

Automática (Traducción)

En breve



 **ENG** *Machine translation* **CAT** *Traducció automàtica* **EUS** *Makina bidezko itzulpengintza* **GLG** *Tradución automática* **POR** *Tradução automática*

orígenes

La parte *translatio/traductio* del término aquí es claramente analógica; las diferencias se evocan claramente modificándolo con el adjetivo *automática*, como hacen prácticamente todas las lenguas románicas, el cual es un reflejo moderno del término griego *αὐτόματον* (*autómata*), un adjetivo neutro que significa ‘espontáneo’ y ‘que se mueve impulsado por sí mismo’, que se utiliza para referirse a la manera en que actúan las máquinas sin ninguna intervención humana. Los términos en otras lenguas (como en inglés *machine translation*) son reflejos del latín *machina*, un préstamo de una forma del griego *μηχανή* (*mekhané*), que significa *dispositivo*, *engranaje* o *artificio*. Curiosamente, el ruso utilizaba originalmente *автоматический перевод* (*avtomaticheskii perevod*), pero ahora usa más comúnmente *машинный перевод* (*machinniy perevod*), paralelo al término inglés.

otros nombres

automatic translation (utilizada por Yehoshua Bar-Hillel entre otros en los sesenta); *mechanical translation* (‘traducción mecánica’, utilizada en los años cincuenta y sesenta y después principalmente en Japón a los noventa, pero con un significado diferente en el campo de la traducción de la Torá); *automated translation* (‘traducción automatizada’, a veces en lenguaje de la Comisión Europea).

resumen

La traducción automática es el proceso mediante el cual un sistema informático produce, a partir de un texto legible por ordenador en una lengua de partida, un texto legible por ordenador en una


lengua de llegada, el cual se pretende que sea una traducción aproximada del primero.

La traducción automática, una tecnología madura en la actualidad, ha cambiado radicalmente la forma en que las personas perciben la comunicación multilingüe, puesto que actualmente cualquier persona que tenga acceso a Internet la puede utilizar, por ejemplo, para dar sentido al contenido de Internet escrito en otra lengua. Por supuesto, también ha tenido un impacto considerable en la traducción como profesión (y en la forma en que es percibida por el gran público). Después de definir la traducción automática y distinguirla claramente de otras tecnologías de traducción asistida por ordenador y de hacer una breve revisión histórica, de los primeros sistemas basados en reglas de los años cincuenta a los sistemas estadísticos de los años noventa y primer decenio del siglo XX hasta el advenimiento de los enfoques neuronales de este decenio, este artículo describe cómo se utiliza la traducción automática entre la gente común y en los flujos de trabajo de traducción profesional asistida por ordenador, y cómo se puede evaluar, tanto cuando se considera su adopción como durante el desarrollo. También describe los principales enfoques tecnológicos: por un lado, la traducción automática basada en reglas y, por otro lado, la traducción automática basada en corpus en sus dos variantes: estadística y neuronal, tanto para permitir a los traductores profesionales tomar decisiones informadas sobre la tecnología como para sensibilizar al público en general sobre qué esperar de esta tecnología y cómo utilizarla si se tercia. Para cerrar, se detallan algunas líneas de investigación activas en el campo de la traducción automática.

ficha

 Mikel L. Forcada Zubizarreta

 2022

 Forcada Zubizarreta, Mikel L. 2022."Automática (Traducción)" @ *ENTI (Enciclopedia de traducción e interpretación)*. AIETI.

 <https://doi.org/10.5281/zenodo.6634083>

 https://www.aieti.eu/enti/machine_translation_SPA/

Entrada




ENG *Machine translation* **CAT** *Traducció automàtica* **EUS** *Makina bidezko itzulpengintza* **GLG** *Traducción automática* **POR** *Tradução automática*

contenido

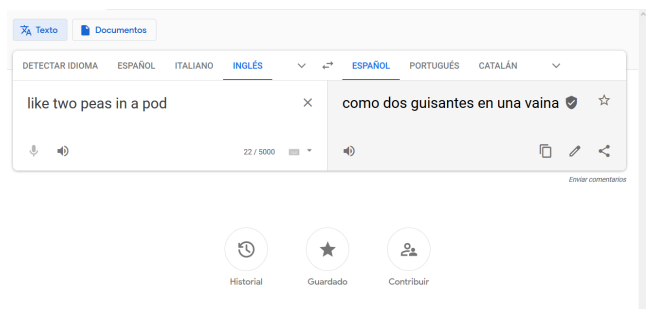
[Introducción](#) | [Dos usos principales de la traducción automática, la asimilación y la difusión](#) | [Posedición, preedición, lenguajes controlados](#) | [Una breve historia de la TA](#) | [TA de propósito general y de propósito específico](#) | [Aproximaciones a la TA](#) | [Corpus para la traducción automática](#) | [Evaluación de la traducción automática](#) | [Potencial de investigación](#)

Introducción

La traducción automática (TA) es el proceso mediante el cual un programa de ordenador produce, a partir de un texto legible por ordenador en una lengua de partida, un texto legible por ordenador en una lengua de llegada, el cual se pretende que sea una traducción aproximada del primero, todo ello sin intervención humana.

La TA debe distinguirse claramente de otras tecnologías de traducción utilizadas por los profesionales de la traducción, como por ejemplo la traducción asistida por ordenador basada en memorias de traducción, en la cual los profesionales utilizan traducciones previas de segmentos de textos similares para traducir nuevos segmentos, o, incluso, otras tecnologías de procesamiento de lenguaje natural que aplican técnicas de [lingüística computacional](#) como por ejemplo la traducción automática de voz a voz, es decir, la interpretación automática. La TA es una tecnología de texto a texto y está completamente automatizada.

Pero, ¿es la traducción automática en bruto realmente una traducción? Normalmente, no se puede utilizar como se haría con una traducción profesional; como dijo Sager (1994) en su libro pionero,



La traducción automática en bruto no siempre está preparada para ser usada tal como se ha producido: la expresión inglesa “like two peas in a pod”, que significa “muy parecida”, se traduce literalmente al castellano.

“no hay ninguna situación en la cual [la TA y la traducción profesional] serían igualmente adecuadas”. Esto quiere decir que, por ejemplo, el producto de la TA raramente se puede publicar tal como aparece en primera instancia; sin embargo, esto no significa que la TA sea inútil. De hecho, los clientes de los traductores profesionales empiezan a ser conscientes de que hay una tecnología que les puede ayudar a hacer su trabajo y, por lo tanto, exigen precios mejores, mientras que el público en general se acostumbra gradualmente a leer traducción automática en bruto, incluso para tomar decisiones en cuanto a adquisiciones basándose en reseñas o descripciones traducidas automáticamente. Como resultado, la traducción profesional se percibe a veces como un lujo prescindible en muchas aplicaciones. Un conocimiento profesional de la utilidad y las limitaciones de la TA resulta, por lo tanto, crucial para la práctica de la traducción contemporánea.

[cabecera](#)

¶ Dos usos principales de la traducción automática: la asimilación y la difusión

La amplia disponibilidad de la TA, una tecnología madura en la actualidad, ha cambiado radicalmente la forma en que las personas perciben las comunicaciones multilingües, puesto que actualmente cualquier persona que tenga acceso a Internet puede utilizarla, en muchos casos de forma gratuita, para comprender textos (normalmente contenido web) escritos en una lengua que no entienden. Cuando esto sucede, se dice que la TA se usa para la asimilación. La asimilación es, con diferencia, el uso más común de la TA. Franz Josef Och, quien fue responsable científico de TA de Google, ya dijo en 2012: “Todos los días traducimos aproximadamente todo el texto de un millón de libros. Dicho de otro modo: lo que todos los traductores humanos profesionales del mundo traducen en un año, nuestro sistema lo traduce aproximadamente en un solo día” (Och [2012](#)).

