Universitat Autònoma de Barcelona

Dipòsit digital de documents de la UAB

This is the **published version** of the master thesis:

Lai, Haohong; Sánchez-Gijón, Pilar , dir. Análisis de las características de los errores de traducción automática neuronal y su posedición : un estudio de las traducciones (del español al chino) de un artículo periodístico. Bellaterra: Universitat Autònoma de Barcelona, 2023. 98 pag. (Màster Universitari en Traducció, Interpretació i Estudis Interculturals)

This version is available at https://ddd.uab.cat/record/289027

under the terms of the license

Universitat Autònoma de Barcelona

Facultad de Traducción e Interpretación

Departamento de Traducción, Interpretación y Estudios de Asia oriental

Máster Universitario en Traducción y Estudios Interculturales

TRABAJO DE FIN DE MÁSTER:

Análisis de las características de los errores de traducción automática neuronal y su posedición: Un estudio de las traducciones (del español al chino) de un artículo periodístico

Autor: Lai, Haohong

Directora: Dra. Pilar Sánchez-Gijón

Curso: 2022-2023

Barcelona, junio de 2023

Índice

Índice de figuras ..... **I**

Índice de tablas ..... **II**

Resumen **1**

1. Introducción **3**

2. Marco teórico **6**

2.1 Traducción automática neuronal **6**

2.1.1. Neuronal artificial y red neuronal artificial 7

2.1.2. *Word vector*, *word embedding* y predicción 9

2.1.3 Arquitecturas 13

2.1.4 Entrenamiento 20

2.1.5 Un sistema típico de TA neuronal: DeepL 22

2.2 Modelo de lenguaje y ChatGPT **23**

2.3 Posedición **24**

2.3.1 Definición 24

2.3.2 Tipos de la posedición y sus guías correspondientes 28

2.3.3 Revisión de la literatura de la posedición de TA neuronal 30

2.3.4 *Prompt* para traducción y posedición 37

2.4 Traducción periodística **38**

2.5 La noción de error de traducción **41**

3. Metodología **47**

3.1 Instrumentos de la investigación **47**

3.1.1 Corpus de texto 47

3.1.2 Recursos tecnológicos 47

3.2 Proceso de la investigación: análisis cualitativo **50**

3.3 Estudio exploratorio sin posedición **51**

4. Análisis de las características de error y su posedición **58**

4.1 Precisión **59**

4.2 Fluidez **68**

4.3 Terminología **70**

4.4 Verity **71**

5. Conclusiones **74**

6. Bibliografía **77**

7. Anexo **86**

7.1 Corpus de texto y la traducción con posedición **86**

7.2 Lista de los nombres propios y términos **93**

Índice de figuras

Figura 1. Una red neuronal simple formada por tres neuronas de entrada, tres neuronas ocultas y dos neuronas de salida 8
Figura 2. Representación distribuida 11
Figura 3. Experimento para la predicción de palabras de chino a español utilizando el software de traducción DeepL 13
Figura 4. Red neuronal recurrente 14
Figura 5. El proceso de un caso de traducción en el RNN con la atención 16
Figura 6. El Transformador - modelo de arquitectura 17
Figura 7. Proceso de la investigación 51
Figura 8. Rendimiento en la precisión de Google Translate 59
Figura 9. Rendimiento en la precisión de DeepL y ChatGPT-3.5 60
Figura 10. El desglose de los elementos en el segmento 62

Índice de tablas

Tabla 1. Guidelines for achieving “good enough” quality 29

Tabla 2. Guidelines for achieving quality similar or equal to human translation 30

Tabla 3. Propuesta de tipificación de errores de traducción 41

Tabla 4. Reflexión teórica sobre errores de traducción en TA 43

Tabla 5. Los tipos de error planificados para analizar 45

Tabla 6. Los *prompts* planificados para emplear 49

Tabla 7. La relación entre la reflexión teórica sobre error de traducción y la tipificación de errores de TAUS 56

Tabla 8. Números de errores de traducción 58

Tabla 9. Número y porcentaje de errores gramaticales 69

Resumen

A pesar de la prevalencia del uso de la traducción automática neuronal (TA neuronal) en la era contemporánea, existen escasos estudios que abordan de forma detallada las características de los errores que surgen en las traducciones entre chino y español proporcionadas por estas herramientas. En el presente trabajo de fin de máster, se efectuó la traducción de un artículo periodístico español al idioma chino mediante Google Translate, DeepL y ChatGPT-3.5. Posteriormente, se llevó a cabo un análisis cualitativo de las características de los errores en términos de precisión, fluidez, terminología y verity de las traducciones generadas. Los resultados del estudio evidenciaron que tanto el sistema de TA neuronal como el modelo de lenguaje de inteligencia artificial no siempre transfieren de manera precisa el contenido desde el texto original hasta el meta. Además, se apreciaron una confusión en la equivalencia léxica, una alta proporción de errores gramaticales en chino, así como una inconsistencia en la utilización de la terminología. Por último, se descubrió seguir las convenciones chinas de la denominación en textos españoles favorece una traducción correcta mediante la TA neuronal y ChatGPT-3.5.

Palabras claves: traducción automática neuronal, características de error, ChatGPT, posedición

Abstract

Despite the prevalent use of neural machine translation (NMT) in the contemporary era, there are limited studies that delve into the detailed characteristics of the errors arising in translations between Chinese and Spanish provided by these tools. In the current master's thesis, a Spanish journalistic article was translated into Chinese using Google Translate, DeepL, and ChatGPT-3.5. Subsequently, a qualitative analysis was conducted on the characteristics of the errors in terms of accuracy, fluency, terminology, and verity of the generated translations. The results of the study demonstrated that neither the NMT system nor the artificial intelligence language model always

accurately transferred content from the source text to the target. Additionally, confusion in lexical equivalence, a high proportion of grammatical errors in Chinese, and inconsistency in the use of terminology were noted. Lastly, it was discovered that adhering to Chinese naming conventions in Spanish texts promotes accurate translation through the NMT and ChatGPT-3.5.

Keywords: neural machine translation, error features, ChatGPT, post-editing

Resum

Malgrat la prevalença de l'ús de la traducció automàtica neuronal (TA neuronal) en l'era contemporània, hi ha pocs estudis que tracten de manera detallada les característiques dels errors que sorgeixen en les traduccions entre xinès i espanyol proporcionades per aquestes eines. En el present treball de fi de màster, es va realitzar la traducció d'un article periodístic espanyol al xinès mitjançant Google Translate, DeepL i ChatGPT-3.5. Posteriorment, es va dur a terme una anàlisi qualitativa de les característiques dels errors en termes de precisió, fluïdesa, terminologia i veritat de les traduccions generades. Els resultats de l'estudi van evidenciar que tant el sistema de TA neuronal com el model de llenguatge d'intel·ligència artificial no sempre transfereixen de manera precisa des del text original fins a l'objectiu. A més a més, es van apreciar una confusió en l'equivalència lèxica, una alta proporció d'errors gramaticals en xinès, així com una inconsistència en la utilització de la terminologia. Finalment, es va descobrir que seguir les convencions xineses de denominació en textos espanyols afavoreix una traducció correcta mitjançant la TA neuronal i ChatGPT-3.5.

Paraules clau: traducció automàtica neuronal, característiques d'error, ChatGPT, posedició

1. Introducción

Motivación

En los últimos años, la traducción automática neuronal (TA neuronal) ha ganado creciente popularidad entre el público en general y los profesionales debido a la mejora significativa en la calidad de las traducciones (Bentivogli *et al*. 2016; Castilho *et al*. 2017; Jia *et al*. 2019b; Toral & Sánchez-Cartagena, 2017; Wu *et al*. 2016), especialmente en términos de fluidez, en comparación con otras traducciones automáticas. Como resultado, se ha aplicado gradualmente a una amplia variedad de dominios textuales que antes se consideraban fuera de los límites de la tecnología de traducción (Vieira, 2019). Aunque la investigación sobre la posedición de TA basada en reglas y de la TA estadística lleva ya algún tiempo en marcha, numerosos estudios han demostrado que los sistemas de TA neuronal tienen propiedades muy diferentes a los de TA más antiguos en lo que se refiere a la posedición (Koponen *et al*. 2019). Sin embargo, la mayoría de los estudios sobre posedición en TA neuronal se han centrado en evaluar los resultados y compararlos con los modelos de posedición anteriores, y aún no se han explorado en profundidad sus propiedades. Además, se desconoce si la aplicación de la TA neuronal a la enseñanza de traducción dará lugar a importantes redefiniciones o actualizaciones conceptuales y metodológicas (Vieira, 2019).

Objetivos

El presente trabajo tiene como principal objetivo profundizar en el conocimiento de las propiedades de los errores del resultado generado por TA neuronal y de la aplicación de su posedición en la traducción periodística. Para lograr este objetivo general, se han establecido los siguientes objetivos específicos:

- Elaborar un marco teórico que incluya los conocimientos teóricos sobre el sistema de TA neuronal, el modelo de lenguaje, la posedición, la traducción periodística y la noción de error de traducción en el contexto de la posedición y la traducción periodística, con el fin de establecer una base teórica sólida para el análisis.
- Presentar el corpus de texto, los recursos tecnológicos seleccionados y la

herramienta TAUS DQF[1] que se utilizará, especificando los tipos y definiciones de errores previstos para el análisis. Realizar un estudio exploratorio sin posedición entre los recursos tecnológicos empleados con el objetivo de relacionar la reflexión teórica acerca de los errores de traducción con la clasificación de errores desarrollada por TAUS, garantizando que no existan contradicciones y que ambas perspectivas puedan ser empleadas en el presente estudio.

– Analizar el rendimiento respectivo de Google Translate, DeepL y ChatGPT-3.5 en función de las distintas categorías de errores. A continuación, resumir las características generales de los errores de los sistemas de TA neuronal en la traducción periodística y discutir cómo pueden corregirse los errores.

Con base en los objetivos propuestos anteriormente, se plantea la hipótesis de que es posible identificar características de error comunes en las traducciones generadas por sistemas de TA neuronal en el mismo dominio de texto (en este caso, los textos periodísticos). Esto puede facilitar una posedición eficaz por parte de los traductores humanos.

Estructura

En primer lugar, se presentarán la motivación, los objetivos y la hipótesis de la investigación.

En segundo lugar, se expondrá de manera concreta el marco teórico de esta investigación. Se destaca que el objeto de estudio es la posedición de la TA neuronal, y se explicarán algunos conceptos teóricos clave relacionados con la TA neuronal que son fundamentales para los investigadores en este ámbito. Se evitarán las explicaciones detalladas de las operaciones matemáticas y principios informáticos subyacentes. Posteriormente, se abordarán los conocimientos teóricos directamente relevantes para

[1] Translation Automation User Society Dynamic Quality Framework. Consultar más información: https://www.taus.net/data-services/dqf-mqm-error-annotation

este estudio, que incluyen la posedición, la traducción periodística y la noción de error de traducción.

En tercer lugar, se presentará la metodología, incluyendo las herramientas y métodos de investigación empleados y cómo se llevará a cabo el estudio. Se realizará un estudio exploratorio antes de iniciar el estudio principal con el fin de relacionar la reflexión teórica acerca de los errores de traducción con la clasificación de errores desarrollada por TAUS, garantizando que no existan contradicciones y que ambas perspectivas puedan ser empleadas de forma integrada en el presente estudio.

En cuarto lugar, en la sección de descripción y análisis de resultados, se analizarán las características de los errores cometidos por Google Translate, DeepL y ChatGPT-3.5 en relación con los tipos de error (precisión, fluidez, terminología y verity. Después del cada análisis de los ejemplos de errores en los textos traducidos automáticamente, se discutirán las soluciones de posedición apropiadas.

Al concluir este trabajo, se presentarán los resultados del análisis y se incluirán el artículo periodístico original utilizado para la investigación, la traducción completa con posedición, así como sus enlaces en la sección de anexo.

2. Marco teórico

Primeramente, este marco teórico ofrecerá una introducción concisa sobre la traducción neuronal automática, profundizando en la comprensión de conceptos como redes neuronales artificiales, vectores de palabras y arquitecturas. Adicionalmente, se abordarán los principios del descenso de gradiente y la generalización, que son elementos fundamentales en el proceso de entrenamiento del aprendizaje automático. Seguidamente, se detallará la definición del modelo de lenguaje de inteligencia artificial, utilizando como ejemplo ilustrativo a ChatGPT.

A continuación, se procederá a explorar de manera secuencial los conceptos restantes que están intrínsecamente vinculados a esta investigación: la posedición, la traducción periodística y los errores de traducción. Es importante subrayar que, considerando que este estudio se centra en las características comunes de los errores de traducción en la traducción automática, la noción de error de traducción será uno de los tópicos esenciales en nuestro discurso teórico.

2.1 Traducción automática neuronal

La TA neuronal, como una de las tecnologías de traducción más avanzadas, difiere significativamente de la TA basada en reglas y de la TA estadística. Los sistemas de TA basados en reglas son más fáciles de comprender, ya que utilizan reglas léxicas y gramaticales para establecer una equivalencia directa entre los idiomas de origen y destino. En cambio, la TA estadística utiliza un corpus extenso para entrenar un modelo estadístico de palabras y frases, el cual permite calcular las opciones de traducción más probables en función de la entrada en la lengua de origen (Sánchez Ramos & Rico Pérez, 2020).

Sin embargo, es importante destacar que la TA neuronal considera la traducción como una tarea matemática, en la cual se utilizan sistemas matemáticos denominados *redes neuronales artificiales* para realizar operaciones numéricas. Estos sistemas toman una

oración como entrada y la convierten en una secuencia de números (Pérez-Ortiz *et al*. 2022, p. 141). En otras palabras, en la TA neuronal, las palabras o frases se convierten en una serie de representaciones numéricas que se obtienen a partir del entrenamiento del sistema. A continuación, la TA neuronal utiliza el análisis del contexto para predecir palabras o frases en la lengua de destino (Forcada, 2017). Y todas estas operaciones se realizan en una arquitectura de *codificador-decodificador* (Pérez-Ortiz *et al*. 2022).

En segundo lugar, es importante señalar que la TA neuronal utiliza un mecanismo de *aprendizaje profundo*, el cual se lleva a cabo mediante un algoritmo específico llamado *algoritmo de aprendizaje profundo* (Sánchez Ramos & Rico Pérez, 2020; Pérez-Ortiz *et al*. 2022). En este sentido, los datos generados por los usuarios de la TA pueden ser utilizados para entrenar automáticamente el sistema, lo que se traduce en una mejora gradual de la precisión de las traducciones a medida que el sistema continúa «aprendiendo». Se dice «pueden» porque esto está relacionado con cuestiones de seguridad de los datos derivadas del aprendizaje automático (Nitzke & Hansen-Schirra, 2021), pero este aspecto no será abordado en el presente trabajo.

Con el objetivo de brindar una explicación sobre el concepto de TA neuronal en este trabajo, se llevará a cabo un desglose conceptual en las secciones siguientes. El propósito de este análisis es ofrecer una explicación concisa de los diferentes aspectos implicados en la TA neuronal sin profundizar en los aspectos matemáticos asociados a ella.

2.1.1. Neuronal artificial y red neuronal artificial

Los elementos fundamentales del sistema de TA neuronal son las neuronas y las redes neuronales (LeCun *et al*. 2015). Los seres humanos reaccionan naturalmente y comprenden su significado. Esto se debe a que el cerebro humano, compuesto por complejas redes neuronales y neuronas, posee una región específica encargada del procesamiento de imágenes. No obstante, las máquinas no tienen esta capacidad

intrínseca. Por lo tanto, para que una máquina pueda interpretar información visual, se necesitan utilizar neuronas artificiales. Y una red neuronal artificial, como su nombre sugiere, está compuesta por múltiples neuronas artificiales, distribuidas en tres tipos de capas: la capa de entrada, la capa oculta y la capa de salida. La descripción de la composición de cada capa se proporcionó en la sección anterior. La siguiente figura muestra una red neuronal simple compuesta por 8 neuronas que se utiliza con fines ilustrativos.

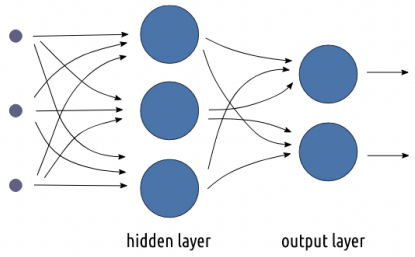

Figura 1. Una red neuronal simple formada por tres neuronas de entrada, tres neuronas ocultas y dos neuronas de salida

(Pérez-Ortiz *et al*. 2022, p. 146)

En la Figura 1, se observa que las tres neuronas muy pequeñas situadas en el extremo izquierdo forman la capa de entrada, cuya función es procesar la información de entrada y transmitirla a las neuronas de la capa oculta para su procesamiento adicional. Es importante señalar que los valores de activación de estas neuronas se establecen previamente durante el entrenamiento y se transmiten directamente a las neuronas de la capa oculta como entradas externas sin ser sometidos a ningún proceso de cálculo.

La capa oculta de una red neuronal es clave para que la TA neuronal produzca resultados precisos. Se puede comparar con el proceso de mejorar las habilidades de canto de un estudiante con la ayuda de un profesor de canto: primero se aprenden las técnicas de respiración, luego se perfecciona la resonancia nasal para controlar mejor las notas altas y finalmente se ensaya detenidamente para una actuación exitosa. En la red neuronal, este proceso paso a paso de optimización se lleva a cabo en las capas ocultas,

permitiendo un cálculo progresivo de la traducción. Cuantas más capas ocultas tenga la red, más capacidad tendrá para procesar información compleja y, por lo tanto, más precisos serán los resultados.

Una red neuronal con un número limitado de capas se conoce como «red neuronal de capas», mientras que una red neuronal con muchas capas se conoce como «red neuronal profunda». El algoritmo correspondiente se denomina «algoritmo de aprendizaje profundo» (Pérez-Ortiz *et al*. 2022). Este algoritmo tiene dos implicaciones importantes: en primer lugar, como en el ejemplo anterior sobre el estudiante que aprende a cantar, la salida generada por una red neuronal también se calcula a través del aprendizaje automático en las capas ocultas. En segundo lugar, el resultado puede mejorar gradualmente a medida que el modelo se entrena más. Por ejemplo, el motor de traducción de DeepL utiliza el texto ingresado por los usuarios y las traducciones obtenidas para entrenar y mejorar su red neuronal y algoritmo de traducción. Esto significa que los errores de traducción que se presentan actualmente en DeepL serán corregidos en algún momento futuro mediante el entrenamiento[2].

2.1.2. *Word vector*, *word embedding* y predicción

- Word vector y word embedding

Cuando se introducen palabras en un sistema de TA neuronal, se transforman en una serie de representaciones vectoriales, conocidas en el campo del procesamiento del lenguaje natural como *vector de palabra* (*word vector*) (LeCun *et al*. 2015, p. 441). Al principio, los expertos en el campo del procesamiento del lenguaje natural utilizaban la codificación *one-hot* para representar las palabras como vectores, donde cada palabra se representaba como un vector en el que solo un elemento era «1» y los demás eran «0». La posición de este elemento correspondía a la posición de la palabra en el

[2] Toda la información procede de: https://www.deepl.com/zh/privacy

vocabulario. Por ejemplo[3], si tomamos las palabras: manzana, plátano y naranja, sus vectores de palabras, obtenidos mediante la codificación *one-hot*, serían los siguientes:

manzana	1	0	0
plátano	0	1	0
naranja	0	0	1

Es decir, manzana [1,0,0]; plátano [0,1,0]; naranja [0,0,1].

Sin embargo, La codificación *one-hot* tiene limitaciones obvias, ya que solo usa 0 y 1 para componer sus elementos. En particular, la TA neuronal requiere el procesamiento de cantidades extremadamente grandes de información lingüística, y la codificación *one-hot* no puede manejar grandes cantidades de valores discretos ni captar las relaciones semánticas entre las palabras.

En consecuencia, métodos como *Word2Vec* (Goldberg & Levy, 2014; Rong, 2016) o *Glove* (Pennington *et al*. 2014), que mapean las palabras en un espacio vectorial continuo de baja dimensión (*low-dimensional continuous vector space*[4]) y construyen *representaciones distribuidas* (*distributed representations*) de los vectores de palabras en redes neuronales que permiten capturar las relaciones sintácticas y semánticas entre las palabras (Mikolov *et al*. 2006), han reemplazado a la codificación *one-hot*.

Cabe destacar que el vector de palabra y *word embedding* no son sinónimos

[3] Tenga en cuenta que en la TA neuronal, los vectores de palabras no necesitan ser fijados manualmente, ya que sus valores iniciales se basan en un corpus similar, y pueden actualizarse continuamente durante el entrenamiento para producir los mejores resultados en la tarea de traducción (Pérez-Ortiz *et al*. 2022).

[4] En el ámbito del procesamiento de lenguaje natural y el aprendizaje automático, se ha vuelto común usar espacios vectoriales de pocas dimensiones para simbolizar datos de texto, como palabras, frases y oraciones, en donde cada vector simboliza una entidad o concepto abstracto. (Bengio *et al*. 2003; Mikolov *et al*., 2006).

intercambiables, aunque están estrechamente relacionados entre sí. El término «vector de palabra» se refiere simplemente a una representación vectorial de palabra, mientras que «*word embedding*» se refiere al proceso de codificación de palabras (una vez que se ha generado un vector de palabras) y su mapeo en un espacio vectorial continuo de baja dimensión mediante técnicas como Word2Vec o Glove. el *Word embedding* es, por tanto, un proceso que debe ser considerado como una técnica holística en el campo del procesamiento del lenguaje natural. En el caso de la TA neuronal, la clave para el aprendizaje de las redes neuronales radica en la capacidad de calcular con precisión los vectores de palabras o frases en un espacio continuo de baja dimensión y formar las representaciones distribuidas adecuadas.

