

Doğal Dil İşleme, Derin Öğrenme ve Metin İşleme: Çeviri Süreçlerine Yönelik Bir İnceleme *

Derya OĞUZ¹

Geliş Tarihi: 17.03.2025
Kabul Tarihi: 12.05.2025
Yayın Tarihi: 24.06.2025
Değerlendirme: İki Dış Hakem /
Çift Taraflı Körleme
Makale Türü: Derleme

Atıf Bilgisi:

Oğuz, Derya (2025). Doğal Dil İşleme, Derin Öğrenme ve Metin İşleme: Çeviri Süreçlerine Yönelik Bir İnceleme. *International Journal of Language and Translation Studies*, 5/1, 166-195.

Benzerlik Taraması: Yapıldı –
iThenticate

Etik Bildirim:
lotusjournal@selcuk.edu.tr

Çıkar Çatışması: Çıkar çatışması beyan edilmemiştir.

Finansman: Bu araştırmayı desteklemek için dış fon kullanılmamıştır.

Telif Hakkı & Lisans Yazarlar: Dergide yayınlanan çalışmalarının telif hakkına sahiptirler ve çalışmaları CC BY-NC 4.0 lisansı altında yayımlanmaktadır.

Öz

Bu çalışmada yapay zekanın önemli bileşenleri olan doğal dil işleme (DDİ) ve derin öğrenme modelleri çok yönlü olarak incelenmiş; bu doğrultuda yapay sinir ağları üzerinde gerçekleşen metin işleme süreçleri, çeviri bakımından ele alınmıştır. Yapay sinir ağlarının gelişimi ve dolayısıyla derin öğrenme algoritmalarının yaygınlaşması, doğal dil işleme alanında önemli gelişmelere yol açmıştır. Yapay zekâ alanında büyük bir dönüşümle yerini alan nöral makine çevirisi, çeviri dünyasını tartışmalara açmıştır. Nöral makine çevirisinin henüz insan düzeyinde güvenilir çeviri yapıp yapmadığı tartışılrsa da çevirmenlere sağlayacağı hız ve kolaylık, şüphesiz endüstri 4.0 çağında dijitalleşme ve otomasyona katkı sunacaktır.

Doğal dil işleme bilgisayarların insan dilini işlemesi amacıyla çeşitli yöntemler kullanmaktadır. Bu yöntemler arasında yapay sinir ağlarından oluşan derin öğrenme algoritmaları, günümüz uygulamalarını ve nöral makine çevirisini domine etmektedir. Bu doğrultuda doğal dil işlemede ve derin öğrenme mekanizmalarında çeşitli metin işleme süreçleri gerçekleşmektedir. Metin işleme süreçleri dil modelinde kullanılan mimarinin niteliğine bağlı olarak değişiklik arz edebilir. Çalışmada en güncel dil mimarileri ve özellikleri incelenerek dil modellerine içkin metin işleme süreçleri, insan beyninin dil işleme süreçleri ile karşılaştırılarak betimleyici ve analitik bir yaklaşım çerçevesinde ele alınmıştır. Çalışma, doğal dil işleme ve derin öğrenme teknolojilerinin gelecekte çevirmenlik mesleğinde önemli bir rol oynayacağı gerçekliğini ve çevirmenlerin bu dönüşüme karşı teknolojik gelişmeleri takip etmeleri gerekliliğini ortaya koymuştur.

Anahtar Kelimeler: doğal dil işleme, derin öğrenme, metin işleme süreçleri, çeviri.

* Etik Beyan: * Bu çalışmanın hazırlanma sürecinde bilimsel ve etik ilkelere uyulduğu ve yararlanılan tüm çalışmaların kaynakçada belirtildiği beyan olunur.

¹ Doç. Dr., Marmara Üniversitesi, İnsan ve Toplum Bilimleri Fakültesi, Mütercim ve Tercümanlık Bölümü, Almanca Mütercim ve Tercümanlık Anabilim Dalı, İstanbul, Türkiye, derya.oguz@marmara.edu.tr, ORCID ID: 0000-0001-5228-076X

Natural Language Processing, Deep Learning, and Text Processing: A Translational Perspective *

Derya OĞUZ²

Date of Submission: 17.03.2025
Date of Acceptance: 15.05.2025
Date of Publication: 24.06.2025
Review: Double-blind peer review
Article Type: Review

Citation:

Oğuz, Derya (2025). Natural Language Processing, Deep Learning, and Text Processing: A Translational Perspective. *International Journal of Language and Translation Studies*, 5/1, 166-195.

Plagiarism Check: Yes - iThenticate

Complaints: lotusjournal@selcuk.edu.tr

Conflict of Interest: The author(s) has no conflict of interest to declare.

Grant Support: The author(s) acknowledges that they received no external funding to support this research.

Copyright & License: Authors publishing in the journal retain the copyright to their work and their work is licensed under the CC BY-NC 4.0.

Abstract

This study offers a multifaceted examination of Natural Language Processing (NLP) and deep learning models, which are key components of artificial intelligence. In this context, text processing workflows operating on artificial neural networks are discussed with a particular focus on translation. The advancement of artificial neural networks and the widespread adoption of deep learning algorithms have led to significant developments in the field of NLP. Neural machine translation, which has emerged as a transformative development in artificial intelligence, has sparked debates within the translation community. Although it is still under discussion whether neural machine translation can produce translations at a human level of reliability, the speed and convenience it offers undoubtedly contribute to digitalization and automation in the era of Industry 4.0.

NLP employs various methods to enable computers to process human language. Among these, deep learning algorithms based on artificial neural networks dominate current applications and neural machine translation systems. Accordingly, diverse text processing workflows are carried out within NLP and deep learning mechanisms. These workflows may vary depending on the architectural characteristics of the language model being used. The study examines recent language model architectures and their properties, with a particular focus on the text processing procedures inherent to these models. These procedures are examined in relation to the language processing mechanisms of the human brain, within the framework of a descriptive analytical approach. The study concludes that NLP and deep learning technologies will play a significant role in the future of the translation profession and emphasizes the necessity for translators to follow technological advancements in response to this transformation.

Keywords: natural language processing, deep learning, text processing workflows, translation.

* Ethical Statement: * It is declared that scientific and ethical principles have been followed while carrying out and writing this study and that all the sources used have been properly cited.

² Assoc. Prof., Marmara University, Faculty of Humanities and Social Sciences, Department of Translation and Interpretation (German), İstanbul, Türkiye, derya.oguz@marmara.edu.tr, ORCID ID: 0000-0001-5228-076X

Giriş

Doğal dil işleme-DDI (*Natural Language Processing-NLP*), insan bilgisayar etkileşiminde bilgisayarların insan dilini kullanmaya başlaması amacıyla (Adalı, 2016: 3) ortaya çıkmış, zamanla bilgisayarların doğal dili işlemesiyle hesaplamalı dilbilim (computational linguistics-CL) adıyla da anılır olmuştur (Seker, 2015: 14; Alpaydın, 2022: 135). Yapay zekâ araçlarında dil modelleri olarak karşımıza çıkan doğal dil işleme, bilgisayar teknolojilerinde kullanılmak üzere insan dilini analiz eder, işler ve çıktılarına dönüştürür. Doğal dil işleme günümüzde sosyal medya analizi, sohbet botları, akıllı asistanlar, çağrı merkezlerinde sesli yanıt sistemleri, müşteri memnuniyet analizi, dil çeviri uygulamaları gibi birçok alanda karşımıza çıkmaktadır.

Doğal dil işleme, yapay zekâ alanında makine öğrenimi başlığıyla ilişkilendirilebilir. Makine öğrenimi büyük veriden bilgi çıkararak öğrenen bir sistemdir. Bundan önce bilgisayar programcıları, programlama yapar, verileri ve bununla ilgili kuralları sisteme girer, sistemin bundan çıktı elde etmesini sağlardı. Bu şekilde lineer bir düzenek ile işleyen, girdilerden çıktı üreten tek taraflı bir sistem mevcuttu. Teknolojinin gelişmesi ve internet ile ortaya büyük miktarda veri çıktı. Söz konusu verilerin işlenmesi güçleşmeye başladı. 2000’li yıllarda programlama yerine öğrenme algoritmaları devreye girdi (Alpaydın, 2022: 27). Son yıllarda yapay zekâ alanında makine öğreniminde yapay sinir ağları ile derin öğrenme gibi gelişmeler sayesinde ise sistem verilerden öğrenerek, modeller üretmeye, kendi kendine öğrenmeye ve kendini optimize etmeye başladı³.

Doğal dil işleme, bilgisayar bilimleri, yapay zekâ ve dilbilimin kesişim kümesini oluşturan disiplinler arası bir araştırma alanıdır (Pekcoşkun Güner, 2023: 59). Doğal dil işleme süreçleri Khurana v.d.’ne (2022) göre temelde “doğal dilin anlaşılması” ve “doğal dilin yeniden üretilmesi” olarak ikiye ayrılmaktadır (akt. a.g.e., 59). Doğal dilin anlaşılmasında dilbilim alanlarından yararlanır. Doğal dil işleme, bu yönüyle hesaplamalı dilbilim olarak da adlandırılır (Alpaydın, 2022: 135). Kabaca söz edecek olursak sözü edilen dilbilim alanları: ses bilgisi örüntüleri ve birliktelikleri ile ilgilenen fonetik ve fonoloji, dildeki sözcüklerin kök, yapı, ek ve anlama etkisi bilgisiyle ilgilenen morfoloji, tümce öğeleri ve dizilişleri ile ilgilenen sözdizimi, metinde niyet ve bağlamın belirleyiciliğini inceleyen edimbilim (pragmatik) ve anlambilimdir.

³ Bundan önceki süreçte bilgisayarlar için programlama dilinde programlar yazılıyordu. Şimdi ise örneklerden zengin veri toplanıyor. Veri, öğrenme algoritması tarafından bu verinin tanımladığı gerekliliklerle örtüşecek biçimde öğreniyor ve otomatik olarak güncellenerek kendini düzenliyor. Bir tür tersine mühendislik gibi düşünülebilir (Ethem Alpaydın, 2022: 11; https://www.youtube.com/watch?v=Bee_sls2FIE&ab_channel=TekeTekBilim 10.03.2025).

Makine öğrenimi ve doğal dil işleme, dilbilim alanlarını kullanırken derin öğrenme modelinden faydalanır. Bilgisayar dilinde her şey matematiksel temsillerle ifade edildiğinden doğal dil işleme adımlarında dilsel ifadelerin anlaşılması için bu disiplinlerden faydalanarak dil, matematiksel sayı kümelerine ve kodlara dönüşür. Makine öğreniminde bilgisayarın bir girdiyi tanıması için eğitilmesi sırasında her bir sözcüğe anlam verilir. Sözcüklere yüklenen anlamlar, bağlam içinde ilişkilendirilerek matematiksel bir karşılık bulur. Anlamlarla ilişkilendirilen ve matematiksel bir karşılığı olan sözcükler, bilgisayar dilinde vektör/yöney denilen ve bir tür anlam evrenini temsil eden grafikte aynı yöne bakar. Yapay zekâ böylelikle bir metindeki sözcüklerin bağlantısallığından faydalanarak sözcüklerin birbirine göre kazandığı anlamı, soyutlamalar yaparak matematiksel olarak tespit eder. Soyutlama, derin öğrenmenin temelini oluşturur (Alpaydın, 2022: 91). Doğal dil işlemede programlanmış kurallar üzerine süren araştırmalar, dilin sözcüksel, sözdizimsel ve semantik dilbilimsel kurallarını tanımlayan bir dil modeli oluştururken en verimli öğrenme yönteminin büyük veri kümelerinden yararlanmak olduğunu öne sürmüştür (Alpaydın, 2022: 64). Bu doğrultuda yapay zekâyı büyük veri setleriyle eğittikçe daha doğru sonuçlar vermesi beklenir. Çeviri sırasında buna göre iyi eğitilmiş dil modellerinde algoritma, bağlama göre seçim yaparak doğru karar vermeye çalışır.

Amaç ve yöntem

Çalışmanın amacı doğal dil işleme, derin öğrenme algoritmaları ve metin işleme süreçlerinin çeviri uygulamaları üzerindeki etkisini inceleyerek yapay zekâ çağında dönüşen çevirmenlik mesleği açısından teknolojik gelişmeleri takip etmenin önemini ortaya koymaktır. Bu amaçla betimsel ve analitik bir yöntem izlenmiştir. Doğal dil işleme ve derin öğrenme alanlarında geniş literatür taramasına yer verilmiş; metin işleme süreçleri çeviri bakımından ele alınmış ve metin ön işleme süreçleri örneklerle açıklanmış; insan beyninin dili işleme süreçleriyle doğal dil işleme süreçleri karşılaştırılarak yapay öğrenme alanı değerlendirilmiştir. Bunun yanı sıra elde edilen bilgilerin çeviri süreçlerinde uygulanabilirliği tartışılmış, dönüşen çevirmenlik mesleğinin günümüz gelişmeleriyle uyumlanması gerekliliğinin altı çizilmiştir.

