

Ελληνικό Μεσογειακό Πανεπιστήμιο
Πολυτεχνική Σχολή
Τμήμα Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Ηλεκτρονικής, Συστημάτων και Τεχνολογίας Υπολογιστών

Σχήμα ελέγχου για αποφυγή τραυματισμού του ασθενή κατά την διάρκεια τηλεχειριζόμενου (leader-follower) ρομποτικού χειρουργείου, με χρήση Τεχνητής Νοημοσύνης

Διπλωματική Εργασία
της
Μαρία Παπαδοπούλου

Επιβλέπων:
Δρ. Παπαγεωργίου Δημήτριος
Επίκουρος Καθηγητής ΕΛ.ΜΕ.ΠΑ

Σεπτέμβριος 2025



Hellenic Mediterranean University
School of Engineering
Department of Electrical and Computer Engineering
Department of Electronics, Systems and Computer Technology

A control scheme for avoiding iatrogenic harm during a teleoperated (leaderfollower) robotic surgery, utilizing Artificial Intelligence

Diploma Thesis
of

Maria Papadopoulou

Advisor:

Dr. Papageorgiou Dimitrios
Professor HMU

September 2025

Περίληψη

Η ρομποτικά υποβοηθούμενη χειρουργική έχει εισέλθει στην καθημερινότητά μας την τελευταία δεκαετία. Ωστόσο, τα τρέχοντα ρομπότ που χρησιμοποιούνται, δεν προσφέρουν στον χρήστη/χειρουργό την δυνατότητα αίσθησης του περιβάλλοντος (π.χ. μαλακός ιστός) με το οποίο έρχεται σε αλληλεπίδραση, δηλαδή την δυνατότητα απτικής ανάδρασης, ούτε μπορούν να εξασφαλίσουν ή να αποφύγουν πιθανό τραυματισμό του ασθενή κατά τον χειρισμό του συστήματος από τον χειρουργό. Σκοπός της διπλωματικής αυτής είναι ο σχεδιασμός νόμου ελέγχου για σύστημα ρομπότ leader-follower, το οποίο διασφαλίζει πως δεν θα υπάρξει τραυματισμός του μαλακού ιστού (που δεν σχετίζεται με το χειρουργείο) του ασθενή. Προς την επίτευξη αυτού του στόχου, θα μελετηθεί η χρήση Βαθέων Νευρωνικών Δικτύων (Deep Neural Networks) για την αναγνώριση και την ποσοτικοποίηση του τραυματισμού του ιστού σε πραγματικό χρόνο, και έπειτα σχεδιάζεται κατάλληλο σήμα ελέγχου που δρα ως τεχνητή δύναμη/ροπή στην μεριά του χειρούργου, έτσι ώστε να αποφεύγεται η εκτεταμένη βλάβη. Για την επαλήθευση χρησιμοποιούνται δύο ρομπότ UR3 ή/και UR5 του εργαστηρίου, ένα ως leader και ένα ως follower, και τα πειράματα εμπλέκουν τεχνητά/κατασκευασμένα μοντέλα οργάνων του ανθρωπίνου σώματος έχοντας, όσο γίνεται, παρόμοια δυναμικά και γεωμετρικά χαρακτηριστικά με αυτά του ανθρώπου.

Λέξεις-Κλειδιά: Ρομποτικά υποβοηθούμενη ελάχιστα επεμβατική χειρουργική, ρομποτικό σύστημα leader-follower, απτική ανάδραση, βαθιά συνελικτικά νευρωνικά δίκτυα, εκτίμηση παραμόρφωσης μαλακού ιστού, έλεγχος ρομπότ, έλεγχος ενδοτικότητας.

Abstract

Robotic-assisted surgery has entered our daily lives in recent such a decade. However, the current robots in use do not offer the user to/surgeon the ability to feel the environment (e.g. soft tissue) with which he interacts, i.e. the possibility of tactile feedback, nor can they ensure or avoid possible injury to the patient when handling the system by the surgeon. The purpose of this thesis is to design a control law for a robot system leader-follower, which will ensure that there will be no injury to the soft tissue (which is not related to surgery) of the patient. To achieve this goal, it will study the use of Deep Neural Networks (DNN) for the recognition and quantification of tissue injury in real-time, and then an appropriate control signal will be designed that will act as an artificial force/torque on the part of the surgeon, so as to avoid the extensive damage. Two UR3 and/or UR5 robots of the lab will be used for verification, one as a leader and one as a follower, and the experiments will involve artificial/constructed models of human organs having, as far as possible, similar dynamics and geometry characteristics with those of humans.

Keywords: Robotically assisted minimally invasive surgery, leader-follower robotic system, haptic feedback, deep convolutional neural networks, soft tissue deformation estimation, robot control, admittance control.

Ευχαριστίες

Θα ήθελα να εκφράσω τις θερμές μου ευχαριστίες στον επιβλέποντα καθηγητή μου, τον Καθηγητή Δημήτριο Παπαγεωργίου, για την πολύτιμη καθοδήγηση, την υπομονή και τη συνεχή στήριξή του καθ' όλη τη διάρκεια εκπόνησης της διπλωματικής εργασίας.

Επιπλέον, θα ήθελα να ευχαριστήσω για την συνεργασία και τη βοήθεια τους, τον Νίκο Ευσταθόπουλο, υποψήφιο διδάκτορα και την Θεοδώρα Καστρίτση, ερευνήτρια στο Ιταλικό Ινστιτούτο Τεχνολογίας (IIT) στη Γένοβα.

Ιδιαίτερες ευχαριστίες οφείλω στην οικογένειά μου, για την αμέριστη υποστήριξη, ενθάρρυνση και αγάπη τους σε όλη τη διάρκεια των σπουδών μου, καθώς και στους φίλους μου, που στάθηκαν δίπλα μου σε κάθε βήμα.

Τέλος, ευχαριστώ όλους όσους συνέβαλαν άμεσα ή έμμεσα στην ολοκλήρωση αυτής της προσπάθειας, είτε με πρακτική βοήθεια είτε με ηθική στήριξη. Η συμβολή τους υπήρξε πολύτιμη για την επιτυχία της διπλωματικής μου εργασίας.

Πίνακας Περιεχομένων

1 Εισαγωγή **1**
- 1.1 Σκοπός της εργασίας . . . 2
- 1.2 Χειρουργικά Ρομπότ - Da Vinci . . . 2
- 1.3 Τεχνητή νοημοσύνη σε ιατρικές εφαρμογές . . . 6
- 1.4 Περιγραφή του προβλήματος . . . 7
- 1.5 Η καινοτομία της διπλωματικής εργασίας και η συνεισφορά της στην επιστήμη . . . 8
- 1.6 Δομή διπλωματικής εργασίας . . . 10

2 Προτεινόμενη μέθοδος εκτίμησης παραμόρφωσης μέσω τεχνητής νοημοσύνης **11**
- 2.1 Θεωρητικό Υπόβαθρο . . . 12
  - 2.1.1 Τεχνητή Νοημοσύνη και Μηχανική Μάθηση . . . 12
  - 2.1.2 Τι είναι τα νευρωνικά δίκτυα; . . . 13
  - 2.1.3 Η λειτουργία ενός νευρώνα . . . 14
  - 2.1.4 Συνάρτηση Ενεργοποίησης . . . 16
  - 2.1.5 Πολυεπίπεδα τεχνητά νευρωνικά δίκτυα . . . 18
  - 2.1.6 Βαθιά Νευρωνικά Δίκτυα-Deep Neural Networks . . . 20
  - 2.1.7 Εκπαίδευση νευρωνικού δικτύου . . . 21
  - 2.1.8 Αλγόριθμος οπισθοδιάδοσης . . . 24
  - 2.1.9 Βαθιά Συνελικτικά Νευρωνικά Δίκτυα (DCNN) . . . 25
- 2.2 Χρήση βαθιών συνελικτικών νευρωνικών δικτύων στη διπλωματική εργασία . . . 29
  - 2.2.1 Δημιουργία του Συνόλου Δεδομένων . . . 30
  - 2.2.2 Εκπαίδευση του DCNN . . . 33
  - 2.2.3 Αξιολόγηση Αποτελεσμάτων Νευρωνικου Δικτύου (Evaluation) . . . 37

3 Leader-Follower set-up **41**
- 3.1 Ρομποτικό Σύστημα Leader-Follower . . . 41
- 3.2 Θεωρητικό Υπόβαθρο Ρομποτικού Ελέγχου και Σύζευξης Leader-Follower . . . 41
  - 3.2.1 Κινηματικός Έλεγχος Ρομποτικών Βραχιόνων . . . 41
  - 3.2.2 Έλεγχος Ενδοτικότητας - Admittance Control . . . 44
- 3.3 Υλοποίηση Admittance control στον leader ρομποτικό βραχίονα . . . 46
- 3.4 Έλεγχος κίνησης στον follower ρομποτικό βραχίονα . . . 48

4 Σχεδίαση και Υλοποίηση Ολοκληρωμένου Συστήματος Ελέγχου Leader-Follower με Απτική Ανάδραση μέσω DCNN **53**
- 4.1 Πολυνηματική Αρχιτεκτονική . . . 54
- 4.2 Κατάλληλη προετοιμασία της εξόδου του νευρωνικού δικτύου . . . 54
- 4.3 Υπολογισμός εικονικής δύναμης από DCNN . . . 55
  - 4.3.1 Υπολογισμός εκτιμώμενης απόστασης επαφής του εργαλείου . . . 57
- 4.4 Μηχανισμός Διασφάλισης Παθητικότητας μέσω Δεξαμενής Ενέργειας . . . 60
- 4.5 Περιγραφή του ολοκληρωμένου Συστήματος Ελέγχου . . . 62

5 Πειραματική Αξιολόγηση **65**

5.1 Υλοποίηση του συστήματος leader-follower με ρομποτικούς βραχίονες UR3/UR3e . 65
5.2 Πειραματικό set-up του ρομποτικού συστήματος 66
5.3 Πειράματα και Αποτελέσματα 68
5.3.1 Πείραμα 1: Χρήση Σιλικόνης 68
5.3.2 Πείραμα 2: Χρήση Ζελατίνης 71
5.3.3 Πείραμα 3: Κινούμενη τομή 73

6 Συμπεράσματα και Μελλοντική έρευνα **75**

Βιβλιογραφία **79**
Πίνακας Συμβολισμών 82
Πίνακας Συντομογραφιών 83

Λίστα Σχημάτων

1.1 Τα αναφερόμενα μοντέλα Da Vinci 5, Xi και SP 3
1.2 Da Vinci set-up μέσα σε ένα χειρουργείο 4
1.3 Senhance set-up μέσα σε ένα χειρουργείο 5
1.4 EndoTheranostics 5
1.5 Setup leader-follower 8

2.1 Απλό νευρωνικό δίκτυο 14
2.2 Ανατομία απλού νευρώνα 15
2.3 Μαθηματική έκφραση και γραφική βηματικής συνάρτησης 16
2.4 Γράφημα Σιγμοειδούς Συνάρτησης 17
2.5 Γράφημα υπερβολικής εφαπτομένης 17
2.6 Γράφημα συνάρτησης ReLU 18
2.7 Σύγκριση γραφημάτων συνάρτησης ReLU και ELU 18
2.8 Νευρωνικό δίκτυο πολλαπλών στρωμάτων 19
2.9 Deep Neural Network with L layers 20
2.10 Traditional Pattern Recognition 21
2.11 Ιεραρχική εκμάθηση χαρακτηριστικών 21
2.12 Αναπαράσταση του αλγορίθμου καθόδου κλίσης 23
2.13 Παράδειγμα υποπρορσαρμογής, υπερπροσαρμογής και ενός μοντέλου ”σωστού” . . 25
2.14 Η πράξη μίας 2D συνέλιξης της εικόνας I με το φίλτρο K 27
2.15 Συνέλιξη μεταξύ δύο σημάτων 27
2.16 Παράδειγμα max pooling και average pooling 28
2.17 Dropout layer 29
2.18 Παράδειγμα αρχιτεκτονικής βαθιού συνελικτικού δικτύου 29
2.19 Φωτογραφίες, στις οποίες δεν έχει προκληθεί καμία παραμόρφωση στην σιλικόνη . . 30
2.20 Φωτογραφίες, στις οποίες έχει προκληθεί παραμόρφωση της σιλικόνης 31
2.21 Ενδεικτικές εικόνες μετά τη διαδικασία του annotation 32
2.22 Μορφή excel για τα train data, μετά τη διαδικασία του annotation 32
2.23 Μορφή excel για τα test data, μετά τη διαδικασία του annotation 33
2.24 Εικόνα από την εξωτερική κάμερα και το διάνυσμα παραμόρφωσης, που πρέπει να προβλέψει το DCNN 34

2.25 Αρχιτεκτονική του DCNN που επιλέχθηκε για την αναγνώριση της παραμόρφωσης της χειρουργικής τομής 35
2.26 Δύσκολα αναγνωρίσιμες παραμορφώσεις για το νευρωνικό δίκτυο 39

3.1 Η είσοδος και η έξοδος στον έλεγχο ενδοτικότητας και εμπέδησης 45
3.2 Εξήγηση των πλαισίων και των αποστάσεων στους δύο ρομποτικούς βραχίονες . . . 48
3.3 Διανυσματική απεικόνιση της σχέσης $\mathbf{V}_P = \mathbf{V}_O + \boldsymbol{\omega} \times \mathbf{r}$. Η ταχύτητα στο σημείο P προκύπτει από το άθροισμα της ταχύτητας στο σημείο αναφοράς O και της συνιστώσας που οφείλεται στη γωνιακή ταχύτητα $\boldsymbol{\omega}$ και την απόσταση $\mathbf{r}$. 50

4.1 Πίνακας στροφής $\mathbf{R}_{wc}$ και σχήμα διάταξης εργαλείου/κάμερας. 56
4.2 Η εικόνα της κάμερας στο χώρο των εικονοστοιχείων 57
4.3 Γραφική παράσταση της παραμέτρου σ ως προς την απόσταση επαφής επί του εργαλείου 59
4.4 Μπλοκ διάγραμμα του συνολικού συστήματος. 63

5.1 Ρομποτικός βραχίονας Ur3e της universal robots 65
5.2 Experimental setup with the UR3 (follower) and UR3e (leader). 67
5.3 Image from the endoscope camera, i.e. the surgeon's view. 67
5.4 Αποτελέσματα με χρήση σιλικόνης, της εφαρμογής κυρίως δυνάμεων στο άκρο . . . 69
5.5 Αποτελέσματα με χρήση σιλικόνης, της εφαρμογής δυνάμεων και ροπών στο άκρο . 70
5.6 Παραμόρφωση του χειρουργικού εργαλείου χωρίς τη χρήση της προτεινόμενης μεθόδου 71
5.7 Πείραμα με ζελατίνη 72
5.8 Βλάβη της ζελατίνης με και χωρίς τον προτεινόμενο ελεγκτή. 72
5.9 Σύγκριση της εκτίμησης παραμόρφωσης ($\|\mathbf{p}_2 - \mathbf{p}_1\|$) με την απόσταση του σημείου επαφής από το κέντρο του δίσκου ($\|\mathbf{p}_c - \mathbf{p}_{c0}\|$), με τον δίσκο ζελατίνης. 73
5.10 Πείραμα κινούμενης τομής. 74

Λίστα Πινάκων

2.1 Συναρτήσεις ενεργοποίησης με τις παραγώγους τους 18

4.1 Υπολογισμός της παραμέτρου σ βάσει της θέσης του εργαλείου στην εικόνα 58
4.2 Σύγκριση τιμών μεταξύ δύο προσεγγίσεων απόστασης επαφής (σε μέτρα) 59

Κεφάλαιο 1

Εισαγωγή

Τα τελευταία χρόνια, η ραγδαία ανάπτυξη της τεχνολογίας έχει επιφέρει σημαντικές αλλαγές σε πολλούς τομείς της ανθρώπινης δραστηριότητας και της επιστήμης. Ένας από τους σημαντικότερους είναι η ιατρική, στην οποία έχουν ενσωματωθεί προηγμένες τεχνολογικές λύσεις, όπως τα ευφυή συστήματα, η τεχνητή νοημοσύνη, η μηχανική μάθηση και η ρομποτική. Τα συστήματα αυτά επιτρέπουν την αυτοματοποίηση πολύπλοκων διαδικασιών, την επεξεργασία μεγάλων όγκων ιατρικών δεδομένων και τη γενικότερη διευκόλυνση των ιατρών και των χειρουργών, αυξάνοντας την ακρίβεια και μειώνοντας το περιθώριο σφάλματος. Έτσι, πλέον η τεχνολογία έχει συμβάλλει καθοριστικά όχι μόνο στη βελτίωση της διάγνωσης και της θεραπείας, αλλά και στη συνολική ποιότητα φροντίδας των ασθενών, ενισχύοντας την εξατομικευμένη προσέγγιση και μειώνοντας τον χρόνο νοσηλείας. Η αλματώδης πρόοδος της ρομποτικής έχει καταστήσει πλέον δυνατή την ενσωμάτωση της Ρομποτικά Υποβοηθούμενης Ελάχιστα Επεμβατικής Χειρουργικής (Robotic-Assisted Minimally Invasive Surgery/RAMIS) στην κλινική πράξη, μετασχηματίζοντας ριζικά τον τρόπο διεξαγωγής επεμβάσεων υψηλής ακρίβειας.

Η RAMIS επιτρέπει την εκτέλεση επεμβάσεων με εξαιρετική ακρίβεια, προσφέροντας στους χειρουργούς βελτιωμένη εργονομία, μεγαλύτερη σταθερότητα και έλεγχο στις κινήσεις, σε σύγκριση με τις παραδοσιακές χειρουργικές μεθόδους. Παράλληλα, έχει αναδειχθεί ως μία από τις πιο καινοτόμες τεχνολογικές εξελίξεις στον χώρο της ιατρικής, καθώς επιτρέπει την πραγματοποίηση επεμβάσεων μέσω μικρών χειρουργικών τομών στο σώμα. Αυτό μεταφράζεται σε μικρότερο χρόνο ανάρρωσης για τον ασθενή, μειωμένη πιθανότητα μόλυνσης και σημαντική μείωση του μετεγχειρητικού πόνου και της απώλειας αίματος. Επιπλέον, συμβάλλει ουσιαστικά στη μείωση της σωματικής κόπωσης του χειρουργού και ταυτόχρονα της πιθανότητας κάποιου λάθους, ενώ παράλληλα του παρέχει διευρυμένο και λεπτομερές οπτικό πεδίο, μεγαλύτερη ευχέρεια κινήσεων και ακρίβεια, διευκολύνοντας την ομαλή και αποτελεσματική εξέλιξη της επέμβασης.

Βασική πρόκληση στη RAMIS είναι η απουσία άμεσης ορατότητας και απτικής αντίληψης της περιοχής γύρω από τη χειρουργική τομή. Ο χειρουργός βλέπει, συνήθως, μόνο το εσωτερικό του σώματος και τις κινήσεις που εκτελεί σε αυτό, μέσω μιας ενδοσκοπικής κάμερας, η οποία προβάλλει μία 3D στερεοσκοπικής εικόνας [6], χωρίς να βλέπει άμεσα την κατάσταση που βρίσκεται η τομή. Με αυτόν τον τρόπο, δεν έχει πρόσβαση σε πληροφορίες για το αν το χειρουργικό εργαλείο, που εισέρχεται στο σώμα μέσω μίας μικρής τομής, την πιέζει υπερβολικά, είτε κατά την είσοδο του σε αυτήν, είτε κατά τη διάρκεια του χειρουργείου, προκαλώντας, έτσι, κάποιον τραυματισμό. Ειδικά σε δυναμικά περιβάλλοντα, όπως η ανθρώπινη κοιλιακή χώρα, όπου η κίνηση της τομής επηρεάζεται από την αναπνοή, τους καρδιακούς παλμούς ή ακούσιες μυϊκές συσπάσεις, ο έλεγχος της θέσης και της δύναμης που ασκείται στην τομή απαιτεί αυξημένη προσοχή και τεχνολογική υποστήριξη. Αυτό το πρόβλημα προσπαθεί να λύσει αυτή η εργασία προτείνοντας κάτι καινοτόμο και εντάσσοντας την απτική ανάδραση σε συνδυασμό με την τεχνητή νοημοσύνη στη RAMIS.

Η απτική ανάδραση (haptic feedback) αναφέρεται στην παροχή πληροφορίας μέσω της αίσθησης της αφής και της δύναμης. Στα πλαίσια της χειρουργικής, η αίσθηση της δύναμης που ασκείται σε

ιστούς επιτρέπει στον χειρουργό να διακρίνει μεταξύ διαφορετικών τύπων ιστών, να εκτιμά την πίεση που εφαρμόζει και να αποφεύγει ακούσιους τραυματισμούς. Η ενσωμάτωση απτικής ανάδρασης σε ρομποτικά συστήματα θεωρείται καθοριστικής σημασίας για την ασφάλεια και την αποτελεσματικότητα των επεμβάσεων.

Στη RAMIS συνήθως χρησιμοποιείται ένα σύστημα τηλεχειρισμού (teleoperation), στο οποίο υπάρχουν δύο ρομπότ leader-follower, όπου τον leader τον χειρίζεται ο χειρουργός και ο follower είναι δίπλα στον ασθενή και εκτελεί τις κινήσεις, κάνοντας την επέμβαση. Αντίστοιχα, στην συγκεκριμένη εργασία επιλέχθηκε να χρησιμοποιηθεί αυτό το ρομποτικό σύστημα.

1.1 Σκοπός της εργασίας

Η παρούσα διπλωματική εργασία εντάσσεται στο πλαίσιο της RAMIS, και έχει ως κύριο στόχο τον σχεδιασμό ενός ευφυούς νόμου ελέγχου για ρομποτικό σύστημα τύπου leader-follower, ο οποίος επιτρέπει την ασφαλή εκτέλεση χειρουργικών επεμβάσεων, αποτρέποντας την πρόκληση τραυματισμών στους μαλακούς ιστούς γύρω από τη χειρουργική τομή. Μέσα από τη συνδυαστική αξιοποίηση οπτικών δεδομένων και της τεχνητής νοημοσύνης (AI), η μέθοδος αυτή ανιχνεύει σε πραγματικό χρόνο την παραμόρφωση των μαλακών ιστών γύρω από τη χειρουργική τομή. Συγκεκριμένα, χρησιμοποιείται ένα Βαθύ Συνελικτικό Νευρωνικό Δίκτυο (Deep Convolutional Neural Network – DCNN), το οποίο λαμβάνει τις οπτικές πληροφορίες μέσω μίας κάμερας, τοποθετημένη στον καρπό του follower και εντοπίζει έγκαιρα τις ενδείξεις υπερβολικής πίεσης που μπορεί να ασκηθεί, προτού αυτή οδηγήσει σε τραυματισμό ιστών.

Τα αποτελέσματα του DCNN τροφοδοτούνται άμεσα σε απτική ανάδραση στον βραχίονα leader, με τη μορφή διακριτικών, κατευθυντικών ωθήσεων. Με αυτόν τον τρόπο, ο χειρουργός λαμβάνει μία αίσθηση αντίστασης/καθοδήγησης, χωρίς να αποσπάται από την οπτική εικόνα της επέμβασης, διατηρώντας πλήρως τον έλεγχο και αποτρέποντας κινήσεις που ενδέχεται να οδηγήσουν σε βλάβη των ιστών.

Μία ακόμα σημαντική συνιστώσα της εργασίας αφορά τον σχεδιασμό ενός νόμου ελέγχου που καθιστά δυνατή τη χρήση του μηχανισμού σε συμβατικά, γενικής χρήσης ρομποτικά συστήματα, χωρίς την ανάγκη υλοποίησης ειδικών μηχανικών περιορισμών τύπου RCM (Remote Center of Motion). Αυτό επιτρέπει την ευρύτερη εφαρμογή της προτεινόμενης μεθόδου, ακόμη και σε περιβάλλοντα προσομοίωσης ή σε ιατρικές εκπαιδεύσεις, χωρίς την απαίτηση ακριβού εξοπλισμού. Επιπλέον, η παρούσα μελέτη λαμβάνει υπόψη της την κίνηση που μπορεί να υπάρξει στην τομή, λόγω αναπνοής, καρδιακού παλμού κλπ, και χρησιμοποιεί απευθείας τα οπτικά δεδομένα για τη λήψη αποφάσεων σε πραγματικό χρόνο.

Συνολικά, λοιπόν, ο σκοπός της εργασίας είναι ο σχεδιασμός μιας μεθόδου που διασφαλίζει την αποφυγή των επικίνδυνων και επιβλαβών καταπονήσεων στους ιστούς γύρω από τη χειρουργική τομή του ασθενούς, ώστε να αποτρέπεται οποιαδήποτε περαιτέρω βλάβη ή διεύρυνση του ανοίγματος της τομής.

1.2 Χειρουργικά Ρομπότ - Da Vinci

Η ρομποτικά υποβοηθούμενη χειρουργική έχει καθιερωθεί ως μια από τις πλέον προηγμένες τεχνολογικές εφαρμογές στην ιατρική πράξη, προσφέροντας στον χειρουργό εργαλεία υψηλής ακρίβειας και σταθερότητας. Το ρομποτικό σύστημα da Vinci (Intuitive Surgical Inc., Sunnyvale, CA, USA), που διατίθεται εμπορικά από το 2001, αποτελεί το πλέον διαδεδομένο σύστημα ρομποτικής χειρουργικής παγκοσμίως. Έχει εξελιχθεί μέσα από τρεις γενιές σχεδίασης, με πιο σύγχρονο μοντέλο το da Vinci 5 (βλ. εικόνα 1.1), και μέχρι σήμερα έχει χρησιμοποιηθεί σε περισσότερα από 10 εκατομμύρια χειρουργεία, καλύπτοντας πέντε διαφορετικές ιατρικές ειδικότητες. Μερικά ακόμα διαθέσιμα μοντέλα είναι το Si, X, Xi, SP. Συγκεκριμένα, το da Vinci 5 διαθέτει υπολογιστική ισχύ 10.000 φορές μεγαλύτερη

από το da Vinci Xi, προσφέροντας περισσότερη αυτονομία στον χειρουργό και εξελιγμένη ανάλυση δεδομένων μεταξύ άλλων. Από την άλλη πλευρά, το Da Vinci X αποτελεί μια πιο οικονομική επιλογή με βασικές λειτουργίες, διατηρώντας όμως την ίδια αρχιτεκτονική των βραχιόνων και της τεχνολογία όρασης με το Xi. Τέλος, το da Vinci SP έχει σχεδιαστεί αποκλειστικά για επεμβάσεις μέσω μόνο μίας χειρουργικής τομής, χρησιμοποιώντας έναν ρομποτικό βραχίονα που φέρει τρία ευέλικτα εργαλεία και μία κάμερα υψηλής ευκρίνειας 3D.



(α□) Da Vinci 5 (β□) Da Vinci Xi (γ□) Da Vinci SP

Σχήμα 1.1: Τα αναφερόμενα μοντέλα Da Vinci 5, Xi και SP
[12]

Η διείσδυσή του da Vinci στην κλινική πράξη είναι εντυπωσιακή· ενδεικτικά, το 85% των προστατεκτομών πλέον πραγματοποιούνται ρομποτικά, ενώ ο αριθμός των ρομποτικών υστερεκτομών έχει αυξηθεί κατά 300% την τελευταία δεκαετία [27]. Το σύστημα παρέχει στους χειρουργούς τη δυνατότητα να εκτελούν σύνθετες και ακριβείς κινήσεις μέσω ρομποτικών βραχιόνων με επτά βαθμούς ελευθερίας, εξασφαλίζοντας βελτιωμένα μετεγχειρητικά αποτελέσματα, όπως μειωμένη απώλεια αίματος, συντομότερη παραμονή στο νοσοκομείο και μειωμένη κατανάλωση αναλγητικών. Ο χειρισμός γίνεται μέσω τηλεχειρισμού από κονσόλα υψηλής εργονομίας, ενώ η παρακολούθηση της επέμβασης γίνεται μέσω τρισδιάστατης κάμερας υψηλής ευκρίνειας.

Ένα επιπλέον χαρακτηριστικό του συστήματος είναι η δυνατότητα διπλής χειρουργικής κονσόλας, η οποία επιτρέπει τη συμμετοχή δύο χειρουργών ταυτόχρονα. Η λειτουργία αυτή αξιοποιείται κυρίως για σκοπούς εκπαίδευσης, καθώς επιτρέπει στους ειδικευόμενους να συμμετέχουν ενεργά στην επέμβαση υπό την καθοδήγηση έμπειρων χειρουργών, ενισχύοντας έτσι την πρακτική τους εξάσκηση σε πραγματικό περιβάλλον. Μάλιστα, σε πολλές ιατρικές σχολές και νοσοκομεία έχουν ήδη ενταχθεί στην εκπαίδευση τα ρομποτικά χειρουργικά συστήματα στα προγράμματα σπουδών τους.

Παρά τη σημαντική του επιτυχία και ευρεία αποδοχή, το σύστημα da Vinci παρουσιάζει ορισμένους εγγενείς περιορισμούς. Ένας από τους βασικότερους είναι η απουσία απτικής ανάδρασης (haptic feedback), περιορίζοντας την απτική επίγνωση του χειρουργού κατά τη διάρκεια της επέμβασης. Επιπλέον, η μεγάλη φυσική διάσταση της ρομποτικής πλατφόρμας, καθώς και το υψηλό κόστος απόκτησης (άνω του $1,5 εκατομμυρίου δολαρίων), αποτελούν ανασταλτικούς παράγοντες για την υιοθέτησή του από μικρότερα ή περιφερειακά νοσοκομεία με περιορισμένους πόρους. Έτσι, άνοιξε ο δρόμος για την ανάπτυξη νέων ανταγωνιστικών ρομποτικών συστημάτων, τα οποία εστιάζουν στη μείωση κόστους, στην ευελιξία και στην ενσωμάτωση τεχνολογικών καινοτομιών.

Ένα άλλο ρομποτικό σύστημα, είναι το Senhance, το οποίο αναπτύχθηκε από την εταιρεία Asensus



Σχήμα 1.2: Da Vinci set-up μέσα σε ένα χειρουργείο
[11]

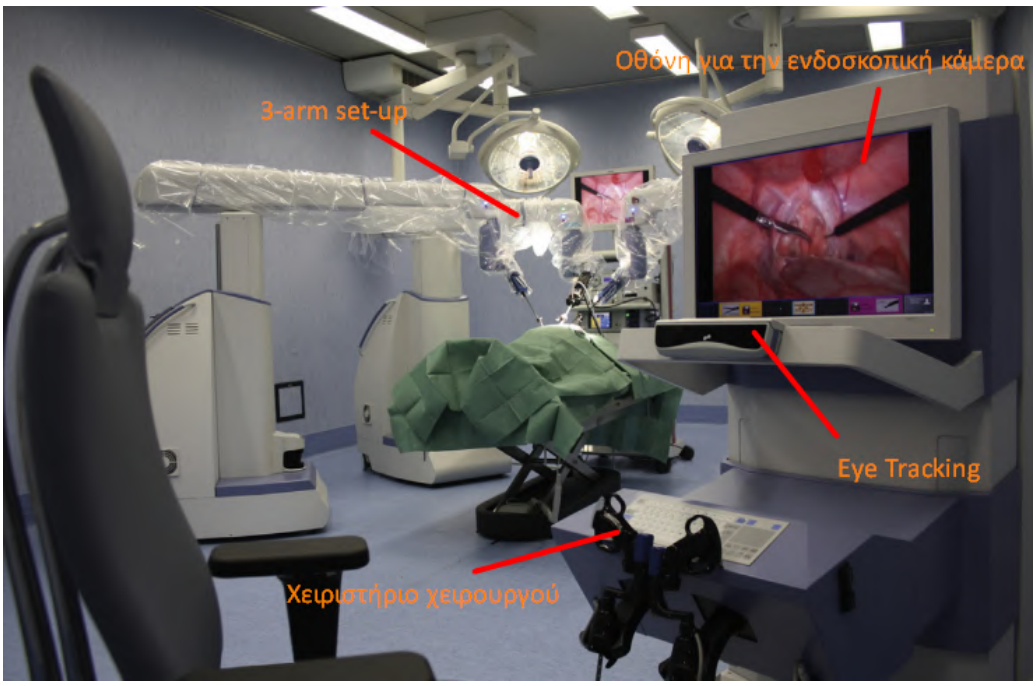
Surgical [4] (πρώην TransEnterix), και αποτελεί μια ανερχόμενη λύση στον χώρο της ρομποτικά υποβοηθούμενης λαπαροσκοπικής χειρουργικής. Ένα από τα πιο καινοτόμα χαρακτηριστικά του συστήματος είναι η ενσωμάτωση απτικής ανάδρασης (haptic feedback), ενισχύοντας την ασφάλεια και την ακρίβεια κατά την επέμβαση. Παράλληλα, χρησιμοποιείται η τεχνολογία eye-tracking, επιτρέποντας τον έλεγχο της ενδοσκοπικής κάμερας μέσω μόνο της κατεύθυνσης του βλέμματος του χειρουργού, προσφέροντας εργονομία και διαισθητική αλληλεπίδραση. Επιπλέον, τα εργαλεία του συστήματος είναι μικρής διαμέτρου (3mm και 5mm), επιτρέποντας χειρισμούς με ελάχιστο τραυματισμό των ιστών και καλύτερο αισθητικό αποτέλεσμα.

Το Senhance είναι σχεδιασμένο ώστε να είναι συμβατό με υπάρχουσες χειρουργικές υποδομές, αξιοποιώντας τυπικές χειρουργικές αίθουσες χωρίς την ανάγκη ριζικών τροποποιήσεων. Επιπλέον, χρησιμοποιεί επαναχρησιμοποιούμενα εργαλεία, κάτι που μειώνει το λειτουργικό κόστος ανά επέμβαση, καθιστώντας το ιδανικό για νοσοκομεία με περιορισμένους πόρους.

Παρότι το Senhance αποτελεί σχετικά νέο σύστημα στην αγορά, έχει ήδη αρχίσει να χρησιμοποιείται σε διάφορες ειδικότητες και διάφορα πρώιμα κλινικά δεδομένα δείχνουν ότι μπορεί να χρησιμοποιηθεί με ασφάλεια για την αποτελεσματική αντιμετώπιση του καρκίνου του παχέος εντέρου. Ωστόσο, για την πλήρη καθιέρωσή του στην ιατρική πρακτική, απαιτείται περαιτέρω μακροχρόνια αξιολόγηση, συγκριτικές μελέτες και επέκταση της κλινικής εμπειρίας σε ευρύτερο φάσμα επεμβάσεων και πληθυσμών.

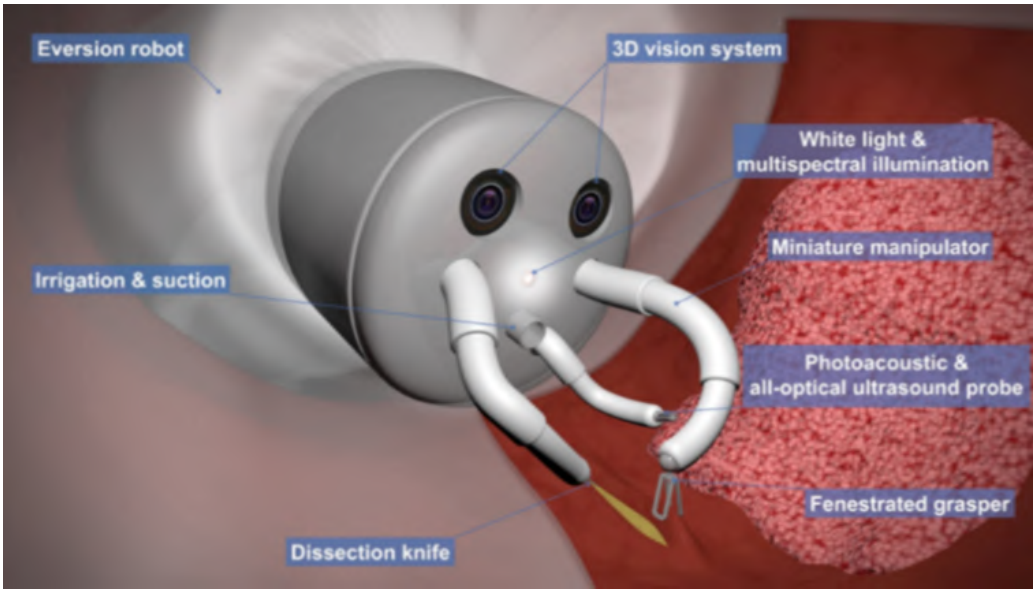
Ο καρκίνος του παχέος εντέρου (CRC) είναι πολύ συχνός και επικίνδυνος, διότι συνήθως εντοπίζεται όταν είναι ήδη σε προχωρημένο στάδιο. Έτσι, και οι επεμβάσεις γίνονται όταν η ασθένεια είναι ήδη προχωρημένη, κάτι που μειώνει την επιβίωση των ασθενών. Οπότε, έχουν γίνει πολλές προσπάθειες στην ρομποτική χειρουργική για αυτό του είδους του καρκίνου. Ένα καινοτόμο σύστημα για τη διάγνωση και τη θεραπεία του καρκίνου του παχέος εντέρου αποτελεί το EndoTheranostics (therapy + diagnostics), το οποίο σχεδιάστηκε από τους Bruno Siciliano, Sébastien Ourselin, Kaspar Althoefer και Alberto Arezzo [3].

Πρόκειται για ένα ρομπότ με μαλακή άκρη που «ξετυλίγεται» ή αναστρέφεται και η δομή του μοιάζει με «μανίκι» (sleeve-like). Πραγματοποιεί τη διάγνωση μέσω μιας πιο άνετης και τεχνολογικά εξελιγμένης μορφής κολονοσκόπησης, χρησιμοποιώντας αισθητήρες και κάμερες, καθώς και τεχνητή νοημοσύνη, με σκοπό να αξιολογεί τους ιστούς και να αναγνωρίζει σε πραγματικό χρόνο την τυχόν ύπαρξη πολυπόδων (βλάβη, η οποία αναπτύσσεται στο εσωτερικό του παχέος εντέρου και μπορεί να



Σχήμα 1.3: Senhance set-up μέσα σε ένα χειρουργείο
[25]

εξελιχθεί σε καρκίνο). Έπειτα, σε περίπτωση εμφάνισης πολυπόδων, στοχεύει στην αποτελεσματική αφαίρεση τους με τη βοήθεια μικροσκοπικών ρομποτικών εργαλείων που μεταφέρονται στο σημείο μέσα από το εσωτερικό του ρομπότ. Ο συνεργατικός έλεγχος (shared control) του ρομπότ και των εργαλείων, επιτρέπουν την ασφαλή και ακριβή εκτομή των πολυπόδων, χωρίς να χρειάζεται χειρουργική τομή.



Σχήμα 1.4: EndoTheranostics
[3]

Η ρομποτική χειρουργική επεκτείνεται σταδιακά και σε άλλους τομείς της ιατρικής. Στον τομέα της νευροχειρουργικής, αξιοποιείται για την εκτέλεση βιοψιών εγκεφαλικών όγκων υπό την καθοδήγηση της μαγνητικής τομογραφίας, καθώς και για μικροχειρουργικές εκτομές. Επιβλεπόμενα ρομποτικά συστήματα, όπως το SpineAssist και το Renaissance, χρησιμοποιούνται πλέον ευρέως σε

επεμβάσεις της σπονδυλικής στήλης, προσφέροντας αυξημένη ακρίβεια και βελτιώνοντας την ασφάλεια της διαδικασίας. Επίσης, υπάρχουν εξειδικευμένα ρομποτικά συστήματα, όπως το Evolution 1 της Universal Robot Systems, τα οποία είναι σχεδιασμένα για την πραγματοποίηση ενδοσκοπικών επεμβάσεων στον εγκέφαλο [23].

1.3 Τεχνητή νοημοσύνη σε ιατρικές εφαρμογές

Η εξέλιξη της τεχνολογίας έχει ανοίξει νέους ορίζοντες στον τομέα της ιατρικής, με την τεχνητή νοημοσύνη (AI) να βρίσκεται στο επίκεντρο αυτής. Η τεχνητή νοημοσύνη μπορεί να οριστεί ως η ικανότητα ενός υπολογιστικού συστήματος να προσομοιώνει ανθρώπινες νοητικές διαδικασίες, όπως η μάθηση, η επίλυση προβλημάτων και η λήψη αποφάσεων. Η εφαρμογή της στην ιατρική δεν περιορίζεται πλέον μόνο στη θεωρία ή σε μεμονωμένα ερευνητικά έργα, αλλά υλοποιείται σε πραγματικές συνθήκες, επηρεάζοντας τον τρόπο διάγνωσης, πρόληψης, περίθαλψης και θεραπείας ασθενειών. Με αυτόν τον τρόπο υπερισχύει των παραδοσιακών μεθόδων, δίνοντας μία νέα προοπτική στη φροντίδα υγείας.

Στη διάγνωση, συστήματα τεχνητής όρασης (π.χ. βαθιά νευρωνικά δίκτυα) χρησιμοποιούνται ευρέως για την ανάλυση ιατρικών απεικονίσεων. Συγκεκριμένα, χρησιμοποιούνται τεχνικές μηχανικής μάθησης και τα συστήματα αυτά εκπαιδεύονται στο να αναγνωρίζουν χαρακτηριστικά παθήσεων (π.χ. όγκους) με μεγάλη ακρίβεια και κάποιες φορές καλύτερη από τους ιατρούς. Για παράδειγμα, σε ακτινολογικές εξετάσεις, οι αλγόριθμοι βαθιάς μάθησης έχουν εξαιρετικά αποτελέσματα στην ανίχνευση πνευμονίας από ακτινογραφίες θώρακα ή στη διάγνωση καρκίνου του μαστού από μαστογραφίες, καθιστώντας τα ως υποστηρικτικά εργαλεία για τον ακτινολόγο. Πέραν της απεικόνισης, το AI συμβάλλει, επίσης, στην πρόγνωση και τη διαχείριση ασθενειών. Υπάρχουν διάφορα προγνωστικά μοντέλα, τα οποία συνδυάζουν κλινικά δεδομένα, γενετικές πληροφορίες και πρώιμα σημεία νόσησης για να εκτιμήσουν τον κίνδυνο εμφάνισης ή επιδείνωσης ενός νοσήματος. Ιδίως στην καρδιολογία, προγράμματα AI αναλύουν εικόνες αγγείων ή ηλεκτροκαρδιογραφήματα, προβλέποντας την πιθανότητα μελλοντικής καρδιαγγειακής νόσου. Αντίστοιχα, στην ογκολογία μελέτες δείχνουν ότι συστήματα AI μπορούν να αναγνωρίζουν γονιδιακούς δείκτες, οι οποίοι συνδέονται με επικίνδυνες εξελίξεις των όγκων. Με αυτόν τον τρόπο, ενισχύεται η εξατομικευμένη ιατρική, ιδιαίτερα στον καρκίνο, όπου αναλύονται τα γενετικά προφίλ των ασθενών και σχεδιάζονται εξατομικευμένα θεραπευτικά πλάνα γι' αυτούς. Κάποια παραδείγματα ανά ειδικότητα της χρήσης της τεχνητής νοημοσύνης είναι:

Στην καρδιολογία, σημαντική εξέλιξη υπάρχει στη μελέτη ηλεκτροκαρδιογραφημάτων (ECG) με AI. Συγκεκριμένα, δοκιμές του Mayo Clinic έχουν δείξει ότι η εφαρμογή νευρωνικών δικτύων σε απλά, φαινομενικά φυσιολογικά ΗΚΓ μπορεί να αποκαλύψει πρώιμα ενδείξεις κολπικής μαρμαρυγής ή να διαγνωστεί υποκείμενη μυοκαρδιοπάθεια (π.χ. καρδιομυοπάθεια) πολύ νωρίτερα από ότι θα μπορούσε το ανθρώπινο μάτι [14]. Σε μία τέτοια μελέτη, το μοντέλο AI κατέταξε ασθενείς σε κατηγορίες κινδύνου βάσει του ΗΚΓ και διαπιστώθηκε ότι η ομάδα υψηλού κινδύνου είχε όντως σημαντικά μεγαλύτερη πιθανότητα εμφάνισης κολπικής μαρμαρυγής σε σύγκριση με την παραδοσιακή κλινική αξιολόγηση. Επιπλέον, η ικανότητα του AI να εντοπίζει υποκείμενες καρδιομυοπάθειες, μέσω μοτίβων στο ΗΚΓ που είναι δυσδιάκριτα για τον άνθρωπο, ανοίγει νέους δρόμους για την πρώιμη διάγνωση και τη στοχευμένη παρακολούθηση ασθενών.

Στην ακτινολογία, όπως αναφέρθηκε, οι αλγόριθμοι βαθιάς μάθησης αυτοματοποιούν εργασίες ανάλυσης εικόνας, προσδίδοντας ποσοτικές μετρήσεις και άλλα, που συχνά απουσιάζουν από την παραδοσιακή αναφορά του ακτινολόγου. Χαρακτηριστικά, βελτιώνουν ανίχνευση παθήσεων στον πνεύμονα, στη μαστογραφία, στην αξονική και μαγνητική τομογραφία, μειώνοντας το φόρτο εργασίας και αυξάνοντας τη συνέπεια. Εξαιτίας της ικανότητας αυτοματοποίησης σύνθετων αποκομμάτων εικόνας (segmentation) και αναγνώρισης όγκων, ορισμένοι όροι όπως υπολογιστική ακτινολογία (Computational Radiology) έχουν ήδη εισαχθεί στη βιοϊατρική.

Η ρομποτική χειρουργική, όπως είδαμε στο προηγούμενο κεφάλαιο και όπως διαπιστώνουμε σε

αυτή την εργασία, έχει επίσης ενισχυθεί από την τεχνητή νοημοσύνη, προσφέροντας ακρίβεια και ελαχιστοποίηση των ιατρικών σφαλμάτων. Η ενσωμάτωση της AI στη ρομποτική χειρουργική επιτρέπει την αυτοματοποίηση χειρουργικών εργασιών και την ενίσχυση της ασφάλειας κατά τη διάρκεια των επεμβάσεων. Συνήθως στη ρομποτική χειρουργική χρησιμοποιείται σε συστήματα ελέγχου ρομπότ και στην ανάλυση εικόνων σε πραγματικό χρόνο. Τέτοια ρομποτικά συστήματα έχουν αναλυθεί στο προηγούμενο κεφάλαιο. Παρ' όλα αυτά, έχει χρησιμοποιηθεί η τεχνητή νοημοσύνη από το Watson, το οποίο σχεδίασε η IBM και αποτελεί έναν "έξυπνο χειρουργικό βοηθό", ικανό να ανακτά πληροφορίες από τεράστιες βάσεις δεδομένων και ιατρική βιβλιογραφία, ώστε να απαντά γρήγορα σε ερωτήματα χειρουργών κατά τη διάρκεια μιας επέμβασης [10]. Ωστόσο, είναι σημαντικό να τονιστεί ότι τέτοια συστήματα απαιτούν συνεχή αξιολόγηση· π.χ. το Watson for Oncology κρίθηκε ότι απαντάει μεροληπτικά προς πρότυπα αμερικανικών κέντρων, οδηγώντας τελικά στην απόσυρσή του. Επίσης, είναι σημαντικό να τονιστεί ότι ακόμα η πλήρης αυτονομία παραμένει σε αρχικό στάδιο· μέχρι στιγμής τα ρομπότ λειτουργούν ως επεκτάσεις των ικανοτήτων του χειρουργού, ενώ η «εποπτευόμενη» αυτοματοποίηση (supervised autonomy) όπως στο STAR, το οποίο έκανε συρραφή εντέρου, χωρίς καμία παρέμβαση, αποτελεί μία εξαίρεση υψηλού βαθμού πολυπλοκότητας.