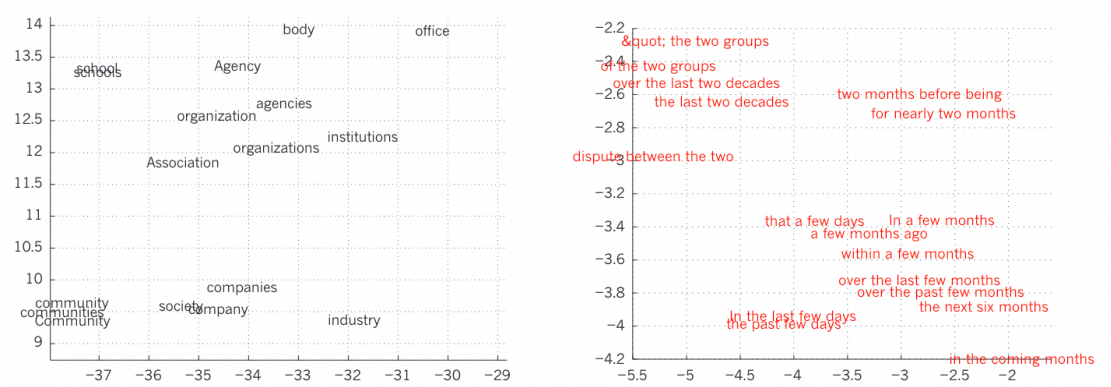

Figura 2. Representación distribuida

(LeCun *et al*. 2015, p. 441)

En la parte izquierda de la Figura 2 se presenta una representación de las palabras aprendidas para el modelar el lenguaje, las cuales son visualizadas en un sistema de coordenadas bidimensional para facilitar su comprensión. Por otro lado, en la parte derecha se muestra una representación bidimensional del vector de frases.

Sin embargo, las primeras técnicas del *word embedding* tenían algunas limitaciones evidentes. En primer lugar, no eran contextualizadas, ya que se calculaban considerando únicamente las palabras que suelen aparecer juntas en una frase, sin tener en cuenta los distintos significados que pueden tener las palabras (Pérez-Ortiz *et al*. 2022). Además,

en el modelo *sequence to sequence* propuesto por Sutskever *et al*. (2014), la entrada en el idioma de origen se codifica como un vector de longitud fija, lo que plantea ciertas limitaciones. Por ejemplo, cuando la secuencia de entrada es muy larga o contiene estructuras sintácticas complejas, este enfoque puede no capturar completamente toda la información de la secuencia, lo que resulta en una representación vectorial insuficiente del codificador para expresar el significado completo de la secuencia de entrada. En segundo lugar, este enfoque puede no tener capacidad para manejar algunos fenómenos lingüísticos como la desambiguación semántica y las relaciones semánticas complejas (Bahdanau *et al*. 2015).

Por lo tanto, para abordar estos problemas en la TA neuronal, se ha propuesto el mecanismo de *atención* (*attention*) por Bahdanau *et al*. (2015). En concreto, al utilizar el mecanismo de atención, el modelo de red neuronal puede asignar diferentes pesos a las distintas palabras del contexto en función de su importancia en la tarea actual, al igual que lo hace nuestro cerebro humano. De esta manera, el modelo puede representar mejor las relaciones entre las palabras y la información contextual. Normalmente, las palabras que cambian de significado en distintos contextos recibirán mayor atención por parte de la red neuronal, como es el caso de la palabra «estación», que puede referirse a diferentes cosas dependiendo del contexto (por ejemplo, estación de tren, estación del año, etc.), el *word embedding* intervenido en el mecanismo de atención se define como *contextual word embedding* (Pérez-Ortiz *et al*. 2022, p. 153).

- Predicción de la TA neuronal

La predicción de palabras es una tarea crucial en la tecnología de la TA neuronal, y para llevarla a cabo se utilizan arquitecturas como el RNN (*Recurrent neural network*) o el transformador. Es importante destacar que estas dos arquitecturas no son excluyentes y pueden coexistir de manera paralela en un sistema de TA neuronal. Además, se han introducido mecanismos de atención en el proceso de predicción para permitir que el modelo lingüístico tenga en cuenta la información importante en la secuencia de entrada y la meta.

En primer lugar, la secuencia de entrada en el idioma de origen se codifica en un vector de longitud fija en un espacio vectorial continuo de baja dimensión a través del proceso del *word embedding*. Cuando se genera la siguiente palabra, se calcula una distribución de probabilidad basada en las palabras generadas previamente y la información contextual, que indica la probabilidad de que la siguiente palabra sea la adecuada en el contexto del idioma de destino El sistema selecciona una palabra basándose en esta distribución de probabilidad para generar una predicción de palabra. Esta palabra predicha se agrega a la secuencia de destino y se convierte en la entrada para el siguiente momento, y el proceso se repite hasta que se completa la traducción de la frase.

A continuación, en la Figura 3 se muestra un pequeño experimento con el *software* de traducción DeepL para predecir palabras de chino a español. En este experimento, se introdujo como entrada únicamente la frase «El estudio de Wu *et al*. mostró [...] positivos», sin incluir la palabra «resultado», pero el software de traducción DeepL pudo predecir con éxito la salida de la frase completa, esto se debe a que el modelo de red neuronal puede inferir la palabra faltante basándose en el contexto y la información previa en la secuencia de entrada.

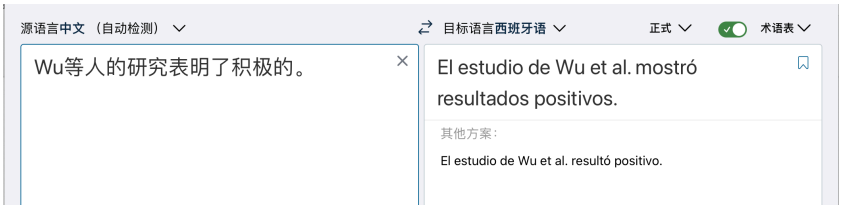

Figura 3. Experimento para la predicción de palabras de chino a español utilizando el software de traducción DeepL

2.1.3 Arquitecturas

- Red neuronal recurrente

Kalchbrenner y Blunsom (Kalchbrenner & Blunsom, 2013) fueron los primeros en introducir los *Modelos de traducción continua recurrentes* (*Recurrent Continuous Translation Model*s) como la arquitectura interna para la TA neuronal. Desde entonces,

las redes neuronales recurrentes (*Recurrent neural network, RNN*) han experimentado una serie de desarrollos clave, como el trabajo de Sutskever *et al*. (2014), que propusieron el uso de la red neuronal del *Long Short-Term Memory* (LSTM) para resolver el problema de la desaparición y explosión del gradiente en RNN. En resumen, el RNN originales eran incapaces de recordar información de secuencias más largas, lo que llevó a una degradación del rendimiento de la TA al traducir frases largas, como se ha demostrado en numerosos estudios de evaluación (Bentivogli *et al*. 2016; Toral & Sánchez-Cartagena, 2017).

En la etapa de codificación, el RNN procesa secuencialmente cada elemento de la lengua de origen, en el cual cada elemento sucesivo se procesa teniendo en cuenta la información del elemento previo. El resultado de este proceso es un *vector de estado* (*state vector*) que contiene el historial de todos los elementos previos de la secuencia, una vez que todos los elementos de la lengua de origen han sido procesados (LeCun *et al*. 2015). A continuación, se explicará el funcionamiento del RNN mediante una figura teórica.

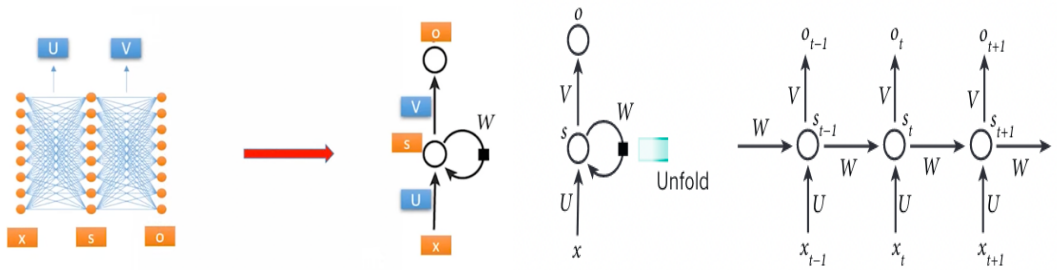

Figura 4. Red neuronal recurrente

(LeCun *et al*. 2015, p. 442)

De acuerdo con la Figura 4, se puede observar que «x» representa la capa de entrada, «s» es la capa oculta y «o» es la capa de salida, mientras que las líneas azules representan las conexiones entre neuronas con pesos. Estas conexiones de peso entre las neuronas forman dos matrices, «u» y «v», entre las tres capas de neuronas. En la

figura, «t» hace referencia al tiempo en un instante determinado, mientras que «w» se refiere al valor de la capa oculta anterior (pueden existir varias capas ocultas). Se puede apreciar que el valor de la capa oculta «s» no solo depende de la entrada actual «x», sino también del valor de la capa oculta anterior, este proceso se define como *autorregresivo*. Por lo tanto, en un RNN, cuantas más capas ocultas se agreguen, mayor será la precisión de la representación vectorial de la palabra y, por ende, mejor será la calidad de la traducción.

A pesar de los beneficios del modelo de RNN mencionado anteriormente, es importante señalar que este modelo no incorpora el mecanismo de atención. Esta limitación puede generar importante pérdida de información semántica en la traducción resultante, similar a un juego de «teléfono roto», donde el mensaje recibido por la primera persona no siempre coincide con el mensaje transmitido por la última, ya que puede haber información faltante debido a un descuido en el proceso de transmisión. Por lo tanto, Bahdanau *et al*. (2015) propusieron el mecanismo de atención que permitía que las redes neuronales recurrentes prestaran atención a las palabras de la frase de origen mientras procesaban el vector de estado. esto llevó al desarrollo de las redes neuronales recurrentes actuales, cuyo funcionamiento se muestra en la Figura 5, la cual ilustra el proceso de traducción en los RNNs que incorpora el mecanismo de atención. En este proceso, las redes neuronales recurrentes prestan atención a las palabras de la frase de origen mientras procesan el vector de estado, lo que permite una traducción más precisa y completa.

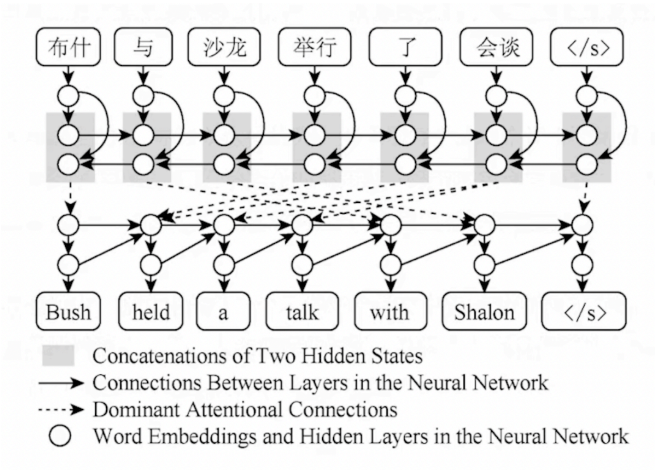

Figura 5. El proceso de un caso de traducción en el RNN con la atención

(Zhang & Han, 2019)

En la fase de codificación del sistema de TA neuronal, se puede observar claramente que el resultado del *word embedding* en el momento anterior influye en el *word embedding* en el momento siguiente, lo que finalmente genera un vector de estado que se utiliza como salida del RNN en la parte codificadora. Luego, este vector de estado se convierte en la entrada del RNN en la parte descodificadora del sistema de TA neuronal. Gracias a la implementación de la atención, el RNN es capaz de enfocarse en el vector de palabras generado en la fase de codificación durante la fase de descodificación, lo que se utiliza para identificar las palabras clave y las estructuras gramaticales necesarias para la traducción.

- Transformador: Codificador-decodificador basado en la atención

La arquitectura del codificador es una innovadora arquitectura de TA neuronal propuesta por Vaswani *et al*. (2017). Aunque se basa en el modelo convencional de codificador-decodificador, representa el primer modelo de transducción de secuencias basado completamente en la atención, reemplazando las capas recurrentes comúnmente utilizadas en las arquitecturas codificador-decodificador por la autoatención multicabezal (*multi-headed self-attention*). A continuación, se presentan las partes fundamentales de esta arquitectura mediante la ayuda de la Figura 6, que ilustra la estructura del codificador-decodificador con autoatención multicabezal. La figura

muestra las diferentes capas y subcapas que componen esta arquitectura, así como el flujo de información durante la fase de codificación y descodificación.

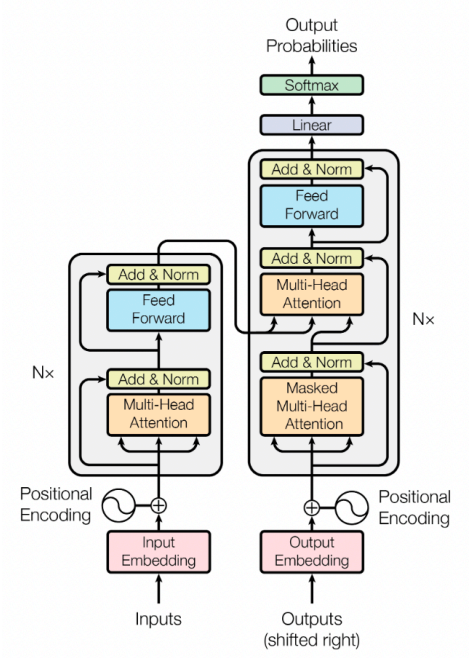

Figura 6. El Transformador - modelo de arquitectura

(Vaswani *et al*. 2017)

En primer lugar, comencemos por discutir la función de los codificadores en la arquitectura del transformador. Un codificador se encarga de transformar una oración en lengua fuente en una representación vectorial de longitud fija. En esta arquitectura, el codificador está compuesto por varias capas de codificación, cada una de las cuales se compone de dos subcapas:

- Autoatención multicabezal (*Multi-Head Self-Attention*): Esta subcapa capta la información relevante de la oración a través del cálculo de autoatención multicabezal en el vector de *word embedding*[5] de entrada y genera una nueva representación vectorial.
- Capa Totalmente Conectada de Avance (*Feed-Forward Fully Connected*

[5] En este contexto, se puede afirmar que las representaciones vectoriales de entrada han sido previamente sometidas al proceso de *word embedding*.

Layer): Esta subcapa toma la salida del mecanismo de autoatención multicabezal como entrada y la transforma y mapea a través de una red neuronal *feed-forward* para obtener la entrada de la siguiente capa codificadora.

Cada capa codificadora cuenta con una conexión residual (*Residual Connection*) y una normalización de capa (*Layer Normalization, Norm*), las cuales se emplean para mejorar la estabilidad y la eficacia del entrenamiento de la red.

El modelo codificador basado en la autoatención multicabezal difiere significativamente de las redes neuronales recurrentes previas, ya que permite al modelo procesar la frase de entrada completa de manera simultánea y sin tener en cuenta el orden secuencial de las palabras, lo que mejora significativamente la eficiencia y la capacidad de procesamiento de la red. En contraste, las redes neuronales recurrentes procesan cada palabra de manera secuencial y requieren un mayor tiempo de procesamiento para capturar las relaciones a largo plazo entre las palabras en una frase.

A continuación, se presenta la sección del decodificador. La función del decodificador es generar una traducción en la lengua de destino. En la arquitectura del transformador, el decodificador también está compuesto por varias capas de decodificación (*Decoder Layers*), cada una de las cuales se compone de tres subcapas:

- Atención Multicabezal Enmascarada (*Masked Muti-Head Attention*): Aunque el modelo puede procesar todas las frases de entrada al mismo tiempo en la fase de codificación, en la fase de decodificación la salida se predice de forma secuencial, es decir, la salida en un punto específico de tiempo depende de las salidas anteriores. Para mantener esta secuencialidad, se utiliza la atención multicabezal enmascarada, que oculta la información futura en el momento actual, asegurando que el modelo no vea la entrada

futura cuando los datos del codificador ingresan al decodificador. Esto es similar a un estudiante que no puede ver las respuestas a una pregunta antes de tiempo durante un examen, garantizando que el modelo funcione de la misma manera durante el entrenamiento y la predicción.

El mecanismo de atención es el componente fundamental de la arquitectura del transformador, ya que permite calcular los pesos de importancia de cada posición en la secuencia de entrada y utilizarlos para generar una representación vectorial. Tanto en el mecanismo de autoatención multicabezal como en el mecanismo de atención del codificador-decodificador, el mecanismo de atención calcula la similitud de cada posición de la secuencia de entrada con la posición actual, convirtiendo esta similitud en un coeficiente de peso normalizado que se utiliza para ponderar la suma y generar la representación vectorial (Vaswani *et al*. 2017). Este enfoque permite concentrar la información importante de la secuencia de entrada en la representación vectorial, mejorando así la precisión y fluidez de la traducción.

Debido a que el modelo no contiene ninguna recurrencia ni convolución, es necesario inyectar información sobre la posición relativa o absoluta de los *tokens* en la secuencia para que el modelo pueda utilizar el orden de la secuencia (Vaswani *et al*. 2017). En consecuencia, tanto en la parte del codificador como en la del descodificador, la entrada del vector de *word embedding* primero se somete al proceso de codificación posicional (*Positional Encoding*), cuyo propósito es preservar la información posicional en la secuencia de entrada. La codificación posicional convierte la información posicional de la secuencia en una representación vectorial que se agrega al vector de *word embedding* de la secuencia de entrada como entrada al modelo. En la arquitectura del transformador, la codificación posicional se calcula mediante una combinación de funciones seno y coseno, lo que resulta eficaz para retener la información en distintas posiciones de la secuencia.

2.1.4 Entrenamiento

En el sistema de TA neuronal, el cálculo de los vectores de palabras es, en realidad, el de los valores de activación del grupo de neuronas (Forcada, 2017). Este proceso está directamente relacionado con la capacidad de la TA neuronal para generar representaciones distribuidas precisas con el fin de acceder a la información semántica y contextual de palabras o frases durante el aprendizaje. La activación de una neurona se consigue sumando los valores de activación de todas las neuronas conectadas a ella en la capa anterior y multiplicándolos por sus pesos correspondientes. En resumen, se puede decir que entrenar una red neuronal es el proceso de determinar el peso de las conexiones entre sus neuronas (Pérez-Ortiz *et al*. 2022, p. 148).

Además, para entrenar la TA neuronal, se requiere el uso de tres corpus paralelos: el corpus de entrenamiento, que suele contener entre 100,000 y 1 millón de frases, y cuya función es entrenar las neuronas de la red; el corpus de desarrollo, que consta de 1,000 a 3,000 frases, y se utiliza para detener el entrenamiento en un momento determinado con el fin de prevenir el sobreajuste; y el corpus de *test*, que también consta de 1,000 a 3,000 frases, y se utiliza para evaluar el efecto del entrenamiento en la calidad de la traducción de la red neuronal (Forcada, 2019).

- Descenso gradiente (*Gradient descent*)

Cuando una red neuronal no entrenada recibe una entrada, no puede generar la salida deseada, ya que sus pesos no se han ajustado adecuadamente. Por lo tanto, es común utilizar un modelo de *descenso de gradiente* (*Gradient Descent*) para entrenar la red neuronal en un corpus extenso. La utilidad de este modelo se puede comparar con una persona en una ladera con un terreno complejo, donde tiene varios caminos para descender, pero no siempre es fácil elegir el camino más rápido y adecuado. El modelo de descenso de gradiente está diseñado para ayudar a la TA neuronal a reducir el valor de la función de error de la forma más rápida posible y a aprender los pesos óptimos (*3Blue1Brown - Gradient Descent, How Neural Networks Learn*, 2023).

La magnitud del cambio en los pesos se regula mediante un parámetro denominado *tasa de aprendizaje* (*learning rate*). En las primeras fases del entrenamiento, esta tasa de aprendizaje suele ser elevada, pero se reduce gradualmente a medida que los pesos se acercan a sus valores óptimos. Como el material de entrenamiento de la red neuronal proviene de un corpus bilingüe de ejemplos, es necesario entrenar la red para que su salida sea similar o idéntica a los ejemplos de entrenamiento. Cuanto mayor sea el cambio en los pesos, mayor será la tasa de aprendizaje, lo que indica que la red neuronal está en una fase inicial de aprendizaje y su salida es muy diferente a los ejemplos. Por el contrario, cuanto menor sea la magnitud de la tasa de aprendizaje, menor será el cambio en los pesos, lo que indica que el aprendizaje se acerca a su fin. Una vez que se determinan los pesos óptimos, el entrenamiento se detiene y se considera que la red neuronal está entrenada y es capaz de traducir con éxito frases en la lengua de destino que sean similares al ejemplo de traducción proporcionado.

La red neuronal puede emplear los pesos óptimos obtenidos durante el entrenamiento para producir resultados precisos en nuevas entradas que comparten características similares con los ejemplos utilizados en el entrenamiento. Este proceso se asemeja a la solución de un problema matemático en el cual la red neuronal sigue las directrices del instructor para resolver algunos ejemplos y, posteriormente, tiene la capacidad de resolver problemas similares de forma autónoma. Este fenómeno se conoce como «generalización» y se abordará con mayor profundidad en un contexto no matemático en el siguiente punto.

