



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ

ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ

ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ

**Ανάπτυξη συστήματος προτάσεων κρασιών με
χρήση LLM**

Σαμαρά Αικατερίνη

ΑΜ: 2120002

Επιβλέπων

Κολομβάτσος Κωνσταντίνος

«Με ατομική μου ευθύνη και γνωρίζοντας τις κυρώσεις ⁽¹⁾, που προβλέπονται από της διατάξεις της παρ. 6 του άρθρου 22 του Ν. 1599/1986, δηλώνω ότι:

1. Δεν παραθέτω κομμάτια βιβλίων ή άρθρων ή εργασιών άλλων αυτολεξεί **χωρίς να τα περικλείω σε εισαγωγικά** και χωρίς να αναφέρω το συγγραφέα, τη χρονολογία, τη σελίδα. Η αυτολεξεί παράθεση χωρίς εισαγωγικά χωρίς αναφορά στην πηγή, είναι λογοκλοπή. Πέραν της αυτολεξεί παράθεσης, λογοκλοπή θεωρείται και η παράφραση εδαφίων από έργα άλλων, συμπεριλαμβανομένων και έργων συμφοιτητών μου, καθώς και η παράθεση στοιχείων που άλλοι συνέλεξαν ή επεξεργάστηκαν, χωρίς αναφορά στην πηγή. Αναφέρω πάντοτε με πληρότητα την πηγή κάτω από τον πίνακα ή σχέδιο, όπως στα παραθέματα.

2. Δέχομαι ότι η αυτολεξεί **παράθεση χωρίς εισαγωγικά**, ακόμα κι αν συνοδεύεται από αναφορά στην πηγή σε κάποιο άλλο σημείο του κειμένου ή στο τέλος του, είναι αντιγραφή. Η αναφορά στην πηγή στο τέλος π.χ. μιας παραγράφου ή μιας σελίδας, δεν δικαιολογεί συρραφή εδαφίων έργου άλλου συγγραφέα, έστω και παραφρασμένων, και παρουσίασή τους ως δική μου εργασία.

3. Δέχομαι ότι υπάρχει επίσης περιορισμός στο μέγεθος και στη συχνότητα των παραθεμάτων που μπορώ να εντάξω στην εργασία μου εντός εισαγωγικών. Κάθε μεγάλο παράθεμα (π.χ. σε πίνακα ή πλαίσιο, κλπ), προϋποθέτει ειδικές ρυθμίσεις, και όταν δημοσιεύεται προϋποθέτει την άδεια του συγγραφέα ή του εκδότη. Το ίδιο και οι πίνακες και τα σχέδια

4. Δέχομαι όλες τις συνέπειες σε περίπτωση λογοκλοπής ή αντιγραφής.

Ημερομηνία:/...../20.....

Ο – Η Δηλ.

(1) «Όποιος εν γνώσει του δηλώνει ψευδή γεγονότα ή αρνείται ή αποκρύπτει τα αληθινά με έγγραφη υπεύθυνη δήλωση του άρθρου 8 παρ. 4 Ν. 1599/1986 τιμωρείται με φυλάκιση τουλάχιστον τριών μηνών. Εάν ο υπαίτιος αυτών των πράξεων

σκόπευε να προσπορίσει στον εαυτόν του ή σε άλλον περιουσιακό όφελος βλάπτοντας τρίτον ή σκόπευε να βλάψει άλλον, τιμωρείται με κάθειρξη μέχρι 10 ετών.»

Περίληψη

Στην παρούσα πτυχιακή εργασία παρουσιάζεται η έννοια της Τεχνητής Νοημοσύνης (Artificial Intelligence), γίνονται αναφορές στα κύρια πεδία εφαρμογής και αναλύονται οι βασικές κατηγορίες της. Στη συνέχεια, γίνεται εισαγωγή στην έννοια της Μηχανικής Μάθησης (Machine Learning), ενός βασικού υποπεδίου της Τεχνητής Νοημοσύνης, και παρατίθεται η διάκριση στα είδη της. Ακολουθεί συνοπτική παρουσίαση της Βαθιάς Μάθησης (Deep Learning) με έμφαση στην αρχιτεκτονική και τα επιμέρους κομμάτια της. Τέλος, εξετάζονται τα Μεγάλα Γλωσσικά Μοντέλα (LLMs), παρουσιάζοντας τα βασικά χαρακτηριστικά τους, τις σχετικές βιβλιοθήκες, την αρχιτεκτονική των Μετασχηματιστών (Transformers) που τα υποστηρίζει, καθώς και τη διαδικασία fine-tuning που επιτρέπει την εξειδίκευσή τους σε συγκεκριμένες εργασίες. Αφού παρουσιάστηκαν τα βασικά θεωρητικά στοιχεία που σχετίζονται με την Τεχνητή Νοημοσύνη, τη Μηχανική και Βαθιά Μάθηση, καθώς και τα Μεγάλα Γλωσσικά Μοντέλα, η εργασία προχωρά στην υλοποίηση ενός προτεινόμενου μοντέλου. Συγκεκριμένα, σχεδιάστηκε και αναπτύχθηκε ένα απλοποιημένο γλωσσικό μοντέλο τύπου Transformer, με στόχο την ανάλυση και την πρόβλεψη των χαρακτηριστικών των οίνων με βάση τις κριτικές εξειδικευμένων ατόμων, αξιοποιώντας δεδομένα από την πλατφόρμα Kaggle.

Περιεχόμενα

1. Εισαγωγή	7
2. Τεχνητή Νοημοσύνη (Artificial Intelligence)	8
2.1 Τι είναι η τεχνητή νοημοσύνη	8
2.2 Που χρησιμοποιείται	8
2.2.1 Κλάδος Υγείας.....	8
2.2.2 Κλάδος Εκπαίδευσης	9
2.2.3 Κλάδος Marketing	11
2.2.4 Κλάδος Προγνωστικής Συντήρησης	11
2.3 Επίπεδα Τεχνητής Νοημοσύνης.....	12
3. Μηχανική Μάθηση (Machine Learning)	15
3.1 Ορισμός.....	15
3.2 Είδη Μηχανικής Μάθησης.....	15
3.2.1 Επιβλεπόμενη Μάθηση (Supervised Learning)	15
3.2.2 Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning)	19
3.2.3 Ενισχυτική Μάθηση (Reinforcement Learning).....	21
3.2.4 Ημιαυτοεπιβλεπόμενη Μάθηση (Semi-Supervised Learning)	22
4. Βαθιά Μάθηση (Deep Learning)	25
4.1 Ορισμός Βαθιάς Μάθησης	25
4.2 Βασικές Έννοιες.....	25
4.3 Είδη Βαθιάς Μάθησης.....	27
4.3.1 Συνελικτικό Νευρωνικό Δίκτυο (Convolutional Neural Network - CNN)	28
4.3.2 Συνελικτική Λειτουργία (Convolutional Operation)	28
4.3.3 Το Συνελικτικό Στρώμα (Convolutional Layer)	29
4.3.4 Η Αρχιτεκτονική των Συνελικτικών Νευρωνικών Δικτύων (Convolutional Neural Network Architectures)	31
4.3.5 Επαναλαμβανόμενα Νευρωνικά Δίκτυα (Recurrent Neural Networks - RNN)	36
4.3.6 Περιορισμένο Μηχάνημα Boltzmann (Restricted Boltzmann Machine - RBM)	37
4.3.7 Autoencoders (Autoassociators)	38
5. Μεγάλα Γλωσσικά Μοντέλα (Large Language Models - LLM).....	40
5.1 Γενικά	40
5.2 Βασικές Τεχνικές Πτυχές των Μεγάλων Γλωσσικών Μοντέλων	40
5.2.1 Tokenization	40
5.2.2 Encoding Positions	40
5.2.3 Μηχανισμοί Προσοχής (Attention Mechanisms)	41
5.2.4 Συναρτήσεις Ενεργοποίησης (Activation Functions).....	43

5.2.5 Στρωματική Κανονικοποίηση (Layer Normalization)	44
5.2.6 Διαμοιρασμένη Εκπαίδευση (Distributed Training)	44
5.3 Οι Βιβλιοθήκες των Μεγάλων Γλωσσικών Μοντέλων	45
5.4 Η αρχιτεκτονική των Transformer για τα Μεγάλα Γλωσσικά Μοντέλα	46
5.5 Fine-Tuning Μεγάλων Γλωσσικών Μοντέλων	48
5.5 Προεκπαιδευμένα Μεγάλα Γλωσσικά Μοντέλα.....	49
5.5.1 Προεκπαιδευμένα Μεγάλα Γλωσσικά Μοντέλα Γενικού Σκοπού	50
5.5.2 Προεκπαιδευμένα Μεγάλα Γλωσσικά Μοντέλα Προγραμματισμού.....	51
6. Προτεινόμενο μοντέλο	53
6.1 Δεδομένα	53
6.2 Αρχιτεκτονική	54
7. Μελέτη Περιπτώσεων	55
7.1 Εκτέλεση.....	55
8. Συμπεράσματα και Μελλοντικές Προεκτάσεις	57
8.1 Συμπεράσματα	57
8.2 Μελλοντικές Προεκτάσεις	57
BIBΛΙΟΓΡΑΦΙΑ	59

1. Εισαγωγή

Στη σύγχρονη εποχή, επικρατεί μία μικρή τεχνολογική επανάσταση. Η δημιουργία και εδραίωση των LLM (Large Language Models – Μεγάλα Γλωσσικά Μοντέλα) έχει αλλάξει ριζικά τον τρόπο με τον οποίον ο άνθρωπος σκέφτεται, εργάζεται και αλληλεπιδρά με την τεχνολογία στην καθημερινή του ζωή. Τα LLM πλέον χρησιμοποιούνται σε ένα ευρύ φάσμα εφαρμογών, όπως στην αυτόματη μετάφραση, τη δημιουργία κειμένου και κώδικα και την αναγνώριση ομιλίας που διευκολύνουν την ζωή των χρηστών. Η απότομη πρόοδος στην υπολογιστική ισχύ, ο υπερμεγέθης όγκος δεδομένων που παράγουν οι χρήστες του διαδικτύου και για τα οποία δίνουν την έγκριση τους να επεξεργαστούν και να αξιοποιηθούν από τρίτους, καθώς και η ανθρώπινη ανάγκη για συνεχής εξέλιξη, έχουν επιτρέψει την εκπαίδευση μοντέλων με δισεκατομμύρια παραμέτρους. Τα μοντέλα αυτά, έχουν την δυνατότητα να κατανοούν την φυσική γλώσσα και να την παράγουν με ακριβή και ευφυή απόδοση ώστε να δρουν ως στενοί συνεργάτες σε ότι τους χρειαστεί κάποιος φέρνοντας έτσι την τεχνητή νοημοσύνη πιο κοντά από ποτέ στον άνθρωπο.

Μέσα σε αυτό το πλαίσιο, στην παρούσα πτυχιακή εργασία αναπτύχθηκε ένα LLM μοντέλο βασισμένο στην αρχιτεκτονική Transformer με στόχο την δημιουργία ενός έξυπνου συστήματος συστάσεων κρασιών. Το μοντέλο εκπαιδεύτηκε πάνω σε δεδομένα χαρακτηριστικών κρασιού που αντλήθηκαν από το www.kaggle.com για την εξαγωγή προτιμήσεων και τροποποιημένων προτάσεων.

2. Τεχνητή Νοημοσύνη (Artificial Intelligence)

2.1 Τι είναι η τεχνητή νοημοσύνη

Η Τεχνητή Νοημοσύνη (Artificial Intelligence - AI) ονομάζεται η ικανότητα των υπολογιστικών συστημάτων να προσομοιώνουν ανθρώπινες γνωστικές λειτουργίες όπως η επικοινωνία, η λογική σκέψη και η λήψη αποφάσεων με προσαρμοστικό τρόπο ώστε να αντιμετωπίσουν γνωστές ή απρόσμενες καταστάσεις αξιοποιώντας προηγούμενη γνώση και εμπειρία όπως ένας άνθρωπος (Du-Harpur et al. 2020). Αποτελεί μέρος ενός διεπιστημονικού κλάδου της πληροφορικής και επικεντρώνεται στην ανάπτυξη αλγορίθμων, συστημάτων και μοντέλων που επιτρέπει στα υπολογιστικά συστήματα να προσομοιώνουν βασικές πτυχές της ανθρώπινης νοημοσύνης ("Artificial Intelligence - Wikipedia," n.d.).

2.2 Που χρησιμοποιείται

Η Τεχνητή Νοημοσύνη βρίσκει όλο και περισσότερες εφαρμογές σε ένα ευρύ φάσμα κλάδων και τομέων δίνοντας λύσεις σε προβλήματα που υπό κανονικές συνθήκες θα χρειαζότουσαν ανθρώπινη παρέμβαση για την επίλυση τους. Οι τομείς αυτοί εκτείνονται από εφαρμογές στον ιατρικό κλάδο, στον κλάδο της εκπαίδευσης, στον τομέα προγνωστικής συντήρησης μέχρι και στις προσωποποιημένες συστάσεις για μάρκετινγκ.

2.2.1 Κλάδος Υγείας

Στον κλάδο της υγείας, η Τεχνητή Νοημοσύνη βοηθά στο να αναλύονται χιλιάδες ιατρικά δεδομένα με απώτερο σκοπό να επιτευχθεί καλύτερη παροχή ιατρικής περίθαλψης και ανώτερα κλινικά αποτελέσματα επιλύοντας διάφορες προκλήσεις ιατρικού υπόβαθρου. Αποθηκεύει ψηφιακά τα δεδομένα ασθενών για καλύτερη διάγνωση και φροντίδα και ενισχύει την δημιουργικότητα των γιατρών και των χειρουργών αφού οι έξυπνες μηχανές μπορούν και κατανοούν γρήγορα και με ακριβή τρόπο τα ιατρικά δεδομένα, ώστε να ληφθούν σε σύντομο χρονικό διάστημα ορθές αποφάσεις, οι οποίες θα βοηθήσουν τους γιατρούς να υλοποιήσουν μια πιο ακριβή χειρουργική επέμβαση με μηδαμινό ποσοστό κινδύνου και λάθους. Επιπροσθέτως, η Τεχνητή Νοημοσύνη, μπορεί να προσφέρει φαρμακοϊατρική υποστήριξη σε αγροτικές και δυσπρόσιτες περιοχές οι οποίες έχουν έλλειψη από ιατρικό προσωπικό και η πρόσβαση στην

ιατρική περίθαλψη είναι δύσκολη λόγω απόστασης. Με αυτόν τον τρόπο αυξάνεται τόσο το προσδόκιμο ζωής όσο και η ποιότητα ζωής των κατοίκων των περιοχών αυτών με λιγότερο κόστος. Τέλος, διαδραματίζει καθοριστικό ρόλο σε τεχνολογίες απεικόνισης όπως η ακτινογραφία, η αξονική και ο μαγνητικός τομογράφος, ενώ παράλληλα μπορεί να διαχειρίζεται την διατροφή, τα ιατρικά ραντεβού των ασθενών και να ανιχνεύει εξιδεικευμένες μετρήσεις, όπως την ανάλυση αορτικής βαλβίδας και την διάμετρο της πνευμονικής αρτηρίας, ενώ στον τομέα της ορθοπεδικής μπορεί να ανιχνεύει κατάγματα (Haleem et al. 2019).

2.2.2 Κλάδος Εκπαίδευσης

Στον κλάδο της εκπαίδευσης, η Τεχνητή Νοημοσύνη λειτουργεί ως ένα πολύτιμο εργαλείο μάθησης, ελαφρύνοντας το φόρτο εργασίας των μαθητών και των εκπαιδευτικών που επιθυμούν να την αξιοποιήσουν, αφού ενισχύει την εξατομικευμένη εκπαίδευση. Συνδυάζει τάσεις της σημερινής εποχής, όπως η ψηφιοποίηση, η ανάπτυξη παιγνίων και η προσωποποιημένη μάθηση στον εκάστοτε μαθητή, δημιουργώντας έτσι πολλές νέες ευκαιρίες για την ανάπτυξη και την αξιοποίηση διαφόρων εφαρμογών που κάνουν χρήση της Τεχνητής Νοημοσύνης στον τομέα. Ένα χαρακτηριστικό παράδειγμα είναι τα ευφυή εκπαιδευτικά συστήματα (Intelligent Tutoring Systems – ITS) τα οποία προσαρμόζονται στις ανάγκες του εκάστοτε μαθητή και παρέχουν εξατομικευμένη υποστήριξη μάθησης, παρακολουθώντας την πρόοδό τους και προσφέροντας κατάλληλες δραστηριότητες με άμεση ανατροφοδότηση. Οι μαθητές, με την βοήθεια της άμεσης ανατροφοδότησης, μαθαίνουν μέσω των σφαλμάτων τους. Η ενσωμάτωση της Τεχνητής Νοημοσύνης στην εκπαίδευση υποστηρίζει τέσσερα βασικά μοντέλα μάθησης.

