

# Procesamiento del Lenguaje Natural

Ingeniería de instrucciones

## Clase 5

Maestría en Educación en Inteligencia Artificial y Entornos Virtuales

La excelencia no se improvisa



## Introducción

Esta clase aborda la ingeniería de instrucciones en el Procesamiento de Lenguaje Natural (PLN), destacando su importancia para optimizar la interpretación y generación de texto por parte de modelos de inteligencia artificial. Se presentan diversas técnicas fundamentales como el aprendizaje en contexto, que permite a los modelos ajustar sus respuestas según la información proporcionada, y las transformaciones texto a texto, que incluyen traducción automática, resumen y parafraseo. También se exploran métodos avanzados como la conversión de texto a imagen y el uso de formatos no textuales, ampliando el alcance del PLN en disciplinas como la medicina, la educación y la publicidad.

Los resultados de aprendizaje que se desarrollarán incluyen analizar los conceptos y técnicas de PLN en ambientes educativos, la comprensión de los principios del aprendizaje en contexto, la capacidad de diseñar instrucciones efectivas para modelos de IA y la exploración de las aplicaciones de los modelos Transformer en distintos ámbitos. Además, se espera que los estudiantes adquieran habilidades para manipular técnicas de procesamiento de texto y comprendan la relevancia de los modelos de lenguaje en la automatización y optimización de tareas lingüísticas complejas.

## Clase 5

### 9. Ingeniería de instrucciones

La ingeniería de instrucciones en el Procesamiento de Lenguaje Natural (PLN) es una disciplina que permite optimizar la forma en que los modelos de inteligencia artificial interpretan y generan texto. Se trata de un campo en constante evolución que busca mejorar la precisión y eficiencia de los modelos lingüísticos mediante el diseño de instrucciones precisas y adaptadas a diferentes tareas. En este contexto, el aprendizaje en contexto juega un papel clave, permitiendo a los modelos refinar sus respuestas en función de la información provista. Asimismo, existen diversas técnicas para transformar y generar texto, imagen y otros formatos no textuales, lo que expande las aplicaciones del PLN a diversas áreas del conocimiento. Esta clase explora en detalle estas dimensiones, proporcionando ejemplos específicos y analizando la aplicabilidad de cada enfoque. Dado que la ingeniería de instrucciones es un tema muy relevante en la actualidad, se recomienda escuchar este podcast, que presenta una visión de corte práctico y empresarial: <https://youtu.be/rivQdMVm1XQ?si=0WVFjLEsWvKvhkKl>.

#### 9.1. Aprendizaje en contexto

El aprendizaje en contexto en PLN se refiere a la capacidad de los modelos de IA para generar respuestas adaptadas a una situación específica basándose en la información contextual que se les proporciona. Esto se logra a través de diversas estrategias, entre ellas el uso de *few-shot learning* y *zero-shot learning* (Kadam, 2020).

En el *few-shot learning*, el modelo recibe algunos ejemplos de una tarea determinada antes de realizar una predicción. Por ejemplo, si se le pide a un modelo de PLN generar resúmenes de artículos científicos, se le podrían proporcionar algunos ejemplos de resúmenes bien estructurados para que identifique patrones. Por otro lado, el *zero-shot learning* se basa en la capacidad del modelo para realizar tareas sin ejemplos previos, confiando en su preentrenamiento y en las instrucciones dadas.

Un aspecto clave del aprendizaje en contexto es la manipulación de los *prompts* o instrucciones para guiar al modelo hacia una salida deseada. Por ejemplo, en la generación de respuestas a preguntas en

sistemas conversacionales, la especificidad de las instrucciones puede determinar la relevancia y utilidad de la respuesta. En aplicaciones médicas, un modelo puede ser instruido para diferenciar entre respuestas generales y diagnósticos específicos dependiendo del nivel de detalle en el *prompt*.

## 9.2. Técnicas texto a texto

Las técnicas de transformación texto a texto son herramientas utilizadas en PLN para modificar, reformular o mejorar textos a partir de algoritmos y modelos de inteligencia artificial. Estas técnicas incluyen la traducción automática, el resumen automático, la generación de texto y la conversión de texto a formato estructurado.