- Generalización (*Generalisation*)

La generalización es un proceso cognitivo esencial tanto para humanos como para animales, ya que permite la aplicación de lo aprendido en nuevos contextos que pueden ser similares pero no idénticos a los que se presentaron originalmente durante el aprendizaje (Pérez-Ortiz *et al*. 2022). Por ejemplo, al aprender un nuevo idioma, no es necesario dominar todas las expresiones de la lengua desde el principio, pero una vez que se ha adquirido un cierto vocabulario, frases y gramática, se puede utilizar lo

aprendido para desenvolverse competente en diversas situaciones cotidianas, de estudio y de trabajo. Del mismo modo, la TA neuronal puede no producir una traducción precisa si el corpus utilizado para el entrenamiento no es lo suficientemente grande, pero aún puede seguir trabajando en lugar de no responder, como si el ordenador se hubiera bloqueado, cuando se ingresa una frase en el idioma de origen. Por esta razón, la TA neuronal requiere un entrenamiento amplio y continuo para mejorar su rendimiento de traducción.

La capacidad de generalización de la TA neuronal, es decir, la habilidad de traducir frases que no han sido vistas durante el entrenamiento se basa en el uso de vectores de palabras similares para representar palabras similares. La representación vectorial de la frase se obtiene a partir del vector de palabras. Para lograr esto, la red neuronal debe entrenarse para proporcionar representaciones vectoriales similares para palabras que están fuertemente relacionadas en algunas dimensiones y así generar la representación distribuida correcta. Sólo entonces, la TA neuronal podrá producir salidas similares al introducir entradas similares, independientemente de que estén o no incluidas en el conjunto de entrenamiento. Además, una característica de las redes neuronales es la suavidad de los cálculos, lo que significa que si los valores de entrada se modifican ligeramente, el resultado no variará significativamente. Esto puede ser de interés en el campo de la preedición para la TA neuronal.

2.1.5 Un sistema típico de TA neuronal: DeepL[6]

DeepL es un traductor automático neuronal de alta calidad que fue lanzado en agosto de 2017 por la compañía alemana DeepL SE, con sede en Colonia. Según los expertos, la mayoría de los traductores automáticos neuronales comerciales utilizan una arquitectura de transformador basada en la autoatención, que consta de un codificador y un descodificador (Pérez-Ortiz *et al*. 2022). Aunque la tecnología específica de traducción utilizada por DeepL es un secreto comercial, se sabe que la tecnología

[6] Toda la información procede de: https://www.DeepL.com/press.html

subyacente es una red neuronal que calcula representaciones vectoriales de palabras o frases para obtener una representación distribuida capaz de captar la información semántica. Además, los datos de uso de los usuarios de DeepL Free se utilizan para el entrenamiento continuo de la red neuronal. Inicialmente, DeepL ofrecía traducciones gratuitas entre siete idiomas, pero actualmente su soporte se ha ampliado a 31 idiomas.

2.2 Modelo de lenguaje y ChatGPT

En el procesamiento del lenguaje natural, un modelo de lenguaje es una herramienta que se utiliza para predecir la probabilidad de aparición de una secuencia de texto determinada. Este tipo de modelo se basa en datos de entrenamiento, como un gran corpus de texto, y emplea el aprendizaje de los patrones de distribución de probabilidad de las palabras y frases de una lengua para predecir la probabilidad de una secuencia de texto en particular. Los modelos lingüísticos pueden ser empleados en diversas tareas del procesamiento del lenguaje natural, tales como el reconocimiento de voz, la traducción automática y la generación de texto.

La obtención de los patrones de distribución de probabilidad de las palabras y frases puede basarse en dos enfoques. Los modelos lingüísticos tradicionales, como los N-gramas[7], se basan en modelos de datos estadísticos que analizan y modelizan grandes cantidades de datos de texto para determinar los patrones de distribución de probabilidad de las palabras y frases, lo cual es similar al funcionamiento de la TA estadística. Sin embargo, en los últimos años se ha popularizado el uso de modelos de lenguaje basados en redes neuronales en el campo del procesamiento del lenguaje natural. Estos modelos utilizan técnicas de *word embedding* (Véase las páginas 9-12 del marco teórico) para mapear palabras en vectores de baja dimensión, lo que puede reflejar mejor la información semántica (Bengio *et al*. 2003). Posteriormente, emplean

[7] Es una secuencia de un número de palabras (N) en un determinado texto. Por ejemplo, si hablamos de unigrama, estaremos hablando de una sola palabra; bigramas, de dos palabras; trigrama, de tres palabras (Sánchez Ramos & Rico Pérez, 2020, p. 52).

arquitecturas como los RNNs o los transformadores (Véase las páginas 13-19 del marco teórico) para modelar las relaciones entre las palabras y aprender los patrones de distribución de probabilidad en las secuencias de texto.

ChatGPT es un modelo de lenguaje de red neuronal basado en transformadores desarrollado por OpenAI, que utiliza el método de «aprendizaje no supervisado» para entrenarse en un corpus de gran tamaño y aprender la distribución de probabilidad de las palabras y frases (Brown *et al*. 2020). Este modelo ha demostrado una gran capacidad para generar textos coherentes y fluidos, lo que lo convierte en una de las herramientas más avanzadas de procesamiento del lenguaje natural en la actualidad.

Es importante destacar que ChatGPT-3.5 es actualmente el modelo de lenguaje con red neuronal más grande en el campo de la generación de lenguaje natural, con 175 mil millones de parámetros de peso y 96 capas de neuronas (Brown *et al*. 2020). Debido a su complejidad, el entrenamiento del modelo requiere una gran cantidad de recursos computacionales y financieros. De hecho, según estimaciones recientes, el entrenamiento de ChatGPT-3.5 en un ordenador potente con sistema de GPU en la nube podría costar hasta 4,6 millones de dólares y tardar unos 355 años (*OpenAI's GPT-3 Language Model*, 2020) Sin embargo, gracias a su gran capacidad expresiva y de generalización, ChatGPT-3.5 ha demostrado ser una herramienta poderosa y versátil para diversas aplicaciones del procesamiento del lenguaje natural.

2.3 Posedición

2.3.1 Definición

La posedición ha sido una práctica común desde los primeros días de la tecnología de la TA (Vieira, 2019), y su relación con la TA es estrecha e inseparable (Sánchez Ramos & Rico Pérez, 2020). En cierto sentido, incluso se podría afirmar que el desarrollo de la TA es la base para el estudio de la posedición. Para los diferentes sistemas de TA, ya sean basados en reglas, estadísticos o neuronales, se han llevado a cabo investigaciones

específicas sobre posedición, mientras que la definición de posedición ha sido objeto de debate por parte de muchos estudiosos hasta la actualidad. Pero conforme se siguen integrando los recursos de la tecnología de traducción, es necesario reconocer que los límites entre posedición y otros conceptos de la tecnología de traducción se vuelven cada vez más difusos (por ejemplo, entre posedición y traducción asistida por ordenador), y que cada vez están más integrados en el proceso de traducción.

Al principio, Wagner (1985) propuso una definición extremadamente simple de la posedición: «la posedición implica la corrección de un texto pretraducido en lugar de traducirlo «*from scratch*». Esta definición destaca una de las diferencias más básicas entre posedición y traducción «*from scratch*», a saber, que el poseditor siempre trabaja con un texto que ya ha sido traducido. Vasconcellos y Bostad (1992) la definen en términos de una estrategia para preservar la mayor parte posible de la producción de la TA. con el fin de aumentar la productividad de los traductores y reducir su carga de trabajo. Estudios posteriores han confirmado esta idea en el caso de la posedición para la TA basada en reglas y la TA estadística (Sanchez-Torron & Koehn, 2016), aunque en el caso de la posedición para la TA neuronal, las conclusiones parecen ser más complejas de lo esperado (Zouhar *et al*. 2021).

En 2003, Allen (2003, p. 298) propuso una definición de posedición que abarcaba una amplia gama de información:

> «In basic terms, the task of the post-editor is to edit, modify and/or correct pre-translated text that has been processed by an MT system from a source language into (a) target language(s).»

En aquel entonces, la propuesta de Allen fue una de las definiciones más autorizadas de posedición y, aun en la actualidad, sigue siendo informativa. En esta definición se reflejan por primera vez los tipos de edición que se llevan a cabo durante el proceso de posedición, incluyendo la edición, revisión y/o corrección. Es interesante destacar que el autor limita el tipo de posedición a la bilingüe o multilingüe, ignorando la posibilidad

de posedición monolingüe. Esto puede deberse a que la posedición monolingüe fue necesaria en el pasado debido a la escasez de traductores bilingües y multilingües, (Vieira, 2019), mientras que en el siglo XXI, la industria de la traducción ha alcanzado su apogeo y el número de traductores satisface cada vez más las necesidades del mercado internacional (Hurtado Albir, 2001).

En 2011, O'Brien (2011, p. 197) propuso una definición que sigue siendo autorizada hoy en día:

> «The post-editing is the correction of raw machine translated output by a human translator according to specific guidelines and quality criteria.»

Al igual que Allen, O'Brien deja claro en su definición el tema de la responsabilidad en la posedición, que debe ser realizada por traductores profesionales en lugar de personas sin formación y con una competencia lingüística ordinaria. Además, la definición incluye la necesidad de seguir «directrices y criterios de calidad específicos», lo que implica que la posedición tiene tareas y requisitos de calidad diferentes a los de la traducción «*from scratch*» y la revisión de traducción.

Sin embargo, ninguna de las definiciones previas de posedición ha considerado la tendencia actual hacia la integración de recursos tecnológicos en la traducción, lo que hace importante considerar la capacidad instrumental del poseditor al definir la posedición (Sánchez-Gijón, 2016). Es ampliamente conocido que, la traducción asistida por ordenador (TAO) se ha considerado una herramienta útil para los traductores profesionales que trabajan con traducciones «*from scratch*», especialmente a través del uso de memoria de traducción y gestión terminológica. Actualmente, la TA, la TAO y la posedición han surgido como un modelo integrado de trabajo. Muchas plataformas de traducción profesional ofrecen esta integración, como *Trados Studio* y *LanguageX*, que recientemente ha sido presentada en el concurso internacional WMT (*Workshop on Machine Translation*) de 2022.

En este sentido, Cui Qiliang (2014, p. 69) se refirió a la posedición anterior que no consideraba la integración de los recursos de tecnología de traducción como «la posedición en sentido estricto» y propuso un «entorno de traducción integrado» que consiste en la TAO con memoria de traducción y gestión terminológica en su núcleo, así como la TA y el sistema de gestión de proyectos de traducción (*Translation Management System*, TMS en inglés). Por lo tanto, la posedición se define en sentido amplio como:

> «En el entorno de traducción integrado, la posedición se refiere al proceso de revisión manual o corrección parcialmente automatizada de la traducción inicial producida, llevado a cabo por editores profesionales con objetivos de calidad específicos en mente, con el fin de mantener la calidad de la traducción y la eficiencia del proceso.»[8]

En esta definición, no solo se mencionan las herramientas técnicas que se utilizarán en la tarea de posedición, sino que también se abarca tanto la posedición manual como la automática. No obstante, en este trabajo nos centraremos únicamente en la posedición manual, mientras que la posedición automática quedará fuera del alcance del presente estudio.

Lo último que hay que subrayar es que «el desarrollo de la posedición está íntimamente ligado a la evolución de la TA» (Sánchez Ramos & Rico Pérez, 2020, p. 73). Así pues, a medida que la tecnología de la TA continúe avanzando, las connotaciones de la posedición se actualizarán constantemente. Desde una perspectiva diferente, diferentes significados se desplegarán. Como señaló Vieira (2019, p. 329), la posedición es un término inclusivo que puede ser utilizado para describir no solo la edición estática de los resultados de la TA, sino también el uso de la TA como fuente adicional de

---

[8] Texto original traducido por el autor de este trabajo: «在集成翻译环境中，为保持译文质量和翻译效率，由专业编辑人员根据特定的质量目标，对输出的初始译文进行人工评审或部分自动化修订的过程。»

coincidencias en entornos de la TAO. Puede ser tanto un servicio profesional como una forma de aumentar la productividad de los traductores en encargos regulares que permiten el uso de la TA. En cualquier caso, el concepto de posedición como forma de aumentar la productividad permanecerá invariable.

2.3.2 Tipos de la posedición y sus guías correspondientes

Al conversar con individuos que tienen un conocimiento limitado acerca de la posedición, pueden pensar que la competencia en la lengua de destino es suficiente para llevar a cabo la tarea de posedición (Nitzke & Hansen-Schirra, 2021). No obstante, como traductor profesional, debe considerarse que evaluar la corrección de una traducción sin compararla con el texto original puede ser peligroso. En un mundo en el que escasean los traductores bilingües y multilingües, llevar a cabo una posedición monolingüe parece ser una medida de último recurso (Vieira, 2019). Aunque Mitchell *et al*. (2013) demostraron que en algunos casos la posedición monolingüe puede mejorar la fluidez y comprensibilidad de una traducción, esto podría ser a expensas de la precisión y adecuación (Nitzke, 2016), ya que la posedición monolingüe carece de referencia al texto de origen y podría ser considerada como una «mejora estética sin sentido» de la traducción.

En resumen, desde la perspectiva de las lenguas implicadas, se puede distinguir entre dos tipos de posedición: *posedición monolingüe* y *posedición bilingüe*. Sin embargo, es bien sabido que es poco probable que algún cliente en el mercado de la traducción busque específicamente un «poseditor monolingüe», y que la posedición monolingüe no merece ser estudiada por sí sola en la actualidad. En consecuencia, toda la tarea de posedición en este trabajo se refiere únicamente a la posedición bilingüe.

Si se considera hasta qué punto pueden editarse las traducciones automáticas, hay dos tipos de posedición ampliamente utilizados: posedición rápida (*light post-editing*) y posedición completa (*full post-editing*) (Nitzke & Hansen-Schirra, 2021, pp. 30-31).

- Posedición rápida

La posedición rápida está relacionada con *inbound translation approach* propuesto por Allen (2003), el cual implica que las traducciones solo son utilizadas internamente por el grupo destinatario y no se difunden, y a menudo tienen un carácter perecedero (Sánchez Ramos & Rico Pérez, 2020). Para llevar a cabo la posedición rápida, TAUS ha desarrollado una guía específica basada en los estándares de *good enough quality*, que incluye los siguientes contenidos:

Guidelines for achieving "good enough[9]" quality
1. Aim for semantically correct translation.
2. Ensure that no information has been accidentally added or omitted.
3. Edit any offensive, inappropriate or culturally unacceptable content.
4. Use as much of the raw MT output as possible.
5. Basic rules regarding spelling apply.
6. No need to implement corrections that are of a stylistic nature only.
7. No need to restructure sentences solely to improve the natural flow of the text.

Tabla 1. Guidelines for achieving "good enough" quality

(Massardo *et al*. 2016, p. 17)

- Posedición completa

A diferencia de la posedición rápida, la posedición completa se asocia con el enfoque de *outbound translation* propuesto por Allen (2003), que algunos estudiosos denominan también *traducción con fines divulgativos* (Sánchez Ramos & Rico Pérez, 2020). Dado que estas traducciones están destinadas a ser difundidas en la sociedad, requieren un alto nivel de calidad lingüística. TAUS equipara este tipo de posedición con la traducción humana, argumentando que la calidad de un texto sometido a una posedición

[9] «Good enough» se define como comprensible (es decir, se puede entender el contenido principal del mensaje), preciso (es decir, comunica el mismo significado que el texto de origen), sin ser estilísticamente convincente. Puede que el texto suene como si lo hubiera generado un ordenador, que la sintaxis sea algo inusual, que la gramática no sea perfecta, pero el mensaje es preciso (Massardo *et al*. 2016, p. 17).

completa debería ser equivalente a la de una traducción humana. En este sentido, TAUS ha estandarizado las directrices correspondientes:

Guidelines for achieving quality similar or equal to human translation[10]
1. Aim for grammatically, syntactically and semantically correct translation.
2. Ensure that key terminology is correctly translated and that untranslated terms belong to the client's list of "Do Not Translate" terms.
3. Ensure that no information has been accidentally added or omitted.
4. Edit any offensive, inappropriate or culturally unacceptable content.
5. Use as much of the raw MT output as possible.
6. Basic rules regarding spelling, punctuation and hyphenation apply.
7. Ensure that formatting is correct.

Tabla 2. Guidelines for achieving quality similar or equal to human translation

(Massardo *et al*. 2016, p. 18)

2.3.3 Revisión de la literatura de la posedición de TA neuronal

1. Antecedentes de la investigación

La posedición de la TA se considera una técnica efectiva para mejorar la productividad de los traductores en comparación con las traducciones «*from scratch*» (Koponen, 2016; Nitzke & Hansen-Schirra, 2021). En los últimos años, ha habido una serie de avances en los modelos lingüísticos mediante redes neuronales, incluyendo el enfoque «secuencia a secuencia» propuesto por Sutskever *et al*. (2014) y el mecanismo de «atención» propuesto por Bahdanau *et al*. (2015). El lanzamiento de Google Neural Machine Translation en 2016 y de DeepL en 2017 ha llevado a la TA neuronal a convertirse en la primera opción tanto para el público en general como para los

[10] Este nivel de calidad se define generalmente como comprensible (es decir, un usuario final entiende perfectamente el contenido del mensaje), preciso (es decir, comunica el mismo significado que el texto de origen), estilísticamente fino, aunque el estilo puede no ser tan bueno como el logrado por un traductor humano nativo. La sintaxis es normal, la gramática y la puntuación son correctas (Massardo *et al*. 2016, p. 18).

profesionales (Sánchez Ramos & Rico Pérez, 2020). Como resultado, los académicos han comenzado gradualmente a investigar el modelo de trabajo de *NMT* (*Neural Machine Translation*) +*PE* (*Post-Editing*).

Muchos estudiosos han partido de una posibilidad aparentemente razonable, a saber, de que la posedición basada en las traducciones de mayor calidad generadas por TA neuronal puede aumentar aún más la productividad del traductor. Sin embargo, varios estudios realizados en los últimos años han indicado que este supuesto no es necesariamente cierto. En consecuencia, esta revisión bibliográfica intenta resumir tan exhaustivamente como sea posible las investigaciones recientes relacionadas con la posedición de la TA neuronal, y trata de analizar sus defectos y limitaciones, así como de proponer las tendencias de investigación clave en esta área para el futuro.

Es importante destacar que, debido a la amplia variedad de pares de lenguas y dominios textuales que se han estudiado en el campo de la TA neuronal, resulta difícil obtener una conclusión generalizada (Castilho *et al*. 2017; Nitzke & Hansen-Schirra, 2021). En este sentido, es recomendable considerar otras líneas de investigación, como el análisis de las características de los errores en la salida de la TA neuronal o la utilización de herramientas de recursos externos (por ejemplo, el modelo de lenguaje ChatGPT), con el objetivo de mejorar la eficacia de la posedición en general y proporcionar orientación en cuanto a la preedición y posedición de textos generados por TA neuronal. Esta perspectiva de investigación representa la principal aportación del presente trabajo de fin de máster.

2. Estado actual de la investigación

De acuerdo con la revisión bibliográfica actual, se ha podido constatar que una parte sustancial de la investigación en este ámbito se ha centrado en la medición de los esfuerzos de posedición de la TA neuronal, comparando estos resultados con los obtenidos en la posedición para la TA estadística basada en frases, en la TAO, así como en la traducción «*from scratch*». Todos los estudios de evaluación del esfuerzo de la

posedición de la TA neuronal utilizan las tres dimensiones separadas pero interrelacionadas establecidas por Krings (2001): temporal, técnica y cognitiva. El esfuerzo temporal mide el tiempo dedicado a la posedición, el esfuerzo técnico se refiere a las inserciones, supresiones o reescrituras realizadas por el traductor para editar las traducciones generadas por TA, y suele medirse mediante HTER (Snover *et al*. 2006). Finalmente, la dimensión del esfuerzo cognitivo examina los procesos de pensamiento del traductor mientras realiza la posedición y puede medirse mediante protocolos de pensamiento audible o seguimiento ocular.

- Esfuerzo de posedición con TA neuronal vs posedición con TA estadística y traducción «*from scratch*»

El estudio llevado a cabo por Bentivogli *et al*. (2016) fue uno de los primeros sobre la posedición de la TA neuronal. Los autores realizaron una posedición completa del resultado del inglés al alemán de un sistema de TA neuronal y tres sistemas de TA estadística en la campaña de evaluación IWSLT[11] 2015. Los resultados del estudio indicaron una reducción global del esfuerzo de posedición del 26%, aunque la ventaja se redujo a medida que aumentaba la longitud de las frases. Esta conclusión ha sido confirmada sucesivamente por estudios posteriores (por ejemplo, Toral & Sánchez-Cartagena, 2017; Toral *et al*. 2018). Sin embargo, el resultado en cuestión se enfoca únicamente en la dimensión técnica de la posedición, sin considerar el tiempo de posedición y el esfuerzo cognitivo. Además, los datos han sido recopilados solamente en un par de lenguas, específicamente del inglés al alemán, lo que plantea interrogantes sobre la generalización de los resultados obtenidos en otros contextos lingüísticos. En el estudio realizado por Castilho *et al*. (2017), se ha señado que, en términos generales, la TA neuronal produce resultados más fluidos en comparación con los producidos por la TA estadística, no obstante, el esfuerzo de la posedición de la TA neuronal no disminuye.