1. Βιο-ανάδραση (biofeedback)

Η βιο-ανάδραση χρησιμοποιείται για την ανάλυση συναισθημάτων μέσω αλγορίθμων και αισθητήρων και επιδιώκει την βελτίωση της ανθρώπινης - υπολογιστικής αλληλεπίδρασης. Ακόμη, εντοπίζει την συναισθηματική κατάσταση του μαθητή με τεχνικές όπως η ανίχνευση προσώπου ή η παρακολούθηση ματιών για να εντοπίσουν σε ποιο σημείο εστιάζουν περισσότερο.

2. Μάθηση με Ρόλους (Role-Playing)

Η μέθοδος role-playing ενθαρρύνει τους μαθητές να σκέφτονται το πως να επιλύουν διάφορα προβλήματα με έξυπνους πράκτορες (Intelligent Agents) ως δάσκαλους. Αυτή η μέθοδος ενισχύει το αίσθημα ευθύνης και αλληλεπίδρασης των μαθητών ως προς τους υπολογιστές και τους πράκτορες, ενώ έρευνες έχουν δείξει πως οι μαθητές προσπαθούν περισσότερο να μάθουν και να βελτιωθούν όταν είναι για χάρη του πράκτορα παρά για τον εαυτό τους.

3. Εμβυθιστική Μάθηση (Immersive Learning)

Η εμβυθιστική μάθηση αποτελεί μια καινοτόμα προσέγγιση που επιτρέπει στους μαθητές να διαμορφώνουν διαδραστικά περιβάλλοντα σε σκηνές πλήρους οπτικής. Η χρήση XR (Extended Reality), 3D και φορητών συσκευών προσφέρει μαθησιακά περιβάλλοντα που ενισχύουν την επίδοση και την συμμετοχή των μαθητών, προκαλώντας αύξηση στην δημιουργικότητα, τον ενθουσιασμό και το ενδιαφέρον για το μάθημα. Τέτοια περιβάλλοντα έχουν την δυνατότητα να περιορίσουν το άγχος για τεχνικά ή πολύπλοκα προβλήματα διότι έχουν ήδη εκτεθεί σε τέτοιου είδους τεχνολογικά και υπολογιστικά θέματα μέσω της εμβυθιστικής μάθησης.

4. Παιγνιοποίηση (Gamification)

Η παιγνιοποίηση ενισχύει τη μαθησιακή εμπειρία εφόσον συνδυαστούν επιτυχώς ο εκπαιδευτικός σχεδιασμός, η γνώση και το συναίσθημα με το παιχνίδι. Η Τεχνητή Νοημοσύνη παίζει σημαντικό ρόλο στο να προσαρμόζει το περιβάλλον του παιχνιδιού και τους χαρακτήρες του στις ανάγκες του κάθε μαθητή μαθαίνοντας από την συμπεριφορά του. Ένα παράδειγμα τέτοιου παιχνιδιού είναι το Minecraft Edu στο οποίο οι μαθητές αλληλοεπιδρούν με ιστορικές φιγούρες και γεγονότα σε πραγματικό χρόνο προωθώντας έτσι την ενεργή συμμετοχή. Το σύστημα ανταμοιβής στα παιχνίδια, από την άλλη μεριά, λειτουργεί ως κίνητρο για εθελοντική και ενεργή μάθηση και η Τεχνητή Νοημοσύνη βελτιώνει περαιτέρω την εξατομίκευση του παιχνιδιού ανάλογα με την συμπεριφορά και τις ακαδημαϊκές ανάγκες του κάθε μαθητή (Zhai et al. 2021).

2.2.3 Κλάδος Marketing

Στον κλάδο του μάρκετινγκ, η Τεχνητή Νοημοσύνη κατέχει κυρίαρχη θέση. Πιο συγκεκριμένα, στις σύγχρονες στρατηγικές του ψηφιακού μάρκετινγκ κύριοι στόχοι αποτελούν η διατήρηση χρηστών και η μετατροπή επισκέψεων σε πωλήσεις αξιοποιώντας πλήθος εφαρμογών όπως chatbot, έξυπνη αποστολή email και διαδραστικά websites. Επίσης, η Τεχνητή Νοημοσύνη αναλαμβάνει την ευθύνη να παρέχει στοχευμένο περιεχόμενο στους χρήστες και να τους καθοδηγεί σύμφωνα με τους επιχειρηματικούς στόχους των εταιριών που την χρησιμοποιούν. Τα εργαλεία που τους παρέχει, μπορούν να μειώσουν το διαφημιστικό κόστος, κάνοντας καλύτερες τις διαφημιστικές καμπάνιες και ενισχύοντας την εμπειρία του πελάτη. Πιο συγκεκριμένα, γίνεται χρήση μιας υποκατηγορίας της Τεχνητής Νοημοσύνης, η Μηχανική Μάθηση (Machine Learning), η οποία με την σειρά της αναλύει τα δεδομένα που συλλέγονται από ποικίλες πηγές, όπως τα social media και οι ιστοσελίδες με κριτικές, και δημιουργεί εξατομικευμένο περιεχόμενο για τον κάθε πελάτη αναλόγως τις προτιμήσεις του. Χάρη στην ανάλυση δεδομένων που πραγματοποιεί, προβλέπει επιτυχώς τις μελλοντικές τάσεις σε οποιονδήποτε τομέα χρειαστεί και αναλύει εις βάθος την καταναλωτική και διαδικτυακή συμπεριφορά των πελατών, ώστε να προβλέψει ποιοι έχουν μεγαλύτερη πιθανότητα να εγκαταλείψουν την εκάστοτε υποστηριζόμενη υπηρεσία. Έτσι, μπορεί να βοηθήσει το ανθρώπινο δυναμικό να αναπτύξει καμπάνιες οι οποίες θα καταφέρουν να τους διατηρήσουν ως πελάτες και να προωθεί τις κατάλληλες διαφημίσεις, την κατάλληλη χρονική περίοδο για μέγιστη απόδοση (Haleem et al. 2022).

2.2.4 Κλάδος Προγνωστικής Συντήρησης

Η Προγνωστική Συντήρηση βασίζεται πάνω στην Τεχνητή Νοημοσύνη και πιο συγκεκριμένα στην Μηχανική Μάθηση με σκοπό να εντοπίζει έγκαιρα βλάβες ή αστοχίες τόσο στον εξοπλισμό όσο και στο λογισμικό. Αρκετά σύγχρονα συστήματα βασίζονται στην ανάλυση των δεδομένων που συλλέγονται και επεξεργάζονται με την πάροδο του χρόνου από συσκευές και αισθητήρες IoT (Διαδίκτυο των πράγματος – Internet of Things) και μετρούν κραδασμούς ή θερμοκρασία για να υπολογίσουν πόσο χρόνο ακόμα είναι ικανό να λειτουργήσει ένα εξάρτημα. Επιπλέον, η Προγνωστική Συντήρηση

ενσωματώνει τεχνικές Βαθιάς Μάθησης (Deep Learning), καθώς επιτρέπουν την ανάλυση τεράστιου όγκου πολύπλοκων και πολυδιάστατων δεδομένων με πιο γρήγορο και αποδοτικό τρόπο. Η χρήση δεδομένων ήχου και εικόνας από αισθητήρες συσκευών χαμηλού κόστους, όπως μικρόφωνα και κάμερες, δίνει την δυνατότητα στα Νευρωνικά Δίκτυα (Neural Networks) να προσφέρουν πιο ακριβείς και εξελιγμένες προβλέψεις από τις παραδοσιακές τεχνικές πρόγνωσης.

Η ικανότητα της Τεχνητής Νοημοσύνης να προβλέπει βλάβες στον εξοπλισμό και να επιτρέπει εγκαίρως τον προγραμματισμό συντήρησής του, συμβάλλει στη μείωση του χρόνου αδράνειας, στον περιορισμό του λειτουργικού κόστους και την ενίσχυση της παραγωγικότητας. Έρευνες έχουν δείξει πως η εφαρμογή εξ αποστάσεως διαγνωστικών τεχνικών σε βιομηχανίες θα μπορούσε, σε θεωρητικό υπόβαθρο, να αποφέρει έσοδα έως και το 1-2% του συνολικού κύκλου εργασιών της εταιρίας. Ενδεικτικά, στον τομέα των αερομεταφορών, η αξιοποίηση της Τεχνητής Νοημοσύνης συμβάλλει στην επιμήκυνση της επιχειρησιακής διάρκειας ζωής των αεροσκαφών υπερβαίνοντας τα όρια των παραδοσιακών αναλυτικών τεχνικών. Η επίτευξη αυτού καθίσταται δυνατή μέσω της ενσωμάτωσης και επεξεργασίας πολλαπλών τεχνικών χαρακτηριστικών του αεροσκάφους, όπως η συντήρησή τους και οι μετρήσεις των αισθητήρων IoT που αποτυπώνουν την τρέχουσα κατάσταση κρίσιμων μηχανικών εξαρτημάτων ("Notes-from-the-AI-Frontier-Insights-from-Hundreds-of-Use-Cases-Discussion-Paper.Pdf," n.d.).

2.3 Επίπεδα Τεχνητής Νοημοσύνης


Υπάρχουν τρία βασικά επίπεδα Τεχνητής Νοημοσύνης, η Στενή (ANI), η Γενική (AGI) και η Υπερνοημοσύνη (ASI).

ANI (Artificial Narrow Intelligence – Στενή Τεχνητή Νοημοσύνη): Είναι η πρώτη και πιο περιορισμένη μορφή της Τεχνητής Νοημοσύνης και είναι σχεδιασμένη να εκτελεί συγκεκριμένες πράξεις σε ένα μόνο πεδίο. Για παράδειγμα, ένα τέτοιο σύστημα μπορεί να υπερέχει στο σκάκι, φτάνοντας στο σημείο να νικάει παγκόσμιους πρωταθλητές, αλλά αυτό να είναι η μοναδική του γνωστική ικανότητα.

AGI (Artificial General Intelligence – Γενική Τεχνητή Νοημοσύνη):

Θεωρείται ως το επόμενο εξελικτικό στάδιο στο οποίο η Τεχνητή Νοημοσύνη αποκτά νοημοσύνη ίση ή και ανώτερη από εκείνη του ανθρώπου. Σε αυτό το στάδιο η Τεχνητή Νοημοσύνη είναι ικανή να συλλογίζεται, να σχεδιάζει και να μαθαίνει από παλαιότερες εμπειρίες να λύνει περίπλοκα προβλήματα και να σκέφτεται αφηρημένα σε διαφορετικά πεδία γνώσης.

ASI (Artificial Super Intelligence – Υπερνοημοσύνη): Το συγκεκριμένο σύστημα αναφέρεται σε ένα προηγμένο επίπεδο Τεχνητής Νοημοσύνης το οποίο ξεπερνάει κατά πολύ τις δυνατότητες και του πιο έξυπνου ανθρώπινου εγκεφάλου σχεδόν σε κάθε τομέα, από την επιστημονική έρευνα και την σοφία, έως και τη δημιουργικότητα και τις κοινωνικές δεξιότητες. Θεωρείται από πολλούς το μέλλον της ανθρώπινης εξέλιξης.



Εικόνα 1: Τα τρία επίπεδα της Τεχνητής Νοημοσύνης

Η ανθρωπότητα έχει ήδη κατακτήσει σε μεγάλο βαθμό το επίπεδο ANI. Τα συστήματα ANI χρησιμοποιούνται καθημερινά σε κάθε πτυχή της ζωής μας και βρίσκουν εφαρμογή σε πολλούς τομείς. Μερικά παραδείγματα είναι τα

ηλεκτρονικά συστήματα στα αυτοκίνητα, όπως το σύστημα φρεναρίσματος (ABS), οι αλγόριθμοι της Google που είναι υπεύθυνοι για τις μηχανές αναζήτησης, τα φίλτρα ανεπιθύμητης αλληλογραφίας στις υπηρεσίες e-mail και τα επιβατικά αεροσκάφη που πετούν σχεδόν εξ ολοκλήρου με τη βοήθεια ANI συστημάτων (*Three Types of Artificial Intelligence*, n.d.).

3. Μηχανική Μάθηση (Machine Learning)

3.1 Ορισμός

Η Μηχανική Μάθηση (Machine Learning) αποτελεί υποκλάδο της Τεχνητής Νοημοσύνης ο οποίος επικεντρώνεται στην ανάπτυξη αλγορίθμων που μαθαίνουν από δεδομένα και προσαρμόζονται καταλλήλως για κάθε εργασία χωρίς ανθρώπινη παρέμβαση. Στη εποχή των Big Data (Μεγάλα Δεδομένα), η Μηχανική Μάθηση αξιοποιείται ευρέως σε τομείς όπως η επεξεργασία φυσικής γλώσσας, η αναγνώριση εικόνας και η προγνωστική ανάλυση (Wikipedia 2025, "Machine learning").

3.2 Είδη Μηχανικής Μάθησης


Η Μηχανική Μάθηση περιλαμβάνει μια σειρά από μεθόδους οι οποίες επιτρέπουν στους υπολογιστές να μαθαίνουν από δεδομένα αναλόγως με τον τρόπο που τροφοδοτούνται και τον στόχο της εκπαίδευσης. Με τον τρόπο αυτό, η Μηχανική Μάθηση χωρίζεται σε διακριτές κατηγορίες, η καθεμία από τις οποίες χρησιμοποιεί εξειδικευμένες μεθόδους και εξυπηρετεί συγκεκριμένες εφαρμογές.

3.2.1 Επιβλεπόμενη Μάθηση (Supervised Learning)

Η Επιβλεπόμενη Μάθηση αποτελεί μια βασική κατηγορία της Μηχανικής Μάθησης, στην οποία οι αλγόριθμοι εκπαιδεύονται με σύνολα δεδομένων που περιλαμβάνουν τόσο τις εισόδους όσο και τις αντίστοιχες προκαθορισμένες εξόδους. Ο στόχος είναι η δημιουργία μιας συνάρτησης που χαρτογραφεί τις εισόδους στις αντίστοιχες εξόδους. Ορισμένοι αλγόριθμοι τέτοιου είδους είναι:

Δέντρα Απόφασης (Decision Trees): Τα Δέντρα Απόφασης αποτελούν ταξινομητές που αναπαριστούν μια διαδοχική διαίρεση του χώρου των παραδειγμάτων. Αποτελούνται από κόμβους, με τον αρχικό κόμβο να ονομάζεται ρίζα, ενώ οι υπόλοιποι κατηγοριοποιούνται σε εσωτερικούς κόμβους και φύλλα. Κάθε εσωτερικός κόμβος διαιρεί τα υποσύνολά του με βάση κάποια συνθήκη και τα φύλλα αντιστοιχίζονται σε κατηγορίες εξόδου και περιλαμβάνουν πιθανότητες που εκφράζουν τη βεβαιότητα για κάθε τιμή της εξαρτημένης μεταβλητής. Η ταξινόμηση γίνεται διασχίζοντας το δέντρο από τη ρίζα έως


κάποιο φύλλο του δέντρου βάσει των αποτελεσμάτων των ενδιαμέσων ελέγχων (Nasteski 2017).



Εικόνα 2: Δέντρο Απόφασης

Γραμμική Παλινδρόμηση (Linear Regression): Η Γραμμική Παλινδρόμηση χρησιμοποιείται για την πρόβλεψη μιας συνεχούς αριθμητικής μεταβλητής η οποία βασίζεται πάνω σε μια ή περισσότερες ανεξάρτητες μεταβλητές. Ο σκοπός της είναι να περιγράψει τη σχέση μεταξύ των μεταβλητών μέσω μιας γραμμικής εξίσωσης (Nasteski 2017). Το μοντέλο της γραμμικής παλινδρόμησης έχει την μορφή: $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + e$,

όπου β_0 είναι η σταθερά, $\beta_1, \beta_2, \dots$ είναι οι συντελεστές (βάρη) του μοντέλου και e το σφάλμα.