Bulgular ve tartışma

Doğal dil işleme, bilgisayar bilimlerinde makine öğrenimi alanında yapay sinir ağlarının ve derin öğrenme algoritmalarının yaygın kullanımı ile karakterizedir. Derin öğrenmenin uygulandığı büyük dil modellerinde çok katmanlı ağlar kullanılmaktadır ve ağlar arasında çeşitli metin işleme süreçleri gerçekleşmektedir. Metin işleme süreçlerinin, kullanılan mimariye bağlı olmak üzere çeviri süreçlerini etkilediği görülmektedir. Metin işleme süreçleri aynı zamanda çevirinin nasıl gerçekleştiğine dair veri sunmaktadır. Çeviri süreçlerinin

açıklanabilirliği, çevirinin güvenilirliği ve doğruluğu bakımından önemlidir. Doğal dil işleme ve derin öğrenme insan beyninden esinlenerek oluşturulsa da dil modelleri ve mimarileri ile insan beyninin dil işleme süreçleri karşılaştırıldığında, bazı benzerliklere rağmen dil modellerinin kullanılan mimariye göre farklı işleyiş mekanizmalarına sahip olduğu görülmektedir. Bu doğrultuda farklılıklar üzerinde çalışarak dil modellerinin işleyişine aşina olmanın ve teknolojik gelişmeleri takip etmenin, nöral makine çevirisinde doğru sonuçlar elde etmek açısından büyük öneme sahip olduğu görülmektedir.

Doğal dil işleme ne yapar?

Doğal dil işleme, insan dilinin kullanıldığı her türlü yapay zekâ aracında karşımıza çıkar. Artık görüntü ve sesin de eşlik ettiği çokkipli/çokmodlu metinleri de işleyebilen yapay zekânın insan düzeyinde çeviri yapıp yapamayacağı hala tartışma konusudur. Alpaydın (2022: 64-66), doğal dil işleme ve çeviriyi ele alırken yapay zekânın konuşma tanıma ve görüntü tanıma özelliklerinin yanı sıra metin konusuna gelince şöyle bir betimleme yapar:

Bir yüz bir görüntüdür ve söylenmiş bir cümle akustik bir sinyaldir, fakat metin neden oluşur? Metin bir karakter dizisidir ve karakterler bir alfabeye tanımlanır ama bir dil ile kullanılan alfabe arasındaki ilişki basit değildir. Bir cümlenin neredeyse hiçbir zaman tek başına bulunmadığı ya da tek başına yorumlanmaması gerektiği, aksine bir diyalogun ya da genel bir bağlamın parçası olduğu gerçeği bir yana, insan dili mizah ve hiciv gibi incelikleriyle farklı düzeylerdeki sözcüksel, sözdizimsel ve anlamsal kurallar içeren çok karmaşık bir bilgi gösterim biçimidir.

Alpaydın'a göre (a.g.e.: 92) doğal dil işlemede iki temel aşamadan biri olan dili anlama, verilen bir metne göre üst düzey soyutlama yapılarak gerçekleştirilen bir kodlama işlemidir. Dil üretimi ise üst düzey bir soyutlamadan doğal bir dil metnini sentezlediğimiz bir kod çözme işlemidir. Çeviri sırasında kaynak dil kodlanır ve erek dilde kod çözülür. Bu tanımlar işin teknik yönünü betimlemek için kullanılmıştır ve esasında çeviribilimde tartıştığımız üzere dilin çok anlamlılığı, bağlamsal bağlayıcılığı, sosyokültürel faktörlere göre değişkenlik göstermesi, aynı zamanda evrimsel ve dinamik doğası, onu basit bir kodlama işleminden çok daha karmaşık bir yapıya dönüştürür. Tam da bu nedenle dil, elbette basit bir kod çözme işlemi değildir. Yapay çevirinin hala insan denetimi gerektirmesi bu yüzdendir.

Nöral makine çevirisinde ayrıca farklı mimariler söz konusu olsa da klasik olarak kaynak metin ve erek metin arasındaki kodlayıcı ve kod çözücü sistemi (*encoder-decoder framework*), girdileri çıktıya çevirmek üzere yapay sinir ağlarının kullanımı ile karakterizedir (Ahammad v.d., 2023: 39335). Çok basit olarak ifade edecek olursak kodlayıcı ağ, girdiyi işleyerek bunun belli bir matematiksel temsilini oluştururken, kod çözücü ağ, kodlayıcının temsilinden bir çıktı dizisi üretir.

Derin öğrenme algoritması nasıl çalışır?

Derin öğrenmede temel ana fikir, yapay sinir ağları ile soyutlama yaparak insan müdahalesi gerektirmeden öğrenmenin sağlanmasıdır (akt. Alpaydın, 2022: 90; Schmidhuber, 2014). Bu amacı gerçekleştirmek için insan beyninden esinlenerek oluşturulmuş yapay sinir ağları çok önemli bir işlev görür. Yapay sinir ağlarının zemini, daha önce yaptıkları çalışmalarla 2024 yılında Nobel Fizik Ödülü'ne layık görülen John Hopfield (1982) ve Geoffrey Hinton (1986)⁴ tarafından hazırlanmıştır. Daha sonra gerçekleştirdikleri çalışmalarla Hinton, LeCun ve Bengio yapay sinir ağlarını geliştirmiş ve 2018 Turing Ödülü'nü⁵ almıştır. Bilgisayar sisteminde yapay sinir ağları insan beynine benzer biçimde birbiriyle etkileşime geçerek öğrenirler. Yapay sinir ağları, girdi katmanını, ara katmanlar (*hidden layers*) ve çıktı katmanından oluşur. Girdi katmanında veri işlenir, verilerin önem derecesine göre gerçekleşen bağlantılara ağırlıklar atanır. Sonrasında insan beyninde olduğu gibi bir tür aktivasyon (*activation functions*) gerçekleşir ve sinyal üretilir. Burada üretilen veriler her katmanda işlenerek ilerler ve sonrasında geriye yayılarak (*backpropagation*; Rumelhart v.d., 1986) ağırlıkları günceller ve öğrenme gerçekleşir. Bu şekilde yapay sinir ağı, çıktıları güncellemeyi ve doğru tahmin yapmayı öğrenmiş olur.


Yapay sinir ağları, girdileri anlamlandırmak için verileri sayısal hale getirir. Bu doğrultuda bilgisayarlar sayıları ya da bilgileri 0 ya da 1'den oluşan ikili bit dizileri olarak temsil eder ve bu tür bit dizileri başka bilgi türlerini de temsil edebilir. Örneğin "101100", ondalık sayı 44'ü temsil etmek için kullanılabilir ayrıca virgölün kodu olarak da kullanılabilir (Alpaydın, 2022: 18). Verilerin bit dizileri olarak temsil edilmesi bilgisayar sistemlerinde olduğu gibi doğal dil işlemede de temel bir adımdır.

Doğal dil işlemede kullanılan derin öğrenme algoritmasının mekanizmasını kabaca anlamak için somut bir örnek verelim⁶. Diyelim ki bir harf var ve onu tanıması için bilgisayar dilinde 0 ile 9 arasında sayı atanarak bazı veri setleri oluşturuluyor. Bilgisayara söz konusu harfin çeşitli versiyonları bu şekilde girdilerle tanıtılıyor (bkz. Görsel 1). Makine öğreniminde veri setleri ile bu harfi tanıyor ve öğreniyor. Bunun için sınır tanıma (*boundary detection, edge detection*) adı verilen matematiksel bir işlemle veri setleri oluşturuluyor.

4 Geoffrey Hinton'ın sözü edilen çalışması "Rumelhart, D. E., Hinton, G. ve Williams, R. J." adıyla kaynakçada verilmiştir.


3 <https://awards.acm.org/about/2018-turing> (17.03.2025); yapay zekâ hakkında detaylı bilgi için bkz. LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. "Deep learning." *nature* 521.7553 (2015): 436-444.

4 Evrim Ağacı youtube kanalında "ChatGPT Her Şeyi Nasıl Bilebiliyor?" başlıklı videoda derin öğrenme ile ilgili verilen örnekten faydalanılmıştır. <https://www.youtube.com/watch?v=7foCbOktTzM> 10.03.2025



Görsel 1


Sınır tanıma ile gerçekleştirilen matematiksel işlemde el yazısı biçimindeki a harfini girdiyi dönüştürmek ve makine öğrenmesine hazırlamak için görüntü kutu içine alınır. El yazısı biçimindeki “a” harfi görüntü işleme tekniğiyle piksellere ayrılır ve her piksel parlaklık değerine göre bir sayıyla temsil edilir. 28x28 pikselden (piksel, insan beyninde nörona tekabül etmektedir) oluşan kutuda “a” harfi beyaz ve gri renklerden oluşmaktadır. Siyah pikseller ise zemini oluşturmaktadır. Siyah renginde kalan piksellere “0”, beyaz-gri aralığında parlak görünümde harfi oluşturan piksellere ise parlaklıklarına göre “0.1, 0.2, 1.0” arasında ikili haneler atanır. Bu sayılar el yazısının beyazlık ve grilik derecesine göre verilir (bkz. Görsel 2).



Görsel 2

784 pikselin toplamı ile girdiyi oluşturduktan sonra elde edilen çıktı arasındaki ilişkide öğrenme sırasında aradaki iki katman arasında el yazısının belli niteliklerini tanımlayacak biçimde çeşitli bağlantılar gerçekleşir. En sağda ise katmanlar arasında gerçekleşen bağlantılar sonucunda görseldeki harf ya da sayı matematiksel bir karşılık elde etmektedir. Sağda hangi sayı görünür hale gelirse, sistem kendisine gösterilen yazının o olduğunu düşünmektedir (bkz. Görsel 3). “Gizli katmanlar” denilen ara katmanlarda görüntünün belirli özellikleri (örneğin, eğim, çizgiler) tanınır ve son katmanda bu özellikler birleştirilerek⁷ harf ya da sayı tahmini yapılır. Sistemin adının derin öğrenme olmasının altında katmanlar arasında gerçekleşen işlemler silsilesinin derinliği yatmaktadır (Goodfellow v.d., 2015: 165).

⁷ Son tahmin softmax aktivasyonu ile gerçekleştirilmektedir (Antoine ve Tixier, 2018: 6).



Görsel 3

Temel anlamda yapay zekânın çalışma mekanizması yukarıdaki gibi olmakla beraber her geçen gün insan beyninden esinlenerek gelişen, kendini optimize eden ve geliştirilen yeni yapay sinir ağları, yapay zekânın gittikçe yeni özellikler kazanmasını sağlamaktadır. Derin öğrenme algoritmaları, yalnızca el yazısı tanıma değil, görüntü tanıma, makine çevirisi (Bahdanau v.d. 2015: 12) gibi birçok alanda oldukça önemli bir etki sağlamaktadır.

Katmanlar arasında neler oluyor? Kara kutu mu?

Derin öğrenme konusunda yukarıda anlatılan girdi ve çıktı arasındaki katmanlar ve sayılar temsilidir. Kullanılan mimarinin, modelin özelliklerine göre katman sayısı ve işleyiş mekanizması değişiklik arz etmektedir. Büyük dil modellerinde dil, çoklu katmanlar arasında işlenmektedir.

Bir dil modelinde girdi ve çıktı arasındaki katmanlar arttıkça olasılıklar da arttığı için öğrenmenin derinleştiği kabul edilmektedir. Katmanlar arasında veri işlenerek ve bağlantıların niteliğine göre soyutlanarak ilerler ve bu süreçte dil modeli belli özelliklere göre çıkarım yapar (*feature extraction*; Alpaydın, 2022: 87). Katmanlar arasında gerçekleşen bağlantıların çokluğu, karmaşıklığı ve niteliği dışardan bakıldığında tam anlaşılamamaktadır. Dolayısıyla dilin işleme süreci, şeffaf olarak kabul edilmemekte ve bu nedenle yapay zekâ kara kutu (*black box*) olarak adlandırılmaktadır. Öte yandan karar verme süreci daha net izlenebilir ve açıklanabilir, kısmen şeffaf ya da tamamen şeffaf (*white box*) olarak nitelendirilen modeller (kural tabanlı, istatistiksel makine çevirisi gibi modeller vb.) mevcut olsa da bu modeller özellikle çeviride istenen sonuçları vermemektedir. Derin öğrenmeye dayalı modellerde ise sonuçlar çok daha başarılı olsa da modelin neye göre karar verdiğini anlamak, ayrıca bir zorluk oluşturmaktadır.

