

Σύστημα Υποστήριξης Κλινικών Αποφάσεων
για τη Νόσο των Ανευρυσμάτων Κοιλιακής Αορτής
Βασισμένο σε Μοντέλα Τεχνητής Νοημοσύνης



Παραδοτέο Π4.3

Εργαλείο Αιμοδυναμικής Ανάλυσης

Όνομα Αρχείου:	Safe-Aorta-D4.3-v1.0-Εργαλείο αιμοδυναμικής ανάλυσης ΑΚΑ.pdf	Επίπεδο Διάδοσης:	Δημόσιο
Ημερομηνία Υποβολής:	Αύγουστος 2025 (M24)	Κωδικός Έργου:	ΤΑΕΔΡ-0535983
Κοινοπραξία:	ΕΜΠ, ΠΔΜ, ΠΚ, ΕΛΜΕΠΑ, ΠΑΔΑ, ΙΙΒΕΑΑ, ΠΑΠΕΛ	Υπεύθυνος Παραδοτέου:	ΠΑΠΕΛ
Διάρκεια:	28 μήνες	Κατάσταση:	Τελική Έκδοση

ΛΙΣΤΑ ΣΥΓΓΡΑΦΕΩΝ

Συγγραφείς				
#	Επίθετο	Όνομα	Φορέας	Email Επικοινωνίας
1	Κυριακούδη	Κωνσταντίνα	ΠΙ-ΠΑΠΕΛ	k.kyriakoudi@uoi.gr
2	Χρηματόπουλος	Γρηγόριος	ΠΑΠΕΛ	g.chrimatopoulos@go.uop.gr
3	Κατσούδας	Σπυρίδων	ΠΙ-ΠΑΠΕΛ	spyroskatsoudas@gmail.com
4	Λιναρδόπουλος	Παναγιώτης	Εξ. Συνεργάτης ΠΙ-ΠΑΠΕΛ	plnardopoulos@gmail.com
5	Αραβανής	Θεοφάνης	ΠΑΠΕΛ	taravanis@uop.gr
6	Ξένος	Μιχαήλ	ΠΙ-ΠΑΠΕΛ	mxenos@uoi.gr
7	Τζιρτζιλάκης	Ευστράτιος	ΠΑΠΕΛ	etzirtzilakis@go.uop.gr
8	Φουρνιώτης	Νικόλαος	ΠΑΠΕΛ	nfou@uop.gr
9	Ασλάνη	Κυριακή-Ευαγγελία	ΠΑΠΕΛ	k.aslani@go.uop.gr
Συν-συγγραφείς				
#	Επίθετο	Όνομα	Φορέας	Email Επικοινωνίας
1	Κάβουρας	Διονύσης	ΠΑΔΑ	
2	Δημητριάδης	Αβταντίλ	ΕΛΜΕΠΑ	
3	Γκίκας	Στέφανος	ΕΛΜΕΠΑ	
4	Ζερβάκης	Μιχάλης	ΠΚ	
5	Σταυρουλάκης	Γιώργος	ΠΚ	
6	Ουγγρινής	Κωνσταντίνος- Αλκέτας	ΠΚ	
7	Διαγγελάκης	Νικόλαος	ΠΚ	
8	Μπέη	Αικατερίνη	ΠΚ	
9	Μοιρογιώργου	Κωνσταντία	ΠΚ	
10	Κλαδοβασιλάκης	Νίκος	ΠΚ	
11	Μουρατίδου	Αλίκη	ΠΚ	
12	Καρασμανόγλου	Απόστολος	ΠΚ	
13	Πολιτώφ	Κωνσταντίνος	ΠΚ	
14	Δαράκη	Μαρία Στυλιανή	ΠΚ	
15	Χατζηγιάννου	Αριστοτέλης	ΙΙΒΕΑΑ	
16	Αναγνωστόπουλος	Κωνσταντίνος	ΙΙΒΕΑΑ	

ΛΙΣΤΑ ΚΡΙΤΩΝ

Κριτές				
#	Επίθετο	Όνομα	Φορέας	Email Επικοινωνίας
1	Μανόπουλος	Χρήστος	ΕΜΠ	manopoul@central.ntua.gr
2	Ράπτης	Αναστάσιος	ΕΜΠ	raptistasos@mail.ntua.gr

ΕΛΕΓΧΟΣ ΑΝΑΘΕΩΡΗΣΗΣ

Έκδοση	Συγγραφέας	Ημερομηνία	Κατάσταση
0.1			Προσχέδιο
0.2			
0.3			
1.0		8/2025	Τελικό

Πίνακας Περιεχομένων

Πίνακας Περιεχομένων.....	3
Πίνακας Σχημάτων	5
Πίνακας Πινάκων.....	8
Λίστα Συντομογραφιών.....	9
Περίληψη	11
1. Επεξεργασία Ανευρισματικών δομών.....	12
1.1 Σκοπός του παραδοτέου.....	12
1.2 Υπόβαθρο.....	12
1.3 Ανάλυση Εργασιών.....	12
2. Δημιουργία και επεξεργασία δεδομένων για την τροφοδότηση ΤΝΔ	15
2.1 Σκοπός του παραδοτέου.....	15
2.2 Υπόβαθρο.....	15
2.3 Ανάλυση Εργασιών.....	16
2.4 Δημιουργία Νέφους Σημείων εντός μοντέλου αορτής	25
3. Εφαρμογή Νευρωνικού Δικτύου.....	26
3.1 Σκοπός του παραδοτέου.....	26
3.2 Υπόβαθρο.....	26
3.3 Ανάλυση Εργασιών.....	26
3.4 Προφίλ Δεδομένων	29
3.5. Αρχιτεκτονική και Εκπαίδευση Τεχνητού Νευρωνικού Δικτύου - MLP	33
3.6 Εξαρτήσεις Λογισμικού του Συστήματος.....	46
3.7 Εναλλακτικό Τεχνητό Νευρωνικό Δίκτυο - CNN.....	47
4. Εφαρμογή Docker για την υλοποίηση στην εφαρμογή ΨηφιΔΑ	50

4.1 Περιγραφή των Docker.....	51
4.2 Λήψη (pull) των Docker απο το DockerHub.....	51
4.3 Εκτέλεση των Docker.....	52
4.4 Αποτελέσματα.....	53
5. Δημοσιεύσεις και Συνέδρια.....	55
6. Βιβλιογραφία.....	57
7. Παράρτημα.....	58

Πίνακας Σχημάτων

Εικόνα 1. Διαδικασίες πακέτων Π.4.2, Π.4.3.

Εικόνα 2. Τομή Ανευρυσμάτων Κοιλιακής Αορτής.

Εικόνα 3. Διαχωρισμός Καλυμμάτων.

Εικόνα 4. Προσανατολισμός δομών μέσω Mimics.

Εικόνα 5. Προσανατολισμός δομών μέσω Mimics.

Εικόνα 6. Προσανατολισμός δομών.

Εικόνα 7. Δημιουργία πλέγματος.

Εικόνα 8. Συνθήκες RCR στο περιβάλλον MATLAB.

Εικόνα 9. Συνοριακές συνθήκες.

Εικόνα 10. Ενδεικτικές ανευρυσματικές δομές

Εικόνα 11. Αποτελέσματα ταχύτητας, πίεσης και διατμητικών τάσεων.

Εικόνα 12. Αποτελέσματα ταχύτητας και διατμητικών τάσεων για διάφορες δομές.

Εικόνα 13. Ρευματικές γραμμές (*streamlines*) για έξι μοντέλα ανευρυσμάτων κοιλιακής αορτής (*VAID3*, *VAID7*, *VAID53*, *T1-P8*, *T2-P4* και *T2-P17*) σε τρεις χρονικές φάσεις του καρδιακού κύκλου: *T1* (μέγιστη συστολή), *T2* (όψιμη συστολή) και *T3* (όψιμη διαστολή). Οι ροϊκές γραμμές αναδεικνύουν τις αιμοδυναμικές μεταβολές, με έμφαση στις περιοχές ανακυκλοφορίας και στον σχηματισμό δινών στο εσωτερικό των ανευρυσμάτων.

Εικόνα 14. Τομές ταχύτητας (*velocity slices*) για έξι επιλεγμένα μοντέλα ανευρυσμάτων κοιλιακής αορτής σε τρεις χρονικές στιγμές του καρδιακού κύκλου (*T1*: μέγιστη συστολή, *T2*: συστολική επιβράδυνση, *T3*: διαστολή). Οι τομές λαμβάνονται στον εγγύς αυχένα (*Y1*), στον σάκο του ανευρύσματος (*Y2*) και στον άπω αυχένα (*Y3*). Οι μονάδες ταχύτητας δίνονται σε *cm/s*.

Εικόνα 15. Χρονικά μέσες διατμητικές τάσεις τοιχώματος (*TAWSS*), δείκτης ταλαντούμενης διατμητικής τάσης (*OSI*) και σχετικός χρόνος παραμονής (*RRT*) για έξι μοντέλα ανευρυσμάτων κοιλιακής αορτής. Για κάθε περίπτωση παρουσιάζονται προβολές του πρόσθιου (+*Y*) και οπίσθιου (-*Y*) τοιχώματος. Οι μονάδες της *TAWSS* είναι *dyne/cm²*, ο δείκτης *OSI* είναι αδιάστατος και το *RRT* δίνεται σε *cm²/dyne*.

Εικόνα 16. Θερμικοί χάρτες (*heatmaps*) του συντελεστή συσχέτισης *Spearman* για (α) την υπονεφρική περιοχή και (β) την λαγόνια περιοχή της κοιλιακής αορτής. Η χρωματική κλίμακα αντιστοιχεί στις τιμές του συντελεστή συσχέτισης *Spearman* στο διάστημα $[-1, 1]$, ενώ η στατιστική σημαντικότητα αποδίδεται με τα σύμβολα **p-value* < 0.05, ***p-value* < 0.01, ****p-value* < 0.001.

Εικόνα 17. Αποτελέσματα σε μορφή excel.

Εικόνα 18. α) Νέφος σημείων στην αορτή και β) τοπικό χωρίο της αορτής με το νέφος σημείων του.

Εικόνα 19. Αρχιτεκτονική συστήματος για την εκτίμηση αιμοδυναμικών δεικτών μιας κοιλιακής αορτής

Εικόνα 20. Κατά προσέγγιση θέσεις των χρονικών φάσεων καρδιακού παλμού που το σύστημα λαμβάνει ως είσοδο.

Εικόνα 21. Η αρχιτεκτονική του μοντέλου Μηχανικής Μάθησης.

Εικόνα 22. Το αναπτυχθέν Τεχνητό Νευρωνικό Δίκτυο (κάτω) δύναται να ενεργήσει ως ένα ταχύτατο και ακριβές υποκατάστατο της αριθμητικής προσομοίωσης (επάνω).

Εικόνα 23. Δείγμα της μορφής των διαθέσιμων δεδομένων.

Εικόνα 24. Ιστογράμματα (histograms) των μεταβλητών πρόβλεψης, μέσω των οποίων αναπαρίστανται οπτικά οι κατανομές των τιμών των μεταβλητών του συνόλου εκπαίδευσης.

Εικόνα 25. Ιστογράμματα (histograms) των μεταβλητών πρόβλεψης, μέσω των οποίων αναπαρίστανται οπτικά οι κατανομές των τιμών των μεταβλητών του συνόλου επικύρωσης.

Εικόνα 26. Μέτρα περιγραφικής στατιστικής.

Εικόνα 27. Τρισδιάστατη κατανομή τιμών της πίεσης (*pressure*), της ταχύτητας (*w*), και της διατμητικής τάσης τοιχώματος (*WSS_Z*), για το χωρίο ενδιαφέροντος μιας κοιλιακής αορτής ($z \in [0.3, 0.8]$).

Εικόνα 28. Αφηρημένη απεικόνιση της τοπολογίας του *TNΔ* του συστήματος.

Εικόνα 29. *MSE* (πάνω) και *MAE* (κάτω) του *TNΔ* στα σύνολα εκπαίδευσης (*training*) και επικύρωσης (*validation*), κατά τη διαδικασία εκπαίδευσης.

Εικόνα 30. Μετρητικά σφάλματα *MSE*, *MAE* και *Relative Error* (%) των μεταβλητών πρόβλεψης για τη δευτερη χρονική φάση.

Εικόνα 31. Μετρητικά σφάλματα *MSE*, *MAE* και *Relative Error* (%) των μεταβλητών πρόβλεψης για τη πέμπτη χρονική φάση.

Εικόνα 32. Μετρητικά σφάλματα *MSE*, *MAE* και *Relative Error* (%) των μεταβλητών πρόβλεψης για τη δέκατη χρονική φάση.

Εικόνα 33. Μέσα Μετρητικά σφάλματα *MSE*, *MAE* και *Relative Error* (%) των μεταβλητών πρόβλεψης.

Εικόνα 34. Τρισδιάστατη απεικόνιση των προβλέψεων του *TNΔ* για ενδεικτικές μεταβλητές πρόβλεψης (δεξιά), και των τιμών αναφοράς, όπως εξήχθησαν από την αριθμητική προσομοίωση (αριστερά).

Εικόνα 35. Δισδιάστατες τομές, κατά μήκος του κατακόρυφου άξονα z, μιας κοιλιακής αορτής του συνόλου επικύρωσης, στις οποίες φαίνονται οι προβλέψεις του TND για ενδεικτικές μεταβλητές πρόβλεψης (δεξιά), καθώς και οι τιμές αναφοράς, όπως εξήχθησαν από την αριθμητική προσομοίωση (αριστερά).

Εικόνα 36. Τρόπος λειτουργίας του υλοποιηθέντος συστήματος.

Εικόνα 37. Αφηρημένη απεικόνιση αρχιτεκτονικής Συνελικτικού Νευρωνικού Δικτύου.

Εικόνα 38. MSE (πάνω) και MAE (κάτω) του ΣΝΔ στα σύνολα εκπαίδευσης (training) και επικύρωσης (validation), κατά τη διαδικασία εκπαίδευσης των 5 εποχών.

Εικόνα 39. Οι εντολές στο τερματικό (terminal) για τη λειτουργία του Docker.

Εικόνα 40. Φάκελοι με τα παραγόμενα αποτελέσματα.

Πίνακας Πινάκων

Πίνακας 1. Αποτελέσματα ταχύτητας, πίεσης και διατμητικών τάσεων.

Πίνακας 2. Χρονική φάση και φιλική ονομασία αυτής ενός καρδιακού παλμού.

Πίνακας 3. Κλάσεις Μεταβλητών.


Λίστα Συντομογραφιών

Συντομογραφία	Ορισμός
2D	Two Dimensional (δύο διαστάσεων)
AI	Artificial Intelligence (Τεχνητή Νοημοσύνη)
AKA	Ανευρυσμάτων Κοιλιακής Αορτής
BC	Boundary Condition (Οριακή Συνθήκη)
CFD	Computational Fluid Dynamics (Υπολογιστική Ρευστοδυναμική)
CGS	Centimetre–Gram–Second (σύστημα μονάδων)
CNN	Convolutional Neural Network (Συνελικτικό Νευρωνικό Δίκτυο)
CPU	Central Processing Unit
CT	Computed Tomography (Αξονική Τομογραφία)
DL	Deep Learning (Βαθιά Μάθηση)
Docker	Πλατφόρμα containerization εφαρμογών
EE	Ενότητα Εργασίας
FVM	Finite Volume Method (Μέθοδος Πεπερασμένων Όγκων)
HTML	HyperText Markup Language
Linux	Λειτουργικό σύστημα Linux
MAE	Mean Absolute Error (Μέσο Απόλυτο Σφάλμα)
MAPE	Mean Absolute Percentage Error (Μέσο Απόλυτο Ποσοστιαίο Σφάλμα)
MATLAB	Λογισμικό δημιουργίας κώδικα
ML	Machine Learning (Μηχανική Μάθηση)
MLP	Multilayer Perceptron
MSE	Mean Squared Error (Μέσο Τετραγωνικό Σφάλμα)
NMAE	Normalized Mean Absolute Error (Κανονικοποιημένο Μέσο Απόλυτο Σφάλμα)
NS	Navier–Stokes equations (Εξισώσεις Navier–Stokes)
RAM	Random Access Memory
RCR	Resistance–Compliance–Resistance (μοντέλο συνοριακών συνθηκών)
ReLU	Rectified Linear Unit
SimVascular	Λογισμικό αιμοδυναμικών προσομοιώσεων ανοιχτού κώδικα
STL	Μορφή αρχείων γεωμετρίας
TN	Τεχνητή Νοημοσύνη

VMTK	Vascular Modeling Toolkit
WSS / WSS_X / WSS_Y / WSS_Z	Διατμητικές τάσεις (Wall Shear Stress) και συνιστώσες
ΣΝΔ	Συνελικτικό Νευρωνικό Δίκτυο
ΤΝΔ	Τεχνητό Νευρωνικό Δίκτυο
ΤΝΔΒΜ	Τεχνητό Νευρωνικό Δίκτυο Βαθιάς Μάθησης

Περίληψη

Στην παρούσα αναφορά παρουσιάζονται οι εργασίες και τα αποτελέσματα της **Ενότητας Εργασίας (ΕΕ) 4**. Η ΕΕ 4 αφορά στην ανάπτυξη του Ψηφιακού Διδύμου της Αορτής και περιλαμβάνει τη μορφολογική ανάλυση των Ανευρυσμάτων Κοιλιακής Αορτής (ΑΚΑ) (**Π.4.2. Εργαλείο μορφολογικής ανάλυσης ΑΚΑ**), τη μελέτη της αιμοδυναμικής συμπεριφοράς τους, καθώς και την επεξεργασία των παραγόμενων αποτελεσμάτων με σκοπό την αξιοποίησή τους από μοντέλα Τεχνητής Νοημοσύνης (**Π.4.3. Εργαλείο αιμοδυναμικής-εμβιομηχανικής ανάλυσης ΑΚΑ**). Ειδικότερα, οι εργασίες επικεντρώνονται στην επεξεργασία ανευρυσματικών δομών που προέρχονται από νοσοκομειακές μονάδες της επικράτειας και στη μετατροπή τους σε κατάλληλη ψηφιακή μορφή, ώστε να είναι δυνατή η εκτέλεση αξιόπιστων αιμοδυναμικών προσομοιώσεων (**Εικόνα 1**). Τα αποτελέσματα των προσομοιώσεων αυτών χρησιμοποιούνται ως δεδομένα εισόδου για την εκπαίδευση και λειτουργία Τεχνητού Νευρωνικού Δικτύου Βαθιάς Μάθησης (Deep Learning Artificial Neural Network). Συμπληρωματικά περιγράφεται η ενσωμάτωση του Τεχνητού Νευρωνικού Δικτύου στο λογισμικό ΨηφίΔΑ (**Π.4.4. Λογισμικό ΨηφίΔΑ**), καθώς και η διασύνδεσή του με τα υπόλοιπα υποσυστήματα της πλατφόρμας μέσω τεχνολογιών containerization (Docker), εξασφαλίζοντας επεκτασιμότητα, διαλειτουργικότητα και αποδοτική διαχείριση των υπολογιστικών πόρων. Το συνολικό σύστημα αναπτύχθηκε στο πλαίσιο του έργου SAFE-AORTA, το οποίο στοχεύει στη δημιουργία ενός ολοκληρωμένου συστήματος υποστήριξης κλινικών αποφάσεων για τη νόσο των Ανευρυσμάτων Κοιλιακής Αορτής, βασισμένου σε προηγμένα μοντέλα Τεχνητής Νοημοσύνης, και στην ενσωμάτωσή του στο λογισμικό ΨηφίΔΑ.



Εικόνα 1. Διαδικασίες πακέτων Π.4.2 και Π.4.3.

1. Επεξεργασία Ανευρυσματικών δομών

Το πακέτο Μορφολογικής Ανάλυσης αφορά την επεξεργασία των ανευρυσματικών δομών που προέρχονται από αξονικές τομογραφίες (CT Scans).

1.1 Σκοπός του παραδοτέου

Ο σκοπός του παραδοτέου είναι η αναδόμηση ανευρυσματικών γεωμετριών από τα στοιχεία των ασθενών με την χρήση των δεδομένων από τις αξονικές τομογραφίες. Για τις γεωμετρίες αυτές απαιτείται να είναι σε κατάλληλη μορφή ώστε να είναι σύμφωνα με τις απαιτήσεις των αιμοδυναμικών εργαλείων.


