

Die neuronale didaktische Herausforderung: Berufsbild und Kompetenzen im Wandel

Abstract: Künstliche Intelligenz und Neuronale Netze haben bedeutende Fortschritte in der Maschinenübersetzung gebracht. Die Abhängigkeit statistischer und neuronaler MÜSysteme von einem Korpus an Übersetzungen, die vom Menschen in hoher Qualität angefertigt wurden, führt zu besseren Ergebnissen, die ihrerseits wiederum eine verstärkte Konkurrenz für die Humanübersetzung bedeuten. Die Notwendigkeit, aus diesem Teufelskreis auszubrechen, wird in diesem Beitrag anhand einer veränderten Schwerpunktsetzung der translatorischen Kompetenzen sowie einer Neuausrichtung der Ausbildung beschrieben. Das Berufsprofil wandelt sich vom ausführenden Übersetzen hin zur beratenden Dienstleistung, wobei das Übersetzen-Können zugunsten des Übersetzen-Planens in den Hintergrund gerückt wird.

Keywords: Maschinelles Übersetzen; Ausbildung; Zukunftschancen; Beruf Übersetzen

Die Entwicklung der maschinellen Übersetzung hat – aufbauend auf zwei Jahrzehnten Erfahrung mit statistischen Methoden – durch die Anwendung künstlicher Intelligenz und neuronaler Netze einen weiteren Entwicklungsschritt gemacht. Innerhalb von zwei Jahren haben die wichtigsten Online-Dienste ihre maschinellen Übersetzungssysteme auf die Basis neuronaler Netze gestellt und damit die Qualität ihrer Übersetzungen deutlich erhöht. Für das Selbstverständnis und die Berufschancen der Übersetzer*innen bringt diese Entwicklung bedeutende Veränderungen mit sich: Eine mögliche Verschiebung und Neudefinition bzw. Neubewertung der zentralen Kompetenzen des Berufes führt zu curricularen Überlegungen, die – in der Tradition der Translationswissenschaft stehend – eine Konzentration auf jene Aspekte des Übersetzens postulieren, die über eine reine Textarbeit hinausgehen. Dies sind insbesondere kulturelle, textsortenspezifische und vor allem translationsplanerische und -organisatorische Fähigkeiten. Nicht mehr die Vermittlung durchführender Tätigkeiten steht im Vordergrund einer solchen Wende, sondern die Kompetenz, Fragen der Mehrsprachigkeit und der daraus sich ergebenden translatorischen Aufgabenstellung innerhalb eines spezifischen organisatorischen bzw. institutionellen Rahmens unter Nutzung aller zur Verfügung stehenden technischen Möglichkeiten situationsadäquat einer für alle beteiligten Kommunikationspartner befriedigenden Lösung zuzuführen zu können.

Welche Folgen ergeben sich daraus für Übersetzer*innen und den Übersetzungsmarkt und wie kann, soll oder muss eine universitäre Ausbildung darauf reagieren? Auf diese Fragen versucht der folgende Beitrag einzugehen, wobei zunächst ein Überblick über die Technologie neuerer maschineller Übersetzungssysteme gegeben wird, worauf eine Abschätzung der potenziellen Auswirkungen und Folgen auf das berufliche Übersetzen folgt, die abschließend für die Übersetzer*innenausbildung aufgearbeitet werden.

Eine kurze Geschichte des Maschinellen Übersetzens

Ein kurzer historischer Ausflug in die Entwicklungsgeschichte der Maschinellen Übersetzung vermag die Bedeutung ihres Einflusses auf das berufliche Übersetzen darzustellen. Mit der Erfindung elektronischer Rechner begann nach dem zweiten Weltkrieg bereits das Bestreben, diese für das Übersetzen nutzen zu können (Somers 2011:284). Die erste öffentliche Vorführung eines automatischen Übersetzungssystems erfolgte 1954 durch die Zusammenarbeit von IBM und der Georgetown University in Washington. Dabei wurde eine russisch-englische Übersetzung anhand zweisprachiger Wörterbücher und rudimentärer grammatischer Regeln an einem Computerterminal durchgeführt und damit der Beginn der regelbasierten Übersetzungssysteme (RBMT) begründet (Hutchins 2005). Überzogene Hoffnungen führten in dem folgenden Jahrzehnt zu zahlreichen, hoch dotierten Forschungsprojekten, bis 1966 das von der US-Regierung eingesetzte Automatic Language Processing Advisory Committee (ALPAC) aufgrund mangelnden Fortschritts feststellte: „There is no immediate or predictable prospect of useful machine translation“ (ALPAC 1966:32). Damit wurde ein Umdenken in der Forschungsfinanzierung erzwungen, das in der Folge zur Entwicklung maschinengestützter Hilfsmittel für Humanübersetzer*innen führte.

In diesem Zeitraum entstanden die ersten großen Terminologiedatenbanken: Eurodicautom durch die Europäische Gemeinschaft und Termium durch die kanadische Regierung. Zeitgleich wurde jedoch auch der regelbasierte Ansatz des maschinellen Übersetzens weiterentwickelt und in der Praxis eingesetzt (Systran 1976 in der Europäischen Kommission, TAUM-Meteo in Kanada, verschiedene Forschungsansätze in der UDSSR (vgl. Marchuk 1984). In der Folge entstanden zahlreiche maschinelle regelbasierte Übersetzungssysteme mit verschiedenen Ansätzen der semantischen, morphologischen und syntaktischen Analyse sowie wissensbasierter Kognitionsforschung. Einen großen Einfluss auf den Übersetzungsmarkt und die Nachfrage nach professionellen Übersetzer*innen hatten diese Systeme aufgrund ihrer mangelhaften Qualität jedoch kaum.

Wesentlich bedeutsamer für die Produktivität und die Arbeitsweise des Menschen war die Entwicklung von Translation-Memory-Systemen gegen Ende der 1980er Jahre, wodurch den Übersetzer*innen einmal übersetzte Textsegmente ohne kognitiven Aufwand immer wieder zur Verfügung standen.