Yapay zekânın hayatımızda gelecekte oldukça önemli bir yer tutacak olması sebebiyle şeffaflık ve açıklanabilirlik gibi konular son zamanlarda gündeme gelmiştir. Dil modellerinde özellikle tıp, hukuk gibi insan hayatını etkileyen alanlar başta olmak üzere karar verme mekanizmalarının açıklanabilirliği gittikçe önem kazanmaktadır. Hatta bu konuda Explainable

Artificial Intelligence-XAI adı verilen açıklanabilir yapay zekâ modelleri önerilmekte ve bu ihtiyaca dikkat çekilmektedir (Samek v.d., 2017; Holzinger v.d., 2022; Luo v.d., 2024). Bu durum doğal dil işleme ve derin öğrenme modeli ile çalışan çeviri araçları için de geçerlidir. Çeviri araçlarının eğitilmesi ve geliştirilmesi bakımından bir çeviri aracının karar verme mekanizmalarını görmek, çevirilerin güvenilirliğini artırmaya yardım edecektir. Bir çeviri aracının çeviri sürecinde insan çevirmenin karar mekanizmalarıyla benzer bir biçimde çalışıp çalışmadığı, neden-sonuç silsilesi ile yaptığı çıkarımlar, sistemin ön kabulleri ve temel aldığı doğrular, özellikle ön yargıları araştırmaya değer heyecan verici konulardır ⁸. Yapay zekâda öğrenme algoritmasının yatkınlığını/yanlılığını, varsayımlarını (*inductive bias*, Alpaydın, 2022: 45) açıklanabilirlik ile tespit edebilmek, sistemin neye göre genelleme yaptığını anlamayı sağlayabilir; daha doğru ve güvenilir sonuçlar elde etmenin ön koşulu olabilir.

Yapay zekâ ile çalışan doğal dil modellerinde açıklanabilirlik konusu oldukça güncel bir konu haline gelmiştir. Dil modelleri ham veriyi birçok ön işlem ve işleminden geçirerek öğrenir. Bu süreçte gerçekleşen işlemler derin öğrenme algoritmalarının doğruluğu, güvenilirliği ve açıklanabilirliği bakımından ayrıca önem arz etmektedir. Bu süreçlerle ilgili bilgi sahibi olmak ve bir dil modeli eğitiminde bunları uygulamaya dönüştürmek, bir taraftan modelin performansını artıracak diğer taraftan açıklanabilirliğe katkı sunarak daha doğru ve güvenilir çeviriye doğru sistemlerin optimizasyonuna hizmet edecektir.

Metin işleme süreçleri

Doğal dil işlemede veri toplama, veri hazırlama ya da veri ön işleme, özellik belirleme, model eğitimi, test ve değerlendirme, sonuçların yorumlanması, geliştirme ve optimizasyon gibi temel ve genel işlemlerden söz edilebilir. Metinler üzerinden bilgiye erişme (*information retrieval*), bilgi çıkarma (*information extraction*) ve veri madenciliği (*data mining*) işlemlerini metin madenciliği (*text mining*) ana başlığında toplayabiliriz. Metin madenciliği, metinlerden bilgi çıkararak ve bilgiyi bir dizi işleminden geçirerek anlamlı sonuçlar çıkarmaya yardım eder ve metin ön işleme metin madenciliği için oldukça önemlidir (Feldman ve Dagan, 1995; akt. Lourdasamy ve Abraham, 2018: 148). Daha çok teknik boyutuyla mühendislerin ilgilendiği bu adımlardan ziyade dilbilim alanını ilgilendiren bazı metin işleme adımları mevcuttur. Doğal dil

⁸ Bu konuda ilginç çalışmalar yürütülmektedir ve gün geçtikçe gelişme kaydedilmektedir. Sözgelimi Singh v.d. (2023) yaptıkları bir çalışmada fMRI ile beyin taramalarında belirli bir bölgeyi temsil eden veri noktalarının dilsel uyarılara verdiği tepkileri yapay zekânın açıklayabileceğini göstermiştir. Bu çalışmada kara kutu, yapay zekânın şeffaflığı ve açıklanabilirliği (*explainable AI*) konusuna yeni bir bakış açısı sunan “Özetle ve puanla” (*Summarize and Score- SASC*) yöntemi tanıtılmaktadır. Araştırmacılar bu yöntemi kullanmayı önererek yapay zekânın, açıklanabilirliğe katkı sunacağını savunmaktadır. Yöntemin kodları github’da kullanıma sunulmuştur. SASC, yapılan işlemler için metin modüllerinde en güçlü yanıtın ya da kararın neye göre verildiğini gerekçelendiren doğal dil açıklamaları üretmekte ve bunun için insan müdahalesi gerektirmemektedir.

işlemede çeviri amaçlı gerçekleşen bazı metin işleme uygulamaları, genellikle dille uğraşan, morfoloji, sözdizimi, anlabilim, pragmatik gibi alanlarda uzmanlığı olan kişiler ile doğal dil uzmanları, veri analistleri, yapay zekâ mühendisleri gibi mesleklerin disiplinler arası çalışmaları ile gerçekleştirilir. Doğal dil işleme ile ilgilenmek, temel makine öğrenimi algoritmalarına aşina olmak, çeşitli doğal dil işleme ve derin öğrenme mimarilerinden haberdar olmak, bu alanda çalışmayı sürdürmek isteyenler için artık bir zorunluluk gibi görünmektedir. Metin işleme ile ilgilenen çevirmenler, ayrıca veri setlerinin hazırlanmasında, ayıklanmasında ve dil modellerinin eğitilmesinde görev alabilirler.

Çeviri amaçlı bir dil modeli oluşturulurken öncelikle çok miktarda çift dilli veri setine ihtiyaç vardır. Veri setleri, her iki dilde paralel metinden oluşabilir. Bunun yanı sıra açık kaynak dil ve veri sağlayıcılarından, web sitelerinden, çeşitli derin öğrenme kütüphanelerinden dil verileri elde edilebilir. Toplanan veri, metinlerdeki tutarsızlıklar ve hatalar bakımından incelenir; temizleme ve ayıklama işlemine tabi tutulduktan sonra etiketlenerek kullanıma hazır hale gelir. Veri etiketleme, makine öğreniminde hangi verilerin ne anlama geldiğini öğretmek için yapılan bir işlemdir; modelin girdi ve çıktı arasındaki ilişkiyi öğrenmesini sağlar. Kaynak ve erek metinde tümcelerın eşleştirilmesi buna örnek verilebilir.

Verilerin etiketlenmesinin ardından metin, ön işleme süreçlerinden geçer ve ardından eğitimden geçirilir. Eğitim tamamlandıktan sonra dil modeli, gerçek veri ile test edilir. Dil girdileri ile çeviri yapılarak çıktı kontrol edilir. Sonrasında modelin çeviri kalitesi çeşitli metriklerle ölçülür. Tekrar başa dönersek metinlerin işlenmesi için bir hazırlanma aşamasına, diğer bir deyişle veri ön işlemeye (*preprocessing*) ihtiyaç vardır. Metin işleme ile ilgili bazı adımlar şöyledir: ⁹

Öncelikle metinlerin dili tespit edilir (*detect language*; Jabeen v.d. 2023: 4). Makinenin genelleme işlevini artırmak için metindeki özel karakterler temizlenir. Sözelimi Almancada kullanılan “ö, ä, ü” gibi karakterlerin yerine standart harfler getirilir. “Ich mag Österreich” (Avusturya’yı seviyorum) tümcesinde “Österreich” sözcüğü “Oesterreich” biçimine, “eşdeğerlik” anlamındaki “Äquivalenz” sözcüğü “Aequivalenz” biçimine dönüştürülür. Bunun yanı sıra kullanılan dile bağlı olarak yanlış kodlanan karakterler ve yazım hataları düzeltilir. Örnek verecek olursak “tapınılan ve fazla önem verilen şey; put,” anlamındaki “der Götze”

⁹ Metin işleme süreçleri ve ön işleme adımları birkaç çalışma (Ahmmed v.d. 2023; Jabeen v.d. 2023; Sankar ve Subramaniyaswamy, 2017; Lourdasamy ve Abraham, 2018) ve ChatGPT yardımıyla derlenmiştir.

sözcüğü “G\u00F6tze” biçiminde bir *unicode*¹⁰ karakterle temsil ediliyorsa bu karakter normalize edilerek “Götze” biçimine çevrilir.

Metin ön işleme sürecinde metin, kullanım amacına göre sözcüklere, anlamlı ve işlenebilir birimlere ayrılır ve bu işlem *tokenization*¹¹ olarak adlandırılır (Jabeen v.d. 2023: 4; Sankar ve Subramaniaswamy, 2017: 87). “Die Zitronenfalter fliegen im Sommer” (Limon kelebekleri yazın uçar) tümcesinde her bir sözcüğü [‘Die’, ‘Zitronenfalter’, ‘fliegen’, ‘im’, ‘Sommer’] biçiminde tek tek ayırması tümcenin tokenize edilmesi demektir. Bunun yanı sıra bazı bileşik sözcükler [“Zitrone”, “##n”, “##falter”] biçiminde alt sözcük düzeyinde bileşenlerine ayrılır (*subword tokenization*). “##” sembolü, sözcüklerin alt birimlerini gösterir. Tümcenin Türkçesi [‘Limon’, ‘kelebekleri’, ‘yazın’, ‘uçar’] biçiminde birimlere ayrılırken, alt birimlere ise [“kelebek”, “##leri”] biçiminde ayrılabilir. Veri setine bağlı olarak kimi zaman birimlere ya da alt birimlere ayırma doğru gerçekleşmeyebilir. Model bir sözcüğü tanıımıyorsa ve ilk defa görüyorsa sözgelimi “Zitronenfalter” sözcüğü [“Zitrone”, “##n”, “##falt “##er”] biçiminde alt birimlere ayırabilir. Bu “Falter” sözcüğünün “kelebek” olarak tanınmadığını, “katlamak” anlamında kullanılan “falten” sözcüğüne göre ayırma yaptığını gösterir. Burada model istatistiksel olarak en çok gördüğü sözcüğe ve en çok kullanılan kombinasyonlara göre karar verir. Bu bağlamda modelin morfolojik analiz yapabilmesi önemlidir.

Metin işlemede yukarıdaki işlemlerin yanı sıra metin, büyük ve küçük harf farkı kaldırılarak küçük harflere dönüştürülür (*lowercasing*). Bunun amacı metni normalize (*normalization*) ederek eğitim aşamasına hazırlamaktır. Camacho-Collados ve Pilehvar (2018: 2) bu uygulamayı açıklarken “Apple is asking its manufacturers to move MacBook Air production to the United States” tümcesini örnek vererek “apple” sözcüğünün çevirisinde şirket olan “Apple” ile meyve olan “elma”nın normalde karışabileceğine dikkat çeker. Metin işlemede bunun yanı sıra sözcüklerin anlaşılması ve yüksek oranda doğruluğun sağlanması için sözcükler kök ve eklerine kadar incelenir ve indirgenir (*stemming*; Camacho-Collados ve Pilehvar 2018: 2). Bu işlem alt sözcük düzeyinde gerçekleşen birimlere ayırma işleminden (*subword tokenization*) farklıdır. Burada dilbilgisel olarak kök formu tespit edilir ve bağlam önemli değildir. Sözgelimi Almanca oyuncu anlamındaki “Spieler” sözcüğün kök formu “Spiel” dir. Türkçeden bir örnek verecek olursak “sevinç” sözcüğünün kökü “sev” olarak alınır; “inç” eki ise isim türeten bir yapım ekidir. Model burada sözcüğün kökünü “sevin” olarak da alabilir. Aynı şekilde “sevgi”

¹⁰ *Unicode*, farklı alfabelere ait karakterlerin tek bir standartta kodlanmasını sağlayan evrensel bir kod sistemidir. Kodlama türleri ve dil özelliklerine uygun bir şekilde UTF-8, ASCII, ISO-8859-1 gibi formatlar arasında dönüşüm yapılabilir. Unicode düzeltmeleri dil modelleri için önemlidir.

