

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



Παραδοτέο Π5.1.
Λογισμικό ΣΥΠΟΚΑ

Όνομα Αρχείου:	Safe-Aorta-D5.1-v1.0-Λογισμικό ΣΥΠΟΚΑ.pdf	Επίπεδο Διάδοσης:	Δημόσιο
Ημερομηνία Υποβολής:	Δεκέμβριος 2025 (M29)	Κωδικός Έργου:	TAEDR-0535983
Κοινοπραξία:	ΕΜΠ, ΠΔΜ, ΠΚ, ΕΛΜΕΠΑ, ΠΑΔΑ, ΠΒΕΑΑ, ΠΑΠΕΛ	Υπεύθυνος Παραδοτέου:	ΕΛΜΕΠΑ
Διάρκεια:	28 μήνες	Κατάσταση:	Τελική έκδοση

ΛΙΣΤΑ ΣΥΓΓΡΑΦΕΩΝ

Συγγραφείς				
#	Επίθετο	Όνομα	Φορέας	Email Επικοινωνίας
1	Μανίκης	Γεώργιος	ΕΛΜΕΠΑ	manikis@hmu.gr
2	Κουτουλάκης	Εμμανουήλ	ΕΛΜΕΠΑ	manoskout@ics.forth.gr
3	Δημητριάδης	Αβταντίλ	ΕΛΜΕΠΑ	dimitriadi@ics.forth.gr
4	Μαρκοδημητράκης	Εμμανουήλ	ΕΛΜΕΠΑ	manosmark@ics.forth.gr
5	Μαριάς	Κώστας	ΕΛΜΕΠΑ	kmarias@hmu.gr
6	Τσικνάκης	Εμμανουήλ	ΕΛΜΕΠΑ	tsiknaki@hmu.gr
7	Αθανασιάδης	Εμμανουήλ	ΠΑΔΑ	mathan@uniwa.gr
8	Βεντούρας	Ερρίκος	ΠΑΔΑ	vent@uniwa.gr
9	Κορκίδης	Παναγιώτης	ΠΑΔΑ	p.korkidis@uniwa.gr
10	Σκουρολιάκου	Αικατερίνη	ΠΑΔΑ	kskourol@uniwa.gr
11	Ντούνης	Αναστάσιος	ΠΑΔΑ	aidounis@uniwa.gr
12	Καλατζής	Ιωάννης	ΠΑΔΑ	ikalatzis@uniwa.gr
13	Κωστόπουλος	Σπυρίδων	ΠΑΔΑ	skostopoulos@uniwa.gr
14	Θεοχαράκης	Ιωάννης	ΠΑΔΑ	itheocharakis@uniwa.gr
Συν-συγγραφείς				
#	Επίθετο	Όνομα	Φορέας	Email Επικοινωνίας
1	Σταυρουλάκης	Γιώργος	ΠΚ	
2	Πετράκης	Ευριπίδης	ΠΚ	
3	Διαγγελάκης	Νικόλαος	ΠΚ	
4	Αντωνακάκης	Μάριος	ΠΚ	
5	Μπέη	Αικατερίνη	ΠΚ	
6	Μοιρογιώργου	Κωνσταντία	ΠΚ	
7	Κλαδοβασιλάκης	Νίκος	ΠΚ	
8	Μουρατίδου	Αλίκη	ΠΚ	
9	Καρασμανόγλου	Απόστολος	ΠΚ	
10	Πολιτώφ	Κωνσταντίνος	ΠΚ	
11	Χριστουλάκης	Μάριος	ΠΚ	
12	Ιωαννίδης	Μάριος	ΠΚ	
13	Αγγελίδης	Παντελής	ΠΔΜ	
14	Τσίπουρας	Μάρκος	ΠΔΜ	
15	Τζημούρτα	Αικατερίνη	ΠΔΜ	

16	Κατσούλη	Παρασκευή	ΠΑΔΜ	
----	----------	-----------	------	--

ΛΙΣΤΑ ΚΡΙΤΩΝ

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

Περιεχόμενα

Περιεχόμενα.....	5
1. Περιγραφή.....	6
2. Εισαγωγή	6
3. Περιγραφή των Safe Aorta Δεδομένων	8
4. Εξαγωγή Απεικονιστικών Χαρακτηριστικών της Αορτής	13
5. Μεθοδολογία Μηχανικής Μάθησης.....	15
5.1 Μεθοδολογία από την ομάδα του ΕΛΜΕΠΑ	15
5.1.1 Αλγόριθμοι Μηχανικής Μάθησης	15
5.1.2 Επιλογή Χαρακτηριστικών με LASSO.....	16
5.1.3 Σχεδιασμός Διασταυρούμενης Επικύρωσης.....	17
5.1.4 Αποτελέσματα Μηχανικής Μάθησης.....	17
5.1.5 Δημιουργία του Safe-Aorta ΣΥΠΟΚΑ.....	19
5.1.6 Συμπεράσματα και Περιορισμοί στην Ανάλυση	21
5.2 Μεθοδολογία από την ομάδα MEDISP του ΠΑΔΑ	22
5.2.1 Περιγραφή των δεδομένων	22
5.2.2 Μεθοδολογία Στατιστικής Ανάλυσης.....	22
5.2.3 Μεθοδολογία Μηχανικής Μάθησης.....	23
5.2.4 Αποτελέσματα Μηχανικής Μάθησης.....	25
5.2.5 Λογισμικό Μηχανικής Μάθησης και Στατιστικής Ανάλυσης.....	27
5.3 Μεθοδολογία από την ομάδα ACIMA του ΠΑΔΑ.....	30
5.3.1 Αλγόριθμοι Υπολογιστικής Νοημοσύνης.....	30
5.3.2 Ομαδοποίηση και Επιλογή Ραδιομικών Χαρακτηριστικών mRMR	36
5.3.3 Κανονικοποίηση και Διασταυρούμενη Επικύρωση	37
5.3.4 Πρακτικές Λεπτομέρειες Μεθοδολογίας και Αποτελέσματα	37
5.3.5 Συμπεράσματα	42
5.3.6 READ ME FOR SAFE-AORTA APP INSTALLATION INSTRUCTIONS.....	43

1. Περιγραφή

Το παρόν έγγραφο αποτελεί το Παραδοτέο 5.1 «Λογισμικό ΣΥΠΟΚΑ» του έργου **SAFE-AORTA**, το οποίο χρηματοδοτείται από το Ταμείο Ανάκαμψης και Ανθεκτικότητας στο πλαίσιο του προγράμματος «Ελλάδα 2.0 ΕΘΝΙΚΟ ΣΧΕΔΙΟ ΑΝΑΚΑΜΨΗΣ ΚΑΙ ΑΝΘΕΚΤΙΚΟΤΗΤΑΣ», της δράσης «Εμβληματικές δράσεις σε διαθεματικές επιστημονικές περιοχές με ειδικό ενδιαφέρον για την σύνδεση με τον παραγωγικό ιστό» (ID 16618) με κωδικό ΟΠΣ ΤΑ 5149305.

Το έργο **SAFE-AORTA** επικεντρώνεται στην ανάπτυξη μιας καινοτόμου πλατφόρμας που υποστηρίζει τη διάγνωση, παρακολούθηση και θεραπεία ασθενών με ανεύρυσμα κοιλιακής αορτής (ΑΚΑ). Στα πλαίσια του Παραδοτέου 5.1 αναπτύχθηκε ένα ολοκληρωμένο πλαίσιο μοντέλων μηχανικής μάθησης το οποίο πλαισιώθηκε από ένα Σύστημα Υποστήριξης Κλινικών Αποφάσεων (ΣΥΠΟΚΑ) με χρήση νομογράμματος, παρέχοντας υψηλή ερμηνευσιμότητα και διευκόλυνση στην λήψη αποφάσεων από τον κλινικό αναφορικά με την ακριβή πρόβλεψη της πιθανότητας ρήξης ΑΚΑ.

2. Εισαγωγή

Το ανεύρυσμα κοιλιακής αορτής (ΑΚΑ) αποτελεί μία από τις σημαντικότερες αγγειακές παθήσεις με εκτιμώμενο επιπολασμό 4-8% στους άνδρες άνω των 65 ετών. Η ρήξη του ΑΚΑ συνδέεται με θνητότητα που υπερβαίνει το 80%, καθιστώντας την πρόληψη και την έγκαιρη αντιμετώπιση θέματα κρίσιμης κλινικής σημασίας¹. Σύμφωνα με τις τρέχουσες κατευθυντήριες οδηγίες της Ευρωπαϊκής Εταιρείας Αγγειακής Χειρουργικής (ESVS), η προληπτική επέμβαση συνιστάται όταν η μέγιστη διάμετρος του ανευρύσματος υπερβεί τα 55mm στους άνδρες ή τα 50mm στις γυναίκες². Η παθοφυσιολογία του ΑΚΑ χαρακτηρίζεται από χρόνια φλεγμονή, αποδόμηση της εξωκυττάριας θεμέλιας ουσίας και απώλεια λείων μυϊκών κυττάρων στο τοίχωμα της αορτής. Οι παράγοντες κινδύνου περιλαμβάνουν το κάπνισμα (ισχυρότερος τροποποιησιμος παράγοντας), την υπέρταση, τη δυσλιπιδαιμία, το οικογενειακό ιστορικό και την προχωρημένη ηλικία³. Ειδικότερα, το κάπνισμα έχει συσχετιστεί με 5-πλάσιο κίνδυνο ανάπτυξης ΑΚΑ και αυξημένο ρυθμό επέκτασης⁴. Παρά την καθιέρωση του κατωφλίου των 55mm για χειρουργική παρέμβαση, σημαντικό ποσοστό ρήξεων συμβαίνει σε ανευρύσματα μικρότερης διαμέτρου, ενώ παράλληλα πολλά μεγάλα ανευρύσματα παραμένουν σταθερά. Αυτή η κλινική πραγματικότητα υποδεικνύει ότι η διάμετρος από μόνη της δεν αποτελεί επαρκή προβλεπτική μεταβλητή του κινδύνου ρήξης και

¹ Sakalihasan N, Michel JB, Katsargyris A, et al. Abdominal aortic aneurysms. Nat Rev Dis Primers. 2018;4(1):34

² Wanhainen A, Verzini F, Van Herzele I, et al. Editor's Choice - European Society for Vascular Surgery (ESVS) 2019 Clinical Practice Guidelines on the Management of Abdominal Aorto-iliac Artery Aneurysms. Eur J Vasc Endovasc Surg. 2019;57(1):8-93

³ Golledge J. Abdominal aortic aneurysm: update on pathogenesis and medical treatments. Nat Rev Cardiol. 2019;16(4):225-242

⁴ Lederle FA, Johnson GR, Wilson SE, et al. Relationship of age, gender, race, and body size to infrarenal aortic diameter. J Vasc Surg. 1997;26(4):595-601

ότι απαιτούνται πιο εξελιγμένες μέθοδοι εκτίμησης κινδύνου που να λαμβάνουν υπόψη τα δομικά χαρακτηριστικά του τοιχώματος.

Η ραδιομική (radiomics) αποτελεί ένα αναδυόμενο πεδίο που αξιοποιεί την εξαγωγή ποσοτικών χαρακτηριστικών από ιατρικές εικόνες με στόχο την ανακάλυψη βιοδεικτών με προγνωστική και διαγνωστική αξία⁵. Η βασική υπόθεση της ραδιομικής είναι ότι οι ιατρικές εικόνες περιέχουν πληροφορία που δεν είναι άμεσα ορατή στον κλινικό, αλλά μπορεί να εξαχθεί και να ποσοτικοποιηθεί μέσω υπολογιστικών μεθόδων. Τα ραδιομικά χαρακτηριστικά περιλαμβάνουν στατιστικά μεγέθη πρώτης τάξης (π.χ. μέση τιμή, διακύμανση), χαρακτηριστικά υφής (texture features) που ποσοτικοποιούν χωρικές σχέσεις μεταξύ εντάσεων, και γεωμετρικά χαρακτηριστικά (shape features)⁶. Στο πεδίο των αγγειακών παθήσεων, η ραδιομική έχει εφαρμοστεί για τον χαρακτηρισμό της αθηρωματικής πλάκας και την πρόβλεψη καρδιαγγειακών επεισοδίων⁷. Η μηχανική μάθηση (machine learning - ML) έχει αποκτήσει ολοένα και μεγαλύτερη σημασία στην ιατρική απεικόνιση λόγω της ικανότητάς της να αναγνωρίζει πολύπλοκα μοτίβα σε υψηλής διάστασης δεδομένα⁸. Παρά την πρόοδο αυτή, υπάρχουν σημαντικές μεθοδολογικές προκλήσεις. Κύριο στοιχείο αυτών αποτελεί ο λεπτομερής χαρακτηρισμός/σκιαγράφηση των περιοχών ενδιαφέροντος από τις οποίες εξάγονται τα απεικονιστικά χαρακτηριστικά. Επιπλέον, το περιορισμένο μέγεθος δείγματος στις περισσότερες μελέτες περιορίζει τη δυνατότητα εξωτερικής επικύρωσης και αυξάνει τον κίνδυνο υπερπροσαρμογής αν δεν οριστεί ένα σαφές πλαίσιο για την αποφυγή διαρροής δεδομένων (data leakage) κατά την εκπαίδευση και αξιολόγηση της διαδικασίας.

Στο πλαίσιο αυτό, αναπτύχθηκε ένα ραδιομικό μοντέλο μηχανικής μάθησης το οποίο οδήγησε στην δημιουργία μιας «ραδιομικής υπογραφής» (τα σημαντικότερα απεικονιστικά χαρακτηριστικά από την σκιαγραφημένη περιοχή της αορτής με εργαλεία όπως αυτά περιγράφονται στο **Παραδοτέο Π4.1. Εργαλείο τμηματοποίησης εικόνων**) για την πρόβλεψη της πιθανότητας ρήξης ΑΚΑ. Στην συνέχεια η απεικονιστική υπογραφή αποτέλεσε είσοδο για την ανάπτυξη του Safe Aorta κλινικού νομογράμματος που συνδυάζει τη ραδιομική υπογραφή με κλινικές και δημογραφικές μεταβλητές, καθώς και πληροφορία από συννοσηρότητες και φαρμακευτική αγωγή (**Παραδοτέα Π3.1. Έκθεση Αναδρομικής Κλινικής Μελέτης** και **Π3.2. Έκθεση Προοπτικής Κλινικής Μελέτης**), παρέχοντας ένα εργαλείο άμεσα εφαρμόσιμο στην κλινική πράξη με διαφάνεια στην μοντελοποίηση και ερμηνευσιμότητα των αποτελεσμάτων.

⁵ Gillies RJ, Kinahan PE, Hricak H. Radiomics: Images Are More than Pictures, They Are Data. *Radiology*. 2016;278(2):563-577

⁶ Lambin P, Leijenaar RTH, Deist TM, et al. Radiomics: the bridge between medical imaging and personalized medicine. *Nat Rev Clin Oncol*. 2017;14(12):749-762

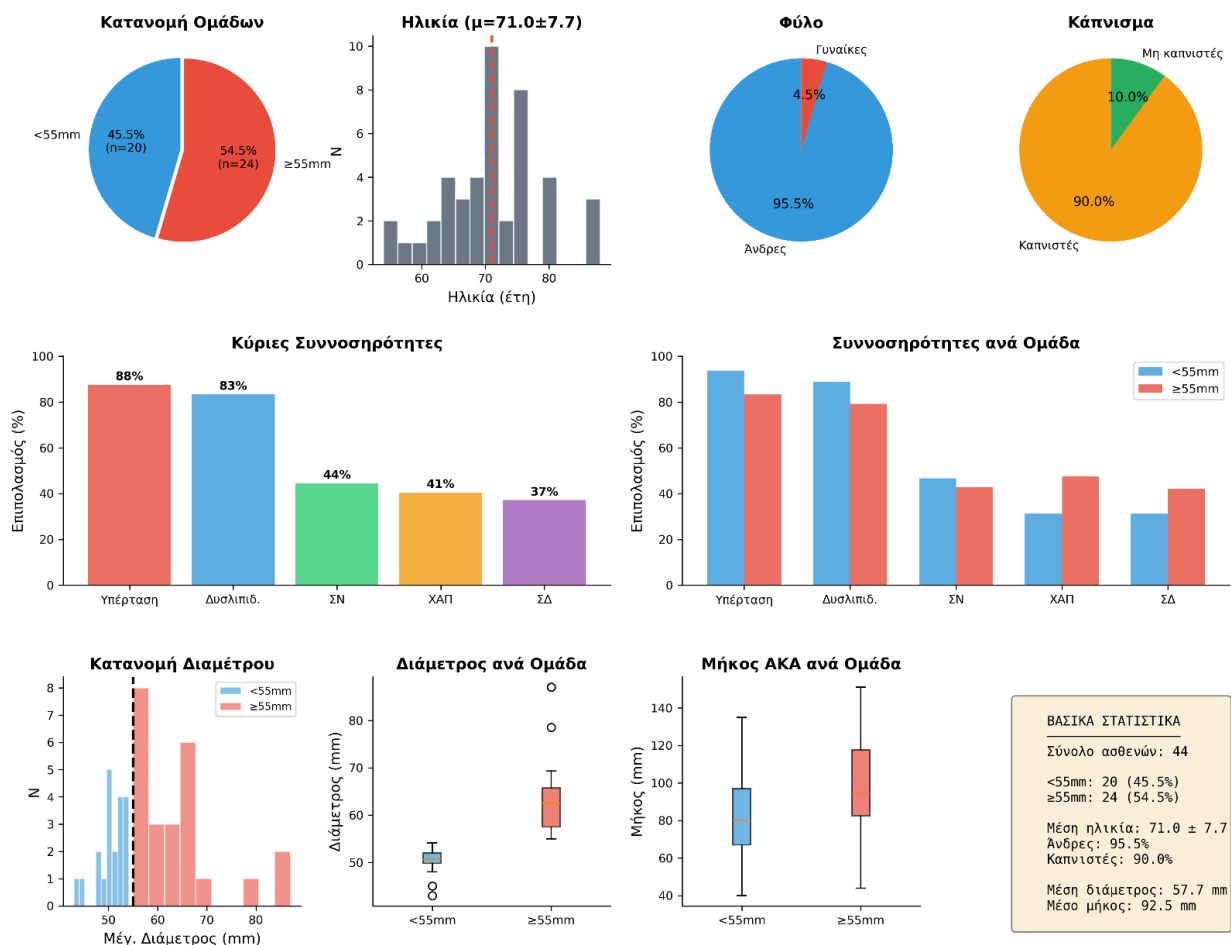
⁷ Kolossváry M, Karády J, Szilveszter B, et al. Radiomic Features Are Superior to Conventional Quantitative Computed Tomographic Metrics to Identify Coronary Plaques With Napkin-Ring Sign. *Circ Cardiovasc Imaging*. 2017;10(12):e006843