[11] International Conference on Spoken Language Translation. Consultar más información: https://iwslt.org/

El presente fenómeno paradójico ha sido objeto de estudio por diversos investigadores, y algunos de ellos han obtenido resultados positivos. En el estudio realizado por Toral *et al*. (2018) se encargó a seis traductores con experiencia en traducción literaria la traducción de un capítulo de la novela inglesa *Warbreaker* al catalán en tres situaciones alternas (traducción «*from scratch*», posedición con TA estadística basada en frases y posedición con TA neuronal) y se analizaron sus esfuerzos en tres dimensiones: temporal, técnica y cognitiva. Los resultados mostraron que la posedición con TA neuronal fue la modalidad más productiva. Sin embargo, en términos de esfuerzo cognitivo, la posedición de la TA neuronal dio lugar a tiempos de pausa más largos.

Además, Koponen *et al*. (2019) llevaron a cabo una comparación de la posedición del inglés al finés empleando la TA neuronal, la TA basada en frases y la TA estadística. El análisis demostró que existen diferencias significativas en el tipo de edición entre los sistemas de TA, y señaló una disminución del esfuerzo requerido en la dimensión temporal de la posedición para la TA neuronal. Asimismo, Álvarez *et al*. (2019) realizaron un estudio de la posedición empleando la TA neuronal y la TA estadística basada en frases en una combinación de idiomas estrechamente relacionados (catalán-español). Una vez más, los resultados revelaron que la posedición basada en TA neuronal conservaba más fragmentos sin modificar y reducía el esfuerzo temporal en comparación con la posedición de TA estadística.

No obstante, los dos estudios mencionados, sin excepción, han empleado la métrica BLEU o una metodología similar para predecir tanto la carga de trabajo requerida de la posedición como la calidad del resultado final. Aunque es cierto que los sistemas de TA más avanzados generan menos cambios en la oración en comparación con las traducciones realizadas por humanos, esto no implica necesariamente que la tarea de posedición sea más sencilla. Varios expertos han analizado y señalado que, dado que las traducciones generadas por TA neuronal poseen un alto grado de fluidez, sus errores son más difíciles de identificar y resolver (Castilho *et al*. 2017; Nitzke & Hansen-Schirra, 2021; Van Brussel *et al*. 2018). Esto puede dificultar la posedición con TA

neuronal y costar más esfuerzo al traductor, lo cual se ve respaldado en cierta medida por la investigación que se presenta a continuación.

Por un lado, en un estudio llevado a cabo por Daems y Macken (2019) se investigó el impacto de los sistemas de TA interactivos y adaptativos en el proceso de posedición (del inglés al neerlandés). En este estudio se concluyó que, en términos de esfuerzo temporal y técnico de posedición, la diferencia entre la TA estadística y la TA neuronal era escasa, si bien los resultados iniciales de la TA estadística presentaban una mayor cantidad de errores. Por otro lado, en un estudio sobre la posedición de 68 estudiantes de traducción que traducían dos periódicos ingleses al chino, Jia *et al*. (2019a) descubrieron que, a pesar del menor esfuerzo técnico y cognitivo, la posedición con TA neuronal no era mucho más rápida que la posedición con TA estadística basada en frases.

En un estudio realizado por Zouhar *et al*. (2021) se utilizaron 13 sistemas de TA neuronal para generar traducciones del inglés al checo y se analizó el trabajo de posedición de 30 traductores profesionales. Los resultados indicaron que la relación entre la calidad de la TA neuronal y el tiempo de posedición es débil y no directa. Por consiguiente, es posible que pequeñas mejoras en los sistemas de TA, evaluadas por medio de métricas automáticas, no tengan un efecto significativo en la eficacia de la posedición.

- Esfuerzo de posedición con TA neuronal vs TAO

La investigación en cuestión ha recibido una atención limitada en el campo debido a la sugerencia de que la relación entre la TAO y la posesión de TA debería ser complementaria en lugar de rival (Cui, 2014; Nitzke & Hansen-Schirra, 2021). Sin embargo, algunos académicos han examinado este aspecto en cierta medida.

Läubli *et al*. (2019) llevaron a cabo un estudio comparativo para examinar el efecto de la posedición de TA neuronal y TAO en la velocidad y la calidad de la traducción de textos en el sector bancario y financiero. Los pares de lenguas estudiados fueron

alemán-francés/italiano. Los resultados del estudio indicaron que la posedición con la TA neuronal ofreció una ventaja significativa en términos de tiempo en comparación con la traducción mediante TAO, pero no fue tan beneficiosa cuando se pretendía obtener la máxima calidad en la traducción. El estudio tiene limitaciones, ya que sólo contó con la participación de cuatro traductores, por lo que no se pudo observar el nivel medio de los participantes, y no se examinó si los traductores tenían conocimientos del dominio.

Sánchez-Gijón *et al*. (2019) realizaron también un interesante estudio. Compararon los datos de traducción (inglés-español) utilizando la posedición de la TA neuronal y la traducción asistida por memoria de traducción, descubrieron que era necesario editar menos fragmentos después de utilizar la TA neuronal que utilizando la memoria de traducción, pero que dicha edición parecía llevar más tiempo. También observaron que los traductores con una actitud positiva hacia la posedición con TA neuronal eran más productivos que aquellos con una actitud negativa.

3. Valoración crítica y tendencia futura

La posedición de la TA neuronal es, sin duda, un campo de investigación «joven». En la comunidad académica se han realizado diversos estudios evaluativos para medir esfuerzos de este enfoque. Los resultados de investigación varían según los pares de lenguas y las áreas textuales. Algunos sostienen que la TA neuronal puede mejorar la productividad del traductor hasta cierto punto, pero otros sugieren que la relación entre una mejor calidad de la TA y la productividad de la posedición es compleja. Una reducción del esfuerzo técnico no significa una reducción del esfuerzo temporal y cognitivo. Se necesita más investigación para sacar conclusiones más precisas. Además, la actitud del traductor hacia la posedición de TA neuronal también puede ser un factor que afecta la productividad.

Sin embargo, la investigación actual sobre la posedición de la TA neuronal parece ser limitada y superficial en sus datos del análisis. La naturaleza de la posedición con la TA

neuronal sigue siendo un tema poco explorado. Por ejemplo, ¿cuáles son las características de los errores de salida que deben tratar los poseditores con la TA neuronal? ¿Cuáles son las capacidades y habilidades correspondientes de la posedición mediante la TA neuronal cuando se aplica a dominios específicos? ¿Son siempre científicos los métodos de evaluación automática utilizados hasta ahora?

El trabajo de Viera (2019) sostiene que la posedición se considera actualmente como la dirección más probable que tomarán los traductores profesionales a medida que se consoliden los recursos técnicos para la traducción. Debido a la integración de los recursos tecnológicos, los límites entre la posedición y la traducción «*from scratch*», así como entre los conceptos de traductor y poseditor, se volverán cada vez más difusos. Además, el rol del traductor o poseditor no se limita a realizar una transcripción puramente lingüística, sino que se les exigirá que proporcionen una variedad de servicios relacionados con la tradumática. Este nuevo enfoque supone un gran desafío para la formación de poseditores, ya que las investigaciones han demostrado que el nivel actual de concienciación sobre la posedición entre los estudiantes de traducción sigue siendo muy limitado (Koponen & Salmi, 2017; Yamada, 2019).

La exploración de la posedición en áreas textuales específicas es también una de las direcciones futuras. Particularmente, ha habido un gran interés en la aplicación de la posedición en el campo de la traducción literaria (Moorkens *et al*. 2018; Guerberof-Arenas & Toral, 2020), el cual durante mucho tiempo ha sido considerado un terreno vedado para la entrada de la tradumática. A pesar de que las primeras investigaciones sobre este tema han arrojado resultados alentadores, es necesario redefinir algunos conceptos y metodologías importantes para poder avanzar en esta área. Por ejemplo, las expectativas de calidad en la posedición aumentarán considerablemente, lo que requerirá un nuevo paradigma teórico para evaluar la calidad de los trabajos realizados.

Otro punto que merece la pena mencionar es que ChatGPT-3.5, lanzada en noviembre de 2022. Un estudio reciente de Jiao *et al*. (2023) indica que el rendimiento de la

traducción ofrecido por ChatGPT-3.5 en pares de idiomas de alto nivel de recursos es equiparable al obtenido por Google Translate, DeepL y Tencent. Asimismo, se observan mejoras significativas en la calidad de la traducción en idiomas de bajo nivel de recursos al utilizar la técnica «*pivot prompting*[12]». El 1 de marzo de 2023, OpenAI ha anunciado el lanzamiento del programa API de ChatGPT, que primero pone en marcha en varias aplicaciones que tienen la relación cooperativa con OpenAI, y cuya principal función es insertar una interfaz API de conversación inteligente en ellos para satisfacer las necesidades más personalizadas de los usuarios (Brockman *et al*. 2023). En Quizlet (Bayer, 2023), por ejemplo, los usuarios pueden acceder a su propio asistente ChatGPT-3.5 para resolver cualquier duda relacionada con el aprendizaje de idiomas. Este es un buen ejemplo de lo que se puede lograr en el futuro si el ChatGPT-3.5 se pudiera introducir a un *software* de procesamiento de textos como Word o a una plataforma de traducción integrada como Trados Studio, lo que permitiría ofrecer sugerencias de traducción valiosas a los poseditores (traductores) durante el proceso de traducción y reducir, por ende, el tiempo necesario para identificar y solucionar los problemas de la traducción automática. Pero esto es solo el comienzo. El martes 14 de marzo, OpenAI sorprendentemente lanzó GPT-4, que ahora tiene la capacidad de procesar información de imágenes (OpenAI, 2023). Estos cambios tecnológicos consecuentes sin duda generarán una nueva ronda de reflexión sobre el modelo de trabajo para traductor o poseditor.

2.3.4 *Prompt* para traducción y posedición

El *prompt* puede es una herramienta esencial para interactuar con la inteligencia artificial (IA). pudiendo manifestarse como una pregunta, una instrucción o la descripción de una tarea. Así, puede interpretarse como un conjunto de instrucciones modulables que orienta al sistema de IA hacia la generación de la respuesta adecuada.

[12] En concreto, pedimos a ChatGPT que traduzca primero la frase de origen a una lengua pivote con muchos recursos (por defecto, el inglés) y después a la lengua de destino (Jiao *et al*. 2023).

En términos de las IA más sofisticadas, como las recientes incorporaciones New Bing o ChatGPT-3.5, estas poseen la habilidad de reconocer prácticamente cualquier tipo de prompt y responder de forma pertinente. Aún más, estos modelos de IA exhiben capacidades de memoria, lo que permite una interacción coherente y prolongada con los usuarios, ofreciendo una experiencia que asemeja la comunicación con un humano. Este avance abre el camino hacia interacciones más profundas con los modelos de lenguaje de IA, incluyendo la realización de traducciones interactiva.

2.4 Traducción periodística

A pesar de que se han llevado a cabo numerosos estudios en el ámbito de la comunicación sobre el periodismo, la traducción periodística ha sido una área escasamente estudiada durante la década posterior al nuevo milenio (Palmer, 2009; Guerrero, 2019), Esto se debe, en parte, a que los académicos de la comunicación prestaron poca atención a las transformaciones interlingüísticas que tienen lugar en la producción de noticias y, además, tendieron a considerar la traducción como un proceso secundario (Barkho, 2008). Incluso los periodistas que trabajaban a nivel internacional y realizaban actividades de traducción, percibían que la traducción era la parte menos relevante de sus carreras (Bielsa & Bassnett, 2008). Como resultado, no concebían su trabajo como fruto de actividades de traducción (Holland, 2013, pp. 337-338).

No obstante, la importancia de la traducción en la comunicación de noticias no puede ser subestimada. Palmer (2009, p. 187) enfatizó que la traducción periodística puede considerarse una articulación del discurso que produce su propia gama de efectos, particularmente los cambios de significado que pueden derivarse del acto de traducir. Esto es consecuencia de la intervención de diversas organizaciones involucradas en el proceso de recopilación y difusión de noticias.

Siguiendo los criterios de división propuestos por Valdeón (2015), se considera que todos los estudios sobre traducción periodística se llevan a cabo bajo los siguientes

enfoques:

- Enfoques basados en productos

Se trata de uno de los métodos de investigación más destacados en el ámbito de la traducción periodística. Los investigadores parten de ciertos textos de traducción periodística ya concluidos y se enfocan en componentes específicos de los textos traducidos. Por ejemplo, los titulares (Ono, 2003; Shi, 2014), en parte debido a que suelen ser breves y desempeñan un papel crucial en los textos de noticias (Valdeón, 2015, p. 647). Otros académicos, por supuesto, realizan comparaciones de la traducción de periódicos en diferentes idiomas en su totalidad y se apoyan en la práctica de la traducción para analizar las técnicas de traducción periodística (Guerrero, 2006).

La ideología ha sido la base de muchos estudios de este tipo, que han explorado cómo las traducciones modifican el mensaje del periódico original y han analizado las razones y objetivos detrás de ello desde la perspectiva de la ideología del traductor. Por ejemplo, los estudios de Chen (2009; 2011a; 2011b) analizaron en profundidad el componente ideológico de las traducciones de noticias cuando el texto informativo aborda la relación entre China y Taiwán (China). Luo (2015) también investigó las estrategias de traducción utilizadas por los traductores que trabajaron en las traducciones periodísticas durante los Juegos Olímpicos de Londres 2012 para presentar una imagen positiva del pueblo chino.

- Enfoques basados en procesos

Este enfoque ha recibido menos atención que el enfoque basado en el producto (Valdeón, 2015, p. 648). Su objeto de investigación se centra en cómo se producen los textos de traducción periodística, quién los produce y en qué contextos se traducen. La ideología del traductor sigue siendo un punto clave del enfoque, como lo demostró Pan (2017) en su estudio sobre cómo funciona la traducción periodística en los países comunistas, donde la libertad de expresión está profundamente controlada en algunos aspectos, así como la ambivalencia de las personas que esperan ser informadas por

traducciones fieles y al mismo tiempo desean adherirse a los principios ideológicos de su propio país.

Además, existen otras perspectivas de investigación relevantes en el ámbito de la traducción periodística. Por ejemplo, los estudios culturales en la traducción periodística, que se enfocan en analizar cómo los elementos culturales afectan a la traducción periodística (Bielsa & Bassnett, 2008; Conway, 2010). También están los estudios de recepción, en los que los investigadores estudian la traducción periodística desde la perspectiva del lector, explorando las formas en que los lectores interpretan e interactúan con los periódicos traducidos (Valdeón, 2015). Finalmente, los enfoques de investigación basados en los medios de comunicación, que analizan la difusión de las noticias en diferentes medios (periódicos, televisión, radio e Internet) y las variaciones y técnicas de traducción que se aplican en cada uno de ellos, requieren atención por parte de los traductores periodísticos.

Otro aspecto importante a destacar es el interés que siempre han suscitado los textos periodísticos en la enseñanza de la traducción o de idiomas extranjeros (Guerrero, 2006). En este sentido, Valdeón (2015, p. 651) señala que la traducción periodística puede ser un recurso valioso para la enseñanza de lenguas, debido en parte a que los periódicos en lengua extranjera son fácilmente accesibles y cubren una amplia variedad de áreas temáticas. Por ejemplo, la página web oficial de *El País* divide sus textos en secciones de noticias internacionales, opinión, economía, sociedad, educación, medio ambiente, ciencias médicas, ciencias y tecnología, cultura, deportes, entre otras.

Por último, varios estudiosos coinciden en que el carácter interdisciplinario de la traducción de noticias es muy deseable y, de hecho, debe ser considerado en la investigación (Valdeón, 2015; Guerrero, 2019). En este trabajo, se utiliza un periódico como fuente para analizar las características de los errores de la TA neuronal y las técnicas de posedición correspondientes, intentando vincular la posedición con la traducción periodística, pero se trata de un intento preliminar.

2.5 La noción de error de traducción

En la traductología, se han propuesto diferentes nociones del *error de traducción* por varios estudiosos, desde sus propias perspectivas y puntos de vista analíticos. No se pretende revisar ni comparar estas nociones en este trabajo. Según Hurtado Albir (2001, p. 289), el error de traducción se refiere a «una equivalencia inadecuada para la tarea traductora encomendada». Además, presenta una propuesta general para clasificar los distintos tipos de errores de traducción (2001, pp. 305-306):

Propuesta de tipificación	● Inadecuaciones que afectan a la comprensión del TO (texto original): falso sentido, sinsentido, no mismo sentido, adición, supresión, referencia extralingüística mal solucionada e inadecuaciones de variación lingüística (tono, dialectos, idiolecto, etc.);
	● Inadecuaciones que afectan a la expresión en la lengua de llegada: ortografía y puntuación, gramática, léxico, aspectos textuales (coherencia, progresión temática, elementos de referencia, conectores) y redacción (formulación defectuosa o poco clara, falta de riqueza expresiva, pleonasmos, etc.);
	● Inadecuaciones pragmáticas, por no ser acordes con la finalidad de traducción (en relación con el tipo de encargo, el destinario a que va dirigida), el método elegido, el género textual y sus convenciones, etc.

Tabla 3. Propuesta de tipificación de errores de traducción

Sin embargo, es importante tener en cuenta que, por un lado, los errores de traducción descritos por Hurtado están orientados a traductores humanos. Cuando los traductores

automáticos se convierten en objeto de estudio, resulta imperativo revisar y reformular estos conceptos.

En primer lugar, es importante destacar que para los sistemas de traducción automática contemporáneos, no existe una función cognitiva humana específica denominada «comprensión». La traducción que estos sistemas efectúan es, en esencia, el producto de una serie de operaciones matemáticas ejecutadas dentro de su arquitectura interna, que permite la transferencia del idioma de origen al idioma de destino. De acuerdo con la definición de errores de traducción propuesta por Hurtado, se podría inferir que las inadecuaciones tales como falso sentido, sinsentido, no mismo sentido, adición y omisión, posiblemente se deben a imprecisiones en las operaciones matemáticas de la arquitectura interna del sistema, lo cual resulta en una representación incorrecta del contenido entre el texto de origen y el de destino. Por ende, desde la perspectiva de la traducción automática, las inadecuaciones que afectan la comprensión del texto original son, en realidad, errores en la transferencia entre el texto de origen y el de destino.

En segundo lugar, aspectos tales como la ortografía y puntuación, la gramática, el léxico, los aspectos textuales y la redacción en la lengua de llegada, pueden ser categorizados como errores de redacción en el texto meta producido por la TA. En este tipo de error, la transferencia del contenido literal del texto fuente se logra en el texto de destino sin omisiones aparentes. Sin embargo, el texto traducido exhibe varias deficiencias, entre las que se incluyen errores gramaticales y ortográficas, ausencia de equivalencia léxica, presencia de expresiones poco claras, etc.

En síntesis, es posible formular una reflexión acerca de la teoría de errores de traducción sugerida por Hurtado desde la perspectiva de la traducción automática, como se ilustra en la Tabla 4:

Reflexión teórica sobre errores de traducción en TA	
Tipos de error dirigidos a la traducción humana	Tipos de error dirigidos a la traducción automática
1. Inadecuaciones que afectan a la comprensión del TO.	1. Errores en la transferencia entre el texto original y el meta.
2. Inadecuaciones que afectan a la expresión en la lengua de llegada.	2. Errores de la redacción en el texto meta.
3. Inadecuaciones pragmáticas	3. Errores pragmáticos

Tabla 4. Reflexión teórica sobre errores de traducción en TA

Por otro lado, la tipificación de errores de traducción en la Tabla 4 es de carácter más macroscópico. Dado que este estudio implica la evaluación de dichos errores, se hace necesaria una teoría de criterios de errores de traducción más elaborada. *Translation Automation User Society* (TAUS), en colaboración con *Multidimensional Quality Metrics* (MQM), ha establecido una serie de criterios para evaluar los errores de traducción. De acuerdo con la tipología de errores propuesta por TAUS (Lommel, 2018), los tipos de errores detectables son: precisión, fluidez, terminología, estilo, diseño, convención local y veracidad. Dada la naturaleza del presente estudio, solo se evaluarán y analizarán la precisión, la fluidez, la terminología y *verity*. Las definiciones de cada uno de estos términos se detallan a continuación:

Tipo de error de alto nivel	Tipo de error de bajo nivel	Definición
Precisión: El texto meta no refleja fielmente el texto fuente, teniendo en cuenta las diferencias autorizadas por las especificaciones.	Adición	El texto de destino incluye texto que no está presente en el origen.
	Omisión	Falta contenido en la traducción que está presente en el origen.

	Mistranslation	El contenido de destino no representa con precisión el contenido de origen.
	Over-translation	El texto de destino es más específico que el texto de origen.
	Under-translation	El texto de destino es menos específico que el texto de origen.
	Texto no traducido (Untranslated text)	El contenido que debía ser traducido se ha dejado sin traducir.
	Coincidencia de memoria de traducción exacta incorrecta (Improper exact TM match)	Se proporciona una traducción como una coincidencia exacta de un sistema de memoria de traducción, pero en realidad es incorrecta.
Fluidez: Cuestiones relacionadas con la forma o el contenido de un texto, independientemente de si se trata de una traducción o no.	Puntuación	Se utiliza incorrectamente (para la configuración regional o el estilo).
	Ortografía	Cuestiones relacionadas con la ortografía de las palabras.
	Gramática	Cuestiones relacionadas con la gramática o la sintaxis del texto, distintas de la ortografía y la ortotipografía.