Los profesionales también usan la TA como fuente de ayuda a la hora de producir traducciones que se publicarán en ámbitos a veces no muy reducidos. Cuando esto sucede, se dice que la TA se usa para propósitos de difusión. De hecho, la TA ha provocado en la traducción como profesión (y en la forma en que es percibida por el público en general) un impacto tal que los *retrónimos* 'traducción humana' y (por desgracia menos frecuentemente) 'traducción profesional', se usan cada día más para referirse a las traducciones que no se han producido con un sistema de TA.

[cabecera](#)

¶ Posedición, preedición, lenguajes controlados

Una manera habitual en que los traductores profesionales aprovechan la traducción automática con fines de difusión es mediante la edición o, como se acostumbra a denominar, la posedición del producto de la TA para convertirla en una traducción adecuada para el propósito previsto, siempre que esto sea económicamente posible. Cuando el texto se traduce de una única lengua de partida a varias lenguas de llegada (por ejemplo, en los flujos de trabajo de gestión de documentos multilingües), una preedición proactiva del texto original (probablemente más costosa que la posedición, puesto que requiere comprender qué tipo de entrada hace que el sistema produzca errores) puede ser una manera de evitar parcialmente la posedición del contenido del resultado del sistema de TA en más de una lengua de llegada. De hecho, la misma preedición se puede evitar si se restringe el lenguaje en que pueden escribir los autores de los textos originales. Esto se hace

definiendo y aplicando (mediante la edición asistida) un lenguaje controlado que utiliza reglas para restringir el léxico y las estructuras de la lengua de partida para evitar problemas de traducción automática.


[cabecera](#)

¶ Una breve historia de la TA

La idea de la traducción mecánica existía desde hacía mucho tiempo. Entre los precedentes de la TA moderna, a menudo se cita el memorándum de Warren Weaver (1949). Las dos contribuciones principales de Weaver fueron: (a) la idea de que un texto en la lengua de partida es como una versión “cifrada” del texto en la lengua de llegada, y que la traducción sería similar a un proceso de “desciframiento” que utilizaría de manera inteligente las teorías estadísticas de probabilidad de la teoría de la comunicación; y (b) la idea que en lugar de traducir directamente de una lengua a otra puede ser más útil buscar representaciones de texto más profundas e intentar aprovechar lo que las lenguas tienen en común. Estas dos ideas fundamentan buena parte de la tecnología que se aplicó a partir de entonces.

La TA fue una de las primeras aplicaciones de los sistemas pioneros de computación electrónica. En 1954 se hizo por primera vez la demostración pública de un sistema de TA (desarrollado por IBM y la Universidad de Georgetown). Se tradujo al inglés un conjunto de 49 oraciones en ruso usando una aproximación directa, palabra a palabra, con un diccionario de 250 palabras, seguida de algunos ajustes realizados mediante seis reglas gramaticales. A pesar de las limitaciones de los resultados, se hizo creer al público y a la industria que en pocos años se podrían conseguir traducciones de calidad de documentos científicos y técnicos. La investigación floreció con una financiación pública generosa, pero el progreso hacia el objetivo de la traducción completamente automatizada de alta calidad era demasiado lento. En 1966, el Comité Asesor sobre el Procesamiento Automático de las Lenguas (*Automatic Language Processing Advisory Committee*, ALPAC) publicó un informe que recomendaba que los recursos dedicados en la investigación en TA se usaran para tareas de procesamiento del lenguaje natural mejor definidas y menos ambiciosas y para el desarrollo de ayudas a la traducción como por ejemplo diccionarios automáticos. La investigación en los Estados Unidos prácticamente se detuvo —sin desaparecer del todo—, mientras que continuó en Europa y Japón. De hecho, en los años setenta, un sistema comercial, Systran (todavía disponible, pero ahora [un sistema completamente nuevo](#)), fue adoptado tanto por las Fuerzas Aéreas de los Estados Unidos como por la Comisión Europea.

La década de los ochenta vio cómo se dirigían los esfuerzos hacia la traducción indirecta mediante diferentes niveles de análisis de la lengua de partida para construir representaciones intermedias, en sistemas como GETA-Ariane (Grenoble; Hutchins y Somers, 1992, cap. 13), SUSY (Saarbrücken; Hutchins y Somers 1992, cap. 11), Mu (Kioto; Nagao, Nishida y Tsujii 1984), DLT (Utrecht; Hutchins & Somers 1992, cap. 17), Rosetta (Eindhoven; Hutchins & Somers, 1992, cap. 16), los sistemas desarrollados en la Universidad Carnegie-Mellon (Pittsburgh; Hutchins & Somers 1992, sec. 18.1) y los desarrollados por dos proyectos internacionales: Eurotra,



financiado por la Comunidad Europea (Hutchins & Somers 1992, cap. 14), y el proyecto japonés CICC con participantes en China, Indonesia y Tailandia (Tanaka, Ishizaki, Uehara *et al.* 1989). A pesar de que Eurotra no consiguió ofrecer un sistema de TA útil y se canceló en 1992, estimuló la investigación sobre tecnologías del lenguaje en toda Europa y condujo a la concepción de sistemas comerciales como el Metal de Siemens (Hutchins & Somers 1992, cap. 15), los cuales se basaban en principios lingüísticos como el análisis sintáctico y las transformaciones. Todos estos sistemas se basaban en reglas y diccionarios elaborados por expertos, y en programas informáticos que los aplicaban en los textos (traducción automática basada en reglas, véase más abajo).

El Informe ALPAC (1966).

Sin embargo, hacia el final de los años ochenta surgió un nuevo enfoque en IBM (Brown, Cocke, Della Pietra *et al.* 1988; Hutchins & Somers 1992, epígrafe 18.3), a pesar de que solo empezó a ser conocido en los noventa. Un nuevo sistema llamado Candide extraía información estadística detallada de una versión alineada oración a oración de los Hansards, las actas bilingües inglés–francés del Parlamento de Canadá, *aprendía* modelos probabilísticos de traducción automática y los aplicaba eficientemente a nuevos textos, casi sin que hiciesen falta conocimientos lingüísticos para desarrollarlo. El sistema resultante no estaba demasiado lejos del enfoque estadístico de Weaver (1949) de descifrar el texto de partida para traducirlo. La TA estadística (véase más abajo) había entrado en escena para competir con las aproximaciones basadas en reglas y empezó a desplazarlas. Hacia 2015, muchos sistemas de traducción automática se regían por la llamada *traducción automática estadística basada en segmentos (phrase-based machine translation)*, una evolución del enfoque original de IBM, de hecho, la variedad más utilizada. Esto fue posible gracias a la disponibilidad de *software* libre para entrenar e implementar sistemas de traducción automática, como por ejemplo Moses. Aunque el *software* era libre, la clave era tener buenos datos de entrenamiento; aparecieron empresas que ofrecían a los clientes la posibilidad de combinar sus datos con los datos generales de la empresa para construir sistemas especializados, usando un navegador de Internet ordinario.