1.2 Υπόβαθρο

Για την επίτευξη των απαιτήσεων της μορφολογικής ανάλυσης είναι απαραίτητη η γνώση χειρισμού λογισμικών όπως Mimics, VMTK, Meshmixer, με τα οποία γίνεται η κατάλληλη αναδόμηση και προετοιμασία των δομών για την χρήση τους για την ομάδα αιμοδυναμικής. Η ομάδα του ΠΑΠΕΛ για το συγκεκριμένο κομμάτι ασχολήθηκε με την βελτίωση των αρχικών δομών και την περαιτέρω επεξεργασία των δομών ώστε να είναι συμβατές και να μην δημιουργηθούν προβλήματα κατά την επίλυση της αιμοδυναμικής ανάλυσης.

1.3 Ανάλυση Εργασιών


Η υλοποίηση της αιμοδυναμικής προσομοίωσης προϋποθέτει την επεξεργασία των ανευρυσματικών δομών που προέρχονται από αξονικές τομογραφίες (CT Scans). Η διαδικασία περιλαμβάνει την απομόνωση και «καθαρισμό» των γεωμετριών ενδιαφέροντος, καθώς και την μετατροπή των αρχείων σε κατάλληλη μορφή για χρήση στα προγράμματα αιμοδυναμικής. Σε ορισμένες περιπτώσεις, οι δομές απαιτούσαν βελτιώσεις για να υποστηρίξεται η προσομοίωση στο επόμενο στάδιο. Για την εργασία αυτή έγινε χρήση λογισμικών ανοικτού κώδικα.

Η βελτιστοποίηση περιλαμβάνει την εκ νέου υπονεφρική τομή των κοιλιακών αορτών αλλά και την τομή των λαγονίων πριν την δεύτερη διακλάδωση τους, **Εικόνα 2**. Οι τομές έγιναν με την χρήση επιπέδων και έπειτα έγινε εξαγωγή των δομών σε μορφή αρχείων .stl.



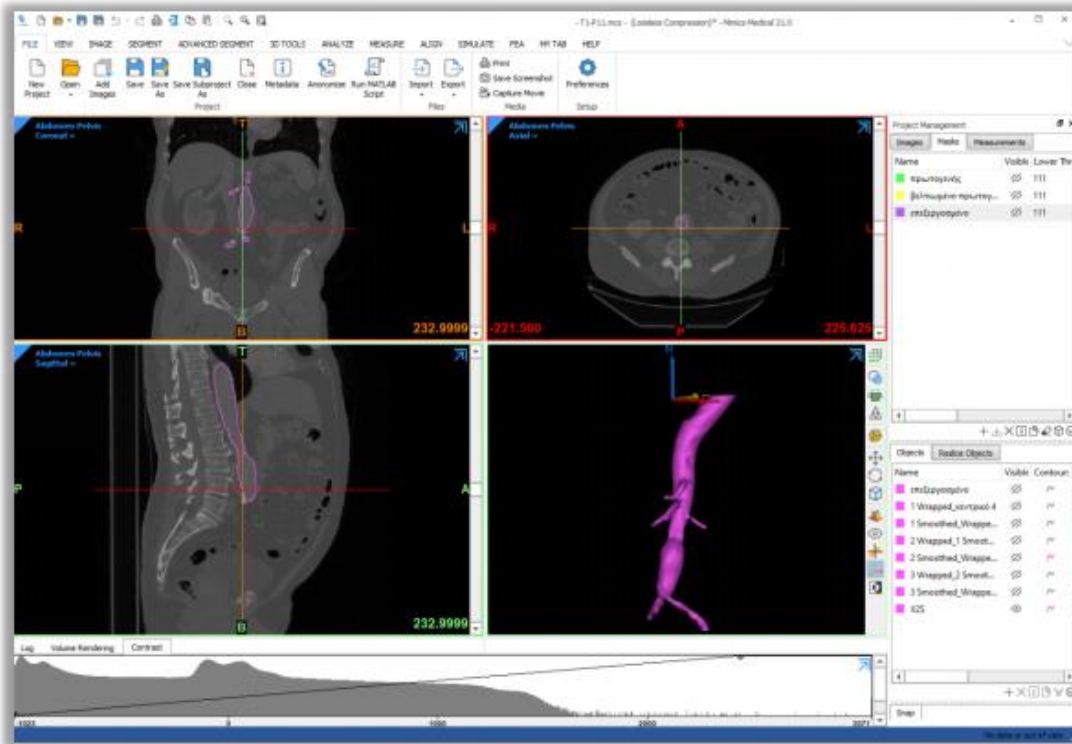
Εικόνα 2. Τομή Ανευρυσμάτων Κοιλιακής Αορτής.

Έπειτα γίνεται διαχωρισμός των τμημάτων του τοιχώματος και των καλυμμάτων στις εισόδους και εξόδους, **Εικόνα 3**. Τέλος γίνεται αφαίρεση των καλυμμάτων στις εισόδους-εξόδους των ΑΚΑ, όπως και η μετατροπή των μονάδων μέτρησης ώστε να συμβαδίζουν με τις απαιτήσεις των προσομοιώσεων αιμοδυναμικής.

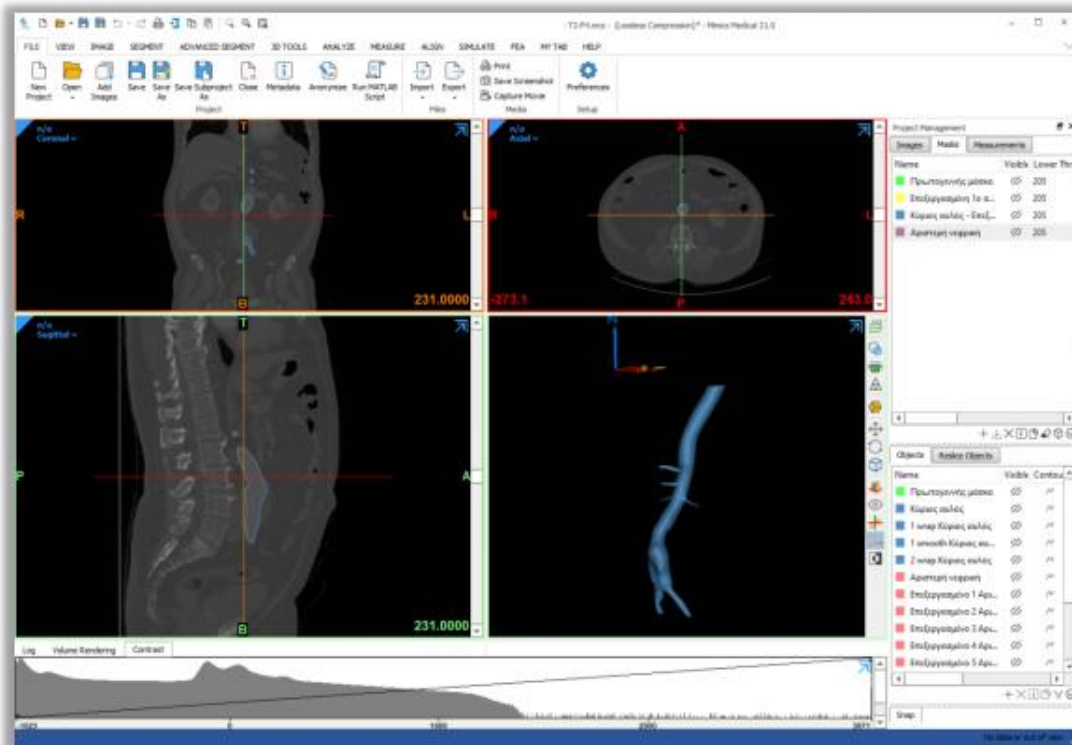


Εικόνα 3. Διαχωρισμός Καλυμμάτων.

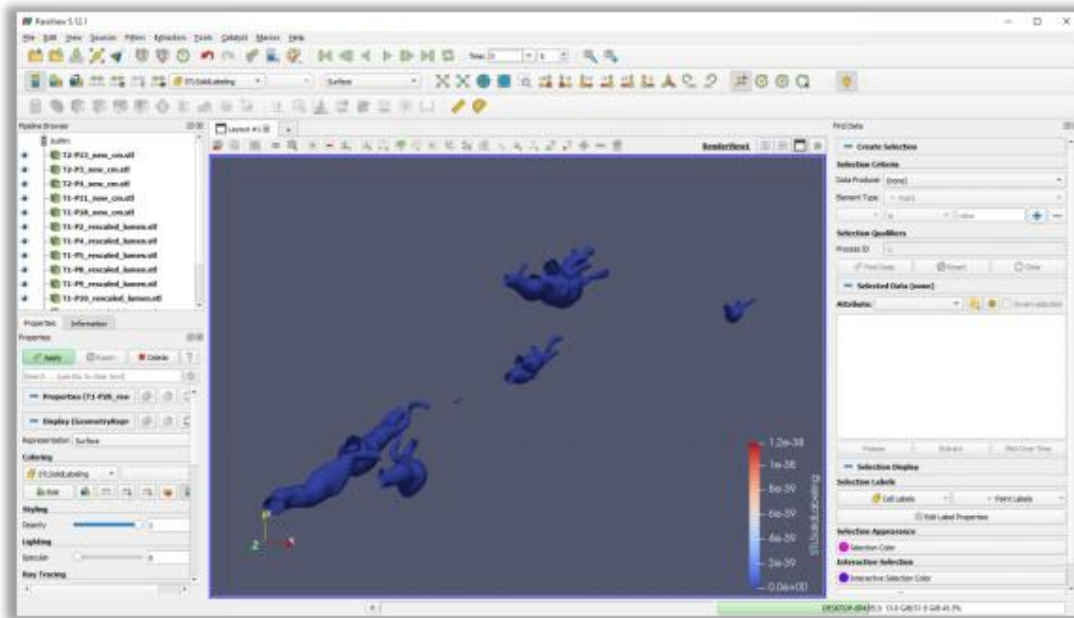
Επιπλέον αναφέρεται ότι όλες οι τελικές μορφές των ΑΚΑ έχουν τον ίδιο προσανατολισμό και πως οι διαστάσεις κανονικοποιήθηκαν για την επίτευξη ομοιομορφίας, **Εικόνες 4-6**.



Εικόνα 4. Προσανατολισμός δομών μέσω Mimics.



Εικόνα 5. Προσανατολισμός δομών μέσω Mimics.



Εικόνα 6. Προσανατολισμός δομών.

2. Δημιουργία και επεξεργασία δεδομένων για την τροφοδότηση ΤΝΔ

Το πακέτο της Αιμοδυναμικής αποσκοπεί στην δημιουργία των απαραίτητων δεδομένων για την είσοδο του Τεχνητού Νευρωνικού Δικτύου Βαθιάς Μάθησης, με τη χρήση επιλυτών ανοιχτού κώδικα (SimVascular). Η διαδικασία που ακολουθήθηκε περιλαμβάνει την εισαγωγή των δομών που προήλθαν από το τμήμα της μορφολογικής ανάλυσης, τη δημιουργία καλυμμάτων και την κατασκευή ενός αρχικού πλέγματος.

2.1 Σκοπός του παραδοτέου

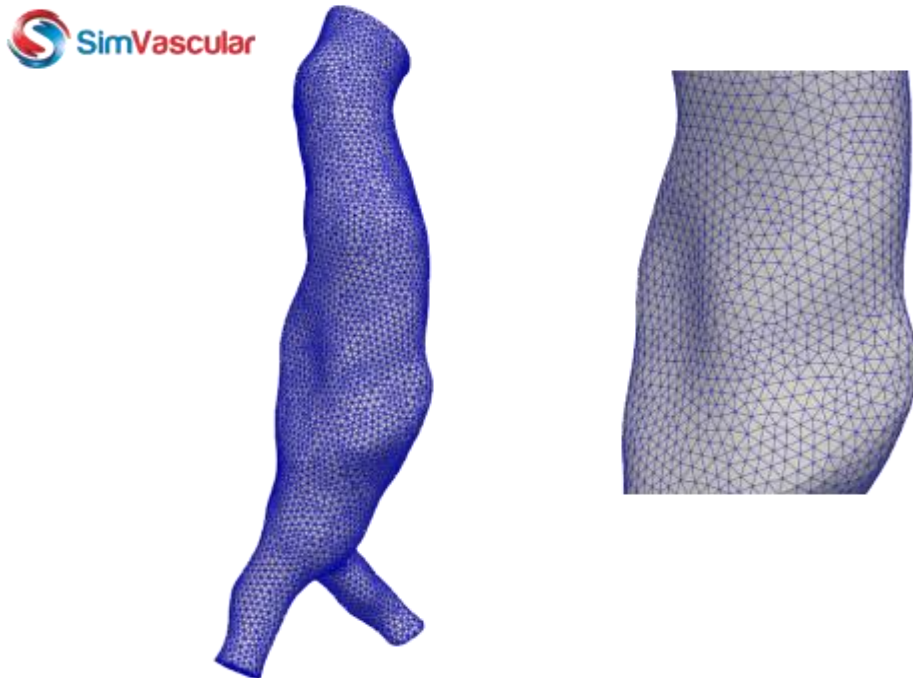
Σκοπός του πακέτου αυτού είναι η δημιουργία των απαραίτητων δεδομένων για την είσοδο του Τεχνητού Νευρωνικού Δικτύου Βαθιάς Μάθησης, με τη χρήση επιλυτών ανοιχτού κώδικα (SimVascular).

2.2 Υπόβαθρο

Για την επίτευξη των στόχων του πακέτου της Αιμοδυναμικής το υπόβαθρο των εργασιών απαιτεί γνώσεις βασικών αρχών ρευστομηχανικής, και επιπλέον την χρήση των υπολογιστικών εργαλείων SimVascular και Matlab.

2.3 Ανάλυση Εργασιών

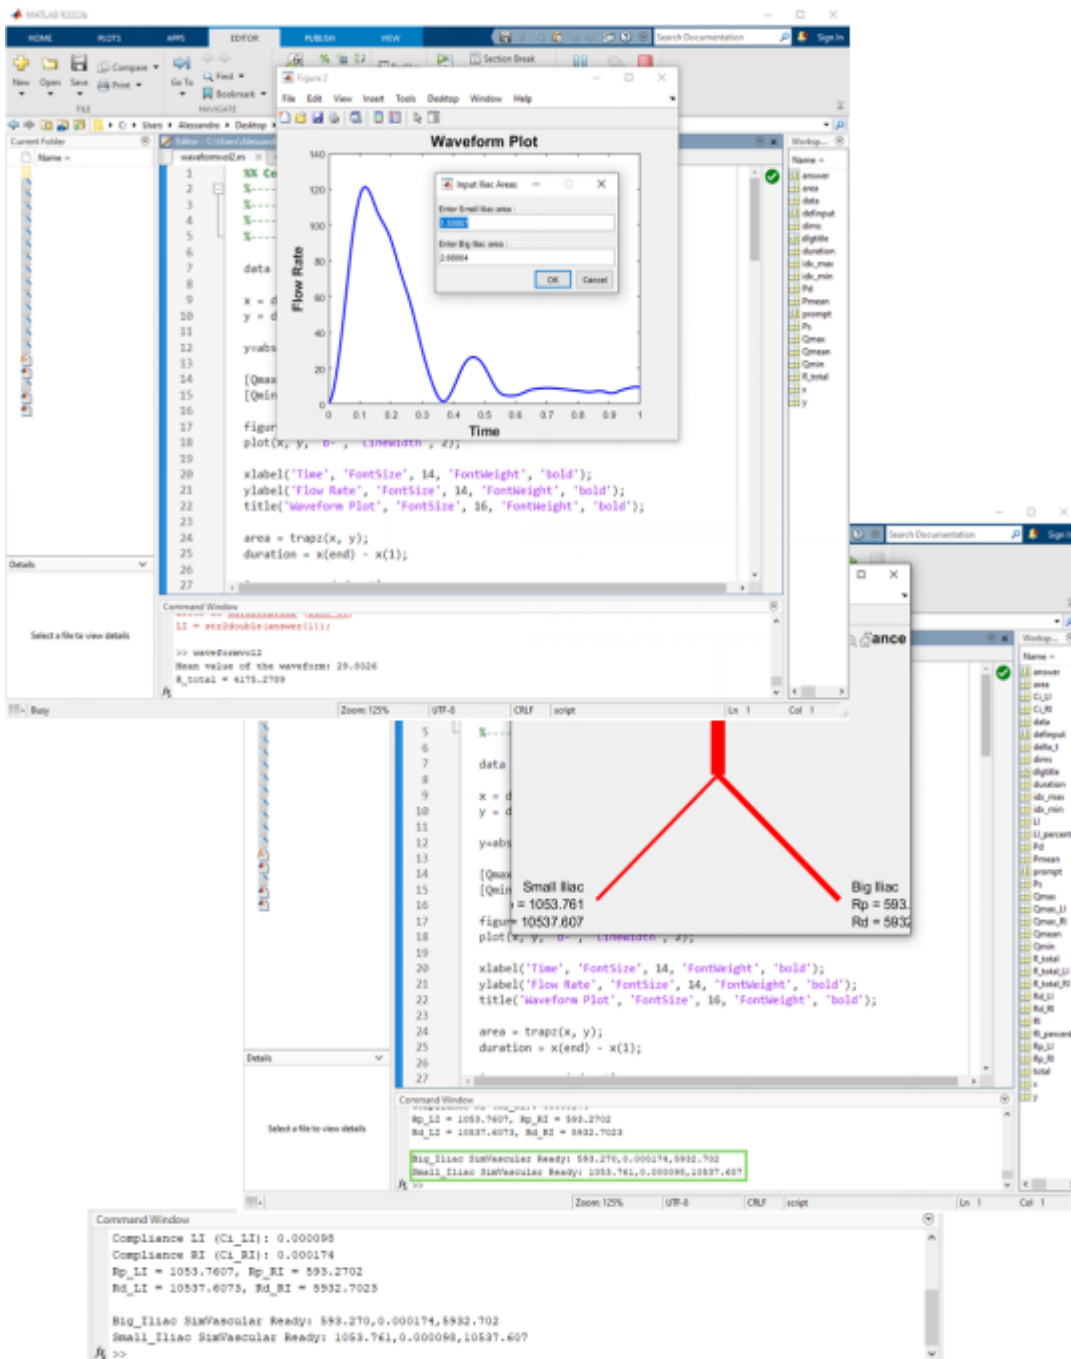
Η διαδικασία ξεκινά με την δημιουργία ενός ολικού πλέγματος, το μέγεθος του οποίου επιλέχθηκε ανάλογα με τις ιδιαιτερότητες της κάθε γεωμετρίας, **Εικόνα 7**.



Εικόνα 7. Δημιουργία πλέγματος.

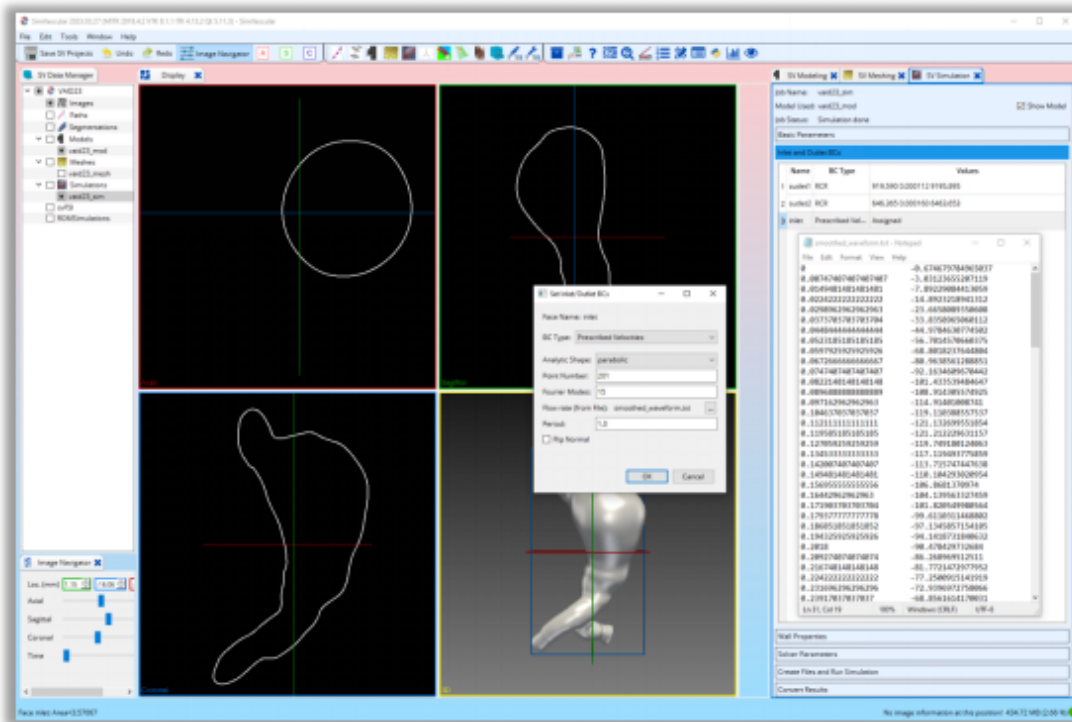
Κατά το στάδιο της προσομοίωσης, εισάγονται κατάλληλες παράμετροι που περιγράφουν την ροή τους αίματος στην είσοδο του ανευρύσματος και συνθήκες RCR στις λαγόνιες αρτηρίες.