	Registro gramatical	El contenido utiliza un registro gramatical incorrecto, como el uso de pronombres o formas verbales informales cuando se requieren sus homólogos formales.
	Inconsistencia	El texto muestra incoherencias internas.
	Link/cross-reference	Los enlaces son incoherentes en el texto.
	Codificación de caracteres	Los caracteres son ilegibles debido a la aplicación incorrecta de una codificación.
Terminología: Un término (palabra específica del dominio) se traduce con un término distinto del esperado para el dominio o se especifica de otro modo.	Incoherente con termbase	Un término se utiliza de forma incoherente con un término base especificado.
	Uso incoherente de la terminología	La terminología se utiliza de forma incoherente en el texto.
Verity: El texto hace afirmaciones que contradicen el mundo del texto.	Referencia cultural específica	El contenido utiliza de forma inapropiada una referencia específica de una cultura que no será comprensible para el público al que va dirigido.

Tabla 5. Los tipos de error planificados para analizar
(Adaptada y traducida de «CriteriaDefinitions» de la tipología de errores TAUS DQF)

Adicionalmente, con el propósito de evidenciar y robustecer la correlación existente entre los criterios de errores empleados en la práctica de evaluación de errores y la reflexión teórica, se implementará un estudio exploratorio previo a la realización de la

investigación principal. Los detalles de este estudio se expondrán en la última sección metodológica.

Por último, hay que tener en cuenta que algunos aspectos, que en otros dominios textuales podrían ser evaluados como secundarios, pueden requerir más atención en la traducción de periódicos, especialmente el factor ideológico del lector final. Por ejemplo, si un traductor, ya sea español o chino, traduce del español al chino un artículo periodístico sobre la situación en el Estrecho de Taiwán, es inaceptable no indicar claramente que «Taiwán» pertenece a China para los lectores chinos. Aunque esto no afecte la comprensión del texto original y no contenga ningún error a nivel lingüístico en la lengua meta, se debe tener en cuenta durante la posedición, ya que se considera una inadecuación pragmática y es, sin duda, un error de traducción que a menudo se ignora en las evaluaciones de calidad, especialmente en las automáticas.

Como ha destacado Sánchez-Gijón (2022) en su una reflexión sobre la lengua generada por la TA neuronal, su calidad ha mejorado significativamente tanto en términos de precisión como de fluidez. No obstante, enfocarse solamente en estos aspectos para evaluar la calidad de una traducción no es prudente. El poseditor debe esforzarse por adaptar la traducción a la naturalidad y las condiciones comunicativas de la lengua meta, mientras que el traductor debe tomar la decisión de traducción más adecuada en consecuencia.

3. Metodología

En la sección metodológica, se expondrán los instrumentos de investigación empleados en este estudio, que incluyen Google Translate, DeepL, ChatGPT-3.5 y TAUS DQF. A continuación, se presentará la forma para obtener traducciones al chino mediante Google Translate, DeepL y ChatGPT-3.5, así como el método de análisis cualitativo implementado en la investigación principal. Adicionalmente, se describirán el contenido y los hallazgos del estudio exploratorio, cuyo propósito es relacionar la reflexión teórica acerca de los errores de traducción y la clasificación de errores desarrollada por TAUS para la evaluación práctica, garantizando que no existan contradicciones y que ambas perspectivas puedan ser empleadas en el presente estudio.

3.1 Instrumentos de la investigación

3.1.1 Corpus de texto

Debido a las limitaciones inherentes de este estudio y la necesidad de definir claramente las áreas textuales analizadas para garantizar la exactitud y validez de los resultados, en este estudio, se ha seleccionado un reportaje interpretativo (Ghignoli & Ortiz, 2014) de la sección internacional del prestigioso diario español *El País*, con una extensión de 1299 palabras. En dicho reportaje, se aborda una polémica política recientemente implementada por el Gobierno chino ante la creciente crisis demográfica, la cual permite el registro en el censo de hogares y el acceso a diversos servicios sociales a los niños nacidos fuera del matrimonio. La medida ha generado gran controversia en China, con algunos que la consideran una medida desesperada del gobierno ante la agudización de la crisis demográfica, mientras que otros la critican por no ser ética y fomentar la infidelidad conyugal.

3.1.2 Recursos tecnológicos

- Google Translate y DeepL

En 2006, Google Translate se lanzó y diez años después, en 2016, Google Translate oficialmente adoptó la tecnología de redes neuronales para el par de idiomas inglés-

latino, y la extendió con éxito a todos los idiomas en marzo de 2017. Debido a los vastos recursos de corpus propios de Google, se cree que GNMT (Google Neural Machine Translation) está bien entrenado, lo que lo convierte en uno de los sistemas de TA neuronal más utilizados en la actualidad.

En cuanto a DeepL, se ha discutido en el marco teórico anterior. Sin embargo, es importante destacar que, aunque se trata de la misma tecnología de traducción automática neural que Google Translate, no ofrecen el mismo nivel de interacción con el usuario. Google Translate únicamente puede ofrecer una alternativa si el usuario no se encuentra satisfecho con el resultado de la traducción. Por otro lado, DeepL permite la sustitución de todos los componentes de la traducción y genera automáticamente una nueva traducción que coincide con las opciones de sustitución según el algoritmo. Además, DeepL ayuda a los usuarios a crear un glosario de términos que se adapte a sus necesidades específicas, así como a establecer el tono formal o informal de la lengua de destino. DeepL también proporciona un diccionario de traducción en línea, *Linguee*, que ayuda a los usuarios a consultar el significado de las palabras en cualquier momento. Aunque estas funciones no están disponibles en todos los pares de idiomas, demuestran que DeepL es mucho más interactivo con los usuarios que Google Translate.

- ChatGPT-3.5

ChatGPT también posee capacidades de traducción comparables a las de los sistemas de TA neuronal comerciales (Jiao *et al*. 2023). En el presente estudio, emplearemos una serie de *prompts* para guiar a ChatGPT-3.5 en la tarea de traducir completamente un reportaje interpretativo del español al chino. Además, durante el proceso de posedición, evaluaremos si ChatGPT-3.5 es capaz de proporcionar sugerencias útiles de posedición al traductor a través de un *prompt* específico. Los prompts planificados que se espera utilizar son los siguientes:

Para traducir	Por favor, traduce el titular / la entrada de periódico en español al chino, teniendo en cuenta el estilo lingüístico del periódico chino al hacerlo.
	Por favor, traduce al chino un artículo periodístico en español, teniendo en cuenta el estilo lingüístico del periódico chino al hacerlo. Te enviaré el contenido párrafo a párrafo en secuencia, así que ten cuidado de captar el contexto entre párrafos al traducir.
Para proporcionar los consejos de PE	«…», este es un resultado generado por «…», el texto correspondiente en el idioma de origen es «...». ¿Puedes proporcionar algunas sugerencias para la posedición?

Tabla 6. Los *prompts* planificados para emplear

Cabe enfatizar que los *prompts* presentados en la Tabla 6, los cuales solicitan recomendaciones de posedición por parte de ChatGPT, no son exclusivos. La interacción con un modelo de lenguaje de inteligencia artificial ostenta una gran flexibilidad, por lo que la aplicación de prompts fijos no resulta ni realista ni adecuada.

- Herramienta de análisis auxiliar externa: TAUS DQF

En 2012, TAUS desarrolló el DQF (*Dynamic Quality Framework*) con el objetivo de abordar la cuestión de los criterios de evaluación de la calidad de la traducción, que sigue siendo un tema controvertido en todo el sector de la traducción. A diferencia de los criterios estáticos de evaluación de la calidad de la traducción, como el SAEJ2450, este marco se basa en la idea de que el tipo de evaluación seleccionado debe ajustarse de manera flexible y dinámica al tipo de contenido, propósito y contexto comunicativo de la traducción en cuestión (Görög, 2014, p. 155). El DQF combina el propio modelo

de evaluación de TAUS con el MQM para crear una norma dinámica de evaluación de la calidad de la traducción que varía según el tipo de contenido, propósito y destinatario (Görög, 2014). Actualmente, el DQF se considera una herramienta integral para analizar el rendimiento de la traducción (Panić, 2020).

- **Formas de obtener resultados de traducción automática**

En efecto, la calidad de la TA se ve afectada por el texto de origen, y si el texto de origen no contiene suficiente información contextual, el rendimiento del traductor automático puede verse reducido (Nitzke & Hansen-Schirra, 2021). Por lo tanto, en este estudio se tuvo que considerar la forma en que se ingresó el texto fuente.

En este sentido, para lograr la mayor precisión posible en la comprensión del contexto del texto de origen, se proporcionó un texto completo como entrada al emplear Google Translate y DeepL (el límite de entrada del idioma de origen de Google Translate y DeepL Free es de 5000 palabras). Por el contrario, al utilizar ChatGPT-3.5, se empleó el método de ingreso párrafo por párrafo para evitar interrupciones en la traducción debido al límite superior de palabras por respuesta. Es necesario mencionar que, incluso después de recibir el prompt de «continuar», ChatGPT-3.5 puede cambiar su enfoque de respuesta a otros aspectos, en lugar de centrarse exclusivamente en la traducción del texto. Con el fin de que ChatGPT-3.5 capture la mayor cantidad de información contextual posible, se indicó en los prompts la relación de contexto entre párrafos.

3.2 Proceso de la investigación: análisis cualitativo

En la presente investigación, se han adoptado los criterios de tipología de errores del TAUS DQF para efectuar un análisis cualitativo de precisión, fluidez, terminología y *verity* en las traducciones generadas por Google Translate, DeepL y ChatGPT-3.5. El evaluador de los errores de traducción ha sido el suscrito, Lai Haohong, autor de este trabajo académico.

En primer lugar, se empleó la plataforma DQF para identificar de forma detallada los segmentos de texto que contenían errores de traducción, a fin de obtener los informes de evaluación de las traducciones generadas por Google Translate, DeepL y ChatGPT-3.5. Basándose en estos informes, se analizaron los segmentos con errores de traducción y se resumieron las características de los errores en términos de precisión, fluidez, terminología y *verity.* Posteriormente, se llevó a cabo el proceso de posedición. La representación visual del proceso de investigación se exhibe en la Figura 7:

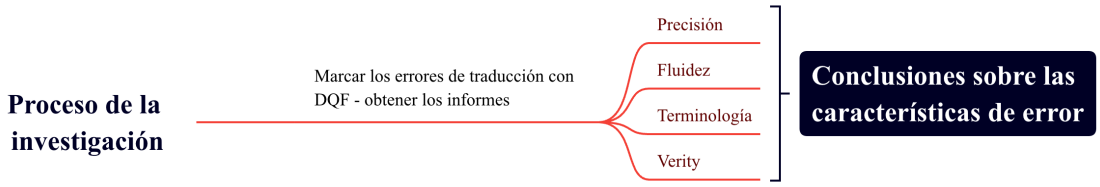

Figura 7. Proceso de la investigación

3.3 Estudio exploratorio sin posedición

El propósito de este estudio exploratorio es relacionar la reflexión teórica acerca de los errores de traducción y la clasificación de errores desarrollada por TAUS para la evaluación práctica, garantizando que no existan contradicciones y que ambas perspectivas puedan ser empleadas en el presente estudio. El texto original de prensa fue dividido en 40 segmentos que sumaron un total de 1299 palabras. Este estudio exploratorio se emplea la plataforma DQF para llevar a cabo un análisis comparativo. Esta plataforma proporciona al evaluador, Lai Haohong, la capacidad de analizar en paralelo las traducciones generadas por distintos motores de traducción.

- Ejemplo representativo 1

Segmento de origen	Cada vez son más las jóvenes que rechazan el matrimonio y la maternidad, por diversos motivos. En el caso de Jiang, que estudió en el extranjero, porque prioriza su carrera y “felicidad personal”.

Google Translate	出于各种原因，越来越多的年轻女性拒绝结婚和生育。就海外留学的蒋来说，因为他把事业和“个人幸福”放在首位。
DeepL	越来越多的年轻女性出于各种原因拒绝结婚和做母亲。就出国留学的姜女士而言，这是因为她把自己的事业和〝个人幸福〞放在首位。
ChatGPT-3.5	越来越多的年轻女性出于各种原因拒绝结婚和生育。对于姜来说，她出于对事业和“个人幸福”的优先考虑，尤其是她在海外留学后。

En el Ejemplo representativo 1, se detectaron fallos en la transferencia del contenido original tanto en Google Translate como en ChatGPT-3.5. Las dos sentencias del segmento original mantienen una profunda conexión contextual: en primer lugar, se declara que «cada vez son más jóvenes que rechazan el matrimonio y la maternidad», seguido por el caso Jiang, quien opta por no casarse ni tener descendencia debido a su priorización de la carrera profesional y la felicidad personal. No obstante, las traducciones proporcionadas por Google Translate y ChatGPT-3.5 resultan complicadas de interpretar para los lectores, dado que no reflejan con claridad la dicha vinculación entre ambas sentencias del texto fuente. Además, ChatGPT-3.5 comete un error en la traducción de «que estudió en el extranjero» como *youqi shi zaita haiwai liuxue hou* (尤其她在海外留学后), lo que transmite incorrectamente la idea de que la decisión de Jiang de no casarse ni tener hijos se ha fortalecido tras su experiencia de estudios en el extranjero. Por otro lado, DeepL efectúa una adecuada transferencia del contenido.

A partir de este ejemplo, se observaron errores de transferencia que afectan la comprensión del texto original por parte de los lectores, correspondientes a la precisión (Mistranslation, en concreto) en el marco de errores TAUS.

- Ejemplo representativo 2

Segmento de origen	Aunque el Gobierno central lleva varios años anunciando políticas preferenciales para animar a la población a tener más hijos, paradójicamente, no todas las mujeres que dan a luz cumplen con los parámetros establecidos formalmente.
Google Translate	尽管中央政府多年来一直在出台优惠政策以鼓励人口生育更多孩子，但矛盾的是，并非所有生育的妇女都符合正式规定的参数。
DeepL	尽管中央政府几年来一直宣布鼓励人们多生孩子的优惠政策，但矛盾的是，并非所有生育的妇女都符合正式规定的参数。
ChatGPT-3.5	尽管中央政府已经数年来宣布了优惠政策以鼓励人们生育更多的孩子，但讽刺的是，并非所有生育孩子的女性都符合正式设定的参数。

En el Ejemplo representativo 2, se detectaron errores compartidos en las traducciones proporcionadas por Google Translate, DeepL y ChatGPT. Primero, todos ellos traducen «parámetro» como *canshu* (参数), pero en realidad «parámetro» está vinculado con las «políticas preferenciales» mencionadas anteriormente. En el idioma chino, «política» y «parámetro» no guardan relación, aunque los lectores podrían llegar a entender el sentido de *fuhe zhengshi shedin de canshu* (符合正式设定的参数). Adicionalmente, tanto DeepL como ChatGPT-3.5 traducen «anunciar políticas» como *xuanbu zhengce* (宣布政策) en el texto de destino, lo cual, aunque puede ser comprendido por los hablantes nativos de chino, no se expresa de esa forma en el idioma chino. Estos errores previamente citados son categorizados como errores de redacción en el texto meta, correspondiendo al estándar de precisión en el marco de errores de TAUS.

- Ejemplo representativo 3

Segmento de origen	Aunque el Gobierno central lleva varios años anunciando políticas preferenciales para animar a la población a tener más

	hijos, paradójicamente, no todas las mujeres que dan a luz cumplen con los parámetros establecidos formalmente.
ChatGPT-3.5	尽管中央政府已经数年来宣布了优惠政策以鼓励人们生育更多的孩子，但讽刺的是，并非所有生育孩子的女性都符合正式设定的参数。

No obstante, también identificamos un error gramatical en la redacción de la traducción aportada por ChatGPT-3.5, donde se indica *jinguan zhongyang zhengfu yijing shunianlai xuanbule* (尽管中央政府已经数年来宣布了), que constituye un error de fluidez en el texto meta, de acuerdo con los estándares de TAUS.

- Ejemplo representativo 4

Segmento de origen	También en 2021, el Consejo de Estado –el Ejecutivo– se marcó la meta de reducir el número de interrupciones del embarazo que no se deban a una “necesidad médica”.
Google Translate	同样在 2021 年，国务委员会——行政部门——为自己设定了减少非“医疗必要性”中断妊娠次数的目标。
DeepL	同样在 2021 年，国务委员会--行政部门--为自己设定的目标是减少非因“医疗需要”而终止妊娠的数量。
ChatGPT-3.5	同样在 2021 年，国务院制定了减少非医疗需求的流产数量的目标。

Es manifiesto que la traducción en Ejemplo representativo 4 está íntimamente vinculada al conocimiento sociocultural inherente al idioma chino, dado que «Consejo de Estado» posee una denominación específica dentro del sistema sociocultural de China. De acuerdo con la definición de Hurtado acerca de cuestiones «extralingüísticas», estas se refieren a aspectos temáticos, culturales o enciclopédicos (2001, p. 288). Por consiguiente, se puede establecer que los errores de traducción relacionados con este tipo de nombres propios de una cultura se pertenecen a errores de transferencia y se

asocian a *verity*, según el estándar de TAUS. En este ejemplo de traducción, Google y DeepL procesaron incorrectamente el nombre propio político «Consejo de Estado» como *guowu weiyuanhui* (国务委员会). Sin embargo, en China, el Consejo de Estado se conoce como *guowuyuan* (国务院).

- Ejemplo representativo 5

Segmento de origen	Tina Jiang (nombre ficticio)
Google Translate	30 岁的 Tina Jiang（化名）
DeepL	30 岁的 Tina Jiang（不是她的真名）
ChatGPT-3.5	30 岁的蒂娜·姜（化名）

En el presente estudio exploratorio se ha descubierto que los nombres de personas escritos en forma *pinyin*, que no se adhieren a las reglas chinas de nomenclatura (apellido primero, nombre después), no pueden ser traducidos correctamente por sistemas de TA neuronal y modelos de lenguaje de IA. La regla de nomenclatura está intrínsecamente ligado a las referencias culturales del idioma de destino, lo que conlleva a errores de transferencia asociados a *verity*, tal y como se define en el estándar TAUS.

- Ejemplo representativo 6

Segmento de origen	El reconocimiento de bebés fuera del matrimonio se abre paso en una China inmersa en una grave crisis demográfica
Google Translate	在陷入严重人口危机的中国，对非婚生婴儿的认可
DeepL	在严重的人口危机中，非婚生子女的认可在中国取得了进展
ChatGPT-3.5	婚外生育儿的认可在陷入严重人口危机的中国逐渐普及

En el Ejemplo representativo 6, los tres motores de traducción generaron traducciones diversas para el término «bebés fuera del matrimonio». La traducción aportada por Google Translate es la menos precisa, ya que su traducción *fei hunsheng yinger* (非婚

生婴儿) limita el concepto de «bebés fuera del matrimonio» únicamente a los recién nacidos, mientras que la traducción de ChatGPT-3.5, *hunwai shengyuer* (婚外生育儿), es una expresión sumamente poco habitual. Es evidente que los errores terminológicos se manifiestan principalmente en el uso inapropiado del vocabulario en el idioma objetivo, lo cual se considera un error de redacción en el texto meta, y se clasificaría como un error de precisión de acuerdo con el estándar de TAUS.

Mediante el análisis de seis ejemplos representativos de traducción, se puede establecer una conexión orgánica entre la reflexión teórica sobre la noción de error de traducción desde una perspectiva basada en la investigación de la traducción automática, propuesta en el marco teórico, y la tipificación de errores de TAUS utilizada en la práctica evaluativa de esta investigación, tal como se ilustra en la Tabla 7.

	Errores en la transferencia entre el texto original y el meta	Errores de la redacción en el texto meta	Errores pragmáticos
Precisión	Ej. 1	Ej. 2	
Fluidez		Ej. 3	
Terminología		Ej. 6	
Verity	Ej. 4; Ej. 5		

Tabla 7. La relación entre la reflexión teórica sobre error de traducción y la tipificación de errores de TAUS

En conclusión, a través de este estudio exploratorio se ha evidenciado de manera preliminar que la reflexión teórica sobre los errores de traducción propuesta en el marco teórico no entra en contradicción con la tipificación de errores de TAUS. Los errores de transferencia pueden ser correspondientes a las categorías de precisión y *verity*, mientras que los errores de redacción en el texto meta pueden asociarse a las categorías

de precisión, fluidez y terminología. Finalmente, dado que las normas para la denominación de nombres propios suelen ser convencionales, los errores asociados con estos nombres se clasifican como errores pragmáticos y están vinculados con *verity*.

4. Análisis de las características de error y su posedición

	Google Translate	DeepL	ChatGPT-3.5
Precisión	26	10	11
Fluidez	20	8	12
Terminología	3	2	2
Verity	4	4	4
Suma Total	53	23	29

Tabla 8. Números de errores de traducción

La Tabla 8 presenta la cantidad de errores detectados en las dimensiones de precisión, fluidez, terminología y *verity* en las traducciones al chino proporcionadas por los tres motores de traducción, marcados a través del uso de DQF. Resulta manifiesto que Google Translate exhibe la mayor cantidad de errores, mientras que DeepL se distingue por la menor cantidad de estos.

TAUS DQF permite marcar los errores con mayor detalle y no se limita a contar el número de cada tipo de error. En primer lugar, en cuanto a la calidad global de la traducción, DQF utiliza la fluidez y la precisión para evaluarla. La fluidez se clasifica en cuatro puntuaciones: *impecable* (el texto meta no tiene errores de fluidez), *buena* (el texto meta tiene algunos errores de fluidez, pero no afectan la comprensión del texto por parte del hablante nativo o tienen un impacto menor), disfluente (el texto meta no es fluido y afecta la comprensión del texto por parte del hablante nativo) e *incomprensible* (el texto meta es tan disfluente que es casi incomprensible para los hablantes nativos).