¹¹ *Token* sözcüğü gösterge, belirti işaret anlamlarına gelir. Sözcük veya daha küçük birimlere *token* denilebilir.

sözcüğünün kökü “sev”dir. Duygu analizi ya da metin sınıflandırma gibi işlevlerde kök yanlış alındığında iki sözcük birbirine karışabilir. Şöyle ki “Yazdığı kitabın yayımlanması ona büyük sevinç verdi” tümcesinde “sevinç” soyut bir kavramdır ve bir duygudur. “Sevgi onu iyileştirdi” tümcesinde ise “sevgi” sözcüğü yine soyut bir kavram olmakla birlikte farklı bir duygudur ve her tümcede bir duygu olarak alımlanmaz. Eğer morfolojik analiz doğru yapılmazsa model, kökü esas alarak iki sözcüğü de aynı duygu olarak kabul edebilir.

Diğer taraftan herhangi bir sözcüğün kök formu dışında temel halini alma/indirgeme işlemi (*lemma*¹²- *lemmatization*; Jabeen v.d. 2023: 4; Camacho-Collados ve Pilehvar 2018: 2) uygulanır. Sözcükler, sözlükte yer aldığı biçimine indirgenir ve bu noktada bağlam esas alınır. İndirgeme işlemine Almancadaki sıfatların derecelendirilmesi (*Komparativ*) konusundan örnek verebiliriz. Sözelimi “daha yüksek” anlamındaki “höher” sıfatının temel formu “yüksek, yukarı” anlamındaki “hoch” sözcüğüdür. Farklı bir örnek üzerinden gidersek “daha iyi” anlamındaki “besser” sözcüğünün temel formu ise sözcüğün kök formundan farklı olmak üzere “iyi” anlamına gelen “gut” sözcüğüdür. Türkçeden örnek verirsek “Sabahları koşuyorum.” tümcesinde “sabahları” sözcüğünün kök formu “sabah”, “koşuyorum” sözcüğünün sözlük biçimine indirgenmiş hali ise “koşmak”tır. Buradaki seçim, anlamsal ve dilbilgisel analizler sonucunda makinenin öğrenmesiyle gerçekleşir.

Bu adımda ayrıca gürültü giderme (*noise removal*; Jabeen v.d. 2023: 4) adı verilen bir aşamada, gereksiz karakterler, semboller, hatalı yazımların ayıklanması gerçekleştirilir ve anlama etkisi bulunmayan sözcükler (*stop words removal*) ayıklanır (Sankar ve Subramaniaswamy, 2017: 88; Lourdasamy ve Abraham, 2018: 149). “And”, “this”, “are”, “ben”, “bir”, “ve”, “oder”, “und”, “mit” gibi dolgu sözcükleri metinden kaldırılır. Sözelimi Almancada “mit” sözcüğü bağımsız bir edat (*Präposition*) görevinde kullanıldığında dolgu sözcüğü olarak işaretlenip silinebilir ancak “mitbringen” biçiminde ayrılabilir bir fiil olarak kullanıldıysa “mit” ön eki dolgu sözcüğü olarak görülmez. Bu durumu ayırt etmek için özellikle bağlamı dikkate alan algoritmalar kullanılır.

Bunun yanı sıra metin işleme sürecinde metindeki kısaltmalar belirlenir (örn: dm, TSK, do not vs.) ve “dm-direct message/data mining”, “TSK-Türk Silahlı Kuvvetleri” biçiminde açıklanır. Sözelimi Almancada “Wie geht’s dir?” ifadesi, kesme işareti ayıklanarak “Wie gehts dir” biçimine getirilir. “Der Roman (geschrieben von Goethe) ist berühmt” tümcesi, parantezinden arındırılarak “Der Roman ist berühmt” biçiminde alınır. Türkçesinde “Roman (Goethe

¹² *Lemma* sözcüğü Latince “elde tutulan, önerme, temel” anlamlarında kullanılmış, Yunanca “lēmna” (λήμμα) sözcüğünden türemiştir. <https://www.nisanyansozluk.com/kelime/lemma>

tarafından yazılan) ünlüdür.” tümcesi “Roman ünlüdür.” biçiminde alınır. Metinlerin işlenmesinde etkisiz sözcüklerin ayıklanmasının sebebi, anlamda ve içerikte belirleyici olmayan sözcüklerin yok sayılarak modelin hata yapmasının engellenmesi ve duru bir verinin çıkarılabilmesidir.

Diğer bir metin işleme uygulaması, metin içerisinde geçen sözcüklerin dilbilgisel kategorisi ve sözcük türünü tespit etmek için kullanılan sözcük türü etiketlemedir (*part-of-speech POS tagging*; Sankar ve Subramaniaswamy, 2017: 88). POS adı verilen etiketleme, isim, zamir, fiil, zarf, sıfat, artikel, edat ve bağlaç gibi sözcük türlerinin tümce içindeki kullanımı, komşu sözcükler ve onların etrafında örülen sözdizimsel yapı hakkında olası bilgilerin çıkarılmasına yardımcı olur (Lourdusamy ve Abraham, 2018: 149). Sözcükler türüne göre tespit edildikten sonra tümce içinde kullanımında hangi tümce ögesi olduğu belirlenir (Deshmukh ve Kiwelekar, 2020). Bu, anlamın belirlenmesinde önemli bir adımdır. Tümce ögeleri belirlenirken aynı zamanda sözdizimsel çözümleme (*syntactic parsing*; Sankar ve Subramaniaswamy, 2017: 88) yapılır. Sonuç olarak POS etiketleme, sözcüğün türünü ve tümcedeki işlevini belirleyerek bağlamdan anlam çıkarmaya yarar. Bu konuda Lourdusamy ve Abraham (2018: 149), İngilizcede hem isim hem fiil işlevi gören “book” sözcüğü ile yine birçok farklı işlevde kullanılabilen “that” sözcüğünü verirler. “Book that flight” tümcesinde “book” sözcüğü, “ayırtmak” anlamında fiil olarak kullanılırken, “Hand me that book” tümcesinde isim “kitap” anlamında isim olarak işlev görmektedir. “That” sözcüğü ise bu tümcelerde işaret sıfatı olarak göze çarpmaktadır. Oysa “I thought that your flight was earlier” tümcesinde “that” sözcüğü bağlaç işlevindedir. Örnekleri Almanca üzerinden genişletirsek “Band” ve “das” sözcüklerini inceleyebiliriz. Almancada “Band” sözcüğü önüne aldığı artikele (tanımlık) göre farklı anlamlarda kullanılır. “Ich brauche das rote Band.” (Kırmızı kurdeleye ihtiyacım var) tümcesinde “Band” sözcüğü “das” tanımlığı olarak “kurdele” anlamında kullanılır. “Ein Werk in zehn Bänden” (On ciltlik bir eser) ifadesinde “Band” sözcüğü “der” tanımlığı alır ve “cilt” anlamında kullanılır. “Wie heißt die Band?” (Bu müzik grubunun adı ne?) ifadesinde ise sözcük “die” tanımlığı alır ve “müzik grubu” anlamındadır. “Das” sözcüğüne gelirse yukarıdaki “das rote Band” ifadesinde tanımlık olarak kullanılırken, “Ich dachte, das wäre klar” (Konunun yeterince açık olduğunu düşünüyordum) tümcesinde “das” sözcüğü tanımlık değil, zamir görevindedir ve tüm tümceyi etkiler. POS etiketleme, örneklerde görüldüğü üzere farklı dilbilgisel işlevlerde kullanılan yapıları bağlama göre ayırt etmeyi öğrenerek etiketler.

Bu aşamanın ardından metnin özelliklerinin belirlenmesi için özellik çıkarma (*feature extraction*; Jabeen v.d. 2023: 4) işlemi uygulanabilir. Bu adımda metnin anlam belirleyici

özellikleri sayısal bir formata dönüştürülerek modelleme yapılır. Metin işleme süreçlerinde ayrıca model eğitimi sırasında sözcük gömme işlemi (*embedding*) gerçekleşir. Sözcük gömme işleminde sözcükler, sayısal vektörlere dönüştürülerek matematiksel ifadeler haline getirilir. Böylece sözcükler anlamsal ilişkilerine ve bağlantısallıklarına göre kategorize edilerek kullanılmaya hazırlanır ve doğru anlamın yakalanması sağlanır (Ahammad v.d., 2023: 39341). Gömme, aynı zamanda modelin kendini optimize etmesi ve öğrenmesi bakımından oldukça önemli bir aşamadır.

Bunun yanı sıra metin ön işleme veya sonrasında da bir dizi işlem gerçekleşir. Sözelimi dilin bağlamını ve yapısal örüntüsünü anlamak için N-gram denilen sayısal değerler oluşturulur. N-gram, tekli, ikili ya da üçlü sözcük gruplarının ve örüntülerin nasıl kullanıldığını sayısal temsil eder. Somutlaştıracak olursak metin içerisinde geçen “cep” ve “telefon” sözcükleri ayrı ve tekli bir n-gram (*unigram*) ile ifade edilirken “cep telefonu” ikili bir n-gram (*bigram*) ile ifade edilir. Bu aşama, sözcüklerin tek başlarına anlamlarının yanı sıra bir araya geldiklerinde ayrı bir anlam kazandıklarının anlaşılması bakımından önemlidir. Son işleme adımında modelin doğruluğunun ölçülmesi için de n-gram kullanılabilir (Liu v.d., 2003). Ardından metin içerisindeki özel isimler, kurumlar, tarihler, para birimi gibi varlık isimleri (*named entity recognition*) belirlenir (Sharma v.d., 2022).

Diğer bir metin işleme aşaması, eğitim sırasında uygulanan metin sınıflamadır. Makine öğreniminde ve doğal dil işlemede metin sınıflandırma (*text classification*), algoritmada istatistiksel yöntemler kullanılarak metni içeriğine göre belli kategorilerde sınıflandırma işlemidir. İleri düzey ve özel amaçlı metinlerde gerekiyorsa metnin tonunu belirlemek için ton analizi (*ton analysis*), niyet analizi (*intent analysis*) ya da duygu analizi (*sentiment analysis*; Sankar ve Subramaniaswamy, 2017: 89) yapılır. Yukarıda sayılan işlemler, eğitim sırasında sistemin bu verilerden öğrenmesini sağlayarak metni sınıflandırmaya yardım eder. Metin işlemede gerçekleşen uygulamalar, dil modelinin kullandığı mimariye göre değişkenlik gösterebilmektedir.

Dil modelleri, dil mimarileri ve güncel çalışmalar

Nöral makine çevirisinde daha önce de belirttiğimiz üzere genellikle kaynak metin ve erek metin arasındaki kodlayıcı ve kod çözücü sistemi (*encoder-decoder framework*) kullanılır. Kodlayıcı ağ, girdiyi işleyerek bunun belli bir matematiksel temsilini oluştururken, kod çözücü ağ, kodlayıcının temsilinden bir çıktı dizisi üretir. Derin öğrenme, metin verilerindeki karmaşık örüntüleri modellemek için çok katmanlı yapay sinir ağlarının kullanılması anlamına gelir. Günümüzde derin öğrenmede çeşitli özellikte gelişmiş evrişimli (*Convolutional Neural*

Networks-CNN), üretken çekişmeli sinir ağları (*Generative Adversarial Networks-GAN*) ile özellikle nöral makine çevirisinde yineleyen/özyineleyici sinir ağları (*Recurrent Neural Networks-RNN*) ve *Transformer* gibi modeller kullanılmaktadır. Yapay zekâ her geçen gün yeni gelişmelere gebedir. Bu ağların çok katmanlı, ileriye dönük ve beslemeli özellikleri sayesinde daha doğru çeviri, duygu analizi, görüntü üretme gibi nitelikler yapay zekâyâ eklenmeye devam etmektedir.

Ahammad v.d. (2023: 30337) yaptıkları çalışmada nöral makine çevirisinde birkaç prototipi, yeni nesil mimarileri ve çalışma prensiblerini incelemişlerdir. Sözgelimi en çok kullanılan platformlardan biri olan Google translate yineleyen sinir ağları (RNN) ile birlikte bu mimariye “dikkat modülü” anlamında *attention* düzeneği ekleyerek sistemin verimliliğini ve yüksek doğruluğunu hedeflemiştir. Çeşitli çeviri araçlarında evrişimli sinir ağları (CNN) ile yineleyen sinir ağları (RNN) kombine biçimde kullanılabilir. Bunun yanı sıra GPT (*Generative Pre-trained Transformer*) gibi “*attention*” (Vaswani v.d., 2017) özelliği içeren Transformer mimarisi de son zamanların güncel uygulamalarındandır. “*Self attention*” (öz dikkat) (Shaw v.d. 2018; Rahali ve Akhloufi, 2023) mekanizması ise nöral makine çevirisinde umut vaat eden bir ağ türü olarak kabul edilmiştir. Bu mekanizmayla sistem, uzun süreli hafızada belli verileri tutarak ve göz önünde bulundurarak metni işlemektedir.

