



ΙΟΝΙΟ ΠΑΝΕΠΙΣΤΗΜΙΟ

ΣΧΟΛΗ ΑΝΘΡΩΠΙΣΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ

ΤΜΗΜΑ ΞΕΝΩΝ ΓΛΩΣΣΩΝ, ΜΕΤΑΦΡΑΣΗΣ ΚΑΙ ΔΙΕΡΜΗΝΕΙΑΣ

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

ΜΕΤΑΦΡΑΣΗ ΤΕΧΝΙΚΟΥ ΚΕΙΜΕΝΟΥ ΜΕ ΘΕΜΑ:

« Ένας οδηγός για την Βαθιά Μάθηση στην υγειονομική περίθαλψη»

Ζεύγος γλωσσών: Αγγλικά-Ελληνικά

Φοιτήτρια: Λένγκου Γεωργία (Ξ 2015 108)

Επιβλέποντες Καθηγητές:

- Κεραμίδας Σωτήριος
- Νικολάου Πασχάλης

ΑΘΗΝΑ, ΙΑΝΟΥΑΡΙΟΣ 2021

ΠΕΡΙΕΧΟΜΕΝΑ

ΕΥΧΑΡΙΣΤΙΕΣ.....	4
ΚΕΙΜΕΝΟ ΑΦΕΤΗΡΙΑΣ	5
ΚΕΙΜΕΝΟ ΑΦΙΞΕΩΣ	20
ΕΙΣΑΓΩΓΗ.....	34
ΣΧΟΛΙΑΣΜΟΣ	35
ΜΕΤΑΦΡΑΣΤΙΚΑ ΠΡΟΒΛΗΜΑΤΑ	44
ΣΥΜΠΕΡΑΣΜΑ.....	50
ΓΛΩΣΣΑΡΙ ΟΡΩΝ	51
ΒΙΒΛΙΟΓΡΑΦΙΑ	54

ΕΥΧΑΡΙΣΤΙΕΣ

Φτάνοντας εδώ και γράφοντας αυτές τις σελίδες θα ήθελα να ευχαριστήσω αρχικά τον στενό μου κύκλο για την αμέριστη υποστήριξη όλον αυτόν τον καιρό. Από τις ευχαριστίες φυσικά δε θα έλειπαν όλοι οι καθηγητές μου αλλά ιδιαιτέρως ο επιβλέπωντας καθηγητής της πτυχιακής μου εργασίας, Σ.Γ. Κεραμίδας, για την καθοδήγησή του αυτά τα χρόνια μέσω των μαθημάτων του και την πολύτιμη βοήθεια που προσέφερε συγγράφοντας το βιβλίο “Ζητήματα Ορολογίας στην Τεχνική Μετάφραση”. Επιπρόσθετα ένα μεγάλο ευχαριστώ ανήκει στον μεταπτυχιακό φοιτητή Χρήστο Γιαννούτσο για την πολύτιμη βοήθεια του στον εμπλουτισμό της βιβλιογραφίας. Τέλος, θα ήθελα να ευχαριστήσω την καλή μου φίλη και φοιτήτρια του τμήματος Πληροφορική με Εφαρμογές στην Βιοιατρική, Ζηνοβία Λάζαρη, για την πνευματική της καθοδήγηση στον επιστημονικό τομέα της Γονιδιωματικής και της Πληροφορικής.

A guide to deep learning in healthcare

Andre Esteva, 3*, Alexandre Robicquet^{1, 3}, Bharath Ramsundar¹, Volodymyr Kuleshov¹, Mark DePristo²,

Katherine Chou², Claire Cui², Greg Corrado², Sebastian Thrun¹ and Jeff Dean²

Here we present deep-learning techniques for healthcare, centering our discussion on deep learning in computer vision, natural language processing, reinforcement learning, and generalized methods. We describe how these computational techniques can impact a few key areas of medicine and explore how to build end-to-end systems. Our discussion of computer vision focuses largely on medical imaging, and we describe the application of natural language processing to domains such as electronic health record data. Similarly, reinforcement learning is discussed in the context of robotic-assisted surgery, and generalized deep-learning methods for genomics are reviewed.

Deep learning¹, a subfield of machine learning (ML), has seen a dramatic resurgence in the past 6 years, largely driven by increases in computational power and the availability of massive new datasets. The field has witnessed striking advances in the ability of machines to understand and manipulate data, including images², language³, and speech⁴. Healthcare and medicine stand to benefit immensely from deep learning because of the sheer volume of data being generated (150 exabytes or 10¹⁸ bytes in United States alone, growing 48% annually⁵) as well as the increasing proliferation of medical devices and digital record systems.

ML is distinct from other types of computer programming in that it transforms the inputs of an algorithm into outputs using statistical, data-driven rules that are automatically derived from a large set of examples, rather than being explicitly specified by humans. Historically, constructing a ML system required domain expertise and human engineering to design feature extractors that transformed raw data into suitable representations from which a learning algorithm could detect patterns. In contrast, deep learning is a form of representation learning—in which a machine is fed with raw data and develops its own representations needed for pattern recognition—that is composed of multiple layers of representations. These layers are typically arranged sequentially and composed of a large number of primitive, nonlinear operations, such that the representation of one layer (beginning with the raw data input) is fed into the next layer and transformed into a more abstract representation¹. As data flows through the layers of the system, the input space becomes iteratively warped until data points become distinguishable (Fig. 1a). In this manner, highly complex functions can be learned.

Deep-learning models scale to large datasets—in part owing to their ability to run on specialized computing hardware—and continue to improve with more data, enabling them to outperform many classical ML approaches. Deep-learning systems can accept multiple data types as input—an aspect of particular relevance for heterogeneous healthcare data (Fig. 1b). The most common models are trained using supervised learning, in which datasets are composed of input data points (e.g., skin lesion images) and corresponding output data labels (e.g., ‘benign’ or ‘malignant’). Reinforcement learning (RL), in which computational agents learn by trial and error or by expert demonstration, has progressed with the adoption of deep learning, achieving remarkable feats in areas such as game playing (e.g., Go⁶). RL can be useful in healthcare whenever learning requires physician demonstration, for instance in learning to suture wounds for robotic-assisted surgery⁷.

Computer vision


Some of the greatest successes of deep learning have been in the field of computer vision (CV)². CV focuses on image and video understanding, and deals with tasks such as object classification, detection, and segmentation—which are useful in determining whether a patient’s radiograph contains malignant tumors. Convolutional neural networks (CNNs)^{1,2}, a type of deep-learning algorithm designed to process data that exhibits natural spatial invariance (e.g., images, whose meanings do not change under translation), have grown to be central in this field.

Medical imaging, for instance, can greatly benefit from recent advances in image classification and object detection^{2,8}. Many studies have demonstrated promising results in complex diagnostics spanning dermatology^{9,10}, radiology^{11–14}, ophthalmology^{15–17}, and pathology^{18–21} (Fig. 2). Deep-learning systems could aid physicians by offering second opinions and flagging concerning areas in images.

Image-level diagnostics have been quite successful at employing CNN-based methods (Fig. 2). This is largely due to the fact that CNNs have achieved human-level performance in object-classification tasks², in which a CNN learns to classify the object contained in an image. These same networks have demonstrated strong performance in transfer learning²², in which a CNN initially trained on a massive dataset that is unrelated to the task of interest (e.g., ImageNet², a dataset of millions of common everyday objects) is further fine-tuned on a much smaller dataset related to the task of interest (e.g., medical images). In the first step, the algorithm leverages large amounts of data to learn of the natural statistics in images—straight lines, curves, colorations, etc.—and in the second step, the higher-level layers of the algorithm are retrained to distinguish between diagnostic cases. Similarly, object detection and segmentation algorithms identify specific parts of an image that correspond to particular objects. CNN methods take image data as input and iteratively warp it through a series of convolutional and nonlinear operations

until the original raw data matrix is transformed into a probability distribution over potential image classes (e.g., medical diagnostic cases) (Fig. 2).

Remarkably, deep-learning models have achieved physician-level accuracy at a broad variety of diagnostic tasks, including identifying moles from melanomas^{9,10}, diabetic retinopathy, cardiovascular risk, and referrals from fundus^{15,16} and optical coherence tomography (OCT)¹⁷ images of the eye, breast lesion detection in mammograms¹³, and spinal analysis with magnetic resonance imaging²³. A single deep-learning model has even been shown to be effective at diagnosis across medical modalities (e.g., radiology and ophthalmology)²⁴.



[Fig. 1 | Deep learning. a, A simple, multilayer deep neural network takes two classes of data, denoted by the different colors, and makes them linearly separable by iteratively distorting the data as it flows from layer to layer. The final output layer serves as a classifier by outputting the probability of either one of the classes. This example illustrates the basic concept used by large scale networks. Conceptual illustration adapted with permission from <http://colah.github.io/>. b, Example large-scale network that accepts as input a variety of data types (images, time-series, etc.), and for each data type learns a useful featurization in its lowerlevel towers. The data from each tower is then merged and flows through higher levels, allowing the DNN

to perform inference across data types—a capability that is increasingly important in healthcare.]

However, a key limitation across studies that compare human to algorithmic performance has been a lack of clinical context—they constrain the diagnosis to be performed using just the images at hand. This often increases the difficulty of the diagnostic task for the human reader, who in real-world clinical settings has access to both the medical imagery and supplemental data, including the patient history and health record, additional tests, patient testimony, etc.

Clinics are beginning to employ object detection and segmentation in images for urgent and easily missed cases, such as flagging large-artery occlusion in the brain using radiological images¹⁴, during which patients have a limited amount of time (a few minutes) before permanent brain damage occurs. Further, cancer histopathology reads, which require human experts to laboriously scan and diagnose gigapixel images (or equivalently large physical slides) can be supplemented with CNNs trained to detect mitotic cells¹⁸ or tumor regions¹⁹. They can be trained to quantify the amount of PD-L1 present in a histopathology image²⁰—a task important in determining which type of immuno-oncology drug a patient would be receptive to. Combined with pixel-level analyses, CNNs have even been used to discover biological features of tissue associated with survival probability²¹.

The primary limitation to building a supervised deep-learning system for a new medical imaging task is access to a sufficiently large, labeled dataset. Small and labeled datasets for specific tasks are easier to collect, but result in algorithms that tend to perform poorly on new data. In these cases, techniques for heavy data augmentation have been shown to be effective at helping algorithms generalize²⁵. Similarly, large but unlabeled datasets are also easier to collect, but will require a shift towards improved semisupervised and unsupervised techniques, such as generative adversarial networks²⁶.

Natural language processing

Natural language processing (NLP) focuses on analyzing text and speech to infer meaning from words. Recurrent neural networks (RNNs)—deep learning algorithms effective at processing sequential inputs such as language, speech, and time-series data²⁷—play an important role in this field. Notable successes of NLP include machine translation²⁸, text generation²⁹, and image captioning³⁰. In healthcare, sequential deep learning and language technologies power applications within domains such as electronic health records (EHRs).


EHRs are rapidly becoming ubiquitous³¹. The EHR of a large medical organization can capture the medical transactions of over 10 million patients throughout the course of a decade. A single hospitalization alone typically generates ~150,000

pieces of data. The potential benefits derived from this data are significant. In aggregate, an EHR of this scale represents 200,000 years of doctor wisdom and 100 million years of patient outcome data, covering a plethora of rare conditions and maladies. As such, application of deep-learning methods to EHR data is a rapidly expanding area^{32,33}.

Figure 3 outlines the technical steps in building deep-learning systems for EHRs. Raw data are first aggregated across institutions in order to ensure that a generalizable system is built. The data are then standardized and parsed temporally and across patients, which makes them suitable for deep-learning training. From this, we can then infer answers to high-level medical questions, such as ‘What past history is relevant to the patient’s current diagnosis?’, ‘What is the patient’s current problem list?’, and ‘What opportunities are there to intervene?’

When making predictions, most work to date uses supervised learning on limited sets of structured data, including lab results, vitals, diagnostic codes, and demographics. To account for the structured and unstructured data contained in EHRs, researchers are beginning to employ unsupervised learning approaches, such as auto-encoders—in which networks are first trained to learn useful representations by compressing and then reconstructing unlabeled data—to predict specific diagnoses³⁴. Recent uses of deep learning model the temporal sequence of structured events that occurred in a patient’s record with convolutional and recurrent neural networks in order to predict future medical incidents^{35–38}. Much of this work focuses on the Medical Information Mart for Intensive Care (MIMIC) dataset³⁹ (e.g., for the prediction of sepsis⁴⁰), which contains intensive care unit (ICU) patients from a single center. While ICU patients generate more EHR data than non-ICU patients, they are significantly outnumbered by non-ICU patients. As such, it is still uncertain how well techniques derived from this data will generalize to broader populations.

The next generation of automatic speech recognition³² and information extraction models will likely develop clinical voice assistants to accurately transcribe patient visits. Doctors easily spend 6 hours in an 11-hour workday working on documentation in the EHR, which leads to burnout and reduces time with patients³¹. Automated transcription will alleviate this and facilitate more affordable scribing services. Consider RNN-based language translation²⁷, which uses an end-to-end technique to translate directly from speech in one language to text in another. Adapted to EHRs, this technique could translate a patient–provider conversation directly into a transcribed text record. The key challenge lies in classifying the attributes and status of each medical entity from the conversation while accurately summarizing the dialogue. Though promising in early human–computer interaction experiments, these techniques have yet to be widely deployed in medical practice.



[Fig. 2 | Medical imaging. CNNs can be trained on a variety of medical imagery, including radiology, pathology, dermatology, and ophthalmology.

Information flows left to right. CNNs take input images and sequentially transform them, using simple operations such as convolutional, pooling, and fully connected layers, into flattened vectors. The elements of the output vector (softmax layer) represent the probabilities of the presence of disease. During the training process, the internal parameters of the network layers are iteratively adjusted to improve accuracy. Typically, lower layers (left) learn simple image features—edges and basic shapes—which influence the high-level representations (right). Prediction tasks include both classification of the images (i.e., cancerous versus benign) as well as localization of medical features such as tumors.]

Future work will likely focus on developing algorithms to better leverage some of the information-rich yet unstructured data in EHRs. Clinical notes, for instance, are often omitted or redacted when developing predictive systems. Here, large-scale RNNs are beginning to demonstrate impressive predictive results by combining structured and unstructured data in a semisupervised way³³. This data combination allows them to learn from broader populations across more diverse data types, outperforming other techniques across tasks including mortality, readmission, length of stay, and diagnosis predictions.

Reinforcement learning

Reinforcement learning (RL) refers to a class of techniques designed to train computational agents to successfully interact with their environment, typically to achieve specific goals. This learning can happen through trial and error, through demonstration, or through a hybrid approach. As an agent takes actions within its environment, an iterative feedback loop of reward and consequence trains the agent to better accomplish the goals at hand. Learning from expert demonstration is accomplished either by learning to predict the expert's actions directly via supervised learning (i.e., imitation learning) or by inferring the expert's objective

(i.e., inverse RL). To successfully train an agent, it is critical to have a model function that can take as input sensory signals from the environment and output the next actions for the agent to take. Deep RL, in which a deep-learning model serves as the model function, shows promise.

One healthcare domain that can benefit from deep RL is robotic-assisted surgery (RAS). Currently, RAS largely depends on a surgeon guiding a robot's instruments in a teleoperated fashion. Deep learning can enhance the robustness and adaptability of RAS by using computer vision models (e.g., CNNs) to perceive surgical environments and RL methods to learn from a surgeon's physical motions^{41,42}.

These techniques support the automation and speed of highly repetitive and time-sensitive surgical tasks, such as suturing and knot-tying⁷. For instance, computer vision techniques (e.g., CNNs for object detection/segmentation and stereovision) can reconstruct the landscape of an open wound from image data, and a suturing or knot-tying trajectory can be generated by solving a path optimization problem that attempts to find an optimal trajectory while accounting for external constraints, such as joint limits and obstacles⁴³. Similarly, image-trained RNNs can learn to tie knots autonomously by learning sequences of events, in this case physical maneuvers, from surgeons⁴⁴.

These techniques are particularly advantageous for fully autonomous robotic surgery or minimally invasive surgery. Consider modern laparoscopic surgery (MLS)—in which several small incisions are used to insert a number of instruments into the body, including cameras and surgical tools, which surgeons then teleoperate. Deep imitation learning, RNNs, and trajectory transfer algorithms can fully automate certain teleoperated manipulation tasks of the surgical procedure⁷. In MLS, the automation of repetitive tasks is even more time-critical than in open surgery. For instance, it may take 3 minutes to tie a knot in MLS instead of a few seconds, as in open surgery.