Συνολικά, τα θετικά του AI είναι πραγματικά πολυάριθμα σε πολλούς τομείς. Η τεχνητή νοημοσύνη έχει τη δυνατότητα να επαναπροσδιορίσει την ιατρική φροντίδα, μέσω της συνεργασίας του ανθρώπινου μυαλου και σκέψης με την υπολογιστική δύναμη, καθιστώντας τη διάγνωση και τη θεραπεία πιο ακριβείς, προσιτές και εξατομικευμένες. Καθώς η τεχνολογία εξελίσσεται, αναμένεται να δούμε ακόμη περισσότερες εφαρμογές της AI στην ιατρική, βελτιώνοντας την ποιότητα ζωής των ασθενών και διευκολύνοντας το έργο των επαγγελματιών της υγείας.

1.4 Περιγραφή του προβλήματος

Η εργασία αυτή εστιάζει στον σχεδιασμό σχήματος ελέγχου για την αποφυγή τραυματισμού της χειρουργικής τομής του ασθενή, κατά τη διάρκεια ενός τηλεχειριζόμενου (leader-follower) ρομποτικού χειρουργείου, με τη βοήθεια της Τεχνητής Νοημοσύνης. Συγκεκριμένα, χρησιμοποιείται ένας ρομποτικός βραχίονας UR3e ως leader, τον οποίο χειρίζεται ο χειρουργός, και ένας ρομποτικός βραχίονας UR3 ως follower, ο οποίος είναι αυτός που πραγματοποιεί την επέμβαση πάνω στον ασθενή και εκτελεί τις εντολές του leader. Οι δυο αυτοί ρομποτικοί βραχίονες ελέγχονται κινηματικά, δηλαδή δέχονται εντολές ταχύτητας στις αρθρώσεις. Θεωρείται ότι δεν υπάρχουν καθυστερήσεις στην επικοινωνία μεταξύ leader και follower γιατί είναι κοντά ο ένας με τον άλλον.

Υπάρχουν δύο τρόποι επικοινωνίας μεταξύ leader και follower, η μονοκατευθυντική (unilateral) [32] και η αμφίδρομη (bilateral) [16]. Η μονοκατευθυντική είναι όταν η επικοινωνία γίνεται μόνο από τον leader προς τον follower, ενώ η αμφίδρομη είναι η αμοιβαία επικοινωνία, όπου υπάρχει ανατροφοδότηση και από τον follower προς τον leader. Για την συγκεκριμένη εργασία επιλέχθηκε η αμφίδρομη επικοινωνία, οπότε ο χειρουργός μπορεί να νιώθει δυνάμεις (haptic-feedback). Μέσω του leader και της απτικής ανάδρασης, ο χειρουργός νιώθει τη δύναμη/ροπή που ασκείται όταν γίνει κάποια παραμόρφωση του μαλακού ιστού. Με αυτόν τον τρόπο, παρέχεται στον χειρουργό μια πιο φυσική αλληλεπίδραση, το οποίο βελτιώνει την αποτελεσματικότητα της εργασίας που εκτελείται [24].

Ο follower έχει στερεωμένο στον καρπό του ένα λεπτό, μακρύ χειρουργικό εργαλείο, το οποίο εισέρχεται στο σώμα του ασθενούς, μέσω μίας μικρής τομής. Στη βάση του μεταλλικού εργαλείου, τοποθετήθηκε μία κάμερα RGB, η οποία παίρνει δεδομένα σε πραγματικό χρόνο για την χειρουργική τομή και την περιοχή γύρω από αυτήν. Τα οπτικά αυτά δεδομένα, περνούν από ένα DCNN, μέσω του οποίου εκτιμάται η παραμόρφωση του μαλακού ιστού, όπως φαίνεται στην εικόνα. Για την προσομοίωσης της τομής και του μαλακού ιστού, χρησιμοποιήθηκε μία σιλικόνη.

Η πληροφορία της εκτιμώμενης παραμόρφωσης μεταφέρεται άμεσα στον χειρουργό μέσω απτικής ανάδρασης στον leader βραχίονα, με τη μορφή δύναμης ανάσχεσης ή "ώθησης" προς διαφορετική,

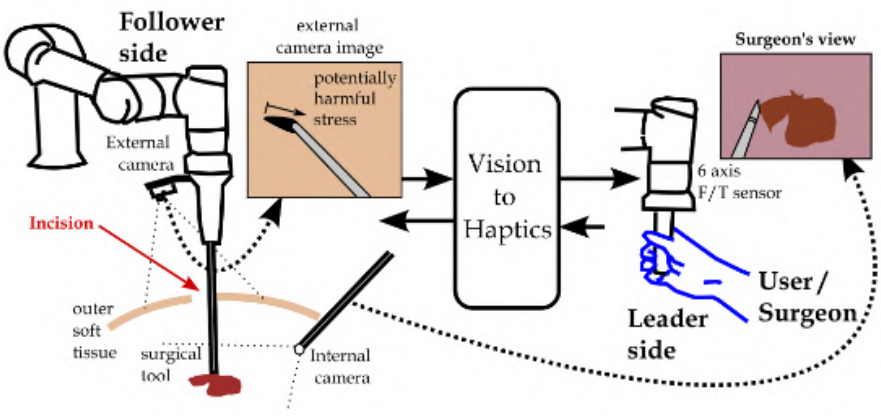
ασφαλέστερη κατεύθυνση. Η απτική αυτή ειδοποίηση λειτουργεί προληπτικά, αποτρέποντας, άμεσα, τον χειρουργό από το να συνεχίσει μια κίνηση που θα μπορούσε να προκαλέσει τραυματισμό. Αξίζει να σημειωθεί ότι δεν παρέχεται στον χειρουργό οπτική πληροφόρηση από την κάμερα του follower, αλλά μόνο απτική. Με αυτόν τον τρόπο, μειώνεται ο φόρτος της υπερβολικής πληροφόρησης του χειρουργού και παραμένει συγκεντρωμένος στην κύρια εικόνα του εσωτερικού του σώματος και της ίδιας της χειρουργικής επέμβασης.

Επιπρόσθετα, ο σχεδιασμός αυτός υπερβαίνει την ανάγκη για αισθητήρες δύναμης στην τομή, οι οποίοι θα απαιτούσαν πολύπλοκη εγκατάσταση τόσο εντός όσο και εκτός του σώματος, με σκοπό την άμεση μέτρηση της δύναμης και της πίεσης που ασκείται στην τομή. Αυτό, βέβαια, είναι ιδιαίτερα δύσκολο και δαπανηρό. Οπότε, αντί αυτού, επιλέχθηκε να εκτιμάται η παραμόρφωση σε πραγματικό χρόνο μέσω του DCNN.

Οπότε, η ακολουθία λειτουργίας του συστήματος έχει ως εξής:

$$\text{Leader} \rightarrow \text{Follower} \rightarrow \text{Camera} \rightarrow \text{DCNN} \rightarrow \text{Haptic Feedback}$$

Έτσι, υπάρχει πλέον ασφαλής αλληλεπίδραση του ρομποτικού βραχίονα με τον ανθρώπινο ιστό.



Σχήμα 1.5: Setup leader-follower

1.5 Η καινοτομία της διπλωματικής εργασίας και η συνεισφορά της στην επιστήμη

Η παρούσα διπλωματική εργασία συνεισφέρει σε πολλά επίπεδα στην Ρομποτικά Υποβοηθούμενη Ελάχιστα Επεμβατική Χειρουργική, συνδυάζοντας προηγμένους νόμους ελέγχου ρομποτικών συστημάτων, τεχνητή νοημοσύνη και απτική ανάδραση.

Αρχικά, προτείνεται ένας νέος τρόπος αποτροπής του τραυματισμού της τομής κατά τη διάρκεια ρομποτικής χειρουργικής, ο οποίος βασίζεται στην αναγνώριση της παραμόρφωσης του μαλακού ιστού μέσω οπτικών δεδομένων. Σε αντίθεση με κάποια ρομποτικά συστήματα (όπως τα da Vinci) που βασίζονται στη χρήση αισθητήρων δύναμης ή μηχανικούς περιορισμούς (όπως το RCM – Remote Center of Motion) [8], ώστε το εργαλείο να κινείται σαν να περιστρέφεται γύρω από ενα σταθερό σημείο (την τομή), η παρούσα προσέγγιση χρησιμοποιεί μία κάμερα RGB, τοποθετημένη στον καρπό του follower ρομποτικού βραχίονα, και ένα DCNN για την ανίχνευση παραμόρφωσης σε πραγματικό χρόνο. Με αυτόν τον τρόπο, δεν απαιτούνται ειδικά σχεδιασμένα ρομπότ, που δεν είναι ευέλικτα.

Επιπλέον, η εργασία εισάγει μία πιο ρεαλιστική παραδοχή ως προς την συμπεριφορά του ανθρώπινου σώματος. Συγκεκριμένα, πολλά από τα υπάρχοντα ερευνητικά έργα, προσπαθούν να χρησιμοποιήσουν RCM με έλεγχο ([20, 29, 31, 28, 16]), θεωρώντας ότι η τομή δεν κινείται και παραμένει

σταθερή στο χρόνο, πράγμα που έρχεται σε αντίθεση με το ότι το σώμα κινείται ακούσια, λόγω διάφορων βιολογικών παραγόντων, όπως η αναπνοή και οι καρδιακοί παλμοί, άρα και η τομή δεν παραμένει σταθερή σε συγκεκριμένο σημείο. Βέβαια, μερικά έργα [26, 28, 15], προσπαθούν να λάβουν υπόψη τους τη μετακίνηση της τομής, αλλά είτε προϋποθέτουν ότι γνωρίζουν ήδη την κίνηση της (κάτι μη ρεαλιστικό), είτε βασίζονται σε προσομοιώσεις, χωρίς πειραματική επιβεβαίωση. Έτσι, αντί για όλα αυτά, στην παρούσα εργασία χρησιμοποιείται η τεχνητή νοημοσύνη και ένα DCNN για την αναγνώριση της καταπόνησης των μαλακών ιστών, που υφίσταται η τομή. Με αυτόν τον τρόπο, το σύστημα δεν απαιτεί καμία ακριβή μοντελοποίηση της κίνησης της τομής, ούτε την υπόθεση ότι αυτή είναι γνωστή εκ των προτέρων, κάτι που το καθιστά πιο ευπροσάρμοστο σε πραγματικές συνθήκες.

Υπάρχουν, κάποιες έρευνες που εστιάζουν μόνο σε αυτό, δηλαδή μόνο στην απλή παρακολούθηση της χειρουργικής τομής, δίνοντας οπτικές (εμφάνιση προειδοποίησης στην οθόνη) ή ακουστικές ειδοποιήσεις. Όμως, το κύριο καινοτόμο στοιχείο και σκοπός της εργασίας είναι να χρησιμοποιήσει τα οπτικά δεδομένα (παραμόρφωση, λόγω υπερβολικής πίεσης της τομής) και να προσφέρει απτική ανάδραση (δηλαδή να σπρώχνει ”διακριτικά” το χέρι του χειρουργού για να αποφύγει επικίνδυνες κινήσεις). Δηλαδή, χρησιμοποιεί την τυχόν πληροφορία για παραμόρφωση ως απτική ειδοποίηση στον χειρουργό, μέσω αμφίδρομης επικοινωνίας μεταξύ των ρομποτικών βραχιόνων, καθοδηγώντας την κίνηση του leader. Με αυτόν τον τρόπο, η ανάδραση δεν είναι απλώς ένα «σήμα κινδύνου», αλλά συμβάλλει στην αλλαγή της πορείας του χειρουργικού εργαλείου προς ασφαλέστερες κατευθύνσεις, πριν προκληθεί τραυματισμός. Επίσης, δεν φορτώνεται νοητικά ο χειρουργός με οπτικές ειδοποιήσεις ή ακουστικές, που θα πρέπει να παρακολουθεί ή ακόμα να παρακολουθεί ο ίδιος τη χειρουργική τομή. Έτσι, παραμένει πλήρως συγκεντρωμένος στο ίδιο το χειρουργείο και την εκτέλεση της επέμβασης, βλέποντας μόνο το εσωτερικό του σώματος του ασθενή.

Μία ακόμη σημαντική επιστημονική συμβολή είναι η ανάδειξη της δυνατότητας του συνδυασμού τεχνητής νοημοσύνης και απτικής ανάδρασης σε πραγματικό χρόνο, σε χειρουργικά σενάρια υψηλού ρίσκου. Ενώ σε πολλές ερευνητικές εργασίες η χρήση deep learning περιορίζεται σε καθαρά διαγνωστικά ή εποπτικά συστήματα, εδώ η τεχνητή νοημοσύνη ενσωματώνεται ενεργά στον βρόχο ελέγχου του ρομποτικού συστήματος, επηρεάζοντας άμεσα τη συμπεριφορά του χειριστή. Με αυτόν τον τρόπο επιτυγχάνεται στενότερη και ασφαλέστερη συνεργασία ανθρώπου-ρομπότ (Human-Robot Interaction), στοιχείο κρίσιμο για την επόμενη γενιά ιατρικών ρομποτικών συστημάτων.

Μία ακόμη ουσιώδης συμβολή της παρούσας εργασίας είναι η ανάδειξη και πειραματική τεκμηρίωση, της δυνατότητας σύζευξης της τεχνητής νοημοσύνης και της απτικής ανάδρασης σε πραγματικό χρόνο, σε σενάρια ρομποτικά υποβοηθούμενης χειρουργικής. Σε αντίθεση με το κύριο ρεύμα της τρέχουσας βιβλιογραφίας, όπου τα μοντέλα υπολογιστικής όρασης και βαθιάς μάθησης χρησιμοποιούνται, κυρίως για την αναγνώριση χειρουργικής δραστηριότητας [37], την αποκωδικοποίηση των ενεργειών του χειρουργού, όπως οι βασικές κινήσεις των χεριών και των εργαλείων που κάνει ένας χειρουργός για να εκτελέσει μια ραφή (suturing gestures) [17, 19] ή την αξιολόγηση των δεξιοτήτων του χειρουργού [18], καθώς και για την αξιολόγηση της τάσης ή/και των δυνάμεων που ασκούνται στους μαλακούς ιστούς από οπτικά δεδομένα [5, 21, 9] (βλ. και την πρόσφατη ανασκόπηση [35]), εδώ η τεχνητή νοημοσύνη ενσωματώνεται ενεργά στον βρόχο ελέγχου του ρομποτικού συστήματος. Έτσι, η AI παύει να λειτουργεί ως παθητικός «παρατηρητής» και καθίσταται ενεργό στοιχείο λήψης αποφάσεων που επηρεάζει άμεσα τόσο τη συμπεριφορά του χειρουργού όσο και την κίνηση του ρομποτικού εργαλείου. Η εν λόγω σύζευξη AI–haptics ενισχύει την ποιότητα της αλληλεπίδρασης ανθρώπου–ρομπότ (Human–Robot Interaction), επιτρέποντας συνεχή, προσαρμοστική και ασφαλή υποστήριξη του χειρουργού, με στόχο την αποφυγή τραυματισμού του μαλακού ιστού. Η απευθείας, αυτή, παροχή απτικής ανάδρασης καθοδήγησης, που προκύπτει από την οπτική καθοδήγηση, μέσω του AI σε πραγματικό χρόνο, δεν έχει διερευνηθεί και εξεταστεί, μέχρι σήμερα στη βιβλιογραφία.

Τέλος, η εργασία αυτή ανοίγει νέους δρόμους για την ανάπτυξη νόμων ελέγχου ρομποτικών βραχιόνων γενικής χρήσης (όπως οι UR3/UR3e), που δεν έχουν μηχανικά RCM και μπορούν να αξιοποιηθούν με μεγαλύτερη ευελιξία σε ποικίλες χειρουργικές εφαρμογές. Το γεγονός ότι η εργασία βασίζεται σε εμπορικά διαθέσιμο υλικό και δεν απαιτεί εξειδικευμένο ρομποτικό εξοπλισμό, ενισχύει

τη δυνατότητα μετάβασης από την έρευνα στην κλινική πράξη.

Συνολικά, η εργασία προτείνει έναν έξυπνο και πρακτικό μηχανισμό για την ασφαλή αλληλεπίδραση μεταξύ ρομποτικού εργαλείου και ανθρώπινου ιστού, αξιοποιώντας την οπτική αναγνώριση μέσω DCNN και τη φυσική ανάδραση. Η συμβολή της έγκειται τόσο στον τομέα του ελέγχου όσο και σε αυτόν της τεχνητής νοημοσύνης, προσφέροντας μία ρεαλιστική, καινοτόμα και επεκτάσιμη λύση σε ένα κρίσιμο πρόβλημα της ρομποτικής χειρουργικής.

Στα πλαίσια της διπλωματικής εργασίας συντάχθηκε εργασία που παρουσιάζει την μέθοδο που αναπτύχθηκε, η οποία έγινε αποδεκτή στο European Control Confeence 2025 (ECC 2025).

1.6 Δομή διπλωματικής εργασίας

Η παρούσα διπλωματική εργασία οργανώνεται σε έξι κεφάλαια, με στόχο την ευκολία κατανόησης και την σαφή παρουσίαση της μεθοδολογίας και των αποτελεσμάτων.

Αρχικά, στο **Κεφάλαιο 1 –** ***Εισαγωγή*** διατυπώνεται το πρόβλημα και ο σκοπός της διπλωματικής εργασίας. Επιπλέον, σκιαγραφείται το πλαίσιο της Ρομποτικά Υποβοηθούμενης Ελάχιστα Επεμβατικής Χειρουργικής (RAMIS) και ο ρόλος των σύγχρονων τεχνολογιών στην κλινική πράξη, με αναφορά σε αντιπροσωπευτικά ρομποτικά συστήματα (π.χ. da Vinci, Senhance) και στα οφέλη τους. Τέλος, αναδεικνύεται η καινοτομία της ενσωμάτωσης AI μέσα στον βρόχο ελέγχου και περιγράφεται συνοπτικά η αρχιτεκτονική του συστήματος και αναλύεται η συνεισφορά της εργασίας προτεινόμενης προσέγγισης στην επιστήμη.

Στο **Κεφάλαιο 2 –** ***Προτεινόμενη μέθοδος εκτίμησης παραμόρφωσης μέσω Τεχνητής Νοημοσύνης*** αναπτύσσεται διεξοδικά το θεωρητικό υπόβαθρο στα νευρωνικά δίκτυα και τα Βαθιά Συνελικτικά Νευρωνικά Δίκτυα (DCNNs). Έπειτα, παρουσιάζεται η χρήση των DCNN για την εκτίμηση της παραμόρφωσης του μαλακού ιστού, γύρω από τη χειρουργική τομή. Συγκεκριμένα, αναλύεται η αρχιτεκτονική του δικτύου, καθώς και ο τρόπος που υλοποιήθηκε η συλλογή δεδομένων. Επιπλέον, αναλύεται το πώς έγινε η εκπαίδευση του νευρωνικού δικτύου και τέλος παρουσιάζεται η αξιολόγηση του μοντέλου.

Στο **Κεφάλαιο 3 –** ***Leader–Follower set-up*** ορίζεται και υλοποιείται η διάταξη τηλεχειρισμού leader–follower. Στον leader εφαρμόζεται έλεγχος ενδοτικότητας στο χώρο των αρθρώσεων, ενώ για το follower ρομπότ εφαρμόζεται κινηματικός έλεγχος παρακολούθησης (CLIK).

Στο **Κεφάλαιο 4 –** ***Σχεδίαση και υλοποίηση ολοκληρωμένου συστήματος*** ολοκληρώνεται το τηλεχειριζόμενο σύστημα δύο βραχιόνων τύπου leader–follower με απτική ανάδραση από το DCNN. Παρουσιάζεται αναλυτικά ο υπολογισμός της εικονικής δύναμης από το DCNN, καθώς και πως έγινε αντιστοίχηση από το χώρο των εικονοστοιχείων στον φυσικό χώρο, με σκοπό τον υπολογισμό της εκτιμώμενης επαφής του εργαλείου. Επιπλέον, παρατίθεται ο μηχανισμός διασφάλισης παθητικότητας μέσω δεξαμενής ενέργειας και η απόδειξη τη; παθητικότητας του συστήματος.

Στο **Κεφάλαιο 5 –** ***Πειραματική αξιολόγηση*** παρουσιάζεται το πειραματικό set-up με τους ρομποτικούς βραχίονες UR3/UR3e. Έπειτα, αναλύονται τα πειράματα και τα αποτελέσματα. Αποτυπώνονται τα 3 πειράματα με χρήση σιλικόνης, χρήση ζελατίνης και κινούμενη τομή και παρουσιάζονται τα αποτελέσματα που επιβεβαιώνουν την αποτελεσματικότητα της μεθόδου ως προς την αποφυγή βλάβης ιστών.

Τέλος, στο **Κεφάλαιο 6 –** ***Συμπεράσματα και μελλοντική έρευνα*** συνοψίζονται τα κύρια ευρήματα και η συνεισφορά της εργασίας, καθώς και συζητούνται οι περιορισμοί και προτείνονται κατευθύνσεις για μελλοντική έρευνα .

Κεφάλαιο 2

Προτεινόμενη μέθοδος εκτίμησης παραμόρφωσης μέσω τεχνητής νοημοσύνης

Όπως παρουσιάστηκε στο προηγούμενο κεφάλαιο, η επιτυχής αποφυγή τραυματισμού της χειρουργικής τομής κατά τη διάρκεια της επέμβασης προϋποθέτει την εκτίμηση της παραμόρφωσης του μαλακού ιστού σε πραγματικό χρόνο. Η λύση που προτείνεται βασίζεται στην τεχνητή νοημοσύνη και, πιο συγκεκριμένα, στην εφαρμογή βαθιών νευρωνικών δικτύων (Deep Neural Networks – DNNs), λόγω της ικανότητάς τους να μοντελοποιούν περίπλοκες μη-γραμμικές σχέσεις και να εξάγουν σημαντικά χαρακτηριστικά από υψηλής διάστασης δεδομένα, όπως είναι τα οπτικά δεδομένα RGB.

Η επιλογή της τεχνητής νοημοσύνης, και ειδικότερα των DNNs, δεν είναι τυχαία. Τα βαθιά νευρωνικά δίκτυα μπορούν να μαθαίνουν απευθείας από τα δεδομένα, χωρίς την ανάγκη εξειδικευμένης προγραμματιστικής παρέμβασης, και να εκτελούν τις προβλέψεις σε ελάχιστο χρόνο (της τάξεως ms), καθιστώντας τα ιδανικά για εφαρμογές σε ρομποτικά χειρουργικά συστήματα.

Στην παρούσα εργασία τα δεδομένα εισόδου στο νευρωνικό δίκτυο είναι εικόνες RGB, οπότε η επιλογή του κατάλληλου είδους νευρωνικού δικτύου ήταν αρκετά εύκολη και δεν θα ήταν άλλη πέρα από τα Βαθιά Συνελικτικά Νευρωνικά Δίκτυα (Deep Convolutional Neural Networks – DCNNs), καθώς αποτελούν το πιο διαδεδομένο εργαλείο για την αναγνώριση μοτίβων και αντικειμένων σε εικόνες. Τα DCNNs έχουν ήδη αποδείξει την αξία και την αποτελεσματικότητά τους σε πολλές εφαρμογές, όπως στην ιατρική απεικόνιση, στην ανίχνευση όγκων σε μαγντικές και αξονικές τομογραφίες κλπ.

Η χρήση συνελικτικών επιπέδων στα DCNNs καθιστά δυνατή την αυτόματη εξαγωγή χαρακτηριστικών από τις εικόνες εισόδου, χωρίς να απαιτείται προηγούμενη επεξεργασία ή χειροκίνητη εξαγωγή των χαρακτηριστικών. Το κάθε συνελικτικό επίπεδο χρησιμοποιεί φίλτρα (kernels), τα οποία εφαρμόζονται στην εικόνα και με τη βοήθεια αυτών το δίκτυο ανιχνεύει βασικά μορφολογικά στοιχεία της εικόνας, όπως ακμές, γωνίες, καμπυλότητες ή ακόμα και πιο σύνθετα μοτίβα. Αυτή η ικανότητα προσφέρει δύο σημαντικά πλεονεκτήματα: πρώτον, η αναγνώριση των χαρακτηριστικών απαιτεί χαμηλό υπολογιστικό κόστος, και δεύτερον, ενισχύει τη γενίκευση του μοντέλου σε νέες εικόνες, καθώς τα ίδια φίλτρα εφαρμόζονται καθολικά (με διαμοιραζόμενα βάρη – weight sharing) σε όλη την εικόνα.

Το γεγονός ότι κάθε φίλτρο ενεργεί σε μια περιορισμένη περιοχή της εικόνας μειώνει σημαντικά την πολυπλοκότητα του δικτύου και τον αριθμό των απαιτούμενων παραμέτρων. Αυτό καθιστά δυνατή τη δημιουργία βαθύτερων δικτύων με περισσότερα επίπεδα, ικανών να εντοπίζουν ιεραρχικά χαρακτηριστικά, ξεκινώντας από απλές γραμμές και άκρα στα πρώτα επίπεδα έως πολύπλοκες μορφές και σχήματα στα βαθύτερα επίπεδα. Με αυτό τον τρόπο, τα DCNNs επιτυγχάνουν την κατανόηση της συνολικής δομής της εικόνας, γεγονός που είναι κρίσιμο για την αναγνώριση μεταβολών στη γεωμετρία της χειρουργικής τομής και, κατά συνέπεια, για την εκτίμηση της παραμόρφωσης του μαλακού ιστού.

Η χρήση των pooling layers σε συνδυασμό με τα συνελικτικά φίλτρα συνεισφέρει περαιτέρω στη μείωση των διαστάσεων των πινάκων χαρακτηριστικών. Αυτό οδηγεί όχι μόνο σε αυξημένη υπολογι-

στική αποδοτικότητα, αλλά και σε μεγαλύτερη ανθεκτικότητα του μοντέλου σε μικρές μετατοπίσεις, περιστροφές ή παραμορφώσεις της εικόνας. Η ανθεκτικότητα αυτή είναι ιδιαίτερα σημαντική στο ρομποτικό χειρουργικό περιβάλλον, όπου οι κάμερες ενδέχεται να παρουσιάζουν μικρές αλλαγές θέσης ή εστίασης λόγω των διάφορων κινήσεων του σώματος (αναπνοή, καρδιά κλπ) κατά τη διάρκεια της επέμβασης.

Επιπλέον, τα DCNNs ενσωματώνονται εύκολα σε σύγχρονα εργαλεία ανάπτυξης βαθιάς μάθησης, όπως το PyTorch, TensorFlow και Keras, και μπορούν να επωφεληθούν από την επιτάχυνση της κάρτας γραφικών (GPU), επιτρέποντας την αποτελεσματική εκπαίδευση και εκτέλεση σε περιβάλλοντα χαμηλής καθυστέρησης.

Ως εκ τούτου, τα DCNNs αποτελούν το θεμέλιο της προτεινόμενης προσέγγισης για την πρόβλεψη τραυματισμού της τομής λόγω παραμόρφωσης. Συγκεκριμένα, προβλέπουν, με ακρίβεια και ταχύτητα, την παραμόρφωση που μπορεί να υπάρξει στη χειρουργική τομή σε πραγματικό χρόνο.

Πρώτα, όμως, θα πρέπει να γίνει ανάλυση σε βάθος των νευρωνικών δικτύων, καθώς αυτά αποτελούν το κύριο κομμάτι της παρούσας διπλωματικής εργασίας.

2.1 Θεωρητικό Υπόβαθρο

Σε αυτό το κεφάλαιο παρατίθενται οι γνώσεις που χρειάζονται, με σκοπό να αποσαφηνιστούν κάποιες έννοιες που θα εμφανιστούν στα επόμενα κεφάλαια πάνω στην τεχνητή νοημοσύνη, τη μηχανική μάθηση και κυρίως τα νευρωνικά δίκτυα.

2.1.1 Τεχνητή Νοημοσύνη και Μηχανική Μάθηση

Η Τεχνητή Νοημοσύνη (AI) αποτελεί έναν ευρύ επιστημονικό κλάδο της πληροφορικής, ο οποίος έχει ως στόχο την ανάπτυξη συστημάτων και αλγορίθμων που μπορούν να προσομοιώνουν γνωστικές λειτουργίες του ανθρώπινου μυαλού, όπως η αντίληψη, η λήψη αποφάσεων, η μάθηση και η προσαρμογή. Με άλλα λόγια, το AI στοχεύει στη δημιουργία μηχανών που «σκέφτονται» και επιλύουν προβλήματα. Με την εξέλιξη των υπολογιστικών πόρων, η Μηχανική Μάθηση έχει αναδειχθεί ως ο κυριότερος πυλώνας της σύγχρονης Τεχνητής Νοημοσύνης.

Η Μηχανική Μάθηση (ΜΜ) είναι μία υποκατηγορία της ΤΝ, ο οποίος επικεντρώνεται στην ανάπτυξη αλγορίθμων που μπορούν να ”μαθαίνουν” από δεδομένα (εκπαίδευση - training) και να βελτιώνονται μέσω της εμπειρίας, χωρίς να έχουν προγραμματιστεί ρητά για κάθε πιθανή περίπτωση. Η βασική ιδέα είναι ότι ένα υπολογιστικό σύστημα μπορεί να εντοπίζει πρότυπα (patterns) και να εξάγει συμπεράσματα από δεδομένα, ώστε να παίρνει αποφάσεις ή να κάνει προβλέψεις.

Ανάλογα με τη φύση του προβλήματος και τα διαθέσιμα δεδομένα, η Μηχανική Μάθηση διακρίνεται κυρίως σε τρεις κατηγορίες:

- **Επιβλεπόμενη μάθηση (Supervised Learning)**: Ο αλγόριθμος εκπαιδεύεται σε ένα γνωστό σύνολο δεδομένων εισόδου, το οποίο συνοδεύεται από τις αντίστοιχες επιθυμητές εξόδους (ετικέτες). Ο στόχος είναι η μοντελοποίηση της σχέσης εισόδου–εξόδου ώστε να μπορεί να προβλέπει σωστά τις εξόδους για νέες, άγνωστες εισόδους.

  Παραδείγματα:

  - **Παλινδρόμηση (Regression)**: Η έξοδος είναι συνεχής αριθμητική τιμή (π.χ. πρόβλεψη θερμοκρασίας).
  - **Ταξινόμηση (Classification)**: Η έξοδος είναι διακριτή κατηγορία (π.χ. πρόβλεψη αν μια εικόνα είναι ”γάτα” ή ”σκύλος”). Οι πιο δημοοφιλείς αλγόριθμοι κατηγοριοποίησης είναι το Support Vector Machine (SVM), το Decision Tree και ο Naive Bayes.

- **Μη επιβλεπόμενη μάθηση (Unsupervised Learning)**: Σε αυτήν την περίπτωση, δεν υπάρχουν προκαθορισμένες ετικέτες στις εξόδους. Αντίθετα, ο αλγόριθμος προσπαθεί να εντοπίσει δομές ή ομάδες (clusters) στα δεδομένα εισόδου μόνος του και να τα κατηγοροποιήσει.

  Η μη επιβλεπόμενη μηχανική μάθηση χωρίζεται σε δύο υποκατηγορίες:

  - **Συσχέτιση (Assosiation)** : Είναι το είδος της μάθησης χωρίς επίβλεψη όπου βρίσκει τις εξαρτήσεις ενός συνόλου δεδομένων με ένα άλλο. Αλγόριθμοι συσχέτισης είναι ο Apriori και ο FP-Growth.
  - **Ομαδοποίηση (Clustering)**: Ο αλγόριθμος καταφέρνει να βρίσκει μοτίβα στα δεδομένα, όπως το χρώμα, το μέγεθος, το σχήμα κλπ, τα οποία χρησιμοποιούνται για τη δημιουργία των clusters. Οι πιο γνωστοί αλγόιθμοι ομαδοποίησης είναι ο K-Means και ο K-NN.

- **Ήμι-Επιβλεπόμενη Μηχανική μάθηση (Semi-supervised machine learning)**: Αυτή η κατηγορία μάθησης αποτελεί μια ενδιάμεση μορφή μεταξύ της επιβλεπόμενης και της μη επιβλεπόμενης μάθησης. Σε αυτό το σενάριο, το σύνολο δεδομένων περιλαμβάνει έναν μικρό αριθμό δεδομένων με γνωστές ετικέτες εξόδου και έναν πολύ μεγαλύτερο αριθμό δεδομένων, χωρίς ετικέτα. Ο στόχος είναι να αξιοποιηθεί η πληροφορία από τα δεδομένα χωρίς ετικέτα, ώστε να ενισχυθεί η απόδοση του μοντέλου, αξιοποιώντας μόνο την περιορισμένη εποπτευόμενη γνώση. Η μέθοδος αυτή είναι ιδιαίτερα χρήσιμη σε περιπτώσεις όπου η συλλογή και επισήμανση των δεδομένων είναι χρονοβόρα ή μεγάλο κόστος, όπως στην επεξεργασία φυσικής γλώσσας, στην ταξινόμηση ακολουθιών πρωτεϊνών, στις ταξινομήσεις εγγράφων κειμένου.

- **Μάθηση ενίσχυσης (Reinforcement Learning)**: Η μάθηση ενίσχυσης βασίζεται σε ένα διαφορετικό μαθησιακό πλαίσιο, όπου ένας πράκτορας (agent) αλληλεπιδρά με ένα περιβάλλον και μαθαίνει μέσω δοκιμών και σφαλμάτων. Ο πράκτορας εκτελεί ενέργειες, λαμβάνει αρνητικές ανταμοιβές (ή ποινές) από το περιβάλλον, και προσαρμόζει τη στρατηγική του (πολιτική) με σκοπό τη μεγιστοποίηση των συνολικών θετικών ανταμοιβών σε βάθος χρόνου. Χρησιμοποιείται, κυρίως, σε αυτόνομα ρομπότ, παιχνίδια κλπ.

Από όλες τις παραπάνω κατηγορίες στα πλαίσια της συγκεκριμένης εργασίας, για την επίλυση του προβλήματος επιλέχθηκε η επιβλεπόμενη μηχανική μάθηση.

Η διαδικασία εκπαίδευσης ενός αλγορίθμου περιλαμβάνει συνήθως τον διαχωρισμό των δεδομένων σε δύο βασικά σύνολα:

- **Training set (σύνολο εκπαίδευσης)**: Χρησιμοποιείται για την εκμάθηση των παραμέτρων του μοντέλου.

- **Test set (σύνολο δοκιμής)**: Χρησιμοποιείται για την αξιολόγηση της ικανότητας του μοντέλου να γενικεύει σε νέα, μη ορατά δεδομένα.

Η Μηχανική Μάθηση αποτελεί τη βάση για πολλές από τις σύγχρονες εφαρμογές τεχνητής νοημοσύνης, συμπεριλαμβανομένων των νευρωνικών δικτύων, τα οποία αξιοποιούνται ευρέως στην επεξεργασία εικόνας, στον εντοπισμό προτύπων και στη ρομποτική. Στα παρακάτω κεφάλαια, γίνεται εμβάθυνση στα νευρωνικά δίκτυα και εξηγούνται όλες οι έννοιες γύρω από αυτά.

2.1.2 Τι είναι τα νευρωνικά δίκτυα;

Τα νευρωνικά δίκτυα είναι ένας τύπος αλγόριθμου μηχανικής μάθησης (machine learning) και αποτελούν μια τεχνική της τεχνητής νοημοσύνης, η οποία εκπαιδεύει τους υπολογιστές να επεξεργάζονται δεδομένα, προσπαθώντας να προσομοιωθεί η δομή και η λειτουργία του ανθρώπινου εγκεφάλου. Το στοιχειώδες υπολογιστικό εργαλείο του εγκεφάλου είναι το νευρωνικό κύτταρο, ή αλλιώς νευρώνας. Έτσι, αυτά τα δίκτυα αποτελούνται από στρώματα (layers) διασυνδεδεμένων τεχνητών

νευρώνων, που επεξεργάζονται πληροφορίες και παράγουν ένα αποτέλεσμα βάση των δεδομένων εισόδου(inputs).

Τα νευρωνικά δίκτυα μπορούν να βοηθήσουν τους υπολογιστές να παίρνουν έξυπνες αποφάσεις, μειώντας την ανάγκη για ανθρώπινη παρέμβαση. Αυτό επιτυγχάνεται με την εκπαίδευση τους σε μεγάλα σύνολα δεδομένων (dataset), ώστε να μάθουν πολύπλοκες σχέσεις μεταξύ των δεδομένων εισόδου και εξόδου, εξάγοντας συμπεράσματα και κάνοντας γενικεύσεις.

2.1.3 Η λειτουργία ενός νευρώνα

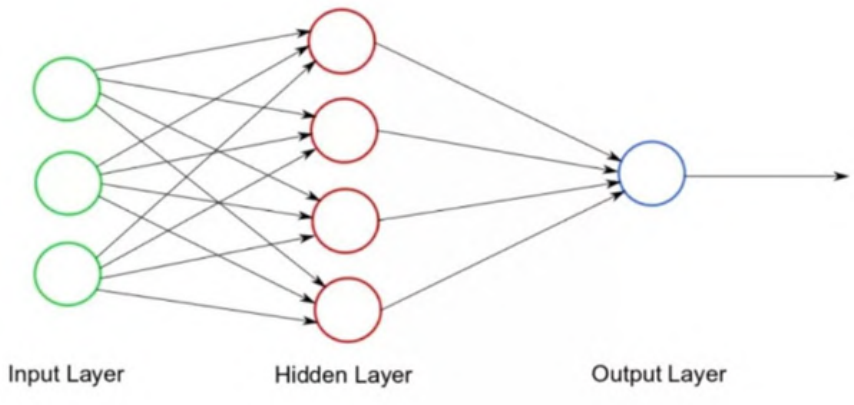
Ένα τεχνητό νευρωνικό δίκτυο αποτελείται από τεχνητούς νευρώνες, που ονομάζονται κόμβοι. Αυτοί οι κόμβοι είναι μονάδες λογισμικού που συνεργάζονται για την επίλυση προβλημάτων και την πραγματοποίηση υπολογισμών, χρησιμοποιώντας διάφορους αλγόριθμους.

Ένα βασικό νευρωνικό δίκτυο έχει διασυνδεδεμένους τεχνητούς νευρώνες που οργανώνονται σε τρία κύρια επίπεδα:

Επίπεδο εισόδου (input layer): Αυτό είναι το πρώτο επίπεδο σε ένα νευρωνικό δίκτυο και είναι υπεύθυνο για τη λήψη των αρχικών δεδομένων εισόδου. Οι νευρώνες σε αυτό το επίπεδο επεξεργάζονται και μεταφέρουν τα δεδομένα στα επόμενα επίπεδα του δικτύου. Για παράδειγμα, σε εφαρμογή αναγνώρισης εικόνας, το επίπεδο εισόδου θα λάβει τις πληροφορίες των pixel της εικόνας. Ο αριθμός των νευρώνων στο επίπεδο εισόδου εξαρτάται αποκλειστικά από τη διάσταση των δεδομένων εισόδου που χρησιμοποιούμε.

Κρυμμένο επίπεδο (hidden layer): Αποτελούν τα ενδιάμεσα επίπεδα, που βρίσκονται μεταξύ του επιπέδου εισόδου και του επιπέδου εξόδου και είναι υπεύθυνα για την επεξεργασία των δεδομένων. Τα κρυμμένα στρώματα ενδέχεται να είναι πολλά, ανάλογα του πόσο σύνθετο είναι το δίκτυο. Το μεγαλύτερο μέρος του υπολογισμού γίνεται σε αυτά, καθώς κάθε κρυφό επίπεδο εφαρμόζει μετασχηματισμούς στα δεδομένα, προσπαθώντας να ανιχνεύσει μοτίβα και σχέσεις.

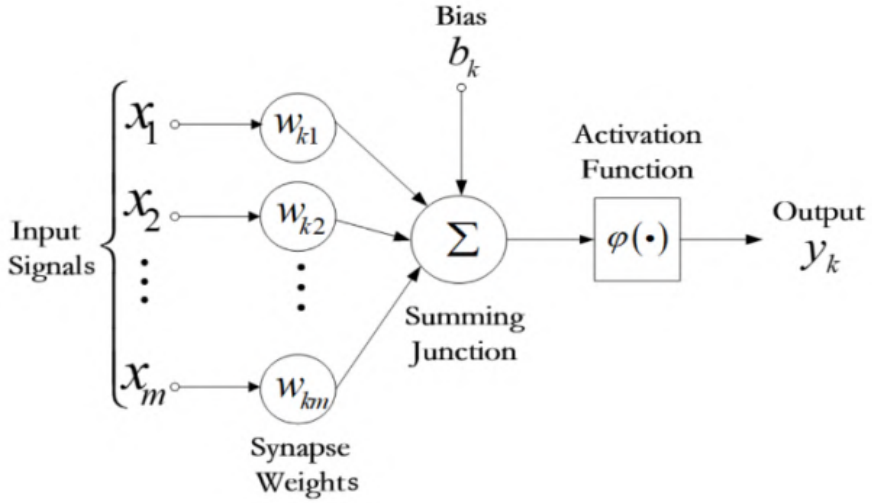
Επίπεδο εξόδου (output layer): Το τελικό επίπεδο σε ένα νευρωνικό δίκτυο, που παράγει την τελική απόφαση ή πρόβλεψη του δικτύου. Ο αριθμός των νευρώνων σε αυτό το επίπεδο εξαρτάται από το είδος του προβλήματος που επιλύεται. Σε ένα πρόβλημα δυαδικής ταξινόμησης, υπάρχει μόνο ένας νευρώνας στο επίπεδο εξόδου. Σε ένα πρόβλημα ταξινόμησης πολλαπλών κατηγοριών, υπάρχουν πολλαπλοί νευρώνες, καθένας από τους οποίους αντιπροσωπεύει μια διαφορετική κατηγορία.



Σχήμα 2.1: Απλό νευρωνικό δίκτυο
[7]

Ο συνολικός αριθμός στρωμάτων και ο συνολικός αριθμός κόμβων σε κάθε κρυφό στρώμα καθορίζουν την αρχιτεκτονική ή την τοπολογία του νευρωνικού δικτύου, όπως φαίνεται στο Σχήμα 2.2.

Για να λειτουργήσουν τα νευρωνικά δίκτυα, κάθε νευρώνας λαμβάνει εισόδους και τις επεξεργάζεται χρησιμοποιώντας συγκεκριμένα βάρη (**weights**). Κάθε σύνδεση ανάμεσα στους νευρώνες δύο



Σχήμα 2.2: Ανατομία απλού νευρώνα
[30]

γειτονικών επιπέδων έχει ένα βάρος, το οποίο καθορίζει πόσο ισχυρά επηρεάζει ο νευρώνας του ενός επιπέδου τον νευρώνα του επόμενου. Όσο μεγαλύτερο είναι, τόσο μεγαλύτερη επίδραση έχει. Στην αρχή της εκπαίδευσης, τα βάρη συνήθως αρχικοποιούνται τυχαία, αλλά στην συνέχεια προσαρμόζονται έτσι ώστε να μειώνεται το σφάλμα.

Έστω ότι έχουμε τις εισόδους του νευρώνα, $x_1, x_2, \ldots, x_n$, όπου n είναι ο αριθμός των εισόδων, και κάθε $x_i \in \mathbb{R}$. Κάθε μία από αυτές τις εισόδους σχετίζεται με ένα βάρος, $w_1, w_2, \ldots, w_n$, όπου και κάθε $w_i \in \mathbb{R}$, το οποίο καθορίζει πόσο σημαντική είναι η κάθε είσοδος για τον νευρώνα. Τα βάρη είναι συνήθως αριθμοί στο διάστημα $[-1, 1]$. Είναι ιδιαίτερα σημαντικός ο τρόπος με τον οποίο αλληλεπιδρούν τα βάρη και οι είσοδοι, διότι από αυτό εξαρτάται σε μεγάλο βαθμό η απόδοση του νευρωνικού δικτύου. Η διαδικασία εκπαίδευσης του δικτύου προσαρμόζει τα βάρη με σκοπό να ελαχιστοποιηθεί το σφάλμα μεταξύ των προβλέψεων του δικτύου και των πραγματικών δεδομένων.

Επιπλέον, υπάρχει και μια ειδική είσοδος x_0, η οποία μπορεί να πάρει μόνο τρεις τιμές:

- $x_0 = 0$, οπότε αγνοείται $(0 \cdot w_0)$
- $x_0 = -1$, τότε $w_0 = \theta$ (το θ καλείται κατώφλι)
- $x_0 = 1$, τότε $w_0 = b$ (το b καλείται πόλωση)

Άρα, ο νευρώνας τελικά λαμβάνει $n+1$ εισόδους. Η συνολική είσοδος στον νευρώνα υπολογίζεται ως το άθροισμα των εσωτερικών γινομένων των εισόδων με τα αντίστοιχα βάρη τους και ονομάζεται δυναμικό ενεργοποίησης v και δίνεται από την παρακάτω εξίσωση:

$$v = \sum_{i=0}^{n} w_i \cdot x_i = w_0 \cdot x_0 + w_1 \cdot x_1 + w_2 \cdot x_2 + \cdots + w_n \cdot x_n$$

Συνήθως προστίθεται στον υπολογισμό η πόλωση (bias), η οποία επιτρέπει τη μετατόπιση της συνάρτησης ενεργοποίησης και βοηθάει στη βελτίωση της ευελιξίας και προσαρμογής του μοντέλου στα δεδομένα εκπαίδευσης, συνεισφέροντας σημαντικά στην απόδοση του μοντέλου. Έτσι,

$$v = \sum_{i=0}^{n} (w_i \cdot x_i) + b = w_0 \cdot x_0 + w_1 \cdot x_1 + w_2 \cdot x_2 + \cdots + w_n \cdot x_n + b \tag{2.1}$$

Αφού υπολογιστεί το v, περνάει από την συνάρτηση μεταφοράς **(transfer function)**, η οποία συνδυάζει πολλές εισόδους σε μία μόνο τιμή εξόδου, επιτρέποντας έτσι την εφαρμογή της συνάρτησης ενεργοποίησης. Στην ουσία, αυτό επιτυγχάνεται μέσω της άθροισης όλων των εισόδων που λαμβάνει

η συνάρτηση μεταφοράς. Έπειτα, περνάει απο μία **συνάρτηση ενεργοποίησης** $f(v)$ που καθορίζει την τελική έξοδο του νευρώνα.

2.1.4 Συνάρτηση Ενεργοποίησης

Η συνάρτηση ενεργοποίησης (Activation Function) αποτελεί μια θεμελιώδη μαθηματική συνιστώσα των τεχνητών νευρωνικών δικτύων, η οποία εφαρμόζεται στο δυναμικό ενεργοποίησης ενός νευρώνα, δηλαδή στο συνολικό άθροισμα των εισόδων πολλαπλασιασμένων με τα αντίστοιχα βάρη, καθορίζοντας την τελική έξοδο του νευρώνα. Η παρουσία της συνάρτησης ενεργοποίησης είναι καθοριστική για την αποτελεσματική μάθηση και για την απόδοση του δικτύου, καθώς προσδίδει μη-γραμμικότητα στο σύστημα.

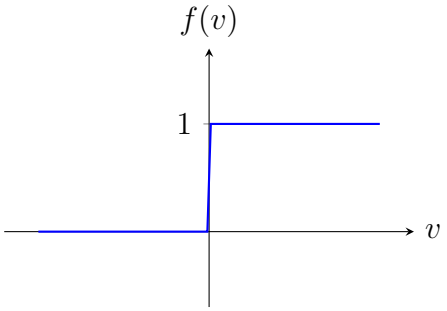
Χωρίς αυτήν, το δίκτυο θα ήταν ουσιαστικά ένας γραμμικός μετασχηματισμός, δηλαδή ένα μοντέλο όπου η έξοδος θα ήταν ένας γραμμικός συνδυασμός των εισόδων, ανεξαρτήτως του αριθμού επιπέδων και νευρώνων, με αποτέλεσμα να μην μπορεί το δίκτυο να μάθει και να αναπαραστήσει πολύπλοκες σχέσεις και μοτίβα στα δεδομένα. Οι συναρτήσεις ενεργοποίησης χωρίζονται σε δύο βασικές κατηγορίες:

- **Μη-Γραμμικές Συναρτήσεις ενεργοποίησης - NonLinear Activation Functions**: Προσδίδει περιορισμένη υπολογιστική ισχύ στο δίκτυο και δεν μπορεί να επιλύσει σύνθετα προβλήματα, καθώς λειτουργεί ως μία ευθεία γραμμή της μορφής $f(x) = a \cdot x$, όπου α είναι μία σταθερά.
- **Γραμμικές Συναρτήσεις ενεργοποίησης - Linear Activation Functions**: Επτρέπουντη τη διαμόρφωση μιας σύνθετης αντιστοίχισης μεταξύ των εισόδων και των εξόδων του δικτύου. Επίσης, καθιστούν δυνατή την ανάπτυξη βαθιών νευρωνικών δικτύων, με πολλαπλούς κρυφούς νευρώνες.