Εικόνα 3:Γραμμική Παλινδρόμηση

Λογιστική Παλινδρόμηση (Logistic Regression): Η Λογιστική Παλινδρόμηση είναι ένας αλγόριθμος που αποσκοπεί στην πρόβλεψη της πιθανότητας εμφάνισης ενός δυαδικού γεγονότος (ναι/όχι, θετικό/αρνητικό). Βασίζεται στη χρήση της λεγόμενης λογιστικής συνάρτησης (Sigmoid) ώστε να περιορίσει τις προβλέψεις εντός του διαστήματος 0 έως 1. Η διαδικασία του βασίζεται στην εξαγωγή αριθμητικών χαρακτηριστικών από τα δεδομένα εισόδου τα οποία πολλαπλασιάζονται με αντίστοιχα βάρη και αθροίζονται γραμμικά (Nasteski 2017). Η υπόθεση της λογιστικής παλινδρόμησης ορίζεται ως :

$$h_{\theta}(x) = g(\theta^T x),$$

όπου η συνάρτηση g είναι σιγμοειδής συνάρτηση που ορίζεται ως:


$$g(z) = \frac{1}{1 + e^{-z}}$$



Εικόνα 4: Λογιστική Παλινδρόμηση

Naïve Bayes: Η ταξινόμηση με βάση το θεώρημα του Bayes ανήκει στις στατιστικές προσεγγίσεις για την επίλυση προβλημάτων ταξινόμησης. Χρησιμοποιεί ένα πιθανοτικό μοντέλο για να χειριστεί την αβεβαιότητα, δηλαδή καταγράφει πόσο πιθανό είναι να ισχύει κάθε πιθανή κατηγορία. Η μέθοδος αυτή μπορεί να λειτουργήσει ακόμα και όταν τα δεδομένα περιέχουν «θόρυβο» ή μικρά λάθη (Nasteski 2017). Η εξίσωση το Bayes ορίζεται ως:

$$P(x_1, x_2) = P(x_1 | x_2) P(x_2)$$




Εικόνα 5: Ο ταξινομητής Naive Bayes

3.2.2 Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning)


Η Μη Επιβλεπόμενη Μάθηση είναι η δεύτερη υποκατηγορία της Μηχανικής Μάθησης και είναι υπεύθυνη για την ανάπτυξη ενός μοντέλου που βασίζεται αποκλειστικά στα δεδομένα εισόδου χωρίς αυτά να έχουν ετικέτες ή να υπάρχουν γνωστά αποτελέσματα. Παραδείγματα τέτοιων μεθόδων είναι οι κανόνες συσχέτισης (Association Rule) και η διαδικασία συσταδοποίησης (Clustering).

Διαδικασία Συσταδοποίησης (Clustering): Συσταδοποίηση ονομάζεται η διαδικασία κατά την οποία αντικείμενα ομαδοποιούνται με τέτοιο τρόπο ώστε τα στοιχεία μέσα σε μια ομάδα ή σύμπλεγμα να είναι πιο όμοια μεταξύ συγκριτικά με αυτά που βρίσκονται σε άλλες ομάδες. Η βασική ιδέα πίσω από την ομαδοποίηση είναι η δημιουργία ομάδων με τα μικρότερα δυνατά διαστήματα μεταξύ των μελών τους και με ελάχιστη επικάλυψη στους χώρους δεδομένων (Naeem et al. 2023).



Εικόνα 6: Παράδειγμα συσταδοποίησης

Μάθηση Κανόνων Συσχέτισης (Association Rule Learning): Είναι μια μέθοδος που αποκαλύπτει σχέσεις μεταξύ μεταβλητών σε μεγάλα σύνολα δεδομένων. Σε αντίθεση με άλλες τεχνικές, μπορεί να χειριστεί και μη αριθμητικά δεδομένα. Πιο συγκεκριμένα, αναζητά συσχετίσεις μεταξύ αντικειμένων ή γεγονότων οι οποίες μπορούν να αξιοποιηθούν εμπορικά. Η μέθοδος βασίζεται σε έννοιες όπως η υποστήριξη (support) που μετρά τη συχνότητα εμφάνισης της σχέσης και η εμπιστοσύνη (confidence) που δείχνει πόσο αξιόπιστη είναι η σύνδεση (Naeem et al. 2023).



Εικόνα 7: Κανόνες Συσχέτισης

3.2.3 Ενισχυτική Μάθηση (Reinforcement Learning)


Η Ενισχυτική Μάθηση βασίζεται στην αρχή ότι οι επιλογές επηρεάζονται από τα αποτελέσματα προηγούμενων ενεργειών. Ένας πράκτορας (agent) αλληλοεπιδρά με το περιβάλλον του εκτελώντας ενέργειες και λαμβάνοντας ανατροφοδότηση με την μορφή θετικών (επιβράβευση) ή αρνητικών (ποινή) τιμών. Η μάθηση του πράκτορα γίνεται μέσω δοκιμής και σφάλματος ώστε να επιτυγχάνει τους στόχους του. Η Ενισχυτική Μάθηση συνδυάζει στοιχεία της Επιβλεπόμενης Μάθησης και του δυναμικού προγραμματισμού ώστε να αναπτύξει ισχυρά συστήματα Μηχανικής Μάθησης.

Minimax-Q Learning Algorithm: Ο αλγόριθμος αυτός εφαρμόζεται σε περιβάλλοντα μηδενικού αθροίσματος όπου το κέρδος ενός παίκτη ισοδυναμεί με την απώλεια ενός άλλου. Σε τέτοιου είδους ανταγωνιστικά πλαίσια, ο πράκτορας επιδιώκει να μεγιστοποιήσει την αναμενόμενη απόδοση ακόμη και απέναντι στις πιο δυνατές κινήσεις του αντιπάλου. Ο αλγόριθμος επεκτείνει τη βασική λογική του Q-learning ενσωματώνοντας την στρατηγική *minimax*, προσφέροντας με αυτόν τον τρόπο τη δυνατότητα εκμάθησης βέλτιστων ενεργειών σε αντίξοες και ανταγωνιστικές καταστάσεις ("Ijstr.Org/Research-Paper-Publishing.Php?Month=mar2020," n.d.).

Friend-or-Foe Q-Learning (FFQ): Αποτελεί μια προσέγγιση στην οποία ο κάθε πράκτορας του περιβάλλοντος ταξινομείται είτε ως φίλος (Friend) είτε ως εχθρός (Foe). Αυτή η διάκριση επιτρέπει στον αλγόριθμο να διαχειρίζεται τις αλληλεπιδράσεις είτε ως παιχνίδια συντονισμού είτε ως ανταγωνισμού ανάλογα με την φύση των υπόλοιπων πρακτόρων ("Ijstr.Org/Research-Paper-Publishing.Php?Month=mar2020," n.d.).

Fictitious Play Algorithm: Ο αλγόριθμος αυτός χρησιμοποιείται σε περιπτώσεις όπου χρειάζεται μια διαφορετική προσέγγιση για την εκπαίδευση πρακτόρων σε πολυπρακτορικά περιβάλλοντα. Όπως αναφέρουν οι Cao (1997) και Suematsu (2002), κάθε παίκτης θεωρεί ότι οι αντίπαλοι ακολουθούν μια σταθερή στρατηγική της οποίας η εκτίμηση γίνεται σταδιακά με πειραματική κατανομή. Οι παίκτες θα πρέπει να διατηρήσουν τις δικές του τιμές Q που σχετίζονται με όλους τους πιθανούς συνδυασμούς ενεργειών. Ο αλγόριθμος Fictitious Play αποτελεί μια προσαρμογή της κλασσικής Q-learning για

περιβάλλοντα με σταθερές ή μεταβαλλόμενες στρατηγικές αντιπάλων και εφαρμόζεται τόσο σε ανταγωνιστικά παιχνίδια όσο και σε συνεργατικά, στα οποία οι παίκτες μαθαίνουν να συντονίζουν τις ενέργειές τους με την τεχνική Joint Action Learning (“Ijstr.Org/Research-Paper-Publishing.Php?Month=mar2020,” n.d.).




Εικόνα 8: Ο αλγόριθμος Fictitious Play

3.2.4 Ημιαυτοεπιβλεπόμενη Μάθηση (Semi-Supervised Learning)

Η Ημιαυτοεπιβλεπόμενη Μάθηση είναι μια πιο πρόσφατη τεχνική σε σύγκριση με την Επιβλεπόμενη και τη Μη Επιβλεπόμενη Μάθηση. Αποτελεί μια ενδιάμεση προσέγγιση όπου το σύνολο των δεδομένων περιλαμβάνει έναν μικρό αριθμό επισημασμένων (Labeled) και έναν μεγάλο αριθμό μη επισημασμένων (Unlabeled) δεδομένων. Κύριος στόχος της τεχνικής αυτής είναι να ξεπεράσει τα μειονεκτήματα τόσο της Επιβλεπόμενης όσο και της Μη Επιβλεπόμενης Μάθησης, και οι μέθοδοί της έχουν προταθεί για περιπτώσεις όπου υπάρχει έλλειψη επαρκώς επισημασμένων δεδομένων. Πιο πρακτικά, ο αλγόριθμος αυτός δημιουργεί ένα μοντέλο χρησιμοποιώντας τις λίγες επισημασμένες εγγραφές και εφαρμόζει το μοντέλο αυτό στα υπόλοιπα μη επισημασμένα δεδομένα αντιμετωπίζοντας τα ως δεδομένα δοκιμής (Test data). Διαχωρίζεται σε δυο τύπους, την Ημιεπιβλεπόμενη Ταξινόμηση (Semi-Supervised classification) και την Ημιεπιβλεπόμενη Συσταδοποίηση (Semi-Supervised Clustering).

Ημιεπιβλεπόμενη Ταξινόμηση (Semi-Supervised classification): Η Ημιεπιβλεπόμενη Ταξινόμηση είναι παρόμοια με την Επιβλεπόμενη Ταξινόμηση, καθώς και αυτή στοχεύει στην ταξινόμηση των δεδομένων δοκιμής (Test data). Ωστόσο, η Ημιεπιβλεπόμενη Ταξινόμηση απαιτεί πολύ μικρότερο όγκο δεδομένων εκπαίδευσης για να καταφέρει να ταξινομήσει μεγάλο αριθμό δεδομένων δοκιμής. Αυτό έχει ως αποτέλεσμα να επιτυγχάνεται μείωση της εξάρτησης από επισημασμένα δεδομένα, γεγονός που καθιστά την Ημιεπιβλεπόμενη Ταξινόμηση ιδιαίτερα χρήσιμη σε περιπτώσεις όπου η σήμανση των δεδομένων είναι χρονοβόρα ή δαπανηρή (Padmanabha Reddy




Εικόνα 9: Ημιεπιβλεπόμενη Ταξινόμηση

Ημιεπιβλεπόμενη Συσταδοποίηση (Semi-Supervised Clustering): Η Ημιεπιβλεπόμενη Συσταδοποίηση αποτελεί μια ειδική περίπτωση της παραδοσιακής συσταδοποίησης. Ενώ στην απλή συσταδοποίηση χρησιμοποιούνται μη επισημασμένα πρότυπα δεδομένων (Unlabeled data patterns), στην Ημιεπιβλεπόμενη Συσταδοποίηση αξιοποιούνται τόσο τα επισημασμένα όσο και τα μη επισημασμένα δεδομένα μαζί με πρόσθετες πληροφορίες (Side information), όπως περιορισμοί τύπου must-link και cannot-link οι οποίοι καθορίζουν ποια δεδομένα πρέπει ή δεν πρέπει να ανήκουν στα ίδια σύνολα. Μια προσέγγιση είναι ο αλγόριθμος Semi-Supervised Single Link

ο οποίος αντιμετωπίζει το πρόβλημα συσταδοποίησης σχημάτων αυθαίρετης μορφής (arbitrary shaped cluster) καθώς και το πρόβλημα του θορυβώδους γεφυρώματος μεταξύ συστάδων αξιοποιώντας έναν προϋπάρχοντα πίνακα αποστάσεων και ελάχιστους περιορισμούς. Η λειτουργία του αλγορίθμου βασίζεται στα λίγα επισημασμένα δεδομένα εκπαίδευσης με τα οποία ξεκινάει η διαδικασία ταξινόμησης. Στη συνέχεια, ταξινομούνται μη επισημασμένα δείγματα τα οποία αφού προβλεφθούν προστίθενται στο σύνολο εκπαίδευσης. Η διαδικασία επαναλαμβάνεται έως ότου εξαντληθούν όταν τα δεδομένα

Semi-supervised clustering



Εικόνα 10: Ημιεπιβλεπόμενη Συσταδοποίηση


4. Βαθιά Μάθηση (Deep Learning)

4.1 Ορισμός Βαθιάς Μάθησης

Η Βαθιά Μάθηση (Deep Learning) αποτελεί μια προηγμένη μορφή της Μηχανικής Μάθησης και επικεντρώνεται στη χρήση πολυεπίπεδων τεχνητών Νευρωνικών Δικτύων για την επίλυση προβλημάτων όπως η ταξινόμηση, η παλινδρόμηση και η εκμάθηση αναπαραστάσεων δεδομένων. Η φιλοσοφία της Βαθιάς Μάθησης εμπνέεται από τη λειτουργία του ανθρώπινου εγκεφάλου και την νευρο-επιστήμη, ενώ παράλληλα βασίζεται στην αρχή της διαστρωμάτωσης τεχνητών νευρώνων τους οποίους εκπαιδεύει ώστε να επεξεργαστεί δεδομένα. Ο χαρακτηρισμός “Βαθιά” αναφέρεται στο βάθος του δικτύου δηλαδή στον αριθμό των επιπέδων (Layers) τα οποία απαριθμούνται από μερικές εκατοντάδες έως και χιλιάδες (Wikipedia 2025, “Deep learning”).

4.2 Βασικές Έννοιες


Νευρωνικά Δίκτυα (Artificial Neural Network – ANN): Τα Νευρωνικά Δίκτυα είναι υπολογιστικά μοντέλα εμπνευσμένα από τη δομή και τη λειτουργία των βιολογικών νευρωνικών δικτύων. Πιο συγκεκριμένα, αποτελούνται από τεχνητούς νευρώνες που ανταλλάζουν σήματα και συνδέονται μεταξύ τους μέσω βαρών τα οποία μπορούν να προσαρμοστούν κατά τη διάρκεια της εκπαίδευσης. Συνήθως οι τεχνητοί νευρώνες οργανώνονται σε 3 διαφορετικά στρώματα (Layers). Το πρώτο θεωρείται ως το στρώμα εισόδου (Input Layer) και λαμβάνει τα αρχικά δεδομένα. Τα στρώματα που ακολουθούν ονομάζονται κρυφά στρώματα (Hidden Layers) αφού εφαρμόζουν ενδιάμεσους μετασχηματισμούς. Το τελευταίο είναι το στρώμα εξόδου (Output Layer) το οποίο παράγει το τελικό αποτέλεσμα. Ένα δίκτυο δέχεται τον χαρακτηρισμό του Βαθύ Νευρωνικού Δικτύου αν και μόνο αν περιλαμβάνει δύο ή περισσότερα κρυφά στρώματα (Wikipedia 2025, “Neural network (machine learning)”).



Εικόνα 11: Ένα Νευρωνικό Δίκτυο

Οπισθοδιάδοση (Backpropagation): Ο αλγόριθμος της οπισθοδιάδοσης είναι μία από τις πιο δημοφιλείς μεθόδους για την εκπαίδευση των Νευρωνικών Δικτύων και η επιτυχία του βασίζεται κυρίως στην απλότητά του και στην ισχυρή του απόδοση. Ο αλγόριθμος αυτός βασίζεται στον καθορισμό μιας συνάρτησης σφάλματος και στην εφαρμογή του αλγόριθμου καθοδικής κίνησης στην κλίση (Gradient Descent algorithm) για τη ρύθμιση των βαρών του δικτύου με στόχο τη βελτιστοποίηση της απόδοσης. Η υλοποίησή του είναι εύκολη και σύντομη, γεγονός που τον καθιστά προσιτό για ευρεία χρήση. Σε αντίθεση με παλαιότερους αλγόριθμους, όπως του Perceptron ή του Widrow-Hoff, η οπισθοδιάδοση μπορεί να εκπαιδεύσει πολύπλοκα και μη γραμμικά δίκτυα. Η συνδυαστική ικανότητα της οπισθοδιάδοσης είναι αυτή που την οδήγησε στο να

είναι θεμέλιο για τη σύγχρονη Βαθιά Μάθηση και έχει εφαρμοστεί σε αμέτρητα συστήματα Τεχνητής Νοημοσύνης (Rumelhart et al., n.d.).