Hacia 2013, una nueva forma de traducción basada en el llamado aprendizaje profundo empezó a disputar la hegemonía a la TA estadística. Esta nueva TA *neuronal* (véase más abajo) utiliza métodos de un campo maduro de la inteligencia artificial, el de las *redes neuronales artificiales*; en pruebas de laboratorio, sus resultados son comparables o superiores a los mejores resultados de TA estadística disponibles. Como la TA estadística, la TA neuronal aprende de los textos bilingües y está detrás de los populares sistemas comerciales contemporáneos de TA, como por ejemplo [Google Translate](#), [Microsoft Translator](#) o [DeepL](#).

[cabecera](#)

¶ TA de propósito general y de propósito específico

En cuanto a la sensibilidad al género o a la temática concreta de los textos, se pueden distinguir dos tipos de TA: la de propósito general y la de propósito específico o ajustada a la tarea. La TA de propósito general (es decir, sistemas como por ejemplo Google, Microsoft Translator, DeepL, etc.)

trata de satisfacer las necesidades de todo el mundo y de cualquier tipo de texto: en general es gratuita o casi gratuita, pero no puede satisfacer plenamente las necesidades de una determinada tarea de traducción, puesto que trata de abordar todas al mismo tiempo. La TA es cada vez mejor en el uso del cotexto (texto adyacente), pero todavía está lejos de poder considerar el contexto (el conjunto de circunstancias de comunicación que también contribuyen a la interpretación del texto). La TA de propósito especial o ajustada a la tarea puede ser mejor para la traducción de textos en un género o de un tema en particular, pero en general se tiene que pagar para tener acceso a ella; de hecho, hay negocio en la adaptación de la TA para tareas específicas. Un sistema TA muy ajustado a una tarea puede ahorrar a los traductores las partes aburridas (mecánicas) de su trabajo: proporciona traducciones en bruto rápidas y asequibles, prácticamente no comete errores tipográficos u ortográficos, y tiende a ser terminológicamente consistente.

[cabecera](#)


¶ Aproximaciones a la TA

Como hemos visto más arriba, las tecnologías de traducción automática se pueden dividir de manera general en dos grupos: la TA basada en reglas y la basada en corpus, esta última con dos variedades principales: la TA estadística y la neuronal. Es importante tener en cuenta que la mayoría de los sistemas de traducción automática actuales simplifican el problema de traducir un texto a traducir sus oraciones una a una (esto va cambiando en la TA neuronal). Esta visión “miope” del texto, sin embargo, no solo se encuentra en la traducción automática: en la traducción asistida por ordenador, las memorias de traducción suelen funcionar con unidades de traducción de tamaño aproximadamente oracional.

Traducción automática basada en reglas (TABR)

La traducción automática basada en reglas (TABR), el enfoque dominante de la traducción automática desde los primeros intentos de los años cincuenta hasta los años noventa, todavía se puede encontrar en sistemas como [Apertium](#). La traducción automática basada en reglas progresa a partir de la traducción palabra a palabra, añadiendo reglas que pueden incluir o no toda la oración.

Para desarrollar un sistema de TABR, por un lado, los expertos en traducción recopilan diccionarios en forma electrónica y escriben reglas que analizan el texto de partida y transforman las estructuras de la lengua de partida en estructuras equivalentes de la lengua de llegada. Los expertos tienen que convertir el conocimiento intuitivo e incompletamente formalizado de los traductores profesionales sobre la tarea de traducción en reglas que se tienen que codificar de una manera eficientemente computable; esto puede conducir a simplificaciones bastante radicales, que, aun así, si se eligen bien, pueden ser útiles en la mayoría de los casos. Por otro lado, los expertos en informática escriben programas (llamados *motores* de TA) que



La traducción automática basada en reglas es habitualmente indirecta y opera en tres etapas: análisis, transferencia y generación. Cuando el análisis es tan profundo que la

consultan diccionarios y aplican (en el orden previsto) las reglas en el texto de partida para analizarlo y traducirlo.

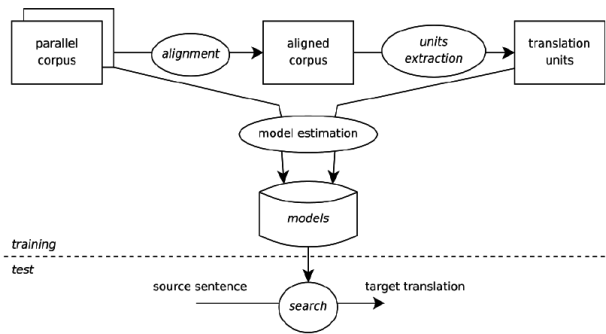
transferencia no es necesaria, tenemos sistemas de interlingua.

Los enfoques históricos de la traducción automática, como los llamados enfoques *directos* o *transformadores* (*transformer*), empezaban con una traducción aproximadamente palabra a palabra seguida de unas reglas de *acabado* que intentaban convertirla en un texto gramatical en la lengua de llegada. En la actualidad, sin embargo, la mayoría de sistemas de traducción automática basados en reglas se pueden describir siguiendo un enfoque de *transferencia* de tres etapas: en la primera, el *análisis*, se analiza el texto fuente (morfológica, sintáctica y semánticamente) y se genera una representación abstracta en la lengua de partida; la segunda etapa, la *transferencia*, sustituye los ítems léxicos de la lengua de partida por ítems léxicos de la lengua de llegada (*transferencia léxica*) y transforma las estructuras de la lengua de partida en estructuras de la lengua de llegada (*transferencia estructural*) para generar una representación abstracta en la lengua de llegada; finalmente, la tercera etapa, la *generación*, es la que produce texto real en la lengua de llegada. En el caso extremo en que el análisis y la generación son tan profundas que las representaciones abstractas de las lenguas de partida y de llegada son la misma y no hace falta transferencia, hablamos de sistemas de *interlingua* (el término *interlingua* designa en realidad esta representación abstracta lingüísticamente neutral).

El resultado de los sistemas de TABR suele ser consistente, pero mecánico y carente de fluidez. La TABR es conocida por sus problemas a la hora de resolver ambigüedades, tanto léxicas (“quieren” → “desean” / “se desplazan por los aires”) como sintácticas/estructurales (“Vendí las naranjas que compré a Fermín” → “he vendido a Fermín unas naranjas: las naranjas que compré a otra persona” / “Vendí a otra persona unas naranjas: las naranjas que compré a Fermín”). La personalización de la TABR para obtener un sistema de propósito específico o ajustado a la tarea es bastante costosa, puesto que requiere el trabajo de expertos que editen los diccionarios y las reglas.

Traducción automática estadística

La traducción automática estadística fue el primer enfoque de la traducción automática basada en corpus (TABC). A menudo se menciona a Pierre Isabelle (Isabelle, Dymetman, Foster *et al.* [1993](#): 205) por haber dicho que «las traducciones existentes contienen más soluciones a más de problemas de traducción que cualquier otro recurso disponible». Esta es la idea fundamental que hay detrás de la traducción automática basada en corpus, un enfoque en crecimiento constante desde mediados de los años noventa. Los programas de traducción automática basados en corpus *aprenden* a traducir a partir de enormes corpus de textos bilingües donde centenares de miles o millones de oraciones en una lengua se han emparejado o alineado con su traducción a otra lengua (es decir, enormes *memorias de traducción*); en algunos enfoques, también se pueden utilizar corpus monolingües en la lengua de llegada (no traducidos). En el caso de la traducción automática basada en corpus, el papel de los expertos en traducción puede parecer menos importante hasta que se tiene en cuenta el hecho que los corpus de entrenamiento contienen el trabajo de traductores (idealmente, pero desgraciadamente no siempre, de traductores profesionales). Estos corpus tan grandes pocas veces están disponibles para idiomas o dominios menos traducidos, y esto restringe la aplicabilidad de la TA basada en corpus.



