



Πανεπιστήμιο Πειραιώς – Τμήμα Πληροφορικής

Πρόγραμμα Μεταπτυχιακών Σπουδών

«Προηγμένα Συστήματα Πληροφορικής»

Μεταπτυχιακή Διατριβή

Τίτλος Διατριβής	Εντοπισμός και Ανάλυση Ψευδών Ειδησεογραφικών Άρθρων με Χρήση Βαθέων Τεχνητών Νευρωνικών Δικτύων και Μοντελοποίησης Θεμάτων Fake News Detection and Analysis using Artificial Neural Networks and Latent Topic Analysis
Όνοματεπώνυμο Φοιτητή	Δήμητρα Πουρνάρα
Πατρώνυμο	Γεώργιος
Αριθμός Μητρώου	ΜΠΣΠ/14078
Επιβλέπων	Δημήτριος Αποστόλου, Αναπληρωτής Καθηγητής

Ημερομηνία Παράδοσης **Οκτώβριος 2020**

Τριμελής Εξεταστική Επιτροπή

(υπογραφή)

(υπογραφή)

(υπογραφή)

Δημήτριος Αποστόλου
Αναπληρωτής Καθηγητής

Άγγελος Πικράκης
Επίκουρος Καθηγητής

Διονύσιος Σωτηρόπουλος
Επίκουρος Καθηγητής

Αφιερώνεται στην προσφάτως εκλιπούσα γιαγιά μου

Ευχαριστίες

Η παρούσα εργασία αποτελεί μεταπτυχιακή διατριβή στα πλαίσια του μεταπτυχιακού προγράμματος σπουδών «Προηγμένα Συστήματα Πληροφορικής» με κατεύθυνση «Ευφυείς Τεχνολογίες Επικοινωνίας Ανθρώπου - Υπολογιστή» στο Πανεπιστήμιο Πειραιώς. Με την διεκπεραίωση της μελέτης επιθυμώ να εκφράσω τις ευχαριστίες μου σε όσους συνέβαλαν στις διάφορες πτυχές της.

Πρωτίστως θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή κ. Δημήτρη Αποστόλου για την ευκαιρία που μου έδωσε να αναπτύξω, να διευρύνω και να εξελίξω το γνωστικό μου πεδίο σε τεχνολογίες της Επιστήμης Δεδομένων, της Βαθιάς Μάθησης και της Επεξεργασίας Φυσικής Γλώσσας όπως και για την εμπειρία στην έρευνα.

Ευχαριστώ από καρδιάς τους γονείς και τις αδερφές μου για την αδιάλειπτη υποστήριξη που μου πρόσφεραν, και τον Δημήτρη Μακρή για την καθοριστική συμπαράσταση, κατανόηση και εμπύχωση.

Κλείνοντας θα ήθελα να ευχαριστήσω τους ανθρώπους της επιστημονικής κοινότητας, και όσους συνεισφέρουν σε αυτή, για το επιστημονικό και ερευνητικό τους έργο.

Περίληψη

Το πρόβλημα της διασποράς ψευδών ειδήσεων έχει λάβει μεγάλες διαστάσεις στην διαδικτυακή εποχή και ανά περίπτωση διώκεται ποινικά. Οι πληροφορίες μπορούν να διαδίδονται χωρίς κάποιο φίλτρο αξιοπιστίας της πληροφόρησης, γεγονός που ενέχει κινδύνους ανάλογα με την απήχηση και τους αποδέκτες, ειδικά όταν αφορά σε σοβαρά ζητήματα όπως δημόσιας υγείας και ασφάλειας. Ο όγκος των πληροφοριών και η ταχύτητα μετάδοσής τους καθιστούν σχεδόν ανέφικτη την έγκαιρη ανάλυσή τους χωρίς την χρήση νέων τεχνολογιών.

Η παρούσα μελέτη πραγματεύεται το πρόβλημα του εντοπισμού των ψευδών ειδησεογραφικών άρθρων με χρήση βαθέων τεχνητών νευρωνικών δικτύων Long Short-Term Memory. Στα ειδησεογραφικά άρθρα εφαρμόζεται επιπρόσθετη σημασιολογική ανάλυση με τεχνικές επεξεργασίας της φυσικής γλώσσας και μοντελοποίησης θεμάτων, σε μία προσέγγιση αναζήτησης και σύγκρισης μοτίβων στις θεματολογίες των ψευδών και αληθών άρθρων. Για τις ανάγκες του πειράματος χρησιμοποιήθηκαν τέσσερις συλλογές πραγματικών δημοσιευμάτων που αγγίζουν τις 60.000 εγγραφές και δύο συλλογές για τον έλεγχο των τελικών μοντέλων. Σκιαγραφείται το απαραίτητο θεωρητικό υπόβαθρο που πλαισιώνεται από τους τομείς της μηχανικής μάθησης και της επιστήμης δεδομένων. Η παρουσίαση της μεθοδολογίας και της υλοποίησης του πειράματος ακολουθείται από την ανάλυση των αποτελεσμάτων. Συμπερασματικά διατυπώνονται παρατηρήσεις και μελλοντικές βελτιώσεις.

Λέξεις-κλειδιά: εντοπισμός ψευδών ειδήσεων, μοντελοποίηση θεμάτων, βαθιά μάθηση, LDA, LSTM, tensorflow

Abstract

In the internet era, the spread of fake news has grown and might even lead to legal actions per occasion. The dissemination of information without a prior credibility check on their reliability, combined with their popularity and the targeted audience, may involve risks especially on important issues, such as public health and safety. The increased volume and diffusion speed of the information makes their timely analysis almost impossible except when new technologies are utilized.

This dissertation approaches the problem of fake news detection using Long Short-Term Memory deep neural networks. Additional semantic analysis was performed to identify and compare patterns in the topics of fake and real news respectively, using natural language processing and topic modeling techniques. The dataset of the experiment is a combination of four separate datasets constituting a unified set of 60,000 fake and real news articles. Two more datasets were combined to construct the unseen dataset for the finalized models. The theoretical background is discussed covering aspects of machine learning and data science. The representation of the methodologies and the implementation of the models is followed by the research results. In conclusion observations and future improvements are discussed.

Keywords: fake news detection, deep learning, topic modeling, LDA, LSTM, tensorflow

Περιεχόμενα

Εισαγωγή	4
Ανασκόπηση Βιβλιογραφίας.....	5
1. Μεγάλα Δεδομένα.....	6
2. Νευρωνικά Δίκτυα.....	9
2.1. Βιολογικά Νευρωνικά Δίκτυα	9
2.2. Τεχνητά Νευρωνικά Δίκτυα	11
2.3. Τεχνικές Βαθιάς Μάθησης	16
2.3.1. Αρχιτεκτονικές Βαθέων Νευρωνικών Δικτύων	16
2.3.2. Συναρτήσεις Ενεργοποίησης	18
2.3.3. Συναρτήσεις Σφάλματος	19
2.3.4. Κανονικοποίηση.....	19
3. Εξόρυξη και Ανακάλυψη Γνώσης	20
3.1. Ανακάλυψη Γνώσης σε Βάσεις Δεδομένων	20
3.2. Επεξεργασία Φυσικής Γλώσσας και Ανακάλυψη Γνώσης από Κείμενα.....	21
3.3. Μοντελοποίηση Θεμάτων	22
3.3.1. Latent Dirichlet Allocation	23
4. Εντοπισμός και Ανάλυση Ψευδών Ειδήσεων	23
4.1. Μεθοδολογία.....	24
4.2. Τεχνολογίες	24
4.3. Επιλογή Δεδομένων	25
4.4. Κατηγοριοποίηση.....	27
4.4.1. Προετοιμασία Δεδομένων	27
4.4.2. Συντονισμός Υπερπαραμέτρων	30
4.4.3. Επιλογή του Καλύτερου Μοντέλου	33
4.4.4. Κανονικοποίηση και Δοκιμή.....	34
4.4.5. Παραγωγή Τελικού Μοντέλου	35
4.4.6. Αξιολόγηση Αποτελεσμάτων.....	36
4.5. Μοντελοποίηση Θεμάτων	36
4.5.1. Προετοιμασία Δεδομένων	36
4.5.2. Επιλογή Αριθμού Θεμάτων.....	37
4.5.3. Παραγωγή και Επιλογή Μοντέλων.....	38
4.5.4. Δοκιμές	46
4.5.5. Αξιολόγηση Αποτελεσμάτων.....	48
4.6. Καθολικό Παράδειγμα Εκτέλεσης	48
5. Συμπεράσματα και Βελτιώσεις	49
Συντομεύσεις και Αρκτικόλεξα	51

Βιβλιογραφία	52
--------------------	----

Ευρετήριο Σχημάτων

Σχήμα 1.1: Παγκόσμια Αύξηση των Χρηστών του Διαδικτύου	6
Σχήμα 1.2: Δεδομένα που Παράγονται στο Διαδίκτυο ανά Λεπτό	7
Σχήμα 2.1: Βασικά Μέρη Τυπικού Νευρώνα	10
Σχήμα 2.2: Σύνδεση Φυσικών Νευρώνων	10
Σχήμα 2.3: Μοντέλο Τεχνητού Νευρώνα	12
Σχήμα 2.4: Δομή Τεχνητού Νευρωνικού Δικτύου	12
Σχήμα 2.5: Μοντέλο Νευρώνα Perceptron	13
Σχήμα 2.6: ΤΝΔ Τεσσάρων Επιπέδων με Δύο Κρυφά Επίπεδα	14
Σχήμα 2.7: Αρχιτεκτονικές ΤΝΔ	15
Σχήμα 2.8: RNN	17
Σχήμα 2.9: Κύτταρο Μνήμης LSTM	18
Σχήμα 2.10: Συναρτήσεις Ενεργοποίησης	19
Σχήμα 3.1: Βασικά Στάδια KDD	20
Σχήμα 3.2: Σχηματική Αναπαράσταση LDA Plate Notation	23
Σχήμα 4.1: Στιγμιότυπο Δοκιμής – Ευρετήριο Λέξεων	28
Σχήμα 4.2: Στιγμιότυπο Δοκιμής – Μετατροπή Εγγραφών σε Ακολουθία Όρων	28
Σχήμα 4.3: Στιγμιότυπο Δοκιμής – Μετατροπή Εγγραφών σε Λίστα Κλειδιών	29
Σχήμα 4.4: Στιγμιότυπο Δοκιμής – Μετατροπή Λίστας Κλειδιών σε Δισδιάστατο Πίνακα	29
Σχήμα 4.5: Στιγμιότυπο Δοκιμής – Μετατροπή Λέξεων σε Διανυσματική Αναπαράσταση	29
Σχήμα 4.6: Διανυσματική Αναπαράσταση των Λέξεων στον χώρο	30
Σχήμα 4.7: Διανυσματική Αναπαράσταση των Λέξεων (zoom)	30
Σχήμα 4.8: Model Summary	32
Σχήμα 4.9: Wordcloud Αληθών Νέων	37
Σχήμα 4.10: Wordcloud Ψευδών Νέων	37
Σχήμα 4.11: Διαφορές Θεμάτων για το Μοντέλο των Αληθών Δηλώσεων	40
Σχήμα 4.12: Διαφορές Θεμάτων για το Μοντέλο των Ψευδών Δηλώσεων	41
Σχήμα 4.13: Διαφορές Θεμάτων μεταξύ των Μοντέλων Αληθών και Ψευδών Δηλώσεων	41
Σχήμα 4.14: Ενδεικτικό Θέμα #12 Αληθών Δηλώσεων	42
Σχήμα 4.15: Ενδεικτικό Θέμα #26 Αληθών Δηλώσεων	43
Σχήμα 4.16: Ενδεικτικό Θέμα #3 Ψευδών Δηλώσεων	43
Σχήμα 4.17: Ενδεικτικό Θέμα #9 Ψευδών Δηλώσεων	44
Σχήμα 4.18: Wordcloud Αληθών Δηλώσεων της Συλλογής Δοκιμής	46
Σχήμα 4.19: Wordcloud Ψευδών Δηλώσεων της Συλλογής Δοκιμής	47

Ευρετήριο Διαγραμμάτων

Διάγραμμα 1.1: Πρόβλεψη Μεγέθους της Αγοράς Μεγάλων Δεδομένων	8
Διάγραμμα 2.1: Δομή Νευρικού Συστήματος	9
Διάγραμμα 4.1: Θεματολογία Άρθρων	26
Διάγραμμα 4.2: Κατανομή των Άρθρων σε Ψευδή και Αληθή	26
Διάγραμμα 4.3: Επίπεδα Τελικού Νευρωνικού Δικτύου	31
Διάγραμμα 4.4: Ακρίβεια ανά Δοκιμή	33
Διάγραμμα 4.5: Ακρίβεια ανά Συνδυασμό Νευρώνων	33
Διάγραμμα 4.6: Συνάρτηση Σφάλματος ανά Εποχή	34
Διάγραμμα 4.7: Ακρίβεια ανά Εποχή	34
Διάγραμμα 4.8: Συνάρτηση Σφάλματος ανά Εποχή με Regularizer	35
Διάγραμμα 4.9: Ακρίβεια ανά Εποχή του με Regularizer	35
Διάγραμμα 4.10: Συνοχή c_v των Μοντέλων για τις Αληθείς Δηλώσεις	38
Διάγραμμα 4.11: Συνοχή u_{mass} των Μοντέλων για τις Αληθείς Δηλώσεις	38

Διάγραμμα 4.12: Περιπλοκή των Μοντέλων για τις Αληθείς Δηλώσεις	39
Διάγραμμα 4.13: Συνοχή c_v των Μοντέλων για τις Ψευδείς Δηλώσεις	39
Διάγραμμα 4.14: Συνοχή u_{mass} των Μοντέλων για τις Ψευδείς Δηλώσεις	39
Διάγραμμα 4.15: Περιπλοκή των Μοντέλων για τις Ψευδείς Δηλώσεις	40
Διάγραμμα 4.16: Λέξεις Ενδεικτικών Θεμάτων - Μοντέλο Αληθών Δηλώσεων	44
Διάγραμμα 4.17: Λέξεις Ενδεικτικών Θεμάτων - Μοντέλο Ψευδών Δηλώσεων	45

Ευρετήριο Πινάκων

Πίνακας 2-1: Αρχιτεκτονικές ΒΝΔ ανά Πεδίο Εφαρμογής	16
Πίνακας 4-1: Κυρίαρχο Θέμα ανά Έγγραφο – Ψευδείς Ειδήσεις	45
Πίνακας 4-2: Αριθμός και Ποσοστό Εγγράφων ανά Θέμα – Ψευδείς Ειδήσεις	46
Πίνακας 4-3: Αριθμός και Ποσοστό Άρθρων ανά Θέμα – Ψευδείς Ειδήσεις – Συλλογή Δοκιμής	47

Εισαγωγή

Η εποχή μας χαρακτηρίζεται από καταιγισμό πληροφορίας. Παράλληλα με τον τεράστιο και συνεχώς αυξανόμενο όγκο των δεδομένων εντείνεται η ανάγκη διαχείρισης και αξιοποίησής τους σε θεμιτό χρόνο. Η ανάγκη διαχείρισης των μεγάλων δεδομένων και άντλησης χρήσιμης πληροφορίας από αυτά σε συνδυασμό με την εξέλιξη των υπολογιστικών συστημάτων είχε ως αποτέλεσμα την δημιουργία του διεπιστημονικού κλάδου της Επιστήμης Δεδομένων (Data Science). (Βερύκιος, et al., 2015) Η Επιστήμη Δεδομένων χρησιμοποιεί αλγόριθμους, μηχανική μάθηση, βαθιά μάθηση και στατιστική για την εξαγωγή γνώσης, προβλέψεων και την οπτικοποίηση των δεδομένων. (Βερύκιος, et al., 2015)

Η Μηχανική Μάθηση μελετά αλγορίθμους που καθιστούν τα συστήματα ικανά να βελτιώνουν ή να προσαρμόζουν την συμπεριφορά τους αξιοποιώντας προηγούμενη γνώση και εμπειρία δημιουργώντας πρότυπα από το σύνολο δεδομένων. (Γεωργούλη, 2015) Τα Τεχνητά Νευρωνικά Δίκτυα επιτυγχάνουν αυτές τις διαδικασίες με μία προσπάθεια μίμησης του τρόπου μάθησης, επεξεργασίας και επικοινωνίας που συναντάται στα Βιολογικά Νευρωνικά Δίκτυα του εγκεφάλου. (Eluyode, et al., 2013) Ειδικά σε προβλήματα όπου υπάρχουν μεγάλο όγκο και πολυσύνθετα δεδομένα μπορούν να εφαρμοστούν στα νευρωνικά δίκτυα τεχνικές Βαθιάς Μάθησης (Deep Learning - DL) όπου η διαδικασία μάθησης είναι αποτέλεσμα της επεξεργασίας της πληροφορίας και της εξαγόμενης γνώσης από πολλαπλά επίπεδα διασυνδεδεμένων νευρώνων. Η βαθιά μάθηση προσφέρει μία πιο αφαιρετική αντίληψη στην ανακάλυψη γνώσης και σε συνδυασμό με την ύπαρξη του κατάλληλου υλικού όπως οι Γραφικές Μονάδες Επεξεργασίας (Graphical Processing Unit – GPU), η διαδικασία μάθησης είναι σημαντικά ταχύτερη και οι δυνατότητες των δικτύων επεκτείνονται σε πολύπλοκα προβλήματα. (Najafabadi, et al., 2015) (Nielsen, 2015)

Στην περίπτωση της εξόρυξης γνώσης από κείμενα η δυσκολία έγκειται στην διπλή φύση της γλώσσας και στις ασάφειες που την χαρακτηρίζουν. Προκειμένου να γίνει εφικτή η ανακάλυψη γνώσης οι υπολογιστές χρειάζεται να «μάθουν» την γλώσσα των ανθρώπων. Καλούνται να αναγνωρίσουν τις διάφορες σημασίες των λέξεων και των προτάσεων, την σύνταξη, την γραμματική και επιπρόσθετα να εντοπίσουν το ύφος, το βαθύτερο νόημα ή το θέμα ενός κειμένου. Έπειτα δύνανται να ανακαλύψουν υπάρχοντα ή κρυμμένα κοινά χαρακτηριστικά και μοτίβα στα σύνολα δεδομένων. Τα προβλήματα αυτά πραγματεύεται ο τομέας της μηχανικής μάθησης Επεξεργασία Φυσικής Γλώσσας σε συνδυασμό με την γλωσσολογία. (Eisenstein, 2019) Μία ερευνητική περιοχή που ανάγεται στον κλάδο αυτό είναι η μοντελοποίηση θεμάτων όπου αναπτύσσονται αλγόριθμοι με σκοπό να εντοπίσουν ή να ανακαλύψουν την θεματολογία σε συλλογές δεδομένων κειμένου. (Blei, et al., 2003)

Με την ανάπτυξη και την δημοτικότητα του διαδικτύου, των ιστοσελίδων, των ιστολογίων (blogs) και των μέσω κοινωνικής δικτύωσης η παραγωγή, η διάδοση και η ανταλλαγή της πληροφορίας πραγματοποιείται ταχύτατα. Το γεγονός αυτό έχει πολλές θετικές πτυχές και καθιστά την πληροφορία πιο εύκολα και άμεσα προσβάσιμη και διαδόσιμη, δεν συνεπάγεται όμως ότι η πληροφορία είναι αξιόπιστη, συνεπώς το ίδιο εύκολα διαδίδονται ψευδείς ειδήσεις (fake news). Οι ψευδείς ειδήσεις περιλαμβάνουν κάθε είδος κίτρινου τύπου, παραπληροφόρησης, συκοφαντίας, προκατάληψης, ρητορικής μίσους και μπορεί να υποκινούνται από κάθε είδους κίνητρο (οικονομικό, πολιτικό, κοινωνικό, ανθρωπιστικό) αποσκοπώντας στην χειραγώγηση του αποδέκτη. (Özgöbek, et al., 2018)

Η παρούσα έρευνα προσεγγίζει το πρόβλημα του διαχωρισμού των ειδήσεων ανάλογα με την αξιοπιστία τους και την ανάλυσή τους με την χρήση των ανωτέρω τεχνολογιών.

Ανασκόπηση Βιβλιογραφίας

Από το έτος 2016 και έπειτα παρατηρείται στην βιβλιογραφία αύξηση των δημοσιεύσεων που σχετίζονται με την ανίχνευση ψευδών ειδήσεων. Το γεγονός αυτό σχετίζεται με τον καταϊγισμό παραπληροφορίας που παρατηρήθηκε -κυρίως στα Μέσα Κοινωνικής Δικτύωσης (ΜΚΔ)- κατά την περίοδο των προεδρικών εκλογών στις Η.Π.Α., που υποστηρίζεται ότι επιτέλεσε σημαντικό ρόλο στο αποτέλεσμά τους. Με την έκταση του ζητήματος εταιρείες όπως οι Facebook και Twitter ενσωμάτωσαν αλγόριθμους για να αποτρέπεται η διάδοση ψευδών δημοσιευμάτων. (Allcott, et al., 2019). Τα δεδομένα αυτά αποτέλεσαν υλικό για πολλές έρευνες, έδωσαν ώθηση στον εντοπισμό ψευδών ειδήσεων με χρήση μηχανικής και βαθιάς μάθησης και επιπροσθέτως στην δημιουργία νέων συλλογών δεδομένων πλαστών δημοσιεύσεων.

Οι τεχνικές που συναντώνται στις έρευνες περιλαμβάνουν ανάλυση συναισθήματος, k-means, κατηγοριοποιητές Naïve Bayes και Linear Support Vector Machine, νευρωνικά δίκτυα και βαθιά μάθηση. (Steni, et al., 2020) Οι περισσότερες έρευνες αναλύουν δεδομένα από ΜΚΔ και λιγότερες περιλαμβάνουν δημοσιεύσεις τύπου. Στις σχετικές με τα ΜΚΔ έρευνες διακρίνονται τρεις βασικές προσεγγίσεις που αφορούν την ανάλυση και είναι: βάσει περιεχομένου, βάσει κοινωνικού πλαισίου και βάσει διάδοσης. Στις συλλογές που περιέχουν δεδομένα τύπου συναντάται η ανάλυση με βάση το περιεχόμενο (Shu, et al., 2017). Η συλλογή δεδομένων LIAR, που δημοσιεύτηκε από τον W. Wang είναι ένα μεγάλο όγκου dataset που περιέχει δημοσιεύσεις τύπου και συναντάται ευρέως σε σχετικές έρευνες. Ο Wang στην έρευνά του προτείνει ένα υβριδικό νευρωνικό μοντέλο CNN και BLSTM για τον εντοπισμό πλαστών νέων. (Wang, 2017). Το 2018 αντιπροτείνονται, για το ίδιο dataset, τα δίκτυα GRU ως καλύτερης απόδοσης (Girgis, et al., 2018). Η έρευνα των M. Granik και V. Mesyura αντιμετωπίζει το θέμα των ψευδών δημοσιεύσεων του ΜΚΔ Facebook προτείνοντας υβριδικά μοντέλα εμπιστοσύνης (Hybrid Trust Models) που χρησιμοποιούν τεχνικές αποσύνθεσης τανυστών για να δημιουργήσουν κύκλους εμπιστοσύνης (Ghafari, et al., 2018). Σε μία διαφορετική οπτική παρουσιάζεται το deep diffusive νευρωνικό μοντέλο FAKEDETECTOR, που συσχετίζει ταυτόχρονα τα χαρακτηριστικά των άρθρων, των συντακτών και των θεμάτων μέσω μία πύλης GDU· κατά συνέπεια μπορεί να ανιχνεύσει ένα πλαστό νέο με δεδομένο όποιο από αυτά τα χαρακτηριστικά (Zhang, et al., 2018).