One of the main challenges during semiautonomous teleoperation is correctly localizing an instrument's position and orientation in the vicinity of surgical scenes. Here, recent pixel-wise instrument segmentation techniques⁴⁵, developed using an improved U-Net architecture CNN^{25,46}, begin to show promise. Another challenge for the progression of deep learning in surgical robotics is data collection. Deep imitation learning requires large training datasets with many examples per surgical action. Given that many surgeries are nuanced and unique, it remains difficult to collect sufficient data for more general surgical tasks. Further, it remains difficult for autonomous systems to adapt to completely unknown and unobserved situations highly dissimilar from anything previously seen, such as an anomalous surgical accident.


Generalized deep learning

Beyond CV, NLP, and RL tasks, deep learning is adaptable to domains in which input data is nuanced and requires specialized treatment. For illustrative purposes, here we consider genomics, an example domain in which deep learning has been adapted beyond conventional (e.g., CNN- or RNN-based) approaches to work with unique (e.g., nonimage, nontemporal) data representations.

Modern genomic technologies collect a wide variety of measurements, from an individual's DNA sequence to the quantity of various proteins in their blood. There are many opportunities for deep-learning system in genomics involves taking raw data (e.g., deep learning to improve the methods used to analyze these mea- gene expression data), converting this raw data into input data tensors, which will ultimately help clinicians provide more accusers, and feeding these tensors through neural networks which then rate treatments and diagnoses. The typical pipeline for building a power specific biomedical applications (Fig. 4).



[Fig. 3 | Making predictions using EHRs. a, Unstructured EHR data. Medical records are stored in idiosyncratic data structures and formats such that models built on a given hospital's record do not necessarily work with data from a different hospital. b, Data standardization. By mapping data from multiple sites to a single format based on FHIR, data are standardized into a homogeneous format. c, Sequencing. By temporally sequencing all data into a patient timeline, time-based deep-learning techniques can be applied on the entirety of EHR datasets for making predictions about single patients.]



[Fig. 4 | ML in genomics. a, Input data. Genomic data consists of experimental measurements from which certain properties or outcomes of interest may be predicted. This data is often diverse and may include sequencing, gene expression, and functional data as well as other forms of molecular data. b Example data tensors. Raw experimental measurements need to be transformed into a form that is suitable for consumption by deep-learning algorithms, which take as input multidimensional data tensors and associated target labels. c, DNN. Labeled tensors are used to train DNNs to predict the label from the input data tensor. d, Biomedical applications. Trained DNNs can be used in biomedical applications, such as in predicting labels for previously unseen data tensors or examining the relationship between input data and output labels. Example applications include interpreting experimental data (e.g., inferring DNA sequences from the output of a sequencing instrument or inferring the effects of DNA mutations on gene splicing) and molecular diagnostics (e.g., predicting the effects of genetic mutations on disease risk or drug response), among many others.]

Pershttps://doi.org/10.1038/s41591-018-0316-PersPPpectiveective | FOCUS | FOCUS
z Nature MediCiNe

One set of opportunities centers on genome-wide association (GWA) studies—large case-control studies that seek to discover causal genetic mutations affecting specific traits. Analyzing GWA studies requires algorithms that scale to very large patient cohorts and that deal with latent confounders. These challenges can be addressed via optimization tools and techniques developed for deep learning—including stochastic optimization and other modern algorithms⁴⁷ combined with software frameworks for scaling computation in parallel⁴⁸—as well as through modeling techniques that handle unseen confounders⁴⁹. In the near future, models that

integrate external modalities and additional sources of biological data into GWA studies—e.g., medical images or measurements of splicing and other intermediary molecular phenotypes—may also benefit from deep learning to more accurately identify disease-associated causal mutations⁵⁰.

Understanding the genetics of disease allows clinicians to recommend treatments and provide more accurate diagnoses. A key challenge for physicians is determining if novel variants in a patient's genome are medically relevant. In part, this decision relies on predicting the pathogenicity of mutations; a task which already uses features like protein structure and evolutionary conservation to train learning algorithms⁵¹. Given their greater power and ability to effectively integrate disparate data types, deep-learning techniques are likely to provide more accurate pathogenicity predictions than are possible today⁵².

Machine learning also plays a role in phenotype prediction from genetic data, including complex traits such as height as well as disease risk. Deep learning can further enhance such models by integrating additional modalities such as medical images, clinical history, and wearable device data⁵³. A particularly promising approach to phenotype prediction is to predict intermediate molecular phenotypes—e.g., gene expression or gene splicing—which then feed into downstream disease predictors⁵⁴. Intermediate molecular states can be easier to predict than human traits because of larger, more proximal signals and more extensive training data. These two features make the problem a good fit for deep learning, which has shown success at predicting splicing⁵⁵ and transcription factor binding⁵⁶.

Genomic data can also directly serve as a biomarker for the onset and progression of disease. For example, blood contains small fragments of cell-free DNA released from cells present elsewhere in the body. These fragments are noninvasive indicators of organ rejection (i.e., the immune system attacking graft cells⁵⁷), bacterial infection⁵⁸, and early-stage cancer⁵⁹. Cell-free DNA is successfully used in prenatal diagnostics: fetal DNA present in the mother's blood indicates chromosomal aberrations and can reveal the whole genome of the fetus⁶⁰. Biomarker data are often noisy and requires sophisticated analysis (e.g., to determine whether cell-free DNA is indicative of cancer); deep-learning systems can enhance the quality of biomarker assays targeting DNA sequences⁶¹, methylation⁶², gene expression⁶³, chromatin⁶⁴ profiles, and many other measurements.

Received: 17 October 2018; Accepted: 28 November 2018;

Published online: 7 January 2019

1. LeCun, Y., Bengio, Y. & Hinton, G. Deep learning. *Nature* 521, 436–444 (2015).
2. Russakovsky, O. et al. Imagenet large scale visual recognition challenge. *Int. J. Compute. Vis.* 115, 211–252 (2015).

3. Hirschberg, J. & Manning, C. D. Advances in natural language processing. *Science* 349, 261–266 (2015).
4. Geoffrey Hinton, et al. Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups. *IEEE Signal Process. Mag.* 29, 82–97 (2012).
5. Stanford Health. Harnessing the power of data in health. *Stanford Medicine 2017 Health Trends Report* (2017).
6. Silver, D. et al. Mastering the game of go with deep neural networks and tree search. *Nature* 529, 484–489 (2016).
7. Yohannes Kassahun, et al. Surgical robotics beyond enhanced dexterity instrumentation: a survey of machine learning techniques and their role in intelligent and autonomous surgical actions. *Int. J. Comput. Assist. Radio. Surg.* 11, 553–568 (2016).
8. Litjens, G. et al. A survey on deep learning in medical image analysis. *Med. Image Anal.* 42, 60–88 (2017).
9. Esteva, A. et al. Dermatologist-level classification of skin cancer with deep neural networks. *Nature* 542, 115–118 (2017).
10. Haenssle, H. A. et al. Man against machine: diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. *Ann. Oncol.* 29, 1836–1842 (2018).
11. Cheng, J.-Z. et al. Computer aided diagnosis with deep learning architecture: applications to breast lesions in us images and pulmonary nodules in CT scans. *Sci. Rep.* 6, 24454 (2016).
12. Cicero, M. et al. Training and validating a deep convolutional neural network for computer-aided detection and classification of abnormalities on frontal chest radiographs. *Invest. Radiol.* 52, 281–287 (2017).
13. Kooi, T. et al. Large scale deep learning for computer aided detection of mammographic lesions. *Med. Image Anal.* 35, 303–312 (2017).
14. Barreira, C. M. et al. Abstract WP61: Automated large artery occlusion detection in stroke imaging-paladin study. *Stroke* 49, AWP61 (2018).
15. Gulshan, V. et al. Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA* 316, 2402–2410 (2016).
16. Poplin, R. et al. Webster. Prediction of cardiovascular risk factors from retinal fundus photographs via deep learning. *Nat. Biomed. Eng.* 2, 158–164 (2018).
17. Fauw, J. et al. Clinically applicable deep learning for diagnosis and referral in retinal disease. *Nat. Med.* 24, 1342 (2018).
18. Cireşan, D. C., Giusti, A., Gambardella, L. M. & Schmidhuber, J. Mitosis detection in breast cancer histology images with deep neural networks. In *International Conference on Medical Image Computing and Computer-assisted Intervention* 411–418 (Springer, 2013).
19. Liu, Y. et al. Detecting cancer metastases on gigapixel pathology images. Preprint at <https://arxiv.org/abs/1703.02442> (2017).

20. Charoentong, P. et al. Pan-cancer immunogenomic analyses reveal genotype–immunophenotype relationships and predictors of response to checkpoint blockade. *Cell Rep.* 18, 248–262 (2017).
21. Beck, A. H. et al. Systematic analysis of breast cancer morphology uncovers stromal features associated with survival. *Sci. Transl. Med.* 3, 108ra113 (2011).
22. Yosinski, J., Clune, J., Bengio, Y. and Lipson, L. How transferable are features in deep neural networks? In *Advances in Neural Information Processing Systems* 3320–3328 (2014).
23. Jamaludin, A., Kadir, T. and Zisserman, A. Spinenet: automatically pinpointing classification evidence in spinal mris. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* 166–175 (Springer, 2016).
24. Kermany, D. S. et al. Identifying medical diagnoses and treatable diseases by image-based deep learning. *Cell* 172, 1122–1131 (2018).
25. Ronneberger, O., Fischer, P. & Brox, T. U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (2015).
26. Goodfellow, I. et al. Generative adversarial nets. In *Advances in Neural Information Processing Systems* 2672–2680 (2014).
27. Sutskever, I., Vinyals, O. & Le, Q. V. Sequence to sequence learning with neural networks. In *Advances in Neural Information Processing Systems* 3104–3112 (2014).
28. Wu, Y. et al. Google’s neural machine translation system: bridging the gap between human and machine translation. Preprint at <https://arxiv.org/abs/1609.08144> (2016).
29. Kannan, A. et al. Smart reply: automated response suggestion for email. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (ACM, 2016)*.
30. Vinyals, O., Toshev, A., Bengio, S. & Erhan, D. Show and tell: a neural image caption generator. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* 3156–3164 (2015).
31. The Office of the National Coordinator for Health Information Technology. Quick stats: health IT dashboard. <https://dashboard.healthit.gov/quickstats/quickstats.php> (2017).
32. Shickel, B., Tighe, P. J., Bihorac, A. & Rashidi, P. Deep EHR: a survey of recent advances in deep learning techniques for electronic health record (EHR) analysis. *IEEE J. Biomed. Health Inform.* 22, 1589–1604 (2017).
33. Rajkomar, A. et al. Scalable and accurate deep learning with electronic health records. *NPJ Digit. Med.* 1, 18 (2018).
34. Miotto, R. et al. Deep patient: an unsupervised representation to predict the future of patients from the electronic health records. *Sci. Rep.* 6, 26094 (2016).

FOCUS |

Nature MediCine FOCUS <https://doi.org/10.1038/s41591-018-0316-z> | Perspectives

35. Liu, V., Kipnis, P., Gould, M. K. & Escobar, G. J. Length of stay predictions:

- improvements through the use of automated laboratory and comorbidity variables. *Med. Care* 48, 739–744 (2010).
36. Choi, E. et al. Doctor AI: predicting clinical events via recurrent neural networks. In *Machine Learning for Healthcare* 301–318 (2016).
 37. Che, Z. et al. Recurrent neural networks for multivariate time series with missing values. *Rep.* 8, 1–12 (2018).
 38. Suresh, H. et al. Clinical intervention prediction and understanding with deep neural networks. *PMLR* 68, 322–377 (2017).
 39. Johnson, A. E. W. et al. MIMIC-III, a freely accessible critical care database. *Sci. Data* 3, 160035 (2016).
 40. Mao, Q. et al. Multicentre validation of a sepsis prediction algorithm using only vital sign data in the emergency department, general ward and ICU. *BMJ Open* 8, e017833 (2018).
 41. Abbeel, P. & Ng, A. Y. Apprenticeship learning via inverse reinforcement learning. In *Proceedings of the Twenty-First International Conference on Machine Learning* 1 (ACM, 2004).
 42. Ratliff, N. D., Silver, D. & Bagnell, J. A. Learning to search: functional gradient techniques for imitation learning. *Autonomous Robots* 27, 25–53 (2009).
 43. Schulman, J. et al. A case study of trajectory transfer through non-rigid registration for a simplified suturing scenario. In *2013 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* 4111–4117 (IEEE, 2013).
 44. Mayer, H. et al. A system for robotic heart surgery that learns to tie knots using recurrent neural networks. *Adv. Robot* 22, 1521–1537 (2008).
 45. Shvets, A., Rakhlin, A., Kalinin, A. A. and Iglovikov, V. Automatic instrument segmentation in robot-assisted surgery using deep learning. Preprint at <https://arxiv.org/abs/1803.01207> (2018).
 46. Jin, A. et al. Tool detection and operative skill assessment in surgical videos using region-based convolutional neural networks. Preprint at <https://arxiv.org/abs/1802.08774> (2018).
 47. Loh, P.-R. et al. Efficient bayesian mixed-model analysis increases association power in large cohorts. *Nat. Genet.* 47, 284 (2015).
 48. Abadi, M. et al. Tensorflow: Large-scale machine learning on heterogeneous distributed systems. <http://download.tensorflow.org/paper/whitepaper2015.pdf> (2015).
 49. Tran, D. and Blei, D. M. Implicit causal models for genome-wide association studies. In *International Conference on Learning Representations* (2018).
 50. Lee, S.-I. et al. Learning a prior on regulatory potential from eQTL data. *PLoS Genet.* 5, e1000358 (2009).
 51. Kircher, M. et al. A general framework for estimating the relative pathogenicity of human genetic variants. *Nat. Genet.* 46, 310–315 (2014).
 52. Quang, D., Chen, Y. & Xie, X. Dann: a deep learning approach for annotating the pathogenicity of genetic variants. *Bioinformatics* 31, 761–3 (2015).
 53. Dudley, J. T. et al. Personalized medicine: from genotypes, molecular phenotypes and the quantified self, towards improved medicine. In *Pacific Symposium on Biocomputing* 342–346 (2014).

54. Leung, M. K. K., Delong, A., Alipanahi, B. & Frey, B. J. Machine learning in genomic medicine: a review of computational problems and data sets. *Proc. IEEE* 104, 176–197 (2016).
55. Xiong, H. Y. et al. The human splicing code reveals new insights into the genetic determinants of disease. *Science* 347, 1254806 (2015).
56. Alipanahi, B. et al. Predicting the sequence specificities of dna-and rna-binding proteins by deep learning. *Nature Biotechnol.* 33, 831–838 (2015).
57. Snyder, T. M., Khush, K. K., Valantine, H. A. & Quake, S. R. Universal noninvasive detection of solid organ transplant rejection. *Proc. Natl Acad. Sci. USA* 108, 6229–6234 (2011).
58. Abril, M. K. et al. Diagnosis of capnocytophaga canimorsus sepsis by whole-genome next-generation sequencing. In *Open Forum Infectious Diseases* Vol. 3, ofw144 (Oxford University Press, 2016).
59. Forshew, T. et al. Noninvasive identification and monitoring of cancer mutations by targeted deep sequencing of plasma dna. *Sci. Transl. Med.* 4, 136 ra 68–136ra68 (2012).
60. Fan, H. C. et al. Non-invasive prenatal measurement of the fetal genome. *Nature* 487, 320–324 (2012).
61. Ching, T. et al. Opportunities and obstacles for deep learning in biology and medicine. Preprint at <https://doi.org/10.1101/142760> (2017).
62. Angermueller, C., Lee, H. J., Reik, W. & Stegle, O. Deepcpg: accurate prediction of single-cell dna methylation states using deep learning. *Genome Biol.* 18, 67 (2017).
63. Chen, Y. et al. Gene expression inference with deep learning. *Bioinformatics* 32, 1832–1839 (2016).
64. Koh, P. W., Pierson, E. & Kundaje, A. Denoising genome-wide histone chip-seq with convolutional neural networks. *Bioinformatics* 33, i225–i233 (2017).

Acknowledgements

The authors would like to thank D. Wang, E. Dorfman, and A. Rajkomar for the visual design of the figures in this paper and P. Nejad for insightful conversation and ideas.

Author contributions

B.R., V.K., M.D., and K.C. share second authorship. C.C., G.C., and S.T. share third authorship. J.D. is the principal investigator. A.E. and A.R. conceptualized the structure of the review and contributed to the computer vision and reinforcement learning sections. V.K., B.R., and M.D. contributed to the generalized deep learning section. K.C. and J.D. contributed to the natural language processing section. C.C., G.C., S.T., and J.D. oversaw the work. All authors contributed to multiple parts of the review, as well as the style and overall contents.

Competing interests

M.D., C.C., K.C., G.C. and J.D. are employees of Google Inc. This work was internally funded by Google Inc. G.C. is a board member at the Partnership on AI to Benefit People and Society. S.T. is an employee of Udacity, Inc. and the Kitty Hawk Corporation. He is on the faculty of Stanford University and Georgia Institute of Technology. B.R. is a partner of Computable LLC.