⁸ Rajkomar A, Dean J, Kohane I. Machine Learning in Medicine. *N Engl J Med*. 2019;380(14):1347-1358

3. Περιγραφή των Safe Aorta Δεδομένων

Στην ενότητα αυτή παρουσιάζουμε με συνοπτικό τρόπο το σύνολο των δεδομένων της μελέτης του έργου. Αναλυτικές πληροφορίες παρέχονται στα **Παραδοτέα Π3.1. Έκθεση Αναδρομικής Κλινικής Μελέτης** και **Π3.2. Έκθεση Προοπτικής Κλινικής Μελέτης**. Η μελέτη περιλαμβάνει ένα ολοκληρωμένο σετ πολυπαραγοντικών δεδομένων από 44 ασθενείς με διαγνωσμένο ανεύρυσμα κοιλιακής αορτής (ΑΚΑ) (συνολική επισκόπηση όπως φαίνεται στην Εικόνα 1). Ο πληθυσμός χαρακτηρίζεται από τυπικά επιδημιολογικά χαρακτηριστικά για το ανεύρυσμα κοιλιακής αορτής, με σαφή επικράτηση ανδρών, μέση ηλικία στην όγδοη δεκαετία της ζωής και πολύ υψηλό ποσοστό καπνιστικού ιστορικού. Οι ασθενείς με μεγαλύτερα ανευρύσματα τείνουν να είναι μεγαλύτεροι σε ηλικία, να έχουν υψηλότερο ποσοστό καπνιστικού ιστορικού και να εμφανίζουν συχνότερα χρόνια αποφρακτική πνευμονοπάθεια. Τα ανατομικά χαρακτηριστικά υποδεικνύουν ότι τα μεγαλύτερα ανευρύσματα σχετίζονται με μεγαλύτερη έκταση νόσου, όπως φαίνεται από το αυξημένο μήκος και την τάση για βραχύτερο αυχένα.

SAFE-AORTA: Επισκόπηση Πληθυσμού Μελέτης



Εικόνα 1 Συνολική επισκόπηση πληθυσμού μελέτης Safe-Aorta

Σε αυτούς τους ασθενείς συλλέχθηκαν δημογραφικά στοιχεία, κλινικά χαρακτηριστικά και ανατομικές μετρήσεις όπως φαίνεται παρακάτω:

- **Δημογραφικά στοιχεία:** Ηλικία, φύλο, σωματομετρικά δεδομένα
- **Ιστορικό καπνίσματος:** Κατάσταση καπνίσματος, pack-years
- **Συννοσηρότητες:** Καρδιαγγειακές παθήσεις, μεταβολικές διαταραχές, πνευμονοπάθειες
- **Φαρμακευτική αγωγή:** Στατίνες, αντιαιμοπεταλιακά, αντιπηκτικά, αντιυπερτασικά
- **Ανατομικά χαρακτηριστικά ΑΚΑ:** Διαστάσεις, μορφολογία, αγγείωση

Επιπροσθέτως, η δημιουργία προχωρημένων αλγορίθμων βαθιάς μάθησης για την αυτόματη τμηματοποίηση της κοιλιακής αορτής σε εικόνες X-ray CT (**Παραδοτέο Π4.1. Εργαλείο τμηματοποίησης εικόνων**) και η εφαρμογή καινοτόμων τεχνικών ανάλυσης της εικόνας για την εξαγωγή πολυδιάστατου σετ ποσοτικών δεδομένων από αυτές (radiomics), οδήγησε στην δημιουργία ενός πολυπληθούς σετ χαρακτηριστικών της κοιλιακής αορτής όπως περιγράφονται παρακάτω.

Αρχικά, οι ασθενείς κατηγοριοποιήθηκαν με βάση τη μέγιστη διάμετρο του ανευρύσματος σε δύο ομάδες, χρησιμοποιώντας ως κατώφλι τα 55mm, το οποίο αποτελεί ένα κλινικά καθιερωμένο όριο για εξέταση προληπτικής χειρουργικής αποκατάστασης:

Ομάδα	N	Ποσοστό
ΑΚΑ < 55mm (Κλάση 0)	20	45.5%
ΑΚΑ ≥ 55mm (Κλάση 1)	24	54.5%
Σύνολο	44	100%

Πίνακας 1. Κατανομή ασθενών ανά ομάδα μεγέθους ΑΚΑ

Όπως φαίνεται και από τον παραπάνω πίνακα, η κατανομή είναι σχετικά ισορροπημένη γεγονός που διευκολύνει την ανάλυση μηχανικής μάθησης και μειώνει την ανάγκη για τεχνικές εξισορρόπησης κλάσεων με χρήση συνθετικών δεδομένων. Ο Πίνακας 2 παρουσιάζει τα δημογραφικά χαρακτηριστικά του πληθυσμού μελέτης, συνολικά και ανά ομάδα μεγέθους ΑΚΑ. Οι συνεχείς μεταβλητές παρουσιάζονται ως μέσος όρος ± τυπική απόκλιση και οι κατηγορικές ως N (%). Επίσης η Εικόνα 2 παρουσιάζει αναλυτικά τα δημογραφικά χαρακτηριστικά του πληθυσμού με 6 πάνελ που περιλαμβάνουν την κατανομή ηλικίας ανά ομάδα, την κατανομή φύλου, τη σύγκριση ηλικίας μεταξύ ομάδων, τα ποσοστά καπνίσματος, την αθροιστική έκθεση σε pack-years και την κατανομή σωματικού βάρους.

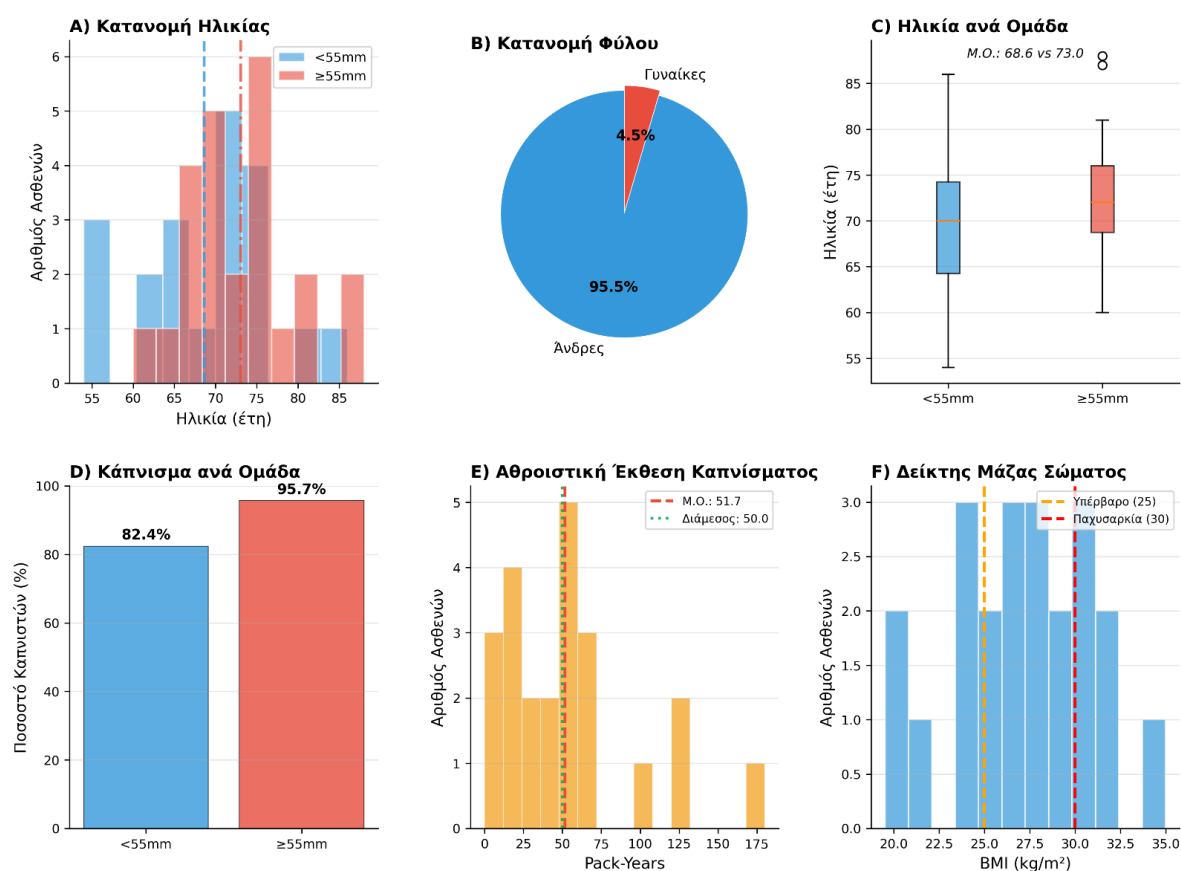
Μεταβλητή	Σύνολο (N=44)	<55mm (N=20)	≥55mm (N=24)
Ηλικία (έτη)	71.0 ± 7.7	68.6 ± 8.4	73.0 ± 6.7
Φύλο (άνδρες)	42 (95.5%)	20 (100%)	22 (91.7%)
Ύψος (cm)*	173.6 ± 7.2	172.9 ± 4.8	173.9 ± 8.5
Βάρος (kg)*	81.6 ± 14.0	86.4 ± 11.2	78.9 ± 15.1

Κάπνισμα	36 (90.0%)	14 (82.4%)	22 (95.7%)
Pack-years*	51.7 ± 43.6	42.5 ± 53.0	58.8 ± 35.4

Πίνακας 2. Δημογραφικά χαρακτηριστικά. Όπου * ελλιπής τιμές

Όπως φαίνεται και από τον πίνακα, η μέση ηλικία του πληθυσμού μελέτης είναι 71.0 ± 7.7 έτη, με τους ασθενείς με μεγαλύτερο ΑΚΑ ($\geq 55\text{mm}$) να είναι κατά μέσο όρο μεγαλύτεροι σε ηλικία (73.0 vs 68.6 έτη). Αυτή η διαφορά είναι κλινικά σημαντική και συνάδει με την αυξημένη επίπτωση μεγαλύτερων ανευρυσμάτων σε προχωρημένη ηλικία, καθώς η ηλικία αποτελεί έναν από τους κύριους παράγοντες κινδύνου για την ανάπτυξη και εξέλιξη του ΑΚΑ. Η συντριπτική πλειοψηφία των ασθενών είναι άνδρες (95.5%), γεγονός αναμενόμενο δεδομένου ότι το ΑΚΑ είναι 4-6 φορές συχνότερο στους άνδρες. Αξιοσημείωτο είναι ότι στην ομάδα $<55\text{mm}$ όλοι οι ασθενείς ήταν άνδρες, ενώ στην ομάδα $\geq 55\text{mm}$ υπήρχαν 2 γυναίκες (8.3%). Το ιστορικό καπνίσματος είναι εξαιρετικά υψηλό (90%), με υψηλότερο ποσοστό στην ομάδα μεγαλύτερων ανευρυσμάτων (95.7% vs 82.4%). Επιπλέον, τα pack-years είναι υψηλότερα στην ομάδα $\geq 55\text{mm}$ (58.8 vs 42.5), υποδεικνύοντας ισχυρότερη έκθεση στο κάπνισμα.

Δημογραφικά Χαρακτηριστικά Πληθυσμού Μελέτης



Εικόνα 2 Δημογραφικά χαρακτηριστικά πληθυσμού μελέτης

Ο Πίνακας 3 παρουσιάζει τις συννοσηρότητες του πληθυσμού μελέτης. Οι καρδιαγγειακές και μεταβολικές παθήσεις είναι ιδιαίτερα συχνές, αντανακλώντας το κοινό παθοφυσιολογικό υπόβαθρο με το ΑΚΑ.

Συννοσηρότητα	Σύνολο	<55mm	≥55mm
Υπέρταση	35 (87.5%)	15 (93.8%)	20 (83.3%)
Δυσλιπιδαιμία	35 (83.3%)	16 (88.9%)	19 (79.2%)
Στεφανιαία νόσος (CAD)	16 (44.4%)	7 (46.7%)	9 (42.9%)
ΧΑΠ (COPD)	15 (40.5%)	5 (31.2%)	10 (47.6%)
Σακχαρώδης διαβήτης	13 (37.1%)	5 (31.2%)	8 (42.1%)
ΑΕΕ/ΠΑΕ (CVD)	1 (3.0%)	1 (6.7%)	0 (0%)
Νεφρική ανεπάρκεια	1 (3.1%)	0 (0%)	1 (5.6%)

Πίνακας 3. Συννοσηρότητες του πληθυσμού μελέτης

Η υπέρταση (87.5%) και η δυσλιπιδαιμία (83.3%) είναι εξαιρετικά συχνές, αντανακλώντας την αθηροσκληρωτική φύση του ΑΚΑ. Αξιοσημείωτο είναι ότι τα ποσοστά αυτά είναι ελαφρώς υψηλότερα στην ομάδα μικρότερων ανευρυσμάτων, πιθανώς λόγω καλύτερης φαρμακευτικής διαχείρισης. Το ΧΑΠ είναι σημαντικά συχνότερη στην ομάδα μεγαλύτερων ανευρυσμάτων (47.6% vs 31.2%). Αυτό μπορεί να εξηγηθεί από κοινούς παθοφυσιολογικούς μηχανισμούς: το κάπνισμα προκαλεί τόσο ΧΑΠ όσο και αποδόμηση της ελαστίνης στο τοίχωμα της αορτής. Το ΧΑΠ αποτελεί και ανεξάρτητο παράγοντα κινδύνου για ταχύτερη εξέλιξη του ΑΚΑ. Η στεφανιαία νόσος εμφανίζεται σε παρόμοια ποσοστά στις δύο ομάδες (44.4% συνολικά), υποδεικνύοντας κοινή αθηροσκληρωτική νόσο χωρίς σαφή συσχέτιση με το μέγεθος του ΑΚΑ. Επιπλέον, παρατηρείται υψηλότερο ποσοστό διαβήτη στην ομάδα ≥55mm (42.1% vs 31.2%). Ωστόσο, η βιβλιογραφία παραμένει αντικρουόμενη σχετικά με τον ρόλο του διαβήτη στην εξέλιξη του ΑΚΑ, με ορισμένες μελέτες να υποδεικνύουν προστατευτικό ρόλο.

Ο Πίνακας 4 παρουσιάζει τη φαρμακευτική αγωγή των ασθενών. Σημειώνεται ότι τα δεδομένα φαρμακευτικής αγωγής παρουσιάζουν σημαντικό ποσοστό ελλειπουσών τιμών λόγω ελλιπούς καταγραφής σε ορισμένα κέντρα.

Φάρμακο	Σύνολο*	<55mm	≥55mm
Στατίνες	21 (87.5%)	9 (90.0%)	12 (85.7%)
Αντιυπερτασικά	19 (90.5%)	7 (87.5%)	12 (92.3%)
Αντιαιμοπεταλιακά	8 (61.5%)	3 (60.0%)	5 (62.5%)
Αντιδιαβητικά	6 (42.9%)	3 (42.9%)	3 (42.9%)

Πίνακας 4. Φαρμακευτική αγωγή. Όπου *, ποσοστά επί των διαθέσιμων δεδομένων

Η υψηλή συχνότητα χρήσης στατινών (87.5%) και αντιυπερτασικών (90.5%) αντανακλά την ορθή εφαρμογή των κατευθυντήριων οδηγιών για τη διαχείριση καρδιαγγειακού κινδύνου σε

ασθενείς με ΑΚΑ. Οι στατίνες έχουν δειχθεί ότι πιθανώς επιβραδύνουν την εξέλιξη του ανευρύσματος μέσω πλειοτροπικών αντιφλεγμονωδών δράσεων. Το σχετικά χαμηλότερο ποσοστό αντιαιμοπεταλιακών (61.5%) μπορεί να οφείλεται σε αντενδείξεις ή απουσία πρόσθετων αθηροσκληρωτικών επεισοδίων πέραν του ΑΚΑ.