Transformer (Irie v.d. 2020; Patwardhan v.d., 2023; M.P. Brasoveanu ve Andonie, 2020) mimarisi *encoder-decoder* adı verilen iki bileşenden oluşur. Bu bileşenler hem öz dikkat (*self-attention*) mekanizmasından hem de ileri beslemeli (*feed-forward*) yapay sinir ağı katmanlarından oluşur. *Self attention*, Transformer’ın en yenilikçi özelliklerinden biridir ve bu mekanizma, bir tümcedeki her bir sözcüğün diğer sözcüklerle olan ilişkisini değerlendirir. Öncelikle girdi, diğer bir deyişle metin, ilk katmana iletilir. Metin ön işlemde geçer ve gömme işlemi gerçekleştirilir. Girdi, sayısal vektörlere dönüştürülür. Sözdizimini düzenlemek için vektörlere pozisyon kodlama eklenir. Sonrasında self-attention mekanizması devreye girer; girdiler, ağırlıklarla işlenir ve her sözcüğün diğer sözcüklerle bağlantısallığı incelenerek bir dikkat skoru hesaplanır. Bu aşamada, her sözcüğün dikkat skoru hesaplanırken, sapma (*bias*)¹³ adı verilen değer de eklenir. *Bias*, modelin ağırlıklarla doğrusal ilişkiler öğrenmesi yerine, daha karmaşık yapıları öğrenmesine olanak sağlar. Self-attention mekanizması, dikkat skorları, matris çarpımları ve normalizasyon işlemleri ile gerçekleştirilir; böylelikle model, her sözcüğün diğer sözcüklerle olan ilişkisini öğrenir ve girdilerin anlamı belirlenir. Normalizasyon, her katmandaki girdilerin ortalamasını düzenleyerek hızlı öğrenmeyi sağlar. Bunun yanı sıra

¹³ *Bias* bilgisayar bilimlerinde aynı zamanda makinenin yanlılığı, ön yargıları anlamına da gelir.

modelin hangi bilgileri aktarıp hangi bilgileri elemesi gerektiğini belirleyen ve matematiksel bir işlem olan aktivasyon fonksiyonları devreye girer; modelin daha karmaşık yapıları öğrenmesi sağlanır. Burada yapay sinir hücresine gelen sinyal alınır ve yeterince güçlü ise nöron aktif hale gelir, veriler bir sonraki katmana iletilir. İleri beslemeli sinir ağları bu şekilde çalışır ve Transformer mimarisinde her katmanda aynı işlem yeniden yapılır. Transformer gibi büyük dil modelleri büyük veri setleri ile eğitilir. Eğitim sürecinde model, sözcük ve tümce temsilcilerini optimize eder, böylelikle karmaşık kalıpları öğrenir. Model hataları en aza indirmek için geri yayılım (*backpropagation*) algoritmasını kullanarak ağırlıkları günceller. Geri yayılım yapay zekanın temelini oluşturan önemli bileşenlerden biridir (Dohare v.d., 2024). Bu şekilde döngü tekrarlanarak model öğrenmiş olur.

Wang v.d.’nin (2024) büyük dil modellerini incelediği, insan ve makine arasındaki ayırmadan söz edilerek bazı mimariler hakkında ayrıntılı bilgi verdiği çalışmada ise, Transformer mimarisi hakkında çoklu dikkat katmanları kullanılmasından ve modelin bağlamsal anlam ayırt etmeyi öğrenmesinden (2024: 5) farklı olarak bu modellerin ön eğitiminde sözcük maskeleyme (*Masked Language Modeling-MLM*) kullanıldığından söz etmiştir. Wang v.d. bunun için 2018 yılında Google’ın tanıttığı ve kullandığı BERT modelinin sözcük maskeleymesini örnek vermiştir. GPT ise tüm bağlamları dikkate alarak sonraki sözcüğü tahmin mekanizmasına dayanmaktadır.

Büyük dil modellerinden biri olan BERT (*Bidirectional Encoder Representations from Transformers*) (Koroteev, 2021), yine Transformer mimarisine dayanan *Encoder* tabanlı bir dil işleme modelidir. Encoder katmanları sayesinde bir metin girdisinde sözcüklerin birbiriyle ilişkisini anlamak için dikkat self-attention kullanılır. BERT, giriş metnini hem soldan sağa hem de sağdan sola doğru işler. Bu çift yönlü işleme (*Bidirectional Processing*, a.g.e.: 8), modelin sözcükler arasındaki daha karmaşık bağlantısal ilişkileri anlamasını sağlar. Transformer’da olduğu gibi burada da modelin sözdizimini anlaması için pozisyon kodlama kullanılır. BERT, büyük bir metin veri kümesi üzerinde iki görev için önceden eğitilir: Maskelenmiş Dil Modeli (*Masked Language Model- MLM*, a.g.e.: 2) ve Sonraki Tümce Tahmini (*Next Sentence Prediction- NSP*, a.g.e.:12). Bu süreç, modelin geniş bir dil bilgisi edinmesini sağlar.

Lindborg ve Rabovsky’nin (2021:1049-1050) yaptığı çalışmaya baktığımızda GPT-2’nin yine bir tür dikkat mekanizmasıyla işlediği, bu mekanizma sayesinde modelin, bir metin parçasındaki tüm önceki girdileri hatırladığı ve mevcut sözcüğü işlerken önemli görülen sözcüklere dinamik olarak dikkat atadığı görülmektedir. Buna karşın yinelemeli sinir ağları (RNN) kullanan diğer dil modeli SG’nin (*Sentence Gestalt*) tümcelerin anlamını kavramada durum ya da olayları haritalama ile tahmin ettiği görülmektedir. SG modeli, dilin dünya ile

bağlantılı olarak nasıl işlendiğini ve anlamlandırıldığını incelemek üzerine kuruludur. Dil girdilerini ardışık olarak işler ve her adımda önceki adımlardan elde edilen bilgiyi güncelleyerek sonraki adımlara aktarır. SG, çok güncel olmayan bir modeldir.

Yineleyen sinir ağlarının uzun dönem bellek ve bağımlılık sorunlarını çözmek için geliştirilmiş RNN mimari ailesine ait LSTM (*Long Short-Term Memory*) dil modeli ise nöral makine çevirisi alanında oldukça yaygın derin öğrenme modellerinden biridir. LSTM, hücre mekanizmasıyla (*cell state*) bilginin zaman içinde saklanmasını ve gerektiğinde erişilmesini sağlar; kapı mekanizmalarıyla (giriş, unutma, çıkış kapıları) bilginin belleğe ne zaman dahil olacağını denetler, gereksiz bilgiyi ayıklar ve bilginin güncellenmesini sağlar (Hochreiter ve Schmidhuber, 1997; akt. Özengi, 2024: 11-12).


Çeviriyi ilgilendiren dil modellerinin kullandığı mimarilerle ilgili güncel çalışmalara bakıldığında araştırmaların daha çok yineleyen sinir ağları (RNN) ve türleri ile Transformer mimarisi ve türlerine odaklandığı görülmektedir. Son zamanlarda ayrıca yineleyen sinir ağları ve Transformer mimarileri birleştirilerek hibrit dil modelleri oluşturulmaktadır. Her yeni model önceki modellerin kısıtlılıkları ve sorunlarını çözmek üzere yeni öneriler sunmaktadır. Yeni modeller önerilirken insan beyninin bellek, öğrenme, bilgi işleme mekanizmalarından esinlenilmektedir. Her ne kadar insan beyninin işleyiş mekanizmasından esinlenilse de (Alpaydın, 2022: 29-30) beynin dil işleme süreçleri ile yapay sinir ağlarının işleyişi arasında önemli farklılıklar söz konusudur.

İnsan beyninin dil işleme süreci

Beyin, dil işleme sırasında bir dizi karmaşık işlem gerçekleştirir. Dil, görsel ve işitsel modaliteler olarak adlandırılan herhangi bir duyuşsal kanal aracılığıyla beyinde algılanır, nöronlar arasındaki ağlar ve elektrokimyasal birtakım bağlantılarla işlenir. Dilin işlenmesi konusunda çeşitli teoriler olmakla birlikte beyinde dilin nasıl işlendiği hala tam olarak açıklanmış bir konu değildir. Alanda yapılan çalışmalar konuya ışık tutmaya çalışmaktadır.

İnsan beyninin dili işlemesi ile ilgili klasik bilgi, beynin çeşitli bölgelerinin özellikle de sol yarımkürenin bundan sorumlu olduğu yönünde idi. Sol yarımkürede frontal lobda yer alan Broca alanı, bilindiği kadarıyla dil üretmekten ve konuşmaktan, yine solda temporal lobda yer alan Wernicke alanı ise anlam vermektan sorumluuydu. Alman bilim insanı Korbinian Brodmann (1868-1918) beyindeki bölgeleri numaralandırarak haritalandırmıştı (Kerimoğlu, 2022: 25). Buna göre dil işleme beyinde birkaç spesifik yerde gerçekleşiyordu. Ancak daha sonra yapılan çalışmalar, yeni eklenen ve tanımlanan alanlar, dil işlemenin nöronal ağlar

yoluyla çok daha karmaşık, kapsamlı ve bağlantısal boyutta gerçekleştiğini gösterdi (Benítez-Burraco ve Boeckx 2015; Poeppel v.d. 2012, akt. Kerimoğlu, 2022: 26; Hickok ve Poeppel 2007; Vigneau v.d. 2006; Friederici, 2011). Özellikle nörobiyolojik gelişmeler ve beyin görüntüleme yöntemlerinin gelişmesi bu alandaki bilgilerin güncellenmesini sağladı.



Görsel 4: The Brain Dictionary <https://www.youtube.com/watch?v=k61nJkx5aDQ&t=7s> 10.03.2025

Minnesota Üniversitesi'nde görev yapan Prof. Dr. Kamil Uğurbil ve arkadaşları (Hinke v.d., 1993)¹⁴ konuşma merkezi olarak bilinen Broca alanı ve dil işleme üzerine yaptıkları çalışmada özellikle fonksiyonel MRI (fMRI) teknikleri kullanılarak beynin bu bölgesindeki aktiviteyi incelemeyi amaçlamışlardır. Bu araştırma, Broca alanının dil üretimi ve anlamadaki rolünü derinlemesine inceleyerek, içsel konuşma ve sözcük üretimi gibi dil görevlerinde nasıl aktif olduğunu ortaya koymaktadır. Araştırmada yapılan fMRI görüntülemelerinden elde edilen haritalamalara göre ve Huth v.d.'nin (2016)¹⁵ gerçekleştirdiği araştırmaya göre sözcüklerin ve anlamların beynin çeşitli bölgelere dağıldığını, beynin yalnızca dil işleme ve anlam vermeden sorumlu alanları olan Broca ya da Wernicke gibi bölümlerinin yanı sıra birçok bölgesinde aktivasyon olduğu gözlemlenmiştir. Bu çalışmalarda deneklere hikayeler okunmuş ve dinleme sırasında beyin aktiviteleri gözlenmiştir. Hikâyede geçen sözcüklere beynin çeşitli bölgeleri tepki vererek aktivasyon göstermiş ve bu aktivasyonlar, anlamsal ilişkilere göre renklerle haritalandırılmıştır. Deniz v.d.'nin (2019)¹⁶ yaptığı çalışma ise beynin anlam işleyen bölgelerinin, bilginin alındığı modaliteden, diğer bir deyişle görme, işitme, okuma gibi hangi duyuşal yolla alındığından bağımsız olarak çalıştığını göstermiştir. Zhang v.d.'nin (2022)¹⁷


¹⁴ https://journals.lww.com/neuroreport/abstract/1993/06000/Functional_magnetic_resonance_imaging_of_Broca_s.18.aspx 10.03.2025

¹⁵ Huth, A. G., De Heer, W. A., Griffiths, T. L., Theunissen, F. E., & Gallant, J. L. (2016). Natural speech reveals the semantic maps that tile human cerebral cortex. *Nature*, 532(7600), 453-458.

¹⁶ Deniz, F., Nunez-Elizalde, A. O., Huth, A. G., & Gallant, J. L. (2019). The representation of semantic information across human cerebral cortex during listening versus reading is invariant to stimulus modality. *Journal of Neuroscience*, 39(39), 7722-7736.