Μερικές από τις πιο συχνές συναρτήσεις ενεργοποίησης είναι:

- **Βηματική συνάρτηση(ή συνάρτηση κατωφλίου)**: Είναι μία από τις πιο βασικές συναρτήσεις ενεργοποίησης, η οποία παρέχει δυαδική έξοδο. Ορίζεται μία τιμή κατωφλίου (threshold) $x_0 = -1$, και όταν η είσοδος ξεπερνά το κατώφλι αυτό, η συνάρτηση δίνει την τιμή 1, ενεργοποιώντας τον νευρώνα. Αντίθετα, όταν η είσοδος δεν ξεπερνά το κατώφλι, η συνάρτηση δίνει την τιμή 0 και ο νευρώνας παραμένει ανενεργός (βλ. Σχήμα 2.3). Αυτός είναι και ο λόγος που η συνάρτηση αυτή είναι ιδιαίτερα χρήσιμη σε προβλήματα δυαδικής ταξινόμησης.

$$f(v) = \begin{cases} 0, & \text{για } v < 0 \\ 1, & \text{για } v \geq 0 \end{cases}$$

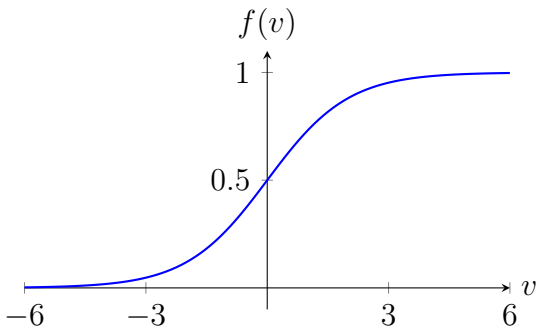


Σχήμα 2.3: Μαθηματική έκφραση και γραφική βηματικής συνάρτησης

- **Σιγμοειδής συνάρτηση** : Μετατρέπει τις τιμές εισόδου, οποιουδήποτε μεγέθους, σε τιμές εξόδου που βρίσκονται στο διάστημα μεταξύ 0 και 1, αντιστοιχίζοντας έτσι τις προβλεπόμενες τιμές σε πιθανότητες (βλ. Σχήμα 2.4). Με αυτόν τον τρόπο κανονικοποιείται η έξοδος κάθε νευρώνα.

  Η συγκεκριμένη συνάρτηση είναι μονότονη σε όλο το πεδίο ορισμού της και εύκολα διαφορίσιμη. Ωστόσο, η παράγωγός της δεν είναι μονότονη. Η σιγμοειδής συνάρτηση παρουσιάζει

$$f(v) = \frac{1}{1 + e^{-v}}$$

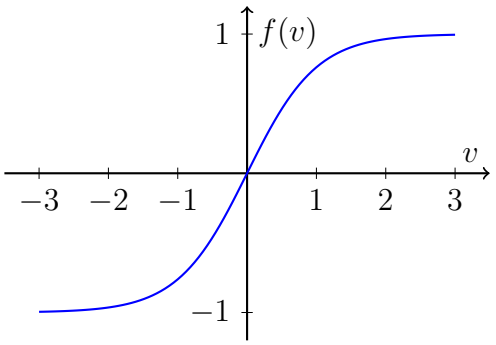


Σχήμα 2.4: Γράφημα Σιγμοειδούς Συνάρτησης

προβλήματα κυρίως σε βαθιά δίκτυα, κυρίως λόγω του ότι η παράγωγός της γίνεται πολύ μικρή για μεγάλες ή πολύ μικρές τιμές του x. Αυτό το πρόβλημα προκαλείται από τη συρρίκνωση των gradient καθώς μεταδίδεται προς τα πίσω στις προηγούμενες στρώσεις, με αποτέλεσμα η μάθηση να γίνεται πιο αργή ή και να σταματάει τελείως όταν φτάνει στις πρώτες στρώσεις. Αυτό είναι το γνωστό πρόβλημα του vanishing gradient.

- **Συνάρτηση tanh** : Σε όλες σχεδόν τις περιπτώσεις, η tanh είναι καλύτερη απο τη Sigmoid. Είναι μια μαθηματικά τροποποιημένη σιγμοειδής συνάρτηση, η οποία μετατρέπει τις τιμές είσοδου σε τιμές εξόδου στο διάστημα από -1 εώς 1 (βλ. Σχήμα 2.5). Η υπερβολική εφαπτομένη εξακολουθεί να έχει το πρόβλημα του vanishing gradient, αλλά σε μικρότερο βαθμό λόγω του μεγαλύτερου εύρους τιμών της.

$$f(v) = \frac{e^{v} - e^{-v}}{e^{v} + e^{-v}}$$

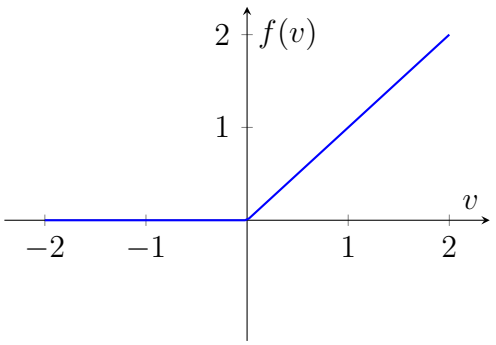


Σχήμα 2.5: Γράφημα υπερβολικής εφαπτομένης

- **Rectified Linear Unit (ReLU)** : Στα μοντέλα βαθιάς μάθησης, η συνάρτηση ενεργοποίησης ReLU αποτελεί μία από τις πιο δημοφιλείς και ευρέως χρησιμοποιούμενες συναρτήσεις ενεργοποίησης. Είναι μία μη γραμμική συνάρτηση, λόγω της ασυνέχειας στο σημείο $x = 0$. Επιπλέον, σε αντίθεση με τις προηγούμενες συναρτήσεις αποτρέπει το πρόβλημα του vanishing gradient. Έτσι, προσφέρει μια πιο εύκολη και γρήγορη εκπαίδευση ποικίλων μοντέλων νευρωνικών δικτύων με καλή απόδοση. Η γραφική της παράσταση απεικονίζεται στο Σχήμα 2.6.

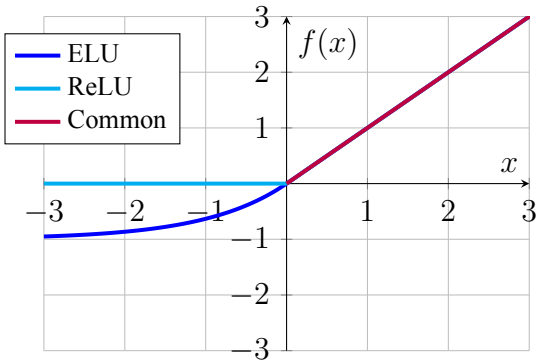
- **Exponential Linear Unit (ELU)** : Η ELU είναι παρόμοια της ReLU, καθώς για θετικές τιμές εισόδου x, η εξίσωση παράγει αυστηρά μια τιμή x, όπως και η ReLU, αλλά για αρνητικές τιμές η έξοδος είναι α φορές το $e^{x} - 1$. Το α είναι μια υπερπαράμετρος που ελέγχει την τιμή των αρνητικών εισόδων για τις οποίες η ELU φτάνει σε κορεσμό. Προκειμένου να επιτευχθεί ο μέσος όρος των ενεργοποιήσεων πιο κοντά στο μηδέν, οι ELUs έχουν αρνητικές τιμές. Όταν η κλίση είναι πιο κοντά στη φυσική κλίση, αυτό επιτρέπει ταχύτερη εκμάθηση. Επιπλέον, αποφεύγεται το πρόβλημα των dying neurons, χάρη στη χρήση της εκθετικής συνάρτησης, οι νευρώνες συνεχίζουν να μαθαίνουν ακόμα και όταν x<0. Ακολουθούν οι γραφικές παραστάσεις των συναρτήσεων ReLU και ELU, για σύγκριση στο Σχήμα 2.7.

$$f(v) = \begin{cases} v, & \text{αν } v \geq 0 \\ 0, & \text{αν } v < 0 \end{cases} = \max(v, 0)$$



Σχήμα 2.6: Γράφημα συνάρτησης ReLU

$$f(x) = \begin{cases} x, & \text{αν } x > 0 \\ \alpha(e^x - 1), & \text{αν } x \leq 0 \end{cases}$$



Σχήμα 2.7: Σύγκριση γραφημάτων συνάρτησης ReLU και ELU

Συνοπτικά παρουσιάζονται οι πιο συχνές συναρτησείς ενεργοποίησης στον παρακάτω πίνακα:

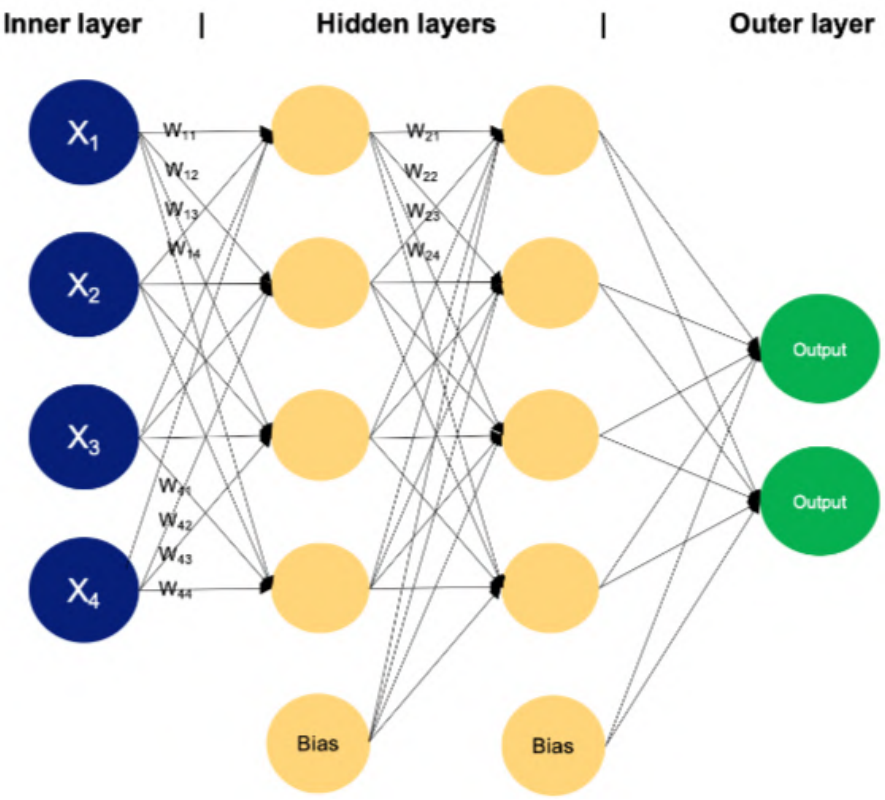
Συνάρτηση Ενεργοποίησης	**Εξίωση**	**Πραάγωγος**
Step Function	$f(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$	Μη παραγωγίσιμη στο $x = 0$, αλλού 0
Sigmoid	$f(x) = \dfrac{1}{1 + e^{-x}}$	$f'(x) = f(x)(1 - f(x))$
Tanh	$f(x) = \tanh(x) = \dfrac{e^x - e^{-x}}{e^x + e^{-x}}$	$f'(x) = 1 - f(x)^2$
ReLU	$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases}$	$f'(x) = \begin{cases} 1, & x > 0 \\ 0, & x < 0 \end{cases}$
ELU	$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha(e^x - 1), & x < 0 \end{cases}$	$f'(x) = \begin{cases} 1, & x > 0 \\ f(x) + \alpha, & x \leq 0 \end{cases}$

Πίνακας 2.1: Συναρτήσεις ενεργοποίησης με τις παραγώγους τους

2.1.5 Πολυεπίπεδα τεχνητά νευρωνικά δίκτυα

Το πολυεπίπεδο ΤΝΔ (MultiLayer Perceptron (MLP) αποτελείται από πολλά επίπεδα διασυνδεδεμένων νευρώνων (perceptons) που είναι οργανωμένα σε στρώματα, καθένα από τα οποία συνδέεται με το επόμενο μέσω συνάψεων (weights, bias). Ένα MLP αποτελείται από **τουλάχιστον** τρία επίπεδα κόμβων (input, hidden και output layer), όπως αναλύθηκε παραπάνω (Ενότητα 2.2).

Οι νευρώνες σε ενα MLP δεν συνδέονται με αυτούς στο ίδιο στρώμα, αλλά με κάθε νευρώνα στο στρώμα πριν από αυτό, καθώς και με κάθε νευρώνα σε στρώμα μετά από αυτό. Συγκεκριμένα, στα



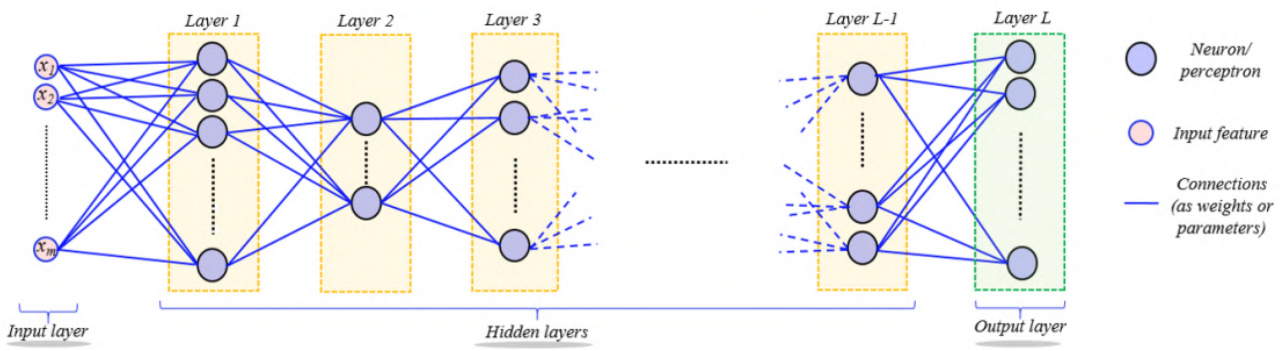
Σχήμα 2.8: Νευρωνικό δίκτυο πολλαπλών στρωμάτων
[13]

hidden layers καθε νευρώνας λαμβάνει είσοδο από όλους τους νευρώνες στο προηγούμενο επίπεδο. Οι είσοδοι πολλαπλασιάζονται με τα αντίστοιχα βάρη (w). Επίσης, κάθε νευρώνας έχει μια σχετική πόλωση (b), η οποία προστίθεται στο άθροισμα των γινομένων (Εξίσωση (2.1)). Τα βάρη και η πόλωση, μαθαίνονται από το μόντελο κατά τη διάρκεια της εκπαίδευσης του. Έπειτα, το άθροισμα των γινομένων περνά από την συνάρτηση ενεργοποίησης, εισάγωντας τη μη γραμμικότητα στο δίκτυο. Η συνάρτηση ενεργοποίησης μετατρέπει το άθροισμα σε μια τιμή εξόδου, που χρησιμοποιείται είτε από τον επόμενο νευρώνα είτε ως τελική έξοδος. Οι νευρώνες που βρίσκονται στο τελευταίο hidden layer δίνουν είσοδο για τον κάθε νευρώνα στο output layer, ο οποίος εφαρμόζει μια συνάρτηση ενεργοποίησης. Αυτή η συνάρτηση ενεργοποίησης είναι μερικές φορές διαφορετική από αυτήν που χρησιμοποιείται στα hidden layers και παράγει την τελική τιμή εξόδου ή την πρόβλεψη. Στο Σχήμα 2.8 είναι ένα πλήρως συνδεδεμένο MLP που έχει τέσσερις τιμές εισόδου, δύο κρυφά επίπεδα, και δύο τιμές εξόδου.

Ο λόγος που ονομάζονται τα ενδιάμεσα στρώματα ”κρυφά” είναι γιατί αποτελούν το ”εσωτερικό” του νευρωνικού δικτύου, όπου πραγματοποιούνται πολύπλοκοι υπολογισμοί και εξαγωγή χαρακτηριστικών, που είναι μη ορατοί από τον χρήστη. Για παράδειγμα, σε ένα δίκτυο που αναγνωρίζει εικόνες, τα κρυφά στρώματα μπορεί να μάθουν να αναγνωρίζουν χαρακτηριστικά όπως γραμμές, καμπύλες ή σύνθετα μοτίβα που δεν είναι ορατά μεμονωμένα από τα δεδομένα εισόδου. Στην πράξη ο χρήστης παρατηρεί μόνο την είσοδο και την έξοδο του δικτύου. Αυτό συμβαίνει, διότι οι ενδιάμεσες τιμές δεν χρησιμοποιούνται άμεσα για την εκτίμηση της απόδοσης του μοντέλου. Το κομμάτι της αξιολόγησης των σφαλμάτων στηρίζεται καθαρά στην σύγκριση των εξόδων που προέβλεψε στο τέλος το μοντέλο με τις ιδανικές, θεωρητικές τιμές που θα έπρεπε να έχουν προκύψει, σύμφωνα με τα δεδομένα εισόδου που του παρασχέθηκαν.

2.1.6 Βαθιά Νευρωνικά Δίκτυα-Deep Neural Networks

Τα MLPs είναι μια υποκατηγορία των deep neural networks (DNN), καθώς αποτελούνται μόνο από πλήρως συνδεδεμένα επίπεδα (Fully Connected Layers), ενώ τα DNN περιλαμβάνουν πιο εξειδικευμένες τεχνικές. Συγκεκριμένα, τα DNN αποτελούν την βάση της βαθιάς μάθησης (Deep Learning) και χρησιμοποιούνται για πολύπλοκα προβλήματα, φέρνοντας επανάσταση στην τεχνητή νοημοσύνη, καθώς επιτρέπουν σε υπολογιστικές μηχανές να μαθαίνουν δεδομένα με εντυπωσιακή ακρίβεια και προσαρμοστικότητα. Στο Σχήμα 2.9 φαίνεται ένα παράδειγμα δικτύου με επίπεδα L. Κάθε επίπεδο



Σχήμα 2.9: Deep Neural Network with L layers
[2]

$\boldsymbol{i}$ παίρνει ως είσοδο την έξοδο του προηγούμενου επιπέδου $\boldsymbol{i-1}$. Η τελική πρόβλεψη του δικτύου είναι η έξοδος $\hat{y}$ του τελευταίου επιπέδου. Αυτό περιγράφεται από την παρακάτω εξίσωση:

$$\hat{y} = z^L(z^{L-1}(...z^1(x))) \tag{2.2}$$

όπου $\boldsymbol{z^i}$ είναι η έξοδος του i-οστού επιπέδου και x είναι η αρχική είσοδος. Η έξοδος $\boldsymbol{z^i}$ υπολογίζεται από την εξίσωση:

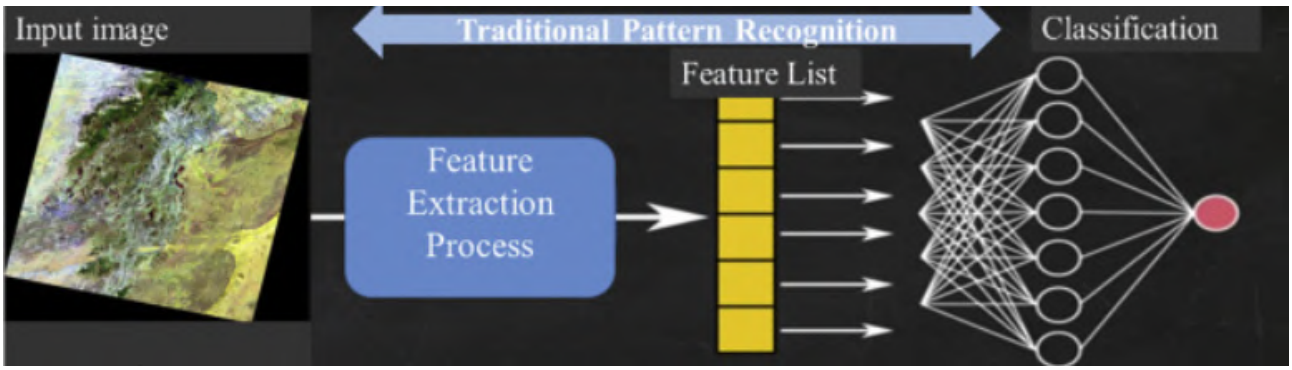
$$z^i = f(W \cdot z^{i-1} + b) \tag{2.3}$$

Τα DNN χρησιμοποιούνται ευρέως στην υπολογιστική όραση (Computer Vision), για την επεξεργασία και ανάλυση εικόνων και βίντεο, στην επεξεργασία φυσική γλώσσας (Natural Language Processing - NLP), στην ρομποτική και στα αυτόνομα συστήματα, καθώς και σε πολλές ακόμα εφαρμογές, οι οποίες απαιτούν την επεξεργασία μεγάλων και πολύπλοκων δεδομένων. Σε αυτήν την εργασία θα γίνει εστίαση στην αναγνώριση συγκεκριμένων χαρακτηριστικών της εικόνας.

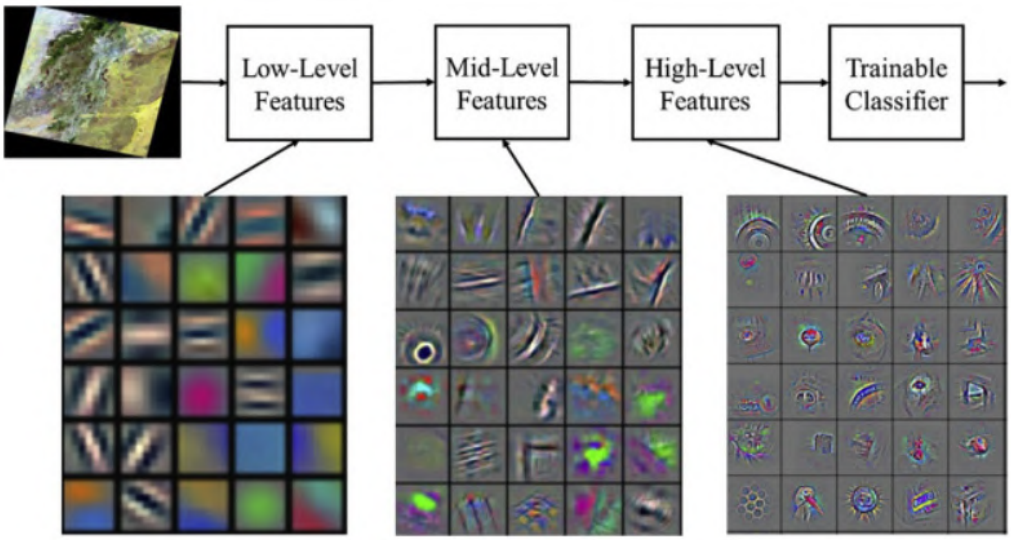
Πριν από την βαθιά μάθηση, η διαδικασία εξαγωγής χαρακτηριστικών (feature extraction) γινόταν χειροκίνητα, επιλέγοντας τα σημαντικά χαρακτηριστικά από τα δεδομένα εισόδου, όπως χρώματα, γωνίες, ακμές και τροδοδοτώντας τα σε έναν κλασικό νευρωνικό ταξινομητή για να κάνει την πρόβλεψη. Η διαδικασία αυτή απαιτούσε μεγάλη γνώση του αντικειμένου και προφανώς ήταν χρονοβόρα. Στο Σχήμα 2.10 απεικονίζεται αυτή η παραδοσιακή αναγνώριση προτύπων.

Παρ' όλα αυτά, οι αλγόριθμοι βαθιάς μάθησης εξάγουν αυτόματα χαρακτηριστικά από τα δεδομένα μειώνοντας την ανθρώπινη παρέμβαση. Αυτό επιτυγχάνεται μέσω μιας ιεραρχικής διαδικασίας, όπου τα νευρωνικά δίκτυα μαθαίνουν από απλά χαρακτηριστικά και στη συνέχεια συνθέτουν πιο σύνθετες δομές (βλ. Σχήμα 2.11). Ουσιαστικά, στα αρχικά κρυφά επίπεδα, το δίκτυο μαθαίνει βασικά χαρακτηριστικά χαμηλού επιπέδου (low-level-features), όπως ακμές, κορυφές, blobs. Στα επόμενα επίπεδα, αρχίζει να αναγνωρίζει πιο σύνθετα μοτίβα μεσσαίου επιπέδου (mid-level-features), ενώ στα τελευταία επίπεδα κατανοεί υψηλού επιπέδου χαρακτηριστικά (high-level-features), όπως ολόκληρα τμήματα μια εικόνας (αντικείμενα, φύλλα δέντρων).

Αυτοί οι πίνακες με τα χαρακτηριστικά ονομάζονται χάρτες χαρακτηριστικών (**feature maps**). Τα feature maps παίζουν πολύ σημαντικό ρόλο στα DNN, ειδικά στα Convolutional Neural Networks, τα οποία θα αναλυθούν σε παρακάτω κεφάλαιο.



Σχήμα 2.10: Traditional Pattern Recognition
[33]



Σχήμα 2.11: Ιεραρχική εκμάθηση χαρακτηριστικών
[33]

2.1.7 Εκπαίδευση νευρωνικού δικτύου

Αφού κατανοηθούν η δομή και η λειτουργία ενός πολυεπίπεδου και βαθιού τεχνητού νευρωνικού δικτύου, το επόμενο σημαντικό στάδιο είναι η κατανόηση της διαδικασίας εκπαίδευσής του. Η επιτυχία της διαδικασίας της εκπαίδευσης εξαρτάται από την ικανότητα του δικτύου να γενικεύει σωστά από τα δεδομένα εκπαίδευσης σε νέα, άγνωστα δεδομένα. Με την πρόοδο στους αλγορίθμους και την υπολογιστική ισχύ, η εκπαίδευση των νευρωνικών δικτύων έχει γίνει πιο αποδοτική, καθιστώντας τα εργαλεία βασικά για πολλές εφαρμογές στην τεχνητή νοημοσύνη και τη μηχανική μάθηση. Κατά την εκπαίδευση, το νευρωνικό δίκτυο μαθαίνει να προσαρμόζει τα βάρη και τις πολώσεις των νευρωνικών συνδέσεων, με σκοπό να μειώσει το σφάλμα και κατ' επέκταση να έχει μεγαλύτερη ακρίβεια στις προβλέψεις. Οι μέθοδοι με τις οποίες μαθαίνουν τα δίκτυα είναι με την βοήθεια των αλγορίθμων βελτιστοποίησης. Ο αλγόριθμος που θεωρείται επικρατέστερος μέχρι στιγμής είναι η **κάθοδος κλίσης (Gradient Descent)**. Παρ' όλα αυτά, κάποιοι ακόμα γνωστοί είναι ο RMSprop, **Adam** και οι γενετικοί αλγόριθμοι (Genetic Algorithms).

Συνάρτηση κόστους

Για την εκπαίδευση ενός νευρωνικού δικτύου, χρειάζεται η μέτρηση του πόσο κοντά βρίσκονται οι προβλέψεις στις επιθυμητές εξόδους, δηλαδή το $\hat{y}$ να τείνει στο y. Η μέτρηση αυτού του σφάλματος γίνεται μέσω μιας μαθηματικής συνάρτησης που ονομάζεται συνάρτηση κόστους (μέση απώλεια ό-

ταν πρόκειται για ολόκληρο σύνολο δεδομένων εκπαίδευσης) ή συνάρτηση απώλειας - Loss function (όταν έχουμε ένα μόνο παράδειγμα εκπαίδευσης/εισαγωγής). Κατά τη διαδικασία της εκπαίδευσης, η συνάρτηση κόστους μειώνεται λόγω των επαναλαμβανόμενων τροποποιήσεων των βαρών του δικτύου. Όταν η τιμή της συνάρτησης κόστους είναι πολύ μικρή, δηλαδή θα υπάρχουν μικρά σφάλματα, σημαίνει ότι το δίκτυο έχει εκπαιδευτεί και μπορεί να κάνει ακριβείς προβλέψεις. Δύο από τις πιο σημαντικές συναρτήσεις κόστους που χρησιμοποιούνται για ταξινόμηση και παλινδρόμηση είναι:

Μέσο Τετραγωνικό Σφάλμα (Mean Square Error - MSE): Για προβλήματα παλινδρόμησης (regression), μια πολύ συχνή συνάρτηση κόστους είναι το μέσο τετραγωνικό σφάλμα (MSE), που ορίζεται ως:

$$J(y, \hat{y}) = MSE(y, \hat{y}) = \frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i)^2 \tag{2.4}$$

όπου J συμβολίζεται η συνάρτηση κόστους (συνήθως συμβολίζεται με J ή L) και N το πλήθος των δειγμάτων στο σύνολο δεδομένων. Το y_i είναι η πραγματική τιμή της εξόδου και $\hat{y}_i$ είναι η πρόβλεψη του δικτύου. Σκοπός είναι $y_i \approx \hat{y}_i$, δηλαδή η συνάρτηση να τείνει όσο περισσότερο γίνεται στο μηδέν. Στην εξίσωση (2.4) υπολογίζεται το άθροισμα για όλα τα δείγματα των δεδομένων εκπαίδευσης, καθώς είναι απαραίτητο το μοντέλο να παρουσιάζει ικανοποιητική απόδοση σε ολόκληρο το σύνολο των δεδομένων. Η διαδικασία αυτή δεν συμβάλλει μόνο στην επίτευξη υψηλής ακρίβειας στα δεδομένα εκπαίδευσης, αλλά και στην εξαγωγή μιας συνολικής εικόνας της απόδοσής του. Χρήσιμο θα ήταν να εξηγηθεί ολόκληρη η διαδικασία με συγκεκριμένη συνάρτηση κόστους.

Διασταυρούμενη εντροπία (Cross-Entropy): Ένα παράδειγμα συνάρτησης απώλειας για πρόβλημα ταξινόμησης (classification), είναι η διασταυρούμενη εντροπία, που ορίζεται ως:

$$J(y, \hat{y}) = H(y, \hat{y}) = \sum_{i=1}^{N}\sum_{j=1}^{C} y_i^j \log \hat{y}_i^j \tag{2.5}$$

όπου C είναι ο αριθμός των κατηγοριών (ή κλάσεων), y_i^j είναι η πραγματική τιμή (label) του δείγματος i για την κατηγορία j. Συνήθως, αυτά τα labels είναι one-hot encoded, δηλαδή παίρνουν την τιμή 1 για τη σωστή κατηγορία και 0 για τις υπόλοιπες.

Με βάση την συνάρτηση κόστους, η διαδικασία εκπαίδευσης ενός νευρωνικού δικτύου μπορεί να θεωρηθεί ως ένα πρόβλημα βελτιστοποίησης. Όπως προαναφέρθηκε, ο σκοπός είναι να βρεθούν οι κατάλληλες τιμές των βαρών και των πολώσεων, ώστε η συνάρτηση κόστους να πάρει την ελάχιστη δυνατή τιμή. Αυτό διατυπώνεται μαθηματικά ως εξής:

$$\theta^* = \arg\min_{\theta} J(y, \hat{y}) \tag{2.6}$$

Αυτή η μαθηματική σχέση εκφράζει το πρόβλημα της βελτιστοποίησης, δηλαδή την εύρεση των παραμέτρων (θ) που ελαχιστοποιούν τη συνάρτηση κόστους (J). Όλες οι εκπαιδεύσιμες μεταβλητές θεωρούνται παράμετροι, δηλαδή στην συγκεκριμένη περίπτωση τα βάρη και οι πολώσεις του κάθε νευρώνα. Έτσι, για την επίλυση τέτοιων προβλημάτων χρειάζεται ο αλγόριθμος gradient descent ή γενικά κάποιος αλγόριθμος βελτιστοποίησης. Ο αλγόριθμος της καθοδικής κλίσης χρησιμοποιεί την παράγωγο της συνάρτησης κόστους για να προσαρμόσει τα βάρη ενός νευρωνικού δικτύου με στόχο τη μείωση του λάθους. Γι' αυτό και τέτοιες προσεγγίσεις απαιτούν την συνάρτηση κόστους να είναι παραγωγίσιμη. Αυτή η σχέση της παραγώγου της συνάρτησης κόστους ως προς τις παραμέτρους της, μπορεί να εκφραστεί μέσω του Ιακωβιανού πίνακα:

$$\nabla_{w_i} J(y, \hat{y}) = \frac{\partial J(y, \hat{y})}{\partial w_i} \tag{2.7}$$

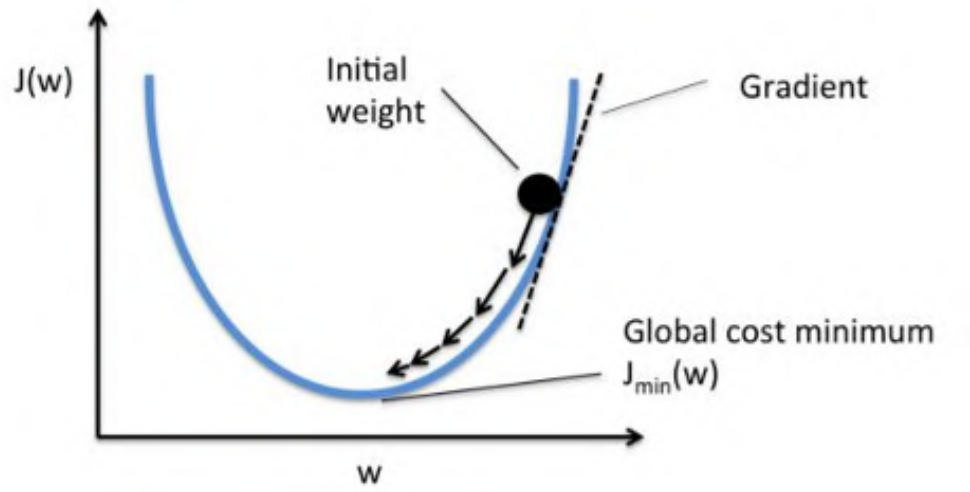
Η βασική ιδέα του αλγορίθμου είναι ότι η συνάρτηση κόστους θα μειώνεται όσο προχωράμε προς την αντίθετη κατεύθυνση της παραγώγου. Ο αλγόριθμος εκτελεί επαναλαμβανόμενες ενημερώσεις, αφαιρώντας από τα βάρη την παράγωγο τους ως προς το κόστος. Αυτό περιγράφεται από τον ακόλουθο κανόνα:

$$W_{t+1} = W_t - \alpha \nabla_{w_i} J(y, \hat{y}) \tag{2.8}$$

όπου W_t είναι το διάνυσμα των βαρών στη χρονική στιγμή t, ενώ W_{t+1} είναι τα νέα βάρη που προκύπτουν μετά την ενημέρωση. Η παράμετρος $\alpha \in \mathbb{R}^+$ είναι ο ρυθμός μάθησης (learning rate), που ελέγχει το μέγεθος των αλλαγών στα βάρη σε κάθε επανάληψη. Αν ο ρυθμός μάθησης είναι πολύ μικρός, η σύγκλιση μπορεί να είναι αργή, ενώ αν είναι πολύ μεγάλος, το μοντέλο μπορεί να γίνει ασταθές. Αν η προσοχή τεθεί σε κάθε μεμονωμένο βάρος w_i, η διαδικασία ενημέρωσης γράφεται ως:

$$w_i^{t+1} = w_i^t - \alpha \frac{\partial J(y, \hat{y})}{\partial w_i} \tag{2.9}$$

όπου w_i^t είναι η τιμή του συγκεκριμένου βάρους στην επανάληψη t και w_i^{t+1} η νέα τιμή μετά την ενημέρωση. Ο στόχος του αλγορίθμου είναι, μετά από πολλές επαναλήψεις, η κλίση να συγκλίνει στο μηδέν και να γίνονται ελάχιστες ανανεώσεις των w. Έτσι, έχουμε το σημείο σύγκλισης, το οποίο είναι ουσιαστικά το σταθερό σημείο που έχει καταλήξει ο αλγόριθμος και δεν θα αλλάξει με την πάροδο του χρόνου. Το χαμηλότερο σημείο ολόκληρης της συνάρτησης κόστους ονομάζεται ολικό ελάχιστο, ενώ το χαμηλότερο σημείο για μία συγκεκριμένη περιοχή ονομάζεται τοπικό ελάχιστο.



Σχήμα 2.12: Αναπαράσταση του αλγορίθμου καθόδου κλίσης

Στο Σχήμα 2.12 φαίνεται η διαδικασία του αλγορίθμου gradient descent για να φτάσει στο ελάχιστο σημείο. Αξίζει να τονιστεί ότι στην προκειμένη περίπτωση, η συνάρτηση κόστους είναι κυρτή. Αυτό συνεπάγεται ότι διαθέτει ένα ολικό ελάχιστο, αντί για απλά τοπικά ελάχιστα. Ωστόσο, σε πολλά προβλήματα μηχανικής μάθησης, η συνάρτηση κόστους δεν παρουσιάζει κυρτότητα, γεγονός που καθιστά απαραίτητη την εφαρμογή ειδικών τεχνικών, εννοιών ή αλγορίθμων κατά τη διαδικασία της εκπαίδευσης. Οι μέθοδοι αυτές προέρχονται από τον κλάδο των μαθηματικών που ονομάζεται κυρτή βελτιστοποίηση. Στην συγκεκριμένη, όμως, περίπτωση αξίζει να επεξηγηθεί ότι εάν το αρχικό σημείο βρίσκεται δεξιά του ολικού ελαχίστου η παράγωγος θα ήταν θετική, άρα σύμφωνα με την σχέση 2.9 το w θα μειωνόταν. Αντίθετα, όταν το αρχικό σημείο βρίσκεται αριστερά του ολικού ελαχίστου, τότε το w θα αυξανόταν.

2.1.8 Αλγόριθμος οπισθοδιάδοσης

Με στόχο μια γρήγορη και ομαλή εκπαίδευση, θα πρέπει να υπολογίζονται οι παράγωγοι στους αλγορίθμους εκπαίδευσης με έναν αποδοτικό αλγόριθμο, ο οποίος θα μειώνει τον υπολογιστικό φόρτο. Γι' αυτό το λόγο, έχει επιλεχθεί ο αλγόριθμος της οπισθοδιάδοσης (backward propagation).

Αυτός ο αλγόριθμος εκμεταλλεύεται την ιδιότητα των νευρωνικών δικτύων να εξαρτώνται οι παράγωγοι (ρυθμοί μεταβολής) από ένα επίπεδο σε ένα άλλο, αφού τα επίπεδα συνδέονται σειριακά μεταξύ τους. Έτσι, υπολογίζονται οι παράγωγοι προς τα πίσω, ξεκινώντας από το τελευταίο επίπεδο του δικτύου και προχωρώντας σταδιακά προς το πρώτο, με την βοήθεια του κανόνα της αλυσίδας. Με αυτόν τον τρόπο, η παράγωγος ενός ενδιάμεσου επιπέδου i υπολογίζεται γρήγορα, επειδή στηρίζεται στις ήδη υπολογισμένες τιμές του επιπέδου $i + 1$. Η διαδικασία αυτή περιγράφεται με την εξίσωση 2.10, η οποία εκφράζει την παράγωγο μίας συνάρτησης κόστους ως αλυσίδα μερικών παραγώγων των διαδοχικών επιπέδων. Ο αλγόριθμος αντλεί την ονομασία του από το γεγονός ότι η διάδοση των παραγώγων γίνεται από τα τελικά επίπεδα προς τα αρχικά.

$$\frac{\partial J(y, \hat{y})}{\partial w_i} = \frac{\partial J(y, \hat{y})}{\partial z_L} \cdot \frac{\partial z_L}{\partial z_{L-1}} \cdots \frac{\partial z_i}{\partial w_i} \tag{2.10}$$

Κατά την εκπαίδευση ενός νευρωνικού δικτύου, η διαδικασία χωρίζεται σε **εποχές** (epochs). Σε κάθε εποχή γίνεται μια πλήρης διέλευση όλων των δεδομένων εκπαίδευσης μέσα από το δίκτυο, δηλαδή το δίκτυο "βλέπει" από μία φορά όλα τα δεδομένα εκπαίδευσης. Οπότε, και σε κάθε εποχή, το δίκτυο προσαρμόζει τα βάρη του. Αν ο αλγόριθμος εκπαίδευσης επεξεργαζόταν όλα τα δεδομένα μαζί, τότε σε κάθε εποχή θα έπρεπε να φορτωθεί ολόκληρος ο πολυδιάστατος πίνακας των δεδομένων στη μνήμη. Παρ' όλα αυτά, σε πραγματικές εφαρμογές βαθιών νευρωνικών δικτύων, αυτοί οι πίνακες είναι τεράστιοι, λόγω και του μεγάλου όγκου δεδομένων. Επίσης τα δίκτυα μπορεί να έχουν εκατομμύρια βάρη, κάτι που απαιτεί μεγάλη υπολογιστική ισχύ.

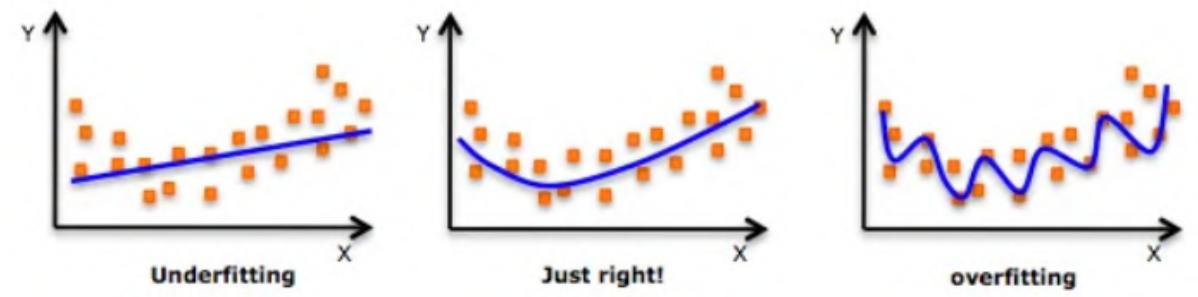
Για να αντιμετωπιστεί αυτό το πρόβλημα χρησιμοποιούνται οι **παρτίδες** (batches). Με αυτόν τον τρόπο, το δίκτυο δεν τροφοδοτείται ταυτόχρονα με όλα τα δεδομένα, αλλά τροφοδοτείται με μικρότερα σύνολα δεδομένων. Με τη χρήση των παρτίδων, η διαδικασία της εκπαίδευσης διαφοροποιείται ελαφρώς. Κάθε παρτίδα περιλαμβάνει ένα υποσύνολο των δεδομένων εκπαίδευσης και σε καθεμία υπολογίζεται η συνάρτηση κόστους για τα δεδομένα της και μετέπειτα γίνονται οι ανανεώσεις των βαρών. Αυτό σημαίνει ότι κατά τη διάρκεια μίας εποχής, το δίκτυο περνάει από όλες τις εποχές, και άρα από όλα τα δεδομένα, απλά αυτό γίνεται σταδιακά. Ο αριθμός των παρτίδων εξαρτάται από το μέγεθος της κάθε παρτίδας (**batch size**). Για παράδειγμα, αν χρησιμοποιείται batch size 128 και υπάρχουν συνολικά 12.800 δείγματα, τότε κάθε εποχή περιλαμβάνει 100 παρτίδες.

Ωστόσο, κατά την εκπαίδευση ενός νευρωνικού δικτύου, δεν αρκεί το μοντέλο απλώς να μάθει τα δεδομένα εκπαίδευσης, αλλά να είναι ικανό να τα γενικεύσει σωστά (generalization), δηλαδή να μπορεί να αποδώσει καλά και σε νέα, άγνωστα δεδομένα. Εδώ εμφανίζεται ένα από τα πιο συχνά προβλήματα στην εκπαίδευση, η υπερπροσαρμογή (**overfitting**). Η υπερπροσαρμογή εμφανίζεται όταν το μοντέλο μαθαίνει υπερβολικά καλά τα δεδομένα εκπαίδευσης, σε σημείο που αρχίζει να τα "παπαγαλίζει". Αυτό έχει ως αποτέλεσμα να παρουσιάζει εξαιρετικά μικρό σφάλμα στο σετ εκπαίδευσης, αλλά πολύ υψηλό σφάλμα στο σετ αξιολόγησης. Υπάρχουν δύο κύριες αιτίες του προβλήματος αυτού. Η πρώτη είναι ότι το μοντέλο στη διαδικασία της εκπαίδευσης μπορεί να μαθαίνει και τον θόρυβο (πχ. κάποια χαρακτηριστικά που δεν έχουν κάποια σχέση με το πρόβλημα) που εμπεριέχουν τα δείγματα και η δεύτερη είναι η χωρητικότα του μοντέλου. Μοντέλα με πολλά επίπεδα έχουν περισσότερες πιθανότητες για overfitting, ειδικά όταν τα δεδομένα εκπαίδευσης είναι λίγα. Μία ακόμα αιτία είναι όταν η υπερβολική εκπαίδευση του μοντέλου, δηλαδή όταν υπάρχουν παραπάνω εποχές από όσες χρειάζονται.

Από την άλλη πλευρά, όταν το μοντέλο είναι πολύ απλό (μικρή χωρητικότητα) για την πολυπλοκότητα του προβλήματος, παρατηρείται το φαινόμενο της υποπροσαρμογής (**underfitting**). Σε αυτή την περίπτωση, το μοντέλο αποτυγχάνει να αποδώσει καλά ακόμη και στα δεδομένα εκπαίδευσης,

γιατί δεν έχει αρκετή ικανότητα για να ”κατανοήσει” τις πιο σύνθετες σχέσεις των δεδομένων.

Οπότε, η λύση βρίσκεται στη δημιουργία ενός μοντέλου με ισορροπία, δηλαδή να μαθαίνει τα δεδομένα εκπαίδευσης, χωρίς όμως να τα αποστηθίζει, και να μπορεί να τα γενικεύει σωστά σε άγνωστα δεδομένα.



Σχήμα 2.13: Παράδειγμα υποπρορσαρμογής, υπερπροσαρμογής και ενός μοντέλου ”σωστού” [36]

Στο 2.13 είναι ένα πρόβλημα γραμμικής παλινδρόμησης και φαίνεται στο πρώτο γράφημα (underfitting) ότι το μοντέλο είναι απλό και σχηματίζει μία απλή γραμμη, αγνοώντας την καμπυλότητα των σημείων. Στο μεσαίο γράφημα (just right), το μοντέλο έχει «μάθει» με επαρκή τρόπο τις γενικές σχέσεις μεταξύ των σημείων, χωρίς να δίνει σημασία σε ακραίες τιμές ή στον θόρυβο. Τέλος, στο τρίτο γράφημα (overfitting) το μοντέλο προσπαθεί να περάσει από όλα τα σημεία, ακόμα κι αν κάνει αυτές τις πολύπλοκες αλλαγές στην πορεία του.