Στην παρούσα μελέτη χρησιμοποιούνται συνενωμένα dataset που αποτελούνται από διάφορες πηγές με σκοπό την επίτευξη μίας επιμελούς ανομοιογένειας όσον αφορά τις θεματολογίες και τις πηγές των δεδομένων. Η ποικιλία αυτή συνεπάγεται διαφορετικούς τρόπους συγγραφής και χρήσης της γλώσσας με στόχο τα μοντέλα να εκπαιδευτούν σε αυτές τις διαφορετικότητες. Ηθελμένα αποφεύχθηκε η επιλογή πιο δημοφιλών datasets, όπως το LIAR επειδή έχει αναλυθεί σε αρκετές δημοσιεύσεις. Η προσέγγιση της ανάλυσης είναι βάσει κειμένου. Η έρευνα δεν είναι συγκριτική και πραγματοποιεί δύο ανεξάρτητες διεργασίες: τον εντοπισμό των ψευδών δημοσιευμάτων με LSTM και την μοντελοποίηση θεμάτων του σώματος κειμένων ανά αξιοπιστία με LDA· αποτυπώνεται μία ολοκληρωμένη εικόνα των δεδομένων που μπορεί να αποτελέσει πηγή πολλών στατιστικών και μη αναλύσεων. Εκτός από τα αποτελέσματα αναδεικνύονται τα στάδια του πειράματος και τα εργαλεία που συνέβαλλαν στην υλοποίηση και την διεξαγωγή του.

1. Μεγάλα Δεδομένα


Τα μέσα κοινωνικής δικτύωσης, οι όροι αναζήτησης (σε μηχανές αναζήτησης π.χ. google), το ηλεκτρονικό εμπόριο, οι εφαρμογές για smartphones, τα forums και πολλές άλλες πηγές εμπλουτίζουν αδιάκοπα το διαδίκτυο με νέες ποικίλων ειδών πληροφορίες. Τα είδη της πληροφορίας είναι μεταξύ άλλων εικόνες, βίντεο, κείμενα, προτιμήσεις, σχόλια, κριτικές, αγορές και δεδομένα συναλλαγών, όροι αναζήτησης, άρθρα, ειδήσεις κ.ά. Από το 2013 η εταιρεία Domo, που εξειδικεύεται σε λογισμικά επιχειρηματικής ευφυΐας και οπτικοποίησης δεδομένων, δημοσιεύει ετησίως μία γραφική αναπαράσταση των δεδομένων που παράγονται ανά λεπτό σε κάποιες από τις πιο διαδεδομένες διαδικτυακές υπηρεσίες καθώς και το σύνολο των χρηστών του διαδικτύου. Το 2012 οι χρήστες του διαδικτύου ανέρχονταν στα 2,5 δισεκατομμύρια ενώ το 2018 σε 4,39 δισεκατομμύρια αποτελώντας το 56,1% του συνολικού πληθυσμού του πλανήτη. Μερικά παραδείγματα υπολογισμών ανά δευτερόλεπτο είναι τα εξής:

- Twitter: αποστολή 511.200 tweets
- Instagram: μεταφόρτωση 55.140 φωτογραφιών
- Google: πραγματοποίηση 4.497.420 αναζητήσεων
- Venmo: διεξαγωγή 162.037 συναλλαγών
- Μηνύματα: 18.100.000

(Domo, 2018) Τμήμα της αναπαράστασης για το έτος 2018 φαίνεται στις παρακάτω εικόνες.



Σχήμα 1.1: Παγκόσμια Αύξηση των Χρηστών του Διαδικτύου (Domo, 2018)




Σχήμα 1.2: Δεδομένα που Παράγονται στο Διαδίκτυο ανά Λεπτό (Domo, 2018)

Όσον αφορά την ειδησεογραφία, η εφημερίδα *The Washington Post* δημοσιεύει 500 άρθρα και βίντεο ανά ημέρα, η *The New York Times* 230 και η *The Wall Street Journal* 240 (Robinson Meyer, 2016). Σύμφωνα με την *WordPress* οι χρήστες της πραγματοποιούν περισσότερες από 70 εκατομμύρια αναρτήσεις και 52,1 εκατομμύρια σχόλια. (Nick Galon, 2020)

Ο όγκος των δεδομένων αυξάνεται αντίστοιχα στους επιστημονικούς κλάδους και στις κυβερνήσεις. Στην ιατρική και την γενετική, παράδειγμα αποτελούν τα κλινικά δεδομένα και η ανάλυση του DNA αποσκοπώντας στην επιλογή της πιο κατάλληλης θεραπείας ανά τα δεδομένα του ασθενή (Big Data Analytics for Genomic Medicine, 2017). Σημαντική πηγή πληροφορίας αποτελούν τα δεδομένα που παράγονται από μηχανήματα όπως αισθητήρες, βιομηχανικό εξοπλισμό, κάμερες οδών, ιατρικές συσκευές, συσκευές Internet of Things (IoT) και δορυφόρων (CloudMogio). Το 2012 σε αναφορά από το ευρωπαϊκό κέντρο πυρηνικών ερευνών CERN αναγράφεται πως ο παραγόμενος όγκος δεδομένων ανά δευτερόλεπτο σε GB για πειράματα που διεξήχθησαν, κυμαίνεται από 600MB/s έως 4GB/s (CERN, 2012) (Gaillard, 2017), ενώ το 2017 αναφέρεται ότι έχουν αποθηκευτεί οριστικά 200 petabytes δεδομένων στο CERN Data DC (Gaillard, 2017). Τα κυβερνητικά δεδομένα όπως γεωχωρικά, υγειονομικά, οικονομικά, δεδομένα καιρού και δορυφόρων (Bwalya, 2018) αποτελούν μία αστείρευτη πηγή πληροφορίας.

Τα παραπάνω αποτελούν παραδείγματα Μεγάλων Δεδομένων (*Big Data*). Κατά καιρούς έχουν δοθεί διάφοροι ορισμοί για τα Μεγάλα Δεδομένα. Συνθέτοντας τους πιο κοινούς ορισμούς, τα Μεγάλα Δεδομένα είναι αδόμητα σύνολα πληροφοριών ποικίλων μορφοποιήσεων (format) και μεγάλου όγκου, που παράγονται ή/και μεταβάλλονται με πολύ γρήγορο ρυθμό. Μεγάλα Δεδομένα μπορούν να θεωρηθούν επίσης σύνολα, που δεν είναι απαραίτητα ογκώδη, παρουσιάζουν όμως υψηλές μεταβολές και αλληλεπιδράσεις-αλληλοσυσχετίσεις μεταξύ τους, γεγονός που απαιτεί μεγάλη υπολογιστική ισχύ για την επεξεργασία τους (Ward, et al., 2013).

Η παγκόσμια αγορά των μεγάλων δεδομένων αναμένεται να αυξηθεί στα 103 εκατομμύρια δολάρια (USD) έως το 2027 όπως φαίνεται στο παρακάτω διάγραμμα (Holst, 2018).



Διάγραμμα 1.1: Πρόβλεψη Μεγέθους της Αγοράς Μεγάλων Δεδομένων (Holst, 2018)

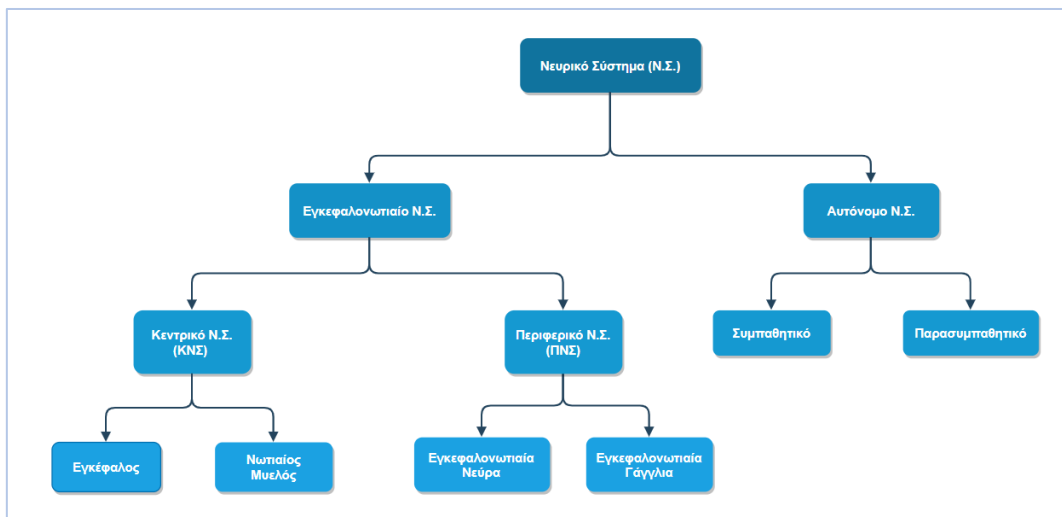
Παρά το γεγονός της αύξησης του όγκου και της πολυπλοκότητας των δεδομένων, η ικανότητα της επεξεργασίας και της αφομοίωσής τους από τον ανθρώπινο εγκέφαλο παραμένει ίδια. Κατά συνέπεια, η ανάπτυξη των μεγάλων δεδομένων επιτάσσει την χρήση τεχνολογιών της τεχνητής νοημοσύνης όπως η Μηχανική Μάθηση, η Βαθιά Μάθηση και όταν πρόκειται για δεδομένα που αφορούν την φυσική γλώσσα του ανθρώπου, την Επεξεργασία Φυσικής Γλώσσας.

2. Νευρωνικά Δίκτυα

Η έμπνευση της υλοποίησης των τεχνητών νευρωνικών δικτύων προήλθε από την βιολογία και πιο συγκεκριμένα από την παρατήρηση του νευρικού συστήματος των ζώντων οργανισμών και κυρίως του ανθρώπου (Eluyode, et al., 2013). Ένα νευρωνικό δίκτυο είναι ένα σύνολο διασυνδεδεμένων νευρώνων που λειτουργούν παράλληλα, δέχονται ερεθίσματα και παράγουν αποτελέσματα. Οι νευρώνες είναι η θεμελιώδης μονάδα του νευρικού συστήματος και θα αναλυθούν στην συνέχεια (Eluyode, et al., 2013) (Γεωργούλη, 2015). Τα τεχνητά νευρωνικά δίκτυα επιχειρούν να προσομοιώσουν τις διαδικασίες του νευρικού συστήματος. Με την ανάπτυξη των τεχνητών νευρωνικών δικτύων εκείνα των ζώντων οργανισμών ονομάστηκαν βιολογικά. (Αργυράκης, 2001)

2.1. Βιολογικά Νευρωνικά Δίκτυα

Οι λειτουργίες του ανθρώπινου σώματος, οι ενέργειες, τα αντανακλαστικά και οι αισθήσεις, συντονίζονται από το νευρικό σύστημα (University of Queensland, 2018) (Γεωργούλη, 2015). Το νευρικό σύστημα αποτελείται από δύο επιμέρους συστήματα, το σωματικό -ή ζωικό ή εγκεφαλονωτιαίο- και το αυτόνομο -ή φυτικό- (Φραγκοράπτης, 2015). Το εγκεφαλονωτιαίο νευρικό σύστημα ελέγχει τις συνειδητές λειτουργίες και διαμερίζεται στο Κεντρικό Νευρικό Σύστημα (ΚΝΣ) και στο Περιφερικό Νευρικό Σύστημα (ΠΝΣ). Το ΚΝΣ αποτελούν ο εγκέφαλος και ο νωτιαίος μυελός ενώ το ΠΝΣ αποτελείται από τα εγκεφαλονωτιαία νεύρα και γάγγλια. (Φραγκοράπτης, 2015) (University of Queensland, 2018) Το αυτόνομο νευρικό σύστημα είναι υπεύθυνο για την διαχείριση των ακούσιων λειτουργιών του οργανισμού, για παράδειγμα την ομοίωση, και τον συντονισμό των εσωτερικών οργάνων· αποτελείται από το συμπαθητικό και παρασυμπαθητικό νευρικό σύστημα. (Φραγκοράπτης, 2015) (University of Queensland, 2018) (The Editors of Encyclopaedia Britannica, 2019) Η βασική δομή του νευρικού συστήματος του ανθρώπου φαίνεται στο ακόλουθο διάγραμμα.




Διάγραμμα 2.1: Δομή Νευρικού Συστήματος

Η μονάδα επεξεργασίας του ανθρώπινου σώματος είναι το κεντρικό νευρικό σύστημα και αποτελείται από τον εγκέφαλο και τον νωτιαίο μυελό (University of Queensland, 2018) (Φραγκοράπτης, 2015) (Haines, et al., 2020). Το κεντρικό νευρικό σύστημα δέχεται και επεξεργάζεται τα σήματα των αισθητηρίων οργάνων και αποστέλλει σήματα στο περιφερικό νευρικό σύστημα για ενδεχόμενες ενέργειες· είναι επίσης υπεύθυνο για τις ανώτερες νοητικές

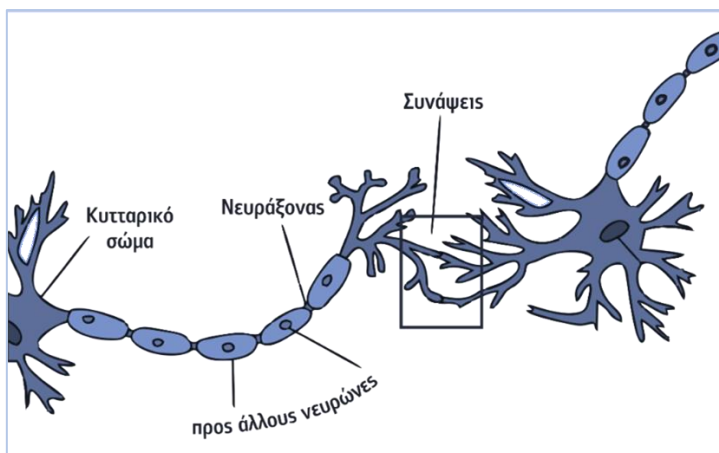
λειτουργίες (μάθηση, μνήμη, αντίληψη), τα συναισθήματα και την συμπεριφορά (Biswas-Diener, 2020) (Noback, et al., 2020). Η επικοινωνία πραγματοποιείται μέσω νευρικών κυττάρων τα οποία αποτελούν το θεμελιώδες συστατικό του νευρικού συστήματος και ονομάζονται νευρώνες. Στον εγκέφαλο έχουν εντοπιστεί 10^{11} νευρώνες οι οποίοι επικοινωνούν με άλλους νευρώνες και κύτταρα, μέσω ειδικών συνδέσεων που ονομάζονται συνάψεις (Biswas-Diener, 2020). Η μορφή ενός τυπικού νευρώνα συντελείται από τρία βασικά μέρη:

- Δενδρίτες
- Άξονας ή νευράξονας
- Κυτταρικό σώμα

Οι δενδρίτες λειτουργούν ως κεραίες, που λαμβάνουν εισόδους -ερεθίσματα- από άλλα κύτταρα, ο άξονας μεταφέρει εξόδους προς επικοινωνία με άλλους νευρώνες και στο σώμα βρίσκεται ο πυρήνας του κυττάρου (Γεωργούλη, 2015) (Biswas-Diener, 2020). Τα βασικά μέρη και οι συνάψεις ενός τυπικού νευρώνα φαίνονται στις παρακάτω εικόνες.



Σχήμα 2.1: Βασικά Μέρη Τυπικού Νευρώνα (Γεωργούλη, 2015)



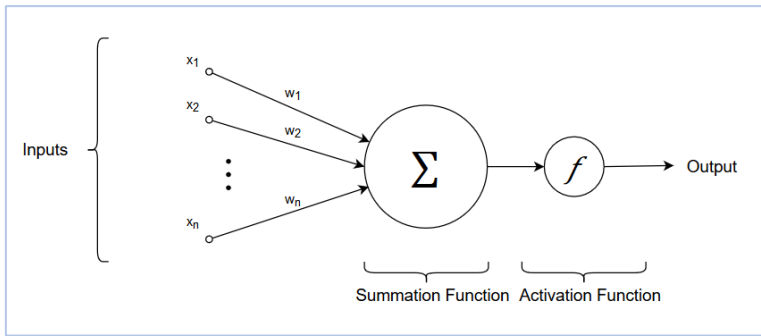
Σχήμα 2.2: Σύνδεση Φυσικών Νευρώνων (Γεωργούλη, 2015)

Όταν ο νευρώνας δεν δέχεται σήματα, διατηρεί ένα σταθερό μεμβρανικό δυναμικό, μία σταθερή διαφορά δυναμικού μεταξύ των περιοχών που βρίσκονται έσω και έξω από το κύτταρο· η κατάσταση αυτή ονομάζεται δυναμικό ηρεμίας και αντιστοιχεί σε περίπου -70mV . Το κατώφλιο δυναμικό, περίπου -50mV , είναι το κατώτατο όριο που χρειάζεται προκειμένου να δημιουργηθεί ένα σήμα προς αποστολή. Όταν ένας νευρώνας λαμβάνει ερεθίσματα, τότε μεταβάλλεται το δυναμικό της μεμβράνης του συναθροίζοντας τα δεχόμενα ερεθίσματα, και σε περίπτωση που η μεταβολή αυτή είναι μεγαλύτερη από το κατώφλιο δυναμικό παράγεται ένα ηλεκτρικό σήμα, το δυναμικό ενέργειας. Το δυναμικό ενέργειας, μέσω του άξονα, μεταφέρεται στην σύναψη ώστε να διαδοθεί σε άλλους νευρώνες. (University of Queensland, 2018) (Γεωργούλη, 2015) (Biswas-Diener, 2020) Σε μία επικοινωνία μεταξύ δύο νευρώνων, ο νευρώνας που στέλνει σήματα λέγεται προσυναπτικός και ο νευρώνας στον οποίο αποστέλλονται τα σήματα μετασυναπτικός. Οι συνάψεις μπορεί να είναι ηλεκτρικές ή χημικές. Στις ηλεκτρικές συνάψεις η μεταφορά του σήματος είναι άμεση ενώ στις χημικές έμμεση διότι τα κύτταρα δεν εφάπτονται. Η περιοχή μεταξύ των κυτταρικών μεμβρανών ονομάζεται συναπτικό χάσμα. Στις χημικές συνάψεις το δυναμικό ενέργειας προκαλεί στον προσυναπτικό νευρώνα την απελευθέρωση χημικών ουσιών, τους νευροδιαβιβαστές, οι οποίοι εκλύονται στο συναπτικό χάσμα και προκαλείται αλλαγή στο μετασυναπτικό δυναμικό. Στην σύναψη του μετασυναπτικού νευρώνα το χημικό σήμα των νευροδιαβιβαστών μετατρέπεται ξανά σε ηλεκτρικό, και ανάλογα με το είδος της σύναψης και το είδος του νευροδιαβιβαστή μπορεί το σήμα να ενισχυθεί ή να μειωθεί. (University of Queensland, 2018)


2.2. Τεχνητά Νευρωνικά Δίκτυα

Ένα Τεχνητό Νευρωνικό Δίκτυο (ΤΝΔ, Artificial Neural Network - ANN) είναι ένα υπολογιστικό μοντέλο, η δομή του οποίου αποτελεί μία αφαιρετική προσομοίωση της λειτουργίας του ΚΝΣ και των νευρώνων (Eluyode, et al., 2013). Δεδομένου ενός σύνθετου (συνήθως μη γραμμικού) προβλήματος και σχετικών συνόλων δεδομένων, τα τεχνητά νευρωνικά δίκτυα χρησιμοποιούν τεχνικές μάθησης ώστε να αντλήσουν συσχετίσεις από τα δεδομένα και να αποκτήσουν γνώση την οποία μπορούν να επαναχρησιμοποιήσουν ώστε να επιλύσουν το πρόβλημα λαμβάνοντας ως παραμέτρους καινούρια δεδομένα -σχετικά πάντα με το αντικείμενο του προβλήματος (Graupe, 2007). Δείγμα δημοφιλών κατηγοριών προβλημάτων όπου αξιοποιούνται ΤΝΔ αποτελούν η κατανόηση προφορικού λόγου, η κατανόηση και μετάφραση γραπτού λόγου, η αναζήτηση βάσει εικόνας (αναγνώριση παρόμοιων εικόνων), η αναγνώριση προτύπων, η αναλυτική προβλέψεων (predictive analytics), οι έξυπνοι βοηθοί, τα αυτοκινούμενα αυτοκίνητα.