Εικόνα 12: Ο αλγόριθμος Backpropagation

4.3 Είδη Βαθιάς Μάθησης

Στην παραδοσιακή Μηχανική Μάθηση γίνεται χρήση Νευρωνικών Δικτύων τα οποία είναι ρηχά (Shallow Neural Networks), δηλαδή αποτελούνται από το στρώμα εισόδου, το στρώμα εξόδου και το πολύ ένα κρυφό στρώμα ανάμεσα των δυο. Από την άλλη μεριά, η Βαθιά Μάθηση χρησιμοποιεί βαθιά δίκτυα με δυο ή παραπάνω κρυφά στρώματα ανάμεσα στα στρώματα εισόδου και εξόδου. Αυτό γίνεται γιατί όσο περισσότερα είναι τα ενδιάμεσα στρώματα τόσο πιο πολύ βαθαίνει το δίκτυο και τόσο μεγαλύτερες γίνονται οι πιθανότητες να αναγνωρίσει το δίκτυο περίπλοκα μοτίβα στα δεδομένα που του προσφέρθηκαν. Παρακάτω παρουσιάζονται οι βασικότεροι αλγόριθμοι της Βαθιάς Μάθησης.

4.3.1 Συνελικτικό Νευρωνικό Δίκτυο (Convolutional Neural Network - CNN)

Τα Συνελικτικά Νευρωνικά Δίκτυα παρουσιάστηκαν για πρώτη φορά από τον Kunihiko Fukushima και στην συνέχεια εξελίχθηκαν από τον Yann LeCun από τον οποίον συνδυάστηκαν με την μέθοδο της οπισθοδιάδοσης με στόχο την αναγνώριση ψηφίων και εγγράφων που είχαν γραφεί με το χέρι. Το σύστημα που κατάφερε να αναπτύξει ο Yann LeCun έμελλε να χρησιμοποιηθεί στο μέλλον για την ανάγνωση χειρόγραφων επιταγών και ταχυδρομικών κωδικών. Τα Συνελικτικά Νευρωνικά Δίκτυα αποτελούνται κυρίως από τα Στρώματα Συνέλιξης (Convolutional Layers) και τα Στρώματα Υποδειγματοληψίας (Pooling Layers). Τα πρώτα φιλτράρουν τα δεδομένα εισόδου για να εντοπίσουν και να απομονώσουν μόνο τις χρήσιμες πληροφορίες. Οι παράμετροι των φίλτρων που χρησιμοποιούνται εκπαιδεύονται με τέτοιον τρόπο ώστε να μπορούν να προσαρμόζονται αυτόματα στην εκάστοτε εργασία. Τα Στρώματα Υποδειγματοληψίας από την άλλη, συμβάλλουν στην επίτευξη μιας περιορισμένης μεταθετικής και περιστροφικής αμεταβλητότητας. Με αυτόν τον τρόπο, υπάρχει μείωση της κατανάλωσης μνήμης επιτρέποντας έτσι τη χρήση περισσότερων Συνελικτικών στρώσεων (Coşkun et al. 2017).



Εικόνα 13: Το Συνελικτικό Νευρωνικό Δίκτυο

4.3.2 Συνελικτική Λειτουργία (Convolutional Operation)

Η Συνέλιξη αποτελεί μια βασική μαθηματική διαδικασία για το πώς μπορούν να συνδυαστούν δύο συναρτήσεις ώστε να προκύψει μια τρίτη. Η

συνάρτηση που προκύπτει υπολογίζει μέσω ολοκλήρωσης τον βαθμό αλληλοεπικάλυψης της πρώτης συνάρτησης καθώς αυτή μετακινείται πάνω στην δεύτερη. Στο πλαίσιο των Νευρωνικών Δικτύων, τα δεδομένα εισόδου και ο συνελικτικός πυρήνας υφίστανται μια συγκεκριμένη πράξη, με αποτέλεσμα τη δημιουργία ενός νέου χάρτη χαρακτηριστικών. Συχνά, η Συνέλιξη θεωρείται μια μορφή φιλτραρίσματος κατά την οποία ο πυρήνας λειτουργεί ως φίλτρο για τον εντοπισμό συγκεκριμένων δεδομένων από τα δεδομένα της εισόδου (Coşkun et al. 2017). Η συνέλιξη περιγράφεται από τον εξής τύπο:

$$h(t) = \int_{-\infty}^{\infty} f(t)g(t - \tau)d\tau$$

Τα Συνελικτικά Νευρωνικά Δίκτυα κατά κανόνα λειτουργούν με δυοδιάστατη Συνέλιξη. Στη παρακάτω φωτογραφία υπάρχει στον αριστερό πίνακα τα δεδομένα εισόδου, στον μεσαίο είναι ο πυρήνας της Συνέλιξης και τέλος στα δεξιά είναι ο νέος χάρτης χαρακτηριστικών (Coşkun et al. 2017).

5	18	23	14	30
5	7	27	34	19
21	49	54	52	15
22	5	80	14	1
10	0	40	62	25

*

1	0	0
0	0	0
1	0	0

=

26	67	77
27	12	107
31	49	94

Όπως φαίνεται παραπάνω, η Συνελικτική λειτουργία βασίζεται στην χρήση των πυρήνων που εφαρμόζονται πάνω στα δεδομένα εισόδου για να αποδοθεί το επιθυμητό αποτέλεσμα εξαγωγής χαρακτηριστικών. Ανάλογα με τον τύπο του πυρήνα μπορεί να προκύψουν διαφορετικά αποτελέσματα, όπως για παράδειγμα ο εντοπισμός ακμών και η θόλωση ή όξυνση μιας εικόνας. Ένα από τα πιο σημαντικά σημεία της λειτουργίας των Συνελικτικών Νευρωνικών Δικτύων είναι η βελτιστοποίηση του καταλλήλου Συνελικτικού πυρήνα ο οποίος καθορίζει το πόσο καλά το δίκτυο μπορεί να αντιληφθεί τις οπτικές πληροφορίες (Coşkun et al. 2017).

4.3.3 Το Συνελικτικό Στρώμα (Convolutional Layer)

Όπως αναλύθηκε παραπάνω, ένα Συνελικτικό Νευρωνικό Δίκτυο περιλαμβάνει τα δυο στρώματα Συνέλιξης και Υποδειγματοληψίας. Το


Συνελικτικό Στρώμα είναι υπεύθυνο για την εκτέλεση της πράξης της Συνέλιξης και αποσκοπεί στην ανάδειξη σημαντικών χαρακτηριστικών της εισόδου. Όταν αυτά τα στρώματα συνδυάζονται διαδοχικά, η πληροφορία της εικόνας μετασχηματίζεται ιεραρχικά μέχρι να αναγνωριστούν πλήρη αντικείμενα και στο τέλος σκηνές. Εφόσον ολοκληρωθεί η Συνέλιξη εφαρμόζεται ένας μη γραμμικός μετασχηματισμός, γνωστός και ως Συνάρτηση ReLU (Rectified Linear Unit – ReLU) για μεγαλύτερη απόδοση. Παρόλο που υπάρχουν και άλλες μη γραμμικές συναρτήσεις όπως η Hyperbolic Tangent και η sigmoid, η ReLU έχει αποδειχθεί ως η πιο αποδοτική στην πράξη και για αυτόν τον λόγο προτιμάται περισσότερο (Coşkun et al. 2017). Ο τύπος της είναι ο: $f(x) = \max(0, x)$.

Ο τύπος αυτός αποτελεί έναν μετασχηματισμό που αντικαθιστά όλες τις αρνητικές τιμές των pixel στον χάρτη χαρακτηριστικών με την τιμή μηδέν, γεγονός που αντιμετωπίζει το πρόβλημα ακύρωσης και ταυτόχρονα δημιουργεί έναν πιο αραιό χάρτη ενεργοποιήσεων ο οποίος είναι πιο σταθερός σε μικρές διαταραχές του σήματος εισόδου (Coşkun et al. 2017).

Η Υποδειγματοληψία αποτελεί ένα ξεχωριστό στάδιο το οποίο στοχεύει στην μείωση της χωρικής διάστασης των χαρτών ενεργοποίησης. Υπάρχουν διάφορες μέθοδοι για Υποδειγματοληψία με τις πιο βασικές να είναι η Μέγιστη Υποδειγματοληψία (Max Pooling) η οποία επιλέγει τη μεγαλύτερη τιμή, τη Μέση Υποδειγματοληψία (Average Pooling) που υπολογίζει το μέσο όρο και η Πιθανολογική Υποδειγματοληψία (Probabilistic Pooling) όπου επιλέγεται μια τυχαία τιμή από τα δεδομένα εισόδου. Η Υποδειγματοληψία συμβάλλει στην μείωση της πολυπλοκότητας του δικτύου, ενισχύοντας παράλληλα την ανθεκτικότητα σε μικρές παραμορφώσεις ή μετατοπίσεις και μειώνοντας τον κίνδυνο υπερεκπαίδευσης (Coşkun et al. 2017).

Αφού εφαρμοστούν αρκετά Συνελικτικά και Υποδειγματοληπτικά στρώματα, ακολουθεί η φάση της εξαγωγής συμπερασμάτων μέσω των Πλήρως Συνδεδεμένων Στρωμάτων (Fully Connected Layers – FCL). Σε αυτά τα στρώματα κάθε νευρώνας συνδέεται με όλους τους νευρώνες του προηγούμενου στρώματος και η χωρική πληροφορία πλέον δεν λαμβάνεται υπόψη. Εξαιτίας αυτής της πλέον μονοδιάστατης φύσης δεν είναι δυνατή η προσθήκη Συνελικτικών Στρωμάτων μετά από ένα Πλήρως Συνδεδεμένο

Στρώμα. Τα χαρακτηριστικά που έχουν εξαχθεί μέσω των προηγούμενων στρωμάτων εισάγονται στο Πλήρως Συνδεδεμένο στρώμα για τελική επεξεργασία. Αντί να συνδεθούν κατευθείαν με την έξοδο, η χρήση ενός ακόμα τέτοιου στρώματος επιτρέπει την εκμάθηση πολύπλοκων συνδυασμών. Για την τελική απόδοση προβλέψεων χρησιμοποιείται η συνάρτηση ενεργοποίησης Softmax η οποία μετατρέπει τα αποτελέσματα σε πιθανότητες με άθροισμα ίσο με ένα (Coşkun et al. 2017).




Εικόνα 14: Η συνάρτηση ενεργοποίησης Softmax

4.3.4 Η Αρχιτεκτονική των Συνελικτικών Νευρωνικών Δικτύων (Convolutional Neural Network Architectures)

Τα Συνελικτικά Νευρωνικά Δίκτυα έχουν σημειώσει εντυπωσιακή πρόοδο στην αναγνώριση εικόνας και βίντεο σε μεγάλη κλίμακα τα τελευταία χρόνια. Οι σημαντικότερες αρχιτεκτονικές αυτών εξελίχθηκαν με την πάροδο του χρόνου ξεκινώντας από το LeNet και φτάνοντας ως το DenseNet, παρουσιάζοντας σταδιακά βελτιωμένη ακρίβεια (Coşkun et al. 2017).


LeNet (LeNet-5): Δημιουργήθηκε αρχικά από τον Yann LeCun και αποτέλεσε ένα από τα πρώτα επιτυχημένα μοντέλα Συνελικτικών Νευρωνικών Δικτύων που χρησιμοποιήθηκαν κυρίως για αναγνώριση χαρακτήρων όπως ταχυδρομικών κωδικών και ψηφίων. Με αυτή την αρχιτεκτονική παρουσιάστηκε και η γνωστή βάση δεδομένων MNIST η οποία παραμένει μέχρι και σήμερα η

πιο διαδεδομένη και δημοφιλή βάση δεδομένων για αναγνώριση ψηφίων (Coşkun et al. 2017).



Εικόνα 15: Η Αρχιτεκτονική LeNet


AlexNet: Θεωρείται ως η επόμενη μεγάλη πρόοδος που έκανε τα Συνελικτικά Νευρωνικά Δίκτυα στο πεδίο της Υπολογιστικής Όρασης. Η συγκεκριμένη αρχιτεκτονική αναπτύχθηκε από τον Alex Krizhevsky και τους συνεργάτες του και περιλαμβάνει πέντε Συνελικτικά και τρία Πλήρως Συνδεδεμένα Στρώματα. Κέρδισε το διαγωνισμό ImageNet ILSVRC του 2012 χάρη στις κορυφαίες επιδόσεις του (Coşkun et al. 2017).



Εικόνα 16: Η Αρχιτεκτονική AlexNet


ZFNet: Είναι έργο των Matthew Zeiler και Rob Fergus, κέρδισε την πρωτιά το 2013 στο ImageNet ILSVRC και βελτίωσε το AlexNet κυρίως μέσω προσαρμογών στις υπερπαραμέτρους όπως το μέγεθος των φίλτρων και η απόσταση μετατόπισης. Πιο συγκεκριμένα, αύξησε το μέγεθος των μεσαίων

Συνελικτικών στρωμάτων κάνοντας τον διασκελισμό και το φίλτρο του πρώτου στρώματος μικρότερο (Coşkun et al. 2017).




Εικόνα 17: Η Αρχιτεκτονική ZFNet

VGGNet: Προτάθηκε από την ομάδα πανεπιστημίου της Οξφόρδης. Τονίζει την σημασία του βάθους του δικτύου για την επίτευξη υψηλής ακρίβειας φτάνοντας τα 19 στρώματα. Ωστόσο, η μεγάλη υπολογιστική ισχύς που απαιτεί για την υλοποίησή του το καθιστά λιγότερο πρακτικό για εφαρμογές σε πιο απλές συσκευές λόγω του μεγάλου πλήθους Συνελικτικών Στρωμάτων που χρησιμοποιεί (Coşkun et al. 2017).



Εικόνα 18: Η Αρχιτεκτονική VGGNet


GoogLeNet: Ο νικητής του ILSVRC 2014 που δημιουργήθηκε από την ομάδα του Szegedy, υπάλληλο της Google. Εισήγαγε την έννοια του Inception Module που μείωσε δραστικά τον αριθμό των παραμέτρων του δικτύου διατηρώντας την απόδοση. Ο στόχος του Inception Module ήταν να προσεγγίσει ένα αραιό Συνελικτικό δίκτυο χρησιμοποιώντας μια πιο πυκνή δομή. Χρησιμοποιεί Συνελικτικά φίλτρα διαφορετικών μεγεθών ταυτόχρονα επιτρέποντας την εξαγωγή χαρακτηριστικών σε πολλαπλές κλίμακες. Περιλαμβάνει επίσης τα Bottleneck στρώματα, δηλαδή τα στρώματα με 1x1 Συνελίξεις, που περιορίζουν τις διαστάσεις και βελτιώνουν την απόδοση. Μια ακόμη σημαντική διαφορά είναι η αντικατάσταση των Πλήρως Συνδεδεμένων Στρώσεων με μια Παγκόσμια Μέση Υποδειγματοληψία (Global Average Pooling) στο τέλος του δικτύου μειώνοντας δραστικά τον αριθμό των παραμέτρων χωρίς να μειώνεται η ακρίβεια. Το GoogLeNet πετυχαίνει μεγαλύτερη ακρίβεια, ενώ παράλληλα είναι πιο αποδοτικό και ελαφρύ από τα προηγούμενα μοντέλα (Cszkun et al. 2017).



