



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

UNIVERSITY OF WEST ATTICA

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

Τμήμα Μηχανικών Πληροφορικής και Υπολογιστών

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Μηχανική μάθηση με λίγα δεδομένα

Απόλλων Φοίβος Μακρογαμβράκης

Αριθμός Μητρώου: 713242017105

Επιβλέπων: Γιαννακόπουλος Ηρ. Παναγιώτης
Καθηγητής

Ακαδημαϊκό έτος 2022-2023

Αιγάλεω, Σεπτέμβριος 2023

Η Τριμελής Εξεταστική
Επιτροπή

Ο Επιβλέπων Καθηγητής

ΠΑΝΑΓΙΩΤΗΣ
ΓΙΑΝΝΑΚΟΠΟΥΛΟΣ
Καθηγητής

ΓΕΩΡΓΙΟΣ
ΠΡΕΖΕΡΑΚΟΣ
Καθηγητής

ΚΩΝΣΤΑΝΤΙΝΟΣ
ΜΑΥΡΟΜΜΑΤΗΣ
Λέκτορας

]

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο υπογράφων Μακρογαμβράκης Απόλλων Φοίβος του Κοσμά, με αριθμό μητρώου 713242017105 φοιτητής του Τμήματος Μηχανικών Πληροφορικής Και Υπολογιστών της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της διπλωματικής εργασίας και κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του διπλώματός μου».

Ημερομηνία
24/10/2023

Μακρογαμβράκης Απόλλων Φοίβος

ΠΕΡΙΛΗΨΗ

Η εκμάθηση με λίγα παραδείγματα (Few-Shot Learning - FSL) εστιάζει σε μοντέλα εκπαίδευσης χρησιμοποιώντας ελάχιστα παραδείγματα με ετικέτα, συχνά μόνο ένα έως δέκα δείγματα ανά κατηγορία. Αντικατοπτρίζει την ανθρώπινη γνώση όπου κατανοούμε νέες έννοιες με ελάχιστες οδηγίες. Αν και περισσότερα δεδομένα παράγουν συνήθως καλύτερα αποτελέσματα μηχανικής εκμάθησης, η απόκτηση μεγάλων συνόλων δεδομένων με ετικέτα μπορεί να είναι δύσκολη λόγω κόστους, ζητημάτων απορρήτου ή σπανιότητας δεδομένων. Ως εκ τούτου, η FSL, η οποία εκπαιδεύει μοντέλα με σπάνια δεδομένα, κέρδισε την προσοχή των ερευνητών.

Οι κυριότερες τεχνικές της FSL είναι οι μετροκεντρικές μέθοδοι, όπου στο επίκεντρο της μάθησης βρίσκεται η αξιολόγηση του πόσο παρόμοια ή διαφορετικά τα δείγματα είναι μεταξύ τους, και το Meta-Learning, που εκπαιδεύει μοντέλα σε ποικίλες εργασίες, επιτρέποντας γρήγορη προσαρμογή σε νέες χρησιμοποιώντας την αποκτηθείσα «μετα-γνώση».

Η εκμάθηση με λίγα παραδείγματα είναι ζωτικής σημασίας για την ταξινόμηση εικόνων, την επεξεργασία της γλώσσας και την ενισχυτική εκμάθηση (reinforcement learning). Για ασυνήθιστα περιστατικά, όπως ορισμένες ιατρικές καταστάσεις, η συλλογή άφθονων δεδομένων είναι δύσκολη και η FSL μπορεί να παράσχει λύσεις.

Λέξεις Κλειδιά: εκμάθηση, μοντέλα εκπαίδευσης, μετα-μάθηση

Keywords: Learning, Training Models, Meta-Learning

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήθελα να ευχαριστήσω θερμά τον Καθηγητή κ. Παναγιώτη Γιαννακόπουλο για την εμπιστοσύνη που μου έδειξε για την υλοποίηση της πτυχιακής εργασίας, και για την πολύτιμη βοήθεια και καθοδήγηση. Θα ήθελα επίσης να απευθύνω ευχαριστίες στους γονείς μου, οι οποίοι στήριξαν τις σπουδές μου με διάφορους τρόπους, φροντίζοντας για την καλύτερη δυνατή μόρφωση μου.

1. Μάθηση με λίγα δεδομένα (Few Shot Learning)	1
1.1. Επιβλεπόμενη ή εποπτευόμενη μάθηση (supervised learning).....	1
1.2. Παλινδρόμηση (regression).....	2
1.3. Ταξινόμηση (classification).....	3
1.4. Εφαρμογές Εποπτευόμενης Μάθησης.....	4
1.5. Μάθηση με λίγα δεδομένα (Few Shot Learning).....	5
1.6. Η διαδικασία της εκπαίδευσης και της δοκιμής.....	7
1.7. Η δομή των n-κλάσεων k-παραδειγμάτων (N-Way, K-Shot).....	9
1.8. Μάθηση με ένα παράδειγμα (One-Shot Learning).....	10
2. Σύνολα Δεδομένων (Datasets)	11
2.1. Omniglot.....	11
2.2. MNIST.....	12
2.3. ImageNet.....	13
2.4. CIFAR.....	14
2.5. Άλλα σύνολα δεδομένων.....	15
3. Σιαμαία Νευρωνικά Δίκτυα (Siamese Neural Networks)	16
3.1. Εισαγωγή.....	16
3.2. Δομή.....	17
3.3. Επίπεδα (layers).....	18
3.4. Διανυσματικές έξοδοι χαρακτηριστικών (Feature Vector Outputs).....	19
3.5. Ανάλυση ομοιότητας.....	20
3.6. Εκπαίδευση Σιαμαίων Νευρωνικών Δικτύων.....	21
3.7. Label Tuning.....	23
3.8. Εφαρμογές των σιαμαίων δικτύων.....	24
3.9. Πλεονεκτήματα και μειονεκτήματα των σιαμαίων δικτύων.....	25
4. Δίκτυα αντιστοίχισης (Matching Networks)	27
4.1. Εισαγωγή.....	27
4.2. Καινοτομίες.....	28
4.3. Θεμελιώδεις έννοιες.....	30
4.4. Δομή.....	32


4.5. Ο αλγόριθμος εκπαίδευσης.....	35
4.6. Εφαρμογές.....	38
4.7. Πλεονεκτήματα.....	40
4.8. Μειονεκτήματα	41
5. Δίκτυα πρωτοτύπων (Prototypical Networks).....	42
5.1. Εισαγωγή.....	42
5.2. Ο Βασικός Μηχανισμός των Πρωτοτυπικών Δικτύων: Εξισορρόπηση	43
5.3. Κατασκευή πρωτοτύπων	43
5.4. Εξαγωγή συμπερασμάτων.....	44
5.5. Εκμάθηση ενός μετρικού χώρου	44
5.6. Η σημασία των ενσωματώσεων.....	45
5.7. Πρόβλεψη νέων περιπτώσεων.....	46
5.8. Ο Αλγόριθμος Εκπαίδευσης.....	47
5.9. Ένα πρακτικό σενάριο: Ταξινόμηση χειρόγραφων ψηφίων	48
6. Σχισιακά Δίκτυα (Relation Networks).....	49
6.1. Εισαγωγή.....	49
6.2. Μεθοδολογία Εκπαίδευσης	50
6.3. Δομή.....	51
6.4. Εφαρμογές.....	52
7. Μετα-μάθηση με μεταφορά (Meta-Transfer Learning)	53
7.1. Μάθηση με μεταφορά (Transfer Learning)	53
7.2. Μετα-μάθηση (Meta-Learning).....	55
7.3. Μετα-μάθηση με μεταφορά (Meta-Transfer Learning).....	57
7.4. Πλεονεκτήματα.....	58
8. Μετα-μάθηση σε διαφορετικά πεδία (Model Agnostic Meta Learning ή MAML)...	59
8.1. Εισαγωγή.....	59
8.2. Βελτιστοποίηση δύο επιπέδων.....	61
8.3. Εφαρμογές.....	63
9. Συμπεράσματα	65
10. Βιβλιογραφία.....	67

1. Μάθηση με λίγα δεδομένα (Few Shot Learning)

1.1. Επιβλεπόμενη ή εποπτευόμενη μάθηση (supervised learning)

Η εποπτευόμενη μάθηση είναι ένας τύπος μηχανικής μάθησης όπου ένας αλγόριθμος εκπαιδεύεται σε δεδομένα εκπαίδευσης με ετικέτα. Ο απώτερος στόχος της εποπτευόμενης μάθησης είναι να κάνει προβλέψεις για μη ορατά δεδομένα με βάση τα μοτίβα που έμαθε από τα δεδομένα εκπαίδευσης. Στην εποπτευόμενη μάθηση, τα δεδομένα εκπαίδευσης περιλαμβάνουν ένα σύνολο παραδειγμάτων εισόδου και τις αντίστοιχες σωστές ετικέτες εξόδου τους. Ο αλγόριθμος κάνει προβλέψεις με βάση τα δεδομένα εισόδου και στη συνέχεια αυτές οι προβλέψεις συγκρίνονται με τις πραγματικές ετικέτες εξόδου. Στη συνέχεια, ο αλγόριθμος προσαρμόζεται για να ταιριάζει καλύτερα στα δεδομένα και αυτή η διαδικασία επαναλαμβάνεται έως ότου ο αλγόριθμος φτάσει σε ένα ικανοποιητικό επίπεδο ακρίβειας. Ουσιαστικά, η εποπτευόμενη μάθηση αποτελεί το θεμέλιο πολλών εργασιών μηχανικής μάθησης και αποτελεί αναπόσπαστο κομμάτι σε αμέτρητες πρακτικές εφαρμογές.

Αυτό το υποσύνολο μηχανικής μάθησης κατηγοριοποιείται περαιτέρω σε δύο κύριους τύπους - **παλινδρόμηση (regression)** και **ταξινόμηση (classification)**. Αυτές οι μέθοδοι είναι ευρέως εφαρμόσιμες σε διάφορους τομείς και η χρήση τους συνεχίζει να αυξάνεται με την πρόοδο στις υπολογιστικές δυνατότητες και τη διαθεσιμότητα δεδομένων. Είτε πρόκειται για την πρόβλεψη των τάσεων της χρηματιστηριακής αγοράς (παλινδρόμηση) είτε για τον εντοπισμό καρκινικών κυττάρων σε μια ιατρική σάρωση (ταξινόμηση), οι εποπτευόμενοι αλγόριθμοι μάθησης διαδραματίζουν κρίσιμο ρόλο στη λήψη σημαντικών αποφάσεων και προβλέψεων.



Ταξινόμηση (classification) και παλινδρόμηση (regression) (<https://dev.to/petercour/machine-learning-classification-vs-regression-1gn>)

1.2. Παλινδρόμηση (regression)

Η ανάλυση παλινδρόμησης είναι μια στατιστική διαδικασία που εκτιμά τις σχέσεις μεταξύ των μεταβλητών. Ο πρωταρχικός στόχος της παλινδρόμησης στη μηχανική μάθηση είναι η κατανόηση της συσχέτισης μεταξύ μιας εξαρτημένης (στόχου) και ανεξάρτητης μεταβλητής (πρόβλεψης) και η πρόβλεψη ενός συνεχούς αποτελέσματος.

Με απλά λόγια, εάν προσπαθούμε να προβλέψουμε μια τιμή που είναι συνεχής, όπως η θερμοκρασία για την επόμενη εβδομάδα ή η τιμή ενός σπιτιού, θα χρησιμοποιούσαμε αλγόριθμους παλινδρόμησης.

Μερικοί συνήθεις τύποι αλγορίθμων παλινδρόμησης περιλαμβάνουν:

Γραμμική παλινδρόμηση (Linear regression): Στην απλούστερη μορφή της, η γραμμική παλινδρόμηση αφορά την πρόβλεψη μιας γραμμικής σχέσης μεταξύ της εισόδου και της εξόδου. Όταν υπάρχει μια μεμονωμένη μεταβλητή εισόδου, η μέθοδος ονομάζεται απλή γραμμική παλινδρόμηση και όταν υπάρχουν πολλές μεταβλητές εισόδου, ονομάζεται πολλαπλή γραμμική παλινδρόμηση. Η γραμμική παλινδρόμηση χρησιμοποιείται για την πρόβλεψη μιας εξαρτημένης μεταβλητής με βάση την τιμή μιας ανεξάρτητης μεταβλητής.

Πολυωνυμική παλινδρόμηση (Polynomial regression): Πρόκειται για μια μορφή ανάλυσης παλινδρόμησης στην οποία η σχέση μεταξύ της ανεξάρτητης μεταβλητής x και της εξαρτημένης μεταβλητής y μοντελοποιείται ως πολυώνυμο του βαθμού. Η πολυωνυμική παλινδρόμηση μπορεί να μοντελοποιήσει σχέσεις μεταξύ μεταβλητών που δεν είναι γραμμικές.

Παλινδρόμηση κορυφογραμμής (Ridge Regression): Η παλινδρόμηση κορυφογραμμής είναι ένας τρόπος δημιουργίας ενός φειδωλού μοντέλου όταν ο αριθμός των μεταβλητών πρόβλεψης σε ένα σύνολο υπερβαίνει τον αριθμό των παρατηρήσεων ή όταν ένα σύνολο δεδομένων έχει πολυσυγγραμμικότητα (συσχετίσεις μεταξύ μεταβλητών πρόβλεψης).

Υποστήριξη διανυσματικής παλινδρόμησης (Support Vector Regression - SVR): Σε αντίθεση με τις απλές μεθόδους παλινδρόμησης, το SVR δεν στοχεύει στην ελαχιστοποίηση του ποσοστού σφάλματος, αλλά αντίθετα προσπαθεί να προσαρμόσει το σφάλμα μέσα σε ένα συγκεκριμένο όριο.

1.3. Ταξινόμηση (classification)

Η ταξινόμηση αφορά την πρόβλεψη μιας ετικέτας και περιλαμβάνει την ανάθεση της εισόδου σε δύο ή περισσότερες κλάσεις. Εάν προσπαθούμε να προβλέψουμε κάτι που έχει διακριτή τιμή, όπως αν ένα μήνυμα ηλεκτρονικού ταχυδρομείου είναι ανεπιθύμητο ή όχι ή εάν ένας όγκος είναι καλοήθης ή κακοήθης, θα χρησιμοποιούσαμε αλγόριθμους ταξινόμησης. Οι κύριοι τύποι αλγορίθμων ταξινόμησης περιλαμβάνουν:

Λογιστική παλινδρόμηση (Logistic Regression): Παρά το όνομα, η logistic regression χρησιμοποιείται για την επίλυση προβλημάτων ταξινόμησης. Μετρά την πιθανότητα ενός δυαδικού αποτελέσματος και ταξινομεί τα δεδομένα σε δύο διακριτές ετικέτες.

Δέντρα απόφασης (Decision trees): Τα δέντρα αποφάσεων χωρίζουν τα δεδομένα σε κλάδους για να λάβουν μια απόφαση. Κάθε κλάδος αντιπροσωπεύει μια πιθανή διαδρομή απόφασης.

Τυχαία δάση (Random forests): Τα τυχαία δάση, από την άλλη πλευρά, είναι συλλογές δέντρων απόφασης, τα οποία παρέχουν πιο ισχυρές και ακριβείς προβλέψεις.

Μηχανές υποστήριξης διανυσμάτων (Support-vector machines - SVM): Στόχος τους είναι να βρουν το βέλτιστο υπερεπίπεδο που διαχωρίζει τα δεδομένα στις τάξεις του με τον καλύτερο δυνατό τρόπο.

Μπεϋζιανή στατιστική (Bayesian statistics): Παρέχει μια στατιστική προσέγγιση στη μηχανική μάθηση. Με βάση το θεώρημα του Bayes, ο αλγόριθμος Naive Bayes κάνει μια απλουστευτική (αφελή) υπόθεση ότι κάθε χαρακτηριστικό είναι ανεξάρτητο από τα άλλα.

K-πλησιέστεροι γείτονες (K-nearest neighbors): Το K-NN ταξινομεί ένα σημείο δεδομένων με βάση τον τρόπο ταξινόμησης των γειτόνων του. Το 'K' στο K-NN αναφέρεται στον αριθμό των γειτονικών σημείων δεδομένων που συμβάλλουν στην ταξινόμηση.

Νευρωνικά δίκτυα (Neural networks): Πρόκειται για αλγόριθμους σχεδιασμένους να μιμούνται τον ανθρώπινο εγκέφαλο, ο οποίος μπορεί να μάθει από δεδομένα παρατήρησης. Έχουν χρησιμοποιηθεί με επιτυχία σε πολλούς τομείς, συμπεριλαμβανομένης της αναγνώρισης εικόνας και ομιλίας. Ένας συγκεκριμένος τύπος νευρωνικών δικτύων, που ονομάζονται Συνελικτικά Νευρωνικά Δίκτυα (CNN), χρησιμοποιούνται συχνά για εργασίες ταξινόμησης εικόνων.

Σύνολα ταξινομητών (Ensembles of classifiers): Αυτά χρησιμοποιούν πολλαπλούς αλγόριθμους εκμάθησης για να αποκτήσουν καλύτερη προγνωστική απόδοση.

1.4. Εφαρμογές Εποπτευόμενης Μάθησης

Χρηματοοικονομικές υπηρεσίες (financial services): Η πιστοληπτική αξιολόγηση χρησιμοποιεί μοντέλα εκπαιδευμένα με ιστορικά οικονομικά δεδομένα για την πρόβλεψη της πιθανότητας αποπληρωμής του δανείου των πελατών. Στις συναλλαγές, αυτοί οι αλγόριθμοι δημιουργούν προγνωστικά μοντέλα για τις τιμές των μετοχών.

Υγειονομική περίθαλψη (healthcare): Πρόβλεψη και τη διάγνωση ασθενειών και εξατομικευμένος σχεδιασμός θεραπείας. Αυτά τα μοντέλα προβλέπουν την πιθανότητα ασθένειας ενός ασθενούς με βάση το ιατρικό ιστορικό, τα γενετικά δεδομένα και τους παράγοντες του τρόπου ζωής του.

Μάρκετινγκ και πωλήσεις (Marketing and sales): Τμηματοποίηση πελατών, πρόβλεψη πωλήσεων και πρόβλεψη απόκλισης. Τα μοντέλα μηχανικής εκμάθησης τμηματοποιούν τους πελάτες σε ομάδες για στοχευμένες καμπάνιες μάρκετινγκ.

Κυβερνοασφάλεια (cybersecurity): Χρησιμοποιεί εποπτευόμενη μάθηση για την ανίχνευση εισβολών και την ταξινόμηση κακόβουλου λογισμικού.

Ανάκτηση και εξαγωγή πληροφορίας (Information retrieval and extraction): Οι αλγόριθμοι εποπτευόμενης μάθησης χρησιμοποιούνται σε μηχανές αναζήτησης, συστήματα προτάσεων και φιλτράρισμα πληροφοριών.

Αναγνώριση αντικειμένων (Object recognition): Στην όραση υπολογιστή, χρησιμοποιείται για την αναγνώριση αντικειμένων σε μια εικόνα ή ένα βίντεο. Η βιομηχανία αυτόνομων οχημάτων (autonomous vehicle industry) αξιοποιεί την εποπτευόμενη μάθηση για πλοήγηση και έλεγχο και ανίχνευση εμποδίων. Τα μοντέλα μηχανικής μάθησης εκπαιδεύονται να αντιδρούν σε σενάρια δρόμου, κίνηση και σήματα, ενώ εντοπίζουν επίσης πιθανά εμπόδια για την ασφαλή πλοήγηση.

Οπτική αναγνώριση χαρακτήρων (Optical character recognition - OCR): Οι αλγόριθμοι χρησιμοποιούνται για τη μετατροπή διαφορετικών τύπων εγγράφων, όπως σαρωμένα έγγραφα, αρχεία PDF ή εικόνες που καταγράφονται από ψηφιακή φωτογραφική μηχανή, σε επεξεργάσιμα και αναζητήσιμα δεδομένα.

Αναγνώριση προτύπων (Pattern recognition): Η εποπτευόμενη μάθηση χρησιμοποιείται για βιομετρική αναγνώριση, αναγνώριση ομιλίας και κατηγοριοποίηση κειμένου.

Αναγνώριση ομιλίας (Speech recognition): Οι αλγόριθμοι χρησιμοποιούνται σε εφαρμογές όπως οι φωνητικές διεπαφές χρήστη, η φωνητική αναζήτηση και οι ψηφιακοί βοηθοί.

1.5. Μάθηση με λίγα δεδομένα (Few Shot Learning)

Το Few-Shot Learning αναφέρεται στην πρακτική του σχεδιασμού μοντέλων μηχανικής εκμάθησης που μπορούν να επιτύχουν ικανοποιητική απόδοση με πρόσβαση σε πολύ λίγα παραδείγματα εκπαίδευσης με ετικέτα – συνήθως ένα, πέντε ή δέκα παραδείγματα ανά τάξη. Αυτή η προσέγγιση είναι εμπνευσμένη από τις ανθρώπινες γνωστικές ικανότητες, όπου συχνά μαθαίνουμε νέες έννοιες με πολύ λίγες άμεσες οδηγίες.

Στον τομέα της μηχανικής μάθησης, είναι κοινή αντίληψη ότι περισσότερα δεδομένα οδηγούν γενικά σε καλύτερα μοντέλα. Εξάλλου, τα νευρωνικά δίκτυα, ειδικά τα βαθιά, είναι διαβόητα για την πείνα τους για τεράστιες ποσότητες δεδομένων με ετικέτα. Ωστόσο, η συλλογή τεράστιων συνόλων δεδομένων με ετικέτα δεν είναι πάντα εφικτή λόγω κόστους, ανησυχιών σχετικά με το απόρρητο ή της απόλυτης σπανιότητας ορισμένων τύπων δεδομένων. Αυτό οδήγησε στην εμφάνιση και τη σημασία του Few-Shot Learning (FSL), ενός τομέα που εστιάζει σε μοντέλα εκπαίδευσης που χρησιμοποιούν ελάχιστα δεδομένα με ετικέτα.

Η εκμάθηση με λιγοστά δεδομένα αφορά τη μηχανική μάθηση που εκπαιδεύει μοντέλα για την ταξινόμηση νέων αντικειμένων με ελάχιστα παραδείγματα. Στοχεύει στη δημιουργία μοντέλων που μπορούν να γενικεύουν σε νέες κατηγορίες χρησιμοποιώντας περιορισμένα δεδομένα, σε αντίθεση με τις συμβατικές τεχνικές που απαιτούν πολλαπλά ετικετοποιημένα δεδομένα.

Η τεχνική αυτή είναι χρήσιμη όταν είναι δυσκολεύεται η συλλογή μεγάλων δεδομένων και μπορεί να βοηθήσει στην εκμάθηση κλάσεων που δεν είναι παρούσες στα αρχικά δεδομένα, αλλά είναι σχετικές με γνωστές κατηγορίες (Wang, 2020).

Η εκμάθηση με λιγοστά δεδομένα προσφέρει εφαρμογές σε τομείς όπως ταξινόμηση εικόνων, επεξεργασία γλώσσας και ενισχυτική μάθηση. Είναι πεδίο στο οποίο η έρευνα συνεχίζεται και υπόσχεται πιο εξελιγμένα συστήματα στο μέλλον.

Ωστόσο, καθώς η κοινότητα της μηχανικής μάθησης συνεχίζει την έρευνά της, υπάρχει αισιοδοξία ότι η μάθηση με λιγοστά δεδομένα μπορεί να φέρει επανάσταση στον τρόπο με τον οποίο σκεφτόμαστε τις απαιτήσεις δεδομένων στο AI. Με τη σύγκλιση άλλων τεχνικών, όπως η μάθηση χωρίς επίβλεψη και η ενισχυτική μάθηση, η εκμάθηση με λίγα δεδομένα μπορεί να ανοίξει το δρόμο για πιο αποτελεσματικά, προσαρμόσιμα και συνειδητά δεδομένα AI συστήματα στο μέλλον.

Γιατί είναι **σημαντική** η εκμάθηση με λίγα δεδομένα;

- Σπάνια συμβάντα: Σε περιπτώσεις όπου ορισμένα συμβάντα είναι σπάνια (όπως σπάνιες ιατρικές καταστάσεις), η συλλογή ενός μεγάλου συνόλου δεδομένων δεν είναι πρακτική. Το FSL προσφέρει έναν τρόπο δημιουργίας ισχυρών μοντέλων σε τέτοια σενάρια.
- Προβλήματα κόστους και απορρήτου: Η επισήμανση μεγάλων συνόλων δεδομένων, ειδικά εκείνων που απαιτούν ειδικές γνώσεις, μπορεί να είναι δαπανηρή. Επιπλέον, η συλλογή δεδομένων μπορεί μερικές φορές να παραβιάζει τους κανόνες απορρήτου. Το FSL μετριάζει αυτά τα ζητήματα.
- Δυναμικά περιβάλλοντα: Σε περιβάλλοντα που αλλάζουν γρήγορα, μέχρι τη στιγμή που συλλέγεται ένα τεράστιο σύνολο δεδομένων, μπορεί να είναι ξεπερασμένο. Το FSL επιτρέπει την ταχεία ανάπτυξη μοντέλων.

Ενώ το Few-Shot Learning είναι πολλά υποσχόμενο, δεν είναι χωρίς **προκλήσεις**:

- Υπερπροσαρμογή μοντέλου: Λόγω των περιορισμένων δεδομένων, τα μοντέλα μπορούν εύκολα να υπερπροσαρμοστούν, καθιστώντας δύσκολη τη γενίκευση.
- Διαφορετικότητα σε λίγα παραδείγματα: Η διασφάλιση ότι τα περιορισμένα παραδείγματα αποτυπώνουν την ποικιλομορφία της τάξης είναι πρόκληση.
- Έλλειψη καθιερωμένων σημείων αναφοράς: Το πεδίο είναι σχετικά νέο και εξακολουθούν να εμφανίζονται τυποποιημένα σημεία αναφοράς για σύγκριση.

Τεχνικές στη μάθηση με λίγα δεδομένα:

- Meta-Learning ή Learning to Learn: Η μετα-μάθηση εστιάζει σε μοντέλα εκπαίδευσης σε μια ποικιλία εργασιών με τέτοιο τρόπο ώστε να μπορούν να προσαρμοστούν γρήγορα σε μια νέα εργασία με ελάχιστα δεδομένα. Το μοντέλο μαθαίνει τη «μετα-γνώση» από διάφορες εργασίες, η οποία βοηθά στην ταχεία εκμάθηση νέων εργασιών.
- Εκμάθηση μεταφοράς: Ένα προεκπαιδευμένο μοντέλο σε ένα μεγάλο σύνολο δεδομένων μπορεί να ρυθμιστεί με ακρίβεια σε ένα μικρό σύνολο δεδομένων μιας σχετικής εργασίας. Αυτή η προσέγγιση αξιοποιεί τη γνώση που αποκτήθηκε κατά τη φάση της προεκπαίδευσης.
- Επαύξηση δεδομένων: Επεκτείνοντας τεχνητά το σύνολο δεδομένων εκπαίδευσης μέσω μεθόδων όπως περικοπή, περιστροφή ή άλλες μικρές τροποποιήσεις, η αύξηση δεδομένων μπορεί να βοηθήσει στη βελτίωση της απόδοσης του μοντέλου με περιορισμένα δεδομένα.

1.6. Η διαδικασία της εκπαίδευσης και της δοκιμής

Η μηχανική μάθηση περιλαμβάνει μια αυστηρή διαδικασία εκπαίδευσης και δοκιμών. Κάθε φάση είναι κρίσιμη, διασφαλίζοντας ότι το τελικό μοντέλο είναι ακριβές και εφαρμόσιμο σε σενάρια πραγματικού κόσμου. Καθώς το πεδίο προχωρά, αυτές οι διαδικασίες συνεχίζουν να εξελίσσονται, αλλά η θεμελιώδης σημασία τους παραμένει αμετάβλητη.

Προετοιμασία δεδομένων (Data Preparation). Προτού προκύψει οποιαδήποτε ουσιαστική μάθηση, τα δεδομένα που χρησιμοποιούνται πρέπει να υποβληθούν σε επεξεργασία σε κατάλληλη μορφή. Αυτό το βήμα, που συχνά θεωρείται μία από τις πιο χρονοβόρες φάσεις ενός έργου μηχανικής μάθησης, περιλαμβάνει:

- **Καθαρισμός των δεδομένων (Cleaning).** Αφαίρεση διπλότυπων, διαχείριση τιμών που λείπουν και διόρθωση σφαλμάτων.
- **Προεπεξεργασία των δεδομένων (Preprocessing).** Μετατροπή των δεδομένων σε μορφή κατάλληλη για τον συγκεκριμένο αλγόριθμο, η οποία μπορεί να περιλαμβάνει κανονικοποίηση, τυποποίηση και κωδικοποίηση κατηγορικών μεταβλητών.

Διαχωρισμός δεδομένων (Data Splitting): Μόλις τα δεδομένα είναι έτοιμα, χωρίζονται σε δύο κύρια υποσύνολα:

- **Σετ εκπαίδευσης (Training set):** Αυτό το σετ χρησιμοποιείται για τη διδασκαλία του μοντέλου. Εκεί ο αλγόριθμος θα προσπαθήσει να αποκαλύψει τα υποκείμενα μοτίβα και τις σχέσεις.
- **Δοκιμαστικό σύνολο (Test set):** Αυτό το σετ χρησιμοποιείται για την αξιολόγηση της απόδοσης του μοντέλου. Είναι σημαντικό ότι θα πρέπει να περιέχει μόνο δεδομένα που το μοντέλο δεν έχει δει κατά τη διάρκεια της εκπαίδευσής του.

Εκπαίδευση μοντέλου (Model Training). Κατά τη διάρκεια αυτής της φάσης, η μαγεία συμβαίνει. Χρησιμοποιώντας έναν καθορισμένο αλγόριθμο, το μοντέλο επιχειρεί να μάθει από τα δεδομένα εκπαίδευσης. Αυτό περιλαμβάνει:

- Προβλέψεις με βάση τα δεδομένα εισόδου.
- Συγκρίνονται αυτές οι προβλέψεις με τα πραγματικά αποτελέσματα στο σετ εκπαίδευσης.
- Προσαρμογή των εσωτερικών παραμέτρων του μοντέλου για την ελαχιστοποίηση της απόκλισης μεταξύ προβλεπόμενων και πραγματικών τιμών. Αυτή η διαδικασία προσαρμογής συνήθως διέπεται από έναν αλγόριθμο βελτιστοποίησης.