Οι νευρώνες στα ΤΝΔ αναφέρονται και ως κόμβοι ή μονάδες. Ένα ΤΝΔ αποτελείται από διασυνδεδεμένες επεξεργαστικές μονάδες οργανωμένες σε επίπεδα, και κάθε μεταξύ τους σύνδεση έχει κάποιο συντελεστή βάρους (weight), προσομοιώνοντας έτσι τις συνάψεις. Οι επεξεργαστικές μονάδες είναι μαθηματικές συναρτήσεις που δέχονται εισόδους (σήματα-ερεθίσματα) και παράγουν εξόδους οι οποίες δυναμικά προωθούνται ως εισόδοι σε άλλους νευρώνες. Σε ένα τεχνητό νευρώνα μετά την λήψη σημάτων υπολογίζεται το σταθμισμένο άθροισμά τους με μία συνάρτηση αθροίσματος (summation function). Στην συνέχεια εφαρμόζεται σε αυτό μία συνάρτηση ενεργοποίησης (activation function) ή συνάρτηση μεταφοράς (transfer function) παράγοντας την τιμή εξόδου η οποία μπορεί να αποσταλεί σε άλλες μονάδες. Η συνάρτηση ενεργοποίησης μετατρέπει το σήμα εξόδου σε κατάλληλη μορφή (π.χ. να αντιστοιχεί σε ορισμένο εύρος τιμών) ώστε να μπορεί να αποτελέσει τιμή εισόδου σε άλλη μονάδα επεξεργασίας. Επικρατεί το σήμα εξόδου να αντιστοιχίζεται σε συνεχείς τιμές εντός των εκάστοτε ορίων ώστε να χρησιμοποιηθεί έπειτα η εύρεση της σύγκλισης των τιμών με την μέθοδο της σταδιακής καθόδου (gradient descent) η οποία προαπαιτεί μία συνάρτηση σφάλματος (cost function). Οι σχηματικές αναπαραστάσεις ενός βασικού τεχνητού νευρώνα και τμήματος ενός απλού τεχνητού νευρωνικού δικτύου φαίνονται στα σχήματα Σχήμα 2.3 και Σχήμα 2.4. (Eluyode, et al., 2013) (Βλαχάβας, et al., 2006) (Γεωργούλη, 2015) (Graupe, 2007)



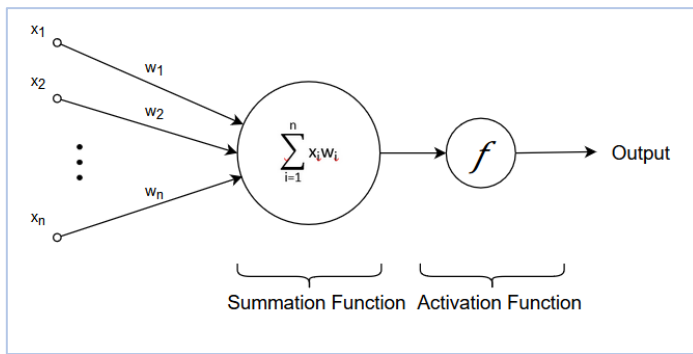
Σχήμα 2.3: Μοντέλο Τεχνητού Νευρώνα



Σχήμα 2.4: Δομή Τεχνητού Νευρωνικού Δικτύου

Ιστορικά, ο νευρώνας Perceptron ήταν από τους πρώτους νευρώνες που επινοήθηκαν και αποτελεί δομικό στοιχείο των ΤΝΔ ακόμη και σήμερα. Χρονολογείται στο 1958 και προτάθηκε από τον Frank Rosenblatt το 1957. Ο Perceptron (Σχήμα 2.5) χρησιμοποιεί την συνάρτηση αθροίσματος (2.1) (Γεωργούλη, 2015) (Graupe, 2007). Ο τεχνητός νευρώνας Adaline (ADaptive Linear NEuron) που προτάθηκε από τον B. Widrow το 1960, προσθέτει μία σταθερά πόλωσης (bias) στην συνάρτηση αθροίσματος του Perceptron για να εκπαιδεύσει τα βάρη (2.2). Μία συνάρτηση προσήμου (signum) (2.3) μετατρέπει τις εξόδους εντός των ορίων [-1, 1] και αποτελεί μία λειτουργία κατωφλίου (threshold). Ο Adaline θεωρείται ως ειδική υλοποίηση του Perceptron. (Graupe, 2007)

$$\sum_{i=1}^n x_i w_i \tag{2.1}$$



Σχήμα 2.5: Μοντέλο Νευρώνα Perceptron


$$z = \sum_{i=1}^n w_0 + x_i w_i \quad (2.2)$$

$$y = \text{sgn}(z) \quad (2.3)$$

Ενώ επικρατούσε ο ισχυρισμός πως οι μονάδες Perceptron μπορούν να επιλύσουν οποιοδήποτε πρόβλημα, έρευνες των Minsky και Perpert το 1969 υπέδειξαν πως μπορεί να λύσει μόνο προβλήματα γραμμικά διαχωρίσιμων δεδομένων, αναφέροντας χαρακτηριστικά το παράδειγμα της επίλυσης της δυαδικής πράξης XOR. Η διαπίστωση αυτή είχε ως αποτέλεσμα την προσθήκη περισσότερων επιπέδων από perceptrons, τα λεγόμενα κρυφά επίπεδα (hidden layers), καθιστώντας τα ΤΝΔ ικανά να ανταποκριθούν σε μη γραμμικά διαχωρίσιμα δεδομένα (Graupe, 2007) (Γεωργούλη, 2015). Πολυεπίπεδα ΤΝΔ χρησιμοποιούνται στα περισσότερα σύγχρονα προβλήματα. Η τοπολογία του δικτύου και παράμετροι που καθορίζουν τον τύπο του νευρώνα, διαμορφώνονται βάσει του εκάστοτε προβλήματος στο οποίο το δίκτυο καλείται να ανταποκριθεί.

Ένα ΤΝΔ αποτελείται από τρία βασικά επίπεδα (layers) και κάθε επίπεδο αποτελείται από νευρώνες (Σχήμα 2.6):

- *Επίπεδο Εισόδου (Input Layer)*: Λαμβάνεται η είσοδος του ΤΝΔ
- *Κρυφό Επίπεδο (Hidden Layer)*: Επεξεργάζονται τα δεδομένα εισόδου
- *Επίπεδο Εξόδου (Output Layer)*: Υπολογίζεται το αποτέλεσμα



Σχήμα 2.6: ΤΝΔ Τεσσάρων Επιπέδων με Δύο Κρυφά Επίπεδα (Nielsen, 2015)

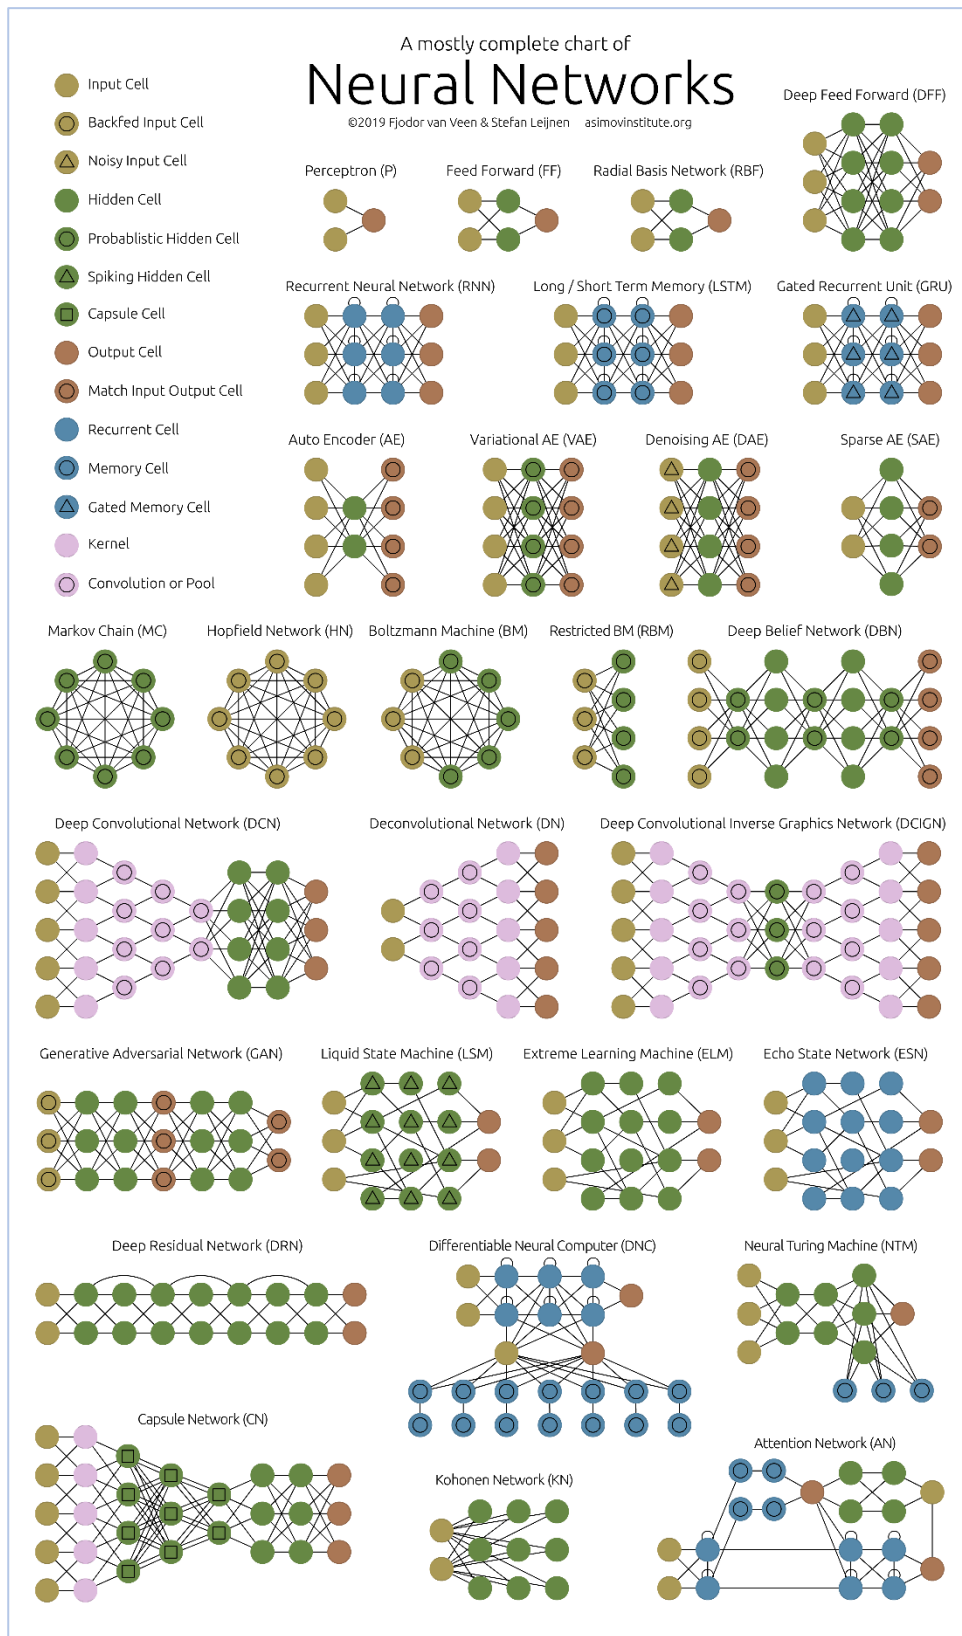
Τα ΤΝΔ διαχωρίζονται σε δύο βασικές κατηγορίες αρχιτεκτονικής όσον αφορά τον τρόπο διασύνδεσης των νευρώνων (Γεωργούλη, 2015):

- *Πρόσθιας τροφοδότησης (feed forward)*: Οι μονάδες κάθε επιπέδου τροφοδοτούν τις μονάδες του επόμενου
- *Οπίσθιας τροφοδότησης (feed backward)*: Οι μονάδες κάθε επιπέδου μπορούν να τροφοδοτούν μονάδες προηγούμενων, επόμενων ή και του ίδιου επιπέδου

Έχουν αναπτυχθεί διάφορες αρχιτεκτονικές ΤΝΔ (Σχήμα 2.7) οι οποίες εξυπηρετούν ομάδες προβλημάτων και η παρουσίαση κάθε μίας από αυτές δεν είναι στα πλαίσια της παρούσας έρευνας.

Η μάθηση στα ΤΝΔ εφαρμόζει τεχνικές μηχανικής μάθησης με βασικές να αποτελούν η μάθηση με επίβλεψη (*supervised learning*), όπου η επιθυμητή έξοδος είναι γνωστή, και η μάθηση χωρίς επίβλεψη (*unsupervised learning*) όπου οι έξοδοι δεν είναι γνωστοί (Γεωργούλη, 2015) (Graupe, 2007) (Sarveralli, 2015). Η διαδικασία εκπαίδευσης ανάγεται στον υπολογισμό και την προσαρμογή των συνδεσμικών βαρών και χρησιμοποιεί αλγόριθμους όπως ο αλγόριθμος οπισθοδιάδοσης λάθους, η ανταγωνιστική και η τυχαία μάθηση (Γεωργούλη, 2015) (Βλαχάβας, et al., 2006).

Τεχνητά νευρωνικά δίκτυα με πολλαπλά κρυφά επίπεδα συνδεδεμένων νευρώνων ονομάζονται Βαθιά Νευρωνικά Δίκτυα (ΒΝΔ, *Deep Neural Networks - DNN*). Εκτός από το πλήθος των κρυφών επιπέδων και των συνδέσεων είναι πιο πολύπλοκα και απαιτητικά από υπολογιστική άποψη και από άποψη υλικού (Sarveralli, 2015). Θα αναλυθούν στην συνέχεια οι βαθιές αρχιτεκτονικές RNN και LSTM οι οποίες σχετίζονται με το πρόβλημα της παρούσας έρευνας και συναντώνται ευρέως σε σύγχρονες εφαρμογές NLP. Η εκπαίδευση ΒΝΔ αναφέρεται ως Βαθιά Μάθηση (*Deep Learning*) και έχει αποδειχθεί εξαιρετικά ισχυρή και αποδοτική (Leshkovec, et al., 2020).



Σχήμα 2.7: Αρχιτεκτονικές ΤΝΔ

2.3. Τεχνικές Βαθιάς Μάθησης

Η προσθήκη επιπέδων στις βαθιές αρχιτεκτονικές των ΤΝΔ αυξάνει τις διασυνδέσεις μεταξύ των νευρώνων και των επιπέδων, γεγονός που αυξάνει τους υπολογισμούς και απαιτεί περισσότερο χρόνο εκπαίδευσης. Η εμφάνιση των GPU (και αργότερα των TPU) αποδείχθηκε άκρως βοηθητική στην επίλυση του χρονικού προβλήματος, επιτρέποντας υψηλότερη παραλληλοποίηση από τις πολυπύρηνες CPU (Multi-core CPU). Τα ΒΝΔ χρειάζονται πλήθος δεδομένων ώστε να εκπαιδευτούν και ισχύει πως όσο περισσότερη γνώση δίνεται σε ένα ΒΝΔ τόσο πιο ισχυρό θα είναι. Τα Μεγάλα Δεδομένα συμπλήρωσαν αυτή την παράμετρο. Οι συνδυασμοί των παραπάνω έδωσαν νέα ώθηση στην Βαθιά Μάθηση. (Nielsen, 2015) (Najafabadi, et al., 2015) (Leskovec, et al., 2020)

Στην συνέχεια περιγράφονται αρχιτεκτονικές, συναρτήσεις ενεργοποίησης, συναρτήσεις σφάλματος και κανονικοποιητές, που χρησιμοποιούνται σε εφαρμογές ΒΝΔ.

2.3.1. Αρχιτεκτονικές Βαθίων Νευρωνικών Δικτύων


Σε βάθος χρόνου έχουν αναπτυχθεί αρχιτεκτονικές ΒΝΔ για πληθώρα κατηγοριών προβλημάτων όπως υπολογιστική όραση, προβλέψεις, εφαρμογές NLP, αναγνώριση φωνής, επεξεργασία video, αναλυτική Big Data, αυτόνομα οχήματα (Najafabadi, et al., 2015) (Sengupta, et al., 2020). Δημοφιλείς αρχιτεκτονικές ανά κατηγορία εφαρμογής συνοψίζονται στον ακόλουθο πίνακα (Jones, 2017).

Πίνακας 2-1: Αρχιτεκτονικές ΒΝΔ ανά Πεδίο Εφαρμογής

Αρχιτεκτονική	Εφαρμογή
RNN	Αναγνώριση φωνής, αναγνώριση γραφής
LSTM/GRU	Διαδικασίες NLP, αναγνώριση γραφής, αναγνώριση φωνής
CNN	Υπολογιστική όραση, αναγνώριση εικόνας, επεξεργασία video
DBN	Αναγνώριση εικόνας, NLU, προβλέψεις, ανάκτηση πληροφορίας
DSN	Ανάκτηση πληροφορίας, αναγνώριση φωνής

Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks - RNN)

Η αρχιτεκτονική RNN (Σχήμα 2.8) έχει αποτελέσει βάση για την δημιουργία βαθίων αρχιτεκτονικών και προσφέρει την δυνατότητα επεξεργασίας ακολουθιών (sequences) και χρονολογικών σειρών (time series), προσομοιώνοντας ένα είδος μνήμης όσον αφορά την προϋπάρχουσα γνώση του δικτύου. Η αναδρομή επιτρέπει σε νευρώνες διάφορων επιπέδων να επικοινωνούν μεταξύ τους διαμοιράζοντας την παρελθοντική γνώση ώστε να μοντελοποιούν το πρόβλημα σε βάθος χρόνου. Τα RNN διαθέτουν εισόδους σε κάθε επίπεδο και όχι μόνο στο επίπεδο εισόδου όπως είθισται σε άλλες αρχιτεκτονικές. Σε κάθε χρονική στιγμή ο νευρώνας λαμβάνει τα δεδομένα εισόδου και τα δεδομένα εξόδου από νευρώνες του κρυφού επιπέδου τα οποία έχουν μορφοποιήσει προηγούμενες χρονικές στιγμές. (Leskovec, et al., 2020) (Nielsen, 2015) (Jones, 2017)



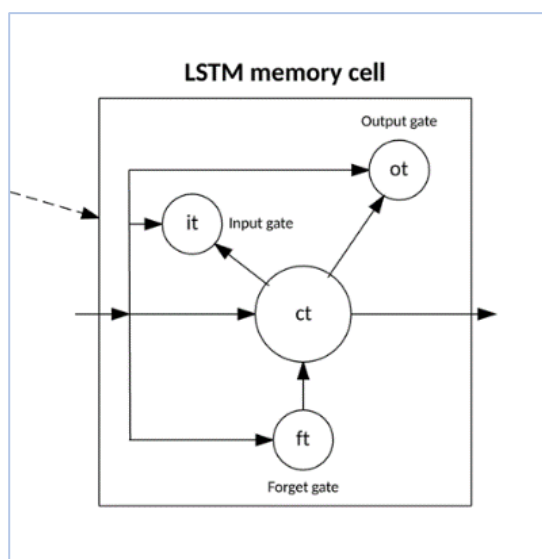
Σχήμα 2.8: RNN (Jones, 2017)

Η ύπαρξη της μνήμης και ο τρόπος αξιοποίησης της μακράς και της βραχείας, αποκάλυψε ένα ενδεχόμενο πρόβλημα στα RNN. Υπάρχουν περιπτώσεις που αναλόγως τον τρόπο υπολογισμού των βαρών τα οποία προέρχονται από διασυνδέσεις με κρυφά επίπεδα, η σημασία (βάρος) παλαιότερης πληροφορίας μπορεί να υποτιμηθεί (εξαφανιστεί) και νεότερης πληροφορίας μπορεί να υπερεκτιμηθεί (εκτοξευθεί). Το πρόβλημα αυτό είναι γνωστό ως εξαφάνιση ή εκτόξευση της κλίσης (vanishing exploding gradient problem) και το επιλύει μία ειδική παραλλαγή των RNN, τα δίκτυα Long Short-Term Memory που προτάθηκαν από τους Hochreiter και Schmidhuber το 1997 (Leskovec, et al., 2020) (Nielsen, 2015) (Jones, 2017).

Long Short-Term Memory

Τα δίκτυα LSTM αποτελούν μία βελτίωση των RNN προς μία κατεύθυνση επίλυσης του προβλήματος της διαχείρισης εξαρτήσεων μακράς και βραχείας μνήμης. Οι βελτιώσεις πρόσθεσαν την δυνατότητα στο δίκτυο να ξεχνά πληροφορίες, να αποθηκεύει συγκεκριμένες πληροφορίες και να εστιάζει μόνο σε τμήματα της μνήμης άμεσα σχετιζόμενα υπό μία συγκεκριμένη οπτική (π.χ. μόνο σε συγκεκριμένα χαρακτηριστικά που αφορούν την τρέχουσα είσοδο). Η διαδικασία αυτή πραγματοποιείται με την προσθήκη ενός διάνυσματος καταστάσεων του κυττάρου (cell state) και πυλών (gates) όπου αποφασίζεται ποια πληροφορία θα προωθηθεί. Σε κάθε χρονική στιγμή αποστέλλεται ένα διάνυσμα κρυφών καταστάσεων (όπως στα RNN) και ένα διάνυσμα καταστάσεων κυττάρου. Σε κάθε πύλη αντιστοιχεί ένα βάρος με το οποίο συνυπολογίζονται τα αντίστοιχα διανύσματα προκειμένου να παραχθεί η έξοδος: οι πύλες που

συναντώνται στα LSTM (Σχήμα 2.9) είναι εισόδου (input gate), εξόδου (output gate) και λήθης (forget gate). (Jones, 2017) (Leskovec, et al., 2020) (Sengupta, et al., 2020)



Σχήμα 2.9: Κύτταρο Μνήμης LSTM (Jones, 2017)

2.3.2. Συναρτήσεις Ενεργοποίησης

Οι συναρτήσεις ενεργοποίησης αντιστοιχίζουν την έξοδο του νευρώνα σε συνεχείς τιμές εντός επιλεγμένου εύρους· θα πρέπει να είναι συνεχείς και διαφορίσιμες και η παράγωγός τους να μην μεγαλώνει ή μικραίνει πολύ εντός των ορίων ενδιαφέροντος. Οι συναρτήσεις εφαρμόζονται σε κάθε στοιχείο του διανύσματος. Τα πιο δημοφιλή είδη συναρτήσεων ενεργοποίησης στα ΒΝΔ είναι σιγμοειδείς συναρτήσεις (sigmoid), υπερβολική εφαπτομένη (hyperbolic tangent - tahn), εκθετική συνάρτηση softmax και συνάρτηση ReLU (REctified Linear Unit) (Σχήμα 2.10: Συναρτήσεις Ενεργοποίησης). (Leskovec, et al., 2020)

Από τις σιγμοειδείς συναρτήσεις συνήθως γίνεται χρήση της λογιστικής παλινδρόμησης (2.4) η τιμή της οποίας είναι μεταξύ $[0, 1]$. Για υψηλές αρνητικές τιμές του x η συνάρτηση πλησιάζει το 0 και για υψηλές θετικές τιμές το 1.

$$\sigma(x) = \frac{1}{1 + e^{-x}} = \frac{e^x}{1 + e^x} \quad (2.4)$$

Η υπερβολική εφαπτομένη (2.5) αποτελεί μία μετατόπιση και κλιμάκωση της λογιστικής παλινδρόμησης με κέντρο το 0, συνεπώς παίρνει τιμή στο διάστημα $[-1, 1]$.