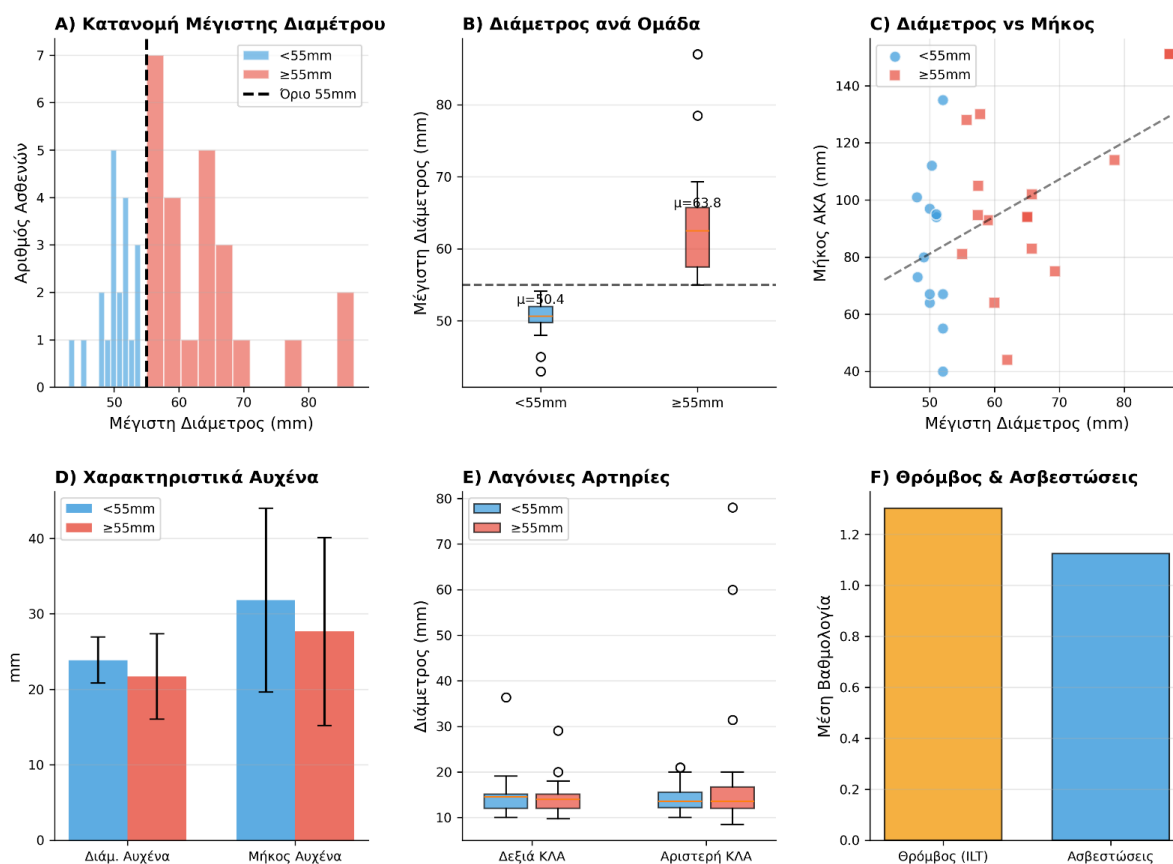
Ο Πίνακας 5 παρουσιάζει τα ανατομικά χαρακτηριστικά του ανευρύσματος. Αυτές οι μετρήσεις είναι κρίσιμες τόσο για τον σχεδιασμό της θεραπείας όσο και για την εκτίμηση του κινδύνου ρήξης. Όπως φαίνεται σε αυτόν, η μέση μέγιστη διάμετρος αορτής είναι 57.7 ± 9.6 mm, με σαφή διαφορά μεταξύ των δύο ομάδων (50.4 vs 63.8 mm) όπως αναμενόταν με βάση τον ορισμό των ομάδων. Η ομάδα ≥ 55 mm παρουσιάζει μεγαλύτερη διακύμανση ($SD = 9.1$ vs 2.8), υποδεικνύοντας ευρύτερο φάσμα μεγεθών. Τα μεγαλύτερα ανευρύσματα τείνουν να είναι και μακρύτερα (100.2 vs 83.1 mm), υποδεικνύοντας εκτεταμένη διάταση του αορτικού τοιχώματος. Αυτό έχει σημασία για τον σχεδιασμό ενδαγγειακής αποκατάστασης. Ενδιαφέρον παρουσιάζει ότι η ομάδα μεγαλύτερων ανευρυσμάτων έχει ελαφρώς μικρότερη διάμετρο (21.7 vs 23.9 mm) και μήκος αυχένα (27.7 vs 31.8 mm). Αυτό μπορεί να σχετίζεται με πιο εκτεταμένη νόσο που προσεγγίζει τις νεφρικές αρτηρίες.

Παράμετρος	Σύνολο	<55mm	≥ 55 mm
Μέγ. διάμετρος (mm)	57.7 ± 9.6	50.4 ± 2.8	63.8 ± 9.1
Μήκος ΑΚΑ (mm)*	92.5 ± 28.7	83.1 ± 25.7	100.2 ± 29.4
Διάμετρος αυχένα (mm)	22.7 ± 4.7	23.9 ± 3.1	21.7 ± 5.7
Μήκος αυχένα (mm)	29.6 ± 12.4	31.8 ± 12.2	27.7 ± 12.5
Υπονεφρική γωνία ($^{\circ}$)*	22.8 ± 14.4	19.1 ± 13.7	24.9 ± 14.8
Δ. ΔΚΛΑ (mm)	14.7 ± 4.8	14.9 ± 5.6	14.4 ± 4.1
Δ. ΑΚΛΑ (mm)	17.0 ± 12.5	14.3 ± 3.3	19.3 ± 16.6

Πίνακας 5. Ανατομικά χαρακτηριστικά ΑΚΑ. Όπου *, με ελλιπής τιμές

Η εικόνα 3 παρουσιάζει αναλυτικά τα ανατομικά χαρακτηριστικά των ανευρυσμάτων με 6 πάνελ που περιλαμβάνουν την κατανομή της μέγιστης διαμέτρου, τη σύγκριση διαμέτρου μεταξύ ομάδων, τη σχέση μεταξύ διαμέτρου και μήκους, τα χαρακτηριστικά του αυχένα, τις διαμέτρους των λαγονίων αρτηριών και την εκτίμηση του ενδοαυλικού θρόμβου και των ασβεστώσεων.

Ανατομικά Χαρακτηριστικά Ανευρύσματος Κοιλιακής Αορτής



Εικόνα 3 Ανατομικά χαρακτηριστικά ανευρυσμάτων

4. Εξαγωγή Απεικονιστικών Χαρακτηριστικών της Αορτής

Για την εξαγωγή των απεικονιστικών χαρακτηριστικών από την περιοχή της αορτής, χρησιμοποιήθηκαν τα παραγόμενα εργαλεία βαθιάς μάθησης όπως αυτά περιγράφονται στο **Παραδοτέο Π4.1. Εργαλείο τμηματοποίησης εικόνων**. Ιδιαίτερα σημαντική πληροφορία για την ανάπτυξη του λογισμικού ΣΥΠΟΚΑ αποτελεί η εξαγωγή μεγάλου πλήθους ποσοτικών χαρακτηριστικών με ραδιομική ανάλυση. Η εξαγωγή ραδιομικών χαρακτηριστικών πραγματοποιήθηκε σύμφωνα με τις οδηγίες του Image Biomarker Standardisation Initiative (IBSI) για τη διασφάλιση αναπαραγωγιμότητας και συγκρισιμότητας των αποτελεσμάτων. Συνολικά εξήχθησαν 5638 ραδιομικά χαρακτηριστικά για κάθε ασθενή, κατηγοριοποιημένα σε χαρακτηριστικά σχήματος, στατιστικά πρώτης τάξης και χαρακτηριστικά υφής. Τα τελευταία περιλαμβάνουν τη μήτρα συννεφάνισης επιπέδων του γκρι, τη μήτρα μηκών διαδρομών, τη μήτρα ζωνών μεγέθους και τη μήτρα εξάρτησης γειτονικών επιπέδων. Επιπλέον, εφαρμόστηκαν διάφορα φίλτρα προεπεξεργασίας πριν την εξαγωγή χαρακτηριστικών, συμπεριλαμβανομένων του exponential filter, του square filter, του wavelet transform και του Laplacian of Gaussian. Η εφαρμογή αυτών των φίλτρων πολλαπλασιάζει

τον αριθμό των διαθέσιμων χαρακτηριστικών και επιτρέπει την ανάλυση της εικόνας σε διαφορετικές κλίμακες και αναπαραστάσεις. Τα χαρακτηριστικά κατηγοριοποιούνται ως εξής:

Κατηγορία	Περιγραφή	N χαρακτ.
Shape features	Γεωμετρικά χαρακτηριστικά	~14
First-order features	Στατιστικά ιστογράμματος	~18
GLCM features	Μήτρα συνεμφάνισης	~24
GLRLM features	Μήτρα μηκών διαδρομών	~16
GLSZM features	Μήτρα ζωνών μεγέθους	~16
Filtered features	Wavelet, LoG, κ.λπ.	~5.500

Πίνακας 6. Κατηγορίες ραδιομικών χαρακτηριστικών.

Τα δεδομένα που αναλύονται στην παρούσα μελέτη αφορούν χαρακτηριστικά που εξήχθησαν μέσω διαδικασίας ραδιομικής, με τη χρήση του λογισμικού PyRadiomics (έκδοση 3.0.1) στη γλώσσα προγραμματισμού Python (έκδοση 3.9.23). Η διαδικασία εξαγωγής σχεδιάστηκε ώστε να υπολογίζει πολυδιάστατες παραμέτρους απεικονιστικών δεδομένων, περιλαμβάνοντας τόσο τρισδιάστατη (3D) ογκομετρική ανάλυση όσο και δισδιάστατη (2D) ανάλυση στα αξονικά (Axial), στεφανιαία (Coronal) και οβελιαία (Sagittal) επίπεδα. Οι τρισδιάστατοι όγκοι των ανευρυσμάτων κοιλιακής αορτής (AAA) εξετάστηκαν διεξοδικά για πιθανές ασυμφωνίες δεδομένων και επικαλύψεις επισημάνσεων (labels). Για τον περιορισμό του πεδίου όρασης (Field of View – FOV) εφαρμόστηκε περικοπή όγκου (volume cropping), δημιουργώντας ένα πλαίσιο που περιέκλειε την περιοχή ενδιαφέροντος, με αρχή κοντά στις νεφρικές αρτηρίες και επέκταση έως το επίπεδο της διακλάδωσης των κοινών λαγόνιων αρτηριών.

Όλες οι εικόνες υπολογιστικής τομογραφίας (CT) και οι αντίστοιχες τμηματοποιημένες μάσκες κανονικοποιήθηκαν προκειμένου να εξασφαλιστεί η ομοιογένεια των εξαγόμενων χαρακτηριστικών. Η διαδικασία αυτή περιλάμβανε επαναδειγματοληψία των όγκων σε ισοτροπική απόσταση voxel 1 mm³, με χρήση παρεμβολής B-spline. Στη συνέχεια, οι τιμές έντασης διακριτοποιήθηκαν με σταθερό πλάτος bin ίσο με 25 μονάδες Hounsfield, τιμή κατάλληλη για δεδομένα CT, πριν από τον υπολογισμό των χαρακτηριστικών. Οι αρχικοί τρισδιάστατοι όγκοι CT αξιολογήθηκαν από τις ιατρικές ομάδες του έργου, οι οποίες πραγματοποίησαν την τμηματοποίηση του αυλού, του ενδοαυλικού θρόμβου (Intraluminal Thrombus – ILT) και τυχόν ασβεστώσεων. Στη συνέχεια, δημιουργήθηκε ένα ενιαίο Voxel of Interest (VOI) μέσω συγχώνευσης των επιμέρους επισημάνσεων, το οποίο χρησιμοποιήθηκε για την εξαγωγή των ραδιομικών χαρακτηριστικών.

Υπολογίστηκε ένα εκτενές σύνολο τρισδιάστατων ογκομετρικών χαρακτηριστικών ραδιομικής, το οποίο περιλάμβανε χαρακτηριστικά πρώτης τάξης (First-order), χαρακτηριστικά σχήματος (Shape) και χαρακτηριστικά υφής (Textural Features). Τα χαρακτηριστικά υφής προέκυψαν από τους πίνακες Gray Level Co-occurrence Matrix (GLCM), Gray Level Run Length Matrix (GLRLM), Gray Level Size Zone Matrix (GLSZM),

Neighboring Gray Tone Difference Matrix (NGTDM) και Gray Level Dependence Matrix (GLDM).

Για την ανάλυση σε επίπεδο 2D, τα χαρακτηριστικά υπολογίστηκαν ανεξάρτητα σε κάθε τομή κατά μήκος των αξονικών, στεφανιαίων και οβελιαίων επιπέδων. Οι τιμές των χαρακτηριστικών σε επίπεδο τομής συγκεντρώθηκαν στη συνέχεια σε μία συνοπτική αντιπροσωπευτική τιμή ανά χαρακτηριστικό και επίπεδο. Προκειμένου να αποφευχθεί ο πλεονασμός πληροφορίας και η πιθανή αστάθεια που μπορεί να προκύψει από τη συγκέντρωση 2D χαρακτηριστικών, τα χαρακτηριστικά σχήματος 2D δεν υπολογίστηκαν, καθώς περιγράφονται επαρκώς από τα αντίστοιχα χαρακτηριστικά σχήματος 3D. Επιπλέον, για την καταγραφή πολυκλιμακικών πληροφοριών και μετασχηματισμών έντασης, εφαρμόστηκε πλήρες σύνολο φίλτρων εικόνας πριν από τον υπολογισμό των χαρακτηριστικών. Τα φίλτρα αυτά περιλάμβαναν: (α) αρχικά δεδομένα (Original), (β) μετασχηματισμό κυματίου σε οκτώ υποζώνες (Wavelet), (γ) Laplacian of Gaussian με τιμές σίγμα 1,0, 2,0, 3,0 και 5,0, (δ) τετραγώνου (Square), (ε) τετραγωνικής ρίζας (Square Root), (στ) λογαριθμικό (Logarithm), (ζ) εκθετικό (Exponential) και (η) Gradient.

5. Μεθοδολογία Μηχανικής Μάθησης

5.1 Μεθοδολογία από την ομάδα του ΕΛΜΕΠΑ

5.1.1 Αλγόριθμοι Μηχανικής Μάθησης

Αξιολογήθηκαν συστηματικά 13 αλγόριθμοι μηχανικής μάθησης από 4 διακριτές οικογένειες, παρέχοντας ολοκληρωμένη σύγκριση διαφορετικών προσεγγίσεων. Η οικογένεια regression-based περιλαμβάνει Lasso (L1 regularization), Ridge (L2 regularization), και ElasticNet (συνδυασμός L1+L2), οι οποίοι αποτελούν γραμμικά μοντέλα με διαφορετικούς τύπους κανονικοποίησης. Η οικογένεια ensemble περιλαμβάνει Random Forest και ExtraTrees που χρησιμοποιούν τεχνικές bootstrap aggregating, καθώς και AdaBoost που εφαρμόζει adaptive boosting. Η οικογένεια boosting περιλαμβάνει τους πιο εξελιγμένους αλγορίθμους gradient boosting: GradientBoosting από το scikit-learn⁹, XGBoost που αποτελεί βελτιστοποιημένη υλοποίηση με regularization, LightGBM που χρησιμοποιεί histogram-based splitting για ταχύτητα, και CatBoost που έχει ειδική υποστήριξη για κατηγορικές μεταβλητές. Τέλος, η οικογένεια SVM περιλαμβάνει Support Vector Machines με γραμμικό kernel και με RBF kernel για μη-γραμμικές σχέσεις. Όλοι οι αλγόριθμοι ρυθμίστηκαν με συντηρητικές υπερπαραμέτρους λόγω του μικρού μεγέθους δείγματος. Χρησιμοποιήθηκε class_weight='balanced' για τη διαχείριση της ανισορροπίας κλάσεων, μικρό βάθος δέντρων (max_depth=3-5) για τους tree-based αλγορίθμους, και ισχυρή κανονικοποίηση (χαμηλά C για regression/SVM) για τη μείωση της πολυπλοκότητας των μοντέλων.

Οικογένεια	Αλγόριθμος	Χαρακτηριστικά
Regression	Lasso (L1)	Sparse solutions, feature selection

⁹ <https://scikit-learn.org/>

	ElasticNet	L1+L2, handles correlated features
	Ridge (L2)	Shrinkage, stable coefficients
Ensemble	Random Forest	Bootstrap aggregating
	ExtraTrees	Extreme randomization
	AdaBoost	Adaptive boosting
	GradBoost	Gradient boosting
Boosting	XGBoost	Optimized gradient boosting
	LightGBM	Fast histogram-based
	CatBoost	Categorical features support
SVM	SVM Linear	Maximum margin, linear
	SVM RBF	Non-linear kernel
Distance	KNN	Instance-based learning

Πίνακας 7. Αλγόριθμοι μηχανικής μάθησης

Η αξιολόγηση της επίδοσης των μοντέλων βασίστηκε σε πολλαπλές μετρικές για ολοκληρωμένη εικόνα. Η κύρια μετρική ήταν το Area Under the ROC Curve (AUC-ROC), το οποίο ποσοτικοποιεί τη διακριτική ικανότητα του μοντέλου ανεξάρτητα από το κατώφλι ταξινόμησης. Το Area Under the Precision-Recall Curve (AUC-PR) είναι ιδιαίτερα χρήσιμο για ανισόρροπα σύνολα δεδομένων. Το F1 Score αποτελεί τον αρμονικό μέσο της precision και recall, ενώ το Brier Score μετρά τη βαθμονόμηση των πιθανοτήτων.