Un ejemplo destacado de esta técnica es la traducción automática, que ha avanzado significativamente con el desarrollo de modelos neuronales como Google Translate (Google, 2025) y DeepL (DeepL, 2025). Estos sistemas utilizan redes neuronales recurrentes y transformadores como GPT-4 (OpenAI, 2025a) y BERT (Devlin, 2019) para mejorar la precisión y fluidez de las traducciones en tiempo real (Figura 1).

**Figura 1.** Traducción texto a texto

Traduce al francés: "Hola, este es un ejemplo para el curso de Procesamiento del Lenguaje Natural"

Bonjour, ceci est un exemple pour le cours de Traitement du Langage Naturel.

Nota: Creado en OpenAI (2025)

Otra aplicación clave es la generación automática de resúmenes, que permite sintetizar grandes volúmenes de información en textos más compactos sin perder el significado esencial. Herramientas como Sumy (miso-belica, 2025) y TextRank (Adamo, 2022) utilizan algoritmos de selección de oraciones clave basados en relevancia semántica y frecuencia de términos. Esto es particularmente útil en la investigación académica y el análisis de noticias, donde los profesionales requieren resúmenes precisos para una toma de decisiones eficiente (Figura 2).

**Figura 2.** Resumen texto a texto

Resume en dos líneas: "Otra aplicación clave es la generación automática de resúmenes, que permite sintetizar grandes volúmenes de información en textos más compactos sin perder el significado esencial. Herramientas como Sumy (miso-belica, 2025) y TextRank (Adamo, 2022) utilizan algoritmos de selección de oraciones clave basados en relevancia semántica y frecuencia de términos. Esto es particularmente útil en la investigación académica y el análisis de noticias, donde los profesionales requieren resúmenes precisos para una toma de decisiones eficiente."

La generación automática de resúmenes sintetiza información extensa en textos concisos, manteniendo su significado esencial. Herramientas como Sumy y TextRank emplean algoritmos basados en relevancia semántica y frecuencia de términos, útiles en investigación y análisis de noticias.

Nota: Creado en OpenAI (2025)

El parafraseo automático es otra técnica fundamental en texto a texto, utilizada para reformular frases manteniendo su significado original. Plataformas como QuillBot (Learneo, 2025) emplean inteligencia artificial para mejorar la redacción, facilitando la reescritura de contenido sin incurrir en plagio.

**Figura 3.** Parafraseo texto a texto

Parafrasea: "El parafraseo automático es otra técnica fundamental en texto a texto, utilizada para reformular frases manteniendo su significado original. Plataformas como QuillBot (Learneo, 2025) emplean inteligencia artificial para mejorar la redacción, facilitando la reescritura de contenido sin incurrir en plagio."

La reformulación automática es una técnica esencial en las transformaciones de texto a texto, que permite expresar ideas de manera diferente sin alterar su significado. Herramientas como QuillBot (Learneo, 2025) utilizan inteligencia artificial para optimizar la redacción y reescribir contenido evitando el plagio.

Nota: Creado en OpenAI (2025)

La conversión de texto a formato estructurado es esencial en la extracción de información de documentos. Herramientas como SpaCy (Explosion, 2025) y NLTK (NLTK, 2024) permiten la identificación de entidades, relaciones semánticas y categorización de contenido, lo que optimiza procesos en minería de datos y análisis de información empresarial (Figura 4).

**Figura 4.** Categorización y estructuración texto a texto

Categoriza en una tabla: "Finalmente, la conversión de texto a formato estructurado es esencial en la extracción de información de documentos. Herramientas como SpaCy (Explosion, 2025) y NLTK (NLTK, 2024) permiten la identificación de entidades, relaciones semánticas y categorización de contenido, lo que optimiza procesos en minería de datos y análisis de información empresarial.

En síntesis, las técnicas texto a texto han revolucionado la gestión y procesamiento de la información, facilitando la automatización de tareas lingüísticas complejas en diversos sectores.

Categoría	Descripción	Herramientas	Aplicaciones
Conversión de texto a formato estructurado	Extrae e identifica entidades, relaciones semánticas y categoriza contenido.	SpaCy (Explosion, 2025), NLTK (NLTK, 2024)	Minería de datos, análisis de información empresarial.
Técnicas texto a texto	Automatizan la gestión y procesamiento de información, simplificando tareas lingüísticas complejas.	-	Diversos sectores, incluyendo empresarial y académico.