$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.5)$$

Η συνάρτηση ReLU (2.6) δεν είναι διαφορίσιμη στο 0, αλλά σε όλα τα άλλα σημεία τα οποία συμπεριλαμβάνουν τις τιμές κοντά στο 0. Για αρνητικές τιμές του x η κλίση της είναι 0. Επειδή απαιτεί απλούς αριθμητικούς υπολογισμούς υπερτερεί σε ταχύτητα εκτέλεσης.

$$f(x) = \max(0, x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (2.6)$$

Η συνάρτηση softmax εφαρμόζεται σε ολόκληρο το διάνυσμα και η έξοδος της μπορεί να θεωρηθεί πως υπολογίζει μία κατανομή πιθανότητας των στοιχείων. Δεδομένου ενός διανύσματος $x = [x_1, x_2, \dots, x_n]$ η τιμή της υπολογίζεται από την σχέση (2.7) (Leskovec, et al., 2020).

$$s(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (2.7)$$



Σχήμα 2.10: Συναρτήσεις Ενεργοποίησης

2.3.3. Συναρτήσεις Σφάλματος

Η συνάρτηση σφάλματος (cost function) εφαρμόζεται στο επίπεδο εξόδου των ΒΝΔ και υπολογίζει τον μέσο όρο των σφαλμάτων που παρατηρήθηκαν στις προβλέψεις του δικτύου κατά την φάση εκπαίδευσης. Οι πιο συχνά εμφανιζόμενες συναρτήσεις είναι το μέσο τετραγωνικό σφάλμα (mean Squared Error - MSE) και η δισταυρωμένη εντροπία (binary, categorical, sparse categorical cross-entropy) οι οποίες επιλέγονται ανάλογα με το είδος του προβλήματος (π.χ. κατηγοριοποίηση, διακριτή έξοδος). (Leskovec, et al., 2020)

2.3.4. Κανονικοποίηση

Παρά τον υπολογισμό των παραμέτρων που αφορά κυρίως την καλή απόδοση του μοντέλου στην συλλογή εκπαίδευσής του, υπάρχουν περιπτώσεις κατά τις οποίες το μοντέλο δεν είναι αποδοτικό σε δεδομένα εκτός του συνόλου εκπαίδευσης (overfitting). Για την εξομάλυνση του φαινομένου αυτού, μπορούν να δοκιμαστούν, μεταξύ άλλων, οι τεχνικές dropout, norm penalties και EarlyStopping.

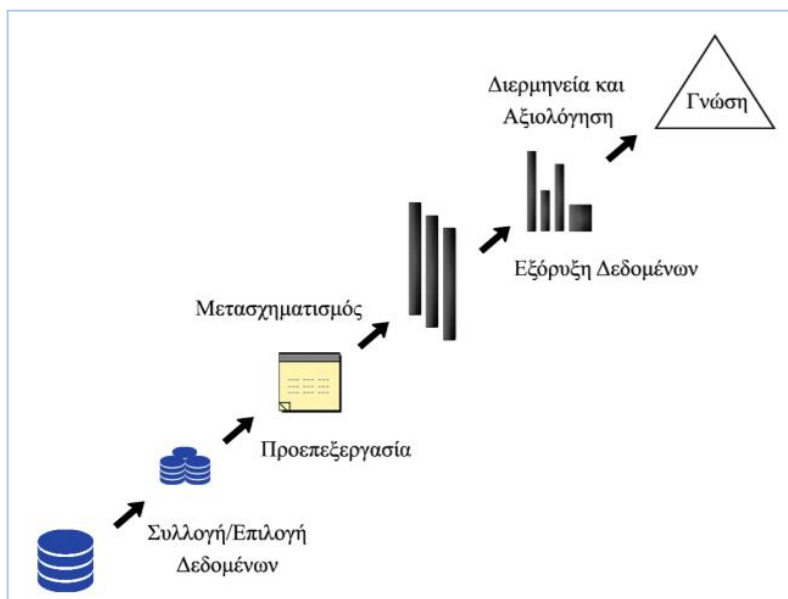
Στο προαιρετικό επίπεδο dropout, επιλέγεται ένα ποσοστό τυχαίων νευρώνων των οποίων οι έξοδοι θα αγνοηθούν. Norm penalties είναι νόρμες που μπορούν να εφαρμοστούν σε διάφορα σημεία, όπως στον πυρήνα, στο κατώφλι ή στο επίπεδο, και συμβάλλουν στον υπολογισμό του σφάλματος: λαμβάνουν υπόψη τις τοπικές τιμές και επηρεάζουν τα βάρη. Συνήθως χρησιμοποιούνται οι νόρμες L1, L2. Η τεχνική EarlyStopping προλαμβάνει την συνέχιση της εκπαίδευσης εφόσον θεωρηθεί (βάσει παραμέτρων που επιλέγονται) πως δεν ευνοεί πλέον το μοντέλο (Leskovec, et al., 2020) και υπάρχει δυνατότητα ανάκτησης των προηγούμενων βαρών.

3. Εξόρυξη και Ανακάλυψη Γνώσης

3.1. Ανακάλυψη Γνώσης σε Βάσεις Δεδομένων

Η Ανακάλυψη Γνώσης σε Βάσεις Δεδομένων (Knowledge Discovery in Databases - KDD) είναι η διαδικασία εντοπισμού χρήσιμων συσχετίσεων σε πολύπλοκες και μεγάλο όγκου συλλογές δεδομένων. Περιλαμβάνει την επιλογή των δεδομένων, την επεξεργασία τους, την εφαρμογή αλγορίθμων και την ερμηνεία των αποτελεσμάτων. Ο πυρήνας των εφαρμογών KDD είναι η Εξόρυξη Δεδομένων (Data Mining). (Maimon, et al., 2005) Η διαδικασία της ανακάλυψης γνώσης αποτελείται από τα παρακάτω βασικά στάδια:

1. *Επιλογή Δεδομένων*: Επιλέγεται ή δημιουργείται το σύνολο των δεδομένων στο οποίο θα εφαρμοστεί η διαδικασία. Συχνά η συλλογή δεδομένων χρειάζεται να δημιουργηθεί ώστε να καλύπτει τις ανάγκες του προς επίλυση προβλήματος (π.χ. με κάποια όψη (view), με ανάκτηση πληροφοριών από το διαδίκτυο κ.ά.). Η επιλογή δεδομένων είναι πολύ σημαντική διότι τα μοντέλα θα μάθουν και θα αναπτυχθούν από αυτή.
2. *Προ-επεξεργασία*: Αναφέρεται και ως καθαρισμός δεδομένων. Τα δεδομένα μπορεί να περιέχουν θόρυβο, να είναι ελλιπή ή να παρουσιάζουν ασυνέπειες. Στο στάδιο αυτό εφαρμόζονται τεχνικές για την απαλλαγή των ανωμαλιών ώστε τα δεδομένα να είναι ποιοτικά και να οδηγήσουν σε ορθά πρότυπα.
3. *Μετασχηματισμός*: Τα δεδομένα προσαρμόζονται στις απαιτήσεις της εκάστοτε μεθόδου ανάλυσης ώστε να διευκολυνθεί η ανακάλυψη γνώσης.
4. *Εξόρυξη Δεδομένων*: Αρχικά καθορίζεται το είδος της προς αναζήτηση γνώσης και επιλέγεται ο κατάλληλος αλγόριθμος που θα εφαρμοστεί. Στην συνέχεια εκτελείται ο αλγόριθμος παράγοντας τα πρότυπα.
5. *Ερμηνεία και Αξιολόγηση*: Αξιολογούνται τα πρότυπα που παράχθηκαν από την εξόρυξη δεδομένων. Για την ερμηνεία και την αναπαράσταση της γνώσης συνήθως χρησιμοποιούνται τεχνικές οπτικοποίησης. Αν τα αποτελέσματα δεν είναι ικανοποιητικά τα στάδια επαναλαμβάνονται. (Βλαχάβας, et al., 2006) (Κύρκος, 2015) (Βερούκιος, et al., 2015)



Σχήμα 3.1: Βασικά Στάδια KDD (Βερούκιος, et al., 2015)

Η Εξόρυξη Δεδομένων (*Data Mining*) είναι η αυτόματη ή ημιαυτόματη διαδικασία εύρεσης προτύπων από μεγάλο όγκο δεδομένα. Η αναζήτηση αφορά κανονικότητες, μοτίβα, κρυφές ή ήδη γνωστές συσχετίσεις. Τα πρότυπα ή τα μοντέλα που παράγονται θα πρέπει να έχουν νόημα και να προσφέρουν κάποιο πλεονέκτημα. (Witten, et al., 2011) (Jiawei Han, 2011) (Witten I. H., 2000) Η Εξόρυξη Δεδομένων αποτελεί στάδιο της KDD και συχνά χρησιμοποιείται λανθασμένα για να περιγράψει όλη την διαδικασία KDD ενώ ουσιαστικά αφορά τον ορισμό της προς αναζήτηση γνώσης, την επιλογή του αλγορίθμου που θα εφαρμοστεί για την ανακάλυψή της και απαραίτητες διαδικασίες προκειμένου να γίνει αυτό εφικτό μέσω του αλγορίθμου (Βλαχάβας, et al., 2006). Μπορεί να εφαρμοστεί Περιγραφική (*descriptive*) ή Προγνωστική (*predictive*) Ανάλυση. Στην Περιγραφική Ανάλυση σκοπός είναι ο εντοπισμός ομαδοποιήσεων και ιδιοτήτων των δεδομένων και στην Προγνωστική Ανάλυση η πρόβλεψη μελλοντικών ή αγνώστων τιμών κάποιων μεταβλητών. (Κύρκος, 2015) (Βερούκιος, et al., 2015) Τα είδη γνώσης που προκύπτουν είναι:

- *Μοντέλα Πρόβλεψης (Predictive Models)*: Προβλέπουν την τιμή κάποιας μεταβλητής
- *Πρότυπα Πληροφόρησης (Informative Patterns)*: Περιγράφουν τις συσχετίσεις μεταξύ των δεδομένων (Βλαχάβας, et al., 2006)

Μία ειδική περίπτωση δεδομένων είναι τα κείμενα. Ο κλάδος της Ανακάλυψης Γνώσης από Κείμενα (Knowledge Discovery from Text – KDT, Text Mining) ακολουθεί τα ίδια βασικά στάδια με την KDD προσαρμοσμένα στις ανάγκες των δεδομένων γραπτής φυσικής γλώσσας χρησιμοποιώντας τεχνολογίες της NLP (Lata, 2015) και θα αναλυθούν στην συνέχεια.

3.2. Επεξεργασία Φυσικής Γλώσσας και Ανακάλυψη Γνώσης από Κείμενα

Οι διεπιστημονικοί κλάδοι Επεξεργασία Φυσικής Γλώσσας και Ανακάλυψης Γνώσης από Κείμενα συνδυάζουν την γλωσσολογία, την στατιστική και την τεχνητή νοημοσύνη με σκοπό την μετατροπή της αδόμητης φυσικής γλώσσας που χρησιμοποιείται από τους ανθρώπους σε δομημένη μορφή που μπορεί να επεξεργαστεί και να κατανοηθεί από τους υπολογιστές (Eisenstein, 2019) (Lata, 2015). Ένας τομέας της NLP είναι η Κατανόηση Φυσικής Γλώσσας (Natural Language Understanding - NLU). Η χρήση τεχνολογιών NLP και NLU έχει διεισδύσει στην καθημερινότητα των αμθρώπων με μερικά παραδείγματα να αποτελούν οι μηχανές αναζήτησης, η αυτόματη μετάφραση, η αυτόματη διόρθωση, το λογισμικό Siri της εταιρείας Apple, οι συσκευές Alexa και Google Home των εταιρειών Amazon και Google αντίστοιχα, τα chatbots και η κατηγοριοποίηση των ανεπιθύμητων μηνυμάτων ηλεκτρονικού ταχυδρομείου.

Η διπλή φύση της γλώσσας (συντακτική, σημασιολογική) συμβάλλει ενίοτε στην ύπαρξη ασαφειών και αμφισημίας, γεγονός που προσθέτει δυσκολία στην επεξεργασία φυσικής γλώσσας. Σε πολλές περιπτώσεις το νόημα μίας λέξης ή μίας ορθής συντακτικά πρότασης επιδέχεται πολλές ερμηνείες. Ασάφειες μπορεί να παρουσιαστούν μεμονωμένα ή συνδυαστικά στα ακόλουθα επίπεδα:

- *Λεξιλογικό*: Μία λέξη δεν είναι μονόσημη π.χ. «Ο τόνος που χρησιμοποίησε ήταν λάθος.» Η λέξη τόνος μπορεί να σημαίνει το γραπτό ή προφορικό ύφος, το σημείο στίξης ή το ψάρι.
- *Συντακτικό*: Σε μία πρόταση διαφορετικές συντακτικές αναλύσεις παράγουν διαφορετική ερμηνεία π.χ. «Είδαν τον Χ στο πάρκο με τα τριαντάφυλλα.» Δεν είναι σαφές αν το πάρκο έχει τριαντάφυλλα ή αν ο Χ κρατούσε τριαντάφυλλα.
- *Αναφορικό*: Μία αναφορά είναι διφορούμενη π.χ. «Ο Χ έπαιξε κιθάρα στον Υ επειδή του αρέσει η μουσική.» Δεν είναι σαφές σε ποιον αρέσει η μουσική.
- *Σημασιολογικό*: Μία πρόταση ερμηνεύεται με πολλούς τρόπους χωρίς να αλλάζει η συντακτική της ανάλυση όπως σε φράσεις που χρησιμοποιούνται μεταφορικά π.χ. «Ο Χ έφυγε από την εταιρεία.» Ο Χ μπορεί να εξήλθε από το κτίριο, να απολύθηκε ή να παραιτήθηκε από την εταιρεία.

- **Πραγματολογικό:** Μία πρόταση περιέχει ασάφειες και δεν παρέχει το πλαίσιο ώστε αυτές να αποσαφηνιστούν π.χ. «Τα μαμούθ ζούσαν στην Γη πριν πολλά χρόνια.» Δεν είναι σαφές πόσα χρόνια θεωρούνται πολλά.

(Γεωργούλη, 2015)

Προκειμένου να μετατραπεί η γλώσσα σε δομημένη πληροφορία ώστε να αναλυθεί από αλγορίθμους είναι απαραίτητες οι διεργασίες KDT. Δεδομένης μίας συλλογής κειμένων, εφαρμόζεται αρχικά η προ-επεξεργασία τους, η κανονικοποίηση και στο τελευταίο στάδιο ο μετασχηματισμός. Στόχος είναι να διακριθεί η πληροφορία από τον θόρυβο και να μετατραπεί σε κατάλληλη δομή. Οι διεργασίες προ-επεξεργασίας που μπορούν να εφαρμοστούν είναι οι εξής: (Lata, 2015)

- **Λεξική Ανάλυση (Tokenization):** Το κείμενο διασπάται σε όρους (*tokens*). Π.χ. το κείμενο: «*If you thought that science was certain - well, that is just an error on your part. — Richard P. Feynman*» θα μετατραπεί στην ακολουθία: «'If', 'you', 'thought', 'that', 'science', 'was', 'certain', '-', 'well', ',', 'that', 'is', 'just', 'an', 'error', 'on', 'your', 'part', '.', '—', 'Richard', 'P', ',', 'Feynman'».
- **Αφαίρεση Τερματικών Όρων (Stopwords):** Αφαιρούνται από το κείμενο όροι που δεν προσφέρουν πληροφορία για το προς επίλυση πρόβλημα. Τέτοιοι όροι είναι συνήθως λέξεις που χρησιμοποιούνται πολύ συχνά στα κείμενα και μέρη του λόγου όπως άρθρα, αντωνυμίες κ.ά. Αναλόγως το πρόβλημα, μπορεί να κριθεί σκόπιμη η αφαίρεση αριθμών, σημείων στίξης και πολύ μικρών λέξεων. Αν εφαρμοστούν τα παραπάνω, το προαναφερθέν παράδειγμα θα μετατραπεί στην ακολουθία: «'thought', 'science', 'was', 'certain', 'well', 'just', 'error', 'part', 'Richard', 'Feynman'».
- **Αναγνώριση Μέρους του Λόγου (Part-of-Speech-Tagging-POS):** Εντοπίζονται τα μέρη του λόγου στο κείμενο, γεγονός που επιτρέπει την επιλογή των επιθυμητών. Π.χ. επιλογή όρων που ανήκουν στο μέρος του λόγου: ρήμα.

Στην συνέχεια μπορεί να εφαρμοστούν οι κανονικοποιήσεις:

- **Αποκατάληξη (Stemming):** Αφαιρούνται οι καταλήξεις από τον όρο και ο όρος ανάγεται στην ρίζα. Αυτό σημαίνει πως οι παραγόμενοι όροι μπορεί να μην είναι πραγματικές λέξεις αλλά μόνο το θέμα. Π.χ. *computer, computing, computations* → *comput*
- **Λημματοποίηση (Lemmatization):** Με την χρήση μορφολογικού λεξικού οι όροι ανάγονται στο λήμμα, την κύρια μορφή μιας λέξης. Π.χ. *thought, talking, systems* → *think, talk, system*

Έπειτα πραγματοποιείται ο μετασχηματισμός κειμένου (*Text Transformation*). Εξάγονται και επιλέγονται τα χαρακτηριστικά (*features*). Κάθε εγγραφή κειμένου προκειμένου να γίνει κατανοητή από τον υπολογιστή αντιπροσωπεύεται από τις λέξεις που αποτελείται ή και την συχνότητα εμφάνισης κάθε λέξης (BoW, vector space, TF-IDF). Στο τελευταίο στάδιο επιλέγεται η μέθοδος KDT που θα χρησιμοποιηθεί, όπως κατηγοριοποίηση (*classification*), συσταδοποίηση (*clustering*), σύνοψη (*summarization*), μοντελοποίηση θεμάτων (*topic modeling*). (Lata, 2015)

3.3. Μοντελοποίηση Θεμάτων

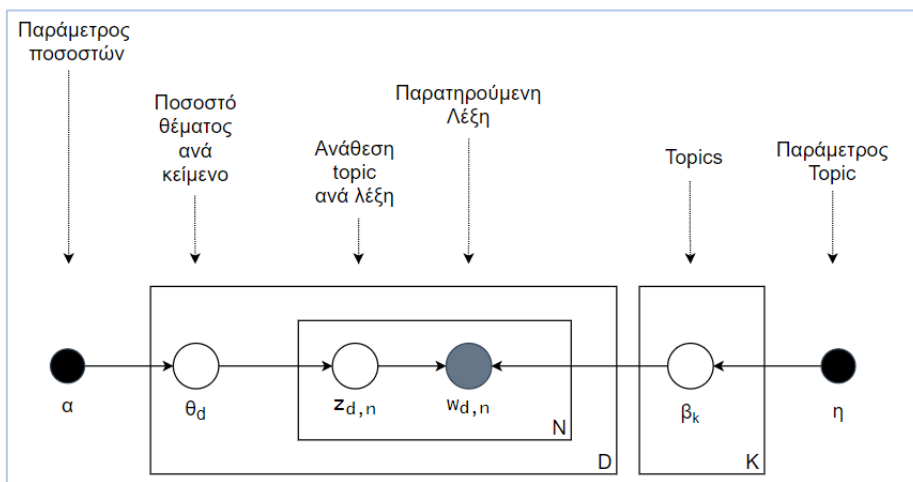
Η μοντελοποίηση θεμάτων αναπτύσσει αλγορίθμους με σκοπό να εκπαιδεύσουν (χωρίς επίβλεψη) μοντέλα ικανά να ανιχνεύσουν σημασιολογικές συσχετίσεις σε μεγάλες συλλογές δεδομένων (συνήθως κειμένου). Τα μοντέλα θεμάτων (*topic models*) που παράγονται, είναι στατιστικά μοντέλα που ακολουθούν την παρακάτω λογική:

- τα δεδομένα (π.χ. πρόταση, έγγραφο, κείμενο) είναι προϊόν της ανάμειξης λέξεων οι οποίες αποτελούν το λεξιλόγιο
- κάθε θέμα (*topic*) είναι μία κατανομή πιθανότητας των λέξεων του λεξιλογίου
- τα δεδομένα θεωρούνται ως ανάμειξη θεμάτων
- κάθε θέμα αποτελείται από ομάδες λέξεων που συνυπάρχουν συχνά

Ευρέως διαδεδομένοι αλγόριθμοι για topic modeling είναι οι: Latent Semantic Analysis , Non-Negative Matrix Factorization, Latent Dirichlet Allocation και παραλλαγές τους όπως PLSI και hLDA. (Likhitha, et al., 2019) (International Conference on Machine Learning, 2013)

3.3.1. Latent Dirichlet Allocation

Ο αλγόριθμος LDA είναι ένα Bayesian μοντέλο πιθανότητας που εντοπίζει λανθάνουσες θεματικές δομές (topics) σε ένα σώμα κειμένων (corpus). Τα κείμενα θεωρούνται τυχαίες αναμειγυρισμένες των λανθανόντων θεμάτων και τα θέματα χαρακτηρίζονται από κατανομές λέξεων· ο αριθμός των θεμάτων θεωρείται δεδομένος. Το μοντέλο (Σχήμα 3.2) δημιουργεί κατανομές κειμένου-θεμάτων και λέξεων-θεμάτων χρησιμοποιώντας τις παραμέτρους α και β της μεταγενέστερης κατανομής Dirichlet για την εκτίμηση της πυκνότητας των κατανομών Σχήμα 3.2: Σχηματική Αναπαράσταση LDA Plate Notation και εντοπίζει ομάδες λέξεων που συνυπάρχουν συχνά. Στην συνέχεια μπορεί να χρησιμοποιηθεί σε άλλους αλγορίθμους επεξεργασίας δεδομένων. (Likhitha, et al., 2019) (Blei, et al., 2003)



Σχήμα 3.2: Σχηματική Αναπαράσταση LDA Plate Notation (Blei, 2017)

4. Εντοπισμός και Ανάλυση Ψευδών Ειδήσεων

Η παρούσα έρευνα προσεγγίζει το πρόβλημα του εντοπισμού και της ανάλυσης των ψευδών ειδήσεων από την οπτική της κατηγοριοποίησής τους βάσει της αξιοπιστίας τους, και της συσταδοποίησής τους βάσει της θεματολογίας τους. Το πρόβλημα διακρίνεται στις δύο προαναφερθείσες διεργασίες και ανάγεται στην παραγωγή ενός τελικού μοντέλου για κάθε μία. Ως αποτέλεσμα, για κάθε άρθρο θα προβλέπονται:

- Η αξιοπιστία του άρθρου (ψευδές ή αληθές)
- Τα θέματα που πραγματεύεται το άρθρο

Κατόπιν σχετικών αναζητήσεων και δοκιμών, επιλέχθηκε η κατηγοριοποίηση να υλοποιηθεί με βαθιά τεχνητά νευρωνικά δίκτυα στα οποία η διαδικασία μάθησης θα πραγματοποιείται από μονάδες Long Short-Term Memory, και η συσταδοποίηση να υλοποιηθεί με μοντελοποίηση θεμάτων μέσω του αλγορίθμου Latent Dirichlet Allocation.

4.1. Μεθοδολογία

Η μεθοδολογία που ακολούθησε η μελέτη είναι παρόμοια με τα στάδια της KDD και περιλαμβάνει τα ακόλουθα βασικά βήματα:

1. Επιλογή Δεδομένων
2. Καθαρισμός Δεδομένων
3. Εξόρυξη Δεδομένων
 - i. Επιλογή Αλγορίθμου
 - ii. Προ-επεξεργασία Δεδομένων
 - iii. Μετασχηματισμός Δεδομένων
 - iv. Παραγωγή Μοντέλων
 - v. Αξιολόγηση Μοντέλων
4. Αξιολόγηση Αποτελεσμάτων

Η Εξόρυξη Δεδομένων εφαρμόζεται ανεξάρτητα στις δύο διεργασίες (κατηγοριοποίηση, συσταδοποίηση).