5.1.2 Επιλογή Χαρακτηριστικών με LASSO

Λόγω του μεγάλου αριθμού των εξαγόμενων ραδιομικών χαρακτηριστικών, σε κάθε εκπαίδευση χρησιμοποιήθηκαν τεχνικές ελάττωσης αριθμού/επιλογής ραδιομικών χαρακτηριστικών με σκοπό την επιλογή των κατάλληλων χαρακτηριστικών που οδηγούν στον βέλτιστο διαχωρισμό των 2 ομάδων ΑΚΑ. Η επιλογή χαρακτηριστικών πραγματοποιήθηκε με τη μέθοδο LASSO (Least Absolute Shrinkage and Selection Operator), η οποία επιτυγχάνει αυτόματη επιλογή χαρακτηριστικών μηδενίζοντας τους συντελεστές των λιγότερο σημαντικών μεταβλητών¹⁰. Η LASSO είναι ιδιαίτερα κατάλληλη για υψηλής διάστασης δεδομένα όπως τα ραδιομικά, όπου ο αριθμός των χαρακτηριστικών (5.638) υπερβαίνει κατά πολύ τον αριθμό των δειγμάτων (n=44). Η διαδικασία επιλογής ακολούθησε διαφασική προσέγγιση. Στην πρώτη φάση (εξερεύνηση), εφαρμόζεται LASSO στα δεδομένα εκπαίδευσης και καταγράφεται ποια χαρακτηριστικά επιλέγονται (δηλαδή αποκτούν μη-μηδενικό συντελεστή). Στη δεύτερη φάση (επικύρωση), τα χαρακτηριστικά που επιλέχθηκαν αποτελούν την τελική ραδιομική υπογραφή. Αυτή η προσέγγιση εξασφαλίζει ότι η υπογραφή περιέχει μόνο χαρακτηριστικά με σταθερή προβλεπτική αξία. Επιπλέον, εφαρμόστηκε ο κανόνας Events Per Variable (EPV) για την αποφυγή υπερπροσαρμογής. Σύμφωνα με αυτόν τον κανόνα, ο μέγιστος αριθμός χαρακτηριστικών στο τελικό μοντέλο πρέπει να είναι περίπου 1/10 του αριθμού events στη μειονοτική κλάση. Με 20 ασθενείς στην κλάση 0 (AKA <55mm), αυτό επιτρέπει 2-5

¹⁰ Tibshirani R. Regression Shrinkage and Selection via the Lasso. J R Stat Soc B. 1996;58(1):267-288

χαρακτηριστικά στην τελική υπογραφή, περιορίζοντας τον κίνδυνο υπερπροσαρμογής των μοντέλων μηχανικής μάθησης.

5.1.3 Σχεδιασμός Διασταυρούμενης Επικύρωσης

Για την αξιολόγηση της επίδοσης των μοντέλων εφαρμόστηκε επαναλαμβανόμενη στρωματοποιημένη διασταυρούμενη επικύρωση (Repeated Stratified K-Fold Cross-Validation), η οποία αποτελεί τη μέθοδο αναφοράς για μικρά σύνολα δεδομένων. Συγκεκριμένα, χρησιμοποιήθηκαν 100 επαναλήψεις των 4 folds (400 συνολικές επαναλήψεις), με στρωματοποίηση βάσει της κατηγορίας για τις 2 ομάδες ΑΚΑ και τη διατήρησή της σε κάθε fold. Η επιλογή 4 folds (αντί για το συνηθέστερο 5 ή 10) υπαγορεύθηκε από το μικρό μέγεθος δείγματος: με 44 ασθενείς, κάθε test fold περιέχει περίπου 11 δείγματα, εξασφαλίζοντας επαρκή αριθμό δειγμάτων ανά κλάση. Οι 100 επαναλήψεις παρέχουν σταθερές εκτιμήσεις της επίδοσης μειώνοντας τη διακύμανση που οφείλεται στον τυχαίο διαχωρισμό δεδομένων.

Κρίσιμο στοιχείο του σχεδιασμού είναι η αυστηρή διατήρηση του διαχωρισμού εκπαίδευσης-ελέγχου σε όλα τα στάδια της ανάλυσης. Συγκεκριμένα, τα ακόλουθα βήματα εκτελούνται εξ' ολοκλήρου εντός κάθε fold χρησιμοποιώντας αποκλειστικά τα δεδομένα εκπαίδευσης: η αντικατάσταση ελλειπουσών τιμών (median imputation), η κανονικοποίηση (Z-score standardization), και η επιλογή χαρακτηριστικών (LASSO feature selection). Τα δεδομένα ελέγχου μετασχηματίζονται με τις παραμέτρους που υπολογίστηκαν από τα δεδομένα εκπαίδευσης, χωρίς καμία πληροφορία να διαρρέει από το test set στη διαδικασία εκπαίδευσης. Αυτή η μεθοδολογία αποφεύγει τη διαρροή δεδομένων (data leakage), η οποία αποτελεί συχνή αιτία υπερεκτίμησης της επίδοσης σε μελέτες μηχανικής μάθησης, ιδιαίτερα στη ραδιομική. Η διαρροή δεδομένων συμβαίνει όταν πληροφορία από τα δεδομένα ελέγχου επηρεάζει τη διαδικασία εκπαίδευσης, για παράδειγμα όταν η επιλογή χαρακτηριστικών γίνεται σε όλα τα δεδομένα πριν τον διαχωρισμό.

Παράμετρος	Τιμή
Επαναλήψεις (repeats)	100
Folds ανά επανάληψη	4
Συνολικές επαναλήψεις	400
Στρωματοποίηση	Ναι με βάση την κατηγορική μεταβλητή για τις 2 ομάδες ΑΚΑ
Δείγματα εκπαίδευσης/fold	~33
Δείγματα test/fold	~11

Πίνακας 8. Παράμετροι διασταυρούμενης επικύρωσης

5.1.4 Αποτελέσματα Μηχανικής Μάθησης

Η διαδικασία επιλογής χαρακτηριστικών κατέληξε σε μία συμπαγή ραδιομική υπογραφή 3 χαρακτηριστικών υφής, τα οποία επιλέχθηκαν σταθερά σε περισσότερο από το 50% των 400 folds κατά την διάρκεια της εκπαίδευσης των μοντέλων. Το πρώτο χαρακτηριστικό είναι το RunVariance από τη μήτρα GLRLM μετά την εφαρμογή του φίλτρου exponential filter στις δισδιάστατες τομές της αορτής, το οποίο επιλέχθηκε σε 83.8% των folds και αποτελεί το πιο

σταθερά επιλεγόμενο χαρακτηριστικό. Το δεύτερο χαρακτηριστικό είναι το RunEntropy από τη μήτρα GLRLM μετά εφαρμογή exponential filter (65.8%) και το τρίτο χαρακτηριστικό είναι το SizeZoneNonUniformity από τη μήτρα GLSZM μετά από εφαρμογή του square filter, με συχνότητα επιλογής 59.2%. Αξιοσημείωτο είναι ότι και τα τρία χαρακτηριστικά προέρχονται από δισδιάστατες αξονικές τομές με εφαρμογή φίλτρων προεπεξεργασίας, υποδεικνύοντας ότι η κρίσιμη πληροφορία για το μέγεθος του ανευρύσματος κωδικοποιείται στη μικροδομή της εικόνας σε συγκεκριμένες αναπαραστάσεις. Δύο από τα τρία χαρακτηριστικά προέρχονται από τη μήτρα GLRLM που αναλύει τα μήκη διαδρομών ομοιογενούς έντασης, ενώ το τρίτο προέρχεται από τη μήτρα GLSZM που αναλύει τις ζώνες ομοιογενούς μεγέθους. Ο παρακάτω πίνακας παρουσιάζει την υπογραφή με τις συχνότητες επιλογής.

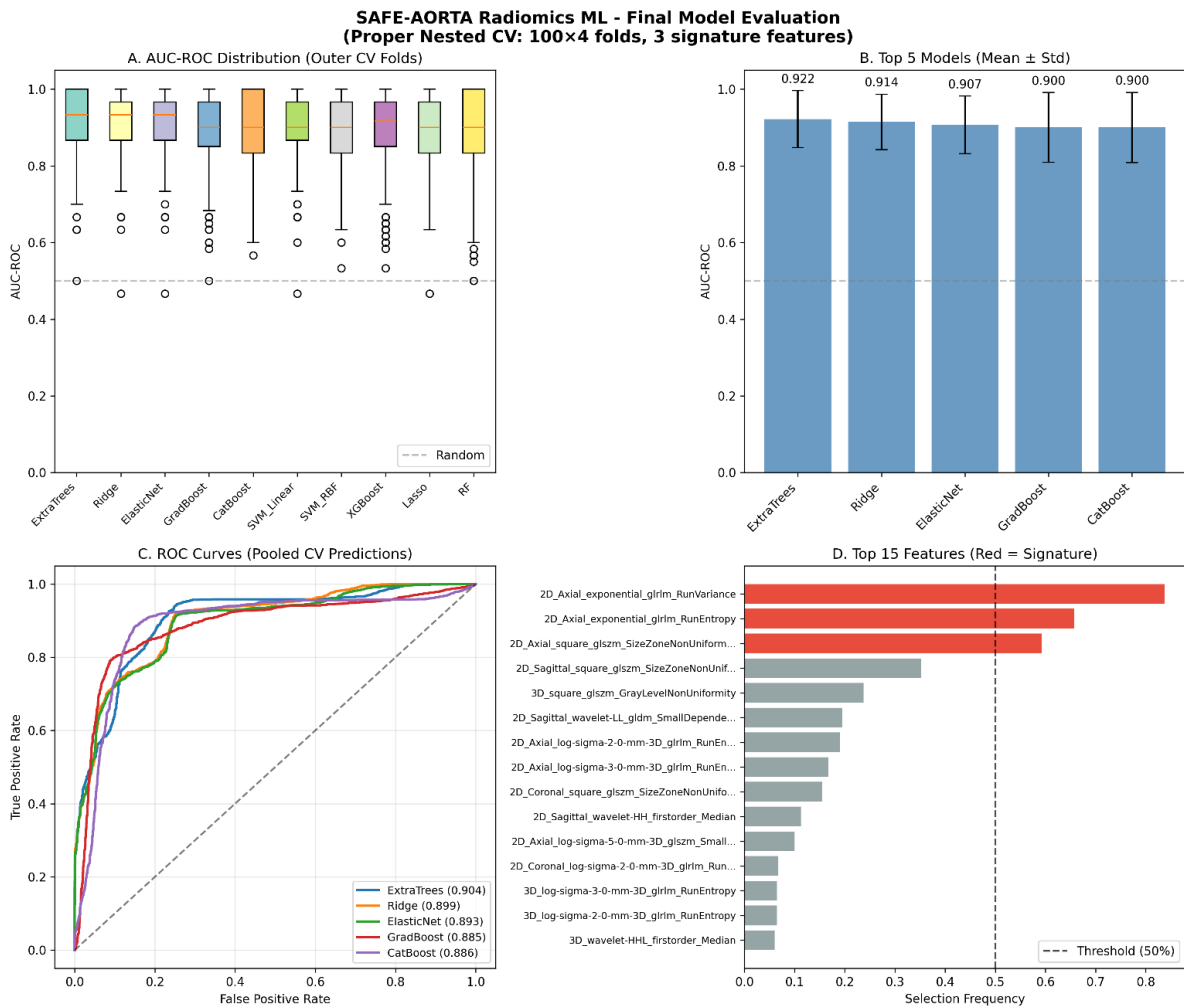
Το RunVariance από τη μήτρα GLRLM μετρά τη διακύμανση των μηκών διαδρομών (run lengths) ομοιόμορφης έντασης στην εικόνα. Υψηλές τιμές υποδεικνύουν ετερογενή υφή με μεγάλη διακύμανση στο μέγεθος των ομοιογενών περιοχών. Στο πλαίσιο του ΑΚΑ, αυτό μπορεί να αντανακλά ανομοιογένεια στη δομή του τοιχώματος ή του ενδοαυλικού θρόμβου, η οποία έχει συσχετιστεί με αυξημένο κίνδυνο ρήξης. Το SizeZoneNonUniformity από τη μήτρα GLSZM ποσοτικοποιεί την ομοιομορφία του μεγέθους των ζωνών ομοιόμορφης έντασης. Χαμηλές τιμές υποδεικνύουν ομοιογενή κατανομή μεγεθών ζωνών, ενώ υψηλές τιμές αντανακλούν ανομοιογένεια με κυριαρχία συγκεκριμένων μεγεθών. Αυτό μπορεί να σχετίζεται με τη δομική οργάνωση του θρόμβου και του τοιχώματος. Το RunEntropy μετρά την εντροπία (αταξία) της κατανομής run lengths. Υψηλές τιμές υποδεικνύουν πολύπλοκη υφή με μεγάλη ποικιλία μοτίβων, ενώ χαμηλές τιμές υποδεικνύουν πιο ομοιόμορφη δομή. Η εντροπία υφής έχει προταθεί ως δείκτης αστάθειας ιστού σε διάφορες παθολογικές καταστάσεις.

#	Χαρακτηριστικό	Συχνότητα
1	2D_Axial_exponential_glrlm_RunVariance	83.8%
2	2D_Axial_square_glszm_SizeZoneNonUniformity	65.8%
3	2D_Axial_exponential_glrlm_RunEntropy	59.2%

Πίνακας 9. Ραδιομική υπογραφή με συχνότητα επιλογής σε 400 folds

Ο αλγόριθμος ExtraTrees επέτυχε την υψηλότερη επίδοση με AUC: 0.922 ± 0.075 . Ακολουθεί ο Ridge με AUC: 0.914 ± 0.072 , και ο ElasticNet με AUC 0.907 ± 0.075 . Οι αλγόριθμοι GradientBoosting και CatBoost ισοβαθμούν στην τέταρτη θέση με AUC 0.900 ± 0.091 . **Αξιοσημείωτο είναι ότι τα δέκα καλύτερα μοντέλα επέτυχαν AUC μεγαλύτερο του 90%, υποδεικνύοντας την ισχυρή προβλεπτική αξία της ραδιομικής υπογραφής ανεξάρτητα από τον συγκεκριμένο αλγόριθμο.**

Η εικόνα 4 παρουσιάζει την ολοκληρωμένη ανάλυση μηχανικής μάθησης σε 4 πάνελ. Το πάνελ Α παρουσιάζει την κατανομή AUC για κάθε μοντέλο με boxplots από τις τετρακόσιες επαναλήψεις του εξωτερικού cross-validation (CV). Το πάνελ Β παρουσιάζει τα κορυφαία πέντε μοντέλα με μέσο AUC και διαστήματα σφάλματος (standard deviation). Το πάνελ Γ παρουσιάζει τις καμπύλες ROC για τα 5 κορυφαία μοντέλα. Το πάνελ Δ παρουσιάζει τη συχνότητα επιλογής των 15 κορυφαίων χαρακτηριστικών, με κόκκινο χρώμα τα 3 χαρακτηριστικά της υπογραφής που υπερβαίνουν το όριο του 50%.