Nota: Creado en OpenAI (2025)

### 9.3. Técnicas Texto a Imagen

Las técnicas de conversión de texto a imagen han avanzado con la integración de modelos de inteligencia artificial capaces de generar representaciones visuales a partir de descripciones textuales. Estas herramientas han encontrado aplicaciones en el arte digital, la publicidad, la medicina y la educación.

Uno de los avances más destacados en este campo es el uso de modelos generativos como DALL-E-3 (OpenAI, 2025b) y Stable Diffusion (StabilityAI, 2022), que permiten la creación de imágenes a partir de descripciones textuales (Figura 5). Estos modelos utilizan redes neuronales convolucionales y transformadores para interpretar instrucciones en lenguaje natural y generar ilustraciones detalladas.

**Figura 5.** Texto a Imagen

 Dibuja un estudiante de PLN



Nota: Creado en DALL-E (2025)

En el ámbito publicitario, estas técnicas permiten la generación automática de contenido visual para campañas de marketing. Empresas como Adobe (Adobe, 2025) y Canva (Canva, 2025) han implementado herramientas que convierten descripciones en gráficos listos para su publicación, optimizando los tiempos de producción y personalización.

En medicina, la conversión de texto a imagen ha facilitado la visualización de datos clínicos complejos. Por ejemplo, en la radiología asistida por inteligencia artificial, los médicos pueden ingresar descripciones de síntomas y obtener representaciones visuales de posibles diagnósticos. Esto ha mejorado la precisión en la interpretación de imágenes médicas y la toma de decisiones.

Por otro lado, en la educación, las técnicas de texto a imagen han permitido la creación de contenido didáctico interactivo. Herramientas como ThingLink (ThingLink, 2025) y Genially (Genially, 2025) transforman conceptos textuales en diagramas y presentaciones visuales, mejorando la comprensión de temas complejos.

#### 9.4. Técnicas no texto

Las técnicas no texto incluyen métodos de comunicación y procesamiento de información que no dependen del lenguaje escrito. Estas abarcan desde la interpretación de señales visuales y auditivas hasta el análisis de patrones en datos sensoriales.

Un ejemplo clave de estas técnicas es el reconocimiento de imágenes y videos mediante inteligencia artificial (Figura 6). Algoritmos de visión computacional como los utilizados en sistemas de seguridad pueden identificar rostros, objetos y comportamientos en tiempo real, aplicándose en vigilancia, control de acceso y análisis de datos urbanos.

**Figura 6.** Descripción de imagen “no texto”



Describe la imagen

La imagen muestra a un perro de pelaje dorado claro, vestido con una camisa blanca y una corbata gris. El perro sostiene un helado de cono con una bola de helado de vainilla y chocolate, y luce alegre con la lengua afuera, como si estuviera disfrutando de un día soleado al aire libre. El fondo muestra un parque con césped verde y árboles, iluminado por la luz cálida del sol. La escena transmite un ambiente divertido y relajado, destacando la representación antropomorfizada del perro.


Nota: Creado en ChatGPT (2025)

En el ámbito de la salud, la tecnología de reconocimiento de voz ha revolucionado la transcripción médica y la interacción con dispositivos. Sistemas como Dragon Medical (Nuance, 2025) permiten a los médicos dictar informes clínicos sin necesidad de escribir, mejorando la eficiencia y reduciendo errores en la documentación.

Otro avance significativo es el análisis de señales cerebrales mediante interfaces cerebro-computadora (BCI, por sus siglas en inglés). Estas tecnologías han permitido la comunicación de personas con

discapacidades severas mediante el control de dispositivos a través de ondas cerebrales, facilitando su autonomía e integración social (Figura 7).

**Figura 7.** Brain Computer Interface



Nota: Tomado de Williams (2021)

En el entretenimiento, las técnicas no texto han impulsado la personalización de experiencias a través de la música y los videojuegos. Algoritmos de recomendación como los utilizados por Spotify y Netflix analizan patrones de consumo y preferencias del usuario sin necesidad de interacción textual, ofreciendo contenido adaptado a sus intereses.