4.2. Τεχνολογίες

Το πείραμα πραγματοποιήθηκε σε διακομιστές της πλατφόρμας Spell και σε προσωπικό υπολογιστή με λειτουργικό σύστημα Windows 10 Home 64 bit, επεξεργαστή Intel® Core™ i7-770HQ CPU @ 2.80 GHz με τέσσερις πυρήνες και 8GB RAM. Όσον αφορά τους διακομιστές, για την εκτέλεση του νευρωνικού δικτύου χρησιμοποιήθηκε το Spell GPU Instance K80, που διαθέτει μία NVIDIA GPU Tesla K80, VRAM 12GB, TFlops 4.3, τέσσερις vCPUs, 61GB RAM και για την θεματική μοντελοποίηση το cru-big Instance με 16 vCPUs και 32GB RAM. Η γλώσσα προγραμματισμού που χρησιμοποιήθηκε είναι η Python 3.7, λόγω της δημοτικότητάς της στον κλάδο αλλά και ως προτιμώμενη επιλογή. Έγινε χρήση του Anaconda (Anaconda Inc) με Spyder IDE (στα Windows) και Jupyter Notebook, Jupyter Lab (στα Windows και Linux-Spell). Ιδιαίτερες βιβλιοθήκες που αξιοποιήθηκαν είναι οι εξής:

- genism
- jupyter-tensorboard 0.2.0
- matplotlib
- nltk
- numpy
- pandas
- pickle
- PyLDAvis
- seaborn
- sklearn
- TSNE
- tensorboard 2.1.0
- tensorflow 2.1

Για την ανάπτυξη του νευρωνικού δικτύου επιλέχθηκε η υλοποίηση CUDA LSTM (CuDNNLSTM) του Tensorflow Keras API η οποία αξιοποιεί τις μονάδες GPU, μειώνοντας σημαντικά τον χρόνο εκπαίδευσης του δικτύου. Η πλατφόρμα Tensorflow της εταιρείας Google είναι ειδικά σχεδιασμένη για την ανάπτυξη διεργασιών μηχανικής μάθησης (Abadi, et al., 2015). Η Διασύνδεση Προγραμματισμού Εφαρμογών (Application Programming Interface - API) του Keras ειδικεύεται στην ανάπτυξη και επέκταση μοντέλων βαθιάς μάθησης και προσφέρει αφαιρετικότητα και μεγάλο βαθμό ελέγχου στην υλοποίηση νευρωνικών δικτύων (Gulli, et al., 2017).

Όσον αφορά την υλοποίηση του αλγορίθμου LDA, χρησιμοποιήθηκαν οι βιβλιοθήκες Gensim και *nltk* (Natural Language Toolkit). Η *nltk* είναι μια πλατφόρμα ανάπτυξης προγραμμάτων σε Python, που παρέχει βιβλιοθήκες επεξεργασίας φυσικής γλώσσας (Brew, et al., 2018). Η Gensim παρέχει εργαλεία μοντελοποίησης θεμάτων και σημασιολογικής ανάλυσης δεδομένων για

προγράμματα γραμμένα σε γλώσσα Python (Řehůřek, et al., 2010). Για την οπτικοποίηση του διαδραστικού μοντέλου των θεμάτων χρησιμοποιήθηκε η βιβλιοθήκη PyLDAvis.

Τα βασικά βήματα που ακολούθησαν και οι δύο διεργασίες είναι τα εξής:

1. Επιλογή Κατάλληλων Δεδομένων
2. Προ-επεξεργασία Δεδομένων
3. Εκτέλεση Αλγορίθμων
4. Συντονισμός Υπερπαραμέτρων
5. Επιλογή του Καλύτερου Μοντέλου
6. Οπτικοποίηση (όπου κρίνεται σκόπιμο) και Ανάλυση Αποτελεσμάτων

4.3. Επιλογή Δεδομένων

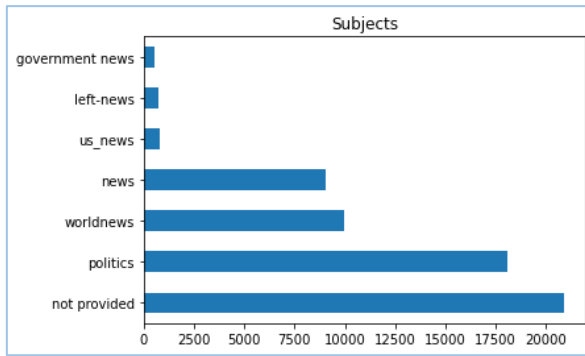
Η αναζήτηση και η επιλογή δεδομένων όσον αφορά το δεδομένο πρόβλημα και τις διαθέσιμες μεθόδους προσέγγισης, προϋποθέτουν την τήρηση ορισμένων προϋποθέσεων ώστε να αποτελέσουν τα δεδομένα ποιοτικό και κατάλληλο δείγμα. Ιδανικό θα ήταν να χαρακτηρίζονται από σχετικά μεγάλο όγκο, να προέρχονται από διάφορες πηγές, να πραγματεύονται ποικίλες θεματολογίες και να αποτελούνται από κυρίως σώμα είδησης και τίτλο. Οι προϋποθέσεις αυτές αποσκοπούν στην άντληση ποιοτικής και ποσοτικής γνώσης.

Για τις ανάγκες του πειράματος συνδυάστηκαν τέσσερις συλλογές που φέρονται να πληρούν τα παραπάνω:

1. ISOT (Information Security and Object Technology) Fake News Dataset (Ahmed, et al., 2018) (Ahmed, et al., 2017)
2. Kaggle: Getting Real About Fake News (Risdal, 2016)
3. Kaggle: Real or Fake (Raluca, 2018)
4. Kaggle: Fake News Detection (Jruvika, 2018)

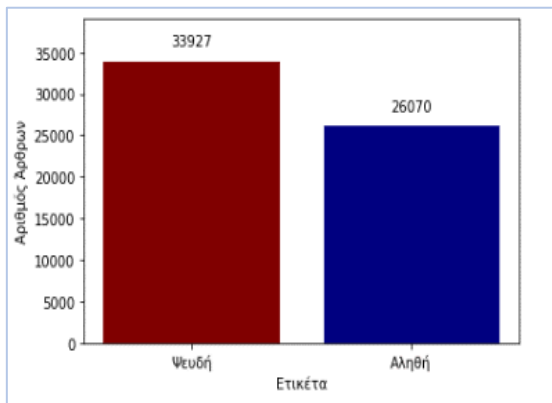
Στην ISOT dataset τα αληθή άρθρα έχουν συλλεχθεί από την ιστοσελίδα του ειδησεογραφικού πρακτορείου Reuters και τα ψευδή από διάφορες πηγές που έχουν χαρακτηριστεί ως αναξιόπιστες από τους ιστοτόπους Politifact¹ και Wikipedia (Information security and object technology (ISOT) research lab, 2018). Στην συλλογή *Getting Real About Fake News* περιέχονται μόνο ψευδή άρθρα που έχουν χαρακτηριστεί αντιστοίχως από την επέκταση του περιηγητή ιστού Chrome, BS Detector (Risdal, 2016). Στην συλλογή Real or Fake υπάρχουν ισοκατανεμημένα άρθρα χωρίς να δίνονται ακριβείς πληροφορίες για την προέλευση και τον τρόπο συλλογής τους, φαίνονται όμως ποιοτικά και περιλαμβάνουν δημοσιεύματα από γνωστές πηγές όπως Cable News Network - CNN. Παρομοίως στην συλλογή Fake News Detection υπάρχουν αληθή άρθρα από αξιόπιστες πηγές όπως New York Times, British Broadcasting Corporation - BBC, Reuters, CNN και ψευδή άρθρα που προέρχονται από αναξιόπιστες πηγές των Politifact και Wikipedia χωρίς όμως αυτό να αναφέρεται ρητά (Jruvika, 2018). Οι θεματολογίες των άρθρων παρουσιάζονται στο ακόλουθο διάγραμμα, όπου οι άγνωστες έχουν σημειωθεί ως *not provided*.

¹ Πρόκειται για ένα έργο του Poynter Institute for Media Studies, που έχει σκοπό την εξακρίβωση πληροφοριών (fact-checking) που διαδίδονται στα μέσα ενημέρωσης (PolitiFact, 2020).



Διάγραμμα 4.1: Θεματολογία Άρθρων

Στην συνενωμένη συλλογή που δημιουργήθηκε από τις προαναφερθείσες, υπάρχει για κάθε άρθρο η πληροφορία: τίτλος, κυρίως κείμενο, θέμα (όπου παρέχεται), ημερομηνία δημοσίευσης (όπου παρέχεται), και η ετικέτα (label), που δηλώνει εάν η είδηση είναι ψευδής (Fake) ή αληθής (Real). Η συλλογή αυτή θα αποτελέσει την συλλογή εκπαίδευσης. Κρίθηκε σκόπιμη η εκκαθάριση των διπλότυπων εγγραφών λαμβάνοντας υπόψη τον τίτλο και το κυρίως κείμενο συνδυαστικά, ώστε να ελέγχεται επιπλέον η εγκυρότητα του τίτλου σε συνάρτηση με το κείμενο· για παράδειγμα το ίδιο κυρίως κείμενο με διαφορετικό τίτλο ή διαφορετικό κυρίως κείμενο με ίδιο τίτλο δεν αποτελούν θόρυβο ενώ ο ίδιος τίτλος με το ίδιο κυρίως κείμενο είναι πλεονασμός να υπάρχει στην συλλογή δεδομένων². Μετά την εκκαθάριση των διπλότυπων και την επιλογή χαρακτηριστικών, το τελικό σύνολο δεδομένων συγκροτείται από 59.997 εγγραφές. Η κατανομή των άρθρων σε ψευδή και αληθή φαίνεται στο επόμενο διάγραμμα.



Διάγραμμα 4.2: Κατανομή των Άρθρων σε Ψευδή και Αληθή

Λήφθηκε υπόψη πως η διαφορά στην ισοκατανομή των εγγραφών ενδέχεται να επηρεάσει μεροληπτικά τα μοντέλα και να «μάθουν» καλύτερα τα ψευδή μοτίβα. Δοκιμάστηκε η εκπαίδευση μοντέλου σε ισοκατανομημένη συλλογή και δεν εντοπίστηκε μεροληψία συνεπώς επιλέχθηκε να χρησιμοποιηθεί ολόκληρη η συλλογή δεδομένων όπως φαίνεται στο παραπάνω διάγραμμα.

Τα τελικά μοντέλα δοκιμάστηκαν σε νέα συλλογή δεδομένων. Για την συλλογή δοκιμής χρησιμοποιήθηκαν αρχεία από συλλογές της Fake News Data, που περιέχουν μόνο τίτλους νέων (Maronikoulakis, 2019), και από την FakeNewsAMT, που αποτελείται από νέα ποικίλων θεμάτων

² Είδηση με ίδιο τίτλος και κυρίως κείμενο θα ήταν σκόπιμο να παραμείνει στην συλλογή εάν εξετάζονταν στοιχεία σχετικά με την αναδημοσίευση των ειδήσεων.

όπως τεχνολογία, εκπαίδευση, επιχειρηματικά, αθλητικά, πολιτικά και διασκέδαση (Perez-Rosas, et al., 2018). Η διαμορφωμένη συλλογή αποτελείται από 912 εγγραφές. Η συγκεκριμένη συνενωμένη συλλογή η οποία διαφέρει αρκετά από την συλλογή εκπαίδευσης τόσο στην μορφή (εγγραφές αποτελούμενες μόνο από τον τίτλο) όσο και στην θεματολογία, επιλέχθηκε ώστε να παρατηρηθεί η συμπεριφορά των τελικών μοντέλων στην επίλυση του ίδιου προβλήματος σε πιο αφαιρετικό (πιο γενικευμένο) επίπεδο.

4.4. Κατηγοριοποίηση

Η διεργασία της κατηγοριοποίησης υλοποιήθηκε με την ανάπτυξη βαθέν τεχνητών νευρωνικών δικτύων με μονάδες LSTM. Η μεθοδολογία περιλαμβάνει τα παρακάτω βήματα:

1. Προετοιμασία των δεδομένων (προ-επεξεργασία και μετασχηματισμός)
2. Επιλογή επιπέδων και συνδεσμολογίας του δικτύου
3. Συντονισμός υπερπαραμέτρων
4. Επιλογή του καλύτερου μοντέλου
5. Κανονικοποίηση
6. Παραγωγή και δοκιμή τελικού μοντέλου
7. Αξιολόγηση

4.4.1. Προετοιμασία Δεδομένων

Καταρχάς πραγματοποιείται προ-επεξεργασία των δεδομένων, ώστε να διακριθεί η πληροφορία από τον θόρυβο. Στην συνέχεια δημιουργείται το ευρετήριο όρων, όπου κάθε λέξη αντιπροσωπεύεται από ένα μοναδικό αναγνωριστικό. Οι διαδικασίες προ-επεξεργασίας και μετασχηματισμού των δεδομένων είναι οι ακόλουθες και συνοδεύονται από αντίστοιχα στιγμιότυπα δοκιμών που διεξήχθησαν στον προσωπικό υπολογιστή με το Spyder IDE³:

1. Κατά την προ-επεξεργασία κάθε κειμένου αφαιρούνται υπερσύνδεσμοι, τερματικοί όροι (stopwords), λέξεις μικρότερες των δύο χαρακτήρων, σημεία στίξης, ειδικοί χαρακτήρες και μετατρέπονται οι χαρακτήρες σε πεζούς. Έπειτα δημιουργείται το ευρετήριο λέξεων (word index) όπου κάθε εμφανιζόμενη λέξη αντιστοιχίζεται σε ένα μοναδικό αναγνωριστικό (Σχήμα 4.1).
2. Κάθε προ-επεξεργασμένο κείμενο μετατρέπεται σε ακολουθία από τους όρους που το αποτελούν (Σχήμα 4.2).
3. Κάθε όρος αντικαθίσταται από το κλειδί του στο ευρετήριο λέξεων (Σχήμα 4.3).
4. Οι λίστες μετατρέπονται σε πίνακα δύο διαστάσεων (Σχήμα 4.4): προκειμένου οι ακολουθίες να έχουν ίδιο μήκος κατά την μετατροπή προστίθενται στις μικρότερες μία επιλεγμένη τιμή (π.χ. 0) ενώ οι μεγαλύτερες διακόπτονται στο κατάλληλο μήκος.
5. Οι πίνακες μετατρέπονται σε διανυσματικές αναπαραστάσεις των λέξεων οι οποίες μετασχηματίζουν την αναλογία των πιθανών συν-εμφανίσεων των λέξεων, σε διανυσματικές διαφορές σε ένα πολυδιάστατο χώρο, τοποθετώντας λέξεις με παρεμφερή σημασία παραπλήσια. Με την διαδικασία αυτή αποτυπώνονται οι σημασιολογικές σχέσεις μεταξύ των λέξεων (Σχήμα 4.6, Σχήμα 4.7, Σχήμα 4.7): η διαδικασία υπολογισμού των βαρών γίνεται με την χρήση του προ-εκπαιδευμένου διανύσματος λέξεων GloVe 100d⁴ (Pennington, et al., 2014) .

³ Τα συγκεκριμένα στιγμιότυπα επιλέχθηκε να προέρχονται από δοκιμές και όχι από το τελικό πείραμα αφενός για να αναδειχθούν οι δυνατότητες του Spyder IDE -το οποίο δεν ήταν εφικτό να χρησιμοποιηθεί στον διακομιστή του spell- και αφετέρου για την παρακολούθηση της εξέλιξης του πειράματος. Οι δοκιμές αφορούν σε δείγμα των πραγματικών δεδομένων ώστε να είναι εφικτή η εκτέλεσή τους στον προσωπικό υπολογιστή.

⁴ Ο αλγόριθμος GloVe είναι μη επιβλεπόμενης μάθησης και αποσκοπεί στην διανυσματική αναπαράσταση λέξεων. Το μοντέλο που χρησιμοποιείται έχει εκπαιδευτεί σε 6 δις tokens από σώματα κειμένων των Wikipedia και Gigaword5 εκ των οποίων τα 400.000 είναι διακριτά

Σημαντικές παράμετροι που καθορίζονται μέσω σχετικών δοκιμών πριν την εφαρμογή του μετασχηματισμού είναι οι εξής:

- Ο μέγιστος αριθμός διακριτών όρων (tokens) στους οποίους θα διασπάται ένα άρθρο, βάσει της συχνότητας εμφάνισης των όρων – 100.000
- Ο μέγιστος αριθμός όρων από τους οποίους θα αντιπροσωπεύεται ένα άρθρο – 1.000
- Το μήκος του πίνακα των διανυσματικών αναπαραστάσεων ενός όρου – 100

Key	Type	Size	Value
trump	int	1	1
people	int	1	10
white	int	1	11
republican	int	1	12
one	int	1	13
senate	int	1	14
also	int	1	15
new	int	1	16
bill	int	1	17
republicans	int	1	18
twitter	int	1	19

Σχήμα 4.1: Στιγμιότυπο Δοκιμής – Ευρετήριο Λέξεων

Index	Word Sequence
0	['gabby', 'giffords', 'drops', 'mic', 'trump', 'exploits', 'london', ' ...
1	['democratic', 'base', 'ready', 'get', 'rid', 'nancy', 'pelosi', 'cert ...
2	['victims', 'terrorist', 'attack', 'question', 'lack', 'presidential', ...
3	['factbox', 'bigticket', 'items', 'center', 'congress', 'spending', 'b ...
4	['high', 'schools', 'start', 'caving', 'trump', 'punish', 'athletes', ...
5	['republicans', 'secretly', 'terrified', 'trump', 'already', 'handing' ...
6	['trump', 'goes', 'ballistic', 'white', 'house', 'correspondents', 'di ...
7	['new', 'york', 'daily', 'news', 'cover', 'savages', 'white', 'house', ...
8	['turkey', 'urges', 'review', 'visa', 'suspension', 'lira', 'stocks', ...
9	['senate', 'takes', 'step', 'toward', 'passage', 'tax', 'bill', 'vote' ...

Σχήμα 4.2: Στιγμιότυπο Δοκιμής – Μετατροπή Εγγραφών σε Ακολουθία Όρων

(Pennington, et al., 2014). Σε περίπτωση ύπαρξης μεγάλου όγκου κειμένων μπορεί να δημιουργηθεί νέο μοντέλο GloVe.

Index	Type	Size	Value
0	list	191	[9973, 7771, 5016, 6280, 1, 13133, 1260, 577, 759, 9974, ...]
1	list	208	[52, 852, 1147, 37, 1607, 1162, 899, 792, 7427, 6078, ...]
2	list	294	[873, 1292, 268, 402, 1186, 137, 88, 2097, 374, 151, ...]
3	list	280	[2025, 14032, 3732, 635, 32, 287, 16, 17, 32, 87, ...]
4	list	464	[449, 2442, 643, 11807, 1, 3700, 3062, 1990, 545, 61, ...]
5	list	233	[15, 4340, 4642, 1, 165, 4684, 32, 48, 320, 1, ...]
6	list	165	[1, 768, 1957, 8, 5, 7863, 1362, 1079, 159, 130, ...]
7	list	194	[14, 120, 965, 33, 838, 12392, 8, 5, 11288, 1626, ...]
8	list	476	[1324, 3618, 672, 1579, 4064, 14814, 2085, 14706, 4244, 17, ...]
9	list	471	[12, 1024, 530, 639, 1350, 7, 16, 81, 218, 70, ...]


Σχήμα 4.3: Στιγμιότυπο Δοκιμής – Μετατροπή Εγγραφών σε Λίστα Κλειδιών

	0	1	2	3	4	5	6
0	9973	7771	5016	6280	1	13133	1260
1	52	852	1147	37	1607	1162	899
2	873	1292	268	402	1186	137	88
3	2025	14032	3732	635	32	287	16
4	449	2442	643	11807	1	3700	3062
5	15	4340	4642	1	165	4684	32
6	1	768	1957	8	5	7863	1362
7	14	120	965	33	838	12392	8
8	1324	3618	672	1579	4064	14814	2085
9	12	1024	530	639	1350	7	16


Σχήμα 4.4: Στιγμιότυπο Δοκιμής – Μετατροπή Λίστας Κλειδιών σε Δισδιάστατο Πίνακα

	0	1	2	3	4	5	6
0	-0.15731	-0.75503	0.36845	-0.18958	-0.16896	-0.23157	-0.22658
1	-0.13128	-0.452	0.043399	-0.99798	-0.21053	-0.95868	-0.24609
2	-0.038194	-0.24487	0.72812	-0.39961	0.083172	0.043953	-0.39141
3	0.66248	0.0465	0.65824	-0.83239	0.48056	0.16532	0.49798
4	-0.064549	-0.13812	0.50017	0.41434	0.45832	-0.048331	-0.21651
5	0.039741	0.035052	0.32988	-0.5879	-0.25054	-0.40719	-0.13904
6	-0.18867	-0.040943	0.58878	0.11062	0.14236	0.4885	-0.31832
7	-0.54968	-0.48832	0.59132	-0.66138	-0.15055	-0.5017	-0.14806
8	-0.32956	0.25699	0.26541	-0.63736	0.74103	-0.15453	-0.73308
9	0.29019	0.80497	0.31187	-0.32706	-0.47237	1.1363	-0.37966

Σχήμα 4.5: Στιγμιότυπο Δοκιμής – Μετατροπή Λέξεων σε Διανυσματική Αναπαράσταση



Σχήμα 4.6: Διανυσματική Αναπαράσταση των Λέξεων στον χώρο



Σχήμα 4.7: Διανυσματική Αναπαράσταση των Λέξεων (zoom)

4.4.2. Συντονισμός Υπερπαραμέτρων

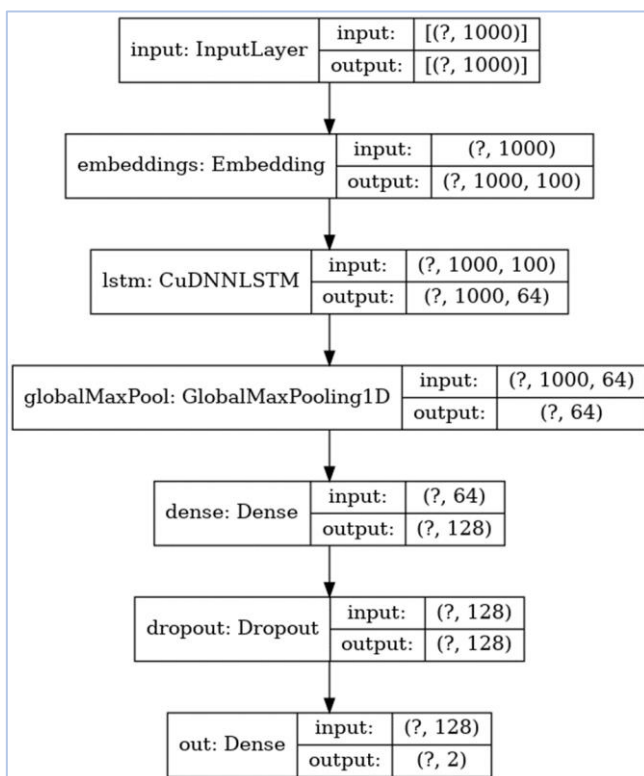
Στην συνέχεια προκειμένου να εντοπιστεί και να επιλεγεί το καλύτερο μοντέλο για το δοθέν πρόβλημα, είναι σκόπιμη η αναζήτηση και ο καθορισμός παραμέτρων του δικτύου. Σημαντικές παράμετροι του δικτύου αποτελούν οι παρακάτω:

- Αριθμός και είδος επιπέδων
- Αριθμός νευρώνων ανά επίπεδο
- Συναρτήσεις (ενεργοποίησης, σφάλματος, ακρίβειας)
- Αριθμός κύκλων εκπαίδευσης (epochs)
- Μέγεθος δέσμης μάθησης (batch size)
- Κανονικοποίηση (π.χ. dropouts, regularizers)

Το νευρωνικό δίκτυο θα αποτελείται από την είσοδο, την έξοδο και τα κρυφά επίπεδα:

- Ενσωμάτωσης
- Μονάδων LSTM
- Συγκέντρωσης
- Πλήρως Συνδεδεμένο Επίπεδο

Στην είσοδο καταφθάνουν τα δεδομένα σε μορφή ακολουθιών, ίδιου μήκους, από τα κλειδιά των λέξεων που τα αντιπροσωπεύουν. Το επίπεδο Ενσωμάτωσης τροφοδοτεί το δίκτυο με τις διανυσματικές αναπαραστάσεις των λέξεων που προαναφέρθηκαν. Ακολουθεί το επίπεδο μονάδων LSTM στο οποίο πραγματοποιείται η διαδικασία μάθησης. Η διάδοση συνεχίζεται στο επίπεδο συγκέντρωσης όπου τα δεδομένα υποδειγματοποιούνται βάσει της μέγιστης τιμής των διανυσμάτων (μειώνεται η διάσταση). Ακολουθεί ένα πλήρως συνδεδεμένο επίπεδο όπου οι εισοδοί συντελούνται από τους νευρώνες του προηγούμενου επιπέδου πλήρως συνδεδεμένους μεταξύ τους και υπολογίζεται η έξοδος μέσω της συνάρτησης ενεργοποίησης. Προαιρετικά μπορεί να προστεθεί ένα επίπεδο dropout κατά το οποίο επιλέγεται το ποσοστό των εισόδων τυχαίων νευρώνων που θα αγνοηθούν. Η μέθοδος αυτή βοηθά στην εξάλειψη του φαινομένου της υπερπροσαρμογής (overfitting) κατά το οποίο το μοντέλο προσαρμόζεται τόσο καλά στα δεδομένα που πλέον τα έχει αποστηθίσει· το overfitting καθιστά το μοντέλο να υστερεί στην αφαιρετική εικόνα των δεδομένων και να είναι αναποτελεσματικό σε νέα δεδομένα. (Hawkins, 2004) Η έξοδος του δικτύου είναι ένα πλήρως συνδεδεμένο επίπεδο με συνάρτηση ενεργοποίησης που επιστρέφει την έξοδο. Το διάγραμμα και η περίληψη του νευρωνικού δικτύου φαίνονται στο Διάγραμμα 4.3 και στο Σχήμα 4.8.