Traducción estadística (Karan Singla 2015).

determinada a la oración de llegada).

Los sistemas de traducción automática estadística se entrenan sobre un corpus grande de texto bilingüe alineado oración a oración y, opcionalmente, un corpus de texto monolingüe en la lengua de llegada todavía mayor. Cuanto más grandes son los corpus, mejor se representa estadísticamente cada ítem posible de traducción (palabra, estructura, transformación); es decir, cuanto mayores son los corpus, más probable es que cubran palabras y estructuras que aparecerán en textos futuros.

El entrenamiento genera (a) diccionarios probabilísticos que contienen palabras y segmentos de más de una palabra, donde se asocian probabilidades a unidades de traducción como por ejemplo (“pursuant to”, “de acuerdo con”), la cual es muy probable o (“pursuant to”, “excepto en el caso de”), que es bastante improbable; (b) modelos que asignan probabilidades a cada posible secuencia de palabras en la lengua de llegada (de forma que “dos de cada tres son” es más probable que “dos son tres cada de”) y, finalmente, modelos probabilísticos de reordenación de palabras (por ejemplo, para obtener “el coche nuevo de Peter” a partir de “Peter’s new car”).

Utilizando estas correspondencias entre secuencias breves de palabras de partida y de llegada aprendidas del corpus de entrenamiento (las cuales habitualmente se denominan *parejas de frases* aunque no tengan que ser *frases* en sentido lingüístico), la TA estadística cubre la oración de partida con las *frases* de partida de todas las maneras posibles, concatena las *frases* de llegada correspondientes en casi todas las formas posibles y elige la manera más probable (más verosímil) de hacerlo.

Por ejemplo, la oración en euskera

Hilaren 21ean irekiko dute Ipar eta Hego Euskal Herriaren arteko muga

se podría traducir al inglés por

The border between the North and South Basque Country will be opened on the 21st of this month

utilizando algunos de los millones de pares de *frases* extraídos automáticamente de un corpus vasco–inglés como por ejemplo

1. Hilaren→of this month
2. 21ean→on the 21st

3. arteko muga→the border between
4. Euskal Herriaren→Basque Country
5. Ipar eta Hego→North and South
6. irekiko dut→will be opened

dividiendo primero el texto de partida como

Hilaren / 21ean / irekiko dute / Ipar eta Hego / Euskal Herriaren / arteko muga

y usando después el modelo de lengua de llegada para elegir posibles ordenaciones de los elementos

1. *of this month*
2. *on the 21st*
3. *will be opened*
4. *North and South*
5. *Basque Country*
6. *the border between*

y llegar a una reordenación razonable

On the 21st of this month the border between the North and South Basque Country will be opened.

Pero, ¿cómo se utilizan para traducir las probabilidades de traducción y de la lengua de llegada obtenidas de corpus paralelos? Se utilizan como *puntuaciones parciales* que se combinan para cada posible traducción candidata de la oración y se ponderan mediante un tipo de *baremo* que asigna una puntuación global a cada posible traducción de una oración determinada: la mejor traducción será la que obtenga la mejor puntuación global. Obviamente, no todas las traducciones posibles se puntúan (pero muchas sí; se usan aproximaciones para buscar solo entre las que son, a priori, las más probables). Esta *baremación* es un proceso computacional muy intenso; es por eso que la TA estadística solo es factible desde hace unos veinte años. Antes, los ordenadores no eran lo bastante rápidos y no podían almacenar las tablas de parámetros de los grandes modelos probabilísticos que se usan.

Como se ha dicho más arriba, el *baremo* tiene pesos para cada puntuación parcial, pero ¿cuáles son estos pesos? El ajuste de estos pesos se hace generalmente sobre una pequeña parte del corpus bilingüe que no ha sido utilizada para el entrenamiento (el llamado corpus de desarrollo); cada oración de este corpus se traduce a la lengua de llegada usando valores diferentes para los pesos, y la similitud del resultado traducido automáticamente se compara automáticamente y cuantitativamente con la traducción que hay en el lado de llegada del corpus de desarrollo. A continuación, se eligen los pesos para que esta similitud sea lo más ajustada posible para todo el corpus. La evaluación de esta similitud es en general bastante cruda; la medida más popular de este tipo, denominada BLEU (Papineni, Roukos, Ward *et al.*, 2002) cuenta las coincidencias de los grupos de una sola palabra, de dos palabras, de tres palabras, etc., entre la oración traducida automáticamente y la traducción de referencia y las combina en una única medida que oscila entre 0 (cuando no hay ninguna relación) y el 100% (cuando la concordancia es exacta). Como resultado, una propiedad importante de las traducciones estadísticas es que se asemejan a las que se

encuentran en los corpus de entrenamiento, lo que proporciona una clara oportunidad para la personalización mediante la selección de material de entrenamiento adecuado.

Como se ha dicho anteriormente, prácticamente no hacen falta expertos en traducción para construir un sistema de traducción automática estadística: los expertos eran los que produjeron las traducciones utilizadas para entrenarlo y ajustarlo.

La traducción automática estadística también tiene limitaciones importantes. Una de ellas es que las traducciones pueden parecer muy fluidas (a causa del peso en el baremo del modelo de probabilidad de la lengua de llegada), pero también pueden ser infieles, por ejemplo, porque contienen palabras adicionales innecesarias o porque faltan palabras necesarias.

Traducción automática neuronal

La nueva TA neuronal se empezó a explotar comercialmente en 2016. Se basa en redes neuronales artificiales que se inspiran (vagamente) en la forma en que el cerebro aprende y generaliza. En este caso, aprenden y generalizan a partir de la observación de corpus bilingües (Forcada [2017](#), Casacuberta & Peris [2017](#)). De hecho, los principales sistemas en línea públicamente disponibles de Google, Microsoft, etc., se han convertido en neuronales y, además, hay nuevos sistemas “nacidos neuronales”, como por ejemplo DeepL.

Se suele decir que la traducción automática neuronal necesita más datos que la TA estadística (Koehn & Knowles [2017](#)), pero estas afirmaciones han estado recientemente puestas en cuestión (Sennrich & Zhang [2019](#)). También se suele ver que es más sensible que la traducción automática estadística en el ruido en los datos (es decir, cuando los datos contienen pares de oraciones que no se pueden considerar traducciones mutuas) (Belinkov & Bisk 2018).

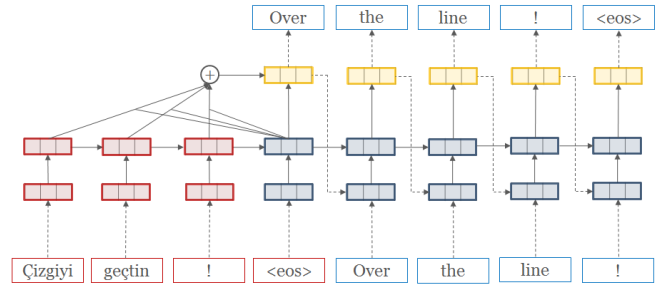
La TA neuronal se considera competitiva frente a la TA estadística en muchas aplicaciones (Koehn & Knowles 2017, Sennrich & Zhang [2019](#)), pero las evaluaciones comparativas completas en aplicaciones reales todavía son escasas (véase, por ejemplo, Jia, Carl & Wang 2019; Shterionov, Superbo, Nagle *et al.* 2018; Klubička, Toral & Sánchez-Cartagena 2018).