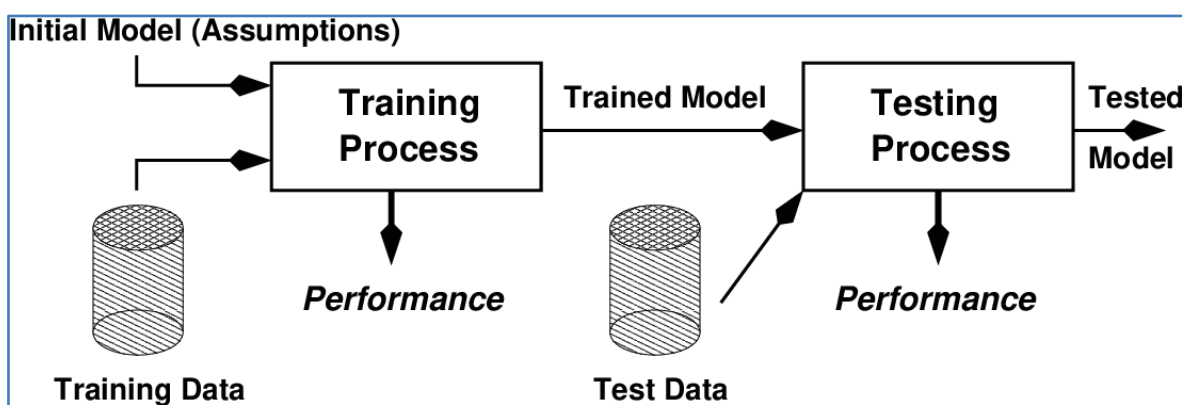
Αξιολόγηση μοντέλου (Model Evaluation). Αφού το μοντέλο έχει εκπαιδευτεί, ήρθε η ώρα να δοκιμάσετε τις δυνατότητές του. Χρησιμοποιώντας το σύνολο δοκιμών, μπορούμε να εκτιμήσουμε πόσο καλά θα αποδώσει το μοντέλο σε αόρατα δεδομένα. Πιθανές καταστάσεις:

- **Υπερπροσαρμογή (Overfitting):** Όταν ένα μοντέλο έχει εξαιρετικά καλή απόδοση στα δεδομένα εκπαίδευσης αλλά ελάχιστα στα δεδομένα δοκιμής, μπορεί να έχει απομνημονεύσει τα δεδομένα εκπαίδευσης αντί να έχει μάθει από αυτά.
- **Γενίκευση (Generalization):** Ο απώτερος στόχος είναι το μοντέλο να γενικεύεται καλά, που σημαίνει ότι μπορεί να κάνει ακριβείς προβλέψεις για νέα, αόρατα δεδομένα.

Βελτιστοποίηση μοντέλου (Model Optimization). Εάν η απόδοση του μοντέλου δεν είναι στο ίδιο επίπεδο, επιστρέφει στον πίνακα σχεδίασης. Κατά τη φάση της βελτιστοποίησης, γίνονται τροποποιήσεις για τη βελτίωση του μοντέλου. Αυτό μπορεί να περιλαμβάνει:

- Προσαρμογή υπερπαραμέτρων, που διέπουν τη διαδικασία εκμάθησης του μοντέλου.
- Πιθανή προσθήκη περισσότερων δεδομένων ή λειτουργιών.
- Διαφορετικούς αλγόριθμους ή αρχιτεκτονικές μοντέλων.
- Μετά από αυτές τις προσαρμογές, το μοντέλο επανεκπαιδεύεται και επαναξιολογείται μέχρι να επιτευχθεί ικανοποιητική απόδοση.

Δοκιμή (Testing). Τέλος, μόλις το μοντέλο εκπαιδευτεί και τελειοποιηθεί με ικανοποιητικό τρόπο, είναι έτοιμο για εφαρμογή στον πραγματικό κόσμο. Σε αυτό το στάδιο, το μοντέλο μπορεί να αναπτυχθεί για να κάνει προβλέψεις σε εντελώς νέα δεδομένα, εκπληρώνοντας τον σκοπό του στη γραμμή μηχανικής μάθησης.



Η διαδικασία της εκπαίδευσης και της δοκιμής. (<https://www.semanticscholar.org/paper/Training-Process-Testing-Initial-Model-%28-%29-Trained-Lucas/c2229d9ed78ad846d365cbf5c34ca463ee5f375c/figure/0>)

1.7. Η δομή των n-κλάσεων k-παραδειγμάτων (N-Way, K-Shot)

Η εκμάθηση με λίγα δεδομένα, που βασίζεται στο μοντέλο N-Way, K-Shot εστιάζει στην επίτευξη επάρκειας με περιορισμένα παραδείγματα, καθιστώντας το ένα ισχυρό εργαλείο σε σενάρια με σπάνια δεδομένα.

Ένα σύνολο δεδομένων χωρίζεται συνήθως σε δύο κύρια τμήματα:

- Σετ εκπαίδευσης ή σετ υποστήριξης: Αυτό το τμήμα χρησιμοποιείται για την εκπαίδευση του μοντέλου. Είναι η κύρια πηγή δεδομένων από την οποία μαθαίνει το μοντέλο.
- Test Set ή Query Set: Αυτό το σύνολο προορίζεται για την αξιολόγηση της απόδοσης του μοντέλου. Περιέχει δεδομένα που δεν έχει δει το μοντέλο κατά τη φάση εκπαίδευσης και χρησιμοποιείται για τη μέτρηση των δυνατοτήτων γενίκευσης του μοντέλου.

Η εκμάθηση N-Way, K-Shot είναι μια ιδιαίτερη προσέγγιση που χρησιμοποιείται κυρίως σε μαθησιακές εργασίες με λιγοστά δεδομένα. Στοχεύει να κάνει ακριβείς προβλέψεις ακόμα και όταν υπάρχουν πολύ λίγα παραδείγματα διαθέσιμα για κάθε τάξη. Η κατανομή έχει ως εξής:

- N (Αριθμός κλάσεων): Αναφέρεται στις διακριτές κατηγορίες ή κλάσεις που υπάρχουν στο σύνολο υποστήριξης.
- K (Δείγματα ανά Τάξη): Υποδεικνύει τον αριθμό των διαθέσιμων παραδειγμάτων ή δειγμάτων για καθεμία από αυτές τις N κατηγορίες.

Για παράδειγμα, σε μια εργασία ταξινόμησης εικόνων 12 κλάσεων, 7 δειγμάτων, το σύνολο υποστήριξης θα περιέχει 12 διακριτές κατηγορίες εικόνων, με 7 δείγματα (ή εικόνες) για καθεμία από αυτές τις κατηγορίες. Έτσι, θα υπήρχαν συνολικά 84 μοναδικά δείγματα στο σετ υποστήριξης.

Το σύνολο ερωτημάτων περιλαμβάνει πολλά άγνωστα δείγματα. Αυτά τα δείγματα κατανέμονται ομοιόμορφα στις N κατηγορίες. Ο στόχος κατά τη φάση της δοκιμής είναι να εξακριβωθεί η κλάση στην οποία ανήκει κάθε δείγμα στο σύνολο ερωτημάτων.

Κατά τη δοκιμή, η αποστολή του εκπαιδευμένου μοντέλου είναι να προβλέψει τη σωστή κλάση για κάθε δείγμα στο σύνολο ερωτημάτων. Στη συνέχεια, μια μέτρηση απόδοσης αξιολογεί πόσες από αυτές τις προβλέψεις ήταν ακριβείς. Αυτό το ποσοστό των επιτυχημένων προβλέψεων από το μοντέλο συγκρίνεται συνήθως με ένα σημείο αναφοράς — συχνά έναν αλγόριθμο τυχαίας επιλογής.

Ένας αλγόριθμος τυχαίας επιλογής απλώς επιλέγει μια κλάση τυχαία για κάθε δείγμα. Το ποσοστό επιτυχίας του θα ήταν μαθηματικά $100/N$ % για N κλάσεις. Έτσι, στην προαναφερθείσα εργασία ταξινόμησης 12 κλάσεων, ένας αλγόριθμος τυχαίας επιλογής θα ήταν σωστός περίπου στο 8,5% των περιπτώσεων.

1.8. Μάθηση με ένα παράδειγμα (One-Shot Learning)

Τα ανθρώπινα όντα διαθέτουν μια απίστευτη γνωστική ικανότητα να αντιλαμβάνονται γρήγορα νέες κατηγορίες αντικειμένων χρησιμοποιώντας πολύ περιορισμένα παραδείγματα. Μέχρι την ηλικία των έξι ετών, ένα παιδί πιστεύεται ότι έχει αποκτήσει γνώσεις για σχεδόν κάθε κατηγορία αντικειμένων που είναι γνωστή στην ανθρωπότητα. Αυτό το θαύμα αποδίδεται στην ικανότητα του ανθρώπινου εγκεφάλου να συνδυάζει γνώσεις από προηγούμενες κατηγορίες για την κατασκευή νέων ταξινομήσεων αντικειμένων.

Η μάθηση με ένα παράδειγμα είναι μια αλλαγή παραδείγματος στον τομέα της μηχανικής μάθησης, μιμούμενη αυτή την εξαιρετική ανθρώπινη ικανότητα. Επιτρέπει σε ένα μοντέλο να ταξινομεί νέα παραδείγματα με βάση μόνο ένα παράδειγμα. Αυτή η προσέγγιση καθίσταται εξαιρετικά πολύτιμη σε καταστάσεις όπου η συλλογή σημαντικών δεδομένων με ετικέτα για κάθε κατηγορία αποδεικνύεται πρόκληση ή μη πρακτική. Διάφορες τεχνικές έχουν αναπτυχθεί για να επιτευχθεί αυτό, και μερικές από τις αξιοσημείωτες περιλαμβάνουν:

- Σιαμαία Δίκτυα: Πρόκειται για νευρωνικά δίκτυα που αποτελούνται από δύο πανομοιότυπα υποδίκτυα που μοιράζονται τα ίδια βάρη. Ο σχεδιασμός τους είναι τέτοιος ώστε να μπορούν να διαφοροποιήσουν το πόσο όμοια ή διαφορετικά είναι δύο παραδείγματα εισόδου.
- Δίκτυα πρωτοτύπων: Αυτά τα δίκτυα έχουν σχεδιαστεί για να μαθαίνουν ένα πρωτότυπο ή ένα αντιπροσωπευτικό παράδειγμα για κάθε τάξη. Στη συνέχεια, το εκπαιδευμένο μοντέλο ταξινομεί νέες περιπτώσεις με βάση την ομοιότητά τους με αυτά τα πρωτότυπα.
- Μοντέλα γλώσσας: Ιδιαίτερα στις εργασίες επεξεργασίας φυσικής γλώσσας (NLP), μοντέλα γλώσσας όπως το GPT-3 του OpenAI έχουν δείξει πολλά υποσχόμενα αποτελέσματα. Εδώ, τα παραδείγματα τροφοδοτούνται απευθείας στη γραμμή εντολών του μοντέλου, επιτρέποντάς του να δημιουργεί ή να ταξινομεί με βάση τις συμπραζόμενες πληροφορίες στις οποίες έχει εκπαιδευτεί.

Για ένα σύστημα που χρησιμοποιεί μάθηση με ένα παράδειγμα, το σετ υποστήριξης, το οποίο είναι κρίσιμο για την εκπαίδευση, περιλαμβάνει:

- N κλάσεις: Αντιπροσωπεύουν τις διακριτές κατηγορίες που πρέπει να αναγνωρίσει το μοντέλο.
- 1 δείγμα ανά τάξη: Σε αντίθεση με την παραδοσιακή μηχανική εκμάθηση όπου μπορεί να απαιτούνται εκατοντάδες ή χιλιάδες δείγματα, εδώ χρησιμοποιείται μόνο μία παρουσία ανά κατηγορία.

Το σύνολο ερωτημάτων, από την άλλη πλευρά, περιλαμβάνει πολλά άγνωστα δείγματα. Η κλάση στην οποία ανήκει κάθε δείγμα κατανέμεται ομοιόμορφα στις N κατηγορίες.

2. Σύνολα Δεδομένων (Datasets)

2.1. Omniglot

Ανάμεσα στην πληθώρα των συνόλων δεδομένων που είναι διαθέσιμα για μηχανική μάθηση, το σύνολο δεδομένων Omniglot κατέχει μια μοναδική θέση. Αντί να δίνει έμφαση σε μεγάλες ποσότητες παραδειγμάτων για ένα περιορισμένο σύνολο τάξεων, το Omniglot προσφέρει μια πλούσια ποικιλία τάξεων με λιγότερα παραδείγματα η καθεμία.

Σύνθεση του συνόλου δεδομένων Omniglot:

- 1.623 χαρακτήρες: Το σύνολο δεδομένων διαθέτει μια αξιοσημείωτη συλλογή από 1.623 διακριτούς χειρόγραφους χαρακτήρες.
- 50 αλφάβητα: Αυτοί οι χαρακτήρες προέρχονται από 50 διαφορετικά αλφάβητα, προσφέροντας απaráμιλλη ποικιλία και πλούτο.
- 20 στιγμιότυπα ανά χαρακτήρα: Για κάθε χαρακτήρα, υπάρχουν 20 διαφορετικά στιγμιότυπα ή δείγματα, παρέχοντας επαρκή διακύμανση διατηρώντας παράλληλα τη μοναδικότητα.
- Χαρακτηριστικά εικόνας: Κάθε εικόνα είναι μια αναπαράσταση σε κλίμακα του γκρι με διαστάσεις 105 x 105 pixel, διασφαλίζοντας ομοιομορφία σε όλο το σύνολο δεδομένων.

Το όνομα "Omniglot" έχει δημιουργηθεί έξυπνα από το λατινικό πρόθεμα "omnis", που σημαίνει "όλα" και την ελληνική ρίζα "glossa", που σημαίνει "γλώσσα" ή "γλώσσα". Είναι ένας κατάλληλος τίτλος για ένα σύνολο δεδομένων που φιλοδοξεί να περιλάβει τη γλωσσική ποικιλομορφία του κόσμου μας. Η σημασία του εκτείνεται πέρα από το να είναι απλώς ένα σύνολο δεδομένων. Το Omniglot έχει χρησιμοποιηθεί ευρέως στην ανάπτυξη και τη συγκριτική αξιολόγηση μοντέλων τεχνητής νοημοσύνης. Αναγνωρίζοντας τη σημασία του, η κοινότητα AI έχει καθιερώσει την ετήσια πρόκληση Omniglot. Αυτός ο διαγωνισμός αναθέτει στους συμμετέχοντες να ωθήσουν τα όρια της μηχανικής μάθησης αναπτύσσοντας μοντέλα που μπορούν να μάθουν γρήγορα και αποτελεσματικά από τα περιορισμένα παραδείγματα που παρέχονται - παρόμοια με το παράδειγμα της μάθησης με ένα δείγμα.




Χαρακτήρες στο Omniglot (<https://github.com/topics/omniglot>).

2.2. MNIST

Στον κόσμο της μηχανικής μάθησης και της επεξεργασίας εικόνας, υπάρχουν μερικά σύνολα δεδομένων που αποτελούν ορόσημα. Το σύνολο δεδομένων MNIST, από πολλές απόψεις, είναι συνώνυμο με τις απαρχές της μηχανικής μάθησης σε εικόνες. Ήταν το πρώτο σημείο επαφής για πολλούς που τολμούσαν σε αυτόν τον τομέα και παραμένει σημείο αναφοράς για τη σύγκριση της αποτελεσματικότητας νέων αλγορίθμων. Η κληρονομιά του MNIST ως ακρογωνιαίος λίθος της χειρόγραφης αναγνώρισης ψηφίων παραμένει αδιαμφισβήτητη. Είτε κάποιος μόλις ξεκινάει είτε είναι έμπειρος ερευνητής που στοχεύει να δοκιμάσει μια νέα υπόθεση, το σύνολο δεδομένων MNIST είναι πάντα η καλύτερη επιλογή.

Το σύνολο δεδομένων MNIST είναι ουσιαστικά μια συλλογή χειρόγραφων ψηφίων, που κυμαίνονται από το 0 έως το 9. Τι κάνει όμως το MNIST πραγματικά ανεκτίμητο;

- **Όγκος δεδομένων:** Το σύνολο δεδομένων περιέχει ισχυρές 60.000 εικόνες εκπαίδευσης, συνοδευόμενες από ένα επιπλέον σύνολο 10.000 δοκιμαστικών εικόνων. Αυτός ο μεγάλος όγκος διασφαλίζει ότι τα μοντέλα μηχανικής εκμάθησης έχουν άφθονα δεδομένα για να μάθουν και να επικυρώσουν.
- **Διαφορετικές παραστάσεις:** Τα χειρόγραφα ψηφία στο MNIST προέρχονται από διάφορα άτομα, που περιλαμβάνουν τόσο τους φοιτητές όσο και τους υπαλλήλους του Γραφείου Απογραφής. Αυτή η ποικιλομορφία στα στυλ γραφής, τις πινελιές και τις φόρμες διασφαλίζει ότι τα μοντέλα που εκπαιδεύονται σε αυτό μπορούν να γενικεύονται καλά σε διαφορετικά στυλ.
- **Τυποποίηση:** Κάθε εικόνα στο σύνολο δεδομένων MNIST έχει κανονικοποιηθεί ως προς το μέγεθος και έχει κεντραριστεί σε μια εικόνα σταθερού μεγέθους 28 x 28 pixels. Αυτή η ομοιομορφία απλοποιεί τα βήματα προεπεξεργασίας και επιτρέπει στους ερευνητές να επικεντρωθούν στην ανάπτυξη αλγορίθμων.



Χαρακτήρες στο MNIST (<https://paperswithcode.com/dataset/mnist>).

2.3. ImageNet

Το ImageNet είναι μια βάση δεδομένων που δημιουργήθηκε για την έρευνα λογισμικού οπτικής αναγνώρισης αντικειμένων. Το ImageNet δεν έχει χρησιμεύσει μόνο ως μια ανεκτίμητη πηγή για τους ερευνητές, αλλά και ως σημείο αναφοράς για το τι είναι εφικτό στην οπτική αναγνώριση αντικειμένων.

Το ImageNet είναι μια εκτεταμένη συλλογή που αποτελείται από πάνω από 14 εκατομμύρια φωτογραφίες με επικέτα. Πάνω από ένα εκατομμύριο εικόνες είναι εξοπλισμένες με πλαίσια καθορισμένα με όρια, καθιστώντας την ανίχνευση και την κατηγοριοποίηση αντικειμένων πιο ακριβή.

Η συνεισφορά του ImageNet υπερβαίνει το να είναι απλός χώρος αποθήκευσης. Από το 2010, το έργο ImageNet φιλοξενεί τον ILSVRC, έναν ετήσιο διαγωνισμό λογισμικού όπου τα προγράμματα λογισμικού ανταγωνίζονται σε εργασίες ακριβούς αναγνώρισης και ανίχνευσης αντικειμένων.

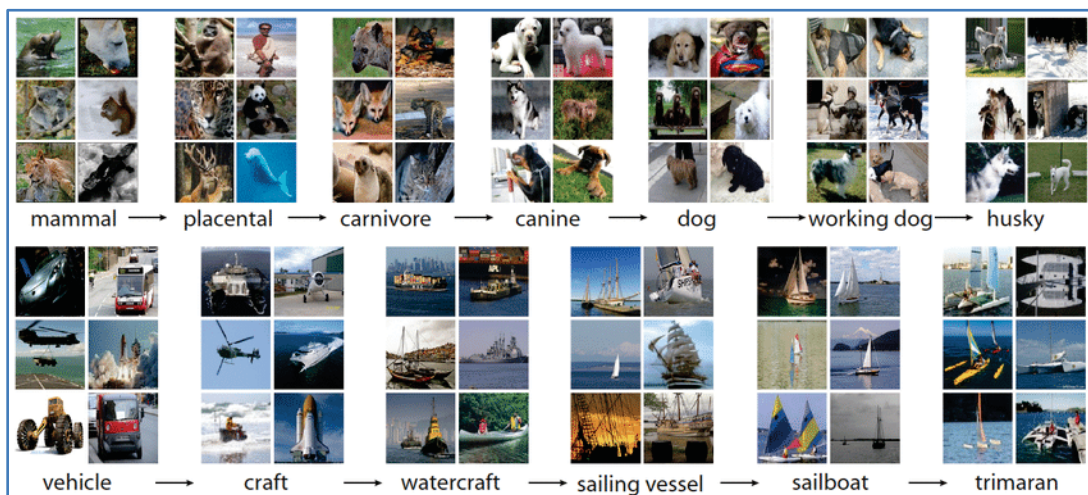
Μια πρωτοποριακή στιγμή ήρθε το 2012 όταν ένα συνελκτικό νευρωνικό δίκτυο (CNN) με το όνομα AlexNet πέτυχε ποσοστό σφάλματος μόλις 15,3%. Αυτό ήταν εκπληκτικά 10,8 ποσοστιαίες μονάδες καλύτερο από τον δεύτερο καλύτερο συμμετέχοντα. Τέτοια ακρίβεια ήταν προηγουμένως αδιανόητη,

Τα διαφορετικά υποσύνολα ImageNet είναι:

ImageNet-21K: Η αρχική εκτεταμένη συλλογή του ImageNet. Διαθέτει 14.197.122 εικόνες που εκτείνονται σε 21.841 διακριτές κατηγορίες.

ImageNet-1K: Περιλαμβάνει 1.281.167 εικόνες εκπαίδευσης, 50.000 εικόνες επικύρωσης και επιπλέον 100.000 δοκιμαστικές εικόνες. Παρά το γεγονός ότι είναι μικρότερο, διατηρεί την ποικιλομορφία και την πολυπλοκότητα του γονικού.

Mini-ImageNet: Αυτό το σύνολο δεδομένων προσφέρει 100 κλάσεις με 600 παραδείγματα ανά τάξη.



Εικόνες στο ImageNet (<https://devopedia.org/imagenet>).


2.4. CIFAR

Το **CIFAR-10** είναι ένα βασικό σύνολο δεδομένων στην κοινότητα μηχανικής μάθησης. Αποτελώντας 10 διακριτές κατηγορίες, χρησιμεύει ως σημείο αναφοράς για εργασίες ταξινόμησης. Αυτές οι κατηγορίες είναι αεροπλάνα, πουλιά, γάτες, αυτοκίνητα, ελάφια, σκύλοι, βάτραχοι, άλογα, πλοία και φορτηγά. Το σύνολο δεδομένων προσφέρει μια ισχυρή ποικιλία με 60.000 έγχρωμες εικόνες εκπαίδευσης μεγέθους 32x32 pixel, μαζί με 10.000 δοκιμαστικές εικόνες.

Είναι ενδιαφέρον ότι το CIFAR-10 διασφαλίζει ότι δεν υπάρχει επικάλυψη μεταξύ των κατηγοριών. Για παράδειγμα, όταν εξετάζουμε οχήματα, η κατηγορία "Automobile" περιλαμβάνει αποκλειστικά σεντάν, SUV και παρόμοιους τύπους, ενώ το "Truck" εστιάζει αυστηρά σε μεγαλύτερα φορτηγά.

CIFAR-FS: Αυτή είναι μια βελτιωμένη έκδοση του CIFAR-10, παρέχοντας μόνο 500 παραδείγματα για κάθε κατηγορία. Το CIFAR-FS αναπτύχθηκε κυρίως για να διευκολύνει το Few-Shot Learning, μια τεχνική που στοχεύει στην επίτευξη αξιόπιστης απόδοσης με περιορισμένα δεδομένα εκπαίδευσης.

CIFAR-100: Με βάση τη δομή του CIFAR-10, το CIFAR-100 προσφέρει μια πιο αναλυτική εμπειρία ταξινόμησης, ενσωματώνοντας 100 κατηγορίες με 600 εικόνες η καθεμία. Οι 100 κατηγορίες ομαδοποιούνται σε 20 υπερτάξεις. Κάθε εικόνα σε αυτό το σύνολο δεδομένων έχει δύο συσχετισμένες ετικέτες: μια ετικέτα "φιλή" (η συγκεκριμένη κατηγορία στην οποία ανήκει) και μια "χονδροειδής" ετικέτα (η υπερκλάση της). Για παράδειγμα, κάτω από την υπερκατηγορία "λουλούδια", μπορεί να βρείτε συγκεκριμένες κατηγορίες όπως ορχιδέες, παπαρούνες, τριαντάφυλλα, ηλίανθους και τουλίπες.



Εικόνες στο CIFAR (<https://www.analyticsvidhya.com/blog/2021/09/convolutional-neural-network-pytorch-implementation-on-cifar10-dataset/>).

2.5. Άλλα σύνολα δεδομένων

FC100

<https://github.com/MilesCranmer/FC100>

Το σύνολο δεδομένων FC100 περιλαμβάνει 100 κατηγορίες εικόνων. Κάθε κατηγορία είναι εξοπλισμένη με 500 παραδείγματα εκπαίδευσης και 50 δείγματα δοκιμών. Προσφέρει μια ισορροπημένη δομή, διασφαλίζοντας ότι τα μοντέλα μηχανικής εκμάθησης διαθέτουν άφθονο όγκο δεδομένων τόσο για εκπαίδευση όσο και για επικύρωση, παρέχοντας μια δίκαιη πλατφόρμα για την αξιολόγηση της απόδοσης του μοντέλου.

CUB-200-2011

<http://www.vision.caltech.edu/visipedia/CUB-200-2011.html>

Βουτώντας στον κόσμο της ορνιθολογίας, το σύνολο δεδομένων CUB-200-2011 προσφέρει εικόνες από 200 διαφορετικά είδη πουλιών. Κάθε είδος αντιπροσωπεύεται με περίπου 30 εικόνες, επιτρέποντας λεπτομερή οπτική μάθηση, ειδικά για μοντέλα που στοχεύουν στην κατανόηση των αποχρώσεων των πτηνών.

FGVC-Aircraft.

<http://www.robots.ox.ac.uk/~vgg/data/fgvc-aircraft/>

Για τους λάτρεις της αεροπορίας, το σύνολο δεδομένων FGVC-Aircraft είναι ένας θησαυρός. Αποτελείται από εικόνες αεροσκαφών που κατανέμονται σε 100 διαφορετικές κατηγορίες, με κάθε κατηγορία να διαθέτει περίπου 200 δείγματα. Αυτό το σύνολο δεδομένων παρέχει μια εκτενή επισκόπηση των παραλλαγών των αεροσκαφών, βοηθώντας στην ανάπτυξη μοντέλων για την ταξινόμηση και την αναγνώριση αεροσκαφών.

VGG Flower

<http://www.robots.ox.ac.uk/~vgg/data/flowers/102/>

Τα λουλούδια, με τα μυριάδες σχήματα, χρώματα και δομές τους, είναι μια οπτική απόλαυση. Το σύνολο δεδομένων VGG Flower αξιοποιεί αυτήν την ποικιλομορφία, παρουσιάζοντας εικόνες 102 διαφορετικών ειδών λουλουδιών. Ο αριθμός των εικόνων ανά είδος κυμαίνεται μεταξύ 40 και 258, διασφαλίζοντας μια ολοκληρωμένη συλλογή για εργασίες αναγνώρισης ειδών λουλουδιών.

Stanford Dogs

<http://vision.stanford.edu/aditya86/ImageNetDogs/>

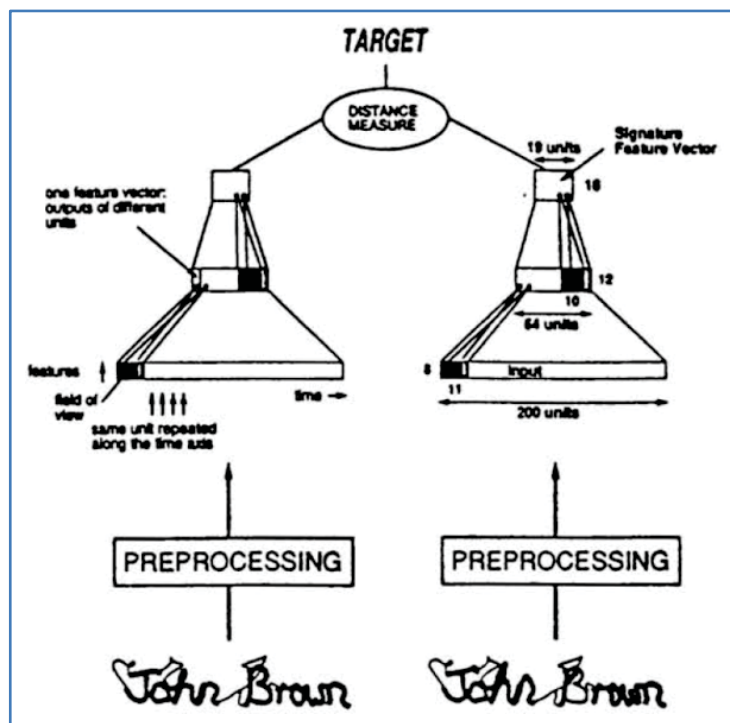
Το σύνολο δεδομένων Stanford Dogs περιλαμβάνει εικόνες 120 φυλών σκύλων, με κάθε ράτσα να αντιπροσωπεύεται από περίπου 150 εικόνες. Αυτή η εκτεταμένη συλλογή μπορεί να βοηθήσει σε μοντέλα που επικεντρώνονται στην αναγνώριση της ράτσας σκύλου.

3. Σιαμαία Νευρωνικά Δίκτυα (Siamese Neural Networks)

3.1. Εισαγωγή

Τα **σιαμαία νευρωνικά δίκτυα (Siamese Neural Networks - SNN)** αποτελούν ένα ισχυρό εργαλείο για την επίλυση ποικίλων εργασιών μηχανικής μάθησης, ειδικά στους τομείς της αναγνώρισης εικόνας και ομιλίας. Εμφανίστηκαν για πρώτη φορά το 1993 για να λύσουν την επαλήθευση υπογραφής ως πρόβλημα αντιστοίχισης εικόνας (Bromley, 1993). Η αρχιτεκτονική τους, χτισμένη στη βάση δίδυμων υποδικτύων, προσφέρει μια μοναδική προσέγγιση στη μάθηση συγκρίνοντας ζεύγη εισροών αντί για παραδοσιακές μεθόδους ταξινόμησης. Είναι μια κλάση νευρωνικών δικτύων που συναντάται σε εφαρμογές της μάθησης με λίγα δεδομένα και είναι κατάλληλα για μάθηση με ένα δεδομένο ανά κλάση (Koch, 2015).