Εικόνα 19: Η Αρχιτεκτονική GoogLeNet


ResNet (Residual Network): Παρουσιάστηκε από τον Kaiming He και τους συνεργάτες του και διακρίθηκε στο ILSVRC 2015. Η αρχιτεκτονική αυτή εισήγαγε μια σημαντική καινοτομία: τις συνδέσεις παράλειψης (Skip Connections). Αυτές επιτρέπουν στη ροή πληροφορίας να παρακάμπτει ορισμένα επίπεδα, καθιστώντας δυνατή την εκπαίδευση εξαιρετικά βαθιών νευρωνικών δικτύων. Το μοντέλο αυτό ονομάζεται και ResNet-152 χάρη στα 152 στρώματα που χρησιμοποιεί και ενσωματώνει την κανονικοποίηση παρτίδας (Batch Normalization) και την Παγκόσμια Μέση Υποδειγματοληψία (Global Average Pooling) πριν το τελικό στάδιο του στρώματος Ταξινόμησης (Classification Layer). Χάρη στο μεγάλο του βάθος, που είναι έως και 10 φορές

πιο βαθύ από άλλες παρόμοιες αρχιτεκτονικές, και την υψηλή αποδοτικότητά του, το ResNet προσφέρει υψηλότερη ακρίβεια από τα VGG και GoogLeNet αλλά απαιτεί λιγότερους πόρους από το VGG (Coşkun et al. 2017).



Εικόνα 20: Η Αρχιτεκτονική ResNet-152

DenseNet: Παρουσιάστηκε από τον Gao Huang και τους συνεργάτες του και απέσπασε το βραβείο καλύτερης δημοσίευσης στο CVPR 2017. Προτείνει ένα διαφορετικό τρόπο σύνδεσης των στρωμάτων στον οποίο το κάθε επίπεδο συνδέεται απευθείας με όλα τα προηγούμενα με feed-forward τρόπο. Ως αποτέλεσμα, το DenseNet επιτυγχάνει εξαιρετικές επιδόσεις σε διάσημα σύνολα δεδομένων ταξινόμησης εικόνων όπως το CIFAR-10, CIFAR-100, SVHN και ImageNet (Coşkun et al. 2017).



Εικόνα 21: Η Αρχιτεκτονική DenseNet

4.3.5 Επαναλαμβανόμενα Νευρωνικά Δίκτυα (Recurrent Neural Networks - RNN)

Τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα ανήκουν σε μια κατηγορία νευρωνικών δικτύων σχεδιασμένων για την επεξεργασία διαδοχικών δεδομένων. Είναι αρκετά δημοφιλή και έχουν αποδώσει εξαιρετικά σε εφαρμογές όπως η αναγνώριση φωνής, η γλωσσική μοντελοποίηση, η μετάφραση και η περιγραφή εικόνων. Ονομάζονται Επαναλαμβανόμενα (Recurrent) επειδή εφαρμόζουν την ίδια λειτουργία σε κάθε στοιχείο μιας ακολουθίας, με κάθε έξοδο να εξαρτάται από τα προηγούμενα βήματα υπολογισμού. Με άλλα λόγια, διαθέτουν μια μορφή μνήμης που επιτρέπει στο δίκτυο να συγκρατεί πληροφορίες από το παρελθόν. Ένα από τα πρώτα και πιο απλά μοντέλα Επαναλαμβανόμενων Νευρωνικών Δικτύων παρουσιάστηκε από τον Elman (Coşkun et al. 2017).

Ένα τμήμα ενός νευρωνικού δικτύου λαμβάνει εισόδους και παράγει μια έξοδο. Όταν εισάγεται μια επαναληπτική δομή (Loop), γίνεται εφικτή η μεταφορά πληροφορίας από ένα χρονικό βήμα στο επόμενο. Τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα μπορούν να νοηθούν ως πολλαπλές διαδοχικές επαναλήψεις του ίδιου δικτύου, όπου κάθε ένα μεταβιβάζει δεδομένα στον επόμενο. Αυτή η αλυσιδωτή δομή τα καθιστά ιδανικά για την επεξεργασία ακολουθιακών δεδομένων όπως λίστες ή χρονοσειρές. Η βασική συνεισφορά των δικτύων αυτών είναι η δυνατότητα να «θυμούνται», δηλαδή να μοντελοποιούν πρότυπα που βασίζονται σε χρονική εξάρτηση. Ωστόσο, τα πρώιμα Επαναλαμβανόμενα Νευρωνικά Δίκτυα υπέφεραν από το πρόβλημα των Vanishing Gradients γεγονός που τα καθιστούσε αναποτελεσματικά σε μακρές ακολουθίες. Η ανακάλυψη των Δικτύων Μακροπρόθεσμης Βραχυπρόθεσμης Μνήμης (Long Short Term Memory – LSTM) έδωσε λύση σε αυτό το πρόβλημα (Coşkun et al. 2017).

Δίκτυο Μακροπρόθεσμης Βραχυπρόθεσμης Μνήμης (Long Short Term Memory – LSTM): Τα Δίκτυα Μακροπρόθεσμης Βραχυπρόθεσμης Μνήμης παρουσιάζουν σημαντική υπεροχή έναντι των κλασικών Επαναλαμβανόμενων Νευρωνικών Δικτύων, καθώς είναι ικανά να διατηρούν πληροφορία για μεγαλύτερα χρονικά διαστήματα. Η αρχιτεκτονική τους βασίζεται σε μια «κυψέλη μνήμης» (Memory Cell) που διατηρεί την κατάστασή της με την

πάροδο του χρόνου, και σε μη γραμμικές μονάδες πύλης (Non Linear Gating Units) που ρυθμίζουν ποια πληροφορία θα εισέλθει ή θα αποθηκευτεί ή θα απορριφθεί (Sakib Ashraf Zargar 2021).


Μονάδα Επαναλαμβανόμενης Πύλης (Gated Recurrent Unit – GRU): Ένα μοντέλο που προτάθηκε το 2014 από τους Cho και Chung, αποτελεί μια απλούστερη εκδοχή των Δικτύων Μακροπρόθεσμης Βραχυπρόθεσμης Μνήμης. Σε σύγκριση με τα Δίκτυα αυτά όμως, η αρχιτεκτονική των Μονάδων Επαναλαμβανόμενης Πύλης είναι λιγότερο περίπλοκη και πιο εύκολη στην εκπαίδευση λόγω της μειωμένης υπολογιστικής απαίτησης. Η απλοποίηση επιτυγχάνεται κυρίως με δύο τρόπους. Πρώτον, η πύλη εισόδου (Input Gate) και η πύλη λήθης (Forget Gate) συγχωνεύονται σε μια ενιαία πύλη που ονομάζεται πύλη ενημέρωσης (Update Gate). Δεύτερον, καταργείται ο διαχωρισμός μεταξύ της εσωτερικής κατάστασης (Cell State) και της κρυφής κατάστασης (Hidden State) καθώς ενοποιούνται σε ένα κοινό στοιχείο (Sakib Ashraf Zargar 2021).

4.3.6 Περιορισμένο Μηχάνημα Boltzmann (Restricted Boltzmann Machine - RBM)

Τα Περιορισμένα Μηχανήματα Boltzmann παρουσιάστηκαν για πρώτη φορά το 1985. Από τότε χάρη στη σημαντική πρόοδο στην υπολογιστική ισχύ και στις νέες μεθόδους εκπαίδευσης, τα Περιορισμένα Μηχανήματα Boltzmann βρίσκουν εφαρμογές σε πολλούς τομείς, όπως η αναγνώριση εικόνων, η σύνθεση υφών, η επεξεργασία ιατρικών εικόνων και η αποθορυβοποίηση. Ένα Περιορισμένο Μηχάνημα Boltzmann αποτελείται από δύο στρώματα, το ορατό στρώμα το οποίο είναι και το στρώμα εισόδου του και το κρυφό στρώμα. Ο όρος «περιορισμένο» προκύπτει από το γεγονός ότι δεν υπάρχουν συνδέσεις μεταξύ των νευρώνων του ίδιου στρώματος αλλά κάθε νευρώνας σε ένα στρώμα συνδέεται με όλους τους νευρώνες του άλλου. Οι συνδέσεις αυτές είναι συμμετρικές και αμφίδρομες επιτρέποντας στην πληροφορία να ρέει τόσο κατά τη φάση προώθησης όσο και κατά την αντίστροφη φάση (Coşkun et al. 2017).

Αρχικά, όταν κατευθύνεται προς τα εμπρός, το Περιορισμένο Μηχάνημα Boltzmann δέχεται δεδομένα εισόδου και τα μετατρέπει σε έναν κώδικα που περιγράφει τα κύρια χαρακτηριστικά τους. Στη συνέχεια, όταν κατευθύνεται προς τα πίσω, επιχειρεί να ανακατασκευάσει τα αρχικά δεδομένα από τον

κώδικα αυτόν. Όταν το δίκτυο έχει εκπαιδευτεί σωστά η ανακατασκευή αυτή είναι εξαιρετικά ακριβής. Τα βάρη και οι μεροληψίες (Biases) έχουν καθοριστικό ρόλο στην αποτελεσματικότητα του μοντέλου και ορίζουν ποιες σχέσεις μεταξύ των εισόδων είναι σημαντικές και βοηθούν το Περιορισμένο Μηχάνημα Boltzmann να εντοπίζει τα πιο κρίσιμα χαρακτηριστικά στο σύνολο δεδομένων. Ένα από τα πιο ενδιαφέροντα στοιχεία του Περιορισμένου Μηχανήματος Boltzmann είναι το ότι μπορεί να εκπαιδευτεί χωρίς να απαιτεί ετικέτες (Labels) γεγονός που το καθιστά ιδανικό για Μη Επιβλεπόμενη Μάθηση (Coskun et al. 2017).




Εικόνα 22: Συνδέσεις ενός Περιορισμένου Μηχανήματος Boltzmann

4.3.7 Autoencoders (Autoassociators)

Οι Autoencoders, γνωστοί και ως Autoassociators, είναι ένα είδος νευρωνικών δικτύων όπου η έξοδος έχει τον ίδιο αριθμό κόμβων με την είσοδο και χρησιμοποιούνται κυρίως για Μη Επιβλεπόμενη Μάθηση. Η βασική τους λειτουργία περιλαμβάνει τη συμπίεση των εισόδων σε μια κρυφή (Latent) αναπαράσταση και στη συνέχεια την ανακατασκευή των δεδομένων από αυτή την εσωτερική αναπαράσταση. Ουσιαστικά πρόκειται για έναν αλγόριθμο απώλειας δεδομένων ο οποίος μαθαίνει αυτόματα πως να κωδικοποιεί και να αποκωδικοποιεί τα δεδομένα μέσω παραδειγμάτων. Χρησιμοποιούνται συχνά για μείωση διαστάσεων και ως θεμέλιο για τα Βαθιά Νευρωνικά Δίκτυα. Ο τυπικός Autoencoder αποτελείται από ένα στρώμα εισόδου, ένα στρώμα

εξόδου και ένα κρυφό στρώμα, λειτουργώντας έτσι και ως μηχανή εξαγωγής χαρακτηριστικών (Coşkun et al. 2017).

Οι βαθιοί Autoencoders (Deep Autoencoders) είναι ιδιαίτερα αποτελεσματικοί στην συμπίεση δεδομένων. Για παράδειγμα, μια εικόνα διαστάσεων 28x28 pixels μπορεί να αναπαρασταθεί με μόλις 30 αριθμούς, επιτρέποντας σημαντική εξοικονόμηση υπολογιστικών πόρων. Ακόμα, μερικά μοντέλα προσθέτουν τεχνητό θόρυβο για να ενισχύσουν την ανθεκτικότητα της μάθησης. Δύο βασικές εφαρμογές τους είναι η καθαριότητα των δεδομένων από θόρυβο (Denoising) και η οπτικοποίηση μέσω μείωσης διαστάσεων. Όταν εφαρμοστούν σωστοί περιορισμοί διαστάσεων και αραιότητας, οι Autoencoders μπορούν να προσφέρουν πιο ενδιαφέρουσες προβολές των δεδομένων σε σχέση με πιο κλασικές μεθόδους όπως η Ανάλυση Κύριων Συνιστωσών (Principal Component Analysis - PCA) (Coşkun et al. 2017).



Εικόνα 23: Autoencoder

5. Μεγάλα Γλωσσικά Μοντέλα (Large Language Models - LLM)


5.1 Γενικά

Μεγάλα Γλωσσικά Μοντέλα (Large Language Models – LLM) θεωρούνται τα συστήματα Τεχνητής Νοημοσύνης που αποτελούνται από μοντέλα επεξεργασίας της φυσικής γλώσσας τα οποία εκπαιδεύονται πάνω σε τεράστιους όγκους κείμενων με την βοήθεια την Ημιεπιβλεπόμενης Μάθησης με σκοπό την κατανόηση και την παραγωγή γλώσσας (Wikipedia 2025, “Large language model”; “(PDF) GPT (Generative Pre-Trained Transformer)— A Comprehensive Review on Enabling Technologies, Potential Applications, Emerging Challenges, and Future Directions,” n.d.).

5.2 Βασικές Τεχνικές Πτυχές των Μεγάλων Γλωσσικών Μοντέλων

5.2.1 Tokenization

Το Tokenization αποτελεί σημαντικό βήμα προεπεξεργασίας για την εκπαίδευση Μεγάλων Γλωσσικών Μοντέλων στο οποίο το κείμενο διασπάται σε αναγνωρίσιμες μονάδες που ονομάζονται Tokens. Τα Tokens μπορεί να είναι από λέξεις και χαρακτήρες μέχρι σύμβολα και υπολέξεις ανάλογα με τη μέθοδο που χρησιμοποιείται. Διαδεδομένες τεχνικές για Tokenization περιλαμβάνουν το Wordpiece, το Byte Pair Encoding (BPE), και το μοντέλο UnigramLM (Naveed et al. 2024).



Εικόνα 24: Ένα παράδειγμα Tokenization

5.2.2 Encoding Positions


Οι Transformers, μια αρχιτεκτονική νευρωνικού δικτύου υπεύθυνη για την επεξεργασία ακολουθιών δεδομένων και εντοπισμού της σημαντικότερης πληροφορίας, επεξεργάζονται τις ακολουθίες χωρίς έμφαση στη σειρά των tokens και προσθέτουν διανύσματα θέσης για να ενσωματωθεί η πληροφορία της θέσης. Οι τεχνικές αυτές μπορεί να είναι είτε σχετικές, είτε να μαθαίνονται

κατά την εκπαίδευση, είτε να είναι απόλυτες. Δύο σχετικά παραδείγματα της κωδικοποίησης αυτής είναι πρώτον το Alibi το οποίο εισάγει αριθμητική μετατόπιση (Bias) στον βαθμολογητή προσοχής ο οποίος αυξάνεται όσο μεγαλώνει η απόσταση μεταξύ των tokens. Αυτό έχει ως αποτέλεσμα η προσοχή να δίνεται περισσότερο σε πιο πρόσφατα Tokens. Δεύτερο είναι το RoPE που περιστρέφει τα διανύσματα των ερωτήσεων (Query) και των κλειδιών (Key) κατά γωνίες που σχετίζονται με τη θέση των Tokens μέσα στην ακολουθία. Έτσι επιτυγχάνεται ένας σχετικός τρόπος ενσωμάτωσης θέσης όπου η επιρροή μειώνεται όσο αυξάνεται η απόσταση ανάμεσα στα Tokens (Naveed et al. 2024).

5.2.3 Μηχανισμοί Προσοχής (Attention Mechanisms)


Η προσοχή επιτρέπει στο μοντέλο να εντοπίζει ποια μέρη της εισόδου είναι σημαντικότερα δίνοντάς τους μεγαλύτερο βάρος. Στους transformers η προσοχή προκύπτει από τον συνδυασμό ερωτημάτων, κλειδιών και τιμών.

Self-Attention: Υπολογίζεται εντός της ίδιας μονάδας (Κωδικοποιητής ή Αποκωδικοποιητής) (Naveed et al. 2024).




Εικόνα 25: Μηχανισμός Self-Attention

Cross-Attention: Χρησιμοποιείται όταν τα ερωτήματα προέρχονται από τον Αποκωδικοποιητή και τα κλειδιά και οι τιμές από τον Κωδικοποιητή (Naveed et al. 2024).




Εικόνα 26: Μηχανισμός Cross-Attention

Sparse Attention: Περιορίζει την υπολογιστική πολυπλοκότητα της Self-Attention, η οποία είναι $O(n^2)$, μέσω εφαρμογής προσοχής σε επιλεγμένα παράθυρα μειώνοντας έτσι σημαντικά τον χρόνο υπολογισμού (Naveed et al. 2024).