Για τη σωστή ρύθμιση των τιμών RCR έχει αναπτυχθεί κώδικας σε περιβάλλον MATLAB R2023a (MathWorks, Natick, MA) που υπολογίζει τις τιμές με βάση το εμβαδόν των λαγονίων, **Εικόνα 8**.




Εικόνα 8. Συνθήκες RCR στο περιβάλλον MATLAB.

Η κυματομορφή που χρησιμοποιείται για την ροή στην είσοδο του ανευρύσματος έχει εξαχθεί από την βιβλιογραφία και έχει ρυθμιστεί ώστε να αντιστοιχεί σε πραγματικές τιμές παρόμοιες με εκείνες των ασθενών, **Εικόνα 9**.



Εικόνα 9. Συνοριακές συνθήκες.

Παρακάτω παρατίθενται κάποιες ενδεικτικές δομές για τις οποίες λάβαμε κατάλληλα αποτελέσματα, Εικόνα 10.



Εικόνα 10. Ενδεικτικές ανευρυσματικές δομές.

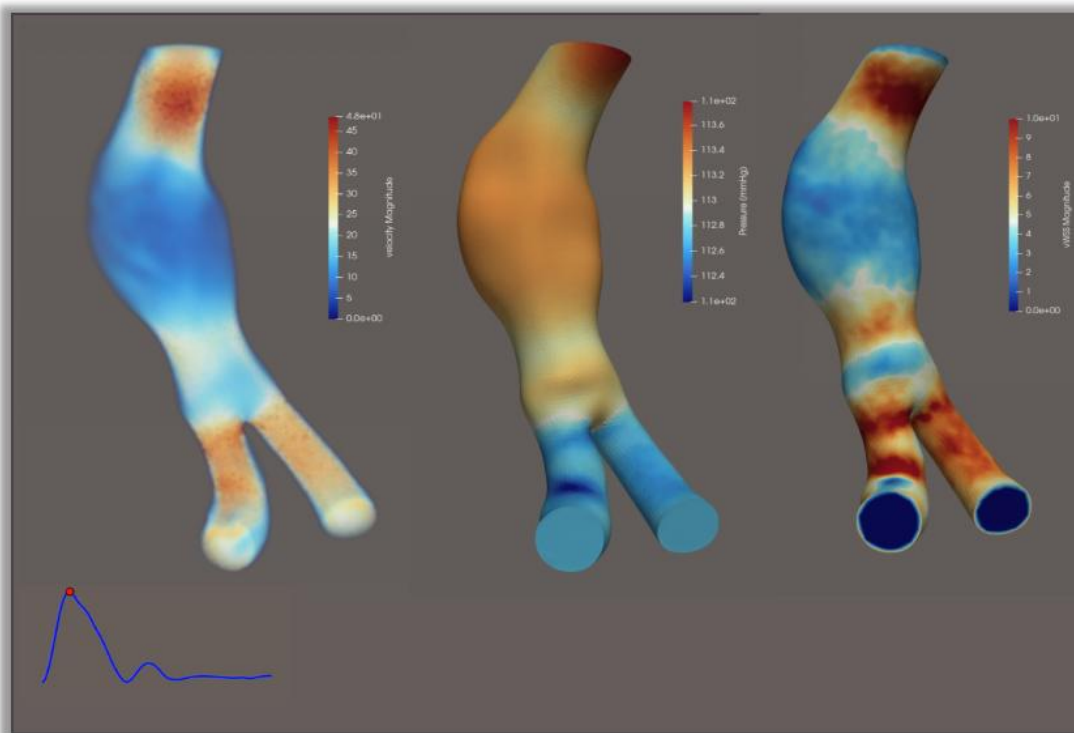
Συνολικά συλλέχθηκαν 143 δομές από διαφορετικές πηγές, κατανομημένες ως εξής:

- **Batch 1** 19 δομές
- **Batch 2** 11 δομές


- **Batch 3** 6 δομές
- **Batch 4** 15 δομές
- **Vasculaid** 92 δομές

Από το σύνολο των 143 δομών, πραγματοποιήθηκαν υπολογιστικές προσομοιώσεις σε 74 γεωμετρίες, καλύπτοντας διαφορετικές μορφολογικές παραλλαγές των ανευρυσμάτων της κοιλιακής αορτής. Οι υπολοιπες θα χρησιμοποιηθούν ως δεδομένα εισόδου για την εκπαίδευση και πρόβλεψη του νευρωνικού δικτύου, εξασφαλίζοντας ότι το μοντέλο θα έχει δυνατότητα γενίκευσης και αξιολόγησης σε νέα, μη χρησιμοποιημένα δείγματα.

Από τις δυναμικές προσομοιώσεις προέκυψαν δεδομένα όπως ταχύτητα, πίεση και τις διατμητικές τάσεις (Wall Shear Stress - WSS) κατά τη διάρκεια ενός καρδιακού παλμού. Οι προσομοιώσεις έγιναν για 8 καρδιακούς για την σταθεροποίηση των αποτελεσμάτων και την αποφυγή εξάρτησης τους από τις συνοριακές συνθήκες. Τα αποτελέσματα που παρατίθενται αναφέρονται στον όγδοο καρδιακό παλμό, **Εικόνα 11** και **Εικόνα 12** καθώς και **Πίνακας 1**.



Εικόνα 11. Αποτελέσματα ταχύτητας, πίεσης και διατμητικών τάσεων.

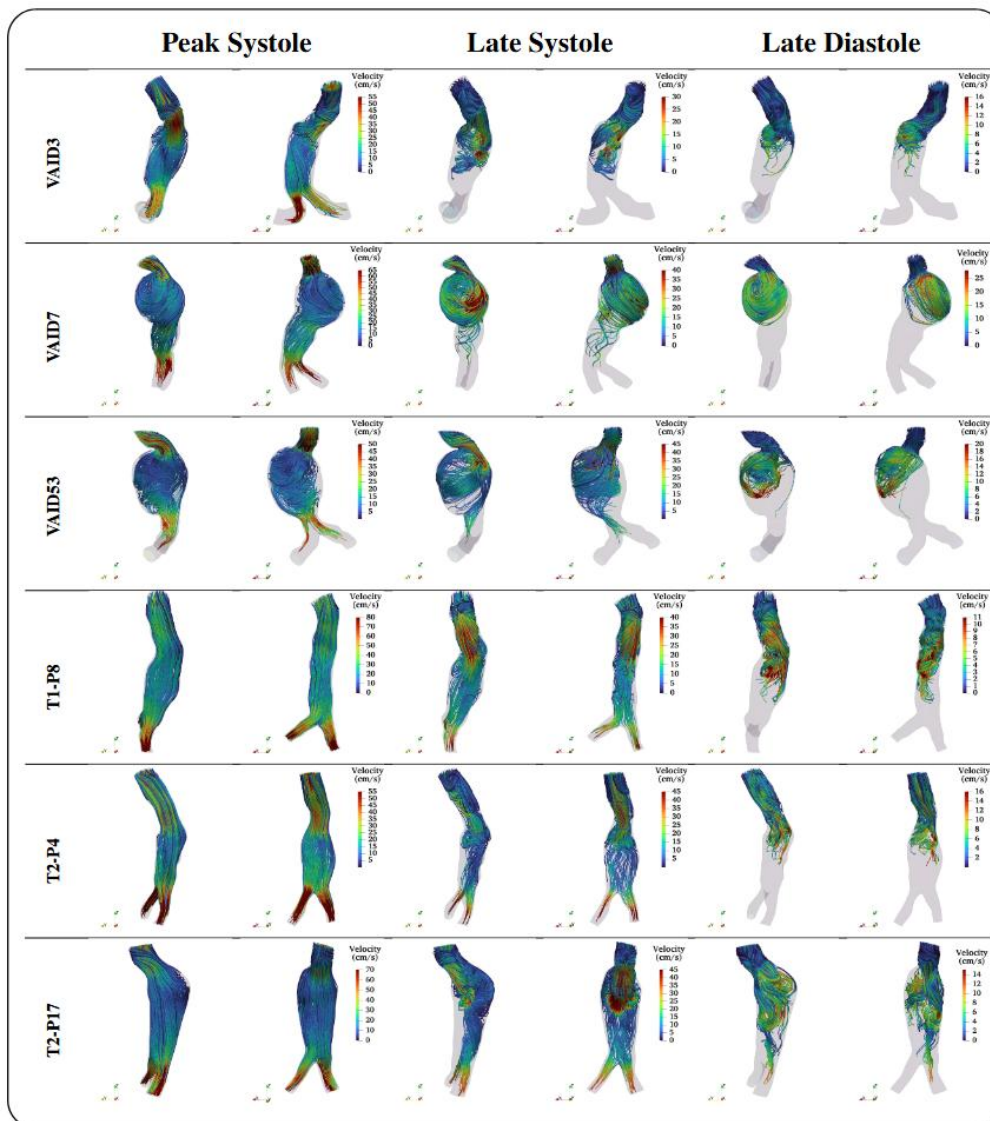


Εικόνα 12. Αποτελέσματα ταχύτητας και διατμητικών τάσεων για διάφορες δομές.

Δομές	Max Vel Mag	Pres Systolic	Pres Diastolic	Max WSS
1. T1-P10	0.85	117.393	74.5237	25.3373
2. B2-P33	1.69	118	76	45.4418
3. KMR15	1.3	121.9	80.1129	33.60
4. VAID7	1.2	123.265	71.7732	32.653
5. VAID40	0.5	121.579	71.721	12.6627

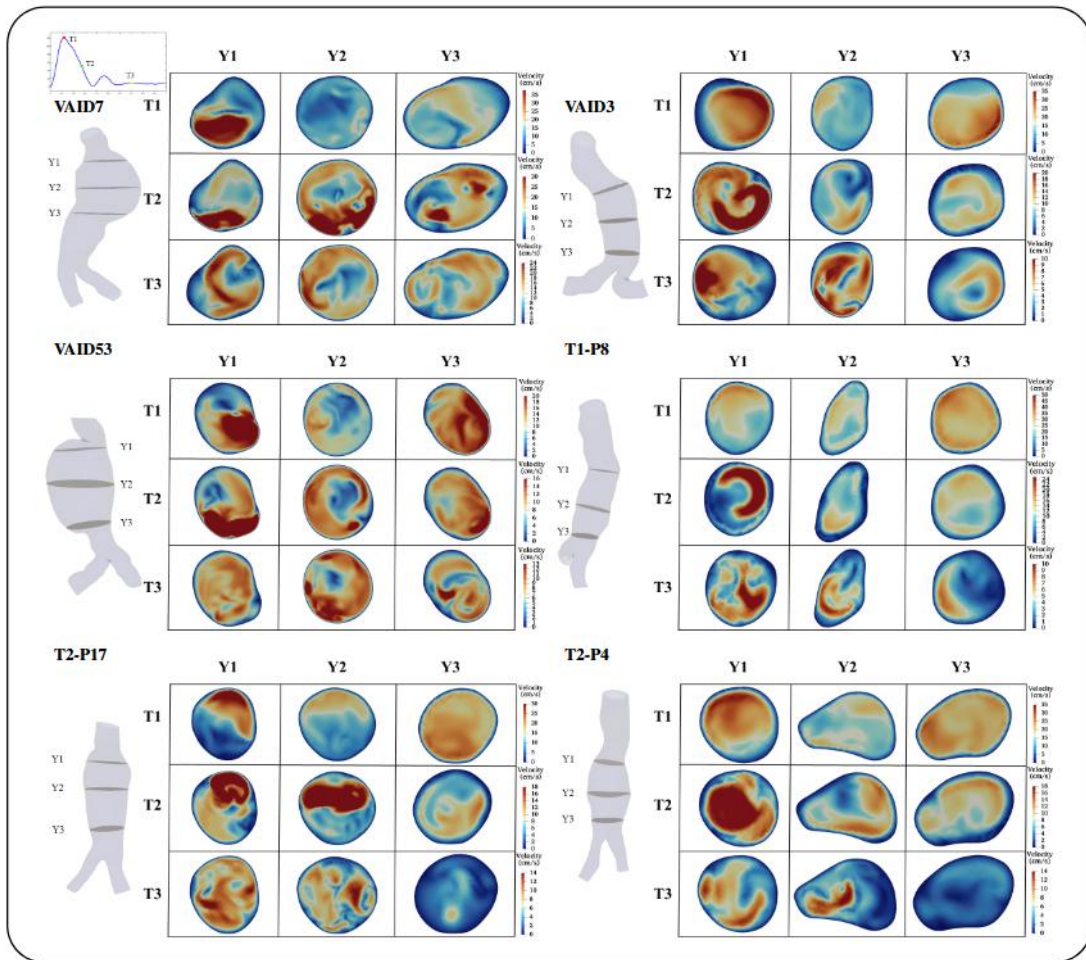
Πίνακας 1. Αποτελέσματα ταχύτητας, πίεσης και διατμητικών τάσεων.

Στην **Εικόνα 13**, παρατηρούνται οι ζώνες ανακυκλοφορίας, ιδιαίτερα στα μοντέλα VAID3, VAID7 και VAID53. Κατά τη συστολικής φάση (T1), τα μοντέλα T1-P8, T2-P4 και T2-P17 παρουσιάζουν πιο ομαλές ρευματικές γραμμές ενώ στα VAID3, VAID7 και VAID53 η ροή είναι διαταραγμένη, με χαοτικά μοτίβα, ιδιαίτερα στην μέση των ανευρυσμάτων.



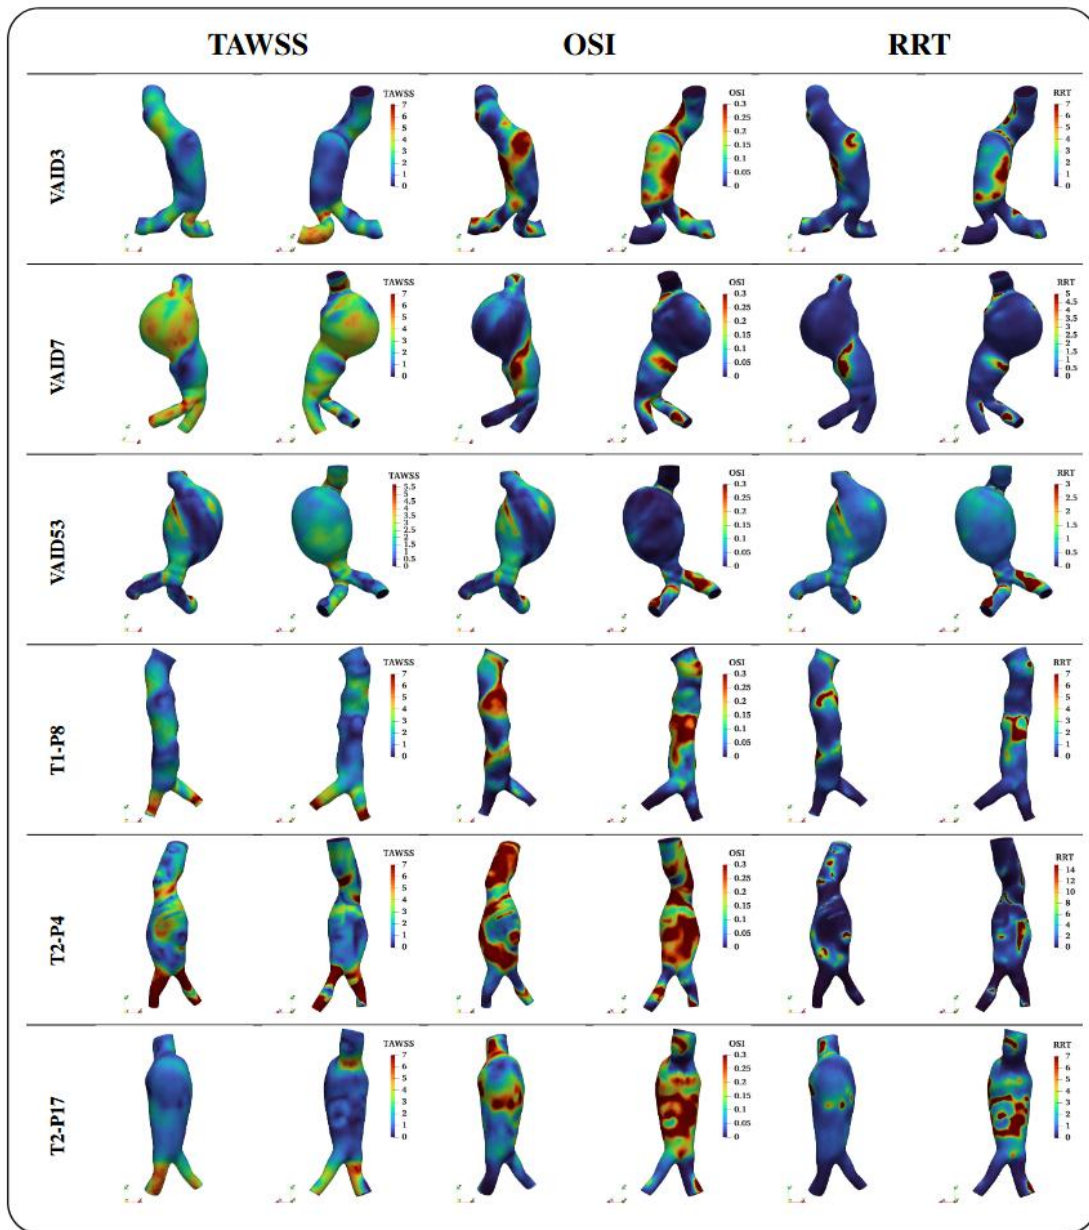
Εικόνα 13. Ρευματικές γραμμές (streamlines) για έξι μοντέλα ανευρυσμάτων κοιλιακής αορτής (VAID3, VAID7, VAID53, T1-P8, T2-P4 και T2-P17) σε τρεις χρονικές φάσεις του καρδιακού κύκλου: **T1** (μέγιστη συστολή), **T2** (όψιμη συστολή) και **T3** (όψιμη διαστολή). Οι ροϊκές γραμμές αναδεικνύουν τις αιμοδυναμικές μεταβολές, με έμφαση στις περιοχές ανακυκλοφορίας και στον σχηματισμό δινών στο εσωτερικό των ανευρυσμάτων.

Στην **Εικόνα 14**, παρουσιάζονται οι τομές της ταχύτητας σε έξι επιλεγμένες δομές. Κατά τη μέγιστη συστολική φάση (T1), η ροή υψηλής ταχύτητας εισέρχεται στον ανευρυσματικό σάκο (Y1), παράγοντας ροή δίπλα στο τοίχωμα. Στο μέσο του σάκου (Y2), σχηματίζονται στρόβιλοι και περιοχές ανακυκλοφορίας. Ενώ στο επίπεδο (Y3) η ροή γίνεται πιο ομοιόμορφη λόγω της συστολής της αορτής. Κατά την συστολική φάση (T2), η ροή επιβραδύνεται και δημιουργούνται πιο σύνθετες περιοχές ανακύκλωσης. Κατά τη διαστολική φάση (T3), η ταχύτητα μειώνεται σημαντικά, με πολλαπλές περιοχές ανακυκλοφορίας, δημιουργώντας ένα κοινό μοτίβο στα έξι μοντέλα.




Εικόνα 14. Τομές ταχύτητας (velocity slices) για έξι επιλεγμένα μοντέλα ανευρυσμάτων κοιλιακής αορτής σε τρεις χρονικές στιγμές του καρδιακού κύκλου (**T1**: μέγιστη συστολή, **T2**: συστολική επιβράδυνση, **T3**: διαστολή). Οι τομές λαμβάνονται στον εγγύς αυχένα (**Y1**), στον σάκο του ανευρύσματος (**Y2**) και στον άπω αυχένα (**Y3**). Οι μονάδες ταχύτητας δίνονται σε **cm/s**.