Additional information

Reprints and permissions information is available at www.nature.com/reprints.

Correspondence should be addressed to A.E.

Publisher's note: Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations. © Springer Nature America, Inc. 2019

Ένας οδηγός για την βαθιά μάθηση στην υγειονομική περίθαλψη

Andre Esteva ^{1, 3*}, Alexandre Robicquet ^{1, 3}, Bharath Ramsundar ¹, Volodymyr Kuleshov ¹, Mark DePristo ², Katherine Chou ², Claire Cui ², Greg Corrado ², Sebastian Thrun ¹ and Jeff Dean ².

Στο παρόν επιστημονικό άρθρο παρουσιάζονται τεχνικές βαθιάς μάθησης για την υγειονομική περίθαλψη, εστιάζοντας την προσοχή μας στην βαθιά μάθηση της υπολογιστικής όρασης, στην επεξεργασία της φυσικής γλώσσας, στην ενίσχυση της μάθησης και των γενικευμένων μεθόδων. Περιγράφουμε πώς αυτές οι υπολογιστικές τεχνικές μπορούν να επηρεάσουν μερικούς βασικούς τομείς της ιατρικής και διερευνούμε το πως να χτίσουμε διατεματικά συστήματα. Η συζήτηση μας για την μηχανική όραση επικεντρώνεται σε μεγάλο βαθμό στην ιατρική απεικόνιση και περιγράφεται η εφαρμογή της επεξεργασίας της φυσικής γλώσσας σε τομείς όπως τα δεδομένα ηλεκτρονικών μητρώων υγείας. Παρομοίως, η ενισχυτική μάθηση συζητείται στο πλαίσιο της ρομποτικής χειρουργικής και εξετάζονται γενικευμένες μέθοδοι βαθιάς μάθησης για την Γονιδιωματική.

Η βαθιά μάθηση ¹, ένα υποπεδίο της μηχανικής μάθησης (ML), έχει γνωρίσει σημαντική επιτυχία τα τελευταία 6 χρόνια, κυρίως λόγω της αύξησης της υπολογιστικής ισχύος και της μαζικής διαθεσιμότητας νέων συνόλων δεδομένων. Το πεδίο έχει σημειώσει εντυπωσιακές προόδους στην ικανότητα των μηχανών να κατανοούν και να χειρίζονται δεδομένα, συμπεριλαμβανομένων εικόνων ², γλώσσας ³ και ομιλίας ⁴. Η υγειονομική περίθαλψη και η ιατρική επωφελούνται σε μεγάλο βαθμό από τη βαθιά μάθηση λόγω του υπερμεγέθους όγκου δεδομένων που δημιουργούνται (150 exabytes ή 10¹⁸ bytes μόνο στις Ηνωμένες Πολιτείες, σε αύξηση κατά 48% ετησίως ⁵) καθώς και τον αυξανόμενο πολλαπλασιασμό ιατρικών συσκευών και συστημάτων ψηφιακών αρχείων.

Η μηχανική μάθηση (ML) διαφέρει από άλλους τύπους προγραμματισμού υπολογιστών, δεδομένου ότι μετατρέπει τις εισαγωγές ενός αλγορίθμου σε εξαγωγές, χρησιμοποιώντας στατιστικούς κανόνες βάσει δεδομένων, που προέρχονται αυτόματα από ένα μεγάλο σύνολο παραδειγμάτων, αντί να προσδιορίζονται λεπτομερώς από τον άνθρωπο. Παραδοσιακά, η κατασκευή ενός συστήματος μηχανικής μάθησης (ML) απαιτούσε εξειδίκευση τομέα και εργονομία για το σχεδιασμό εξαγωγών χαρακτηριστικών, που μετέτρεψαν επεξεργασμένα δεδομένα σε κατάλληλες αναπαραστάσεις, από τις οποίες ένας αλγόριθμος μάθησης μπορούσε να αναγνωρίσει πρότυπα.

Αντιθέτως, η βαθιά μάθηση είναι μια μορφή μάθησης αναπαράστασης- κατά την οποία μια μηχανή τροφοδοτείται με μη επεξεργασμένα δεδομένα και αναπτύσσει τις δικές της αναπαραστάσεις, που απαιτούνται για την αναγνώριση προτύπων – η οποία αποτελείται από πολλαπλά στρώματα αναπαραστάσεων. Αυτά τα στρώματα συνήθως είναι τοποθετημένα διαδοχικά και αποτελούνται από μεγάλο αριθμό πρωτογενών, μη γραμμικών λειτουργιών, έτσι ώστε η αναπαράσταση ενός στρώματος (ξεκινώντας με την εισαγωγή μη-επεξεργασμένων δεδομένων) να τροφοδοτείται στο επόμενο στρώμα και να μετατρέπεται σε μια συνοπτικότερη αναπαράσταση ¹. Καθώς τα δεδομένα ρέουν μέσω των στρωμάτων του συστήματος, ο χώρος εισόδου στρεβλώνεται επαναληπτικά έως ότου τα σημεία δεδομένων να γίνουν διακριτά (Εικ. 1α). Με αυτόν τον τρόπο, μπορούν πολύπλοκες λειτουργίες να γίνουν μέρος της βαθιάς μάθησης.

Τα μοντέλα βαθιάς μάθησης κλιμακώνονται σε μεγάλα σύνολα δεδομένων - εν μέρει λόγω της ικανότητάς τους να «τρέχουν» σε εξειδικευμένο υπολογιστικό υλικό - και συνεχίζουν να βελτιώνονται με περισσότερα δεδομένα, επιτρέποντάς τους να σημειώσουν καλύτερη επίδοση από άλλες κλασικές προσεγγίσεις της Μηχανικής Μάθησης (ML). Τα συστήματα βαθιάς μάθησης μπορούν να δεχτούν πολλαπλούς τύπους δεδομένων ως είσοδο - μια πτυχή ιδιαίτερης σημασίας για ετερογενή δεδομένα υγειονομικής περίθαλψης (Εικ. 1β). Τα πιο συνηθισμένα μοντέλα εκπαιδεύονται χρησιμοποιώντας επιβλεπόμενη μάθηση, όπου τα σύνολα δεδομένων αποτελούνται από σημεία εισαγωγής δεδομένων (π.χ. εικόνες βλάβης δέρματος) και αντίστοιχες ετικέτες εξαγωγής δεδομένων (π.χ. «καλοήγη» ή «κακοήγη»). Η ενισχυτική μάθηση, κατά την οποία υπολογιστικοί παράγοντες μαθαίνουν μέσω δοκιμής και σφάλματος ή κατόπιν καθοδήγησης εμπειρογνώμονα, έχει προοδεύσει με την υιοθέτηση της βαθιάς μάθησης, επιτυγχάνοντας έτσι αξιοσημείωτα επιτεύγματα σε τομείς όπως το παιχνίδι (π.χ. Go⁶). Η ενισχυτική μάθηση ενδέχεται να φανεί χρήσιμη στην υγειονομική περίθαλψη, σε περιπτώσεις που η μάθηση απαιτεί επίδειξη από ιατρό. Ένα τέτοιο παράδειγμα είναι η περίπτωση κατά την οποία απαιτείται η εκμάθηση ραμμάτων χειρουργικών επεμβάσεων με ρομποτική βοήθεια ⁷.

Μηχανική όραση

Μερικές από τις πιο σπουδαίες επιτυχίες της βαθιάς μάθησης έχουν σημειωθεί στον τομέα της μηχανικής όρασης (CV) ². Η μηχανική όραση επικεντρώνεται στην κατανόηση εικόνων και βίντεο και ασχολείται με θέματα όπως η ταξινόμηση αντικειμένων, η ανίχνευση και η κατάτμηση -τα οποία βοηθούν στον καθορισμό του εάν στο ραδιογράφημα του ασθενούς ανιχνεύονται κακοήθεις όγκοι. Τα Συνελκτικά Νευρωνικά Δίκτυα (CNNs) ^{1,2}, το οποίο είναι ένα είδος βαθιάς μάθησης, που σχεδιάστηκε για να επεξεργάζεται δεδομένα, τα οποία παρουσιάζουν

τη φυσική χωρική αμεταβλητότητα (για παράδειγμα, εικόνες, των οποίων οι έννοιες δεν αλλάζουν κατά τη διαδικασία της μετάφρασης), έχουν καταλήξει να κατέχουν βασική θέση σε αυτόν τον τομέα.¹

Η ιατρική απεικόνιση, παραδείγματος χάριν, μπορεί κάλλιστα να ωφεληθεί από πρόσφατες προόδους, που έχουν σημειωθεί, στην ταξινόμηση εικόνων και την ανίχνευση αντικειμένων^{2,8}. Πολλές μελέτες έχουν δώσει ελπιδοφόρα αποτελέσματα σε περίπλοκες διαγνωστικές, που αφορούν τη δερματολογία⁹⁻¹⁰, την ραδιολογία¹¹⁻¹⁴, την οφθαλμολογία¹⁵⁻¹⁷ και την παθολογία¹⁸⁻²¹ (Εικόνα 2). Τα συστήματα βαθιάς μάθησης θα μπορούσαν να βοηθήσουν τους ιατρούς προσφέροντας τους μια δεύτερη γνώμη και επισημαίνοντας τα ανησυχητικά σημεία στις εικόνες.


Οι απεικονιστικές διαγνωστικές έχουν σημειώσει αρκετά μεγάλη επιτυχία σε ότι αφορά τη χρήση μεθόδων που έχουν βασιστεί στο Συνελικτικό Νευρωνικό Δίκτυο (CNN). Αυτό οφείλεται σε μεγάλο βαθμό στο γεγονός ότι τα Συνελικτικά Νευρωνικά Δίκτυα έχουν κατορθώσει να φτάσουν την ανθρώπινη απόδοση σε ζητήματα ταξινόμησης αντικειμένων, στα οποία ένα Νευρωνικό Συνελικτικό Δίκτυο (CNN) μαθαίνει να ταξινομεί το αντικείμενο που απεικονίζεται. Αυτά τα ίδια δίκτυα έχουν επιδείξει δυνατή απόδοση στη μεταφορά μάθησης²². Κατά την διάρκεια της οποίας, ένα Συνελικτικό Νευρωνικό Δίκτυο (CNN), αρχικά εκπαιδευμένο σε ένα ογκώδες σύνολο δεδομένων, το οποίο δεν σχετίζεται με το πεδίο ενδιαφέροντος (για παράδειγμα, το ImageNet [ΣτΜ¹], ένα σύνολο δεδομένων αποτελούμενο από εκατομμύρια συνηθισμένα αντικείμενα καθημερινής χρήσης) προσαρμόζεται με ακρίβεια σε ένα πολύ μικρότερο σύνολο δεδομένων σχετιζόμενο με το πεδίο ενδιαφέροντος (για παράδειγμα, ιατρικές απεικονίσεις). Καταρχήν, ο αλγόριθμος «μοχλεύει» μαζικές ποσότητες δεδομένων ούτως ώστε να μάθει από φυσικές στατιστικές εικόνες -ευθείες γραμμές, καμπύλες, χρωματισμούς κ.λπ.-. Σε δεύτερη φάση, τα υψηλότερα επίπεδα στρωμάτων του αλγόριθμου εκπαιδεύονται εκ νέου να διακρίνουν την μία διαγνωστική περίπτωση από την άλλη. Ομοίως, η ανίχνευση αντικειμένων και ο αλγόριθμος κατάτμησης αναγνωρίζει συγκεκριμένα μέρη μιας εικόνας. Η μέθοδος των Συνελικτικών Νευρωνικών Δικτύων συλλέγει τα δεδομένα εικόνας ως είσοδο και με επαναλαμβανόμενο τρόπο τα «τυλίγει» μέσω μιας σειράς συνελικτικών και μη γραμμικών διαδικασιών έως ότου η αρχική, ανεπεξέργαστη μήτρα δεδομένων να καταλήξει σε μια κατανομή πιθανότητας πάνω στην ταξινόμηση εικόνων (για παράδειγμα, ιατρικές γνωματεύσεις περιστατικών) (Εικόνα 2).

Παραδόξως, τα μοντέλα βαθιάς μάθησης έχουν κατορθώσει να φτάσουν σε ακρίβεια το επίπεδο των ιατρών σε ένα ευρύ φάσμα διαγνωστικών περιπτώσεων,

¹ ΣτΜ¹: Το έργο ImageNet είναι μια μεγάλη οπτική βάση δεδομένων σχεδιασμένη για χρήση στην έρευνα λογισμικού αναγνώρισης αντικειμένων.

συμπεριλαμβάνοντας την αναγνώριση στη διαφορά μιας ελιάς από το μελάνωμα ⁹ ¹⁰, την διαβητική αμφιβληστροειδοπάθεια, τον καρδιαγγειακό κίνδυνο, δείγματα από τον βυθό του οφθαλμού ¹⁵ ¹⁶, εικόνες των ματιών κατόπιν εξέτασης σε οπτική τομογραφία συνοχής ¹⁷, ανίχνευση αλλοιώσεων στον μαστό κατά την

μαστογραφία¹³ και τέλος σπονδυλική ανάλυση με απεικόνιση μαγνητικού συντονισμού (μαγνητική τομογραφία) ²³. Ακόμη και ένα μόνο μοντέλο βαθιάς μάθησης έχει αποδειχθεί αποτελεσματικό στο να κάνει διάγνωση σε διάφορους τομείς της ιατρικής (π.χ. ραδιολογία και οφθαλμολογία) ²⁴.



Εικόνα 1. Βαθιά μάθηση. Α, Ένα απλό, πολυστρωματικό βαθύ νευρωνικό δίκτυο συλλέγει δυο κατηγορίες δεδομένων, που υποδηλώνονται από διαφορετικά χρώματα και τα μετατρέπει σε γραμμικώς χωριζόμενα παραμορφώνοντάς τα επανειλημμένα καθώς τα δεδομένα ρέουν από το ένα στρώμα στο άλλο. Το τελευταίο στρώμα εξόδου εκτελεί καθήκοντα ταξινομητή με το να δημιουργεί πιθανότητες σε μία από τις κατηγορίες. Αυτό το παράδειγμα αποτυπώνει τη βασική ιδέα που χρησιμοποιείται από μεγάλης κλίμακας συστήματα. Η εννοιολογική απεικόνιση είναι τροποποιημένη με άδεια από: <http://colah.github.io>. **Β,**

Παράδειγμα δικτύου μεγάλης κλίμακας, το οποίο δέχεται ως σημείο εισόδου μια ποικιλία από διάφορους τύπους δεδομένων (εικόνες, χρονοσειρές, κ.λπ.) και για κάθε τύπο δεδομένου μαθαίνει ένα χρήσιμο χαρακτηριστικό στα χαμηλότερα επίπεδα των ιστών του. Έπειτα, τα δεδομένα από κάθε ιστό ενώνονται και ρέουν μέσω των υψηλότερων επιπέδων, επιτρέποντας έτσι στο Βαθύ Νευρωνικό Δίκτυο (DNN) να αποδώσει συμπεράσματα για όλους τους τύπους δεδομένων - μια ικανότητα, η οποία είναι ιδιαίτερα σημαντική για την υγειονομική περίθαλψη.

Ωστόσο, ένας βασικός περιορισμός σε όλες τις μελέτες, που συγκρίνουν τον άνθρωπο με την αλγοριθμική απόδοση, είναι ότι υστερεί σε κλινική συνάφεια - η διαδικασία της διάγνωσης γίνεται υπό τον περιορισμό του ότι λαμβάνονται υπόψιν απλώς οι επικείμενες εικόνες. Αυτό συχνά αυξάνει το επίπεδο δυσκολίας της διαγνωστικής διαδικασίας για το ανθρώπινο όν, το οποίο σε πραγματικές συνθήκες κλινικών διαδικασιών έχει πρόσβαση και σε ιατρική απεικόνιση αλλά και σε συμπληρωματικά δεδομένα, συμπεριλαμβανομένων το ιατρικό ιστορικό του ασθενούς, τις συμπληρωματικές εξετάσεις, την συγκατάθεση του ασθενούς κλπ.