Τα σιαμαία νευρωνικά δίκτυα είναι ένας ειδικός τύπος νευρωνικού δικτύου που έχει σχεδιαστεί για να εκτελεί εργασίες που απαιτούν τον προσδιορισμό της ομοιότητας ή της ανομοιότητας μεταξύ δύο σημείων δεδομένων εισόδου. Το δίκτυο αποτελείται από δύο πανομοιότυπα υποδίκτυα, ή «δίδυμα», συνδεδεμένα σε έναν μόνο κόμβο εξόδου που υπολογίζει την απόσταση μεταξύ των διανυσμάτων χαρακτηριστικών εξόδου των δύο υποδικτύων.



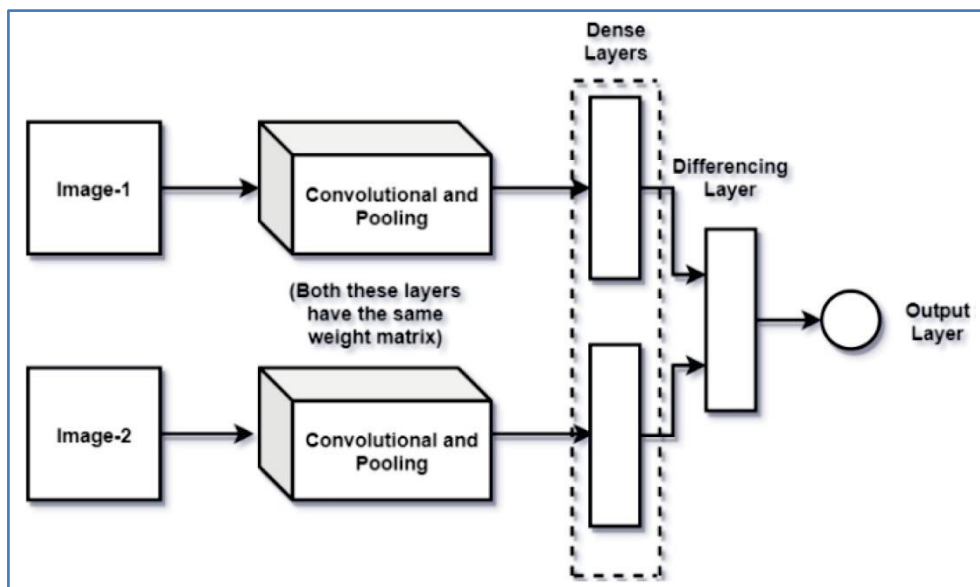
Σιαμαίο Νευρωνικό Δίκτυο για επαλήθευση υπογραφής (Bromley, 1993)

3.2. Δομή

Τα σιαματικά νευρωνικά δίκτυα (SNN) αντιπροσωπεύουν μια ξεχωριστή κατηγορία νευρωνικών δικτύων που επικεντρώνονται στην αξιολόγηση της ομοιότητας ή της ομοιότητας μεταξύ δύο σημείων δεδομένων εισόδου. Τα SNN ξεχωρίζουν από τα παραδοσιακά νευρωνικά δίκτυα ανατροφοδότησης λόγω της μοναδικής αρχιτεκτονικής τους που αποτελείται από δύο πανομοιότυπα υποδίκτυα ή «δίδυμα». Αυτά τα υποδίκτυα μοιράζονται τα ίδια βάρη και την ίδια αρχιτεκτονική, διασφαλίζοντας ότι και οι δύο εισοδοί μαθαίνουν τα ίδια χαρακτηριστικά για να καταγράψουν αποτελεσματικά την ομοιότητά τους.

Η ομοιότητα μεταξύ των δύο διανυσμάτων χαρακτηριστικών υπολογίζεται στη συνέχεια χρησιμοποιώντας μια συνάρτηση απόστασης, όπως η ευκλείδεια απόσταση ή η ομοιότητα συνημιτόνου. Η απόσταση που προκύπτει χρησιμοποιείται ως έξοδος του δικτύου και χρησιμεύει ως βάση για τη σύγκριση ζευγών σημείων δεδομένων εισόδου.

Τα δομικά στοιχεία ενός σιαμαίου νευρωνικού δικτύου είναι τα δίδυμα υποδίκτυά του, τα οποία μοιράζονται την ίδια αρχιτεκτονική και βάρη. Αυτή η κατανομή βάρους διασφαλίζει ότι μαθαίνονται τα ίδια χαρακτηριστικά και για τις δύο εισόδους, καταγράφοντας αποτελεσματικά την ομοιότητα μεταξύ τους. Συνήθως, αυτά τα υποδίκτυα αποτελούνται από πολλαπλά επίπεδα συνελικτικών, συγκέντρωσης, και πλήρως συνδεδεμένων επιπέδων, ακολουθούμενα από μια έξοδο διανυσματικών χαρακτηριστικών.

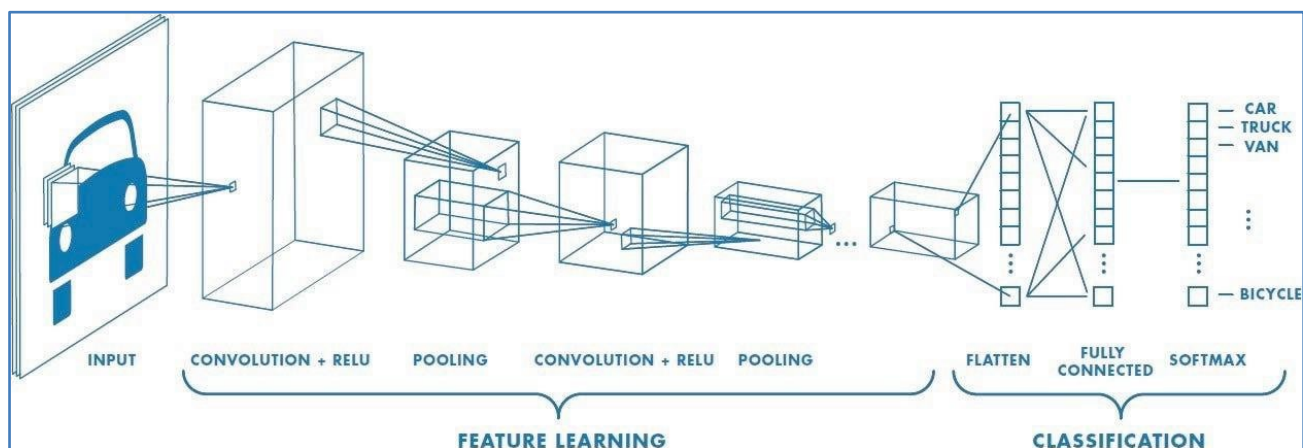


Η δομή ενός Σιαμαίου Νευρωνικού Δικτύου (Spyropoulos, 2021)

3.3. Επίπεδα (layers)

Τα πανομοιότυπα υποδίκτυα αποτελούνται από πολλά επίπεδα, συμπεριλαμβανομένων των συνελικτικών, ομαδοποιημένων και πλήρως συνδεδεμένων επιπέδων. Η αρχιτεκτονική και τα βάρη μοιράζονται μεταξύ των υποδικτύων, γεγονός που βοηθά στη διατήρηση της συνέπειας κατά την εκμάθηση χαρακτηριστικών από τα δεδομένα εισόδου. Τα ακόλουθα είναι τα κύρια στοιχεία των υποδικτύων:

- **Συνελικτικά επίπεδα (Convolutional layers):** Αυτά τα επίπεδα είναι υπεύθυνα για την εξαγωγή τοπικών χαρακτηριστικών από τα δεδομένα εισόδου με την εφαρμογή μιας σειράς φίλτρων ή πυρήνων. Διαδραματίζουν κρίσιμο ρόλο στον εντοπισμό μοτίβων, όπως άκρες, γωνίες και υφές, που συμβάλλουν στη συνολική ομοιότητα ή ανομοιότητα μεταξύ των εισόδων.
- **Επίπεδα συγκέντρωσης (Pooling layers):** Τα επίπεδα συγκέντρωσης, όπως η μέγιστη συγκέντρωση (max-pooling) ή η μέση συγκέντρωση (average-pooling), χρησιμεύουν για τη μείωση των χωρικών διαστάσεων των χαρτών χαρακτηριστικών που λαμβάνονται από τα συνελικτικά επίπεδα. Αυτή η μείωση βοηθά στον έλεγχο του αριθμού των παραμέτρων, αποτρέποντας την υπερπροσαρμογή και μειώνοντας την υπολογιστική πολυπλοκότητα.
- **Πλήρως συνδεδεμένα επίπεδα (Fully connected layers):** Τα πλήρως συνδεδεμένα επίπεδα στα υποδίκτυα λειτουργούν ως γέφυρα μεταξύ των χαρτών χαρακτηριστικών υψηλής διάστασης που λαμβάνονται από τα επίπεδα συνέλιξης και συγκέντρωσης και των τελικών διανυσμάτων χαρακτηριστικών. Αυτά τα επίπεδα μαθαίνουν μια πιο αφηρημένη και σφαιρική αναπαράσταση των δεδομένων εισόδου.



Συνελικτικά επίπεδα (Convolutional layers) (<https://saturncloud.io/blog/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way/>)

3.4. Διανυσματικές έξοδοι χαρακτηριστικών (Feature Vector Outputs)

Μετά την επεξεργασία των δεδομένων εισόδου μέσω των συνελικτικών, ομαδοποιημένων και πλήρως συνδεδεμένων επιπέδων, κάθε υποδίκτυο παράγει ένα διάνυσμα χαρακτηριστικών υψηλών διαστάσεων. Αυτά τα διανύσματα χαρακτηριστικών, που συχνά αναφέρονται ως **ενσωματώσεις** (embeddings), είναι αντιπροσωπευτικά των σημείων δεδομένων εισόδου και περιέχουν τα μαθημένα χαρακτηριστικά που επιτρέπουν στο δίκτυο να συγκρίνει και να ποσοτικοποιήσει την ομοιότητα ή την ανομοιότητα μεταξύ τους.

Οι διανυσματικές έξοδοι χαρακτηριστικών ή ενσωματώσεις αποτελούν τη ραχοκοκαλιά των σιαμαίων νευρωνικών δικτύων (SNN). Αντιπροσωπεύουν μια υψηλών διαστάσεων, αφηρημένη και συνολική άποψη των σημείων δεδομένων εισόδου, που περιλαμβάνει τα χαρακτηριστικά που μαθαίνονται από τα δίδυμα υποδίκτυα. Αυτά τα διανύσματα χαρακτηριστικών παίζουν ζωτικό ρόλο στην ποσοτικοποίηση της ομοιότητας ή της ανομοιότητας μεταξύ των ζευγών εισόδου, καθιστώντας τα ένα βασικό συστατικό των SNN.

Ο σχηματισμός εξόδων διανύσματος χαρακτηριστικών σε SNN είναι μια διαδικασία πολλαπλών σταδίων που περιλαμβάνει μια σειρά διασυνδεδεμένων επιπέδων εντός των δίδυμων υποδικτύων. Τα κύρια στάδια στη δημιουργία διανυσμάτων χαρακτηριστικών είναι τα συνελικτικά επίπεδα, τα επίπεδα συγκέντρωσης, και τα πλήρως συνδεδεμένα επίπεδα. Οι έξοδοι χαρακτηριστικών στα SNN εμφανίζουν πολλά βασικά στοιχεία, όπως:

- **Υψηλή διάσταση:** Οι ενσωματώσεις που δημιουργούνται από το Νευρωνικό Δίκτυο του Σιάμ υπάρχουν συχνά σε χώρους υψηλών διαστάσεων, επιτρέποντας τη διατήρηση και την αναπαράσταση πολύπλοκων σχέσεων και χαρακτηριστικών εντός των δεδομένων εισόδου.
- **Αφαίρεση:** Τα διανύσματα χαρακτηριστικών αντιπροσωπεύουν αφηρημένες, καθολικές προβολές των δεδομένων εισόδου, που περιλαμβάνουν πληροφορίες από ολόκληρη την είσοδο αντί να εστιάζουν μόνο σε τοπικά χαρακτηριστικά.
- **Μοναδικότητα:** Ως αποτέλεσμα της διαδικασίας εκμάθησης, κάθε έξοδος διανυσμάτων χαρακτηριστικών θα πρέπει ιδανικά να είναι μοναδική για το σημείο δεδομένων εισόδου που αντιπροσωπεύει. Αυτή η μοναδικότητα επιτρέπει στο δίκτυο να κάνει πιο αποτελεσματική διαφοροποίηση μεταξύ παρόμοιων και ανόμοιων εισόδων.

3.5. Ανάλυση ομοιότητας

Ο πρωταρχικός σκοπός της δημιουργίας εξόδων διανύσματος χαρακτηριστικών σε SNN είναι να συγκρίνει και να ποσοτικοποιήσει την ομοιότητα ή την ανομοιότητα μεταξύ των ζευγών εισόδου.

Η διαδικασία ανάλυσης της ομοιότητας περιλαμβάνει τα ακόλουθα βήματα:

- **Υπολογισμός συνάρτησης απόστασης:** Μια συνάρτηση απόστασης, όπως η ευκλείδεια απόσταση ή η ομοιότητα συνημιτόνου, μετρά την ομοιότητα μεταξύ των διανυσμάτων χαρακτηριστικών. Οι μικρότερες αποστάσεις υποδηλώνουν μεγαλύτερη ομοιότητα, ενώ οι μεγαλύτερες αποστάσεις υποδηλώνουν ανομοιότητα.
- **Προσδιορισμός κατωφλίου:** Μια προκαθορισμένη τιμή κατωφλίου χρησιμοποιείται για τη λήψη απόφασης με βάση την υπολογισμένη απόσταση μεταξύ των διανυσμάτων χαρακτηριστικών. Εάν η απόσταση είναι κάτω από το όριο, το ζεύγος εισόδου θεωρείται παρόμοιο. Διαφορετικά, θεωρούνται ανόμοια.

Ένα από τα πλεονεκτήματα της χρήσης εξόδων διανύσματος χαρακτηριστικών σε SNN είναι η δυνατότητά τους να βελτιώσουν την ερμηνευσιμότητα του μοντέλου. Δεδομένου ότι οι ενσωματώσεις είναι αναπαραστάσεις υψηλών διαστάσεων των δεδομένων εισόδου, η οπτικοποίηση αυτών των διανυσμάτων χρησιμοποιώντας τεχνικές μείωσης διαστάσεων, όπως η ενσωμάτωση στοχαστικού γείτονα με t -distributed (t -SNE) ή η ανάλυση κύριου στοιχείου (PCA), μπορεί να παρέχει πληροφορίες για τον τρόπο με τον οποίο επεξεργάζεται το δίκτυο και διακρίνει τα ζεύγη εισόδου.

Σύγκριση διανυσμάτων χαρακτηριστικών

Μόλις τα δίδυμα υποδίκτυα παράγουν τα αντίστοιχα διανύσματα χαρακτηριστικών τους, μια συνάρτηση απόστασης υπολογίζει την ομοιότητα μεταξύ αυτών των διανυσμάτων. Οι κοινές **συναρτήσεις απόστασης** που χρησιμοποιούνται για το σκοπό αυτό περιλαμβάνουν:

- **Ευκλείδεια απόσταση:** Αυτή η μέτρηση απόστασης υπολογίζει την ευθεία απόσταση μεταξύ δύο σημείων σε ένα χώρο υψηλών διαστάσεων. Μια χαμηλότερη Ευκλείδεια απόσταση συνεπάγεται υψηλότερο βαθμό ομοιότητας μεταξύ των εισόδων, ενώ μια μεγαλύτερη απόσταση υποδηλώνει ανομοιότητα.
- **Ομοιότητα συνημιτόνου:** Αυτή η μέτρηση μετρά το συνημίτονο της γωνίας μεταξύ δύο διανυσμάτων. Κυμαίνεται από -1 έως 1, όπου τιμές κοντά στο 1 υποδεικνύουν υψηλότερο βαθμό ομοιότητας και τιμές κοντά στο -1 δηλώνουν ανομοιότητα. Η ομοιότητα συνημιτονίου είναι ιδιαίτερα χρήσιμη σε περιπτώσεις όπου το μέγεθος των διανυσμάτων χαρακτηριστικών είναι λιγότερο σημαντικό από τον προσανατολισμό τους.

3.6. Εκπαίδευση Σιαμαίων Νευρωνικών Δικτύων

Η εκπαίδευση είναι μια κρίσιμη πτυχή των σιαμαίων νευρωνικών δικτύων (SNN), καθώς τους δίνει τη δυνατότητα να μάθουν διακριτικά χαρακτηριστικά για τη σύγκριση ζευγών εισόδου. Μέσω της εκπαιδευτικής διαδικασίας, το δίκτυο προσαρμόζει τα βάρη του για να ελαχιστοποιήσει μια συνάρτηση απώλειας, ενισχύοντας την ικανότητά του να διαφοροποιεί αποτελεσματικά παρόμοια και ανόμοια ζεύγη. Τα σιαματικά νευρωνικά δίκτυα εκπαιδεύονται χρησιμοποιώντας μια συνάρτηση απώλειας αντίθεσης (contrastive loss function), η οποία τιμωρεί το δίκτυο εάν δεν διακρίνει μεταξύ παρόμοιων και ανόμοιων ζευγών. Σε αυτή τη διαδικασία, το δίκτυο τροφοδοτείται με θετικά και αρνητικά ζεύγη, όπου τα θετικά ζεύγη αποτελούνται από παρόμοιες εισόδους και τα αρνητικά ζεύγη αποτελούνται από ανόμοιες εισόδους. Ο στόχος της εκπαίδευσης είναι να ελαχιστοποιηθεί η απώλεια αντίθεσης, η οποία αναγκάζει το δίκτυο να μάθει να διαφοροποιεί αποτελεσματικά μεταξύ παρόμοιων και ανόμοιων ζευγών εισόδου.

Τα SNN χρησιμοποιούν εξειδικευμένες συναρτήσεις απώλειας για να βελτιστοποιήσουν τη διαδικασία εκμάθησής τους. Δύο ευρέως χρησιμοποιούμενες συναρτήσεις απώλειας για SNN είναι:

- **Απώλεια αντίθεσης (Contrastive Loss):** Η απώλεια αντίθεσης έχει σχεδιαστεί για να μειώνει την απόσταση μεταξύ παρόμοιων ζευγών εισόδου ενώ αυξάνει την απόσταση μεταξύ ανόμοιων ζευγών. Χρησιμοποιεί μια παράμετρο περιθωρίου που καθορίζει τον διαχωρισμό μεταξύ παρόμοιων και ανόμοιων ζευγών στον χώρο χαρακτηριστικών.
- **Απώλεια τριπλέτας (Triplet Loss):** Η απώλεια τριπλέτας επεκτείνει την ιδέα της απώλειας αντίθεσης λαμβάνοντας υπόψη τριπλές εισόδους: μια άγκυρα, μια θετική (παρόμοια με την άγκυρα) και μια αρνητική (όμοια με την άγκυρα). Ο στόχος είναι να ελαχιστοποιηθεί η απόσταση μεταξύ της άγκυρας και του θετικού, ενώ η μεγιστοποίηση της απόστασης μεταξύ της άγκυρας και του αρνητικού, μέχρι ένα ορισμένο περιθώριο.

Ο αλγόριθμος εκπαίδευσης για τα σιαματικά νευρωνικά δίκτυα βασίζεται στη δημιουργία ζευγών εισόδου. Δύο κύριοι τύποι ζευγών εισόδου είναι:

- **Θετικά ζεύγη:** Αυτά τα ζεύγη αποτελούνται από παρόμοιες εισόδους, όπως εικόνες του ίδιου ατόμου ή δείγματα από την ίδια τάξη. Ο στόχος είναι να ελαχιστοποιηθεί η απόσταση μεταξύ των διανυσμάτων χαρακτηριστικών αυτών των εισόδων.
- **Αρνητικά ζεύγη:** Αυτά τα ζεύγη αποτελούνται από ανόμοιες εισόδους, όπως εικόνες διαφορετικών προσώπων ή δείγματα από διαφορετικές κατηγορίες. Ο στόχος είναι να μεγιστοποιηθεί η απόσταση μεταξύ των διανυσμάτων χαρακτηριστικών αυτών των εισόδων.

Οι στρατηγικές για τη δημιουργία ζευγών εισόδου κατά τη διάρκεια της εκπαιδευτικής διαδικασίας περιλαμβάνουν τυχαία δειγματοληψία, σκληρή αρνητική εξόρυξη (δειγματοληψία αρνητικών ζευγών με τη μικρότερη απόσταση) και σκληρή θετική εξόρυξη (δειγματοληψία θετικών ζευγών με τη μεγαλύτερη απόσταση).

Τα σιαματικά νευρωνικά δίκτυα χρησιμοποιούν επεξεργασία κατά παρτίδες και στοχαστική κλίση κατάβασης (SGD) για να ενημερώνουν τα βάρη του δικτύου επαναληπτικά. Σε κάθε επανάληψη εκπαίδευσης, επιλέγεται μια μίνι παρτίδα ζευγών εισόδου και η συνάρτηση απώλειας υπολογίζεται με βάση τα τρέχοντα βάρη. Στη συνέχεια, τα βάρη ενημερώνονται κάνοντας ένα βήμα προς την κατεύθυνση της αρνητικής κλίσης της συνάρτησης απώλειας σε σχέση με τα βάρη, κλιμακούμενα με ρυθμό εκμάθησης. Αυτή η διαδικασία επαναλαμβάνεται για πολλές εποχές μέχρι να ικανοποιηθεί ένα κριτήριο διακοπής, όπως η σύγκλιση ή ένας μέγιστος αριθμός εποχών.

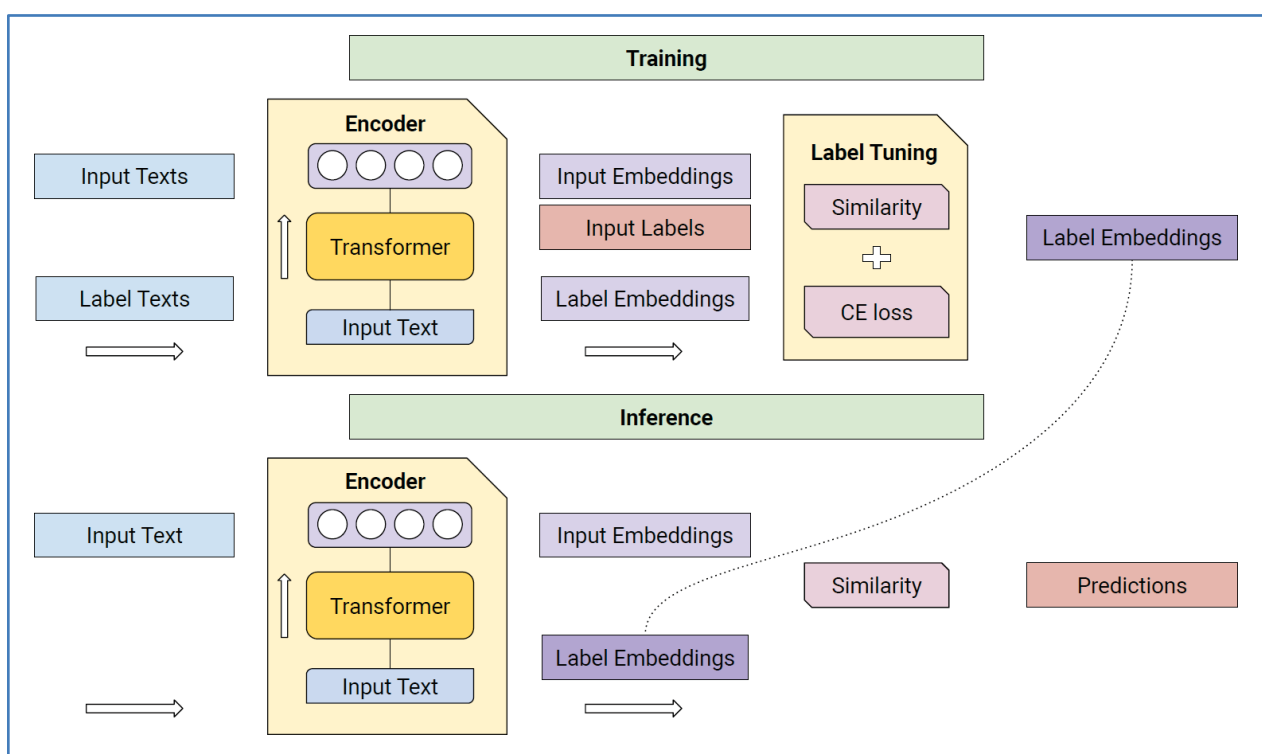
Για να αποφευχθεί η υπερβολική προσαρμογή και να βελτιωθούν οι δυνατότητες γενίκευσης των σιαμαίων νευρωνικών δικτύων, μπορούν να χρησιμοποιηθούν διάφορες τεχνικές τακτοποίησης κατά τη διάρκεια της εκπαιδευτικής διαδικασίας. Αυτές οι τεχνικές περιλαμβάνουν:

- **Αποσύνθεση βάρους:** Η αποσύνθεση βάρους εισάγει έναν πρόσθετο όρο στη συνάρτηση απώλειας που τιμωρεί τα μεγάλα βάρη, ενθαρρύνοντας το δίκτυο να μάθει πιο απλά και πιο στιβαρά χαρακτηριστικά.
- **Dropout:** Η εγκατάλειψη είναι μια τεχνική κατά την οποία οι νευρώνες τυχαία «αποσύρονται» ή απενεργοποιούνται κατά τη διάρκεια της εκπαίδευσης, εκπαιδεύοντας αποτελεσματικά ένα πλήθος αραιωμένων δικτύων. Το σύνολο δικτύων που προκύπτει βοηθά στην αποφυγή της υπερπροσαρμογής και ενισχύει τη γενίκευση.

Η βελτιστοποίηση της απόδοσης των σιαμαίων νευρωνικών δικτύων συχνά περιλαμβάνει συντονισμό διαφόρων υπερπαραμέτρων, όπως ο ρυθμός εκμάθησης, η παράμετρος περιθωρίου για τη συνάρτηση απώλειας, το μέγεθος παρτίδας και η αρχιτεκτονική των υποδικτύων. Τεχνικές όπως η αναζήτηση πλέγματος, η τυχαία αναζήτηση και η Bayesian βελτιστοποίηση μπορούν να χρησιμοποιηθούν για την εύρεση των βέλτιστων ρυθμίσεων υπερπαραμέτρων για τον αλγόριθμο εκπαίδευσης.

3.7. Label Tuning

Τα Σιαμέζικα Δίκτυα, όταν είναι κατάλληλα προεκπαιδευμένα για την ενσωμάτωση τόσο κειμένων όσο και ετικετών, παρουσιάζουν μια βιώσιμη εναλλακτική λύση. Αυτά τα δίκτυα μειώνουν σημαντικά το κόστος εξαγωγής συμπερασμάτων, καθιστώντας το σταθερό σε σχέση με τον αριθμό των ετικετών αντί να αυξάνεται γραμμικά. Η "ρύθμιση ετικετών", μια υπολογιστικά λιτή μέθοδος προσαρμογής μοντέλων σε σενάριο με λίγα δεδομένα, αλλάζει απλώς τις ενσωματώσεις ετικετών. Αν και δεν αποδίδει τόσο αποτελεσματικά όσο η πλήρης μικρορύθμιση του μοντέλου, προσφέρει το σχεδιαστικό πλεονέκτημα της χρήσης ενός μοναδικού κωδικοποιητή σε πολλαπλές εργασίες (Müller, 2022).



Label Tuning. Κατά την εκπαίδευση, εισαγόνται και επισημαίνονται κείμενα (υποθέσεις) που επεξεργάζεται ο κωδικοποιητής. Στη συνέχεια, το Label Tuning συντονίζει τις ετικέτες χρησιμοποιώντας απώλεια διασταυρούμενης εντροπίας. Κατά το χρόνο συμπερασμάτων, το κείμενο εισόδου διέρχεται από τον ίδιο κωδικοποιητή. Οι συντονισμένες ενσωματώσεις ετικετών και μια συνάρτηση ομοιότητας χρησιμοποιούνται στη συνέχεια για τη βαθμολογία κάθε ετικέτας. Ο κωδικοποιητής παραμένει αμετάβλητος και μπορεί να γίνει κοινή χρήση πολλών εργασιών (Müller, 2022).

3.8. Εφαρμογές των σιαμαίων δικτύων

Τα SNN έχουν επιδείξει εξαιρετική απόδοση σε μια ποικιλία εργασιών, μερικές από τις οποίες περιλαμβάνουν:

- **Αναγνώριση εικόνας:** Τα SNN υπερέχουν σε εργασίες όπως η αναγνώριση προσώπου, όπου μπορούν να διακρίνουν μεταξύ εικόνων διαφορετικών ατόμων μαθαίνοντας διακριτικά χαρακτηριστικά. Η στιβαρότητά τους έναντι των παραλλαγών στο φωτισμό, τη στάση και την έκφραση τα καθιστά δημοφιλή επιλογή για αυτήν την εφαρμογή.
- **Επαλήθευση υπογραφής:** Τα σιαματικά νευρωνικά δίκτυα μπορούν επίσης να χρησιμοποιηθούν για την επαλήθευση χειρόγραφων υπογραφών, συγκρίνοντας μια δεδομένη υπογραφή με μια γνωστή βάση δεδομένων αυθεντικών υπογραφών.
- **Αναγνώριση χειρόγραφων χαρακτήρων:** Τα SNN μπορούν να μάθουν να αναγνωρίζουν νέους χαρακτήρες από διάφορα αλφάβητα με λίγα μόνο παραδείγματα, καθιστώντας τα κατάλληλα για εργασίες όπως η οπτική αναγνώριση χαρακτήρων και η ανάλυση χειρόγραφου.
- **Αναγνώριση αντικειμένων:** Τα σιαματικά νευρωνικά δίκτυα μπορούν γρήγορα να μάθουν να αναγνωρίζουν νέα αντικείμενα σε εικόνες με ελάχιστα δεδομένα εκπαίδευσης, μια χρήσιμη δεξιότητα για εργασίες όπως η ρομποτική, η όραση υπολογιστή και τα αυτόνομα οχήματα.
- **Επαλήθευση ομιλητών:** Ο στόχος είναι να επιβεβαιωθεί η ταυτότητα ενός ομιλητή με βάση τη φωνή του. Συγκρίνοντας το δείγμα φωνής ενός ομιλητή με μια βάση δεδομένων γνωστών φωνητικών αποτυπωμάτων, τα SNN μπορούν να προσδιορίσουν αποτελεσματικά εάν η φωνή είναι γνήσια ή απατεώνας. Αυτή η εφαρμογή είναι πολύτιμη σε συστήματα τηλεπικοινωνιών, ασφάλειας και φωνητικών ελεγχόμενων συστημάτων.
- **Ανάλυση Ιατρικής Εικόνας:** Τα SNN έχουν επιδείξει πολλά υποσχόμενα αποτελέσματα σε διάφορες εργασίες ανάλυσης ιατρικών εικόνων, όπως:
 - **Διάγνωση ασθενειών:** Τα σιαματικά νευρωνικά δίκτυα μπορούν να εντοπίσουν ασθένειες ή ανωμαλίες σε ιατρικές εικόνες, όπως ακτινογραφίες ή μαγνητικές τομογραφίες, συγκρίνοντάς τις με γνωστά παραδείγματα υγιών και ασθενών ιστών.
 - **Καταχώριση εικόνας:** Τα SNN μπορούν να ευθυγραμμίσουν ιατρικές εικόνες που λαμβάνονται σε διαφορετικές χρονικές στιγμές, από διαφορετικές οπτικές γωνίες ή χρησιμοποιώντας διαφορετικούς τρόπους, παρέχοντας βελτιωμένη απεικόνιση.
- **Ανίχνευση ανωμαλιών:** Τα SNN μπορούν να εντοπίσουν αποτελεσματικά ανωμαλίες σε διάφορους τύπους δεδομένων, όπως χρονοσειρές ή εικόνες, συγκρίνοντας τα σημεία δεδομένων με ένα σύνολο αναφοράς κανονικών σημείων δεδομένων. Αυτή η εφαρμογή είναι πολύτιμη σε τομείς όπως ο εντοπισμός απάτης, η ασφάλεια δικτύου και ο ποιοτικός έλεγχος.