Διάγραμμα 4.3: Επίπεδα Τελικού Νευρωνικού Δικτύου

Layer (type)	Output Shape	Param #
embeddings (Embedding)	(None, 1000, 100)	29077300
lstm (CuDNNLSTM)	(None, 1000, 64)	42496
globalMaxPool (GlobalMaxPool)	(None, 64)	0
dense (Dense)	(None, 128)	8320
dropout (Dropout)	(None, 128)	0
out (Dense)	(None, 2)	258
Total params: 29,128,374		
Trainable params: 51,074		
Non-trainable params: 29,077,300		

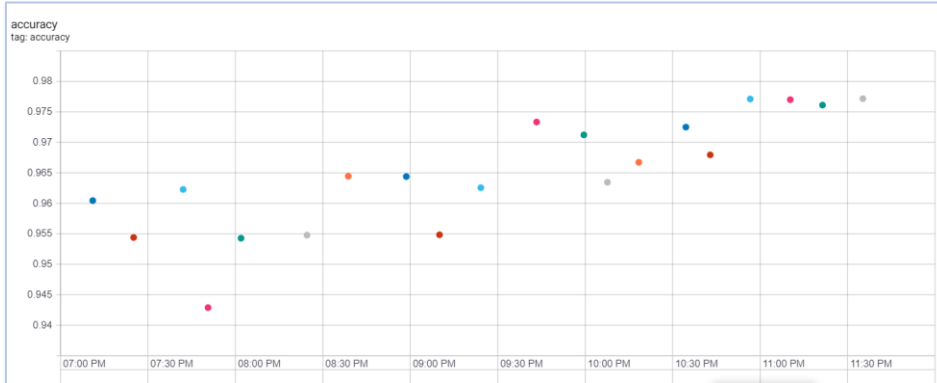
Σχήμα 4.8: Model Summary

Κατά την εκπαίδευση το batch size, που υποδεικνύει μετά από πόσα παραδείγματα θα ενημερώνεται η εσωτερική κατάσταση του μοντέλου, τέθηκε ως 32 και ο αριθμός των epochs, που υποδηλώνει πόσες φορές θα προσπελαστεί το σύνολο των δεδομένων εκπαίδευσης, τέθηκε ως 10. Πριν από κάθε epoch, τα δεδομένα εκπαίδευσης αναμιγνύονται (shuffle). Η συλλογή εκπαίδευσης διαμοιράστηκε σε υποσύνολα για την εκπαίδευση (train set): 41997 εγγραφές, την επικύρωση (validation set): 9000 εγγραφές και την δοκιμή (test set): 9000 εγγραφές. Η αναλογία είναι 70% train set και από 15% για τα test και validation set αντίστοιχα.

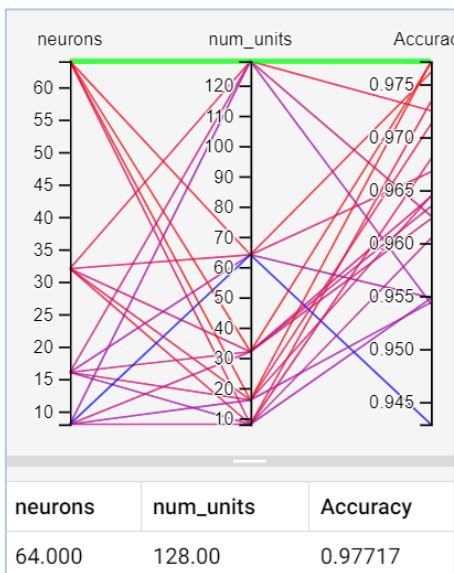
Προκειμένου να επιλεγεί ο αριθμός νευρώνων για τα κρυφά επίπεδα Dense και LSTM, παράγονται δίκτυα με διαφορετικούς συνδυασμούς (αριθμών νευρώνων): για κάθε δίκτυο και κάθε epoch παρακολουθούνται τα μεγέθη της ακρίβειας, του σφάλματος, της ακρίβειας επικύρωσης και του σφάλματος επικύρωσης (accuracy, validation accuracy, loss, validation loss). Κατά την εκπαίδευση κάθε δικτύου, έχει τεθεί πρόωρη διακοπή (Early Stopping) όπου σε κάθε epoch παρακολουθείται το σφάλμα επικύρωσης ώστε να διακοπεί η εκπαίδευση του δικτύου όταν το σφάλμα αυξηθεί συγκριτικά με το προηγούμενο epoch. Σε περίπτωση πρόωρης διακοπής επαναφέρονται τα βάρη και αποθηκεύεται το καλύτερο μοντέλο μέσω ελέγχου (Model Checkpoint) του σφάλματος επικύρωσης. Εφόσον εκπαιδευτούν όλα τα δίκτυα, συγκρίνονται τα καλύτερα μοντέλα που παράχθηκαν και επιλέγεται εκείνο με την καλύτερη ακρίβεια. Το δίκτυο από το οποίο προέρχεται το επιλεγθέν μοντέλο θα είναι και το δίκτυο στο οποίο θα συνεχιστούν οι δοκιμές: θα διορθωθεί εφόσον χρειάζεται και θα αποτελέσει το τελικό δίκτυο που θα παραγάγει το τελικό μοντέλο.

Οι δοκιμές οπτικοποιήθηκαν αξιοποιώντας το Tensorboard. Το Tensorboard δίνει την δυνατότητα διαγραμματικής παρακολούθησης της εκπαίδευσης και του συντονισμού υπερπαραμέτρων του μοντέλου κατά την εκτέλεση των διεργασιών αλλά και με το πέρασ τους - εφόσον έχει υλοποιηθεί προγραμματιστικά η καταγραφή των ενδιαφερόμενων παραμέτρων σε αρχεία (logs). Οι τελικές δοκιμές έγιναν για αριθμό νευρώνων του LSTM = [8, 16, 32, 64] και για αριθμό μονάδων του Dense = [8, 16, 32, 64, 128] ενώ έχουν τεθεί ως callbacks τα EarlyStopping και ModelCheckpoint με monitor="val_loss" ώστε να σταματά η εκπαίδευση του μοντέλου όταν παρουσιάζεται αύξηση του validation loss (προς αποφυγή της υπερπροσαρμογής) και να αποθηκεύεται το προηγούμενο μοντέλο. Επιπρόσθετα callbacks τέθηκαν για να αποθηκεύονται logs ώστε να οπτικοποιηθούν μέσω του Tensorboard. Στα ακόλουθα διαγράμματα φαίνεται η ακρίβεια ανά δοκιμή και ανά συνδυασμό νευρώνων των LSTM και Dense κρυφών επιπέδων όπως εμφανίζεται στο Tensorboard: ως ακρίβεια επιλέχθηκε η συνάρτηση categorical_accuracy. Ως συνάρτηση σφάλματος χρησιμοποιήθηκε η τεχνική της διασταυρωμένης εντροπίας (binary

cross entropy) και ως αλγόριθμος βελτιστοποίησης ο Adam (Adaptive Moment Estimation) ο οποίος συνδυάζει θετικές πτυχές άλλων αλγορίθμων και μπορεί να διαχειριστεί ακραίες κλίσεις. Στο κρυφό επίπεδο Dense χρησιμοποιήθηκε συνάρτηση ενεργοποίησης ReLu και στο επίπεδο εξόδου η sigmoid.



Διάγραμμα 4.4: Ακρίβεια ανά Δοκιμή




Διάγραμμα 4.5: Ακρίβεια ανά Συνδυασμό Νευρώνων

4.4.3. Επιλογή του Καλύτερου Μοντέλου


Η καλύτερη ακρίβεια όπως φαίνεται στο παραπάνω διάγραμμα επιτυγχάνεται όταν χρησιμοποιούνται 64 νευρώνες στο επίπεδο LSTM και 128 στο Dense επίπεδο. Δεδομένης της πρόωρης διακοπής που είχε τεθεί (ως callback) θεωρείται ότι το μοντέλο έχει αντίστοιχα θεμιτό σφάλμα επικύρωσης, συνεπώς επιλέχθηκε ως καλύτερο παρότι οι ακρίβειες δεν παρουσιάζουν μεγάλες διακυμάνσεις. Η υπερ-παραμέτρος dropout και οποιαδήποτε κανονικοποίηση θα πραγματοποιηθεί στο συγκεκριμένο μοντέλο. Στο σημείο αυτό λήφθηκε υπόψη πως τα νευρωνικά δίκτυα είναι στοχαστικά συνεπώς η επανεκτέλεση του ίδιου δικτύου ακόμη και αν δεν αλλάξουν οι παράμετροι θα έχει διαφοροποιημένο αποτέλεσμα· εφόσον όμως έχουν πραγματοποιηθεί οι

κατάλληλες διαδικασίες επιλογής και συντονισμού που περιεγράφηκαν προηγουμένως αναμένεται το αποτέλεσμα να μην απέχει αρκετά από εκείνο των δοκιμών.

Στα ακόλουθα διαγράμματα φαίνεται η ακρίβεια και η συνάρτηση σφάλματος για τα δεδομένα εκπαίδευσης και επικύρωσης αντίστοιχα.



Διάγραμμα 4.6: Συνάρτηση Σφάλματος ανά Εποχή




Διάγραμμα 4.7: Ακρίβεια ανά Εποχή


4.4.4. Κανονικοποίηση και Δοκιμή

Στο επιλεγθέν μοντέλο διακρίνεται υπερπροσαρμογή. Για την αντιμετώπισή της προστέθηκε στο επίπεδο μονάδων LSTM, ένας κανονικοποιητής πυρήνα ως προς την L2 νόρμα των παραμέτρων ($\text{kernel regularizer} = l2(1e-1)$) η ποινή του οποίου υπολογίζεται από την συνάρτηση (4.1) (TensorFlow, 2019). Η νέα τιμή της ακρίβειας στο σύνολο εκπαίδευσης είναι 0,9546 και στο σύνολο επικύρωσης 0,9527. Το μοντέλο δοκιμάστηκε στα δεδομένα του συνόλου δοκιμής (test set) με ακρίβεια δοκιμής ίση με 0,95. Τα αποτελέσματα παρουσιάζονται στα Διάγραμμα 4.8, Διάγραμμα 4.9.

$$l_2 \text{penalty} = l_2 \sum_{i=0}^n x_i^2 \quad (4.1)$$



Διάγραμμα 4.8: Συνάρτηση Σφάλματος ανά Εποχή με Regularizer



Διάγραμμα 4.9: Ακρίβεια ανά Εποχή του με Regularizer

4.4.5. Παραγωγή Τελικού Μοντέλου

Στο τελευταίο στάδιο προκειμένου να προκύψει το τελικό μοντέλο (finalized model), το μοντέλο εκπαιδεύεται σε ολόκληρη πλέον την συλλογή εκπαίδευσης, χωρίς να πραγματοποιηθεί σε αυτή διαχωρισμός (train, validation, test). Στην συνέχεια επιλέχθηκε το τελικό μοντέλο να δοκιμαστεί πειραματικά στην συλλογή δοκιμής η οποία περιέχει ορισμένα πιο διαφοροποιημένα δεδομένα ώστε να ελεγχθεί η αφαιρετικότητα του μοντέλου και το επίπεδο γενίκευσης του προβλήματος. Η συλλογή δοκιμής περιέχει δεδομένα που αποτελούνται μόνο από τίτλο -γεγονός που σημαίνει ελάχιστη πληροφορία- και δεδομένα από διάφορες πηγές και θεματολογίες, κάποιες εκ των οποίων το μοντέλο δεν έχει αναπαραστήσει. Το τελικό μοντέλο είχε ακρίβεια στην συλλογή εκπαίδευσης 0,97 και ακρίβεια στην συλλογή δοκιμής 0,70. Η τελευταία ήταν αναμενόμενη λόγω των διαφορετικότητων που χαρακτηρίζουν την συλλογή δοκιμής που προαναφέρθηκαν, και αποδεικνύει πως το πρόβλημα δεν μπορεί να γενικευτεί ευρέως.

Η αποτελεσματικότητα των μοντέλων στην συλλογή εκπαίδευσης επιβεβαιώθηκε από όλες τις δοκιμές που πραγματοποιήθηκαν κατά την διεξαγωγή της μελέτης. Σε δοκιμή παραγωγής τελικού μοντέλου με χρήση συνόλου δοκιμής διαχωρισμένο από την συλλογή εκπαίδευσης, η ακρίβεια

του μοντέλου στο σύνολο εκπαίδευσης ήταν 0.9560 και η ακρίβεια στο σύνολο δοκιμής 0.9557 όπως αναμένεται.

4.4.6. Αξιολόγηση Αποτελεσμάτων

Το τελικό μοντέλο είχε πολύ καλή προσαρμογή στα ποικίλα δεδομένα της συλλογής εκπαίδευσης. Ο έλεγχός του στην συλλογή δοκιμής ενίσχυσε αυτή την πεποίθηση αναδεικνύοντας παράλληλα την ανάγκη επικείμενων βελτιώσεων. Η συλλογή δοκιμής ήταν πολύ πιο γενικευμένη από τις θεματολογίες του μοντέλου και περιείχε επίσης κάποιες εγγραφές αποτελούμενες μόνο από τίτλους. Το μοντέλο δεν κατάφερε να τις κατανοήσει όλες επιτυχώς γεγονός που φαίνεται από τις προβλέψεις, η πλειονότητα των οποίων έδιναν αποτέλεσμα πλησίον του 0,5 (π.χ. 0,55456 ή 0,45612). Το μοντέλο κατάφερε όμως να κατηγοριοποιήσει πιο αποτελεσματικά δεδομένα όπως πολιτικά άρθρα.

4.5. Μοντελοποίηση Θεμάτων

Για την μοντελοποίηση θεμάτων χρησιμοποιείται ο αλγόριθμος Latent Dirichlet Allocation. Η εκτέλεση της διαδικασίας που περιγράφεται στην συνέχεια, πραγματοποιείται ανεξάρτητα για τα αληθή και τα ψευδή νέα και περιλαμβάνει τα παρακάτω βήματα:

1. Προετοιμασία των δεδομένων (προ-επεξεργασία και μετασχηματισμός)
2. Επιλογή αριθμού θεμάτων
3. Παραγωγή και επιλογή μοντέλων
4. Δοκιμή
5. Αξιολόγηση

Σημαντική είναι η οπτικοποίηση των αποτελεσμάτων σε κάθε στάδιο, ώστε να αποτυπωθεί πιο ευκρινώς το αποτέλεσμα. Σε όλα τα διαγράμματα και τους πίνακες που θα ακολουθήσουν το αναγνωριστικό του θέματος ξεκινάει από τον αριθμό 1⁵.

4.5.1. Προετοιμασία Δεδομένων

Πριν την εκτέλεση του αλγορίθμου εκτελούνται ορισμένα βήματα προ-επεξεργασίας και μετασχηματισμού των δεδομένων. Αρχικά εφαρμόζεται λεκτική ανάλυση, όπου τα κείμενα διαχωρίζονται στις λέξεις από τις οποίες αποτελούνται (*tokens*): ως αποτέλεσμα κάθε κείμενο έχει μετατραπεί σε ακολουθία λέξεων. Από τα *tokens* αφαιρούνται οι αριθμοί, τα σημεία στίξης, οι ειδικοί χαρακτήρες, λέξεις μικρότερες των δύο χαρακτήρων, τερματικές λέξεις (*stopwords*) και σύνδεσμοι ιστοτόπων. Έπειτα τα *tokens* μετατρέπονται σε πεζά. Στην συνέχεια εντοπίζονται λέξεις που συνυπάρχουν συχνά ως ζεύγος και ενοποιούνται με αποτέλεσμα να αντιμετωπίζονται ως ένας όρος (*bigrams*). Στο τελευταίο στάδιο για την κανονικοποίηση των λέξεων εφαρμόζεται λημματοποίηση και αναγνώριση μέρους του λόγου κατά την οποία επιλέγονται μόνο τα μέρη του λόγου που ανήκουν στις κατηγορίες ουσιαστικό, επίθετο, ρήμα, επίρρημα. Το λεξικό αντιστοιχίζει κάθε όρο σε ένα μοναδικό κλειδί και επιλέχθηκε να κατασκευάζεται ώστε να περιέχει λέξεις που δεν εμφανίζονται σε λιγότερα από 20 κείμενα και σε ποσοστό μεγαλύτερο του 20% των κειμένων. Το σώμα των κειμένων μετασχηματίζεται σε διανύσματα τα οποία περιέχουν το κλειδί της λέξης και τον αριθμό των εμφανίσεών της.

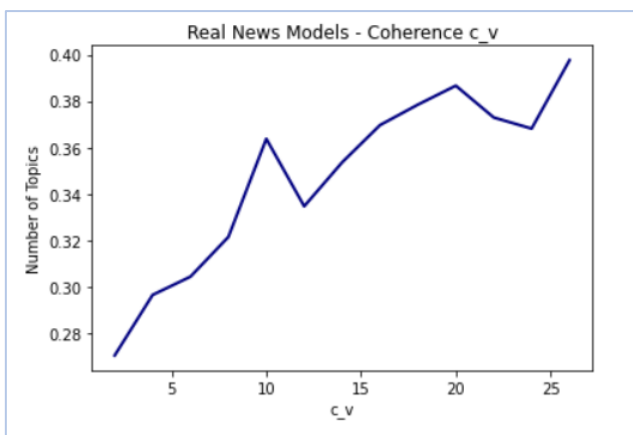
Σαν πρώτη εικόνα των λέξεων και της θεματολογίας των άρθρων εξάχθηκαν τα wordclouds (Σχήμα 4.10, Σχήμα 4.10) στα οποία διακρίνεται η αμερικάνικη και πολιτική τους φύση.

⁵ Στην βιβλιοθήκη Gensim η αρίθμηση των θεμάτων ξεκινάει από το 0 ενώ στην οπτικοποίηση pyLDAvis από τον αριθμό 1. Συνεπώς τα αποτελέσματα προσαρμόστηκαν αναλόγως ώστε να είναι πιο προσιτά και ώστε να αποφευχθεί η σύγχυση μεταξύ των ποικίλων οπτικοποιήσεων.

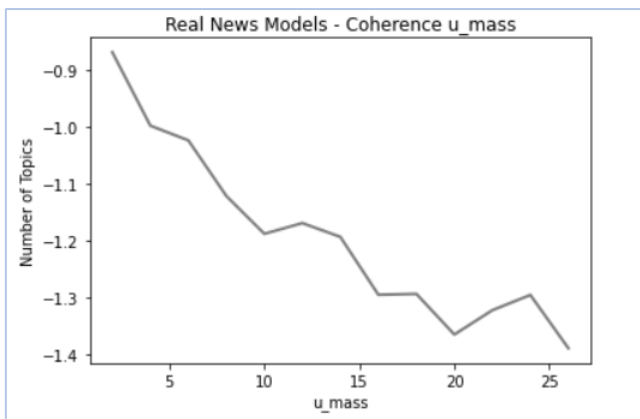
θέμα#2: αθλητισμός) επιλέγονται λιγότερα θέματα ενώ σε άλλη περίπτωση περισσότερα (π.χ. εμπάθουση στα θέματα της πολιτικής όπως: εκλογές, εξωτερική πολιτική, πολιτικός πολιτισμός).