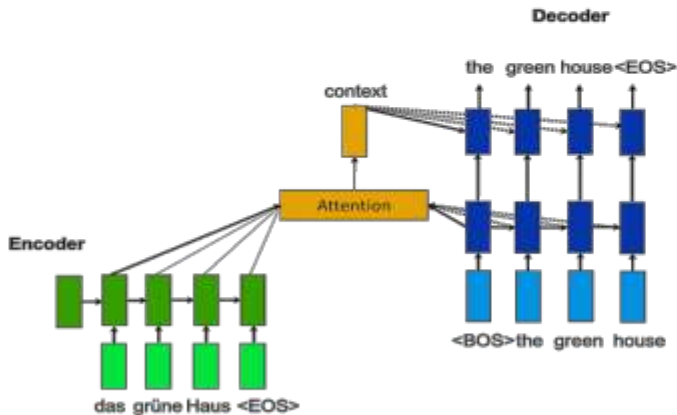
Einen Wendepunkt in der MÜ-Forschung brachten statistische Ansätze (Statistical Machine Translation SMT), die von IBM Anfang der 1990er Jahre im MÜ-Forschungssystem *Candide* erstmals umgesetzt wurden. Dabei verzichteten die Entwickler gänzlich auf linguistische, semantische, grammatische oder syntaktische Regeln und stützten sich mit Hilfe von Wahrscheinlichkeitsberechnungen auf statistische Auswertungen umfangreicher Sammlungen von vorhandenen Übersetzungen. Ein weiterer Baustein in der Verbreitung und Nutzung maschineller Übersetzungssysteme stand mit dem WWW zur Verfügung, das es 1997 Altavista erlaubte, sein auf Systran basierendes regelbasiertes MÜ-System online zur Verfügung zu stellen. Google folgte kurz darauf mit seinem eigenen webbasierten System Google Translate. Diese im WWW verfügbaren MÜ-Systeme zeigten aufgrund ihrer immer noch geringen Qualität für professionelle Übersetzer*innen keine Auswirkungen; sie standen eher in Konkurrenz zum Nicht-Übersetzen – d. h. sie übersetzten Texte, die ohne diese Systeme nicht übersetzt worden wären.

Erst als Google im Oktober 2007 sein selbst entwickeltes statistisches MÜ-System online stellte, wurden aufgrund der höheren Qualität Konsequenzen für den Übersetzungsmarkt spürbar: Der Low-End-Bereich, wo es lediglich um ein überblicksartiges Verstehen des Ausgangstextes geht, wurde dadurch bereits ansatzweise abgedeckt. Die breite Verwendung der statistischen Maschinenübersetzung rückte aber auch ihre Defizite und Fehleranfälligkeit in den Vordergrund, wodurch sich die Nachbearbeitung und Korrektur des Outputs durch den Menschen, das Post-Editing, als Tätigkeit für professionelle Übersetzer etablierte.

Eine neuerliche Qualitätsverbesserung zeichnete sich durch die Einführung neuronaler Übersetzungssysteme (Neural Machine Translation NMT) im Jahr 2016 ab, als *DeepL.com* online ging. Neuronale Netze lernen dabei völlig autonom aus umfangreichen Beständen bereits vorhandener Übersetzungen, wobei typischerweise ganze Sätze in einem integrierten Modell abgebildet werden (Zhou/Kurenkov/See 2018). Im Gegensatz dazu versuchte die vorhergehende Generation der statistischen MÜ-Systeme (SMT) in dem sogenannten Phrase-Based-Ansatz, ganze Sätze in einzelne Abschnitte zu zerlegen, für die dann jeweils die höchstwahrscheinlichen Entsprechungen gesucht und mit Hilfe des Zielsprachenmodells wieder zu ganzen Sätzen zusammengestellt wurden. Beiden Ansätzen gemeinsam ist die Notwendigkeit eines großen Datenbestandes an Beispielübersetzungen, ohne den diese Systeme nicht funktionieren können.

Die für neuronale Maschinenübersetzungssysteme verwendeten Algorithmen basieren meist auf einem Zweig der Künstlichen Intelligenz, dem Maschinellen Lernen, das neben anderen Arten der KI wie Expertensystemen, Spracherkennung, Sprachproduktion und Robotik unterschiedliche Ansätze hervorgebracht hat. Einer davon ist das sogenannte Deep Learning, das spezifische Optimierungsmethoden künstlicher neuronaler Netze mit einer umfangreichen inneren Struktur zahlreicher Zwischenebenen (hidden layers) nach der Eingabeschicht und vor der Ausgabeschicht zur Anwendung bringt. Dabei imitiert diese Technologie das menschliche Gehirn:

Deep-learning software attempts to mimic the activity [...] in the neocortex, the wrinkly 80 percent of the brain where thinking occurs. The software learns [...] to recognize patterns in digital representations of sounds, images, and other data. (Massey/Ehrensberger-Dow 2017:301 mit Bezug auf MIT Technological Review



2016).

Abb. 1: Module eines neuronalen MÜ-Systems (Hieber/Domhan 2017)

Mit Hilfe solcher Techniken strebt die Künstliche Intelligenz nach der sogenannten High Level Machine Intelligence (HLMI), die es in Zukunft ermöglichen soll, verschiedene Aufgaben besser durchzuführen als der Mensch. Eine unter KI-Forschern durchgeführte Untersuchung stellte die Frage, wann dieser Zeitpunkt erreicht werden kann (Grace/Salvatier et al 2018): Neben einer Reihe anderer Berufe und Tätigkeiten (z. B. LKW-Fahrer, Verkäufer, GO-Spieler u. a.) wurde auch das Übersetzen abgefragt: Den Antworten der KI-Forscher zufolge wird in 8 Jahren, mit einer möglichen Bandbreite von 3 bis 18 Jahren, der Zeitpunkt erreicht, an dem die Maschine besser übersetzen kann als ein menschlicher Laie. Obwohl sich solche Vorhersagen im Nachhinein immer wieder als falsch

erwiesen haben, brachte der Einsatz von MÜ-Systemen und insbesondere neuronaler Netze unbestritten einen enormen Produktivitätszuwachs für das Übersetzen sowie in Ansätzen auch für das Dolmetschen. So stieg durch den Einsatz Maschineller Übersetzungssysteme in der Generaldirektion Übersetzen der Europäischen Kommission (DGT) die Anzahl übersetzter Seiten im Zeitraum 2012–2018 von 1.750.000 auf rund 2.250.000 Seiten, während im gleichen Zeitraum die Zahl der angestellten Übersetzer*innen von 2530 auf ca. 2300 reduziert wurde (Rummel 2019:4).

Sukzessive Verbesserung der Ergebnisse

Eine Untersuchung der Korrekturrate und des nötigen Aufwandes an Post-Editing (overall correction rate, post-editing effort) wurde von der Europäischen Kommission und dem Unternehmen Translated gemeinsam durchgeführt: Während 2003 dieser Anteil für die Sprachkombinationen Englisch-Französisch und Englisch-Italienisch noch ca. 43 % betrug, betrug der Wert 2015 nur mehr 27 % für dieselben Sprachkombinationen (Trombetti 2016). Diese deutliche Verbesserung wird auch im folgenden kleinen Experiment bestätigt.