2.1.9 Βαθιά Συνελικτικά Νευρωνικά Δίκτυα (DCNN)

Οι αλγόριθμοι βαθιάς μάθησης ταξινομούνται, κυρίως σε: Συνελικτικά Νευρωνικά Δίκτυα (CNNs), Αναδρομικά Νευρωνικά Δίκτυα (RNNs), Περιορισμένα Μπολτσμανιανά Μηχανήματα (RBMs), Αυτοκωδικοποιητές (Autoencoders). Τα δύο πρώτα ανήκουην στην επιβλεπόμενη μάθηση, και τα άλλα δύο στην μη-επιβλεπόμενη μάθηση. Στην παρούσα εργασία, έχουν χρησιμοποιηθεί τα CNN, καθώς είναι η πιο διαδεδομένη και αποτελεσματική προσέγγιση για αυτό το είδος προβλήματος, και γι’ αυτόν τον λόγο θα εστιαστεί σε αυτά το ενδιαφέρον. Αξίζει, όμως, να αναφερθούν κάποια σημαντικές πληροφορίες και για τα υπόλοιπα.

Τα RNN χρησιμοποιούνται, κυρίως, στην επεξεργασία ακολουθιακών δεδομένων σε προβλήματα όπου τα δεδομένα είναι διατεταγμένα χρονικά ή εξαρτώνται από προηγούμενες καταστάσεις. Αυτό συμβαίνει επειδή χρησιμοποιούν σαν βάση αναδρομικά στρώματα. Ένα αναδρομικό στρώμα διαθέτει έναν μηχανισμό ”βρόχου” που επιτρέπει στην είσοδο του να αποτελείται τόσο από τα τρέχοντα δεδομένα προς ανάλυση, όσο και από την έξοδο από έναν προηγούμενο υπολογισμό που πραγματοποιήθηκε στο ίδιο στρώμα. Έτσι, για να επιτευχθεί αυτό, τα αναδρομικά στρώματα διαθέτουν μνήμη και ”θυμούνται” προηγούμενες καταστάσεις, χρησιμοποιώντας τις πληροφορίες για μελλοντικές προβλέψεις. Συγκεκριμένα, σε κάθε χρονική στιγμή t, η έξοδος του δικτύου δεν εξαρτάται μόνο από την τρέχουσα είσοδο x_t, αλλά και από την κρυφή κατάσταση (hidden state) του προηγούμενου χρόνου h_{t-1}. Η βασική μαθηματική εξίσωση ενός κλασικού RNN είναι:

$$h_t = f(W_x x_t + W_h h_{t-1} + b) \quad \text{και} \quad y_t = g(W_y h_t + c) \tag{2.11}$$

όπου h_t είναι η κρυφή κατάσταση στο χρόνο t και y_t είναι η έξοδος. Τα W_x, W_h, W_y είναι οι πίνακες βαρών, τα b, c είναι οι μεταβλητές μετατόπισης, f είναι η μη γραμμική συνάρτηση ενεργοποίησης, κυρίως είναι η tanh ή η ReLU και τέλος το g είναι η συνάρτηση εξόδου (πχ. softmax).

Τα RBMs είναι ένας τύπος πιθανοτικού νευρωνικού δικτύου. Αποτελούνται από δύο επίπεδα: την ορατή στοιβάδα (που δέχεται δεδομένα εισόδου) και την κρυφή στοιβάδα (που μαθαίνει αναπαραστάσεις των δεδομένων). Σε αντίθεση με τα άλλα νευρωνικά δίκτυα, οι νευρώνες της ίδιας στοιβάδας

δεν συνδέονται μεταξύ τους, με αποτέλεσμα να απλοποιούνται οι υπολογισμοί και να υπάρχει μια πιο γρήγορη εκπαίδευση. Μία από τις κύριες εφαρμογές τους είναι στα συστήματα συστάσεων, όπου χρησιμοποιούνται για την πρόβλεψη των προτιμήσεων χρηστών (π.χ. στο Netflix, στο Amazon).

Οι Autoencoders-AEs είναι ένας τύπος νευρωνικού δικτύου που μαθαίνει να αναπαριστά τα δεδομένα του σε έναν πιο συμπιεσμένο χώρο με μικρότερη διάσταση. Η βασική τους δομή αποτελείται από έναν κωδικοποιητή (encoder) που μετατρέπει την είσοδο σε μία συμπιεσμένη αναπαράσταση και έναν αποκωδικοποιητή (decoder) που προσπαθεί να ανακατασκευάσει τα αρχικά δεδομένα από αυτήν την αναπαράσταση. Οι Αυτόκωδικοποιητές χρησιμοποιούνται σε πολλές εφαρμογές, όπως η συμπίεση δεδομένων, αποθορυβοποίηση εικόνων (denoising autoencoders). Μία από τις βασικές τους χρήσεις είναι η εύρεση σημαντικών χαρακτηριστικών στα δεδομένα, καθιστώντας τους ιδιαίτερα χρήσιμους σε προβλήματα όπου η κλασική Μηχανική Μάθηση αποτυγχάνει λόγω υπερβολικών διαστάσεων των δεδομένων.

Αφού παρουσιάστηκαν οι βασικές κατηγορίες αλγορίθμων βαθιάς μάθησης, θα αναλυθούν παρακάτω εκτενώς CNNs. Πρώτα, όμως, θα πρέπει να επεξηγηθούν κάποιες έννοιες. Για να επιτευχθεί ένα τελικό αποτέλεσμα, όπως η ταξινόμηση μιας εικόνας ή η αναγνώριση ενός αντικειμένου, τα δεδομένα διέρχονται από διαφορετικά επίπεδα του δικτύου. Αυτά τα στρώματα έχουν κάποια χαρακτηριστικά, ανάλογα με το έργο που επιτελούν μέσα σε μια αρχιτεκτονική βαθιού νευρωνικού δικτύου. Οι κυριότεροι και πιο συχνοί τύποι στρωμάτων που συναντώνται σε ένα δίκτυο είναι:

Fully connected layer: Αυτό το στρώμα ονομάζεται και αλλιώς **dense layer** και είναι ένα κλασικό πλήρως συνδεδεμένο στρώμα νευρωνικού δικτύου, όπου κάθε κόμβος εισόδου συνδέεται σε κάθε κόμβο εξόδου. Η χρήση αυτών των στρωμάτων βοηθά στη μοντελοποίηση πολύπλοκων σχέσεων μεταξύ των δεδομένων.

Συνελικτικό στρώμα - Convolutional layer: Είναι ένα από τα κύρια είδη στρώματος που χρησιμοποιούνται στα CNN. Ο πιο κοινός του ρόλος είναι να μπορεί να ανιχνεύει χαρακτηριστικά μέσα σε εικόνες, κάτι που επιτυγχάνεται με τη χρήση φίλτρων. Σε αυτή τη διαδικασία, ένα φίλτρο (ή πυρήνας -kernel) «σαρώνει» την εικόνα, πάνω σε μερικά pixel κάθε φορά (μικρότερα τμήματα της εικόνας - patches). Το φίλτρο αποτελείται από ένα σύνολο βαρών n-διαστάσεων και κάθε στοιχείο του φίλτρου πολλαπλασιάζεται με το αντίστοιχο pixel της εικόνας και έπειτα προστίθενται όλα τα γινόμενα, με αποτέλεσμα να προκύπτει ένα νούμερο. Ουσιαστικά, γίνεται σύγκριση του φίλτρου με κάθε μικρό τμήμα της εικόνας, ώστε να ανιχνευθούν κοινά μοτίβα. Καθώς προχωρά το φίλτρο, δημιουργείται ένας πίνακας (feature map), στον οποίο καταγράφονται τα εντοπισμένα χαρακτηριστικά.

Η διαδικασία γίνεται επαναληπτικά, ξεκινώντας από την πάνω αριστερή γωνία της εικόνας και κινούμενη προς τα δεξιά και κάτω. Το πόσο μετακινείται το φίλτρο κάθε φορά ορίζεται από μια τιμή που λέγεται διασκελισμός (stride). Αν το stride είναι μικρό, η ανάλυση γίνεται πιο λεπτομερής, ενώ αν είναι μεγάλο, η διαδικασία γίνεται πιο γρήγορη αλλά λιγότερο ακριβής. Έτσι, μεγάλο stride, σημαίνει και μεγαλύτερο μέγεθος εξόδου, ενώ μικρό stride, σημαίνει μικρότερο μέγεθος εξόδου. Επιπλέον, γύρω από την εικόνα εισόδου προστίθενται κάποια επιπλέον εικονοστοιχεία, ώστε το φίλτρο να ταιριάζει πάντα στα συνολικά όρια της εικόνας, καλύπτοντας και τις ακριανές περιοχές. Αυτή η διαδικασία ονομάζεται padding.

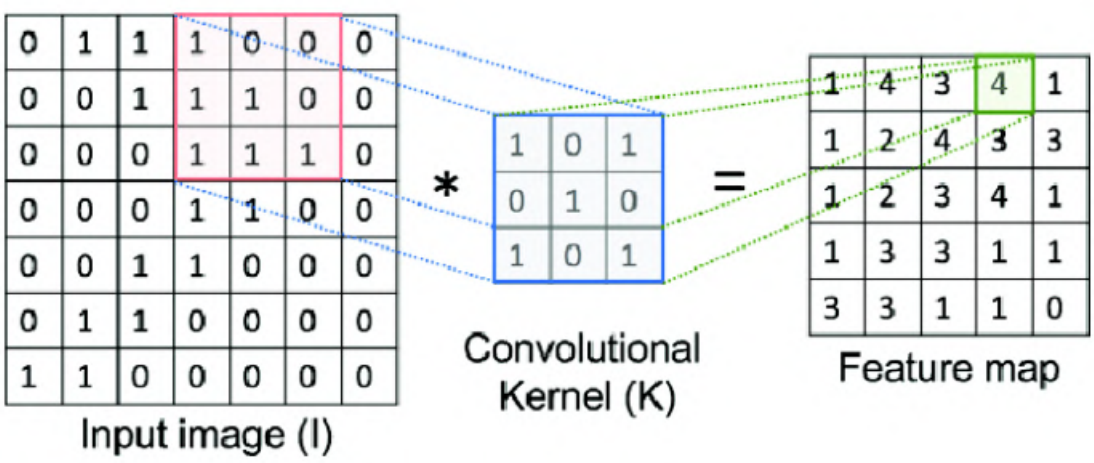
Στην εικόνα 2.14 απεικονίζεται μία εικόνα διάστασης 7x7, στην οποία εφαρμόζεται ένα φίλτρο 3x3 και γίνεται η πράξη της συνέλιξης.

Η συνέλιξη αποτελεί βασική μαθηματική πράξη τόσο στη θεωρία σημάτων όσο και στη λειτουργία των συνελικτικών νευρωνικών δικτύων. Στην απλή περίπτωση της μιας διάστασης, για δύο συναρτήσεις $f(t)$ και $g(t)$, ο τύπος της συνέλιξης είναι:

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

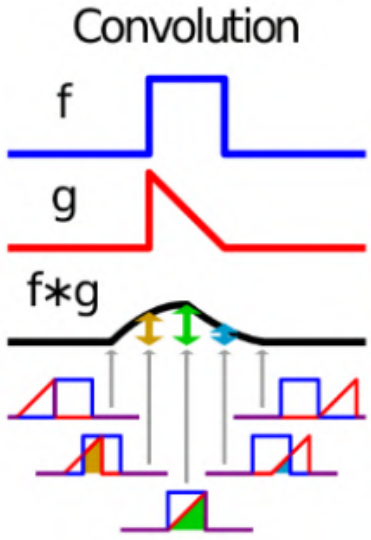
ή εναλλακτικά (όταν είναι σε πεπερασμένα διαστήματα):

$$(f * g)(t) = \int_{0}^{t} f(\tau) \cdot g(t - \tau)\, d\tau$$



Σχήμα 2.14: Η πράξη μίας 2D συνέλιξης της εικόνας I με το φίλτρο K
[38]

Η συνέλιξη περιγράφει ουσιαστικά το ποσοστό της περιοχής της συνάρτησης $g(t)$, το οποίο επικαλύπτει την περιοχή που ορίζει η συνάρτηση $f(t)$, για κάποια συγκεκριμένη στιγμή ενός χρονικού διαστήματος. Στην εικόνα 2.15, η συνάρτηση g ολισθαίνει επάνω στην f, και για κάθε χρονική στιγμή t, υπολογίζεται ο βαθμός επικάλυψής τους μέσω του ολοκληρώματος και προκύπτει ένα νέο σήμα, το οποίο αποτελεί το αποτέλεσμα της συνέλιξης.



Σχήμα 2.15: Συνέλιξη μεταξύ δύο σημάτων
[39]

Στην περίπτωση επεξεργασίας εικόνας, όπου τα δεδομένα είναι δισδιάστατα, η συνέλιξη επεκτείνεται στις δύο διαστάσεις. Αν $I(x, y)$ η είσοδος (εικόνα) και $K(i, j)$ το φίλτρο (kernel), τότε η συνέλιξη ορίζεται ως:

$$(I * K)(x, y) = \int_0^x \int_0^y I(i, j) \cdot K(x - i, y - j)\, di\, dj \tag{2.12}$$

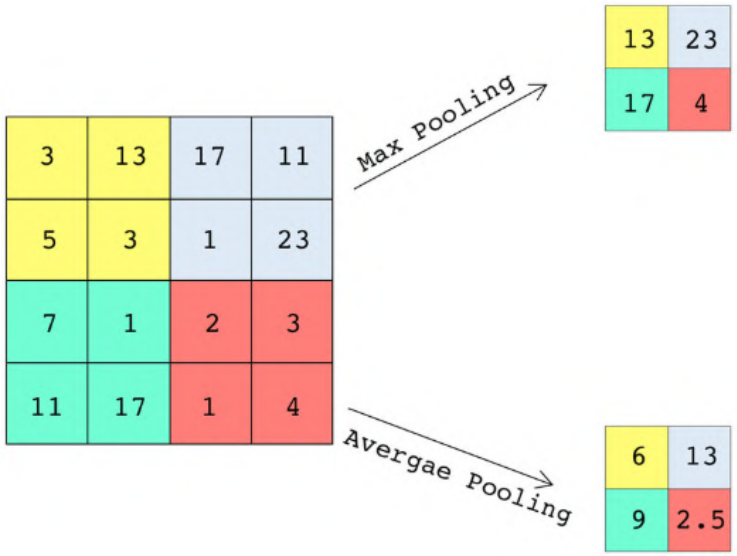
ή ισοδύναμα

$$= \int_0^x \int_0^y I(x - i, y - j) \cdot K(i, j)\, di\, dj \tag{2.13}$$

Για κάθε θέση (pixel), (x, y) της εικόνας υπολογίζεται το εσωτερικό γινόμενο μεταξύ του φίλτρου και της περιοχής της εικόνας που καλύπτει. Το αποτέλεσμα αυτού του υπολογισμού είναι μία τιμή του feature map, το οποίο αποτελεί την έξοδο του συνελικτικού επιπέδου.

Επίπεδο Συμψηφισμού - Pooling layer: Αυτό το στρώμα χρησιμοποιείται σε συνδυασμό με τα συνελικτικά επίπεδα. Τα pooling layers χρησιμοποιούνται, μεταξύ άλλων, για να μειώσουν το μέγεθος των feature maps. Με αυτόν τον τρόπο, μειώνεται ο αριθμός των παραμέτρων που χρειάζεται να μάθει το δίκτυο και ο υπολογιστικός φόρτος, με αποτέλεσμα να αποφεύγεται το φαινόμενο της υπερπροσαρμογής (overfitting). Ουσιαστικά, το επίπεδο συμψηφισμού «συνοψίζει» τις τιμές που υπάρχουν σε μικρές περιοχές ενός χάρτη χαρακτηριστικών, οι οποίες προέρχονται από προηγούμενο συνελικτικό επίπεδο. Αυτό το κάνει με τη χρήση ενός φίλτρου, το οποίο ”σαρώνει” τις εικόνες και εφαρμόζει μία συνάρτηση συμψηφισμού, με σκοπό να διατηρήσει τις πιο αντιπροσωπευτικές πληροφορίες από κάθε περιοχή. Οι πιο διαδεδομένες συναρτήσεις συμψηφισμού είναι η max pooling και η average pooling.

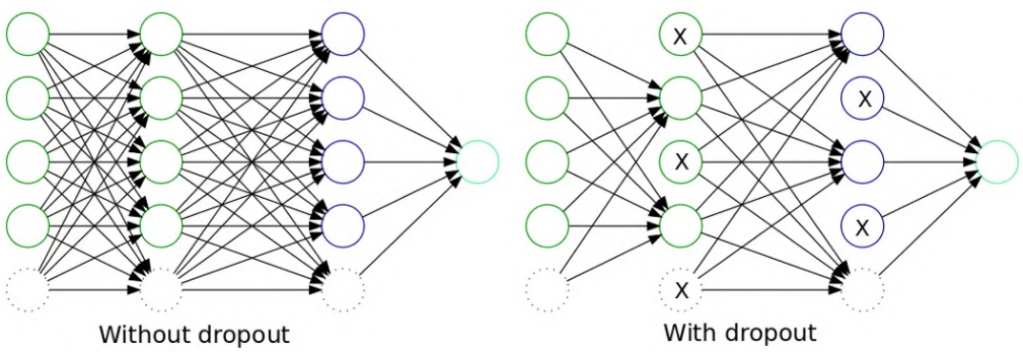
Στην εικόνα 2.16 απεικονίζεται ένα παράδειγμα αυτών των δύο συναρτήσεων. Συγκεκριμένα, γίνεται υποδειγματοληψία μίας εικόνας 4x4 σε 2x2 με την επιλογή της μέγιστης τιμής στην μία περίπτωση και με την επιλογή της μέσης τιμής στην άλλη περίπτωση για κάθε μικρότερο τμήμα της εικόνας.



Σχήμα 2.16: Παράδειγμα max pooling και average pooling
[1]

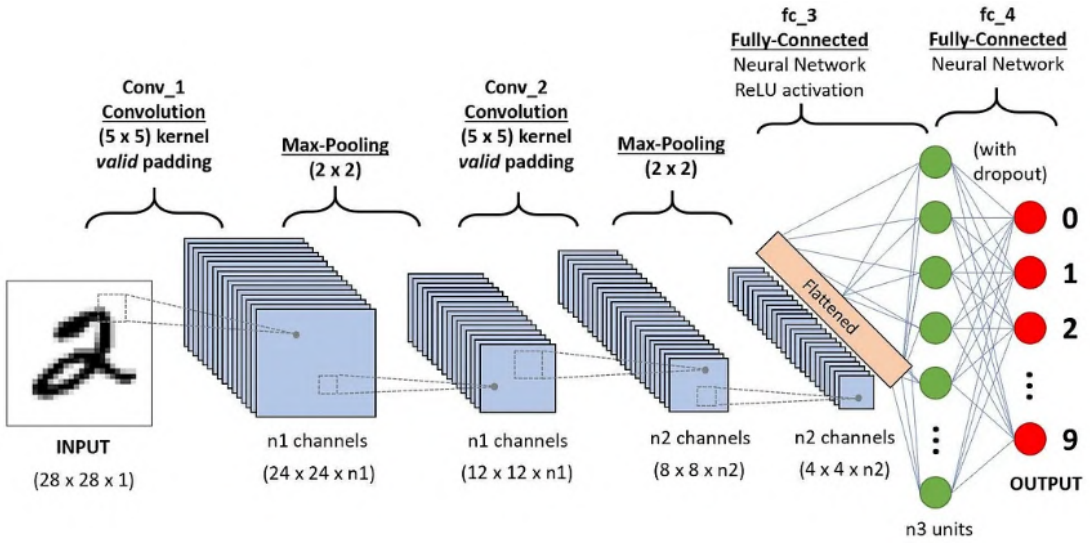
Απόσυρση - Dropout layer: Είναι ένα ακόμα στρώμα που βοηθά στην καταπολέμηση της υπερπροσαρμογής. Συνήθως τοποθετείται ως στρώμα είτε μετά από ένα πλήρως συνδεδεμένο επίπεδο είτε μετά από ένα συνελικτικό στρώμα. Η λειτουργία αυτού του στρώματος είναι κατά τη διαδικασία της εκπαίδευσης του μοντέλου, να απενεργοποιεί τυχαία ένα ποσοστό νευρώνων, οι οποίοι επιλέγονται με βάση μια προκαθορισμένη πιθανότητα. Πιο συγκεκριμένα, κάθε νευρώνας έχει πιθανότητα $1 - p$ να απενεργοποιηθεί από το δίκτυο και πιθανότητα p να παραμείνει ενεργός, όπου p είναι μια υπερπαράμετρος που ορίζεται από τον χρήστη (dropout rate). Οι εισερχόμενες και εξερχόμενες άκρες σε έναν αποκλεισμένο κόμβο αγνοούνται επίσης. Για παράδειγμα, αν εφαρμοστεί dropout με rate 50% μετά από ένα επίπεδο (πχ. πλήρες συνδεδεμένο) 10 νευρώνων, τότε κατά την εκπαίδευση υπάρχει 50% πιθανότητα κάθε νευρώνας να απενεργοποιηθεί προσωρινά. Δηλαδή, σε κάθε παρτίδα (batch) της εκπαίδευσης, κατά μέσο όρο οι 5 από τους 10 νευρώνες δεν θα ”δουλέψουν” καθόλου και η έξοδος τους θα θεωρηθεί μηδενική. Αυτό σημαίνει πως η έξοδος του επιπέδου θα βασιστεί μόνο στους ενεργούς νευρώνες, γεγονός που επαναλαμβάνεται κάθε φορά με διαφορετικό τρόπο. Η χρησιμότητα αυτής της τεχνικής είναι ότι δεν επιτρέπει στο μοντέλο να εξαρτάται υπερβολικά από συγκεκριμένους

νευρώνες ή συνδέσεις. Στο τέλος, μαθαίνει να αποδίδει καλά ανεξαρτήτως του ποιοι νευρώνες είναι ενεργοί, καθιστώντας το πιο ανθεκτικό και ικανό να γενικεύει καλύτερα σε μη γνωστά δεδομένα.



Σχήμα 2.17: Dropout layer

Στην 2.18 φαίνεται ένα παράδειγμα αρχιτεκτονικής ενός βαθιού συνελικτικού δικτύου για αναγνώριση ψηφίων. Το δίκτυο λαμβάνει ως είσοδο, μια εικόνα γκρι κλίμακας (grayscale) διαστάσεων 28x28 και μέσω διαδοχικών επιπέδων συνελικτικών επιπέδων, εξάγει τα χαρακτηριστικά από την εικόνα και δημιουργούνται τα feature maps. Μετά από κάθε συνελικτικό επίπεδο ακολουθεί το στάδιο υποδειγματοληψίας (max-pooling), το οποίο μειώνει τις διαστάσεις των feature maps. Τα τελικά επίπεδα χαρακτηριστικών μετατρέπονται σε μονοδιάστατο διάνυσμα (flattening) και στη συνέχεια δίνονται ως είσοδος σε πλήρως συνδεδεμένα επίπεδα. Σε αυτά εφαρμόζεται συνάρτηση ενεργοποίησης ReLU, ενώ χρησιμοποιείται και dropout για την αποφυγή υπερπροσαρμογής. Στην έξοδο του δικτύου υπάρχουν 10 νευρώνες, ένας για κάθε ψηφίο (0–9), και η τελική πρόβλεψη βασίζεται στον νευρώνα με τη μεγαλύτερη ενεργοποίηση.



Σχήμα 2.18: Παράδειγμα αρχιτεκτονικής βαθιού συνελικτικού δικτύου [22]

2.2 Χρήση βαθιών συνελικτικών νευρωνικών δικτύων στη διπλωματική εργασία

Από το σημείο αυτό και στο εξής, παρουσιάζεται η εφαρμογή των Βαθιών Συνελικτικών Νευρωνικών Δικτύων (DCNNs) στο πλαίσιο της παρούσας διπλωματικής εργασίας, με στόχο την εκτίμηση της

παραμόρφωσης μαλακού ιστού σε πραγματικό χρόνο. Αφού αναλύθηκαν διεξοδικά οι βασικές αρχές λειτουργίας των νευρωνικών δικτύων και ο τρόπος λειτουργίας των DCNNs στην επεξεργασία οπτικών δεδομένων, η έμφαση μετατοπίζεται πλέον στη σχεδίαση, την υλοποίηση και την αξιολόγηση της προτεινόμενης μεθοδολογίας. Περιγράφονται αναλυτικά η δημιουργία του κατάλληλου συνόλου δεδομένων, οι επιλογές σχεδίασης του δικτύου, τα χαρακτηριστικά του συνόλου δεδομένων, οι τεχνικές προεπεξεργασίας, καθώς και οι μετρικές αξιολόγησης της απόδοσης.

2.2.1 Δημιουργία του Συνόλου Δεδομένων

Το πρώτο βήμα, πριν την εκπαίδευση του μοντέλου και την τελική εξαγωγή αποτελεσμάτων, είναι η δημιουργία ενός κατάλληλου συνόλου δεδομένων (dataset), το οποίο να περιλαμβάνει εικόνες που σχετίζονται άμεσα με το πρόβλημα προς επίλυση. Στην παρούσα εργασία, το πρόβλημα επικεντρώνεται στην εκτίμηση της παραμόρφωσης του μαλακού ιστού γύρω από τη χειρουργική τομή, με στόχο την πρόληψη τραυματισμών κατά τη διάρκεια της ρομποτικά υποβοηθούμενης ελάχιστα επεμβατικής επέμβασης. Ως εκ τούτου, το dataset πρέπει να αντικατοπτρίζει ρεαλιστικά σενάρια αλληλεπίδρασης του χειρουργικού εργαλείου με την τομή. Γι' αυτό το λόγο, χρησιμοποιήθηκε μία σιλικόνη με μία μικρή τρύπα στο κέντρο της (συμβολίζοντας τη χειρουργική τομή από την οποία εισέρχεται το χειρουργικό εργαλείο), απόχρωσης ροζ για την αναπαράσταση του μαλακού ιστού, η οποία τοποθετήθηκε σε μία ειδική βάση, που κατασκευάστηκε από 3D εκτυπωτή. Επιπλέον, χρησιμοποιήθηκε ένα μακρύ, λεπτό χειρουργικό εργαλείο πάνω στο οποίο στερεώθηκε στην άκρη του μία κάμερα RGB. Έτσι, συλλέχθηκαν για εκπαίδευση ένα μεγάλο σύνολο εικόνων, όπου χειροκίνητα προκακαλούσαμε παραμόρφωση της σιλικόνης σε διαφορετικές κατευθύνσεις. Επιπλέον, συλλέχθηκαν και δεδομένα, στα οποία δεν προκαλούσαμε κάποια παραμόρφωση (ground truth). Συνολικά, συλλέχθηκαν 1582 φωτογραφίες για εκπαίδευση (training) και 280 για τεστ (testing). Κάποιες από αυτές φαίνονται στα Σχήματα 2.19 και 2.20.



Σχήμα 2.19: Φωτογραφίες, στις οποίες δεν έχει προκληθεί καμία παραμόρφωση στην σιλικόνη



Σχήμα 2.20: Φωτογραφίες, στις οποίες έχει προκληθεί παραμόρφωση της σιλικόνης

Προκειμένου να γίνει η διαδικασία της εκπαίδευσης του μοντέλου, θα πρέπει να έχει γίνει εκ των προτέρων, η κατάλληλη επισήμανση της παραμόρφωσης της σιλικόνης στις εικόνες του συνόλου δεδομένων, που συλλέχθηκαν, και που ουσιαστικά θα του δοθούν σαν είσοδο. Υπάρχουν πολλές μέθοδοι επισήμανσης αντικειμένων (annotation methods). Κάποιες από αυτές είναι:

- **Γραμμές και καμπύλες (Lines and splines)**: Όπως υποδηλώνει και το όνομα, αυτή η μέθοδος annotation, χρησιμοποιείται για την σχεδίαση γραμμών ή καμπυλών.

- **Ορθογώνια πλαίσια (Bounding boxes)**: Πρόκειται για παραλληλόγραμμα (συνήθως ευθυγραμμισμένα με τους άξονες x και y), τα οποία περικλείουν ένα αντικείμενο προκειμένου να προσδιοριστεί η γενική θέση και η διάστασή του μέσα στην εικόνα.

- **Πολυγωνική Τμηματοποίηση (Polygonal Segmentation)**: Σε αυτή τη μέθοδο χρησιμοποιούνται σύνθετα πολύγωνα, αντί για ορθογώνια, τα οποία περιγράφουν με μεγαλύτερη ακρίβεια τα όρια ενός αντικειμένου. Συγκεκριμένα, ο χρήστης ορίζει διαδοχικά σημεία γύρω από το αντικείμενο σχηματίζοντας ένα πολύγωνο.

- **Σημασιολογική Τμηματοποίηση (Semantic Segmentation)**: Η συγκεκριμένη τεχνική, στοχεύει στην ταξινόμηση κάθε εικονοστοιχείου της εικόνας σε μία προκαθορισμένη κατηγορία, δηλαδή αντί να επισημαίνονται μεμονωμένα αντικείμενα, ολόκληρες περιοχές της εικόνας έχουν από μία διαφορετική ετικέτα (label). Αυτές οι κατηγορίες θα μπορούσαν να είναι πεζοί, αυτοκίνητο, λεωφορείο, δρόμος, πεζοδρόμιο κλπ.

- **Τρισδιάστατα Κυβοειδή (3D Cuboids)**: Τα 3D cuboids αποτελούν επέκταση των bounding boxes στο τρισδιάστατο χώρο. Χρησιμοποιούνται για να αναπαραστήσουν το μήκος, πλάτος και βάθος ενός αντικειμένου, επιτρέποντας στα συστήματα να κατανοούν τον όγκου και τη θέση του στον τρισδιάστατο χώρο.

- **Σημεία Κλειδιά και Ορόσημα (Keypoints and Landmarks)**: Αυτή η προσέγγιση βασίζεται στην ανίχνευση μικρών αντικειμένων και σχημάτων δημιουργώντας κουκκίδες στην εικόνα. Συχνά χρησιμοποιούνται σε μορφές πλέγματος για την ανίχνευση χαρακτηριστικά προσώπου, συναισθημάτων, ανάλυση της ανθρώπινης στάσης, χειρονομιών κλπ.

Από όλες τις παραπάνω μεθόδους, δεδομένου ότι θέλουμε διανυσματικά να εκτιμήσουμε την παραμόρφωση, χρησιμοποιήθηκε ως μέθοδος επισήμανσης η πρώτη, δηλαδή οι γραμμές (lines). Συγκεκριμένα, Η διαδικασία του annotation στο σύνολο των εικόνων πραγματοποιήθηκε χειροκίνητα, με τη βοήθεια ενός απλού διαδραστικού εργαλείου που υλοποιήθηκε σε Python, χρησιμοποιώντας

τη βιβλιοθήκη OpenCV. Στόχος της μεθόδου ήταν η καταγραφή της κατεύθυνσης ενός διανύσματος, μέσω της επιλογής δύο σημείων πάνω σε κάθε εικόνα.

Ουσιαστικά, η διαδικασία ξεκινάει με τον χρήστη να πρέπει να επιλέξει τον φάκελο, στον οποίο βρίσκονται όλες οι εικόνες τύπου .png και ακολούθως, εμφανίζεται στον χρήστη η εικόνα, στην οποία πρέπει να επιλέξει με το ποντίκι δύο σημεία. Η εικόνα εμφανίζεται κροπαρισμένη, προκειμένου να μειωθεί η οπτική πληροφορία των σημείων που είναι εκτός ενδιαφέροντας. Επίσης, τα σημεία που επιλέγει ο χρήστης αντιπροσωπεύουν την αρχή και το τέλος του διανύσματος της παραμόρφωσης, δηλαδή ως πρώτο σημείο επιλέγεται το σημείο που θα έπρεπε η τομή να βρίσκεται και ως δεύτερο, το σημείο που βρίσκεται κανονικά. Προφανώς, στις εικόνες όπου δεν υπάρχει καμία παραμόρφωση της τομής από το χειρουργικό εργαλείο το σημείο που επιλέγεται ως πρώτο και δεύτερο είναι ακριβώς το ίδιο. Τα σημεία αυτά αποθηκεύονταν ως συντεταγμένες (x_1, y_1) και (x_2, y_2), ενώ μία κόκκινη ευθεία σχεδιάζεται μεταξύ τους για επιβεβαίωση της επιλογής. Οι σχεδιασμένες, πλέον, εικόνες αποθηκεύονται ξεχωριστά σε έναν υποφάκελο, ώστε να διατηρείται το αρχικό dataset ανεπηρέαστο. Παράλληλα, όλες οι συντεταγμένες και τα paths των εικόνων καταγράφονται αυτόματα σε ένα αρχείο .csv, το οποίο χρησιμοποιείται για τη μεταγενέστερη εκπαίδευση του μοντέλου. Έτσι, υπάρχουν δύο .csv αρχεία, ένα για το training (train.csv, Σχήμα 2.22) και ένα για το testing (test.csv, Σχήμα 2.23).



Σχήμα 2.21: Ενδεικτικές εικόνες μετά τη διαδικασία του annotation

	A	B	C	D	E
1	Image_Path	x1	x2	y1	y2
2	example_dataset/train/images/Image_1.png	366	345	260	255
3	example_dataset/train/images/Image_10.png	369	346	256	266
4	example_dataset/train/images/Image_100.png	319	347	265	252
5	example_dataset/train/images/Image_101.png	339	331	214	242
6	example_dataset/train/images/Image_102.png	313	322	219	234
7	example_dataset/train/images/Image_103.png	381	350	235	238
8	example_dataset/train/images/Image_104.png	366	341	253	240
9	example_dataset/train/images/Image_105.png	333	335	198	221

Σχήμα 2.22: Μορφή excel για τα train data, μετά τη διαδικασία του annotation

Η μέθοδος αυτή, παρότι βασίζεται σε ανθρώπινη παρέμβαση, επιτρέπει μεγάλη ακρίβεια στον ορισμό κατευθύνσεων και είναι κατάλληλη για dataset μικρού ή μεσαίου μεγέθους, όπου η ποιότητα του annotation είναι πιο κρίσιμη από την ποσότητα. Σε ρεαλιστικές συνθήκες, το annotation θα πρέπει να πραγματοποιηθεί από έναν χειρουργό με εμπειρία.

Επίσης, αξίζει να σημειωθεί ότι επιλέχθηκαν έγχρωμες (RGB) εικόνες αντί για ασπρόμαυρες (grayscale). Η επιλογή αυτή έγινε καθώς οι RGB εικόνες παρέχουν περισσότερη πληροφορία, αφού κάθε pixel αναπαρίσταται ως συνδυασμός των τριών βασικών χρωμάτων (κόκκινου, πράσινου και μπλε) επιτρέποντας την καλύτερη απεικόνιση και διάκριση των αντικειμένων. Αν και αυτή η προσέγγιση είναι πιο απαιτητική από πλευράς μνήμης και υπολογιστικών πόρων, προσφέρει μεγαλύτερη

	A	B	C	D	E
1	Image_Path	x1	x2	y1	y2
2	example_dataset/test/images/Image_857.png	377	348	274	246
3	example_dataset/test/images/Image_858.png	384	361	255	272
4	example_dataset/test/images/Image_859.png	373	346	226	240
5	example_dataset/test/images/Image_860.png	338	335	284	255
6	example_dataset/test/images/Image_861.png	349	342	237	262
7	example_dataset/test/images/Image_862.png	314	327	222	258
8	example_dataset/test/images/Image_863.png	354	338	212	233
9	example_dataset/test/images/Image_864.png	313	313	215	241

Σχήμα 2.23: Μορφή excel για τα test data, μετά τη διαδικασία του annotation

ακρίβεια στην αναγνώριση λεπτομερειών. Αντίθετα, οι grayscale εικόνες, παρόλο που απαιτούν λιγότερους πόρους και επιτρέπουν την ταχύτερη επεξεργασία, αναπαριστούν κάθε pixel με μία αριθμητική τιμή (0 εώς 255) που αντιστοιχίζεται σε μια απόχρωση του χρώματος γκρι, χάνοντας ουσιαστικά την πληροφορία του χρώματος. Έτσι, κρίθηκε πως η χρήση RGB εικόνων είναι πιο κατάλληλη για τον σκοπό της συγκεκριμένης μελέτης, δεδομένης της ανάγκης για καλύτερη ευκρίνεια των χρωμάτων.

Ακολούθως, χωρίστηκαν οι φωτογραφίες σε train και test, όπου για το train επιλέχθηκαν 1582 και για το test επιλέχθηκαν 280. Στη συνέχεια, γράφτηκε κώδικας σε Python, με σκοπό τη φόρτωση των δεδομένων και την επεξεργασία τους για την εκπαίδευση του νευρωνικού δικτύου. Το σύστημα αυτό επιτρέπει την ευέλικτη διαχείριση των δεδομένων και τη χρήση έτοιμων εργαλείων από το PyTorch. Αρχικά, οι εικόνες βρίσκονται αποθηκευμένες σε φάκελο με συγκεκριμένη δομή: ένας κύριος φάκελος περιέχει δύο υποφακέλους (train και test) που περιλαμβάνουν τις εικόνες του κάθε σετ. Παράλληλα, υπάρχουν και τα δύο αρχεία .csv (ένα για το train και ένα για το test). Η διαδικασία φόρτωσης ξεκινάει με την εφαρμογή συγκεκριμένων μετασχηματισμών στις εικόνες (όπως cropping και resizing). Οι μετασχηματισμοί αυτοί εξασφαλίζουν ότι όλες οι εικόνες έχουν το ίδιο μέγεθος, ώστε να μπορούν να εισαχθούν στο νευρωνικό δίκτυο. Έπειτα, αντιστοιχίζεται κάθε εικόνα με τις τιμές των συντεταγμένων των δύο σημείων που έχουν καταγραφεί στο .csv αρχείο.

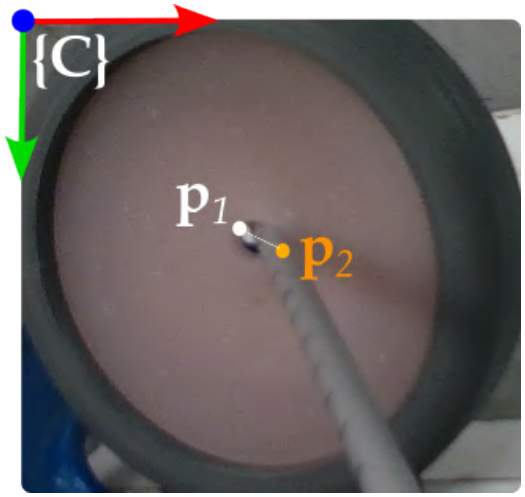
Τέλος, γίνεται τμηματική φόρτωση των δεδομένων (σε batches) κατά τη διάρκεια της εκπαίδευσης και της αξιολόγησης.

2.2.2 Εκπαίδευση του DCNN

Αφού ολοκληρώθηκε η διαδικασία δημιουργίας του συνόλου δεδομένων, η επόμενη φάση αφορά την εκπαίδευση του Βαθιού Συνελικτικού Νευρωνικού Δικτύου (DCNN), το οποίο καλείται να μάθει την ακριβή τιμή της παραμόρφωσης (αν υφίσταται) του μαλακού ιστού. Η εκπαίδευση πραγματοποιείται με βάση τον κώδικα που υλοποιήθηκε σε Python, κάνοντας χρήση της βιβλιοθήκης PyTorch, η οποία παρέχει ευέλικτα εργαλεία για την υλοποίηση μοντέλων μηχανικής μάθησης και καθίσταται η κατάλληλη για τέτοιου είδους προβλήματα. Ουσιαστικά, το δίκτυο καλείται να προβλέψει ένα διάνυσμα δύο διαστάσεων, το $(x_2 - x_1, y_2 - y_1)$ και κατά συνέπεια το πρόβλημα τίθεται ως πρόβλημα παλινδρόμησης (regression).

Παρουσιάζονται, συνοπτικά, παρακάτω τα στρώματα που χρησιμοποιήθηκαν και γιατί επιλέχθηκε το καθένα (για παραπάνω θεωρητική ανάλυση βλ. Κεφ. 2.1.9). Το συγκεκριμένο DCNN, αποτελείται από διάφορα πλήρως συνδεδεμένα στρώματα (fully connected), στρώματα συμψηφισμού (pooling), απόσυρσης (dropout) και φυσικά συνελικτικά στρώματα (convolutional). Τα convolutional layers είναι υπεύθυνα για την εξαγωγή χαρακτηριστικών από τις εικόνες εισόδου, ενώ τα pooling layers μειώνουν τη διάσταση των πινάκων αυτών των χαρακτηριστικών, μειώνοντας έτσι και την υπολογιστική πολυπλοκότητα του μοντέλου. Μετά από κάθε συνελικτική στρώση εφαρμόζεται η συνάρτηση ενεργοποίησης Rectified Linear Unit (ReLU), η οποία εισάγει μη γραμμικότητα στο δίκτυο και εξασφαλίζει την αποδοτική διάδοση του σφάλματος προς τα πίσω (backpropagation), επιταχύνοντας τη διαδικασία εκπαίδευσης και βελτιώνοντας τη συνολική απόδοση του μοντέλου. Τα dropout layers

χρησιμοποιούνται για την αποτροπή του φαινομένου της υπερπροσαρμογής (overfitting), μέσω της τυχαίας απενεργοποίησης ενός ποσοστού των νευρώνων κατά την εκπαίδευση. Τέλος, στο τελευταίο τμήμα του δικτύου τοποθετούνται τα fully connected layers, τα οποία συνθέτουν τα εξαγόμενα χαρακτηριστικά και παράγουν την τελική έξοδο του μοντέλου. Η έξοδος αυτή αποτελείται από τέσσερις πραγματικούς αριθμούς, οι οποίοι αντιστοιχούν στις δισδιάστατες συντεταγμένες $\mathbf{p}_1, \mathbf{p}_2 \in \mathbb{R}^2$ των σημείων αρχής και τέλους του διανύσματος παραμόρφωσης, στο επίπεδο των εικονοστοιχείων (pixel space) της κάμερας, όπως απεικονίζεται στο Σχήμα 2.24, όπου $\mathbf{p}_1 = (x_1, y_1)$ και $\mathbf{p}_2 = (x_2, y_2)$.



Σχήμα 2.24: Εικόνα από την εξωτερική κάμερα και το διάνυσμα παραμόρφωσης, που πρέπει να προβλέψει το DCNN

Στο Σχήμα 2.25 απεικονίζεται η αρχιτεκτονική του DCNN, το οποίο δέχεται ως είσοδο την ήδη επεξεργασμένη RGB εικόνα, διαστάσεων $620 \times 620 \times 3$. Τα 3 κανάλια αφορούν τα χρώματα Red, Green, Blue.

Αναλυτικά η πορεία της εικόνας μέσα από τα διαδοχικά στρώματα του δικτύου έχει ως εξής:

i. Αρχικά, η εικόνα περνάει από το **συνελικτικό στρώμα**, στο οποίο εφαρμόζονται 4 φίλτρα με kernel size 3×3, άρα προκύπτουν 4 feature maps, padding = 1 και stride = 1. Οι χωρικές διαστάσεις (ύψος και πλάτος) της εικόνας διατηρούνται, καθώς ισχύει:

$$Outputsize = \left\lfloor \frac{Inputsize + 2 \cdot padding - kernelsize}{stride} \right\rfloor + 1 = \left\lfloor \frac{620 + 2 \cdot 1 - 3}{1} \right\rfloor + 1 = 620$$

Άρα, η έξοδος του πρώτου συνελικτικού στρώματος έχει διαστάσεις $4 \times 620 \times 620$.

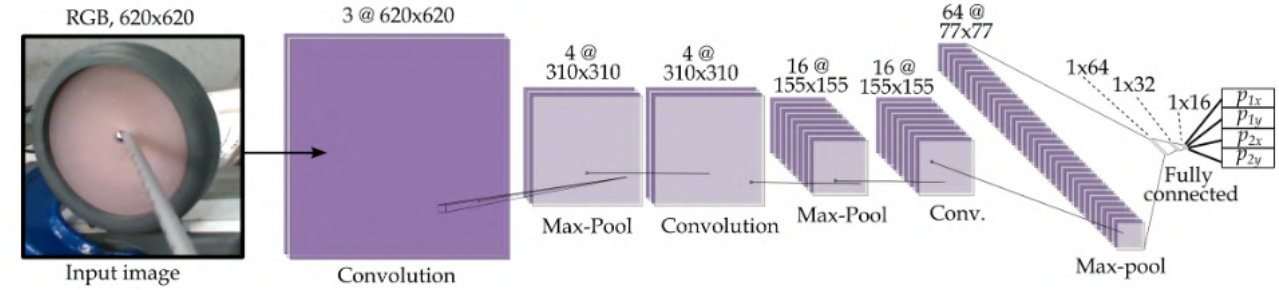
ii. Στη συνέχεια, εφαρμόζεται η συνάρτηση ενεργοποίησης **ReLU**.

iii. Γίνεται υποδειγματοληψία (downsampling) με τη χρήση του **Max Pooling** μεγέθους 2×2, η οποία μειώνει τις διαστάσεις κατά 50%, διατηρώντας τα πιο αντιπροσωπευτικά χαρακτηριστικά από κάθε περιοχή.

iv. Μετά, ακολουθεί το **dropout** με πιθανότητα 0.4, το οποίο απενεργοποιεί τυχαία ένα ποσοστό των νευρώνων.

Η παραπάνω διαδικασία επαναλαμβάνεται με αύξηση του πλήθους των φίλτρων σε κάθε συνελικτικό επίπεδο (από 4 → 16 → 64), διατηρώντας τις ίδιες παραμέτρους πυρήνα (kernel size = 3×3, padding = 1, stride = 1). Μετά από κάθε συνελικτικό στρώμα, εφαρμόζεται ReLU, pooling και ενίοτε dropout. Κατά αυτόν τον τρόπο, το δίκτυο μαθαίνει ολοένα και πιο αφηρημένες αναπαραστάσεις των δεδομένων εισόδου, καθώς αυξάνεται το βάθος και ο αριθμός των φίλτρων.

Όταν οι χωρικές διαστάσεις έχουν μειωθεί σημαντικά (από 620×620 σε 77×77), το τελικό feature map αναδιαμορφώνεται (**flattened**) σε ένα μονοδιάστατο διάνυσμα μεγέθους 64 × 77 × 77 = 380.689 χαρακτηριστικά. Το διάνυσμα αυτό εισέρχεται σε μια σειρά από πλήρως συνδεδεμένα (**fully connected**) επίπεδα, τα οποία μειώνουν διαδοχικά τη διάστασή του: πρώτα σε 64, έπειτα σε 32, 16 και τελικά σε 4. Έτσι, η τελική έξοδος είναι το διάνυσμα 4 συνεχών τιμών, που προαναφέρθηκαν.



Σχήμα 2.25: Αρχιτεκτονική του DCNN που επιλέχθηκε για την αναγνώριση της παραμόρφωσης της χειρουργικής τομής

Αξίζει να σημειωθεί ότι η τελική αρχιτεκτονική του νευρωνικού δικτύου προέκυψε μετά από εκτενή διαδικασία πειραματισμού και βελτιώσεων. Κατά την διάρκεια εκτέλεσης της εργασίας, δοκιμάστηκαν εναλλακτικές διαμορφώσεις με μικρότερο ή μεγαλύτερο πλήθος συνελικτικών και πλήρως συνδεδεμένων επιπέδων, με σκοπό τη διερεύνηση της επίδρασης του βάθους του δικτύου στην απόδοσή του. Επιπλέον, σε μεταγενέστερο στάδιο, προστέθηκαν dropout layers, τα οποία αποδείχθηκαν καθοριστικά στη βελτίωση της γενίκευσης του μοντέλου. Συγκεκριμένα, η χρήση dropout συνέβαλε στη μείωση του φαινομένου της υπερπροσαρμογής (overfitting), οδηγώντας σε αισθητή μείωση του σφάλματος στο test set και τελικά σε πιο αξιόπιστες προβλέψεις.