Η **Εικόνα 15.**, απεικονίζει τις τιμές TAWSS, OSI και RRT. Οι περιοχές χαμηλούς TAWSS μπορούν να συσχετιστούν με τη δημιουργία ενδοαυλικού θρόμβου και ενδοθηλιακή δυσλειτουργία. Στη στήλη των τιμών OSI παρατηρούμε τις περιοχές με έντονα διαταραγμένη ροή. Οι υψηλές τιμές RRT εμφανίζονται κυρίως στον σάκο του ανευρύσματος, υποδεικνύοντας παρατεταμένη παραμονή σωματιδίων αίματος και υψηλότερο κίνδυνο για τον σχηματισμό θρόμβου. Οι δείκτες αυτοί βοηθούν στον εντοπισμό περιοχών με παθολογική αιμοδυναμική και μπορούν να οδηγήσουν σε αποδυνάμωση ή ρήξη του τοιχώματος των αγγείων.



Εικόνα 15. Χρονικά μέσες διατμητικές τάσεις τοιχώματος (TAWSS), δείκτης ταλαντούμενης διατμητικής τάσης (OSI) και σχετικός χρόνος παραμονής (RRT) για έξι μοντέλα ανευρυσμάτων κοιλιακής αορτής. Για κάθε περίπτωση παρουσιάζονται προβολές του πρόσθιου (+Y) και οπίσθιου (-Y) τοιχώματος. Οι μονάδες της TAWSS είναι **dyne/cm²**, ο δείκτης OSI είναι αδιάστατος και το RRT δίνεται σε **cm²/dyne**.

Στην υπονεφρική περιοχή, **Εικόνα 16**, υπάρχει αρνητική συσχέτιση μεταξύ της μέγιστης διαμέτρου και των δεικτών TAWSS και OSI, υποδεικνύοντας ότι σε μεγαλύτερες διαμέτρους μειώνονται οι διατμητικές τάσεις του τοιχώματος. Στην περιοχή των λαγονίων, η μέγιστη διάμετρος παρουσιάζει αρνητική συσχέτιση με το TAWSS και θετική με τα OSI και RRT, τονίζοντας την σημαντική επίδραση της γεωμετρίας στην αιμοδυναμική.



Εικόνα 16. Θερμικοί χάρτες (heatmaps) του συντελεστή συσχέτισης Spearman για (α) την υπονεφρική περιοχή και (β) την λαγόνια περιοχή της κοιλιακής αορτής. Η χρωματική κλίμακα αντιστοιχεί στις τιμές του συντελεστή συσχέτισης Spearman στο διάστημα $[-1, 1]$, ενώ η στατιστική σημαντικότητα αποδίδεται με τα σύμβολα *p-value < 0.05, **p-value < 0.01, *** p-value < 0.001.

Τα αποτελέσματα αυτά θα αξιοποιηθούν είτε για την εκπαίδευση του Τεχνητού Νευρωνικού Δικτύου είτε για επικύρωση των προβλέψεων του. Για τον λόγο αυτό γίνεται η εξαγωγή των αποτελεσμάτων σε αρχεία Excel τα οποία περιλαμβάνουν τις συντεταγμένες της γεωμετρίας, τις συνοριακές συνθήκες πίεσης, ταχύτητας, τις πιέσεις και τις διαμητικές τάσεις του τοιχώματος, **Εικόνα 17.**

	A	B	C	D	E	F	G	H	I	J	K	L	M
1	vWSS:0	vWSS:1	vWSS:2	average_speed	average_pressure	pressure	velocity:0	velocity:1	velocity:2	Points:0	Points:1	Points:2	Pressure_bc
2	0.014198	-0.003361	0.089607	0	1479.4	1550.5	0	0	0	0.94647	-0.90715	29.561	200
3	0.01663	-0.014442	0.086861	0	1479.4	1549.8	0	0	0	0.93221	-0.75354	29.643	200
4	0.013034	-0.014297	0.099896	0	1479.6	1556	0	0	0	0.90755	-0.77037	29.473	200

Εικόνα 17. Αποτελέσματα σε μορφή Excel.

Προδιαγραφές συστημάτων

Όλες οι προσομοιώσεις πραγματοποιήθηκαν στα παρακάτω μηχανήματα:

- 4th Gen Intel(R) Core(TM) i7-4790, 3.60GHz και 16GB RAM
- Server Intel(R) Xeon(R) E5645 2.40GHz και 48GB RAM
- 12th Gen Intel(R) Core(TM) i7 12700 και 128GB RAM
- 13th Gen Intel(R) Core(TM) i9 13900 και 128GB RAM
- Server (2x) CPU Intel(R) Xeon(R) E5-2697v2 και 256GB RAM

2.4 Δημιουργία Νέφους Σημείων εντός μοντέλου αορτής


Εφόσον έχει ολοκληρωθεί η διαδικασία της δημιουργίας και επεξεργασίας των αποτελεσμάτων πρέπει να γίνει η τροφοδότηση αυτών στο ΤΝΔ για την εκπαίδευση του. Για αυτό το σκοπό, παρατηρήθηκε ότι χρειάζεται και ένα “ψευδοπλέγμα” της εκάστοτε γεωμετρίας (μορφής .stl) με στόχο τη γενίκευση του μοντέλου. Για τη δημιουργία του “ψευδοπλέγματος” αποφασίστηκε από την ερευνητική ομάδα να τοποθετηθούν τυχαία σημεία μέσα στο μοντέλο.

Όντας τυχαία, υπάρχει το ενδεχόμενο τα σημεία αυτά να είναι σε μεγάλο ποσοστό διαφορετικά από τα σημεία του υπολογιστικού πλέγματος. Με αυτή τη μέθοδο όμως μειώνεται σημαντικά το υπολογιστικό κόστος καθώς δεν χρειάζεται από την αρχή και σε κάθε γεωμετρία υπολογιστικό πλέγμα. Η κατασκευή αυτών των σημείων γίνεται μέσω κώδικα που θα είναι ενσωματωμένος στο τελικό σύστημα και δεν θα χρειάζεται παρέμβαση και επιπλέον μάθηση από τον εμπειρογνώμονα.

Αρχικά τα όρια της εκάστοτε γεωμετρίας υπολογίζονται μέσω του αλγορίθμου. Έπειτα υπολογίζεται το σύνορο της αορτής και δημιουργεί ένα καρτεσιανό χωρίο το οποίο γεμίζει με τυχαία σημεία. Στη συνέχεια ο αλγόριθμος δημιουργεί το νέφος των σημείων βασισμένο στα σημεία τα οποία βρίσκονται μέσα στη γεωμετρία, παραβλέπει δηλαδή όσα βρίσκονται έξω από αυτή. Τέλος, οι συντεταγμένες του νέφους σημείων γράφονται σε αρχεία Excel που θα χρησιμοποιηθούν από το νευρωνικό δίκτυο.

Στην **Εικόνα 18 α)** φαίνονται το νέφος σημείων μέσα στην αορτή καθώς στην **Εικόνα 18 β)** φαίνεται το νέφος των σημείων σε ένα συγκεκριμένο χωρίο της αορτής το οποίο θα χρησιμοποιηθεί από την ομάδα για την καλύτερη εκπαίδευση του νευρωνικού δικτύου. Για την εύρεση των σημείων μέσα στη γεωμετρία της αορτής έγινε χρήση της συνάρτησης:

[*inpolyhedron - are points inside a triangulated volume?*](#) by Sven



Εικόνα 18. α) Νέφος σημείων στην αορτή και **β)** τοπικό χωρίο της αορτής με το νέφος σημείων του.

3. Εφαρμογή Νευρωνικού Δικτύου

Το πακέτο της Μηχανικής Μάθησης αποσκοπεί στην υλοποίηση αλγορίθμου που εκπαιδεύεται στα δεδομένα των αιμοδυναμικών προσομοιώσεων και αποσκοπεί στην ακριβή πρόβλεψη αιμοδυναμικών παραμέτρων χωρίς την επανάληψη προσομοιώσεων και ό,τι περιλαμβάνεται σε αυτές.

3.1 Σκοπός του παραδοτέου

Η παρούσα ενότητα παρουσιάζει την προσέγγιση που ακολουθήθηκε για την ανάπτυξη ενός συστήματος *Μηχανικής Μάθησης* (Machine Learning) για την πρόβλεψη/εκτίμηση αιμοδυναμικών δεδομένων που αφορούν σε ΑΚΑ. Το σύστημα που παρουσιάζεται αποτελεί μονάδα του λογισμικού *ΨηφίΔΑ* (Ψηφιακό Δίδυμο Αορτής).

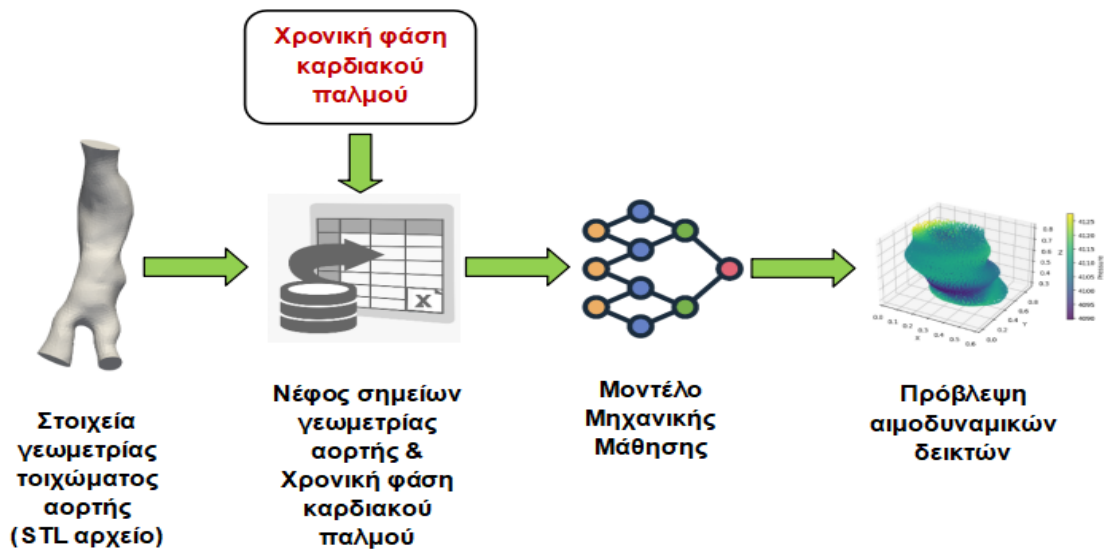
3.2 Υπόβαθρο

Για την επίτευξη των στόχων του πακέτου κατασκευής του μοντέλου Μηχανικής Μάθησης το υπόβαθρο των εργασιών απαιτεί γνώσεις βασικών αρχών μοντέλων Μηχανικής Μάθησης τόσο σε θεωρητικό επίπεδο όσο και σε πρακτικό με υλοποίηση σε γλώσσες προγραμματισμού όπως η Python με τα πακέτα που περιέχει.

3.3 Ανάλυση Εργασιών

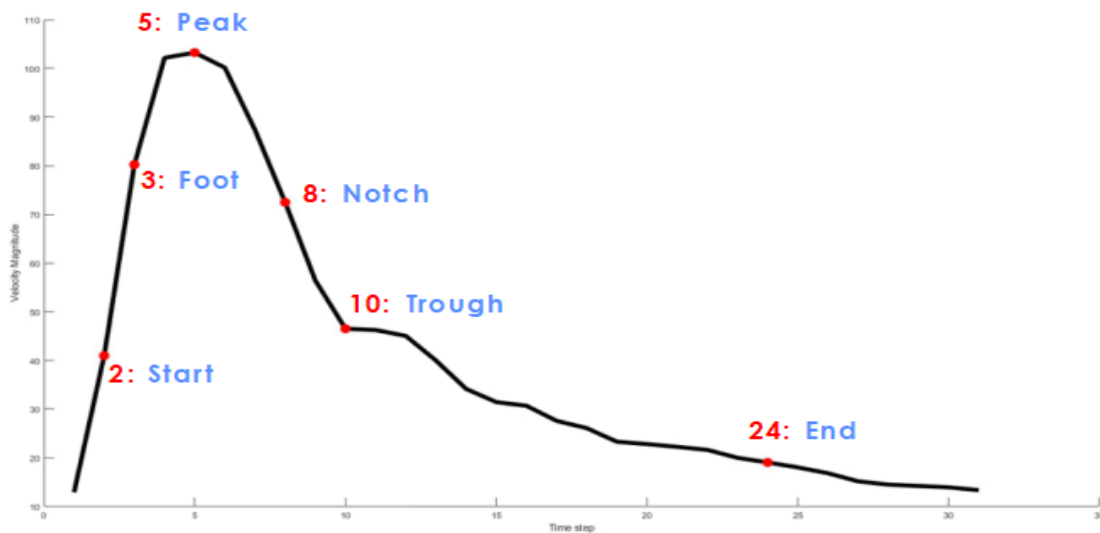
Η προσέγγιση που ακολουθήθηκε είναι εμπνευσμένη από την προσέγγιση των Liang, Liu, Martin, και Sun, “A deep learning approach to estimate stress distribution: A fast and accurate surrogate of finite-element analysis” (2018), εργασία που αποτελεί βασική αναφορά της Πρότασης του Έργου SAFE-AORTA.

Όπως φαίνεται στην **Εικόνα 19**, το υλοποιηθέν σύστημα αρχικά λαμβάνει ως είσοδο τα στοιχεία της *γεωμετρίας του τοιχώματος* μιας κοιλιακής αορτής, κωδικοποιημένα σε ένα αρχείο STL (Standard Triangle Language) καθώς και το νέφος σημείων που δημιουργείται από το αρχείο STL (Ενότητα 2.5. Δημιουργία Νέφους Σημείων εντός μοντέλου αορτής).



Εικόνα 19: Αρχιτεκτονική συστήματος για την εκτίμηση αιμοδυναμικών δεικτών μιας κοιλιακής αορτής.

Το νέφος σημείων συνδυάζεται με τη χρονική φάση ενός καρδιακού παλμού. Στην **Εικόνα 18**, παρουσιάζεται η (κατά προσέγγιση) θέση των χρονικών φάσεων καρδιακού παλμού που μπορεί το σύστημα να λάβει ως είσοδο.



Εικόνα 20: Κατά προσέγγιση θέσεις των χρονικών φάσεων καρδιακού παλμού που το σύστημα λαμβάνει ως είσοδο.

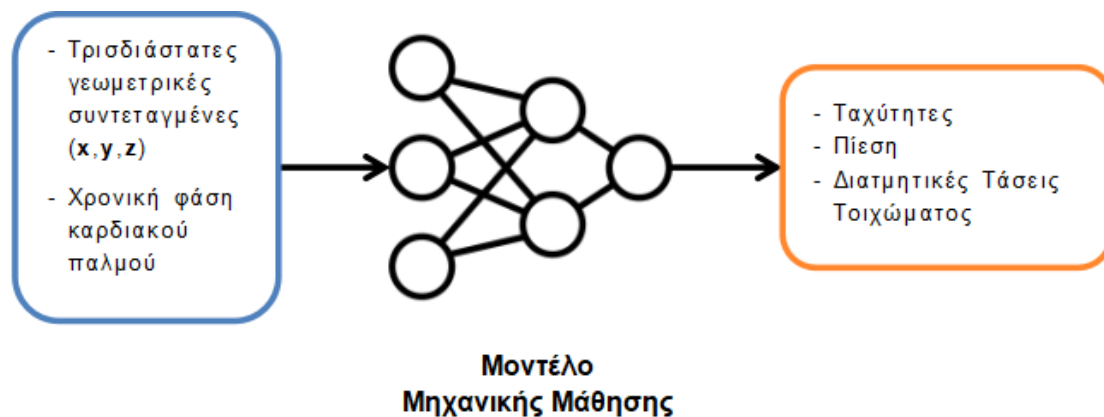
Αυτές συνοψίζονται και στον **Πίνακα 2**.

Χρονική Φάση	Φιλική Ονομασία
2	Start
3	Foot
5	Peak
8	Notch
10	Trough
24	End

Πίνακας 2. Χρονική φάση και φιλική ονομασία αυτής ενός καρδιακού παλμού.

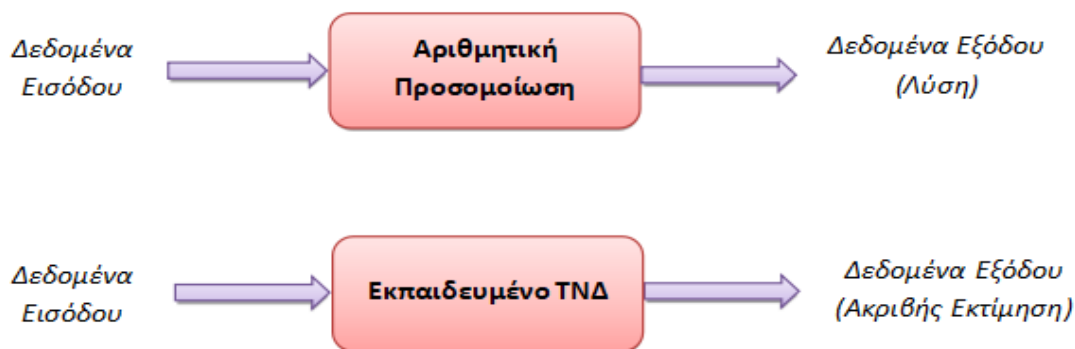
Ο συνδυασμός του νέφους σημείων της γεωμετρίας της αορτής και της χρονικής φάσης του καρδιακού παλμού καταγράφεται σε μορφή πίνακα (tabular form), ο οποίος και αποτελεί είσοδο του μοντέλου Μηχανικής Μάθησης. Τελικά, το μοντέλο Μηχανικής Μάθησης παράγει ως έξοδο μία πρόβλεψη/εκτίμηση για ένα σύνολο μη επεμβατικών αιμοδυναμικών δεικτών της αορτής. Με τη σειρά τους, οι δείκτες αυτοί ερμηνεύονται από τους εμπειρογνώμονες, οι οποίοι και λαμβάνουν αποφάσεις σχετικές με την πορεία ενός (ενδεχόμενου) ΑΚΑ.

Η αρχιτεκτονική του μοντέλου Μηχανικής Μάθησης αποτυπώνεται στην **Εικόνα 21**. Το μοντέλο λαμβάνει ως είσοδο το προαναφερθέν νέφος σημείων της γεωμετρίας μιας αορτής (σε μορφή τρισδιάστατων γεωμετρικών συντεταγμένων), καθώς και την προαναφερθείσα χρονική φάση του καρδιακού παλμού. Έξοδο του μοντέλου αποτελεί μία πρόβλεψη/εκτίμηση για ένα σύνολο μη επεμβατικών αιμοδυναμικών δεικτών της αορτής, όπως ταχύτητες, πίεση και διατμητικές τάσεις τοιχώματος.



Εικόνα 21. Η αρχιτεκτονική του μοντέλου Μηχανικής Μάθησης.

Τα δεδομένα στα οποία εκπαιδεύτηκε το σύστημα συλλέχθηκαν από μεγάλες νοσηλευτικές μονάδες της ελληνικής επικράτειας. Το σύστημα αναπτύχθηκε σε γλώσσα προγραμματισμού Python, και κτίστηκε στη βάση ενός μοντέλου Τεχνητού Νευρωνικού Δικτύου Βαθιάς Μάθησης (Deep-Learning Artificial Neural Network), το οποίο αποτελεί ένα πανίσχυρο εργαλείο Μηχανικής Μάθησης. Το εκπαιδευμένο σύστημα αναπαράγει τάχιστα ομοιότυπα αποτελέσματα με μία προσομοίωση Υπολογιστικής Ρευστοδυναμικής (Computational Fluid Dynamics – CFD), και ως εκ τούτου, δύναται να αποτελέσει ένα ταχύτατο υποκατάστατο της αντίστοιχης αριθμητικής προσομοίωσης, όπως απεικονίζεται στην **Εικόνα 22**. Ο πηγαίος κώδικας (source code) Python του συστήματος παρατίθεται στο Παράρτημα.



Εικόνα 22: Το αναπτυχθέν Τεχνητό Νευρωνικό Δίκτυο (κάτω) δύναται να ενεργήσει ως ένα ταχύτατο και ακριβές υποκατάστατο της αριθμητικής προσομοίωσης (επάνω).