## 10. Uso de Transformer Models

El PLN ha experimentado avances significativos en los últimos años, impulsados en gran parte por la introducción de los modelos *Transformer*. Estos modelos, que incluyen arquitecturas como BERT, GPT y T5, han revolucionado la forma en que las máquinas comprenden, generan y manipulan el lenguaje humano. A diferencia de los enfoques tradicionales basados en redes recurrentes (RNN) o convolucionales (CNN), los Transformers utilizan mecanismos de autoatención para procesar texto en paralelo, lo que mejora su eficiencia y capacidad de capturar relaciones contextuales de largo alcance.

La aplicación de los modelos Transformer en PLN abarca desde la traducción automática y la generación de texto hasta la respuesta a preguntas y el análisis semántico. Gracias a su flexibilidad y escalabilidad, estos modelos han sido adoptados en diversas áreas, incluyendo la educación, la atención al cliente y la investigación científica. Esta sección explora los fundamentos técnicos de los modelos Transformer, sus avances más recientes, sus aplicaciones en el ámbito educativo y su proyección futura, destacando sus implicaciones y desafíos.

### 10.1. Fundamentos técnicos

El PLN ha experimentado una evolución significativa con el desarrollo de los modelos Transformer. Estos modelos han revolucionado la comprensión y generación de lenguaje natural al emplear mecanismos de autoatención que eliminan la dependencia de arquitecturas secuenciales como las redes neuronales recurrentes (RNN) y las redes convolucionales (CNN).


### 10.1.1. Principios de los modelos Transformer

La arquitectura Transformer se basa en el mecanismo de autoatención escalada (Self-Attention Mechanism), que permite al modelo evaluar la importancia relativa de cada palabra en una secuencia con respecto a las demás (Raschka, 2023). Esto se logra mediante el uso de tres componentes fundamentales:

- Vectores de consulta (Query)
- Vectores de clave (Key)
- Vectores de valor (Value)

Cada palabra en una oración se representa a través de estos vectores (Figura 8) y se procesa en paralelo, mejorando la eficiencia computacional y permitiendo la captura de dependencias a largo plazo en los textos.

Figura 8. QKV vectors



Nota: Tomado de Rahulraj (2023)

Además, los modelos Transformer incorporan un mecanismo de atención multi-cabezal (Multi-Head Attention), que permite a la red aprender múltiples representaciones de las relaciones semánticas de las palabras dentro del texto. Estos modelos también incluyen capas feedforward completamente conectadas y normalización por lotes (Batch Normalization) para mejorar la estabilidad del entrenamiento.

### 10.1.2. Principales modelos basados en Transformer

Desde la introducción del Transformer, han surgido diversas variantes optimizadas para distintas tareas de PLN. Algunos de los más destacados incluyen:

- **BERT (Bidirectional Encoder Representations from Transformers):** Introducido por Google, este modelo es entrenado con el método de enmascaramiento de palabras (Masked

Language Model), permitiendo un aprendizaje bidireccional del contexto de las palabras en una oración. Se ha utilizado para tareas como la clasificación de texto, la extracción de información y la respuesta a preguntas.

- **GPT (Generative Pre-trained Transformer):** Desarrollado por OpenAI, este modelo es un Transformer unidireccional basado en aprendizaje auto-regresivo. Ha sido utilizado para tareas de generación de texto, chatbots y escritura creativa.
- **T5 (Text-to-Text Transfer Transformer):** Propuesto por Google, este modelo reformula todas las tareas de PLN en problemas de transformación de texto a texto, mejorando la versatilidad en tareas de traducción, resumen automático y generación de texto.

### 10.1.3. Ejemplos de aplicación en PLN

1. **Traducción automática:** Modelos como MarianNMT, basados en Transformer, han mejorado la precisión en la traducción de textos al captar mejor las relaciones semánticas y contextuales entre los idiomas.
2. **Generación de texto:** Chatbots avanzados, como ChatGPT, emplean Transformers para producir respuestas coherentes y naturales en conversaciones humanas.
3. **Análisis de sentimientos:** Modelos como RoBERTa se utilizan en plataformas de redes sociales y servicio al cliente para evaluar la opinión de los usuarios.

Los modelos Transformer han redefinido el PLN, mejorando la eficiencia y la precisión de las tareas de procesamiento del lenguaje. Con el continuo desarrollo de arquitecturas más especializadas y eficientes, su impacto en la inteligencia artificial y en la interacción humano-máquina seguirá expandiéndose en los próximos años.