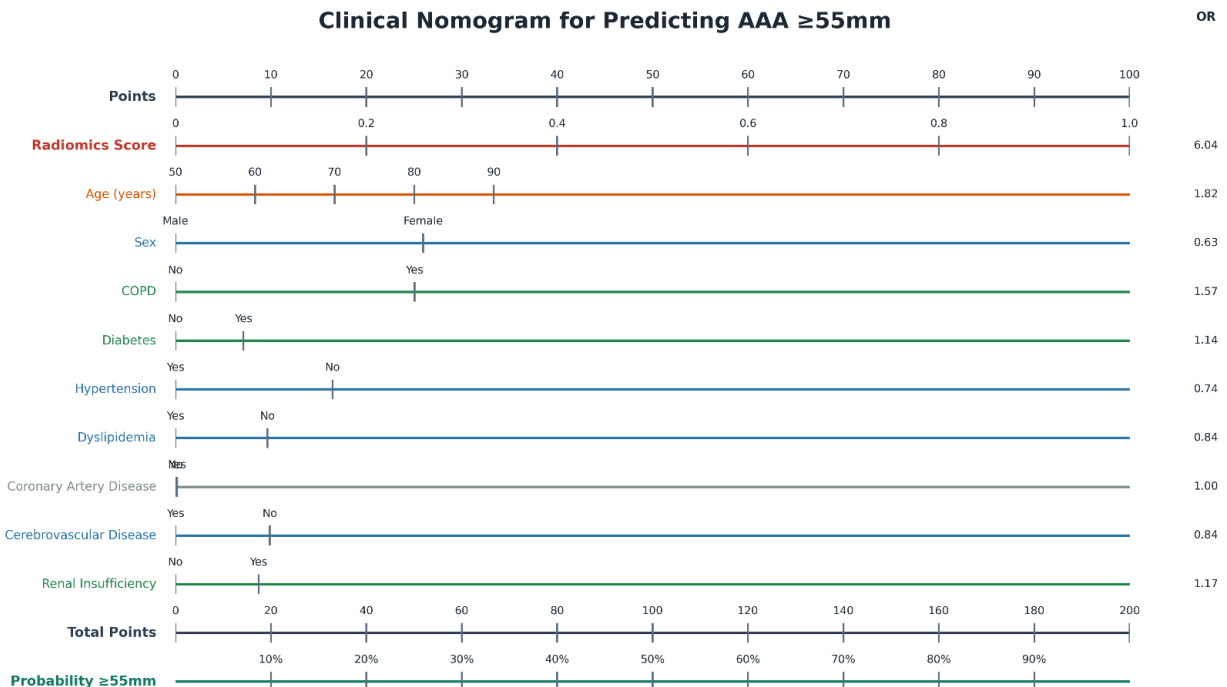
Εικόνα 4 Αποτελέσματα ανάλυσης μηχανικής μάθησης (Nested CV: 100×4 folds)

5.1.5 Δημιουργία του Safe-Aorta ΣΥΠΟΚΑ

Για την δημιουργία του εργαλείου ΣΥΠΟΚΑ, αναπτύχθηκε ένα κλινικό νομόγραμμα το οποίο συνδυάζει την σύντηξη πληροφορίας από την ραδιομική υπογραφή του μοντέλου μηχανικής μάθησης, τα βασικά δημογραφικά χαρακτηριστικά και τις ενδεχόμενες συννοσηρότητες όπως αυτές παρουσιάζονται στα δεδομένα του έργου που αναλύθηκαν. Οι μεταβλητές πλην της ραδιομικής υπογραφής περιλαμβάνουν την ηλικία, το φύλο, την υπέρταση, τον σακχαρώδη διαβήτη, τη δυσλιπιδαιμία, τη στεφανιαία νόσο, τη χρόνια αποφρακτική πνευμονοπάθεια, το αγγειακό εγκεφαλικό επεισόδιο και τη νεφρική ανεπάρκεια. Για το νομόγραμμα, χρησιμοποιήθηκε Ridge λογιστική παλινδρόμηση για τη διασφάλιση σταθερότητας των συντελεστών παρουσία συσχετισμένων μεταβλητών. Η αξιολόγηση του νομογράμματος πραγματοποιήθηκε με την ίδια ακριβώς επαναληπτική διαδικασία που χρησιμοποιήθηκε και στην ανάπτυξη των μοντέλων μηχανικής μάθησης, εξασφαλίζοντας δίκαιη σύγκριση μεταξύ των μοντέλων. Αυτή η μεθοδολογική συνέπεια είναι κρίσιμη για την αξιόπιστη αξιολόγηση της προστιθέμενης αξίας του συνδυασμού ραδιομικών και κλινικών δεδομένων.

Όπως φαίνεται και στα αποτελέσματα της παρακάτω εικόνας (Εικόνα 5) η ραδιομική υπογραφή αποτελεί μακράν τον ισχυρότερο προβλέπτη στο νομόγραμμα με odds ratio 6.04.

Αυτό σημαίνει ότι αύξηση κατά μία μονάδα στο σκορ του νομογράμματος σχετίζεται με σχεδόν εξαπλάσιες πιθανότητες για ανεύρυσμα ίσο ή μεγαλύτερο των 55mm. Η ηλικία αποτελεί τον δεύτερο ισχυρότερο προβλέπτη με odds ratio 1.82, υποδεικνύοντας ότι μεγαλύτερη ηλικία σχετίζεται με μεγαλύτερα ανευρύσματα.



Εικόνα 5 Το λογισμικό ΣΥΠΟΚΑ μέσω του Safe Aorta νομογράμματος

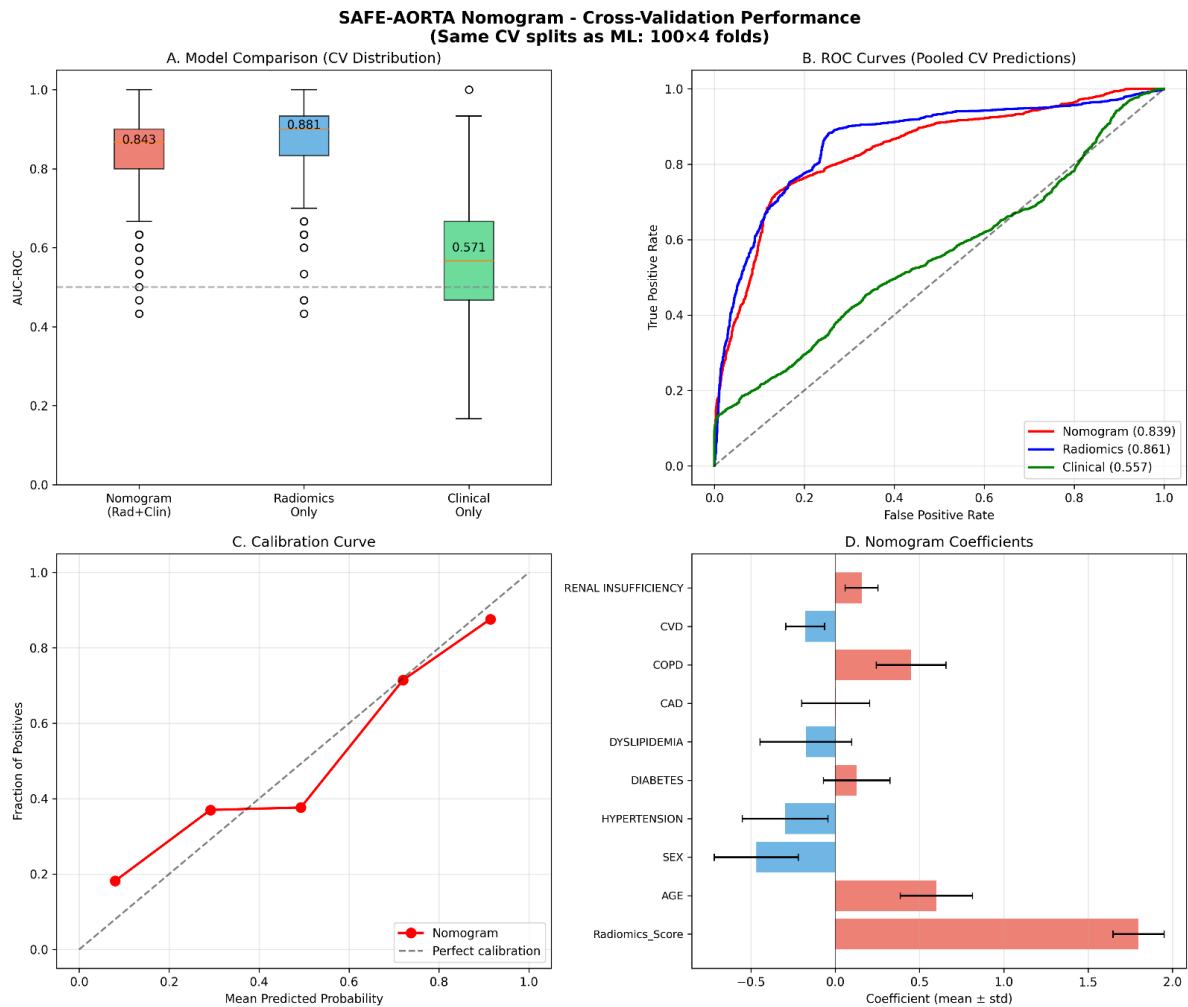
Οδηγίες χρήσης νομογράμματος

1. Για κάθε μεταβλητή, εντοπίστε την τιμή του ασθενούς στην αντίστοιχη κλίμακα
2. Σχεδιάστε κάθετη γραμμή προς την κλίμακα 'Points' στην κορυφή
3. Καταγράψτε τους πόντους για κάθε μεταβλητή
4. Αθροίστε όλους τους πόντους για να λάβετε το 'Total Points'
5. Εντοπίστε την αντίστοιχη πιθανότητα στην κλίμακα 'Probability' στο κάτω μέρος

Στο τελευταίο μέρος της ανάλυσης προχωρήσαμε σε σύγκριση μεταξύ 3 βασικών μοντέλων:

- Μοντέλο μηχανικής μάθησης με δεδομένα αποκλειστικά από την ραδιομική ανάλυση
- Μοντέλο μηχανικής μάθησης, χρησιμοποιώντας αποκλειστικά κλασσικές κλινικές μεταβλητές όπως αυτές καταγράφονται στην κλινική ρουτίνα
- Το νομόγραμμα, προερχόμενο από την σύντηξη όλης της διαθέσιμης πληροφορίας

Τα αποτελέσματα της ανάλυσης παρουσιάζονται στην Εικόνα 6. Στο πάνελ Α απεικονίζεται η σύγκριση της κατανομής AUC μεταξύ των 3 μοντέλων. Το πάνελ Β παρουσιάζει τις καμπύλες ROC από την επαναληπτική αξιολόγηση για τα 3 μοντέλα. Το πάνελ Γ παρουσιάζει την καμπύλη βαθμονόμησης του νομογράμματος που δείχνει καλή συμφωνία μεταξύ προβλεπόμενων και παρατηρούμενων πιθανοτήτων. Το πάνελ Δ παρουσιάζει τους συντελεστές του νομογράμματος με τα διαστήματα σφάλματος, αναδεικνύοντας την κυριαρχία της ραδιομικής υπογραφής για την πρόγνωση του ΑΚΑ.



Εικόνα 6 Αποτελέσματα σύγκρισης των 3 μοντέλων

5.1.6 Συμπεράσματα και Περιορισμοί στην Ανάλυση

Η παρούσα μελέτη ανέδειξε τη δυνατότητα χρήσης ραδιομικών χαρακτηριστικών υφής για την πρόβλεψη ανευρύσματος κοιλιακής αορτής με εξαιρετική επίδοση. Το πιο σημαντικό εύρημα είναι η υπεροχή της ραδιομικής υπογραφής έναντι των κλασικών κλινικών μεταβλητών γεγονός που αναδεικνύει της προγνωστική αξία των απεικονιστικών μέσων στην ΑΚΑ σε σχέση με τα παραδοσιακά κλινικά δεδομένα. Η χαμηλή επίδοση των κλινικών μεταβλητών μόνων τους δεν αποτελεί έκπληξη, καθώς αυτές οι μεταβλητές σχετίζονται κυρίως με τον κίνδυνο εμφάνισης ανευρύσματος παρά με το μέγεθός του. Η μελέτη παρουσιάζει ορισμένους περιορισμούς που πρέπει να ληφθούν υπόψη κατά την ερμηνεία των αποτελεσμάτων. Το σχετικά μικρό μέγεθος δείγματος 44 ασθενών περιορίζει τη στατιστική ισχύ, αν και η εκτεταμένη nested cross-validation με 400 επαναλήψεις παρέχει σταθερές εκτιμήσεις. Η απουσία εξωτερικής επικύρωσης σε ανεξάρτητο σύνολο δεδομένων από διαφορετικό κέντρο περιορίζει αντίστοιχα τα συμπεράσματα σχετικά με τη γενικευσιμότητα του μοντέλου. Μελλοντικές κατευθύνσεις περιλαμβάνουν την εξωτερική επικύρωση σε ανεξάρτητο σύνολο δεδομένων, την επέκταση σε πρόβλεψη εξέλιξης και κινδύνου ρήξης με διαχρονική παρακολούθηση, τη διερεύνηση προσεγγίσεων βαθιάς μάθησης, και την ενσωμάτωση σε συστήματα υποστήριξης κλινικών αποφάσεων.

5.2 Μεθοδολογία από την ομάδα MEDISP του ΠΑΔΑ

5.2.1 Περιγραφή των δεδομένων

Τα δεδομένα για την εφαρμογή αλγορίθμων Μηχανικής Μάθησης αποτελούνταν από τις μετρήσεις εξετάσεων 64 ασθενών σε csv φάκελο όπου για κάθε ασθενή υπήρχαν υπολογισμένες ή καταμετρημένες 5667 παράμετροι, εκ των οποίων οι 5637 ήταν χαρακτηριστικά υφής εικόνων Αξονικής Τομογραφίες και οι υπόλοιπες παράμετροι (5637:5667) ήταν δεδομένα ανθρωπομορφικά και ιατρικά που αφορούσαν τον ασθενή. Μία από τις καταμετρημένες παραμέτρους ήταν η μεγίστη διάμετρος της Αορτής. Η διάμετρος αυτή χρησιμοποιήθηκε για τον διαχωρισμό των δεδομένων σε 2 κατηγορίες, ασθενείς με διάμετρο μικρότερη ή ίση των 55mm χαρακτηρίστηκε, σύμφωνα με την διεθνή βιβλιογραφία, ως αμελητέου κινδύνου για ρήξη αορτής και για ασθενείς με μήκος διαμέτρου αορτής >55mm χαρακτηρίστηκε ως υψηλού κινδύνου για ρήξη αορτής. Στο όριο των 55mm εντάσσονται οι άντρες ενώ για τις γυναίκες όριο θεωρείται το 50mm. Τελικά, μετά από καθαρισμό των δεδομένων και την χρήση δεδομένων των μόνο των ανδρών (2 μόνο γυναίκες υπήρχαν που αποκλείστηκαν), τα δεδομένα των χαρακτηριστικών υφής για χρήση είχαν διαστάσεις, για την κατηγορία άνευ κινδύνου (24 x 5637) και για υψηλού κινδύνου (18 x 5637).

Τα χαρακτηριστικά υφής υπολογίστηκαν με χρήση βιβλιοθήκης για υπολογισμό των Radiomics Features (<https://pyradiomics.readthedocs.io/en/latest/features.html>) και της γλώσσας προγραμματισμού Python. Περαιτέρω, η Python και οι βιβλιοθήκες της sklearn της Python χρησιμοποιήθηκαν για την εφαρμογή της Στατιστικής Ανάλυσης και της Μηχανικής Μάθησης στα δεδομένα.

Τα 5637 χαρακτηριστικά υφής αποτελούνταν από 11 κατηγορίες ('3D_original_', '3D_wavelet-', '3D_log-sigma-', '3D_square_', '3D_squareroot_', '3D_logarithm_', '3D_exponential_', '3D_gradient_', '2D_Axial_', '2D_Coronal_', '2D_Sagittal_'] με αντίστοιχο αριθμό χαρακτηριστικών υφής (106,743,371,92,92,92,90,1315,1315,1315).

5.2.2 Μεθοδολογία Στατιστικής Ανάλυσης

Ακολούθησε στατιστική ανάλυση μεταξύ των 2 κατηγοριών με χρήση του Mann-Whitney στατιστικού τεστ και βρέθηκαν εκείνα χαρακτηριστικά που είχαν στατιστικά σημαντική διαφορά μεταξύ των 2 κατηγοριών (μη-κινδύνου/υψηλού κινδύνου ρήξης αορτής). Στον ακόλουθο πίνακα τα πρώτα νούμερα είναι ο αριθμός των χαρακτηριστικών υφής με στατιστικά σημαντική διαφορά μεταξύ των κατηγοριών και το δεύτερο νούμερο είναι ο συνολικός αριθμός των χαρακτηριστικών υφής της κατηγορίας.