3.9. Πλεονεκτήματα και μειονεκτήματα των σιαμαίων δικτύων

Τα σιαματικά νευρωνικά δίκτυα (SNN) προσφέρουν πολλά πλεονεκτήματα σε σύγκριση με τα παραδοσιακά νευρωνικά δίκτυα. Μερικά από τα πιο σημαντικά οφέλη περιλαμβάνουν:

- **Αποτελεσματική εκμάθηση με ένα δείγμα:** Τα SNN υπερέρχουν σε εργασίες εκμάθησης ενός δείγματος, όπου μπορούν να μάθουν να αναγνωρίζουν νέα αντικείμενα ή χαρακτήρες με ελάχιστα δεδομένα εκπαίδευσης. Αυτό το πλεονέκτημα καθιστά τα SNN κατάλληλα για προβλήματα με περιορισμένα δεδομένα με ετικέτα ή σενάρια όπου η γρήγορη προσαρμογή είναι απαραίτητη.
- **Αμετάβλητο στους μετασχηματισμούς δεδομένων:** Τα σιαματικά νευρωνικά δίκτυα είναι εγγενώς πιο ανθεκτικά σε διάφορους μετασχηματισμούς δεδομένων, όπως μεταφράσεις, περιστροφές ή αλλαγές κλίμακας. Αυτή η ανθεκτικότητα τα καθιστά κατάλληλα για εργασίες που αφορούν δεδομένα πραγματικού κόσμου, όπως η αναγνώριση εικόνας ή προσώπου, όπου η μεταβλητότητα είναι κοινή.
- **Κοινή χρήση παραμέτρων:** Τα SNN μοιράζονται τις ίδιες παραμέτρους στα δίδυμα υποδίκτυά τους, μειώνοντας ουσιαστικά τον αριθμό των εκπαιδευσιμων παραμέτρων σε σύγκριση με ανεξάρτητα δίκτυα. Αυτή η κοινή χρήση παραμέτρων όχι μόνο βοηθά στη μείωση των απαιτήσεων μνήμης και της υπολογιστικής πολυπλοκότητας, αλλά επίσης βελτιώνει την απόδοση γενίκευσης.
- **Transfer Learning:** Τα SNN μπορούν να αξιοποιήσουν προεκπαιδευμένα μοντέλα, επωφελούμενοι από τη μεταφορά μάθησης. Ρυθμίζοντας ένα προεκπαιδευμένο σιαμαίο νευρωνικό δίκτυο σε μια συγκεκριμένη εργασία ή τομέα, οι επαγγελματίες μπορούν να επιτύχουν υψηλότερη απόδοση με λιγότερα δεδομένα εκπαίδευσης και υπολογισμούς.
- **Βελτιωμένη ερμηνευσιμότητα μοντέλων:** Τα διανύσματα χαρακτηριστικών υψηλών διαστάσεων που δημιουργούνται από SNN μπορούν να οπτικοποιηθούν χρησιμοποιώντας τεχνικές μείωσης διαστάσεων, παρέχοντας πληροφορίες για τον τρόπο με τον οποίο το δίκτυο επεξεργάζεται και διακρίνει μεταξύ των ζευγών εισόδου.

Παρά τα πολυάριθμα πλεονεκτήματά τους, τα σιαματικά νευρωνικά δίκτυα παρουσιάζουν επίσης ορισμένες προκλήσεις και περιορισμούς, όπως:

- **Πιο αργή εκπαίδευση:** Η διαδικασία εκμάθησης διακριτικών χαρακτηριστικών στα SNN μπορεί να είναι υπολογιστικά απαιτητική και πιο αργή από τα παραδοσιακά νευρωνικά δίκτυα. Αυτό οφείλεται στις συγκρίσεις κατά ζεύγη ή τριπλό που εμπλέκονται στη διαδικασία εκπαίδευσης, οι οποίες μπορεί να είναι χρονοβόρες, ειδικά για μεγάλα σύνολα δεδομένων.
- **Στρατηγικές δημιουργίας και δειγματοληψίας ζευγών:** Η δημιουργία ζευγών εισόδου για εκπαίδευση SNN μπορεί να είναι μια προκλητική και υπολογιστικά δαπανηρή εργασία. Επιπλέον, ο καθορισμός μιας κατάλληλης στρατηγικής δειγματοληψίας (π.χ. τυχαία δειγματοληψία, σκληρή αρνητική/θετική εξόρυξη) μπορεί να είναι δύσκολος και μπορεί να επηρεάσει σημαντικά την απόδοση του δικτύου.
- **Ευαισθησία υπερπαραμέτρων:** Τα σιαματικά νευρωνικά δίκτυα μπορεί να είναι ευαίσθητα σε επιλογές υπερπαραμέτρων, όπως ο ρυθμός εκμάθησης, οι παράμετροι περιθωρίου και οι αρχιτεκτονικές αποφάσεις. Ο εντοπισμός των βέλτιστων ρυθμίσεων υπερπαραμέτρων μπορεί να είναι χρονοβόρος και υπολογιστικά δαπανηρός, καθώς συχνά περιλαμβάνει τεχνικές όπως η αναζήτηση πλέγματος, η τυχαία αναζήτηση ή η βελτιστοποίηση Bayes.
- **Επιλογή λειτουργίας απώλειας:** Η επιλογή μιας κατάλληλης συνάρτησης απώλειας για την εκάστοτε εργασία είναι κρίσιμη για την επιτυχία ενός SNN. Ωστόσο, αυτή η διαδικασία επιλογής μπορεί να είναι περίπλοκη και μια μη βέλτιστη επιλογή της συνάρτησης απώλειας μπορεί να οδηγήσει σε κακή απόδοση ή αργή σύγκλιση.
- **Περιορισμένη επεκτασιμότητα:** Τα SNN ενδέχεται να αντιμετωπίσουν προκλήσεις όσον αφορά την επεκτασιμότητα, ιδιαίτερα όταν ασχολούνται με μεγάλες βάσεις δεδομένων ή χώρους χαρακτηριστικών υψηλών διαστάσεων. Ο υπολογισμός των μέτρων ομοιότητας σε χώρους υψηλών διαστάσεων μπορεί να είναι υπολογιστικά εντατικός και μπορεί να απαιτεί εξειδικευμένες τεχνικές ή υλικό για τη βελτίωση της αποτελεσματικότητας.

4. Δίκτυα αντιστοίχισης (Matching Networks)

4.1. Εισαγωγή

Τα **δίκτυα αντιστοίχισης (Matching Networks)**, που εισήχθη από τους Vinyals et al. το 2016, είναι μια κατηγορία νευρωνικών δικτύων που έχουν σχεδιαστεί ειδικά για να αντιμετωπίζουν προκλήσεις μάθησης ενός δείγματος. Η εκμάθηση με ένα δείγμα περιλαμβάνει την εκμάθηση αναγνώρισης νέων αντικειμένων ή χαρακτήρων από έναν ελάχιστο όγκο δεδομένων εκπαίδευσης. Σε αντίθεση με τα παραδοσιακά νευρωνικά δίκτυα, τα οποία απαιτούν εκτεταμένα δεδομένα εκπαίδευσης για καλή γενίκευση, τα Matching Networks μπορούν να προσαρμοστούν γρήγορα σε νέες εργασίες με περιορισμένα δεδομένα, καθιστώντας τα μια δημοφιλή επιλογή για εργασίες με λίγα διαθέσιμα παραδείγματα με ετικέτα. Στο (Vinyals, 2016) οι ερευνητές προσπάθησαν να εκπαιδεύσουν Δίκτυα αντιστοίχισης τα οποία καλούνταν στη συνέχεια να ταξινομήσουν η αντικείμενα από k κλάσεις που δεν προϋπήρχαν στο σύνολο εκπαίδευσης.

Τα δίκτυα αντιστοίχισης λειτουργούν κωδικοποιώντας πρώτα το σύνολο υποστήριξης και το παράδειγμα ερωτήματος σε μια κοινή **αναπαράσταση**. Αυτή η αναπαράσταση χρησιμοποιείται στη συνέχεια για τον υπολογισμό μιας βαθμολογίας ομοιότητας μεταξύ του συνόλου υποστήριξης και του παραδείγματος ερωτήματος. Στη συνέχεια, η ετικέτα του παραδείγματος ερωτήματος προβλέπεται με βάση τη βαθμολογία ομοιότητας.

Τα δίκτυα αντιστοίχισης αποτελούνται από δύο κύρια στοιχεία: έναν κωδικοποιητή και μια συνάρτηση ομοιότητας.

Ο **κωδικοποιητής** είναι υπεύθυνος για την κωδικοποίηση του συνόλου υποστήριξης και του παραδείγματος ερωτήματος σε μια κοινή αναπαράσταση. Ο κωδικοποιητής μπορεί να είναι οποιοσδήποτε τύπος αρχιτεκτονικής νευρωνικών δικτύων, όπως ένα συνελκτικό νευρωνικό δίκτυο ή ένα επαναλαμβανόμενο νευρωνικό δίκτυο.

Η **συνάρτηση ομοιότητας** είναι υπεύθυνη για τον υπολογισμό μιας βαθμολογίας ομοιότητας μεταξύ του συνόλου υποστήριξης και του παραδείγματος ερωτήματος. Η συνάρτηση ομοιότητας μπορεί να είναι οποιοσδήποτε τύπος συνάρτησης που μετρά την ομοιότητα μεταξύ δύο διανυσμάτων, όπως η ομοιότητα συνημιτόνου ή η Ευκλείδεια απόσταση.

4.2. Καινοτομίες

Η Μηχανική Μάθηση, η μελέτη συστημάτων που μπορούν να μάθουν από δεδομένα, ήταν η κινητήρια δύναμη πίσω από πολλές από τις τεχνολογικές μας προόδους. Αυτό το πεδίο έχει δει μια μετατόπιση παραδείγματος από τα παραδοσιακά συστήματα που βασίζονται σε κανόνες σε μοντέλα που βασίζονται σε δεδομένα, ικανά να προβλέψουν, να ταξινομήσουν και ακόμη και να δημιουργήσουν σύνθετα δεδομένα. Μια τέτοια νέα προσέγγιση είναι η χρήση των δικτύων αντιστοίχισης, μια έννοια που έχει φέρει επανάσταση στον τομέα της μάθησης με λίγα δεδομένα.

Τα δίκτυα αντιστοίχισης σχεδιάστηκαν όχι μόνο για να μαθαίνουν από μερικά παραδείγματα αλλά και για να μπορούν να γενικεύουν αυτή τη μάθηση σε νέα σημεία δεδομένων. Η βασική ιδέα πίσω από τα δίκτυα αντιστοίχισης είναι ότι "ταιριάζουν" μια δεδομένη παρουσία δοκιμής με τις σχετικές περιπτώσεις στο σετ εκπαίδευσης και χρησιμοποιούν αυτήν την "αντιστοιχία" για να ταξινομήσουν την περίπτωση δοκιμής.

Τα δίκτυα αντιστοίχισης αντιπροσωπεύουν ένα σημαντικό ορόσημο στον τομέα της μάθησης με λίγα δεδομένα. Ενσωματώνοντας τις αρχές της προσοχής και της μάθησης με βάση το πλαίσιο, παρέχουν μια βιώσιμη λύση για μάθηση από μερικά παραδείγματα. Παρά ορισμένους περιορισμούς, με συνεχή έρευνα και βελτίωση, τα Matching Networks υπόσχονται πολλά για την προώθηση των δυνατοτήτων μας στη μηχανική εκμάθηση, ανοίγοντας πόρτες σε πολυάριθμες εφαρμογές πραγματικού κόσμου που προηγουμένως ήταν προκλητικές λόγω της έλλειψης επαρκών δεδομένων εκπαίδευσης.

Τα δίκτυα αντιστοίχισης αποτελούνται από πολλά βασικά στοιχεία που επιτρέπουν την αποτελεσματική εκμάθηση:

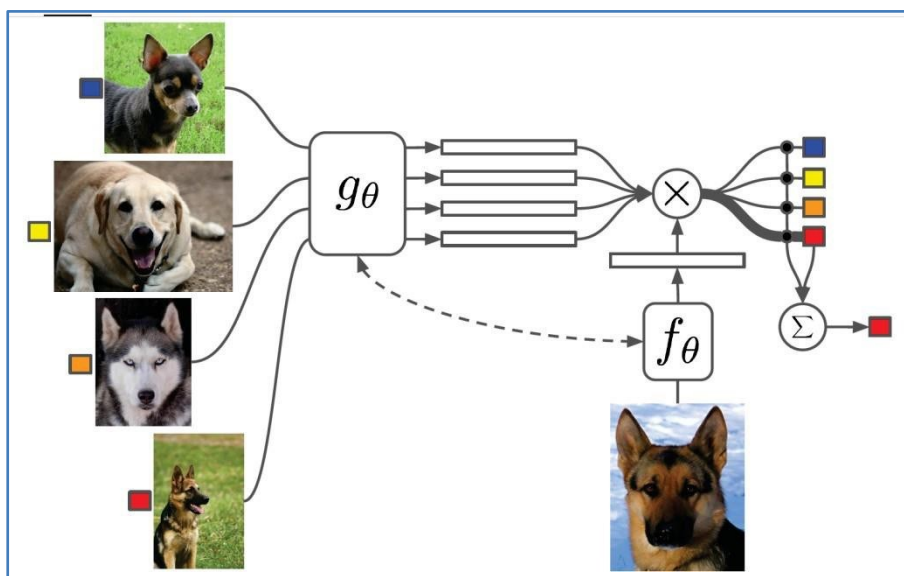
- **Νευρωνικά δίκτυα επαυξημένης μνήμης:** Αυτά τα δίκτυα χρησιμοποιούν εξωτερική μνήμη για την αποθήκευση και τον χειρισμό πληροφοριών, επιτρέποντας στα δίκτυα αντιστοίχισης να μαθαίνουν και να αιτιολογούν νέες εργασίες με βάση την προηγούμενη εμπειρία.
- **Λειτουργίες ενσωμάτωσης:** Οι συναρτήσεις ενσωμάτωσης αντιστοιχίζουν παραδείγματα εισόδου και τις αντίστοιχες ετικέτες τους σε έναν κοινόχρηστο χώρο ενσωμάτωσης. Αυτές οι λειτουργίες συχνά υλοποιούνται χρησιμοποιώντας συνελκτικά νευρωνικά δίκτυα (CNN) ή επαναλαμβανόμενα νευρωνικά δίκτυα (RNNs) για την επεξεργασία εικόνων ή ακολουθιών, αντίστοιχα.
- **Μηχανισμοί προσοχής:** Τα δίκτυα αντιστοίχισης αξιοποιούν μηχανισμούς προσοχής για να σταθμίσουν τη συνεισφορά κάθε παραδείγματος στη μνήμη με βάση την ομοιότητά του με την είσοδο του ερωτήματος. Η χρήση της προσοχής επιτρέπει στο δίκτυο να επικεντρωθεί σε σχετικές πληροφορίες και να βελτιώσει τη γενίκευση σε νέες εργασίες.

Τα δίκτυα αντιστοίχισης εισάγουν την έννοια ενός μηχανισμού προσοχής πάνω από τις μαθημένες ενσωματώσεις, ο οποίος επιτρέπει στο μοντέλο να εστιάζει σε σχετικές περιπτώσεις κατά τη διαδικασία ταξινόμησης. Αυτός ο μηχανισμός προσοχής εμπνέεται από τη γνωστική διαδικασία που χρησιμοποιούν οι άνθρωποι για να αναγνωρίζουν μοτίβα, όπου εστιάζουμε στις πιο σχετικές πληροφορίες για να λάβουμε μια απόφαση.

Επιπλέον, τα δίκτυα αντιστοίχισης χρησιμοποιούν ένα μοναδικό σχήμα εκπαίδευσης γνωστό ως Full Context Embeddings. Σε αντίθεση με τις τυπικές μεθόδους εκπαίδευσης όπου λαμβάνονται υπόψη μόνο οι περιπτώσεις εκπαίδευσης κατά τη διαδικασία εκμάθησης, το Full Context Embeddings λαμβάνει υπόψη τόσο τις περιπτώσεις εκπαίδευσης όσο και τις περιπτώσεις δοκιμής. Αυτό οδηγεί σε ένα πιο ισχυρό και γενικευμένο μοντέλο, καθώς αποτρέπει την υπερβολική προσαρμογή του μοντέλου στα δεδομένα εκπαίδευσης και προωθεί την καλύτερη γενίκευση σε άρατα δεδομένα.

Τα Δίκτυα Ταιριάσματος χρησιμοποιούν διαφορετικό ταξινομητή πλησιέστερου γείτονα τόσο για να δημιουργείται η μετρική της απόστασης αλλά όσο και για να εξετάζεται αν ανήκει μια εικόνα σε μια συγκεκριμένη κλάση. Αυτά γίνονται στο ίδιο βήμα.

Βέβαια η δυνατότητα των Δικτύων Ταιριάσματος να βρίσκουν τις ομοιότητες μεταξύ των παρατηρήσεων δεν καλύπτουν την αδυναμία των δικτύων στην περίπτωση που υπάρχουν μη ισορροπημένα (inbalanced) δεδομένα (Vinyals, 2016).



Αρχιτεκτονική δικτύων αντιστοίχισης (Vinyals, 2016).

4.3. Θεμελιώδεις έννοιες

Η **ενσωμάτωση δεδομένων (embedding of data)** είναι μια θεμελιώδης έννοια στα δίκτυα αντιστοίχισης. Η «ενσωμάτωση» αναφέρεται στη μετατροπή ακατέργαστων δεδομένων υψηλών διαστάσεων σε χώρο χαμηλότερης διάστασης, όπου διατηρούνται τα βασικά χαρακτηριστικά των δεδομένων. Αυτή η αντιστοίχιση σε έναν πυκνό διανυσματικό χώρο απλοποιεί την επακόλουθη επεξεργασία και υπολογισμούς. Οι ενσωματώσεις είναι ένας ισχυρός τρόπος αναπαράστασης αντικειμένων. Μας επιτρέπουν να συλλάβουμε τη σημασιολογική σημασία των αντικειμένων και διευκολύνουν τα νευρωνικά δίκτυα να μάθουν τις σχέσεις μεταξύ των αντικειμένων.

Τυπικά, ένας **κωδικοποιητής ενσωμάτωσης (embedding encoder)**, ο οποίος μπορεί να είναι ένα συνελκτικό νευρωνικό δίκτυο (CNN), ένα επαναλαμβανόμενο νευρωνικό δίκτυο (RNN) ή οποιαδήποτε άλλη κατάλληλη λειτουργία ανάλογα με τον τύπο δεδομένων, εκτελεί αυτήν την εργασία. Η συνάρτηση αντιστοιχίζει τα ακατέργαστα δεδομένα σε ένα χώρο όπου τα μέτρα ομοιότητας μπορούν να υπολογιστούν αποτελεσματικά και με ακρίβεια, παρέχοντας τη βάση για τη διαδικασία αντιστοίχισης.

Ο κωδικοποιητής είναι βασικό συστατικό των δικτύων αντιστοίχισης. Είναι υπεύθυνος για την εκμάθηση μιας κοινής αναπαράστασης του συνόλου υποστήριξης και του παραδείγματος ερωτήματος. Η κοινή αναπαράσταση θα πρέπει να μπορεί να καταγράψει τα σημαντικά χαρακτηριστικά και των δύο αντικειμένων, έτσι ώστε η συνάρτηση ομοιότητας να μπορεί να υπολογίσει με ακρίβεια την ομοιότητα μεταξύ των δύο αντικειμένων.

Η **μέτρηση της ομοιότητας (similarity measure)** μεταξύ των περιπτώσεων είναι ένας άλλος θεωρητικός ακρογωνιαίος λίθος των Δικτύων Αντιστοίχισης. Μόλις τα δεδομένα αντιστοιχιστούν στον χώρο ενσωμάτωσης, χρησιμοποιείται ένα μέτρο ομοιότητας για τον υπολογισμό της εγγύτητας ή της ομοιότητας μεταξύ του στιγμιότυπου δοκιμής και κάθε στιγμιότυπου εκπαίδευσης.

Αυτά τα μέτρα ομοιότητας είναι ζωτικής σημασίας για τον προσδιορισμό των βαρών που χρησιμοποιούνται στον υπολογισμό της ενσωμάτωσης των συμφραζόμενων του στιγμιότυπου δοκιμής. Όσο πιο παρόμοιο είναι ένα παράδειγμα εκπαίδευσης με το παράδειγμα δοκιμής, τόσο μεγαλύτερο είναι το αντίστοιχο βάρος του στο σταθμισμένο άθροισμα που σχηματίζει την ενσωμάτωση με βάση τα συμφραζόμενα.

Τα κοινά μέτρα ομοιότητας που χρησιμοποιούνται στα δίκτυα αντιστοίχισης περιλαμβάνουν την ομοιότητα συνημιτόνου και το γινόμενο κουκκίδων. Ωστόσο, ανάλογα με τη φύση των δεδομένων, θα μπορούσαν να χρησιμοποιηθούν και άλλα μέτρα.

Η **συνάρτηση ομοιότητας** είναι βασικό συστατικό των δικτύων αντιστοίχισης. Είναι υπεύθυνη για τον υπολογισμό της ομοιότητας μεταξύ του συνόλου υποστήριξης και του παραδείγματος ερωτήματος. Η συνάρτηση ομοιότητας θα πρέπει να μπορεί να καταγράφει τα σημαντικά χαρακτηριστικά και των δύο αντικειμένων, έτσι ώστε ο προγνωστικός δείκτης ετικετών να μπορεί να προβλέψει με ακρίβεια την ετικέτα του παραδείγματος ερωτήματος.

Η **πρόβλεψη ετικετών** είναι βασικό συστατικό των δικτύων αντιστοίχισης. Είναι υπεύθυνο για την πρόβλεψη της ετικέτας του παραδείγματος ερωτήματος. Το εργαλείο πρόβλεψης ετικετών θα πρέπει να μπορεί να χρησιμοποιεί τη βαθμολογία ομοιότητας μεταξύ του συνόλου υποστήριξης και του παραδείγματος ερωτήματος για να προβλέψει με ακρίβεια την ετικέτα του παραδείγματος ερωτήματος.

Στο πλαίσιο των Δικτύων Αντιστοίχισης, ο **μηχανισμός προσοχής (attention mechanism)** παίζει κεντρικό ρόλο. Αυτός ο μηχανισμός επιτρέπει στο μοντέλο να εστιάζει στις πιο σχετικές περιπτώσεις στη διαδικασία ταξινόμησης.

Οι βαθμολογίες ομοιότητας μεταξύ της περίπτωσης δοκιμής και των περιπτώσεων εκπαίδευσης λειτουργούν αποτελεσματικά ως μηχανισμός προσοχής. Αυτές οι βαθμολογίες χρησιμοποιούνται ως σταθμίσεις κατά τον υπολογισμό της ενσωμάτωσης με βάση τα συμφραζόμενα για το παράδειγμα δοκιμής, με αποτέλεσμα υψηλότερα βάρη για πιο σχετικές περιπτώσεις. Αυτή η προσέγγιση διασφαλίζει ότι οι περιπτώσεις που είναι πιο παρόμοιες με το παράδειγμα δοκιμής συμβάλλουν περισσότερο στην τελική απόφαση ταξινόμησης.

Αυτός ο μηχανισμός εστίασης σε σχετικές περιπτώσεις είναι εμπνευσμένος από τις ανθρώπινες γνωστικές διαδικασίες. Ακριβώς όπως οι άνθρωποι εστιάζουν στις πιο σχετικές πληροφορίες για τη λήψη αποφάσεων, ο μηχανισμός προσοχής επιτρέπει στα Matching Networks να εστιάζουν στις πιο σχετικές περιπτώσεις.

Μια μοναδική θεωρητική έννοια που εφαρμόζεται στα δίκτυα αντιστοίχισης είναι η ιδέα των **Ενσωματώσεων Πλήρους Περιεχομένου (full context embeddings)**. Σε αντίθεση με τις παραδοσιακές μεθόδους εκπαίδευσης που λαμβάνουν υπόψη μόνο τις περιπτώσεις εκπαίδευσης κατά τη διάρκεια της μαθησιακής διαδικασίας, οι ενσωματώσεις πλήρους πλαισίου ενσωματώνουν τόσο την εκπαίδευση όσο και τις περιπτώσεις δοκιμής.

4.4. Δομή

Το δίκτυο αντιστοίχισης λειτουργεί κωδικοποιώντας πρώτα το σύνολο υποστήριξης και το παράδειγμα ερωτήματος σε μια κοινή αναπαράσταση. Αυτή η αναπαράσταση χρησιμοποιείται στη συνέχεια για τον υπολογισμό μιας βαθμολογίας ομοιότητας μεταξύ του συνόλου υποστήριξης και του παραδείγματος ερωτήματος. Στη συνέχεια, η ετικέτα του παραδείγματος ερωτήματος προβλέπεται με βάση τη βαθμολογία ομοιότητας.

Η αρχιτεκτονική των δικτύων αντιστοίχισης είναι ευέλικτη και μπορεί να προσαρμοστεί ώστε να ταιριάζει στη συγκεκριμένη εργασία. Ωστόσο, υπάρχουν ορισμένα κοινά χαρακτηριστικά που είναι κοινά σε όλα τα δίκτυα που ταιριάζουν.

Τα Matching Networks, μια κατηγορία νευρωνικών δικτύων που αναπτύχθηκαν ειδικά για την αντιμετώπιση εργασιών μάθησης λίγων βολών, διαθέτουν μοναδική δομή και αρχιτεκτονική που τα ξεχωρίζει από τα συμβατικά μοντέλα νευρωνικών δικτύων. Η αρχιτεκτονική των δικτύων αντιστοίχισης είναι χτισμένη γύρω από τα δύο κεντρικά στοιχεία του κωδικοποιητή ενσωμάτωσης και της μονάδας αντιστοίχισης. Μετατρέποντας αποτελεσματικά τα ακατέργαστα δεδομένα σε έναν κατάλληλο χώρο ενσωμάτωσης και αξιοποιώντας τη δύναμη της αντιστοίχισης βάσει ομοιοτήτων, τα δίκτυα αντιστοίχισης προσφέρουν μια ισχυρή λύση στις προκλήσεις που τίθενται από τις εργασίες μάθησης με λίγα δεδομένα. Η μοναδική δομή και ο σχεδιασμός των Matching Networks τα καθιστούν ένα πολύτιμο εργαλείο στην εργαλειοθήκη μηχανικής εκμάθησης, ικανό να μαθαίνει και να γενικεύει αποτελεσματικά από έναν περιορισμένο αριθμό περιπτώσεων εκπαίδευσης.

Πριν εμβαθύνουμε στη δομή, είναι σημαντικό να κατανοήσουμε το πρόβλημα που στοχεύουν να λύσουν τα Matching Networks. Στην μάθηση με λίγα δεδομένα, ο στόχος είναι να σχεδιαστεί ένα μοντέλο μηχανικής μάθησης που μπορεί να μάθει χρήσιμες πληροφορίες από έναν μικρό αριθμό παραδειγμάτων — συνήθως της τάξης του 1-10 εκπαιδευτικών παραδειγμάτων. Αυτό έρχεται σε πλήρη αντίθεση με τα παραδοσιακά μοντέλα μηχανικής εκμάθησης που συνήθως απαιτούν μεγάλες ποσότητες δεδομένων για να γενικευθούν αποτελεσματικά. Τα δίκτυα αντιστοίχισης έχουν σχεδιαστεί για να χειρίζονται αυτό το σενάριο «ταιριάζοντας» μια δεδομένη παρουσία δοκιμής με τις σχετικές περιπτώσεις στο σετ εκπαίδευσης για την ταξινόμηση της παρουσίας δοκιμής.

Κωδικοποιητής ενσωμάτωσης (Embedding Encoder)

Το πρώτο μέρος της αρχιτεκτονικής του Matching Network είναι ο κωδικοποιητής ενσωμάτωσης. Ο ρόλος αυτού του στοιχείου είναι να μετατρέπει τα ακατέργαστα δεδομένα εισόδου σε μια μορφή που μπορεί να χρησιμοποιηθεί αποτελεσματικά από την αντίστοιχη ενότητα. Αυτή η μορφή είναι γνωστή ως «ενσωμάτωση», μια διανυσματική αναπαράσταση των δεδομένων που αποτυπώνει τα βασικά χαρακτηριστικά τους.

Το επίπεδο ενσωμάτωσης είναι συνήθως ένα συνελκτικό νευρωνικό δίκτυο (CNN) ή ένα επαναλαμβανόμενο νευρωνικό δίκτυο (RNN). Το CNN χρησιμοποιείται για την εκμάθηση χωρικών σχέσεων μεταξύ των pixel σε μια εικόνα, ενώ το RNN χρησιμοποιείται για την εκμάθηση χρονικών σχέσεων μεταξύ των λέξεων σε μια πρόταση.