Auf der Basis eines stichprobenartigen Vergleichs von Übersetzungen, die von Studierenden des Masterstudiums Translationswissenschaft an der Universität Innsbruck durchgeführt wurden, mit Übersetzungen von neueren neuronalen Maschinenübersetzungssystemen kann einerseits der deutliche Fortschritt, andererseits aber auch die mangelnde Transparenz und Verlässlichkeit solcher MÜ-Systeme dargestellt werden. Die Anwendung einer einheitlichen Fehlerkategorisierung – zugrunde gelegt wurde die Fehlertypologie des Mellange-Projektes (Mellange 2006) – erlaubt dabei die Differenzierung von Fehlern des Inhaltstransfers (TR) und Fehlern der sprachlichen Ebene (LA), und einen Vergleich der Stärken und Schwächen von humanen und maschinellen Übersetzungen. Dazu wurden die Prüfungsergebnisse der Studierenden des Kurses ‚Fachübersetzen Recht‘ in der Übersetzungsrichtung Italienisch-Deutsch im Sommersemester 2013 gleichzeitig mit den Ergebnissen der maschinellen Übersetzungssysteme von Microsoft und Google, beide damals noch statistische MÜ-Systeme, verglichen (Abb. 2 unten). Beim Inhaltstransfer kamen Studierende auf 1–5 Fehlerpunkte, bei einem Durchschnitt von 3,1, Google erreichte 10 Fehlerpunkte, Microsoft 13, während die sprachlichen Fehler der Studierenden von 1 bis 38 bei einem Mittel von 17,4 reichten, bei Microsoft 23 bei Google 36 betrug. Beide statistischen maschinellen Übersetzungssysteme wurden damit mit ungenügend bewertet.

SS 2013 SMT




Abb. 2: Ergebnisse SS 2013: Transferfehler (TR) und Sprachfehler (LA)

WS 2018/19 NMT




Abb. 3: Ergebnisse WS 2018/19: Transferfehler (TR) und Sprachfehler (LA)

Dieser stichprobenartige Versuch wurde mit demselben Ausgangstext im Wintersemester 2018/19 wiederholt, wobei neben Microsoft und Google nun auch DeepL, alle drei mittlerweile neuronale maschinelle Systeme, eingebunden wurden (Abb. 3). Google und Microsoft landeten mit 10 bzw. 14 Inhaltstransferfehlern (TR) auf den beiden letzten Plätzen, während DeepL mit lediglich 2 Transferfehlern gleich gut abschnitt wie mehrere Studierende. Bei den sprachlichen Fehlern (LA) schnitten DeepL, Google und Microsoft mit

15 und jeweils 18 Fehlerpunkten besser ab als zwei Studierende mit 21 und 27 Fehlerpunkten, wobei diese beiden Studierenden jedoch in die Fremdsprache übersetzten. Alle drei maschinell erzeugten Übersetzungen wurden auch hier wieder negativ bewertet. Aus diesem Versuch geht hervor, dass die sprachliche Formulierung der neuronalen MÜ-Systeme sich deutlich verbessert hat, während sich dies für Fehler des Inhaltstransfers mit der Ausnahme von DeepL nicht sagen lässt.

Die Berechnung der BLEU-Werte (BiLingual Evaluation Understudy) bzw. der Ähnlichkeit des MÜ-Outputs mit der Referenz der besten Übersetzung durch einen Studierenden verdeutlicht die Steigerung der Qualität der neuronalen MÜ-Systeme: Je höher der Wert, desto näher das Output an der Humanübersetzung, bei einem Wert von 1 wird von einer Übersetzung durch den Menschen ausgegangen. Erreichten die statistischen Systeme 2013 noch Werte zwischen 0,117 (Microsoft) und 0,146 (Google), konnten die neuronalen Systeme 2018 die BLEU-Werte auf 0,190 (Microsoft), 0,232 (Google) und 0,348 (DeepL) steigern.

Obwohl die neuronalen Systeme einen deutlichen Qualitätssprung brachten, was die allgemeine sprachliche Qualität angeht, zeigen diese unter dem Aspekt der terminologischen Konsistenz neue Schwächen. So wird in dem Ausgangstext (einem Text zum Europäischen Betriebsrat) der Terminus „Comitato Ristretto“, dessen offizielle deutsche Bezeichnung „Engerer Ausschuss“ lautet und der insgesamt viermal im Text vorkommt, im Output von Google mit jeweils vier unterschiedlichen Bezeichnungen wiedergegeben: „eingeschränkter Ausschuss“, „Select-Ausschuss“, „Auswahlausschuss“ und „Auswahlkomitee“. Microsoft verwendet drei unterschiedliche Bezeichnungen: „beschränkter Ausschuss“, „Komitee und Ausschuss“. DeepL setzt hingegen zwei Termini ein: „Distriktausschuss“ und „Distriktsvorstand“. Kein MÜ-System verwendet den zutreffenden deutschen Terminus: Alle drei variieren ihre Übersetzungen für denselben ausgangssprachlichen Terminus, was eine Korrektur deutlich erschwert. Dies ist auf die Satz-für-Satz-Vorgangsweise neuronaler Systeme zurückzuführen.

Neuronale MÜ-Systeme weisen somit systembedingte Nachteile auf, die auf ihre spezifische Struktur der verborgenen Verarbeitungsebenen zurückzuführen sind. Die verborgenen neuronalen Layer können nicht eingesehen werden und es kann nicht nachvollzogen werden, wie das Ergebnis zustande gekommen ist. Aufgrund der mangelnden Nachvollziehbarkeit kann neben dem Wie auch nicht das Warum der von der Maschine getroffenen Entscheidungen im Nachhinein nicht beantwortet werden. Die Ergebnisse des Übersetzungsprozesses lassen sich schlecht vorhersagen und die Frage, welche Entscheidungen die Maschine treffen wird, kann niemals sicher beantwortet werden.

Erfahrungsberichte wie jener von Rummel und Experimente wie das hier beschriebene zeigen jedenfalls, dass sich die Grenze zwischen dem Low-End-Markt für Übersetzungen, der bereits seit den statistischen Systemen von der Maschine bedient wird, und professionellen Übersetzungen damit aus Zeit- und Kostengründen zunehmend zum Nachteil der Humanübersetzer*innen verschiebt. Daneben nimmt der Anteil an Post-Editing zu, der von ausgebildeten Übersetzer*innen durchgeführt wird.

Ein ‚Circulus vitiosus‘?

Für den Einsatz maschineller Übersetzungssysteme müssen drei Voraussetzungen gegeben sein: Software, Hardware und Trainingsdaten. Algorithmen für allgemeine neuronale Netze wurden von großen Internet-Unternehmen entwickelt und als freie Software kostenlos zur Verfügung gestellt (z. B. TensorFlow, PyTorch). Die Algorithmen für Maschinelle Übersetzungssysteme auf der Basis von neuronalen Netzen sind heute unter anderem ebenfalls als freie und kostenlose Software verfügbar (z. B. OpenNMT, ModernMT). Die Hardware-Entwicklung ist mittlerweile so weit fortgeschritten, dass ein geeignetes PC-System mit genügend Rechenleistung mit geringem finanziellem Aufwand jederzeit erworben werden kann. Die dritte Voraussetzung, geeignete Trainingsdaten, stellt hingegen die wichtigste und am wenigsten verfügbare Ressource dar. Um ein an einen spezifischen Verwendungszweck angepasstes maschinelles Übersetzungssystem zu entwickeln, bedarf es großer Mengen an vorhandenen Übersetzungen, die zudem je nach Anwendungszweck des MÜ-Systems fachspezifisch, unternehmensspezifisch, textsortenspezifisch oder kontextspezifisch sein sollten. Ausschlaggebende Kriterien für ein solches Trainingskorpus sind Übersetzungsqualität und Verlässlichkeit, die nur durch eine genaue Kenntnis der Autor*innenschaft und des Produktionskontextes der Übersetzungen im Korpus gewährleistet wird.