Cómo se ha dicho más arriba, la TA neuronal se llama así porque se realiza mediante un *software* que simula grandes redes de *neuronas artificiales*, las cuales, a su vez, son versiones altamente simplificadas de las neuronas biológicas. La activación o la excitación de una neurona artificial depende de la activación de otras neuronas artificiales y de la intensidad de las conexiones a través de las cuales reciben sus señales (y las posibles señales de entrada provenientes del exterior). Las señales que provienen de neuronas excitadas a través de conexiones positivas tenderán a excitar las neuronas que las reciben; las señales procedentes de neuronas inhibidas o deprimidas mediante conexiones positivas tenderán a inhibirlas. Con conexiones negativas, el comportamiento es el opuesto.

Para que una red neuronal concreta tenga un comportamiento específico —es decir, patrones específicos de activación de las neuronas de la red— cuando se procesa una

serie de ejemplos de aprendizaje, la red se tiene que entrenar modificando las intensidades de las conexiones.

En las redes neuronales artificiales, las neuronas suelen formar *capas*, es decir, grupos de neuronas que reciben señales solo de las neuronas de la capa anterior y envían señales solo a las neuronas de la capa siguiente. Se dice que el *aprendizaje profundo* se produce cuando hay muchas de estas capas, es decir, cuando el aprendizaje es realizado por una red neuronal *profunda*.



Estructura de un sistema de TA neuronal: la oración “Çizgiyi geçtin!” se traduce como “Over the line” (<eos> es el marcador de final de oración).

Un concepto importante en las redes neuronales es el de la *representación*. Se dice que los valores de activación de las neuronas de una capa forman una representación de la información que procesan. Por ejemplo, en una red neuronal entrenada, el *vector* o lista o de longitud fija (0,35, 0,28, -0,15, ... 0,88), donde cada uno de los (posiblemente centenares de) valores representa la activación de las neuronas en una capa, podría formar la representación de la palabra *estudio*, mientras que (-0,35, 0,90, -0,12 ... 0,73) podría ser la de la palabra *serpiente*. Las representaciones aprendidas suelen tener propiedades interesantes. A menudo los conceptos similares tienen representaciones matemáticamente similares, lo que se podría interpretar como si la red neuronal aprendiera su semántica durante el entrenamiento.

La mayoría de las arquitecturas de traducción automática neuronal leen secuencialmente una a una las palabras de la oración de partida para construir progresivamente una representación de toda la oración (*codificación*) y, una vez construida, extraen una a una las palabras de la oración de llegada (*descodificación*), teniendo en cuenta las palabras de llegada ya escritas. Más precisamente, en cada paso, cada unidad del descodificador calcula, para todas las palabras del vocabulario, la probabilidad de cada palabra posible de llegada y, en general, se selecciona la palabra más probable, de una forma que recuerda la característica de predicción de la siguiente palabra que encontramos en el teclado de nuestros *smartphones*.

Hay una amplia variedad de diseños de TA neuronal: *arquitecturas recurrentes codificador–descodificador* (Sutskever, Vinyals & Le [2013](#)), arquitecturas suplementadas con mecanismos de atención donde se examina cada paso del proceso de construcción de las representaciones de las oraciones cada vez que se produce una palabra en la lengua de llegada (Bahdanau, Cho & Bengio [2015](#)) o incluso arquitecturas *transformadoras* (*transformer*, Vaswani, Shazeer, Parmar *et al.* 2017) donde no se construye una representación explícita de toda la oración original y donde se presta atención también a las palabras de llegada ya escritas.

La TA neuronal es una tecnología completamente nueva y esto tiene implicaciones importantes. Por un lado, requiere hardware especializado y potente, puesto que los cálculos necesarios para simular redes neuronales artificiales con muchos miles de unidades y con millones de conexiones son matemáticamente muy intensos. En particular, se suele añadir a ordenadores especializados una evolución de las tarjetas gráficas por ordenador denominadas GPU (*graphic processing units*, unidades de procesamiento gráfico). Como se ha mencionado, se suele decir que los sistemas de

TA neural requieren grandes cantidades de datos para el aprendizaje bilingüe. Ni este *hardware* especializado ni la gran cantidad de datos de entrenamiento suelen estar disponibles para la mayoría de los traductores profesionales, que por lo tanto tienen que recurrir a terceros para entrenar sistemas neuronales de TA y después ejecutarlos. Esto, de hecho, constituye un modelo de negocio en la industria de la traducción, como ya sucedía en el caso de la TA estadística; las empresas de TA neuronal pueden añadir las memorias de traducción del cliente a sus corpus bilingües generales para crear un sistema de TA ajustado a la tarea.

Pero, por otro lado, la TA neuronal también produce un tipo de producto bastante diferente. En primer lugar, como la descodificación parte de representaciones de la oración completa, es difícil saber de dónde viene cada palabra de llegada (en TA estadística, se puede rastrear fácilmente las *frases* de partida correspondientes a cada *frase* de llegada). En segundo lugar, como pasaba con la TA estadística, la TA neuronal puede producir de vez en cuando textos gramaticalmente naturales que no son, aun así, una traducción de la oración de partida y, de hecho, la traducción neural lo hace más a menudo. Los errores son generalmente de naturaleza semántica: las palabras que no se han visto durante el entrenamiento se pueden sustituir por palabras con un significado similar (*widget*→*dispositivo*), incluso con resultados peligrosos (*Túnez* →*Noruega*); incluso se pueden producir paráfrasis (*Michael Jordan* → *el escolta de los Chicago Bulls*). Para mitigar el problema de la traducción de palabras que no se han visto durante el entrenamiento, el material de entrenamiento se suele segmentar automáticamente en unidades subléxicas, circunstancia que puede llevar al sistema a producir palabras inventadas como por ejemplo *ingenieraje* (por *ingeniería*) o *reclutación* (por *reclutamiento*), contruidos a partir de traducciones subléxicas de las unidades subléxicas de partida. Todo esto quiere decir que los profesionales que poseen el resultado de la TA tienen que prestar todavía más atención, puesto que es probable que los errores sean bastante sutiles.

[cabecera](#)

¶ Corpus para la traducción automática

La elaboración y la gestión de los corpus necesarios para entrenar sistemas de traducción automática basada en corpus (estadística o neuronal) presenta retos importantes:

- Hay que conseguir y montar colecciones muy grandes de textos paralelos, es decir, textos en una lengua con un texto equivalente en la otra lengua. Es posible que esto no esté disponible para algunas lenguas o para algunos géneros de texto.
- Garantizar que un texto es una traducción adecuada de otro texto puede no ser una cuestión trivial en algunos casos (puesto que la reutilización de los textos puede haber causado que partes de estos no sean una traducción en sentido estricto). Cuando se recopila texto de sitios web multilingües, la alineación de cada documento con su traducción se tiene que hacer automáticamente y la tarea es propensa a errores.
- Después, se tiene que segmentar el texto bilingüe en oraciones y alinearlas oración a oración (con la excepción de las memorias de traducción producidas en entornos de traducción asistida por ordenador, que ya vienen alineadas). Para colecciones tan grandes, se tiene que recurrir a la segmentación automática (mediante reglas sencillas basadas en la puntuación y el formato) y la alineación automática de oraciones (mediante métodos estadísticos), los cuales pueden introducir errores.

- El entrenamiento de sistemas de traducción automática requiere reunir un conjunto de desarrollo con unos cuantos miles de pares de oraciones —que sean tan representativas como sea posible de las que traducirá el sistema entrenado— para guiar el entrenamiento y obtener indicadores de rendimiento.