La precisión también se valora en cuatro puntuaciones: *todo* (todo el texto original se traduce correcta y adecuadamente, ni más ni menos), *mayoría* (la mayor parte del texto original se traduce correcta y adecuadamente), *poco* (solo una pequeña parte del texto original se traduce correcta y adecuadamente) y *nada* (nada del texto original se traduce

correcta y adecuadamente). Por supuesto, DQF también especifica los tipos de errores de bajo nivel relacionados con la precisión y la fluidez. Todos los tipos de errores que se analizarán en este estudio para el texto periodístico se indican explícitamente en la sección de marco teórico[13].

Con el fin de brindar mayor objetividad a las cuatro puntuaciones de fluidez y precisión, un error normalmente implicaría que la calificación se bajaría en un nivel. Por ejemplo, si se encuentra un error de fluidez y un error de precisión en un segmento del texto meta proporcionado por Google Translate, la calificación de fluidez para esta traducción sería «buena» y la calificación de precisión sería «mayoría». Sin embargo, si un error de fluidez o precisión es muy grave, por ejemplo, si afecta seriamente a la comprensión de toda la frase, entonces la puntuación se reducirá aún más.

4.1 Precisión

En el presente estudio se ha observado que los resultados obtenidos por Google Translate son los más preocupantes. De los 40 segmentos analizados, únicamente 19 fueron considerados como «todo» del texto original. La información estadística correspondiente a estos resultados se presenta en la Figura 8.

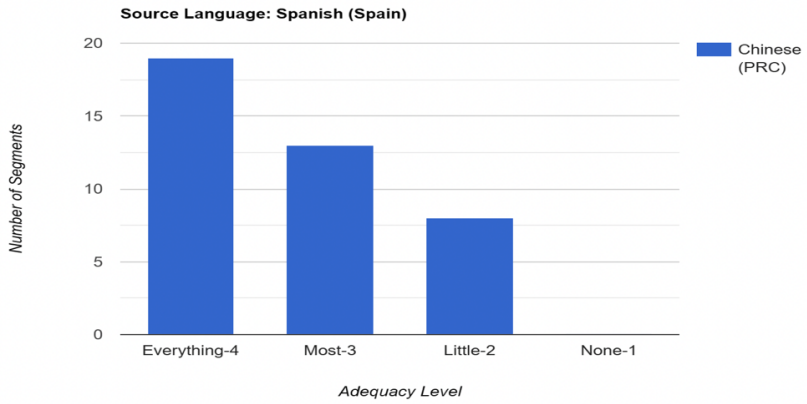

Figura 8. Rendimiento en la precisión de Google Translate

[13] Véase el Marco teórico (la Tabla 5 de las páginas 43-45) para los tipos de errores que se deben analizar.

DeepL proporcionó los resultados de traducción más exactos, con 31 de los 40 segmentos calificados como traducciones integrales de la información contenida en la frase original. Los 9 segmentos restantes obtuvieron la misma puntuación. Asimismo, se consideró que 31 de las traducciones de ChatGPT-3.5 habían representado de manera completa toda la información del texto original, pero la precisión de los 9 segmentos restantes resultó ser cuestionable. Las estadísticas correspondientes se presentan en la Figura 9.

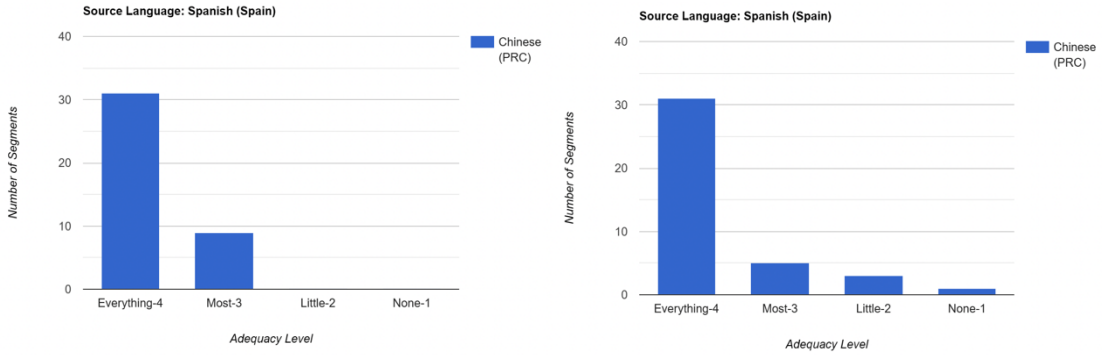

Figura 9. Rendimiento en la precisión de DeepL y ChatGPT-3.5

De acuerdo con los datos sobre los errores de traducción en el aspecto de la precisión, se podría concluir las características siguientes:

1) Transferencia incorrecta de elementos lingüísticos o contexto del texto original

Ejemplo 1

Segmento de origen	Sichuan, la quinta provincia más poblada del país, permitirá a todas las personas, independientemente de su estado civil, registrar cuantos hijos tengan.
Google Translate (Error de la transferencia)	中国第五大人口大省四川将允许每个人，无论婚姻状况如何，都可以登记他们有多少孩子。
DeepL	全国第五大人口大省四川将允许所有人，无论其婚姻状况如何，都可以登记他们所拥有的孩子。

ChatGPT-3.5 (Error de la transferencia)	四川是中国人口第五大省，将允许所有人，无论其婚姻状况如何，登记他们的孩子数量。

En el Ejemplo 1, tanto Google Translate como ChatGPT-3.5 no transfieren correctamente el significado de la estructura que está guiada por el pronombre relativo «cuantos» en este contexto. Ambas traducciones se centran en el reconocimiento de la información cuantitativa proporcionada por «cuantos», pero la expresión original «cuantos hijos tengan» pretende significar «los hijos que tengan», en lugar de *dengji tamen you duoshao haizi* (登记他们有多少孩子), como se traduce en Google Translate y *dengji tamen de haizi shuliang* (登记他们的孩子数量), 'registrar la cantidad de hijos que tienen' en ChatGPT-3.5. Solamente la traducción proporcionada por DeepL es una representación correcta del texto original.

- El resultado de la posedición

中国第五大人口大省四川将允许所有人**登记他们所拥有的孩子**，无论其婚姻状况如何。

La traducción de frases largas y complejas ha sido siempre un gran desafío para la TA neuronal (Toral & Sánchez-Cartagena, 2017). Esto puede no solo afectar la precisión de la traducción, sino también otros aspectos como la fluidez del texto traducido y otros errores.

Ejemplo 2

Segmento de origen	El Gobierno promueve desde 2021 políticas preferenciales de acceso a la vivienda, mayor flexibilidad laboral o ayudas fiscales y a la educación con el objetivo de "crear un entorno favorable al matrimonio y la fertilidad" y animar a las parejas casadas a tener hasta tres hijos.

Google Translate (Error de la transferencia)	自 2021 年以来，政府一直在推动住房、更大的劳动力灵活性或税收援助和教育方面的优惠政策，旨在“创造良好的婚姻和生育环境”，并鼓励已婚夫妇最多生育三个孩子。
DeepL (Error de la transferencia)	自 2021 年以来，政府一直在推动获得住房的优惠政策、更大的劳动灵活性以及税收和教育补贴，目的是 "为婚姻和生育创造有利的环境"，并鼓励已婚夫妇最多生育三个孩子。
ChatGPT-3.5 (Error de la transferencia)	政府自 2021 年开始推广优惠政策，例如住房和税收优惠、更加灵活的就业市场以及教育援助，旨在“创造一个有利于婚姻和生育的环境”，并鼓励已婚夫妇生育至多三个孩子。

El Ejemplo 3 es representativo de una oración larga y compleja en español, con múltiples elementos de oración entrelazados, lo que resulta en tres motores de TA neuronal que producen resultados casi completamente diferentes basados en sus propias estrategias de traducción y técnicas. Lamentablemente, ninguno de los motores de traducción logra una traducción completamente correcta. La traducción relativamente más precisa es la de DeepL, pero aun así presenta errores en la colocación léxica. Al descomponer el texto fuente, se puede apreciar que el gobierno ha implementado cuatro medidas para «crear un entorno favorable para el matrimonio y la fertilidad», como se muestra en el diagrama lógico de la Figura 10.

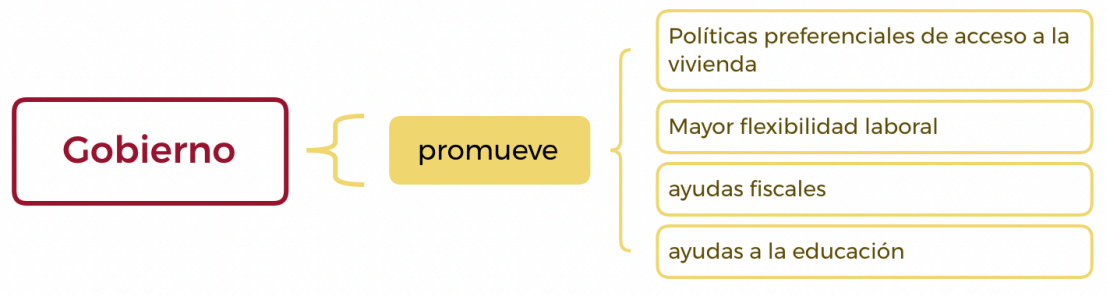

Figura 10. El desglose de los elementos en el segmento

Según la Figura 10, se deduce que las medidas implementadas son promover: «políticas preferenciales para el acceso a la vivienda», «una mayor flexibilidad laboral», «la ayuda fiscal» y «la ayuda educativa» para los niños. En español, por un lado, es posible usar solamente el verbo «promover», pero en chino es claramente insuficiente para transmitir la información semántica. Por otro lado, en la traducción es importante capturar con precisión la correspondencia entre el predicado y el objeto en el español original, de lo contrario, la lógica de la traducción podría resultar confusa.

- El resultado de la posedición

政府自 2021 年以来就一直在**出台住房方面的优惠政策**、**鼓励灵活就业**、**加大财政补贴和教育帮扶力度**，其目的是“为结婚和生育创造一个良好的环境”，并鼓励已婚夫妇生育最多三个孩子。

Ejemplo 3

Segmento de origen	La nueva norma, que estará en vigor durante cinco años, otorga un carácter más inclusivo a la existente desde 2019, bajo la cual solamente las parejas casadas podían registrar hasta dos retoños.
Google Translate (Error de la transferencia)	新规范将生效五年，它比 2019 年以来的规范更具包容性，根据该规范，只有已婚夫妇最多可以登记两个子女。
DeepL (Error de la transferencia)	这项新规定将实施五年，比自 2019 年以来实施的规定更具包容性，根据该规定，只有已婚夫妇可以登记最多两个孩子。
ChatGPT-3.5	新规定将在五年内有效，它对于 2019 年已有的规定进行了更为包容性的补充，2019 年的规定仅允许已婚夫妇登记两个孩子。

La incorrecta transferencia del texto original también se refleja en el contexto. En el

Ejemplo 2, el texto fuente afirma que «la nueva norma, que tendrá una vigencia de cinco años, es más inclusiva que la antigua norma en vigor desde 2019, que solo permitía a las parejas casadas tener dos hijos». Sin embargo, tanto Google Translate como DeepL no transfieren correctamente el contexto, traduciendo incorrectamente «bajo la cual» como *genju gai guidin* (根据该规定). Esto conduce directamente a una grave ambigüedad, que imposibilita al lector saber si *gai guidin* (该规定) se refiere a la antigua normativa vigente desde 2019 o a la nueva que entra en vigor este año. En este caso, la traducción proporcionada por ChatGPT-3.5 es la más precisa, ya que establece claramente que «bajo la cual» se refiere a *er lin yi jiu nian de guidin* (2019 年的规定).

- El resultado de la posedición

将实施 5 年的新规定比自 2019 年以来实施的旧规定更具包容性，**2019 年的规定**仅允许已婚的夫妇登记最多两个孩子。

2) Confusión en la equivalencia de palabras.

Es sabido que tanto en chino como en español existen palabras con diferentes significados, lo que en lingüística se conoce como «polisemia». Encontrar la equivalencia requiere que el traductor o la traductora comprenda con precisión el contexto del texto en la lengua de origen o destino. Después de un análisis específico de errores, se descubrió que en las traducciones del chino aportadas por la TA neuronal y el modelo de lenguaje de IA hay un gran número de errores en la equivalencia de palabras.

Ejemplo 4

Segmento de origen	Aunque el Gobierno central lleva varios años anunciando políticas preferenciales para animar a la población a tener más hijos, paradójicamente, no todas las mujeres que dan a luz cumplen con los parámetros establecidos formalmente.

Google Translate (Error de la redacción en el texto meta)	尽管中央政府多年来一直在出台优惠政策以鼓励人口生育更多孩子，但矛盾的是，并非所有生育的妇女都符合正式规定的参数。
DeepL (Error de la redacción en el texto meta)	尽管中央政府几年来一直宣布鼓励人们多生孩子的优惠政策，但矛盾的是，并非所有生育的妇女都符合正式规定的参数。
ChatGPT-3.5 (Error de la redacción en el texto meta)	尽管中央政府已经数年来宣布了优惠政策以鼓励人们生育更多的孩子，但讽刺的是，并非所有生育孩子的女性都符合正式设定的参数。

En el Ejemplo 4, se enfocó en el error de identificación de la equivalencia de la palabra «parámetro». Conforme al Diccionario de la Real Academia de la Lengua Española (DLE)[14], se establecen las siguientes acepciones en español.

Palabra	Acepciones del español[15]	Acepciones del chino[16]
parámetro	1. m. Dato o factor que se toma como necesario para analizar o valorar una situación.	1. *Yinsu* (因素)
		2. *Yuanze* (原则)
		3. *Biaozhun* (标准)

[14] Consultar más información: https://www.rae.es/

[15] las acepciones proceden de: https://dle.rae.es/par%C3%A1metro

[16] las acepciones proceden de: https://www.esdict.cn/dicts/es/par%C3%A1metro

	2. m. Mat. Variable que, en una familia de elementos, sirve para identificar cada uno de ellos mediante su valor numérico.	4. *Canshu* (参数)

El DLE establece que *canshu* (参数) es una acepción empleada en el ámbito de las matemáticas, aunque su uso no se encuentra restringido exclusivamente a esta área. No obstante, en el contexto del Ejemplo 4, el término «parámetros» se relaciona con «políticas preferenciales», por lo que el uso de *canshu* (参数) resulta necesariamente inapropiado. En este sentido, en este contexto específico, se debería seleccionar la acepción *biaozhun* (标准) para alcanzar la equivalencia.

- El resultado de posedición

尽管中央政府多年来一直在出台优惠政策以鼓励人们生育更多孩子，但矛盾的是，并非所有生了孩子的妇女都符合优惠政策规定的**标准**。

El anterior ejemplo ilustra principalmente las fallas del sistema de TA neuronal y el modelo de lenguaje en la búsqueda de la equivalencia de palabras a nivel del idioma objetivo. No obstante, en el presente estudio, se ha evidenciado otro fenómeno adicional que merece ser destacado. En español, es común recurrir a diversas locuciones para aludir a un mismo concepto, con el objetivo de evitar la reiteración de términos y expandir el repertorio léxico. Por caso, en los artículos periodísticos, la referencia a *zhongguo* (中国) no se circunscribe únicamente a «China», sino que se utilizan sustituciones frecuentes como «el gigante asiático», «la segunda economía del mundo», entre otros.

Sin embargo, en chino, a pesar de que puede presentarse una situación similar (generalmente cuando el autor del texto pretende exhibir sus habilidades literarias), este

patrón lingüístico no es la norma. La repetición de palabras, vista con recelo en español, es menos reprochable en chino, y un exceso de sustituciones incluso puede afectar la precisión del mensaje.

Ejemplo 5

Segmento de origen	El paso se toma en medio del desplome histórico en la tasa de natalidad que enfrenta el gigante asiático
Google Translate (Error de la redacción en el texto meta)	此举是在这个亚洲巨人面临出生率历史性崩溃的情况下进行的
ChatGPT-3.5 (Error de la redacción en el texto meta)	在亚洲巨人国家面临历史性的出生率下降之际，四川省采取了这一措施

Segmento de origen	De hecho, las estimaciones más recientes predicen que el gigante asiático cederá este año el primer puesto como la nación más poblada del planeta a India.
DeepL (Error de la redacción en el texto meta)	事实上，根据最新的估计，这个亚洲巨人今年将把世界上人口最多的国家的位置让给印度。

Como se ilustra en el Ejemplo 5, los tres motores de TA neuronal que hemos empleado traducen la expresión «gigante asiático» de manera literal como *yazhou juren* (亚洲巨人), lo cual indudablemente impactará en la comprensión de los hablantes nativos de chino. Si bien ChatGPT-3.5 logra procesar con éxito esta divergencia léxica en ciertos segmentos, desafortunadamente no consigue evitar del todo este tipo de imprecisiones.

Asimismo, tanto Google Translate como DeepL y ChatGPT-3.5 traducen literalmente la expresión «la segunda economía más grande del mundo» como *shijie dierda jingjiti* (世界第二大经济体), en vez de recurrir a *zhongguo* (中国).

- Los resultados de posedición

此举是在**中国**面临出生率历史性下降的背景下采取的。
事实上，根据最新的估计，**中国**今年将让位于印度，不再是世界上人口最多的国家。

4.2 Fluidez

- Errores gramaticales en abundancia.

Ejemplo 6

Segmento de origen	Sichuan, hogar de casi 84 millones de habitantes, se sumó a esa lista esta semana, acabando con la implementación de una normativa que...
Google Translate (Error de la redacción en el texto meta)	拥有近 8400 万人口的四川本周加入了该名单，结束了一项法规的实施...
DeepL (Error de la redacción en el texto meta)	拥有近 8400 万人口的四川本周加入了这一名单，结束了一项法规的实施...
ChatGPT-3.5 (Error de la redacción en el texto meta)	本周，人口将近 8400 万的四川也加入了这一名单，结束了一个...规定。

De acuerdo con el contexto establecido en el segmento original, se sugiere que el sujeto

tanto de «se sumó a esa lista» como de «acabando con la implementación de una normativa» debería ser *sichuan* (四川). No obstante, en el Ejemplo 6, ninguna de las traducciones facilitadas por los tres motores de traducción especifica el sujeto de «acabar», lo cual genera un error gramatical de sujeto indeterminado en el idioma chino. Los errores gramaticales son relativamente comunes en los vinculados a la fluidez.

- El resultado de posedición

四川，这个拥有近 8400 万居民的省份，本周通过结束一项在法律上不承认非传统家庭（非一男一女婚姻）出生的子女的规定，也加入了这一（开放子女登记限制的）名单。

Conforme a la información presentada en la Tabla 6 (consultar página 58), se observa que las traducciones generadas por Google Translate contienen 20 errores de fluidez, mientras que las producidas por ChatGPT-3.5 y DeepL presentan 12 y 8 respectivamente. Dentro de esta categoría de errores, aquellos de naturaleza gramatical constituyen la proporción más significativa.

Motor de traducción	Número de error gramatical	Porcentaje
Google Translate	11/20	55%
DeepL	4/8	50%
ChatGPT-3.5	5/12	41.6%

Tabla 9. Número y porcentaje de errores gramaticales

De este análisis, se puede inferir que, debido probablemente a la marcada discrepancia entre la gramática china y la española, los sistemas de TA neuronal no pueden procesar de manera eficiente las transformaciones gramaticales que se requieren en el proceso de traducción. Esta situación exige a los poseditores o poseditoras realizar esfuerzos adicionales para corregir dichas inconsistencias gramaticales. Por otro lado, la calidad en términos de fluidez varía considerablemente entre los distintos sistemas. Los

resultados indican que, al emplear Google Translate para traducir textos del español al chino, se generan numerosos errores que afectan la fluidez del texto traducido.

4.3 Terminología

- Incongruencias en la aplicación de términos entre diferentes contextos

Este estudio ha revelado incongruencias en la aplicación de términos específicos entre diferentes contextos durante el procesamiento a través de la TA neuronal y el modelo de lengua de IA. Tomando como ilustración los sistemas de Google Translate, DeepL y ChatGPT-3.5, se encontró que traducen correctamente el término «la planificación familiar» como *jihua shengyu* (计划生育) en algunas secciones del texto meta que generan. Sin embargo, emergen discrepancias en la traducción cuando el término «la planificación familiar» aparece en otras partes del texto, tal y como se evidencia en el Ejemplo 7.

Ejemplo 7

Segmento de origen	las políticas estatales establecen que la planificación familiar es un deber “de maridos y esposas juntos”.
ChatGPT-3.5 (Error de la redacción en el texto meta)	但国家政策规定，生育计划是“夫妻共同的责任”。

Segmento de origen	las políticas estatales establecen que la planificación familiar es un deber “de maridos y esposas juntos”. [...]. Las normas hacia los hijos “no planificados” ...
Google Translate (Error de la redacción en el texto meta)	但是，国家政策规定计划生育是“夫妻共同”的义务...。对“计划外”孩子的规定...

DeepL (Error de la redacción en el texto meta)	但是，国家政策规定，计划生育是“夫妻共同”的义务...。对“计划外”孩子的规定...

Otra observación notable concierne a la traducción de «covid-19». Google Translate y DeepL omiten su traducción al correspondiente término chino, *xinguan feiyan* (新冠肺炎), mientras que ChatGPT-3.5 efectivamente realiza dicha traducción. En situaciones en las que existen términos equivalentes en el idioma de destino, se aconseja llevar a cabo una traducción íntegra a la lengua de llegada, en lugar de recurrir a la técnica *préstamo* que conserve el término original en el texto meta.