## 10.2. Avances en modelos de lenguaje

El PLN ha experimentado una transformación radical con la aparición de los modelos de lenguaje basados en la arquitectura Transformer. Desde su introducción, estos modelos han superado significativamente a las aproximaciones anteriores basadas en redes neuronales recurrentes (RNN) y redes convolucionales (CNN). Gracias a su capacidad para procesar texto en paralelo y capturar dependencias de largo alcance, los modelos Transformer han impulsado el desarrollo de aplicaciones avanzadas en PLN.

### 10.2.1. Principales avances en los Modelos Transformer

Uno de los avances más significativos en los modelos Transformer ha sido la mejora en la eficiencia computacional y la adaptabilidad a distintas tareas de PLN. A continuación, se destacan algunos de los desarrollos más relevantes:

#### 1. BERT (Bidirectional Encoder Representations from Transformers)

- Introducido por Devlin en 2019, BERT revolucionó el PLN al utilizar un método de entrenamiento bidireccional, permitiendo que el modelo comprenda el contexto de una palabra basada en las palabras anteriores y posteriores en una oración.
- Aplicaciones: Respuesta a preguntas, clasificación de texto y análisis semántico.

#### 2. GPT (Generative Pre-trained Transformer)

- Desarrollado por OpenAI, GPT introdujo el preentrenamiento seguido de ajuste fino (fine-tuning) para tareas específicas. Su evolución ha llevado a versiones como GPT-2 y GPT-3, que han mejorado la coherencia y fluidez de la generación de texto.

- Aplicaciones: Chatbots, generación de contenido y asistencia en redacción automatizada.

### 3. T5 (Text-to-Text Transfer Transformer)

- Propuesto por Google Research, T5 (Raffel, 2023) plantea un enfoque unificado en el que todas las tareas de PLN se reformulan como problemas de transformación de texto a texto.
- Aplicaciones: Traducción automática, generación de resúmenes y reformulación de textos.

### 4. XLNet y RoBERTa

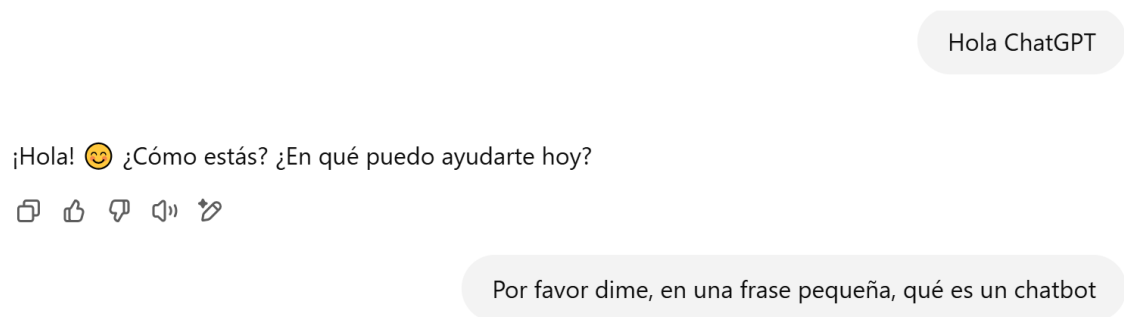
- XLNet (Yang, 2020) mejoró a BERT introduciendo una permutación de palabras para capturar mejor las relaciones contextuales.
- RoBERTa (Liu, 2019) optimizó el preentrenamiento de BERT aumentando la cantidad de datos y eliminando la predicción de la siguiente oración.
- Aplicaciones: Análisis de sentimientos, detección de entidades nombradas y motores de recomendación.

#### 10.2.2. Ejemplos de Aplicación en PLN

Los avances en los modelos Transformer han permitido el desarrollo de aplicaciones prácticas con impacto en diversos sectores:

- Asistentes virtuales y chatbots: Modelos como ChatGPT han mejorado la interacción humano-máquina (Figura 9) proporcionando respuestas más precisas y contextualmente adecuadas.
- Traducción automática: Modelos como MarianMT han elevado la calidad de la traducción al capturar matices lingüísticos y culturales.
- Análisis de sentimientos y moderación de contenido: Empresas utilizan RoBERTa y BERT para detectar discursos de odio y mejorar la seguridad en plataformas digitales.