Οι κλινικές αρχίζουν να επιστρατεύουν την ανίχνευση αντικειμένων και την κατάτμηση τους σε εικόνες για καταστάσεις έκτακτης ανάγκης και αναμφισβήτητα σε καταστάσεις αποτυχημένων περιπτώσεων, όπως για παράδειγμα την προειδοποίηση σε περίπτωση μεγάλης αρτηριακής απόφραξης στον εγκέφαλο χρησιμοποιώντας ακτινολογικές εικόνες ¹⁴, μέσω των οποίων οι ασθενείς έχουν περιορισμένο χρόνο (μόλις λίγα λεπτά) πριν παραστεί μόνιμη εγκεφαλική βλάβη. Επιπλέον, οι ενδείξεις ιστοπαθολογικού καρκίνου, οι οποίες απαιτούν την ανθρώπινη εμπειρογνωμοσύνη ούτως ώστε να σκανάρουν με εργαστηριακό τρόπο και να μπορέσουν να κάνουν διάγνωση σε μια εικόνα gigapixel (ή αντιστοίχως μεγάλες φυσικές διαφάνειες) μπορούν να ενισχυθούν με τα Συνελκτικά Νευρωνικά Δίκτυα, τα οποία είναι εκπαιδευμένα να ανιχνεύουν μιτωτικά κύτταρα ¹⁸ ή περιοχές του σώματος στα οποία έχει αναπτυχθεί όγκος ¹⁹. Τα ΣΝΔ είναι εκπαιδευμένα να μετρούν την ποσότητα της τρέχουσας πρωτεΐνης PD-L1 σε μια ιστοπαθολογική εικόνα ²⁰ - ένα έργο σημαντικό στο να καθοριστεί τι τύπος φαρμάκου ενδείκνυται στη περίπτωση που ένας ασθενής πάσχει από άνοσο-ογκολογία.

Σε συνδυασμό με αναλύσεις επιπέδου μικροστοιχείων εικόνας, τα ΣΝΔ έχουν ακόμη χρησιμοποιηθεί για να ανακαλυφθούν βιολογικά χαρακτηριστικά ιστών, που σχετίζονται με την πιθανότητα επιβίωσης ²¹.

Ο πρωτεύων περιορισμός για την κατασκευή ενός επιβλεπόμενου συστήματος βαθιάς μάθησης για ένα νέο έργο ιατρικής απεικόνισης αποτελεί η πρόσβαση σε ένα αρκετά μεγάλο σύνολο δεδομένων με ετικέτα. Τα μικρά σύνολα δεδομένων με ετικέτα για συγκεκριμένες εργασίες είναι ευκολότερο να συλλεχθούν, αλλά καταλήγουν σε αλγόριθμους, οι οποίοι τείνουν να έχουν χαμηλότερη απόδοση σε νέα δεδομένα. Σε αυτές τις περιπτώσεις, οι τεχνικές, που

χρησιμοποιούνται για την αύξηση των δεδομένων, έχουν δείξει πως είναι πολύ πιο αποτελεσματικά στην γενίκευση ²⁵ των αλγόριθμων. Ομοίως, τα ογκώδη αλλά χωρίς ετικέτα σύνολα δεδομένων είναι επίσης ευκολότερο να συλλεχθούν, ωστόσο απαιτείται η μετάθεση προς ημι- επιτηρούμενες και μη επιβλεπόμενες τεχνικές, όπως για παράδειγμα το γενετικό ανταγωνιστικό δίκτυο (GAN) ²⁶.

Επεξεργασία φυσικής γλώσσας

Η επεξεργασία φυσικής γλώσσας επικεντρώνεται στην ανάλυση κειμένου και λόγου με σκοπό την εξαγωγή νοήματος από τις λέξεις. Τα αναδρομικά νευρωνικά συστήματα (RNN) - αλγόριθμοι βαθιάς μάθησης, που είναι αποτελεσματικοί στο να επεξεργάζονται διαδοχικές εισαγωγές όπως η γλώσσα, ο λόγος και δεδομένα σε χρονική σειρά ²⁷- παίζουν σημαντικό ρόλο σε αυτό το πεδίο. Στις αξιοσημείωτες επιτυχίες της Επεξεργασίας Φυσικής Γλώσσας συμπεριλαμβάνονται η μηχανική μετάφραση ²⁸, η παραγωγή κειμένου ²⁹ και ο υποτιτλισμός ³⁰. Στον τομέα της υγειονομικής περίθαλψης, οι συνδυαστικές τεχνολογίες της βαθιάς μάθησης και της γλώσσας, αποτελούν την κινητήρια δύναμη για διάφορες εφαρμογές σε τομείς όπως το σύστημα ηλεκτρονικών μητρώων υγείας.

Τα συστήματα ηλεκτρονικών μητρώων υγείας διαδίδονται ολοένα και περισσότερο ευρέως ³¹. Το ηλεκτρονικό σύστημα μητρώων υγείας ενός μεγάλου ιατρικού οργανισμού μπορεί να καταγράψει ιατρικές συναλλαγές (δεδομένων) για πάνω από 10 εκατομμύρια ασθενείς μέσα σε μια δεκαετία. Μία και μόνο εισαγωγή νοσηλείας κατά κανόνα δημιουργεί περίπου 150.000 κομμάτια δεδομένων. Τα ενδεχόμενα οφέλη που πηγάζουν από αυτά τα δεδομένα είναι αξιόλογα. Συνολικά, ένα σύστημα ηλεκτρονικού μητρώου υγείας αυτής της κλίμακας αναπαριστά 200.000 χρόνια ιατρικής σοφίας και 100 εκατομμύρια χρόνια αποτελέσματα δεδομένων από ασθενείς, καλύπτοντας έτσι μια πληθώρα από σπάνιες καταστάσεις και ασθένειες. Ως εκ τούτου, η εφαρμογή των μεθόδων της βαθιάς μάθησης στα δεδομένα του ²συστήματος ηλεκτρονικού μητρώου υγείας είναι ένα ταχέως αναπτυσσόμενο κομμάτι ^{32,33}.

Η εικόνα 3 περιγράφει συνοπτικά τα τεχνικά βήματα κατά την διαδικασία της κατασκευής συστημάτων βαθιάς μάθησης για τα συστήματα ηλεκτρονικών μητρώων υγείας. Τα μη επεξεργασμένα δεδομένα αρχικά συγκεντρώνονται από όλα τα ιδρύματα ούτως ώστε να διασφαλιστεί πως κατασκευάστηκε ένα εκτενές και

² ΣτΜ²: Η βάση δεδομένων MIMIC-III (Medical Information Mart for Intensive Care III), είναι μια μεγάλη σχεσιακή βάση ιατρικών δεδομένων, με ελεύθερη πρόσβαση σε μη ταυτοποιήσιμα με τα φυσικά πρόσωπα δεδομένα, με περισσότερους από 40000 ασθενείς. Οι ασθενείς αυτοί νοσηλεύθηκαν στις μονάδες εντατικής θεραπείας του Beth Israel Deaconess Medical Center ανάμεσα στο έτος 2001 και το έτος 2012. Π.Μ.Σ. «ΨΗΦΙΑΚΑ ΣΥΣΤΗΜΑΤΑ ΚΑΙ ΥΠΗΡΕΣΙΕΣ» ΚΑΤΕΥΘΥΝΣΗ: ΜΕΓΑΛΑ ΔΕΔΟΜΕΝΑ ΚΑΙ ΑΝΑΛΥΤΙΚΗ
<http://dione.lib.unipi.gr/xmlui/bitstream/handle/unipi/12876/thesis%20elpida%20mezili%20final.pdf?sequence=1&isAllowed=y>


αναλυτικό σύστημα. Τα δεδομένα έπειτα προτυποποιούνται και αναλύονται προσωρινά σε όλους τους ασθενείς, κάτι το οποίο τους καθιστά κατάλληλους για την εκπαίδευση που απαιτείται στη βαθιά μάθηση. Από δω και στο εξής, έχουμε τη δυνατότητα λοιπόν να ανάγουμε απαντήσεις στο πιο υψηλό επίπεδο των ιατρικών διερωτήσεων, όπως για παράδειγμα “τι σχέση έχει το ιστορικό του ασθενούς με την τρέχουσα διάγνυσή του;”, “ποια είναι η τρέχουσα λίστα με τα προβλήματα υγείας του;” και “ ποιες είναι οι ευκαιρίες που μας επιτρέπουν να παρέμβουμε;”.

Όταν γίνονται προβλέψεις, οι περισσότεροι δουλεύουν προκειμένου να υπολογίσουν τη χρησιμότητα της επιβλεπόμενης μάθησης σε περιορισμένα σύνολα δομών δεδομένων, συμπεριλαμβανομένων εργαστηριακών αποτελεσμάτων, ζωτικών ενδείξεων, διαγνωστικών κωδικών και δημογραφικών. Λαμβάνοντας υπόψιν τα δομημένα και μη δομημένα δεδομένα, που εμπεριέχονται στα συστήματα ηλεκτρονικών μητρώων υγείας, οι ερευνητές αρχίζουν να χρησιμοποιούν μεθόδους μη επιβλεπόμενης μάθησης, όπως για παράδειγμα αυτόματους κωδικοποιητές - στους οποίους τα δίκτυα αρχικά εκπαιδεύτηκαν να μαθαίνουν χρήσιμες αναπαραστάσεις, συμπιέζοντας και έπειτα ανακατασκευάζοντας δεδομένα χωρίς ετικέτα - ούτως ώστε να προβλέψουν συγκεκριμένες διαγνώσεις ³⁴. Πρόσφατες εφαρμογές της βαθιάς μάθησης υποδεικνύουν την χρονική ακολουθία των δομημένων συμβάντων, που προέκυψαν στο ιστορικό του ασθενούς με συνελκτικά και αναδρομικά νευρωνικά δίκτυα προκειμένου να προβλέψουν μελλοντικά ιατρικά περιστατικά ³⁵⁻³⁸. Μεγάλο μέρος αυτής της δουλειάς επικεντρώνεται στο σύνολο δεδομένων ³⁹ της MIMIC [ΣτΜ²] (για παράδειγμα, για την πρόβλεψη της σηψαιμίας ⁴⁰), η οποία περιλαμβάνει ασθενείς σε μονάδα εντατικής θεραπείας από ένα και μόνο ιατρικό κέντρο. Ενώ οι ασθενείς της ΜΕΘ παράγουν περισσότερα δεδομένα ηλεκτρονικών μητρώων υγείας από τους ασθενείς που δεν ανήκουν σε ΜΕΘ, οι πρώτοι υπερέχουν αριθμητικά των δεύτερων. Ως εκ τούτου, είναι ακόμα αβέβαιο το πόσο καλά οι τεχνικές που προέρχονται από αυτά τα δεδομένα θα εφαρμοστούν και στις ευρύτερες πληθυσμιακές ομάδες.

Η επόμενη γενιά αυτόματης αναγνώρισης ομιλίας ³² και μοντέλων άντλησης πληροφοριών είναι πιθανό να αναπτύξουν κλινικό φωνητικό βοηθό, προκειμένου να είναι σε θέση να απομαγνητοφωνεί με ακρίβεια κατά την διάρκεια των επισκέψεων σε ασθενείς. Οι γιατροί αναμφίβολα σπαταλούν ημερησίως τις 6 από τις 11 ώρες εργασίας τους, δουλεύοντας με έγγραφα ηλεκτρονικών μητρώων υγείας, κάτι το οποίο οδηγεί σε επαγγελματική εξουθένωση και μειώνει τον χρόνο που μπορεί ένας γιατρός να περάσει με τον ασθενή ³¹. Η αυτόματη συνταγογράφηση θα αποσυμφορήσει αυτή τη κατάσταση και θα διευκολύνει τις πιο οικονομικές υπηρεσίες αντιγραφής. Ας ληφθεί υπόψιν η γλωσσική μετάφραση ²⁷ που βασίζεται στο αναδρομικό νευρωνικό δίκτυο, το οποίο χρησιμοποιεί διαδοχική τεχνική για να μεταφράζει απευθείας την ομιλία από την μια γλώσσα και

να την μετατρέπει σε κείμενο στην άλλη. Προσαρμοσμένη στο σύστημα ηλεκτρονικού μητρώου υγείας, η τεχνική αυτή θα μπορούσε να μεταφράζει μια συζήτηση μεταξύ ασθενούς και υγειονομικού φορέα απευθείας σε ένα απομαγνητοφωνημένο κείμενο. Η βασική πρόκληση βρίσκεται στη ταξινόμηση των χαρακτηριστικών και της κατάστασης του κάθε ιατρικού φορέα, που πηγάζει από την συζήτηση ενώ με ακρίβεια θα γίνεται ανακεφαλαίωση του διαλόγου. Αν και πολλά υποσχόμενα τα πειράματα για αλληλεπίδραση ανθρώπου - υπολογιστή είναι σε πρώιμα στάδια, αυτές οι τεχνικές δεν έχουν ακόμη αναπτυχθεί ευρέως στην ιατρική.

Η μελλοντική εργασία πιθανώς να επικεντρωθεί στην ανάπτυξη αλγόριθμων για την καλύτερη αξιοποίηση ορισμένων από τα πλούσια σε πληροφορίες δεδομένα αλλά ακόμη μη δομημένα σε συστήματα ηλεκτρονικών μητρώων υγείας. Οι κλινικές παρατηρήσεις, για παράδειγμα, συχνά παραλείπονται ή διαγράφονται όταν πρόκειται για την ανάπτυξη συστημάτων πρόβλεψης. Σε αυτήν τη περίπτωση, τα μεγάλης κλίμακας αναδρομικά νευρωνικά δίκτυα, αρχίζουν να παρουσιάζουν εντυπωσιακά προγνωστικά αποτελέσματα συνδυάζοντας δομημένα και μη δομημένα δεδομένα σε έναν ημι-επιβλεπόμενο τρόπο ³³. Αυτός ο συνδυασμός δεδομένων τους επιτρέπει να μαθαίνουν από τις ευρύτερες πληθυσμιακές ομάδες σε πιο διαφορετικούς τύπους δεδομένων, αποδίδοντας καλύτερα από άλλες τεχνικές σε τομείς όπως η θνησιμότητα, η επανεισδοχή, η διάρκεια παραμονής και οι προβλέψεις διαγνώσεων.



Εικόνα 2. Ιατρική απεικόνιση.

Τα συστήματα Συνελικτικών Νευρωνικών Δικτύων μπορούν να εκπαιδευτούν σε μια ποικιλία ιατρικών απεικονίσεων, συμπεριλαμβανόμενων της ραδιολογίας, παθολογίας, δερματολογίας και οφθαλμολογίας. Οι πληροφορίες ρέουν από τα αριστερά στα δεξιά. Τα Συνελικτικά Νευρωνικά Δίκτυα λαμβάνουν εικόνες εισόδου και διαδοχικά τις μετατρέπουν, χρησιμοποιώντας απλές διαδικασίες όπως συνελικτικές, ομαδοποιημένες και πλήρως συνδεδεμένες στρώσεις σε επίπεδα διανύσματα. Τα στοιχεία του διανύσματος εξόδου αντιπροσωπεύουν τις πιθανότητες παρουσίας ασθένειας. Κατά τη διάρκεια της διαδικασίας εκπαίδευσης, οι εσωτερικές παράμετροι των επιπέδων δικτύου διαδοχικά προσαρμόζονται ούτως

ώστε να ³βελτιστοποιηθεί η ακρίβεια. Συνήθως, τα κάτω επίπεδα (αριστερά) μαθαίνουν απλές λειτουργίες εικόνας -άκρες και βασικά σχήματα-, τα οποία επηρεάζουν τις αναπαραστάσεις υψηλού επιπέδου (δεξιά). Οι εργασίες πρόβλεψης συμπεριλαμβάνουν τόσο την ταξινόμηση εικόνων (για παράδειγμα, καρκινικό versus καλοήθους) όσο και τον εντοπισμό και άλλων ιατρικών χαρακτηριστικών όπως οι όγκοι.

Ενισχυτική μάθηση

Η ενισχυτική μάθηση αφορά σε μια κατηγορία τεχνικών ειδικά σχεδιασμένων να εκπαιδεύουν υπολογιστικούς παράγοντες να αλληλοεπιδρούν επιτυχώς με το περιβάλλον τους, συνήθως για να επιτύχουν συγκεκριμένους στόχους. Αυτό το είδος μάθησης μπορεί να επιτευχθεί μέσω δοκιμής και σφάλματος, μέσω επίδειξης ή και υβριδικής προσέγγισης. Καθώς ένας παράγοντας αναλαμβάνει δράση μέσα στο περιβάλλον του, ένας επαναληπτικός βρόγχος ανατροφοδότησης απόδοσης και συνέπειας εκπαιδεύει τον παράγοντα να ολοκληρώσει στο βέλτιστο τους επικείμενους στόχους. Η εκμάθηση μέσω της επίδειξης ειδικού επιτυγχάνεται είτε με την εκμάθηση της πρόβλεψης των ενεργειών του ειδικού απευθείας μέσω της εποπτευόμενης μάθησης (π.χ. τεχνητή μάθηση) ή μέσω της εξαγωγής συμπεράσματος του στόχου του ειδικού (δηλ. αντίστροφη ενισχυτική μάθηση). Για να εκπαιδευτεί επιτυχώς ένας παράγοντας, είναι αποφασιστικής σημασίας να υπάρξει μια λειτουργία μοντέλου, η οποία να μπορεί να λαμβάνει ως είσοδο αισθητήρια σήματα που προέρχονται από το περιβάλλον και ως σημεία εξόδου τις επόμενες ενέργειες του παράγοντα. Η βαθιά ενισχυτική μάθηση, στην οποία ένα μοντέλο βαθιάς μάθησης εξυπηρετεί τον ρόλο του μοντέλου λειτουργίας, φαίνεται να είναι πολλά υποσχόμενη.