¹⁷ Zhang, X., Wang, S., Lin, N. and Zong C. (2022). Is the brain mechanism for hierarchical structure building universal across languages? An fmri study of chinese and english, in *Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing*, 7852-7861.

gerçekleştirdiği ilginç bir çalışmada ise farklı dillerde beyindeki aktivasyonun birbirinden ayrışıp ayrışmadığı gösterilmektedir.



Görsel 5: Anlam haritalama, Huth v.d. 2016

Yapay zekâ ve beyin çalışmaları

Bildiğimiz kadarıyla yapay zekâ ve dil modelleri, insan beyninin ve sinir ağlarının çalışma prensibinden esinlenmektedir. Ancak insan beyni ile doğal dil işleme arasında bazı farklar söz konusudur. İnsan beyni dili, nöronal ağlar yoluyla biyolojik bir süreçten geçerek işlerken elektrokimyasal işlemler gerçekleşir. Bu süreçte kültür, bağlam, üslup, kişisel paradigmlar ve ayrımlar, durumsallık, bilinç dışı gibi birçok etken devreye girerken yapay zekâda istatistiksel modeller, algoritmalar kullanılarak dil, sayısal verilere dönüştürülerek yapay bir sistemde hiyerarşik biçimde işlenir. Doğal dil işleme, matematiksel ve veri tabanına dayalı bir mekanizmadır (Alpaydın, 2022). Bazı dil modelleri kural tabanlı, bazıları istatistik tabanlı, çeviride güncel olarak kullanılanlar ise makine öğrenimi ve derin öğrenme algoritmaları ile desteklenen modellerdir. İnsan beyni doğal dil işlemeye göre daha esnek anlam verme ve muhakeme etme yetisine sahiptir. Doğal dil işlemenin bu alanda çeşitli sınırlılıkları vardır. Çeşitli dil modellerini inceleyerek işleme mekanizmasını beyin ile karşılaştıran çalışmaların (Lindborg ve Rabovsky, 2021; Pasquiou v.d. 2022) ortaya koyduğu bulgular, dil modellerinin mekanizmaları hakkında önemli veriler sunmaktadır.

Lindborg ve Rabovsky'nin (2021:1049-1050) çalışmasında son yılların işlevsel ve güncel modeli olan Transformer mimarisine sahip büyük dil modellerinin dil işleme ve anlam verme mekanizmasının bazı yönleriyle beynin anlam vermesinden farklı çalıştığını göstermektedir. Öte yandan çalışma, işlevsel anlamda beyne yakın işlevsel benzerlikler de ortaya koymaktadır. Pasquiou v.d. (2022) çalışmasında ise çeşitli dil modelleri (GloVe, LSTM, GPT-2, BERT) eğitilerek modele verilen girdilerden aktivasyon vektörleri elde edilmiştir. Diğer taraftan katılımcılara “Küçük Prens” dinletilerek onların fMRI aktivasyonları zaman serileri biçiminde kayıt edilmiştir. Buradan elde edilen veriler ile dil modellerinden elde edilen aktivasyon

vektörleri eşleştirilerek, beyin makine arasındaki aktivasyon benzerliği incelenmiş, regresyon modeli ile analizi edilmiştir. Bulgulara göre eğitilmiş transformer modellerinin, LSTM (*Long-Short Term Memory*) gibi yinelemeli sinir ağları (*Recurrent Neural Networks-RNN*) tabanlı modellere oranla beyin aktivasyonlarını tahmin etmede daha iyi sonuçlar elde ettiği görülmüştür.

Bunun yanı sıra Wang v.d.'nin (2024) gerçekleştirdiği çalışmada doğal dil işlemenin insana göre üstün özelliklerin söz edilerek beyin çalışmalarında beyni anlamak için dil modellerinden faydalanılması önerilmiştir. Wang v.d., insan beyninin dil işleme süreçlerini anlamak için yapay zekâdan faydalanmak gerektiğine ilişkin bir derleme sunmuşlardır. Buna göre yapay zekâ ve büyük dil modelleri, beyin anlaşılmasına katkı sağlayabilir, insan beyin-dil ilişkisine yönelik içgörü sunabilir ve beyin dili işleme mekanizmasının anlaşılmasına yardım edebilir (2024: 1-5). Yapay zekâ kullanılarak yapılacak çalışmalar, dil işleme sırasında oluşan bilişsel yükün ve işleyişin mekanizması, anlam ve yapının beyinde nasıl temsil edildiği, beyin sözcükleri parça bütün ilişkisi içerisinde nasıl ayrıştırıp işlediği konularında önemli veriler sunarak gelecekteki beyin çalışmalarına rehberlik edebilir (a.g.e.: 9). Büyük dil modelleri zaten insan davranışlarından esinlenerek üretildiği için her ne kadar genel anlamda arada benzerlik ve farklar olsa da belli bir görevi yerine getirmek için eğitilmiş bir modeli, yapay sinir ağlarının insan benzeri davranışlarını ve beyin aktiviteleriyle benzerlik gösterdiği durumları incelemek ve analiz etmek, beyinde dil işlemenin nasıl gerçekleştiği konusunda da yeni hipotezlerin oluşmasına ve değerlendirilmesine olanak tanımaktadır (a.g.e.: 8). Bu doğrultuda çeviri yapmak için eğitilmiş bir modeli ve yapay sinir ağlarının insan benzeri davranışlarını ve beyin aktiviteleriyle benzerlik gösterdiği durumları disiplinler arası ve bağlantısallık yaklaşımıyla incelemek, çeviri edimi sırasında fMRI gibi cihazlar ile görüntüleme yapmak¹⁸, sezgi, bilinç, karar verme mekanizmaları gibi tartışmalı konularda yeni ufukların açılmasına imkân sağlayabilir .

Çeviribilimsel perspektiften yapay zekâ ve çevirmen

Çeviri süreçlerinin bilişsel yönü ile ilgili çalışmalar ve nöral makine çevirisindeki örüntüler üzerine çalışmalar, kara kutu olarak nitelendirilen beyni ve nöral makine çevirisinin işleyiş mekanizmasını anlamak bakımından oldukça önemlidir. Çeviri süreçlerini anlamaya yönelik bilişsel ve teknolojik temelli çalışmalar, çeviribilimi bağımsız ve akademik bir disiplin olarak

¹⁸ Bu alanda yapılmış benzer çalışma için bkz. Lu, F., Yuan, Z. (2019). Explore the Brain Activity during Translation and Interpreting Using Functional Near-Infrared Spectroscopy. In: Li, D., Lei, V., He, Y. (eds) *Researching Cognitive Processes of Translation. New Frontiers in Translation Studies*. Springer, Singapore. https://doi.org/10.1007/978-981-13-1984-6_5

tanımlayan James S. Holmes’ün “*The Name and Nature of Translation Studies*” (1972) başlıklı makalesinde öne sürdüğü kuramsal ayrımlarla da bağdaşmaktadır. Holmes, çalışmasında çeviriyi salt kuram ve uygulama olarak iki temel alanda incelemiş, salt kuramsal çeviri çalışmalarını betimleyici çeviri çalışmaları (*descriptive translation studies*) ve kuramsal çeviri çalışmaları (*theoretical translation studies*) biçiminde sınıflamıştır. Betimleyici çeviri çalışmaları altında Holmes, bilişsel alanla ilgili süreç odaklı betimleyici çalışmalara (*process oriented translation studies*) bir alan ayırmıştır. Bu alanda çeviri süreci odak alınmış, çevirmenin zihinsel işlemlerinin doğrudan gözlemlenememesi nedeniyle bu süreç “kara kutu” olarak adlandırılarak bilişsel çalışmaların önemine vurgu yapılmıştır. Bunun yanı sıra Holmes, bilişsel alanda yapılmasını öngördüğü çalışmaların “çeviri psikolojisi”¹⁹ ya da “psiko-çeviri” adıyla ayrı bir alt alan oluşturabileceğini belirtmiştir (Holmes, 2000: 177). Holmes’ün çevirmenin zihinsel işlemlerini “kara kutu” metaforuyla tanımlaması, derin öğrenme temelli dil modellerinde yapay zekâ destekli çeviri araçlarının işleyiş mekanizmalarının tam olarak açıklanamaması ile paralellik göstermektedir. Zira, dil modellerinde yapay sinir ağlarından oluşan katmanlar da “kara kutu” olarak nitelendirilmektedir. Bu benzerlik, akla açıklanabilir yapay zeka (XAI) çalışmalarını getirmekte, insan çevirmen ve makine çevirmen olarak adlandırılan her iki çeviri eyleyicisinin karar mekanizmalarıyla ilgili çözümleyici incelemeleri işaret etmektedir.

Holmes, uygulamalı çeviri çalışmaları (*applied translation studies*) olarak tanımladığı alana ise çeviri eğitimi, çeviriye yardımcı araçlar (sözlükler, bilgisayar programları) gibi bileşenleri dahil etmiş; makine çevirisine ayrıca kuramsal alanda ayrıntılı yer vermiştir. Araç-ortam temelli çeviri kuramları (*medium restricted translation theories*) olarak adlandırdığı alanda çevirinin gerçekleştirildiği araç-ortam üzerinden kuramsal ayrımların yapılması gerektiğini belirten Holmes, bu alanı insan çevirisi (*human translation*), makine çevirisi (*machine translation*) ve makine destekli karma model (*mixed or machine aided translation*) olarak üç bölüme ayırmıştır. Holmes’e göre kuramsal çalışmalar genel kuram olma eğilimindedir. Oysaki bir alanda yapılan kuramsal çalışma, hangi araçla yapıldığına bağlı olarak belirlenmeli, kuramsal alanın sınırları bu doğrultuda çizilmelidir (a.g.e.: 182).

İnsan makine etkileşimine yönelik kuramsal çalışmaları altında ele alınabileceğimiz makine destekli karma model, günümüz teknolojik gelişmeleriyle ayrı bir çalışma alanı olarak gittikçe anlam kazanmaktadır ve bu alan Endüstri 4.0 çağının bir yansıması olarak öne çıkmaktadır.

¹⁹ Çeviri Psikolojisi ile ilgili çalışma için bkz. Jääskeläinen, R. (2016). Translation Psychology, çev. Eračıkbaş, A.F., *Handbook of Translation Studies*, Volume 3 (2012), 191-197, John Benjamins Publishing Company.

Doğal dil işleme, derin öğrenme ve metin işleme süreçleri, dijital dönüşümün önemli ölçüde hissedildiği yeni dönemde çeviribilimsel perspektiften çeviri süreçlerini yeni bir konumlanmaya doğru itmektedir. Özellikle nöral makine çevirisi, ön düzenleme (*pre-editing*) son düzenleme (*post editing*) gibi işlemlerde çevirmenin, nasıl çalıştığını bildiği bir düzenek için metin hazırlaması, bir düzenek tarafından üretilmiş çıktıyı değerlendirmesi ve metnin amaca uygun olarak yeniden üretilmesinde başat rol alması, çeviri süreçlerinin amaç, işlev, anlam, kaynak-erek ilişkisi gibi temel kavramları, teknolojik gelişmelere uyumlanarak yeniden ele alınmasını gerekli kılmaktadır. Bu doğrultuda çeviri kuramlarının bakış açısından yapay zekâ ve çevirmen etkileşimi incelemeye değerdir.

Sözgelimi *Skopos* (Amaç/Erek) kuramına göre çevirinin amacı, kaynak metni erek dildeki işlevi bakımından değerlendirmeyi ve çeviri süreçlerini buna göre yönetmeyi (Reiß ve Vermeer, 1984: 96) esas aldığından çevirmen bu süreçten sorumlu bir uzmandır. Çevirmen, donanımıyla bu sürecin en önemli karar vericisi ve belirleyicisidir (a.g.e.: 149). Yapay zekânın işleyiş mekanizmasına vakıf olan bir çevirmen, kaynak metnin çözümlenip erek dilde yeniden oluşturulmasına kadar olan süreçte uzmanlığını farklı bir konuma taşıma imkânına sahip olacaktır. Böylelikle çevirmen, kaynak metni yalnızca dilsel anlamda dönüştüren ve aktaran bir uzman olmaktan ziyade, amaca yönelik olarak bilgi işleyen bir sistem olarak yapay zekâ çıktılarını değerlendiren, analiz eden ve düzenleyen başka bir mekanizmaya yön veren karar verici bir pozisyonda olacaktır.