Jede Art Künstlicher Intelligenz kann aus sich selbst heraus keine Ergebnisse liefern, sie bedarf immer eines Inputs durch den Menschen – unabhängig davon, ob es sich um Sprache, Übersetzungen oder andere Daten handelt. Dies gilt umso mehr für das maschinelle Lernen und neuronale Netze, eine spezifische Art des maschinellen Lernens. Es handelt sich dabei um Algorithmen, die die Funktionsweise des menschlichen Gehirns nachahmen und selbständig Schlüsse aus großen Mengen von Daten ziehen. Durch dieses maschinelle Lernen entsteht ein sich selbst optimierender Kreislauf, ein ‚Circulus virtuosus‘, der aus den drei Eckpunkten Produkt (Applikation bzw. Anwendung), den Benutzer*innen dieses Produktes und den zur Verfügung stehenden Daten

besteht: „The best products have the most users, and the most users usually means getting the most data, and with modern ML, the product becomes better“ (Ng 2017).




Abb. 4: The virtuous circle of AI (Ng 2017)

Je häufiger eine solche Anwendung gebraucht wird und je mehr Benutzer*innen das System verwenden, desto mehr Daten stehen für das Lernen zur Verfügung, wodurch das Resultat dieser Anwendung besser wird und damit wieder mehr Benutzer*innen anzieht. Wenden wir diesen Kreislauf auf maschinelle Übersetzungssysteme an, kann das problematische Verhältnis zwischen Übersetzer*innen und MÜ deutlich veranschaulicht werden. Der oben genannte Circulus virtuosus funktioniert, wenn Übersetzer*innen sowohl als Hauptnutzer*innen als auch als Datenlieferant*innen in den Kreislauf integriert werden: Neuronale maschinelle Übersetzungssysteme liefern Übersetzungsvorschläge an die Übersetzer*innen, die diese korrigieren und optimiert als Translation-Units eines größeren Bestandes an Translation-Memory-Daten dem System wieder zur Verfügung stellen. Das System kann seinen Output danach optimieren und in der Folge bessere Ergebnisse an die Übersetzer*innen liefern, wodurch sich die Produktivität erhöht.

Online-Übersetzungssysteme sind sehr beliebt, werden aber vorwiegend von Lai*innen verwendet, die damit fehlende Sprachkenntnisse kompensieren möchten. Die zahlreichen online verfügbaren maschinellen Übersetzungssysteme übersetzen heute ein Vielfaches dessen, was Übersetzer*innen produzieren: „99 % of today’s global content is translated by MT without any human intervention“ (Whitty 2019:24). Durch die fehlende Korrektur und damit das Ausbleiben einer Optimierung des zugrunde liegenden Datenmaterials fällt jedoch die gewinnbringende Verbindung zwischen MÜ-Systemen und den Übersetzer*innen als Hauptnutzer*innen bzw. zwischen den Nutzer*innen und den Datenlieferant*innen und der Circulus virtuosus wandelt sich für die

Übersetzer*innen zu einen Circulus vitiosus, einem Teufelskreis: Hauptnutzer können aufgrund der gesteigerten Qualität neuronaler Systeme nun auch potenzielle Auftraggeber*innen von Übersetzungen werden, in der Regel meist Lai*innen, und das maschinelle Übersetzungssystem wird damit als Alternative zu Humanübersetzer*innen gesehen. Dennoch müssen neuronale Übersetzungssysteme auf vorhandene, qualitativ hochwertige Übersetzungen als Daten zurückgreifen, um ihren Output optimieren zu können. Übersetzer*innen werden damit zu Verlierern: Je besser sie arbeiten, je mehr optimierte Trainingsdaten sie der Maschine zur Verfügung stellen, desto größer wird die KI-basierte Konkurrenz.

Ein möglicher Ausweg aus diesem Teufelskreis liegt in der Akzeptanz der Übersetzer*innen als Fachleute für solche Trainingsdaten. Dazu ist es unabdingbar, dass sie sich vermehrt in den Prozess der Übersetzungsvorbereitung und des Trainings von MÜ-Systemen einbringen. Durch ihre Arbeitsleistung kann ein spezifisch vorbereitetes, auf individuelle Kontexte adaptiertes maschinelles Übersetzungssystem trainiert werden, das die Qualität allgemeiner Online-Systeme für diesen spezifischen Einsatzzweck deutlich übersteigt. Doch nicht nur das Einbringen qualitativ hochwertiger Humanübersetzungen in das System wird Aufgabe der Übersetzer*innen sein, sondern ebenfalls das Planen seines Einsatzes sowie die optimale Weiterverarbeitung ihres Outputs. Nicht die Furcht vor einer unkontrollierten Usurpation der eigenen Übersetzungen und einer unrechtmäßigen Konkurrenz darf zum Leitmotiv der Übersetzer*innen werden, sondern vielmehr ihr eigener Beitrag zur Optimierung der Übersetzungsprozesse im Allgemeinen, wozu natürlich auch ihr Beitrag zur Entwicklung angepasster maschineller Übersetzungssysteme zählt.

Kernkompetenzen im Wandel

Um einen sinnvollen Beitrag bei der Weiterentwicklung maschineller Übersetzungssysteme leisten zu können, müssen die dazu benötigten Kompetenzen geschärft und erweitert werden. Kontraproduktiv wäre in dieser Hinsicht ein Beharren auf gewohnten Ausbildungsinhalten und einem Kompetenzprofil, das maschinelles Übersetzen in keiner Weise mitberücksichtigt. Vielfach fokussierte die Übersetzer*innenausbildung bisher auf das individuelle Übersetzen-Können, das als ein ausführendes Handwerk gesehen wurde, und vermittelte daneben einzelne, darüber hinausgehende Kenntnisse, die mittelbar das Übersetzen unterstützen, wie beispielsweise Terminologie und Terminographie. Im Zuge der Globalisierung sowie mit der technologischen Wende (Cronin 2010, Chan 2012) rückte die individuelle Übersetzungsfertigkeit immer mehr

in den Hintergrund: „Translation skill is no longer the key differentiator in the various careers“ (Mügge 2018:22). Übersetzungsprojekte wurden zunehmend umfangreicher und durch die Medienvielfalt und die damit verbundene Technologie komplexer, wodurch Teamarbeit mit unterschiedlichen individuellen Schwerpunkten und Kooperation zwischen PartnerInnen mit unterschiedlichem Ausbildungshintergrund in den Vordergrund rückte. Übersetzen veränderte sich von einer individuellen Tätigkeit hin zu einer konzeptionellen, integrierten Dienstleistung, wobei das Verständnis für Mehrsprachigkeit und ihre Umsetzung durch Translation sowie die Integration des Übersetzens in übergeordnete Unternehmensziele im Zentrum stehen: „Understanding of language processing technology and business processes“ (Mügge 2018:22). Technologie sowie ihr geplanter und koordinierter Einsatz gewinnen an Bedeutung gegenüber individuellen Sprach- und Übersetzungskompetenzen:

Translation and interpreting skills can be seen as something different to translator and interpreter willst, bearing in mind the growing technical and specific expertise that the translation and interpreting industries require. (Calvo 2011:21)

Angesichts dieser Entwicklungen stehen für den Beruf Übersetzen zwei Alternativen zur Wahl, wie auf diese Herausforderung reagiert werden kann:

1. Resteverwertung, d. h. Nischen identifizieren, wofür Technologie und Automatisierung noch keine zufriedenstellende Lösung bieten können, und wo die individuelle Übersetzungsleistung noch im Vordergrund steht;
2. Umfassende konzeptionelle Dienstleistungen durch Einbinden von Automatisierung und Technologie anbieten bzw. Einsatz und Entwicklung der Technologie mitgestalten.

Ersteres bedeutet, das Übersetzen-Können weiterhin in den Mittelpunkt zu stellen, aber eben in Bereichen, in denen Intuition, Kreativität und kritische Urteilsfähigkeit vorausgesetzt werden:

In short, translators will be in demand in those areas where human translation provides clients with the added values of intuition, creativity, and ethical judgement. (Massey/Ehrensberger 2017:303)

Dieser High-End-Premium-Markt verlangt höchste Qualität und umfasst Bereiche wie Transkreation, Lokalisierung, digitales Marketing, Mehrsprachigkeit in Sozialen Medien, Vermitteln von Kulturspezifika. Übersetzer*innen werden damit zu „creative agents in the multilingual text production chain“ (Massey/Ehrensberger 2017:304). Vermehrte Nachfrage wird es künftig vor allem nach „Transcreators, Spoken Content Specialists, Brand Ambassadors, Local Storytellers, Conversational Agent Consultants“ (Whitty 2019) geben. Die Anforderungen an Absolvent*innen universitärer Ausbildungsgänge

steigen dadurch erheblich und müssen sich für Themenbereiche wie kreatives Schreiben, internationales Marketing, Medienvielfalt und Projektmanagement öffnen: „If translators are to survive, they must make the transcultural turn“ (Katan 2016:378). Das Nachbearbeiten maschineller Übersetzungen, PostEditing genannt, zählt ebenso zur ersten Gruppe, da maschinelle Übersetzungssysteme noch nicht hohe Qualitätsansprüche an den Zieltext erfüllen können und für Überprüfung und Korrektur der Mensch eingesetzt wird:

Statistical-based MT, along with its many hybrids, is destined to turn most translators into posteditors one day, perhaps soon. (Kenny 2018:66)

Die zweite Alternative bedeutet eine Schwerpunktverlagerung weg vom individuellen Übersetzen-Können hin zum Übersetzen-Verstehen und dem Übersetzen-Planen. Individuelle Translationskompetenz ist zwar weiterhin erforderlich, sie ist aber nicht mehr das einzige Mittel, wodurch die Leistung erbracht wird. Die Maschine kann Übersetzungsaufträge, für die geringe Qualitätsanforderungen gelten, allein durchführen; andere Übersetzungsaufträge können von der Maschine vorübersetzt und vom Menschen nachbearbeitet werden, und zwar schneller und billiger als bei reiner Humanübersetzung. Das Verstehen des Übersetzungsprozesses, um diesen möglichst effizient durchführen und optimieren zu können, das Einbinden desselben in übergeordnete Kommunikationsvorgänge, um die Ziele des Auftraggebers erreichen zu können, das Nutzen der zur Verfügung stehenden Technologie, um die höchstmögliche Produktivität realisieren zu können, erfordert neue Kompetenzen und lässt das Übersetzen zur Teamarbeit mit einem vorgegebenen und definierten Ziel werden. Neben Fachübersetzen und Terminologiearbeit braucht es allgemeine Kritikfähigkeit, betriebswirtschaftliches Wissen und vor allem technisches Know-how. Das Berufsbild wandelt sich von einer rein ausführenden zu einer beratenden und planenden Dienstleistung.

Beratung und Planung kann nicht unabhängig von Kontext, Einsatzzweck und Auftraggeber betrachtet werden, wofür und wo Translation eingesetzt wird. Jede Institution, Organisation und jedes Unternehmen wird danach streben, Mehrsprachigkeit im Allgemeinen und Translation im Besonderen den spezifischen Anforderungen entsprechend zu gestalten und innerhalb des eigenen Wirkungskreises zu optimieren. Der Begriff der institutionellen Translationskompetenz bezeichnet dabei die über die individuelle Kompetenz hinausgehende Fähigkeit, das Übersetzen innerhalb einer Institution effizient und effektiv zu gestalten (Sandrini 2019:99). Institutionelle Translationskompetenz verbindet die Kompetenzen der einzelnen Mitarbeiter*innen und institutionalisiert sie. Ausgebildete Übersetzer*innen führen dabei nicht mehr primär Übersetzungen durch, sondern stehen für das Know-how, wie Über-

setzungen und allgemein Mehrsprachigkeit am besten zum Vorteil der Institution bzw. Organisation umgesetzt werden können. Übersetzer*innen entscheiden, welche Art von Technologie für welchen Übersetzungsauftrag eingesetzt wird, sie planen die translationstechnologische Infrastruktur, verwalten Translationsdaten (Translation-Memory, Terminologiedaten, Textkorpora), und steuern die Durchführung konkreter Übersetzungsprojekte. Während bisher in der Didaktik vorzugsweise die individuelle Übersetzungsfähigkeit im Mittelpunkt stand, bedarf es zur Berücksichtigung der institutionellen Translationskompetenz einer Ausweitung der Ausbildungsinhalte, um den Auszubildenden die Fähigkeit zu vermitteln, zur kollektiven Translationskompetenz einer Institution beitragen zu können. Institutionelle Translationskompetenz stützt sich zwar auf die individuelle Kompetenz der einzelnen Mitarbeiter*innen, geht aber durch Vernetzung, kollektive Nutzung und Institutionalisierung darüber hinaus und ist mehr als die Summe der Kompetenzen aller innerhalb einer Institution arbeitenden Übersetzer*innen. Sie ist nicht zuletzt geprägt von der jeweiligen Historie von Entscheidungen zum Übersetzen, die von der entsprechenden Institution bzw. ihrer Führung getroffen worden sind. Dies beginnt bei der allgemeinen translationswissenschaftlichen Ausrichtung, führt über Personalentscheidungen, die interne Organisation des Übersetzens und Qualitätsrichtlinien bis hin zu durchgeführten technologischen Investitionen.