Ένας τομέας της υγειονομικής περίθαλψης, ο οποίος θα μπορούσε να ωφεληθεί από την βαθιά ενισχυτική μάθηση, αποτελεί η ρομποτική χειρουργική. Επί του παρόντος, η ρομποτική χειρουργική βασίζεται σε μεγάλο βαθμό σε έναν χειρουργό, ο οποίος καθοδηγεί τον ρομποτικό εξοπλισμό με τηλεχειριζόμενο τρόπο. Η βαθιά μάθηση μπορεί να ενισχύσει την ανθεκτικότητα και την προσαρμοστικότητα της ρομποτικής χειρουργικής χρησιμοποιώντας μοντέλα μηχανικής όρασης (π.χ. Συνελικτικά Νευρωνικά Δίκτυα), ούτως ώστε να μπορεί να διακρίνει χειρουργικά περιβάλλοντα και μεθόδους ενισχυτικής μάθησης, προκειμένου να μάθει παρατηρώντας τις φυσικές κινήσεις ενός χειρουργού ^{41,42}. Αυτές οι τεχνικές υποστηρίζουν την αυτοματοποίηση και την ταχύτητα των εξαιρετικά επαναλαμβανόμενων και ευαίσθητων στον χρόνο χειρουργικών εργασιών, όπως για παράδειγμα το χειρουργικό ράψιμο και οι χειρουργικοί κόμβοι

³ ΣτΜ3: Πρώτος περιέγραψε τους διαφορετικούς χειρουργικούς κόμπους τον 1ο αιώνα, ο Ηρακλής, αρχαίος Έλληνας φυσικός και ιατρός.

[ΣτΜ³] ⁷. Για παράδειγμα, οι τεχνικές μηχανικής όρασης (π.χ. τα συστήματα ΣΝΔ για την ανίχνευση και την κατάτμηση αντικειμένων καθώς και η στερεοσκοπική όραση) μπορούν να αναπαραστήσουν την εικόνα ενός ανοιχτού τραύματος χρησιμοποιώντας δεδομένα εικόνων. Επιπρόσθετα, ένα ράμμα ή η πορεία ενός χειρουργικού κόμβου λύνοντας το πρόβλημα της βελτιστοποίησης ροής, με στόχο την εύρεση της βέλτιστης πορείας, συνυπολογίζοντας εξωτερικούς παράγοντες, όπως οι αρθρώσεις και τυχόν εμπόδια ⁴³. Ομοίως, τα εκπαιδευμένα με εικόνες δεδομένων συστήματα ΑΝΔ, μπορούν αυτόνομα να μάθουν να δένουν χειρουργικούς κόμπους, μαθαίνοντας την ακολουθία γεγονότων και διαδικασιών, που στην παρούσα περίπτωση είναι οι φυσικές κινήσεις, όπως αυτές πραγματοποιούνται από τον χειρουργό ⁴⁴.


Αυτές οι τεχνικές είναι ιδιαίτερες επωφελείς για την εκτέλεση πλήρους αυτόνομης ρομποτικής χειρουργικής επέμβασης ή μερικώς επεμβατικής χειρουργικής επέμβασης. Ας ληφθεί υπόψιν, η σύγχρονη λαπαροσκοπική χειρουργική- στην οποία πολλές μικρές τομές χρησιμοποιούνται ως ένας τρόπος για να εισαχθεί ένας αριθμός εργαλείων στο σώμα, συμπεριλαμβανομένων κάμερας και χειρουργικών εργαλείων, τα οποία με τη σειρά τους οι χειρουργοί τηλεχειρίζονται. Η βαθιά μάθηση μέσω της μίμησης, το σύστημα αναδρομικού νευρωνικού δικτύου και οι αλγόριθμοι μεταφοράς τροχιάς μπορούν να αυτοματοποιήσουν πλήρως συγκεκριμένες τηλεχειριζόμενες εργασίες χειρισμού χειρουργικών διαδικασιών ⁷. Στο σύστημα μηχανικής μάθησης, για αυτοματοποίηση επαναλαμβανόμενων εργασιών ο χρόνος δράσης είναι πιο ζωτικός από ότι είναι σε χειρουργικές επεμβάσεις φυσιολογικών συνθηκών. Για παράδειγμα, με την Μηχανική Μάθηση μπορεί να χρειαστούν 3 λεπτά για να δεθεί ένας χειρουργικός κόμπος, αντί για 2 δευτερόλεπτα που θα διαρκούσε εάν συνέβαινε σε συνθήκες φυσιολογικής εγχείρησης.

Μια από τις βασικές προκλήσεις κατά τη διάρκεια μιας ημιαυτόνομης τηλεχειριζόμενης επέμβασης είναι να επιλεγθεί η σωστή θέση ενός εργαλείου αλλά και ο προσανατολισμός των γύρω περιοχών των χειρουργικών πεδίων. Εδώ, πρόσφατες τεχνικές ⁴⁵ όπως η κατάτμηση οργάνων ανάλογα με τα εικονοστοιχεία, έχουν αναπτυχθεί χρησιμοποιώντας μια εξελιγμένη U-Net αρχιτεκτονική Συνελκτικών Νευρωνικών Δικτύων (CNN ^{25,46}), κάτι το οποίο πλέον φαίνεται ως πολλά υποσχόμενο. Άλλη μια πρόκληση για την πρόοδο της βαθιάς μάθησης στον τομέα της ρομποτικής χειρουργικής είναι η συλλογή των δεδομένων. Η βαθιά μάθηση μέσω μίμησης απαιτεί μεγάλα σύνολα δεδομένων με πολλά παραδείγματα για κάθε χειρουργική ενέργεια. Δεδομένου ότι πολλές εγχειρήσεις διαφοροποιούνται μεταξύ τους σε ανεπαίσθητο βαθμό και είναι η καθεμία ξεχωριστή, καθίσταται δύσκολο το να συλλεχθούν αρκετά δεδομένα για πιο γενικού τύπου χειρουργικές επεμβάσεις. Επιπλέον, παραμένει δύσκολο για τα αυτόνομα συστήματα να προσαρμόζονται σε εντελώς άγνωστες και μη παρατηρήσιμες


καταστάσεις, οι οποίες είναι σε μεγάλο βαθμό ανόμοιες με ότι μέχρι τώρα συναντάται, για παράδειγμα απρόσμενα χειρουργικά ατυχήματα.

Γενικευμένη βαθιά μάθηση

Πέρα από τις εργασίες της μηχανικής όρασης (CV), της επεξεργασίας της φυσικής γλώσσας (NLP) και της ενισχυτικής μάθησης, η βαθιά μάθηση προσαρμόζεται σε πεδία, στα οποία η εισαγωγή δεδομένων (data entry) αποτελεί δουλειά λεπτού χειρισμού και απαιτεί εξειδικευμένη αντιμετώπιση. Για επεξηγηματικούς λόγους, σε αυτή την περίπτωση θεωρούμε την Γονιδιωματική, ένα παράδειγμα πεδίου, στο οποίο η βαθιά μάθηση έχει προσαρμοστεί πέρα από τις συμβατικές προσεγγίσεις (π.χ. βασιζόμενα στα Συνελκτικά Νευρωνικά Δίκτυα ή στα Αναδρομικά Νευρωνικά Δίκτυα), ούτως ώστε να δουλέψει με μοναδικές αναπαραστάσεις δεδομένων (πχ. μη απεικονιστικές και μη χρονικές).



ΕΙΚΟΝΑ 3. Κάνοντας προβλέψεις με τη χρήση του Συστήματος Ηλεκτρονικών Μητρώων Υγείας (EHR). Α) Μη δομημένα δεδομένα EHR. Τα ιατρικά αρχεία αποθηκεύονται σε ιδιοσυγκρασιακές δομές δεδομένων και μορφές έτσι ώστε τα μοντέλα που βασίζονται σε αρχείο ενός συγκεκριμένου νοσοκομείου να μην λειτουργούν απαραίτητα με δεδομένα από διαφορετικό νοσοκομείο. Β) Τυποποίηση δεδομένων. Αντιστοιχίζοντας δεδομένα από πολλούς ιστότοπους σε μία μορφή με βάση το FHIR (Πόροι Γρήγορης Διαλειτουργικότητας της Υγειονομικής Περίθαλψης), τα δεδομένα τυποποιούνται σε ομοιογενή μορφή. C) Αλληλουχία. Προσδιορίζοντας χρονικά την αλληλουχία όλων των δεδομένων σε ένα χρονοδιάγραμμα ασθενούς, τεχνικές βαθιάς μάθησης βάσει χρόνου μπορούν να εφαρμοστούν στο σύνολο των συνόλων δεδομένων EHR για την πραγματοποίηση προβλέψεων για μεμονωμένους ασθενείς.



ΕΙΚΟΝΑ 4. Η μηχανική μάθηση στην Γονιδιωματική. Α) Εισαγωγή δεδομένων. Τα γονιδιωματικά δεδομένα αποτελούνται από πειραματικές μετρήσεις από τις οποίες μπορούν να προβλεφθούν συγκεκριμένες ιδιότητες ή αποτελέσματα ενδιαφέροντος. Αυτά τα δεδομένα είναι συχνά διαφορετικά και μπορεί να περιλαμβάνουν αλληλουχία, γονιδιακή έκφραση και λειτουργικά δεδομένα καθώς και άλλες μορφές μοριακών δεδομένων. **Β) Παράδειγμα τανυστών δεδομένων.** Οι μη επεξεργασμένες πειραματικές μετρήσεις πρέπει να μετατραπούν σε μια μορφή κατάλληλη για κατανάλωση από αλγόριθμους βαθιάς μάθησης, οι οποίοι λαμβάνουν ως πολυδιάστατους τανυστές δεδομένων και σχετικές ετικέτες στόχου. **Γ) Βαθύ Νευρωνικό Δίκτυο (DNN).** Οι τανυστές με ετικέτα χρησιμοποιούνται για την εκπαίδευση των DNNs και την πρόβλεψη της ετικέτας από τον τανυστή δεδομένων εισόδου. **Δ) Βιοϊατρικές εφαρμογές.** Τα εκπαιδευμένα DNN μπορούν να χρησιμοποιηθούν σε βιοϊατρικές εφαρμογές, όπως στην πρόβλεψη ετικετών για προηγούμενως άορατους τανυστές δεδομένων ή στην εξέταση της σχέσης μεταξύ δεδομένων εισόδου και ετικετών εξόδου. Παραδείγματα εφαρμογών περιλαμβάνουν ερμηνεία πειραματικών δεδομένων (π.χ., συμπερασματικές αλληλουχίες DNA από την έξοδο ενός οργάνου προσδιορισμού αλληλουχιών ή συμπεράσματα των επιδράσεων των μεταλλάξεων DNA στο μάτισμα των γονιδίων) και μοριακά διαγνωστικά (π.χ., πρόβλεψη των επιδράσεων των γενετικών μεταλλάξεων στον κίνδυνο εμφάνισης νόσου ή στην απόκριση φαρμάκου), μεταξύ πολλών άλλων.

Οι σύγχρονες γονιδιωματικές τεχνικές συλλέγουν μεγάλη ποικιλία μετρήσεων από την αλληλουχία DNA ενός ατόμου ως και την ποσότητα διάφορων ειδών πρωτεϊνών, που εμπεριέχονται στο αίμα τους. Είναι πολλές οι ευκαιρίες βελτιστοποίησης των μεθόδων, που χρησιμοποιεί η βαθιά μάθηση για να αναλύσει τέτοιες μετρήσεις, οι οποίες με τη σειρά τους θα βοηθήσουν άμεσα τους ιατρούς να παρέχουν ακριβέστερες διαγνώσεις και θεραπείες. Ο τυπικός τρόπος να κατασκευαστεί ένα σύστημα βαθιάς μάθησης στη Γονιδιωματική συμπεριλαμβάνει

την λήψη μη επεξεργασμένων δεδομένων (π.χ. δεδομένα γονιδιακής έκφρασης), μετατρέποντας αυτά τα μη επεξεργασμένα δεδομένα σε τανυστές εισαγωγής δεδομένων, και τροφοδοτώντας αυτούς τους τανυστές μέσω των νευρωνικών δικτύων, τα οποία έπειτα θα τροφοδοτήσουν συγκεκριμένες βιοϊατρικές εφαρμογές (εικ.4).

Ένα σύνολο δυνατοτήτων επικεντρώνεται σε μελέτες συσχέτισης σε ολόκληρο το γονιδίωμα (GWA) - μεγάλες μελέτες περιπτώσεων που επιδιώκουν να ανακαλύψουν αιτιώδεις γονιδιακές μεταλλάξεις, οι οποίες επηρεάζουν συγκεκριμένα χαρακτηριστικά. Η ανάλυση των μελετών GWA απαιτεί αλγόριθμους, που κλιμακώνονται σε πολύ μεγάλες ομάδες ασθενών και που ασχολούνται με λανθάνουσες συγχύσεις. Στο κοντινό μέλλον, μοντέλα τα οποία αφομοιώνουν εξωτερικούς τρόπους και πρόσθετες πηγές βιολογικών δεδομένων σε μελέτες GWA -για παράδειγμα, ιατρικές απεικονίσεις ή μετρήσεις ματίσματος και άλλοι ενδιάμεσοι μοριακοί φαινότυποι- μπορεί να επωφεληθούν από την βαθιά μάθηση ως προς την ακριβέστερη αναγνώριση ασθένειας, η οποία σχετίζεται με αιτιώδεις μεταλλάξεις ⁵⁰.

Η κατανόηση της γενετικής ασθένειας επιτρέπει στους ιατρούς να προτείνουν θεραπείες και να παρέχουν ακριβέστερες διαγνώσεις. Η πιο βασική πρόκληση για τους ιατρούς είναι να προσδιορίσουν εάν οι νέες μεταβολές στο γονιδίωμα ενός ασθενούς είναι ιατρικώς σχετικές. Εν μέρει, αυτή η απόφαση βασίζεται στην πρόβλεψη της παθογένειας των μεταλλάξεων: μια εργασία που ήδη χρησιμοποιεί χαρακτηριστικά όπως η δομή των πρωτεϊνών και η εξελικτική συντήρηση για την εκπαίδευση των αλγόριθμων ⁵¹. Δεδομένης της μεγαλύτερης δύναμης και της ικανότητάς τους να ενσωματώνουν αποτελεσματικά διαφορετικούς τύπους δεδομένων, οι τεχνικές βαθιάς μάθησης είναι πιθανό να παρέχουν πιο ακριβείς προβλέψεις παθογένειας από ό, τι είναι δυνατόν σήμερα ⁵².

Η μηχανική μάθηση παίζει επίσης ρόλο στην πρόβλεψη φαινοτύπων από γενετικά δεδομένα, συμπεριλαμβανομένων σύνθετων χαρακτηριστικών όπως το ύψος καθώς και ο κίνδυνος εκδήλωσης ασθένειας. Η βαθιά μάθηση μπορεί να βελτιώσει περαιτέρω τέτοια μοντέλα ενσωματώνοντας επιπλέον τρόπους όπως ιατρικές απεικονίσεις, κλινικό ιστορικό και δεδομένα φορητής συσκευής ⁵³. Μία ιδιαίτερα ελπιδοφόρα προσέγγιση στην πρόβλεψη φαινοτύπου είναι η πρόβλεψη ενδιάμεσων μοριακών φαινοτύπων - π.χ. γονιδιακής έκφρασης ή ματίσματος γονιδίων - που στη συνέχεια τροφοδοτούν μεταγενέστερους προγνωστικούς παράγοντες ασθένειας ⁵⁴. Οι ενδιάμεσες μοριακές καταστάσεις μπορούν να προβλέψουν ευκολότερα από τα ανθρώπινα γνωρίσματα λόγω των μεγαλύτερων, πιο κοντινών σημάτων και πιο εκτεταμένων δεδομένων εκπαίδευσης. Αυτά τα δύο χαρακτηριστικά καθιστούν το πρόβλημα κατάλληλο για τη βαθιά μάθηση, η οποία έχει δείξει επιτυχία στην πρόβλεψη ματίσματος ⁵⁵ και του παράγοντα μεταγραφής σύνδεσης ⁵⁶.