Επιπλέον, το δίκτυο εκπαιδεύτηκε σε mini-batches μεγέθους 32, μια προσέγγιση που επιτρέπει πιο αποδοτική χρήση των υπολογιστικών πόρων, κάτι ιδιαίτερα σημαντικό, διότι εργαζόμαστε με εικόνες υψηλής ανάλυσης (στη συγκεκριμένη περίπτωση, RGB εικόνες με διαστάσεις 620x620 pixels). Το σύνολο εκπαίδευσης χωρίστηκε σε τέτοια μικρά υποσύνολα (batches), και για κάθε batch υπολογιζόταν η συνάρτηση κόστους και γινόταν οι απαραίτητες ενημερώσεις των παραμέτρων του μοντέλου, μέσω της οπισθοδιάδοσης. Η διαδικασία της εκπαίδευσης πραγματοποιήθηκε για 1200 εποχές (epochs), δηλαδή το δίκτυο διέτρεξε ολόκληρο το σύνολο εκπαίδευσης 1200 φορές. Ο αριθμός των εποχών προσαρμόστηκε πειραματικά, ώστε να επιτευχθεί μια ισορροπία μεταξύ υποπροσαρμογής (underfitting) και υπερπροσαρμογής (overfitting). Συγκεκριμένα, με λιγότερες εποχές, το δίκτυο δεν είχε αρκετό χρόνο να μάθει σημαντικά χαρακτηριστικά των δεδομένων, ενώ αν ήταν περισσότερες, το δίκτυο απομνημόνευε (memorize) τα δεδομένα εκπαίδευσης, χάνοντας τη γενίκευση σε νέα δείγματα και έτσι το σφάλμα ήταν αρκετά μεγάλο. Εννοείται, ότι δεν φαίνονται αισθητές διαφορές σε μεταβολές αυξομειώσεων μικρότερες περίπου των 100 εποχών.

Στη συγκεκριμένη εργασία, για την εκπαίδευση του νευρωνικού δικτύου δεν χρησιμοποιήθηκε ο κλασικός αλγόριθμος gradient descent, αλλά ένας παρόμοιος αλγόριθμος βελτιστοποίησης, ο **Adam (Adaptive Moment Estimation)**. Ο Adam αποτελεί μία βελτιστοποιημένη μορφή του gradient descent, η οποία ενσωματώνει τις έννοιες του momentum και του RMSprop (Root Mean Square Propagation).

Η τεχνική **momentum** χρησιμοποιείται για να επιταχύνει τη διαδικασία gradient descent, ενσωματώνοντας έναν εκθετικά σταθμισμένο κινητό μέσο όρο των παραγώγων (gradients) από προηγούμενα βήματα. Με τον τρόπο αυτό, εξομαλύνεται η πορεία της βελτιστοποίησης και μειώνονται οι ταλαντώσεις, οδηγώντας σε ταχύτερη σύγκλιση. Η ενημέρωση των βαρών με momentum δίνεται από τη σχέση:

$$w_{t+1} = w_t - \alpha m_t \tag{2.14}$$

όπου w_t είναι τα βάρη τη χρονική στιγμή t, α είναι ο ρυθμός μάθησης (learning rate) και m_t είναι

ο μέσος όρος (μεταβλητός) μέχρι τη χρονική στιγμή t και ορίζεται αναδρομικά ως:

$$m_t = \beta_1 m_{t-1} + (1 - {}_1)\frac{\partial L}{\partial w_t} \tag{2.15}$$

όπου β_1 είναι μία σταθερή παράμετρος, συνήθως με τιμή 0.9 και $\frac{\partial L}{\partial w_t}$ είναι το gradient της συνάρτησης κόστους ως προς τα βάρη στο χρόνο t. Αυτό σημαίνει ότι το momentum είναι ένας σταθμισμένος μέσος όρος του προηγούμενου momentum και του νέου gradient.

Ο **RMSprop** (Root Mean Square Propagation) είναι μια τεχνική βελτιστοποίησης που τροποποιεί δυναμικά τον ρυθμό μάθησης, επιτρέποντας γρηγορότερη και πιο σταθερή σύγκλιση. Η ενημέρωση των βαρών γίνεται ως εξής:

$$w_{t+1} = w_t - \frac{\alpha}{\sqrt{v_t + \epsilon}}\frac{\partial L}{\partial w_t}$$

όπου ϵ είναι μία μικρή σταθερά (πχ 10^{-8}) για να μην υπάρξει διαίρεση με το μηδέν και ο όρος v_t είναι ένας εκθετικά σταθμισμένος όρος βασισμένος, κυρίως στα πρόσφατα τετραγωνισμένα gradients και υπολογίζεται ως:

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2)\left(\frac{\partial L}{\partial w_t}\right)^2$$

όπου το β_2 ελέγχει πόσο βάρος δίνεται στα προηγούμενα τετράγωνα των gradients, δηλαδή είναι συντελεστής απόσβεσης και συνήθως έχει την τιμή 0.999.

Έτσι, λοιπόν, ο Adam optimizer συνδυάζει τις ιδιότητες του momentum και του RMSprop, με τον εξής τρόπο:

1. Υπολογίζει το momentum:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1)\frac{\partial L}{\partial w_t}$$

2. Υπολογίζει την εκθετική μεταβλητότητα (RMS):

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2)\left(\frac{\partial L}{\partial w_t}\right)^2$$

3. Επειδή στην αρχή τα m_t και v_t είναι κοντά στο μηδέν, εφαρμόζεται διόρθωση μεροληψίας (bias correction):

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}, \quad \hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

4. Η τελική ενημέρωση των βαρών γίνεται ως:

$$w_{t+1} = w_t - \alpha \cdot \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon}$$

Στην υλοποίηση του Adam optimizer επιλέχθηκε ρυθμός μάθησης ίσος με 0.001. Η τιμή αυτή επιλέχθηκε επειδή εξισορροπεί την ταχύτητα εκμάθησης με τη σταθερότητα σύγκλισης του μοντέλου. Ένας πολύ υψηλός ρυθμός μάθησης μπορεί να προκαλέσει αστάθεια και απόκλιση, ενώ ένας πολύ χαμηλός ρυθμός οδηγεί σε πολύ αργή εκπαίδευση.

Οπότε, **συνοπτικά**, η διαδικασία εκπαίδευσης του νευρωνικού δικτύου περιλαμβάνει μια σειρά από διαδοχικά στάδια που επαναλαμβάνονται για κάθε παρτίδα (batch) δεδομένων. Αρχικά, πραγματοποιείται το λεγόμενο ”forward pass”, όπου τα δεδομένα εισόδου διέρχονται από όλα τα επίπεδα του δικτύου και παράγεται η έξοδος του μοντέλου, δηλαδή η πρόβλεψη για τα αντίστοιχα δείγματα. Στο

στάδιο αυτό, το δίκτυο χρησιμοποιεί τις τρέχουσες τιμές των βαρών του για να υπολογίσει τις εκτιμώμενες τέσσερις τιμές. Στη συνέχεια, ακολουθεί ο υπολογισμός της συνάρτησης κόστους, δηλαδή του σφάλματος που προκύπτει από τη σύγκριση των προβλέψεων του μοντέλου με τις πραγματικές τιμές-στόχους. Ουσιαστικά, η συνάρτηση κόστους εκφράζει πόσο ”μακριά” βρίσκονται οι προβλέψεις από τις επιθυμητές τιμές.

Αμέσως μετά, εκτελείται το στάδιο της οπισθοδιάδοσης (backward propagation), κατά το οποίο το σφάλμα που υπολογίστηκε διαδίδεται προς τα πίσω μέσα στο δίκτυο. Σε αυτό το στάδιο υπολογίζονται οι παραγώγοι της συνάρτησης απώλειας ως προς κάθε βάρος του μοντέλου, με βάση τον κανόνα της αλυσίδας. Οι παράγωγοι αυτοί, γνωστοί και ως gradients, δείχνουν πώς πρέπει να τροποποιηθούν τα βάρη για να μειωθεί η απώλεια. Οπότε, το επόμενο στάδιο είναι η ενημέρωση των βαρών. Σε αυτό το σημείο, ο αλγόριθμος Adam αξιοποιεί τις πληροφορίες από τα προηγούμενα στάδια για να προσαρμόσει τα βάρη του δικτύου με τρόπο που να μειώνει την συνάρτηση κόστους. Χρησιμοποιεί έναν συνδυασμό του μέσου όρου των προηγούμενων παραγώγων (momentum) και της μεταβλητότητας των gradients (RMS), ώστε η εκπαίδευση να είναι πιο σταθερή και αποδοτική, αποφεύγοντας έντονες διακυμάνσεις και τοπικά ελάχιστα.

Τέλος, προτού επεξεργαστεί το δίκτυο την επόμενη παρτίδα δεδομένων, οι τιμές των gradients μηδενίζονται. Ο μηδενισμός αυτός είναι απαραίτητος ώστε να μην συσσωρεύονται gradients από διαφορετικά batches, κάτι που θα αλλοίωνε την κατεύθυνση ενημέρωσης των βαρών.

2.2.3 Αξιολόγηση Αποτελεσμάτων Νευρωνικου Δικτύου (Evaluation)

Η αξιολόγηση της απόδοσης του νευρωνικού δικτύου πραγματοποιήθηκε με χρήση της μέσης τετραγωνικής απόκλισης (Mean Squared Error - MSE) ως συνάρτησης κόστους. Η MSE υπολογίζει το μέσο όρο των τετραγώνων των αποκλίσεων μεταξύ των προβλεπόμενων και των πραγματικών τιμών, προσδίδοντας μεγαλύτερη βαρύτητα σε μεγάλες αποκλίσεις. Πρόκειται για ένα τυπικό και κατάλληλο μέτρο σε προβλήματα παλινδρόμησης, καθώς ευνοεί την ακριβή προσέγγιση των πραγματικών τιμών από το μοντέλο. Ο στόχος κατά την εκπαίδευση ήταν η ελαχιστοποίηση της MSE, οδηγώντας το δίκτυο σε όσο το δυνατόν πιο αξιόπιστες προβλέψεις.

Η αξιολόγηση του μοντέλου πραγματοποιήθηκε σε ανεξάρτητο σύνολο δοκιμής (test set), που δεν χρησιμοποιήθηκε στη φάση εκπαίδευσης, εξασφαλίζοντας αντικειμενική εκτίμηση της γενίκευσης του μοντέλου. Για κάθε δείγμα, υπολογίστηκε η τιμή της συνάρτησης κόστους και εξήχθη ο μέσος όρος της για όλο το σύνολο, παρέχοντας έναν συνοπτικό δείκτη απόδοσης. Η χαμηλή τιμή της MSE στο test set αποτελεί ένδειξη ότι το δίκτυο έχει μάθει να αποδίδει με ακρίβεια τις τιμές παραμόρφωσης από τις εικόνες εισόδου. Σε ένα από τα καλύτερα μοντέλα, το οποίο χρησιμοποιήθηκε κι όλας στο σύστημα, το test loss βγήκε $57,5452$. Καλό είναι να εξηγηθεί, τι σημαίνει πραγματικά αυτή η τιμή. Το MSE, όπως αναφέρθηκε σε προηγούμενο κεφάλαιο υπολογίζεται ως:

$$J(y, \hat{y}) = MSE(y, \hat{y}) = \frac{1}{N} \sum_{i=1}^{N} (y_i - \hat{y}_i)^2 \tag{2.16}$$

Όπου:

- $J(y, \hat{y})$ ή $L(y, \hat{y})$ είναι η τιμή της συνάρτησης κόστους,
- N είναι το πλήθος των δειγμάτων στο σύνολο δεδομένων,
- y_i είναι η πραγματική τιμή της εξόδου για το i-οστό δείγμα,
- $\hat{y}_i$ είναι η τιμή που προέβλεψε το μοντέλο για το i-οστό δείγμα.

Ιδανικά, θέλουμε $y_i = \hat{y}_i$, ώστε η MSE, να έβγαινε μηδέν, δηλαδή η πραγματική τιμή της εξόδου, να είναι ακριβώς ίδια με την τιμή που προέβλεψε το μοντέλο, πράγμα που είναι αδύνατο.

Στην συγκεκριμένη περίπτωση κάθε έξοδος είναι 4 τιμές, που αντιπροσωπεύουν συντεταγμένες σε 2D εικόνες, τότε:

$$\left\|\hat{\mathbf{y}}^{(i)} - \mathbf{y}^{(i)}\right\|^2 = (\hat{y}_1 - y_1)^2 + (\hat{y}_2 - y_2)^2 + (\hat{y}_3 - y_3)^2 + (\hat{y}_4 - y_4)^2$$

όπου y_1, y_2, y_3, y_4 είναι τα σημεία. Η μονάδα της MSE κληρονομεί τη μονάδα των δεδομένων εξόδου, και επειδή προβλέπει το μοντέλο συντεταγμένες σε pixels, αυτό σημαίνει ότι το $57,5452$ είναι μέση τετραγωνική απόκλιση σε $pixels^2$. Οπότε, για να το εκφράσουμε ως μέσο σφάλμα σε pixels είναι:

$$\sqrt{57,5452} \approx 7.5858$$

Άρα, κατά μέσο όρο, οι προβλέψεις του μοντέλου απέχουν περίπου $7,5858$ pixels από τις πραγματικές τιμές. Αυτό στην πράξη σημαίνει, ότι αν οι εικόνες είναι μεγέθους 620x620 pixels(όπως σε αυτήν την περίπτωση), τότε ένα σφάλμα περίπου 7,5858 pixels είναι πολύ μικρό ποσοστιαία. Συγκεκριμένα:

$$\frac{7.5858}{620} \cdot 100\% \approx 1.22\%$$

Το μοντέλο προβλέπει με ακρίβεια 98,8% ως προς τη θέση, κάτι που δείχνει πολύ καλή γενίκευση και το μοντέλο δεν απομνημονεύει απλώς τα δεδομένα.

Για να δούμε σε πραγματικό χρόνο την παραμόρφωση που εκτιμάται σε κάθε κίνηση πάνω στην σιλικόνη με το χειρουργικό εργαλείο γράφτηκε κώδικας, ο οποίος χρησιμοποιεί την εξωτερική κάμερα RGB (Intel Real-sense) για την λήψη έγχρωμης εικόνας σε πραγματικό χρόνο, με στόχο την ανάλυση και εκτίμηση παραμόρφωσης μέσω του DCNN. Η λειτουργία της εντάσσεται σε ένα pipeline όπου η εικόνα που καταγράφεται από την κάμερα περνάει αμέσως στο μοντέλο, που έχει ήδη εκπαιδευτεί. Συγκεκριμένα, η κάμερα ενεργοποιείται και ρυθμίζεται ώστε να παρέχει ροή έγχρωμης εικόνας σε ανάλυση υψηλής ευκρίνειας (1280x720 pixels) με ρυθμό 30 καρέ ανά δευτερόλεπτο. Μετά από μία σύντομη καθυστέρηση, ώστε να σταθεροποιηθεί η ροή εικόνας, το σύστημα αρχίζει να συλλέγει καρέ συνεχώς.

Από κάθε καρέ που λαμβάνεται, επιλέγεται ένα συγκεκριμένο υποσύνολο της εικόνας, το οποίο αντιστοιχεί στη γεωμετρική περιοχή όπου αναμένεται να εμφανιστεί η παραμόρφωση. Αυτό είναι ουσιώδες για να περιοριστεί ο θόρυβος και να βελτιωθεί η ακρίβεια της πρόβλεψης. Η περικομμένη εικόνα μετατρέπεται σε μορφή συμβατή με το νευρωνικό δίκτυο (μέσω μετασχηματισμών όπως αλλαγή μεγέθους κλπ.), και στη συνέχεια διοχετεύεται στο εκπαιδευμένο μοντέλο.

Το μοντέλο εκτιμά την παραμόρφωση με τις τέσσερις αριθμητικές τιμές, που αντιστοιχούν στα δύο σημεία στο επίπεδο της εικόνας (αρχή και τέλος της γραμμής της παραμόρφωσης). Αυτές οι τιμές επιστρέφονται και χρησιμοποιούνται για την οπτική απεικόνιση της παραμόρφωσης, μέσω της γραμμής που σχεδιάζεται πάνω στην εικόνα και προβάλλεται στην οθόνη του χρήστη. Τέλος, εμφανίζονται οι τιμές των 4 αριθμών στο pixel space, που έχει προβλέψει το μοντέλο στην κονσόλα.

Αξίζει να σημειωθεί, ότι κάποιες παραμορφώσεις τις προέβλεπε με μεγαλύτερη ακρίβεια, ενώ άλλες που για παράδειγμα η τομή βρισκόταν στο κρυφό σημείο της κάμερας είχε κάποια pixels διαφορά η παραμόρφωση που προέβλεπε ότι υπάρχει. Στις εικόνες 2.26, φαίνονται κάποια τέτοια παραδείγματα.

Με βάση τα αποτελέσματα, η συνολική διαδικασία αξιολόγησης επιβεβαιώνει ότι το σύστημα μπορεί να υποστηρίξει τη real-time εκτίμηση παραμόρφωσης με ακρίβεια και σταθερότητα, ενισχύοντας τις δυνατότητες του για τη χρήση του στην επεμβατική χειρουργική και τον λόγο που το χρειαζόμαστε.



Σχήμα 2.26: Δύσκολα αναγνωρίσιμες παραμορφώσεις για το νευρωνικό δίκτυο

Κεφάλαιο 3

Leader-Follower set-up

3.1 Ρομποτικό Σύστημα Leader-Follower

Το ρομποτικό σύστημα τύπου leader-follower αποτελεί μια από τις πιο προηγμένες και ευρέως χρησιμοποιούμενες αρχιτεκτονικές στον χώρο της συνεργατικής και τηλεκαθοδηγούμενης (tele-operated) ρομποτικής. Στη συγκεκριμένη υλοποίηση που εξετάζεται στην εργασία, το σύστημα αποτελείται από δύο ρομποτικούς βραχίονες, όπου ο πρώτος λειτουργεί ως ο ηγέτης (leader) και ο δεύτερος ως ο ακόλουθος (follower). Η αρχή λειτουργίας του εν λόγω σχήματος βασίζεται στην παρακολούθηση τροχιάς (trajectory tracking), με στόχο την αντιγραφή της κίνησης του leader από τον follower σε πραγματικό χρόνο, με όσο το δυνατόν ελάχιστο σφάλμα. Το σχήμα αυτό είναι ιδανικό για περιβάλλοντα όπου απαιτείται υψηλός βαθμός ακρίβειας και σταθερότητας, όπως στην ελάχιστα επεμβατική χειρουργική (MIS).

Το σύστημα αποτελείται από δύο ρομποτικούς βραχίονες τύπου UR3e (ως leader) και UR3 (ως follower) της εταιρείας Universal Robots, και συγκεκριμένα:

- Ο *Leader*, ελέγχεται άμεσα από τον χρήστη (χειρουργό) μέσω μίας λαβής (handle) και καταγράφεται συνεχώς η θέση, ο προσανατολισμός και η ταχύτητά του.
- Ο *Follower*, εκτελεί την επέμβαση μέσω ενός χειρουργικού εργαλείου, που έχει στερεωμένο στον καρπό του και λαμβάνει την πληροφορία από τον leader, εκτελώντας τις κινήσεις που του υποδεικνύει.

3.2 Θεωρητικό Υπόβαθρο Ρομποτικού Ελέγχου και Σύζευξης Leader-Follower

Για τον λόγο σύζευξης του leader ρομπότ με αυτό του follower, χρησιμοποιείται στον leader έλεγχος ενδοτικότητας (admittance control) στο χώρο των αρθρώσεων (joint space), ενώ στον follower γίνεται η ακριβής παρακολούθηση της κίνησης στον leader.

Πριν από όλα, θα πρέπει να αναλυθούν κάποιες έννοιες και έπειτα να εξηγηθεί ο τρόπος υλοποίησης τους.

3.2.1 Κινηματικός Έλεγχος Ρομποτικών Βραχιόνων

Ο έλεγχος των ρομποτικών βραχιόνων αποτελεί τον πυρήνα της ρομποτικής και έχει ως στόχο την εκτέλεση καθορισμένων κινήσεων και δυνάμεων. Το πρόβλημα ελέγχου ενός ρομπότ είναι η εύρεση των γενικευμένων δυνάμεων (δυνάμεων ή ροπών) ή κινήσεων που πρέπει να ασκήσει το ρομπότ σε κάθε χρονική στιγμή, ώστε να εκτελέσει τη δοσμένη εργασία με ακρίβεια και ευστάθεια, διατηρώντας

ομαλή και παθητική συμπεριφορά κατά την αλληλεπίδραση με το περιβάλλον. Υπάρχουν δύο βασικές περιπτώσεις:

- Το ρομπότ να κινείται ελεύθερα στον χώρο.
- Το ρομπότ να αλληλεπιδρά με το περιβάλλον.

Στην παρούσα εργασία εξετάζεται η δεύτερη περίπτωση, καθώς ο leader ρομποτικός βραχίονας δέχεται εξωτερικές δυνάμεις και αντιδρά μέσω ελέγχου ενδοτικότητας. Ο follower, ωστόσο, θεωρείται πως εκτελεί τις εντολές ταχύτητας που του αποστέλλονται άμεσα. Συνεπώς, το ρομπότ μοντελοποιείται ως ιδανικά κινηματικά ελεγχόμενο, και ο έλεγχος υλοποιείται αποκλειστικά στο επίπεδο των ταχυτήτων. Η υλοποίηση του κινηματικού ελέγχου βασίζεται στη γνώση της κινηματικής αλυσίδας του ρομπότ και της Ιακωβιανής μήτρας του εργαλείου, ώστε να προκύψει η επιθυμητή ταχύτητα των αρθρώσεων με βάση τις επιθυμητές ταχύτητες στον χώρο εργασίας ή στον χώρο των αρθρώσεων.

Μαθηματική περιγραφή της Ιακωβιανής και οι Ρόλοι της στον Έλεγχο

Η Ιακωβιανή ενός ρομποτικού βραχίονα συσχετίζει τις ταχύτητες των αρθρώσεων (στο joint space) με τις ταχύτητες του εργαλείου στον χώρο εργασίας (στο task space).

Αν $\mathbf{q} \in \mathbb{R}^n$ είναι το διάνυσμα θέσεων των αρθρώσεων, και $\mathbf{x} \in SE(3)$ είναι η γενικευμένη θέση (θέση και προσανατολισμός) του άκρου του εργαλείου (end-effector), τότε η κινηματική σχέση περιγράφεται ως:

$$\mathbf{x} = f(\mathbf{q}) \tag{3.1}$$

όπου $f(\mathbf{q}) : \mathbb{R}^n \to SE(3)$ είναι μια συνεχής μη γραμμική συνάρτηση, η οποία απεικονίζει κάθε $\mathbf{q}$ σε μία γενικευμένη θέση.

Η παράγωγος ως προς τον χρόνο οδηγεί στην σχέση ταχυτήτων:

$$\mathbf{v} = \dot{\mathbf{x}} = \mathbf{J}(\mathbf{q})\,\dot{\mathbf{q}} \tag{3.2}$$

Αυτή η σχέση αποτελεί τη λύση του ευθέως κινηματικού προβλήματος (forward kinematics), στο επίπεδο της ταχύτητας, όπου $\mathbf{J}(\mathbf{q}) \in \mathbb{R}^{6\times n}$ είναι η **Ιακωβιανή μήτρα** του ρομποτικού βραχίονα. Η Ιακωβιανή εξαρτάται από τη διαμόρφωση των αρθρώσεων και περιγράφει πώς η μεταφορική και η γωνιακή ταχύτητα του εργαλείου σχετίζονται με τις ταχύτητες των αρθρώσεων.

Η Ιακωβιανή μπορεί να αναλυθεί ως εξής:

$$\mathbf{J}(\mathbf{q}) = \begin{bmatrix} \mathbf{J}_v(\mathbf{q}) \\ \mathbf{J}_\omega(\mathbf{q}) \end{bmatrix} \tag{3.3}$$

όπου:

- $\mathbf{J}_v(\mathbf{q}) \in \mathbb{R}^{3\times n}$: Υποπίνακας μεταφορικής ταχύτητας (linear velocity).
- $\mathbf{J}_\omega(\mathbf{q}) \in \mathbb{R}^{3\times n}$: Υποπίνακας γωνιακής ταχύτητας (angular velocity).

Η Ιακωβιανή χρησιμοποιείται επίσης για τη μεταφορά δυνάμεων από τον χώρο εργασίας στις αρθρώσεις. Οπότε, σύμφωνα με την αρχή διατήρησης του στιγμιαίου έργου, ισχύει:

$$\boldsymbol{\tau} = \mathbf{J}^\top(\mathbf{q})\mathbf{F} \tag{3.4}$$

Όπου $\mathbf{F} \in \mathbb{R}^6$ είναι η γενικευμένη δύναμη (δύναμη και ροπή) στο end-effector και $\boldsymbol{\tau} \in \mathbb{R}^n$ είναι οι γενικευμένες ροπές (δυνάμεις ή ροπές) που εφαρμόζονται στις αρθρώσεις του ρομπότ.

Έλεγχος κίνησης του ρομπότ στο επίπεδο των ταχυτήτων

Ένας από τους βασικούς στόχους της ρομποτικής είναι η υλοποίηση σταθερών και ακριβών κινήσεων ενός ρομπότ από μια θέση σε μια άλλη. Τα προβλήματα αυτά διακρίνονται σε δύο βασικές κατηγορίες:

- **Προσέγγιση στόχου (Target Reaching)**: Αναφέρεται στην περίπτωση όπου το ρομπότ πρέπει να φτάσει σε μια σταθερή τελική θέση ξεκινώντας από κάποια αρχική.
- **Παρακολούθηση τροχιάς (Trajectory Tracking)**: Σε αυτήν την περίπτωση, ο στόχος μεταβάλλεται συνεχώς, και το ρομπότ πρέπει να ακολουθεί μια συγκεκριμένη τροχιά από την αρχική του θέση.

Έστω ένα ρομπότ με n βαθμούς ελευθερίας, το οποίο ελέγχεται μόνο κινηματικά (χωρίς να λαμβάνονται υπόψη μάζα και αδράνεια), και μπορεί να δεχθεί εντολές ταχυτήτων για τις αρθρώσεις του, δηλαδή $\dot{\mathbf{q}}_\mathbf{c} \in \mathbb{R}^n$. Αν το ρομπότ ακολουθεί έναν ιδανικό κινηματικό έλεγχο, τότε ισχύει ότι η πραγματική ταχύτητα των αρθρώσεων είναι ίση με την εντολή ελέγχου:

$$\dot{\mathbf{q}} = \dot{\mathbf{q}}_\mathbf{c}, \quad \forall t \geq 0 \tag{3.5}$$

Περίπτωση 1: Έλεγχος στον χώρο των αρθρώσεων Για παρακολούθηση τροχιάς (trajectory tracking) στον χώρο των αρθρώσεων, ορίζεται ο νόμος ελέγχου:

$$\dot{\mathbf{q}}_c \triangleq \dot{\mathbf{q}}_d - \mathbf{K}_p(\mathbf{q} - \mathbf{q}_d) \tag{3.6}$$

όπου:

- $\mathbf{q}_d, \dot{\mathbf{q}}_d \in \mathbb{R}^n$: επιθυμητή τροχιά, που πρέπει να ακολουθήσουν οι αρθρώσεις του ρομποτικού βραχίονα,
- $\mathbf{K}_p \in \mathbb{R}^{n \times n}$: διαγώνιος πίνακας θετικών κερδών.

Δηλαδή, η εντολή ταχύτητας στις αρθρώσεις ισούται με την επιθυμητή ταχύτητα μείον έναν διορθωτικό όρο ανάλογο με το σφάλμα θέση.

Περίπτωση 2: Έλεγχος στον χώρο εργασίας (task space) Εναλλακτικά, αντί να οριστεί η επιθυμητή τροχιά στις αρθρώσεις, μπορούμε να ελέγξουμε το εργαλείο του ρομπότ (end-effector) στον καρτεσιανό χώρο. Το επιθυμητό αποτέλεσμα αυτού του ελέγχου είναι το εξής:

$$\lim_{t\to\infty} \mathbf{p}(t) = \mathbf{p_d}(t) \lim_{t\to\infty} \dot{\mathbf{p}}(t) = \dot{\mathbf{p}}_\mathbf{d}(t) \tag{3.7}$$

Άρα, για την περίπτωση παρακολούθησης τροχιάς στον χώρο εργασίας του άκρου, ο νόμος ελέγχου δίνεται από:

$$\dot{\mathbf{q}}_c \triangleq {\mathbf{J_p}}^\dagger(\mathbf{q}) \left(\dot{\mathbf{p}}_d - \mathbf{K}_p(\mathbf{p} - \mathbf{p}_d)\right) \tag{3.8}$$

όπου:

- $\mathbf{p}_d, \dot{\mathbf{p}}_d \in \mathbb{R}^3$: επιθυμητή τροχιά του άκρου, την οποία πρέπει να ακολουθήσει το άκρο του ρομπότ,
- $\mathbf{p} \in \mathbb{R}^3$: τρέχουσα θέση άκρου,
- ${\mathbf{J_p}}^\dagger(\mathbf{q}) \in \mathbb{R}^{n \times m}$: Μπορεί να είναι είτε ο αντίστροφος (${\mathbf{J_p}}^\dagger(\mathbf{q}) \equiv {\mathbf{J_p}}^{-1}(\mathbf{q})$, είτε η δεξιά ψευδοαντίστροφη του Ιακωβιανού πίνακα σε περίπτωση πλεονασματικού ρομπότ $n > m$)

- $\mathbf{K}_p \in \mathbb{R}^{3\times3}$: διαγώνιος πίνακας θετικών κερδών.

Το σύστημα κλειστού βρόχου παρουσιάζει εκθετική σύγκλιση $(\mathbf{p}, \dot{\mathbf{p}}) = (\mathbf{p_d}, \dot{\mathbf{p_d}})$ με χρόνο αποκατάστασης που καθορίζεται από τον πίνακα K_p.

Ανάλυση Ευστάθειας με Lyapunov:

Έστω το σφάλμα θέσης στο χώρο εργασίας ορίζεται ως:

$$\mathbf{e}_p = \mathbf{p} - \mathbf{p}_d$$

και η παράγωγός του δίνεται από:

$$\dot{\mathbf{e}}_p = \dot{\mathbf{p}} - \dot{\mathbf{p}}_d = \mathbf{J}_p\dot{\mathbf{q}}_c - \dot{\mathbf{p}}_d$$

Αντικαθιστώντας τον νόμο ελέγχου 3.8:

$$\dot{\mathbf{e}}_p = \mathbf{J}_p\mathbf{J}_p^{\dagger}(\dot{\mathbf{p}}_d - \mathbf{K}_p\mathbf{e}_p) - \dot{\mathbf{p}}_d$$

και εφόσον ισχύει $\mathbf{J}_p\mathbf{J}_p^{\dagger} = \mathbf{I}_m$, προκύπτει:

$$\dot{\mathbf{e}}_p \approx -\mathbf{K}_p\mathbf{e}_p$$

Ορίζοντας συνάρτηση Lyapunov:

$$V(\mathbf{e}_p) = \frac{1}{2}\mathbf{e}_p^T\mathbf{e}_p$$

η παράγωγός της είναι:

$$\dot{V} = \mathbf{e}_p^T\dot{\mathbf{e}}_p = -\mathbf{e}_p^T\mathbf{K}_p\mathbf{e}_p < 0$$

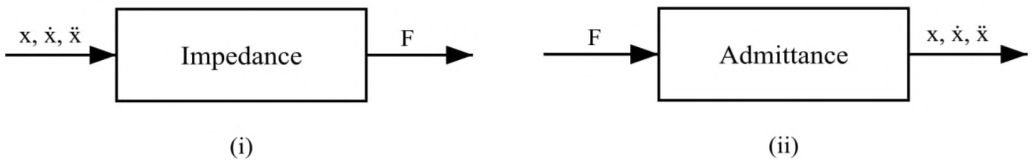
εφόσον $\mathbf{K}_p$ είναι θετικά ορισμένος πίνακας. Άρα, από το κλασικό θεώρημα ευστάθειας Lyapunov, το σφάλμα συγκλίνει εκθετικά στο μηδέν, δηλαδή $\mathbf{p}(t) \to \mathbf{p}_d(t)$.

Αυτός ο νόμος ελέγχου είναι γνωστός ως **Closed Loop Inverse Kinematics (CLIK)** και είναι αυτός, ο οποίος επιλέχθηκε με σκοπό την ακριβή παρακολούθηση της τροχιάς, σε πραγματικό χρόνο, του leader από τον follower στο χώρο εργασίας του άκρου. Στο follower ρομπότ, ο έλεγχος έγινε στο $SE(3)$. Αυτό επιτυγχάνεται μέσω της συνεχούς ανακατασκευής της αντίστοιχης επιθυμητής τροχιάς $\mathbf{p}_d, \dot{\mathbf{p}}_d$ από την κίνηση του leader, και εφαρμογή της αντίστροφης κινηματικής, με εγγύηση ευστάθειας και παρακολούθησης. Η μέθοδος αυτή προσφέρει σημαντικά πλεονεκτήματα, καθώς μπορεί να εξαλείψει σφάλματα μόνιμης κατάστασης που ενδέχεται να προκύψουν κατά την παρακολούθηση της τροχιάς, ενώ επιπλέον διορθώνει σταδιακά τα αθροιστικά σφάλματα που μπορεί να συσσωρεύονται λόγω προσεγγίσεων στον υπολογισμό της Ιακωβιανής ή της αντίστροφής της.

Αν και η CLIK προσφέρει ισχυρό εργαλείο για παρακολούθηση θέσης, δεν επαρκεί σε περιπτώσεις που το ρομπότ αλληλεπιδρά φυσικά με το περιβάλλον, όπως σε επαφή με ανθρώπους ή εύθραυστα αντικείμενα. Σε τέτοια σενάρια απαιτείται η δυναμική συμμόρφωση του ρομπότ, δηλαδή να προσαρμόζει την κίνησή του ανάλογα με εξωτερικές δυνάμεις. Αυτό επιτυγχάνεται μέσω του ελέγχου ενδοτικότητας (admittance control), ο οποίος εισάγεται στο επόμενο κεφάλαιο. Ο έλεγχος αυτός συνδυάζεται ιδανικά με κινηματικές στρατηγικές όπως η CLIK, επιτρέποντας ευέλικτη αλλά σταθερή συμπεριφορά.

3.2.2 Έλεγχος Ενδοτικότητας - Admittance Control

Ο έλεγχος ενδοτικότητας, μαζί με τον συγγενή του, τον έλεγχο εμπέδησης (*impedance control*), αποτελούν τις δύο βασικές μεθόδους ελέγχου αλληλεπίδρασης ρομπότ και περιβάλλοντος. Η ειδοποιός διαφορά μεταξύ των δύο είναι ότι ο έλεγχος ενδοτικότητας λαμβάνει δύναμη ως είσοδο και αποδίδει ταχύτητα ή θέση ως έξοδο, ενώ ο έλεγχος εμπέδησης κάνει το αντίστροφο, δηλαδή όταν η δύναμη αποτελεί την έξοδο του σύστημα και η θέση ή ο ρυθμός μεταβολής της, την είσοδο. Αυτό απεικονίζεται στο Σχήμα 3.1. Με άλλα λόγια, στον έλεγχο ενδοτικότητας το ρομπότ αντιδρά σε εξωτερικές



Σχήμα 3.1: Η είσοδος και η έξοδος στον έλεγχο ενδοτικότητας και εμπέδησης

δυνάμεις (δύναμη ή ροπή), προσπαθώντας να παράγει μία κίνηση (θέση, ταχύτητα ή επιτάχυνση), ενώ στον έλεγχο εμπέδησης το ρομπότ αντιστέκεται στις εξωτερικές δυνάμεις και προσπαθεί να τις αντισταθμίσει, δημιουργώντας αντίσταση που σχετίζεται με την ακαμψία του συστήματος.

Έστω, λοιπόν, ότι ο έλεγχος γίνεται στο άκρο του ρομποτικού βραχίονα και $\mathbf{p}(t)$ η θέση, $\dot{\mathbf{p}}(t)$ η ταχύτητα, $\ddot{\mathbf{p}}(t)$ η επιτάχυνση του άκρου σε έναν χώρο εργασίας $\mathbb{R}^m$ και επιθυμούμε το άκρο αυτό να ακολουθεί μια επιθυμητή τροχιά $\mathbf{p}_d(t), \dot{\mathbf{p}}_d(t), \ddot{\mathbf{p}}_d(t)$. Ο στόχος του ελέγχου είναι να δημιουργηθεί μια επιθυμητή δυναμική σχέση, μεταξύ της εξωτερικής δύναμης $\mathbf{F}_{\text{ext}}$ και του σφάλματος απόκλισης $\mathbf{e}(t) = \mathbf{p}(t) - \mathbf{p}_d(t)$ από την επιθυμητή θέση $\mathbf{p}_d$. Γι' αυτό το λόγο, μοντελοποιείται ένα σύστημα μάζας–ελατηρίου – αποσβεσης (mass-spring-damper), το οποίο περιγράφεται από τη δευτέρου βαθμού διαφορική εξίσωση:

$$\mathbf{M}_d\ddot{\mathbf{e}} + \mathbf{D}_d\dot{\mathbf{e}} + \mathbf{K}_d\mathbf{e} = \mathbf{F}_{\text{ext}} \tag{3.9}$$

όπου:

- $\mathbf{F}_{\text{ext}} \in \mathbb{R}^n$: οι εφαρμοζόμενες εξωτερικές δυνάμεις και ροπές στο ρομπότ,
- **Πίνακας Αδράνειας** $\mathbf{M}_d \in \mathbb{R}^{n\times n}$: Αποτελεί τον επιθυμητό πίνακα αδράνειας του άκρου του ρομπότ. Όπως ένα σώμα με μάζα έχει αδράνεια, έτσι και το ρομπότ αντιστέκεται σε απότομες αλλαγές στην επιτάχυνσή του. Ο πίνακας αυτός εκφράζει αυτή την «αντίσταση στην επιτάχυνση». Αν είναι μεγάλη, το σύστημα καθυστερεί να αντιδράσει σε εξωτερική δύναμη — παρουσιάζει «αδράνεια». Όσο πιο μεγάλη είναι, τόσο πιο βαρύ είναι, οπότε αργεί να αντιδράσει.
- **Πίνακας Απόσβεσης** $\mathbf{D}_d \in \mathbb{R}^{n\times n}$: Αυτός είναι ο επιθυμητός πίνακας του άκρου του ρομπότ, που ρυθμίζει το πώς "σβήνονται" οι ταλαντώσεις ή οι αποκλίσεις από την επιθυμητή τροχιά. Υψηλή απόσβεση μειώνει τις ταλαντώσεις, ενώ χαμηλή απόσβεση κάνει το σύστημα πιο ευέλικτο αλλά δυνητικά ασταθές. Όσο πιο μεγάλο είναι, τόσο πιο γρήγορα σβήνουν οι κινήσεις, αποτρέποντας τις ταλαντώσεις.
- **Πίνακας Ελατηρίου** $\mathbf{K}_d \in \mathbb{R}^{n\times n}$: Είναι ο επιθυμητός πίνακας που ελέγχει την ακαμψία του άκρου του ρομπότ. Όσο μεγαλύτερες είναι οι τιμές του πίνακα K_d, τόσο μεγαλύτερη είναι η δύναμη που ασκείται για να επιστρέψει το άκρο στην αρχική του θέση όταν απομακρυνθεί. Σε ορισμένες εφαρμογές τίθεται $\mathbf{K}_d = 0$ για καθαρά κινηματική απόκριση.

Ουσιαστικά, το ρομπότ συμπεριφέρεται δυναμικά σαν ένα σύστημα μάζας-ελατηρίου-αποσβεστήρα. Οι παράμετροι αυτοί δεν αντιστοιχούν σε φυσικά χαρακτηριστικά του ρομπότ, αλλά ρυθμίζονται για να επιτευχθεί η επιθυμητή συμπεριφορά. Συνήθως, είναι συμμετρικοί, θετικά ορισμένοι πίνακες.

Παρατηρείται, ότι όταν δεν υπάρχει η εξωτερική δύναμη $\mathbf{F}_{ext} = \mathbf{0}$, το σφάλμα και οι παραγωγοί του μηδενίζονται, οπότε $\mathbf{p} = \mathbf{p}_d$ (η επιθυμητή τροχιά ακολουθείται πλήρως).

Οπότε, με σκοπό την υλοποίηση του έλεγχου ενδοτικότητας σε ένα κινηματικά ελεγχόμενο ρομπότ (δέχεται ως είσοδο θέση ή ταχύτητα), έστω $\mathbf{p}_r(t), \dot{\mathbf{p}}_r(t), \ddot{\mathbf{p}}_r(t)$ η αναφορά κίνησης, που προκύπτει από ένα κινηματικό μοντέλο. Λύνοντας την διαφορική εξίσωση (3.9), μπορεί να βρεθεί η επιθυμητή μετατόπιση $\mathbf{e}_d(t)$ και η ταχύτητα $\dot{\mathbf{e}}_d(t)$, αφού βέβαια μετρηθεί η εξωτερική δύναμη $\mathbf{F}_{\text{ext}}$, μέσω του αισθητήρα. Έτσι,

$$\ddot{\mathbf{e}}_d = \mathbf{M}_d^{-1} \left(\mathbf{F}_{\text{ext}} - (\mathbf{D}_d \dot{\mathbf{e}}_d + \mathbf{K}_d \mathbf{e}_d) \right) \tag{3.10}$$

Αντικαθιστώντας στην σχέση $\mathbf{e}_d(t) = \mathbf{p}_r(t) - \mathbf{p}_d(t)$, το $\mathbf{e}_d(t)$ και την κίνηση αναφοράς $\mathbf{p}_r(t)$, $\dot{\mathbf{p}}_r(t)$, $\ddot{\mathbf{p}}_r(t)$, και λύνοντας ως προς αυτή, τότε έχουμε:

$$\mathbf{p}_r(t) = \mathbf{p}_d(t) + \mathbf{e}_d(t) \tag{3.11}$$

$$\dot{\mathbf{p}}_r(t) = \dot{\mathbf{p}}_d(t) + \dot{\mathbf{e}}_d(t) \tag{3.12}$$

$$\ddot{\mathbf{p}}_r(t) = \ddot{\mathbf{p}}_d(t) + \ddot{\mathbf{e}}_d(t) \tag{3.13}$$

όπου με την ολοκλήρωση της σχέσης 3.10 υπολογίζονται τα $\dot{\mathbf{e}}_d(t)$ και $\mathbf{e}_d(t)$.

Με αυτόν τον τρόπο, χωρίς να χρειάζεται κάποια επιθυμητή τροχιά, το ρομπότ μπορεί να κουνιέται, με βάση τη διαταραχή, που του προκαλεί ο χρήστης.

Σημείωση: Για μεγαλύτερη ευκολία στην ανάλυση των κινήσεων του, θεωρείται ότι το ρομπότ εργάζεται σε Ευκλείδειο χώρο, αντί για το γενικότερο χώρο $SE(3)$ (που περιλαμβάνει και περιστροφές και μετατοπίσεις).

3.3 Υλοποίηση Admittance control στον leader ρομποτικό βραχίονα

Ο λόγος που χρησιμοποιήθηκε έλεγχος ενδοτικότητας (*admittance control*) είναι επειδή το ρομπότ δέχεται εντολές ταχύτητας, και όχι ροπές στις αρθρώσεις. Έτσι, στον leader ρομποτικό βραχίονα του παρόντος συστήματος, εφαρμόζεται έλεγχος ενδοτικότητας με σκοπό να μετατραπεί η εφαρμοζόμενη εξωτερική δύναμη σε επιθυμητή κίνηση. Συγκεκριμένα, όταν ο χρήστης εφαρμόζει μία δύναμη χειροκίνητα στη λαβή (handle) του ρομπότ προς κάποια κατεύθυνση, το ρομπότ ανταποκρίνεται ανάλογα και κινείται προς εκείνη την κατεύθυνση, σαν να ήταν ένα φυσικό σώμα με αδράνεια και απόσβεση. Η προσέγγιση αυτή αυξάνει την ασφάλεια και καθιστά το σύστημα κατάλληλο για συνεργασία με ανθρώπους. Εννοείται, πως για να επιτευχθεί αυτό, σημαίνει ότι το ρομποτικό σύστημα ελέγχεται κινηματικά.

Προετοιμασία δεδομένων για τον έλεγχο Πριν την υλοποίηση του ελέγχου ενδοτικότητας, θα πρέπει να πραγματοποιηθούν κάποια βήματα. Αρχικά, μέσω κατάλληλου αισθητήρα παίρνουμε την γενικευμένη δύναμη $\mathbf{F}_h$, που εφαρμόζει ο χρήστης στο άκρο του leader ρομπότ (μετριέται μέσω αισθητήρα Force-Torque) και είναι:

$$\mathbf{F}_h \triangleq \begin{bmatrix} \mathbf{f}_h \\ \boldsymbol{\tau}_h \end{bmatrix} \tag{3.14}$$

όπου $\mathbf{f}_h \in \mathbb{R}^3$ είναι οι δυνάμεις (forces) και $\tau_h \in \mathbb{R}^3$ είναι οι ροπές (torques) που ασκεί ο χρήστης (human) μέσω της λαβής στο leader ρομπότ. Αυτές οι δυνάμεις είναι εκφρασμένες ως προς τη βάση. Η αντίστοιχη ροπή στις αρθρώσεις του ρομπότ (leader) που προκαλείται από τη δύναμη αυτή υπολογίζεται μέσω της ιακωβιανής βάση τη σχέση:

$$\mathbf{u}_h = \mathbf{J}_{e,l}^{\intercal}(\mathbf{q}_l)\mathbf{F}_h \tag{3.15}$$

όπου $\mathbf{u}_h \in \mathbb{R}^{n_l}$ είναι οι ροπές των αρθρώσεων του leader ρομπότ, $\mathbf{q}_l \in \mathbb{R}^{n_l}$ είναι το διάνυσμα των αρθρώσεων του leader ρομπότ (l) και $\mathbf{J}_{e,l}$ είναι η ιακωβιανή του leader ρομπότ, εκφρασμένη ως προς τη βάση.

Πρόσθεση dead-zone - Φιλτράρισμα θορύβου Για την αποφυγή αστάθειας λόγω θορύβου ή μικρών ανεπιθύμητων ερεθισμάτων, χρησιμοποιείται φιλτράρισμα τύπου *deadzone*, όπου μικρές δυνάμεις θεωρούνται μηδενικές. Η ιδέα είναι ότι αν η μετρούμενη δύναμη από τον leader βραχίονα $\mathbf{f}_h \in \mathbb{R}^3$ είναι μικρότερη από μία χαμηλή τιμή, για παράδειγμα 4, τότε να αγνοείται πλήρως. Σε αντίθετη περίπτωση, αυτά τα 4 θα αφαιρούνται πάντα, με σκοπό η "καθαρή" δύναμη, χωρίς τον θόρυβο να ξεκινάει από εκεί και πάνω. Άρα,

$$\mathbf{f}_{\text{filtered}} = \begin{cases} \mathbf{0}, & \text{αν } \|\mathbf{f}_{\text{h}}\| < 4.0N \\ \mathbf{f}_{\text{h}} - 4.0 \cdot \hat{\mathbf{f}}_{\text{h}}, & \text{αλλιώς} \end{cases} \tag{3.16}$$

όπου $\hat{\mathbf{f}}_{\text{h}} = \frac{\mathbf{f}_{\text{h}}}{\|\mathbf{f}_{\text{h}}\|}$ η μοναδιαία διεύθυνση της δύναμης (*unit vector*).

Ομοίως, για τις ροπές $\tau_h \in \mathbb{R}^3$, εφαρμόζεται ένα ελάχιστο κατώφλι ροπής, για παράδειγμα $0.5 \cdot m$:

$$\boldsymbol{\tau}_{\text{filtered}} = \begin{cases} \mathbf{0}, & \text{αν } \|\boldsymbol{\tau}_{\text{h}}\| < 0.5N \cdot m \\ \boldsymbol{\tau}_{\text{h}} - 0.5 \cdot \hat{\boldsymbol{\tau}}_{\text{h}}, & \text{αλλιώς} \end{cases} \tag{3.17}$$

όπου $\hat{\tau}_{\text{h}} = \frac{\tau_{\text{h}}}{\|\tau_{\text{h}}\|}$, η μοναδιαία διεύθυνση της ροπής.