4.5.3. Παραγωγή και Επιλογή Μοντέλων

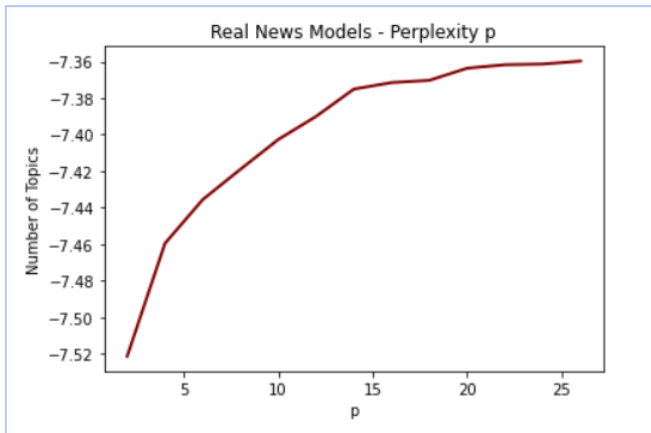
Δημιουργήθηκαν μοντέλα με όριο τα 26 θέματα. Το όριο αυτό προέκυψε από δοκιμές με περισσότερα θέματα τα οποία κατέληγαν να είναι υπερβολικά εξειδικευμένα. Για τις αληθείς δηλώσεις οι τιμές της σύγχυσης και των συνοχών φαίνεται στα Διάγραμμα 4.10, Διάγραμμα 4.11 και Διάγραμμα 4.12 όπου ξεχωρίζουν τα μοντέλα με 10, 20 και 26 θέματα. Για τις ψευδείς δηλώσεις στα αντίστοιχα διαγράμματα Διάγραμμα 4.13, Διάγραμμα 4.14, Διάγραμμα 4.15 διακρίνονται ως καλύτερα τα μοντέλα με 16, 18 και 24 θέματα. Ακολουθεί σχολιασμός των αποτελεσμάτων με την χρήση ενδεικτικών οπτικοποιήσεων.



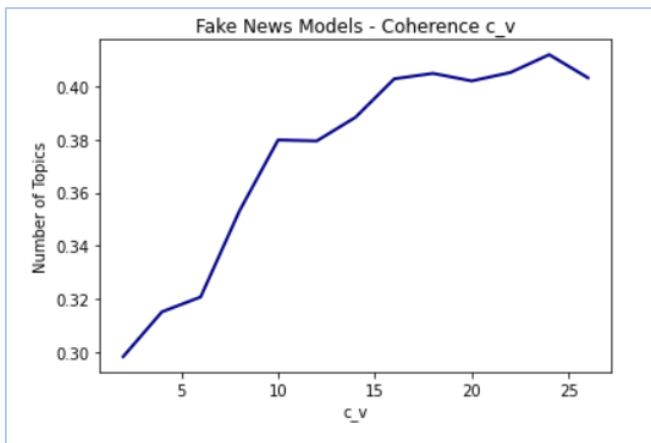
Διάγραμμα 4.10: Συνοχή c_v των Μοντέλων για τις Αληθείς Δηλώσεις



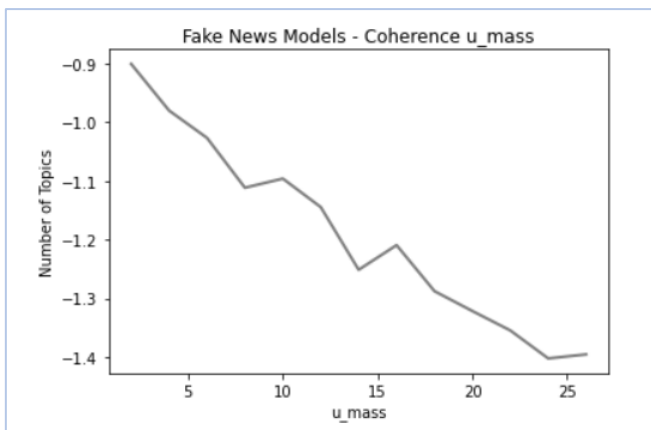
Διάγραμμα 4.11: Συνοχή u_{mass} των Μοντέλων για τις Αληθείς Δηλώσεις




Διάγραμμα 4.12: Περιπλοκή των Μοντέλων για τις Αληθείς Δηλώσεις



Διάγραμμα 4.13: Συνοχή c_v των Μοντέλων για τις Ψευδείς Δηλώσεις




Διάγραμμα 4.14: Συνοχή u_{mass} των Μοντέλων για τις Ψευδείς Δηλώσεις




Διάγραμμα 4.15: Περιπλοκή των Μοντέλων για τις Ψευδείς Δηλώσεις


Προκειμένου να γίνει αντιληπτή η συσχέτιση μεταξύ των θεμάτων του ίδιου μοντέλου δημιουργήθηκε το Σχήμα 4.11 με την συνάρτηση `LdaModel.diff()` του `gensim`. Η συνάρτηση επιστρέφει ένα πίνακα με αποστάσεις μεταξύ των θεμάτων και ένα πίνακα σχολιασμών. Η απόσταση που ορίστηκε είναι η Jaccard, που υπολογίζει την ομοιότητα δύο συνόλων ως την αναλογία του μεγέθους της τομής και του μεγέθους της ένωσής τους (Leskovec, et al., 2020). Στην σύγκριση ενός μοντέλου με τον εαυτό του, επιθυμητό είναι να υπάρχουν όσο το δυνατό λιγότερες ομοιότητες μεταξύ των θεμάτων εκτός από την διαγώνιο που αναφέρεται στην σύγκριση του κάθε θέματος με τον εαυτό του. Όπως φαίνεται στο Σχήμα 4.11 για τις αληθείς δηλώσεις και το μοντέλο των 26 θεμάτων, υπάρχουν αρκετές ομοιότητες μεταξύ των θεμάτων με χαρακτηριστικές των 1, 2 και 22. Στα ψευδή νέα για το μοντέλο των 18 θεμάτων (Σχήμα 4.12) τα θέματα 11, 4, 14 φαίνεται να συσχετίζονται. Στο Σχήμα 4.13 πραγματοποιείται σύγκριση μεταξύ των δύο παραπάνω μοντέλων για να παρατηρηθούν συσχετίσεις στις θεματολογίες των αληθών και ψευδών δηλώσεων. Διακρίνονται αρκετές συσχετίσεις όπως το θέμα #1 του μοντέλου ψευδών δηλώσεων με το θέμα #14 του μοντέλου αληθών δηλώσεων.



Σχήμα 4.11: Διαφορές Θεμάτων για το Μοντέλο των Αληθών Δηλώσεων



Σχήμα 4.12: Διαφορές Θεμάτων για το Μοντέλο των Ψευδών Δηλώσεων




Σχήμα 4.13: Διαφορές Θεμάτων μεταξύ των Μοντέλων Αληθών και Ψευδών Δηλώσεων


Στα παρακάτω σχήματα παρουσιάζονται ενδεικτικά δύο επιλεγμένα θέματα από κάθε κατηγορία (αληθή, ψευδή) όπως οπτικοποιήθηκαν με το pyLDAvis για τα μοντέλα με αριθμό θεμάτων 26 για τις αληθείς δηλώσεις και 18 για τις ψευδείς. Το θέμα #12 των αληθών δηλώσεων έχει πολεμικό χαρακτήρα ενώ το θέμα #26 φαίνεται να αφορά άρθρα με επιχειρησιακό περιεχόμενο. Το θέμα #3 στις ψευδείς δηλώσεις έχει αστυνομικό προσανατολισμό και το θέμα

#9 νομικό. Τα Διάγραμμα 4.16 και Διάγραμμα 4.17 περιέχουν τις δέκα πιο συχνά εμφανιζόμενες λέξεις από τα τέσσερα πρώτα θέματα για κάθε μοντέλο.

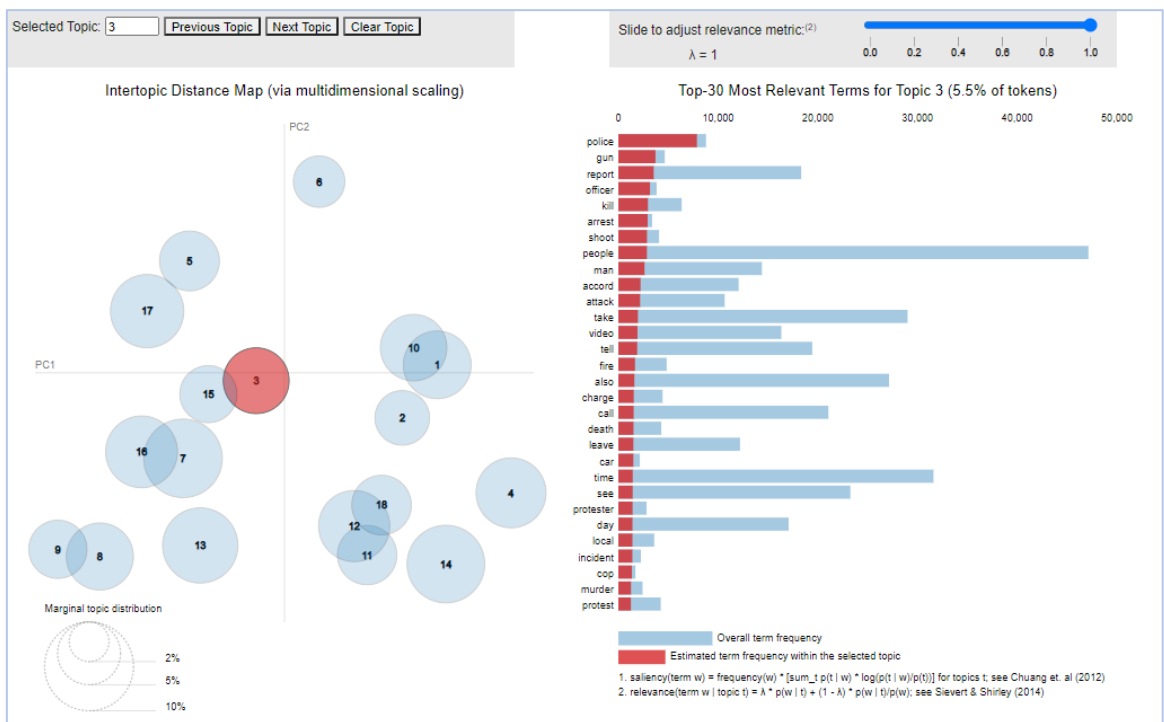
Εξάγονται επίσης χρήσιμες στατιστικές πληροφορίες για την κατανομή των εγγράφων της συλλογής στα θέματα βάσει του κυρίαρχου θέματος που αναδείχθηκε, και το ποσοστό του κυρίαρχου θέματος σε κάθε έγγραφο. Τμήμα της πληροφορίας αυτή για τις ψευδείς ειδήσεις φαίνεται στον Πίνακα 4-1. Στον Πίνακα 4-2 δίνεται πληροφορία για το σύνολο των εγγράφων ανά κυρίαρχο θέμα και το ποσοστό της συλλογής στο οποίο αντιστοιχε



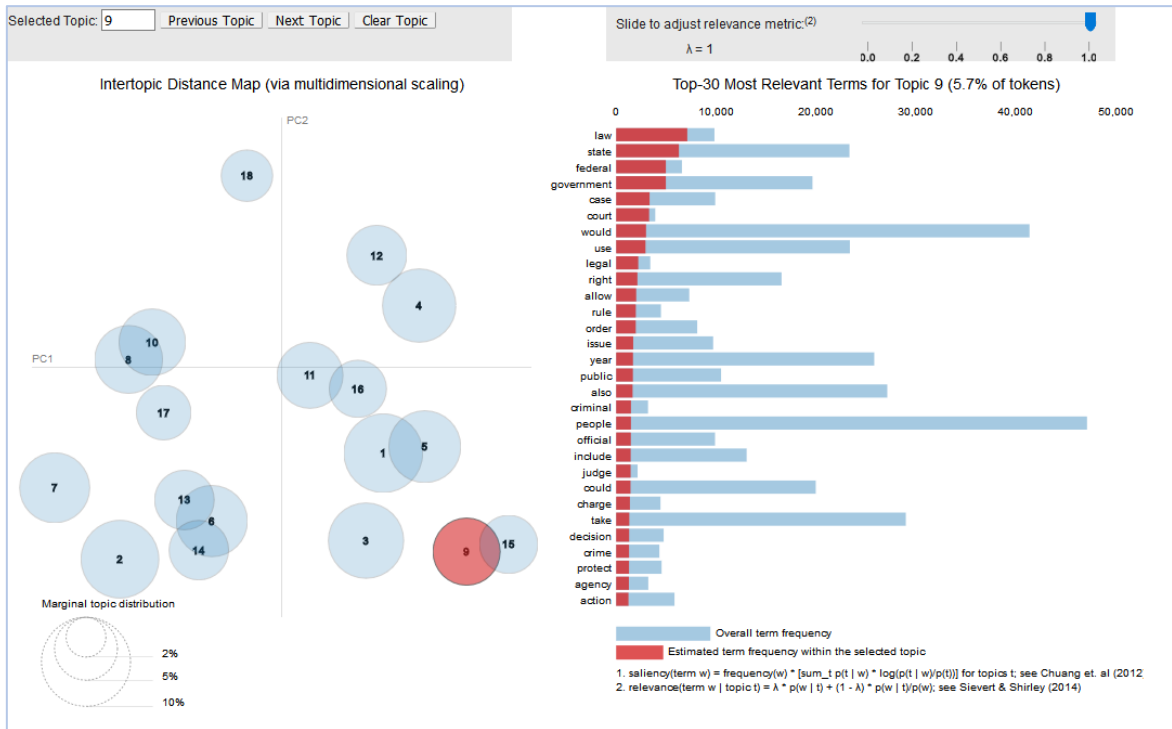
Σχήμα 4.14: Ενδεικτικό Θέμα #12 Αληθών Δηλώσεων




Σχήμα 4.15: Ενδεικτικό Θέμα #26 Αληθών Δηλώσεων



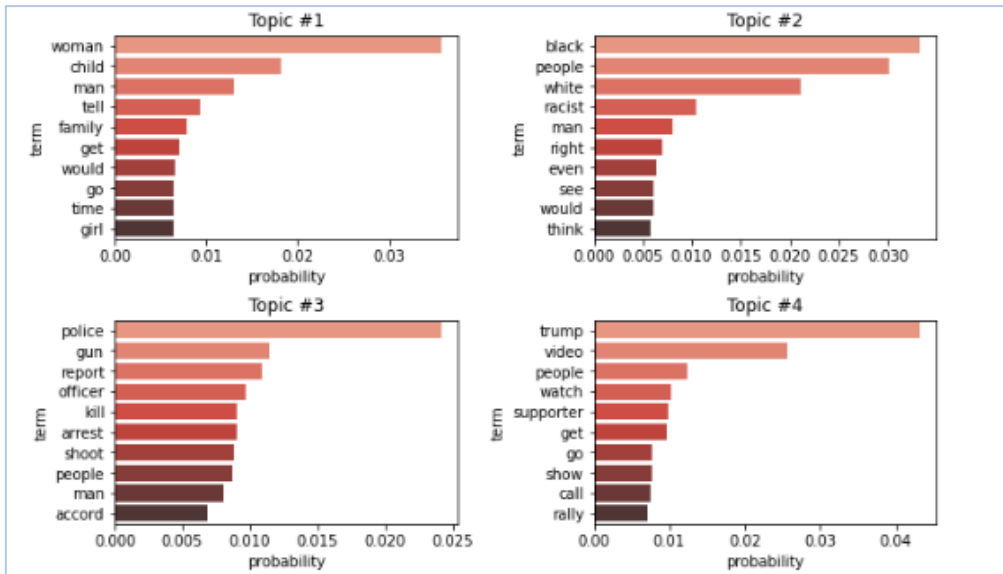
Σχήμα 4.16: Ενδεικτικό Θέμα #3 Ψευδών Δηλώσεων



Σχήμα 4.17: Ενδεικτικό Θέμα #9 Ψευδών Δηλώσεων



Διάγραμμα 4.16: Λέξεις Ενδεικτικών Θεμάτων - Μοντέλο Αληθών Δηλώσεων



Διάγραμμα 4.17: Λέξεις Ενδεικτικών Θεμάτων - Μοντέλο Ψευδών Δηλώσεων

Πίνακας 4-1: Κυρίαρχο Θέμα ανά Έγγραφο – Ψευδείς Ειδήσεις

Document	Dominant Topic	Topic Contrib.	Keywords	Text
0	4	44.94%	trump, video, people, watch, supporter, get, g...	[never, guess, conservative, blowhard, compare...
1	18	50.28%	trump, people, would, pay, job, country, get, ...	[former, drop, massive, truth, bomb, obamacare...
2	18	50.18%	trump, people, would, pay, job, country, get, ...	[internet, go, old, repeatedly, attack, former...
...
33924	13	91.01%	email, investigation, report, campaign, inform...	[campaign, try, hack, wikileaks_julian, assang...
33925	7	52.28%	political, people, world, power, government, c...	[post, television, commercial, system, run, ye...
33926	7	33.88%	political, people, world, power, government, c...	[anti, protester, tools_oligarchy, information...

(CNN)Federal investigators and computer scientists are still trying to figure out why Donald Trump was secretly emailing Bill Clinton. The FBI had named the secret mission RUSSIA, which stood for "R. U. Sure Secret Isn't Affection." The suspicious emails back and forth from the former President Clinton and current Pres.Trump are still being investigated and analyzed. Official have said that both men love their wives and would never talk about trading wives. The statement just raised a frenzy of questions. The odd exchange is under scrutiny and has the FBI working overtime.»

Αποτέλεσμα:

[[1, 0.12292357), (5, 0.07565362), (11, 0.26094672), (13, 0.4806948), (18, 0.04439632)]

Κυρίαρχο θέμα:

Topic #13 - 48.06%

4.5.5. Αξιολόγηση Αποτελεσμάτων

Η διαδικασία σημασιολογικής ανάλυσης και ανίχνευσης της θεματολογίας των αληθών και ψευδών δηλώσεων παρείχε κατατοπιστικά αποτελέσματα όσον αφορά την σημασιολογική ανάλυση και την κατανομή των άρθρων σε εμφανείς και λανθάνουσες συσχετίσεις μεταξύ τους. Τα μοντέλα σχημάτισαν προσιτές αναπαραστάσεις της ποικίλης ύλης των δηλώσεων και παρείχαν αποδοτική κατανομή των δηλώσεων του συνόλου δοκιμής σε αυτές.

4.6. Καθολικό Παράδειγμα Εκτέλεσης

Στην συνέχεια δίνεται ένα παράδειγμα χρήσης για το τελικό αποτέλεσμα των δύο διεργασιών. Το παράδειγμα αφορά σε ψευδές δημοσίευμα. Οι αριθμοί των θεμάτων μπορούν να αντικατασταθούν από ένα όνομα που θα επιλεγθεί να αντιπροσωπεύει το εκάστοτε θέμα (π.χ. topic 5: Ενέργεια, topic 6:Περιβάλλον)

Δεδομένο εισόδου από την συλλογή δοκιμής:

«CNN - Washington Intelligence has learned through very credible sources that the Russians have perfected ways to control President Trump through electronic devices. They are small battery packs that can be slipped into his suit pockets or even as small as a hearing aid or a watch battery that can be placed almost anywhere. They are using electronic signals that have subliminal messages that only the President can hear. Their agenda is clear and the CIA and FBI are monitoring this situation. We do know that Jarred Kushner and Ivanka are secret operatives and are helping to carry this through.»

Σύντομο Αποτέλεσμα:

The article is considered Fake.

Dominant Topic of the article: #6

Εκτενές Αποτέλεσμα:

DNN predicted: [[0.89091927 0.20473047]] . The article is considered Fake.

Top 3 topics found in the article: #5 with 32.0%, #6 with 47.1%, #13 with 18.4%

Dominant Topic: #6 with 47.1%

Top 20 words per topic:

5:: ['use', 'human', 'time', 'see', 'also', 'many', 'world', 'know', 'new', 'could', 'source', 'find', 'pipeline', 'would', 'may', 'people', 'earth', 'energy', 'light', 'come']

6:: ['water', 'use', 'food', 'also', 'may', 'time', 'get', 'year', 'come', 'good', 'day', 'could', 'take', 'plant', 'find', 'live', 'know', 'well', 'show', 'eat']

13:: ['email', 'investigation', 'report', 'campaign', 'information', 'election', 'official', 'story', 'medium', 'know', 'time', 'evidence', 'source', 'release', 'news', 'would', 'tell', 'also', 'use', 'new']

5. Συμπεράσματα και Βελτιώσεις

Ο εντοπισμός των πλαστών νέων είναι ένα επίκαιρο ζήτημα και λόγω της πολυπλοκότητας και των ιδιαιτεροτήτων κάθε είδους ψευδής ειδήσης, κάθε χώρας και κάθε γλώσσας, η εύρεση ενός κοινού μοντέλου δεν έχει ακόμα επιτευχθεί. Στο γεγονός αυτό συμβάλλει και η έλλειψη σχετικών δεδομένων ώστε να παραχθούν ποιοτικά μοντέλα.

Στόχος της έρευνας ήταν να προσεγγίσει υπολογιστικά τις ειδησεογραφικές δηλώσεις υποβοηθώντας το έργο του εντοπισμού των ψευδών ειδήσεων και την παρακολούθηση της θεματολογίας τους. Ο σκοπός των πειραμάτων ήταν αφενός η εύρεση συσχετίσεων μεταξύ των ψευδών και αληθών δηλώσεων ώστε να κατηγοριοποιηθούν ανάλογα με την αξιοπιστία τους και αφετέρου η σημασιολογική ανάλυσή τους ώστε να κατανεμηθούν σε θέματα που χαρακτηρίζονται από κοινά μοτίβα. Αρχικά δημιουργήθηκαν δύο σύνολα δεδομένα, ένα για την εκπαίδευση (σύνολο εκπαίδευσης) και ένα για τον έλεγχο των τελικών μοντέλων (σύνολο επικύρωσης). Έπειτα κλήθηκαν να επιλεχθούν οι τεχνολογίες που θα χρησιμοποιηθούν για κάθε διεργασία, και να ελεγχθούν μέσω πειραματικών δοκιμών και υλοποιήσεων παράγοντας τα μοντέλα. Τα μοντέλα κλήθηκαν να παραμετροποιηθούν, έπειτα να ξεχωρίσουν τα πιο αποδοτικά και να επαναληφθεί η πειραματική διαδικασία παράγοντας τα τελικά μοντέλα και εδραιώνοντάς τα με εκτέλεση στην καινούρια συλλογή δεδομένων. Τα συνολικά αποτελέσματα ήταν ικανοποιητικά και θεωρείται πως επιτεύχθηκαν οι παραπάνω στόχοι. Το νευρωνικό δίκτυο κατάφερε να εκπαιδευτεί ώστε να εντοπίσει με επιτυχία την αξιοπιστία των δηλώσεων και τα μοντέλα θεμάτων εντόπισαν επιτυχώς σημασιολογικές συσχετίσεις και ποιοτικά topics. Τα μοντέλα είχαν καλή απόδοση και στα νέα δεδομένα στα οποία ελέγχθηκαν. Στην συνέχεια αναφέρονται συνοπτικά οι υποδιεργασίες στις οποίες διασπάστηκε το πείραμα, δυσκολίες που αντιμετωπίστηκαν, πιθανές βελτιώσεις και προοπτικές.