3.4 Προφίλ Δεδομένων

Για την εκπαίδευση του συστήματος Μηχανικής Μάθησης, συλλέχθηκαν πρωτογενή δεδομένα από μεγάλες νοσοκομειακές μονάδες της ελληνικής επικράτειας. Αρχικά, τα πρωτογενή δεδομένα αποτέλεσαν είσοδο του *λογισμικού προσομοίωσης*, ανοικτού κώδικα, *SimVascular*, με τη βοήθεια του οποίου παρήχθησαν τα δεδομένα εκπαίδευσης (training) και επικύρωσης (validation) του Τεχνητού Νευρωνικού Δικτύου (ΤΝΔ) που αναπτύχθηκε. Τα δεδομένα εκπαίδευσης και επικύρωσης που αφορούν στο ΤΝΔ επεξεργάστηκαν και διαμορφώθηκαν κατάλληλα σε αρχεία Excel, και τελικά περιλαμβάνουν, για ένα σύνολο 74 αορτών, καταγραφές για τα εξής μεγέθη:

- Γεωμετρικές παράμετροι αορτών (Geometry)
- Ταχύτητες (Velocities)
- Πίεση (Pressure)
- Διατμητικές τάσεις τοιχώματος (Wall Shear Stresses – WSS)

Καθώς, όπως επισημάνθηκε προθύστερα, εξετάζονται οι 6 χρονικές φάσεις καρδιακού παλμού (**Εικόνα 20**), προέκυψαν συνολικά $74 \cdot 6 = 444$ δείγματα (samples). Σημειώνεται πως πραγματοποιήθηκε τυχαίος διαχωρισμός των δεδομένων σε ποσοστό περίπου 90/10 για την εκπαίδευση και την επικύρωση του ΤΝΔ. Συγκεκριμένα, το σύνολο εκπαίδευσης (training dataset) περιλαμβάνει 66 αορτές, δηλαδή συνολικά $66 \cdot 6 = 396$ δείγματα, ενώ το σύνολο επικύρωσης (validation dataset) περιλαμβάνει 8 αορτές, ήτοι $8 \cdot 6 = 48$ δείγματα. Για μία αποτελεσματική αξιολόγηση της επίδοσης του ΤΝΔ, τα δύο σύνολα είναι απολύτως διακριτά, δίχως καμία επικάλυψη δεδομένων.

Οι μονάδες μέτρησης των δεδομένων δίνονται στο σύστημα μονάδων CGS (Centimetre-Gram-Second). Στην **Εικόνα 23** φαίνεται ένα ενδεικτικό δείγμα της *μορφής* των διαθέσιμων δεδομένων, στο οποίο φαίνονται και οι μεταβλητές που υπεισέρχονται.

Γεωμετρικές Συντεταγμένες (cm)			Χρονική Φάση Καρδιακού Παλμού { 2, 3, 5, 8, 10, 24 }	Ταχύτητες (cm/s)			Πίση (dyne/cm ²)	Διαμητικές Τάσεις Τοιχώματος (dyne/cm ²)		
x	y	z	time	u	v	w	Pressure	WSS_X	WSS_Y	WSS_Z


Εικόνα 23. Δείγμα της μορφής των διαθέσιμων δεδομένων.

Όπως φαίνεται στον Πίνακα 3, οι μεταβλητές διακρίνονται σε δύο κλάσεις, στις μεταβλητές εισόδου του ΤΝΔ, και στις μεταβλητές εξόδου/μεταβλητές πρόβλεψης του ΤΝΔ.

	Φιλική Ονομασία	Τεχνική Ονομασία
Μεταβλητές Εισόδου	x	x
	y	y
	z	z
	time	time
Μεταβλητές Εξόδου – Μεταβλητές Πρόβλεψης	u	vx
	v	vy
	w	vz
	p	pressure
	WSS_X	wssx
	WSS_Y	wssy
	WSS_Z	wssz


Πίνακας 3. Κλάσεις Μεταβλητών.

Στα γραφήματα της Εικόνας 24 παρουσιάζεται ένα σύνολο ιστογραμμάτων (histograms) των μεταβλητών πρόβλεψης, μέσω των οποίων αναπαρίστανται οπτικά οι κατανομές των τιμών των μεταβλητών του συνόλου εκπαίδευσης. Καθώς οι απεικονισθείσες τιμές ανήκουν στο σύνολο εκπαίδευσης του ΤΝΔ, το τελευταίο, ουσιαστικά, καλείται να «μάθει»/κωδικοποιήσει αυτές τις κατανομές των τιμών των μεταβλητών.



Εικόνα 24. Ιστογράμματα (histograms) των μεταβλητών πρόβλεψης, μέσω των οποίων αναπαρίστανται οπτικά οι κατανομές των τιμών των μεταβλητών του συνόλου εκπαίδευσης.

Στα γραφήματα της **Εικόνας 25** παρουσιάζεται ένα σύνολο ιστογραμμάτων (histograms) των μεταβλητών πρόβλεψης, μέσω των οποίων αναπαρίστανται οπτικά οι κατανομές των τιμών των μεταβλητών του συνόλου επικύρωσης.



Εικόνα 25. Ιστογράμματα (histograms) των μεταβλητών πρόβλεψης, μέσω των οποίων αναπαρίστανται οπτικά οι κατανομές των τιμών των μεταβλητών του συνόλου επικύρωσης.

Επιπροσθέτως, παρακάτω απεικονίζονται ορισμένα μέτρα περιγραφικής στατιστικής (descriptive statistics) των μεταβλητών πρόβλεψης των συνόλων εκπαίδευσης και επικύρωσης, όπως ο μέσος όρος (mean), η τυπική απόκλιση (std), οι ελάχιστες και μέγιστες τιμές (min, max), καθώς και τα ποσοστιαία σημεία (25%, 50%, 75%).


	vx	vy	vz	pressure	wssx	wssy	wssz
mean	-0,34807	0,156296	-6,40973	136014,4	-0,02865	0,078386	-0,388
std	8,028739	7,717509	11,16197	23525,57	1,498762	1,333664	1,864493
min	-463,954	-141,679	-271,975	40061,81	-113,034	-41,0502	-73,1434
25%	-2,56779	-2,2541	-9,68868	110522,4	0	0	0
50%	0	0	-3,25682	143475	0	0	0
75%	1,879039	2,394077	0	159094,4	0	0	0
max	272,3115	270,2143	81,7152	210117,1	80,35048	84,47315	33,31946

	v _x	v _y	v _z	pressure	w _{ssx}	w _{ssy}	w _{ssz}
mean	-0,76965	0,272156	-6,26403	138958,8	-0,03673	0,113562	-0,44516
std	7,980099	8,520051	13,06814	24303,28	1,5513	1,662952	2,479275
min	-310,676	-177,669	-342,438	103643,9	-77,5386	-45,5034	-87,3412
25%	-2,70071	-2,23975	-8,99456	110773,9	0	0	0
50%	0	0	-3,14193	144201,2	0	0	0
75%	1,350197	2,24443	0	159987,9	0	0	0
max	193,2117	239,8596	70,45831	232341,9	56,47579	63,6909	18,17196

Εικόνα 26. Μέτρα περιγραφικής στατιστικής.

Επισημαίνεται ότι τόσο τα δεδομένα του συνόλου εκπαίδευσης, όσο και αυτά του συνόλου επικύρωσης, κανονικοποιήθηκαν στο εύρος $[0,1]$ για μία αποτελεσματικότερη διαχείρισή τους από το ΤΝΔ. Οι προβλέψεις του ΤΝΔ που θα χρησιμοποιηθούν/ερμηνευτούν από τους εμπειρογνώμονες από-κανονικοποιούνται στην αρχική τους κλίμακα.

Επιπροσθέτως, προκειμένου να επιτευχθεί μία ακριβέστερη πρόβλεψη από το ΤΝΔ, πραγματοποιήθηκε εστίαση σε ένα συγκεκριμένο χωρίο ενδιαφέροντος της αορτής, και συγκεκριμένα στην ευρύτερη περιοχή εντοπισμού του ανευρύσματος της αορτής (περιοχή αυξημένης πιθανότητας ρήξης). Δεδομένου ότι οι γεωμετρικές συντεταγμένες x , y , z κάθε αορτής έχουν κανονικοποιηθεί στο εύρος $[0,1]$, το επιλεγθέν χωρίο ενδιαφέροντος μιας αορτής προσδιορίζεται για $z \in [0.3, 0.8]$. Για το συγκεκριμένο χωρίο μιας αορτής, απεικονίζεται στην **Εικόνα 27**, η τρισδιάστατη κατανομή τιμών ορισμένων ενδεικτικών μεταβλητών, και συγκεκριμένα της πίεσης (pressure), της ταχύτητας (w), και της διατμητικής τάσης τοιχώματος (WSS_Z).




Εικόνα 27. Τρισδιάστατη κατανομή τιμών της πίεσης (pressure), της ταχύτητας (w), και της διατμητικής τάσης τοιχώματος (WSS_Z), για το χωρίο ενδιαφέροντος μιας κοιλιακής αορτής ($z \in [0.3, 0.8]$).

3.5. Αρχιτεκτονική και Εκπαίδευση Τεχνητού Νευρωνικού Δικτύου - MLP

Το Τεχνητό Νευρωνικό Δίκτυο (ΤΝΔ) του συστήματος είναι ένα Πολυστρωματικό Perceptron (Multilayer Perceptron – MLP) τεσσάρων επιπέδων, πλήρως διασυνδεδεμένων (fully connected), όπως αφηρημένα παρουσιάζεται στην **Εικόνα 28**. Συγκεκριμένα, το ΤΝΔ περιλαμβάνει ένα επίπεδο εισόδου (input layer) που απλώς λαμβάνει τις μεταβλητές εισόδου, δύο κρυφά επίπεδα (hidden layers), και ένα επίπεδο εξόδου (output layer) που παράγει τις εκτιμήσεις/προβλέψεις για τις μεταβλητές εξόδου. Καθώς οι μεταβλητές εισόδου είναι οι 4 μεταβλητές x , y , z και time, το επίπεδο εισόδου αποτελείται από 4 γραμμικούς (linear)

νευρώνες. Το κάθε κρυφό επίπεδο του ΤΝΔ αποτελείται από 100 νευρώνες, καθένας από τους οποίους είναι εφοδιασμένος με μία συνάρτηση ενεργοποίησης (activation function) Rectified Linear Unit (ReLU). Τέλος, καθώς οι μεταβλητές εξόδου είναι οι 7 μεταβλητές u , v , w , p , WSS_X , WSS_Y , και WSS_Z , το επίπεδο εξόδου αποτελείται από 7 γραμμικούς νευρώνες, καθένας από τους οποίους παράγει έναν πραγματικό αριθμό που αντιπροσωπεύει την πρόβλεψη για μία μεταβλητή.



Εικόνα 28. Αφηρημένη απεικόνιση της τοπολογίας του ΤΝΔ του συστήματος.

Κατά τη διαδικασία επιβλεπόμενης εκπαίδευσης του ΤΝΔ του συστήματος (supervised learning), λαμβάνει χώρα η επαναληπτική έκθεσή του στα κατάλληλα διαμορφωμένα δείγματα (samples) του συνόλου εκπαίδευσης (training dataset). Κάθε τέτοιο δείγμα περιλαμβάνει τις τιμές του επιπέδου εισόδου του ΤΝΔ, δηλαδή τις τιμές των μεταβλητών εισόδου, καθώς και τις τιμές (ετικέτα – label) που οφείλει να παράγει το ΤΝΔ στο επίπεδο εξόδου του (επιθυμητή έξοδος), δηλαδή τις τιμές των μεταβλητών εξόδου. Κατά την εκπαίδευση, τα συναπτικά βάρη (synaptic weights) του ΤΝΔ προσαρμόζονται έτσι ώστε η πραγματική έξοδος του ΤΝΔ να ταυτίζεται όσο το δυνατόν περισσότερο με την επιθυμητή έξοδο, αυτή δηλαδή που επιβάλλεται από τις ετικέτες του συνόλου εκπαίδευσης. Μία πλήρης έκθεση των δειγμάτων του συνόλου εκπαίδευσης στο ΤΝΔ αντιπροσωπεύει μία εποχή (epoch). Απώτερος σκοπός της διαδικασίας εκπαίδευσης είναι η γενίκευση της αποκτηθείσας γνώσης του ΤΝΔ, δηλαδή η εφαρμογή της γνώσης αυτής σε δείγματα στα οποία το ΤΝΔ δεν έχει εκτεθεί, όπως αυτά του συνόλου επικύρωσης (validation dataset).

Ως αλγόριθμος (κανόνας) εκπαίδευσης του ΤΝΔ του συστήματος ορίστηκε ο αλγόριθμος Adam, ο οποίος αποτελεί μία προέκταση του δημοφιλούς αλγορίθμου Στοχαστικής Επικλινούς Καθόδου (Stochastic Gradient Descent). Ως είδος σφάλματος (loss) του ΤΝΔ —το οποίο είναι το μέγεθος που προσπαθεί να ελαχιστοποιήσει ο αλγόριθμος εκπαίδευσης κατά τη διαδικασία εκπαίδευσης— ορίστηκε το Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error – MSE). Στο

τέλος κάθε εποχής εκπαίδευσης παρακολουθείται επίσης και το *Μέσο Απόλυτο Σφάλμα* (Mean Absolute Error – MAE) που επιτυγχάνει το ΤΝΔ, ενώ υπολογίζεται επίσης ένα κανονικοποιημένο MAE (Normalized MAE – NMAE) και ένα *Μέσο Απόλυτο Ποσοστιαίο Σφάλμα* (Mean Absolute Percentage Error – MAPE). Τα MSE, MAE, MAPE και NMAE ορίζονται ακολούθως, για μία προς πρόβλεψη μεταβλητή y .

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \cdot 100\%$$

$$\text{NMAE} = \frac{\text{MAE}}{\max(y) - \min(y)} \cdot 100\%$$

Στις παραπάνω σχέσεις, y_i είναι η τιμή αναφοράς της μεταβλητής y (όπως αυτή εξήχθη από την αριθμητική προσομοίωση), \hat{y}_i είναι η προβλεφθείσα τιμή της μεταβλητής y (όπως εξήχθη από το μοντέλο Μηχανικής Μάθησης), n είναι ο συνολικός αριθμός των δειγμάτων, και $\max(y)$, $\min(y)$ είναι η μέγιστη και ελάχιστη τιμή αναφοράς της μεταβλητής y , αντίστοιχα.

Για το παρόν ΤΝΔ που διαθέτει περισσότερους από έναν νευρώνες στο επίπεδο εξόδου του, και άρα περισσότερες από μία μεταβλητές προς πρόβλεψη, τα MSE και MAE προσδιορίζονται υπολογίζοντας τον μέσο όρο των σφαλμάτων για όλους τους νευρώνες εξόδου, για κάθε δείγμα, και στη συνέχεια λαμβάνοντας τον μέσο όρο για όλα τα δείγματα. Σημειώνεται ότι, καθώς το MSE τετραγωνίζει τα σφάλματα (διαφορές μεταξύ των προβλεπόμενων τιμών και των τιμών αναφοράς), οι προκύπτουσες τιμές του MSE δεν βρίσκονται στις ίδιες μονάδες με αυτές των μεταβλητών που προβλέπονται από το ΤΝΔ. Εν αντιθέσει, οι τιμές του MAE βρίσκονται στις ίδιες μονάδες με αυτές των μεταβλητών που προβλέπονται, καθιστώντας το MAE έναν πιο ερμηνεύσιμο δείκτη σφάλματος. Από την άλλη, τα MAPE και NMAE εκφράζουν ένα *σχετικό* σφάλμα (relative error), καθιστώντας τα ιδανικά για συγκρίσεις μεταξύ μεταβλητών. Βέβαια, το MAPE αποτελεί έναν ασταθή δείκτη σφάλματος όταν οι πραγματικές τιμές της μεταβλητής πρόβλεψης είναι μηδέν ή πολύ μικρές, ενώ το NMAE δίνει αντιπροσωπευτική εικόνα σφάλματος για μεταβλητές που διατηρούν ικανό εύρος τιμών.


Η εκπαίδευση του ΤΝΔ πραγματοποιήθηκε σε σύστημα εφοδιασμένο με επεξεργαστή 13th Gen Intel(R) Core(TM) i7-13700, 2.10 GHz, και 32 GB μνήμη RAM. Ο χρόνος εκπαίδευσης είναι της τάξεως των 30 λεπτών.

Όπως αναφέρθηκε προθύστερα, για μία αποτελεσματικότερη αξιολόγηση της διαδικασίας εκπαίδευσης του ΤΝΔ, χρησιμοποιήθηκε ένα σύνολο επικύρωσης *διαφορετικό* από το σύνολο εκπαίδευσης, γεγονός που εξασφάλισε την αξιολόγηση του ΤΝΔ σε δεδομένα στα οποία το ίδιο δεν είχε εκτεθεί κατά την εκπαιδευτική διαδικασία.

Οι βασικές υπερ-παράμετροι (hyper-parameters) του ΤΝΔ επιλέχθηκαν μέσω πειραματισμού για τη βελτιστοποίηση της απόδοσής του. Αυτές περιλαμβάνουν:

1. **Ρυθμός Εκμάθησης (Learning Rate):** Δοκιμάστηκαν διαφορετικοί ρυθμοί εκμάθησης (0.001, 0.0005, 0.0001), και επιλέχθηκε τελικά ο ρυθμός εκμάθησης 0.001, καθώς παρείχε σταθερή και αποδοτική σύγκλιση.
2. **Μέγεθος Παρτίδας (Batch Size):** Δοκιμάστηκαν μεγέθη παρτίδων 32, 64, 128 και 256, και επιλέχθηκε τελικά το μέγεθος παρτίδας 256, καθώς παρείχε ισορροπία μεταξύ υπολογιστικής αποδοτικότητας και ακρίβειας μοντέλου.
3. **Αριθμός Εποχών (Number of Epochs):** Το μοντέλο εκπαιδεύτηκε για έως και 50 εποχές. Ωστόσο, για την αποφυγή υπερπροσαρμογής (overfitting), εφαρμόστηκε η τεχνική της πρώιμης διακοπής εκπαίδευσης (early stopping), η οποία βασίστηκε στην απόδοση του ΤΝΔ στο σύνολο επικύρωσης.
4. **Κανονικοποίηση (Regularization):** Για την αντιμετώπιση του προβλήματος της υπερπροσαρμογής, χρησιμοποιήθηκε επίσης η τεχνική Dropout όπου ήταν απαραίτητο. Με την εφαρμογή της συγκεκριμένης τεχνικής, επιλεγμένοι νευρώνες του ΤΝΔ αγνοούνται τυχαία (“dropped out”) κατά τη διάρκεια της διαδικασίας εκπαίδευσης, και κατά συνέπεια, τα συναπτικά βάρη των αγνοημένων αυτών νευρώνων δεν ενημερώνονται/μεταβάλλονται.

Στην **Εικόνα 29**, παρουσιάζονται οι καμπύλες εκμάθησης (learning curves), που αντιπροσωπεύουν τις τιμές των MSE και MAE του ΤΝΔ. Οι παρουσιαζόμενες καμπύλες καταγράφουν τις τιμές των σφαλμάτων στα σύνολα εκπαίδευσης (training) και επικύρωσης (validation), κατά τη διαδικασία εκπαίδευσης του ΤΝΔ. Οι καμπύλες εκμάθησης του ΤΝΔ παρουσιάζουν σταθερή και ομαλή συμπεριφορά, χωρίς ενδείξεις υπερπροσαρμογής. Παρατηρείται ταχεία μείωση του MSE κατά τις πρώτες εποχές, και στη συνέχεια, σταθεροποίηση τόσο του σφάλματος εκπαίδευσης όσο και του σφάλματος επικύρωσης σε χαμηλές τιμές, γεγονός που υποδεικνύει επιτυχή σύγκλιση του μοντέλου. Η καμπύλη επικύρωσης παραμένει ελαφρώς χαμηλότερη από την αντίστοιχη της εκπαίδευσης, ενώ η διαφορά τους παραμένει μικρή και σταθερή, στοιχείο που επιβεβαιώνει την καλή γενίκευση του μοντέλου στα δεδομένα επικύρωσης. Συνεπώς, η διαδικασία εκπαίδευσης κρίνεται ικανοποιητική και τα αποτελέσματα αξιόπιστα.



Εικόνα 29. MSE (πάνω) και MAE (κάτω) του ΤΝΔ στα σύνολα εκπαίδευσης (training) και επικύρωσης (validation), κατά τη διαδικασία εκπαίδευσης.

Μετά το πέρας της εκπαίδευσης, το ΤΝΔ πέτυχε τις παρακάτω τιμές σφαλμάτων MSE και MAE στο σύνολο επικύρωσης.

MSE	$6.57 \cdot 10^{-4}$
MAE	0.0157

Δεδομένου ότι τα δεδομένα εκπαίδευσης και επικύρωσης έχουν κανονικοποιηθεί στο διάστημα [0,1], οι τιμές σφαλμάτων ($MSE = 6.57 \cdot 10^{-4}$ και $MAE = 0.0157$) θεωρούνται ιδιαίτερα χαμηλές. Αυτό υποδηλώνει πως το ΤΝΔ έχει επιτύχει υψηλή ακρίβεια στις προβλέψεις του, καθώς η μέση απόκλιση μεταξύ προβλεπόμενων τιμών και τιμών αναφοράς αντιστοιχεί μόλις στο **1,5%** περίπου του εύρους των κανονικοποιημένων δεδομένων.