İşlevsel çeviri kuramlarından Justa Holz Mänttär'i'nin eylem odaklı çeviri kuramında (*Translatorisches Handeln*, 1984) çeviri süreci, çeşitli aktörlerin katılımıyla yürütülen kolektif bir eylemdir ve çevirmen, bu süreçte uzman kimliğinin yanı sıra danışman olarak da öne çıkmaktadır (a.g.e.: 118). Mänttär'i, çeviri eyleminde yer alan aktörlerin işbirliğini vurgulayarak çeviri sürecinde tarafların birbiriyle etkileşiminin önemine işaret etmektedir (a.g.e.: 41-43). Çevirmenin danışman rolü oldukça belirleyicidir. Mänttär'i'ye göre çevirmen, erek dil okuyucusu için belirlenen işlev ve amaç doğrultusunda metni tasarlayan, üreten ve danışman konumuyla gerekli düzenlemeleri gerçekleştiren kişidir. Günümüzde çevirmenler çoğu zaman yapay zekâ ile bir sistem tarafından üretilmiş bir çıktıyla muhatap olurlar. Bu durum yeni bir aktörü devreye sokmakta ve çevirmenin rolünün dönüşmesini gerekli kılmaktadır. Nöral makine çevirisinin çeşitli süreçlerden geçirilerek işleyip ürettiği çıktı, çevirmenin uzman ve danışman kimliğini kullanabileceği bir alan oluşturmakta, çevirmen makine işbirliğini gerekli kılmaktadır. Özellikle nöral makine çevirisinde arka planda metnin işlenişi, bağlam değerlendirmesi, bir dil modelinin eğitimi, amaca yönelik kişiselleştirilmesi ya da spesifik bir

alana yönelik özelleştirilmesi, girdi-çıkı ilişkisinin analizi, çıktının erek metne yönelik inşası ve tasarımı gibi işlemlerin yürütülmesi, metinle kurulan ilişkinin başka bir boyuta taşınmasını ve uzmanlığın derinleşmesini gerektirmektedir.

Çevirmenin uzmanlığını geliştirebileceği ya da bir uzmanlık oluşturabileceği diğer bir konu ise yapay zekâ ve dil işlemede metin işleme süreçleridir. Metin işleme süreçleri Chrisitane Nord'un çeviri amaçlı kaynak metin çözümlemesi (1995: 40-145) kapsamında çeviribilimsel perspektiften değerlendirilebilir. Nord, kaynak metnin çözümlenmesini dilsel düzeye hapsedmez, metni bütün bileşenleriyle ve katmanlarıyla ele almayı önermektedir. Metnin çözümlenmesiyle bağlam ve anlam, metnin ortaya koyduğu bütünlüklü işlevi bakımından ayrıca önem arz etmektedir. Çevirmen, yüzeysel bir değerlendirme ya da çözümleme yapan biri değildir; gerektiğinde metnin içinde, arka planında, derinliklerinde ve çeperinde anlama dair parçalar arayan, bulduğu parçaları birleştiren ve nihayetinde ortaya erek dilde işlevsel bir ürün çıkaran profesyonel bir kimlik taşır. Nöral makine çevirisinde her ne kadar çok başarılı sonuçlar alınsa da sözü edilen boyutta ve kapsamda bir çözümleme ve metin üretme söz konusu değildir. Özellikle metin işleme ve ön işleme süreçleri, kaynak metnin çözümlemesine ilişkin yeni bir alan olarak kabul edilebilir ve mekanizmanın işleyişine dair bilgi vermektedir. Metin ön işleme süreçlerinin incelenmesi ve bu doğrultuda çeviri çıktılarının incelenmesi, çevirmene dili farklı düzeylerden ele alma ve sistemin anlam oluşturma biçimini analiz etme imkânı tanımaktadır.

Sonuç ve öneriler

İnsan beyninin işleyişinin doğal dil modellerine göre çok daha komplike olduğu bir gerçektir. Dil modellerinin işleyiş mekanizması ve derin öğrenmeyi oluşturan yapay sinir ağları her ne kadar temelde beyinden esinlense de sonuçta matematiksel bir işleme ile verinin işlendiği bir süreci temsil eder. Zira bu yönüyle de hesaplamalı dilbilim olarak adlandırılır. Bu yöntemlerle metin işleme süreçlerinde çeviri ile ilgili örneklerden elde edilen bulgular, veri ön işleme aşamalarının ve model açıklanabilirliğinin çeviri çıktılarını doğrudan etkilediğini göstermiştir.

Metin işleme ile ön işleme süreçlerinin ve çeşitli dil modelleri mimarilerinin incelenmesiyle elde edilen bulgular, yapay zekanın etkisiyle hızla dönüşen yeni dönemde çeviri alanında çalışanların doğal dil işleme, derin öğrenme alanında kendilerini geliştirmelerini ve gelişmelere adapte olmalarını gerekli kılmaktadır. Çeviri eğitimi de bu doğrultuda gelişmelere göre güncellenmelidir. Yapay zekâ ve işleyiş mekanizması ile ilgili temel konular derslere konu edilmeli, metin çözümleme ve metin inşa etme süreçlerinde yapay zekâdan faydalanmalı, bilgi işleyen bir sistem olarak nöral makine çevirisinde girdi-çıkı arasındaki ilişkinin gözlenmesi,

çeviri çıktısının bunlara göre düzenlenmesi gibi uygulamalar derslere mümkün olduğunca entegre edilmelidir. Dil modellerinin ve doğal dil işlemenin çalışma prensiplerine ve metin işleme süreçlerine aşina olmak, yapay zekâ çağında çevirmenler için yeni alanlar açabilir. Çevirmenler, dilbilimsel uzmanlık ile teknolojik gelişmelerin birleştiği alanlarda hibrit roller üstlenebilirler. Sözel metin işleme süreçlerinde elde edilen verilerin nasıl değerlendirilmesi gerektiği üzerinde çalışabilir, veri okuryazarlığı alanında kendilerini geliştirebilirler. Bunun yanı sıra bir dil modelinin eğitiminde görev üstlenebilir, dil modelini kişiselleştirebilir, dil modelinin metin işleme süreçlerini izleyerek ve gerektiğinde müdahale ederek çeviri kalitesinin artmasına katkıda bulunabilirler.

Bu çalışma, doğal dil işleme, derin öğrenme, dil modelleri ve mimarileri ile metin işleme süreçlerine temel düzeyde genel bir bakış sunmakta; çevirmenlik mesleğinin dönüşümüne ve çevirmenlerin yapay zekâ çağında edinecekleri konuma bir katkı sunmayı amaçlamaktadır. Bununla birlikte dil modellerinin geliştirilmesi için metin işleme ve metin ön işleme aşamalarının çeviri bakımından incelenmesine yönelik kapsamlı çalışmalar önerilmektedir. Bu çalışmalar sayesinde hata analizleri yapılabilir; çeşitli dil çiftleri ile büyük veri setleri hazırlanabilir, daha doğru ve güvenilir çevirinin ön koşulları oluşturulabilir.

Kaynakça

Adalı, E. (2016). Doğal Dil İşleme. *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*. 5(2).

Ahammad, S. H., Kalangi, R. R., Nagendram, S., Inthiyaz, S., Priya P.P., Faragallah O.S., Mohammad, A., Eid, M.M.A., Rashed, A.N.Z. (2023). Improved neural machine translation using Natural Language Processing (NLP). *Multimedia Tools and Applications*. Springer.

Alpaydın, E. (2022). *Yapay Öğrenme Yeni: Yapay Zekâ*. çev. Aylin Ağar, 3. Baskı, Tellekt, İstanbul.

Antoine J. ve P. Tixier (2018). Notes on Deep Learning for NLP. *arXiv*, preprint arXiv:1808.09772. Erişim adresi <https://doi.org/10.48550/arXiv.1808.09772>

Bahdanau, D., Cho, KH. ve Bengio, Y. (2015). Neural machine translation by jointly learning to align and translate. Proceedings of ICLR. *arXiv*, preprint arXiv:1409.0473. Erişim adresi <https://doi.org/10.48550/arXiv.1409.0473>

Benítez-Burraco, A. ve Boeckx, C. (2015). Possible functional links among brain- and skull-related genes selected in modern humans. *Frontiers in Psychology*, 6, Article 794.

Camacho-Collados J. ve Pilehvar, M.T. (2018). On the Role of Text Preprocessing in Neural Network Architectures: An Evaluation Study on Text Categorization and Sentiment Analysis. *arXiv*, preprint arXiv:1707.01780. Erişim adresi <https://doi.org/10.48550/arXiv.1707.01780>

Deniz, F., Nunez-Elizalde, A. O., Huth, A. G. ve Gallant, J. L. (2019). The representation of semantic information across human cerebral cortex during listening versus reading is invariant to stimulus modality. *Journal of Neuroscience*, 39(39), 7722-7736.

Deshmukh, R. D. ve Kiwelekar, A. (2020). Deep learning techniques for part of speech tagging by natural language processing. *2020 2nd International Conference on Innovative Mechanisms for Industry Applications (ICIMIA)* içinde, 76-81, IEEE.

Dohare, S., Fernando Hernandez-Garcia, J., Lan, Q., Rahman, P., Rupam Mahmood, A., S.Sutton, R. (2024). Loss of plasticity in deep continual learning. *Nature*, Springer Science and Business Media LLC. Erişim adresi <https://doi.org/10.1038/s41586-024-07711-7>

Feldman, R. ve Dagan, I. (1995). *Knowledge Discovery in Textual Databases*. KDD' 95 Proceedings of the First International Conference on Knowledge Discovery and Data Mining, 112-117. Erişim adresi https://www.ijcseonline.org/spl_pub_paper/30-ICCIS-18.pdf

Friederici, A. D. (2011). The brain basis of language processing: from structure to function. *Physiological reviews*, 91(4), 1357-1392.

Goodfellow, I., Bengio, Y. ve Courville, A. (2016). *Deep Learning*. MIT Press. Erişim adresi www.deeplearningbook.org

Hickok, G., ve Poeppel, D. (2007). The cortical organization of speech processing. *Nature reviews neuroscience*, 8(5), 393-402.

Hinke, R. M., Hu, X., Stillman, A. E., Kim, S. G., Merkle, H., Salmi, R. ve Ugurbil, K. (1993). Functional magnetic resonance imaging of Broca's area during internal speech. *Neuroreport*, 4(6), 675-678.

Hochreiter S. ve Schmidhuber J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8); 1735–1780. Erişim adresi <https://doi.org/10.1162/neco.1997.9.8.1735> (17.03.2025)

- Huth, A. G., De Heer, W. A., Griffiths, T. L., Theunissen, F. E. ve Gallant, J. L. (2016). Natural speech reveals the semantic maps that tile human cerebral cortex. *Nature*, 532(7600), 453-458.
- Holmes, J. S. (2000). The Name and Nature of Translation Studies. 1972, In: Venuti, L. (eds): *The Translation Studies Reader*, Chapter 13, 172-185.
- Holzinger, A., Saranti, A., Molnar, C., Biecek, P. ve Samek, W. (2022). Explainable AI Methods - A Brief Overview. *International workshop on extending explainable AI beyond deep models and classifiers* içinde, 13-38, Cham: Springer International Publishing. Erişim adresi https://dx.doi.org/10.1007/978-3-031-04083-2_2
- Hopfield, J. J. (1982). Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences of the United States of America*, Vol. 79, No 8, Part 1 Biological Sciences, 2554-2558.
- Jabeen, R., Ericsson, M., ve Nordqvist, J. (2023). Towards Better Product Quality: Identifying Legitimate Quality Issues through NLP & Machine Learning Techniques. *Linköping Electronic Conference Proceedings*, Linköping University Electronic Press. doi.org/10.3384/ecp199009
- Jääskeläinen, R. (2016). Translation Psychology. Çev. Eraçıkbaş, A.F., *Handbook of Translation Studies*, Vol. 3 (2012), 191-197, John Benjamins Publishing Company.
- Irie, K., Gerstenberger, A., Schlüter, R. ve Ney, H. (2020). How Much Self-Attention Do We Need? Trading Attention for Feed-Forward Layers. *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 6154-6158.
- Kerimoğlu, C. (2022). Dilin Kökeni Arayışları-5: Beyin ve Dil, *Dil araştırmaları Journal of Language Studies*, Yıl: 16, Dönem: 2022/Bahar, Sayı: 30 ISSN 1307-7821 | e-ISSN 2757-8003
- Khurana, D., Koli, A., Khatter, K. ve Singh, S. (2022). Natural language processing: State of the art, current trends and challenges. *Multimedia Tools and Applications*, 82, 3713-3744.
- Koroteev, M. V. (2021). BERT: a review of applications in natural language processing and understanding. *arXiv*, preprint arXiv: 2103.11943. Erişim adresi <https://arxiv.org/pdf/2103.11943> (17.03.2025)
- LeCun, Y., Bengio Y. ve Hinton, G. (2015). Deep learning, *Nature*, 521.7553 (2015): 436-444.
- Lindborg, A. ve Rabovsky, M. (2021). Meaning in brains and machines: Internal activation update in large-scale language model partially reflects the n400 brain potential. *Proceedings of the annual meeting of the cognitive science society*, Vol. 43. Erişim adresi <https://escholarship.org/uc/item/6d71c9sj> (16.03.2025)
- Liu, F. H., Gu, L., Gao, Y. ve Picheny, M. (2003). Use of statistical N-gram models in natural language generation for machine translation. *2003 IEEE International Conference on Acoustics, Speech, and Signal Processing*, Proceedings.(ICASSP'03), Vol. 1, pp.I-I). IEEE.
- Lourdusamy, R. ve Abraham, S. (2018). A Survey on Text Pre-processing Techniques and Tools. *International Journal of Computer Sciences and Engineering*, Vol. 6, Special Issue-3, 148-157, E-ISSN: 2347-2693.
- Lu, F., Yuan, Z. (2019). Explore the Brain Activity during Translation and Interpreting Using Functional Near-Infrared Spectroscopy. In: Li, D., Lei, V., He, Y. (eds) *Researching Cognitive Processes of Translation. New Frontiers in Translation Studies*. Springer, Singapore. Erişim adresi https://doi.org/10.1007/978-981-13-1984-6_5
- Luo, S., Ivison, H., Han, S. C. ve Poon, J. (2024). *Local interpretations for explainable natural language processing: A survey*, ACM Computing Surveys, 56(9), 1-36.