Εικόνα 27: Μηχανισμός Sparse Attention

Flash Attention: Βελτιστοποιεί τη χρήση μνήμης στην GPU με τεχνικές τύπου Tiling, οι οποίες μειώνουν τις προσπελάσεις μεταξύ της γρήγορης μνήμης SRAM και της μνήμης HBM της GPU, για ταχύτερους υπολογισμούς (Naveed et al. 2024).




Εικόνα 28: Μηχανισμός Flash Attention

5.2.4 Συναρτήσεις Ενεργοποίησης (Activation Functions)


Αποτελούν αναπόσπαστο μέρος της μη γραμμικότητας στα νευρωνικά δίκτυα. Στα Μεγάλα Γλωσσικά Μοντέλα συνήθως χρησιμοποιούνται τα παρακάτω (Naveed et al. 2024):

1. **ReLU (Rectified Linear Unit):** Απλή συνάρτηση που μηδενίζει τις αρνητικές τιμές.
2. **GeLU (Gaussian Error Linear Unit):** Συνδυάζει ReLU, Dropout και Zoneout για πιο σταδιακή ενεργοποίηση.



Εικόνα 29: Συναρτήσεις ενεργοποίησης ReLU και GeLU

- 3. GLU (Gated Linear Unit) και τα παράγωγά του:** Χρησιμοποιούν πύλες και γραμμικούς μετασχηματισμούς για καλύτερη εκμάθηση. Παραλλαγές όπως η ReGLU, η GEGLU και η SwiGLU χρησιμοποιούνται στα σύγχρονα Μεγάλα Γλωσσικά Μοντέλα.



Εικόνα 30: Συνάρτηση ενεργοποίησης GLU

5.2.5 Στρωματική Κανονικοποίηση (Layer Normalization)

Η κανονικοποίηση στρωμάτων συμβάλλει στην επιτάχυνση της σύγκλισης και αποτελεί ενσωματωμένο κομμάτι των Transformers. Τεχνικές όπως LayerNorm, RMSNorm και Pre-LayerNorm εφαρμόζονται πριν από την Πολυκέφαλη προσοχή (Multi-Head Attention - MHA) για σταθερότερη εκπαίδευση. Το DeepNorm είναι μια νέα τεχνική που μειώνει την ευαισθησία στις μεγάλες κλίσεις (Naveed et al. 2024).

5.2.6 Διαμοιρασμένη Εκπαίδευση (Distributed Training)

Καθώς τα Μεγάλα Γλωσσικά Μοντέλα απαιτούν μεγάλη ποσότητα υπολογιστικών πόρων για να λειτουργήσουν, καθίσταται αναγκαία η χρήση ορισμένων στρατηγικών παραλληλοποίησης.

Παραλληλία Δεδομένων (Data Parallelism): Στην Παραλληλία Δεδομένων το μοντέλο αναπαράγεται αλώβητο σε πολλές συσκευές, ενώ κάθε συσκευή επεξεργάζεται διαφορετικό τμήμα των δεδομένων και τα βάρη της εκάστοτε εκπαίδευσης συγχρονίζονται μετά από κάθε επανάληψη (Naveed et al. 2024).

Παραλληλία Tensor (Tensor Parallelism): Στην Παραλληλία Tensor, οι υπολογισμοί που υλοποιούν οι ίδιοι οι Tensor κατανέμονται οριζόντια σε πολλαπλές συσκευές, επιτυγχάνοντας έτσι ενδοστρωματική παραλληλία (Naveed et al. 2024).

Παραλληλία Σωλήνωσης (Pipeline Parallelism): Στην Παραλληλία Σωλήνωσης, τα στρώματα του μοντέλου που είναι κατανεμημένα σε διαφορετικές συσκευές επιτρέπουν την κατακόρυφη παραλληλία κατά την διάρκεια της εκπαίδευσης (Naveed et al. 2024).

Παραλληλία Μοντέλου (Model Parallelism): Η Παραλληλία Μοντέλου είναι ένας συνδυασμός της Παραλληλίας Tensor και της Παραλληλίας Σωλήνωσης (Naveed et al. 2024).

3D Παραλληλία (3D Parallelism): Η Παραλληλία 3D θεωρείται μια ολοκληρωμένη στρατηγική η οποία συνδυάζει τις Παραλληλίες Δεδομένων, Μοντέλου και Tensor ώστε να πετύχει την μέγιστη πιθανή απόδοση (Naveed et al. 2024).

Παραλληλία Βελτιστοποιητή (Optimizer Parallelism): Η Παραλληλία Βελτιστοποιητή ή αλλιώς ο Βελτιστοποιητής Μηδενικού Πλεονασμού, διαχωρίζει τα στοιχεία Βελτιστοποιητή, όπως οι καταστάσεις, οι κλίσεις και οι παράμετροι, σε διαφορετικές συσκευές με απώτερο σκοπό την εξοικονόμηση μνήμης και την αποδοτικότερη επικοινωνία (Naveed et al. 2024).

5.3 Οι Βιβλιοθήκες των Μεγάλων Γλωσσικών Μοντέλων

Για την γρηγορότερη και αποδοτικότερη απόδοση στην παραγωγή φυσικού λόγου και πληροφορίας, τα Μεγάλα Γλωσσικά Μοντέλα αξιοποιούν εξειδικευμένες και σύγχρονες βιβλιοθήκες λογισμικού. Μερικές από αυτές τις βιβλιοθήκες είναι οι (Naveed et al. 2024):

1. **Transformers:** Η συγκεκριμένη βιβλιοθήκη προσφέρει πρόσβαση σε ποικιλία από έτοιμα μοντέλα Transformer, επιτρέποντας έτσι την εκπαίδευση, την προσαρμογή, την αξιολόγηση και τέλος την δημιουργία εξατομικευμένων μοντέλων, έτοιμων για χρήση, με ιδιαίτερη ευκολία.

2. **DeepSpeed:** Το DeepSpeed είναι ένα εργαλείο σχεδιασμένο για την κλιμακούμενη και αποτελεσματική εκπαίδευση πολύπλοκων νευρωνικών δικτύων και κατανεμημένα συστήματα.
3. **JAX:** Η JAX είναι μια βιβλιοθήκη για αριθμητικούς υπολογισμούς υψηλής ταχύτητας, με δυνατότητα διαχωρισμού των συναρτήσεων της βιβλιοθήκης NumPy και την τυπικής Python και της εκτέλεσής τους.
4. **BMTrain:** Μια «απλή» βιβλιοθήκη που χρησιμοποιείται για τον αποτελεσματικό προγραμματισμό εκπαιδευτικού κώδικα για τα Μεγάλα Γλωσσικά Μοντέλα με δισεκατομμύρια παραμέτρους.
5. **MindSpore:** Το MindSpore είναι μια πλατφόρμα αφιερωμένη στην ανάπτυξη και την εκπαίδευση νευρωνικών μοντέλων τα οποία είναι ικανά να επεκταθούν με μεγάλη ευκολία τόσο σε κινητές συσκευές όσο και σε cloud και edge υπολογιστικά περιβάλλοντα.
6. **PyTorch:** Μια από τις πιο διαδεδομένες βιβλιοθήκες για τον Βαθιά Μάθηση που δημιουργήθηκε από το Facebook AI Research lab (FAIR). Δίνει έμφαση στην ευχρηστία και τη δυναμική ροή κατά την εκπαίδευση, πράγμα που την καθιστά κατάλληλη τόσο για ερευνητική όσο και βιομηχανική χρήση.
7. **Tensorflow:** Μια ακόμα δημοφιλής βιβλιοθήκη που παράχθηκε από την Google. Γνωστή και για την χρήση της στην παραγωγή γραφημάτων υπολογισμών και την υποστήριξη δυναμικής και στατικής εκτέλεσης.
8. **MXNet:** Το MXNet είναι ένα open source περιβάλλον Βαθιάς Μάθησης που προσφέρει ευελιξία και ποικιλία όσον αφορά τις γλώσσες προγραμματισμού που υποστηρίζει. Παράλληλα, επιτρέπει τόσο τη δυναμική όσο και τη στατική δημιουργία γραφημάτων υπολογισμού.


5.4 Η αρχιτεκτονική των Transformer για τα Μεγάλα Γλωσσικά Μοντέλα

Υπάρχουν διάφορες παραλλαγές όσον αφορά την αρχιτεκτονική του εκάστοτε Transformer που θα χρησιμοποιηθεί από κάποιο LLM. Οι παραλλαγές αυτές προκύπτουν κυρίως από το πως υλοποιείται ο μηχανισμός της προσοχής που αναφέρθηκε παραπάνω και ο τρόπος με τον οποίο συνδέονται τα επιμέρους μπλοκ των Transformers.

Κωδικοποιητής – Αποκωδικοποιητής (Encoder - Decoder): Στην αρχιτεκτονική του Κωδικοποιητή – Αποκωδικοποιητή, η είσοδος επεξεργάζεται αρχικά από τον κωδικοποιητή ο οποίος δημιουργεί μια ενδιάμεση αναπαράσταση. Στη συνέχεια, αυτή η αναπαράσταση μεταφέρεται στον αποκωδικοποιητή για την παραγωγή της εξόδου. Ο κωδικοποιητής αποκτά πρόσβαση σε ολόκληρη την διαδικασία μέσω της τεχνικής Self-Attention, ενώ ο αποκωδικοποιητής επεξεργάζεται διαδοχικά κάθε στοιχείο εφαρμόζοντας την Cross-Attention (Naveed et al. 2024).

Αιτιακός Αποκωδικοποιητής (Causal Decoder): Μια αρχιτεκτονική η οποία δεν περιλαμβάνει κωδικοποιητή και βασίζεται αποκλειστικά και μόνο στον αποκωδικοποιητή για την πρόβλεψη της εξόδου καθώς κάθε νέο στοιχείο που προβλέπεται εξαρτάται μόνο από τα προηγούμενα χρονικά βήματα (Naveed et al. 2024).

Προθεματικός Αποκωδικοποιητής (Prefix Decoder): Ο Προθεματικός Αποκωδικοποιητής ή αλλιώς ο Μη Αιτιακός Αποκωδικοποιητής, είναι ένας αποκωδικοποιητής που επιτρέπει την δισδιάστατη προσοχή (Bidirectional Attention) καθώς αρνείται να περιοριστεί αποκλειστικά στην πληροφορία που προέρχεται από το παρελθόν (Naveed et al. 2024).



Εικόνα 31: Ένα παράδειγμα των μοτίβων προσοχής κωδικοποιητών και αποκωδικοποιητών. Αριστερά ο Αιτιατός Αποκωδικοποιητής, κεντρικά ο Προθεματικός Αποκωδικοποιητής και δεξιά ο Κωδικοποιητής-Αποκωδικοποιητής.

Mixture-of-Experts – MOE: Εκτός από τις τρεις παραπάνω βασικές αρχιτεκτονικές, υπάρχει και η αρχιτεκτονική Mixture-of-Experts, δηλαδή μια δομή πολλαπλών εξειδικευμένων υπομονάδων των Transformers, η οποία

περιλαμβάνει πολλούς παράλληλους «ειδικούς» και έναν μηχανισμό δρομολόγησης που κατευθύνει τα tokens προς τους κατάλληλους «ειδικούς». Οι «ειδικοί», από την μεριά τους, αποτελούνται συνήθως από Feed-Forward στρώματα και ενεργοποιούνται επιλεκτικά, γεγονός που επιτρέπει την αύξηση της χωρητικότητας του μοντέλου χωρίς να αυξάνεται σημαντικά το υπολογιστικό κόστος (Naveed et al. 2024).

5.5 Fine-Tuning Μεγάλων Γλωσσικών Μοντέλων

Το fine-tuning είναι η διαδικασία κατά την οποία ένα ήδη προεκπαιδευόμενο LLM προσαρμόζεται σε μια πιο εξειδικευμένη εργασία ή σύνολο δεδομένων ώστε να αποδίδει καλύτερα σε συγκεκριμένες εφαρμογές. Υπάρχουν διάφορες τεχνικές για να κάνει κάποιος fine-tune σε ένα προεκπαιδευόμενο LLM. Μερικές από αυτές θα αναλυθούν εις βάθος παρακάτω (Naveed et al. 2024).

- 1. Μεταφορά Μάθησης (Transfer Learning):** Στην Μεταφορά Μάθησης, το μοντέλο αφού εκπαιδευτεί, επανεκπαιδεύεται με δεδομένα μιας συγκεκριμένης εργασίας ώστε να βελτιώσει την απόδοσή του σε αυτή.
- 2. Συντονισμός με Οδηγίες (Instruction Tuning):** Για να ενισχυθεί η ικανότητα του μοντέλου να ανταποκρίνεται σωστά στις ερωτήσεις των χρηστών, εφαρμόζεται ένα ειδικό fine-tuning με μία βάση δεδομένων που περιλαμβάνει οδηγίες, εισόδους και τις αντίστοιχες εξόδους. Αυτές οι οδηγίες συνήθως είναι διατυπωμένες σε απλή φυσική γλώσσα και περιλαμβάνουν συνήθως ποικιλία εργασιών. Η μέθοδος αυτή ενισχύει την ικανότητα του μοντέλου να γενικεύει σε νέες εργασίες που δεν έχει ξανά αντιμετωπίσει χωρίς ειδική εκπαίδευση και βελτιώνει τις επιδόσεις σε στοχευμένα καθήκοντα.
- 3. Συντονισμός με Ευθυγράμμιση (Alignment-Tuning):** Καθώς τα LLM ενδέχεται να παράγουν ανακριβείς, μεροληπτικές ή ακόμα και επικίνδυνες απαντήσεις, πρέπει να εξασφαλιστεί ότι η συμπεριφορά τους θα είναι σύμφωνη με τις ανθρώπινες αξίες. Αυτό γίνεται εφαρμόζοντας τεχνικές ευθυγράμμισης οι οποίες αξιοποιούν την ανθρώπινη παρέμβαση για ένα πιο ασφαλές και αξιόπιστο αποτέλεσμα. Ο σκοπός είναι να διαμορφωθεί ένα σύστημα που θα προσφέρει χρήσιμες και ακίνδυνες απαντήσεις και θα θεωρείται

«ευθυγραμμισμένο» όταν θα πληροί τα χαρακτηριστικά HHH (Helpful, Honest, Harmless).

Η βασική μέθοδος για την επίτευξη της ευθυγράμμισης αυτής είναι η ενισχυτική μάθηση με καθοδήγηση από ανθρώπους (reinforcement learning with human feedback - RLHF). Η διαδικασία αυτή βασίζεται σε δύο βασικά στάδια. Πρώτη είναι η Μοντελοποίηση της Επιβράβευσης (Reward Modeling) στην οποία το μοντέλο εκπαιδεύεται ώστε να κατανοεί ποια από τις παραγόμενες απαντήσεις είναι πιο αποδεκτή σύμφωνα με τις αξιολογήσεις ανθρώπων. Με αυτόν τον τρόπο, οι απαντήσεις κατατάσσονται με βάση το αν ανταποκρίνονται στις ηθικές και λειτουργικές προσδοκίες των χρηστών. Δεύτερη, είναι η κλασσική Ενισχυτική Μάθηση. Εκεί, η πληροφορία χρησιμοποιείται από το προτεινόμενο μοντέλο ώστε να εφαρμοστεί μια τεχνική βελτιστοποίησης, η οποία υλοποιεί την Μοντελοποίηση της Επιβράβευσης για να διαχωρίσει τις απαντήσεις σε προτιμώμενες και μη προτιμώμενες, ώστε το γλωσσικό μοντέλο να προσαρμόζει και να βελτιώνει σταδιακά τις απαντήσεις του. Αυτή η διαδικασία επαναλαμβάνεται διαδοχικά μέχρι το σύστημα να ανταποκρίνεται με σταθερό τρόπο στις προσδοκίες των χρηστών (Naveed et al. 2024).