Τα αποτελέσματα της συγκεκριμένης ενότητας αφορούν σε μία ενδεικτική αορτή του συνόλου επικύρωσης. Για την αορτή αυτή, στις **Εικόνες 30-32** παρουσιάζονται τα μετρητικά σφάλματα MSE, MAE και Relative Error (%), ξεχωριστά για κάθε μία από τις μεταβλητές πρόβλεψης, και για κάθε χρονική φάση (time phase) ενώ, στην **Εικόνα 33** παρουσιάζονται τα μέσα μετρητικά σφάλματα MSE, MAE και Relative Error (%) των μεταβλητών πρόβλεψης. Σημειώνεται ότι σε όλες τις μεταβλητές πρόβλεψης, εκτός της πίεσης (pressure), έχει υπολογιστεί το NMAE ως σχετικό σφάλμα. Για την πίεση χρησιμοποιήθηκε ο δείκτης MAPE, δεδομένου ότι οι τιμές της στο σύνολο επικύρωσης δεν παρουσιάζουν επαρκές εύρος.

Evaluate an unknown aorta | Time Phase = 2

Variable	MSE	MAE	Relative Error (%)
pressure	2077898.908	1353.557	1.204
vx	12.359	2.682	12.812
vy	16.007	3.097	13.387
vz	16.266	3.168	13.580
wssx	0.070	0.110	2.964
wssy	0.161	0.171	2.686
wssz	0.565	0.437	8.433

Evaluate an unknown aorta | Time Phase = 3

Variable	MSE	MAE	Relative Error (%)
pressure	1069045.397	799.844	0.576
vx	14.612	3.011	12.746
vy	23.008	3.777	8.899
vz	40.321	4.890	13.606
wssx	0.134	0.160	3.064
wssy	0.283	0.233	2.067
wssz	1.760	0.772	10.158

Εικόνα 30. Μετρητικά σφάλματα MSE, MAE και Relative Error (%) των μεταβλητών πρόβλεψης για τη δεύτερη χρονική φάση.

Evaluate an unknown aorta | Time Phase = 5

Variable	MSE	MAE	Relative Error (%)
pressure	1562779.155	1029.379	0.640
vx	19.104	3.307	7.148
vy	60.741	4.816	4.734
vz	59.037	5.738	7.026
wssx	0.187	0.170	1.639
wssy	0.601	0.230	0.876
wssz	1.729	0.645	3.412

Evaluate an unknown aorta | Time Phase = 8

Variable	MSE	MAE	Relative Error (%)
pressure	2898988.649	1407.727	0.876
vx	48.647	4.547	5.820
vy	115.170	6.952	8.152
vz	58.508	5.813	7.329
wssx	0.342	0.203	1.467
wssy	0.868	0.286	1.324
wssz	0.955	0.394	2.097

Εικόνα 31. Μετρητικά σφάλματα MSE, MAE και Relative Error (%) των μεταβλητών πρόβλεψης για τη πέμπτη χρονική φάση.

Evaluate an unknown aorta Time Phase = 10			
Variable	MSE	MAE	Relative Error (%)
pressure	2167340.782	1208.416	0.838
vx	44.661	4.446	6.878
vy	91.051	6.547	8.645
vz	43.379	4.918	7.326
wssx	0.522	0.214	1.867
wssy	0.856	0.313	2.167
wssz	0.646	0.383	3.020

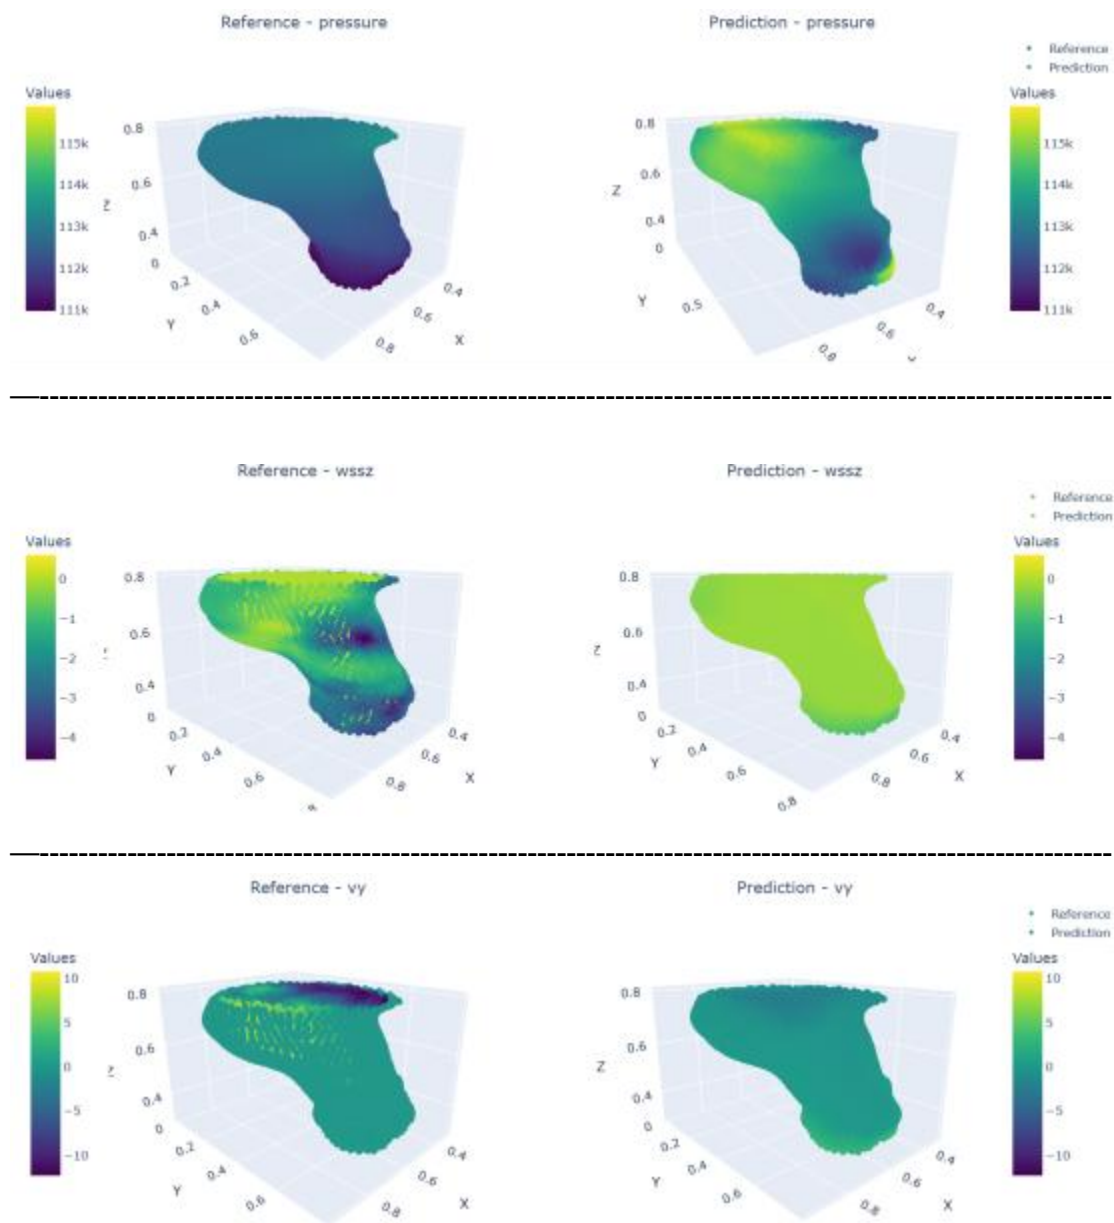
Evaluate an unknown aorta Time Phase = 24			
Variable	MSE	MAE	Relative Error (%)
pressure	6035342.586	2428.439	2.303
vx	17.102	3.000	11.076
vy	24.242	3.574	10.370
vz	11.609	2.608	9.012
wssx	0.098	0.118	2.574
wssy	0.217	0.212	2.878
wssz	0.179	0.177	2.721

Εικόνα 32. Μετρητικά σφάλματα MSE, MAE και Relative Error (%) των μεταβλητών πρόβλεψης για τη δέκατη χρονική φάση.

=== Mean metrics across all samples ===			
Variable	MSE	MAE	Relative Error (%)
pressure	2635232.579	1371.227	1.073
vx	26.081	3.499	9.413
vy	55.037	4.794	9.031
vz	38.187	4.523	9.646
wssx	0.225	0.163	2.263
wssy	0.498	0.241	2.000
wssz	0.972	0.468	4.973



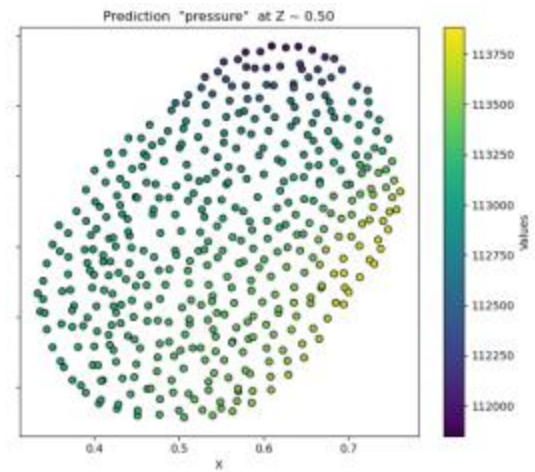



Εικόνα 33. Μέσα Μετρητικά σφάλματα MSE, MAE και Relative Error (%) των μεταβλητών πρόβλεψης.







Ακολουθώς, παρατίθεται μία τρισδιάστατη (3D) απεικόνιση των προβλέψεων του ΤΝΔ για ορισμένες ενδεικτικές μεταβλητές πρόβλεψης, καθώς και των τιμών αναφοράς, όπως εξήχθησαν από την αριθμητική προσομοίωση (CFD).

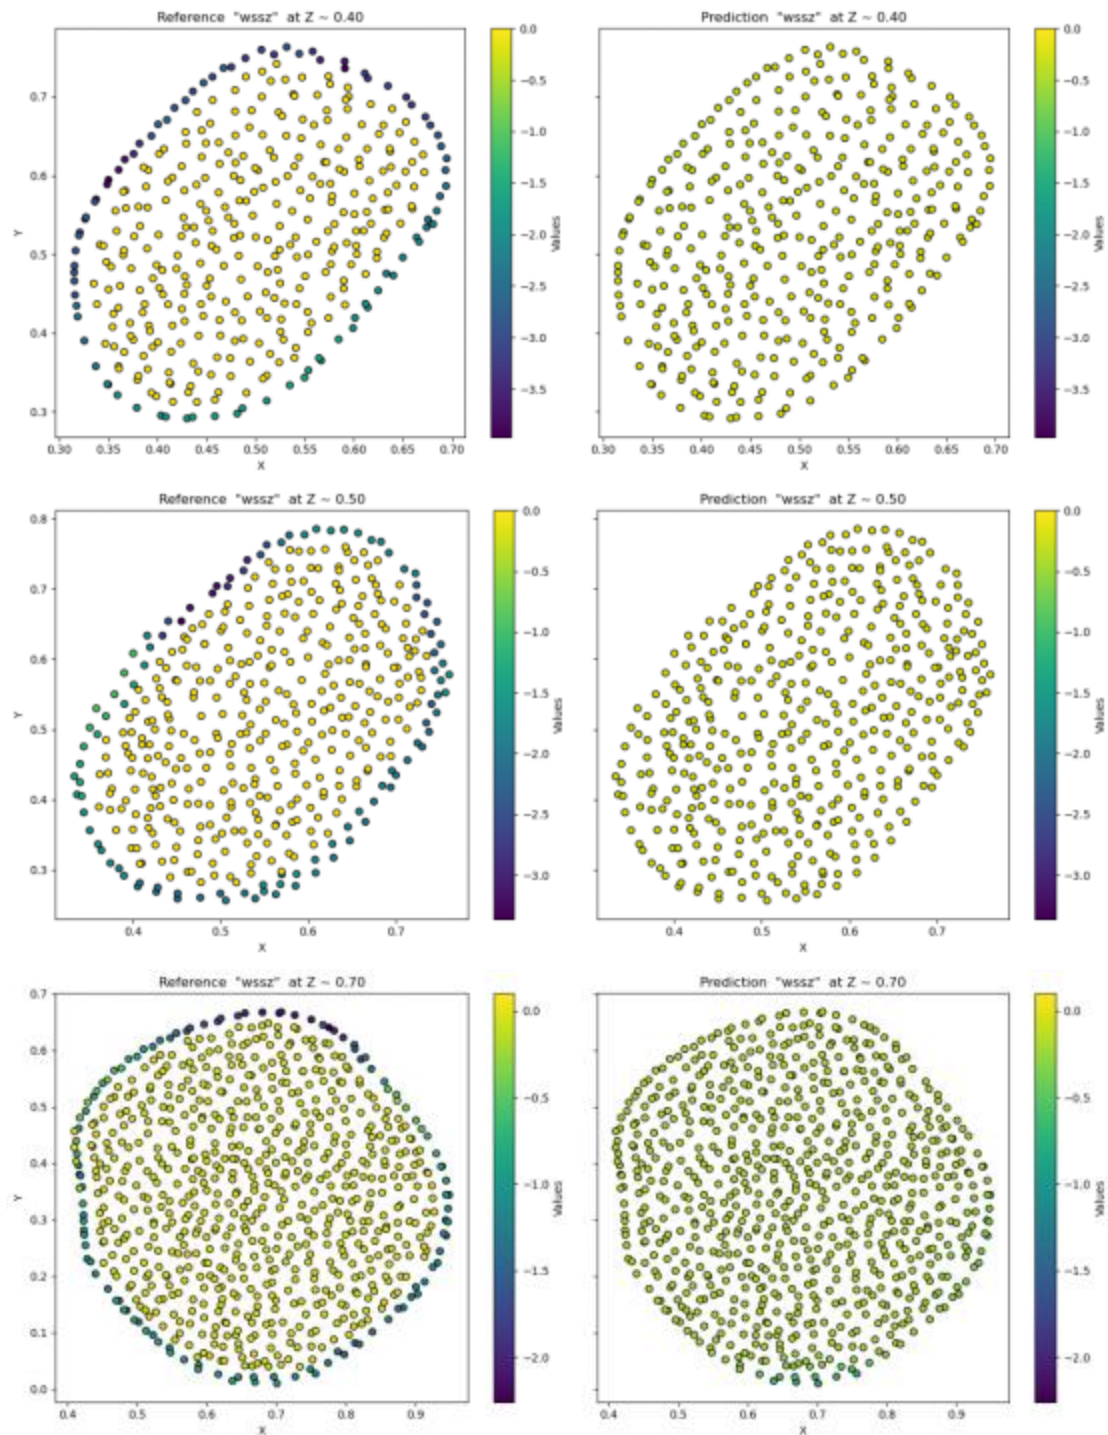


Εικόνα 34. Τρισδιάστατη απεικόνιση των προβλέψεων του ΤΝΔ για ενδεικτικές μεταβλητές πρόβλεψης (δεξιά), και των τιμών αναφοράς, όπως εξήχθησαν από την αριθμητική προσομοίωση (αριστερά).

Επιπροσθέτως, απεικονίζονται αντιπροσωπευτικές δισδιάστατες (2D) τομές, κατά μήκος του κατακόρυφου άξονα z, μιας κοιλιακής αορτής του συνόλου επικύρωσης, στις οποίες φαίνονται οι προβλέψεις του ΤΝΔ για ορισμένες ενδεικτικές μεταβλητές πρόβλεψης. Στο σχήμα φαίνονται επίσης και οι τιμές αναφοράς, όπως εξήχθησαν από την αριθμητική προσομοίωση (CFD).







Εικόνα 35. Δισδιάστατες τομές, κατά μήκος του κατακόρυφου άξονα z, μιας κοιλιακής αορτής του συνόλου επικύρωσης, στις οποίες φαίνονται οι προβλέψεις του ΤΝΔ για ενδεικτικές μεταβλητές πρόβλεψης (δεξιά), καθώς και οι τιμές αναφοράς, όπως εξήχθησαν από την αριθμητική προσομοίωση (αριστερά).

Τα εξαχθέντα αποτελέσματα καταδεικνύουν πως το υλοποιηθέν ΤΝΔ παράγει ικανοποιητικές προβλέψεις για τις υπό εξέταση μεταβλητές πρόβλεψης. Οι προβλέψεις αυτές με τη σειρά τους δύνανται να χρησιμοποιηθούν/ερμηνευτούν από τους εμπειρογνώμονες, προκειμένου να συναχθούν


συμπεράσματα σχετικά με την πορεία ενός (ενδεχόμενου) ανευρύσματος της αορτής. Τεκμαίρεται, λοιπόν, πως το ΤΝΔ δύναται να ενεργήσει ως ένα ταχύτατο υποκατάστατο της αντίστοιχης αριθμητικής προσομοίωσης.

3.6 Εξαρτήσεις Λογισμικού του Συστήματος

Το υλοποιηθέν σύστημα έχει ελάχιστες εξαρτήσεις (dependencies), με την έννοια ότι η λειτουργία του απαιτεί ελάχιστα επιπρόσθετα εργαλεία λογισμικού. Συγκεκριμένα, το σύστημα δύναται να φιλοξενηθεί σε έναν Server (εξυπηρετητή) συμβατικής υπολογιστικής ισχύος, ο οποίος θα παρέχει τη δυνατότητα εκτέλεσης κώδικα γλώσσας προγραμματισμού *Python*, και υποστήριξης βασικών βιβλιοθηκών, όπως οι NumPy, Pandas, TensorFlow και OpenPyXL. Επιπροσθέτως, απαιτείται το πακέτο βιβλιοθηκών MATLAB Runtime 2025. Για την ομαδοποίηση με τις υπόλοιπες ομάδες του προγράμματος, οι παραπάνω εξαρτήσεις έχουν προσαρμοστεί σε ένα ενιαίο πακέτο Docker όπου δεν χρειάζεται περαιτέρω επεξεργασία για τις εκδόσεις των λογισμικών ή την εγκατάστασή τους. Εξαιρετική αποτελεί το λογισμικό Docker το οποίο είναι δωρεάν και ιδιαίτερα εύχρηστο σε περιβάλλον Linux. Περισσότερες πληροφορίες και λεπτομέρειες διατίθενται στην Ενότητα 4.

Τα δεδομένα εισόδου του κώδικα δύναται να φορτώνονται από έναν καθορισμένο κατάλογο εργασίας (working directory) του Server, στον οποίο θα είναι αποθηκευμένα και τα αρχεία που χρησιμοποιεί ο κώδικας κατά την εκτέλεσή του (π.χ., το αρχείο που περιέχει τις παραμέτρους του εκπαιδευμένου ΤΝΔ ή τα αρχεία στα οποία θα περιέχονται τα δεδομένα εισόδου του ΤΝΔ).

Τελικώς, ο τρόπος λειτουργίας του συστήματος παρουσιάζεται στην **Εικόνα 36** (σύγκριση με την **Εικόνα 19**). Ουσιαστικά, ο χρήστης παρέχει ως είσοδο ένα *αρχείο STL* στο οποίο κωδικοποιούνται τα στοιχεία της γεωμετρίας του τοιχώματος μιας κοιλιακής αορτής. Το σύστημα φορτώνει από τον κατάλογο εργασίας το αρχείο που περιέχει τις παραμέτρους του εκπαιδευμένου ΤΝΔ, και τελικά παράγει ως έξοδο μία πρόβλεψη/εκτίμηση για ένα σύνολο μη επεμβατικών αιμοδυναμικών δεικτών της αορτής και για τις έξι φάσεις του καρδιακού παλμού (**Εικόνα 20**).



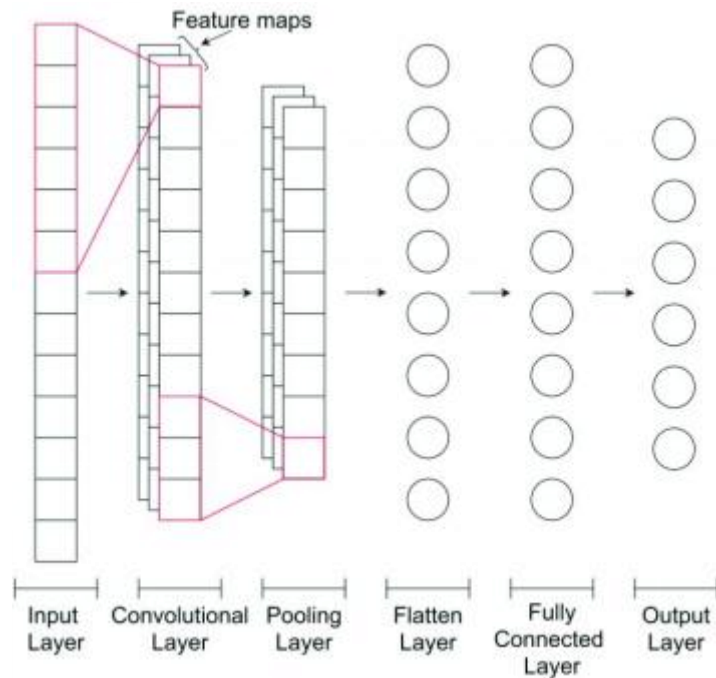
Εικόνα 36. Τρόπος λειτουργίας του υλοποιηθέντος συστήματος.