**Figura 9.** ChatGPT usado como Chatbot



Un **chatbot** es un programa de inteligencia artificial que simula conversaciones con personas mediante texto o voz.

Nota: Creado en ChatGPT (2025)

Los avances en los modelos de lenguaje basados en Transformer han revolucionado el PLN, abriendo nuevas oportunidades para la automatización y comprensión del lenguaje humano. Con el desarrollo de modelos más eficientes y especializados, el impacto de estas tecnologías continuará expandiéndose en los próximos años.

### **10.3. Aplicaciones en la educación**

El desarrollo de los modelos de lenguaje basados en la arquitectura Transformer ha revolucionado el PLN en diversas áreas, incluyendo la educación. Estos modelos, como BERT, GPT y T5, han mejorado significativamente la capacidad de las máquinas para comprender y generar texto, lo que ha permitido la creación de herramientas avanzadas para la enseñanza y el aprendizaje. Su aplicabilidad en la educación abarca desde asistentes virtuales hasta la automatización de la retroalimentación en evaluaciones, transformando la interacción entre estudiantes y sistemas de aprendizaje digital.

#### **10.3.1. Personalización del Aprendizaje**

Uno de los principales beneficios de los modelos Transformer en la educación es la personalización del aprendizaje. Los sistemas educativos basados en PLN pueden analizar el rendimiento y las respuestas de los estudiantes para adaptar el contenido de enseñanza a sus necesidades específicas. Modelos como GPT-4 pueden generar explicaciones personalizadas, resolver dudas en tiempo real y proporcionar ejemplos relevantes según el nivel de comprensión del estudiante. El siguiente Webinar da una visión global del uso de ciertas herramientas para apoyar este proceso: <https://youtu.be/r4rIWWHvk0?si=bSpeQ1jVTdCEN-rB> .

Ejemplo: En plataformas de e-learning como Coursera o Duolingo, los chatbots potenciados por Transformers pueden ajustar la dificultad de las preguntas y sugerir recursos adicionales basándose en el historial de respuestas del usuario.

#### **10.3.2. Generación Automática de Contenidos Educativos**

Los modelos de lenguaje pueden generar materiales de aprendizaje como resúmenes, preguntas de opción múltiple y explicaciones detalladas de conceptos complejos. T5, por ejemplo, puede transformar una explicación técnica en una versión más accesible para diferentes niveles educativos.

Ejemplo: Un profesor puede utilizar un modelo Transformer para generar automáticamente ejercicios de comprensión lectora a partir de un texto dado, reduciendo el tiempo dedicado a la elaboración manual de materiales.

#### **10.3.3. Asistentes Virtuales para el Aprendizaje**

Los asistentes virtuales potenciados por PLN pueden proporcionar tutorías en tiempo real, guiando a los estudiantes en la resolución de problemas matemáticos, redacción de ensayos o comprensión de textos complejos. Herramientas como ChatGPT pueden actuar como tutores personalizados que responden preguntas de manera inmediata y estructurada.

Ejemplo: Universidades han integrado chatbots en sus plataformas de aprendizaje para responder preguntas frecuentes sobre inscripciones, fechas de exámenes y requisitos académicos, aliviando la carga administrativa de los docentes.

#### **10.3.4. Evaluación Automática y Retroalimentación Personalizada**

Los modelos Transformer pueden mejorar la evaluación del rendimiento estudiantil mediante la corrección automática de textos, la detección de plagio y la generación de retroalimentación detallada.

Modelos como RoBERTa y BERT pueden analizar respuestas escritas y proporcionar sugerencias de mejora basadas en criterios específicos.