Ejemplo 8

Segmento de origen	También menciona los elevadísimos costes de la vida y la reducción de ingresos durante los tres años de lucha contra la covid-19.
Google Translate (Error de la redacción en el texto meta)	他还提到在与 covid-19 抗争的三年中，生活成本非常高，收入减少。
DeepL (Error de la redacción en el texto meta)	她还提到了非常高的生活成本，以及在与 covid-19 的三年斗争中收入的减少。
ChatGPT-3.5	她还提到了生活成本的高昂和在抗击新冠肺炎的三年中收入的减少。

4.4 Verity

- La traducción incorrecta de los nombres personales

Resultan particularmente interesante los errores de traducción sobre los nombres personales en los textos traducidos de TA neuronal y el modelo de lenguaje de IA. Las normas de denominación de los nombres personales en las lenguas occidentales, particularmente en las lenguas romances, comparten muchas similitudes. En contraposición, las reglas de denominación en chino (por ejemplo, la ubicación de los apellidos y los nombres) difieren considerablemente. Nuestro estudio halló que la TA neuronal y ChatGPT-3.5 era capaz de traducir correctamente los nombres personales cuando estos se presentaban escritos en *pinyin* de acuerdo con el orden chino de los nombres (primero el apellido, segundo el nombre). Tal como se evidencia en el Ejemplo 9. Aunque la autenticidad de los nombres personales aún requiere verificación.

Ejemplo 9

Segmento de origen	la demógrafa Peng Xiujiang, investigadora sénior en el Centro de Estudios Políticos de la Universidad de Victoria (Australia).
Google Translate	人口统计学家彭秀江，维多利亚大学（澳大利亚）政策研究中心高级研究员。
DeepL	人口学家、澳大利亚维多利亚大学政策研究中心高级研究员彭秀江。
ChatGPT-3.5	澳大利亚维多利亚大学政治研究中心高级研究员彭秀江。

Sin embargo, tal como se evidencia en el Ejemplo 10, cuando el autor del artículo aplica las reglas de la lengua romance para escribir los nombres, antepone el nombre en chino y sitúa el apellido a continuación, se produce una incorrecta traducción del nombre de la persona.

Ejemplo 10

Segmento de origen	Tina Jiang (nombre ficticio)
Google Translate (Error de la transferencia)	30 岁的 Tina Jiang（化名）
DeepL (Error de la transferencia)	30 岁的 Tina Jiang（不是她的真名）
ChatGPT-3.5 (Error de la transferencia)	30 岁的蒂娜·姜（化名）

Por lo tanto, concluimos que los nombres escritos sin adherirse a las convenciones de denominación del idioma de destino generan errores de traducción en la TA neuronal y ChatGPT-3.5. Recomendamos que durante la preedición, especialmente cuando el idioma de destino de la traducción sea el chino, se garantice que el nombre de la persona se redacte de acuerdo con la convención de nomenclatura del chino. Recíprocamente, durante la posedición, se deben revisar los nombres que no se encuentren escritos de acuerdo con la norma de denominación del idioma chino si sean traducidos apropiadamente.

5. Conclusiones

Con la implementación de las redes neuronales en el ámbito de la tecnología de traducción, el epicentro de la investigación en este campo ha evolucionado de la TA estadística hacia la TA neuronal. A lo largo de la última década, se han ejecutado innumerables investigaciones que buscan evidenciar que la posedición de la TA neuronal, en su papel de labor de traducción, genera una mayor calidad y es menos costosa en términos de tiempo invertido. No obstante, las propiedades singulares de la posedición para la TA neuronal han sido insuficientemente examinadas, y la reflexión respecto a las evoluciones que esta tecnología generará en el terreno de la enseñanza y el aprendizaje de la traducción, especialmente tras la introducción de ChatGPT, apenas se encuentra en su etapa inicial.

En este contexto, el presente trabajo de fin de máster se plantea como objetivo la traducción de un artículo periodístico español al chino mediante el uso de Google Translate, DeepL y ChatGPT-3.5. Adicionalmente, se contempla el análisis de las características de los errores manifestados en los resultados generados por la TA neuronal en relación con la precisión, fluidez, terminología y *verity*. Este trabajo busca aportar una referencia valiosa para la investigación de la posedición, así como para la enseñanza de la traducción en futuros trabajos académicos.

Previo al análisis formal de las características de los errores, se llevó a cabo un estudio exploratorio en el cual se constató la relación intrínseca entre la reflexión teórica desde el punto de vista de TA, basándose en la noción de error de traducción propuesta por Hurtado Albir, y la tipología de error establecida por TAUS. Esta interrelación proporciona una sólida fundación teórica para el estudio principal que busca desentrañar las características comunes de error acerca de la TA neuronal.

A continuación, tras la ejecución de un análisis de errores exhaustivo, se extraen las siguientes conclusiones acerca de las características de los errores de TA neuronal.

Con respecto a la precisión:

1) Transferencia incorrecta de elementos lingüísticos o contexto del texto original. Este estudio evidencia que la TA neuronal y el modelo de lenguaje de IA presenta deficiencias en la transferencia de estructuras lingüísticas que resultan complejas o que adquieren diversos significados dependiendo del contexto.
2) Confusión en la equivalencia léxica. Cuando una palabra en el idioma fuente presenta un fenómeno de «polisemia», es decir, posee múltiples significados, es probable que en el idioma destino también tenga una variedad de interpretaciones. Sin embargo, el texto meta proporcionado por los sistemas de TA neuronal, así como por el modelo de lenguaje ChatGPT-3.5, denota cierta confusión en lo que respecta a la equivalencia léxica. Además, los sistemas de TA neuronal y el modelo de lenguaje ChatGPT-3.5 suelen enfrentar dificultades al traducir al chino con exactitud los sinónimos empleados para enriquecer la expresión léxica en español.

Con lo que respecta a la fluidez, se destacan los errores gramaticales en chino. Este estudio constató que los errores gramaticales constituyeron aproximadamente la mitad de todos los errores de fluidez identificados, incluyendo un 55% para Google Translate, un 50% para DeepL y un 41.6% para ChatGPT-3.5.

En relación con la terminología, se observan incongruencias en la aplicación de términos entre diferentes contextos. Este estudio descubrió que, aunque el traductor automático neuronal traduce el término correctamente en una sección del texto meta, ello no garantiza que el término también se emplee de manera apropiada en otras partes del texto. Esta situación demanda que el poseditor o la poseditora mantenga su concentración a lo largo de todo el texto al revisar la terminología del texto traducido automáticamente. Cabe señalar que los sistemas de TA neuronal pueden procesar términos internacionalmente reconocidos, preservando su forma original sin traducción, como es el caso de «covid-19». No obstante, se sugiere fuertemente que, en instancias donde exista un equivalente en el idioma de destino, se priorice la posedición al idioma objetivo.

Respecto a los errores de *verity*, el estudio reveló que mantener el orden de los nombres chinos (apellido primero, nombre al final) siempre proporcionaba resultados más acertados al utilizar la TA neuronal y ChatGPT-3.5 para traducir la forma *pinyin* de los nombres chinos que aparecen en el texto en español al chino.

Por supuesto, es inevitable que este estudio presente ciertas limitaciones. En primer lugar, OpenAI publicó el documento técnico de GPT-4 el 14 de marzo (OpenAI, 2023), lo que implica que ChatGPT-3.5 ya no representa el modelo de lenguaje más avanzado. Aunque el alto costo computacional de GPT-4 limita actualmente su uso generalizado en el campo de la traducción, si GPT-4 supera las barreras técnicas y consigue finalmente una implementación a gran escala, entonces algunas características de error de su versión 3.5 analizadas en este trabajo podrían dejar de ser aplicables. En segundo lugar, debido a limitaciones objetivas, este estudio selecciona únicamente un artículo periodístico como corpus, por lo que la aplicabilidad de las conclusiones obtenidas en otros ámbitos textuales requiere de una investigación más profunda.

En conclusión, el presente trabajo de fin de máster proporciona una referencia para futuras actividades de posedición (especialmente en la traducción del español al chino) a través del análisis de las características comunes de los errores en la traducción automática neuronal y el modelo de lenguaje ChatGPT. Consideramos que la interacción entre los estudiantes de traducción y los modelos lingüísticos basados en tecnología de redes neuronales, tanto en el ámbito de la traducción como en el de la posedición, podría tener un impacto significativo en la docencia de la traducción en un futuro próximo.

6. Bibliografía

Bayer Lex. (2023, febrero 28). *Introducing Q-Chat, the world's first AI tutor built with. OpenAI's ChatGPT*. Quizlet. https://quizlet.com/blog/meet-q-chat [Consultado el 05/06/2023]

3Blue1Brown—Gradient descent, how neural networks learn. (2023). https://www.3blue1brown.com/lessons/3blue1brown.com [Consultado el 01/03/2023]

Allen, Jeffrey. (2003). Post-editing. En Somers. Harold, *Computers and Translation: A translation's guide* (Vol. 35, pp. 297-318). John Benjamins Publishing. http://digital.casalini.it/9789027296696 [Consultado el 15/12/2022]

Alvarez, Sergi; Oliver, Antoni & Badia, Toni. (2019). Does NMT make a difference when post-editing closely related languages? The case of Spanish-Catalan. *Proceedings of Machine Translation Summit XVII: Translator, Project and User Tracks*, 49-56. https://aclanthology.org/W19-6708 [Consultado el 17/02/2023]

Bahdanau, Dzmitry; Cho, Kyung Hyun & Bengio, Yoshua. (2015). Neural machine translation by jointly learning to align and translate. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*. https://doi.org/10.48550/arXiv.1409.0473 [Consultado el 09/02/2023]

Barkho, Leon. (2008). THE BBC'S DISCURSIVE STRATEGY AND PRACTICES VIS-[Agrave]-VIS THE PALESTINIAN–ISRAELI CONFLICT. *Journalism Studies*, *9*(2), 278-294. https://doi.org/10.1080/14616700701848337 [Consultado el 22/02/2023]

Bengio, Yoshua; Ducharme, Réjean; Vincent, Pascal & Jauvin, Christian. (2003). A Neural Probabilistic Language Model. *Journal of Machine Learning Research*, *3*(6), Article 6. https://doi.org/10.1162/153244303322533223 [Consultado el 16/02/2023]

Bentivogli, Luisa; Bisazza, Arianna; Cettolo, Mauro & Federico, Marcello. (2016). Neural versus phrase-based machine translation quality: A case study. *EMNLP 2016 - Conference on Empirical Methods in Natural Language Processing,*

Proceedings, 257-267. https://doi.org/10.18653/v1/d16-1025 [Consultado el 05/02/2023]

Bielsa, Esperanca & Bassnett, Susan. (2008). *Translation in Global News*. Routledge. https://doi.org/10.4324/9780203890011 [Consultado el 18/03/2023]

Brockman, Greg; Eleti, Atty; Georges, Elie; Jang, Joanne; Kilpatrick, Logan; Lim, Rachel; Miller, Luke & Pokrass, Michelle. (2023, marzo 1). *Introducing ChatGPT and Whisper APIs*. https://openai.com/blog/introducing-chatgpt-and-whisper-apis [Consultado el 02/03/2023]

Brown, Tom B; Mann, Benjamin; Ryder, Nick; Subbiah, Melanie; Kaplan, Jared; Dhariwal, Prafulla; Neelakantan, Arvind; Shyam, Pranav; Sastry, Girish; Askell, Amanda; Agarwal, Sandhini; Herbert-Voss, Ariel; Krueger, Gretchen; Henighan, Tom; Child, Rewon; Ramesh, Aditya; Ziegler, Daniel M.; Wu, Jeffrey; Winter, Clemens; … Amodei, Dario. (2020). *Language Models are Few-Shot Learners* (arXiv:2005.14165). arXiv. https://doi.org/10.48550/arXiv.2005.14165 [Consultado el 15/03/2023]

Castilho, Sheila; Moorkens, Joss; Gaspari, Federico; Calixto, Iacer; Tinsley, John & Way, Andy. (2017). Is Neural Machine Translation the New State of the Art? *The Prague Bulletin of Mathematical Linguistics*, *108*(1), 109-120. https://doi.org/10.1515/pralin-2017-0013 [Consultado el 01/02/2023]

Chen, Yamei. (2009). Quotation as a Key to the Investigation of Ideological Manipulation in News Trans-Editing in the Taiwanese Press. *TTR: Traduction, Terminologie, Rédaction*, *22*(2), 203-238. https://doi.org/10.7202/044830ar [Consultado el 22/02/2023]

– (2011a). The ideological construction of solidarity in translated newspaper commentaries: Context models and inter-subjective positioning. *Discourse & Society*, *22*(6), 693-722. https://doi.org/10.1177/0957926511411695 [Consultado el 22/02/2023]

– (2011b). The Translator's Subjectivity and Its Constraints in News Transediting: A Perspective of Reception Aesthetics. *Meta: Journal Des Traducteurs / Meta: Translators' Journal*, *56*(1), 119-144. https://doi.org/10.7202/1003513ar

[Consultado el 22/02/2023]

Chuan Li. *OpenAI's GPT-3 Language Model: A Technical Overview*. (2020, junio 3). https://lambdalabs.com/blog/demystifying-gpt-3 [Consultado el 24/02/2023]

Conway, Kyle. (2010). News Translation and Cultural Resistance. *Journal of International and Intercultural Communication*, *3*(3), 187-205. https://doi.org/10.1080/17513057.2010.487219 [Consultado el 22/02/2023]

Cui Qiliang (崔启亮). (2014). «Lun jiqi fanyi de yihou bianji (论机器翻译的译后编辑)» [La posedición de traducción automática]. *Zhongguo Fanyi* (中国翻译) [Revista de traductores chinos], *35*(06), 68-73 [Consultado el 02/12/2022]

Daems, Joke & Macken, Lieve. (2019). Interactive adaptive SMT versus interactive adaptive NMT: A user experience evaluation. *Machine Translation*, *33*(1), 117-134. https://doi.org/10.1007/s10590-019-09230-z [Consultado el 02/02/2023]

Forcada, M. L. (2017). Making sense of neural machine translation. *Translation Spaces*, *6*(2), 291-309. https://doi.org/10.1075/ts.6.2.06for [Consultado el 01/02/2023]

Forcada, Mikel L. (2019, octubre 31). *Traducción automática neural: Cómo funciona y qué se puede esperar de ella*. Torre Juana OST. https://ost.torrejuana.es/traduccion-automatica-neural-mikel-forcada/ [Consultado el 29/01/2023]

Ghignoli, Alessandro & Ortiz, África Montabes. (2014). La traducción y los géneros periodísticos. *Mutatis Mutandis. Revista Latinoamericana de Traducción*, *7*(2), Article 2. https://doi.org/10.17533/udea.mut.19664 [Consultado el 01/02/2023]

Goldberg, Yoav & Levy, Omer. (2014). *word2vec Explained: Deriving Mikolov et al.'s negative-sampling word-embedding method* (arXiv:1402.3722). arXiv. https://doi.org/10.48550/arXiv.1402.3722 [Consultado el 28/02/2023]

Görög, Attila. (2014, noviembre 27). *Quality evaluation today: The Dynamic Quality Framework*. TC 2014, London, UK. https://aclanthology.org/2014.tc-1.21 [Consultado el 07/03/2023]

Guerberof-Arenas, Ana & Toral, Antonio. (2020). The impact of post-editing and machine translation on creativity and reading experience. *Translation Spaces*, *9*(2), 255-282. https://doi.org/10.1075/ts.20035.gue [Consultado el 16/03/2023]

Guerrero, María José Hernández. (2006). Técnicas específicas de la traducción periodística. *Quaderns: revista de traducció*, *13*, Article 13.

– (2019). Journalistic translation. En *The Routledge Handbook of Spanish Translation Studies*. Routledge.

Holland, Robert. (2013). News translation. En *The Routledge Handbook of Translation Studies*. Routledge.

Hurtado Albir, Amparo. (2001). *Traducción y traductología*. Cátedra.

Jia, Yanfang; Carl, Michael & Wang, Xiangling. (2019a). How does the post-editing of neural machine translation compare with from-scratch translation? A product and process study. *The Journal of Specialised Translation*, *31*(1), 60-86.

– (2019b). Post-editing neural machine translation versus phrase-based machine translation for English–Chinese. *Machine Translation*, *33*(1), 9-29. https://doi.org/10.1007/s10590-019-09229-6 [Consultado el 01/02/2023]

Jiao, Wenxiang; Wang, Wenxuan; Huang, Jen-tse; Wang, Xing & Tu, Zhaopeng. (2023). *Is ChatGPT A Good Translator? A Preliminary Study* (arXiv:2301.08745). arXiv. https://doi.org/10.48550/arXiv.2301.08745 [Consultado el 08/02/2023]

Kalchbrenner, Nal & Blunsom, Phil. (2013). Recurrent Continuous Translation Models. *Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing*, 1700-1709. https://aclanthology.org/D13-1176 [Consultado el 16/02/2023]

Koponen, Maarit. (2016). Is Machine Translation Post-editing Worth the Effort?: A Survey of Research into Post-editing and Effort. *The Journal of Specialised Translation*, *25*(2), 131-148.

Koponen, Maarit & Salmi, Leena. (2017). Post-editing quality: Analysing the correctness and necessity of post-editor corrections. *Linguistica Antverpiensia, New Series – Themes in Translation Studies*, *16*. https://doi.org/10.52034/lanstts.v16i0.439 [Consultado el 18/02/2023]

Koponen, Maarit; Salmi, Leena & Nikulin, Markku. (2019). A product and process analysis of post-editor corrections on neural, statistical and rule-based machine translation output. *Machine Translation*, *33*(1), 61-90.

https://doi.org/10.1007/s10590-019-09228-7 [Consultado el 14/02/2023]

Krings, Hans P. (2001). *Repairing Texts: Empirical Investigations of Machine Translation Post-editing Processes*. Kent State University Press.

Läubli, Samuel; Amrhein, Chantal; Düggelin, Patrick; Gonzalez, Beatriz; Zwahlen, Alena & Volk, Martin. (2019). *Post-editing Productivity with Neural Machine Translation: An Empirical Assessment of Speed and Quality in the Banking and Finance Domain* (arXiv:1906.01685). arXiv. https://doi.org/10.48550/arXiv.1906.01685 [Consultado el 01/02/2023]

LeCun, Yann; Bengio, Yoshua & Hinton, Geoffrey. (2015). Deep learning. *Nature*, *521*(7553), Article 7553. https://doi.org/10.1038/nature14539 [Consultado el 22/02/2023]

Lommel, Arle. (2018). Metrics for translation quality assessment: A case for standardising error typologies. En *Translation quality assessment: From principles to practice* (pp. 109-127). Springer.

Luo, Yongzhou. (2015). News translation as a site of framing Chinese identity: The case of Yeeyan Sport. *Ethnicities*, *15*(6), 829-847. https://doi.org/10.1177/1468796814546912 [Consultado el 22/02/2023]

Massardo, Isabella; Aranberri, Nora & Drescher, Katrin. (2016). *MT POST-EDITING GUIDELINES* (2016.ª ed.). TAUS Signature Editions. https://info.taus.net/mt-post-editing-guidelines [Consultado el 22/02/2023]

Mikolov, Tomas; Chen, Kai; Corrado, Greg & Dean, Jeffrey. (2006). Distributed Representations of Words and Phrases and their Compositionality. *Neural Information Processing Systems*, *1*, 1-9.

Mitchell, Linda; Roturier, Johann & O'Brien, Sharon. (2013, septiembre 2). Community-based post-editing of machine-translated content: Monolingual vs. bilingual. *Proceedings of the 2nd Workshop on Post-Editing Technology and Practice*. MTSummit 2013, Nice, France. https://aclanthology.org/2013.mtsummit-wptp.5 [Consultado el 14/02/2023]

Moorkens, Joss; Toral, Antonio; Castilho, Sheila & Way, Andy. (2018). Translators' perceptions of literary post-editing using statistical and neural machine translation.

Translation Spaces, *7*(2), 240-262. https://doi.org/10.1075/ts.18014.moo [Consultado el 16/03/2023]

Nitzke, Jean. (2016). Monolingual post-editing: An exploratory study on research behaviour and target text quality. En Hansen-Schirra, Silvia & Sambor, Grucza (Eds.), Eyetracking and Applied Linguistics (pp. 83–109). Language Science Press.

Nitzke, Jean & Hansen-Schirra, Silvia. (2021). *A short guide to post-editing*. Language Science Press. https://zenodo.org/record/5646896 [Consultado el 19/12/2022]

O'Brien, Sharon. (2011). Towards predicting post-editing productivity. *Machine Translation*, *25*(3), 197. https://doi.org/10.1007/s10590-011-9096-7 [Consultado el 01/02/2023]

Ono, Kenji. (2003). Translation of news headlines. *Machine Translation Summit IX*, *August*, Article August.

OpenAI. (2023, marzo 14). *GPT-4*. https://openai.com/research/gpt-4 [Consultado el 15/03/2023]

Palmer, Jerry. (2009). News gathering and dissemination. *Routledge Encyclopedia of Translation Studies. London: Routledge*, 186-189.

Pan, Li. (2017). Investigating institutional practice in news translation: An empirical study of a Chinese agency translating discourse on China. En *Chinese Translation Studies in the 21st Century*. Routledge.