- M.P. Brasoveanu, A. ve Andonie, R. (2020). Visualizing Transformers for NLP: A Brief Survey. *24th International Conference Information Visualisation (IV)*. Erişim adresi <https://doi.org/10.1109/iv51561.2020.00051> (17.03.2025)
- Mänttari, J.H. (1984). *Translatorisches Handeln:Theorie und Methode*, Suomalainen Tiedeakatemia, Helsinki.
- Nord, C. (1995). *Textanalyse und Übersetzen: theoretische Grundlagen, Methode und didaktische Anwendung einer übersetzungsrelevanten Textanalyse*. 3. Auflage, Heidelberg, Groos. ISBN: 3-87276-649-X
- Özengi, A. (2024). *Derin Öğrenme Teknikleri Kullanılarak Türkçe-İngilizce Nöral Makine Çevirisi*. Dönem Projesi, İzmir Kâtip Çelebi Üniversitesi Fen Bilimleri Enstitüsü. Erişim adresi <https://acikerisim.ikcu.edu.tr/yayin/1742898&dil=3&q=>(17.03.2025)
- Pasquiou, A., Lakretz, Y., Hale, J., Thirion, B. ve Pallier, C. (2022). Neural language models are not born equal to fit brain data, but training helps. *arXiv*, preprint arXiv:2207.03380. Erişim adresi <https://arxiv.org/pdf/2207.03380> (17.03.2025)
- Patwardhan, N., Marrone, S. ve Sansone, C. (2023). Transformers in the Real World: A Survey on NLP Applications. *Information, MDPI AG*. Erişim adresi <https://doi.org/10.3390/info14040242> (17.03.2025)
- Pekcoşkun Güner, S. (2023). Çevirmen-Bilgisayar Etkileşiminin Kilit Bileşeni: Doğal Dil İşleme. *Karamanoğlu Mehmetbey Üniversitesi Uluslararası Filoloji ve Çeviribilim Dergisi*, 5(1), 56-79. Erişim adresi <https://doi.org/10.55036/ufced.1306746> (17.03.2025)
- Poeppel, D., Emmorey, K., Hickok, G. ve Pylkkänen, L. (2012). Towards A New Neurobiology of Language. *Journal of Neuroscience*, 32/41: 14125–14131.
- Rahali, A. ve Akhloufi, M. A. (2023). End-to-End Transformer-Based Models in Textual-Based NLP, *AI*, 4(1), 54-110. MDPI. Erişim adresi <https://doi.org/10.3390/ai4010004> (17.03.2025)
- Reiß, K. ve Vermeer, H. (1984). *Grundlegung einer allgemeinen Translationstheorie*. De Gruyter.
- Rumelhart, D. E., Hinton, G. ve Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323.6088: 533-536.
- Sankar, H. ve Subramaniaswamy, V. (2017). Investigating sentiment analysis using machine learning approach. *2017 International Conference on Intelligent Sustainable Systems (ICISS)*. Erişim adresi <https://doi.org/10.1109/iss1.2017.8389293> (17.03.2025)
- Samek W., Wiegand T. ve Müller K.R. (2017). *Explainable Artificial Intelligence: Understanding, Visualizing and Interpreting Deep Learning Models*. *arXiv*, preprint arXiv:1708.08296. Erişim adresi <https://doi.org/10.48550/arXiv.1708.08296>
- Schmidhuber, J. (2014). *Deep Learning in Neural Networks: An Overview*. *Neural networks*, 61, 85-117. Erişim adresi <https://doi.org/10.48550/arXiv.1404.7828>
- Seker, S. E. (2015). Doğal Dil İşleme (Natural Language Processing). *YBS Ansiklopedi* 2(4), 14-31.
- Shaw, P., Uszkoreit, J. ve Vaswani, A. (2018). Self-attention with relative position representations. *arXiv*, preprint arXiv:1803.02155. Erişim adresi <https://doi.org/10.48550/arXiv.1803.02155>

- Sharma, A., Amrita, Chakraborty, S. ve Kumar, S. (2022). Named entity recognition in natural language processing: A systematic review. *Proceedings of Second Doctoral Symposium on Computational Intelligence: DoSCI 2021* içinde, 817-828. Springer Singapore.
- Singh, C., Hsu, A. R., Antonello, R., Jain, S., Huth, A. G., Yu, B., Gao, J. (2023). Explaining black box text modules in natural language with language models. *arXiv*, preprint arXiv:2305.09863. Erişim adresi <https://doi.org/10.48550/arXiv.2305.09863>
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, L., Polosukhin, I. (2017). Attention is all you need. *Proceedings of the Advances in Neural Information Processing Systems 30 (NIPS)*, Long Beach, CA, USA, 4–9, 5998–6008.
- Vigneau, M., Beaucousin, V., Hervé, P. Y., Duffau, H., Crivello, F., Houde, O., ... ve Tzourio-Mazoyer, N. (2006). Meta-analyzing left hemisphere language areas: phonology, semantics, and sentence processing. *Neuroimage*, 30(4), 1414-1432.
- Wang, S., Sun, J., Zhang, Y., Lin, N., Moens, M. F. ve Zong, C. (2024). Computational models to study language processing in the human brain: A survey. *arXiv*, preprint arXiv:2403.13368. Erişim adresi <https://arxiv.org/pdf/2403.13368> (17.03.2025)
- Zhang, X., Wang, S., Lin, N. ve Zong, C. (2022). Is the brain mechanism for hierarchical structure building universal across languages? an fmri study of chinese and english. *Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing* içinde, 7852–7861.

Structured Abstract

This study provides a comprehensive conceptual and descriptive examination of natural language processing (NLP) and deep learning models, which are essential components of artificial intelligence. It evaluates commonly used architectures in language models in terms of their characteristics and discusses text processing and preprocessing workflows that operate on artificial neural networks, with examples in the context of translation. Additionally, the article compares the functioning mechanisms of the human brain and artificial neural networks, emphasizing their impact on the training and development of language models.

NLP refers to the field that enables computers to understand, process, and interact using human language. With the development of artificial neural networks inspired by the human brain starting in the 1980s (John Hopfield, Geoffrey Hinton), and the integration of these technologies into natural language modeling and neural machine translation by the 2000s (Yann LeCun, Y. Bengio, Geoffrey Hinton), a major transformation has taken place. The public release of a large-scale language model in 2023 significantly accelerated interest in artificial intelligence systems. What characterizes this new era is the data-driven nature of deep learning algorithms, which, unlike traditional rule-based systems, learn from large datasets and optimize themselves over time (Alpaydın, 2002: 27). These developments have reshaped the landscape of language technologies and initiated discussions on the implications of AI on human communication. NLP and deep learning algorithms operate within this dynamic framework. NLP involves two core stages: text comprehension (encoding) and text generation (decoding) (Alpaydın, 2002: 92). During comprehension, high-level abstraction and encoding occur, while generation involves decoding. In neural machine translation, this corresponds to the encoder-decoder architecture where one neural network processes the input into a mathematical representation and another generates the output sequence. NLP is often referred to as computational linguistics because neural networks convert text data into numerical representations (Şeker, 2015: 14). This abstraction process reflects the shift from symbolic representation to statistical and probabilistic models in modern language technologies. As data progresses through layers in deep learning, it is processed and transformed into outputs. During training, systems learn from big data and continuously optimize themselves throughout the entire text processing workflow. Language models are built upon various architectural frameworks. Among the most prominent is the Transformer model, which applies encoder-decoder mechanisms. Others include recurrent neural networks (RNNs) and hybrid models. The number of layers and processing mechanisms vary depending on the model. Each architecture offers specific strengths in handling language complexity, memory retention, and contextual understanding. Although artificial neural networks are inspired by the human brain, significant differences exist between biological language processing and artificial mechanisms (Alpaydın, 2022: 29–30). The human brain operates through neuronal, biological systems, while NLP follows a mathematical, hierarchical, and data-based framework. Understanding this distinction is crucial in designing language models that strive to emulate natural language comprehension and production. Key components of NLP include data collection, data preparation or preprocessing, feature extraction, model training, testing and evaluation, interpretation of results, and optimization. Tasks such as information retrieval, information extraction, and data mining are grouped under text mining, which helps derive meaningful insights from textual data. Preprocessing plays a crucial role in this context (Feldman and Dagan, 1995; cited in Lourdasamy and Abraham, 2018: 148), as it directly influences the accuracy and efficiency of

subsequent computational processes. Several linguistic applications are incorporated during text processing. Translation-oriented NLP applications often require interdisciplinary collaboration involving linguists, phonologists, morphologists, syntacticians, semanticists, pragmatists, NLP engineers, data analysts, and AI developers. Such cooperation ensures that language-specific complexities are adequately handled, especially in multilingual and domain-specific translation scenarios. Frequent preprocessing tasks include language detection, special character removal, correction of encoding errors and misspellings, and tokenization—segmenting text into meaningful and processable units. Compound words can be further broken into subword units (subword tokenization), determined by statistical frequency in training data. Morphological analysis becomes essential at this stage. Lowercasing is applied to normalize text for model training. Stemming reduces words to their root forms, while lemmatization identifies base forms of words (Camacho-Collados and Pilehvar, 2018: 2; Jabeen et al., 2023: 4). Noise removal targets irrelevant characters and symbols, while stop words removal filters out semantically non-contributive terms (Sankar and Subramaniaswamy, 2017: 88; Lourdasamy and Abraham, 2018: 149). Another key task is part-of-speech tagging to classify each word grammatically. Following this, syntactic parsing identifies sentence components and their functions (Deshmukh and Kiwelekar, 2020; Sankar and Subramaniaswamy, 2017: 88). Feature extraction translates relevant text attributes into numeric vectors to support model training (Jabeen et al., 2023: 4). Embedding further transforms words into mathematical vectors to capture semantic relationships. N-gram modeling helps capture linguistic structure and context and is especially useful in improving predictive accuracy in generative language models. Text processing tasks vary depending on the model but are pivotal for optimizing translation output. This study demonstrates that preprocessing quality and model interpretability directly influence translation performance. For instance, improved morphological analysis and precise lemmatization contribute to more accurate target language outputs. It becomes evident that NLP pipelines must be carefully customized according to linguistic properties of both source and target languages. The research emphasizes that NLP and deep learning technologies will play a critical role in the future of translation practices and language-related professions. Translators equipped with text processing knowledge will find new opportunities in dataset development, text refinement, model training processes, and system evaluation. As digital transformation reshapes language industries, translators are expected to adopt hybrid roles that bridge linguistic expertise and technological literacy. Therefore, integrating linguistic knowledge with computational tools will be indispensable for the evolving role of translators in AI-driven environments. Moreover, translation education must adapt to this shift by incorporating data literacy and NLP competencies to prepare future professionals for collaborative work.