Cada oración a ambos lados del corpus paralelo se tiene que segmentar en unidades más pequeñas llamadas *tokens*. En las lenguas no es demasiado difícil segmentar la mayoría de un texto en *tokens* léxicos (palabras) mediante la puntuación, los separadores (espacios en blanco, tabuladores, marcadores de final de línea) y algunas reglas sobre contracciones, etc. Pero hay idiomas que se escriben en *scriptio continua* y requieren el uso de procesadores lingüísticos adicionales (por ejemplo, basados en diccionarios) para segmentarlas. Más recientemente, las oraciones se dividen automáticamente en tokens que son unidades subléxicas mediante métodos estadísticos o neuronales, independientemente de la lengua..

[cabecera](#)

¶ Evaluación de la traducción automática

Para evaluar una traducción automática, hay que tener en cuenta la finalidad. Consideremos primero un escenario de adopción, en el que queremos decidir si utilizaremos la traducción automática o qué sistema de traducción automática escogeremos. Lo ideal sería intentar idear un experimento que sea representativo de la tarea real donde esperamos que ayude la TA y, a continuación, medir la utilidad del resultado de la traducción automática en esta tarea. Como se ha dicho anteriormente, la traducción automática se puede aplicar con fines de *asimilación* o *difusión*. Históricamente, la evaluación de la traducción automática ha sido un tema controvertido y, por lo tanto, hay muchos enfoques.

Consideremos primero una situación de *asimilación* (o *gisting*) en la cual las instrucciones para realizar una tarea (una receta de cocina, instrucciones para instalar y configurar una aplicación para teléfonos móviles) son el resultado de la TA en bruto. Una medida del éxito en la tarea asociada es claramente un indicador de la utilidad de la traducción automática. Hay que tener en cuenta, que, por un lado, muchos usos de la traducción automática no tienen asociada una tarea muy definida (navegar por el catálogo de una tienda en línea, leer noticias deportivas de otro país, navegar por un foro sobre la menopausia) y que, por otro lado, establecer un experimento representativo con suficiente texto, temas y situaciones puede resultar muy costoso. Una aproximación posible consiste en usar los métodos típicos utilizados en la enseñanza de segundas lenguas: después de leer un texto traducido automáticamente, los sujetos pueden responder a cuestionarios de comprensión lectora (Jones, Shen & Herzog 2009; Scarton & Specia 2016) con preguntas en la lengua de llegada (que también son bastante costosas de preparar), o tests con espacios en blanco (*cloze test*) en que se pide a los sujetos que completen oraciones traducidas profesionalmente en las cuales algunas palabras han sido borradas (Forcada, Scarton, Specia *et al.* 2018, un poco más económico si hay traducciones disponibles de porciones del texto de partida).

En las aplicaciones de *difusión*, la traducción automática será utilizada por los traductores profesionales, sea como materia prima que posteriormente editarán para producir una traducción adecuada al propósito, o como fuente de inspiración. La evaluación puede parecer bastante sencilla: después de seleccionar un conjunto de textos representativos, se pide a un grupo de

traductores que los traduzcan de cero o con la ayuda de uno o más sistemas de traducción automática, y después se mide el esfuerzo que los ha costado producir la traducción en cada situación. Por ejemplo, se podría medir el tiempo que tardan en traducir mil palabras o, a la inversa, medir la productividad, es decir, cuántas palabras traducen por hora. Si un sistema de traducción automática es útil, los traductores traducirán más rápidamente que sin él; si el sistema de traducción automática *A* es mejor que el sistema de traducción automática *B*, la productividad con *A* será mayor que con el *B*. Obtener resultados significativos puede implicar el encargo de tareas de traducción costosas a varios traductores, circunstancia que hace que esta evaluación también sea bastante cara.

Muchos enfoques de evaluación intentan mitigar el coste de las medidas obtenidas durante la realización de tareas. Una manera de hacerlo es recopilando *juicios subjetivos*, normalmente independientemente de la tarea. Recientemente se ha popularizado la llamada *evaluación directa* (*direct assessment*: Graham, Baldwin, Moffat *et al.* [2017](#)): se muestra una traducción profesional de una oración a una multitud de usuarios monolingües en la lengua de llegada (por ejemplo, en gris) y una traducción automática de la misma oración (por ejemplo, en negro) y se les pregunta hasta qué punto concuerdan con la afirmación de que “el texto negro expresa adecuadamente el significado del texto gris” y se les muestra un control deslizante (*slider*) que pueden situar entre el 0% y el 100%. El procesamiento estadístico (y a veces el filtrado) de muchos juicios subjetivos de este tipo conduce a indicadores que han demostrado una correlación razonable con las medidas reales de utilidad.

Pero, ¿qué hacer si se quiere evaluar la traducción automática, no antes de adoptarla, sino durante el desarrollo, repetidamente para diferentes versiones de un sistema? Entonces, todos los métodos anteriores, que implican configuraciones costosas y personas en las pruebas, dejan de ser aplicables. En particular, imaginemos que se está entrenando una traducción automática estadística o neuronal: habría que medir el rendimiento periódicamente durante el entrenamiento, por ejemplo, para decidir cuándo dejar de entrenar (de forma que el sistema no memorice demasiado profundamente). Esto requiere métricas de evaluación automática, que normalmente funcionan de la siguiente manera: un conjunto de desarrollo de, por ejemplo, un par de miles de oraciones en la lengua de partida combinadas con traducciones profesionales de referencia en la lengua de llegada se traducen automáticamente con el sistema que se desarrolla y la similitud entre el resultado traducido automáticamente y la traducción de referencia (o las traducciones de referencia, si el proyecto se puede permitir más de una traducción profesional) se determina automáticamente mediante un sencillo indicador (por ejemplo, calculando cuántas ediciones serían necesarias a través de indicadores como la tasa de error en palabras (*word error rate*) para producir la referencia (más próxima), o cuántos tramos de una, dos, tres y cuatro palabras aparecen tanto en el resultado del sistema de TA como en las referencias, tal como se hace por ejemplo en el indicador popular denominado BLEU que se mencionó anteriormente). Se ha demostrado que la correlación de estos indicadores con la utilidad real es limitada, pero de todos modos se utilizan masivamente dada su fácil aplicación e incluso a veces se presentan como indicadores reales de calidad de la traducción automática cuando se calculan sobre conjuntos de prueba independientes. Hay que tener en cuenta también que no son tampoco excesivamente baratos, puesto que requieren la existencia previa de un conjunto considerable de traducciones de referencia.

De hecho, hay un campo de investigación denominado *estimación de la calidad de la traducción automática* que estudia formas de predecir la utilidad de la traducción automática cuando no se tienen traducciones profesionales de referencia, simplemente examinando el texto original y el resultado traducido automáticamente (Specia & Shah 2018).

[cabecera](#)

Potencial para la investigación

Desde la aparición de la traducción automática basada en corpus, el papel histórico de los lingüistas y de los expertos en traducción se considera accesorio, puesto que la mayoría de las investigaciones sobre el funcionamiento de los sistemas de traducción automática son realizadas por investigadores con formación científica o tecnológica (ingenieros informáticos, estadísticos, científicos de datos, etc.).

Sin embargo, para aquellos pares de lenguas (y géneros de texto) que no se pueden permitir los corpus paralelos de las dimensiones necesarias para entrenar sistemas basados en corpus, la traducción automática basada en reglas puede ser una alternativa. Aquí todavía hacen falta traductores y lingüistas para crear y gestionar los diccionarios y los conjuntos de reglas. Este es el caso, por ejemplo, de Apertium (Forcada, Ginestí-Rosell, Nordfalk *et al.* 2011), una plataforma de traducción automática colaborativa y abierta, que se centra en idiomas con menos recursos y permite hacer investigaciones sobre traducción automática.