Πίνακας 10 Αριθμός Χαρακτηριστικών υφής με στατικά σημαντική διαφορά (ΣΣΔ) μεταξύ των 2 κατηγοριών (μη-κινδύνου /υψηλού κινδύνου ρήξης αορτής)

	Κατηγορίες Χαρακτηριστικών υφής	Χαρακτηριστικά με ΣΣΔ/Σύνολο
1	3D_original_	21/106
2	3D_wavelet-	60/743
3	3D_log-sigma-	60/371
4	3D_square_	9/92
5	3D_squareroot_	7/92

6	3D_logarithm_	8/92
7	3D_exponential_	16/92
8	3D_gradient_	8/90
9	2D_Axial_	169/1315
10	2D_Coronal_	156/1315
11	2D_Sagittal	157/1315

5.2.3 Μεθοδολογία Μηχανικής Μάθησης

1. Χρησιμοποιήθηκαν οι **14 αλγόριθμοι Εποπτευόμενης Μηχανικής Μάθησης της βιβλιοθήκης sklearn της Python και ο XGBClassifier από το πακέτο xgboost** (συνολικά 15 αλγόριθμοι ταξινόμησης). Αλγόριθμοι Βαθιάς Μάθησης (Deep Learning) ή Μεταφερόμενης Μάθησης (Transfer Learning) δεν χρησιμοποιήθηκαν λόγω του περιορισμένου αριθμού των δεδομένων/cases (42 συνολικά).
2. Τα χαρακτηριστικά υφής αρχικά κανονικοποιήθηκαν με βάση τη σχέση $F_i = (f_i - \text{mean}) / \text{std}$, όπου mean είναι η μέση τιμή κάθε χαρακτηριστικού, λαμβάνοντας υπόψη τις τιμές του χαρακτηριστικού και στις 2 κατηγορίες, std είναι η τυπική απόκλιση όλων των δεδομένων του χαρακτηριστικού, f_i είναι η *i-οστή* τιμή του χαρακτηριστικού και F_i είναι η κανονικοποιημένη τιμή του χαρακτηριστικού. Η διεργασία της κανονικοποίησης εκτελείται μέσω της Python βιβλιοθήκης sklearn με την συνάρτηση `preprocessing.normalize`.
3. Ακολούθησε η διαδικασία μείωσης των χαρακτηριστικών, χρησιμοποιώντας ως κριτήριο την στατιστικά σημαντική διαφορά μεταξύ των 2 κατηγοριών (no-risk / high-risk ρήξης αορτής).
4. Μετά την μείωση και ιεράρχηση των χαρακτηριστικών, ακολούθησε η μέθοδος συνδυασμού των χαρακτηριστικών ανά 2 ή 3 (όχι περισσότερα των 3 για αποφυγή overfitting). Για κάθε συνδυασμό χαρακτηριστικών σχεδιάστηκε ο αλγόριθμος ταξινόμησης και αξιολογήθηκε η επίδοση του σχεδιασμού με βάση την μέθοδο Leave-one-out (LOO), λόγω του περιορισμένου αριθμού των δεδομένων. Με αυτό τον τρόπο εντοπίστηκε ο καλύτερος σχεδιασμός (μικρότερος αριθμός χαρακτηριστικών με μεγαλύτερη ακρίβεια ταξινόμησης των υπαρχόντων δεδομένων).
5. Η διαδικασίας 3 και 4 ανωτέρω επαναλήφθηκαν και για τους 15 αλγόριθμους ταξινόμησης, και τα αποτελέσματα καταγράφηκαν και παρουσιάζονται στον πίνακα 11.
6. Επειδή η χρήση όλων των 11 κατηγοριών χαρακτηριστικών, συγχρόνως στον σχεδιασμό συστημάτων ταξινόμησης, έδωσαν σχετικά μέτρια ποσοστά ακρίβειας, εκτιμήθηκε ότι έπρεπε να χρησιμοποιηθεί κάθε μία από τις 11 κατηγορίες ξεχωριστά στον τον σχεδιασμό των μοντέλων ταξινόμησης. Έτσι, εφαρμόζοντας τα ανωτέρω βήματα 1 έως 4, και χρησιμοποιώντας έναν γρήγορο ταξινομητή με ικανοποιητικά αποτελέσματα, τον `Extratrees_classifier`, την σχετικά γρήγορη KFold μέθοδο εκτίμησης της ακρίβειας ταξινόμησης (αντί της LOO), και ξεχωριστά κάθε μία κατηγορία χαρακτηριστικών,

βρέθηκαν οι επιδόσεις σχεδιασμού 11 συστημάτων μηχανικής μάθησης [Extratrees_classifier / κατηγορία χαρακτηριστικών (2-3 χαρακτηριστικά) / KFold evaluation (K=3)] . Ο ακόλουθος πίνακας είναι ενδεικτικός της συνεισφοράς κάθε κατηγορίας χαρακτηριστικών στην ταξινόμηση των 2 κατηγοριών δεδομένων (no-risk / high-risk ρήξης αορτής).

Πίνακας 11 Ταξινόμηση των δεδομένων με αλγόριθμο ExtraTrees, μέθοδο αξιολόγησης επίδοσης KFold, με διάφορα χαρακτηριστικά υφής, και με παράμετρο διαχωρισμού την μέγιστη διάμετρο της Αορτής (όριο διαχωρισμού, σε κατηγορίες μη-κινδύνου Vs υψηλού κινδύνου ρήξης αορτής, τα 55mm).

	Feature_types	Classifier : ExtraTrees_classifier, Label: Diameter, evaluation : KFold (% classification accuracy)
1	3D_original_ ,	87.50%
2	3D_wavelet_ ,	87.50%
3	3D_log-sigma_ ,	87.50%
4	3D_square_ ,	87.50%
5	3D_squareroot_ ,	75.00%
6	3D_logarithm_ ,	77.08%
7	3D_exponential_	87.50%
8	3D_gradient_ ,	79.17%
9	2D_Axial_ ,	89.58%
10	2D_Coronal_ ,	85.42%
11	2D_Sagittal	87.50%

Διαπιστώνεται ότι η κατηγορία χαρακτηριστικών 2D_Axial προσφέρει το μεγαλύτερο ποσοστό ακρίβειας και υιοθετείται περαιτέρω για την χρήση στον σχεδιασμό των συστημάτων Μηχανικής Μάθησης. Στον ακόλουθο πίνακα δίνονται τα 10 χαρακτηριστικά της κατηγορίας 2D_Axial ιεραρχημένα υψηλότερη προς χαμηλότερη στατιστικά σημαντική διαφορά μεταξύ των 2 κατηγοριών (μη-κινδύνου /υψηλού κινδύνου ρήξης αορτής), τα οποία χρησιμοποιήθηκαν για τον σχεδιασμό των αλγορίθμων ταξινόμησης.

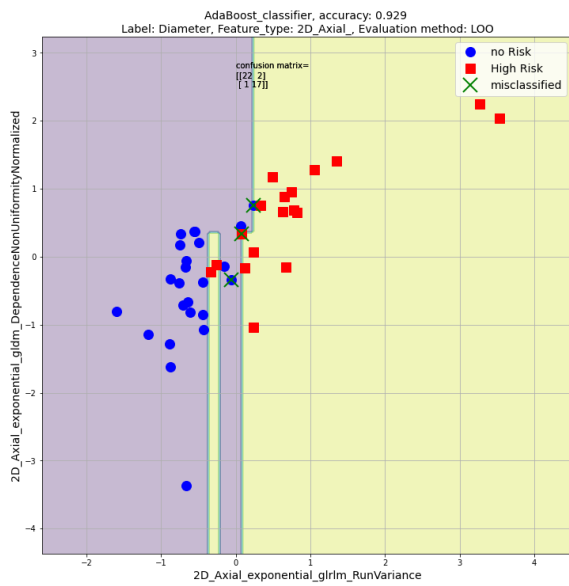
Πίνακας 12. Χαρακτηριστικά υφής υψηλής στατιστικά σημαντικής διαφοράς

	Feature	p_stat
1	2D_Axial_exponential_glrmlm_RunVariance	0.0000002 0
2	2D_Axial_original_shape_SurfaceVolumeRatio	0.0000324 5
3	2D_Axial_exponential_glrmlm_RunEntropy	0.0000324 5
4	2D_Axial_original_shape_LeastAxisLength	0.0000625 2
5	2D_Axial_exponential_glrmlm_LongRunHighGrayLevelEmphasis	0.0000695 9

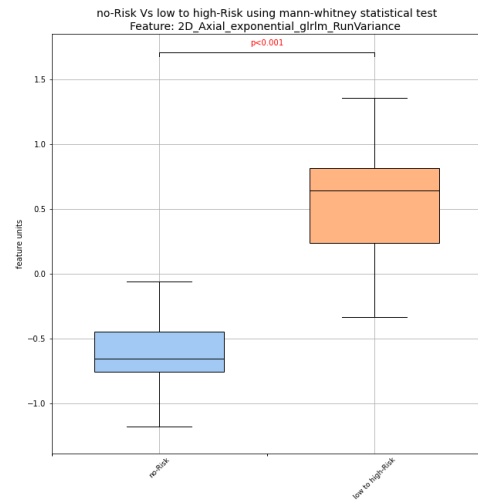
6	2D_Axial_exponential_gldm_LargeDependenceHighGrayLevelEmphas is	0.0000860 7
7	2D_Axial_exponential_glrlm_LongRunEmphasis	0.0000860 7
8	2D_Axial_exponential_glrlm_LongRunLowGrayLevelEmphasis	0.0000860 7
9	2D_Axial_exponential_gldm_DependenceNonUniformity	0.0001061 9
1 0	2D_Axial_exponential_gldm_DependenceNonUniformityNormalized	0.0002650 5

5.2.4 Αποτελέσματα Μηχανικής Μάθησης

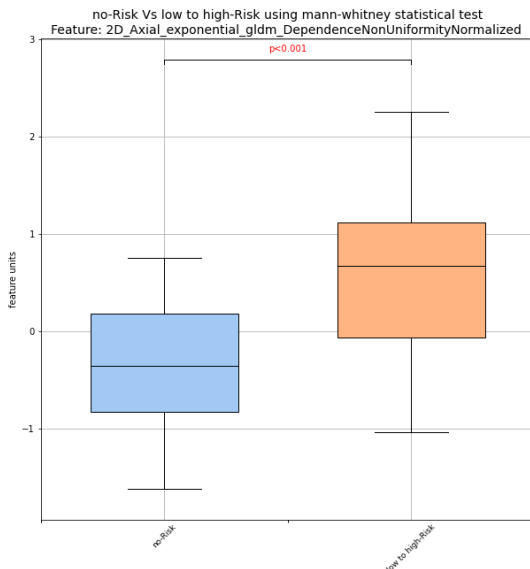
Εφαρμόζοντας τα βήματα 1 έως και 5 της παραγράφου «5.2.3/ Μεθοδολογία Μηχανικής Μάθησης» αποκτήθηκαν τα αποτελέσματα της εφαρμογής 15 αλγορίθμων ταξινόμησης. Η ακρίβεια ταξινόμησης κυμαινόταν μεταξύ 0.85 και 0.928 με την μεγαλύτερη ακρίβεια 0.928 να έχει επιτευχθεί από τους Random Forest, Bagging, and AdaBoost classifiers κάνοντας χρήση 2 ή 3 χαρακτηριστικών υφής, τα οποία είχαν στατικά σημαντική διαφορά μεταξύ των 2 κατηγοριών $p < 0.001$. Στην Εικόνα 7 φαίνονται τα αποτελέσματα του καλύτερου αλγορίθμου ταξινόμησης (AdaBoost) με τα λιγότερα χαρακτηριστικά για υψηλή απόδοση.



(a)



(b)



(c)

=====
 for features:
 ['2D_Axial_exponential_gldm_RunVariance',
 '2D_Axial_exponential_gldm_DependenceNonU
 niformityNormalized']

Truth Table:

[[22 2]
 [1 17]]

%ACCURACIES:

No-risk accuracy : 91.67 %

High risk accuracy : 94.44 %

OVERALL accuracy: 92.86 %

Classifier employed: AdaBoost_classifier
 =====

(d)

Εικόνα 7 (a) Διάγραμμα διασποράς με ταξινομητή AdaBoost, 2 χαρακτηριστικά, και με μέθοδο LOO. (b)&(c) Βoxplots (θηκογράμματα) των 2 χαρακτηριστικών που χρησιμοποιήθηκαν από τον ταξινομητή. (d) Αποτελέσματα ταξινόμησης με τα ονόματα των χαρακτηριστικών, τον πίνακα αλήθειας (truth table), τις ακρίβειες ταξινόμησης ανά κατηγορία και την ολική ακρίβεια ταξινόμησης.

Στον παρακάτω πίνακα δίνονται οι ολικές ακρίβειες ταξινόμησης κάθε αλγορίθμου καθώς και τα χαρακτηριστικά υφής που χρησιμοποιήθηκαν στον σχεδιασμό του μοντέλου ταξινόμησης.

Πίνακας 13 Ταξινόμηση αλγορίθμων και χαρακτηριστικά υφής που χρησιμοποιήθηκαν στον σχεδιασμό του μοντέλου ταξινόμησης

	Ταξινομητές	% Ακρίβεια ταξινόμησης (LOO)	Χαρακτηριστικά υφής
1	MDC_classifier (NearestCentroid)	88.10	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_original_shape_SurfaceVolumeRatio'
2	KNN_classifier	85.71	'2D_Axial_exponential_glrmlm_LongRunHighGrayLevelEmphasis', '2D_Axial_exponential_glrmlm_LongRunEmphasis'
3	Bayesian_classifier (GaussianNB)	88.10	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_original_shape_SurfaceVolumeRatio'
4	LDA_classifier (LinearDiscriminantAnalysis)	88.10	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_exponential_glrmlm_LongRunHighGrayLevelEmphasis'
5	LogReg_classifier (LogisticRegression)	90.48	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_exponential_gldm_DependenceNonUniformity'
6	Perceptron_classifier	88.10	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_exponential_glrmlm_LongRunHighGrayLevelEmphasis'
7	MLP_classifier	90.48	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_original_shape_SurfaceVolumeRatio', '2D_Axial_exponential_glrmlm_RunEntropy'
8	SVM_classifier (LinearSVC)	90.48	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_exponential_glrmlm_RunEntropy'
9	RandomForest_classifier	92.86	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_original_shape_SurfaceVolumeRatio', '2D_Axial_exponential_gldm_LargeDependenceHighGrayLevelEmphasis'
10	DecisionTree_classifier	90.48	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_exponential_gldm_LargeDependenceHighGrayLevelEmphasis', '2D_Axial_exponential_glrmlm_LongRunEmphasis'
11	XGBoost_classifier	88.10	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_exponential_glrmlm_RunEntropy'
12	Bagging_classifier	92.86	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_original_shape_SurfaceVolumeRatio', '2D_Axial_exponential_glrmlm_RunEntropy'
13	ExtraTrees_classifier	90.48	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_exponential_glrmlm_LongRunHighGrayLevelEmphasis', '2D_Axial_exponential_gldm_LargeDependenceHighGrayLevelEmphasis'
14	AdaBoost_classifier	92.86	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_original_shape_SurfaceVolumeRatio'
15	GradientBoost_classifier	88.10	'2D_Axial_exponential_glrmlm_RunVariance', '2D_Axial_original_shape_SurfaceVolumeRatio'

5.2.5 Λογισμικό Μηχανικής Μάθησης και Στατιστικής Ανάλυσης

Το λογισμικό ανάλυσης των δεδομένων που υλοποιήθηκε και παρουσιάζεται είναι ένα ολοκληρωμένο πρόγραμμα Μηχανικής Μάθησης που περιλαμβάνει στατιστική ανάλυση και εποπτευόμενη ταξινόμηση. Δίνεται εντός ενός αρχείου zip (**Safe-Aorta_Classification_UNIWA.zip**), που περιέχει το ίδιο πρόγραμμα (**MEDISP_AortaGUI.exe**) καθώς και το αρχείο των δεδομένων (**radiomics_features_metadata_1.csv**). Αφού τα αποσυμπιέσουμε τοποθετούμε τα δύο αρχεία στον ίδιο φάκελο (directory) στο σκληρό δίσκο του Η/Υ, ώστε να λειτουργήσει το εκτελέσιμο αρχείο (.exe).

Λειτουργία:

Επιλέγουμε και εκτελούμε το πρόγραμμα (μικρή αναμονή μερικών δευτερολέπτων είναι αναμενόμενη, για τη φόρτωση στη μνήμη των ενσωματωμένων βιβλιοθηκών).

Μόλις ενεργοποιηθεί το πρόγραμμα, απεικονίζεται μία οθόνη όπως φαίνεται στην εικόνα 8. Ο χρήστης μπορεί να επιλέξει ως είσοδο:

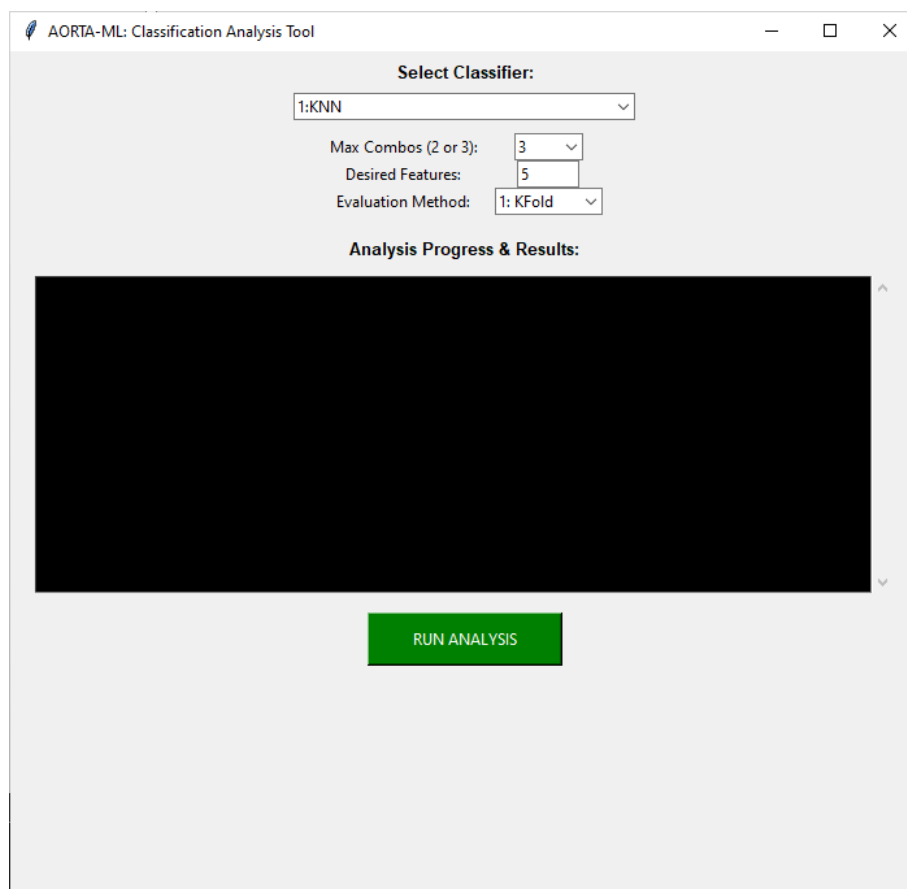
1/ Ένα ταξινομητή (15 δυνατές επιλογές).