Τα γονιδιωματικά δεδομένα μπορούν επίσης να χρησιμεύσουν άμεσα ως βιοδείκτες για την έναρξη και την εξέλιξη της νόσου. Για παράδειγμα, το αίμα περιέχει μικρά τμήματα DNA χωρίς κύτταρα που απελευθερώνονται από κύτταρα, τα οποία βρίσκονται οπουδήποτε στο σώμα. Αυτά τα τμήματα είναι μη επεμβατικοί δείκτες απόρριψης οργάνων (δηλαδή, το ανοσοποιητικό σύστημα που προσβάλλει κύτταρα μοσχεύματος ⁵⁷), βακτηριακή λοίμωξη ⁵⁸ και καρκίνος πρώιμου σταδίου ⁵⁹. Το ακυτταρικό DNA χρησιμοποιείται επιτυχώς σε προγεννητικά διαγνωστικά: το εμβρυϊκό DNA που υπάρχει στο αίμα της μητέρας υποδηλώνει χρωμοσωμικές ανωμαλίες και μπορεί να αποκαλύψει ολόκληρο το γονιδίωμα του εμβρύου⁶⁰. Τα δεδομένα βιοδείκτη είναι συχνά ανομοιόμορφα και απαιτούν εξελιγμένη ανάλυση (π.χ., για να προσδιοριστεί εάν το ακυτταρικό DNA είναι ενδεικτικό του καρκίνου). Τα συστήματα βαθιάς μάθησης μπορούν να βελτιώσουν την ποιότητα των δοκιμών των βιοδεικτών που στοχεύουν αλληλουχίες DNA ⁶¹, μεθυλίωση ⁶², γονιδιακή έκφραση ⁶³, προφίλ χρωματινίνης ⁶⁴ και πολλές άλλες μετρήσεις.

Γ. ΣΧΟΛΙΑΣΜΟΣ

Εισαγωγή

Το παραπάνω κείμενο αφετηρίας αποτελεί ένα επιστημονικό άρθρο δημοσιευμένο σε ηλεκτρονικό περιοδικό, με το ενδιαφέρον του στραμμένο στις επιστήμες της ζωής. Το κείμενο επικεντρώνεται στις τεχνικές της Βαθιάς Μάθησης για την υγειονομική περίθαλψη, εστιάζοντας τμηματικά σε τεχνικές όπως η υπολογιστική όραση, η ρομποτική χειρουργική, η επεξεργασία της φυσικής γλώσσας και άλλες γενικευμένες μέθοδοι.

Η αλματώδης ανάπτυξη της γονιδιωματικής και των υπόλοιπων κλάδων των επιστημών της ζωής έχει σαν αποτέλεσμα την αυξανόμενη ανάγκη παραγωγής νέων όρων για την αποτύπωση των νέων επιστημονικών δεδομένων. Εξίσου σημαντική καθίσταται και η μεταφραστική διαδικασία, κυρίως αγγλικών όρων, με σκοπό την παρακολούθηση των εξελίξεων σε παγκόσμιο επίπεδο και την προσαρμογή και εισαγωγή των νέων δεδομένων στην ελληνική πραγματικότητα.

(Κεραμίδας 2015: 150)

Προκειμένου η παρούσα πτυχιακή εργασία να πραγματοποιηθεί προσέγγισα το έργο αυτό ως ένας εν δυνάμει επαγγελματίας μεταφραστής. Πράγμα που σημαίνει πως αξιοποίησα όλους τους πόρους, που θα μπορούσαν να μου φανούν χρήσιμοι. Ένας μεταφραστής δεν μπορεί να αρνηθεί την χρησιμότητα των ηλεκτρονικών μεταφραστικών εργαλείων. Συγκεκριμένα, χρησιμοποίησα το λεγόμενο Memsorce¹, ένα εργαλείο το οποίο από κοινού με το SmartCat² αποτέλεσαν πολύτιμους αρωγούς στην εκπόνηση μεταφραστικών εργασιών μεγάλης έκτασης κατά την σταδιοδρομία μου στο Πανεπιστήμιο.

¹ Πηγή: <https://www.memsource.com/>

² Πηγή: <https://www.smartcat.com/>

1. Η περίπτωση των επιστημονικών κειμένων

A. Ζητήματα ορολογίας και Απώλεια θεματικού πεδίου

Η μεταφραστική διαδικασία κειμένων με ειδική ορολογία στον τομέα της γονιδιωματικής και της βιοτεχνολογίας, όπως αποτελεί και η περίπτωση του παρόντος κειμένου «αποτελεί μια εξαιρετικά επίπονη και χρονοβόρα διαδικασία» όπως αναφέρει και ο Κεραμίδας (2015: 150). Στα ειδικά κείμενα, ανάλογα βέβαια και με τον επικοινωνιακό σκοπό κάθε φορά, ο μεταφραστής κάνει το λεγόμενο «ράβε ξήλωνε», με σκοπό το μετάφρασμά του να πληροί όλες τις προδιαγραφές και να εμπεριέχει όλες τις πληροφορίες που απαιτούνται, χωρίς να υστερεί σε ουσία ή να υπερτερεί σε γνώση. Επιπροσθέτως, ως γνωστόν η ειδική γλώσσα δεν είναι πάντοτε κατανοητή από όλους και όλες οι πληροφορίες πάντα χρήσιμες σε όλους (ανάλογα σε ποιόν απευθύνεται το κείμενο. Βλ. Μεταφραστική εντολή). Όσες αλλαγές έγιναν στο συγκεκριμένο μετάφρασμα με βάση το πρωτότυπο κείμενο θα αναλυθούν παρακάτω (βλ. μεταφραστικά προβλήματα). Προτού όμως προχωρήσουμε στην ανάλυση της μεταφραστικής διαδικασίας και τα απαραίτητα βήματα, που ακολουθούνται για την εκπόνηση και περάτωση ενός τέτοιου εγχειρήματος, θα αναφερθούμε πρώτα στο γιατί είναι τόσο «επίπονα» τα ειδικά κείμενα και πόσο μάλλον αυτά, τα οποία απαντώνται στον τομέα των επιστημών της ζωής.

Οι τομείς αυτοί έχουν γνωρίσει αλματώδη ανάπτυξη τα τελευταία χρόνια. Οι καινοτόμες θεραπείες και οι πρωτοποριακές μέθοδοι αναγνώρισης και καταπολέμησης ασθενειών με τη βοήθεια της τεχνολογίας, καθιστούν τον εν λόγω τομέα, επιστήμη του μέλλοντος. Στο άκουσμα των λέξεων «καινοτόμος» και «πρωτοποριακός» η πρώτη σκέψη είναι: όγκος νέων όρων, που «ψάχνουν» τη δική τους θέση στα επιστημονικά γλωσσάρια.

Οι νέες πρακτικές και «νεοσύστατοι» τομείς της Ιατρικής όπως η Γονιδιωματική, φέρουν και γλωσσικά επακόλουθα. Η ανάπτυξη λοιπόν των γλωσσών, των διαλέκτων και των ιδιωτισμών οδήγησε αναμφισβήτητα στην ανάγκη δημιουργίας μιας «lingua franca», μιας κοινής γλώσσας. Η γλώσσα αυτή θα αποτελέσει το κυριότερο εργαλείο επικοινωνίας ανάμεσα σε τόσες διαφορετικές

γλώσσες και θα γεφύρωνε το χάσμα επικοινωνίας. «Λαμβάνει το προβάδισμα έναντι άλλων γλωσσών οι οποίες αδυνατούν να ακολουθήσουν κατά πόδας την γλωσσική ανάπτυξή της, με συνέπεια να υστερούν σημαντικά σε διάφορους τομείς. Αυτό συμβαίνει επειδή, σύμφωνα με τους Lauren et al. καμία γλώσσα δεν καλύπτει όλα τα δυνατά θεματικά πεδία.» (Κεραμίδας 2015: 76). Συνεπώς, ερχόμαστε στο ζήτημα της απώλειας του θεματικού πεδίου (domain loss³). Αρχικά, ως «θεματικό πεδίο μπορεί να νοηθεί ένας επιστημονικός τομέας ή γενικότερα ένα πεδίο εφαρμοσμένης ή και θεωρητικής γνώσης, ο οποίος για τις επικοινωνιακές του ανάγκες κάνει χρήση ειδικής ορολογίας/γλώσσας» (Κεραμίδας 2015: 77). Πώς προκύπτει όμως η απώλεια θεματικού πεδίου; Προκύπτει πάντα όταν μια γλωσσική κοινότητα δεν εξελίσσει τα μέσα της, ούτως ώστε να καταφέρει να διασφαλίσει την επικοινωνία, που απαιτείται σε διάφορους επιστημονικούς τομείς. Συνεπώς, απώλεια θεματικού πεδίου (Domain Loss), είναι το φαινόμενο κατά το οποίο μια γλώσσα δεν καταφέρνει να καλύψει γλωσσικά διάφορους τομείς για παράδειγμα τους επιστημονικούς και η «lingua franca» έρχεται να καλύψει τα κενά της.

«Lingua franca» του σύγχρονου Δυτικού πολιτισμού θεωρείται η Αγγλική γλώσσα. Ανάμεσα σε άλλες γλώσσες που έχουν υποστεί τις συνέπειες του «γλωσσικού ιμπεριαλισμού» (Κεραμίδας 2015: 79), βρίσκεται και η Ελληνική. Παρόλο που πληθώρα λέξεων και προσφυμάτων που χρησιμοποιούνται σε τομείς όπως η Ιατρική, πλέον λόγω της απώλειας του θεματικού πεδίου και την αδυναμία της γλώσσας να συμβαδίζει με τους ρυθμούς της παγκόσμιας επιστημονικής κοινότητας, ο μεταφραστής έρχεται αντιμέτωπος με δυσκολίες όπως η ορολογική αβεβαιότητα.

Σκεπτόμενοι όλα τα προαναφερθέντα γεννάται ένα πολύ βασικό ερώτημα: Γιατί να προβεί κάποιος σε μετάφραση; Σύμφωνα με το λειτουργισμό, μία από τις μεθοδολογίες της μετάφρασης, η μετάφραση γίνεται πάντα για να καλύψει έναν συγκεκριμένο σκοπό. Η λειτουργική θεωρία στη μετάφραση παραπέμπει στη θεωρία του σκοπού, σύμφωνα με την οποία «στη μεταφραστική πράξη η βασική αρχή που καθορίζει κάθε μεταφραστική διαδικασία είναι ο στόχος (Skopos) της συνολικής μεταφραστικής δράσης» (Nord 2014: 70). Έχοντας αυτά ο μεταφραστής

³ Domain Loss: Η λέξη domain προτάθηκε από τον Gerhard Schmidt-Rohr το 1933.

διευκολύνεται σε κάποια πράγματα. Γνωρίζει εξ αρχής ποιες είναι οι απαραίτητες πληροφορίες, που θα πρέπει να λάβει, κατά πόσο θα τις κρατήσει ως έχουν ή θα τις απαλείψει εντελώς. Γεγονός που φυσικά καθιστά τον ίδιο ικανό να φέρει εις πέρας το έργο και να “γεννήσει” ένα μετάφρασμα, το οποίο θα είναι απολύτως δόκιμο και θα μπορέσει να σταθεί αντάξιο των προσδοκιών του κοινού του. Για να πετύχει κάτι τέτοιο ο μεταφραστής χρειάζεται να πληροί δύο βασικά κριτήρια:

- Το πρώτο που χρειάζεται είναι: οι γνώσεις, οι οποίες δεν αφορούν μόνο σε γλωσσικό επίπεδο. Στα ειδικά κείμενα ο μεταφραστής οφείλει να έχει και γνώσεις πάνω στο γνωστικό αντικείμενο που καλείται να μεταφράσει, ειδάλλως το μετάφρασμα μπορεί να μην είναι σωστό. Δηλαδή να έχει “γνώση πραγματολογικού ή ρητορικού χαρακτήρα” (Κεντρωτής 1996: 50-51).
- Ως προς το δεύτερο, ο στόχος κάθε μετάφρασης, ο επικοινωνιακός δηλαδή σκοπός της, ορίζεται από τις εκάστοτε “μεταφραστικές οδηγίες” (Nord 2014: 137- 142). Άλλωστε “ο σκοπός αγιάζει τα μέσα”, ο σκοπός δηλαδή καθορίζει τον τρόπο με τον οποίο θα γίνει η μετάφραση.

2. Μεταφραστική διαδικασία- Μεθοδολογία επιστημονικών κειμένων

Η ορολογία που θα χρησιμοποιηθεί στο κείμενο αφίξεως θα πρέπει να αντιμετωπισθεί με ιδιαίτερη προσοχή και ενδιαφέρον από τον μεταφραστή, προκειμένου το κείμενο αφίξεως να ανταποκρίνεται γλωσσικά στις απαιτήσεις του σύγχρονου επιστημονικού κόσμου και παράλληλα να σέβεται τις πληροφορίες και την ουσία του κειμένου αφετηρίας. Ως εκ τούτου, ο μεταφραστής οφείλει να διεξάγει διαρκή και λεπτομερή έρευνα σε διάφορες πηγές και να διατηρεί αμείωτο το ενδιαφέρον του ως προς το θέμα. Όσον αφορά στη μετάφραση κειμένων γονιδιωματικής και βιοτεχνολογίας είναι απαραίτητο ο μεταφραστής να ακολουθήσει τα παρακάτω στάδια όπως παρουσιάζονται από τον Κεραμίδα (2015: 151-152):

- Πραγματολογική έρευνα και μελέτη επί του θέματος που πραγματεύεται το προς μετάφραση κείμενο.
- Σύνταξη γλωσσαρίου που προκύπτει από την αποδελτίωση όρων του κειμένου.
- Έρευνα σε έντυπες και ηλεκτρονικές πηγές για την απόδοση των αποδελτιωμένων όρων στα ελληνικά.
- Τεκμηρίωση των προτεινόμενων αποδόσεων.
- Αντιμετώπιση ασαφούς-προβληματικής ορολογίας (πολυλεκτική, πολλαπλή ορολογία)
- Πρώτη απόπειρα-πρόταση απόδοσης όρων στην ελληνική.
- Τελική αποσαφήνιση προβληματικών ή δυσνόητων σημείων.
- Πλήρης κατανόηση και μετάφραση του κειμένου.

Σε ένα άτομο που η ενασχόληση του δεν είναι η μετάφραση, όλα αυτά τα βήματα φαντάζουν πολύ χρονοβόρα και επίπονα για το μυαλό. Προσωπικώς, δε θα τον διέψευδα. Είναι χρονοβόρο και επίπονο. Εάν όμως παραλειφθούν τα ανωτέρω στάδια, τότε το κείμενο αφίξεως είναι πολύ πιθανό να μην ανταποκρίνεται στη σύγχρονη επιστημονική πραγματικότητα, κάτι που τα καθιστά «αναγκαίο κακό». Προκειμένου να κατανοηθεί το παρόν κείμενο αφετηρίας, χρειάστηκε αρκετή μελέτη του αντικειμένου της Βαθιάς Μάθησης. Μεγάλη δυσκολία κατανόησης αποτέλεσαν οι μακροπερίοδοι λόγοι, τα αρκτικόλεξα, οι πολυλεκτικοί όροι και φυσικά οι όροι εκείνοι, που πραγματεύονται πολύ καινοτόμα ζητήματα όπως η Βαθιά Μάθηση, η εισροή δεδομένων, που αποσκοπεί στην εκπαίδευση ρομπότ (ρομποτική χειρουργική). Προχωρώντας παρακάτω με τη μεταφραστική διαδικασία, δε θα έλειπε η σύνταξη γλωσσαρίου. Ένα εργαλείο πέραν του χρήσιμου. Προκύπτει ένα λεξικό από το μηδέν, το οποίο έχει βασιστεί σε έρευνες ηλεκτρονικών λεξικών ειδικής ορολογίας, διατριβών φοιτητών πανεπιστημίων και διδακτόρων αλλά και έντυπων λεξικών ιατρικής. Το γλωσσάρι φέρει τον αμετάφραστο όρο, την απόδοση του στα ελληνικά, την πηγή απόδοσης και τέλος το συγκεκριμένο, μέσα στο οποίο συναντάται και τεκμηριώνεται η απόδοση του όρου. Συνεπώς, με την ολοκλήρωση των παραπάνω, φτάνουμε στις πρώτες απόπειρες μετάφρασης όρων, που διέπονται από διάφορα μεταφραστικά προβλήματα, τα οποία με τα κατάλληλα εργαλεία και τις γνώσεις,

ξεπερνιούνται και οδηγούμαστε στα τελικά στάδια, αυτά της αποσαφήνισης των όρων και της τελικής μετάφρασης του κειμένου αφετηρίας.

3. Μεταφραστική εντολή

Σε καταστάσεις, στις οποίες οι άνθρωποι, οι οποίοι δεν μπορούν να επικοινωνήσουν λόγω γλωσσικών φραγμών, επιτυγχάνεται η επικοινωνία τους με τη βοήθεια του διαμεσολαβητή. Ο ρόλος αυτός μπορεί να ανήκει αναλόγως τη κατάσταση, σε έναν επαγγελματία μεταφραστή ή μη εκπαιδευόμενο μεταφραστή. Πριν αναφερθούμε στους παράγοντες της συγκεκριμένης μεταφραστικής διαδικασίας, πρωτίστως θα αναφέρουμε το σενάριο, το οποίο κατευθύνει τις μεταφραστικές οδηγίες, δεδομένου ότι ένα κείμενο τέτοιου είδους θα μπορούσε να χρησιμοποιηθεί με διαφορετικούς τρόπους.