La mayoría de las investigaciones sobre traducción automática basadas en corpus son hoy en día investigaciones de traducción automática neuronal y tienen un fuerte componente tecnológico. He aquí algunos ejemplos:

- nuevas *arquitecturas*, es decir, diseños de redes neuronales o estrategias de entrenamiento;
- entrenamiento de sistemas de traducción automática con poco o ningún contenido paralelo (bilingüe) (traducción automática *monolingüe* o *no supervisada*); generación de datos sintéticos adicionales: por ejemplo, generación de datos sintéticos adicionales en la lengua de partida a partir de datos naturales en la lengua de llegada mediante el entrenamiento de un sistema de traducción automática inversa (llegada→partida) (datos retrotraducidos; Sennrich, Haddow & Birch [2016](#));
- algoritmos de entrenamiento más eficientes (importante si se tiene en cuenta que los sistemas de traducción automática neuronal actuales tienen que examinar múltiples veces todo el conjunto de datos de entrenamiento antes de empezar a aprender algo);
- utilizar más cotextos (contexto inmediato del documento) y contexto (imágenes, diagramas, etc.) como entrada para el procesamiento de cada oración;
- traducción condicionada, de forma que el texto traducido automáticamente cumpla las restricciones de un determinado medio, como por ejemplo los subtítulos o los elementos de menú.

Pero incluso sin entrar en estos aspectos técnicos de los sistemas de traducción automática, hay una amplia variedad de aspectos sobre cómo se despliega la traducción automática en el mundo real que abre vías a la investigación de traductores y lingüistas.

En los escenarios de *asimilación*, es decir, los más habituales en que la gente normal la consume en bruto:

- Metodologías de evaluación basadas en juicios o medidas y su capacidad para predecir la utilidad o aceptabilidad real del texto traducido automáticamente en una variedad de escenarios y tareas.
- Comprender cómo las personas hacen uso de la traducción automática en bruto, ya sea observando su comportamiento (seguimiento de la mirada (*eye-tracking*), registro de acciones hechas con el teclado (*key-logging*) y el ratón) o pidiéndoles que informen (protocolos de reflexión en voz alta, cuestionarios posteriores a la tarea); evaluar la activación de estrategias metacognitivas para tratar el contenido traducido automáticamente y la relación con el procesamiento de texto producido por hablantes no nativos, etc.; estudiando la aceptabilidad y las actitudes hacia la TA, etc.

En los escenarios de difusión, es decir, cuando los traductores profesionales utilizan la traducción automática como ayuda:

- Mejorar las metodologías usadas para medir posibles reducciones en el esfuerzo de traducción, especialmente durante la posesición.
- Estudios traductológicos de la naturaleza del texto producido por los sistemas de traducción automática (por ejemplo, la capacidad de los sistemas neuronales para realizar operaciones como reducciones y expansiones del modo en que lo hacen los traductores profesionales).
- Estudiar la capacidad de los indicadores de evaluación (automáticos y manuales, obtenidos a partir de juicios y medidas, etc.) para predecir el esfuerzo de posesición y la mejora de estos indicadores.
- Integración de uno o más sistemas de traducción automática y otras tecnologías de traducción en entornos de traducción asistida por ordenador usados por profesionales y agencias independientes; selección automática de la tecnología más conveniente ("intermediación tecnológica") para cada profesional, para cada trabajo de traducción o incluso para cada segmento; ergonomía, cambios en los flujos de trabajo de traducción, aceptabilidad y su efecto sobre la productividad real, etc.

En ambos escenarios, se necesitan estudios lingüísticos y traductológicos sobre los tipos de errores producidos por cada tipo de tecnología de traducción automática y su efecto sobre la utilidad del resultado.

Finalmente, el uso de la traducción automática en el aprendizaje de lenguas asistido por ordenador o, particularmente, en la formación real de los traductores, se ha vuelto muy importante a la vista del hecho de que actualmente los sistemas de traducción automática están fácilmente disponibles prácticamente para cualquier estudiante que tenga conexión a Internet.

[cabecera](#)

Referencias



Bahdanau, Dzmitry; Kyunghyun Cho & Yoshua Bengio. 2014. "Neural machine translation by jointly learning to align and translate." @ arXiv preprint arXiv:1409.0473. [\[+info\]](#) [\[quod vide\]](#)

Belinkov, Yonatan & Yonatan Bisk. 2017. "Synthetic and natural noise both break neural machine translation." @ *Proceedings of the 6th international conference on learning representations ICLR 2018*. [\[+info\]](#) [\[quod vide\]](#)

Brown, Peter F.; John Cocke; Stephen Andrew Della Pietra; Vincent Joseph Della Pietra; Frederick Jelinek; Robert Leroy Mercer & Paul S. Roossin. 1988. "A statistical approach to language translation". @ *Proceedings of the 12th international conference on computational linguistics COLING-88*, Budapest, 1988, 71-76. <https://doi.org/10.3115/991635.991651> [\[+info\]](#) [\[quod vide\]](#)

*Casacuberta Nolla, Francisco & Álvaro Peris Abril. 2017. "Traducció automàtica neuronal". @ *Tradumàtica* 15, 66-74. <https://doi.org/10.5565/rev/tradumatica.203> [\[+info\]](#) [\[quod vide\]](#)

Forcada, Mikel Lorenzo; Mireia Ginestí-Rosell; Jakob Nordfalk; Jim O'Regan; Sergio Ortiz Rojas; Juan Antonio Pérez Ortiz; Felipe Sánchez Martínez; Gema Ramírez Sánchez & Francis M. Tyers. 2011. "Apertium: A free/open-source platform for rule-based machine translation". @ *Machine translation* 25/2, 127-144. <https://doi.org/10.1007/s10590-011-9090-0> [\[+info\]](#)

*Forcada Zubizarreta, Mikel Lorenzo. 2017. "Making sense of neural machine translation". @ *Translation spaces* 6/2, 291-309. <https://doi.org/10.1075/ts.6.2.06for> [\[+info\]](#) [\[quod vide\]](#)

Forcada Zubizarreta, Mikel Lorenzo; Carolina Scarton; Lucia Specia; Barry Haddow & Alexandra Birch. 2018. "Exploring gap filling as a cheaper alternative to reading comprehension questionnaires when evaluating machine translation for gisting". @ *Proceedings of the 3rd conference on machine translation WMT18*, Brussels, 2018, 192-203. <https://doi.org/10.18653/v1/W18-6320> [\[+info\]](#) [\[quod vide\]](#)

Graham, Yvette; Tim Baldwin; Alistair Moffat & Justin Zobel. 2017. "Can machine translation systems be evaluated by the crowd alone". @ *Natural language engineering* 23/1, 3-30. <https://doi.org/10.1017/S1351324915000339> [\[+info\]](#) [\[quod vide\]](#)

*Hutchins, William John & Harry L. Somers. 1992. *An introduction to machine translation*. London: Academic Press. [\[+info\]](#)

Isabelle, Pierre; Marc Dymetman, George Foster; Jean-Marc Jutras; Elliott Macklovitch; François Perrault; Xiaobo Ren & Michel Simard. 1993. "Translation analysis and translation automation". @ *Proceedings of the fifth international conference on theoretical and methodological issues in machine translation TMI'93: MT in the Next Generation* (Kyoto, 1993), 15-22. [\[+info\]](#) [\[quod vide\]](#)