Ανάλογα με τη φύση των δεδομένων, μπορούν να χρησιμοποιηθούν διαφορετικοί τύποι κωδικοποιητών ενσωμάτωσης. Για παράδειγμα, για δεδομένα εικόνας, ένα συνελκτικό νευρωνικό δίκτυο (CNN) μπορεί να χρησιμοποιηθεί ως κωδικοποιητής ενσωμάτωσης. Για διαδοχικά δεδομένα, όπως κείμενο, μπορεί να χρησιμοποιηθεί ένα επαναλαμβανόμενο νευρωνικό δίκτυο (RNN) ή ένας μετασχηματιστής. Η επιλογή του κωδικοποιητή ενσωμάτωσης εξαρτάται από τα δεδομένα και τα συγκεκριμένα χαρακτηριστικά που πρέπει να αποτυπωθούν.

Μια κρίσιμη πτυχή της αρχιτεκτονικής του Matching Network είναι ο χώρος ενσωμάτωσης, όπου τα ακατέργαστα δεδομένα μετατρέπονται σε ενσωματώσεις. Ο χώρος ενσωμάτωσης έχει σχεδιαστεί έτσι ώστε παρόμοια στιγμιότυπα να είναι κοντά το ένα στο άλλο και ανόμοιες περιπτώσεις να είναι μακριά το ένα από το άλλο. Αυτό επιτυγχάνεται χρησιμοποιώντας ένα κατάλληλο μέτρο ομοιότητας, όπως ομοιότητα συνημιτόνου ή κουκκίδα.

Ο υπολογισμός της ενσωμάτωσης με βάση τα συμφραζόμενα στην αντίστοιχη ενότητα γίνεται σε αυτόν τον χώρο ενσωμάτωσης. Οι ομοιότητες υπολογίζονται μεταξύ του στιγμιότυπου δοκιμής και των περιπτώσεων εκπαίδευσης και αυτές οι ομοιότητες χρησιμοποιούνται ως βάρη για τον υπολογισμό ενός σταθμισμένου αθροίσματος των περιπτώσεων εκπαίδευσης. Αυτό το σταθμισμένο άθροισμα αποτελεί τη συμφραζόμενη ενσωμάτωση του στιγμιότυπου δοκιμής, το οποίο χρησιμοποιείται για την ταξινόμηση.

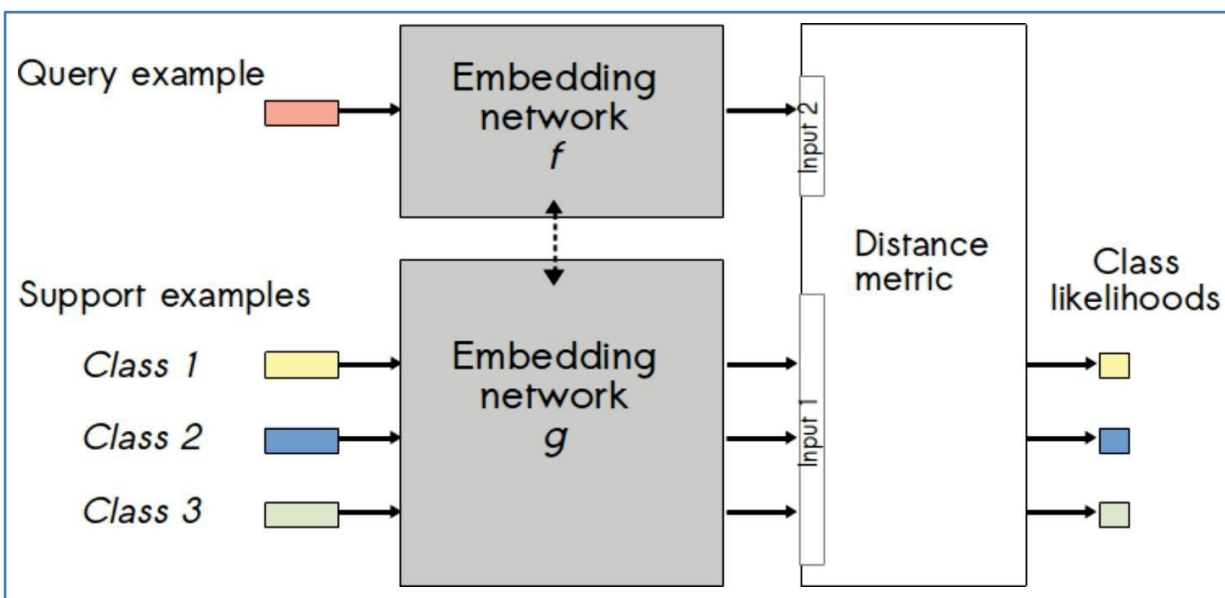
Ενότητα αντιστοίχισης (Matching Module)

Το δεύτερο μέρος της αρχιτεκτονικής του δικτύου αντιστοίχισης είναι η ενότητα αντιστοίχισης. Εδώ γίνεται η «ταίριασμα» του δοκιμαστικού στιγμιότυπου με τα στιγμιότυπα εκπαίδευσης. Με δεδομένο ένα παράδειγμα δοκιμής, η ενότητα αντιστοίχισης υπολογίζει μια ενσωμάτωση με βάση τα συμφραζόμενα για την περίπτωση δοκιμής, η οποία είναι ένα σταθμισμένο άθροισμα των ενσωματώσεων των παρουσιών εκπαίδευσης. Τα βάρη καθορίζονται από τις ομοιότητες μεταξύ της δοκιμασίας και των περιπτώσεων εκπαίδευσης.

Αυτή η ενσωμάτωση με βάση τα συμφραζόμενα χρησιμοποιείται στη συνέχεια για την ταξινόμηση της παρουσίας δοκιμής. Η ενότητα αντιστοίχισης χρησιμοποιεί ουσιαστικά τις πληροφορίες που περιέχονται στις περιπτώσεις εκπαίδευσης για να λάβει μια απόφαση σχετικά με την περίπτωση δοκιμής.

Η **συνάρτηση ομοιότητας** είναι τυπικά μια ομοιότητα συνημιτόνου ή μια Ευκλείδεια απόσταση. Η ομοιότητα συνημιτόνου μετρά τη γωνία μεταξύ δύο διανυσμάτων, ενώ η Ευκλείδεια απόσταση μετρά την απόσταση μεταξύ δύο σημείων σε έναν Ευκλείδειο χώρο.

Η **πρόβλεψη ετικετών** είναι συνήθως ένας ταξινομητής softmax. Ο ταξινομητής softmax εξάγει μια κατανομή πιθανότητας στις πιθανές ετικέτες.



Δομή Δικτύου Ταίριασματος. (Vinyals, 2016).

4.5. Ο αλγόριθμος εκπαίδευσης

Ο αλγόριθμος εκπαίδευσης του Matching Networks είναι μοναδικός και ισχυρός, αξιοποιώντας τα δυνατά σημεία τόσο των μηχανισμών προσοχής όσο και των νευρωνικών δικτύων επαυξημένης μνήμης. Στοχεύει στην επίτευξη ενός μοντέλου που μπορεί να μάθει με ακρίβεια και αποτελεσματικότητα από μερικές περιπτώσεις, ανοίγοντας το δρόμο για πρακτικές εφαρμογές σε σενάρια όπου τα δεδομένα είναι σπάνια ή αλλάζουν γρήγορα.

Ωστόσο, αξίζει να σημειωθεί ότι, όπως κάθε αλγόριθμος μηχανικής εκμάθησης, ο αλγόριθμος εκπαίδευσης του Matching Networks έχει τους περιορισμούς και τις υποθέσεις του. Για παράδειγμα, υποθέτει ότι το σύνολο υποστήριξης περιέχει παραδείγματα από όλες τις κλάσεις που μπορεί να συναντήσει το μοντέλο, κάτι που μπορεί να μην συμβαίνει πάντα σε εφαρμογές πραγματικού κόσμου.

Ο αλγόριθμος εκπαίδευσης του Matching Networks περιστρέφεται γύρω από δύο βασικές έννοιες: έναν μηχανισμό προσοχής και ένα νευρωνικό δίκτυο επαυξημένης μνήμης. Στην ουσία, είναι ένας διαφοροποιήσιμος ταξινομητής πλησιέστερου γείτονα από άκρο σε άκρο, που σημαίνει ότι ολόκληρο το δίκτυο μπορεί να εκπαιδευτεί με backpropagation.

Ο **μηχανισμός προσοχής** στα δίκτυα αντιστοίχισης εφαρμόζεται δύο φορές: πρώτον, για τον υπολογισμό του σταθμισμένου αθροίσματος των ετικετών στο σύνολο υποστήριξης και, δεύτερον, για τον υπολογισμό του περιβάλλοντος στο οποίο είναι ενσωματωμένο το δείγμα δοκιμής. Το τελευταίο ονομάζεται "Ενσωματώσεις πλήρους περιβάλλοντος", το οποίο ουσιαστικά περιλαμβάνει τη λήψη ενός στιγμιότυπου από το σύνολο υποστήριξης και τη σχετική ετικέτα του και τη χρήση τους για τον υπολογισμό ενός διανύσματος περιβάλλοντος για τη δοκιμαστική παρουσία. Αυτό το διάνυσμα περιβάλλοντος χρησιμοποιείται στη συνέχεια για την πρόβλεψη της ετικέτας της παρουσίας δοκιμής.

Η πτυχή του νευρωνικού δικτύου επαυξημένης μνήμης του αλγόριθμου εκπαίδευσης χρησιμοποιείται για τον υπολογισμό μιας μετρικής απόστασης συνημιτόνου μεταξύ του ενσωματωμένου δείγματος δοκιμής και του ενσωματωμένου συνόλου υποστήριξης. Η **απόσταση συνημιτόνου** χρησιμοποιείται επειδή κανονικοποιεί τα μήκη των διανυσμάτων, καθιστώντας την αμετάβλητη ως προς την κλίμακα και ιδανική για διανύσματα υψηλών διαστάσεων. Στη συνέχεια, η έξοδος διέρχεται μέσω μιας συνάρτησης softmax, με αποτέλεσμα μια κατανομή πιθανότητας στις ετικέτες του συνόλου υποστήριξης.

Ο αλγόριθμος εκπαίδευσης για τα δίκτυα αντιστοίχισης βασίζεται στα ακόλουθα βήματα:

- 1. Σύνολο υποστήριξης και κατασκευή παρτίδων (Support Set and Batch Construction):** Για κάθε επανάληψη της εκπαίδευσης, δημιουργείται μια παρτίδα επεισοδίων. Κάθε επεισόδιο περιέχει ένα σύνολο υποστήριξης και μια αντίστοιχη παρτίδα ερωτημάτων. Το σύνολο υποστήριξης περιέχει μερικά παραδείγματα από κάθε κλάση, ενώ η παρτίδα των ερωτημάτων περιέχει παραδείγματα που το μοντέλο πρέπει να ταξινομήσει.
- 2. Αρχικοποίηση στις παραμέτρους του δικτύου αντιστοίχισης.** Μπορούν να αρχικοποιηθούν τυχαία ή χρησιμοποιώντας ένα προεκπαιδευμένο μοντέλο. Τυχαία προετοιμασία: Οι παράμετροι του αντίστοιχου δικτύου αρχικοποιούνται τυχαία. Αυτή είναι η πιο κοινή προσέγγιση για την προετοιμασία των παραμέτρων του δικτύου αντιστοίχισης. Προεκπαιδευμένο μοντέλο: Οι παράμετροι του δικτύου αντιστοίχισης αρχικοποιούνται χρησιμοποιώντας ένα προεκπαιδευμένο μοντέλο. Αυτή η προσέγγιση μπορεί να χρησιμοποιηθεί για την επιτάχυνση της εκπαιδευτικής διαδικασίας.
- 3. Ενσωμάτωση του συνόλου υποστήριξης και της αντίστοιχης παρτίδας των ερωτημάτων.** Κάθε στιγμιότυπο στο σύνολο υποστήριξης διέρχεται μέσω μιας συνάρτησης ενσωμάτωσης, f , η οποία είναι μια μορφή βαθιού νευρωνικού δικτύου και παίζει τον ρόλο του κωδικοποιητή. Το αποτέλεσμα είναι ένα σύνολο ενσωματωμένων διανυσμάτων, ένα για κάθε περίπτωση στο σύνολο υποστήριξης. Κάθε σημείο ερωτήματος διέρχεται επίσης από την ίδια συνάρτηση ενσωμάτωσης, f , με αποτέλεσμα ένα άλλο σύνολο ενσωματωμένων διανυσμάτων. Ο κωδικοποιητής είναι ένα νευρωνικό δίκτυο που λαμβάνει ως είσοδο το σύνολο υποστήριξης και το παράδειγμα ερωτήματος και εξάγει μια κοινή αναπαράσταση των δύο αντικειμένων.
- 4. Υπολογισμός ενσωματώσεων πλήρους περιβάλλοντος:** Κάθε ενσωματωμένη παρουσία από το σύνολο υποστήριξης και οι συσχετισμένες ετικέτες χρησιμοποιούνται για τον υπολογισμό ενός διανύσματος περιβάλλοντος για κάθε ενσωματωμένο σημείο ερωτήματος. Αυτό γίνεται χρησιμοποιώντας έναν μηχανισμό προσοχής, g , ο οποίος χρησιμοποιεί επίσης ένα βαθύ νευρωνικό δίκτυο. Η έξοδος είναι ένα σύνολο από ενσωματώσεις πλήρους περιβάλλοντος.

5. **Υπολογισμός της βαθμολογίας ομοιότητας μεταξύ του συνόλου υποστήριξης και της αντίστοιχης παρτίδας των ερωτημάτων.** Η βαθμολογία ομοιότητας υπολογίζεται χρησιμοποιώντας τη συνάρτηση ομοιότητας. Η συνάρτηση ομοιότητας είναι μια συνάρτηση που λαμβάνει ως είσοδο την κοινή αναπαράσταση του συνόλου υποστήριξης και των ερωτημάτων και εξάγει μια βαθμολογία ομοιότητας. Υπολογίζεται η απόσταση συνημιτόνου μεταξύ κάθε ενσωματωμένου σημείου ερωτήματος και κάθε πλήρους ενσωμάτωσης περιβάλλοντος από το σύνολο υποστήριξης. Η έξοδος διέρχεται μέσω μιας συνάρτησης softmax, με αποτέλεσμα μια κατανομή πιθανότητας στις ετικέτες του συνόλου υποστήριξης.

6. **Ενημέρωση στις παραμέτρους του αντίστοιχου δικτύου.** Οι παράμετροι του δικτύου αντιστοίχισης ενημερώνονται χρησιμοποιώντας τον αλγόριθμο backpropagation. **Ο αλγόριθμος backpropagation** είναι ένας αλγόριθμος που χρησιμοποιείται για την ενημέρωση των παραμέτρων ενός νευρωνικού δικτύου.

7. **Επαναλαμβάνονται τα βήματα 3-6 μέχρι να συγκλίνει το δίκτυο αντιστοίχισης.** Το δίκτυο αντιστοίχισης λέγεται ότι συγκλίνει όταν ελαχιστοποιείται η συνάρτηση απώλειας. Η συνάρτηση απώλειας είναι μια συνάρτηση που μετρά το σφάλμα μεταξύ της προβλεπόμενης ετικέτας και της ετικέτας αλήθειας γείωσης. Ο αλγόριθμος εκπαίδευσης για αντιστοίχιση δικτύων είναι ένα ισχυρό εργαλείο για την εκμάθηση νέων εννοιών από μικρές ποσότητες δεδομένων. Ωστόσο, η εκπαίδευση μπορεί να είναι υπολογιστικά ακριβή, ειδικά για μεγάλα σύνολα δεδομένων.

8. **Βελτιστοποίηση του μοντέλου.** Μόλις το μοντέλο έχει εκπαιδευτεί, μπορεί να βελτιωθεί για να βελτιώσει την απόδοσή του. Ορισμένες κοινές τεχνικές περιλαμβάνουν την προσαρμογή του ρυθμού μάθησης ή τη χρήση της μείωσης του ρυθμού μάθησης, την εφαρμογή τεχνικών τακτοποίησης όπως η διαρροή ή η μείωση του βάρους και η αύξηση των δεδομένων εκπαίδευσης για να παρέχει στο μοντέλο ένα ευρύτερο φάσμα παραδειγμάτων για να μάθει.

4.6. Εφαρμογές

Στον τομέα της μηχανικής μάθησης, τα Matching Networks έχουν δημιουργήσει μια μοναδική θέση για τον εαυτό τους με την καινοτόμο προσέγγισή τους μάθηση με λίγα δεδομένα, μια ιδέα που εστιάζει στον εξοπλισμό μοντέλων ώστε να μαθαίνουν αποτελεσματικά από έναν μικρό αριθμό παραδειγμάτων.

Ιατρική Διαγνωστική. Συχνά, οι γιατροί πρέπει να λάβουν αποφάσεις με βάση μια χούφτα συμπτωμάτων ή εξετάσεων, ένα σενάριο που είναι ανάλογο με τη μάθηση με λίγα δεδομένα. Τα δίκτυα αντιστοίχισης μπορούν να χρησιμοποιηθούν για τη δημιουργία διαγνωστικών μοντέλων που μαθαίνουν από έναν μικρό αριθμό περιπτώσεων. Για παράδειγμα, στο πλαίσιο των σπάνιων ασθενειών, όπου είναι δύσκολο να βρεθούν μεγάλα σύνολα δεδομένων, αυτά τα δίκτυα θα μπορούσαν να χρησιμοποιηθούν για να γίνουν ακριβείς προβλέψεις.

Αναγνώριση εικόνας. Η αναγνώριση εικόνας είναι ένας άλλος τομέας όπου τα δίκτυα αντιστοίχισης έχουν υποσχεθεί πολλά. Τα δίκτυα αντιστοίχισης, μπορούν να μάθουν να αναγνωρίζουν νέα αντικείμενα με βάση λίγες μόνο περιπτώσεις. Αυτή η ικανότητα μπορεί να είναι ζωτικής σημασίας σε σενάρια όπως η παρακολούθηση άγριας ζωής, όπου νέα είδη μπορεί να συναντώνται τακτικά ή σε εφαρμογές ασφαλείας, όπου το σύστημα πρέπει να προσαρμοστεί γρήγορα σε νέες απειλές.

Αναγνώριση ομιλίας. Τα δίκτυα αντιστοίχισης έχουν χρησιμοποιηθεί για την αναγνώριση ομιλίας. Για παράδειγμα, τα δίκτυα αντιστοίχισης έχουν χρησιμοποιηθεί για την αναγνώριση των λέξεων σε μια πρόταση.

Επεξεργασία Φυσικής Γλώσσας (NLP). Τα δίκτυα αντιστοίχισης έχουν βρει τη χρήση τους και στον τομέα του NLP. Για παράδειγμα, μπορούν να χρησιμοποιηθούν σε συστήματα απάντησης ερωτήσεων, όπου το μοντέλο πρέπει να γενικεύσει από μερικά παραδείγματα για να απαντήσει σωστά σε νέες ερωτήσεις. Στην αυτόματη μετάφραση, τα δίκτυα αντιστοίχισης μπορούν να χρησιμοποιηθούν για προσαρμογή σε νέες γλώσσες ή διαλέκτους με βάση έναν μικρό αριθμό παραδειγμάτων.

Αυτόνομα Οχήματα. Στον τομέα των αυτόνομων οχημάτων, η ασφάλεια είναι πρωταρχικής σημασίας και η γρήγορη προσαρμογή σε νέα σενάρια είναι απαραίτητη. Τα δίκτυα αντιστοίχισης μπορούν να χρησιμοποιηθούν στα συστήματα αντίληψης αυτόνομων οχημάτων, επιτρέποντάς τους να αναγνωρίζουν νέα αντικείμενα ή καταστάσεις με βάση μερικά παραδείγματα, ενισχύοντας έτσι την ασφάλεια και την αξιοπιστία τους.

Ρομποτική. Τα δίκτυα αντιστοίχισης μπορούν να χρησιμοποιηθούν για τον έλεγχο ρομπότ από ένα μόνο παράδειγμα. Για παράδειγμα, τα δίκτυα αντιστοίχισης έχουν χρησιμοποιηθεί για τον έλεγχο ενός βραχίονα ρομπότ για τη λήψη ενός αντικειμένου από έναν πίνακα.

Ηλεκτρονικά Συστήματα Συστάσεων. Τα διαδικτυακά συστήματα συστάσεων μπορούν να αξιοποιήσουν τα δίκτυα αντιστοίχισης για να βελτιώσουν την απόδοσή τους. Τα δίκτυα αντιστοίχισης έχουν χρησιμοποιηθεί για να προτείνουν στοιχεία στους χρήστες με βάση την προηγούμενη συμπεριφορά τους. Για παράδειγμα, τα δίκτυα αντιστοίχισης έχουν χρησιμοποιηθεί για να προτείνουν ταινίες σε χρήστες με βάση τις ταινίες που έχουν παρακολουθήσει στο παρελθόν. Τα παραδοσιακά συστήματα συστάσεων συχνά δυσκολεύονται με νέους χρήστες ή στοιχεία λόγω της έλλειψης επαρκών δεδομένων αλληλεπίδρασης. Αυτό το πρόβλημα, γνωστό ως πρόβλημα ψυχρής εκκίνησης, μπορεί να αντιμετωπιστεί χρησιμοποιώντας τα δίκτυα αντιστοίχισης, καθώς μπορούν να κάνουν ακριβείς προβλέψεις με βάση μερικές αλληλεπιδράσεις.

Ανίχνευση ανωμαλιών. Η ανίχνευση ανωμαλιών περιλαμβάνει τον εντοπισμό ασυνήθιστων προτύπων ή ακραίων στοιχείων στα δεδομένα, τα οποία μπορεί να είναι κρίσιμα σε διάφορους τομείς, συμπεριλαμβανομένου του εντοπισμού απάτης, της ασφάλειας δικτύου και του ποιοτικού ελέγχου. Τα δίκτυα αντιστοίχισης μπορούν να εκπαιδευτούν στον εντοπισμό ανωμαλιών με βάση έναν μικρό αριθμό παραδειγμάτων, καθιστώντας τα αποτελεσματικά εργαλεία για το σκοπό αυτό.

Σύσταση προϊόντος. Τα δίκτυα αντιστοίχισης μπορούν να χρησιμοποιηθούν για να προτείνουν προϊόντα σε χρήστες με βάση την προηγούμενη συμπεριφορά τους. Για παράδειγμα, τα δίκτυα αντιστοίχισης μπορούν να χρησιμοποιηθούν για να προτείνουν βιβλία στους χρήστες με βάση τα βιβλία που έχουν διαβάσει στο παρελθόν.

Εποπτεία περιεχομένου. Τα δίκτυα αντιστοίχισης μπορούν να χρησιμοποιηθούν για τον έλεγχο περιεχομένου, όπως κείμενο και εικόνες, για τον εντοπισμό επιβλαβούς ή ακατάλληλου περιεχομένου. Για παράδειγμα, τα δίκτυα αντιστοίχισης μπορούν να χρησιμοποιηθούν για τον εντοπισμό της ρητορικής μίσους σε αναρτήσεις στα μέσα κοινωνικής δικτύωσης.

Ανίχνευση απάτης. Τα δίκτυα αντιστοίχισης μπορούν να χρησιμοποιηθούν για τον εντοπισμό απάτης, όπως απάτη με πιστωτικές κάρτες και ασφαλιστική απάτη. Για παράδειγμα, τα δίκτυα αντιστοίχισης μπορούν να χρησιμοποιηθούν για τον εντοπισμό ύποπτων συναλλαγών σε δεδομένα πιστωτικών καρτών.

4.7. Πλεονεκτήματα

Μπορεί να μάθει από μικρές ποσότητες δεδομένων. Τα δίκτυα αντιστοίχισης μπορούν να μάθουν νέες έννοιες από λίγα μόνο παραδείγματα. Αυτό έρχεται σε αντίθεση με τους παραδοσιακούς εποπτευόμενους αλγόριθμους μάθησης, οι οποίοι απαιτούν μεγάλο αριθμό παραδειγμάτων με ετικέτα για την εκμάθηση μιας νέας έννοιας.

Μπορεί να γενικευτεί σε νέα παραδείγματα. Τα δίκτυα αντιστοίχισης μπορούν να γενικεύσουν σε νέα παραδείγματα που δεν εμφανίζονται κατά τη διάρκεια της εκπαίδευσης. Αυτό συμβαίνει επειδή μαθαίνουν την υποκείμενη δομή των δεδομένων, αντί να απομνημονεύουν απλώς τα παραδείγματα εκπαίδευσης.

Μπορεί να μάθει πολλές έννοιες ταυτόχρονα. Τα δίκτυα αντιστοίχισης μπορούν να μάθουν πολλές έννοιες ταυτόχρονα. Αυτό συμβαίνει επειδή μαθαίνουν τις σχέσεις μεταξύ διαφορετικών συνόλων χαρακτηριστικών εισόδου.

Τα δίκτυα αντιστοίχισης είναι **πλήρως διαφοροποιήσιμα**, πράγμα που σημαίνει ότι μπορούν να εκπαιδεύονται από άκρο σε άκρο με τυπικές τεχνικές backpropagation. Αυτό είναι ένα σημαντικό πλεονέκτημα έναντι ορισμένων άλλων μεθόδων εκμάθησης λίγων βολών, οι οποίες ενδέχεται να απαιτούν πολύπλοκες διαδικασίες εκπαίδευσης ή πρόσθετα βήματα βελτιστοποίησης.

Ο **μηχανισμός προσοχής** που χρησιμοποιείται από τα Matching Networks τους επιτρέπει να εστιάζουν σε σχετικά μέρη των δεδομένων εισόδου ενώ κάνουν προβλέψεις. Αυτό μπορεί να οδηγήσει σε πιο ακριβείς προβλέψεις, ειδικά σε εργασίες όπου τα δεδομένα εισόδου είναι πολύπλοκα ή περιέχουν άσχετες πληροφορίες.

Τα δίκτυα αντιστοίχισης είναι **ευέλικτα** και μπορούν να εφαρμοστούν σε ένα ευρύ φάσμα εργασιών, συμπεριλαμβανομένης της αναγνώρισης εικόνας, της επεξεργασίας φυσικής γλώσσας και των ιατρικών διαγνωστικών. Αυτή η ευελιξία πηγάζει από την ικανότητά τους να μαθαίνουν από λίγα παραδείγματα και τη χρήση μηχανισμών προσοχής.

4.8. Μειονεκτήματα

Μπορεί να είναι υπολογιστικά ακριβό στην εκπαίδευση. Η εκπαίδευση των δικτύων αντιστοίχισης μπορεί να είναι υπολογιστικά ακριβή, ειδικά για μεγάλα σύνολα δεδομένων.

Μπορεί να είναι ευαίσθητο στην επιλογή του επιπέδου ενσωμάτωσης και της συνάρτησης ομοιότητας. Η απόδοση του δικτύου αντιστοίχισης εξαρτάται από την ικανότητα του επιπέδου ενσωμάτωσης να καταγράφει τα σημαντικά χαρακτηριστικά των δεδομένων εισόδου και την ικανότητα της ομοιότητας λειτουργία για τη μέτρηση της ομοιότητας μεταξύ των χαρακτηριστικών εισόδου.

Μπορεί να είναι δύσκολο να ερμηνευθεί. Οι εσωτερικές λειτουργίες του αντίστοιχου δικτύου δεν είναι πάντα εύκολο να κατανοηθούν. Παρά τη χρήση μηχανισμών προσοχής, οι οποίοι μπορούν να παρέχουν κάποια εικόνα για το τι εστιάζει το μοντέλο, τα δίκτυα αντιστοίχισης εξακολουθούν να είναι πολύπλοκα νευρωνικά δίκτυα και, ως εκ τούτου, στερούνται ερμηνείας. Αυτό μπορεί να κάνει δύσκολο να κατανοήσουμε γιατί κάνουν ορισμένες προβλέψεις, κάτι που μπορεί να είναι ένα σημαντικό μειονέκτημα σε εφαρμογές όπου η ερμηνευτικότητα είναι ζωτικής σημασίας.

Τα δίκτυα αντιστοίχισης **εξαρτώνται σε μεγάλο βαθμό από το σύνολο υποστήριξης** τόσο κατά τη διάρκεια της εκπαίδευσης όσο και κατά την εξαγωγή συμπερασμάτων. Υποθέτουν ότι το σύνολο υποστήριξης περιέχει παραδείγματα από όλες τις κλάσεις που μπορεί να συναντήσει το μοντέλο, κάτι που μπορεί να μην συμβαίνει πάντα σε εφαρμογές πραγματικού κόσμου. Αυτό θα μπορούσε να περιορίσει την αποτελεσματικότητά τους σε ορισμένα σενάρια.

Η χρήση μηχανισμών προσοχής σε δίκτυα αντιστοίχισης αυξάνει την **υπολογιστική πολυπλοκότητά** τους. Ο υπολογισμός των βαρών προσοχής για κάθε περίπτωση στο σύνολο υποστήριξης μπορεί να είναι υπολογιστικά ακριβός, ειδικά για μεγάλα σετ υποστήριξης. Αυτό μπορεί να κάνει τα Matching Networks πιο αργά στην εκπαίδευση και χρήση σε σχέση με ορισμένα άλλα μοντέλα μηχανικής εκμάθησης.


Όπως πολλά μοντέλα μηχανικής μάθησης, τα Matching Networks **είναι ευαίσθητα στην επιλογή υπερπαραμέτρων**, όπως ο ρυθμός εκμάθησης και η δομή των υποκείμενων νευρωνικών δικτύων. Η επιλογή λανθασμένων υπερπαραμέτρων μπορεί να οδηγήσει σε κακή απόδοση και η εύρεση των βέλτιστων υπερπαραμέτρων μπορεί να είναι μια χρονοβόρα διαδικασία.