3.7 Εναλλακτικό Τεχνητό Νευρωνικό Δίκτυο - CNN

Στα πλαίσια του έργου, αναπτύχθηκε επίσης ένα *Συνελικτικό Νευρωνικό Δίκτυο* (Convolutional Neural Network – CNN) για την πρόβλεψη των αιμοδυναμικών δεικτών ενδιαφέροντος μιας κοιλιακής αορτής. Το Συνελικτικό Νευρωνικό Δίκτυο (ΣΝΔ) που υλοποιήθηκε αποτελείται από διάφορα επίπεδα (layers), καθένα από τα οποία επιτελεί συγκεκριμένες λειτουργίες κατά την εκπαίδευση και πρόβλεψη του μοντέλου. Ακολουθεί μία αναλυτική περιγραφή των επιπέδων του ΣΝΔ:

1. **Επίπεδο Εισόδου (Input Layer):** Το μοντέλο λαμβάνει ως είσοδο δεδομένα διαστάσεων **(4,1)**, όπου η τετμημένη **4** αντιπροσωπεύει τα χαρακτηριστικά (features) και η τεταγμένη **1** τον αριθμό των καναλιών (channels), προκειμένου να καταστεί δυνατή η επεξεργασία τους από τα συνελικτικά επίπεδα.
2. **Συνελικτικό Επίπεδο (Conv1D Layer):** Το συνελικτικό επίπεδο του μοντέλου εφαρμόζει **64** φίλτρα (filters) με μέγεθος πυρήνα (kernel size) **2**, χρησιμοποιώντας τη συνάρτηση ενεργοποίησης ReLU. Η διαδικασία αυτή παράγει **64** *χάρτες χαρακτηριστικών* (feature maps), οι οποίοι αποτυπώνουν τοπικά μοτίβα στα δεδομένα, όπως σχέσεις μεταξύ των χαρακτηριστικών εισόδου.
3. **Επίπεδο Μέγιστης Συγκέντρωσης (MaxPooling1D Layer):** Το MaxPooling αποτελεί μία τεχνική υπο-δειγματοληψίας (sub-sampling) που βοηθά στη μείωση της διάστασης των δεδομένων μετά το συνελικτικό επίπεδο. Το παράθυρο (window) μεγέθους **2** που επιλέχθηκε διατηρεί μόνο τη μέγιστη τιμή από κάθε ζεύγος τιμών, μειώνοντας έτσι τον αριθμό των παραμέτρων.
4. **Επίπεδο Ισοπέδωσης (Flatten Layer):** Η έξοδος των προηγούμενων επιπέδων μετατρέπεται από ένα πολυδιάστατο διάνυσμα σε ένα μονοδιάστατο διάνυσμα, με τη βοήθεια του επιπέδου ισοπέδωσης. Η διαδικασία αυτή είναι απαραίτητη προκειμένου να διασυνδεθούν τα δεδομένα με τα πλήρως διασυνδεδεμένα επίπεδα που ακολουθούν.
5. **Πλήρως Διασυνδεδεμένα Επίπεδα (Fully Connected/Dense Layers):** Το πρώτο πλήρως διασυνδεδεμένο επίπεδο του μοντέλου περιλαμβάνει **150** νευρώνες και είναι εφοδιασμένο με τη συνάρτηση ενεργοποίησης ReLU. Το επίπεδο αυτό χρησιμοποιείται προκειμένου να εξαχθούν τα πιο περίπλοκα μοτίβα που έχουν προκύψει από τα προηγούμενα στάδια επεξεργασίας του δικτύου. Το δεύτερο και τελευταίο πλήρως διασυνδεδεμένο επίπεδο αποτελεί ουσιαστικά το επίπεδο εξόδου (output layer) του μοντέλου, το οποίο και αντιστοιχεί στις εξόδους του προβλήματος. Το επίπεδο αυτό διαθέτει τόσους νευρώνες όσες και οι μεταβλητές πρόβλεψης, ενώ δεν χρησιμοποιεί κάποια συνάρτηση ενεργοποίησης, καθώς πρόκειται για πρόβλεψη συνεχών τιμών.



Η αρχιτεκτονική του ΣΝΔ απεικονίζεται (αφηρημένα) στην **Εικόνα 37**.



Εικόνα 37. Αφηρημένη απεικόνιση αρχιτεκτονικής Συνελικτικού Νευρωνικού Δικτύου.

Το ΣΝΔ χρησιμοποιεί τον αλγόριθμο εκπαίδευσης Adam, ο οποίος προσαρμόζει δυναμικά τις παραμέτρους του μοντέλου προκειμένου να μειωθεί το σφάλμα μεταξύ των τιμών πρόβλεψης του μοντέλου και των τιμών αναφοράς. Η συνάρτηση σφάλματος που χρησιμοποιείται είναι το *Μέσο Τετραγωνικό Σφάλμα* (MSE), κατάλληλη για προβλήματα παλινδρόμησης, ενώ κατά την εκπαίδευση του μοντέλου παρακολουθείται επίσης και το *Μέσο Απόλυτο Σφάλμα* (MAE).

Στην **Εικόνα 38** παρουσιάζονται οι καμπύλες εκμάθησης (learning curves), που αντιπροσωπεύουν τις τιμές των MSE και MAE του μοντέλου. Οι παρουσιαζόμενες καμπύλες καταγράφουν τις τιμές των σφαλμάτων στα σύνολα εκπαίδευσης (training) και επικύρωσης (validation), κατά τη διαδικασία εκπαίδευσης του ΣΝΔ, επιβεβαιώνοντας ότι η υπερπροσαρμογή αποφεύχθηκε επιτυχώς.



Εικόνα 38. MSE (πάνω) και MAE (κάτω) του ΣΝΔ στα σύνολα εκπαίδευσης (training) και επικύρωσης (validation), κατά τη διαδικασία εκπαίδευσης των 5 εποχών.

MSE	0.013
MAE	0.0155

Είναι σαφές ότι το ΣΝΔ αύξησε το MSE κατά περίπου 1880%, ενώ μείωσε ελαφρά το MAE κατά 1,3%, σε σχέση με το MLP. Καθώς η αύξηση του MSE είναι ιδιαίτερα σημαντική, και δεδομένης της αυξημένης πολυπλοκότητας της αρχιτεκτονικής του ΣΝΔ σε σχέση με την αρχιτεκτονική του MLP, κρίνεται σαφώς προτιμότερη η χρήση του MLP για την πρόβλεψη των αιμοδυναμικών δεικτών ενδιαφέροντος μιας κοιλιακής αορτής.

Το υλοποιηθέν σύστημα Μηχανικής Μάθησης δύναται να βελτιωθεί σε διάφορες πτυχές. Δύο σημαντικές βελτιώσεις θα ήταν η περαιτέρω εκπαίδευσή του σε επιπρόσθετα δεδομένα, καθώς και η ενσωμάτωση μιας «επιλογής απόρριψης» (“rejection option”), τεχνική μέσω της οποίας το ΤΝΔ θα απορρίπτει δείγματα των οποίων η γεωμετρία είναι *σημαντικά διαφορετική* από τη γεωμετρία των δειγμάτων εκπαίδευσης. Σε αυτήν την τελευταία περίπτωση, το ΤΝΔ δεν θα παράγει κάποια εκτίμηση για το απορριφθέν δείγμα, δεδομένου ότι αυτό αποτελεί ένα «ακραίο δείγμα» (“outlier”), και μία ενδεχόμενη εκτίμηση θα ήταν επισφαλής

Ένας περιορισμός που αντιμετωπίστηκε στα πλαίσια της υλοποίησης του συστήματος Μηχανικής Μάθησης είναι αυτός του *περιορισμένου όγκου δεδομένων εκπαίδευσης*. Πρέπει να τονιστεί πως ο συγκεκριμένος περιορισμός εντοπίζεται γενικά σε βιοϊατρικές εφαρμογές Ρευστομηχανικής, όπως επισημαίνεται στο ακόλουθο απόσπασμα της εργασίας του Amirtahà Taebi.

“DL usually requires large volumes of training data. When the training dataset is small, the trained model may be suitable for interpolation but may not perform well for new input data that represent different features than the training dataset (i.e., extrapolation). Many DL datasets in other applications have a large sample size. However, such a large database is not still available for fluid mechanics applications, specifically for biomedical CFD. Thus, the current DL models suffer from insufficient training data. Estimating an appropriate size of training data for a specific application is usually difficult. Based on available studies, the training datasets for hemodynamics applications should include the data of several thousand subjects. However, such big data are not usually available for CFD studies.”

4. Εφαρμογή Docker για την υλοποίηση στην εφαρμογή ΨηφιΔΑ

Στο πακέτο ενοποίησης και παράδοσης του ΨηφιΔΑ περιλαμβάνεται η διαδικασία επικοινωνίας όλων των τμημάτων που θα ενσωματωθούν στο λογισμικό. Στόχος είναι τα δεδομένα που θα προέρχονται από το Τεχνητό Νευρωνικό Δίκτυο να μπορούν να χρησιμοποιηθούν από το επόμενο τμήμα και να αποφευχθούν προβλήματα επικοινωνίας μεταξύ των τμημάτων. Τα στοιχεία εισόδου θα πρέπει να εισέρχονται στο λογισμικό σε μορφή που να είναι αναγνωρίσιμη από όλα τα επιμέρους τμήματα και τα αποτελέσματα να μπορούν να περνάνε από τμήμα σε τμήμα αδιάκοπα.

Για την ομαλή ενσωμάτωση στο λογισμικό χρησιμοποιήθηκε η εφαρμογή Docker ώστε όλα τα προαπαιτούμενα πακέτα και βιβλιοθήκες να περιέχονται στα μέλη των υπολοίπων ομάδων σαν ένα ενιαίο πακέτο.

4.1 Περιγραφή των Docker

Το Docker module του προγράμματος **SAFE AORTA** από το **Πανεπιστήμιο Πελοποννήσου (ΠΑΠΕΛ)** αποτελείται από δύο **διακριτά υποσυστήματα**, τα οποία παρέχονται ως δύο **ξεχωριστές Docker εφαρμογές**, για λόγους ευκολίας χρήσης και συντήρησης. Στο πλαίσιο του προγράμματος **SAFE AORTA** έχει δημιουργηθεί repository στο **DockerHub** με όνομα: «safeaortapapel». Στο συγκεκριμένο repository διατίθενται τα ακόλουθα Docker images:

1. safeaortapapel/cloudp-app

2. safeaortapapel/safe-aorta-time-py

Παρακάτω δίνονται οι οδηγίες για το πως καλούμε τις εφαρμογές μέσω περιβάλλον Linux.

Το πρώτο module βασίζεται στο **MATLAB Runtime 2025 (Linux)** και υλοποιεί την επεξεργασία του νέφους σημείων στο δοσμένο, από το χρήστη, αρχείο κοιλιακής αορτής, ενώ μέσω του δεύτερου module υλοποιεί το νευρωνικό δίκτυο πρόβλεψης ροής όπου είναι γραμμένο στη γλώσσα Python, η οποία είναι διαθέσιμη σε περιβάλλον Linux.

4.2 Λήψη (pull) των Docker απο το DockerHub

Οδηγίες Λήψης (Περιβάλλον Linux): Οι παρακάτω εντολές εκτελούνται σε περιβάλλον **Linux** με εγκατεστημένο το **Docker**, ενώ τα Docker images είναι δημόσια (public) και δεν απαιτείται DockerHub λογαριασμός για τη λήψη τους. Απαιτείται Linux περιβάλλον με ενεργό X11 server.

Βήμα 1. Cloudp-app docker pull

Μέσω του terminal εκτελούμε την εντολή:

1. sudo docker pull safeaortapapel/cloudp-app:latest

Όπου το αναμενόμενο αποτέλεσμα είναι:

latest: Pulling from safeaortapapel/cloudp-app

Digest: sha256:5eea9879a75c007a719062ef889a62cfdccd323802ea81aac303350fbaeb47c5

Status: Image is up to date for safeaortapapel/cloudp-app:latest

docker.io/safeaortapapel/cloudp-app:latest

Βήμα 2. safe-aorta-time-py docker pull

2. sudo docker pull safeaortapapel/safe-aorta-time-py:latest

Όπου το αναμενόμενο αποτέλεσμα είναι:

latest: Pulling from safeaortapapel/safe-aorta-time-py

Digest: sha256:97d9f39143832cb64ebd74970e75d1c72b206b4aaeccc999e940f5e8adfec990
Status: Image is up to date for safeaortapapel/safe-aorta-time-py:latest
docker.io/safeaortapapel/safe-aorta-time-py:latest

Με τις παραπάνω εντολές γίνεται η λήψη των Docker εφαρμογών από το repository του ΠΑΠΕΛ στο DockerHub.

4.3 Εκτέλεση των Docker

Αφού ολοκληρωθεί επιτυχώς η λήψη (pull) των Docker images, οι developers μπορούν να προχωρήσουν στην εκτέλεση των δύο modules.

Βήμα 1. cloudp-app

Η εκτέλεση του πρώτου module γίνεται με την ακόλουθη εντολή:

```
sudo docker run --rm -e DISPLAY=:10.0 -v /tmp/.X11-unix:/tmp/.X11-unix -v "$PWD":/data -w /data --user 0 safeaortapapel/cloudp-app:latest path/Aorta_File.stl
```

Όπου το **Aorta_File.stl** είναι το αρχείο STL της κοιλιακής αορτής, το οποίο παρέχεται από τον εκάστοτε χρήστη. Ο φάκελος από τον οποίο εκτελείται η εντολή (\$PWD) χρησιμοποιείται ως **working directory** και περιέχει τόσο τα input όσο και τα παραγόμενα αρχεία.

Με την παραπάνω εντολή εκτελείται το module του **MATLAB Runtime**, το οποίο δημιουργεί **νέφος σημείων (point cloud)** στο εσωτερικό της γεωμετρίας της αορτής. Το νέφος σημείων είναι απαραίτητο για τη σωστή λειτουργία του νευρωνικού δικτύου. Το αναμενόμενο αποτέλεσμα, είναι το αρχείο **input_point_cloud.xlsx** το οποίο **βρίσκεται στο ίδιο path με το Aorta_File.stl**.

· Η διαδικασία του MATLAB module έχει ολοκληρωθεί με επιτυχία.

Βήμα 2. safe-aorta-time-py

Στο δεύτερο στάδιο εκτελείται το module της Python, το οποίο χρησιμοποιεί ως είσοδο το αρχείο **input_point_cloud.xlsx** που παρήχθη στο προηγούμενο βήμα και βρίσκεται στο working directory (/data).

Για να εκτελέσουμε το module της Python εκτελούμε την εντολή:

```
sudo docker run --rm -it -v "$PWD":/data safeaortapapel/safe-aorta-time-py:latest
```

Όπου περιμένουμε να δούμε τα εξής:

Working directory: /data

Point cloud of the aorta found in Working Directory (input_point_cloud.xlsx).

Input data for the model loaded from the Working Directory.

Prediction done by the model for Time Phase = 2.

Exported: output_results_t_2.xlsx

Saved 3D HTML: pred_3d_vz_t_2.html

Saved slice gallery HTML: slices_vz_t_2.html

Prediction done by the model for Time Phase = 3.

Exported: output_results_t_3.xlsx
Saved 3D HTML: pred_3d_vz_t_3.html
Saved slice gallery HTML: slices_vz_t_3.html
Prediction done by the model for Time Phase = 5.
Exported: output_results_t_5.xlsx
Saved 3D HTML: pred_3d_vz_t_5.html
Saved slice gallery HTML: slices_vz_t_5.html
Prediction done by the model for Time Phase = 8.
Exported: output_results_t_8.xlsx
Saved 3D HTML: pred_3d_vz_t_8.html
Saved slice gallery HTML: slices_vz_t_8.html
Prediction done by the model for Time Phase = 10.
Exported: output_results_t_10.xlsx
Saved 3D HTML: pred_3d_vz_t_10.html
Saved slice gallery HTML: slices_vz_t_10.html
Prediction done by the model for Time Phase = 24.
Exported: output_results_t_24.xlsx
Saved 3D HTML: pred_3d_vz_t_24.html
Saved slice gallery HTML: slices_vz_t_24.html
Elapsed time: x sec

Η εμφάνιση των παραπάνω μηνυμάτων επιβεβαιώνει ότι το νευρωνικό δίκτυο της Python ολοκλήρωσε επιτυχώς την πρόβλεψη της ροής εντός της γεωμετρίας **Aorta_File.stl**.

4.4 Αποτελέσματα

Τα αποτελέσματα έχουν τρεις (3) κατηγορίες:

1. output_results_t_ *i*.xlsx
2. pred_3d_vz_t_ *i*.html
3. slice_vz_t_ *i*_z_ *j*

Η κατηγορία 1. αποτελεί τα αριθμητικά Excel Datasets για τη χρονική στιγμή *i* του καρδιακού κύκλου (Δείτε την εικόνα παρακάτω). Η κατηγορία 2. περιλαμβάνει .html αρχεία τα οποία δείχνουν σε διαδραστικά 3D γραφικά μέσω Internet Browser (Default: Mozilla Firefox). Η κατηγορία 3. περιλαμβάνει .png αρχεία για τις χρονικές στιγμές *I* του καρδιακού παλμού όπου απεικονίζονται 2D τομές στο ύψος *j* της αορτής. Τα διαφορετικά *i* αντιστοιχούν στις χρονικές στιγμές:

Τα αποτελέσματα της κατηγορίας 1. αποθηκεύονται στο ίδιο **path** με το **Aorta_File.stl**, ενώ για πρακτικούς λόγους δημιουργείται ένας φάκελος με το όνομα html όπου περιέχει τα .html αρχεία της κατηγορίας 2. καθώς και έναν φάκελο με όνομα images όπου περιέχει τα αποτελέσματα της κατηγορίας 3. Συμπερασματικά έχουμε την εξής δομή για τα αποτελέσματα:

path/Aorta_File.stl

-> .xlsx (**Files**)

-> html (**Folder**)

.html (**Files**)

-> images (Folder)
.png (Files)

Στην Εικόνα 39 βλέπουμε τις εντολές στο terminal,

```
chrism@linuxstation2:~/Aorta_3D_Deconv$ ls
Aorta-1.stl
chrism@linuxstation2:~/Aorta_3D_Deconv$ sudo docker pull safeortapapel/cloudp-app:latest
latest: Pulling from safeortapapel/cloudp-app
Digest: sha256:6ea9879475c807a719862ef80a62cf6cc0323882aa81aac303150fbae8497c5
Status: Image is up to date for safeortapapel/cloudp-app:latest
chrism@linuxstation2:~/Aorta_3D_Deconv$ sudo docker pull safeortapapel/safe-aorta-time-py:latest
latest: Pulling from safeortapapel/safe-aorta-time-py
Digest: sha256:7f0d720143012c65ab219776e7261c72e204b1aaaccc999e948f3e1adfec998
Status: Image is up to date for safeortapapel/safe-aorta-time-py:latest
chrism@linuxstation2:~/Aorta_3D_Deconv$ sudo docker run --rm -v DISPLAY=:10.0 -v /tmp/.X11-unix:/tmp/.X11-unix -v "$PWD"/data -w /data --user 0 safeortapapel/cloudp-app:latest Aorta-1.stl
chrism@linuxstation2:~/Aorta_3D_Deconv$ ls
Aorta-1.stl  input_point_cloud.xlsx
chrism@linuxstation2:~/Aorta_3D_Deconv$ sudo docker run --rm -it -v "$PWD"/data safeortapapel/safe-aorta-time-py:latest
Working directory: /data
Point cloud of the aorta found in Working Directory (input_point_cloud.xlsx).
Input data for the model loaded from the Working Directory.
Prediction done by the model for Time Phase = 2.
Exported: output_results_t_2.xlsx
Saved 3D HTML: pred_3d_vz_t_2.html
Saved slice gallery HTML: slices_vz_t_2.html
Prediction done by the model for Time Phase = 3.
Exported: output_results_t_3.xlsx
Saved 3D HTML: pred_3d_vz_t_3.html
Saved slice gallery HTML: slices_vz_t_3.html
Prediction done by the model for Time Phase = 5.
Exported: output_results_t_5.xlsx
Saved 3D HTML: pred_3d_vz_t_5.html
Saved slice gallery HTML: slices_vz_t_5.html
Prediction done by the model for Time Phase = 8.
Exported: output_results_t_8.xlsx
Saved 3D HTML: pred_3d_vz_t_8.html
Saved slice gallery HTML: slices_vz_t_8.html
Prediction done by the model for Time Phase = 10.
Exported: output_results_t_10.xlsx
Saved 3D HTML: pred_3d_vz_t_10.html
Saved slice gallery HTML: slices_vz_t_10.html
Prediction done by the model for Time Phase = 24.
Exported: output_results_t_24.xlsx
Saved 3D HTML: pred_3d_vz_t_24.html
Saved slice gallery HTML: slices_vz_t_24.html
Elapsed time: 10.49 sec
chrism@linuxstation2:~/Aorta_3D_Deconv$ |
```

Εικόνα 39. Οι εντολές στο τερματικό (terminal) για τη λειτουργία του Docker.