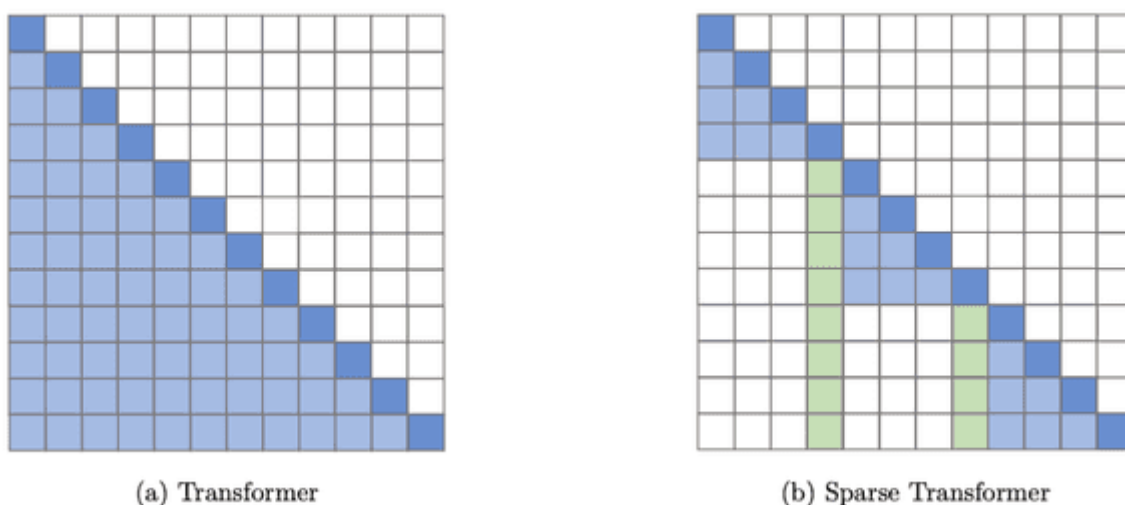
Ejemplo: En cursos de escritura académica, una IA basada en Transformers puede evaluar la coherencia, gramática y estructura de los ensayos, ofreciendo comentarios en tiempo real sobre posibles mejoras en la argumentación.

Los modelos Transformer han abierto nuevas posibilidades en la educación, permitiendo una mayor personalización, eficiencia en la generación de contenido, automatización de evaluaciones y asistencia virtual avanzada. A medida que estos modelos continúan evolucionando, su integración en sistemas educativos promete mejorar la calidad del aprendizaje y optimizar la labor docente, facilitando una educación más accesible y efectiva.

#### 10.4. Proyección

El futuro de los modelos Transformer en PLN apunta a una mayor eficiencia y especialización. La investigación en modelos multimodales, como CLIP y DALL-E, está ampliando la aplicabilidad de estos modelos a tareas que combinan texto, imagen y audio. Además, el desarrollo de modelos más eficientes en términos computacionales, como los Transformers sparse y compactos (Figura 10), busca reducir el alto costo de entrenamiento e inferencia.

**Figura 10.** Transformer sparse vs. Compacto



Nota: Tomado de Honda (2020)

Otro campo emergente es el de los modelos adaptativos, capaces de ajustarse dinámicamente a distintos contextos sin necesidad de un reentrenamiento extenso. Esto permitirá aplicaciones más personalizadas en educación, salud y atención al cliente. A medida que la interpretabilidad de estos modelos mejora, también se abren oportunidades para su regulación y uso ético.