2/ Μέγιστο αριθμό χαρακτηριστικών ανά συνδυασμό. Τα χαρακτηριστικά θα συνδυαστούν ανά 2 και ανά 3 κατά τον σχεδιασμό του συστήματος ταξινόμησης. Για κάθε συνδυασμό σχεδιάζεται ο επιλεγμένος ταξινομητής, και για τον υπολογισμό της ακρίβειας ταξινόμησης χρησιμοποιείται μια από τις μεθόδους Leave-One-Out ή K-Fold. Στο τέλος ευρίσκεται ο καλύτερος συνδυασμός χαρακτηριστικών που δίνει την μεγαλύτερη ακρίβεια για τον επιλεγμένο ταξινομητή.

3/ Τον συνολικό αριθμό των χαρακτηριστικών. Όλα τα χαρακτηριστικά έχουν ιεραρχηθεί κατά φθίνουσα στατιστικά σημαντική διαφορά μεταξύ των 2 κατηγοριών (μη-κινδύνου /κινδύνου ρήξης αορτής) και από αυτά μπορούμε να επιλέξουμε ένα μέγιστο αριθμό (π.χ. 10), τα οποία θα συνδυαστούν ανά 2 ή 3 (λόγω περιορισμένου αριθμού δεδομένων).

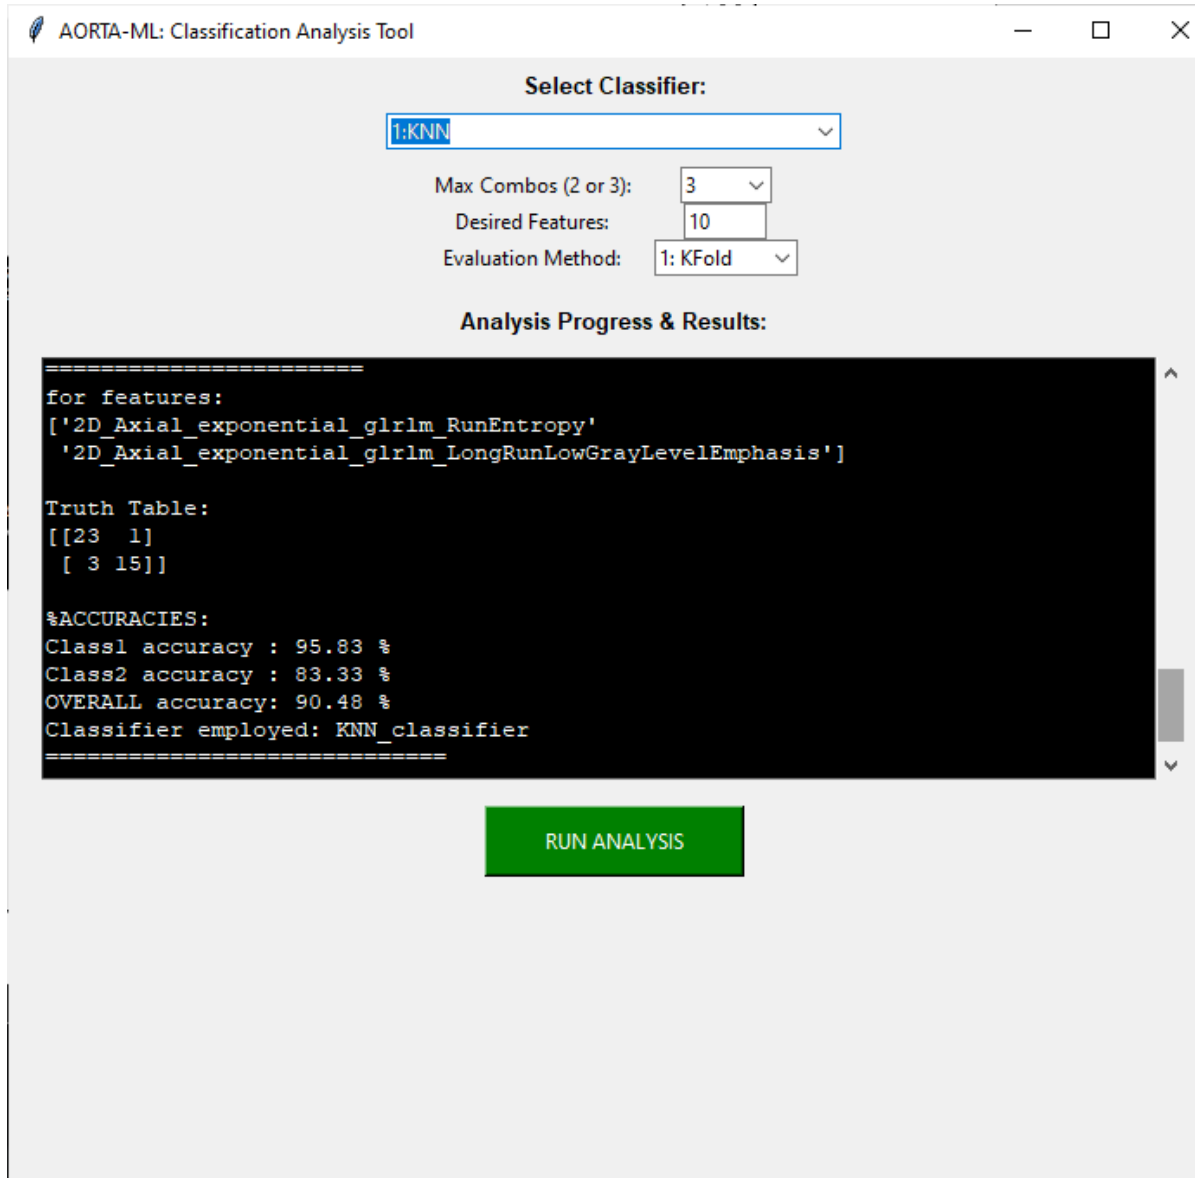
4/ Την μέθοδο αξιολόγησης της επίδοσης (ακρίβειας) του σχεδιαζόμενου συστήματος. Είναι 2 οι επιλογές, η περισσότερο αξιόπιστη με μικρότερη μεροληψία Leave-One-Out, καθώς και για αρχικά γρήγορα τεστ η K-fold (K=3).

Όταν εισαχθούν από τον χρήστη οι ανωτέρω επιλογές, με επιλογή του πλήκτρου RUN ANALYSIS εκκινεί η διαδικασία σχεδιασμού του συστήματος Μηχανικής Μάθησης.



Εικόνα 8. Αρχική οθόνη του προγράμματος **MEDISP_AortaGUI.exe**



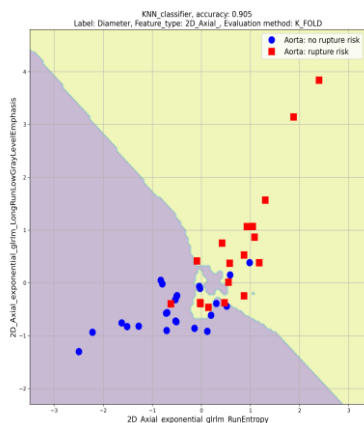
Στην ακόλουθη εικόνα φαίνεται η οθόνη των αποτελεσμάτων της διαδικασίας σχεδιασμού-αξιολόγησης. Πρώτα είναι τα 2 καλύτερα χαρακτηριστικά που ευρέθηκαν, ο πίνακας αληθείας (class1= no-risk, class2= risk for AORTA rupture), οι επιμέρους ακρίβειες όπως και η συνολική ακρίβεια ταξινόμησης, και τέλος ο ταξινομητής που χρησιμοποιήθηκε.



Εικόνα 9. Αποτελέσματα του συστήματος Μηχανικής Μάθησης

Τα γραφικά σχεδιαγράμματα της Μηχανικής Μάθησης και της Στατιστικής ευρίσκονται αποθηκευμένα σε ένα φάκελο με όνομα Results που ευρίσκεται εντός του φακέλου που περιέχει το exe πρόγραμμα (MEDISP_AortaGUI.exe) και το αρχείο με τα δεδομένα (radiomics_features_metadata_1.csv)

Ακολούθως στην εικόνα 10. φαίνονται τα γραφικά διαγράμματα, διασποράς (scatter plot) και θηκογράμματα (box-plots)



5.3 Μεθοδολογία από την ομάδα ACIMA του ΠΑΔΑ

5.3.1 Αλγόριθμοι Υπολογιστικής Νοημοσύνης

Η ανάπτυξη της ερευνητικής μεθοδολογίας¹¹ βασίστηκε σε μοντέλα υπολογιστικής νοημοσύνης (computational intelligence). Συγκεκριμένα, το πρόβλημα που μελετήθηκε αφορά σε ταξινόμηση (classification), ήτοι στην αναγνώριση δύο κλάσεων βάσει της μέγιστης μετρήσιμης διαμέτρου της κοιλιακής αορτής. Όσον αφορά τη διάμετρο, τα ΑΚΑ κατηγοριοποιούνται σε μικρά και μεγάλα. Για τους άνδρες ασθενείς, διάμετρος που υπερβαίνει τα 55 mm θεωρείται κλινικά σημαντική και συνήθως απαιτεί παραπομπή για επέμβαση λόγω αυξημένου κινδύνου ρήξης. Με αυτό υπόψη αναγνωρίστηκαν δύο κλάσεις, οι οποίες αντιστοιχούν σε περιστατικά υψηλού ρίσκου (high-risk) και σε περιστατικά χαμηλού ρίσκου (low-risk). Υψηλού ρίσκου νοούνται οι περιπτώσεις στις οποίες η μέγιστη διάμετρος της αορτής είναι μεγαλύτερη από 55 mm. Αντίθετα, οι περιπτώσεις με μέγιστη τιμή διαμέτρου μικρότερη των 55 mm θεωρούνται ως χαμηλού ρίσκου.

Για την εκτέλεση της προβλεπτικής ανάλυσης, υιοθετήθηκαν νεύρο-ασαφή συστήματα, ensembles νεύρο-ασαφών συστημάτων και υβριδικοί ασαφείς ταξινομητές βασισμένοι σε εξελικτικούς αλγόριθμους. Για την ακρίβεια αναπτύχθηκαν μοντέλα ANFIS (Adaptive-network fuzzy inference system/Προσαρμοστικό νεύρο-ασαφές σύστημα συμπερασμού), ενώ ταυτόχρονα το ίδιο μοντέλο μελετήθηκε σε ένα πλαίσιο ensemble μάθησης. Τα ensemble νεύρο-ασαφή συστήματα που αναπτύχθηκαν, βασίστηκαν στη μεθοδολογία Bootstrap Aggregating (Bagging), ενώ η μέθοδος της συσσωμάτωσης (aggregation) υλοποιήθηκε με πλειοψηφική ψήφο (majority vote). Επιπροσθέτως, μελετήθηκαν ασαφείς ταξινομητές που

¹¹ Korkidis, P., Dounis, A., Theocharakis, I., Athanasiadis, E. I., Kostopoulos, S., Skouroliakou, A., Ventouras, E., Raptis, A., Spanos, K., Moulakakis, K., Giannoukas, A., Kakisis, I., Manopoulos, C., & Kalatzis, I. K. (2026). Ensemble and Evolutionary Fuzzy Classifier Systems for Abdominal Aortic Aneurysms. *Algorithms*, 19(2), 103. <https://doi.org/10.3390/a19020103>

αναπτύχθηκαν πάνω σε συστήματα Mamdani με data-driven εκπαίδευση για τον προσδιορισμό των ασαφών κανόνων. Το είδος και η κρισιμότητα της εφαρμογής, επιτάσσουν την δυνατότητα προβλέψεων υψηλής ακρίβειας. Υπό αυτό το πρίσμα και για την αύξηση της προβλεπτικής ικανότητας του ασαφούς ταξινομητή, αναπτύχθηκαν υβριδικά μοντέλα και συγκεκριμένα εξελικτικά-ασαφή συστήματα ταξινόμησης. Το σύνολο των μοντέλων εκπαιδεύτηκαν χρησιμοποιώντας χαρακτηριστικά που εξάγονται μέσω της ραδιομικής ανάλυσης και επεξεργασίας και επέδειξαν υψηλή απόδοση γενίκευσης, όπως μετρήθηκε από τα θεωρούμενα μέτρα απόδοσης και εκτιμήθηκε σε μία βάση διασταυρούμενης επικύρωσης K-fold. Οι αριθμητικές μελέτες ανέδειξαν πως το υβριδικό ασαφές σύστημα βασισμένο σε εξελικτικούς αλγορίθμους, παρουσίασε εξαιρετική ακρίβεια στη διάκριση μεταξύ των δύο προσδιορισμένων κλάσεων.

Τα ασαφή συστήματα (fuzzy systems), είναι μοντέλα θεμελιωμένα πάνω στη θεωρία ασαφών συνόλων, σε ασαφείς κανόνες IF-THEN (fuzzy rules) και σε ασαφή συλλογισμό (fuzzy reasoning). Είναι εφοδιασμένα με την ιδιότητα της καθολικής προσέγγισης (universal approximation theorem)—έχουν τη δυνατότητα προσέγγισης άγνωστων απεικονίσεων (nonlinear mappings) εισόδου-εξόδου. Μια βασική πτυχή της θεωρίας ασαφών συστημάτων είναι η συστηματική μεθοδολογία για τη μετατροπή μιας συλλογής γλωσσικών κανόνων σε μία μη γραμμική απεικόνιση. Τα ασαφή συστήματα έχουν διττό ρόλο, καθότι είναι συστήματα θεμελιωμένα σε γλωσσικούς κανόνες, και συνάμα αντιπροσωπεύουν μη-γραμμικές απεικονίσεις.

Διακρίνονται δύο κύριες κατηγορίες ασαφών συστημάτων: τα ασαφή συστήματα Mamdani και τα ασαφή συστήματα Takagi-Sugeno-Kang. Αυτή η διάκριση έγκειται στη μορφή του συμπερασματικού μέρους (consequents) των ασαφών κανόνων. Για τη μελέτη της ασαφούς ταξινόμησης των ΑΚΑ, μελετήθηκαν και συστήματα και από τις δύο οικογένειες. Στη συνέχεια δίνεται μία συνοπτική περιγραφή των συστημάτων της κάθε οικογένειας.

Συστήματα Mamdani Ένα ασαφές σύστημα περιέχει τέσσερα εννοιολογικά στοιχεία: τον ασαφοποιητή (fuzzifier), τη βάση ασαφών κανόνων (fuzzy rule base), τη μηχανή ασαφούς συμπερασματολογίας (fuzzy inference engine) και τον αποασαφοποιητή (defuzzifier). Μια είσοδος στο σύστημα, αφού ασαφοποιηθεί, ενεργοποιεί έναν ασαφή κανόνα σε κάποιο βαθμό. Κάθε ασαφής κανόνας δημιουργεί, μέσω συμπερασματολογίας, ένα προκύπτον ασαφές σύνολο εξόδου. Το σύνολο των ασαφών συνόλων εξόδου, με κατάλληλη μέθοδο ενοποιούνται παράγοντας ένα ασαφές συσσωμάτωμα. Εν συνέχεια και με κατάλληλη μέθοδο, το ασαφές συσσωμάτωμα αποασαφοποιείται, απεικονίζοντας την κωδικοποιημένη πληροφορία σε μία πραγματική τιμή, η οποία είναι η έξοδος του ασαφούς συστήματος.

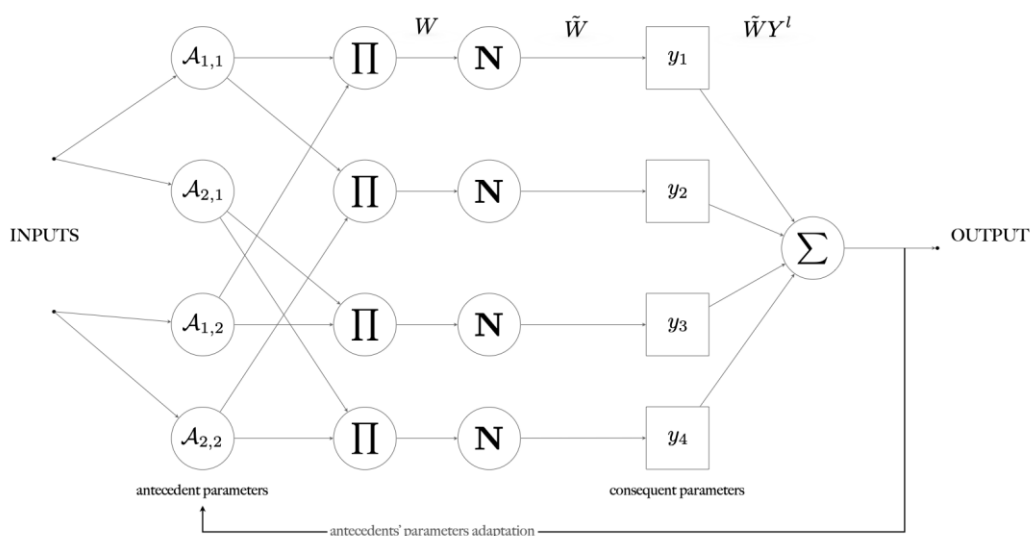
Έστω ασαφές σύστημα $f: U \subset R^m \mapsto V \subset R$, όπου $U = U_1 \times \dots \times U_m$ είναι ο χώρος εισόδου, ενώ $V \subset R$ είναι ο χώρος εξόδου. Ένα ασαφές σύστημα περιγράφεται από ένα σύνολο ασαφών κανόνων. Μέσω της συστηματικής μεθοδολογίας της ασαφούς συμπερασματολογίας, και συγκεκριμένα του κανόνα συνθετικού συμπερασμού (compositional rule of inference), κάθε ασαφής κανόνας παράγει ένα προκύπτον ασαφές σύνολο εξόδου. Το προκύπτον ασαφές σύνολο διέρχεται από τη μονάδα αποασαφοποίησης για να δημιουργηθεί η έξοδος του

ασαφούς συστήματος. Η υπολογιστική μονάδα αποασαφοποίησης αντιστοιχίζει τα ασαφή σύνολα στο $V \subset R$ σε σαφή σημεία $y^* \in V$.

