Se achican y agrandan



Se difuminan y vuelven a aclararse



Y aprendemos a leer




Aprendemos a entender lo que leemos




Aprendemos a relacionar



	El	perro	estaba	en	el	salón	durmiendo	tranquilo
El								
perro								
estaba								
en								
el								
salón								
durmiendo								
tranquilo								



Transformer



Embeddings en acción

Embedding 🔍

Tokenization

Art
ificial
Intelligence
is
transforming
the

Token
Embedding

id
8001
9542
9345
318
25449
262

Positional
Encoding


position
0
1
2
3
4
5

+
+
+
+
+
+

=
=
=
=
=
=




QKV: Preguntas, respuestas y valor




Bloque MLP (FFN): Información interna



Detalle del Proceso de Bloque MLP de un Transformer




Temperatura y salida



Dos pequeños ejemplos




Un ejemplo más grande




Aprendemos diferentes formas de relacionar


COMPARATIVA LLM: BERT vs GPT (ENCODER vs DECODER)




Transformer



GPT*




BERT*



*Illustrative example, exact model architecture may vary slightly

Imágenes




05

SECCIÓN


Sobre el Mundo y las máquinas

Nuevos horizontes

Atención dispersa




Atención con compuertas




Atención latente (Comprimida)

DeepSeek V3/R1




Multi-head Latent Attention (MLA)

Inference step t :




Regular Multi-head Attention (MHA)

Inference step t :




Atención latente (Muy comprimida)


Multi-head **Latent** Attention (MLA)
(only one attention head shown)



Compressed Convolutional Attention (CCA)
(only one attention head shown)




Omni modal (Entra y sale cualquier tipo de dato)



VLA (Visión Lenguaje Acción)



JEPA y los Modelos de mundo



Spiking neural networks



Spiking growing neural networks



Tareas con LLM





EL DATO QUE IMPORTA

2.800
millones

de neuronas tiene el modelo abierto más grande, con unas pocas conexiones cada una, conectadas de forma secuencial y jerárquica.



EL DATO QUE IMPORTA

86.000
millones

de neuronas tiene el cerebro. con 10.000
conexiones cada una aproximadamente,
conectadas en paralelo.

”

“No sé lo que pueda parecerle al mundo, pero a mí mismo me parece que sólo he sido como un niño que juega en la orilla del mar, y se entretiene en encontrar de vez en cuando un guijarro más liso o una concha más bonita de lo ordinario, mientras que el gran océano de la verdad yace todo sin descubrir ante mí”

● Sir Isaac Newton · Físico, Matemático, Teólogo, Político



<https://erickfmm.github.io/frankestein-transformer/>

IDIOMA

Español

[View on GitHub](#)

☒ Light mode

LOAD EXAMPLE

Mini

Standard

Frankenstein

LOAD FROM REPO

bert base uncased

Load Selected

Portfolio / Frankestein Transformer



Frankestein Transformer — Config Builder

Language: Español

Configuracion actualizada.

Configuration Builder

YAML Output

Command

Diagram

Paper

☒ Schema loaded successfully.

ESTIMATED PARAMETERS **≈ 160.71M** structural estimate

[► Breakdown](#)

Configuración del Modelo

Elegir Tipo de Modelo:



**Modelo
Personalizado**



**Modelo
Base**

Clase de Modelo *

Variante de arquitectura del modelo a instanciar. Determina qué clase de implementación se usa.





¡Gracias!

¿Conversamos? Espacio para preguntas.

erickfmm@gmail.com · [@erickfmm](https://twitter.com/erickfmm)

ÚNETE A LA COMUNIDAD

Sigue conectado con IA LATAM



LinkedIn /erickfmm



GitHub @erickfmm



Comunidad Grupo de WhatsApp



Web erickfmm.github.io



Escanea para unirte