Μεταφραστικό σενάριο:

Ένας Έλληνας μεταπτυχιακός φοιτητής σε αγγλόφωνο πανεπιστήμιο ενδιαφέρεται να συγγράψει ένα άρθρο για την Βαθιά Μάθηση και τις τεχνικές της όπως εφαρμόζονται στην υγειονομική περίθαλψη. Το άρθρο αυτό θα δημοσιευθεί ηλεκτρονικά στην ιστοσελίδα Nature Medicine⁶, ένα ηλεκτρονικό ιατρικό περιοδικό. Ο μεταπτυχιακός φοιτητής είχε την ιδέα της δημιουργίας ενός τέτοιου άρθρου λόγω του ενδιαφέροντος, που προήλθε από έναν ελληνόφωνο προπτυχιακό φοιτητή της Ιατρικής στην Αθήνα, ο οποίος ενδιαφέρεται να ακολουθήσει τον συγκεκριμένο τομέα, της Βαθιάς Μάθησης. Το αίτημα του φοιτητή ικανοποιήθηκε από τους αρμόδιους της ιστοσελίδας, μιας και έκριναν πως η δημοσίευση και μετάφραση ενός τέτοιου άρθρου θα είχε μεγάλη απήχηση στους ελληνόφωνους φοιτητές του εξωτερικού αλλά και της Ελλάδας. Λαμβάνοντας το αγγλόφωνο άρθρο και τις σχετικές μεταφραστικές οδηγίες, μετέφρασα το κείμενο αφετηρίας από τα αγγλικά στα ελληνικά και στη συνέχεια με βάση αυτά θα ανασυνταχθεί ένα άρθρο από τον μεταπτυχιακό φοιτητή.

⁶ <https://www.nature.com/nm/>

Σύμφωνα με το μοντέλο της μεταφραστικής δράσης της Holz-Mänttari (1984) η μετάφραση είναι μια επικοινωνιακή και διαπροσωπική διαδικασία, στην οποία συμμετέχουν διάφοροι παράγοντες. Πιο αναλυτικά και βάσει του σεναρίου και κειμένου μου έχουμε:

- Ο **εμπνευστής** της μετάφρασης, “δηλαδή το πρόσωπο (φυσικό ή νομικό) που χρειάζεται τη μετάφραση, δίνει το έναυσμα για την έναρξη της μεταφραστικής διαδικασίας και ορίζει το σκοπό για τον οποίο χρειάζεται το κείμενο υποδοχής” (Κελάνδριας 2007: 31-32, 2016: 102). Στη δική μου περίπτωση είναι ένας Έλληνας φοιτητής Ιατρικής στην Αθήνα που ενδιαφέρεται να μάθει περισσότερα πράγματα για την Βαθιά Μάθηση και τις τεχνικές της.
- Ο **αναθέτων** τη μετάφραση ή εντολέας, “ο οποίος αναθέτει την παραγωγή του κειμένου αφετηρίας στο μεταφραστή για ένα συγκεκριμένο σκοπό και παραλήπτη” (Κελάνδριας 2016: 102). Ο εντολέας στη παρούσα περίπτωση είναι οι αρμόδιοι της ιστοσελίδας που έκριναν αναγκαίο να δημοσιευθεί ένα τόσο ειδικό άρθρο.
- Ο **δημιουργός του κειμένου αφετηρίας**, το οποίο: «συνιστά τη βάση της μεταφραστικής δράσης ανεξάρτητα από τα κίνητρα και τους λόγους που οδήγησαν στη δημιουργία του και από το εάν υπάρχει ταύτιση λόγων και κινήτρων μεταξύ κειμένου αφετηρίας και κειμένου υποδοχής. Ενίοτε, η δημιουργία του κειμένου αφετηρίας δεν γίνεται με σκοπό τη μετάφρασή του, η οποία αποφασίζεται αργότερα. Σε αυτή την περίπτωση, ο δημιουργός του κειμένου αφετηρίας ενδέχεται να μην συμμετέχει άμεσα στη μεταφραστική διαδικασία». (Κελάνδριας 2016: 102-3). Δημιουργός του κειμένου που μετέφρασα είναι το Nature Medicine. Συγκεκριμένα, το κείμενο που μετέφρασα αφορά στη Βαθιά Μάθηση και τις τεχνικές της, όπως εφαρμόζονται στην υγειονομική περίθαλψη.

- Ο **μεταφραστής** “ως καθοριστικός παράγοντας της μεταφραστικής διαδικασίας” (Κελάνδριας 2016: 103), δηλαδή εγώ.
- Ο **χρήστης του κειμένου υποδοχής**, “δηλαδή το φυσικό ή νομικό πρόσωπο που θα χρησιμοποιήσει το μετάφρασμα” (Κελάνδριας 2016: 104). Ο μεταπτυχιακός φοιτητής που ανέλαβε να ασχοληθεί με την συγγραφή του άρθρου.
- Ο **δέκτης του κειμένου υποδοχής**, “δηλαδή ο τελικός παραλήπτης του κειμένου αφετηρίας, αυτός στον οποίο απευθύνεται το κειμένου αφετηρίας (ενίοτε ο χρήστης και ο δέκτης του κειμένου υποδοχής ταυτίζονται)” (Κελάνδριας 2016: 104). Δέκτης του κειμένου αφετηρίας και κατ’ επέκταση υποδοχής είναι ο προπτυχιακός φοιτητής για τον οποίο προορίζεται η μετάφραση.

Στη συνέχεια, θα ασχοληθούμε πιο αναλυτικά με το μετάφρασμα. Αρχικά πρέπει να προσδιορίσουμε τον κειμενικό του τύπο. Τα κείμενα χωρίζονται, ανάλογα με τη λειτουργία της γλώσσας (Reiß 1971: 33), σε:

- Πληροφοριακά κείμενα που αποσκοπούν στην πληροφόρηση του αναγνώστη σχετικά με αντικείμενα και φαινόμενα του πραγματικού κόσμου. Η επιλογή των γλωσσικών και υφολογικών τύπων γίνεται με βάση τη συγκεκριμένη λειτουργία. Ο μεταφραστής θα πρέπει να προσπαθήσει να αποδώσει το περιεχόμενο του κειμένου αφετηρίας με τρόπο σωστό και ολοκληρωμένο, με καθοδηγητή, βέβαια, τις κυρίαρχες νόρμες της γλώσσας και του πολιτισμού αφίξεως. (Nord 2014: 91-92).
- Εκφραστικά κείμενα που αποσκοπούν στην επίκληση συναισθημάτων. Σύμφωνα με τη Nord (2014: 92), «η άσκηση, δηλαδή, αισθητικής επίδρασης στον αναγνώστη έρχεται στο προσκήνιο και γίνεται το κύριο μέλημα τόσο του συγγραφέα όσο και, κατ’ επέκταση, του μεταφραστή».

- Τα κλητικά κείμενα, που έχουν ως στόχο να συμβουλέψουν ή και να πείσουν το κοινό-στόχο για κάτι συγκεκριμένο. «Τα πάντα είναι σχετικά: η πρόκληση της ίδιας –στο πλαίσιο του δυνατού– αντίδρασης από το κοινό είναι αυτή που υπαγορεύει τον τρόπο μετάφρασης, σε σημείο μάλιστα που ενδέχεται να κριθεί αναγκαία η αλλαγή του περιεχομένου ή των υφολογικών χαρακτηριστικών του κειμένου αφετηρίας». (Nord 2014: 92).

Ανάλογα, λοιπόν, με την εκάστοτε κειμενική λειτουργία (αναφορική, εκφραστική, κλητική, φατική), που επιζητά να δώσει ο συγγραφέας του κειμένου αφετηρίας ή ο μεταφραστής του κειμένου αφίξεως, το κείμενο θα έχει και τον ανάλογο τύπο. Το πρωτότυπο αγγλικό κείμενο έχει πληροφοριακό χαρακτήρα, δεδομένου ότι αφορά σε εργαστηριακά πειράματα, δεδομένα πληροφοριακών συστημάτων και ασχολείται με το πεδίο της Γονιδιωματικής. Συνεπώς, το μετάφρασμα μου έχει και αυτό πληροφοριακό χαρακτήρα. Ας επισημανθεί όμως, ότι παρόλο τον πληροφοριακό χαρακτήρα, το κείμενο εξυπηρετεί επίσης και μια κατευθυντήρια λειτουργία όπως επίσης και διδακτική. Αυτά διότι, δεν έχει σκοπό μόνο να ενημερώσει, αλλά διεισδύει βαθύτερα και αποσκοπεί επίσης στο να δώσει οδηγίες χρήσης εργαλείων και μηχανημάτων. Συν τοις άλλοις, ο διδακτικός χαρακτήρας του κειμένου φαίνεται από το ότι εξηγεί λεπτομερώς για το πως η εκπαίδευση στη Βαθιά Μάθηση θα επιτευχθεί ευκολότερα και με ποιες τεχνικές θα γίνει αυτό. Παράλληλα, στο μετάφρασμα συναντά κανείς ΣτΜ, πράγμα που μαρτυρά πως δεν πρόκειται για ένα κείμενο άνευ διδακτικού σκοπού.

Μεταφραστικές οδηγίες:

Οι μεταφραστικές οδηγίες αφορούν το σύνολο των κατευθυντήριων γραμμών που δίδονται στον μεταφραστή από τον αναθέτη και είναι οι εξής (Κελάνδριας 2016: 145-149) :

- Λειτουργίες κειμένων αφετηρίας και υποδοχής: Πληροφοριακή λειτουργία με διακρίσεις σε διδακτική και κατευθυντήρια.
- Χρήστες και δέκτες του κειμένου υποδοχής: Ο χρήστης της μετάφρασης είναι ο ίδιος με τον δέκτη της μετάφρασης, δεδομένου ότι η μετάφραση σαν έργο προορίζεται για εκείνον (τον μεταπτυχιακό φοιτητή).
- Χρόνος και τόπος κυκλοφορίας του κειμένου υποδοχής: Εντός του 2019
- Μέσο μετάδοσης μηνύματος: Δημοσίευση σε ιατρικό περιοδικό/ ιστοσελίδα
- Κίνητρο για τη δημιουργία του κειμένου υποδοχής: Πληροφόρηση φοιτητών που ενδιαφέρονται για τον τομέα της Βαθιάς Μάθησης.

Μεταφραστικά Προβλήματα:

«Τα μεταφραστικά προβλήματα είναι αντικειμενικά ή τουλάχιστον διωποκειμενικά. Δεν θα πρέπει να ταυτίζονται με τις μεταφραστικές δυσκολίες, τις υποκειμενικές, δηλαδή, δυσκολίες που συναντά ένας συγκεκριμένος μεταφραστής ή εκπαιδευόμενος κατά τη μεταφραστική διαδικασία λόγω ανεπαρκών γλωσσικών, πολιτισμικών ή μεταφραστικών δεξιοτήτων ή λόγω έλλειψης σωστής τεκμηρίωσης. Τα μεταφραστικά προβλήματα παραμένουν πάντα προβλήματα, ακόμη και όταν ένας μεταφραστής έχει μάθει πώς να τα επιλύει γρήγορα και αποτελεσματικά.»
(Nord 2014: 145)

Προχωρώντας θα ασχοληθούμε με πιο πρακτικά ζητήματα: Τα μεταφραστικά προβλήματα, που συνάντησα καθώς δούλευα με το κείμενο αφετηρίας. Μεταφραστικά προβλήματα μπορεί να προκύψουν από την έννοια των λέξεων, τη σύνταξη, ακόμη και από τα πολιτισμικά στοιχεία των δυο γλωσσών. Αναλυτικότερα, η κατηγοριοποίηση των μεταφραστικών προβλημάτων με βάση την προσανατολισμένη στη μετάφραση κειμενική ανάλυση της Nord (2001: 59-66) έχει ως εξής:

Πραγματολογικά προβλήματα:

«Πραγματολογικά μεταφραστικά προβλήματα:

Τα πραγματολογικά μεταφραστικά προβλήματα ανακύπτουν από τις διαφορές των περιστάσεων αυτών και μπορούν να εντοπιστούν με τη σύγκριση των εξωκειμενικών παραγόντων (πομπός, δέκτης, μέσο, χρόνος, χώρος, κίνητρο, κειμενική λειτουργία) [...] πραγματολογικά μεταφραστικά προβλήματα υπάρχουν σε κάθε μεταφραστική εργασία, είναι γενικεύσιμα ανεξάρτητα από τις γλώσσες και τους πολιτισμούς που εμπλέκονται ή την κατεύθυνση της μεταφραστικής διαδικασίας (από ή προς τη μητρική γλώσσα). Συνεπώς, κρίνονται ως τα σημαντικότερα προβλήματα που πρέπει να αντιμετωπιστούν στα αρχικά στάδια της εκπαίδευσης των μεταφραστών.»

(Nord 2014: 148)

Τα πραγματολογικά προβλήματα που συνάντησα ήταν διαφόρων ειδών. Παρακάτω θα γίνουν ακριβείς αναφορές με παραδείγματα από το πρωτότυπο κείμενο και το μετάφρασμα.

- ✓ Η συχνή χρήση **του μακροπερίοδου λόγου**. Σε όλη την έκταση του κειμένου συναντάται μεγάλες προτάσεις με περίπλοκο συντακτικό.

Πρωτότυπο κείμενο: «Remarkably, deep-learning models have achieved physician-level accuracy at a broad variety of diagnostic tasks, including identifying moles from melanomas, diabetic retinopathy, cardiovascular risk, and referrals from fundus and optical coherence tomography (OCT) images of the eye, breast lesion detection in mammograms, and spinal analysis with magnetic resonance imaging.»

Μετάφρασμα: «Παραδόξως, τα μοντέλα βαθιάς μάθησης έχουν κατορθώσει να φτάσουν σε ακρίβεια το επίπεδο των ιατρών σε ένα ευρύ φάσμα διαγνωστικών περιπτώσεων, συμπεριλαμβάνοντας την αναγνώριση στη διαφορά μιας ελίας από το μελάνωμα ^{9 10}, την διαβητική αμφιβληστροειδοπάθεια, τον καρδιαγγειακό κίνδυνο, δείγματα από τον βυθό του οφθαλμού ^{15 16}, εικόνες των ματιών κατόπιν εξέτασης σε οπτική τομογραφία συνοχής ¹⁷, ανίχνευση αλλοιώσεων στον μαστό κατά την μαστογραφία¹³ και τέλος σπονδυλική ανάλυση με απεικόνιση μαγνητικού συντονισμού (μαγνητική τομογραφία) ²³.»

Παρόλο που ο μακροπερίοδος λόγος προκαλεί συχνά δυσνόητο αποτέλεσμα, έγινε προσπάθεια να μην αλλοιωθεί η μορφή του κειμένου και να παραμείνει σε ορισμένα σημεία ο μακροπερίοδος λόγος. Φυσικά αυτό συνέβη μέσα στα πλαίσια που δεν δημιουργεί σύγχυση.

- ✓ **Συντακτική δομή:**

Πρωτότυπο: «However, a key limitation across studies that compare human to algorithmic performance has been a lack of clinical context—they constrain the diagnosis to be performed using just the images at hand».

Μετάφρασμα: «Ωστόσο, ένας βασικός περιορισμός σε όλες τις μελέτες, που συγκρίνουν τον άνθρωπο με την αλγοριθμική απόδοση, είναι ότι υστερεί σε κλινική συνάφεια - η διαδικασία της διάγνωσης γίνεται υπό τον περιορισμό του ότι λαμβάνονται υπόψιν απλώς οι επικείμενες εικόνες.»

Στη προκειμένη περίπτωση, χρειάστηκε μια μικρή ανασύνταξη της πρότασης στο μετάφρασμα, προκειμένου να είναι πιο δόκιμη στα ελληνικά.

- ✓ Στην αγγλική ορολογία συναντάται το **ενωτικό (-)**. Στα ελληνικά συνήθως αποδίδεται ή με πλήρη απαλοιφή, ή με χρήση γενικής πτώσης ή με δημιουργία σύνθετης λέξης (Κεραμίδας 2015: 103):

Πρωτότυπο: «*Deep-learning* models scale to large datasets—in part owing to their ability to run on specialized computing hardware—and continue to improve with more data, enabling them to outperform many classical ML approaches.»