5. Δίκτυα πρωτοτύπων (Prototypical Networks)

5.1. Εισαγωγή

Τα δίκτυα πρωτοτύπων (Prototypical Networks), ένας καινοτόμος μηχανισμός που έχει σχεδιαστεί κυρίως για εφαρμογές εκμάθησης με ελάχιστα δεδομένα, σηματοδοτεί μια σημαντική εξέλιξη στον τομέα της μηχανικής μάθησης. Μια κατηγορία αλγορίθμων μηχανικής μάθησης, τα Prototypical Networks αντιμετωπίζουν μια από τις πιο περίπλοκες προκλήσεις στον τομέα, το ζήτημα των μη ισορροπημένων δεδομένων. Όταν πρόκειται για μη ισορροπημένα δεδομένα, οι παραδοσιακοί αλγόριθμοι συχνά παραπαίουν λόγω της αδυναμίας τους να δημιουργήσουν ουσιαστικά συμπεράσματα από ένα περιορισμένο σύνολο δεδομένων. Ωστόσο, τα Prototypical Networks παρακάμπτουν αυτόν τον περιορισμό κατασκευάζοντας ένα πρωτότυπο για κάθε κλάση, ανεξάρτητα από τον αριθμό των παρουσιών που περιέχει.

Τα πρωτότυπα δίκτυα, με την καινοτόμα προσέγγισή τους στον χειρισμό μη ισορροπημένων δεδομένων, έχουν ανοίξει το δρόμο για προόδους στον τομέα της μηχανικής μάθησης. Κατασκευάζοντας αντιπροσωπευτικά πρωτότυπα για κάθε τάξη και μετρώντας τις αποστάσεις στον μετρικό χώρο, αυτά τα δίκτυα προσφέρουν μια πολλά υποσχόμενη λύση σε μια από τις πιο επίμονες προκλήσεις στη μηχανική μάθηση. Η ικανότητά τους να εξάγουν ουσιαστικά συμπεράσματα από ελάχιστα δεδομένα υπογραμμίζει τις δυνατότητές τους, καθιστώντας τα ένα κρίσιμο εργαλείο στο οπλοστάσιο της σύγχρονης μηχανικής μάθησης.



Πρωτότυπα Δίκτυα στα σενάρια λίγων και μηδέν δειγμάτων. Αριστερά: Λίγα πρωτότυπα c_k υπολογίζονται ως ο μέσος όρος των ενσωματωμένων παραδειγμάτων υποστήριξης για κάθε κλάση. Δεξιά: Τα πρωτότυπα μηδέν δειγμάτων c_k παράγονται με την ενσωμάτωση της κλάσης μεταδεδομένων v_k . Και στις δύο περιπτώσεις, τα ενσωματωμένα σημεία ερωτήματος ταξινομούνται μέσω ενός softmax σε αποστάσεις από τα πρωτότυπα κλάσεων (Snell, 2017):

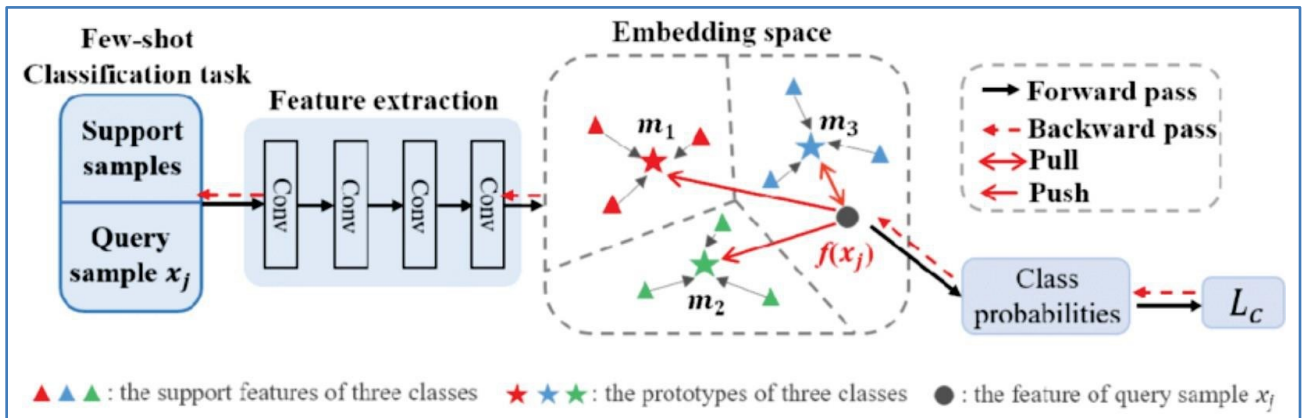
5.2. Ο Βασικός Μηχανισμός των Πρωτοτυπικών Δικτύων: Εξισορρόπηση

Στον τομέα της μηχανικής μάθησης, η έννοια της ισορροπίας έχει σημαντικό βάρος. Η ισορροπία εδώ αφορά την κατανομή των δεδομένων σε διάφορες κλάσεις. Σε έναν ιδανικό κόσμο, τα δεδομένα σε όλες τις κατηγορίες θα ήταν τέλεια ισορροπημένα, επιτρέποντας στους αλγόριθμους να εξάγουν συμπεράσματα με απλό τρόπο. Ωστόσο, ο πραγματικός κόσμος συχνά παρουσιάζει δεδομένα σε μη ισορροπημένη μορφή, θέτοντας μια πρόκληση για τους παραδοσιακούς αλγόριθμους μηχανικής μάθησης.

Τα Πρωτοτυπικά Δίκτυα ξεπερνούν αυτό το πρόβλημα με τη μοναδική τους προσέγγιση. Ο βασικός μηχανισμός βασίζεται στην ύπαρξη ενός πρωτοτύπου για κάθε κατηγορία (Snell, 2017). Το εντυπωσιακό στοιχείο είναι ότι ένα πρωτότυπο μπορεί να δημιουργηθεί ακόμα κι αν μια συγκεκριμένη κλάση έχει μόνο μία παρατήρηση. Ως εκ τούτου, έχουν μια εγγενή ικανότητα να χειρίζονται το πρόβλημα των μη ισορροπημένων δεδομένων.

5.3. Κατασκευή πρωτοτύπων

Η διαδικασία κατασκευής πρωτοτύπων περιλαμβάνει τη δημιουργία μιας μέσης εικόνας, ή πρωτοτύπου, για κάθε τάξη. Αυτό το πρωτότυπο παράγεται με τον μέσο όρο των παρατηρήσεων κάθε τάξης που βρίσκονται στο σύνολο δεδομένων εκπαίδευσης. Με τον μέσο όρο των παρατηρήσεων, τα Prototypical Networks αποτυπώνουν ουσιαστικά την ουσία κάθε τάξης, σχηματίζοντας μια αντιπροσωπευτική εικόνα. Αυτή η αντιπροσωπευτική εικόνα, ή πρωτότυπο, χρησιμεύει στη συνέχεια ως σημείο αναφοράς για την ταξινόμηση νέων παρατηρήσεων.



Η διαδικασία ταξινόμησης του δικτύου πρωτοτύπων

(https://www.researchgate.net/figure/The-classification-process-of-prototypical-network-Conv-denotes-the-convolutional-block_fig2_356072739).

5.4. Εξαγωγή συμπερασμάτων

Η ομοιότητα μεταξύ κάθε νέας παρατήρησης και του πρωτοτύπου αξιολογείται χρησιμοποιώντας την αρνητική έκφραση του Ευκλείδειου κανόνα, που είναι ένα μέτρο της απόστασης. Ως αποτέλεσμα, μια υψηλότερη τιμή υποδηλώνει μεγαλύτερη πιθανότητα παρατήρησης που ανήκει σε μια συγκεκριμένη κατηγορία. Για να δημιουργηθεί μια κατανομή πιθανότητας σε κλάσεις, αυτές οι αποστάσεις περνούν στη συνέχεια μέσω μιας συνάρτησης softmax, μιας συνάρτησης που μπορεί να μετατρέψει ένα διάνυσμα αυθαίρετων πραγματικών τιμών σε κατανομή πιθανότητας.

Για να ταξινομήσουμε ένα νέο δείγμα:

- Ενσωματώνουμε το νέο δείγμα στον χώρο ενσωμάτωσης χρησιμοποιώντας το νευρωνικό δίκτυο.
- Υπολογίζουμε την απόσταση (συνήθως Ευκλείδεια) μεταξύ αυτού του ενσωματωμένου παραδείγματος και καθενός από τα πρωτότυπα κλάσης.
- Αντιστοιχίζουμε το νέο παράδειγμα στην κλάση του πλησιέστερου πρωτοτύπου.

5.5. Εκμάθηση ενός μετρικού χώρου

Τα Πρωτοτυπικά Δίκτυα υπερέχουν στην εκμάθηση ενός μετρικού χώρου, όπου η μέση τιμή των παρατηρήσεων μιας τάξης είναι μια ακριβής αναπαράσταση της τάξης. Σε αυτό το σενάριο, η συμμετοχή μιας νέας παρατήρησης μπορεί να προσδιοριστεί μετρώντας την απόστασή της από το κέντρο της τάξης. Με άλλα λόγια, μια παρατήρηση είναι πιο πιθανό να ανήκει σε μια τάξη εάν είναι πιο κοντά στον μέσο όρο ή στο πρωτότυπο αυτής της κατηγορίας.

Η επιλογή της μέτρησης, η οποία είναι συνήθως η Ευκλείδεια μέτρηση, παίζει κεντρικό ρόλο στα Πρωτοτυπικά Δίκτυα. Επίσης, η απόδοση αυτών των δικτύων είναι ανάλογη με τον αριθμό των τάξεων που υπάρχουν στο εκπαιδευτικό σετ. Περισσότερες κατηγορίες συνεπάγονται μια πλουσιότερη ποικιλία πρωτοτύπων, η οποία με τη σειρά της οδηγεί σε πιο ακριβή ταξινόμηση νέων παρατηρήσεων. Επομένως, τα Πρωτοτυπικά Δίκτυα εμφανίζουν βέλτιστη απόδοση όταν τα σύνολα δεδομένων εκπαίδευσης και δοκιμής περιέχουν δεδομένα από τις ίδιες κλάσεις.

5.6. Η σημασία των ενσωματώσεων

Τα πρωτότυπα δίκτυα, γνωστά για την αποτελεσματικότητά τους στην αντιμετώπιση ελάχιστων δεδομένων, παρέχουν μια νέα προσέγγιση για την κατανόηση και την ταξινόμηση δεδομένων. Εκμεταλλεύονται την ιδέα της δημιουργίας ενός πρωτοτύπου για κάθε κλάση και στη συνέχεια ταξινομούν νέες περιπτώσεις με βάση την απόσταση μεταξύ αυτών των πρωτοτύπων και της νέας παρουσίας. Μια θεμελιώδης πτυχή αυτών των δικτύων που βοηθά στη δημιουργία πρωτοτύπων είναι η έννοια των ενσωματώσεων.

Η χρήση ενσωματώσεων όχι μόνο απλοποιεί τη διαδικασία δημιουργίας πρωτοτύπων αλλά διασφαλίζει επίσης αποτελεσματικές και ακριβείς προβλέψεις ενσωματώνοντας βασικά χαρακτηριστικά των σημείων δεδομένων. Είτε πρόκειται για εικόνες ζώων, χειρόγραφα ψηφία ή οποιονδήποτε άλλο τύπο δεδομένων, τα Prototypical Networks προσφέρουν μια ευέλικτη λύση σε προβλήματα ταξινόμησης, θέτοντας ένα σημείο αναφοράς στον τομέα της μηχανικής μάθησης. Με κάθε νέο παράδειγμα, η δύναμη αυτών των δικτύων στη μόχλευση ενσωματώσεων και πρωτοτύπων γίνεται ολοένα και πιο εμφανής, επιδεικνύοντας τις δυνατότητές τους στην πλοήγηση στον κόσμο που βασίζεται στα δεδομένα.

Η δημιουργία πρωτοτύπων κλάσης στα Πρωτοτυπικά Δίκτυα βασίζεται σε μεγάλο βαθμό στην έννοια των ενσωματώσεων. Για να το διευκρινίσουμε, ας εξετάσουμε ένα σετ υποστήριξης που περιέχει εικόνες λιονταριών, ελεφάντων και σκύλων, που αντιπροσωπεύουν τρεις διαφορετικές κατηγορίες. Ο στόχος είναι να δημιουργηθεί μια πρωτότυπη αναπαράσταση για κάθε κατηγορία, δηλαδή λιοντάρι, ελέφαντας και σκύλος.

Εδώ μπαίνουν στο παιχνίδι οι ενσωματώσεις. Αρχικά, μια συνάρτηση ενσωμάτωσης δημιουργεί τις ενσωματώσεις κάθε σημείου δεδομένων. Η λειτουργία χρησιμεύει για την εξαγωγή βασικών χαρακτηριστικών και δεδομένου ότι τα σημεία δεδομένων εισόδου είναι εικόνες, χρησιμοποιείται ένα συνελικτικό δίκτυο ως λειτουργία ενσωμάτωσης. Ένα Συνελικτικό Δίκτυο, που χρησιμοποιείται συχνά για την επεξεργασία εικόνων, βοηθά στην εξαγωγή κρίσιμων χαρακτηριστικών από την εικόνα εισόδου.

Με τις ενσωματώσεις για κάθε σημείο δεδομένων στο χέρι, το επόμενο βήμα περιλαμβάνει τον υπολογισμό του μέσου όρου των ενσωματώσεων των σημείων δεδομένων σε κάθε κατηγορία. Αυτός ο υπολογισμένος μέσος όρος γίνεται το πρωτότυπο της κλάσης, χρησιμεύοντας ως εκπρόσωπος για κάθε κατηγορία στον χώρο χαρακτηριστικών.

5.7. Πρόβλεψη νέων περιπτώσεων

Όταν πρόκειται για την πρόβλεψη της κατηγορίας μιας νέας παρουσίας, οι ενσωματώσεις συνεχίζουν να παίζουν σημαντικό ρόλο. Παρόμοια με τη διαδικασία δημιουργίας πρωτοτύπου, η ενσωμάτωση για το νέο σημείο δεδομένων δημιουργείται χρησιμοποιώντας την ίδια λειτουργία ενσωμάτωσης.

Μόλις υπολογιστεί η ενσωμάτωση για τη νέα παρουσία, υπολογίζεται η απόσταση μεταξύ αυτής της ενσωμάτωσης και κάθε πρωτοτύπου κλάσης. Η Ευκλείδεια απόσταση χρησιμοποιείται συχνά ως μέτρο απόστασης λόγω της απλότητας και της αποτελεσματικότητάς της.

Ολόκληρη η ροή της διαδικασίας στα Prototypical Networks περιστρέφεται γύρω από τις ενσωματώσεις. Πρώτον, οι ενσωματώσεις υπολογίζονται για όλες τις περιπτώσεις στο σύνολο υποστήριξης. Στη συνέχεια, αυτές οι ενσωματώσεις υπολογίζονται κατά μέσο όρο ανά τάξη για τη δημιουργία πρωτοτύπων κλάσης. Στη συνέχεια, υπολογίζεται η ενσωμάτωση για το σημείο ερωτήματος ή το νέο παράδειγμα. Η απόσταση μεταξύ της ενσωμάτωσης αυτού του σημείου ερωτήματος και κάθε πρωτότυπου κλάσης υπολογίζεται και το softmax εφαρμόζεται σε αυτές τις αποστάσεις για να δώσει πιθανότητες.

Ας το εξηγήσουμε αυτό χρησιμοποιώντας το προηγούμενο παράδειγμα μας ενός σετ υποστήριξης που αποτελείται από λιοντάρια, ελέφαντες και σκύλους. Με δεδομένο ένα νέο στιγμιότυπο (που αντιπροσωπεύεται από ένα ερωτηματικό), οι πιθανότητες κλάσης υποδεικνύουν την πιθανότητα το στιγμιότυπο να ανήκει σε κάθε κλάση. Εάν το παράδειγμα είναι μια εικόνα ενός λιονταριού, η πιθανότητα που αντιστοιχεί στην κατηγορία λιονταριών θα ήταν υψηλή, ας πούμε 0,9. Με τρεις συνολικά κατηγορίες (λιοντάρι, ελέφαντας, σκύλος), καταλήγουμε σε τρεις πιθανότητες. Ως κλάση του στιγμιότυπου επιλέγεται η κλάση που αντιστοιχεί στην υψηλότερη πιθανότητα.

5.8. Ο Αλγόριθμος Εκπαίδευσης

Τα πρωτότυπα δίκτυα, ακρογωνιαίος λίθος στη σφαίρα της μηχανικής μάθησης, έχουν σχεδιαστεί για να λειτουργούν με περιορισμένα δεδομένα ενώ προσφέρουν ανώτερη απόδοση, κυρίως όταν αντιμετωπίζουμε μη ισορροπημένα σύνολα δεδομένων. Αυτά τα δίκτυα περιστρέφονται γύρω από την ιδέα της δημιουργίας ενός πρωτοτύπου για κάθε τάξη, παρέχοντας έτσι έναν ισχυρό και αποτελεσματικό τρόπο χειρισμού συνόλων δεδομένων με άνιση αναπαράσταση κλάσεων. Αυτό το δοκίμιο στοχεύει να ρίξει φως στον αλγόριθμο εκπαίδευσης που ενδυναμώνει τα Πρωτοτυπικά Δίκτυα, επεξεργάζοντας τα ιδιαίτερα χαρακτηριστικά τους και επιδεικνύοντας την εφαρμογή του σε ένα πρακτικό σενάριο.

Ο μηχανισμός εξαγωγής μιας πρωτότυπης αναπαράστασης για κάθε τάξη και ταξινόμησης νέων περιπτώσεων με βάση την απόσταση από αυτά τα πρωτότυπα αποτελεί παράδειγμα μιας νέας

προσέγγισης στη μηχανική μάθηση. Είτε πρόκειται για την ταξινόμηση χειρόγραφων ψηφίων είτε για την αντιμετώπιση άλλων σύνθετων εργασιών ταξινόμησης, το Prototypical Networks αποδεικνύεται ένα ισχυρό και ευέλικτο εργαλείο στο οπλοστάσιο της μηχανικής εκμάθησης.

Στην καρδιά των Prototypical Networks βρίσκεται ο αλγόριθμος εκπαίδευσης, ο οποίος επιδιώκει να μάθει ένα σύνολο πρωτότυπων αναπαραστάσεων για κάθε τάξη στο σύνολο δεδομένων. Ο πρωταρχικός στόχος είναι να διαμορφωθούν πρωτότυπα που ενσωματώνουν την ουσία κάθε κατηγορίας και μπορούν να αξιοποιηθούν για την ταξινόμηση νέων περιπτώσεων. Η εκπαιδευτική διαδικασία εκτυλίσσεται σε μια σειρά βημάτων:

1. Τα παραδείγματα εκπαίδευσης είναι ενσωματωμένα σε ένα χώρο χαρακτηριστικών χρησιμοποιώντας ένα νευρωνικό δίκτυο.
2. Τα ενσωματωμένα παραδείγματα για κάθε τάξη υπολογίζονται κατά μέσο όρο για να προκύψουν οι αρχικές αναπαραστάσεις ή πρωτότυπα.
3. Υπολογίζεται η απόσταση μεταξύ κάθε στιγμιότυπου και του αντίστοιχου πρωτοτύπου κλάσης.
4. Αυτή η απόσταση χρησιμοποιείται για τον υπολογισμό μιας κατανομής πιθανότητας κλάσης για κάθε παράδειγμα.
5. Τέλος, οι υπολογισμένες κατανομές πιθανοτήτων χρησιμοποιούνται για την ενημέρωση των παραμέτρων του νευρωνικού δικτύου χρησιμοποιώντας έναν αλγόριθμο βελτιστοποίησης που βασίζεται σε κλίση.

Μετά την ολοκλήρωση, το μοντέλο αναπαράγει τις πρωτότυπες αναπαραστάσεις για κάθε κατηγορία. Αυτά τα πρωτότυπα μπορούν να χρησιμοποιηθούν για την ταξινόμηση νέων περιπτώσεων μετρώντας την απόσταση μεταξύ του στιγμιότυπου και των πρωτοτύπων.

5.9. Ένα πρακτικό σενάριο: Ταξινόμηση χειρόγραφων ψηφίων

Για να δείξουμε τη χρησιμότητα των Πρωτοτυπικών Δικτύων, ας εξετάσουμε ένα κοινό σενάριο στη μηχανική μάθηση: ταξινόμηση εικόνων χειρόγραφων ψηφίων που κυμαίνονται από το 0 έως το 9. Ο στόχος είναι να εκπαιδεύσουμε ένα νευρωνικό δίκτυο που μπορεί να προσδιορίσει με ακρίβεια το ψηφίο που αναπαρίσταται σε μια εικόνα.

Η διαδικασία ξεκινά με τη διέλευση των εικόνων μέσω ενός Συνελικτικού Νευρωνικού Δικτύου (CNN), ενός τύπου νευρωνικού δικτύου που έχει σχεδιαστεί για να επεξεργάζεται δεδομένα τύπου πλέγματος, όπως εικόνες. Το CNN χρησιμεύει για να αποκτήσει μια ενσωμάτωση χαρακτηριστικών κάθε εικόνας, μετατρέποντας τα ακατέργαστα δεδομένα pixel σε ένα χώρο χαρακτηριστικών υψηλών διαστάσεων.

Μόλις εξαχθούν οι ενσωματώσεις χαρακτηριστικών, υπολογίζεται ο μέσος όρος τους για όλες τις εικόνες σε κάθε κατηγορία για να ληφθεί η αρχική αναπαράσταση ή πρωτότυπο κάθε κατηγορίας. Αυτά τα πρωτότυπα, ενσωματώνοντας τα χαρακτηριστικά γνωρίσματα κάθε κατηγορίας, χρησιμεύουν ως σημεία αναφοράς για την ταξινόμηση.

Το επόμενο βήμα περιλαμβάνει τον υπολογισμό της απόστασης μεταξύ της ενσωμάτωσης χαρακτηριστικών κάθε εικόνας και του πρωτοτύπου κάθε κατηγορίας. Αυτή η απόσταση, που συχνά υπολογίζεται χρησιμοποιώντας την L2 ή την Ευκλείδεια απόσταση, παρέχει ένα μέτρο ομοιότητας μεταξύ μιας εικόνας και κάθε κατηγορίας. Αποτελεί τη βάση για τον υπολογισμό μιας κατανομής πιθανότητας στις κλάσεις για κάθε εικόνα, όπου μια μικρότερη απόσταση αντιστοιχεί σε μεγαλύτερη πιθανότητα, υπονοώντας ότι η εικόνα είναι πιο πιθανό να ανήκει στην κατηγορία με το πλησιέστερο πρωτότυπο.

Στη συνέχεια, η κατανομή πιθανοτήτων βοηθά στην ενημέρωση των παραμέτρων του CNN χρησιμοποιώντας έναν αλγόριθμο βελτιστοποίησης που βασίζεται σε κλίση, όπως το Stochastic Gradient Descent. Η διαδικασία εκπαίδευσης επαναλαμβάνεται για πολλές εποχές, ενημερώνοντας κάθε φορά τις παραμέτρους έως ότου η ακρίβεια του μοντέλου στα δεδομένα εκπαίδευσης είναι ικανοποιητική.

Μετά την ολοκλήρωση της εκπαίδευσης, το μοντέλο είναι έτοιμο να ταξινομήσει νέες εικόνες. Αυτό επιτυγχάνεται με τον εντοπισμό της κλάσης που αντιστοιχεί στο πλησιέστερο πρωτότυπο για κάθε νέα εικόνα, ταξινομώντας την έτσι αποτελεσματικά σε μία από τις 10 ψηφιακές κατηγορίες.

6. Σχεσιακά Δίκτυα (Relation Networks)

6.1. Εισαγωγή

Η εμφάνιση της βαθιάς μάθησης έχει δημιουργήσει διάφορες νευρωνικές αρχιτεκτονικές που προσπαθούν να μιμηθούν την ανθρώπινη γνώση με διαφορετικούς τρόπους. Μια τέτοια εξέλιξη είναι το «Δίκτυο Σχέσεων» (RN), που έχει σχεδιαστεί για τη διαχείριση των σχέσεων μεταξύ ζευγών αντικειμένων. Όταν συνδυάζονται με μάθηση με λίγα δεδομένα, τα RN προσφέρουν μια πολλά υποσχόμενη μέθοδο που επιτρέπει στις μηχανές να γενικεύουν τη γνώση από μια χούφτα παραδείγματα.

Στην ουσία, τα Δίκτυα Σχέσεων (RN) είναι ένας τύπος αρχιτεκτονικής νευρωνικών δικτύων που έχει σχεδιαστεί για να συγκρίνει αντικείμενα μέσα σε ένα δεδομένο πλαίσιο. Τα RN που εισήχθησαν από την DeepMind το 2017, λειτουργούν αποδεχόμενοι ζεύγη αντικειμένων από μια σκηνή και προσδιορίζοντας εάν υπάρχει σχέση μεταξύ τους (Sung, 2017). Για παράδειγμα, σε μια εικόνα με πολλά αντικείμενα, ένα RN θα μπορούσε να αξιολογήσει εάν το αντικείμενο A βρίσκεται στα αριστερά του αντικειμένου B. Η δύναμη των RN έγκειται στην ικανότητά τους να συλλογίζονται για τις σχέσεις των αντικειμένων ακόμα κι αν τα ίδια τα αντικείμενα περιγράφονται με πολύπλοκους όρους.

Τα RN, μαθαίνοντας μια γενικευμένη συνάρτηση σχέσης, γεφυρώνουν το χάσμα μεταξύ γενικής και ειδικής μάθησης. Η ευελιξία τους επεκτείνεται στη μηδενική μάθηση, διευρύνοντας τη δυνατότητα εφαρμογής τους. Αυτό περιλαμβάνει πρώτα την κατανόηση μιας μεταφερόμενης ενσωμάτωσης και, στη συνέχεια, τη μέτρηση μετρήσεων βάθους για τη διάκριση των σχέσεων είτε μεταξύ εικόνων (για λίγα δείγματα) είτε μεταξύ εικόνων και περιγραφών κλάσεων (χωρίς δείγματα εντελώς).

Τα RN χρησιμοποιούν στάδια μη γραμμικής μάθησης, επιτρέποντας μια ευέλικτη προσέγγιση λύσης. Η ικανότητά τους να αποκρυπτογραφούν σχέσεις σε μη γραμμικούς χώρους τους διακρίνει στη σφαίρα της μηχανικής μάθησης. Αυτή η ικανότητα υπογραμμίζει τις μετασημασιτικές δυνατότητές τους στην αντιμετώπιση πολύπλοκων προκλήσεων ταξινόμησης, ιδιαίτερα με περιορισμένα δεδομένα.

Τα RN, από τη σχεδίασή τους, αξιολογούν ζεύγη αντικειμένων στο περιβάλλον τους, επιτρέποντάς τους να διακρίνουν διακριτικά μοτίβα στα δεδομένα. Αυτή η χωρητικότητα είναι επωφελής σε μάθηση με λίγα δεδομένα όπου ο όγκος των διαθέσιμων δεδομένων είναι περιορισμένος.

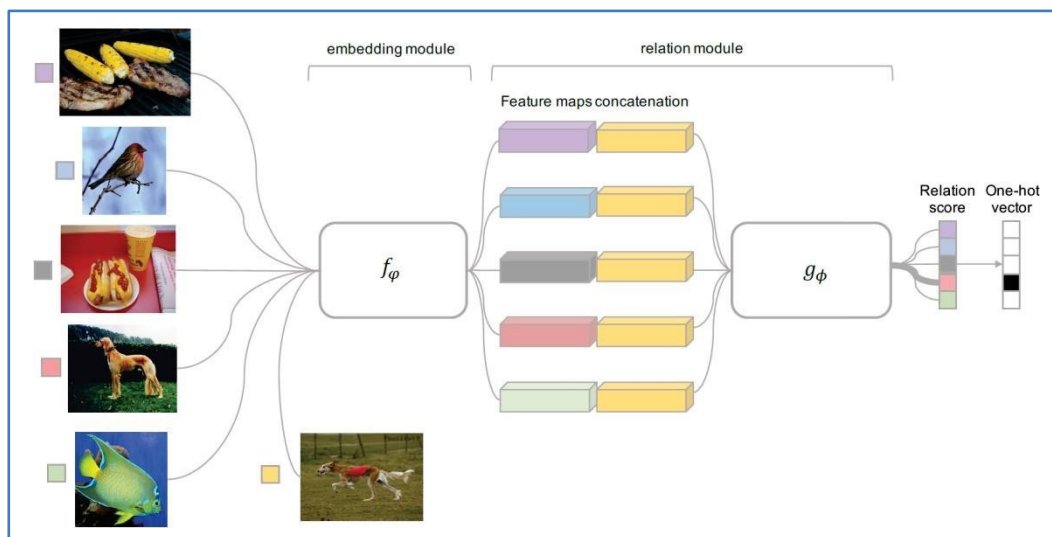
6.2. Μεθοδολογία Εκπαίδευσης

Τα Σχεσιακά Δίκτυα (RN) διαφέρουν από τις τυπικές νευρωνικές αρχιτεκτονικές χρησιμοποιώντας μη γραμμικές μετρήσεις για ταξινόμηση. Δημιουργούν ένα πρωτότυπο ενσωματώνοντας υπολογισμένα χαρακτηριστικά κατηγοριών. Κάθε εικόνα υποβάλλεται σε επεξεργασία μέσω μιας μη γραμμικής συνάρτησης, κλιμακούμενης μεταξύ 0 και 1, σε σχέση με την κατηγορία της.

Τα RN υπερέχουν στην εκμάθηση γενικευμένων χαρακτηριστικών και συναρτήσεων σχέσεων, επιτρέποντας την προσαρμοστικότητα για νέες εργασίες μετά την εκπαίδευση. Προσφέρουν ευελιξία στην αντιμετώπιση ποικίλων προβλημάτων χρησιμοποιώντας λιγοστά δεδομένα. Εκπαιδευμένοι από την αρχή, οι RN στη φάση μετά τη μάθηση χρησιμοποιούν μια μέτρηση για την ανάλυση εικόνων σε

«επεισόδια», μιμούμενοι την μάθηση με λίγα δεδομένα. Το δίκτυο μετράει τις βαθμολογίες σχέσεων μεταξύ εικόνων ερωτημάτων και δειγμάτων νέων κλάσεων χωρίς περαιτέρω ενημερώσεις. Αφού κατακτήσουν αυτήν τη γενική λειτουργία σχέσεων, τα RN προσαρμόζονται με ακρίβεια για συγκεκριμένες εργασίες χρησιμοποιώντας περιορισμένα παραδείγματα, ενισχύοντας την αποτελεσματικότητά τους σε σενάρια σύντομης μάθησης.

Η εκμάθηση σε λίγες περιπτώσεις χρησιμοποιεί συχνά χώρους ενσωμάτωσης όπου παρόμοια αντικείμενα ομαδοποιούνται. Τα RN μπορούν να το βελτιώσουν αυτό όχι μόνο λαμβάνοντας υπόψη τις ενσωματώσεις μεμονωμένων αντικειμένων αλλά εξετάζοντας τις σχεσιακές ενσωματώσεις τους.