Veränderung durch verbesserte maschinelle Übersetzungssysteme erfolgt nicht abrupt und ersetzt nicht plötzlich und vollständig einen Beruf: „These technologies don't replace whole fields, in general. What they do is replace a certain way of applying them“ (Kelly 2011). Berufsbilder werden in neuer und unterschiedlicher Weise definiert und in Ausbildung und Praxis etabliert. Veränderung erfolgt langsam und schleichend. Dabei werden zunehmend einzelne Tätigkeiten von der Maschine übernommen. Sehr früh wurde beispielsweise das Memorisieren von Terminologie durch Terminologieverwaltungssysteme ersetzt, das das Memorisieren oder Verfügbarmachen bereits erarbeiteter Übersetzungen durch Translation-Memory-Systeme sowie das Erstellen von Rohübersetzungen durch maschinelle Übersetzungssysteme, so dass dieser fortschreitende Prozess in dem sogenannten Translatoren-Obsoleszenzyklus dargestellt werden kann (Sandrini 2017:146; 2019a:150); die fortschreitenden technischen Entwicklungen führen darin zu einem Wegfall immer neuer Tätigkeiten der Übersetzer*innen, so dass ihr Aufgabenumfang in einer sich nach unten verengenden Spirale dargestellt werden kann. Um dieser Spirale nach unten, die u. a. als „downward migration“ for talented professionals“ (Kenny 2018:66) bezeichnet wurde und das Übersetzen als ausführende Tätigkeit betrifft, zu entkommen, muss die oben beschriebene zweite Alternative zum Tragen kommen; d. h. vom Übersetzen-Können auf das Übersetzen-Verstehen sowie das Übersetzen-Planen ausgewichen werden.

Der internationale Übersetzerverband FIT empfiehlt in diesem Sinne:

These professionals should act as language services advisors or language consultants, advising their customers on the best approach to a particular assignment and explaining the benefits or drawbacks of certain translation methods. (FIT 2017:2)

Eine Empfehlung, die von Melby/Hague (2019) aufgegriffen und in den Kontext umfassender und strukturierter Übersetzungsanforderungen („structured translation specifications“ ASTM F2575-14) gestellt wird: Erst die genaue Spezifikation der Anforderungen an eine Übersetzung ermöglicht es zu entscheiden, welche Anforderungen die Maschine erfüllen kann und welche nicht. Teilleistungen, wie beispielsweise eine Rohübersetzung unter Zeitdruck, können von der Maschine übernommen werden. Der Mensch hingegen erstellt die situationspezifischen Anforderungen im Kontakt mit dem Auftraggeber und entscheidet über die einzusetzenden Hilfsmittel: „Translators who prosper will be those who expand their role by becoming both translators and language-services advisors“ (Melby/Hague 2019:210). Der Hauptakzent liegt dabei auf dem Anbieten von Lösungen für spezifische Probleme der Mehrsprachigkeit. Pym (2019:17) verwendet den Terminus „solving clients' problems“ und zählt die unterschiedlichen Berufsbezeichnungen, die in der Übersetzungsindustrie dafür verwendet werden, auf:

Solutions architect, director of client solutions, solutions consulting and director of technology solutions, cloud solutions architect, or solutions manager for machine intelligence. (Pym 2019:17)

Die Dienstleistung umfasst demnach nicht mehr ausschließlich das ausführende Übersetzen, sondern vor allem die Kompetenz, Übersetzungsvorgänge zu analysieren, zu planen und dabei die am besten zu den spezifischen Anforderungen passende Technologie einzusetzen. Hummel (2019) spricht vom „Translation Workflow Engineer“ (Hummel 2019:20), der die drei Faktoren Zeit, Kosten und Qualität abwägen und anpassen kann, die entsprechende Technologie auswählt, Qualitätskriterien definiert, Personalressourcen zuteilt sowie Überprüfungsmöglichkeiten bestimmt. Die Abhängigkeit von spezifischen Projektanforderungen (Kunde, Textsorte, Zielpublikum, etc.) tritt auch hier klar in den Vordergrund. Hummel (ibid.) fasst die damit zusammenhängenden Tätigkeiten unter eigenen Berufsbezeichnungen zusammen: Der*die „Revisor*in“ übernimmt Qualitätsprüfung und Post-Editing, der*die „Multilingual Knowledge Manager“ pflegt mehrsprachige Wissens- und Terminologiebestände, der*die „Linguistic Assets Curator“ kümmert sich um sprachliche Ressourcen wie Translation-Memories, Textkorpora und Trainingsdaten für maschinelle Übersetzungssysteme.

Werden diese Tätigkeiten von der Projektebene auf die Ebene einer Institution, einer Organisation oder eines Unternehmens gehoben, so beschreiben sie den Umfang der oben genannten institutionellen Translationskompetenz. Um diese zu erreichen bzw. um sie nutzbar zu machen und an die Institution zu binden, bedarf es jedoch einer entsprechenden Neuausrichtung der Ausbildung.

Neuausrichtung

Darauf aufbauend können die Schwerpunkte eines an diese neuen Entwicklungen angepassten Curriculums identifiziert werden, die u. a. auf die notwendige Differenzierung von Übersetzen-Können und Übersetzen-Planen bzw. von individueller und institutioneller Translationskompetenz zurückgehen. Während die traditionelle Ausbildung ausschließlich den Ausbau der individuellen Translationskompetenz verfolgte, wird in diesem Beitrag das Vermitteln des Übersetzen-Planen-Könnens postuliert. Dabei spielt die Definition der institutionellen Translationskompetenz und die dafür nötigen didaktischen Voraussetzungen eine entscheidende Rolle, um Absolvent*innen in die Lage zu versetzen, einen entscheidenden Beitrag zur kollektiven Translationskompetenz einer Institution leisten zu können.

Technologie spielt dabei eine zentrale Rolle: Nicht als Bedrohung, sondern als mächtiges neues Werkzeug:

A successful language-services advisor must believe that technology – including MT – creates an opportunity, not an obstacle. (Melby/Hague 2019:210)

Der Einsatz von Technologie setzt das Wissen um ihre Vorund Nachteile voraus, um die optimalen Einsatzmöglichkeiten der verschiedenen technologischen Werkzeuge abgestimmt auf die unterschiedliche Anforderungen eines Auftrages bzw. einer Institution oder Organisation planen zu können. Technologie wird damit zum planbaren Instrument, das zunächst als technologische Infrastruktur für die Mehrsprachigkeit und die Translation innerhalb einer Institution oder Organisation installiert werden muss – Einrichten von Werkzeugen wie Terminologiedatenbank, spezifische mehrsprachige Textkorpora, automatisches Redaktionssystem, Translation-Memory-Datenbank, adaptiertes maschinelles Übersetzungssystem –, und danach fallspezifisch und projektorientiert in der jeweils optimalen Kombination zur Anwendung kommt. Übersetzer*innen der Zukunft spielen in einem solchen Szenario nicht mehr die ausführende Rolle des individuellen Zieltextproduzenten, sondern wirkt

als Technologieplaner und -koordinator bzw. Sprachdateningenieur sowie als Supervisor für den Übersetzungsprozess.