Μετάφρασμα: «Τα μοντέλα *βαθιάς μάθησης* κλιμακώνονται σε μεγάλα σύνολα δεδομένων - εν μέρει λόγω της ικανότητάς τους να «τρέχουν» σε εξειδικευμένο υπολογιστικό υλικό - και συνεχίζουν να βελτιώνονται με περισσότερα δεδομένα, επιτρέποντάς τους να σημειώσουν καλύτερη επίδοση από άλλες κλασικές προσεγγίσεις της Μηχανικής Μάθησης (ML).»
Στη προκειμένη περίπτωση επιλέχθηκε η πλήρης απαλοιφή του ενωτικού.

Πολιτισμικά προβλήματα:

«Κάθε πολιτισμός έχει τις δικές του συνήθειες, νόρμες και συμβάσεις. Τα πολιτισμικά μεταφραστικά προβλήματα απορρέουν από τις διαφορές στις νόρμες και τις συμβάσεις που διέπουν τη λεκτική και μη λεκτική συμπεριφορά στους δύο εμπλεκόμενους πολιτισμούς.»

(Nord 2014: 149)

Πρωτότυπο: «For example, blood contains small fragments of cell-free *DNA* released from cells present elsewhere in the body.»

Μετάφρασμα: «Για παράδειγμα, το αίμα περιέχει μικρά τμήματα *DNA* χωρίς κύτταρα που απελευθερώνονται από κύτταρα, τα οποία βρίσκονται οπουδήποτε στο σώμα.»

Στη προκειμένη περίπτωση έχουμε τον αγγλικό όρο *DNA*. Στα ελληνικά ο όρος μεταφράζεται ως «δεοξυριβονουκλεϊκό οξύ». Σε παγκόσμιο επίπεδο και πολιτισμικό, το επικρατέστερο είναι ο όρος *DNA*. Έχει παγιωθεί μέσω της γλώσσας και του επιστημονικού τομέα. Συνεπώς, επέλεξα να διατηρήσω τον αγγλικό όρο έναντι του ελληνικού, προκειμένου να μην προκαλέσει κάποια σύγχυση και να απαντά στην σύγχρονη πραγματικότητα των επιστημών.

Γλωσσικά προβλήματα:

«Μεταφραστικά προβλήματα μπορούν επίσης να προκύψουν από δομικές διαφορές στο λεξιλόγιο, τη σύνταξη και τα υπερτεμαχιακά στοιχεία των δύο γλωσσών»

(Nord 2014: 150).

Είναι δεδομένο ότι εφόσον το κείμενο αφετηρίας ανήκει στα ειδικά κείμενα, ο μεταφραστής να περιμένει να συναντήσει ποικίλα γλωσσικά μεταφραστικά προβλήματα. Μερικά από αυτά:

✓ **Η χρήση αρκτικόλεξων στην Αγγλική:**

Σε όλη την έκταση του κειμένου συναντώνται τα εξής αρκτικόλεξα:

MIMIC dataset	Βάση δεδομένων MIMIC
CNN	Συνελικτικό Νευρωνικό Δίκτυο
DNN	Βαθύ Νευρωνικό Δίκτυο
OCT	Οπτική Τομογραφία Συνοχής
FHIR	Πόροι Γρήγορης Διαλειτουργικότητας της Υγειονομικής Περίθαλψης

ML	Μηχανική Μάθηση
NLP	Επεξεργασία Φυσικής Γλώσσας
EHR system	Σύστημα ηλεκτρονικών μητρώων υγείας
RAS	Ρομποτική χειρουργική
RNN	Αναδρομικό Νευρωνικό Δίκτυο

Ενώ στην Αγγλική χρησιμοποιείται αρκτικόλεξο, στα Ελληνικά έχει παγιωθεί η πλήρης μετάφραση του όρου.(Κεραμίδας 2015: 106). Κατά αυτόν τον τρόπο έπραξα και η ίδια όταν συνάντησα τα ανωτέρω αρκτικόλεξα.

Πρωτότυπο: «Future work will likely focus on developing algorithms to better leverage some of the information-rich yet unstructured data in *EHRs*.»

Μετάφρασμα: «Η μελλοντική εργασία πιθανώς να επικεντρωθεί στην ανάπτυξη αλγόριθμων για την καλύτερη αξιοποίηση ορισμένων από τα πλούσια σε πληροφορίες δεδομένα αλλά ακόμη μη δομημένα σε *συστήματα ηλεκτρονικών μητρώων υγείας*.»

✓ **Ελληνοποίηση:**

Σε τέτοιου είδους κείμενα συνηθίζεται η «ελληνοποίηση» του πρωτογενούς όρου, δηλαδή η ελληνοποιημένη φωνητική απόδοση του ξένου όρου.

Πρωτότυπο: «Deep-learning systems can enhance the quality of biomarker assays targeting DNA sequences⁶¹, *methylation*⁶², gene expression⁶³, *chromatin*⁶⁴ profiles, and many other measurements».

Μετάφρασμα: «Τα συστήματα βαθιάς μάθησης μπορούν να βελτιώσουν την ποιότητα των δοκιμών των βιοδεικτών που στοχεύουν αλληλουχίες DNA ⁶¹, *μεθυλίωση* ⁶², γονιδιακή έκφραση ⁶³, *προφίλ χρωματιτίνης* ⁶⁴ και πολλές άλλες μετρήσεις.»

✓ **Πολυλεκτικοί όροι:**

Συχνά στη περίπτωση ιατρικών όρων σε αγγλικό κείμενο, η διαδικασία που ακολουθείται στα ελληνικά είναι τέτοια που αυξάνεται ο αριθμός των απαρτιζόμενων όρων. Κυρίως λόγω της χρήσης της γενικής πτώσης ή της προτίμησης επεξηγηματικών αποδόσεων. (Κεραμίδας 2015: 101-103). Σπανιότερα συναντάται το αντίστροφο, να δημιουργηθεί μια μονολεκτική λέξη.

Πρωτότυπο: «CV focuses on image and video understanding, and deals with tasks such as *object classification*, detection, and segmentation—which are useful in determining whether a patient’s radiograph contains malignant tumors.»

Μετάφρασμα: «Η μηχανική όραση επικεντρώνεται στην κατανόηση εικόνων και βίντεο και ασχολείται με θέματα όπως η *ταξινόμηση αντικειμένων*, η ανίχνευση και η κατάτμηση -τα οποία βοηθούν στον καθορισμό του εάν στο ραδιογράφημα του ασθενούς ανιχνεύονται κακοήθεις όγκοι.»

✓ **Ορολογική αβεβαιότητα:**

Όταν εντοπίζεται δίπλα στον ελληνικό όρο σε παρένθεση ο αγγλικός, παρατίθεται έτσι προκειμένου να διευκολυνθεί ο αναγνώστης σε περίπτωση που ο όρος δεν είναι ευρέως γνωστός και διαδεδομένος.

Πρωτότυπο: «*Convolutional neural networks (CNNs)*^{1,2}, a type of deep-learning algorithm designed to process data that exhibits natural spatial invariance (e.g., Images, whose meanings do not change under translation), have grown to be central in this field. »

Μετάφρασμα: «*Τα Συνελικτικά Νευρωνικά Δίκτυα (CNNs)*^{1,2}, το οποίο είναι ένα είδος βαθιάς μάθησης, που σχεδιάστηκε για να επεξεργάζεται δεδομένα, τα οποία παρουσιάζουν τη φυσική χωρική αμεταβλητότητα (για παράδειγμα, εικόνες, των οποίων οι έννοιες δεν αλλάζουν κατά τη διαδικασία της μετάφρασης), έχουν καταλήξει να κατέχουν βασική θέση σε αυτόν τον τομέα.»

Κειμενοϊδιομορφικά μεταφραστικά προβλήματα:

Κάποια μεταφραστικά προβλήματα είναι άρρηκτα συνδεδεμένα με ένα συγκεκριμένο κείμενο-πηγή, όπως συμβαίνει με ορισμένα σχήματα λόγου, νεολογισμούς και λογοπαίγνια. Επειδή οι λύσεις που δίνονται στα συγκεκριμένα προβλήματα δεν μπορούν να γενικευτούν και να εφαρμοστούν σε παρόμοιες περιπτώσεις, ο μεταφραστής πρέπει να είναι προετοιμασμένος να δράσει δημιουργικά. (Nord 2014: 152)

Στη παρούσα πτυχιακή δεν συναντώνται κειμενοϊδιομορφικά προβλήματα, άλλωστε το κείμενο αφετηρίας, και κατ' επέκταση το κείμενο αφίξεως, ανήκει στη λεγόμενη «ειδική μετάφραση». Συνεπώς η απουσία τέτοιων προβλημάτων είναι λογική.

Μέσα από την διαδικασία της ενασχόλησης μου με το παρόν κείμενο, κατέληξα στο συμπέρασμα ότι στον τομέα της μετάφρασης, οι γνώσεις και οι σωστές τεχνικές προσέγγισης ενός κειμένου, δεν είναι μόνο ότι χρειάζεται ο μεταφραστής. Η συνέπεια, η λειτουργικότητά του και η διαρκής ενασχόληση με το αντικείμενο είναι που θα «γεννήσουν» ένα δόκιμο και «καθαρό» μετάφρασμα.

ΓΛΩΣΣΑΡΙ ΟΡΩΝ

ΟΡΟΣ	ΑΠΟΔΟΣΗ
Deep learning (DL)	Βαθιά μάθηση (DL)
Computer vision (CV)	Μηχανική όραση
Natural language processing (NLP)	Επεξεργασία φυσικής γλώσσας (NLP)
Reinforcement learning (RL)	Ενισχυτική μάθηση (RL)
Genomics	Γονιδιωματική (Η επιστήμη της Γονιδιωματικής)
Data set	Σύνολο δεδομένων
Machine learning system (MLS)	Σύστημα μηχανικής μάθησης (MLS)
Raw data	Μη επεξεργασμένα δεδομένα
Nonlinear operation	Μη γραμμική λειτουργία
CNN (Convolutional neural network)	Συνελικτικό νευρωνικό δίκτυο (CNN)
Medical imaging	Ιατρική απεικόνιση
data matrix	μήτρα δεδομένων
Fundus	Βυθός οφθαλμού
Mammogram	Μαστογραφία
magnetic resonance imaging (MRI)	Μαγνητικός συντονισμός με απεικόνιση (MRI)
Occlusion	Έγκλειση
Semi-supervised learning	Ημι- επιτηρούμενη μάθηση
Unsupervised learning	Μη επιβλεπόμενη μάθηση
Supervised learning	Επιβλεπόμενη μάθηση
Recurrent neural network (RNN)	Αναδρομικό Νευρωνικό Δίκτυο (RNN)
EHR system	Σύστημα ηλεκτρονικών μητρώων υγείας
MIMIC Data set	Βάση δεδομένων MIMIC
Convolution	Συνέλιξη
Pooling (of data)	Διασύνδεση δεδομένων

Softmax layer (output vector)	Διάνυσμα εξόδου
Vicinity	Γύρω περιοχή
DNN (Deep neutral network)	Βαθύ νευρωνικό δίκτυο (DNN)
Gene-splicing	Μάτισμα
Genome-wide association study (GWAs)	Μελέτη γονιδιακής συσχέτισης (Μελέτη συσχέτισης σε ολόκληρο το γονιδίωμα)
mutation	μετάλλαξη
cohort	κοόρτη
phenotype	φαινότυπος
biomaker	βιοδείκτης
genomics	γονιδιωματική
proliferation	διάδοση
algorithm	αλγόριθμος
feed/feeding	τροφοδοσία
data input	εισαγωγή δεδομένων (data entry)
data point	σημείο δεδομένων
computer hardware	υλισμικό ηλεκτρονικού υπολογιστή
trial	δοκιμή
segmentation	κατάτμηση
object classification	ταξινόμηση αντικειμένων
mole	γραμμομόριο
lesion	αλλοίωση
agent	παράγοντας
(RAS) robotic assisted surgery	ρομποτική χειρουργική (RAS)
robustness	ανθεκτικότητα
suture	συρραφή
stereovision	στερεοσκοπική όραση
(MLS) Modern Laparoscopic Surgery	Σύγχρονη Λαπαροσκοπική Χειρουργική (MLS)
mapping data	χαρτογράφηση δεδομένων

gene expression	γονιδιακή έκφραση
genetic mutation	γονιδιακή μετάλλαξη
computation	υπολογισμός
pathogenicity	παθογονικότητα
conservation	διατήρηση
binding	προσδιοριστικό ζευγάρι
chromosomal aberration	χρωμοσωμική ανωμαλία
assay	δοκιμή
human engineering	εργονομία
representation learning	μάθηση αναπαράστασης
pattern recognition	αναγνώριση προτύπων
image data	δεδομένα εικόνας
probability distribution	κατανομή πιθανότητας
Generative Adversarial Network (GAN)	γεννητικό ανταγωνιστικό δίκτυο (GAN)
automatic speech recognition (ASR)	αυτόματη αναγνώριση ομιλίας (ASR)
end-to-end (system)	διατερματικό (σύστημα)

BIBΛΙΟΓΡΑΦΙΑ

A. ΞΕΝΟΓΛΩΣΣΗ

- Holz-Mänttari, Justa (1984). Translatorisches Handeln. Theorie und Methode. Helsinki: Suomalainen Tiedekatemia.
- Nord, Christiane (2014). Translating as a Purposeful Activity. Functionalist Approaches Explained. Routledge.

B. ΕΛΛΗΝΙΚΗ

- Κελάνδριας, Παναγιώτης Ι. (2016). Λειτουργική Διδακτική της Μετάφρασης. Αθήνα: Δίαυλος.
- Κεντρωτής, Γιώργος (1996). Θεωρία και Πράξη της Μετάφρασης. Αθήνα: Δίαυλος.
- Nord, Christiane (2014). Η Μετάφραση ως στοχευμένη δραστηριότητα. Εισαγωγή στις λειτουργικές προσεγγίσεις [Μετάφρ. Σίμος Π. Γραμμενίδης, Δέσποινα Δ. Λάμπρου]. Αθήνα: Δίαυλος.
- Κεραμίδας, Σ.Γ. (2015). Ζητήματα Ορολογίας στην Τεχνική Μετάφραση. Αθήνα: Δίαυλος.

Γ. ΛΕΞΙΚΑ

- Λεξικό Τεχνολογίας & Επιστημών αγγλοελληνικό & ελληνοαγγλικό. (2018). 4^η Έκδοση. Εκδόσεις Σταφυλλίδη.
- Μιχαηλίδης, Γεώργιος. (Μάιος 2005). Αγγλοελληνικό & ελληνοαγγλικό λεξικό των Ιατρικών Όρων. Αθήνα: Ιατρικές Εκδόσεις Κωνσταντάρας.

ΔΙΑΔΙΚΤΥΑΚΟΙ ΠΟΡΟΙ

- Εμπορικό σύστημα διαχείρισης μετάφρασης και εργαλείο αυτόματης μετάφρασης (CAT tool): <https://www.memsource.com/>
- Η IATE («Interactive Terminology for Europe» – Διαδραστική Ορολογία για την Ευρώπη) είναι η ορολογική βάση δεδομένων της ΕΕ. Χρησιμοποιείται από τα θεσμικά όργανα και τους οργανισμούς της ΕΕ από το καλοκαίρι του 2004 για τη συλλογή, τη διάδοση και τη διαχείριση ορολογίας σε θέματα αρμοδιότητας της ΕΕ.:
<https://iate.europa.eu/home>
- Βάση όρων τεχνολογίας πληροφοριών:
<http://www.eleto.gr/inforterm/greek/search.php>
- Εργαλείο μετάφρασης, που δίνει πρόσβαση σε πηγές όπως το IATE, EUR-LEX κλπ.: <https://el.techdico.com/>
- Εθνικό Κέντρο Πληροφοριών Βιοτεχνολογίας, που προάγει την επιστήμη και την υγεία παρέχοντας πρόσβαση σε βιοϊατρικές και γονιδιωματικές πληροφορίες:
<https://www.ncbi.nlm.nih.gov/clinvar/>
- Η "Νημερτής" είναι το Ιδρυματικό Αποθετήριο που φιλοξενεί την πνευματική παραγωγή του Πανεπιστημίου Πατρών. Συγκεντρώνει τις διδακτορικές διατριβές, μεταπτυχιακές και διπλωματικές εργασίες που εκπονούνται στο Πανεπιστήμιο Πατρών και ταυτόχρονα συλλέγει κι άλλο υλικό, όπως είναι τεχνικές αναφορές, δημοσιεύσεις σε περιοδικά και πρακτικά συνεδρίων των μελών ΔΕΠ και των ερευνητών του Πανεπιστημίου, δημοσιεύσεις του προσωπικού της ΒΚΠ, κλπ.:
<https://nemertes.library.upatras.gr/jspui/>

Ηλεκτρονική διεύθυνση όπου μπορεί κανείς να βρει το εν λόγω κείμενο αφετηρίας: <https://www.nature.com/articles/s41591-018-0316-z>