Πρώτο σημαντικό βήμα ήταν η εύρεση ποιοτικών, σχετικών με το πρόβλημα, δεδομένων μεγάλου σχετικά όγκου και διαφόρων θεμάτων ώστε να μπορούν τα μοντέλα να εξάγουν ποιοτική γνώση. Εκτός από το βασικό dataset αναζητήθηκαν συλλογές δεδομένων για να εξεταστούν σε αυτές τα τελικά μοντέλα. Η αναζήτηση παρουσίασε ανασταλτικό παράγοντα διότι τα θέματα των συλλογών ήταν κυρίως πολιτικά ή τα δεδομένα προέρχονταν μόνο από κοινωνικά δίκτυα ή αποτελούνταν μόνο από τίτλους (headlines). Κάποιες συλλογές απαιτούσαν αρκετή επεξεργασία προκειμένου να καθαριστεί ο θόρυβος και να μορφοποιηθούν βάσει μίας κοινής γραμμογράφησης για να δημιουργηθεί το τελικό dataset.

Για την πρώτη ερευνητική περιοχή χρειάστηκαν πολύ περισσότερα πειράματα για την επιλογή της πιο κατάλληλης αρχιτεκτονικής και τον συντονισμό των υπερπαραμέτρων του δικτύου, χρονοβόρες διαδικασίες που συνεπάγονται την δημιουργία και τον έλεγχο πολλών μοντέλων. Το γεγονός αυτό αλλά και η ανάγκη διερεύνησης των σύγχρονων εργαλείων, έκρινε σκόπιμη την χρήση κατάλληλου υλικού (GPU) για την μείωση του χρόνου των διεργασιών, και την πιο έγκαιρη επίλυση του προβλήματος. Κομβικό σημείο ήταν η κατανόηση των frameworks, της χρήσης τους και του συντονισμού τους. Οι τεχνολογίες και τα frameworks που χρησιμοποιήθηκαν για το BND είναι πολύ ισχυρά και προσφέρουν πληθώρα δυνατοτήτων στην περιοχή της επιστήμης δεδομένων και της αναλυτικής. Το tensorflow επιτρέπει σε εφαρμογές να εκτελούνται σε GPU και CPU και μέσω του Keras η ανάπτυξη των BND είναι πιο προσιτή στον χρήστη προσφέροντας μεγάλο επίπεδο αφαιρετικότητας και ελέγχου. Τόσο κατά την εκπαίδευση των μοντέλων όσο και στα παραγόμενα μοντέλα υπάρχει δυνατότητα οπτικοποιήσεων με την χρήση του tensorboard· τα διαγράμματα μπορούν να συμβάλουν στην σύγκριση των μοντέλων και στην παρακολούθηση της διαδικασίας εκπαίδευσης. Προβλήματα παρουσιάστηκαν κατά τις πρώτες δοκιμές στον προσωπικό υπολογιστή στην δημιουργία περιβάλλοντος Tensorflow, CUDA, Tensorboard και στην μετάβασή του πειράματος στην πλατφόρμα spell, τα οποία αποδείχτηκε πως ήταν κυρίως ασυμβατότητες εκδόσεων βιβλιοθηκών και διαφορές μεταξύ των λειτουργικών συστημάτων. Το τελικό δίκτυο εκτός από τα αποτελέσματά του στο σύνολο εκπαίδευσης φαίνεται να είχε κάποια προσαρμογή στο σύνολο επικύρωσης· παρήγαγε όμως προβλέψεις με σχετική αβεβαιότητα. Δεδομένου ότι το σύνολο επικύρωσης ήταν μικρού όγκου και ετερογενές, δεν αρκεί ώστε να προκύψει τελικό συμπέρασμα, αποτελεί όμως μία πρώτη θετική εικόνα· η εικόνα αυτή ενισχύεται λαμβάνοντας υπόψη πως μοντέλα που δημιουργήθηκαν κατά τους πρώτους πειραματισμούς

ήταν αποδοτικά εντός του συνόλου εκπαίδευσης όχι όμως σε δεδομένα εκτός αυτού. Ως βελτίωση για τις διεργασίες κατηγοριοποίησης προτείνεται η εκπαίδευση του μοντέλου σε περισσότερα δεδομένα ποικίλης θεματολογίας και ο έλεγχός τους σε περισσότερα δεδομένα επικύρωσης. Μία άλλη προσέγγιση που μπορεί να υιοθετηθεί, απαιτεί όμως κατάλληλο dataset, είναι η σήμανση (label) των νέων με περισσότερες από δύο ετικέτες είτε ανάλογα με τον τύπο της παραπληροφόρησης (π.χ. θεωρία συνομωσίας, κίτρινος τύπος, κ.ά.) είτε ανάλογα με το ποσοστό αξιοπιστίας. Ενδεχόμενη βελτίωση αλλά και πειραματικό ενδιαφέρον μπορεί να προκύψει από επιπρόσθετες δοκιμές συντονισμού υπερπαραμέτρων ώστε να παρατηρηθεί η συμπεριφορά του μοντέλου. Μπορεί επίσης να διεξαχθεί πειραματισμός με άλλες αρχιτεκτονικές (τοπολογία, TPU) και συνδυασμούς τους για την επίλυση του ίδιου προβλήματος.

Η δεύτερη ερευνητική περιοχή είχε λιγότερες πειραματικές και χρονικές απαιτήσεις συγκριτικά με το νευρωνικό δίκτυο. Η βιβλιοθήκη genism παρέχει αρκετά εργαλεία σχετικά με την μοντελοποίηση θεμάτων και σημαντικό ρόλο είχαν οι βιβλιοθήκες για την οπτικοποίηση των αποτελεσμάτων. Τα θέματα που εντοπίστηκαν ήταν προσιτά στον παρατηρητή και περιέγραφαν επαρκώς την πραγματική ύλη των δηλώσεων, στον βαθμό που αυτή ήταν δυνατό να ελεγχθεί. Παρείχαν μία εμβάθυνση στις σημασιολογικές συσχετίσεις των κειμένων ώστε να γίνει πιο κατανοητή η συλλογή και οι λανθάνουσες συσχετίσεις που ενσωματώνει. Η κατανομή των δηλώσεων της συλλογής επικύρωσης σε αυτά ήταν κατατοπιστική. Ενδιαφέρον θα παρουσίαζε η παραγωγή λιγότερων και κυρίως περισσότερων θεμάτων (topics) ώστε να αναδυθούν συσχετίσεις που μπορεί να μην είναι αντιληπτές από τον παρατηρητή. Βελτιώσεις μπορεί να προκύψουν από δοκιμές συντονισμού υπερπαραμέτρων (π.χ. alpha) και περισσότερες οπτικοποιήσεις π.χ. χαρακτηριστικές προτάσεις ανά θέμα. Εναλλακτική επιλογή αποτελεί η χρήση μίας συλλογής σημασμένης ως προς το θέμα ώστε η επικύρωση να μην πραγματοποιείται μόνο μέσω των μετρήσεων συνοχής, σύγχυσης, και ερμηνευσιμότητας.

Ερευνητικό ενδιαφέρον θα είχε η εκτέλεση της διαδικασίας σε (Αγγλικής γλώσσας) συλλογές δεδομένων που προέρχονται από διαφορετικές χώρες ή χρονικό εύρος κομβικών γεγονότων ώστε να παρατηρηθούν οι τάσεις στις θεματολογίες ψευδών και αληθών δηλώσεων. Η ανακάλυψη και ανάδειξη περισσότερων δυνατοτήτων των εργαλείων που χρησιμοποιήθηκαν είναι επίσης μία πηγή έρευνας. Μελλοντική προοπτική μπορούσε να αποτελεί η δημιουργία ενός ολοκληρωμένου περιβάλλοντος web για πρόβλεψη fake news στο οποίο θα μπορούσαν να εκτελεστούν τα μοντέλα, με την αξιοποίηση serverless αρχιτεκτονικών, σε δεδομένα εισόδου που θα παρέχονται από τον χρήστη (μεταφόρτωση, URL) ή από υπάρχουσες πηγές. Στην εφαρμογή θα μπορούσαν επίσης να εκπαιδεύονται μοντέλα με χαρακτηριστικά και παραμέτρους που θα επιλέγει ο χρήστης.

Συντομεύσεις και Αρκτικόλεξα

AI	Artificial Intelligence
ANN	Artificial Neural Network
API	Application Programming Interface
BLSTM	Bidirectional Long Short-Term Memory
BoW	Bag of Words
CNN	Convolutional Neural Networks
CPU	Central Processing Unit
CUDA	Compute Unified Device Architecture
CuDNN	Cuda Deep Neural Network
DBN	Deep Belief Network
DNN	Deep Neural Network
DSN	Deep Stacking Network
GDU	Gated Diffusive Unit
GPU	Graphics Processing Unit
GRU	Gated Recurrent Unit
HDP	Hierarchical Dirichlet Process
ISOT	Information Security and Object Technology
KDD	Knowledge Discovery in Databases
KDT	Knowledge Discovery in Texts
LDA	Latent Dirichlet Allocation
LM	Language Model
LSTM	Long Short-Term Memory
ML	Machine Learning
NLP	Natural Language Processing
NLTK	Natural Language Toolkit
NLU	Natural Language Understanding
RNN	Recurrent Neural Networks
TF-IDF	Term Frequency-Inverse Document Frequency
TPU	Tensor Processing Unit
vCPU	virtual Central Processing Unit
VRAM	Video Random Access Memory
ΒΝΔ	Βαθύ Νευρωνικό Δίκτυο
ΚΝΣ	Κεντρικό Νευρικό Σύστημα
ΜΚΔ	Μέσα Κοινωνικής Δικτύωσης
ΠΝΣ	Περιφερικό Νευρικό Σύστημα
ΤΝΔ	Τεχνητό Νευρωνικό Δίκτυο

Βιβλιογραφία

- Abadi, M., et al. 2015.** TensorFlow: Large-scale machine learning on heterogeneous systems. *Software available from tensorflow.org*. 2015.
- Ahmed, H, Traore, I and Saad, S. 2018.** Detecting opinion spams and fake news using text. *Journal of Security and Privacy*. 2018, Vol. 1, 1.
- Ahmed, H., Traore, I. and Saad, S. 2017.** Detection of Online Fake News Using N-Gram Analysis. [compl.] I. Traore, I. Woungang and A. Awad. *Intelligent, Secure, and Dependable Systems in Distributed and Cloud Environments*. s.l. : Springer, Cham, 2017. Vol. 10618, pp. 127-138.
- Aletras, N. και Stevenson, M. 2013.** *Evaluating topic coherence using distributional semantics*. 2013. σσ. 13-22, In Proceedings of the 10th International Conference on Computational Semantics.
- Allcott, H., Gentzkow, M. and Yu, C. 2019.** *Trends in the Diffusion of Misinformation on Social Media*. s.l. : National Bureau of Economic Research, Inc, 2019. 25500.
- Anaconda Inc.** Anaconda Individual Edition. *Anaconda*. [Online] Anaconda Inc. <https://www.anaconda.com/products/individual>.
- Big Data Analytics for Genomic Medicine*. **Karen, Y, HeDongliang, Ge and Max, He M. 2017.** s.l. : MDPI, 2017, International Journal of Molecular Sciences, p. 412.
- Biswas-Diener, Robert. 2020.** The brain and nervous system. *Noba textbook series: Psychology*. 2020.
- Blei, D. 2017.** Probabilistic Topic Models and User Behavior. *Columbia University*. [Online] 2017.
- Blei, David M., Ng, Andrew Y. and L, Micheal I. Jordan. 2003.** Latent Dirichlet Allocation. *Journal of Machine Learning Research*. 2003, pp. 993-1022.
- Brew, C. and Rosner, M. 2018.** *Proceedings of the ACL-02 Workshop on Effective tools and methodologies for teaching natural language processing and computational linguistics - Volume 1*. Stroudsburg, USA : Association for Computational Linguistics, 2018.
- Bwalya, Kelvin J. 2018.** Data Governance, Open Governance, Freedom of Information and e-Government. *The e-Government Development Discourse: Analysing Contemporary and Future Growth Prospects in Developing and Emerging Economies*. South Africa : Open Access Journal Publishing, 2018.
- CERN. 2012.** Processing: What to record? *CERN Accelerating science*. [Online] Αύγουστος 2012. <https://home.cern/about/computing/processing-what-record>.
- Chang, Jonathan, et al. 2009.** Reading tea leaves: how humans interpret topic models. *Proceedings of the 22nd International Conference on Neural Information Processing Systems*. 2009, pp. 288-296.
- CloudMoyo.** Sources of big data: Where does it come from. *CloudMoyo*. [Online] <https://www.cloudmoyo.com/blog/data-architecture/what-is-big-data-and-where-it-comes-from/>.
- Domo. 2018.** Data Never Sleeps 6.0. *Domo*. [Online] Ιανουάριος 2018. <https://www.domo.com/learn/data-never-sleeps-6>.
- Eisenstein, Jacob. 2019.** *Introduction to Natural Language Processing (Adaptive Computation and Machine Learning series)*. s.l. : MIT Press, 2019.
- Eluyode, O.S. and Akomolafe, Dipo Theophilus. 2013.** Comparative study of biological and artificial neural networks. *European Journal of Applied Engineering and. Scholars Research Library*, 2013.
- Gaillard, Mélissa. 2017.** CERN Accelerating Science. *CERN Data Centre passes the 200-petabyte milestone*. [Online] CERN, Ιούλιος 6, 2017. <https://home.cern/about/updates/2017/07/cern-data-centre-passes-200-petabyte-milestone>.

- Ghafari, S., M., et al. 2018.** Social context-aware trust prediction: methods for identifying fake news. Springer, Cham *International Conference on Web Information Systems Engineering*. 2018. pp. 161-177.
- Girgis, S., Amer, E. and Gadallah, M. 2018.** Deep Learning Algorithms for Detecting Fake News in Online Text. 2018. 10.1109/ICCES.2018.8639198.
- Graupe, D. 2007.** *Principles of Artificial Neural Networks*. 2. Singapore : World Scientific Publishing Co. Pte. Ltd., 2007. Vol. 6.
- Gulli, Antonio and Pal, Sujit. 2017.** *Deep learning with Keras*. s.l. : Packt Publishing Ltd, 2017.
- Haines, D. and Ratcliff, G. 2020.** The Central Nervous System. *Encyclopædia Britannica*, [Online] Encyclopædia Britannica, inc., 04 2020. <https://www.britannica.com/science/human-nervous-system/The-central-nervous-system>.
- Hawkins, Douglas. 2004.** The Problem of Overfitting. *Journal of Chemical Information and Computer Sciences*. 2004.
- Holst, Arne. 2018.** Big data market size revenue forecast worldwide from 2011 to 2027. *Statista - The Statistics Portal for Market Data, Market Research and Market Studies*. [Online] Statista, 2018. <https://www.statista.com/statistics/254266/global-big-data-market-forecast/>.
- Information security and object technology (ISOT) research lab. 2018.** ISOT Fake News Dataset. *University of Victoria*. [Online] 2018. https://www.uvic.ca/engineering/ece/isot/assets/docs/ISOT_Fake_News_Dataset_ReadMe.pdf.
- International Conference on Machine Learning. Arora, S., et al. 2013.** 2013. A Practical Algorithm for Topic Modeling with Provable Guarantees. pp. 280-288.
- Jiawei Han, Jian Pei, Micheline Kamber. 2011.** *Data Mining: Concepts and Techniques*. s.l. : Elsevier, 2011.
- Jones, T. 2017.** Deep learning architectures: The rise of artificial intelligence. *IBM Developer*. [Online] IBM, 10 2017. <https://developer.ibm.com/technologies/artificial-intelligence/articles/cc-machine-learning-deep-learning-architectures/>.
- Jruvika, B. 2018.** Fake News Detection. *Kaggle*. [Online] 2018. <https://www.kaggle.com/jruvika/fake-news-detection>.
- Lata, Gohil. 2015.** Text Mining: Process and Techniques. *International Journal of Innovative Research in Computer Science & Technology*. 2015, Vol. 3, 3.
- Leskovec, Jure, Rajaraman, Anand and Ullman, Jeff. 2020.** *Mining of Massive Datasets*. s.l. : Cambridge University Press, 2020. 10.1017/9781108684163.
- Likhitha, S., Harish, B. and Keerthi Kumar, M. 2019.** A Detailed Survey on Topic Modeling for Document and Short Text Data. *International Journal of Computer Applications*. 2019, Vol. 178.
- Maimon, O. and Rokach, L. 2005.** *The Data Mining and Knowledge Discovery Handbook*. New York : Springer Science + Business Media Inc., 2005.
- Maronikolakis, A. 2019.** Fake News Data. *Kaggle*. [Online] 2019. <https://www.kaggle.com/antmarakis/fake-news-data>.
- Mimno, D., και συν. 2011.** *Optimizing semantic coherence in topic models*. s.l. : Association for Computational Linguistics, 2011. σσ. 262-272, In Proceedings of the Conference on Empirical Methods in Natural Language Processing.
- Najafabadi, M. M., et al. 2015.** Deep learning applications and challenges in big data analytics. *Journal of Big Data*. 2, 2015, Vol. 1.
- Nick Galov. 2020.** <https://hostingtribunal.com/blog/wordpress-statistics/>. *Hosting Tribunal*. [Online] Hosting Tribunal, 2020. <https://hostingtribunal.com/blog/wordpress-statistics/>.
- Nielsen, Michael. 2015.** *Neural Networks and Deep Learning*. s.l. : Determination Press, 2015.
- Noback, C. and Haines, D. 2020.** The Peripheral Nervous System. *Encyclopædia Britannica*. [Online] Encyclopædia Britannica, inc., 2020. <https://www.britannica.com/science/human-nervous-system/The-peripheral-nervous-system>.

- Özgöbek, Özlem and Gulla, J. 2018.** *Towards an Understanding of Fake News*. Norway : s.n., 2018.
- Pennington, Jeffrey, Socher, R. and Manning, C. 2014.** GloVe: Global Vectors for Word Representation. *GloVe*. [Online] 2014. <https://nlp.stanford.edu/projects/glove/>.
- Perez-Rosas, V, et al. 2018.** *Automatic Detection of Fake News*. New Mexico : s.n., 2018. Proceedings of the International Conference on Computational Linguistics.
- PolitiFact. 2020.** The Principles of the Truth-O-Meter: PolitiFact's methodology for independent fact-checking. *PolitiFact*. [Online] The Poynter Institute, 8 2020. <https://www.politifact.com/article/2018/feb/12/principles-truth-o-meter-politifact-methodology-i/>.
- Raluca, Chitic. 2018.** real-or-fake. *Kaggle*. [Online] 2018. <https://www.kaggle.com/rchitic17/real-or-fake>.
- Řehůřek, Radim and Sojka, Petr. 2010.** *Software Framework for Topic Modelling with Large Corpora*. Valletta, Malta : ELRA, 2010.
- Risdal, M. 2016.** Getting Real about Fake News. *Kaggle*. [Online] 2016. <https://www.kaggle.com/mrisdal/fake-news/data>.
- Robinson Meyer. 2016.** How Many Stories Do Newspapers Publish Per Day. *The Atlantic*. [Online] 05 26, 2016. <https://www.theatlantic.com/technology/archive/2016/05/how-many-stories-do-newspapers-publish-per-day/483845/>.
- Röder, M., Both, A. και Hinneburg, A. 2015.** *Exploring the Space of Topic Coherence Measures*. 2015. In Proceedings of the eighth International Conference on Web Search and Data Mining.
- Sarvepalli, Sarat Kumar. 2015.** *Deep Learning in Neural Networks: The science behind an Artificial Brain*. 2015. 10.13140/RG.2.2.22512.71682.
- Sengupta, S., et al. 2020.** A review of deep learning with special emphasis on architectures, applications and recent trends. *Knowledge-Based Systems*. 2020, Vol. 194.
- Shu, K., et al. 2017.** Fake News Detection on Social Media: A Data Mining Perspective. *SIGKDD Explorations*. 1, 2017, Vol. 19.
- Steni, T. S, and SREEJA, P.S. 2020.** Fake News Detection on Social Media-A Review. *Test Engineering and Management*. 04 2020, Vol. 83, pp. 12997-13003.
- TensorFlow. 2019.** TensorFlow Core v2.1.0 | tf.keras.regularizers.l2. *TensorFlow*. [Online] 2019. https://www.tensorflow.org/versions/r2.1/api_docs/python/tf/keras/regularizers/l2.
- The Editors of Encyclopaedia Britannica. 2019.** Autonomic nervous system. *Encyclopaedia Britannica*. [Online] Encyclopædia Britannica, inc, 01 2019. <https://www.britannica.com/science/autonomic-nervous-system>.
- University of Queensland. 2018.** Queensland Brain Institute. *The Brain*. [Online] The University of Queensland, 07 17, 2018. <https://qbi.uq.edu.au/brain/brain-anatomy>.
- Wang, C., Paisley, J. και Blei, M., D. 2011.** *Online Variational Inference for the Hierarchical Dirichlet Process*. s.l. : JMLR, 2011.
- Wang, W., Y. 2017.** "Liar, Liar Pants on Fire" :A New Benchmark Dataset for Fake News Detection. s.l. : arXiv preprint, 2017. arXiv:1705.00648.
- Ward, Jonathan Stuart and Barker, Adam. 2013.** *Undefined By Data: A Survey of Big Data Definitions*. s.l. : ArXiv, 2013.
- Witten I. H., Frank, E. 2000.** *Data Mining Practical Machine Learning Tools and Techniques with Java*. San Francisco : Morgan Kaufmann Publishers, 2000.
- Witten, Ian H., Eibe, Frank and Hall, Mark A. 2011.** *Data Mining: Practical Machine Learning Tools and Techniques*. 3. s.l. : Elsevier, 2011.
- Zhang, J., Dong, B. and Yu, S. 2018.** *FAKEDETECTOR: Effective Fake News Detection with Deep Diffusive Neural Network*. s.l. : arXiv preprint, 2018. arXiv:1805.08751.
- Αργυράκης, Π. 2001.** *Νευρωνικά Δίκτυα και Εφαρμογές*. Πάτρα : Ελληνικό Ανοικτό Πανεπιστήμιο, 2001.

Βερούκιος, Β., Καγκλής, Β. and Σταυρόπουλος, Η. 2015. *Η επιστήμη των δεδομένων μέσα από τη γλώσσα R*. Αθήνα : Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών, 2015.

Βλαχάβας, Ιωάννης, et al. 2006. *Τεχνητή Νοημοσύνη*. s.l. : Β. Γκιούρδας Εκδοτική, 2006.

Γεωργούλη, Κατερίνα. 2015. *Τεχνητή Νοημοσύνη*. Αθήνα : Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών, 2015.

Κύρκος, Ευστάθιος. 2015. *Επιχειρηματική Ευφυΐα και Εξόρυξη Δεδομένων*. Αθήνα : Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών, 2015.

Φραγκοράπτης, Ελευθέριος Δ. 2015. *Φυσικοθεραπεία σε Βλάβες του Περιφερικού Νευρικού Συστήματος*. Αθήνα : Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών, 2015.