Αρχιτεκτονική σχεσιακού δικτύου για ένα πρόβλημα 5 κλάσεων 1 παραδείγματος (Sung, 2017).

6.3. Δομή

Τα RN αποτελούνται αρχιτεκτονικά από δύο βασικούς πυλώνες: τον εξαγωγέα χαρακτηριστικών και τη μονάδα σχέσεων.

Ο **εξαγωγέας χαρακτηριστικών** (feature extractor), όπως υποδηλώνει το όνομά του, είναι επιφορτισμένος με την επεξεργασία των ακατέργαστων δεδομένων εισόδου, μετατρέποντάς τα σε έναν πιο εκλεπτυσμένο χώρο χαρακτηριστικών. Όταν ασχολούμαστε με οπτικά δεδομένα ή δεδομένα που βασίζονται σε εικόνες, τα συνελκτικά νευρωνικά δίκτυα (CNN), που είναι γνωστά για την ικανότητά τους να μαθαίνουν αυτόματα και προσαρμοστικά χωρικές ιεραρχίες χαρακτηριστικών, είναι συνήθως το βασικό εργαλείο για αυτήν τη διαδικασία εξαγωγής.

Μετά τη μετάβαση στη **μονάδα σχέσεων** (relationship module), ο πρωταρχικός της ρόλος είναι να εμβαθύνει σε αυτές τις εξαγόμενες αναπαραστάσεις χαρακτηριστικών και να κάνει συγκρίσεις. Πιο συγκεκριμένα, αξιολογεί τον βαθμό ομοιότητας μεταξύ των παραδειγμάτων υποστήριξης, που είναι ουσιαστικά τα δεδομένα εκπαίδευσης, και των παραδειγμάτων ερωτημάτων, που είναι παρόμοια με δεδομένα δοκιμής. Αντί να καταφεύγει σε συμβατικές γραμμικές μεθόδους, η ενότητα σχέσεων χρησιμοποιεί μη γραμμικές μετρήσεις, προσθέτοντας ένα επιπλέον επίπεδο βάθους στις αναλύσεις της.

Ο **πυρήνας της συνάρτησης ακτινικής βάσης** (Radial Basis Function - RBF) ξεχωρίζει για την ικανότητά του να μετράει ομοιότητες. Λειτουργεί προσδιορίζοντας την εγγύτητα ή την εγγύτητα των περιπτώσεων εντός του πολυδιάστατου χώρου χαρακτηριστικών. Εστιάζοντας στην Ευκλείδεια απόσταση μεταξύ των σημείων δεδομένων, προσφέρει ένα ισχυρό και διαισθητικό μέτρο ομοιότητας.

Η **συνάρτηση ομοιότητας συνημιτόνου** προσφέρει διαφορετικό φακό για προβολή ομοιοτήτων. Αντί για μέγεθος ή μέγεθος, μηδενίζει τον προσανατολισμό μεταξύ των αναπαραστάσεων χαρακτηριστικών, αξιολογώντας αποτελεσματικά τη γωνία μεταξύ τους. Αυτό προσφέρει μια διαφοροποιημένη προοπτική, ειδικά σε περιπτώσεις όπου η κατεύθυνση των χαρακτηριστικών δεδομένων είναι πιο ενημερωτική από το μέγεθός τους.

Η δύναμη των **μη γραμμικών μετρήσεων** δεν σταματά στην ικανότητά τους να ταξινομούν δεδομένα. Μόλις οι αναπαραστάσεις χαρακτηριστικών υποβληθούν σε αυτή τη μη γραμμική σύγκριση, οι βαθμολογίες ομοιότητας που προκύπτουν αποτελούν τη βάση πάνω στην οποία λαμβάνονται οι αποφάσεις ταξινόμησης. Αυτές οι βαθμολογίες κατευθύνονται σε έναν ταξινομητή, ο οποίος στη συνέχεια κατασκευάζει μια κατανομή πιθανότητας σε όλες τις πιθανές κλάσεις για κάθε παράδειγμα ερωτήματος. Φυσικά, η τάξη με τη μέγιστη πιθανότητα αναδεικνύεται νικήτρια και γίνεται η προβλεπόμενη κατηγορία για τη συγκεκριμένη περίπτωση.

6.4. Εφαρμογές

Η ενσωμάτωση των RN σε υπάρχουσες αρχιτεκτονικές παραμένει ένας συνεχής τομέας έρευνας.

Οπτική Αναγνώριση:

- **Ταξινόμηση αντικειμένων:** Σε σενάρια όπου είναι διαθέσιμα μόνο λίγα παραδείγματα συγκεκριμένου αντικειμένου, τα RN μπορούν να βοηθήσουν στην αναγνώριση και ταξινόμηση αυτών των αντικειμένων σε νέες εικόνες.
- **Επαλήθευση προσώπου:** Σε συστήματα ασφαλείας ή αναγνώρισης όπου είναι διαθέσιμες μόνο μία ή λίγες εικόνες του προσώπου ενός ατόμου, τα RN μπορούν να καθορίσουν εάν μια νέα εικόνα ταιριάζει με τα παρεχόμενα δείγματα.

Αναγνώριση ασθένειας: Για σπάνιες ασθένειες με περιορισμένα δεδομένα ασθενών, τα RN μπορούν να βοηθήσουν τους γιατρούς αναλύοντας ιατρικές εικόνες ή γονιδιωμικά δεδομένα για τον εντοπισμό μοτίβων που οδηγούν σε πιθανή διάγνωση.

Επεξεργασία Φυσικής Γλώσσας (NLP):

- **Ταξινόμηση εγγράφων:** Τα RN μπορούν να χρησιμοποιηθούν για την ταξινόμηση εγγράφων σε συγκεκριμένες κατηγορίες με βάση μερικά παραδείγματα.
- **Σημασιολογική επισήμανση ρόλων:** Δεδομένου ενός περιορισμένου αριθμού προτάσεων με ετικέτα, τα RN μπορούν να προβλέψουν σημασιολογικούς ρόλους σε νέες προτάσεις.

Ρομποτική: Τα ρομπότ μπορούν να χρησιμοποιήσουν RN για να μάθουν νέες εργασίες που βασίζονται στην παρατήρηση λίγων μόνο επιδείξεων, δίνοντάς τους τη δυνατότητα να προσαρμοστούν σε διάφορες καταστάσεις πιο γρήγορα.

Βιντεοπαιχνίδια και προσομοιώσεις:

- **Πρόβλεψη συμπεριφοράς χαρακτήρων:** Με περιορισμένα δεδομένα παιχνιδιού, οι RN μπορούν να προβλέψουν τις επόμενες κινήσεις ή στρατηγικές ενός χαρακτήρα, βελτιώνοντας τη δυναμική του παιχνιδιού.
- **Δημιουργία Σεναρίων:** Τα RN μπορούν να δημιουργήσουν νέα σενάρια παιχνιδιών ή προσομοιώσεις με βάση μερικά δεδομένα πρότυπα.

Ανίχνευση ανωμαλιών:

- **Ανίχνευση χρηματοοικονομικής απάτης:** Τα RN μπορούν να είναι καθοριστικής σημασίας για τον εντοπισμό νέων, ύποπτων προτύπων.
- **Ασφάλεια δικτύου:** Τα RN μπορούν να ανιχνεύσουν νέα μοτίβα επιθέσεων στον κυβερνοχώρο με βάση περιορισμένα παραδείγματα γνωστών στρατηγικών επίθεσης.

7. Μετα-μάθηση με μεταφορά (Meta-Transfer Learning)

7.1. Μάθηση με μεταφορά (Transfer Learning)

Η μάθηση με μεταφορά αναδύεται ως μια ισχυρή τεχνική στη μηχανική μάθηση, όπου ένα μοντέλο που αναπτύχθηκε για μια συγκεκριμένη εργασία επαναπροσδιορίζεται για να επιταχύνει τη μάθηση σε έναν ξεχωριστό αλλά συναφές τομέα. Οραματιστείτε το ως απόκτηση δεξιοτήτων από μια δουλειά και αποτελεσματική εφαρμογή τους σε ένα διαφορετικό, αν και σχετικό, επάγγελμα. Το σκεπτικό; Οι θεμελιώδεις γνώσεις από την κύρια εργασία μπορούν να αποτελέσουν ένα πρώτο ξεκίνημα, λειτουργώντας ως ευέλικτο "γεννήτρια χαρακτηριστικών" για επόμενες εργασίες.

Με την άνοδο της βαθιάς μάθησης, η μεταβιβαστική μάθηση έχει δημιουργήσει μια θέση, ειδικά στην επεξεργασία φυσικής γλώσσας (NLP) και στην όραση υπολογιστή. Πρωτοποριακά μοντέλα όπως το BERT και το GPT, προεκπαιδευμένα σε τεράστια σύνολα δεδομένων, έχουν γίνει θεμελιώδη μπλοκ στο NLP, οδηγώντας σε αυξημένες επιδόσεις. Ομοίως, στην όραση υπολογιστή, μοντέλα ενισχυμένα με γνώσεις από εκτεταμένα σύνολα δεδομένων όπως το ImageNet χρησιμεύουν ως επιφάνειες εκκίνησης για λεπτές εργασίες.

Η ευελιξία της τεχνικής δεν σταματά εκεί. Από την αναγνώριση ομιλίας, τη βιοπληροφορική έως άλλες εργασίες NLP, η μεταβιβαστική μάθηση κάνει τα κύματα, θέτοντας σταθερά σημεία αναφοράς.

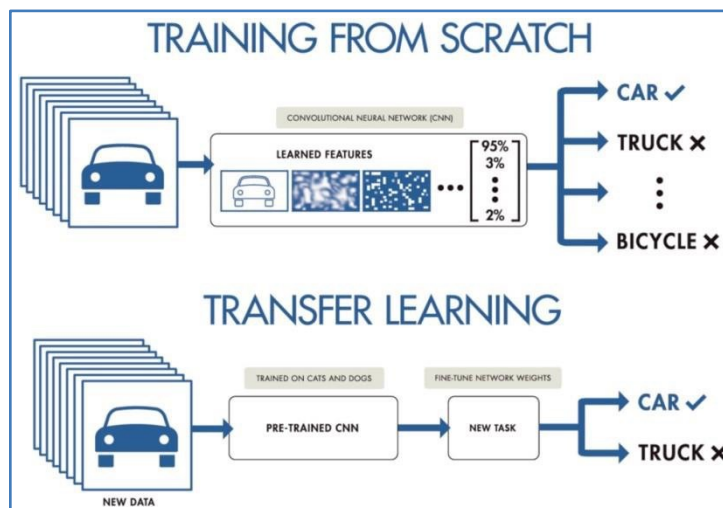
Μερικές βασικές μέθοδοι μεταφοράς μάθησης είναι οι εξής:

- **Βελτιστοποίηση:** Όπου το ήδη εκπαιδευμένο μοντέλο υφίσταται περαιτέρω βελτιστοποίηση σε ένα νέο σύνολο δεδομένων, ιδιαίτερα ωφέλιμο όταν το επόμενο σύνολο δεδομένων αντικατοπτρίζει το πρωτεύον αλλά με μικρές παραλλαγές, ας πούμε, διαφορετικές κλάσεις ή τροποποιημένη κατανομή δεδομένων.
- **Παραγωγή χαρακτηριστικών:** Εδώ, το αρχικό μοντέλο λειτουργεί ως εξαγωγέας χαρακτηριστικών για νέα δεδομένα, με αυτά τα χαρακτηριστικά στη συνέχεια να τροφοδοτούνται σε ένα νέο μοντέλο. Αυτό είναι βολικό όταν η επόμενη εργασία απομακρύνεται από την αρχική, ωστόσο τα βασικά χαρακτηριστικά παραμένουν σχετικά.
- **Ταυτόχρονη μάθηση πολλαπλών εργασιών:** Μια ολιστική προσέγγιση όπου ένα μεμονωμένο μοντέλο υποβάλλεται σε εκπαίδευση για να επιτελεί πολλαπλές διασυνδεδεμένες εργασίες, ειδικά εάν διαθέτουν κοινά χαρακτηριστικά που επωφελούνται από τη συλλογική μάθηση.

Τα βασικά ζητήματα στη μεταφορά μάθησης είναι:

- **Επιλογή του αρχικού μοντέλου:** Η επιλογή ενός προεκπαιδευμένου μοντέλου σε συγχρονισμό με τη νέα εργασία είναι ζωτικής σημασίας. Μια εργασία με επίκεντρο την εικόνα, για παράδειγμα, θα κέρδιζε περισσότερα από ένα μοντέλο εκπαιδευμένο σε ένα τεράστιο σύνολο δεδομένων εικόνας παρά από ένα εκπαιδευμένο σε δεδομένα κειμένου ή ακουστικών δεδομένων.
- **Διαθεσιμότητα δεδομένων για νέα εργασία:** Η εκμάθηση μεταφοράς είναι κατάλληλη σε σενάρια με σπάνια δεδομένα, αξιοποιώντας πληροφορίες από το προεκπαιδευμένο μοντέλο.
- **Αρχιτεκτονική Μοντέλου:** Ενώ αρχιτεκτονικές όπως τα συνελκτικά νευρωνικά δίκτυα (CNN) υπερέχουν στην επεξεργασία εικόνας, τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN) κυριαρχούν στη σφαίρα του κειμένου, καθιστώντας τις προτιμώμενες επιλογές για τέτοιες προεκπαιδευμένες εργασίες.
- **Βάθος μεταφοράς:** Ενώ τα χαμηλότερα επίπεδα ενσωματώνουν περισσότερα γενικά χαρακτηριστικά, τα υψηλότερα είναι πιο εξειδικευμένα και η επιλογή εξαρτάται συχνά από τις ιδιαιτερότητες της νέας εργασίας.

Ουσιαστικά, η μάθηση μεταφοράς προσφέρει μια συντόμευση στη γνώση χωρίς να χρειάζεται να ξεκινήσουμε από το μηδέν. Περιλαμβάνει τη μόχλευση ενός προεκπαιδευμένου νευρωνικού δικτύου για μια άλλη εργασία. Μας δίνει τη δυνατότητα να τροποποιήσουμε συγκεκριμένα επίπεδα ενός δικτύου για να το προσαρμόσουμε σε μια νέα εργασία, εξοικονομώντας υπολογιστικούς πόρους. Η τελειοποίηση γίνεται ευκολότερη όταν τα νέα δεδομένα είναι παρόμοια με τα αρχικά δεδομένα εκπαίδευσης.



Μάθηση με μεταφορά (Transfer Learning)

(https://miro.medium.com/v2/resize:fit:828/0*xNjEPIZmPvKqqs6)

7.2. Μετα-μάθηση (Meta-Learning)

Στον σημερινό κόσμο που βασίζεται στα δεδομένα, οι αλγόριθμοι μηχανικής μάθησης (ML) διαδραματίζουν κρίσιμο ρόλο στην αποκρυπτογράφηση πολύπλοκων μοτίβων, στην πραγματοποίηση προβλέψεων και στη βοήθεια στις διαδικασίες λήψης αποφάσεων σε διάφορους τομείς. Καθώς τα μοντέλα μηχανικής μάθησης εξελίσσονται για να αντιμετωπίσουν ένα ευρύ φάσμα προκλήσεων, υπάρχει αυξανόμενη ζήτηση για αλγόριθμους που όχι μόνο μαθαίνουν από δεδομένα αλλά και κατανοούν την ίδια τη διαδικασία εκμάθησης (Vilalta, 2002).

Ο όρος «μετα-» συχνά υπονοεί κάτι γενικό ή αφηρημένο. Η μετα-μάθηση αφορά την κατανόηση της ίδιας της διαδικασίας μάθησης. Σε αντίθεση με τους συμβατικούς αλγόριθμους μηχανικής μάθησης που εκπαιδεύονται απευθείας σε δεδομένα, οι αλγόριθμοι μετα-μάθησης ενημερώνονται από τα αποτελέσματα άλλων μοντέλων.

Στο πλαίσιο ταξινόμησης εικόνων: ενώ τα μοντέλα μηχανικής μάθησης προβλέπουν τάξεις με βάση την εισαγωγή εικόνας, τα μοντέλα μετα-μάθησης βασίζονται στις προβλέψεις τους στην έξοδο αυτών των μοντέλων μηχανικής μάθησης. Έτσι, η μετα-μάθηση λειτουργεί ένα επίπεδο πάνω από την παραδοσιακή μηχανική μάθηση.

Τα μεμονωμένα μοντέλα εκπαιδεύονται και οι προβλέψεις τους εισάγονται σε ένα «μετα-μοντέλο» όπου αυτές οι προβλέψεις γίνονται «μετα-χαρακτηριστικά». Η διασταυρούμενη επικύρωση είναι απαραίτητη για την αποφυγή υπερβολικής προσαρμογής.

Η μετα-μάθηση βρίσκεται στο σημείο τομής της ενδοσκόπησης και της προσαρμογής στη μηχανική μάθηση. Ενώ τα παραδοσιακά μοντέλα μηχανικής μάθησης εκπαιδεύονται σε ένα συγκεκριμένο σύνολο δεδομένων για την εκτέλεση μιας συγκεκριμένης εργασίας, τα μοντέλα μετα-μάθησης έχουν σχεδιαστεί για να βελτιώσουν την ίδια τη διαδικασία εκμάθησης. Αυτό το επιτυγχάνουν εξετάζοντας τον τρόπο με τον οποίο διαφορετικοί αλγόριθμοι αποδίδουν σε πολλαπλές εργασίες και προσαρμόζονται βάσει αυτής της εικόνας υψηλότερου επιπέδου. Με απλούστερους όρους, ενώ τα μοντέλα ML μαθαίνουν μοτίβα από δεδομένα, τα μοντέλα μετα-μάθησης μαθαίνουν μοτίβα από το πώς μαθαίνουν τα άλλα μοντέλα.

Η μετα-μάθηση αντιπροσωπεύει μια αλλαγή παραδείγματος στον τρόπο που σκεφτόμαστε για τη μηχανική μάθηση. Αντί να εστιάζει αποκλειστικά σε πρότυπα που βασίζονται σε δεδομένα, τονίζει τη σημασία της ίδιας της μαθησιακής διαδικασίας. Καθώς τα συστήματα τεχνητής νοημοσύνης συνεχίζουν να πολλαπλασιάζονται σε διάφορους τομείς, η ικανότητα «μάθησης για τη μάθηση» θα είναι καθοριστική για τη δημιουργία προσαρμοστικών, αποτελεσματικών και αυτόνομων μοντέλων.

Το Meta-Learning είναι **σημαντικό** για διάφορους λόγους:

- **Αποδοτικότητα:** Στην παραδοσιακή μηχανική μάθηση, η εισαγωγή μιας νέας εργασίας σημαίνει συχνά έναρξη της διαδικασίας εκμάθησης από την αρχή. Ωστόσο, η μετα-μάθηση επιτρέπει στα μοντέλα να αξιοποιούν προηγούμενες γνώσεις και εμπειρίες, οδηγώντας σε ταχύτερη σύγκλιση και λιγότερες απαιτήσεις δεδομένων για νέες εργασίες.
- **Γενίκευση:** Δεδομένου ότι τα μοντέλα μετα-μάθησης εκτίθενται σε διάφορα σενάρια μάθησης, τείνουν να γενικεύονται καλύτερα σε διαφορετικές εργασίες, οδηγώντας σε πιο ισχυρές και προσαρμόσιμες λύσεις.
- **Αυτοματισμός:** Ένας από τους πρωταρχικούς στόχους της τεχνητής νοημοσύνης είναι η δημιουργία συστημάτων που μπορούν αυτόνομα να προσαρμοστούν σε νέες, απρόβλεπτες καταστάσεις. Η μετα-μάθηση είναι ένα βήμα προς αυτή την κατεύθυνση καθώς στοχεύει στην αυτοματοποίηση της μαθησιακής διαδικασίας.

Τεχνικές Meta-Learning:

Model-Agnostic Meta-Learning (MAML): Το MAML εκπαιδεύει ένα μοντέλο με τέτοιο τρόπο ώστε να μπορεί να βελτιωθεί με ένα μικρό σύνολο δεδομένων για μια νέα εργασία. Η ιδέα είναι να βρεθεί μια γενικεύσιμη αρχικοποίηση που να μπορεί να προσαρμοστεί αποτελεσματικά σε διάφορες εργασίες.

Transfer Learning: Αν και δεν είναι αυστηρά μετα-μάθηση, η μάθηση με μεταφορά μοιράζεται την αρχή της εφαρμογής της γνώσης από τον έναν τομέα στον άλλο. Τα προεκπαιδευμένα μοντέλα τροποποιούνται για να ταιριάζουν σε νέες εργασίες, εξοικονομώντας υπολογιστικούς πόρους.

Μάθηση για τη μάθηση με Gradient Descent: Αυτή η προσέγγιση περιλαμβάνει εκπαίδευση βελτιστοποιητών για να βοηθήσουν τα νευρωνικά δίκτυα να μαθαίνουν πιο γρήγορα.

Αναζήτηση κατάλληλης Neural Architecture: Εδώ, η μετα-μάθηση βοηθά στην αναζήτηση της καλύτερης αρχιτεκτονικής νευρωνικών δικτύων για μια δεδομένη εργασία.

Stacking: Μια κλασική τεχνική συνόλου, η στοίβαξη συνδυάζει τα αποτελέσματα πολλών μοντέλων. Στη συνέχεια, ένα μετα-μοντέλο εκπαιδεύεται σε αυτά τα συνδυασμένα αποτελέσματα.

Επαυξημένη χωρητικότητα μνήμης. Αρχιτεκτονικές με επαυξημένη χωρητικότητα μνήμης, όπως οι Μηχανές Neural Turing (NTM), προσφέρουν τη δυνατότητα γρήγορης κωδικοποίησης και ανάκτησης νέων πληροφοριών και, να αφομοιώνει γρήγορα νέα δεδομένα και να αξιοποιεί αυτά τα δεδομένα για να κάνει ακριβείς προβλέψεις μετά από λίγα μόνο δείγματα (Santoro, 2016.).

7.3. Μετα-μάθηση με μεταφορά (Meta-Transfer Learning)

Μια άλλη προσέγγιση για τη μάθηση με λίγα βήματα είναι η Μετα-μάθηση με μεταφορά (Meta-Transfer Learning). Το Meta-Transfer Learning έχει εισαγάγει ένα νέο παράδειγμα στη σφαίρα της μηχανικής μάθησης, εμφυσώντας την ουσία τόσο της μετα-μάθησης όσο και της μεταφοράς της μάθησης σε ένα συνεκτικό πλαίσιο. Το ταξίδι ξεκινά με μια διπλή εκπαιδευτική διαδικασία, όπου η αρχική φάση περιλαμβάνει την αξιοποίηση τεράστιων συνόλων δεδομένων ή την καταφυγή σε ήδη προεκπαιδευμένα μοντέλα που έχουν συλλεχθεί από σημαντικές πηγές δεδομένων (Sun, 2018.).

Μετα-εκπαίδευση με Multi-Task Insight. Το εναρκτήριο βήμα, που συχνά χαρακτηρίζεται ως η φάση "μετά-εκπαίδευση", περιλαμβάνει εκπαίδευση σε μια μυριάδα εργασιών, που συλλογικά ονομάζεται το σετ μετά την εκπαίδευση. Καθεμία από αυτές τις εργασίες περιέχει μια περιορισμένη κρυφή μνήμη παραδειγμάτων, η οποία μπορεί να φαίνεται αντίθετη στην αρχή. Ωστόσο, αυτός ο σχεδιασμός σκοπεύει να καλλιεργήσει την ικανότητα του μοντέλου να αποκρυπτογραφεί γενικά χαρακτηριστικά που εκτείνονται σε όλες τις εργασίες και να ρυθμίζει συγκεκριμένα χαρακτηριστικά που σχετίζονται με την εργασία.

Προσαρμογή του μετα-μοντέλου με νέα δεδομένα. Μεταβαίνοντας στη δεύτερη φάση, το πρωτεύον μοντέλο ρυθμίζεται με ακρίβεια χρησιμοποιώντας συγκεκριμένα δεδομένα σετ εκπαίδευσης. Αυτή η φάση λειτουργεί ως σημείο σύγκλισης όπου οι θεμελιώδεις γνώσεις συγκεντρώθηκαν από το τεράστιο σετ μετά την εκπαίδευση και τις εξειδικευμένες αποχρώσεις του νεότερου, μικρότερου συνόλου δεδομένων. Το προκύπτον μοντέλο, επομένως, μπορεί να υπερηφανεύεται για μια εμπλουτισμένη κατανόηση, δίνοντάς του τη δυνατότητα να εγκλιματίζεται γρήγορα σε νέες εργασίες ακόμα και με σπάνιο μέγεθος δείγματος, οδηγώντας πάντα σε βελτιωμένη απόδοση.

Αυτή η σύνθεση μετα-μάθησης και μάθησης μεταφοράς σπάει εμπόδια σε διάφορους επιστημονικούς και τεχνολογικούς τομείς. Είτε είναι η περίπλοκη ύφανση της γλώσσας στην επεξεργασία φυσικής γλώσσας, τα ζωντανά pixels στην όραση υπολογιστή ή οι επιδέξιοι ελιγμοί στη ρομποτική, η μάθηση με μεταφορές φέρνει επανάσταση στον τρόπο με τον οποίο τα μοντέλα προσαρμόζονται και μαθαίνουν.

Μια βαθύτερη βουτιά στη φιλοσοφία του αποκαλύπτει μια αντεπίδραση ενάντια σε μια επικρατούσα πρόκληση. Τα παραδοσιακά βαθιά νευρωνικά δίκτυα (DNN) τείνουν να υπερταϊριάζουν όταν χρειάζονται δεδομένα. Η συμβατική θεραπεία της μετα-μάθησης περιελάμβανε την προσφυγή σε ρητά νευρωνικά δίκτυα (SNN), αλλά αυτό έθεσε σε κίνδυνο το βάθος και την ευρωστία της μαθησιακής διαδικασίας. Η εκμάθηση μετα-μεταφοράς ανακαλύπτει εκ νέου τον τροχό βαθμονομώντας τα DNN για εργασίες αραιών δεδομένων.

7.4. Πλεονεκτήματα

Το Meta-Transfer Learning (MTL) είναι μια πολλά υποσχόμενη προσέγγιση που συνδυάζει τις αρχές τόσο της μετα-μάθησης όσο και της μάθησης μεταφοράς. Ακολουθούν τα κυριότερα πλεονεκτήματα της μεθόδου:

Αξιοποίηση προεκπαιδευμένων μοντέλων: Συχνά, το MTL ξεκινά με μοντέλα που έχουν ήδη εκπαιδευτεί σε μεγάλα σύνολα δεδομένων. Αυτή η προσέγγιση δίνει στα μοντέλα MTL ένα ξεκίνημα, επιτρέποντάς τους να επωφεληθούν από προηγούμενα μοτίβα και γνώσεις.

Ευελιξία ανάμεσα σε διαφορετικά πεδία: Ενώ το μοντέλο ξεκινά με μια τεράστια βάση γνώσεων από το σετ μετά την εκπαίδευση, ο σχεδιασμός του είναι τέτοιος που μπορεί να προσαρμοστεί γρήγορα σε νέες, αφανείς εργασίες, καθιστώντας το ευέλικτο σε πολλούς τομείς όπως το NLP, η όραση υπολογιστή και η ρομποτική .

Αντιμετώπιση υπερπροσαρμογής: Τα βαθιά νευρωνικά δίκτυα (DNN) τείνουν να υπερταυριάζουν όταν εκπαιδεύονται σε εργασίες με περιορισμένα δεδομένα. Το MTL παρέχει μια λύση προσαρμόζοντας τις συναρτήσεις βάρους των DNN για κάθε συγκεκριμένη εργασία. Η ιδέα είναι να γίνουν τα μοντέλα βαθιάς μάθησης προσαρμοστικά σε εργασίες ακόμα και όταν τα δεδομένα είναι σπάνια.

Λειτουργίες κλιμάκωσης και αλλαγής βάρους: Μία από τις αποχρώσεις του MTL είναι η προσαρμογή των DNN μαθαίνοντας να κλιμακώνεται και να μετατοπίζει τις συναρτήσεις βάρους που είναι προσαρμοσμένες για κάθε εργασία.

Εκμετάλλευση κοινών στοιχείων και ιδιαιτεροτήτων: Στον πυρήνα της, η MTL στοχεύει να εκμεταλλευτεί ό,τι είναι κοινό σε πολλαπλές εργασίες και τι είναι συγκεκριμένο για μεμονωμένες εργασίες. Με αυτόν τον τρόπο, διασφαλίζει ότι το μοντέλο δεν ξεκινά από την αρχή για κάθε νέα εργασία, αλλά βασίζεται στη γνώση που έχει συσσωρευτεί από προηγούμενες εργασίες.

Προορατικότητα προς τα αόρατα δεδομένα: Η MTL δεν εστιάζει μόνο στα σημερινά δεδομένα. Η εκπαίδευσή του περιλαμβάνει επίσης δεδομένα που δεν έχει δει, προετοιμάζοντας το μοντέλο για την αντιμετώπιση απρόβλεπτων προκλήσεων σε μελλοντικές εργασίες.

Όφελος από τα αραιά δεδομένα: Ένα από τα ξεχωριστά χαρακτηριστικά του MTL είναι η ικανότητά του να αντλεί σημαντικές πληροφορίες ακόμη και από ελάχιστα δεδομένα. Αξιοποιώντας πληροφορίες από το σύνολο μετά την εκπαίδευση, το μοντέλο μπορεί να κάνει ακριβείς προβλέψεις και αποφάσεις με βάση ένα περιορισμένο νέο σύνολο δεδομένων.

8. Μετα-μάθηση σε διαφορετικά πεδία (Model Agnostic Meta Learning ή MAML)

8.1. Εισαγωγή

Η MAML αναπτύχθηκε από τους Chelsea Finn, Pieter Abbeel και Sergey Levine το 2017 (Finn, 2017). Είναι ένα προηγμένο πλαίσιο μάθησης προσαρμοσμένο για σενάρια μάθησης με λίγα βήματα. "Model-agnostic", υπονοώντας τη συμβατότητά του με οποιοδήποτε μοντέλο εκπαιδευμένο μέσω gradient descent.