Jede Art von Übersetzungstechnologie erfordert einen hohen Einsatz an spezifischen Daten, sei es in Form von institutions-, organisationsoder unternehmensspezifischer Terminologie, mehrsprachigen Texten, mehrsprachigen Textsegmenten in Translation-Memories oder in Form von MÜ-Trainingsdaten. Das Speichern, Aktualisieren, Korrigieren und Optimieren der Übersetzungsdaten (linguistic assets, multilingual knowledge nach Hummel 2019:20), die vom Menschen produziert und in der künstlichen Intelligenz zur Optimierung maschineller Übersetzungssysteme eingesetzt werden, setzt einerseits technologische Kenntnisse voraus, andererseits aber auch eine geisteswissenschaftliche Perspektive:

Moreover, since much of the focus of the new discipline will be on data from and about humans, its development will require perspectives from the social sciences and humanities. (Jordan 2018)

Insbesondere im Umfeld des maschinellen Übersetzens eröffnen sich neue Möglichkeiten:

The need to source and profile (even greater quantities of) training data, to find suitable points at which translators can intervene in or control the translation process, and to educate new generations of translators/post-editors who are capable of working with NMT in a sustainable way. (Kenny 2018:67)

Dadurch kann der oben beschriebene Teufelskreis bzw. Circulus vitiosus durchbrochen werden. Welche Bereiche für die Tätigkeit ausgebildeter Übersetzer*innen sich als zukunftssicher erweisen werden, kann eine Zweiteilung in produktund prozessorientierte Arbeitsfelder veranschaulichen. Erstere werden nur mehr in Ausnahmefällen konkurrenzfähig sein, nämlich dort, wo Automatisierung durch Technologie noch keine akzeptablen Ergebnisse liefert: Übersetzen von kreativer Sprache, Übersetzen von Texten mit höchstem Schwierigkeitsgrad oder auch Übersetzen in Sprachen, für die noch keine bzw. nicht genügend umfangreiche Datenbestände vorliegen. Letztere bieten die Möglichkeit, den gesamten Übersetzungsprozess mit der Maschine als entscheidendem Hilfsmittel zu gestalten: Anpassen und Training von MT-Systemen sowie Planen, Organisieren und Evaluieren von Mehrsprachigkeit. Zudem eröffnen sich weitere wichtige Arbeitsfelder in der vorbereitenden Terminologearbeit, in der Optimierung des MÜ-Outputs sowohl im Vorfeld durch das Pre-Editing und den Einsatz kontrollierter Sprache als auch in der Folge durch das Post-Editing und Nachbearbeiten des Outputs (vgl. Mellinger 2017:284):

Those are the areas where we should be investing new training efforts, working with the technology rather than against it. (Pym 2019:16)

Zusammenfassend können die Veränderungen der Ausbildung in der synoptischen Gegenüberstellung folgendermaßen dargestellt werden, wobei die einzelnen Stichwörter nicht absolut zu sehen sind, sondern vielmehr als Fokustätigkeiten aufzufassen sind.

von	zu
produktorientiert	prozessorientiert
ausführend	planend
Produktion	Beratung
Einzelleistung	Teamarbeit
Handwerk	Expert*Innendienstleistung
individuell	institutionell
Text und Sprache	Text- und Sprachdaten

Tab. 1: Traditionelle und zukunftsorientierte Ausbildung

Die Translationswissenschaft hat sich seit ihrer Entstehung und Etablierung als akademisches Fach mit allen Facetten der Translation, des Übersetzens und des Dolmetschens, auseinandergesetzt, insbesondere mit jenen Aspekten, die über einen Austausch des sprachlichen Codes hinausgehen. Wenn dies ernst genommen wird bzw. in die Überlegungen miteinbezogen wird, so müsste die Maschinenübersetzung nicht automatisches oder maschinelles ‚Übersetzen‘ genannt werden, sondern automatische bzw. maschinelle Sprachersetzung, da gerade die darüber hinausgehenden Aspekte, wie beispielsweise Kontext, Kulturspezifika, Textsortenkonventionen, beim maschinellen Übersetzen nicht berücksichtigt werden. Bewusst und deutlich gemacht werden diese durch die bereits erwähnten strukturierten Auftragspezifikationen und führen zur Übersetzung als einem vielschichtigen Prozess, der in zahlreichen unterschiedlichen Formen auftreten kann, für die sich jeweils unterschiedliche technologische Hilfsmittel eignen. Für das sogenannte „gisting“, bei dem ausschließlich das inhaltliche Erschließen des Ausgangstextes im Mittelpunkt steht, kann die reine maschinelle Übersetzung genügen. Für eine solche rein automatisch erzeugte Übersetzung wurde die Bezeichnung „fully automatic useful translation“ (FAUT) geprägt, die das Gegenstück zur historisch angestrebten „fully automatic high quality translation“ (FAHQT) darstellt (TAUS 2015).

Daraus ergeben sich für die Translationswissenschaft, die sich mit allen Aspekten der Translation beschäftigen und sich nicht auf das professionelle Übersetzen beschränken will, durchaus auch neue Aufgabenfelder:

From this perspective, the great challenges facing translation researchers and teachers might not concern professionals at all: our main task should be to understand the social uses and effects of general non-professional translation. (Pym 2019:7)

Die Ausbildung hingegen kann sich nun angesichts der ubiquitären maschinellen Übersetzung noch mehr auf die Aspekte der Planung und Beratung im Bereich der Translation sowie auf die Translationstechnologie und Translationspolitik konzentrieren und alles, was Sprachersetzung und die reine Produktion von Übersetzungen betrifft und als ein Teil der ausführenden Komponente gesehen werden kann, redimensionieren, da die Maschine dies schneller, effizienter und effektiver durchführen kann.