Έλεγχος Ενδοτικότητας στον ρομποτικό βραχίονα: Σε κινηματικά ελεγχόμενα ρομποτικά συστήματα, η είσοδος δύναμης μεταφράζεται σε επιθυμητές τροχιές (θέσεις ή ταχύτητες). Για τον σκοπό αυτό, χρησιμοποιείται ένας έλεγχος ενδοτικότητας (*admittance control*). Στην παρούσα εργασία, ο έλεγχος ενδοτικότητας υλοποιείται στον χώρο αρθρώσεων (joint space), και αποσκοπεί στη μετατροπή της εξωτερικής δύναμης που εφαρμόζεται από τον χρήστη σε επιθυμητή κίνηση του ρομπότ, προσομοιώνοντας ένα σύστημα δυναμικής συμπεριφοράς μαζας-απόσβεσης. Ο λόγος που δεν χρησιμοποιήθηκε ο όρος του ελατηρίου $\mathbf{K}_d$ είναι επειδή επιθυμούμε ο χρήστης να μπορεί να καθοδηγήσει "ελεύθερα" τον ρομποτικό βραχίονα, χωρίς να έλκεται προς κάποιον στόχο. Αυτό το σύστημα, επιτυγχάνεται χωρίς τη χρήση του δυναμικού μοντέλου του ρομπότ, αλλά μέσω της μέτρησης της εξωτερικής δύναμης από τον αισθητήρα και τον υπολογισμό των αντίστοιχων ροπών αρθρώσεων (3.24).

Αυτές οι ροπές χρησιμοποιούνται ως είσοδος στη διαφορική εξίσωση:

$$\mathbf{M}_d \ddot{\mathbf{q}}_l + \mathbf{D}_d \dot{\mathbf{q}}_l = \mathbf{u}_h, \tag{3.18}$$

όπου $\dot{\mathbf{q}}_l, \ddot{\mathbf{q}}_l \in \mathbb{R}^{n_l}$ είναι οι ταχύτητες και επιταχύνσεις των αρθρώσεων του leader ρομπότ, $\mathbf{M}_d \in \mathbb{R}^{n_l \times n_l}$ είναι ο επιθυμητός πίνακας αδράνειας (inertia) και $\mathbf{D}_d \in \mathbb{R}^{n_l \times n_l}$ είναι ο επιθυμητός πίνακας απόσβεσης (damping). Οι πίνακες $\mathbf{M}_d$ και $\mathbf{D}_d$ είναι συμμετρικοί, θετικά ορισμένοι και η σωστή παραμετροποίηση τους είναι καθοριστικής σημασίας για την επίτευξη σταθερής και "φυσικής" συμπεριφοράς.

Λύνοντας τη διαφορική εξίσωση δεύτερης τάξης (3.18), προκύπτει η επιτάχυνση:

$$\ddot{\mathbf{q}}_l = \mathbf{M}_d^{-1} \left(\mathbf{u}_h - \mathbf{D}_d \dot{\mathbf{q}}_l \right) \tag{3.19}$$

Η εξίσωση 3.19 ολοκληρώνεται αριθμητικά, με σκοπό να παραχθούν οι ταχύτητες των αρθρώσεων $\dot{\mathbf{q}}_{\text{l}}$ και στη συνέχει η θέση $\mathbf{q}_l$. Οι ταχύτητες αυτές εφαρμόζονται απευθείας στο ρομπότ μέσω εντολών ταχύτητας, χρησιμοποιώντας τη διεπαφή RTDE της UR.

Καταληκτικά, η συγκεκριμένη προσέγγιση παρουσιάζει αρκετά πλεονεκτήματα για το ρομποτικό σύστημα και την εργασία που επιθυμούμε να εκτελέσει, καθώς:

- Αυξάνει την ασφάλεια: Μικρές μετακινήσεις από τον χρήστη δεν προκαλούν απότομες κινήσεις λόγω της εικονικής αδράνειας που έχει εισαχθεί στο μοντέλο.
- Επιτρέπει μια "φυσική" καθοδήγηση: Ο χρήστης αισθάνεται αντίσταση ή αδράνεια, όπως σε ένα πραγματικό σύστημα, βελτιώνοντας την αντίληψη και τον έλεγχο.

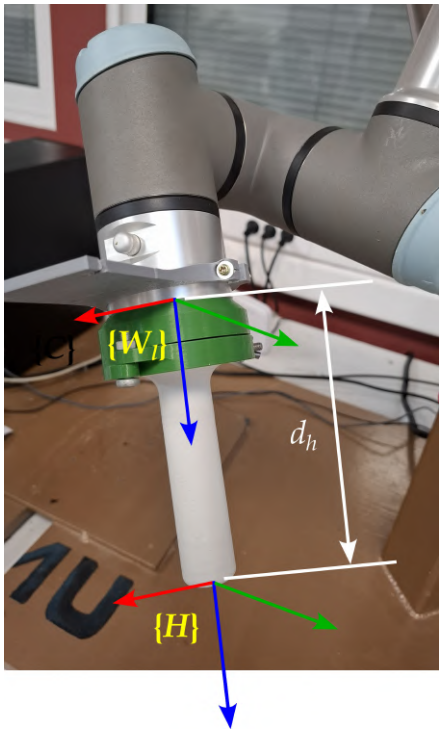
- Ελαχιστοποίηση θορύβων μέτρησης δυνάμης: Η παρουσία απόσβεσης και η χρήση φίλτρων (όπως η dead-zone) εξασφαλίζουν ότι μικρές διακυμάνσεις στη δύναμη δεν επηρεάζουν την κίνηση.

Τέλος, η επιλογή των παραμέτρων $\mathbf{M}_d$ και $\mathbf{D}_d$ παίζει κρίσιμο ρόλο. Πολύ μικρές τιμές οδηγούν σε ευαίσθητο, αλλά ίσως ασταθές σύστημα, ενώ πολύ μεγάλες σε αδρανές και δύσκολα χειρίσιμο σύστημα. Στην πράξη, επιλέχθηκαν εμπειρικά βάσει της φυσικής αλληλεπίδρασης και της επιθυμητής απόκρισης του ρομπότ.

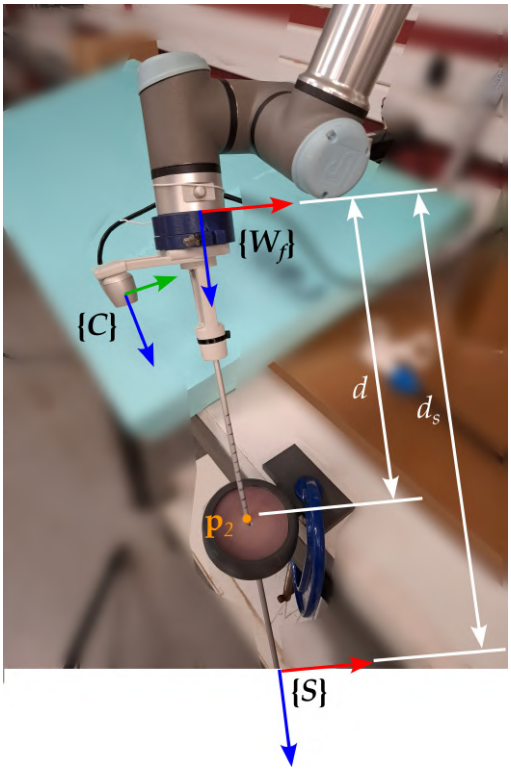
3.4 Έλεγχος κίνησης στον follower ρομποτικό βραχίονα

Προετοιμασία δεδομένων για τον κινηματικό έλεγχο: Πριν την υλοποίηση του ελέγχου κίνησης στο follower ρομπότ, απαιτείται μια αρχική κινηματική ανάλυση. Αρχικά, και για τα δύο ρομπότ (leader-follower 6 β.ε.) θα πρέπει να παρθεί το διάνυσμα των πραγματικών γωνιών των αρθρώσεων σε rad, της μορφής $\mathbf{q}_{oi} = [q_1, q_2, q_3, q_4, q_5, q_6]^T$, όπου $i \in \{l,\ f\}$. Δηλαδή, παίρνουμε την αρχική διαμόρφωση (initial joint configuration) των δύο ρομπότ $\mathbf{q}_{ol}$, $\mathbf{q}_{of} \in \mathbb{R}^6$.

Αξιοποιώντας τις γωνίες των αρθρώσεων και τη λύση του ευθύ κινηματικού (Forward Kinematics), υπολογίζονται οι ομογενείς μετασχηματισμοί $\mathbf{g}_i \in SE(3)$ των δύο ρομποτικών βραχιόνων και από αυτούς εξάγονται οι πίνακες στροφής $\mathbf{R}_i \in SO(3)$ και πίνακες θέσης $\mathbf{p}_i \in \mathbb{R}^3$. Έστω, λοιπόν, $\{S\}$ το πλαίσιο αναφοράς στην άκρη του χειρουργικού εργαλείου του follower ρομπότ (tool tip), $\{\mathrm{H}\}$ το πλαίσιο αναφοράς στην άκρη της λαβής του leader ρομπότ (handle), $\{W_l\}, \{W_f\}$ τα πλαίσιο αναφοράς στους καρπούς του leader και του follower ρομπότ, αντίστοιχα. Επιπλέον, ορίζουμε $d_s, d_h \in \mathbb{R}^+$ τις μετρούμενες αποστάσεις σε μέτρα από τον καρπό ως την άκρη του χειρουργικού εργαλείου ή της λαβής, αντίστοιχα. Τα πλαίσια και οι αποστάσεις φαίνονται στις εικόνες 3.2α□ και 3.2β□.



(α□) Το χειρουργικό εργαλείο με την κάμερα στον follower ρομπότ



(β□) Η λαβή στο leader ρομπότ

Σχήμα 3.2: Εξήγηση των πλαισίων και των αποστάσεων στους δύο ρομποτικούς βραχίονες

Οι αποστάσεις αυτές είναι ευθυγραμμισμένες κατά τον άξονα z κάθε καρπού. Άρα, οι θέσεις των άκρων της λαβής ή του χειρουργικού εργαλείου σε σχέση με τη βάση κάθε ρομπότ δίνονται από:

$$\mathbf{p}_{\text{handle}} = \mathbf{p}_l + \mathbf{R}_l \cdot (d_h \cdot \hat{\mathbf{z}}) \tag{3.20}$$

$$\mathbf{p}_{\text{tool}} = \mathbf{p}_f + \mathbf{R}_f \cdot (d_s \cdot \hat{\mathbf{z}}) \tag{3.21}$$

όπου $\hat{\mathbf{z}} = [0, 0, 1]^T$ και είναι ο μοναδιαίος διανυσματικός άξονας z στο τοπικό πλαίσιο του καρπού.Το d_h μετρήθηκε συγκεκριμένα $0.13m$ και το d_s μετρήθηκε $0.53m$.

Με αυτόν τον τρόπο, η στιγμιαία διαφορά θέσης (offset) μεταξύ των άκρων του leader και του follower βραχίονα υπολογίζεται ως:

$$\mathbf{p}_{dlf} = \mathbf{p}_{tool} - \mathbf{p}_{handle} \in \mathbb{R}^3 \tag{3.22}$$

Το διάνυσμα $\mathbf{p}_{dlf}$ αποτελεί ένα σταθερό διάνυσμα μετατόπισης μεταξύ των σημείων ελέγχου (tool tip) των δύο ρομπότ και χρησιμοποιείται σε κάθε χρονικό βήμα για τον υπολογισμό σφαλμάτων θέσης. Το αρχικό offset μεταξύ των δύο άκρων, την χρονική στιγμή $t = 0$ (όταν ξεκινάει η σύνδεση leader-follower, πάτημα του clutch) είναι:

$$\tilde{\mathbf{p}}_0 \triangleq \mathbf{p}_{tool}(0) - \mathbf{p}_{handle}(0) \in \mathbb{R}^3 \tag{3.23}$$

Υπολογισμός ταχυτήτων Η γενικευμένη ταχύτητα των δύο ρομπότ στο σημείο του καρπού ορίζεται ως:

$$\mathbf{V}_i \triangleq \begin{bmatrix} \dot{\mathbf{p}}_i \\ \boldsymbol{\omega}_i \end{bmatrix} \in \mathbb{R}^6$$

όπου $\dot{\mathbf{p}}_\mathbf{i} \in \mathbb{R}^3$ είναι η ταχύτητα μεταφοράς (translational velocity) και $\omega_i \in \mathbb{R}^3$ είναι η γωνιακή ταχύτητα (angular velocity).

Η σχέση που συνδέει τις ταχύτητες των αρθρώσεων με τη γενικευμένη ταχύτητα του άκρου (γραμμική και περιστροφική) είναι:

$$\mathbf{V}_i = \mathbf{J}_{e,i}(\mathbf{q}_i)\dot{\mathbf{q}}_i \tag{3.24}$$

όπου $\mathbf{J}_{e,i} \in \mathbb{R}^{6\times n}$ είναι η ιακωβιανή μήτρα (Jacobian), που αντιστοιχεί στο άκρο (end-effector) του εργαλείου.

Ωστόσο, σε πολλές εφαρμογές, δεν μας ενδιαφέρει η ταχύτητα στον καρπό, αλλά σε ένα σημείο που βρίσκεται σε απόσταση από αυτόν. Σε αυτήν την περίπτωση, ο στόχος είναι ο έλεγχος της άκρης (tip) του εργαλείου, που βρίσκεται σε απόσταση d_s πάνω στον άξονα z του καρπού στο πλαίσιο $\{W_f\}$. Οπότε, πρέπει να γίνει μετατροπή ταχυτήτων από τον καρπό (wrist) στο άκρο (tip). Γενικά, για έναν άκαμπτο σύνδεσμο (rigid body), όταν θέλουμε να βρούμε την ταχύτητα ενός σημείου P που απέχει διάνυσμα $\mathbf{r}$ από ένα σημείο (βλ. Σχήμα 3.3), ισχύει:

$$\mathbf{V}_P = \mathbf{V}_O + \boldsymbol{\omega} \times \mathbf{r}$$

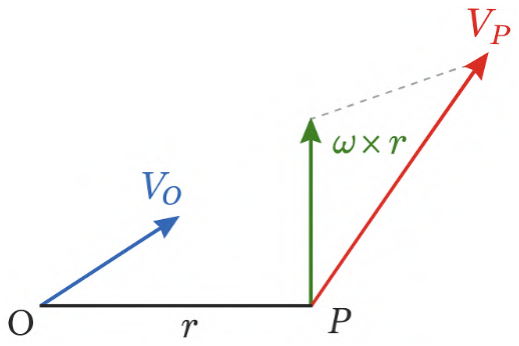
με την προϋπόθεση ότι $\mathbf{V}_O, \boldsymbol{\omega}, \mathbf{r}$ εκφράζονται στο ίδιο πλαίσιο αναφοράς.

Για το follower ρομπότ, η σχέση ταχυτήτων ανάμεσα στον καρπό και την άκρη του χειρουργικού εργαλείου γράφεται:

$$\mathbf{V}_{\text{tool}} = \dot{\mathbf{p}}_f + \boldsymbol{\omega}_f \times \mathbf{r}_\mathbf{f} \tag{3.25}$$

όπου $\mathbf{r}_f = \mathbf{R}_f(d_s\hat{\mathbf{z}})$ είναι το διάνυσμα μετατόπισης από τον καρπό στην άκρη του εργαλείου (στο παγκόσμιο πλαίσιο), $\hat{\mathbf{z}} = [0,\ 0,\ 1]^\top$, και $\boldsymbol{\omega}_f$ είναι η γωνιακή ταχύτητα.

Το εξωτερικό γινόμενο (cross product) για διευκόλυνση στις πράξεις, μπορεί να εκφραστεί ως πολλαπλασιασμός πίνακα με τον αντισυμμετρικό πίνακα (Skew symmetric). Οπότε:



Σχήμα 3.3: Διανυσματική απεικόνιση της σχέσης $\mathbf{V}_P = \mathbf{V}_O + \boldsymbol{\omega} \times \mathbf{r}$. Η ταχύτητα στο σημείο P προκύπτει από το άθροισμα της ταχύτητας στο σημείο αναφοράς O και της συνιστώσας που οφείλεται στη γωνιακή ταχύτητα $\boldsymbol{\omega}$ και την απόσταση $\mathbf{r}$.

$$\omega \times \mathbf{r} = -\mathbf{S}(\mathbf{r}) \cdot \boldsymbol{\omega}, \text{όπου} \quad \mathbf{S}(\mathbf{r}) = \begin{bmatrix} 0 & -r_z & r_y \\ r_z & 0 & -r_x \\ -r_y & r_x & 0 \end{bmatrix}$$

Άρα, ολοκληρωμένα η σχέση 3.25 γράφεται ισοδύναμα:

$$\mathbf{V}_{tool} = \dot{\mathbf{p}}_f - \mathbf{S}(\mathbf{r_f}) \cdot \boldsymbol{\omega}_f \tag{3.26}$$

Ομοίως, και για το leader ρομπότ, η ταχύτητα στο άκρο της λαβής, μπορεί να υπολογιστεί, ως:

$$\mathbf{V}_{handle} = \dot{\mathbf{p}}_l - \mathbf{S}(\mathbf{r_l}) \cdot \boldsymbol{\omega}_l \tag{3.27}$$

όπου $\mathbf{r}_l = \mathbf{R}_l(d_h \hat{\mathbf{z}})$ είναι το διάνυσμα μετατόπισης από τον καρπό του leader στην άκρη της λαβής (στο παγκόσμιο πλαίσιο).

Κινηματικός έλεγχος (CLIK) στο follower ρομπότ Το follower ρομπότ πρέπει να παρακολουθεί την κίνηση της άκρης της λαβής στην πλευρά του leader. Για το σκοπό αυτό, χρησιμοποιείται κινηματικός έλεγχος παρακολούθησης τροχιάς (trajectory tracking) στο επίπεδο ταχυτήτων στον χώρο εργασίας. Ο στόχος είναι, όταν ο χειρουργός κινεί το άκρο της λαβής (στην πλευρά του leader), να ακολουθεί το άκρο του εργαλείου (στην πλευρά του follower) την ίδια τροχιά. Για να επιτευχθεί αυτή η αντιστοίχιση, εφαρμόζουμε το ακόλουθο σήμα κινηματικού ελέγχου παρακολούθησης τροχιάς για τις ταχύτητες των αρθρώσεων του follower ρομπότ, ο οποίος είναι η επέκταση του 3.8, από το $\mathbb{R}^3$ στο χώρο $SE(3)$:

$$\dot{\mathbf{q}}_f \triangleq \mathbf{J}_{0,f}^{\dagger}(\mathbf{q}_f) \begin{bmatrix} \mathbf{I}_3 & \mathbf{S}(\mathbf{r}_f) \\ \mathbf{0}_3 & \mathbf{I}_3 \end{bmatrix} (\mathbf{V}_{handle} - \mathbf{K} \cdot \mathbf{e}), \tag{3.28}$$

όπου $\mathbf{J}_{0,f}^{\dagger} \in \mathbb{R}^{n_f \times 6}$ είναι ο ψευδοαντίστροφος (είναι ο αντίστροφος αν $n_f = 6$) της Ιακωβιανής του follower ως προς τη βάση του $\mathbf{J}_{0,f} = \text{diag}(\mathbf{R}_f, \mathbf{R}_f)\mathbf{J}_{e,f}$ με $\mathbf{R}_l, \mathbf{R}_f \in SO(3)$ να είναι οι πίνακες στροφής του καρπού του leader και του follower αντίστοιχα, ως προς τη βάση κάθε ρομπότ, $\mathbf{K} \in \mathbb{R}^{6\times6}$ είναι ένας θετικά ορισμένος πίνακας κέρδους και το γενικευμένο σφάλμα $\mathbf{e}$, ανάμεσα στη θέση και τον προσανατολισμό της άκρης της λαβής (leader) και του εργαλείου (follower) ορίζεται ως:

$$\mathbf{e} \triangleq \begin{bmatrix} \mathbf{p}_{handle} - \mathbf{p}_{tool} + \tilde{\mathbf{p}}_0 \\ \log\left(\mathbf{R}_s \mathbf{R}_h^{\intercal}\right) \end{bmatrix}, \tag{3.29}$$

όπου $\mathbf{R}_s, \mathbf{R}_h \in SO(3)$ ο προσανατολισμός των άκρων των ρομπότ σε μορφή πίνακα στροφής (στην εξεταζόμενη διάταξη $\mathbf{R}_s = \mathbf{R}_f$ και $\mathbf{R}_h = \mathbf{R}_l$).

Το σφάλμα θέσης είναι ουσιαστικά η διαφορά θέσης με αντιστάθμιση του αρχικού offset. Ουσιαστικά, το $\tilde{\mathbf{p}}_0$, κρατά την σχετική διαφορά θέσης μεταξύ των άκρων την στιγμή της σύνδεσης, ώστε να ακολουθεί σωστά το άκρο του εργαλείου, ακόμα κι αν δεν είναι στην ακριβώς ίδια θέση. Το σφάλμα προσανατολισμού αποσκοπεί στην ταύτιση του πλαισίου $\{S\}$, με το $\{H\}$, με $\log(\mathbf{R}) = \theta\mathbf{k} \in \mathbb{R}^3$ η λογαριθμική απεικόνιση του πίνακα στροφής, όπου $\theta \in \mathbb{R}$ είναι η γωνία περιστροφής και $\mathbf{k} \in \mathbb{R}^3$ είναι η διεύθυνση του άξονα στροφής. Χρησιμοποιείται, διότι ο χώρος $SO(3)$ δεν είναι γραμμικός, οπότε δεν γίνεται απλά να γίνει αφαίρεση των πινάκων στροφής.

Παρατηρείται ότι, το σφάλμα $\mathbf{e}$ μηδενίζεται αν και μόνο αν οι δύο άκρες ταυτιστούν στη θέση και στον προσανατολισμό τους, λαμβάνοντας υπόψη και την αρχική μετατόπιση $\tilde{\mathbf{p}}_0$. Στην παρούσα εφαρμογή, εφόσον το επιθυμητό σήμα, που πρέπει να ακολουθήσει το ρομπότ είναι φραγμένο (δηλαδή $\mathbf{p}_h, \mathbf{R}_h, \mathbf{v}_h$ παραμένουν εντός πεπερασμένων ορίων), τότε το σφάλμα θέσης και προσανατολισμού μεταξύ της άκρης της λαβής και της άκρης του εργαλείου τείνει στο μηδέν με την πάροδο του χρόνου, δηλαδή $\|\mathbf{e}\|_2 \to 0$ για $t \to \infty$. Η ασυμπτωματική ευστάθεια του συστήματος, μπορεί εύκολα να αποδειχθεί με τη χρήση κατάλληλης συνάρτησης Lyapunov. Συνεπώς, το άκρο του εργαλείου προσεγγίζει με την πάροδο του χρόνου την ίδια θέση και κατεύθυνση με τη λαβή, χωρίς την εμφάνιση ταλαντώσεων ή μεγάλων αποκλίσεων, αρκεί τα επιθυμητά σήματα να είναι φραγμένα.

Θα πρέπει να σημειωθεί ότι θεωρούμε μια κλιμάκωση μία προς μία μεταξύ του leader και του follower ρομπότ, αλλά δεν είναι δύσκολο να επεκταθεί η παραπάνω λογική για την ενσωμάτωση και ενός διαφορετικού συντελεστή κλιμάκωσης(π.χ. να μετακινείται το εργαλείο λιγότερο από τη λαβή).

Κεφάλαιο 4

Σχεδίαση και Υλοποίηση Ολοκληρωμένου Συστήματος Ελέγχου Leader-Follower με Απτική Ανάδραση μέσω DCNN

Η ενοποίηση των επιμέρους υποσυστημάτων που παρουσιάστηκαν στα προηγούμενα κεφάλαια οδηγεί στην υλοποίηση ενός ολοκληρωμένου τηλεχειριζόμενου (teleoperated) ρομποτικού συστήματος δύο βραχιόνων τύπου leader–follower. Το σύστημα αυτό, συνδυάζει τεχνικές κινηματικού ελέγχου στους ρομποτικούς βραχίονες, καθώς και τη χρήση βαθιών συνελικτικών νευρωνικών δικτύων για την εκτίμηση παραμόρφωσης σε πραγματικό χρόνο. Συγκεκριμένα, το σύστημα αποτελείται από τα εξής βασικά υποσυστήματα:

- Τον **leader βραχίονα**, τον οποίο χειρίζεται άμεσα ο χρήστης (χειρουργός), παρέχοντας την επιθυμητή τροχιά μέσω φυσικής αλληλεπίδρασης.
- Η απόκριση του συστήματος σε εξωτερικές δυνάμεις, ρυθμίζεται δυναμικά μέσω του **ελέγχου ενδοτικότητας**, που προσομοιώνει μηχανική συμπεριφορά (μάζα–απόσβεση). Στο Κεφ. θα δούμε πώς εκτός από τις εξωτερικές δυνάμεις από τον χρήστη, θα εισαχθεί στον έλεγχο ενδοτικότητας και η καθοδήγηση μέσω του DCNN.
- Τον **follower βραχίονα**, ο οποίος ακολουθεί με ακρίβεια την επιθυμητή τροχιά που προκύπτει από τον leader. Η επικοινωνία μεταξύ των δύο βραχιόνων βασίζεται σε RTDE (Real-Time Data Exchange).
- Ένα υποσύστημα **πραγματικού χρόνου επεξεργασίας εικόνας**, το οποίο φιλτράρει τα δεδομένα της κάμερας και τροφοδοτεί το μοντέλο με κατάλληλα προεπεξεργασμένες εικόνες.
- Ένα **βαθύ συνελικτικό νευρωνικό δίκτυο** (DCNN), το οποίο, με βάση εικόνων από την κάμερα RGB, εκτιμά σε πραγματικό χρόνο, την παραμόρφωση του χειρουργικού εργαλείου και υπολογίζεται η εικονική δύναμη.
- Μία δεξαμενή ενέργειας (**energy tank**), που ρυθμίζει την επίδραση των εικονικών δυνάμεων, διατηρώντας την παθητικότητα του συστήματος και περιορίζοντας την παρεχόμενη ενέργεια εντός ασφαλών ορίων.

Σε αυτό το κεφάλαιο, παρουσιάζεται αναλυτικά η υλοποίηση του ολοκληρωμένου συστήματος που αναπτύχθηκε στο πλαίσιο της παρούσας διπλωματικής εργασίας. Αρχικά περιγράφεται το υποσύστημα επεξεργασίας εικόνας και η ενσωμάτωσή του στο κύριο βρόχο ελέγχου. Στη συνέχεια, αναλύεται ο τρόπος με τον οποίο η εκτίμηση παραμόρφωσης μετασχηματίζεται σε εικονικές δυνάμεις, καθώς και η ενσωμάτωσή τους στο σχήμα admittance ελέγχου. Τέλος, η εφαρμογή των εικονικών δυνάμεων γίνεται υπό τον έλεγχο μιας ενεργειακής δεξαμενής (energy tank), η οποία διασφαλίζει την

παθητικότητα του συστήματος και την ασφαλή λειτουργία του υπό την επίδραση εξωτερικών παρεμβολών.

4.1 Πολυνηματική Αρχιτεκτονική

Στο παρόν σύστημα, η εκτίμηση της παραμόρφωσης επιτυγχάνεται μέσω ενός DCNN που λειτουργεί σε πραγματικό χρόνο, το οποίο λαμβάνει εικόνες από μία κάμερα τύπου Intel RealSense. Το υποσύστημα επεξεργασίας εικόνας είναι υπεύθυνο για την συλλογή των εικόνων, την κτάλληλη προεπεξεργασία τους, την εκτίμηση της παραμόρφωσης μέσω του ήδη εκπαιδευμένου DCNN και εν τέλει τη μετατροπή της εκτίμησης σε πληροφορία κατάλληλη για χρήση στον βρόχο ελέγχου του leader ρομπότ.

Η εκτίμηση της παραμόρφωσης του μαλακού ιστού σε πραγματικό χρόνο και η απόδοση απτικής ανάδρασης απαιτούν την υλοποίηση ενός συστήματος που να μπορεί να εκτελεί υπολογιστικά απαιτητικές διεργασίες με συγκεκριμένο ρυθμό ενημέρωσης, χωρίς να διαταράσσεται η συνολική ευστάθεια και η ανταπόκριση του ρομποτικού ελέγχου. Για τον σκοπό αυτό, το σύστημα υλοποιήθηκε με χρήση **πολυνηματικής αρχιτεκτονικής**, περιλαμβάνοντας δύο ανεξάρτητα νήματα (threads). Με τη βοήθεια των νημάτων, υπάρχει η δυνατότητα να τρέχουν ταυτόχρονα διαφορετικά κομμάτια ενός προγράμματος (παράλληλη επεξεργασία). Έτσι, δημιουργήθηκαν τα:

- **Thread 1 - Βρόχος Ελέγχου Ρομπότ (Robot Control Loop)**: Το πρώτο νήμα είναι το main thread του προγράμματος, το οποίο εκτελεί τον κύριο βρόχο ελέγχου του ρομπότικού συστήματος. Είναι υπεύθυνο, δηλαδή, για την συλλογή δεδομένων από τον αισθητήρα δύναμης, την υλοποίηση του ελέγχου ενδοτικότητας και την αποστολή εντολών ταχυτήτων μέσω του RTDE. Ο χρονισμός του διατηρείται σταθερά στα 2ms (500Hz), εξασφαλίζοντας υψηλή απόκριση.

- **Thread 2 – Επεξεργασία Εικόνας και Εκτίμηση Παραμόρφωσης σε Πραγματικό Χρόνο**: Τρέχει σε ξεχωριστό βοηθητικό νήμα και είναι υπεύθυνο για την επεξεργασία εικόνων που λαμβάνονται συνεχώς από την κάμερα (Intel RealSense). Μέσω του DCNN, εκτιμά σε πραγματικό χρόνο την παραμόρφωση στην περιοχή της τομής. Από την εκτιμώμενη παραμόρφωση υπολογίζεται μια εικονική δύναμη (virtual force), η οποία τροφοδοτείται στο σύστημα.

Η επικοινωνία μεταξύ των δύο νημάτων πραγματοποιείται μέσω δύο κοινών μεταβλητών μνήμης, το φιλτραρισμένο μέτρο της παραμόρφωσης και το ύψος της θέση του χειρουργικού εργαλείου που βρίσκεται πάνω στην τομή. Για την αποφυγή συνθηκών ανταγωνισμού (race conditions), χρησιμοποιούνται κατάλληλοι μηχανισμοί συγχρονισμού (όπως mutexes ή threading.Lock), οι οποίοι διασφαλίζουν την ατομική πρόσβαση στις κοινόχρηστες μεταβλητές.

Η προσέγγιση αυτή εξασφαλίζει την ομαλή και συνεχή λειτουργία του συστήματος σε πραγματικό χρόνο, καθώς και την αποφυγή καθυστερήσεων στον έλεγχο του ρομπότ. Βέβαια, η συνολική απόδοση του συστήματος σε πραγματικό χρόνο εξαρτάται σημαντικά, από το hardware (GPU, CPU, RAM), την πολυπλοκότητα του DCNN και από την συχνότητα λήψης εικόνων από την κάμερα.

4.2 Κατάλληλη προετοιμασία της εξόδου του νευρωνικού δικτύου

Φιλτράρισμα της εκτίμησης παραμόρφωσης μέσω εκθετικού κινητού μέσου όρου (EMA): Για τη βελτίωση της σταθερότητας και της αξιοπιστίας της εκτίμησης παραμόρφωσης, εφαρμόζεται ένας εκθετικός κινητός μέσος όρος (**Exponential Moving Average** - EMA), με σκοπό το φιλτράρισμα της εξόδου του νευρωνικού δικτύου. Η έξοδος από το νευρωνικό δίκτυο όπως αναλύθηκε στο Κεφ.2 αποτελείται από τέσσερις πραγματικούς αριθμούς, οι οποίοι αντιστοιχούν στις συντεταγμένες $\mathbf{p}_1 =$

(x_1, y_1) και $\mathbf{p}_2 = (x_2, y_2)$. Οπότε, για κάθε συντεταγμένη σε pixels (x_1, x_2, y_1, y_2), εφαρμόζεται το φίλτρο, το οποίο είναι της μορφής:

$$x_t^{filtered} = \alpha x_t + (1 - \alpha) x_{t-1}^{filtered} \tag{4.1}$$

και αντίστοιχα για τις y συντεταγμένες:

$$y_t^{filtered} = \alpha y_t + (1 - \alpha) y_{t-1}^{filtered} \tag{4.2}$$

όπου x_t, y_t είναι οι τρέχουσες τιμές εξόδου του νευρωνικού δικτύου, είτε για τις συντεταγμένες του $\mathbf{p}_1$, είτε του $\mathbf{p}_2$ και $x_{t-1}^{filtered}, y_{t-1}^{filtered}$ είναι οι προηγούμενες φιλτραρισμένες τιμές. Ο συντελεστής $\alpha \in (0, 1)$ καθορίζει τον βαθμό εξομάλυνσης. Στην συγκεκριμένη περίπτωση, το α ορίστηκε ίσο με 0.99, με σκοπό να δίνεται πολύ μικρό βάρος στις προηγούμενες εξόδους και να μετράει περισσότερο η νέα πρόβλεψη. Με αυτόν τον τρόπο, αφαιρούνται οι θόρυβοι σε real-time περιβάλλοντα και όσο το δυνατόν εξαλείφεται το ”τρέμουλο” και οι μικροδιακυμάνσεις (jitter), λόγω απότομων μεταβολών.

Υπολογισμός του μέτρου απόστασης παραμόρφωσης: Η εκτίμηση του μέτρου της παραμόρφωσης βασίζεται στην ευκλείδεια απόσταση μεταξύ των φιλτραρισμένων σημείων, αφαιρώντας την αρχική (μη παραμορφωμένη) απόσταση. Ορίζεται ως:

$$\delta = \sqrt{[(x_2 - x_1) - d_{0x}]^2 + [(y_2 - y_1) - d_{0y}]^2} \tag{4.3}$$

όπου x_1, x_2, y_1, y_2 είναι οι ήδη φιλτραρισμένες συντεταγμένες και $d_0 = [d_{0x} \quad d_{0y}]^T$ είναι η αρχική απόσταση, που δεν υπάρχει κάποια παραμόρφωση στον μαλακό ιστό και χρησιμοποιείται ως μία απόσταση αναφοράς.

Εφαρμογή κατωφλίου στην εκτίμηση της παραμόρφωσης: Σε πραγματικά συστήματα, η έξοδος του νευρωνικού δικτύου μπορεί να επηρεάζεται από μικροθορύβους, από τις διάφορες μεταβολές του φωτισμού ή αστάθειες στο μοντέλο. Με σκοπό τον περιορισμό ψευδών ανιχνεύσεων παραμορφώσεων, εφαρμόζεται ένα κατώφλι ενεργοποίησης στην τιμή της εκτιμώμενης παραμόρφωσης. Οπότε, αν η τιμή του μέτρου παραμόρφωσης δ είναι μικρότερη από ένα κατώφλι d_{min} η παραμόρφωση θεωρείται αμελητέα και μηδενίζεται:

$$\text{αν } \delta < d_{\min} \quad \Rightarrow \quad \mathbf{d}_{\text{thres}} = \mathbf{0} \tag{4.4}$$

Στην παρούσα υλοποίηση, επιλέγεται $d_{min} = 5$ pixels. Αντίθετα, όταν $\delta \geq d_{\min}$, τότε υπολογίζεται η κανονικοποιημένη παραμόρφωση, αφαιρώντας το πρώτο κατώφλι και διατηρώντας μόνο το ”καθαρό” μέρος της απόκλισης. Ο υπολογισμός γίνεται ως εξής:

$$\mathbf{d}_{\text{thres}} = d_{vec} \cdot \left(1 - \frac{d\min}{\delta}\right) \tag{4.5}$$

όπου $d_{vec} = [x_2 - x_1, y_2 - y_1]$ είναι το φιλτραρισμένο διάνυσμα παραμόρφωσης.

Το τελικό διάνυσμα d_{thres} αποτελεί την τελική εκτίμηση της παραμόρφωσης του μαλακού ιστού στον εικονοχώρο (pixel space).

4.3 Υπολογισμός εικονικής δύναμης από DCNN

Το βασικό ζητούμενο είναι να εφαρμοστεί μία εικονική δύναμη στο ρομπότ του χειρουργού (leader), η οποία θα δημιουργεί μια αίσθηση σαν “αντίσταση” ή “σπρώξιμο”, αποτρέποντας τον χειρουργό να ασκήσει περισσότερη πίεση στον ιστό και να τον τραυματίσει. Έτσι, λειτουργεί σαν μία καθοδήγηση του χειρουργού να μετακινήσει και να ευθυγραμμίσει το εργαλείο πίσω προς το κέντρο της τομής.

Αυτή η δύναμη μεταφέρεται απτικά στον χειρουργό (μέσω του leader ρομπότ), ώστε να αισθάνεται απτική ανάδραση ανάλογη με την εκτιμώμενη παραμόρφωση του εργαλείου στο σημείο τομής. Το $\mathbf{d}_{thres}$, όπως αναφέρθηκε είναι το διάνυσμα εκτίμησης της παραμόρφωσης και ισούται με $p_2 - p_1$ (πριν την εφαρμογή κατωφλίου). Το p_1 είναι το σημείο που θα έπρεπε να βρίσκεται ο ιστός και p_2 είναι το σημείο, που βρίσκεται στην πραγματικότητα ο ιστός, λόγω κάποιας παραμόρφωσης, που μπορεί να υπέστηκε. Οπότε, το διάνυσμα $p_2 - p_1$, θα μπορούσε να θεωρηθεί σαν ένα διάνυσμα σφάλματος θέσης και θέλουμε να το εξαλείψουμε, μέσω μίας δύναμης. Ισχύει, ότι αν ο ιστός δεν είχε παραμορφωθεί καθόλου, τότε $p_2 = p_1$. Επιπλέον, αν το σφάλμα είναι μικρό, τότε χρειάζεται μικρή εικονική δύναμη, ενώ αν το σφάλμα είναι μεγάλο, τότε χρειάζεται μεγάλη εικονική δύναμη, και να υπάρχει η αίσθηση ότι ο ιστός σπρώχνει πίσω. Οπότε, ο ιστός θα θέλαμε να λειτουργεί σαν ένα ελατήριο και να υπάρχει αυτή η αίσθηση για τον χειρουργό. Άρα, η εικονική δύναμη από το DCNN στο πλαίσιο της κάμερας $\{C\}$ είναι:

$$^{c}\mathbf{f}_d = -\begin{bmatrix} p_2 - p_1 \\ 0 \end{bmatrix} \in \mathbb{R}^3 \tag{4.6}$$

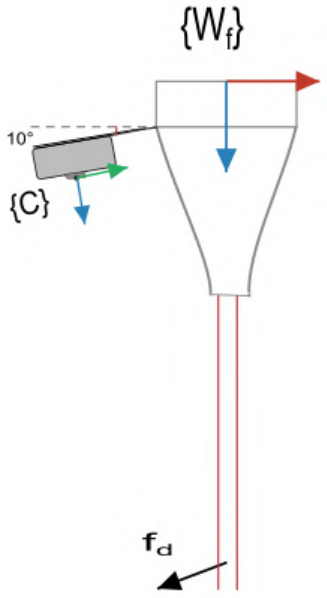
Στην εξίσωση 4.6 ο z άξονας είναι 0, γιατί η κάμερα δεν εκτιμά το βάθος (2D εικόνα). Επίσης, το αρνητικό πρόσημο υπάρχει, γιατί όταν ασκείται μία δύναμη προς μία κατεύθυνση, η οποία προκαλεί την παραμόρφωση, το σύστημα θα πρέπει να αντιδράσει και να σπρώξει προς την αντίθετη κατεύθυνση, δηλαδή με αρνητική δύναμη. Αν για παράδειγμα, το $d_{thres} = [10, -3]$, δηλαδή η τομή έχει μετατοπιστεί κατά 10 pixels δεξιά και 3 pixels κάτω, τότε η εικονική δύναμη θα πρέπει να σπρώξει κατά 10 pixels αριστερά και 3 pixels πάνω, δηλαδή $f_d = [-10, +3, 0]$.

Η εξίσωση 4.6 είναι εκφρασμένη ως προς το πλαίσιο της κάμερας $\{C\}$, οπότε θα πρέπει να μεταφερθεί στο πλαίσιο του καρπού του follower ρομπότ $\{W_f\}$. Άρα, έχουμε:

$$^{w}\mathbf{f}_d = \mathbf{R}_{wc} \cdot {}^{c}\mathbf{f}_d \in \mathbb{R}^3 \tag{4.7}$$

όπου $\mathbf{R}_{wc} \in SO(3)$ είναι ο πίνακας στροφής της κάμερας ως προς τον καρπό. Η τοποθέτηση της κάμερας μετρήθηκε ότι είναι σε μία κλίση 10° (βλ. Σχήμα 4.1) από τον καρπό του follower, οπότε ο πίνακας στροφής θα είναι:

$$\mathbf{R}_{wc} = \begin{bmatrix} 0 & -\cos 10^\circ & -\sin 10^\circ \\ 1 & 0 & 0 \\ 0 & -\sin 10^\circ & \cos 10^\circ \end{bmatrix}$$



Σχήμα 4.1: Πίνακας στροφής $\mathbf{R}_{wc}$ και σχήμα διάταξης εργαλείου/κάμερας.

Ωστόσο, ο στόχος είναι να δωθεί η αίσθηση ότι αυτή η δύναμη, εφαρμόζεται στο άκρο του εργαλείου, ενώ εμείς την στέλνουμε στον καρπό. Επιπλέον, θέλουμε όταν ο χειρουργός μετακινεί το άκρο

της λαβής του leader ρομπότ, να είναι σαν να μετακινεί το άκρο του εργαλείου του follower ρομπότ. Έτσι, κατασκευάζεται το γενικευμένο διάνυσμα των δυνάμεων $\mathbf{F}_{ext} \in \mathbb{R}^6$, το οποίο δρα στο άκρο (end-effector) του ρομπότ.

$$\mathbf{F}_{ext} \triangleq kg \begin{bmatrix} {}^{w}\mathbf{f}_d \\ \mathbf{S}((d_s - d_{tool} - d_h) \cdot \mathbf{z}_w){}^{w}\mathbf{f}_d \end{bmatrix} \tag{4.8}$$

και με αντικατάσταση της ${}^{w}\mathbf{f}_d$, η Σχέση 4.8, γίνεται:

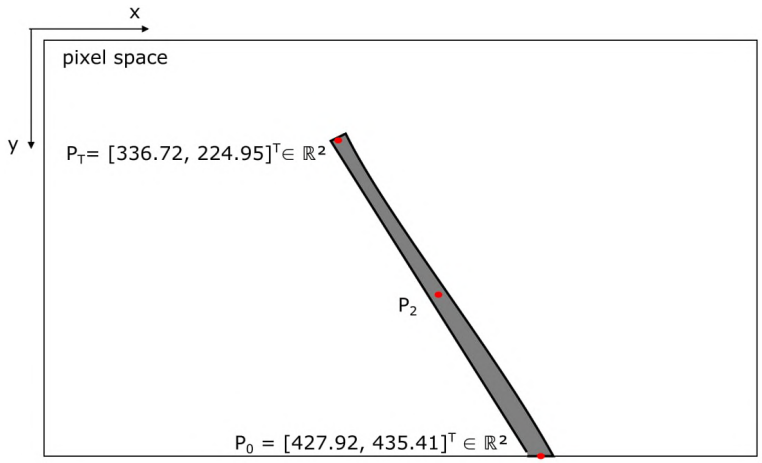
$$\mathbf{F}_{ext} \triangleq k_g \begin{bmatrix} \mathbf{I}_3 \\ -\mathbf{S}((d_s - d_{tool} - d_h)\mathbf{z}_w) \end{bmatrix} \mathbf{R}_{wc} \begin{bmatrix} \mathbf{p}_2 - \mathbf{p}_1 \\ 0 \end{bmatrix} \in \mathbb{R}^6, \tag{4.9}$$

όπου $\mathbf{z} \triangleq [0\ 0\ 1]^\intercal$ και d_{tool} είναι η εκτιμώμενη απόσταση του εργαλείου από τον καρπό εώς το σημείο επαφής του εργαλείου με τον ιστό και ο υπολογισμός της φαίνεται αναλυτικά στο Υποκεφάλαιο 4.3.1. Ο πολλαπλασιαστικός παράγοντας $k_g \in \mathbb{R}^+$ είναι ένα θετικά ορισμένο κέδρος (gain), ο οποίος καθορίζει πόσο έντονη είναι η δύναμη που αισθάνεται ο χειρουργός στην πλευρά του leader ρομπότ, μέσω της ανάδρασης και δημιουργεί την ψευδαίσθηση ότι το εργαλείο αγγίζει κάτι με μία συγκεκριμένη ακαμψία.

4.3.1 Υπολογισμός εκτιμώμενης απόστασης επαφής του εργαλείου

Το σημείο $p_2(x_2, y_2)$, όπως έχει ήδη εξηγηθεί εκτιμάται από το DCNN και είναι η τρέχουσα παραμορφωμένη θέση του ιστού από το χειρουργικό εργαλείο. Οπότε, αποτελεί και την εκτίμηση του σημείου επαφής του εργαλείου με τον μαλακό ιστό. Όμως, αυτό το σημείο βρίσκεται στον χώρο των εικονοστοιχείων (pixel space) και αυτή η θέση είναι εκφρασμένη στο επίπεδο της εικόνας. Ωστόσο, για τον υπολογισμό της απόστασης πάνω στο εργαλείου, από τον καρπό του follower ρομπότ έως το σημείο επαφής του με τον ιστό, απαιτείται η αντιστοίχηση των pixels σε μέτρα (από pixel space στον φυσικό χώρο). Έτσι, ορίζονται δύο σημεία αναφοράς στο επίπεδο της εικόνας:

- Το $\mathbf{p}_0 \in \mathbb{R}^2$, το οποίο είναι το σημείο που η κάμερα αρχίζει να "βλέπει" το εργαλείο. Πρόκειται για ένα σημείο κοντά στον καρπό του follower ρομπότ.
- Το $\mathbf{p}_T \in \mathbb{R}^2$, το οποίο είναι το σημείο της άκρης του εργαλείου, όπως εμφανίζεται στην εικόνα 4.2.