ενώ στην Εικόνα 40 βλέπουμε τους φακέλους με τα αποτελέσματα

```
chrism@linuxstation2:~/Aorta_3D_Deconv$ ls
Aorta-1.stl  input_point_cloud.xlsx  output_results_t_2.xlsx  output_results_t_5.xlsx
HTML       output_results_t_10.xlsx  output_results_t_24.xlsx  output_results_t_3.xlsx
chrism@linuxstation2:~/Aorta_3D_Deconv$ cd HTML/
chrism@linuxstation2:~/Aorta_3D_Deconv/HTML$ ls
images      pred_3d_vz_t_2.html  pred_3d_vz_t_3.html  pred_3d_vz_t_8.html  slices_vz_t_2.html  slices_vz_t_3.html  slices_vz_t_8.html
pred_3d_vz_t_10.html  pred_3d_vz_t_24.html  pred_3d_vz_t_5.html  slices_vz_t_10.html  slices_vz_t_24.html  slices_vz_t_5.html
chrism@linuxstation2:~/Aorta_3D_Deconv/HTML/images$ ls
slices_vz_t_10_vz_t_8_00.png  slices_vz_t_24_vz_t_8_00.png  slices_vz_t_2_vz_t_8_00.png  slices_vz_t_3_vz_t_8_00.png  slices_vz_t_5_vz_t_8_00.png  slices_vz_t_8_vz_t_8_00.png
slices_vz_t_10_vz_t_8_00.png  slices_vz_t_24_vz_t_8_00.png  slices_vz_t_2_vz_t_8_00.png  slices_vz_t_3_vz_t_8_00.png  slices_vz_t_5_vz_t_8_00.png  slices_vz_t_8_vz_t_8_00.png
slices_vz_t_10_vz_t_8_00.png  slices_vz_t_24_vz_t_8_00.png  slices_vz_t_2_vz_t_8_00.png  slices_vz_t_3_vz_t_8_00.png  slices_vz_t_5_vz_t_8_00.png  slices_vz_t_8_vz_t_8_00.png
slices_vz_t_10_vz_t_8_00.png  slices_vz_t_24_vz_t_8_00.png  slices_vz_t_2_vz_t_8_00.png  slices_vz_t_3_vz_t_8_00.png  slices_vz_t_5_vz_t_8_00.png  slices_vz_t_8_vz_t_8_00.png
chrism@linuxstation2:~/Aorta_3D_Deconv/HTML/images$ |
```

Εικόνα 40. Φάκελοι με τα παραγόμενα αποτελέσματα.

5. Δημοσιεύσεις και Συνέδρια

1. Theofanis Aravanis, Grigorios Chrimatopoulos, Michalis Xenos, and Efstratios E. Tzirtzilakis, “Forecasting Two-Dimensional Channel Flow using Machine Learning”, *Physics of Fluids*, Vol. 36, Iss. 10, 2024.
2. Theofanis Aravanis, Grigorios Chrimatopoulos, Michalis Xenos, and Efstratios E. Tzirtzilakis, “Machine Learning-Based Geometric Interpolation for Fluid-Flow Modelling”, *Proceedings of the 28th Pan-Hellenic Conference on Progress in Computing Informatics with International Participation (PCI 2024)*, Athens, Greece, December 13-15, 2024.
3. Theofanis Aravanis, Grigorios Chrimatopoulos, Michalis Xenos, and Efstratios E. Tzirtzilakis, “Machine-Learning Modelling of a Fluid Flow in a Two-Dimensional Channel”, *Proceedings of the 15th International Conference on Information, Intelligence, Systems and Applications (IISA 2024)*, Chania, Greece, July 17-19, 2024.
4. Theofanis Aravanis, Grigorios Chrimatopoulos, Mohammad Ferdows, Michalis Xenos, and Efstratios E. Tzirtzilakis, “ASP-Assisted Symbolic Regression: Uncovering Hidden Physics in Fluid Mechanics”, arXiv:2507.17777, 2025.
5. Spyridon Katsoudas, Stavros Malatos, Anastasios Raptis, Miltiadis Matsagkas, Athanasios Giannoukas, and Michalis Xenos, “Blood Flow Simulation in Bifurcating Arteries: A Multiscale Approach After Fenestrated and Branched Endovascular Aneurysm Repair”, *Mathematics*, Vol. 13, Iss. 9, 2025.
6. Spyridon Katsoudas, Grigorios Chrimatopoulos, Michalis Xenos, and Efstratios A. Tzirtzilakis, “A Finite Volume and Levenberg–Marquardt Optimization Framework for Benchmarking MHD Flows over Backward-Facing Steps”, *Mathematics*, Vol. 13, Iss. 18, 2025.
7. Spyridon C. Katsoudas, Panagiotis D. Linardopoulos, Anastasios A. Raptis, Konstantinos G. Moulakakis, John D. Kakisis, Konstantinos T. Spanos, Miltiadis I. Matsagkas, Athanasios D. Giannoukas, Christos G. Manopoulos, Efstratios E. Tzirtzilakis, and Michalis A. Xenos, “Hemodynamic Shear Stress Patterns in Abdominal Aortic Aneurysms and Healthy Aortas: A CFD Study”, manuscript under preparation, 2026.
8. Spyridon C. Katsoudas, Konstantina C. Kyriakoudi, Grigorios T. Chrimatopoulos, Panagiotis D. Linardopoulos, Christoforos T. Chrimatopoulos, Anastasios A. Raptis, Konstantinos G. Moulakakis, John D. Kakisis, Christos G. Manopoulos, Michail A.

- Xenos, and Efstratios E. Tzirtzilakis, “Linking Aneurysmal Geometry and Hemodynamics Using Computational Fluid Dynamics”, *arXiv preprint arXiv:2512.03660*, 2025.
9. Spyridon C. Katsoudas, Theofanis I. Aravanis, Konstantinos D. Blekas, Efstratios Em. Tzirtzilakis, and Michalis A. Xenos, “Accelerating the Simulation of Pulsatile Turbulent Hemodynamics in Stenotic Arteries Using Artificial Neural Networks”, manuscript under preparation, 2026.
 10. Spyridon C. Katsoudas and Michalis A. Xenos, “Blood Flow Simulation in Bifurcating and Stenotic Geometries Using Advanced Numerical Methods”, 13th Panhellenic Conference on Biomaterials, Ioannina, Greece, 28–29 March 2025.
 11. Konstantina C. Kyriakoudi, Grigorios T. Chrimatopoulos, Efstratios E. Tzirtzilakis and Michail A. Xenos “Aneurysmal haemodynamics: a three-dimensional fluid–structure interaction approach”, Royal Society Open Science, to appear.
 12. Konstantina C. Kyriakoudi, Grigorios T. Chrimatopoulos, Efstratios Em. Tzirtzilakis, and Michalis A. Xenos, “Hemodynamics in Aneurysmal Geometries Using the Finite Volume Method”, 13th Panhellenic Conference on Biomaterials, Ioannina, Greece, 28–29 March 2025.
 13. Konstantina C. Kyriakoudi, Spyridon C. Katsoudas, Grigorios T. Chrimatopoulos, Michalis A. Xenos, and Efstratios Em. Tzirtzilakis, “Simulation of Blood Flow in Pathological Vessels: A Finite Volume Approach”, 1st Hellenic-Italian Conference on Computational Mechanics, Biomechanics and Mechanics of Materials (1st HICOMP Conference), Rhodes, Greece, 19–21 June 2025.
 14. Spyridon C. Katsoudas, Theofanis I. Aravanis, Michalis A. Xenos, and Efstratios Em. Tzirtzilakis, “Predictive Modeling of Blood Flow in Stenotic Geometries Using CFD and Machine Learning”, 1st Hellenic-Italian Conference on Computational Mechanics, Biomechanics and Mechanics of Materials (1st HICOMP Conference), Rhodes, Greece, 19–21 June 2025.
 15. G. Chrimatopoulos, M. Xenos, E. Tzirtzilakis, “A Computational Optimized CFD Solver Using Newton’s Method, GMRES(m) And The Finite Volume Method”, 1st Hellenic-Italian Conference on Computational Mechanics, Biomechanics and Mechanics of Materials (1st HICOMP Conference).

6. Βιβλιογραφία

Alastruey, Jordi, et al. "Lumped parameter outflow models for 1-D blood flow simulations: effect on pulse waves and parameter estimation." *Communications in Computational Physics* 4.2 (2008): 317-336.

Dua, Monica M., and Ronald L. Dalman. "Hemodynamic influences on abdominal aortic aneurysm disease: Application of biomechanics to aneurysm pathophysiology." *Vascular pharmacology* 53.1-2 (2010): 11-21.

Fevola, Elisa, et al. "A vector fitting approach for the automated estimation of lumped boundary conditions of 1D circulation models." *Cardiovascular Engineering and Technology* 14.4 (2023): 505-525.

Les, Andrea S., et al. "Quantification of hemodynamics in abdominal aortic aneurysms during rest and exercise using magnetic resonance imaging and computational fluid dynamics." *Annals of biomedical engineering* 38.4 (2010): 1288-1313.

Lu, Hong, and Alan Daugherty. "Aortic aneurysms." *Arteriosclerosis, thrombosis, and vascular biology* 37.6 (2017): e59-e65.

Raptis, Anastasios, et al. "Comparison of physiological and post-endovascular aneurysm repair infrarenal blood flow." *Computer methods in biomechanics and biomedical engineering* 20.3 (2017): 242-249.

Vignon-Clementel, Irene E., et al. "Outflow boundary conditions for 3D simulations of non-periodic blood flow and pressure fields in deformable arteries." *Computer methods in biomechanics and biomedical engineering* 13.5 (2010): 625-640.

Westerhof, Nico, Jan-Willem Lankhaar, and Berend E. Westerhof. "The arterial windkessel." *Medical & biological engineering & computing* 47.2 (2009): 131-141.

Liang, Liang, et al. "A deep learning approach to estimate stress distribution: a fast and accurate surrogate of finite-element analysis." *Journal of The Royal Society Interface* 15.138 (2018): 20170844.

Goodfellow, Ian. "Deep learning." (2016).

Geifman, Yonatan, and Ran El-Yaniv. "Selective classification for deep neural networks." *Advances in neural information processing systems* 30 (2017).

Taebi, Amirtahà. "Deep learning for computational hemodynamics: A brief review of recent advances." *Fluids* 7.6 (2022): 197.

7. Παράρτημα

```
#-----#

# Description: Python Source Code for the Machine-Learning System (SAFE-AORTA)
# Developers: University of the Peloponnese (UoP)
# Last Change: October 2025
# Version: 1.2
# Tested on: Python 3.11.5 | TensorFlow 2.16.1 | NumPy 1.24.3 | Pandas 2.0.3 | Scikit-learn
1.5.0 | Joblib 1.2.0

# NOTE (Docker version):
# - model.keras and trained_scalers.pkl are stored INSIDE the image at /app
# - The WORKING DIRECTORY /data (mounted) only needs: input_point_cloud.xlsx

# Load modules
import os
import time
import random
import warnings

import numpy as np
import pandas as pd
from matplotlib import colors
import tensorflow as tf
from tensorflow import keras
from sklearn.preprocessing import MinMaxScaler
import joblib
import plotly.graph_objects as go
from plotly.subplots import make_subplots
from mpl_toolkits.mplot3d import Axes3D
from sklearn.exceptions import InconsistentVersionWarning
import matplotlib
matplotlib.use("Agg")
import matplotlib.pyplot as plt

warnings.filterwarnings('ignore', category=InconsistentVersionWarning)

# GLOBAL VARIABLE NAMES
x_variables = ['Points:0', 'Points:1', 'Points:2', 'time']
y_variables = ['pressure', 'vx', 'vy', 'vz', 'wssx', 'wssy', 'wssz']
var_names = {
    'pressure': 'Pressure',
    'vx': 'Velocity X',
```

```

'vy': 'Velocity Y',
'vz': 'Velocity Z',
'wssx': 'Wall Shear Stress X',
'wssy': 'Wall Shear Stress Y',
'wssz': 'Wall Shear Stress Z'
}

# FUNCTIONS #
def denormalize_df(df, scalers):
    df_reversed = df.copy()
    for column in y_variables:
        scaler = scalers[column] # Retrieve the scaler used for this column
        df_reversed[column] = scaler.inverse_transform(df_reversed[[column]])
    return df_reversed

def normalize_x_vars(df): # Normalize (0-1) the coordinates variables of a df
    for column in x_variables[0:3]:
        scaler = MinMaxScaler()
        df[column] = scaler.fit_transform(df[[column]])
    return df

#-----#
# MAIN PROGRAM #
#-----#

try:
    # Directory where the model and scalers live (inside the image)
    model_dir = "/app"

    # Directory where the user's data is mounted
    wd = os.environ.get("SAFE_AORTA_WD", "/data")
    print(f"Working directory: {wd}")

    # Paths to model + scalers (inside image)
    scalers_path = os.path.join(model_dir, "trained_scalers.pkl")
    model_path = os.path.join(model_dir, "model.keras")

    # Load scalers and model from /app (baked into the image)
    trained_scalers = joblib.load(scalers_path)
    model = tf.keras.models.load_model(model_path)

    # Check that the Excel input exists in the mounted working directory
    input_excel_path = os.path.join(wd, "input_point_cloud.xlsx")
    if not os.path.exists(input_excel_path):

```

```

raise FileNotFoundError(
    "input_point_cloud.xlsx not found in working directory. "
    "Run the MATLAB Docker app first to generate it."
)

print('Point cloud of the aorta found in Working Directory (input_point_cloud.xlsx).\n')

t_start = time.time()

# Load once (raw), then we will copy per-time to avoid cumulative changes
df_raw = pd.read_excel(input_excel_path, engine='openpyxl')

# Normalize coordinates once (same for every time)
df_raw = normalize_x_vars(df_raw)
print('Input data for the model loaded from the Working Directory.\n')

# Crop once (same for every time)
min_z, max_z = 0.3, 0.8
df_raw = df_raw[(df_raw['Points:2'] >= min_z) & (df_raw['Points:2'] <=
max_z)].reset_index(drop=True)

# Time phases to run
times = [2, 3, 5, 8, 10, 24]

html_dir = os.path.join(wd, "html")
img_dir = os.path.join(html_dir, "images") # images inside html
os.makedirs(html_dir, exist_ok=True)
os.makedirs(img_dir, exist_ok=True)

for t in times:
    # Work on a copy
    df_test = df_raw.copy()

    # Insert + normalize "time" using the trained scaler
    df_test['time'] = t
    df_test['time'] = trained_scalers['time'].transform(df_test[['time']])

    # Create x_test
    x_test = df_test[x_variables].values # ensures correct column order

    # Predict
    predictions_normalized = model.predict(x_test, verbose=0)
    predictions_normalized_df = pd.DataFrame(predictions_normalized,
columns=y_variables)

```

```

predictions = denormalize_df(predictions_normalized_df, trained_scalers)

print(f'Prediction done by the model for Time Phase = {t}.')

# Insert the coordinates into the prediction dataframe (original normalized coordinates)
predictions.insert(0, 'x', df_test[x_variables[0]].values)
predictions.insert(1, 'y', df_test[x_variables[1]].values)
predictions.insert(2, 'z', df_test[x_variables[2]].values)

# Export per-time results
output_excel_path = os.path.join(wd, f'output_results_t_{t}.xlsx')
predictions.to_excel(output_excel_path, index=False)
print(f'Exported: {os.path.basename(output_excel_path)}')

#-----#
----#
# VISUALIZATION EXPORT (HTML) #
#-----#

variable = 'vz' # change if you want
var_name = var_names.get(variable, variable)
pred = predictions[variable].values

# Coordinates (normalized coordinates, as in your original plotting)
x = df_test[x_variables[0]].values
y = df_test[x_variables[1]].values
z = df_test[x_variables[2]].values

# ---- 3D Plotly HTML ----
fig3d = go.Figure()
fig3d.add_trace(go.Scatter3d(
    x=x, y=y, z=z,
    mode='markers',
    marker=dict(
        size=4,
        color=pred,
        colorscale='Viridis',
        cmin=float(np.min(pred)),
        cmax=float(np.max(pred)),
        colorbar=dict(title='Values', x=1.01, len=0.75),
        showscale=True
    ),
    name=f'{variable} prediction'
))

```

```

fig3d.update_layout(
    title=f'3D Prediction: {var_name} (t={t})',
    scene=dict(xaxis_title='X', yaxis_title='Y', zaxis_title='Z'),
    margin=dict(l=0, r=0, b=0, t=40)
)

html_3d_path = os.path.join(html_dir, f'pred_3d_{variable}_t_{t}.html')
fig3d.write_html(html_3d_path, include_plotlyjs="cdn")
print(f'Saved 3D HTML: {os.path.basename(html_3d_path)}")

# ---- 2D slice PNGs + one gallery HTML ----
step = 0.1
tolerance = 0.01
z_values = np.arange(float(np.min(z)), float(np.max(z)), step)

saved_pngs = []
for z_value in z_values:
    mask = (z >= z_value - tolerance) & (z <= z_value + tolerance)
    x_slice = x[mask]
    y_slice = y[mask]
    pred_slice = pred[mask]

    if pred_slice.size == 0:
        continue

    fig, ax = plt.subplots(figsize=(7, 6))
    sc = ax.scatter(
        x_slice, y_slice,
        c=pred_slice, cmap='viridis',
        marker='o', edgecolor='k',
        vmin=float(np.min(pred_slice)),
        vmax=float(np.max(pred_slice))
    )
    ax.set_title(f'{var_name} at Z ~ {z_value:.2f} (t={t})')
    ax.set_xlabel('X')
    ax.set_ylabel('Y')
    cbar = fig.colorbar(sc, ax=ax, orientation='vertical')
    cbar.set_label('Values')
    plt.tight_layout()

    png_name = f'slice_{variable}_t_{t}_z_{z_value:.2f}.png'
    png_path = os.path.join(img_dir, png_name)
    fig.savefig(png_path, dpi=200)
    plt.close(fig)

```

```

    saved_pngs.append(png_name)

gallery_path = os.path.join(html_dir, f'slices_{variable}_t_{t}.html")
with open(gallery_path, "w", encoding="utf-8") as f:
    f.write("<html><head><meta charset='utf-8'>")
    f.write(f"<title>Slices {variable} t={t}</title></head><body>\n")
    f.write(f"<h2>Slices for {var_name} (t={t})</h2>\n")
    f.write("<p>Images are saved in <code>/data/html/images</code>.</p>\n")
    for p in saved_pngs:
        f.write(f"<div style='margin:12px 0;'>"
                f"<div><b>{p}</b></div>"
                f"<img src='images/{p}' style='max-width:100%;height:auto;border:1px solid
#ccc;'>"
                f"</div>\n")
    f.write("</body></html>\n")

print(f"Saved slice gallery HTML: {os.path.basename(gallery_path)}")

print("\nElapsed time:', round((time.time() - t_start), 2), 'sec')

# For visualization later (pick one time to visualize, e.g., last one)
# If you don't need plotting in Docker, you can just skip all visualization below.
df_test = df_raw.copy()
df_test['time'] = times[-1]
df_test['time'] = trained_scalers['time'].transform(df_test[['time']])
# predictions = combined_results[-1].drop(columns=['time_phase']) if combined_results
else None

except Exception as e:
    print("\nError in line ' + str(e.__traceback__.tb_lineno) + ':'\n\n' + str(e))
    predictions = None
    df_test = None

#-----#

```