Bibliografie

- ALPAC (1966) „Language and Machines. Computers in Translation and Linguistics“. A Report by the Automatic Language Processing Advisory Committee, Division of Behavioral Sciences, National Academy of Sciences, National Research Council. Washington, D. C.
- ASTM F2575 (2014) „Standard Guide for Quality Assurance in Translation“. Active Standard ASTM F2575 | Developed by Subcommittee: F43.03.
- Calvo, Elisa (2011) „Translation and/or Translator Skills as Organising Principles for Curriculum Development Practice“. In Sachinis, Michail (ed.) Special issue: Translator Training, Consecutive Interpreting, Localisation, *JosTrans* 16, 5–25.
- Chan, Sin-Wai (2012) „Translation Technology: Past, Present and Future“. Paper presented at the 2012 LTTTC International Conference: The Making of a Translator, Taipei.
- Cronin, Michael (2010) „The Translation Crowd“. *Revista Tradumatica* 8, 1–7.
- FIT (2017) „FIT Position Paper on the Future for Professional Translators“. International Federation of Translators. https://wa1.fit-ift.org/wp-content/uploads/2015/04/Future-of-professional-translators-bilingual-exit_April-2017.pdf [01.03.2021].
- Grace, Katia; Salvatier, John; Dafoe, Allan; Zhang, Baobao; Evans, Owain (2018) „When Will AI Exceed Human Performance? Evidence from AI Experts“. *ArXiv:1705.08807 v3*, 3 May 2018.
- Hieber, Felix; Domhan, Tobias (2017) „Train Neural Machine Translation Models with Sockeye“. *AWS Machine Learning Blog*, 20 JUL 2017 <https://aws.amazon.com/de/blogs/machine-learning/train-neural-machine-translation-models-withsocketeye/> [01.03.2021].
- Hummel, Jochen (2019) „Sunsetting CAT“. Presentation at the Jiamcatt Annual Meeting

- „The Shape of Things to Come“, Luxembourg, 13 May 2019.
- Hutchins, John (2005) “The First Public Demonstration of Machine Translation: The Georgetown-IBM System”, 7th January 1954. In Frederking, Robert E./Taylor, Kathryn B. (eds.) *Machine Translation: From Real Users to Research*. Proceedings of the 6th Conference of the Association for Machine Translation in the Americas AMTA 2004. Berlin: Springer, 102–114.
- Jordan, Michael (2018) „Artificial Intelligence – The Revolution Hasn’t Happened Yet“. Medium 19.04.2018. <https://medium.com/@mijordan3/artificial-intelligencethe-revolution-hasnt-happened-yet-5e1d5812e1e7> [01.03.2021].
- Katan, David (2016) „Translation at the Cross-Roads: Time for the Transcreational Turn?“ *Perspectives* 24:3, 365–381.
- Kelly, Nathaly (2011) „Ray Kurzweil on Translation Technology“. Huffington Post: Interview mit Ray Kurzweil, 06/13/2011 Updated 12/6/2017. https://www.huffpost.com/entry/ray-kurzweil-on-translati_b_875745 [01.03.2021].
- Kenny, Dorothy (2018) „Sustaining Disruption? On the Transition from Statistical to Neural Machine Translation“. *Tradumatica* 16, 59–70.
- Marchuk, Yuri (1984) „Machine translation in the U.S.S.R“. *Computers and Humanities* 18:1, 39–46.
- Massey, Gary/Ehrensberger-Dow, Maureen (2017) „Machine learning: Implications for translator education“. *Lebende Sprachen*. 62:2. 300–312.
- Melby, Alan/Hague, Daryl H. (2019) „A Singular(ity) Preoccupation. Helping Translation Sstudents Become Language Services Advisors on the Age of Machine Translation“. In Sawyer, David/Austermühl, Frank/Enríquez Raído, Vanessa (eds.) *The Evolving Curriculum in Interpreter and Translator Education*. Amsterdam/Philadelphia: John Benjamins, 205–228.
- Mellange (2006) „Typologie der Übersetzungsfehler. Multilingual eLearning in Language Engineering“. MeLLANGE-Project. Multilingual eLearning in LANGuage Engineering. <http://mellange.eila.univ-paris-diderot.fr/annot.de.shtml> [01.03.2021].
- Mellinger, Christopher D. (2017) „Translators and machine translation: knowledge and skills gaps in translator pedagogy“. *The Interpreter and Translator Trainer* 11:4, 280–293.
- ModernMT (2019) „A Context-aware, Incremental and Distributed General Purpose Neural Machine Translation Technology Based on Fairseq Transformer Model“. <https://github.com/modernmt/modernmt> [22.10.2019].
- Mügge, Uwe (2018) „Teaching Localization in the 21st Century: Six Practices That Make a Difference. Translation Skill is no Longer the Key Differentiator in the Various Careers Available in the Localization Field“. *ATA Chronicle* 47:6, 20–22.
- Ng, Andrew Y. (2017) „Artificial Intelligence is the New Electricity“. 28.04.2017, Baidu, Coursera, Stanford University. <https://medium.com/syncedreview/artificial-intelligence-is-the-new-electricity-andrew-ng-cc132ea6264> [25.03.2020].
- OpenNMT (2019) „An Open Source Neural Machine Translation System“. <http://opennmt.net/> [01.03.2021].
- Pym, Anthony (2019) „How Automation through Neural Machine Translation Might

- Change the Skill Sets of Translators“. Version 3. August 29, 2019. Draft written as part of the project Language Competence and Work (RecerCaixa 2016ACUP00020), 2017–2019. www.academia.edu [20.11.2019].
- Rummel, Dieter (2019) „Beyond MT? A few premature reflections on the use of AI in translation“. TAUS Global Content Summit, Amsterdam, 6 March 2019. <https://www.slideshare.net/TAUS/taus-global-content-summit-amsterdam-2019-beyond-mt-a-few-premature-reflections-on-the-use-of-ai-in-translation-by-dieter-rummel-head-of-informatics-dgt-european-commission> [01.03.2021].
- Sandrini, Peter (2017) „Translation 4.0 – Eine Perspektivenverschiebung“. In Zybatow, Lew/Petrova, Alena/Stauder, Andy/Ustaszewski, Michael (eds.) Übersetzen und Dolmetschen: Berufsbilder, Arbeitsfelder, Ausbildung. Einund Ausblicke in ei sich wandelndes Berufsfeld der Zukunft. 70 Jahre Innsbrucker Institut für Translationswissenschaft. Frankfurt [u.a.]: Peter Lang, 139–152.
- Sandrini, Peter (2019) „Institutionelle Translationskompetenz“. In Luttermann, Claus/Luttermann, Karin/Kazzazi Kerstin (eds.) Institutionelle und individuelle Mehrsprachigkeit. Münster: LIT, 91–109. Sandrini, Peter (2019a) Translationspolitik für Regionaloder Minderheitensprachen unter besonderer Berücksichtigung einer Strategie der Offenheit. Berlin: Frank & Timme.
- Somers, Harold (2011) „Machine Translation: History, Development, and Limitations“. In Malmkjær, Kirsten/Windle, Kevin (eds.) The Oxford handbook of Translation Studies. Oxford: Oxford University Press, 427–440.
- TAUS (2015) „Translation Technology Landscape Report“. <http://www.taus.net> [01.03.2021].
- Trombetti, Marco (2016) „Future“. <https://marcotrombetti.com/future> [20.11.2019].
- Whitty, Tess (2019) „Artificial Intelligence, Machine Learning, and the FutureProofed Translator: What I Learned from TAUS“. ATA Chronicle 48:5, 24–26.
- Zhou, Sharon; Kurenkov, Andrey; See, Alan (2018) „Has AI Surpassed Humans at Translation? Not Even Close!“ https://www.skynettoday.com/editorials/state_of_nmt [20.11.2019].