Σχήμα 4.2: Η εικόνα της κάμερας στο χώρο των εικονοστοιχείων

Η σχετική κανονικοποιημένη απόσταση του σημείου επαφής $\mathbf{p}_2$ από το σημείο αναφοράς $\mathbf{p}_0$, ως προς την πλήρη ορατή έκταση του εργαλείου, δίνεται από το μέγεθος:

$$\sigma = \frac{\|\mathbf{p}_2 - \mathbf{p}_0\|_2}{\|\mathbf{p}_T - \mathbf{p}_0\|_2} = \frac{\sqrt{(x_2 - x_0)^2 + (y_2 - y_0)^2}}{\sqrt{(x_T - x_0)^2 + (y_T - y_0)^2}} \tag{4.10}$$

όπου $\|\cdot\|_2$ είναι η ευκλείδια νόρμα. Ουσιαστικά, η παράμετρος $\sigma \in [0, 1]$ μετράει σε ποιο ποσοστό της συνολικής προβολής του εργαλείου, βρίσκεται το σημείο επαφής με τον ιστό. Ο στόχος είναι η εκτίμηση της πραγματικής απόστασης του εργαλείου, από τον καρπό έως το σημείο επαφής με τον ιστό, δηλαδή το μήκος $d_{tool}(\sigma) \in \mathbb{R}^+$, το οποίο εξαρτάται από την παράμετρο σ. Για να επιτευχθεί αυτό, ακολουθήθηκαν κάποια βήματα και γίναν κάποιοι υπολογισμοί. Αρχικά, πάρθηκαν οι μετρήσεις του $\mathbf{p}_0, \mathbf{p}_T$, στο pixel space, οι οποίες είναι:

$$\mathbf{p}_0 = \begin{bmatrix} 427.92 \\ 435.41 \end{bmatrix}, \quad \mathbf{p}_T = \begin{bmatrix} 336.72 \\ 224.95 \end{bmatrix}$$

Στη συνέχεια, για κάθε εκατοστό του εργαλείου, βρέθηκαν τα pixels που ανήκουν σε αυτές τις τιμές. Συγκεκριμένα, πάρθηκαν από τα 0.06 έως τα 0.18 μέτρα (m) πάνω στο εργαλείο με βήμα 0.01, όπου στα $0.06m$ είναι το $\mathbf{p}_0$ και στα $0.18m$ είναι το $\mathbf{p}_T$. Οι μετρήσεις αυτές παρουσιάζονται στον παρακάτω πίνακα 4.1:

Απόσταση επαφής (m)	**Pixel Space p_2^x**	**Pixel Space p_2^y**	$\boldsymbol{\sigma}$
0.06	427.92	435.41	0
0.07	416.90	407.35	0.13143089
0.08	403.87	377.28	0.2742665
0.09	393.85	354.23	0.38383096
0.10	384.83	333.19	0.48363206
0.11	377.82	316.15	0.5639605
0.12	369.80	297.11	0.65403373
0.13	363.78	280.07	0.73270463
0.14	358.77	268.05	0.78947844
0.15	351.76	254.01	0.85773512
0.16	346.75	242.99	0.9104905
0.17	342.74	231.97	0.96155602
0.18	336.72	224.95	1

Πίνακας 4.1: Υπολογισμός της παραμέτρου σ βάσει της θέσης του εργαλείου στην εικόνα

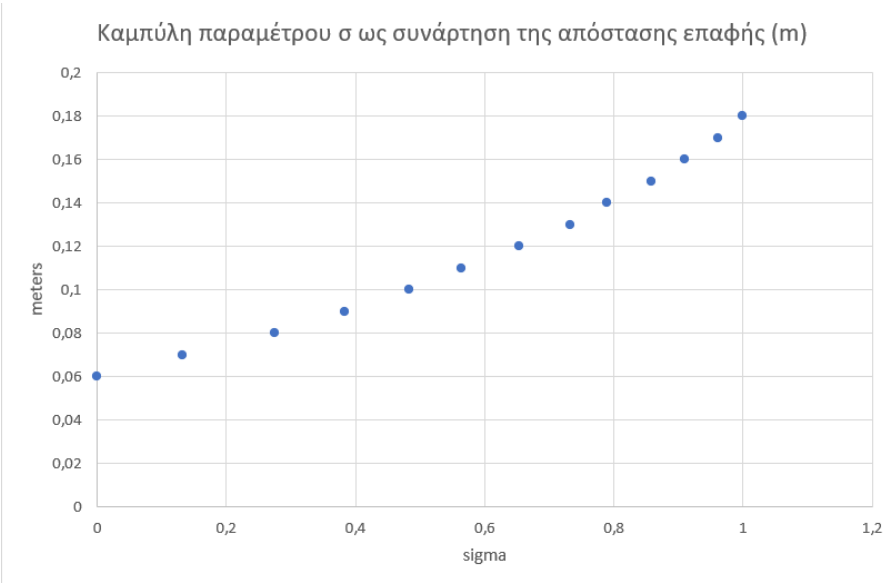
Η γραφική παράσταση της παραμέτρου σ ως προς τη μετρούμενη απόσταση επαφής επί του εργαλείου παρουσιάζεται στην Εικόνα 4.3.

Από την παρατήρηση της καμπύλης, διαπιστώνεται ότι τα σημεία ακολουθούν προσεγγιστικά την γραφική παράσταση μίας παραβολής, η οποία είναι της μορφής:

$$y = \alpha(x + \beta)^2 + \gamma$$

όπου y είναι η απόσταση d_{tool} και x είναι το σ. Τώρα το ζητούμενο είναι η εύρεση των παραμέτρων α, β, γ, που προσαρμόζουν τη θεωρητική παραβολή στα πραγματικά δεδομένα. Η προσέγγιση εκτίμησης αυτών των παραμέτρων πραγματοποιήθηκε με δύο μεθόδους:

1. Βελτιστοποίηση (optimization) καμπύλης, μέσω του λογισμικού Desmos.
2. Επίλυση του γραμμικού συστήματος εξισώσεων, με βάση τα γνωστά ζεύγη τιμών (σ_i, d_i), όπου d_i είναι οι μετρημένες αποστάσεις στο εργαλείο.



Σχήμα 4.3: Γραφική παράσταση της παραμέτρου σ ως προς την απόσταση επαφής επί του εργαλείου

Με βάση τις δύο παραπάνω μεθόδους, βρέθηκαν προσεγγιστικά οι εξής τιμές:

$$\alpha \approx 0.083, \quad \beta \approx 0.2, \quad \gamma \approx 0.06$$

Με την αντικατάσταση των τιμών αυτών στην εξίσωση της παραβολής φαίνονται στον παρακάτω πίνακα 4.2 οι προσεγγίσεις της απόστασης επαφής (m):

Προσέγγιση 1	**Προσέγγιση 2**
0.06332	0.06000
0.06911725	0.06762398
0.07866908	0.07870556
0.08829126	0.08917963
0.09879028	0.10021169
0.10844176	0.11012396
0.12053801	0.12233419
0.13220485	0.13394623
0.14126261	0.14287504
0.1528607	0.15421887
0.1623547	0.16344213
0.17198463	0.17274834
0.17952	0.18000

Πίνακας 4.2: Σύγκριση τιμών μεταξύ δύο προσεγγίσεων απόστασης επαφής (σε μέτρα)

Παρατηρείται ότι και οι δύο προσεγγίσεις είναι πολύ κοντά στις αρχικές τιμές των αποστάσεων επαφής, επιβεβαιώνοντας την καταλληλότητα της εξίσωσης παραβολής για την εκτίμηση της απόστασης επαφής στο εργαλείο. Επίσης, πρέπει να σημειωθεί ότι η παραβολή μοντελοποιεί μόνο το τμήμα του εργαλείου που εκτείνεται πέρα από το ορατό αρχικό σημείο $\mathbf{p}_0$. Γι' αυτό το λόγο, στο τελικό μήκος d_{tool}, προστίθεται η σταθερή απόσταση, έστω d_{base} από τον καρπό μέχρι το σημείο $\mathbf{p}_0$, η οποία μετρήθηκε $0.13m$.

Συνεπώς, η συνολική εκτίμηση της απόστασης του σημείου επαφής από τον καρπό δίνεται από την σχέση:

$$d_{tool} = d_{base} + \alpha(\sigma + \beta)^2 + \gamma \approx 0.13 + 0.083(\sigma + 0.2)^2 + 0.06 \tag{4.11}$$

4.4 Μηχανισμός Διασφάλισης Παθητικότητας μέσω Δεξαμενής Ενέργειας

Κατά την εφαρμογή της εικονικής δύναμης F_{ext}, είναι απαραίτητο να διασφαλιστεί ότι το συνολικό σύστημα θα παραμείνει παθητικό, δηλαδή δεν θα παράγει αυθαίρετα ενέργεια, κάτι που θα μπορούσε να οδηγήσει σε μη ασφαλή και ασταθή συμπεριφορά του συστήματος. Γι' αυτό τον λόγο, επιλέχθηκε να χρησιμοποιηθεί ένας **Παρατηρητής Παθητικότητας** (*Passivity Observer - PO*). Ο μηχανισμός αυτός περιλαμβάνει μια εικονική **δεξαμενή ενέργειας** (*energy tank*), η οποία αποθηκεύει μέρος της ενέργειας που αποσβένεται κατά την κίνηση του ρομπότ και παρέχει την απαιτούμενη ενέργεια για την ενεργοποίηση της εικονικής δύναμης. Εάν η διαθέσιμη ενέργεια στη δεξαμενή δεν επαρκεί, η εφαρμογή της δύναμης απενεργοποιείται αυτόματα, ώστε να διατηρηθεί η παθητικότητα του συνολικού συστήματος. Η στάθμη της δεξαμενής συμβολίζεται με $L \in \mathbb{R}^+$ και μεταβάλλεται δυναμικά σύμφωνα με την εξίσωση:

$$\dot{L} \triangleq \alpha \underbrace{\dot{\mathbf{q}}_l^\intercal \mathbf{D}_d \dot{\mathbf{q}}_l}_{\text{ενέργεια που αποσβένεται}} - \underbrace{s(L)\, \mathbf{F}_{ext}^\intercal \mathbf{J}_{e,l}(\mathbf{q}_l)\, \dot{\mathbf{q}}_l}_{\text{ενέργεια που καταναλώνει η εικονική δύναμη}} \tag{4.12}$$

Ουσιαστικά, το $\dot{L}$ αναπαριστά τον ρυθμός μεταβολής της αποθηκευμένης ενέργειας στη δεξαμενή και αποτελείται από δύο όρους:

1. **Θετικός όρος (αποθηκευμένη ενέργεια):** Αποθηκεύει την ενέργεια που παράγεται μέσω απόσβεσης κατά την κίνηση, όπου:
   - $\dot{\mathbf{q}}_l \in \mathbb{R}^{n_l}$ είναι το διανύσμα ταχυτήτων των αρθρώσεων του leader ρομπότ,
   - $\mathbf{D}_d \in \mathbb{R}^{n \times n}$ είναι η θετικά ορισμένη *μήτρα απόσβεσης* (damping matrix),
   - $\alpha \in (0, 1)$ είναι το ποσοστό της αποσβούμενης ενέργειας, που *αποθηκεύεται* στο "ρεζερβουάρ" L.
2. **Αρνητικός όρος (ενέργεια που καταναλώνει το DCNN):**
   - $\mathfrak{s}(L) \in [0, 1]$ είναι η σιγμοειδής συνάρτηση ενεργοποίησης, η οποία ρυθμίζει τη συμβολή της εικονικής δύναμης στο σύστημα, ανάλογα με το διαθέσιμο ενεργειακό απόθεμα.

Οπότε, αν υπάρχει αρκετή ενέργεια στο σύστημα (αρκετή απόσβεση, δηλαδή κίνηση), η δεξαμενή γεμίζει, ενώ αν η δεξαμενή είναι άδεια, το σύστημα δεν επιτρέπει περαιτέρω εφαρμογή εικονικών δυνάμεων.

Η συνάρτηση $\mathfrak{s}(L)$ χρησιμοποιείται για να εξασφαλίσει μια ομαλή μετάβαση, ανάμεσα στην ενεργοποίηση και την απενεργοποίηση της εικονικής δύναμης, ανάλογα με το διαθέσιμο ενεργειακό απόθεμα. Είναι μια συνεχής σιγμοειδής συνάρτηση και ορίζεται ως:

$$\mathfrak{s}(y) \triangleq \begin{cases} 0, & \text{if } y < 0 \\ 10\left(\frac{y}{\delta}\right)^3 - 15\left(\frac{y}{\delta}\right)^4 + 6\left(\frac{y}{\delta}\right)^5, & \text{if } 0 \leq y \leq \delta \\ 1, & \text{if } y > \delta \end{cases}$$

όπου $\delta \in \mathbb{R}^+$ είναι μια μικρή θετική σταθερά που καθορίζει το εύρος της περιοχής μετάβασης.

- Για $L < 0$: η συνάρτηση είναι μηδενική ($\mathfrak{s}(L) = 0$), και άρα **η εφαρμογή της εικονικής δύναμης απενεργοποιείται πλήρως**.
- Για $L > \delta$: η συνάρτηση ισούται με τη μονάδα, δηλαδή ($\mathfrak{s}(L) = 1$), και επομένως **η δύναμη εφαρμόζεται πλήρως στο σύστημα**.

- Για $L \in [0, \delta]$: η συνάρτηση μεταβαίνει ομαλά από το 0 σε 1 μέσω ενός **πολυωνύμου πέμπτου βαθμού τύπου**, εξασφαλίζοντας *συνεχή πρώτη και δεύτερη παράγωγο* στο σημείο μετάβασης.

Συνολικά, Η εικονική δύναμη καθοδήγησης $\mathbf{F}_{ext}$ που προκύπτει από την εκτίμηση παραμόρφωσης μέσω DCNN εφαρμόζεται στο ρομπότ leader υπό τον έλεγχο της δεξαμενής L, η οποία δρα ως ενεργειακός ρυθμιστής για την εγγύηση παθητικής συμπεριφοράς. Ο παραπάνω μηχανισμός επιτρέπει τον έλεγχο της παθητικής συμπεριφοράς του συστήματος με ομαλό και ασφαλή τρόπο, εξαλείφοντας απότομες μεταβάσεις που θα μπορούσαν να οδηγήσουν σε αστάθεια ή ανεπιθύμητες κινήσεις.

Εφαρμογή της εικονικής δύναμης: Η εικονική δύναμη F_{ext}, πρέπει να μετατραπεί σε ροπές στις αρθρώσεις, ώστε να εφαρμοστεί στο ρομπότ. Αυτό επιτυγχάνεται μέσω της Ιακωβιανής $\mathbf{J}_{e,l}(\mathbf{q}_l)$:

$$\mathbf{u}f = \mathfrak{s}(L)\mathbf{J}e, l^{\intercal}(\mathbf{q}_l)\mathbf{F}_{ext}. \tag{4.13}$$

όπου $\mathbf{u}_f$ είναι το πρόσθετο σήμα ροπής για την παροχή απτικής ανάδρασης στον χρήστη. Αυτή προστίθεται στις υπόλοιπες εισόδους του συστήματος και πλέον, η τροχιά αναφοράς του leader ρομπότ, θα παράγεται με τη λύση του διαφορικού συσήματος:

$$\mathbf{M}_d\ddot{\mathbf{q}}_l + \mathbf{D}_d\dot{\mathbf{q}}_l = \mathbf{u}_h + \mathbf{u}_f, \tag{4.14}$$

Ορίζουμε τις καταστάσεις του συστήματος ως:

$$\mathbf{x}_1 \triangleq \dot{\mathbf{q}}_l, \quad x_2 \triangleq L$$

Παραγωγίζοντας αυτές τις σχέσεις, προκύπτει:

$$\dot{\mathbf{x}}_\mathbf{1} \triangleq \ddot{\mathbf{q}}_l, \quad \dot{x}_2 \triangleq \dot{L}$$

Άρα, λύνοντας την Εξίσωση 4.14 ως προς $\dot{\mathbf{x}}_\mathbf{1} \triangleq \ddot{\mathbf{q}}_l$ και αντικαθιστώντας το $\mathbf{u}_f$, σύμφωνα με την εξίσωση 4.13, έχουμε:

$$\dot{\mathbf{x}}_1 = \mathbf{M}_d^{-1}\left(-\mathbf{D}_d\mathbf{x}_1 + \mathfrak{s}(\mathbf{x}_2)\mathbf{J}_{e,l}^{\intercal}\mathbf{F}_{ext} + \mathbf{u_h}\right) \tag{4.15}$$

Επίσης, αντικαθιστώντας τα x_1, x_2 στην Εξίσωση 4.12, έχουμε:

$$\dot{x}_2 = \alpha\mathbf{x}_1^{\intercal}\mathbf{D}_d\mathbf{x}_1 - \mathfrak{s}(x_2)\mathbf{F}_{ext}^{\intercal}\mathbf{J}_{e,l}\mathbf{x}_1 \tag{4.16}$$

Απόδειξη παθητικότητας του συστήματος:

Θεώρημα 1. *Το δυναμικό σύστημα του leader ρομπότ, που περιγράφεται από τις δυναμικές εξισώσεις είναι αυστηρά παθητικό ως προς το ζεύγος* $(\mathbf{x}_1, \mathbf{u_h})$*, για κάθε φραγμένη* $\mathbf{F}_{ext}$ *όπως αυτή παρέχεται από το DCNN.*

Απόδειξη. Έστω η θετικά ορισμένη συνάρτηση αποθήκευσης (storage function):

$$V(\mathbf{x}_1, x_2) = \frac{1}{2}\mathbf{x}_1^{\intercal}\mathbf{M}_d\mathbf{x}_1 + x_2, \tag{4.17}$$

η οποία εκφράζει το συνολικό ενεργειακό περιεχόμενο του συστήματος, αποτελούμενο από κινητική ενέργεια και την αποθηκευμένη ενέργεια στη δεξαμενή. Η χρονική παράγωγος της V είναι:

$$\dot{V} = \mathbf{x}_1^{\intercal}\mathbf{M}_d\dot{\mathbf{x}}_1 + \dot{x}2. \tag{4.18}$$

Αρκεί να αποδειχθεί ότι $\dot{V} \leq \mathbf{x}_1^{\intercal}\mathbf{u}_h$, ώστε το σύστημα να είναι παθητικό. Αντικαθιστώντας από τις δυναμικές εξισώσεις του συστήματος, προκύπτει:

$$\dot{V} = \mathbf{x}_1^{\intercal}\mathbf{u}_h - \underbrace{(1-\alpha)}_{>0}\mathbf{x}_1^{\intercal}\mathbf{D}_d\mathbf{x}_1. \tag{4.19}$$

Το $(1-\alpha) > 0$, αφού $\alpha \in (0,1)$, ενώ $\mathbf{D}_d \succ 0$ και $\mathbf{x}_1 \neq \mathbf{0}$. Η παραπάνω έκφραση αποδεικνύει ότι το σύστημα είναι *αυστηρά παθητικό*, καθώς η μεταβολή της αποθηκευμένης ενέργειας είναι πάντα μικρότερη ή ίση από την ισχύ που εισάγει ο χρήστης μέσω του όρου $\mathbf{x}_1^\intercal \mathbf{u}_h$, με *ρήτρα απόσβεσης ενέργειας* ίση με $(1-\alpha)\mathbf{x}_1^\intercal \mathbf{D}_d \mathbf{x}_1 > 0$. ■

Η τεκμηρίωση παθητικότητας του παραπάνω ελεγκτή είναι κρίσιμη, καθώς επιτρέπει την ασφαλή ενσωμάτωσή του σε αλληλεπιδραστικά ρομποτικά συστήματα (π.χ. συνεργατικά χειρουργικά ρομπότ), εξασφαλίζοντας ότι καμία πηγή ενέργειας, όπως η έξοδος του DCNN, δεν οδηγεί σε μη φυσιολογική ή ασταθή συμπεριφορά του συστήματος.

4.5 Περιγραφή του ολοκληρωμένου Συστήματος Ελέγχου

Το σύστημα αποτελείται από ένα ολοκληρωμένο ρομποτικό σύστημα τύπου leader-follower, σχεδιασμένο για εφαρμογές ελάχιστης υποβοηθούμενης χειρουργικής, όπου στόχος είναι η ασφαλής και αποτελεσματική καθοδήγηση του χειρουργού, με σκοπό της αποφυγής του τραυματισμού του μαλακού ιστού γύρω από την χειρουργική τομή. Το σύστημα συνδυάζει σε πραγματικό χρόνο, έλεγχο ενδοτικότητας, κινηματικό συγχρονισμό δύο ρομποτικών βραχιόνων, βαθύ συνελικτικό δίκτυο και παρακολούθηση της παθητικότητας του συστήματος.

Στο επίκεντρο βρίσκεται μια RGB κάμερα, η οποία είναι τοποθετημένη έτσι ώστε να καταγράφει σε πραγματικό χρόνο τη χειρουργική τομή. Η εικόνα που λαμβάνεται από την κάμερα περνά σε ένα DCNN, το οποίο έχει εκπαιδευτεί να αναγνωρίζει το ποσό της παραμόρφωσης του ιστού. Αυτή η πληροφορία, δηλαδή τα σημεία $\mathbf{p}_1, \mathbf{p}_2 \in \mathbb{R}^2$, αποτελούν την βασική ένδειξη για το αν υπάρχει παραμόρφωση και κατά πόσο έχει παραμορφωθεί ο ιστός. Έπειτα, με βάση τις εκτιμήσεις του DCNN, υπολογίζεται η εικονική δύναμη $\mathbf{F}_{ext} \in \mathbb{R}^6$ και μέσω αυτής και της αποθηκευμένης ενέργειας από τον παρατηρητή παθητικότητας, υπολογίζεται η ροπή ανάδραση $\mathbf{u}_f$. Ο παρατηρητής παθητικότητας, ενεργοποιεί απενεργοποιεί δυναμικά την επίδραση του $\mathbf{u}_f$, , ώστε να εξασφαλίζεται ότι το σύστημα παραμένει παθητικό και άρα ασφαλές.

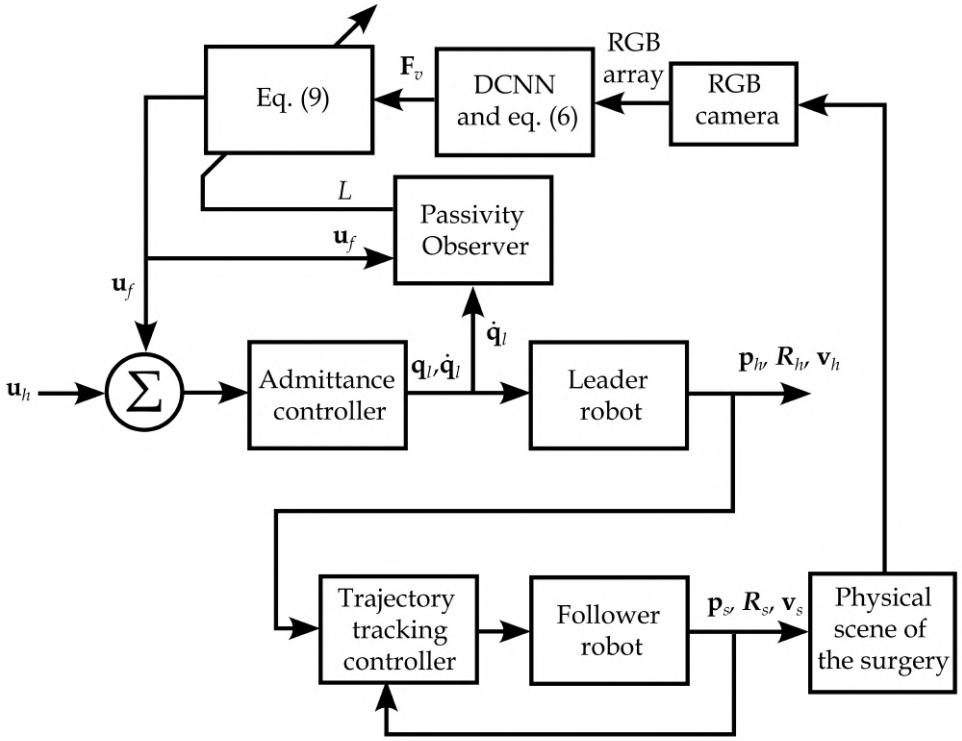
Στον ρομποτικό βραχίονα τύπου leader εφαρμόζεται έλεγχος ενδοτικότητας, ο οποίος επιτρέπει μία φυσική αλληλεπίδραση του χειρουργού με το ρομπότ. Ως είσοδος στον έλεγχο ενδοτικότητας είναι το άθροισμα των ροπών $\mathbf{u}_h$, τις οποίες ασκεί ο χειρουργός στο leader ρομπότ και του επιπλέον σήματος ροπής από το DCNN, $\mathbf{u}_f$ και ως έξοδος είναι η θέση $\mathbf{q}_l$ και ταχύτητα $\dot{\mathbf{q}}_l$ των αρθρώσεων του leader ρομποτικού βραχίονα.

Η θέση και ο προσανατολισμός του εργαλείου του leader, δηλαδή τα $\mathbf{p}_l, \mathbf{R}_l$, καθώς και η ταχύτητα $\mathbf{v}_h$, αποτελούν την πληροφορία, που πρέπει να ακολουθήσει ο δεύτερος ρομποτικός βραχίονας, δηλαδή το follower ρομπότ. Για να επιτευχθεί αυτός ο συγχρονισμός και η ακριβής ακολούθηση της τροχιάς, τα παραπάνω δεδομένα εισάγονται σε έναν ελεγκτή παρακολούθησης τροχιάς, ο οποίος υπολογίζει τις εντολές ταχυτήτων στις αρθρώσεις $\dot{\mathbf{q}}_f$ για τον follower.

Το σύστημα είναι πλήρως συνδεδεμένο και δυναμικά διασυνδεδεμένο: η εικόνα από την κάμερα επηρεάζει το νευρωνικό δίκτυο, το οποίο παρέχει πληροφόρηση για την παραμόρφωση· η πληροφορία αυτή μετατρέπεται σε εικονική δύναμη που επενεργεί στον leader· η κίνηση του leader συγχρονίζεται με τον follower· και όλα μαζί μεταβάλλουν τη φυσική σκηνή του χειρουργείου, κλείνοντας τον βρόχο ανάδρασης. Μέσα σε όλη αυτή τη διαδικασία, ο μηχανισμός παθητικότητας εξασφαλίζει ότι η συνολική δυναμική του συστήματος παραμένει σταθερή, ακόμα και υπό την παρουσία αβέβαιων ή μη φυσικών δυνάμεων που προκύπτουν από οπτικά δεδομένα.

Συνολικά, το σύστημα αποτελεί ένα προηγμένο παράδειγμα συνεργατικής ρομποτικής με ενσωματωμένη ευφυΐα, ικανό να διαχειριστεί σύνθετες αλληλεπιδράσεις με το περιβάλλον, να αξιοποιήσει δεδομένα αισθητήρων και να διασφαλίσει ασφαλή και φυσική λειτουργία ακόμη και σε χειρουργικά σενάρια υψηλού ρίσκου.

Η συνολική αρχιτεκτονική του συστήματος, με την ενσωμάτωση του μηχανισμού παθητικότητας μέσω της δεξαμενής ενέργειας, παρουσιάζεται γραφικά στο διάγραμμα της Εικόνας 4.4.



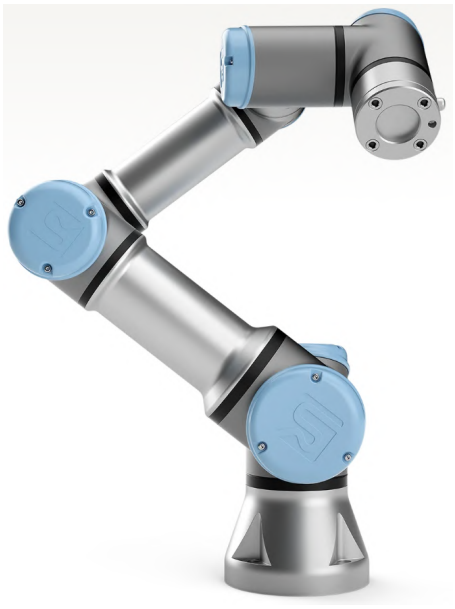
Σχήμα 4.4: Μπλοκ διάγραμμα του συνολικού συστήματος.

Κεφάλαιο 5

Πειραματική Αξιολόγηση

5.1 Υλοποίηση του συστήματος leader-follower με ρομποτικούς βραχίονες UR3/UR3e

Οι UR3/UR3e είναι συνεργατικοί ρομποτικοί βραχίονες 6 βαθμών ελευθερίας (DoF - Degrees of Freedom), σχεδιασμένοι για ακρίβεια, ευελιξία και συνεργασία με τον άνθρωπο. Οι βαθμοί ελευθερίας περιγράφουν τον αριθμό των ανεξάρτητων κινήσεων που μπορεί να εκτελέσει ένα ρομπότ, δηλαδή οι ρομποτικοί βραχίονες UR3/UR3e έχουν 6 διαδοχικές, περιστροφικές αρθρώσεις, οπότε και 6 βαθμούς ελευθερίας. Αυτό σημαίνει ότι, η διάταξή τους επιτρέπει πλήρη κινητικότητα στον 3D χώρο, δηλαδή να φτάσουν οποιαδήποτε θέση και προσανατολισμό του τελικού εργαλείου (end-effector).



Σχήμα 5.1: Ρομποτικός βραχίονας Ur3e της universal robots
[34]

Τα βασικά χαρακτηριστικά των UR3/UR3e που τους καθιστούν κατάλληλους για ρομποτικά σχήματα leader-follower είναι:

- **Υψηλή επαναληψιμότητα**: Με δυνατότητα επαναληψιμότητας της τάξεως των 0.03 mm, επιτρέπουν ακριβή χειρισμό εργαλείων σε περιορισμένους χώρους.
- **Ευελιξία και μικρό μέγεθος**: Επιτρέπουν την εύκολη τοποθέτηση τους σε χειρουργικά ή ερευνητικά εργαστήρια.

- **Ενσωματωμένος αισθητήρας δύναμης (UR3e)**: Ο UR3e διαθέτει εργοστασιακά ενσωματωμένο αισθητήρα 6 αξόνων (force-torque sensor), ο οποίος επιτρέπει ακριβή μέτρηση των δυνάμεων και ροπών στον καρπό του ρομπότ. Αυτό είναι καθοριστικής σημασίας για την υλοποίηση της απτικής ανάδρασης και για τη βελτίωση της ασφάλειας.

- **RTDE επικοινωνία**: Η επικοινωνία μεταξύ του υπολογιστή ελέγχου και των ρομποτικών βραχιόνων UR3/UR3e πραγματοποιείται μέσω της διεπαφής RTDE (Real-Time Data Exchange), την οποία παρέχει η Universal Robots. Η RTDE αποτελεί ένα πρωτόκολλο επικοινωνίας που επιτρέπει την υλοποίηση ελέγχου σε πραγματικό χρόνο, με ρυθμό ανανέωσης που φτάνει έως και $500Hz$. Στην παρούσα εργασία, η αρχιτεκτονική του συστήματος αξιοποιεί την RTDE για την συλλογή των δεδομένων από τους ενσωματωμένους αισθητήρες στα UR3/UR3e (θέσεις, ταχύτητες στις αρθρώσεις και δυνάμεις/ροπές στην άκρη του ρομπότ) σε πραγματικό χρόνο, καθώς και για την αποστολή εντολών ταχύτητας (μέσω της συνάρτησης speedJ) στους κινητήρες του UR3 και UR3e, με χρονική ακρίβεια $2ms$ για τον UR3e και $8ms$ για τον UR3. Επίσης, η εφαρμογή της πολυνηματικής αρχιτεκτονικής επιτρέπει οι παράλληλες διεργασίες, όπως ο έλεγχος, η εκτέλεση του νευρωνικού δικτύου και η καταγραφή δεδομένων, συγχρονίζονται με την ίδια περίοδο RTDE ($2ms$), εξασφαλίζοντας συνεχή και σταθερή επικοινωνία σε πραγματικό χρόνο.

- **Υποστήριξη ελέγχου ταχύτητας σε πραγματικό χρόνο**: Η δυνατότητα χρήσης εντολών ταχύτητας με χρονική ακρίβεια επιτρέπει την ομαλή εκτέλεση ελέγχων, όπως admittance control.

Έτσι, τα χαρακτηριστικά αυτά καθιστούν τους UR3/UR3e ιδανική επιλογή για την υλοποίηση του πειραματικού σεναρίου "leader-follower" με απτική ανάδραση και οπτικά δεδομένα, όπως απαιτείται στο πλαίσιο αυτής της εργασίας.

5.2 Πειραματικό set-up του ρομποτικού συστήματος

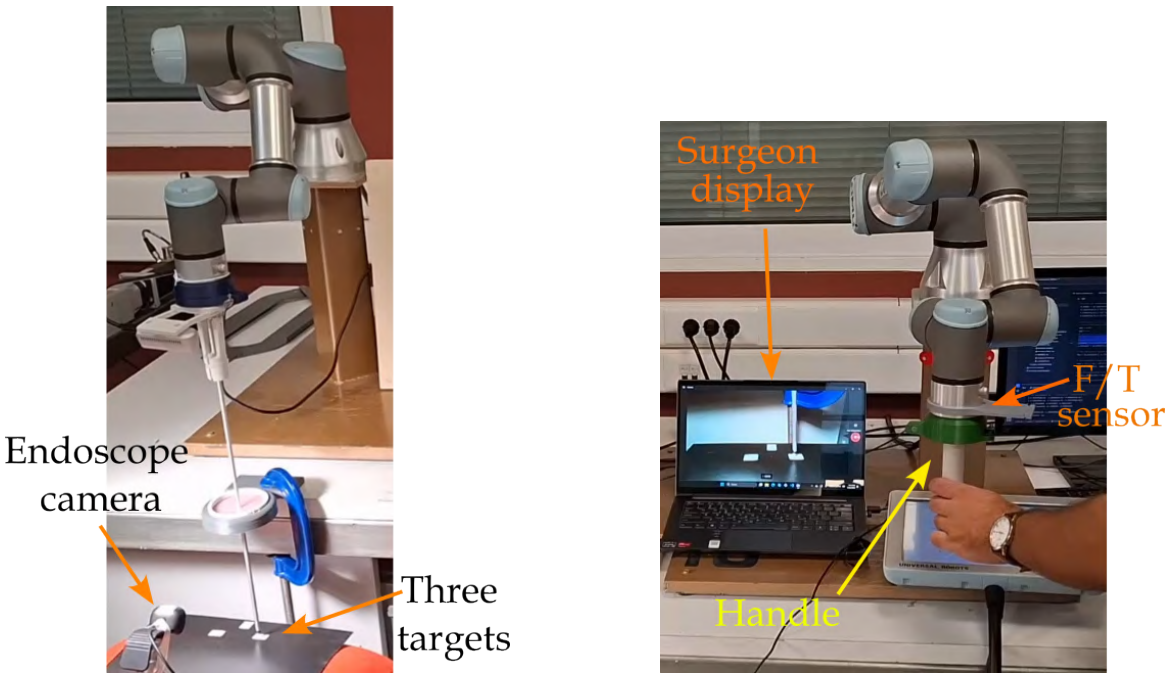
Το πειραματικό σύστημα που αναπτύχθηκε βασίζεται στην αρχιτεκτονική leader-follower και αξιοποιεί δύο ρομποτικούς βραχίονες της Universal Robots: τον UR3e ως leader και τον UR3 ως follower, όπως έχει εξηγηθεί και φαίνεται στις Εικόνες 5.2 και 5.3.

Στον καρπό του UR3e (Εικόνα 5.2b), έχει προσαρμοστεί μία λαβή (handle), μέσω της οποίας ο χρήστης εφαρμόζει δυνάμεις/ροπές, με σκοπό την κινηση του ρομποτικού βραχίονα. Πάνω από την λαβή, έχει τοποθετηθεί ένας αισθητήρας δυνάμεων/ροπών (F/T sensor) 6 αξόνων, ο οποίος καταγράφει τις δυνάμεις που εφαρμόζονται από τον χρήστη σε πραγματικό χρόνο.

Στον καρπό του UR3 (Εικόνα 5.2a), ρομπότ προσαρμόστηκε ένα χειρουργικό εργαλείο από αλουμίνιο, διαμέτρου $6\,\mathrm{mm}$. Στη βάση του εργαλείου αυτού, τοποθετήθηκε μία κάμερα Intel Realsense, η οποία λειτουργεί ως εξωτερική κάμερα και απεικονίζει τη χειρουργική τομή. Αν και η Realsense παρέχει και πληροφορία βάθους (depth), στο παρόν σύστημα χρησιμοποιήθηκαν μόνο τα RGB δεδομένα.

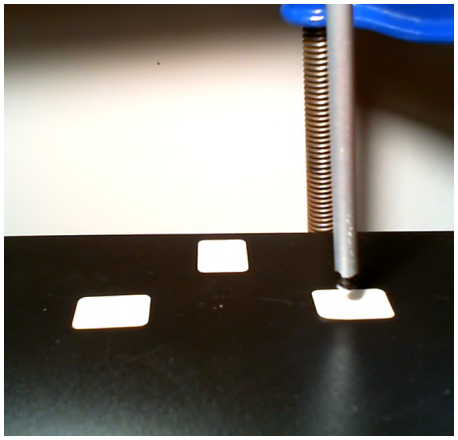
Η απόκτηση των εικόνων πραγματοποιείται μέσω της βιβλιοθήκης `pyrealsense2`, η οποία παρέχει απευθείας πρόσβαση στις ροές δεδομένων της κάμερας Intel RealSense. Κατά την εκκίνηση του συστήματος, δημιουργείται ένα pipeline (`self.pipeline`) και ορίζεται η επιθυμητή ροή δεδομένων μέσω της μεθόδου `enable_stream`, με ανάλυση 1280×720 pixels και ρυθμό ανανέωσης 30 καρέ ανά δευτερόλεπτο (fps). Σε κάθε επανάληψη του βρόχου επεξεργασίας, το pipeline επιστρέφει το επόμενο διαθέσιμο καρέ, το οποίο μετατρέπεται σε πίνακα τύπου `numpy` για ευκολότερο χειρισμό και περαιτέρω επεξεργασία.

Όπως έχει αναφερθεί στο Κεφ.2, για λόγους υπολογιστικής απόδοσης και για να εστιάσουμε στην περιοχή ενδιαφέροντος, εφαρμόζεται περικοπή (cropping) της εικόνας. Συγκεκριμένα, διατηρείται μόνο το τμήμα που αντιστοιχεί στο κάτω κεντρικό μέρος του αρχικού καρέ (από το 1/3 έως το πλήρες



(α□) Follower side (β□) Leader side

Σχήμα 5.2: Experimental setup with the UR3 (follower) and UR3e (leader).



Σχήμα 5.3: Image from the endoscope camera, i.e. the surgeon's view.

ύψος και από 426 έως 1146 pixels στο πλάτος). Η επιλογή αυτή εστιάζει στο πεδίο όπου βρίσκεται συνήθως το εργαλείο κατά τη διάρκεια της αλληλεπίδρασης με τον ιστό, μειώνοντας παράλληλα τον όγκο των δεδομένων που πρέπει να επεξεργαστεί το σύστημα.

Ο στόχος όλων των πειραμάτων περιλαμβάνει τη μετάβαση από τρεις προκαθορισμένους στόχους με την άκρη του εργαλείου του follower ρομπότ. Γι' αυτό το λόγο, τοποθετήθηκε μία ενδοσκοπική κάμερα (Εικόνα 5.3), η οποία αποτελεί και την μόνη πληροφορία που δέχεται ο χειρουργός. Δηλαδή, ο χειρουργός βλέπει μόνο το εσωτερικό του ασθενούς, μέσω αυτής της κάμερας, χωρίς να έχει εικόνα της χειρουργικής τομής.

Το σύστημα υποστηρίζεται από έναν ενδιάμεσο υπολογιστή, ο οποίος αναλαμβάνει την εκτέλεση των αλγορίθμων ελέγχου και την αποστολή των εντολών ταχύτητας στον follower μέσω της διεπαφής RTDE. Για την εξασφάλιση σταθερής και συγχρονισμένης επικοινωνίας μεταξύ των δύο ρομπότ και του υπολογιστή, χρησιμοποιήθηκε ένας τοπικός router, ο οποίος δημιουργεί ένα κοινό τοπικό δίκτυο (LAN). Μέσω αυτού, επιτυγχάνεται πραγματικός χρονισμός, με σταθερές καθυστερήσεις και δυνατότητα χρονικής ακρίβειας της τάξης των 2 ms.

5.3 Πειράματα και Αποτελέσματα

Με σκοπό, λοιπόν, το ρομποτικό εργαλείο να περάσει από τρία προκαθορισμένα σημεία με την άκρη του εργαλείου, στην αξιολόγηση πραγματοποιήθηκαν τα παρακάτω 3 διαφορετικά σενάρια πειραμάτων:

1. **Χρήση της Σιλικόνης**
2. **Χρήση ζελατίνης**
3. **Κινούμενη τομή**

Για λόγους σύγκρισης, πραγματοποιήθηκαν αυτά τα σενάρια με δοκιμές τόσο με ενεργοποιημένη την καθοδήγηση οπτικής–απτικής (*Vision-to-Haptics, V2H*) όσο και με αυτήν απενεργοποιημένη. Επίσης, σε κάθε μία από τις παραπάνω περιπτώσεις, η θέα του χειρουργού περιορίζεται αποκλειστικά στην εικόνα που προβάλλεται στην οθόνη (βλ. Σχ. 5.3). Σημειώνεται ότι σε όλα τα πειράματα η εικονική δεξαμενή ενέργειας δεν εξαντλήθηκε ποτέ, επομένως το $\mathbf{u}_f$ ήταν πάντα ενεργό.

Οι παράμετροι της προτεινόμενης μεθόδου επιλέχθηκαν μετά από δοκιμές (tuning) ως εξής:

$$\mathbf{M}_d = \mathrm{diag}(0.3\mathbf{I}_2,\, 0.1\mathbf{I}_2,\, 0.05\mathbf{I}_2), \quad \mathbf{D}_d = 0.6\mathbf{I}_6, \quad k_g = 0.015, \quad \alpha = 0.9, \quad \mathbf{K} = 4\mathbf{I}_6.$$

Το προτεινόμενο σχήμα ελέγχου υλοποιήθηκε σε `Python` και είναι διαθέσιμο στο GitHub: `https://github.com/CSRL-HMU/vis2haptics`.

5.3.1 Πείραμα 1: Χρήση Σιλικόνης

Σε αυτό το πείραμα, χρησιμοποιείται ο στατικός δίσκος σιλικόνης ZA13, που χρησιμοποιήθηκε και για την εκπαίδευση του βαθιού συνελικτικού νευρωνικού δικτύου, με σκοπό την προσομοίωση του εξωτερικού μαλακού ιστού του ασθενούς (φαίνεται στο Σχήμα 2.24). Για το συγκεκριμένο πείραμα, εξετάστηκαν τα εξής δύο σενάρια, με σκοπό την μετακίνηση της άκρης του χειρουργικού εργαλείου:

1. Ο άνθρωπος (χειρουργός) ασκεί κυρίως μόνο δυνάμεις στην άκρη της λαβής,
2. Ο άνθρωπος (χειρουργός) ασκεί τόσο δυνάμεις όσο και ροπές στην άκρη της λαβής.

Το δεύτερο σενάριο υποθέτει ότι ο χειρουργός έχει τη διαίσθηση και τη σημαντική εμπειρία στην κίνηση του χειρουργικού εργαλείου, καθώς η μόνη πληροφορία που του παρέχεται είναι η εικόνα από την ενδοσκοπική κάμερα.

Στα Σχήματα 5.4 και 5.5 απεικονίζεται η διαδρομή του καρπού του follower ρομπότ, $\mathbf{p}_f$, το διάνυσμα $d_s\mathbf{z}_{wf}$ και το εκτιμώμενο σημείο επαφής, δηλαδή $\mathbf{p}_c$ και για τα δύο παραπάνω σενάρια, δηλαδή και για την περίπτωση εφαρμογής κυρίως δυνάμεων και για την περίπτωση εφαρμογής δυνάμεων και ροπών στη λαβή αντίστοιχα. Το $d_s\mathbf{z}_{wf}$ χρησιμοποιείται ως εκτίμηση του χειρουργικού εργαλείου (υποθέτοντας ότι έχουμε ένα άκαμπτο, μη παραμορφώσιμο χειρουργικό εργαλείο). Ουσιαστικά, είναι το διάνυσμα από τον καρπό μέχρι την άκρη του εργαλείου κατά τη διεύθυνση $\mathbf{z}_{wf}$. Για την αξιολόγηση των αποτελεσμάτων, το σημείο επαφής εργαλείου με τον ιστό $\mathbf{p}_c$, υπολογίζεται γεωμετρικά με βάση τη γνωστή θέση του δίσκου σιλικόνης στον χώρο. Συγκεκριμένα, για τα πειράματα, ο δίσκος τοποθετήθηκε σε ύψος $z = -0.39m$, γεγονός που ορίζει το οριζόντιο επίπεδο:

$$z = -0.39$$

Η παραμετρική ευθεία, που περιγράφει τον άξονα του εργαλείου είναι:

$$\overline{\mathbf{p}}(\sigma) = \mathbf{p}_f + \sigma\mathbf{z}_{wf}, \quad \sigma \in \mathbb{R} \tag{5.1}$$

Αυτή η έκφραση περιγράφει τη γραμμή που περνάει από το σημείο $\mathbf{p}_f \in \mathbb{R}^3$ και έχει κατεύθυνση $z_{wf} \in \mathbb{R}^3$, δηλαδή τον άξονα του εργαλείου. Το $\sigma \in \mathbb{R}$, καθορίζει το πόσο μακριά και προς ποια κατεύθυνση γίνεται η μετακίνηση κατά μήκος του άξονα. Ουσιαστικά, η παραμετρική ευθεία αναλύεται στις συνιστώσες (x, y, z):

$$\begin{cases} x(\sigma) = p_{f,x} + \sigma z_{wf,x} \\ y(\sigma) = p_{f,y} + \sigma z_{wf,y} \\ z(\sigma) = p_{f,z} + \sigma z_{wf,z} \end{cases}$$

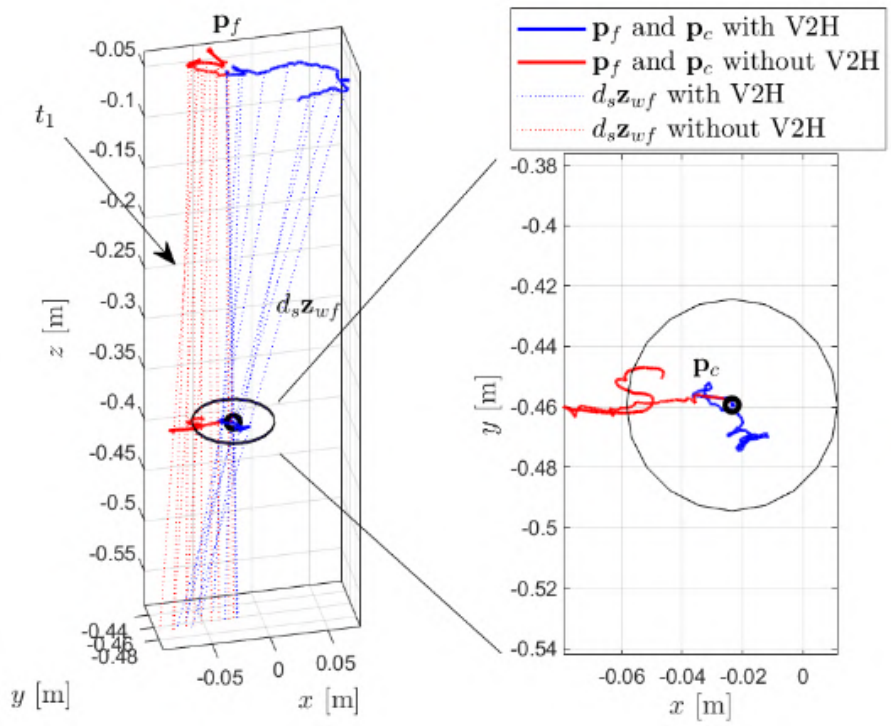
Για την εύρεση του σημείου που η γραμμή $\overline{\mathbf{p}}(\sigma)$, τέμνει το επίπεδο $z = -0.39m$, αρκεί να πούμε ότι στο σημείο αυτό της τομής, η z-συνιστώσα της γραμμής, πρέπει να είναι ίση με τη z-συνιστώσα του επίπεδου. Άρα,

$$p_{f,z} + \sigma z_{wf,z} = -0.39 \Rightarrow \sigma = \frac{-0.39 - p_{f,z}}{z_{wf,z}}$$

Τώρα, που έχουμε το σ, μπορούμε να βρούμε το ακριβές σημείο τομής της ευθείας με το επίπεδο:

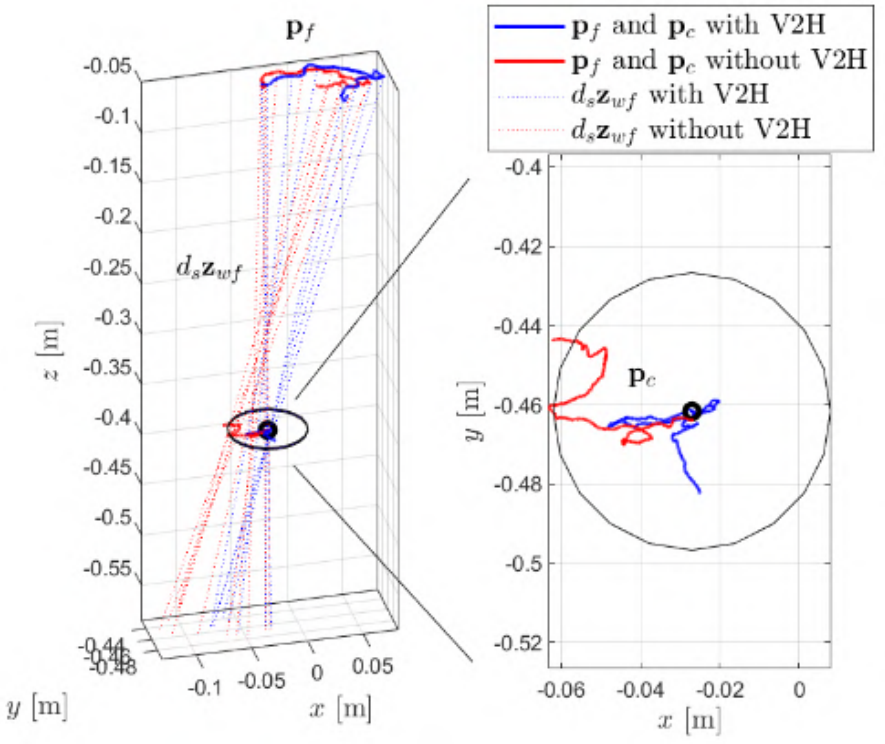
$$\mathbf{p}_c = \mathbf{p}_f + \sigma \mathbf{z}_{wf}$$

Η διαδικασία αυτή βασίζεται στην εκ των προτέρων γνώση του ύψους του δίσκου και δεν ενσωματώνεται στον προτεινόμενο ελεγκτή, καθώς υποτίθεται ότι η ακριβής θέση του σημείου τομής δεν είναι διαθέσιμη. Οπότε, η χρήση της γίνεται αποκλειστικά στο στάδιο της αξιολόγησης.