5.5 Προεκπαιδευμένα Μεγάλα Γλωσσικά Μοντέλα

Τα προεκπαιδευμένα Μεγάλα Γλωσσικά Μοντέλα είναι μοντέλα που έχουν εκπαιδευτεί σε τεράστιους όγκους κειμένου ώστε να κατανοούν και να παράγουν φυσική γλώσσα. Αποτελούν τη βάση για πολλές σύγχρονες εφαρμογές της Τεχνητής Νοημοσύνης καθώς μπορούν να προσαρμοστούν εύκολα σε ποικίλα γλωσσικά καθήκοντα. Κάθε Μεγάλο Γλωσσικό Μοντέλο είναι εξειδικευμένο σε διαφορετικό τομέα. Μερικά είναι ικανά να αποδώσουν αποτελεσματικά πληροφορίες γενικού σκοπού και να υστερούν σε άλλους τομείς όπως ο προγραμματισμός, ενώ κάποια άλλα το αντίστροφο (Naveed et al. 2024).

5.5.1 Προεκπαιδευμένα Μεγάλα Γλωσσικά Μοντέλα Γενικού

Σκοπού

T5: Πρόκειται για ένα μοντέλο τύπου Κωδικοποιητή – Αποκωδικοποιητή που εφαρμόζει μια ενοποιημένη προσέγγιση μετατροπής όλων των γλωσσικών εργασιών σε μορφή «κειμένου προς κείμενο». Χρησιμοποιεί μάσκες σε διαστήματα λέξεων και όχι σε μεμονωμένα Tokens, επιταχύνοντας έτσι την εκπαίδευση. Για να υλοποιήσει το Fine-Tuning, χρησιμοποιεί στρώματα προσαρμογής (Naveed et al. 2024).

GPT-3: Το GPT-3 ακολουθεί την ίδια αρχιτεκτονική με τον προκάτοχο του, το GPT-2, αλλά με την διαφορά ότι είναι εμπλουτισμένο με Dense και Sparse Attention. Έχοντας 175 δισεκατομμύρια παραμέτρους στην κατοχή του, αποδεικνύει ότι είναι εφικτό τα μεγαλύτερα μοντέλα να εκπαιδεύονται με μεγαλύτερα σύνολα δεδομένων ανά επανάληψη, αρκεί να χρησιμοποιηθεί χαμηλότερος ρυθμός μάθησης, πράγμα που δείχνει πως η απόδοση βελτιώνεται με την κλίμακα. Τέλος, το GPT-3 αξιοποιεί το Gradient noise scale για τον καθορισμό του μεγέθους του κάθε συνόλου δεδομένων (Naveed et al. 2024).

mT5: Θεωρείται και ως η πολυγλωσσική εκδοχή του T5 αφού είναι εκπαιδευμένο σε δεδομένα από 101 διαφορετικές γλώσσες. Για την υλοποίησή του ενσωματώνει την διαδικασία της δειγματοληψίας ώστε να αποφεύγεται η υπερπροσαρμογή σε συγκεκριμένες γλώσσες και χρησιμοποιεί για το Fine-Tuning του ένα μικρό κομμάτι από κάθε γλώσσα στο σύνολο δεδομένων για την εκπαίδευσή του ώστε να καλύψει την πολυμορφία των γλωσσών και να παράγει σωστά αποτελέσματα σε κάθε γλώσσα (Naveed et al. 2024).

Jurassic-1: Είναι ένα auto-regressive γλωσσικό μοντέλο και περιλαμβάνει δύο εκδοχές, το J1-Large (7B) και το J1-Jumbo (178B). Το λεξιλόγιο εκπαίδευσης αυτών των μοντέλων δεν περιορίζεται σε μεμονωμένες λέξεις, αλλά ενσωματώνει ολόκληρες λέξεις και παραλλαγές τους. Όταν προκύπτουν άγνωστες λέξεις, αυτές αντιμετωπίζονται ως byte χαρακτήρες Unicode. Χρησιμοποιεί εξελιγμένο Tokenizer και πιο ισορροπημένη αρχιτεκτονική βάθους-πλάτους από το GPT-3, επιτυγχάνοντας καλύτερα αποτελέσματα σε few-shot σενάρια, δηλαδή σε σενάρια όπου η μάθηση είχε ελάχιστα

παραδείγματα εκπαίδευσης για να κατανοήσει τι πρέπει να κάνει (Naveed et al. 2024).

Generalist Language Model (GLaM): Το GLaM είναι ένα μοντέλο που είναι μόνο Αποκωδικοποιητής και χρησιμοποιεί την Mixture - of - Experts τεχνική όπου ενεργοποιούνται μόνο οι δυο καταλληλότεροι «ειδικοί» για κάθε Token. Το GLaM (64B/64E) έχει πολύ μεγαλύτερη χωρητικότητα από το GPT-3, αλλά απαιτεί λιγότερους υπολογιστικούς πόρους ανά είσοδο (Naveed et al. 2024).

LLaMA: Η οικογένεια μοντέλων LLaMA αποτελείται από γλωσσικά μοντέλα βασισμένα αποκλειστικά σε Αποκωδικοποιητές με μέγεθος παραμέτρων που κυμαίνεται από 7 έως 70 δισεκατομμύρια. Τα συγκεκριμένα μοντέλα έχουν αποκτήσει μεγάλη αναγνώριση στην ερευνητική κοινότητα χάρη στην υψηλή αποδοτικότητά τους σε σχέση με τον αριθμό παραμέτρων και την ικανότητά τους να προσαρμόζονται σε εντολές (instruction tuning) (Naveed et al. 2024).

Grok-1: Το Grok-1 είναι ένα γλωσσικό μοντέλο αρχιτεκτονικής Mixture – of - Experts με 314 δισεκατομμύρια παραμέτρους. Αποτελείται από οκτώ επιμέρους «ειδικούς», από τους οποίους ενεργοποιούνται μόνο δυο για κάθε Token, προσφέροντας αποτελεσματικότητα στην υπολογιστική αξιοποίηση (Naveed et al. 2024).

DeepSeek: Ένα γλωσσικό μοντέλο που εστιάζει στην συστηματική διερεύνηση των νόμων κλιμάκωσης των LLM. Μέσα από πειραματισμούς με διαφορετικούς προϋπολογισμούς υπολογιστικής ισχύος, αξιολογήθηκε η βέλτιστη σχέση μεταξύ του μεγέθους του μοντέλου και της ποσότητας εκπαίδευσης χωρίς την χρήση ενσωμάτωσης. Η μελέτη έδειξε ότι όσο αυξάνεται ο υπολογιστικός προϋπολογισμός, τόσο θα πρέπει να αυξάνεται το μέγεθος του συνόλου δεδομένων, ενώ η τιμή της εκπαίδευσης θα πρέπει να μειώνεται (Naveed et al. 2024).

5.5.2 Προεκπαιδευμένα Μεγάλα Γλωσσικά Μοντέλα Προγραμματισμού

CodeGen: Το μοντέλο CodeGen αξιοποιεί παράλληλες δομές προσοχής, πολυστρωματικά MLP και RoPE ενσωματώσεις. Η διαδικασία εκπαίδευσής του

ακολουθεί μια διαδοχική προσέγγιση, ξεκινώντας με δεδομένα φυσικής γλώσσας και συνεχίζοντας με προγραμματιστικά δεδομένα από διάφορες γλώσσες προγραμματισμού χρησιμοποιώντας τα σύνολα δεδομένων PILE, BIGQUERY και BIGPYTHON. Εφαρμόζει μια βήμα προς βήμα μέθοδο παραγωγής κώδικα όπου κάθε νέα έξοδος δημιουργείται με βάση το προηγούμενο prompt και τον ήδη παραγόμενο κώδικα(Naveed et al. 2024).

Codex: Το Codex αποτελεί ένα μεγάλο γλωσσικό μοντέλο που έχει εκπαιδευτεί πάνω σε επιλεγμένα αποθετήρια Python από το Github με σκοπό τη δημιουργία κώδικα βασισμένο σε docstrings. Το Codex μπορεί να δημιουργήσει έως και 100 εκδοχές ενός προγράμματος μέσω επαναλαμβανόμενης δειγματοληψίας από την περιγραφή του, επιτυγχάνοντας λειτουργικές λύσεις για την πλειοψηφία των προβλημάτων (Naveed et al. 2024).

AlphaCode: Το AlphaCode είναι μια σειρά μεγάλων γλωσσικών μοντέλων που ξεκινάνε από 300 εκατομμύρια παραμέτρους και φτάνουν στους 41 δισεκατομμύρια και είναι σχεδιασμένο για την επίλυση πιο σύνθετων προγραμματιστικών προβλημάτων. Εκπαιδεύεται αρχικά σε έναν αρχικό κώδικα από το GitHub ο οποίος έχει φιλτραριστεί στις εκάστοτε ανάγκες και στην συνέχεια βελτιστοποιείται με το σύνολο δεδομένων CodeContests από την πλατφόρμα Codeforces. Χρησιμοποιεί Multi-Query Attention για αποδοτικότερη μνήμη, ενώ εφαρμόζει τη μέθοδο **GOLD** στο fine-tuning (Naveed et al. 2024).

6. Προτεινόμενο μοντέλο

Σε αυτήν την ενότητα παρουσιάζεται το μοντέλο που αναπτύχθηκε στο πλαίσιο της παρούσας πτυχιακής εργασίας. Περιλαμβάνονται πληροφορίες για τα δεδομένα, την αρχιτεκτονική και τις βιβλιοθήκες του μοντέλου που χρησιμοποιήθηκαν.

6.1 Δεδομένα

Για τις ανάγκες της εκπαίδευσης, της αξιολόγησης και της παραγωγής προβλέψεων από το προτεινόμενο μοντέλο, αξιοποιήθηκε το σύνολο δεδομένων Wine Reviews, διαθέσιμο μέσω της πλατφόρμας Kaggle. Το εν λόγω σύνολο αποτελείται από περίπου 130.000 εγγραφές σχετικές με κρασιά συνοδευόμενες από κριτικές και πληροφορίες για τον εκάστοτε οίνο. Συγκεκριμένα, κάθε εγγραφή περιλαμβάνει δεδομένα όπως η ποικιλία του σταφυλιού, μια περιγραφική αξιολόγηση της γεύσης και του αρώματος του κρασιού, το όνομα του παραγωγού ή του οινοποιού, η βαθμολογία που έχει αποδοθεί από την εταιρεία εμπορίου κρασιών Wine Enthusiast, η τιμή ανά φιάλη, καθώς και τα γεωγραφικά στοιχεία σχετικά με τη χώρα προέλευσης, την επαρχία ή πολιτεία και τις αμπελουργικές περιοχές τόσο σε ευρύτερο όσο και σε πιο συγκεκριμένο επίπεδο. Το πλούσιο και ποιοτικά διαφοροποιημένο αυτό περιεχόμενο καθιστά το σύνολο δεδομένων κατάλληλο για την ανάπτυξη μοντέλων επεξεργασίας φυσικής γλώσσας, με στόχο τη βαθύτερη κατανόηση, την εξαγωγή πληροφορίας ή και την πρόβλεψη χαρακτηριστικών σχετικών με το κρασί.

Για την προετοιμασία του συνόλου δεδομένων πραγματοποιήθηκε αρχικά έλεγχος ως προς την ύπαρξη των βασικών πεδίων που είναι απαραίτητα για την εκπαίδευση του μοντέλου. Πιο συγκεκριμένα, χρησιμοποιήθηκε το `description` (περιγραφή), `variety` (ποικιλία), `price` (τιμή) και `score` (βαθμολογία). Σε περίπτωση που κάποιο από αυτά τα πεδία απουσίαζε, προστέθηκαν κάποιες προεπιλεγμένες τιμές όπως μια γενική περιγραφή ("A pleasant wine"), μια κοινή ποικιλία ("Red Blend"), μια μέση τιμή (20) και μια ενδεικτική βαθμολογία (85). Στη συνέχεια, πραγματοποιήθηκε διαχείριση των ελλιπών τιμών. Για τις στήλες που περιείχαν συμβολοσειρές, τα κενά πεδία συμπληρώθηκαν με κενές συμβολοσειρές, ενώ για τις αριθμητικές στήλες οι απουσίες καλύφθηκαν με μηδενικές στήλες. Με αυτόν τον τρόπο εξασφαλίστηκε

η πληρότητα και η συνέπεια των δεδομένων ώστε να καταστούν κατάλληλα για την επεξεργασία και την εκπαίδευση του μοντέλου ("Wine Reviews," n.d.).

6.2 Αρχιτεκτονική

Για την επίλυση του προβλήματος, υλοποιήθηκε ένα απλό νευρωνικό δίκτυο βασισμένο στο Transformer. Το μοντέλο ακολουθεί μια τυπική αρχιτεκτονική encoder-only, η οποία περιλαμβάνει τα εξής βασικά στάδια:

Αρχικά, τα δεδομένα εισόδου μετατρέπονται σε ενσωματώσεις μέσω ενός embedding layer. Παράλληλα, γίνεται προσθήκη θέσης (positional encoding) με χρήση χωριστού embedding επιπέδου, προκειμένου να διατηρείται η πληροφορία της σειράς των λέξεων.

Στη συνέχεια, εφαρμόζεται ένας μηχανισμός πολλαπλής κεφαλής αυτοπροσοχής (Multi-Head Self-Attention), ο οποίος επιτρέπει στο μοντέλο να εντοπίζει συσχετίσεις ανάμεσα στις λέξεις κάθε πρότασης. Το αποτέλεσμα συνδυάζεται με skip connection και layer normalization για μεγαλύτερη σταθερότητα κατά την εκπαίδευση.

Έπειτα, η έξοδος περνάει από ένα πλήρως συνδεδεμένο δίκτυο (feed-forward network) με ενεργοποίηση ReLU, προτού ολοκληρωθεί με μια ακόμη διαδικασία κανονικοποίησης. Η τελική αναπαράσταση του κειμένου εξάγεται μέσω παγκόσμιας μέσης συγκέντρωσης.

7. Μελέτη Περιπτώσεων

7.1 Εκτέλεση

Η διαδικασία εκπαίδευσης του μοντέλου πραγματοποιείται σε 4 εποχές (epochs) με μέγεθος παρτίδας (batch size) ίσο με 32. Η πρώτη εποχή διαρκεί περίπου 91 δευτερόλεπτα, ενώ οι επόμενες τρεις απαιτούν κατά μέσο όρο 75 δευτερόλεπτα η καθεμία. Συνολικά, η εκπαίδευση ολοκληρώνεται σε περίπου 316 δευτερόλεπτα, δηλαδή λίγο περισσότερο από 5 λεπτά.

```
Epoch 1/4  
3774/3774 ————— 91s 20ms/step  
  
Epoch 2/4  
3774/3774 ————— 75s 20ms/step  
  
Epoch 3/4  
3774/3774 ————— 75s 20ms/step  
  
Epoch 4/4  
3774/3774 ————— 75s 20ms/step
```

Κατά την παραγωγή προτεινόμενων κρασιών, το μοντέλο ανταποκρίνεται ιδιαίτερα γρήγορα, καθώς η διαδικασία πρόβλεψης ολοκληρώνεται σε λιγότερο από ένα δευτερόλεπτο.

```
Ask me about wine reccomendations!: i want a cheap bold wine  
from france  
1/1 ————— 0s 91ms/step
```

Συνοπτικά, το μοντέλο λειτουργεί αποδοτικά και με ακρίβεια, καθώς είναι σε θέση να προτείνει κρασιά που ευθυγραμμίζονται πλήρως με τις ζητούμενες προδιαγραφές, βασισμένο στα πρότυπα που έχει μάθει κατά την εκπαίδευσή του από το αρχείο CSV.