Panić, Milica. (2020, julio). *Everything You Need To Know About DQF*. https://www.taus.net/resources/blog/everything-you-need-to-know-about-dqf [Consultado el 07/03/2023]

Pennington, Jeffrey; Socher, Richard & Manning, Christopher. (2014). GloVe: Global Vectors for Word Representation. *Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 1532-1543. https://doi.org/10.3115/v1/D14-1162 [Consultado el 28/02/2023]

Pérez-Ortiz, Juan Antonio; Forcada, Mikel L & Sánchez-Martínez, Felipe. (2022). How neural machine translation works. En Dorothy, Kenny (Ed.), *Machine translation for everyone* (pp. 141-164). Language Science Press. https://doi.org/10.5281/zenodo.6653406 [Consultado el 23/01/2023]

Plitt, Mirko & Masselot, François. (2010). A Productivity Test of Statistical Machine Translation Post-Editing in a Typical Localisation Context. *The Prague Bulletin of Mathematical Linguistics*, *93*(1). https://doi.org/10.2478/v10108-010-0010-x [Consultado el 17/02/2023]

Rong, Xin. (2016). *Word2vec Parameter Learning Explained* (arXiv:1411.2738). arXiv. https://doi.org/10.48550/arXiv.1411.2738 [Consultado el 28/02/2023]

Sánchez Ramos, María del Mar & Rico Pérez, Celia. (2020). *Traducción automática: Conceptos clave, procesos de evaluación y técnicas de posedición*. Editorial Comares.

Sánchez-Gijón, Pilar. (2016). La posedición: Hacia una definición competencial del perfil y una descripción multidimensional del fenómeno. *Sendebar*, *27*, 151-162. https://doi.org/10.30827/sendebar.v27i0.4016 [Consultado el 01/02/2023]

– (2022). Neural machine translation and the indivisibility of culture and language. *FORUM. Revue Internationale d'interprétation et de Traduction / International Journal of Interpretation and Translation*, *20*(2), 357-367. https://doi.org/10.1075/forum.00025.san [Consultado el 08/03/2023]

Sánchez-Gijón, Pilar; Moorkens, Joss & Way, Andy. (2019). Post-editing neural machine translation versus translation memory segments. *Machine Translation*, *33*(1), 31-59. https://doi.org/10.1007/s10590-019-09232-x [Consultado el 05/02/2023]

Sanchez-Torron, Marina & Koehn, Philipp. (2016). Machine Translation Quality and Post-Editor Productivity. *Conferences of the Association for Machine Translation in the Americas: MT Researchers' Track*, 16-26. https://aclanthology.org/2016.amta-researchers.2 [Consultado el 14/02/2023]

Shi, Xuedong. (2014). English-Chinese News Headlines Translation from a Skopostheorie Perspective. *Theory and Practice in Language Studies*, *4*(9), Article 9. https://doi.org/10.4304/tpls.4.9.1881-1885 [Consultado el 04/03/2023]

Snover, Matthew; Dorr, Bonnie; Schwartz, Richard; Micciulla, Linnea & Makhoul, John. (2006). A study of translation edit rate with targeted human annotation. *Proceedings of the 7th Conference of the Association for Machine Translation in*

the Americas: Technical Papers, 223-231. https://aclanthology.org/2006.amta-papers.25 [Consultado el 19/01/2023]

Sutskever, Ilya; Vinyals, Oriol & Le, Quoc V. (2014). Sequence to sequence learning with neural networks. *Advances in Neural Information Processing Systems*, *4*(January), Article January.

Toral, Antonio & Sánchez-Cartagena, Víctor M. (2017). A multifaceted evaluation of neural versus phrase-based machine translation for 9 language directions. *15th Conference of the European Chapter of the Association for Computational Linguistics, EACL 2017 - Proceedings of Conference*, *2*, 1063-1073. https://doi.org/10.18653/v1/e17-1100 [Consultado el 06/02/2023]

Toral, Antonio; Wieling, Martijn & Way, Andy. (2018). Post-editing Effort of a Novel With Statistical and Neural Machine Translation. *Frontiers in Digital Humanities*, *5*. https://www.frontiersin.org/articles/10.3389/fdigh.2018.00009 [Consultado el 02/02/2023]

Valdeón, Roberto A. (2015). Fifteen years of journalistic translation research and more. *Perspectives*, *23*(4), 634-662. https://doi.org/10.1080/0907676X.2015.1057187 [Consultado el 02/02/2023]

Van Brussel, Laura; Tezcan, Arda & Macken, Lieve. (2018). A fine-grained error analysis of NMT, PBMT and RBMT output for English-to-Dutch. *Proceedings of the Eleventh International Conference on Language Resources and Evaluation*, 3799-3804. http://hdl.handle.net/1854/LU-8561558 [Consultado el 03/02/2023]

Vasconcellos, Muriel & Bostad, Dale A. (1992). Machine translation in a high-volume translation environment. En *Computers in Translation* (pp. 78-97). Routledge. https://doi.org/10.4324/9780203128978 [Consultado el 29/01/2023]

Vaswani, Ashish; Shazeer, Noam; Parmar, Niki; Uszkoreit, Jakob; Jones, Llion; Gomez, Aidan N.; Kaiser, Łukasz & Polosukhin, Illia. (2017). Attention is all you need. *Advances in Neural Information Processing Systems*, *2017-December*, 5999-6009.

Vieira, Lucas Nunes. (2019). Post-editing of machine translation. En Minako, O'Hagan, *The Routledge handbook of translation and technology* (pp. 319-336). Routledge. https://doi.org/10.4324/9781315311258 [Consultado el 29/01/2023]

Wagner, Emma. (1985). Post-editing SYSTRAN, a challenge for Commission Translators. *Terminologie et Traduction*, *3*, 1-7.

Wu, Yonghui; Schuster, Mike; Chen, Zhifeng; Le, Quoc V.; Norouzi, Mohammad; Macherey, Wolfgang; Krikun, Maxim; Cao, Yuan; Gao, Qin; Macherey, Klaus; Klingner, Jeff; Shah, Apurva; Johnson, Melvin; Liu, Xiaobing; Kaiser, Łukasz; Gouws, Stephan; Kato, Yoshikiyo; Kudo, Taku; Kazawa, Hideto; … Dean, Jeffrey. (2016). *Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation* (arXiv:1609.08144). arXiv. https://doi.org/10.48550/arXiv.1609.08144 [Consultado el 05/02/2023]

Yamada, Masaru. (2019). The impact of Google neural machine translation on post-editing by student translators. *The Journal of Specialised Translation*, *31*(1), 87-106.

Zhang Chunliang & Han Lintao (张春良&韩林涛). (2019). *Jiqi fanyi yuanli jianjie jiqi yingyong - Wangyi yunketang* (机器翻译原理简介及其应用—网易云课堂) [Introducción a los principios y aplicaciones de la traducción automática]. https://study.163.com/course/introduction.htm?courseId=1209563857&_trace_c_p_k2_=a8d02c48bc884fb6b8e5bb0bc8a72019 [Consultado el 28/02/2023]

Zouhar, Vilém; Tamchyna, Aleš; Popel, Martin & Bojar, Ondřej. (2021). *Neural Machine Translation Quality and Post-Editing Performance* (arXiv:2109.05016). arXiv. https://doi.org/10.48550/arXiv.2109.05016 [Consultado el 01/02/2023]

7. Anexo

7.1 Corpus de texto y la traducción con posedición

Según Guerrero (2006, p. 127), la mayoría de los periódicos en español se estructuran en tres secciones: el *titular*, la *entrada* y el *cuerpo de la noticia*.

Titular	El reconocimiento de bebés fuera del matrimonio se abre paso en una China inmersa en una grave crisis demográfica Texto traducido: 在严重人口危机的背景下，非婚生子女的认可在中国逐渐得到普及
Entrada	Sichuan, la quinta provincia más poblada del país, permitirá a todas las personas, independientemente de su estado civil, registrar cuantos hijos tengan. El paso se toma en medio del desplome histórico en la tasa de natalidad que enfrenta el gigante asiático Texto traducido: 在中国面临出生率历史性下降的背景下，中国第五大人口省份四川，将允许所有人，无论其婚姻状况如何，都可以登记他们所拥有的子女。
Fuente y la fecha consultada	https://elpais.com/sociedad/2023-02-17/el-reconocimiento-de-bebes-fuera-del-matrimonio-se-abre-paso-en-una-china-inmersa-en-una-grave-crisis-demografica.html [Consultado el 21/02/2021]
Cuerpo de la noticia	
La grave crisis demográfica que atraviesa China ha colocado a las autoridades en una encrucijada: o tomar decisiones que puedan revertir el curso de los acontecimientos o aferrarse a un modus operandi que en el contexto actual está menos justificado que nunca. Aunque el Gobierno central lleva varios años anunciando políticas preferenciales para animar a la población a tener más hijos, paradójicamente, no todas	

las mujeres que dan a luz cumplen con los parámetros establecidos formalmente. Hasta la fecha, de entre las 31 provincias y regiones del país, solamente dos tienen estipulado de manera inequívoca que todas las madres, independientemente de su estado civil, pueden registrar a sus hijos. Sichuan, hogar de casi 84 millones de habitantes, se sumó a esa lista esta semana, acabando con la implementación de una normativa que no reconocía en su totalidad a los ojos de la ley a aquellos recién nacidos fuera de un núcleo familiar donde un hombre y una mujer hayan contraído matrimonio.

Texto traducido: 中国面临的严重人口危机使得当局陷入两难境地：要么做出能够扭转局势的决策，要么坚持一种在当前背景下越来越不合理的操作方式。尽管中央政府多年来一直出台优惠政策以鼓励人们生育更多子女，然而矛盾的是，并非所有生育的妇女都符合正式规定的标准。迄今为止，在全国的 31 个省份和地区中，只有 2 个明确规定所有母亲，无论其婚姻状况如何，都可以为他们的孩子办理登记。四川，这个拥有近 8400 万居民的省份，本周通过结束一项在法律上不承认非传统家庭（非一男一女婚姻）出生的子女的规定，也加入了这一（开放子女登记限制的）名单。

Sichuan, ubicada en el suroeste de China, permite desde este miércoles a todos sus residentes registrar cuantos hijos tengan, y simplificará los trámites burocráticos para hacerlo. La nueva norma, que estará en vigor durante cinco años, otorga un carácter más inclusivo a la existente desde 2019, bajo la cual solamente las parejas casadas podían registrar hasta dos retoños. El objetivo, según lee el comunicado de la Comisión de Salud sichuanesa, es “promover un desarrollo demográfico equilibrado y a largo plazo”. Sichuan es la quinta provincia más poblada del gigante asiático y la séptima más envejecida. Según los datos más recientes, el 21% de sus habitantes son mayores de 60 años.

Texto traducido: 位于中国西南部的四川，自本周三起，允许所有居民登记他们

所拥有的子女，并简化相关的行政手续。这项新规定将在未来五年内生效，相较于 2019 年起实施的现行规定，新规更加具有包容性，因为 2019 年的规定仅允许已婚夫妇最多登记两个孩子。根据四川卫健委的声明，新规的目标在于“促进人口长期平衡发展”。四川是中国人口第五多的省份，也是第七个老龄化程度最高的省份。根据最新数据，该省 21%的人口年龄超过了 60 岁。

La legislación china no prohíbe explícitamente las familias monoparentales, sin embargo, las políticas estatales establecen que la planificación familiar es un deber “de maridos y esposas juntos” (el matrimonio homosexual no está aprobado). Bajo ese paraguas, los gobiernos locales redactan sus propios textos, los cuales, a menudo, reflejan estigmas sociales. Las normas hacia los hijos “no planificados” (entre los que se incluyen los de padres no casados o los nacidos más allá del límite por pareja permitido) suelen ser severas y, con frecuencia, los progenitores de esos bebés enfrentan multas y discriminaciones. Han trascendido muchos casos de mujeres solteras embarazadas a las que se les ha negado el acceso a la sanidad pública y a un seguro médico que cubra la baja de maternidad, y suelen no contar con respaldo legal si su empleador las despide por estar encintas. La revista digital china *Sixth Tone* cita una encuesta realizada en 2017 a 250.000 mujeres de entre 15 y 60 años en la que el 20% de las participantes aseguró haberse quedado embarazada sin estar casada en, al menos, una ocasión.

Texto traducido: 中国的法律并未禁止单亲家庭，然而，国家政策规定计划生育是“丈夫和妻子一同的责任”（不承认同性婚姻）。在这个框架下，地方政府制定自己的地方法规，这些法规往往反映了社会上的偏见。对于“非计划生育”的孩子（包括未婚父母的或超过夫妻生育限制而出生的孩子）的相关规定通常十分严格，并且这些孩子的监护人往往面临罚款和歧视。许多未婚怀孕的女性被拒绝享受公共卫生保健和覆盖产假的医疗保险，并且如果雇主因怀孕而解雇她们，她们通常得不到法律支持。中国的数字杂志《第六声》援引了 2017 年对 25 万名 15 至 60 岁女性进行的一项调查，其中 20%的受访者表示至少有一次

未婚先孕的情况。

La flexibilización aprobada en Sichuan es especialmente significativa porque, en China, el registro de nacimiento suele ser necesario para solicitar acceso a servicios públicos y para obtener el registro de residencia, conocido como *hukou*, que concede a los niños derecho a prestaciones sociales, como sanidad y educación. Las provincias de Cantón (sur) y Shaanxi (noroeste) eliminaron el prerrequisito de estar casado en 2022. Anhui (centro) también se está planteando adoptar una política similar, según la prensa local.

Texto traducido: 四川通过的这一放宽措施尤其重要，因为在中国，出生登记通常是申请公共服务和获得居住登记（称为户口）所必需的。户口为儿童提供了享受医疗和教育等社会福利的权利。南部的广东省和西北部的陕西省在 2022 年取消了结婚先决条件。据当地媒体报道，中部的安徽省也正在考虑采取类似的政策。

Las reacciones a la noticia en redes han sido de lo más variopintas, desde los que consideran que se trata de un parche que no aborda la preocupación real sobre los costes de la vida, a los que especulan sobre el impacto que tendrá en las relaciones extramatrimoniales y si promoverá la subrogación ilegal. En medio del acalorado debate, un funcionario sanitario de Sichuan declaró que las nuevas provisiones “no pretenden fomentar los partos antes del matrimonio, sino garantizar que las personas solteras puedan disfrutar de los servicios disponibles de atención materno infantil”.

Texto traducido: 这一消息在社交媒体上引发了各种不同的反应，有人认为这只是一个权宜之计，没有解决人们对生活成本的真正关切，还有人猜测这将对婚外关系产生影响，并且质疑是否会促进非法代孕。在激烈的辩论中，四川的一位卫生官员表示，这些新规定“并不是为了鼓励婚前生育，而是确保单身人士能够享受到可用的母婴保健服务”。

“Persisten muchos tabúes y prejuicios sobre las madres solteras. No veo que haya un cambio en la mentalidad de la sociedad y, por tanto, tampoco creo que se vayan a producir avances drásticos en el discurso oficial”, comentaba el mes pasado en una entrevista para este periódico la demógrafa Peng Xiujiang, investigadora sénior en el Centro de Estudios Políticos de la Universidad de Victoria (Australia).

Texto traducido: “关于单身母亲存在着许多禁忌和偏见。我没有看到社会心态有所改变，因此也不相信官方言论中会有重大进展”。澳大利亚维多利亚大学政治研究中心资深研究员彭秀江上个月在接受本报采访时如此评论。

La nueva disposición en Sichuan se implanta apenas un mes después de que China anunciase un desplome histórico en la tasa de natalidad y su primera contracción poblacional en las últimas seis décadas, un giro que, según los expertos, podría marcar el inicio de un periodo de declive para la segunda potencia económica mundial. De hecho, las estimaciones más recientes predicen que el gigante asiático cederá este año el primer puesto como la nación más poblada del planeta a India.

Texto traducido: 四川省的这项新规定是在中国宣布出生率历史性下降和过去六十年来首次出现人口收缩的仅仅一个月后实施的。专家们认为，这一转变可能标志着中国作为全球第二大经济体进入衰退期的开端。事实上，最近的估计预测，中国将在今年失去世界上人口最多的国家的头衔，被印度取代。

Tina Jiang (nombre ficticio), de 30 años, cuenta por teléfono que cree que el paso dado en Sichuan es un arma de doble filo: por un lado, “es bueno que las mujeres no tengan que estar ligadas a un matrimonio para tener hijos”, pero, por otro, “nos añade presión”; teme que se pueda instrumentalizar para “tratarnos como máquinas de hacer bebés”. Cada vez son más las jóvenes que rechazan el matrimonio y la maternidad, por diversos motivos. En el caso de Jiang, que estudió en el extranjero, porque

prioriza su carrera y “felicidad personal”. También menciona los elevadísimos costes de la vida y la reducción de ingresos durante los tres años de lucha contra la covid-19. Las cifras oficiales reflejan esa tendencia: una encuesta de 2021 de la Comisión Nacional de Salud muestra que las mujeres en edad fértil tienen “poca voluntad” por tener hijos, y en 2022 la tasa de fecundidad del país (el número promedio de hijos que nacerían por mujer) fue de 1,3, muy por debajo del 2,1 que hace falta para que la población se mantenga estable.

Texto traducido: 30 岁的姜提娜（化名）在电话中表示，她认为四川的这一举措是一把双刃剑：一方面，“女性无需为了生孩子而受婚姻的束缚，这是好事”，但另一方面，“这给我们增加了压力”，她担心这可能被利用来将女性视为“生育机器”。越来越多的年轻女性出于各种原因拒绝结婚和生育。对于留过学的姜女士来说，她拒绝结婚和生育是因为她优先考虑自己的职业和“个人幸福”。她还提到生活成本的飙升以及在三年抗击新冠肺炎的斗争期间收入的减少。官方数据也反映了这一趋势：中国国家卫生健康委员会 2021 年的一项调查显示，育龄妇女对生育孩子的“意愿较低”，2022 年中国的生育率（每个女性预计生育的孩子平均数）为 1.3，远低于维持人口稳定所需的 2.1。

El proceso demográfico a la baja de China es fruto, en gran medida, de la política del hijo único que rigió entre 1980 y 2015 para frenar el crecimiento excesivo de la población. Durante décadas, aquella estrategia estatal obligó a muchas mujeres a adoptar decisiones drásticas y traumáticas, como a abortar de manera forzosa o someterse a métodos de esterilización, debido a la presión social y a la imposibilidad de pagar las sanciones. La obsesión en aquellos años de priorizar el nacimiento de un varón ha provocado, además, una enorme brecha de género entre la población en edad reproductiva.

Texto traducido: 中国人口下降的过程在很大程度上是由于 1980 年至 2015 年间实施的独生子女政策所致，该政策旨在遏制人口过快增长。数十年来，这一

国家战略迫使许多妇女做出了极端而痛苦的决定，如被强制堕胎或接受绝育手术，原因是社会压力和无力支付罚款。在那些年里，重男轻女的迷恋还导致了育龄人口之间巨大的性别差距。

Pero, incluso ante las presiones demográficas, el Partido Comunista chino muestra reticencias a renunciar por completo al control sobre la planificación familiar. El Gobierno promueve desde 2021 políticas preferenciales de acceso a la vivienda, mayor flexibilidad laboral o ayudas fiscales y a la educación con el objetivo de "crear un entorno favorable al matrimonio y la fertilidad" y animar a las parejas casadas a tener hasta tres hijos. No obstante, ese mismo año la Comisión Nacional de Salud rechazó una propuesta de abrir la congelación de óvulos a las mujeres solteras, alegando "problemas éticos y de salud", pese a que los hombres no tienen ningún tipo de restricción a la hora de someterse a procesos de fertilidad. También en 2021, el Consejo de Estado –el Ejecutivo– se marcó la meta de reducir el número de interrupciones del embarazo que no se deban a una "necesidad médica". Algunas voces críticas, como la activista feminista Lü Pin, denuncian que Pekín continúa usando a las mujeres como "una herramienta para alcanzar los objetivos nacionales" y "devolverlas a los roles de género" dentro de un sistema que solo entiende por "familia" a aquella formada por parejas heterosexuales.

Texto traducido: 然而，即使面对人口压力，中国共产党仍然不愿完全放弃对计划生育的控制。政府自 2021 年以来就一直在出台住房方面的优惠政策、鼓励灵活就业、加大财政补贴和教育帮扶力度，其目的是"为结婚和生育创造一个良好的环境"，并鼓励已婚夫妇最多生育三个孩子。然而，同年，国家卫健委拒绝了向未婚女性开放卵子冷冻的提议，称存在"伦理和健康问题"，尽管男性在接受辅助生育技术方面没有任何限制。同样在 2021 年，国务院设定了减少非"医疗需要"而流产的数量目标。一些批评的声音，如女权主义活动家吕频，谴责北京继续将妇女视为实现国家目标的"工具"，在一个只有由异性伴侣组成的家庭才被视为"家庭"的系统中，将她们"重新归位到性别角色"。

7.2 Lista de los nombres propios y términos

Lista para castellano y chino[17]

1.	Bebés / hijos fuera del matrimonio	*Fei hunsheng zinü* (非婚生子女)
2.	Registro de residencia	*Hukou* (户口)
3.	Flexibilidad laboral	*Linhuo jiuye* (灵活就业)
4.	Planificación familiar	*Jihua shengyu* (计划生育)
5.	Política del hijo único	*Dusheng zinü zhengce* (独生子女政策)
6.	Covid-19	*Xinguan feiyan* (新冠肺炎)
7.	Comisión Nacional de Salud	*Guojia Weisheng Jiankang Weiyuanhui* (国家卫生健康委员会)
8.	Consejo de Estado	*Guowuyuan* (国务院)

[17] *El Diario del Pueblo*, conocido en chino *Ren Min Ri Bao* (人民日报), es un medio de comunicación oficial de China. http://spanish.peopledaily.com.cn/