Η έννοια της μετα-μάθησης είναι «μαθαίνοντας να μαθαίνω». Αντί για μοντέλα εκπαίδευσης για συγκεκριμένες εργασίες (όπως ταξινόμηση εικόνων ή μετάφραση γλώσσας), η μετα-μάθηση εστιάζει σε μοντέλα εκπαίδευσης για να προσαρμόζεται γρήγορα σε νέες εργασίες με περιορισμένα παραδείγματα. Ο στόχος είναι η γενίκευση από μια εργασία σε πολλαπλές εργασίες, αξιοποιώντας τη γνώση από προηγούμενες μαθησιακές εμπειρίες.

Το MAML μπορεί να εφαρμοστεί σε οποιοδήποτε μοντέλο εκπαίδευσης με gradient descent. Περιλαμβάνει μια σειρά μοντέλων από απλά, όπως γραμμική παλινδρόμηση έως περίπλοκες αρχιτεκτονικές βαθιάς μάθησης. Αυτό το χαρακτηριστικό ενισχύει την ευελιξία του MAML, καθιστώντας το κατάλληλο για διάφορες εργασίες σε διαφορετικούς τομείς.

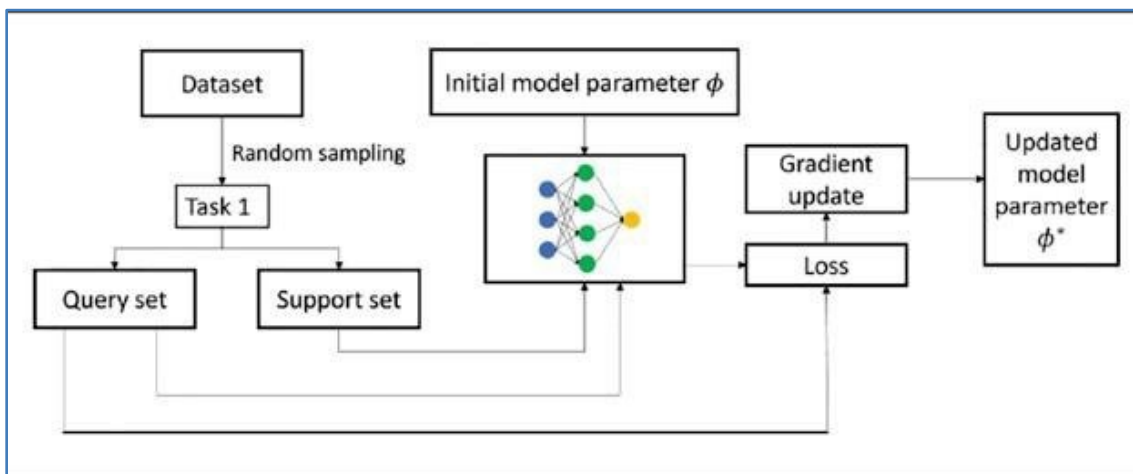
Η MAML δεν στοχεύει άμεσα συγκεκριμένες εργασίες εκμάθησης, αλλά εστιάζει σε μια καλή προετοιμασία των παραμέτρων του μοντέλου για εύκολο και γρήγορο συντονισμό για νέες εργασίες. Λειτουργεί εντός του παραδείγματος μετα-μάθησης, το οποίο δίνει έμφαση στη «μάθηση για μάθηση». Η στρατηγική χρησιμοποιεί γνώσεις από προηγούμενες εργασίες για να επιταχύνει τη διαδικασία μάθησης για νέες εργασίες. Αντί να υπερέχει σε μια μοναδική εργασία, ο στόχος του MAML είναι να εντοπίσει ένα σύνολο παραμέτρων εκκίνησης που μπορούν να συντονιστούν γρήγορα για πολλές νέες εργασίες. Αυτές οι αρχικές παράμετροι χρησιμεύουν ως μια «προηγούμενη» βάση γνώσεων, βοηθώντας το μοντέλο κατά την προσαρμογή σε νέες εργασίες.

Πιθανές εφαρμογές του MAML είναι η ιατρική διαγνωστική και η ρομποτική, όπου μπορεί να μην είναι προσβάσιμα μεγάλα σύνολα δεδομένων και κάθε νέα περίπτωση θα μπορούσε να θεωρηθεί ως ξεχωριστή εργασία. Η ικανότητα αρχικοποίησης παραμέτρων του MAML το καθιστά κατάλληλο για τη μεταφορά γνώσης από μια εργασία σε μια σχετική. Το MAML μπορεί να χρησιμοποιηθεί για να επιτρέψει στους πράκτορες να προσαρμοστούν γρήγορα σε νέα περιβάλλοντα, ενισχύοντας έτσι τόσο τη μαθησιακή απόδοση όσο και τα αποτελέσματα.

Ένα από τα χαρακτηριστικά γνωρίσματα αυτού του αλγορίθμου είναι η έμφαση που δίνει στην αποτελεσματικότητα και την προσαρμοστικότητα. Σε αντίθεση με τις συμβατικές προσεγγίσεις που μπορεί να βασίζονται σε μεγάλο βαθμό σε εκτεταμένα δεδομένα εκπαίδευσης, αυτή η μέθοδος βελτιώνει τις παραμέτρους του μοντέλου έτσι ώστε ακόμη και με λιγοστά δεδομένα εκπαίδευσης και μερικές ενημερώσεις κλίσης, η βελτίωση της απόδοσης είναι απτή.

Κεντρικό στοιχείο αυτής της μεθοδολογίας είναι το μοντέλο, που αναπαρίσταται ως f , που χρησιμεύει ως ο αγωγός μεταξύ των παρατηρήσεων και των αντίστοιχων εξόδων τους. Η ουσία της μετα- μάθησης είναι η έμφυτη ικανότητα αυτού του μοντέλου να εγκλιματίζεται σε μια πληθώρα εργασιών, καθεμία από τις οποίες ορίζεται από τη μοναδική λειτουργία απώλειας, τις παρατηρήσεις, τη δυναμική μετάβασης και τη διάρκεια επεισοδίου.

Η βασική λογική των τροχιών μετα-μάθησης γύρω από μια καθορισμένη κατανομή εργασιών, υποδηλώνεται ως $\rho(T)$. Σε σενάρια όπως η εκμάθηση K -shot, η ικανότητα του μοντέλου αξιολογείται με βάση την ικανότητά του να αφομοιώσει μια νέα εργασία T_i με ακριβώς K δείγματα και η προκύπτουσα ανατροφοδότηση $L T_i$. Η βελτίωση των παραμέτρων του μοντέλου καθοδηγείται από σφάλματα δοκιμών που προέρχονται από νέα δεδομένα εργασιών. Αυτό το σφάλμα, είναι ενδιαφέρον ότι διπλασιάζεται ως ο οδηγός εκπαίδευσης στην επόμενη φάση μετά την εκπαίδευση. Το τέλος του παιχνιδιού; Αξιολογεί πόσο επιδέξια μαθαίνει το μοντέλο K δείγματα που προέρχονται από άγνωστες εργασίες.



Ο μηχανισμός εκπαίδευσης της MAML (https://www.researchgate.net/figure/Illustration-of-Model-Agnostic-Meta-Learning-MAML-algorithm_fig1_368289094).

8.2. Βελτιστοποίηση δύο επιπέδων

Ο μηχανισμός εκπαίδευσης της MAML αποτελείται από δύο ένθετους βρόχους: τον εσωτερικό και τον εξωτερικό.

- Ο εσωτερικός βρόχος εστιάζει στην εκπαίδευση του μοντέλου για μεμονωμένες εργασίες χρησιμοποιώντας ελάχιστα δεδομένα και μέσω gradient descent, με στόχο την ελαχιστοποίηση της απώλειας για αυτήν την εργασία.
- Ο εξωτερικός βρόχος δίνει έμφαση στις παραμέτρους του μοντέλου μετά την εκμάθηση, με βάση την απόδοση από τις ενημερώσεις παραμέτρων του εσωτερικού βρόχου.

Εξωτερικός βρόχος:

- Επικεντρώνεται στη βελτιστοποίηση των αρχικών παραμέτρων (θ) με βάση την απόδοση των παραμέτρων που σχετίζονται με την εργασία σε διάφορες εργασίες.
- Ο στόχος είναι να βελτιστοποιηθούν αυτές οι αρχικές παράμετροι, έτσι ώστε μερικά βήματα κλίσης να μπορούν να οδηγήσουν σε αποτελεσματική απόδοση σε μια νέα εργασία.
- Η έννοια της μετα-απώλειας εισάγεται ως η αντικειμενική συνάρτηση, αντικατοπτρίζοντας την απόδοση του μοντέλου στα αποθηκευμένα δείγματα από μια νέα εργασία.

Εσωτερικός βρόχος:

- Το μοντέλο εκπαιδεύεται σε μεμονωμένες εργασίες, καθεμία από τις οποίες προέρχεται από μια ευρύτερη κατανομή εργασιών.
- Το σημείο εκκίνησης για αυτήν την εκπαίδευση είναι οι αρχικές παράμετροι, που οδηγούν στον σχηματισμό παραμέτρων για συγκεκριμένες εργασίες.
- Για κάθε εργασία του δείγματος, το μοντέλο εκτελεί δύο κύριες λειτουργίες:
 - Υπολογισμός κλίσεων: Η διαβάθμιση της συνάρτησης απώλειας σχετικά με τις παραμέτρους του μοντέλου υπολογίζεται χρησιμοποιώντας το συγκεκριμένο σύνολο δεδομένων της εργασίας.
 - Ενημέρωση παραμέτρων: Η υπολογισμένη κλίση χρησιμοποιείται για την ενημέρωση των παραμέτρων του μοντέλου ειδικά για αυτήν την εργασία μέσω gradient descent. Αυτές οι παράμετροι ονομάζονται παράμετροι για συγκεκριμένες εργασίες.
- Μετά την εκπαίδευση σε ένα περιορισμένο σύνολο παραδειγμάτων από μια νέα εργασία, η απόδοση του μοντέλου αξιολογείται σε ένα ξεχωριστό σύνολο από αυτήν την εργασία.
- Η απώλεια εκπαίδευσης είναι η αντικειμενική συνάρτηση.

Το MAML τονίζει τη σημασία της χρήσης του ίδιου ρυθμού εκμάθησης και για τους δύο βρόχους. Αυτός ο σταθερός ρυθμός εκμάθησης διασφαλίζει ότι το μοντέλο μπορεί να προσαρμοστεί αποτελεσματικά σε νέες εργασίες, ξεκινώντας από τις αρχικές παραμέτρους.

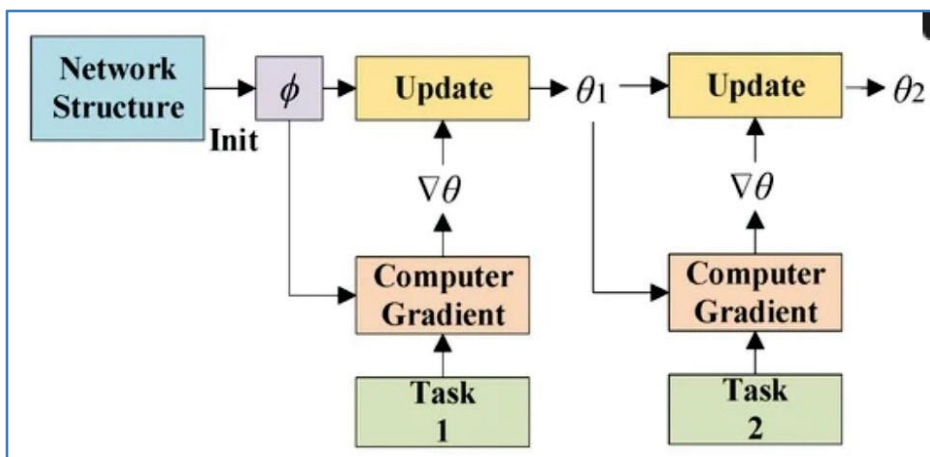
Το MAML χρησιμοποιεί τον ίδιο ρυθμό εκμάθησης τόσο στον εσωτερικό όσο και στον εξωτερικό βρόχο του. Αυτή η συνέπεια είναι ζωτικής σημασίας για την αποτελεσματική προσαρμογή του μοντέλου σε νέες εργασίες ξεκινώντας από τις αρχικές παραμέτρους.

Το MAML είναι εγγενώς ευέλικτο. Ο μετα-μαθητής μπορεί να είναι οποιοδήποτε νευρωνικό δίκτυο που μπορεί να μάθει από δεδομένα εργασιών, ενώ ο αλγόριθμος βελτιστοποίησης του εσωτερικού βρόχου μπορεί να ποικίλλει, π.χ. gradient descent ή Adam.

Ο μετα-μαθητής εκπαιδεύεται χρησιμοποιώντας ένα σύνολο δεδομένων που περιλαμβάνει πολλαπλές εργασίες. Κάθε εργασία έχει ένα περιορισμένο σύνολο παραδειγμάτων εκπαίδευσης και δοκιμών. Ο κύριος στόχος είναι ο μετα-μαθητής να προβλέψει τις βέλτιστες αρχικές παραμέτρους (θ_0) που, όταν τελειοποιηθούν, οδηγούν σε ανώτερη απόδοση στα παραδείγματα δοκιμής μιας εργασίας.

Για μια νέα εργασία, ο μετα-μαθητής παρέχει αρχικές παραμέτρους (θ_0) για να ξεκινήσει το μοντέλο. Στη συνέχεια, το μοντέλο ρυθμίζεται με ακρίβεια χρησιμοποιώντας αυτές τις παραμέτρους στον εσωτερικό βρόχο, με αποτέλεσμα ένα νέο σύνολο παραμέτρων (θ_1) που χρησιμοποιούνται για την αξιολόγηση της απόδοσης στα δείγματα δοκιμής της νέας εργασίας.

Η απώλεια που προκύπτει από την αξιολόγηση του μοντέλου στα παραδείγματα δοκιμής παρέχει ανατροφοδότηση στον μετα-μαθητή. Αυτή η ανατροφοδότηση βελτιώνει τις προβλέψεις του μετα-μαθητή σχετικά με τις καλύτερες αρχικές παραμέτρους (θ_0) για τις επόμενες εργασίες. Με συνεχή εκπαίδευση και ανατροφοδότηση, ο μετα-μαθητής προβλέπει σταδιακά καλύτερες αρχικές παραμέτρους, οδηγώντας σε βελτιωμένη απόδοση σε νέες εργασίες.



Η διαδικασία ενημέρωσης του MAML.

ϕ : παράμετρος του μοντέλου, θ : ενημέρωση μεμονωμένης εργασίας (Liu, 2022.).

8.3. Εφαρμογές

Το Model Agnostic Meta-Learning (MAML) αποτελεί μια μετασχηματιστική προσέγγιση στο απέραντο τοπίο της μηχανικής μάθησης, προσφέροντας απaráμιλλη ευελιξία σε μια μυριάδα εφαρμογών. Με το κεντρικό του δόγμα εστιασμένο στην ταχεία προσαρμογή μοντέλων από ελάχιστα δεδομένα, το MAML εγκαινίασε μια νέα εποχή δυναμικών και προσαρμοσμένων λύσεων εκμάθησης. Στην ουσία, το MAML δεν είναι απλώς ένα άλλο εργαλείο στο κιτ εργαλείων μηχανικής εκμάθησης. Είναι μια προσέγγιση που αναγνωρίζει τη δυναμική φύση των προβλημάτων του πραγματικού κόσμου, προσφέροντας λύσεις που είναι ευκίνητες, προσαρμόσιμες και έτοιμες για τις προκλήσεις του αύριο.

Cybersecurity. Το MAML μπορεί να είναι η εμπροσθοφυλακή έναντι των εξελισσόμενων απειλών στον κυβερνοχώρο. Οι παραδοσιακοί αμυντικοί μηχανισμοί ενδέχεται να παραπαίουν έναντι πρωτοφανών επιθέσεων στον κυβερνοχώρο ή στελέχη κακόβουλου λογισμικού. Τα συστήματα εξοπλισμένα με MAML μπορούν να εξελίσουν την άμυνά τους σε πραγματικό χρόνο, προσαρμόζοντας τις απειλές ακόμη και όταν παρατηρούνται σε ελάχιστες περιπτώσεις.

Μοντελοποίηση του κλίματος. Ο περίπλοκος κόσμος της μοντελοποίησης του κλίματος, γεμάτος με αμέτρητες μεταβλητές και τις αλληλεπιδράσεις τους, πρόκειται να κερδίσει πάρα πολύ από το MAML. Συγκεντρώνοντας πληροφορίες από αραιά σημεία δεδομένων, το MAML θα μπορούσε να βοηθήσει στην πρόβλεψη αποτελεσμάτων από μοναδικά περιβαλλοντικά συμβάντα, ενισχύοντας την ετοιμότητά μας.

Financial Modeling. Στις συνεχώς κυμαινόμενες χρηματοπιστωτικές αγορές, οι δυνατότητες ταχείας προσαρμογής της MAML μπορεί να είναι ανεκτίμητες. Τα μοντέλα εξοπλισμένα με MAML μπορούν να βαθμονομήσουν εκ νέου τις προβλέψεις τους υπό το φως των τάσεων της αναδυόμενης αγοράς, διασφαλίζοντας ότι οι ενδιαφερόμενοι θα παραμείνουν ένα βήμα μπροστά.

Few-Shot Learning. Μία από τις κορυφαίες εφαρμογές της MAML έγκειται στη μάθηση με λίγα δεδομένα, όπου τα μοντέλα εκπαιδεύονται να κατανοούν και να αντιμετωπίζουν νέες εργασίες χρησιμοποιώντας μόνο λίγα παραδείγματα. Ειδικά σε τομείς όπως η αναγνώριση εικόνων, η ανδρεία του MAML λάμπει. Για παράδειγμα, στην ιατρική απεικόνιση, όπου τα άτυπα μοτίβα θα μπορούσαν να εμφανιστούν πέρα από την αρμοδιότητα των δεδομένων εκπαίδευσης, η γρήγορη προσαρμοστικότητα του MAML μπορεί να αλλάξει το παιχνίδι. Προσφέρει πιθανές λύσεις όπου η συγκέντρωση ενός ουσιαστικού σετ εκπαίδευσης δεν είναι εφικτή.

Reinforcement Learning. Στο πλαίσιο της ενισχυτικής μάθησης, οι πράκτορες διαμορφώνουν τις διαδικασίες λήψης αποφάσεων εμπλέκοντας με το περιβάλλον τους. Η προσαρμοστικότητα του MAML σημαίνει ότι οι πράκτορες μπορούν να εγκλιματιστούν γρήγορα σε άγνωστα εδάφη ή σενάρια. Αυτό έχει τεράστιες επιπτώσεις στη ρομποτική, τα παιχνίδια και τις προσομοιώσεις - φανταστείτε έναν ρομποτικό βοηθό που μαθαίνει νέες εργασίες εν κινήσει ή ένα παιχνίδι AI που εξελίσσεται συνεχώς, παρέχοντας στους παίκτες διαρκώς προσαρμοζόμενες προκλήσεις.

Επεξεργασία φυσικής γλώσσας (NLP). Η προσαρμοστικότητα του MAML επεκτείνεται στη σφαίρα του NLP, επιτρέποντας στα μοντέλα να προσαρμόζονται γρήγορα σε διακριτές γλωσσικές αποχρώσεις, διαλέκτους ή μοτίβα επικοινωνίας. Αυτή η γρήγορη επαναβαθμονόμηση μπορεί να φέρει επανάσταση σε τομείς όπως η μηχανική μετάφραση, η ανάλυση συναισθημάτων ή η αναγνώριση φωνής, καθιστώντας τα πιο ικανά παγκοσμίως.

Εξατομικευμένη Φροντίδα Υγείας. Στον τομέα της υγειονομικής περίθαλψης, οι δυνατότητες της MAML είναι τεράστιες. Οραματίζετε σενάρια όπου οι συστάσεις θεραπειών προσαρμόζονται με βάση μεμονωμένες μετρήσεις ασθενών, αποκρυπτογραφημένες από μοντέλα που έχουν μάθει από ελάχιστα δεδομένα. Τέτοιες εφαρμογές υπαινίσσονται την αυγή της πραγματικά εξατομικευμένης ιατρικής.

Προσαρμοσμένες προτάσεις για χρήστες. Η ικανότητα της MAML για γρήγορη μάθηση βρίσκει επίσης απήχηση στα εξατομικευμένα συστήματα συστάσεων. Με την ικανότητά του να αντλεί πληροφορίες από περιορισμένες αλληλεπιδράσεις με τους χρήστες, οι χρήστες μπορούν να απολαμβάνουν περιεχόμενο ή προτάσεις προϊόντων κατά παραγγελία, αυξάνοντας την αφοσίωση και τη συνολική εμπειρία σε πλατφόρμες όπως το ηλεκτρονικό εμπόριο ή η ροή πολυμέσων.

9. Συμπεράσματα

Το παραδοσιακό παράδειγμα της μηχανικής μάθησης βασίζεται σε μεγάλο βαθμό στη διαθεσιμότητα τεράστιων συνόλων δεδομένων, αλλά τι θα γινόταν αν τα μοντέλα μπορούσαν να μιμηθούν ανθρώπινες ικανότητες μάθησης και να αναγνωρίσουν μοτίβα με λίγα μόνο παραδείγματα; Αυτή η έννοια αποτελεί το θεμέλιο της «μάθησης με λίγα δεδομένα», μια αναπτυσσόμενη περιοχή στη μηχανική μάθηση που εστιάζει σε μοντέλα εκπαίδευσης που χρησιμοποιούν περιορισμένα δείγματα.

Η μάθηση με λίγα δεδομένα στοχεύει στην κατασκευή μοντέλων ικανών να ταξινομήσουν νέα αντικείμενα ή εργασίες χρησιμοποιώντας μόνο λίγες περιπτώσεις. Αυτό έρχεται σε αντίθεση με τις συμβατικές προσεγγίσεις που απαιτούν συχνά άφθονο όγκο δεδομένων. Η μέθοδος είναι ιδιαίτερα πλεονεκτική σε σενάρια όπου τα δεδομένα είναι σπάνια ή όπου εμφανίζονται νέες κλάσεις που μπορεί να μην βρίσκονται στο αρχικό σύνολο εκπαίδευσης.

Μέσα στη σφαίρα της μάθησης με λίγα δεδομένα βρίσκεται το "One-Shot Learning", όπου δίνεται στο μοντέλο ένα μεμονωμένο παράδειγμα από κάθε τάξη για να κάνει προβλέψεις. Αυτό διαφέρει από τη "Μηδενική μάθηση" ή τη μηδενική μάθηση, η οποία προκαλεί τα μοντέλα να ταξινομηθούν χωρίς προηγούμενη έκθεση σε δείγματα κατηγορίας στόχου.

Οι βασικοί μηχανισμοί στη μάθηση με λίγα βήματα είναι:

- **Προσεγγίσεις που βασίζονται σε μετρήσεις:** Η ουσία της μάθησης με λίγα δεδομένα συχνά περιστρέφεται γύρω από τον προσδιορισμό της ομοιότητας ή της απόστασης μεταξύ των δειγμάτων. Εδώ, μετρήσεις όπως η Ευκλείδεια απόσταση παίζουν καθοριστικό ρόλο. Ωστόσο, σε περιπτώσεις όπου οι συμβατικές μετρήσεις παραπαίουν, το πεδίο έχει αναπτύξει τεχνικές εκμάθησης μετρήσεων για να χαράξει εξειδικευμένες μετρήσεις προσαρμοσμένες στο πρόβλημα.
- **Στρατηγικές μετα-μάθησης:** Συχνά θεωρούνται ως «μάθηση για μάθηση», τα παραδείγματα μετα-μάθησης χρησιμοποιούνται για την εκπαίδευση μοντέλων στην κατανόηση της ίδιας της ευρύτερης μαθησιακής διαδικασίας. Με αυτόν τον τρόπο, ανοίγουν το δρόμο για τα μοντέλα να προσαρμόζονται γρήγορα σε νέες εργασίες, ακόμη και με ένα αραιό σύνολο παραδειγμάτων.

Τα βασικά πλεονεκτήματα της εκμάθησης Few-Shot:

- **Μίμηση της ανθρώπινης γνώσης:** Μία από τις πιο ενδιαφέρουσες πτυχές είναι η ικανότητά της να κάνει παραλληλισμούς με την ανθρώπινη μάθηση, όπου συχνά αναγνωρίζουμε και προεκτείνουμε μοτίβα από ελάχιστα δεδομένα.
- **Αντιμετώπιση σπάνιων γεγονότων:** Η μάθηση με λίγα δεδομένα είναι ένα όφελος για σενάρια όπου ορισμένα συμβάντα ή μαθήματα είναι σπάνια, διασφαλίζοντας ότι αυτές οι περιπτώσεις δεν θα περάσουν απαρατήρητες ή δεν θα ταξινομηθούν εσφαλμένα.
- **Οικονομική απόδοση:** Με τη μειωμένη ανάγκη για εκτεταμένα δεδομένα, τα έξοδα και οι προσπάθειες που σχετίζονται με την απόκτηση, τον σχολιασμό και την επεξεργασία δεδομένων μειώνονται δραστικά.
- **Εύκολη διαδικασία προετοιμασίας:** Λιγότερα σημεία δεδομένων σημαίνουν εγγενώς ότι τα μοντέλα μπορούν να εκπαιδεύονται με ταχύτερο ρυθμό, αυξάνοντας τη σκοπιμότητά τους για εφαρμογές σε πραγματικό χρόνο.
- **Προσαρμοστικότητα:** Αυτά τα μοντέλα μπορούν να προσαρμόζονται απρόσκοπτα σε νέα δεδομένα ή κατηγορίες, επιδεικνύοντας απaráμιλλη ευελιξία, ειδικά σε συνεχώς εξελισσόμενα περιβάλλοντα.
- **Καινοτομία στις εφαρμογές:** Η δυνατότητα της μάθησης με λίγα δεδομένα εκτείνεται σε μυριάδες τομείς, από την αναγνώριση εικόνας έως την κατανόηση φυσικής γλώσσας και ακόμη και τις ρυθμίσεις ενίσχυσης εκμάθησης.

Πέρα από τις προαναφερθείσες τεχνικές, οι ερευνητές διερευνούν συνεχώς υβριδικά μοντέλα που συνδυάζουν τα δυνατά σημεία τόσο της μετρικής μάθησης όσο και της μετα-μάθησης. Επιπλέον, η ενσωμάτωση της μάθησης μεταφοράς, όπου η γνώση από τον έναν τομέα βοηθά τον άλλον, δοκιμάζεται για να αυξήσει περαιτέρω τις δυνατότητες μάθησης λίγων βολών.

Η εκμάθηση με λίγα δεδομένα σημαίνει μια μεταμορφωτική αλλαγή στη μηχανική μάθηση. Ενσωματώνει την υπόσχεση δημιουργίας μοντέλων που μπορούν να αντλήσουν γνώσεις από περιορισμένα δεδομένα, αντικατοπτρίζοντας μαθησιακά χαρακτηριστικά που μοιάζουν με τον άνθρωπο. Με μεθόδους που βασίζονται σε μετρήσεις που θέτουν τις βάσεις και η μετα-μάθηση ωθεί τα όρια, αυτός ο τομέας είναι έτοιμος να επαναπροσδιορίσει τη νοημοσύνη της μηχανής. Καθώς η έρευνα σε αυτόν τον τομέα συνεχίζει να ανθίζει, το όνειρο της δημιουργίας πραγματικά προσαρμοστικών και ευφυών συστημάτων φαίνεται όλο και πιο εφικτό.

10. Βιβλιογραφία

- Akata Z., F. Perronnin, Z. Harchaoui, and C. Schmid, "Label-embedding for image classification," TPAMI, 2016.
- Bromley Jane, Bentz James W, Bottou Leon, Guyon Isabelle, LeCun Yann, Moore Cliff, Sackinger Eduard, and Shah Roopak. Signature verification using a siamese time delay neural network. International Journal of Pattern Recognition and Artificial Intelligence, 7 (04):669-688, 1993.
- Finn Chelsea, Pieter Abbeel, and Sergey Levine. Model-Agnostic Meta-Learning for Fast Adaptation of Deep Networks. Proceedings of the 34th International Conference on Machine Learning, Sydney, Australia, PMLR 70, 2017.
- Frome A., G. S. Corrado, J. Shlens, S. Bengio, J. Dean, M. A. Ranzato, and T. Mikolov, "Devise: A deep visual-semantic embedding model," in NIPS, 2013, pp. 2121-2129. <https://arxiv.org/abs/1711.06025>
- Koch Gregory, Richard Zemel, and Ruslan Salakhutdinov. Siamese Neural Networks for One-shot Image Recognition. Department of Computer Science, University of Toronto. Toronto, Ontario, Canada, 2015.
- Xiaobo Liu, Wei Teng, Yibing Liu, A Model-Agnostic Meta-Baseline Method for Few-Shot Fault Diagnosis of Wind Turbines, Sensors 2022.
- Muller T., Perez-Torro G., and M. Franco-Salvador. Few-shot learning with siamese networks and label tuning, in ACL, 2022.
- Santoro Adam, Sergey Bartunov, Matthew Botvinick, Daan Wierstra and Timothy Lillicrap. Meta-Learning with Memory-Augmented Neural Networks. Proceedings of the 33 rd International Conference on Machine Learning, New York, NY, USA, 2016.
- Snell Jake, Swersky Kevin and Zemel Richard. Prototypical Networks for Few-shot Learning, <https://arxiv.org/abs/1703.05175v2>, 2017.
- Spyropoulos C. Few Shot Bayesian Meta-Learning, thesis, National Technical University of Athens, 2021
- Sun Qianru, Yaoyao Liu, Tat-Seng Chua and Bernt Schiele. Meta-Transfer Learning for Few-Shot Learning. <https://arxiv.org/abs/1812.02391>, 2018.
- Sung Flood, Yongxin Yang, Li Zhang, Tao Xiang, Torr Philip H.S. and Hospedales Timothy M. Learning to Compare: Relation Network for Few-Shot Learning, 2017.
- Vilalta Ricardo and Youssef Drissi. A Perspective View and Survey of MetaLearning. Hawthorne, NY., 2002.
- inyals Oriol, Charles Blundell, Timothy Lillicrap, Koray Kavukcuoglu, and Daan Wierstra. Matching Networks for One Shot Learning. 30th Conference on Neural Information Processing

Systems (NIPS 2016), Barcelona, Spain.

Wang Yaqing, Quanming Yao, James T. Kwok, and Lionel M. Ni. Generalizing from a Few Examples: A Survey on Few-Shot Learning. *ACM Comput. Surv.* 1, 1, Article 1 (March 2020)