Παρακάτω παρουσιάζονται ενδεικτικά αποτελέσματα του μοντέλου σε διάφορα ερωτήματα, αναδεικνύοντας την ικανότητά του να προτείνει κρασιά με βάση τα δεδομένα εισόδου και τις παραμέτρους που έχουν τεθεί.

```
Ask me about wine: I want a cheap bold wine
1/1 _____ 0s 73ms/step
Overriding price range with explicit intent: budget
Overriding flavor profile with explicit intent: full-bodied

Based on your query, I understood you want a full-bodied wine
like a Rosé in the budget price category.

Recommendations:

Château Pas du Cerf Rosé, France - $17.0, 84 points
This is full, soft and a little heavy. It's condensed with
sweetness from the rich fruit and miss...

Ca' del Solo Rosé, US - $10.0, 90 points
A Rhôneish blend, with Barbera and Zinfandel, it showcases three
of Randall Grahm's signatures, na...

Château Riotor Rosé, France - $14.0, 89 points
Under the same family ownership as Château Mont-Redon in
```

```
Ask me about wine recommendations!: i want an expensive light
wine from France
1/1 _____ 0s 99ms/step
Overriding price range with explicit intent: premium
Overriding flavor profile with explicit intent: light-bodied

Based on your query, I understood you want a light-bodied wine
like a Rosé from france in the premium price category.

Recommendations:

Château Sainte Roseline Rosé, France - $60.0, 90 points
Light and bright, this is so poised and crisp. It has a lift of
raspberry fruit, lime juice and a...

Château d'Esclans Rosé, France - $90.0, 93 points
Onion-skin pink in color, this wood-aged wine is opulent and
ripe. It is textured, with generous ...
```

Για την εκπαίδευση και εκτέλεση του προτεινόμενου μοντέλου χρησιμοποιήθηκε φορητός υπολογιστής Huawei MateBook 14, εξοπλισμένος με 8 GB μνήμης RAM και επεξεργαστή AMD Ryzen 5 3500U. Ο επεξεργαστής αυτός διαθέτει

ενσωματωμένη κάρτα γραφικών Radeon Vega Mobile GFX με συχνότητα 2.10 GHz. Παρά τον περιορισμένο υπολογιστικό εξοπλισμό, το μοντέλο ανταποκρίθηκε ικανοποιητικά στις απαιτήσεις της εκπαίδευσης και της πρόβλεψης.

8. Συμπεράσματα και Μελλοντικές Προεκτάσεις

8.1 Συμπεράσματα

Η παρούσα πτυχιακή εργασία είχε ως στόχο τη δημιουργία ενός απλού αλλά λειτουργικού μοντέλου Μετασχηματιστή (Transformer) για την πρόβλεψη χαρακτηριστικών κρασιού αξιοποιώντας δεδομένα φυσικής γλώσσας. Με βάση ένα σύνολο δεδομένων από το Kaggle και περιορισμένους υπολογιστικούς πόρους, το μοντέλο κατάφερε να εκπαιδευτεί αποδοτικά και να παράγει προβλέψεις σε λιγότερο από ένα δευτερόλεπτο παρά την χρονοβόρα εκπαίδευσή του η οποία αργεί λόγω του υπερμέγεθους αριθμού εγγραφών στο σύνολο δεδομένων. Τα αποτελέσματα δείχνουν πως ακόμη και με μια απλοποιημένη αρχιτεκτονική, ένα μοντέλο μπορεί να αποδώσει ικανοποιητικά αρκεί να έχει προηγηθεί σωστός καθαρισμός και επεξεργασία των δεδομένων. Η χρήση του Μετασχηματιστή (Transformer) αποδείχθηκε αποτελεσματική στην κατανόηση περιγραφών φυσικής γλώσσας, επιτρέποντας τη σύνδεσή τους με χαρακτηριστικά όπως η ποικιλία, η τιμολογιακή κατηγορία και το προφίλ γεύσης. Ωστόσο, η ακρίβεια των προβλέψεων θα μπορούσε να βελτιωθεί περαιτέρω με τη χρήση πιο εξελιγμένων αρχιτεκτονικών, μεγαλύτερου όγκου δεδομένων και ισχυρότερου υλικού.

8.2 Μελλοντικές Προεκτάσεις

Υπάρχουν αρκετές δυνατότητες για περαιτέρω ανάπτυξη του προτεινόμενου μοντέλου. Αρχικά, το πιο σημαντικό, η χρήση ενός μεγαλύτερου και πιο ποιοτικού συνόλου δεδομένων που θα μπορούσε να ενισχύσει την ακρίβεια των προβλέψεων. Επιπλέον, η αξιοποίηση πιο προηγμένων αρχιτεκτονικών, όπως τα Προ-εκπαιδευμένα Μετασχηματιστικά μοντέλα (Pre-trained Transformer based) γλωσσικά μοντέλα, δηλαδή το BERT και το GPT, θα μπορούσε να προσφέρει βαθύτερη κατανόηση της φυσικής γλώσσας και καλύτερη γενίκευση.

Μια άλλη πιθανή επέκταση περιλαμβάνει την ενσωμάτωση επιπλέον μεταβλητών, όπως αισθητηριακές αξιολογήσεις ή δεδομένα εικόνας από ετικέτες κρασιών, για τη δημιουργία ενός πολυτροπικού μοντέλου αλλά αυτό προϋποθέτει το σύνολο δεδομένων που θα χρησιμοποιηθεί να τα περιλαμβάνει. Η δημιουργία μιας διαδραστικής εφαρμογής όπου ο χρήστης θα μπορεί να εισάγει περιγραφές και να λαμβάνει προτάσεις κρασιών σε πραγματικό χρόνο, θα μπορούσε να προσφέρει πρακτική χρησιμότητα στο ευρύ κοινό και στη βιομηχανία οίνου. Επίσης, θα μπορούσε να επεκταθεί ώστε να υποστηρίζει περισσότερες γλώσσες και πολιτισμικές παραμέτρους, προκειμένου να γίνει πιο χρήσιμο σε διεθνές επίπεδο. Επιπλέον, η σύνδεση του μοντέλου με βάσεις δεδομένων κρασιών, που λειτουργούν σε πραγματικό χρόνο, θα επέτρεπε τη συνεχή ενημέρωση και ανανέωση των προβλέψεων. Τέλος, θα μπορούσε να αξιοποιηθεί μεγαλύτερη υπολογιστική ισχύς ώστε να εκπαιδεύουν πιο σύνθετα μοντέλα με περισσότερες παραμέτρους.

BIBΛΙΟΓΡΑΦΙΑ

1. A, Padmanabha Reddy Y. C. 2018. "Semi-Supervised Learning: A Brief Review." *International Journal of Engineering & Technology*, ahead of print, January 1. <https://doi.org/10.14419/IJET.V7I1.8.9977>.
2. "Artificial Intelligence - Wikipedia." n.d. Accessed July 16, 2025. https://en.wikipedia.org/wiki/Artificial_intelligence.
3. Coşkun, Musab, Özal Yildirim, Ayşegül Uçar, and Yakup Demir. 2017. "AN OVERVIEW OF POPULAR DEEP LEARNING METHODS." *European Journal of Technic* 7 (2): 165–76. <https://doi.org/10.23884/ejt.2017.7.2.11>.
4. Du-Harpur, X., F. M. Watt, N. M. Luscombe, and M. D. Lynch. 2020. "What Is AI? Applications of Artificial Intelligence to Dermatology." *The British Journal of Dermatology* 183 (3): 423–30. <https://doi.org/10.1111/bjd.18880>.
5. Haleem, Abid, Mohd Javaid, Mohd Asim Qadri, Ravi Pratap Singh, and Rajiv Suman. 2022. "Artificial Intelligence (AI) Applications for Marketing: A Literature-Based Study." *International Journal of Intelligent Networks* 3: 119–32. <https://doi.org/10.1016/j.ijin.2022.08.005>.
6. Haleem, Abid, Mohd Javaid, and Ibrahim Haleem Khan. 2019. "Current Status and Applications of Artificial Intelligence (AI) in Medical Field: An Overview." *Current Medicine Research and Practice* 9 (6): 231–37. <https://doi.org/10.1016/j.cmrp.2019.11.005>.
7. "Ijstr.Org/Research-Paper-Publishing.Php?Month=mar2020." n.d. Accessed July 16, 2025. <https://www.ijstr.org/research-paper-publishing.php?month=mar2020>.
8. Naeem, Samreen, Aqib Ali, Sania Anam, and Muhammad Munawar Ahmed. 2023. "An Unsupervised Machine Learning Algorithms: Comprehensive Review." *International Journal of Computing and Digital Systems* 13 (1): 911–21. <https://doi.org/10.12785/ijcds/130172>.
9. Nasteski, Vladimir. 2017. "An Overview of the Supervised Machine Learning Methods." *HORIZONS.B* 4 (December): 51–62. <https://doi.org/10.20544/horizons.b.04.1.17.p05>.
10. Naveed, Humza, Asad Ullah Khan, Shi Qiu, et al. 2024. "A Comprehensive Overview of Large Language Models." arXiv:2307.06435. Preprint, arXiv, October 17. <https://doi.org/10.48550/arXiv.2307.06435>.
11. "Notes-from-the-AI-Frontier-Insights-from-Hundreds-of-Use-Cases-Discussion-Paper.Pdf." n.d. Accessed July 16, 2025. https://www.mckinsey.com/west-coast/~/_media/McKinsey/Featured%20Insights/Artificial%20Intelligence/Notes%20from%20the%20AI%20frontier%20Applications%20and%20

value%20of%20deep%20learning/Notes-from-the-AI-frontier-Insights-from-hundreds-of-use-cases-Discussion-paper.pdf.

12. "(PDF) GPT (Generative Pre-Trained Transformer)— A Comprehensive Review on Enabling Technologies, Potential Applications, Emerging Challenges, and Future Directions." n.d. *ResearchGate*.
<https://doi.org/10.1109/ACCESS.2024.3389497>.
13. Rumelhart, David E, Richard Durbin, Richard Golden, and Yves Chauvin. n.d. *Backpropagation: The Basic Theory*.
14. Sakib Ashraf Zargar. 2021. "(PDF) Introduction to Sequence Learning Models: RNN, LSTM, GRU." *ResearchGate*, April.
<https://doi.org/10.13140/RG.2.2.36370.99522>.
15. *Three Types of Artificial Intelligence*. n.d.
16. *Wikipedia*. 2025. "Deep learning." July 4.
https://en.wikipedia.org/w/index.php?title=Deep_learning&oldid=1298683264.
17. *Wikipedia*. 2025. "Machine learning." July 15.
https://en.wikipedia.org/w/index.php?title=Machine_learning&oldid=1300573757.
18. *Wikipedia*. 2025. "Neural network (machine learning)." July 15.
[https://en.wikipedia.org/w/index.php?title=Neural_network_\(machine_learning\)&oldid=1300580164](https://en.wikipedia.org/w/index.php?title=Neural_network_(machine_learning)&oldid=1300580164).
19. *Wikipedia*. 2025. "Large language model." July 16.
https://en.wikipedia.org/w/index.php?title=Large_language_model&oldid=1300783935.
20. "Wine Reviews." n.d. Accessed July 16, 2025.
<https://www.kaggle.com/datasets/zyincide/wine-reviews>.
21. Zhai, Xuesong, Xiaoyan Chu, Ching Sing Chai, et al. 2021. "A Review of Artificial Intelligence (AI) in Education from 2010 to 2020." *Complexity* 2021 (1): 8812542. <https://doi.org/10.1155/2021/8812542>.

Βιβλιογραφία εικόνας

1. <https://www.google.com/url?sa=i&url=https%3A%2F%2Fwww.dn-africa.com%2Fnews%2F20230724-artificial-narrow-intelligence-ani-artificial-general-intelligence-agi-and-artificial-superintelligence-asi%2F&psig=AOvVaw0EWbTIF0KK1W5jsOUiMMHm&ust=1749738430843000&source=images&cd=vfe&opi=89978449&ved=0CBUQjRxqFwoTCJixqeHJ6Y0DFQAAAAAdAAAAABAE>
2. https://www.google.com/url?sa=i&url=https%3A%2F%2Ffritz.ai%2Fthe-mathematics-behind-decision-trees%2F&psig=AOvVaw3gGxullKg09LSlcT_KaAgD&ust=1749738633971000&source=images&cd=vfe&opi=89978449&ved=0CBUQjRxqFwoTCLj_oMDK6Y0DFQAAAAAdAAAAABAL
3. <https://media.geeksforgeeks.org/wp-content/uploads/20231129130431/11111111.png>
4. <https://images.spiceworks.com/wp-content/uploads/2022/04/11040521/46-4-e1715636469361.png>
5. https://miro.medium.com/v2/resize:fit:640/0*g9JkvvCqgCMYZ_C7.png
6. https://developers.google.com/static/machine-learning/clustering/images/clustering_example.png
7. https://www.google.com/url?sa=i&url=https%3A%2F%2Fprimo.ai%2Findex.php%2FAssociation_Rule_Learning&psig=AOvVaw2HSnQFnV8IBixr0_imKoge&ust=1749739034114000&source=images&cd=vfe&opi=89978449&ved=0CBUQjRxqFwoTCPD8s_L6Y0DFQAAAAAdAAAAABA_T
8. <https://towardsdatascience.com/wp-content/uploads/2019/12/0MRXrKM80u4Qdm7p3.jpg>
9. https://miro.medium.com/v2/resize:fit:1400/1*snZhMEQFhoJwbM5c0CPOAw.png
10. <https://www.researchgate.net/publication/377080625/figure/fig2/AS:11431281229672421@1710558168198/Example-of-clustering-with-unsupervised-and-semi-supervised-learning.png>

11. <https://media.geeksforgeeks.org/wp-content/cdn-uploads/20230602113310/Neural-Networks-Architecture.png>
12. <https://media.geeksforgeeks.org/wp-content/uploads/20240217152156/Frame-13.png>
13. <https://www.researchgate.net/publication/372595960/figure/fig1/AS:11431281176932678@1690294248577/Architecture-of-the-CNN-algorithm.ppm>
14. <https://www.google.com/url?sa=i&url=https%3A%2F%2Fwww.singlestore.com%2Fblog%2Fa-guide-to-softmax-activation-function%2F&psig=AOvVaw3vGadvIBLF41uGg9UCvBjU&ust=1749915450107000&source=images&cd=vfe&opi=89978449&ved=0CBUQjRxqFwoTCPCQ0Z7d7o0DFQAAAAAdAAAAABAE>
15. https://upload.wikimedia.org/wikipedia/commons/3/35/LeNet-5_architecture.svg
16. <https://neurohive.io/wp-content/uploads/2018/10/AlexNet-1.png>
17. <https://www.researchgate.net/publication/388513160/figure/fig1/AS:11431281306402294@1738254353789/Architecture-of-ZFNet-neural-network.ppm>
18. https://miro.medium.com/v2/resize:fit:850/1*B_ZaaaBg2njhp8SThjCufA.png
19. <https://viso.ai/wp-content/uploads/2024/04/google-net-like.png>
20. <https://www.researchgate.net/publication/322621180/figure/fig3/AS:11431281271564851@1723666125552/The-representation-of-model-architecture-image-for-ResNet-152-VGG-19-and-two-layered.tif>
21. https://miro.medium.com/v2/resize:fit:678/1*u4hyohOF9SIRRLBAzqYXfQ.jpeg
22. [https://upload.wikimedia.org/wikipedia/commons/thumb/e/e8/Restricted Boltzmann machine.svg/1200px-Restricted Boltzmann machine.svg.png](https://upload.wikimedia.org/wikipedia/commons/thumb/e/e8/Restricted_Boltzmann_machine.svg/1200px-Restricted Boltzmann machine.svg.png)
23. https://www.google.com/url?sa=i&url=https%3A%2F%2Fwww.geeksforgeeks.org%2Ftypes-of-autoencoders%2F&psig=AOvVaw3fh8vzH8vWLPwe73BALXiF&ust=1750320568823000&source=images&cd=vfe&opi=89978449&ved=0CBUQjRxqFwoTCNj3K_C-o0DFQAAAAAdAAAAABAe

24. <https://curator-production.s3.us.cloud-object-storage.appdomain.cloud/uploads/course-v1:IBMSkillsNetwork+GPXX0A7BEN+v1.jpg>
25. https://media.geeksforgeeks.org/wp-content/uploads/20250319173029489747/cross_attention.webp
26. <https://media.geeksforgeeks.org/wp-content/uploads/20200812212119/encoderselfattention-660x360.PNG>
27. <https://www.researchgate.net/publication/372877520/figure/fig2/AS:11431281178811271@1691080218362/The-principle-of-sparse-attention-mechanism.png>
28. https://miro.medium.com/v2/resize:fit:1400/1*0OV7ituGlfv9Ealfmtqbmj.png
29. https://upload.wikimedia.org/wikipedia/commons/thumb/4/42/ReLU_and_GELU.svg/1200px-ReLU_and_GELU.svg.png
30. <https://cdn.labellerr.com/language%20models-4/Screenshot%202023-05-21%20233029.webp>