Σχήμα 5.4: Αποτελέσματα με χρήση σιλικόνης, της εφαρμογής κυρίως δυνάμεων στο άκρο

Φαίνεται και στα δύο σενάρια η σαφής διαφορά των αποτελεσμάτων με ενεργοποιημένη την οπτικό - απτική καθοδήγηση (V2H) και αυτών χωρίς κάποια καθοδήγηση. Στο αριστερό γράφημα των Σχημάτων 5.4 και 5.5, απεικονίζεται η κίνηση στο χώρο $\mathbb{R}^3$ του καρπού του follower ρομπότ ($\mathbf{p}_f$), καθώς και η εκτίμηση του εργαλείου $d_s\mathbf{z}_{wf}$ (διακεκομμένες γραμμές). Οι διακεκομμένες γραμμές παριστάνουν, χρονική στιγμή προς χρονική στιγμή, τον εκτιμώμενο άξονα του εργαλείου και το σημείο τομής του με το επίπεδο του δίσκου σιλικόνης. Όσο πιο συγκεντρωμένες είναι οι τομές, τόσο πιο σταθερά κατευθύνεται το εργαλείο στο ίδιο σημείο.



Σχήμα 5.5: Αποτελέσματα με χρήση σιλικόνης, της εφαρμογής δυνάμεων και ροπών στο άκρο

Στο δεξή γράφημα απεικονίζεται η ίδια πληροφορία, αλλά σε top view (προβολή στο επίπεδο x-y). Σε αυτό, φαίνεται καθαρά, η απόσταση και η απόκλιση του σημείου επαφής $\mathbf{p}_c$ από το κέντρο του δίσκου της σιλικόνης.

Ερμηνεία αποτελεσμάτων με ενεργοποιημένη την οπτικό - απτική καθοδήγηση: Η πορεία του καρπού $\mathbf{p}_f$ και οι τομές $\mathbf{p}_c$ είναι συγκεντρωμένες γύρω από το κέντρο του δίσκου.

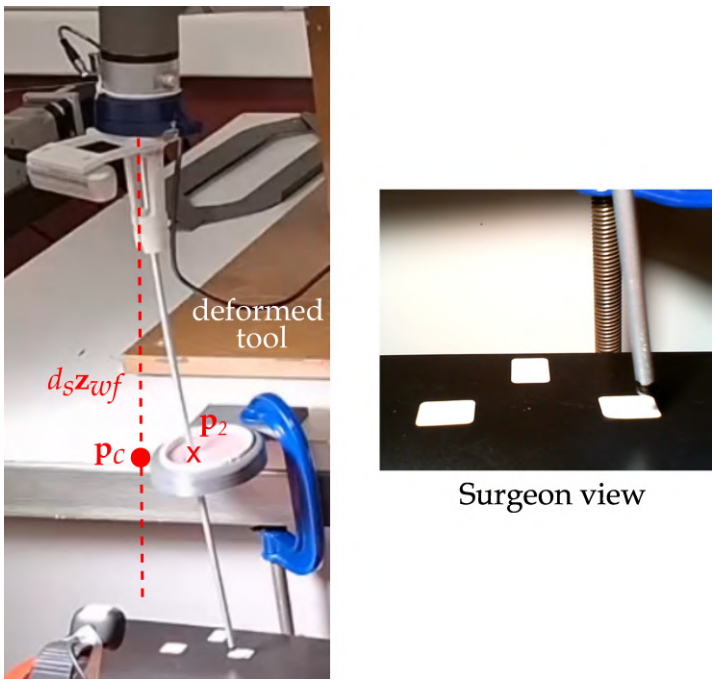
Οι διακεκομμένες γραμμές συσσωρεύονται κοντά στο ίδιο σημείο τομής, γεγονός που δείχνει μικρότερη παραμόρφωση της τομής.

Ερμηνεία αποτελεσμάτων χωρίς οπτικό - απτική καθοδήγηση ενεργή: Η πορεία του καρπού και το εκτιμώμενο $\mathbf{p}_c$ παρουσιάζουν μεγάλη απόκλιση από το κέντρο του δίσκου.

Το εργαλείο βρίσκεται μακριά από το κέντρο της τομής, οδηγώντας σε μεγάλη παραμόρφωση και σίγουρο τραυματισμό της τομής. Στην Εικόνα 5.6, φαίνεται που θα βρισκόταν το εργαλείο τη χρονική στιγμή $t = t_1$(βλ. Εικόνα 5.4).

Αξίζει να σημειωθεί, ότι ο άνθρωπος χωρίς το προτεινόμενο σχήμα ελέγχου δεν θα μπορούσε να εκτελέσει ακόμη και την πρώτη κίνηση του άκρου του εργαλείου από το αρχικό σημείο στο επόμενο, ενώ με την ενεργοποίηση του το εργαλείο περιστρέφεται γύρω από το σημείο τομής, λόγω της δράσης του $\mathbf{u}_f$. Επιπλέον, το εργαλείο φαίνεται να υπερβαίνει τα κυκλικά όρια του δίσκου, αλλά αυτό συμβαίνει λόγω της υπόθεσης ότι το εργαλείο είναι άκαμπτο. Σε ρεαλιστική περίπτωση, ο χρήστης αισθάνεται μία αντίθετη κίνηση από αυτήν που υπαγορεύεται μέσω της λαβής και σε συνδυασμό με την περιοριμένη οπτική πληροφορία που έχει από την κάμερα του ενδοσκοπίου, το σύστημα μπορεί να χαρακτηριστεί ως ανεξέλεγκτο και δυσχερή.

Η θέση της εκτίμησης του σημείου επαφής (δηλαδή $\mathbf{p}_c$) σε σχέση με τη γνωστή θέση του δίσκου σιλικόνης χρησιμεύει ως μέτρο για την παραμόρφωση του προσομοιωμένου ιστού. Και στα δύο σενάρια, η παραμόρφωση της τομής είναι εμφανώς μεγαλύτερη όταν το προτεινόμενο σχήμα ελέγχου δεν είναι ενεργοποιημένο. Στην περίπτωση εφαρμογής τόσο δυνάμεων όσο και ροπών, ο χρήστης κατάφερε να ολοκληρώσει την εργασία και με τις δύο μεθόδους. Ωστόσο, χωρίς V2H, το σημείο επα-



Σχήμα 5.6: Παραμόρφωση του χειρουργικού εργαλείου χωρίς τη χρήση της προτεινόμενης μεθόδου

φής αποκλίνει σημαντικά από το κέντρο του δίσκου, με κίνδυνο πρόκλησης ζημιάς στην τομή, καθώς ο χειρουργός πρέπει να βασίζεται αποκλειστικά στη διαίσθηση και τη φαντασία του σχετικά με την επαφή του εργαλείου με την τομή.

Καταληκτικά, η χρήση του V2H προσφέρει πιο ελεγχόμενη κίνηση και σημαντική μείωση της παραμόρφωσης της τομής, βελτιώνοντας την ακρίβεια και την ασφάλεια της διαδικασίας, ακόμη και σε χειρουργούς με περιορισμένη εμπειρία.

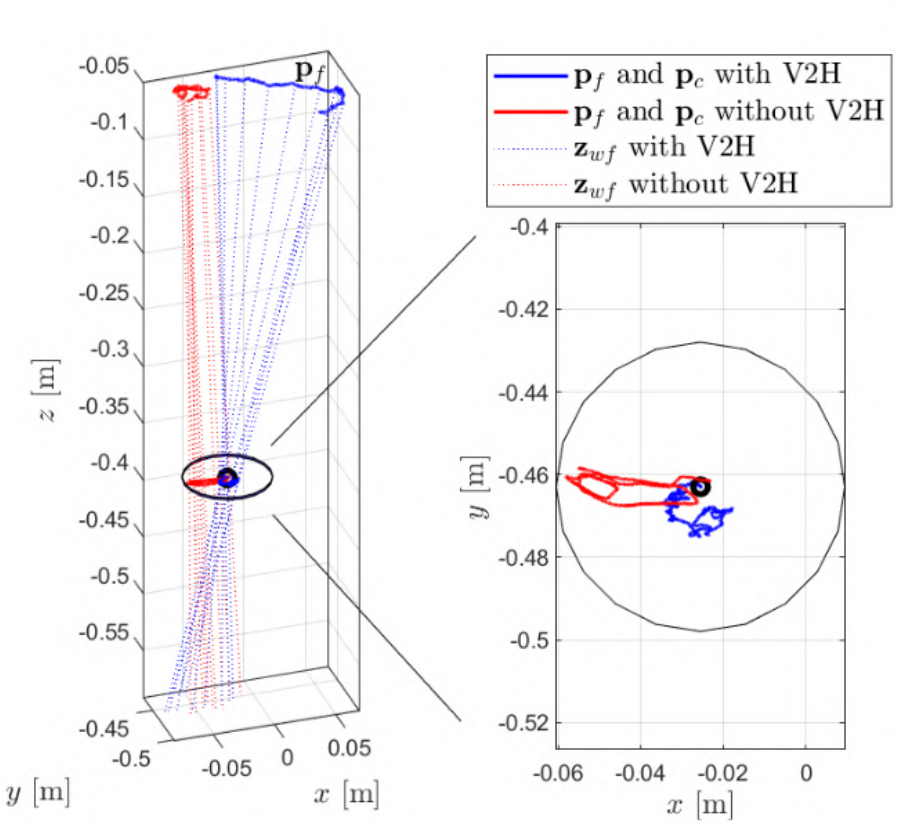
5.3.2 Πείραμα 2: Χρήση Ζελατίνης

Με σκοπό την καλύτερη αξιολόγηση της ικανότητας γενίκευσης και της αποτελεσματικότητας του προτεινόμενου σχήματος ελέγχου vision-to-haptics (V2H), πραγματοποιήθηκε αυτό το πείραμα, χρησιμοποιώντας μία εμπορική ζελατίνη ζαχαροπλαστικής, η οποία διαθέτει διαφορετικές φυσικές ιδιότητες, σε σχέση με την σιλικόνη. Συγκεκριμένα, η ζελατίνη επιλέχθηκε, επειδή είναι πιο ευαίσθητη και έτσι μπορεί να καταστραφεί και να παραμορφωθεί πολύ εύκολα, όταν τις ασκούνται δυνάμεις ή ροπές. Όπως και στο προηγούμενο πείραμα με την σιλικόνη, ο στόχος του χρήστη είναι να περάσει την άκρη του χειρουργικού εργαλείου από τα τρία προκαθορισμένα σημεία. Στα διαγράμματα του Σχ. 5.7 παρουσιάζονται τα αποτελέσματα της κίνησης, με και χωρίς ενεργοποιημένο τον προτεινόμενο ελεγκτή.

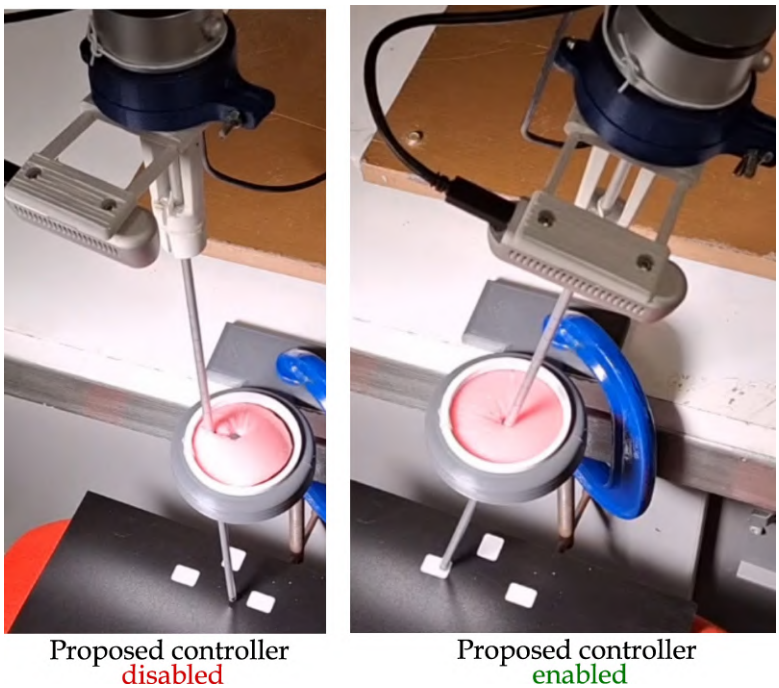
Κατά τη δοκιμή χωρίς το σχήμα ελέγχου, το εργαλείο προκάλεσε υπερβολική καταπόνηση του υλικού, οδηγώντας σε σχίσιμο του δίσκου ζελατίνης (Σχ. 5.8), οπότε και η διαδικασία διακόπηκε για να αποφευχθεί η πλήρης καταστροφή. Αντίθετα, με ενεργοποιημένο τον προτεινόμενο έλεγχο, η παραμόρφωση παρέμεινε εντός ασφαλών ορίων και η εργασία ολοκληρώθηκε επιτυχώς, χωρίς να υπάρξει βλάβη στο υλικό.

Αξίζει να σημειωθεί, ότι με την επιλογή της ζελατίνης επιτυγχάνεται ακριβέστερη εκτίμηση του σημείου επαφής $\mathbf{p}_c$, διότι η ζελατίνη παραμορφώνεται πολύ εύκολα και δεν προκαλείται στον άξονα του εργαλείου κάποια σημαντική παραμόρφωση. Έτσι, αυτό επιτρέπει την άμεση σύγκριση της εκτίμησης της παραμόρφωσης που παράγεται από το DCNN με την απόσταση από το κέντρο του δίσκου της ζελατίνης. Συγκεκριμένα, στο Σχήμα 5.9 παρουσιάζεται η σύγκριση μεταξύ:

1. Της νόρμας της εκτίμησης παραμόρφωσης $\|\mathbf{p}_2 - \mathbf{p}_1\|$ (σε μέτρα)



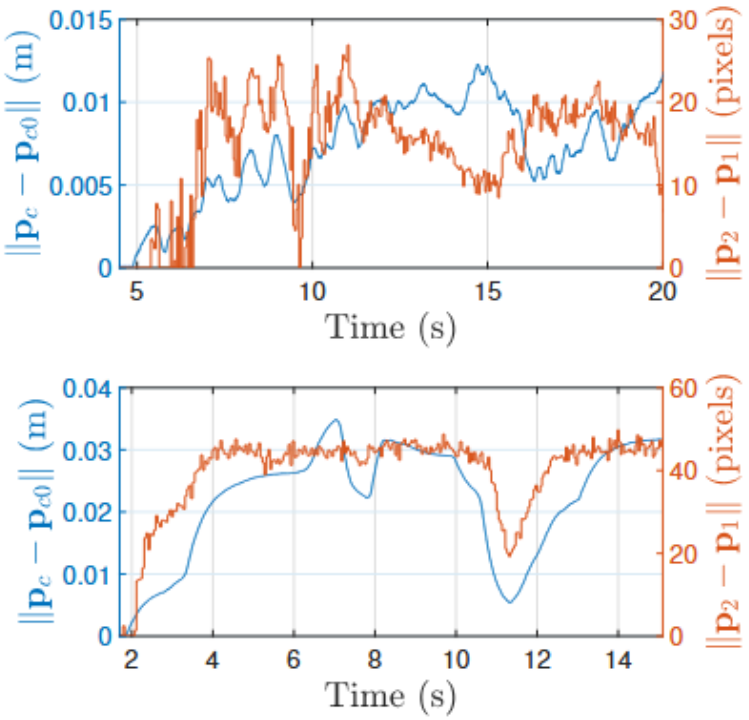
Σχήμα 5.7: Πείραμα με ζελατίνη



Σχήμα 5.8: Βλάβη της ζελατίνης με και χωρίς τον προτεινόμενο ελεγκτή.

2. Της απόστασης του εκτιμώμενου σημείου επαφής από το κέντρο του δίσκου $\|\mathbf{p}_c - \mathbf{p}_{c0}\|$ (σε pixels).

Στο επάνω διάγραμμα απεικονίζεται η εκτέλεση του πειράματος υπό τον έλεγχο του προτεινόμενου σχήματος V2H, ενώ στο κάτω διάγραμμα απεικονίζεται η ίδια διαδικασία χωρίς την ενεργοποίηση του. Παρόλο που οι δύο ποσότητες βρίσκονται σε διαφορετικές κλίμακες και μονάδες μέτρησης,



Σχήμα 5.9: Σύγκριση της εκτίμησης παραμόρφωσης ($\|\mathbf{p}_2 - \mathbf{p}_1\|$) με την απόσταση του σημείου επαφής από το κέντρο του δίσκου ($\|\mathbf{p}_c - \mathbf{p}_{c0}\|$), με τον δίσκο ζελατίνης.

παρουσιάζουν παρόμοια χρονική εξέλιξη και μοτίβο μεταβολής. Η ομοιότητα αυτή είναι ιδιαίτερα σημαντική, καθώς η εκτίμηση παραμόρφωσης $\|\mathbf{p}_2 - \mathbf{p}_1\|$ μειώνεται κατά k_g πριν χρησιμοποιηθεί ως εντολή διόρθωσης κίνησης στο ρομποτικό σύστημα. Η παρατήρηση αυτή ενισχύει την αξιοπιστία του DCNN στην εκτίμηση της πραγματικής παραμόρφωσης και τεκμηριώνει την αποτελεσματικότητα του ελεγκτή V2H σε υλικά αυξημένης ευαισθησίας.

5.3.3 Πείραμα 3: Κινούμενη τομή

Στο τρίτο και τελευταίο πείραμα εξετάστηκε το σενάριο, στο οποίο η τομή δεν παραμένει σταθερή, αλλά μετακινείται τυχαία από ένα άλλο άτομο, όπως φαίνεται στο Σχήμα 5.10α□. Η συνθήκη αυτή προσομοιώνει περιπτώσεις πραγματικών χειρουργικών επεμβάσεων όπου η περιοχή ενδιαφέροντος μπορεί να μετακινηθεί λόγω κίνησης του ιστού, αναπνοής του ασθενούς ή εξωτερικών παρεμβάσεων.

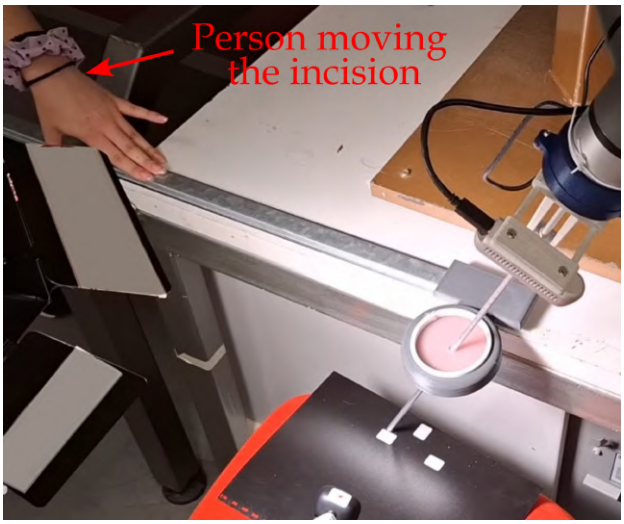
Ο προτεινόμενος ελεγκτής απέδειξε την ικανότητά του να ανταποκρίνεται αποτελεσματικά στην πρόκληση, και να παράγει τις κατάλληλες εικονικές δυνάμεις που εφαρμόζοται στον καρπό του leader ρομπότ. Οι δυνάμεις αυτές λειτουργούσαν ως καθοδηγητικά ερεθίσματα, βοηθώντας τον χρήστη να μην παραμορφώσει την κινούμενη τομή και ουσιαστικά να την ακολουθεί με ακρίβεια, ακόμη και όταν η κίνηση είναι απρόβλεπτη.

Στο Σχήμα 5.10β□ παρουσιάζονται οι μετρήσεις των παραγόμενων εικονικών σημάτων:

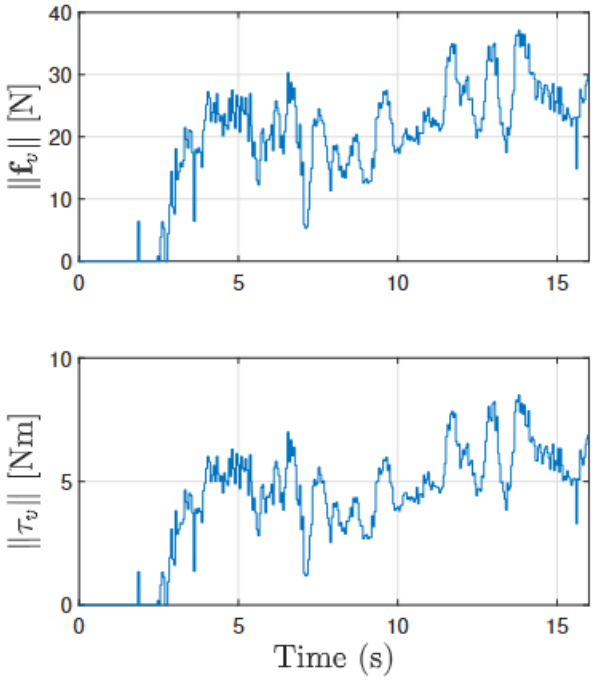
- Στο πάνω διάγραμμα εμφανίζεται το μέτρο της εικονικής δύναμης $\|F_v\|$ (η λεγόμενη F_{ext}, σε Νιούτον), η οποία αυξομειώνεται δυναμικά ανάλογα με την απόκλιση του εργαλείου από την επιθυμητή θέση.

- Στο κάτω διάγραμμα παρουσιάζεται το μέτρο της εικονικής ροπής $\|\tau_v\|$ (σε Νιούτον επί μέτρα), που αντιστοιχεί στις περιστροφικές διορθώσεις της κίνησης.

Η ομαλή αλλά ταυτόχρονα ευέλικτη μεταβολή των μεγεθών αυτών δείχνει την ικανότητα του συστήματος να παρέχει συνεχή και προσαρμοστική καθοδήγηση, ακόμα και υπό συνθήκες έντονης



(α□) Setup για το πείραμα κινούμενης τομής



(β□) Εικονική δύναμη που εφαρμόζεται στον καρπό του leader.

Σχήμα 5.10: Πείραμα κινούμενης τομής.

αβεβαιότητας ως προς την κίνηση του στόχου. Το αποτέλεσμα αυτό ενισχύει την πεποίθηση ότι η μέθοδος μπορεί να επεκταθεί και σε κλινικές εφαρμογές όπου η χειρουργική εργασία εκτελείται σε δυναμικά περιβάλλοντα.

Κεφάλαιο 6

Συμπεράσματα και Μελλοντική έρευνα

Η παρούσα εργασία παρουσίασε την ανάπτυξη, υλοποίηση και πειραματική αξιολόγηση ενός συστήματος ελέγχου με οπτική και απτική καθοδήγηση (vision-to-haptics) για την αποφυγή ιατρογενούς βλάβης σε περιβάλλον Ρομποτικά Υποβοηθούμενης Ελάχιστα Επεμβατικής Χειρουργικής (RAMIS). Το σύστημα στηρίζεται σε αρχιτεκτονική leader–follower και αξιοποιεί έναν Βαθύ Συνελικτικό Νευρωνικό Δίκτυο (DCNN), το οποίο εκτιμά σε πραγματικό χρόνο την παραμόρφωση του σημείου τομής, βάσει εικόνας από εξωτερική κάμερα τοποθετημένη στη βάση του εργαλείου. Η πληροφορία αυτή μετατρέπεται σε απτική ανάδραση προς τον χειρουργό μέσω εικονικών δυνάμεων, με στόχο την καθοδήγησή του μακριά από τον τραυματισμό του μαλακού ιστού.

Η θεωρητική ανάλυση που πραγματοποιήθηκε έδειξε ότι η προτεινόμενη μέθοδος μπορεί να εγγυηθεί παθητικότητα ακόμη και με την προσθήκη ανάδρασης από το DCNN, χάρη στον ενσωματωμένο μηχανισμό passivity observer και τη χρήση εικονικής δεξαμενής ενέργειας (energy tank). Αυτό εξασφαλίζει ότι η αλληλεπίδραση παραμένει ασφαλής και σταθερή, αποφεύγοντας ανεξέλεγκτες δυνάμεις που θα μπορούσαν να θέσουν σε κίνδυνο τον ασθενή ή να υποβαθμίσουν την απόδοση του συστήματος. Η πειραματική αξιολόγηση, χρησιμοποιώντας τους δύο βραχίονες UR3/UR3e και δύο υλικά με διαφορετικά χαρακτηριστικά (ZA13 σιλικόνη και ζελατίνη), έδειξε ότι:

- Με την προτεινόμενη μέθοδο, η παραμόρφωση της τομής μειώθηκε σημαντικά, τόσο με τη χρήση της σιλικόνης, όσο και με τη χρήση της ζελατίνης, ως πιο εύθραυστο υλικό.

- Ο χειρουργός είναι σε θέση να εκτελέσει τα απαιτούμενα καθήκοντα του, χωρίς να εμποδίζεται η φυσική του κίνηση, καθώς η απτική ανάδραση έχει, κυρίως κατευθυντικό και όχι περιοριστικό χαρακτήρα.

- Το σύστημα λειτούργησε ικανοποιητικά και προσαρμόστηκε ακόμη και όταν το σημείο τομής μετακινούταν τυχαία και απρόβλεπτα, γεγονός που προσομοιώνει καταστάσεις όπως η αναπνοή, ο καρδιακός παλμός ή οι ακούσιες κινήσεις του ασθενή που μπορεί να υπάρξουν.

- Η προτεινόμενη μέθοδος απέτρεψε τη ζημιά και την καταστροφή σε εύθραυστα υλικά, όπως η ζελατίνη. Συγκεκριμένα, χωρίς την καθοδήγηση η τομή υπέστη πλήρη ρήξη, ενώ με την καθοδήγηση ολοκληρώθηκε επιτυχώς η εργασία (μετακίνηση του άκρου του χειρουργικού εργαλείου σε τρία προκαθορισμένα σημεία), χωρίς κάποια βλάβη.

Τα πειράματα δείχνουν την αποτελεσματικότητα της προτεινόμενης μεθόδου για την αποφυγή του τραυματισμού της τομής ακόμη και όταν η τομή δεν είναι στατική, καθώς και τη δυνατότητα μεταφοράς της μεθόδου για την αντιμετώπιση του προβλήματος δεδομένων άλλων φυσικών ιδιοτήτων, χωρίς να απαιτείται περαιτέρω εκπαίδευση.

Περιορισμοί και προκλήσεις: Παρά τα ενθαρρυντικά αποτελέσματα, η υλοποίηση παρουσίασε ορισμένους περιορισμούς. Αρχικά, το DCNN εκπαιδεύτηκε σε δεδομένα, με συγκεκριμένα υλικά και φωτισμό, κάτι που μπορεί να περιορίσει τη γενίκευση σε πραγματικές επεμβάσεις. Επιπλέον, ο μηχανισμός παθητικότητας εγγυάται σταθερότητα, αλλά η υπερβολική "σβέση" της δύναμης όταν η δεξαμενή ενέργειας είναι σχεδόν άδεια μπορεί να οδηγήσει σε απώλεια καθοδήγησης σε ακραίες περιπτώσεις. Ακόμα, δεν έχει πραγματοποιηθεί κάποια κλινική αξιολόγηση σε συνεργασία με χειρουργούς σε πραγματικές ή ρεαλιστικά προσομοιωμένες επεμβάσεις, όπως και δεν έχουν δοκιμαστεί η ευχρηστία του συστήματος από πολλούς χρήστες.

Συνολικά, το σύστημα αποδείχθηκε λειτουργικό, αποδοτικό και ασφαλές στις δοκιμές που πραγματοποιήθηκαν, θέτοντας ισχυρές βάσεις για περαιτέρω έρευνα και κλινική εφαρμογή.

Μελλοντική Έρευνα: Με βάση τα αποτελέσματα και τους περιορισμούς που εντοπίστηκαν, μπορούν να προταθούν οι εξής άξονες μελλοντικής έρευνας και ανάπτυξης:

- **Επέκταση των δεδομένων εκπαίδευσης**: Η απόδοση του DCNN εξαρτάται σε μεγάλο βαθμό από την ποικιλία και την ποιότητα των δεδομένων, που χρησιμοποιούνται για την εκπαίδευση του. Ένα σημαντικό επόμενο βήμα είναι η δημιουργία ενός μεγαλύτερου συνόλου δεδομένων, καθώς και να γίνει συλλογή δεδομένων, με εναλλαγές του φωτισμού, με διαφορετικά υλικά, καθώς και με διαφορετικά ύψη εισχώρησης του χειρουργικού εργαλείου στην τομή, με σκοπό τη βελτίωση της γενίκευσης του μοντέλου. Επιπλέον, μεταγενέστερα, να γίνει η ενσωμάτωση δεδομένων από πραγματικές χειρουργικές επεμβάσεις (με τη δέουσα ανωνυμοποίηση και ηθική έγκριση), στις οποίες την διαδικασία της επισήμανσης του διανύσματος της παραμόρφωσης (annotation), θα πραγματοποιήσει ένας καταρτισμένος χειρουργός.

- **Διεύρυνση των οπτικών δεδομένων**: Στην παρούσα υλοποίηση, η εκτίμηση παραμόρφωσης βασίζεται αποκλειστικά σε εικόνες RGB. Η προσθήκη πληροφορίας βάθους (RGB-D) ή ακόμα και θερμικών δεδομένων, θα μπορούσε να προσφέρει πιο ακριβείς και αξιόπιστες εκτιμήσεις. Η συγχώνευση τέτοιων δεδομένων με τεχνικές βαθιάς μάθησης, ανοίγει τον δρόμο για μεγαλύτερη ακρίβεια και σταθερότητα του συστήματος, αυξάνωντας την αξιοπιστία του.

- **Προσαρμοστικά μοντέλα και online μάθηση**: Η ανάπτυξη προσαρμοστικών εκδόσεων του DCNN, ικανών να μαθαίνουν σε πραγματικό χρόνο κατά τη διάρκεια μιας επέμβασης, θα επέτρεπε στο σύστημα να ανταποκρίνεται σε σταδιακές αλλαγές φωτισμού, θέσης κάμερας ή των διαφορετικών ιδιοτήτων του κάθε ιστού. Επιπλέον, η αξιοποίηση μεθόδων μετα-μάθησης (meta-learning) θα μπορούσε να μειώσει τον χρόνο που απαιτείται για την επανεκπαίδευση του μοντέλου και την προσαρμογή του σε νέα περιβάλλοντα ή συνθήκες.

- **Κλινική αξιολόγηση και ανθρωποκεντρική μελέτη**: Για την αποδοχή της μεθόδου στην κλινική πράξη απαιτείται η συνεργασία με πολλούς χειρουργούς και να πραγματοποιηθούν πολλές δοκιμές. Με αυτόν τον τρόπο, θα διαπιστωθεί αν η απτική ανάδραση βοηθά ή αποσπά την προσοχή του χειρουργού. Επίσης, θα πρέπει να αξιολογηθεί η ασφάλεια του συστήματος και η αποτελεσματικότητα του σε πραγματικές συνθήκες.

- **Βελτιστοποίηση σε επίπεδο υλοποίησης**: Η χρήση ελαφριών αρχιτεκτονικών νευρωνικών δικτύων, όπως τα MobileNet ή EfficientNet, θα διευκόλυνε την ενσωμάτωση του συστήματος σε υπολογιστικά περιορισμένες πλατφόρμες (embedded systems). Παράλληλα, η παράλληλη επεξεργασία δεδομένων από πολλαπλές κάμερες θα μπορούσε να προσφέρει ευρύτερο οπτικό πεδίο και βελτιωμένη ανίχνευση παραμόρφωσης, ενισχύοντας περαιτέρω την ακρίβεια της μεθόδου.

Συνολική αξιολόγηση: Η παρούσα εργασία κατέδειξε ότι η σύνδεση οπτικής αντίληψης με απτική καθοδήγηση μέσω βαθιών νευρωνικών δικτύων αποτελεί πολλά υποσχόμενη κατεύθυνση για την ενίσχυση της ασφάλειας στις ρομποτικά υποβοηθούμενες επεμβάσεις. Παρά τους περιορισμούς, η μεθοδολογία απέδειξε ότι είναι τεχνικά εφικτή, αποδοτική και προσαρμόσιμη, θέτοντας τις βάσεις για ένα νέο πεδίο ερευνητικών και κλινικών εφαρμογών όπου η τεχνητή νοημοσύνη λειτουργεί ως προληπτικός συνεργάτης του χειρουργού.

Βιβλιογραφία

[1] Nura Aljaafari. Ichthyoplankton classification tool using generative adversarial networks and transfer learning. Master's thesis, King Abdullah University of Science and Technology, February 2018. Advisor: Panagiotis Kalnis.

[2] Fouzia Altaf, Syed M. S. Islam, Naveed Akhtar, and Naeem Khalid Janjua. Going deep in medical image analysis: Concepts, methods, challenges, and future directions. *IEEE Access*, 7:99540–99572, 2019.

[3] Alberto Arezzo, Kaspar Althofer, Sébastien Ourselin, and Bruno Siciliano. ENDOTHERANOSTICS: Multi-Sensor Eversion Robot Towards Intelligent Endoscopic Diagnosis and Therapy. `https://endotheranostics.com`, 2025. Accessed: 2025-05-09.

[4] Asensus Surgical. Asensus surgical official website, 2025. Accessed: 2025-05-09.

[5] Angelica I. Aviles, Samar M. Alsaleh, Eduard Montseny, and Alicia Casals. V-anfis for dealing with visual uncertainty for force estimation in robotic surgery. In *Proceedings of the 2015 Conference of the International Fuzzy Systems Association and the European Society for Fuzzy Logic and Technology*, pages 1465–1472. Atlantis Press, 2015/06.

[6] Mahdi Azizian, May Liu, Iman Khalaji, Jonathan Sorger, Daniel Oh, and Simon Daimios. The da vinci surgical system. In *Handbook of robotic and image-guided surgery*, pages 39–55. Elsevier, 2020.

[7] M. Badiger and J. Mathew. Retrospective review of activation functions in artificial neural networks. In *Proceedings of Third International Conference on Communication, Computing and Electronics Systems, ICCCES 2021*. Springer, March 2022.

[8] Der-Lin Chow, Peng Xu, Eser Tuna, Siqi Huang, M Cenk Çavuşoğlu, and Wyatt Newman. Supervisory control of a davinci surgical robot. In *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 5043–5049. IEEE, 2017.

[9] Zonghe Chua, Anthony M. Jarc, and Allison M. Okamura. Toward force estimation in robot-assisted surgery using deep learning with vision and robot state. In *2021 IEEE International Conference on Robotics and Automation (ICRA)*, pages 12335–12341, 2021.

[10] Aruni Ghose, Amit Ghose, and Prokar Dasgupta. New surgical robots on the horizon and the potential role of artificial intelligence. *Investigative and Clinical Urology*, 59(4):221–222, 2018.

[11] IEEE Robots Guide. Da vinci, n.d. Accessed: 2025-05-09.

[12] Intuitive Surgical. Da vinci surgical systems, 2024. Accessed: 2025-05-07.

[13] Sejal Jaiswal. Multilayer perceptrons in machine learning: A comprehensive guide, 2024. Updated July 28, 2024, Accessed December 4, 2024.

[14] Matthew M. Kalscheur and Oguz Akbilgic. Ai-enabled ecg for paroxysmal atrial fibrillation detection: One step to closer to the finish line. *JACC: Clinical Electrophysiology*, 9(8, Part 3):1783–1785, 2023. Author manuscript available in PMC: 2024 Aug 1.

[15] Theodora Kastritsi and Zoe Doulgeri. A control method for time-variant rcm constraint in hands-on ramis procedures. In *2021 29th Mediterranean Conference on Control and Automation (MED)*, pages 729–734. IEEE, 2021.

[16] Theodora Kastritsi and Zoe Doulgeri. A passive control framework for a bilateral leader-follower robotic surgical setup imposing rcm and active constraints. In *2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 1175–1181. IEEE, 2022.

[17] Dani Kiyasseh, Runzhuo Ma, Taseen F. Haque, Brian J. Miles, Christian Wagner, Daniel A. Donoho, Animashree Anandkumar, and Andrew J. Hung. A vision transformer for decoding surgeon activity from surgical videos. *Nature Biomedical Engineering*, 7(6):780–796, 2023.

[18] J.L Lavanchy, Joel Zindel, Kadir Kirtac, Isabell Twick, Enes Hosgor, Daniel Candinas, and Guido Beldi. Automation of surgical skill assessment using a three-stage machine learning algorithm. *Scientific Reports*, 11(1):5197, 2021.

[19] Francisco Luongo, Ryan Hakim, Jessica H. Nguyen, Animashree Anandkumar, and Andrew J. Hung. Deep learning-based computer vision to recognize and classify suturing gestures in robot-assisted surgery. *Surgery*, 169(5):1240–1244, 2021.

[20] Murilo M Marinho, Bruno V Adorno, Kanako Harada, Kyoichi Deie, Anton Deguet, Peter Kazanzides, Russell H Taylor, and Mamoru Mitsuishi. A unified framework for the teleoperation of surgical robots in constrained workspaces. In *2019 international conference on robotics and automation (ICRA)*, pages 2721–2727. IEEE, 2019.

[21] Ali A. Nazari, Farrokh Janabi-Sharifi, and Kourosh Zareinia. Image-based force estimation in medical applications: A review. *IEEE Sensors Journal*, 21(7):8805–8830, 2021.

[22] Yen Hoang Nguyen. Scoliosis detection using deep neural network. *arXiv preprint arXiv:2210.17269*, October 2022. Licensed under CC BY 4.0.

[23] Ch. Nimsky, J. Rachinger, H. Iro, and R. Fahlbusch. Adaptation of a hexapod-based robotic system for extended endoscope-assisted transsphenoidal skull base surgery. *Minimally Invasive Neurosurgery*, 47(1):41–46, February 2004.

[24] Allison M Okamura. Haptic feedback in robot-assisted minimally invasive surgery. *Current opinion in urology*, 19(1):102–107, 2009.

[25] Theodore Pappas, Anthony Fernando, and Mohan Nathan. Senhance surgical system: Robotic-assisted digital laparoscopy for abdominal, pelvic, and thoracoscopic procedures. In *Handbook of Robotic and Image-Guided Surgery*, pages 1–14. Elsevier, 2020.

[26] Cong D Pham, Fernando Coutinho, Antonio C Leite, Fernando Lizarralde, Pål J From, and Rolf Johansson. Analysis of a moving remote center of motion for robotics-assisted minimally invasive surgery. In *2015 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 1440–1446. IEEE, 2015.

[27] Patrick Probst. A review of the role of robotics in surgery: To davinci and beyond! *Missouri Medicine*, 120(5):389–396, sep-oct 2023.

[28] Hamid Sadeghian, Fatemeh Zokaei, and Shahram Hadian Jazi. Constrained kinematic control in minimally invasive robotic surgery subject to remote center of motion constraint. *Journal of intelligent & robotic systems*, 95:901–913, 2019.

[29] J Sandoval, Pierre Vieyres, and Gérard Poisson. Generalized framework for control of redundant manipulators in robot-assisted minimally invasive surgery. *IRBM*, 39(3):160–166, 2018.

[30] Guilian Su, Tian Liang, and Mei Wang. Prediction of vessel traffic volume in ports based on improved fuzzy neural network. *IEEE Access*, 2020.

[31] Hang Su, Yunus Schmirander, Zhijun Li, Xuanyi Zhou, Giancarlo Ferrigno, and Elena De Momi. Bilateral teleoperation control of a redundant manipulator with an rcm kinematic constraint. In *2020 IEEE International Conference on Robotics and Automation (ICRA)*, pages 4477–4482. IEEE, 2020.

[32] Hang Su, Chenguang Yang, Giancarlo Ferrigno, and Elena De Momi. Improved human–robot collaborative control of redundant robot for teleoperated minimally invasive surgery. *IEEE Robotics and Automation Letters*, 4(2):1447–1453, 2019.

[33] Boukeye Boubacar Traore, Bernard Kamsu-Foguem, and Fana Tangara. Deep convolution neural network for image recognition. *Ecological Informatics*, 48:257–268, November 2018.

[34] Universal Robots. Ur3e collaborative robot. `https://www.universal-robots.com/products/ur3e/`, 2025. Accessed: 2025-05-29.

[35] Chris Varghese, Ewen M. Harrison, Greg O'Grady, and Eric J. Topol. Artificial intelligence in surgery. *Nature Medicine*, 30(5):1257–1268, 2024.

[36] Shiv Vignesh. The perfect fit for a dnn, July 2020. Published in Analytics Vidhya on Medium, 24 July 2020.

[37] Aneeq Zia, Andrew Hung, Irfan Essa, and Anthony Jarc. Surgical activity recognition in robot-assisted radical prostatectomy using deep learning. In Alejandro F. Frangi, Julia A. Schnabel, Christos Davatzikos, Carlos Alberola-López, and Gabor Fichtinger, editors, *Medical Image Computing and Computer Assisted Intervention – MICCAI 2018*, pages 273–280, Cham, 2018. Springer International Publishing.

[38] Ιωάννα Γκαρτζονίκα. Ανίχνευση Διαβητικής Αμφιβληστροειδοπάθειας με χρήση Βαθιών Συνελικτικών Δικτύων, 2019. Επιβλέπων: Αναστάσιος Ντελόπουλος. Συμβουλευτική Επιτροπή: Δημήτριος Κουγιουμτζής, Ιωάννης Ρέκας.

[39] Χρήστος Στεφάνης. Σήματα και Συστήματα — Συνέλιξη και Συσχέτιση. `https://eclass.hmu.gr/modules/document/file.php/ECE151/erg5-convolution/conv-cross-corr-stefanis.pdf`, 2020. Σημειώσεις Μαθήματος, Τμήμα Ηλεκτρολόγων Μηχανικών Τ.Ε., ΕΛΜΕΠΑ.

Πίνακας Συμβολισμών

Σύμβολο	Περιγραφή	Διαστάσεις / Μονάδες
Γενικά / Γραμμική Άλγεβρα		
$SE(3)$	Special Orthogonal Group (πόζες: θέση & προσανατολισμός)	–
$SO(3)$	Special Euclidean Group	–
$\mathbf{I}_n$	Μοναδιαίος πίνακας $n \times n$	–
$\mathbf{0}$	Μηδενικό διάνυσμα/πίνακας κατά περίπτωση	–
$\|\mathbf{x}\|$	Ευκλείδεια νόρμα διανύσματος $\mathbf{x}$	–
∇	Τελεστής ανάδελτα	–
$\dot{(\cdot)}$	Παράγωγος ως προς χρόνο (π.χ. $\dot{\mathbf{p}}$)	/s, /s^2
$(\cdot)^\top$	Αντίστροφος (transpose)	–
$S(\mathbf{r})$	Αντισυμμετρικός πίνακας	
Κινηματική Ρομπότ		
$\mathbf{q} \in \mathbb{R}^n$	Διάνυσμα αρθρώσεων	rad
$\dot{\mathbf{q}}$	Ταχύτητες αρθρώσεων	rad/s
$\mathbf{p} \in \mathbb{R}^3$	Θέση άκρου (end-effector)	m
$\mathbf{R} \in SO(3)$	Πίνακας στροφής	–
$\mathbf{v} \in \mathbb{R}^3$	Γραμμική ταχύτητα άκρου	m/s
$\boldsymbol{\omega} \in \mathbb{R}^3$	Γωνιακή ταχύτητα άκρου	rad/s
$\mathbf{J}(\mathbf{q})$	Ιακωβιανή μήτρα	$6 \times n$
$\mathbf{J}^\dagger$	Ψευδοαντίστροφος της Ιακωβιανής	–
$\mathbf{e}_p$	Σφάλμα θέσης στο task space	m
$\mathbf{p}_d,\ \dot{\mathbf{p}}_d$	Επιθυμητή θέση και ταχύτητα άκρου	m, m/s
$\mathbf{V}_{\text{tool}}$	Ταχύτητα στο άκρο εργαλείου (follower)	m/s, rad/s
$\mathbf{V}_{\text{handle}}$	Ταχύτητα στο άκρο λαβής (leader)	m/s, rad/s
Έλεγχος (CLIK / Admittance / Haptics)		
$\mathbf{M}_d,\ \mathbf{D}_d,\ \mathbf{K}_d$	Εικονική μάζα–απόσβεση–ελατήριο (admittance)	kg, N·s/m, N/m
$\mathbf{F}_v,\ \boldsymbol{\tau}_v$	Εικονική δύναμη & ροπή απτικής καθοδήγησης (Vis2Haptics)	N, N·m
$E(t)$	Δεξαμενή Ενέργειας (energy tank)	J
Οπτική Εκτίμηση Παραμόρφωσης		
$\mathbf{p}_1$	Αρχή του διανύσματος παραμόρφωσης	px
$\mathbf{p}_2$	Τέλος του διανύσματος παραμόρφωσης	px

Πίνακας Συντομογραφιών

Συντομογραφία	Περιγραφή
RAMIS	Robotic-Assisted Minimally Invasive Surgery (Ρομποτικά Υποβοηθούμενη Ελάχιστα Επεμβατική Χειρουργική)
AI	Artificial Intelligence (Τεχνητή Νοημοσύνη)
ML	Machine Learning (Μηχανική Μάθηση)
DNN	Deep Neural Network (Βαθύ Νευρωνικό Δίκτυο)
RNN	Recurrent Neural Network (Αναδρομικό Νευρωνικό Δίκτυο)
CNN	Convolutional Neural Network (Συνελικτικό Νευρωνικό Δίκτυο)
ReLU	Rectified Linear Unit (Συνάρτηση Ενεργοποίησης)
MSE	Mean Square Error (Μέσο Τετραγωνικό Σφάλμα)
DCNN	Deep Convolutional Neural Network (Βαθύ Συνελικτικό Νευρωνικό Δίκτυο)
CLIK	Closed Loop Inverse Kinematics (Έλεγχος Κλειστού Βρόχου Αντίστροφης Κινηματικής)
UR3 / UR3e	Universal Robots 6 DoF collaborative robotic arms (ρομποτικοί βραχίονες Universal Robots)
RTDE	Real-Time Data Exchange (Πρωτόκολλο επικοινωνίας των UR ρομπότ)