## Referencias

- Adamo, D. (2022). *TextRank*. <https://github.com/davidadamojr/TextRank>
- Adobe. (2025). <https://www.adobe.com/>
- Canva. (2025). <https://www.canva.com/>
- DeepL. (2025). <https://www.deepl.com/>
- Devlin, J., Chang, M.-W., Lee, K., & Toutanova, K. (2019). *BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding* (arXiv:1810.04805). arXiv. <https://doi.org/10.48550/arXiv.1810.04805>
- Explosion. (2025). *spaCy*. <https://spacy.io/>
- Genially. (2025). <https://genially.com/>
- Google. (2025). *Google Translate*. <https://translate.google.com/>
- Honda, S. (2020). Transformers Now: A Survey of Recent Advances. <https://hippocampus-garden.com/xformers/>
- Kadam, S., & Vaidya, V. (2020). *Review and Analysis of Zero, One and Few Shot Learning Approaches*. In A. Abraham, A. K. Cherukuri, P. Melin, & N. Gandhi (Eds.), *Intelligent Systems Design and Applications* (pp. 100–112). Springer International Publishing. [https://doi.org/10.1007/978-3-030-16657-1\\_10](https://doi.org/10.1007/978-3-030-16657-1_10)
- Learneo. (2025). *QuillBot*. <https://quillbot.com/>
- Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., & Stoyanov, V. (2019). *RoBERTa: A Robustly Optimized BERT Pretraining Approach* (arXiv:1907.11692). arXiv. <https://doi.org/10.48550/arXiv.1907.11692>
- miso-belica. (2025). *Sumy*. <https://miso-belica.github.io/sumy/>
- NLTK. (2024). *Natural Language Toolkit*. <https://www.nltk.org/>
- Nuance. (2025). *Dragon Medical One*. <https://www.nuance.com/healthcare/dragon-ai-clinical-solutions/dragon-medical-one.html>
- OpenAI. (2025a). *GPT-4*. <https://openai.com/index/gpt-4/>
- OpenAI. (2025b). *DALL-E*. <https://openai.com/index/dall-e-3/>
- Raffel, C., Shazeer, N., Roberts, A., Lee, K., Narang, S., Matena, M., Zhou, Y., Li, W., & Liu, P. J. (2023). *Exploring the Limits of Transfer Learning with a Unified Text-to-Text Transformer* (arXiv:1910.10683). arXiv. <https://doi.org/10.48550/arXiv.1910.10683>
- Rahulraj, P. (2023). What are the query, key, and value vectors? <https://rahulrajpv7d.medium.com/what-are-the-query-key-and-value-vectors-5656b8ca5fa0>
- Raschka, S. (2023). *Understanding and Coding the Self-Attention Mechanism of Large Language Models From Scratch*. <https://sebastianraschka.com/blog/2023/self-attention-from-scratch.html>
- StabilityAI. (2022). *Stable Diffusion*. <https://stability.ai/stablediffusion>
- ThingLink. (2025). <https://www.thinglink.com/>
- Williams, S. (2021). Brain-Computer Interface User Types 90 Characters Per Minute with Mind. <https://www.the-scientist.com/brain-computer-interface-user-types-90-characters-per-minute-with-mind-68762>

Yang, Z., Dai, Z., Yang, Y., Carbonell, J., Salakhutdinov, R., & Le, Q. V. (2020). *XLNet: Generalized Autoregressive Pretraining for Language Understanding* (arXiv:1906.08237). arXiv. <https://doi.org/10.48550/arXiv.1906.08237>

## **Términos para definición**

### **Interfaz cerebro computadora**

Las interfaces cerebro-computadora (Brain-Computer Interfaces, BCI) son sistemas tecnológicos que permiten la comunicación directa entre el cerebro humano y un dispositivo externo, como una computadora o una prótesis. Estas interfaces captan y procesan señales neuronales, generalmente mediante electroencefalografía (EEG) o técnicas más avanzadas como electrocorticografía (ECoG) y resonancia magnética funcional (fMRI).

El objetivo de las BCI es interpretar la actividad cerebral y convertirla en comandos para controlar dispositivos sin la necesidad de movimientos físicos. Se aplican en el campo de la neurorehabilitación, permitiendo a personas con discapacidades motoras controlar prótesis robóticas o comunicarse mediante sintetizadores de voz. También tienen aplicaciones en neurociencia, videojuegos y entornos de realidad aumentada. Los avances en inteligencia artificial y aprendizaje profundo han mejorado la precisión de las BCI, impulsando su desarrollo para lograr interacciones más fluidas y naturales entre el cerebro y la tecnología.

### **Sparse Transformer**

Un Sparse Transformer es una variante optimizada de la arquitectura Transformer que reduce la complejidad computacional del mecanismo de autoatención, haciéndolo más eficiente para manejar secuencias largas. En los Transformers tradicionales, la autoatención densa requiere  $O(n^2)$  operaciones, lo que dificulta el procesamiento de textos extensos. Los Sparse Transformers optimizan este cálculo aplicando patrones de atención dispersa, donde cada token solo atiende a un subconjunto relevante de otros tokens en la secuencia.

Esta optimización se logra mediante enfoques como la atención fija y local, donde los tokens solo se conectan con vecinos cercanos, o atención basada en bloques y hashing, como en el modelo Reformer, que reduce la carga computacional sin comprometer la calidad del aprendizaje. Los Sparse Transformers se utilizan en tareas como modelado de lenguaje, generación de texto y síntesis de imágenes, permitiendo procesar secuencias más largas con menor costo computacional.



**La excelencia no se improvisa**

síguenos