Jia, Yanfang; Michael Carl & Xiangling Wang. 2019. "Post-editing neural machine translation versus phrase-based machine translation for English-Chinese". @ *Machine translation* 33/1-2, 9-29. <https://doi.org/10.1007/s10590-019-09229-6> [\[+info\]](#)

*Jones, Douglas; Wade Shen & Martha Herzog. 2009. "Machine translation for government applications". @ *Lincoln laboratory journal* 18/1, 41-53. [\[+info\]](#) [\[quod vide\]](#)

Klubička, Filip; Antonio Toral Ruiz & Víctor Sánchez Cartagena. 2018. "Quantitative fine-grained human evaluation of machine translation systems: A case study on English to Croatian". @ *Machine translation* 32/3, 195-215. <https://doi.org/10.1007/s10590-018-9214-x> [\[+info\]](#)

Koehn, Philipp & Rebecca Knowles. 2017. "Six challenges for neural machine translation". @ "Proceedings of the first workshop on neural machine translation", 28-39, Vancouver. <https://doi.org/10.18653/v1/W17-3204> [\[+info\]](#) [\[quod vide\]](#)

Kudo, Taku & John Richardson. 2018. "SentencePiece: A simple and language independent subword tokenizer and detokenizer for neural text processing". @ *Proceedings of the 2018 conference on empirical methods in natural language processing: System demonstrations*, 66-71. <https://doi.org/10.18653/v1/D18-2012> [\[+info\]](#) [\[quod vide\]](#)

Nagao, Makoto; Toyooki Nishida & Jun'ichi Tsujii. 1984. "Dealing with incompleteness of linguistic knowledge in language translation—transfer and generation stage of Mu machine translation project". @ *Proceedings of the 10th International Conference on Computational Linguistics and 22nd Annual Meeting of the Association for Computational Linguistics*, 420-427. <https://doi.org/10.3115/980491.980577> [\[+info\]](#) [\[quod vide\]](#)

Och, Franz Josef. 2012. "Breaking down the language barrier—six years in". Google official blog. [\[quod vide\]](#)

Kishore Papineni; Salim Roukos; Todd Ward & Wei-Jing Zhu. 2002. "BLEU: a method for automatic evaluation of machine translation". @ *Proceedings of the 40th annual meeting of the Association for Computational Linguistics*, 311-318. <https://doi.org/10.3115/1073083.1073135> [\[+info\]](#) [\[quod vide\]](#)

*Sager, Juan Carlos. 1994. *Language engineering and translation: Consequences of automation*. Amsterdam: John Benjamins. [\[+info\]](#)

Scarton, Carolina & Lucia Specia. 2016. "A reading comprehension corpus for machine translation evaluation". @ Calzolari, Nicoletta; Khalid Choukri, Thierry Declerck, Sara Goggi, Mario Grobelnik, Bente Maegarrd, Joseph Mariani, Helène Mazo, Asunción Moreno Bilbao, Jan Odijk & Stelios Piperidis, eds. 2016. *Proceedings of the tenth international conference on language resources and evaluation LREC'16* (Portorož), 3652-3658. [\[+info\]](#) [\[quod vide\]](#)

Sennrich, Rico; Barry Haddow & Alexandra Birch. 2016a. "Improving neural machine translation models with monolingual data". @ *Proceedings of the 54th annual meeting of the Association for Computational Linguistics 1: Long Papers*, 86-96. <https://doi.org/10.18653/v1/P16-1009> [\[+info\]](#) [\[quod vide\]](#)

Sennrich, Rico; Barry Haddow & Alexandra Birch. 2016b. "Neural machine translation of rare words with subword units". @ *Proceedings of the 54th annual meeting of the Association for*

Computational Linguistics, 1715-1725. <https://doi.org/10.18653/v1/P16-1162> [\[+info\]](#) [\[quod vide\]](#)

Sennrich, Rico & Biao Zhang. 2019. "Revisiting low-resource neural machine translation: A case study". @ Korhonen, Anna; David Traum & Lluís Màrquez (eds.) 2019. *Proceedings of the 57th Conference of the Association for Computational Linguistics (ACL 2019)*, 211-221. Firenze: Association for Computational Linguistics. <https://doi.org/10.18653/v1/P19-1021>. [\[+info\]](#) [\[quod vide\]](#)

Shterionov, Dimitar; Riccardo Superbo; Pat Nagle; Laura Casanellas; Tony O'Dowd & Andy Way. 2018. "Human versus automatic quality evaluation of NMT and PBSMT". @ *Machine Translation* 32/3, 217-235. <https://doi.org/10.1007/s10590-018-9220-z> [\[+info\]](#)

Specia, Lucia & Kashif Shah. 2018. "Machine translation quality estimation: Applications and future perspectives". @ Moorkens, Joss; Sheila Castilho, Federico Gaspari & Stephen Doherty, eds. 2018. *Translation quality assessment. Machine translation: Technologies and applications* 1, 201-235. Cham: Springer. https://doi.org/10.1007/978-3-319-91241-7_10 [\[+info\]](#)

Sutskever, Ilya; Oriol Vinyals & Quoc Viet Le. 2014. "Sequence to sequence learning with neural networks." @ Gharahmani, Zoubin; M. Welling & C. Cortes, eds. 2014. *Proceedings of advances in neural information processing systems 27: Annual conference on neural information processing systems*, Montreal, 3104-3112. [\[+info\]](#) [\[quod vide\]](#)

Tanaka, Hozumi; Shun Ishizaki; Akira Uehara & Hiroshi Uchida. 1989. "Research and development of cooperation project on a machine translation system for Japan and its neighboring countries". @ *Proceedings of the MT Summit II* (Munich), 16-18. [\[+info\]](#) [\[quod vide\]](#)

Vaswani, Ashish; Noam Shazeer; Niki Parmar; Jakob Uszkoreit; Llion Jones; Aidan N. Gomez; Łukasz Kaiser & Illia Polosukhin. 2017. "Attention is all you need." @ *Proceedings of the 31st conference on neural information processing systems NIPS 2017*, Long Beach, 5998-6008. [\[+info\]](#) [\[quod vide\]](#)

Weaver, Warren. 1949. "Translation". @ Locke, William N. & Andrew Donald Booth (eds.) 1955. *Machine translation of languages: Fourteen essays*, 15-23. Cambridge: MIT. [\[+info\]](#)

Créditos



Mikel L. Forcada Zubizarreta

Licenciado en ciencias en 1986 y doctorado en química en 1991. Desde 2002 es catedrático de universidad de Lenguajes y Sistemas Informáticos en la Universitat d'Alacant. Mikel Forcada fue presidente de la Asociación Europea de Traducción Automática (EAMT) desde 2015 hasta 2021. Desde el comienzo del milenio, sus intereses de investigación se han centrado principalmente en el campo de las tecnologías de la traducción. Es autor de más de 70 artículos y capítulos de libros, de los cuales cerca de 40 son sobre tecnologías de la traducción. En 2004, después de encabezar varios proyectos de traducción automática financiados pública y privadamente, inició la plataforma de traducción automática libre / de código abierto Apertium (con más de 40 pares de idiomas) y el proyecto de software libre / de código abierto Bitextor (que rastrea en Internet lugares para cosechar corpus paralelos). También es cofundador de la empresa Prompsit Language Engineering (2006).



Obra publicada con [Licencia Creative Commons Reconocimiento No comercial 4.0](#)

[Asociación Ibérica de Estudios de Traducción e Interpretación \(AIETI\)](#)