Τα ασαφή συστήματα είναι από τη φύση τους μοντέλα πρόβλεψης πραγματικών μεταβλητών. Εντούτοις, και υπό το πρίσμα της δυαδικής ταξινόμησης, δηλαδή το πρόβλημα ταξινόμησης των ΑΚΑ, χρησιμοποιήθηκε μέθοδος κατοφλίωσης τέτοια ώστε να αντιστοιχηθεί κάθε δεδομένο εισόδου σε μία μοναδική κλάση. Συγκεκριμένα, ένα μοτίβο εισόδου ταξινομείται ως χαμηλού κινδύνου όταν η αποασαφοποιημένη τιμή y^* είναι κάτω από ένα δεδομένο όριο. Αντίθετα, ταξινομείται ως υψηλού κινδύνου όταν η αποασαφοποιημένη τιμή υπερβαίνει αυτό το όριο. Αυτή η τεχνική είναι εκτενώς καθιερωμένη στη βιβλιογραφία των ασαφών συστημάτων. Έτσι, παρόλο που η έξοδος του ασαφούς συστήματος είναι πραγματικός αριθμός, η τελική υπολογισμένη έξοδος του είναι δυαδική.

Συστήματα Takagi-Sugeno-Kang Η μελέτη των συγκεκριμένων συστημάτων πραγματοποιήθηκε μέσω του προσαρμοστικού νέυρο-ασαφούς συστήματος ασαφούς συμπερασμού, το οποίο ανήκει στην ευρύτερη κλάση ασαφών συστημάτων που καλούνται νέυρο-ασαφή, καθότι εδράζονται πάνω σε μεθοδολογίες που συνδυάζουν τις τεχνικές των νευρωνικών δικτύων πάνω σε ένα θεωρητικό πλαίσιο ασαφών συστημάτων. Το προσαρμοστικό σύστημα ασαφούς συμπερασματολογίας βασισμένο σε δίκτυο, είναι επί της ουσίας ένας αποδοτικός αλγόριθμος επιβλεπόμενης μάθησης για εκπαίδευση μοντέλων Takagi-Sugeno-Kang. Το ANFIS διαθέτει δύο σύνολα ρυθμιζόμενων παραμέτρων. Το πρώτο σύνολο περιλαμβάνει τις παραμέτρους των συναρτήσεων συμμετοχής που ορίζουν τα αίτια (antecedents) των ασαφών κανόνων και καθορίζουν τον βαθμό συμμετοχής των εισόδων στα ασαφή σύνολα. Το δεύτερο σύνολο αποτελείται από τις παραμέτρους των επακόλουθων (consequents) των κανόνων, οι οποίες προσδιορίζουν τη μορφή της εξόδου του συστήματος. Η διαδικασία εκπαίδευσης του ANFIS συνδυάζει τη μέθοδο των ελαχίστων τετραγώνων και τη μέθοδο της βαθμιαίας καθόδου (gradient descent) για την προσαρμογή των παραμέτρων. Η εκπαίδευση πραγματοποιείται σε δύο διαδοχικές φάσεις: στην ευθεία (forward pass), οι παράμετροι των επακόλουθων θεωρούνται μεταβλητές και υπολογίζονται με τη μέθοδο των ελαχίστων τετραγώνων, ενώ οι παράμετροι των αιτίων παραμένουν σταθερές. Στη συνέχεια, κατά την προς τα πίσω διέλευση (backward pass), το σφάλμα που προκύπτει διαδίδεται προς τα πίσω και η μέθοδος της βαθμιαίας καθόδου χρησιμοποιείται για την ενημέρωση των παραμέτρων των συναρτήσεων συμμετοχής, με στόχο τη μείωση του συνολικού σφάλματος του συστήματος.

Τα επίπεδα ενός προσαρμοστικού νέυρο-ασαφούς συστήματος συμπερασμού, παρουσιάζονται στην επόμενη εικόνα.



Εικόνα 11 Προσαρμοστικό νευρο-ασαφές σύστημα συμπερασμού (ANFIS)

Μέθοδος Wang-Mendel Η μεθοδολογία Wang-Mandel (WM) αποτελεί έναν αποδοτικό και ταχύ τρόπο εκπαίδευσης ασαφών συστημάτων τύπου Mamdani. Συγκεκριμένα, η μέθοδος WM έχει στόχο τον προσδιορισμό μίας βάσης γνώσης η οποία χαρακτηρίζει ένα ασαφές σύστημα. Είναι μία από τις πιο διαδεδομένες μεθόδους εκπαίδευσης ασαφών συστημάτων από δεδομένα (data-driven fuzzy systems). Η ταχύτητα της μεθόδου έγκειται στην μη-επαναληπτική φύση του αλγορίθμου, ο οποίος αφορά σε ένα προς τα εμπρός (forward) πέρασμα των δεδομένων. Το τελικό ασαφές σύστημα, δηλαδή στην δική μας περίπτωση ο ασαφής ταξινομητής, θεωρείται ένα απόλυτα διερμηνεύσιμο (interpretable) και συμπαγές προβλεπτικό μοντέλο. Το χαρακτηριστικό αυτό αναδύεται από την ίδια τη φύση των ασαφών συστημάτων, τα οποία θεμελιώνονται πάνω σε γλωσσικούς κανόνες, σε συνδυασμό με τη συμπαγή βάση γνώσης που προκύπτει μέσω της μεθόδου WM. Η μέθοδος Wang-Mandel συνοψίζεται στον επόμενο αλγόριθμο.

Algorithm 1 Wang–Mendel method.

Require: Training Data $\mathcal{D} = \{(x^i, y^i)\}_{i \in [N]}$, type of membership functions, cardinality M of fuzzy partitions for all inputs $x_j \in U_j$ and M_y of output $y \in V$.

- 1: $RB \leftarrow \emptyset$
- 2: **for all** inputs x_j where $j \in [m]$ **do**
- 3: $K_j \leftarrow \text{GENERATEFUZZYPARTITIONS}(x_j, M_j, \text{type})$
- 4: $K_y \leftarrow \text{GENERATEFUZZYPARTITIONS}(y, M_y, \text{type})$ ▷ output
- 5: **end for**
- 6: **for all** $i \in [N]$ **do** ▷ all observations in \mathcal{D}
- 7: $[\mathcal{A}_*^i, \mathcal{C}_*^i] \leftarrow \text{MAXFUZZYSET}(\mathcal{D}, K_j, K_y)$
- 8: $R^i \leftarrow \text{GENERATEFUZZYRULE}(\mathcal{A}_*^i, \mathcal{C}_*^i)$
- 9: $w_i \leftarrow \text{COMPUTERULEDEGREE}(R^i, \mathcal{A}_*^i, \mathcal{C}_*^i)$
- 10: $RB \leftarrow RB \cup_{i \in [N]} R^i$
- 11: **end for**
- 12: $[\text{ind}, w_{\text{ind}}] \leftarrow \text{FINDCONFLICTINGRULES}(RB)$
- 13: $RB \leftarrow \text{REMOVECONFLICTINGRULES}(RB(\text{ind}), w_{\text{ind}})$

Αλγόριθμος 1 Μεθοδολογία Wang-Mendel.

Ensemble μάθηση Εκτός των μοντέλων ANFIS, με σκοπό τη βελτίωση της προβλεπτικής ικανότητας των μεμονωμένων μοντέλων, αναπτύχθηκε μεθοδολογία μάθησης επί συνόλου, ήτοι ensemble learning. Η μάθηση συνόλου βασίζεται στην ιδέα του συνδυασμού της απόδοσης μιας συλλογής απλούστερων βασικών μοντέλων. Η ανάπτυξη του ensemble συστήματος βασίστηκε στην αρχιτεκτονική ενός committee machine, στο πλαίσιο της οποίας εκπαιδεύτηκαν ανεξάρτητοι ταξινομητές ANFIS (base learners) με τη χρήση δειγμάτων bootstrap. Τα δείγματα αυτά παράχθηκαν από το διαθέσιμο σύνολο δεδομένων μέσω ομοιόμορφης δειγματοληψίας με αντικατάσταση. Μέσω της σχήματος bagging, η διακύμανση της πρόβλεψης μειώνεται με τον συνδυασμό των επιμέρους base learners, ενώ στην περίπτωση της ταξινόμησης η τελική απόφαση λαμβάνεται με βάση τον κανόνα της πλειοψηφικής ψήφου (majority vote).

Εξελικτικά Μοντέλα Τέλος, στο πλαίσιο της έρευνας ανάπτυξης των προβλεπτικών μεθοδολογιών, μελετήθηκαν και εφαρμόστηκαν μεθοδολογίες εξελικτικής βελτιστοποίησης (evolutionary optimization), και συγκεκριμένα η μέθοδος διαφορικής εξέλιξης (differential evolution). Αν και η μέθοδος WM παρέχει έναν γρήγορο και αποδοτικό τρόπο εκπαίδευσης ασαφών συστημάτων, δεν παρέχει ρητούς οδηγίες που αφορούν στην επιλογή των παραμέτρων των συναρτήσεων συμμετοχής των αιτίων και επακόλουθων των ασαφών κανόνων. Ενδιαφερόμαστε για την ανάπτυξη ασαφών ταξινομητών με υψηλό βαθμό ακρίβειας, έτσι αναπτύχθηκε ένα υβριδικό ασαφές σύστημα ενσωματώνοντας εξελικτική βελτιστοποίηση, συνδυασμένη με τη μέθοδο Wang-Mendel σχεδιασμού ασαφών συστημάτων. Συγκεκριμένα, υιοθετήθηκε η διαφορική εξέλιξη, για να βελτιστοποιήσει τόσο των παραμέτρων των ασαφών συνόλων των αιτιών όσο και των ασαφών συνόλων των επακόλουθων του ασαφούς μοντέλου. Για την ακρίβεια, μας ενδιαφέρει η βελτιστοποίηση των παραμέτρων των συναρτήσεων συμμετοχής, οι οποίες αντιστοιχούν στα προηγούμενα και τα επακόλουθα των ασαφών κανόνων.

Η διαφορική εξέλιξη εκκινεί δημιουργώντας έναν αρχικό πληθυσμό υποψήφιων λύσεων, που καλούνται και άτομα, εντός ενός εφικτού συνόλου. Μέσω εφαρμογής εξελικτικών τελεστών μεταβολής, η αναζήτηση κατευθύνεται προς τις πιο υποσχόμενες λύσεις του χώρου της λύσης. Βάσει ενός *greedy* κριτηρίου επιλογής (elitism) καθορίζονται ποια άτομα θα διατηρηθούν για την επόμενη γενιά. Ο αλγόριθμος της διαφορικής εξέλιξης, σε σχέση με άλλους εξελικτικούς αλγορίθμους, περιλαμβάνει ελάχιστο αριθμό παραμέτρων ελέγχου: την κλιμάκωση μετάλλαξης, την πιθανότητα διασταύρωσης και το μέγεθος πληθυσμού, ενώ οι πιθανές τιμές των παραμέτρων είναι πολύ καλά μελετημένες στη βιβλιογραφία. Στην παρούσα εργασία ταξινόμησης, το σύνολο των παραμέτρων που πρέπει να βελτιστοποιηθούν αποτελείται από τους πυρήνες και τις τυπικές αποκλίσεις κάθε συνάρτησης συμμετοχής της διαμέρισης εισόδου του ασαφούς συστήματος WM.

Στον επόμενο πίνακα συνοψίζουμε τα μοντέλα, τις παραμέτρους τους, καθώς και τη μέθοδο εκπαίδευσης που υιοθετήθηκε.

Πίνακας 14 Προβλεπτικά μοντέλα, παράμετροι και μέθοδος εκπαίδευσης για το πρόβλημα της ταξινόμησης σε ΑΚΑ.

Μοντέλο	Μέθοδος Εκπαίδευσης	Ρυθμιζόμενες Παράμετροι
Ασαφής ταξινομητής Mamdani	Wang-Mendel method	a. Σύνολο ασαφών κανόνων.
Προσαρμοστικό νευρο-ασαφές σύστημα συμπερασμού (ANFIS)	Υβριδική μεθοδολογία: Συνδυασμός backpropagation με μέθοδο ελαχίστων τετραγώνων	a. Παράμετροι συναρτήσεων συμμετοχής του υποθετικού μέρους των ασαφών κανόνων. b. Παράμετροι του συμπερασματικού μέρους των κανόνων.
Ensemble of ANFIS	Υβριδική μεθοδολογία: Συνδυασμός backpropagation με μέθοδο ελαχίστων τετραγώνων	a. Παράμετροι συναρτήσεων συμμετοχής του υποθετικού μέρους των ασαφών κανόνων. b. Παράμετροι του συμπερασματικού μέρους των κανόνων. <i># για κάθε μέλος του Ensemble</i>
Υβριδικός εξελικτικός ασαφής ταξινομητής	Υβριδική μεθοδολογία: Συνδυασμός εξελικτικού αλγορίθμου διαφορικής	a. Παράμετροι συναρτήσεων συμμετοχής του υποθετικού και

	εξέλιξης με τη μέθοδο Wang-Mendel	συμπερασματικού μέρους των ασαφών κανόνων. b. Σύνολο ασαφών κανόνων.
--	-----------------------------------	---

5.3.2 Ομαδοποίηση και Επιλογή Ραδιομικών Χαρακτηριστικών mRMR

Εν συνεχεία της εξαγωγής των ραδιομικών χαρακτηριστικών, πραγματοποιήθηκε η ομαδοποίηση τους σε έντεκα διακριτά υποσύνολα, βάσει ογκομετρικών χαρακτηριστικών 3D και 2D που δημιουργούνται από ανάλυση κατά μήκος των *Αξονικών*, *Κορωνιαίων* και *Οβελιαίων* επιπέδων. Οι υποομάδες αποτελούνται από τις τέσσερις λειτουργίες εξαγωγής—3D και τα τρία επίπεδα 2D—με κάθε σύνολο να περιέχει χαρακτηριστικά που προέρχονται από τα ενεργοποιημένα φίλτρα εικόνας. Ο χωρισμός των εξαγόμενων χαρακτηριστικών σε υποσύνολα συνοψίζεται στον επόμενο πίνακα.

Πίνακας 15 Ομαδοποίηση ραδιομικών χαρακτηριστικών σε υποσύνολα.

Υποσύνολο Χαρακτηριστικών	Διαστατικότητα
3D original	42 x 107
3D wavelet	42 x 477
3D log-sigma	42 x 372
3D square	42 x 92
3D squareroot	42 x 93
3D logarithm	42 x 93
3D exponential	42 x 93
3D gradient	42 x 93
2D Axial	42 x 1316
2D Coronal	42 x 1316
2D Sagittal	42 x 1316
All Features	42 x 5635

Σε συνέχεια της εξαγωγής των χαρακτηριστικών (feature extraction) από τη ραδιομική ανάλυση και της ομαδοποίησης τους σε υποσύνολα, πραγματοποιήθηκε επιλογή συγκεκριμένων χαρακτηριστικών (feature selection), με εφαρμογή μεθόδων που βασίζονται σε φίλτρα (filter-based feature selection). Τα επιλεγμένα αυτά χαρακτηριστικά οποία θα αποτελέσουν τις εισόδους των προβλεπτικών μοντέλων. Η επιλογή χαρακτηριστικών—μια βασική διαδικασία εντός μιας ροής εργασίας μηχανικής μάθησης—αναφέρεται στον προσδιορισμό ενός υποσυνόλου χαρακτηριστικών, έτσι ώστε το μειωμένο σύνολο δεδομένων να οδηγεί σε βέλτιστη απόδοση του προβλεπτικού μοντέλου. Λόγω της υψηλής διαστατικότητας του χώρου των ραδιομικών χαρακτηριστικών, αυτή η μελέτη εστίασε σε μεθόδους που βασίζονται σε φίλτρα για τον συστηματικό προσδιορισμό ενός κατάλληλου υποσυνόλου. Υιοθετήθηκε η μέθοδος Ελάχιστου Πλεονασμού Μέγιστης Συνάφειας (mRMR - Minimum Redundancy Maximum Relevance), η οποία καθορίζει ένα βέλτιστο σύνολο

χαρακτηριστικών τα οποία είναι εξαιρετικά συναφή με τη μεταβλητή εξόδου, ενώ ταυτόχρονα είναι ελάχιστα πλεονάζοντα μεταξύ τους. Κατατάσσει δε τη σημασία των χαρακτηριστικών με βάση την αξιολόγηση του πλεονασμού και της συνάφειας, η οποία προσδιορίζεται μέσω αμοιβαίας πληροφορίας (mutual information). Η απόφαση επιλογής του αλγορίθμου mRMR για επιλογή χαρακτηριστικών στην προτεινόμενη μεθοδολογία υποστηρίζεται από τη σύγκριση με τη μέθοδο ReliefF, η οποία είναι μια εναλλακτική filter-based μέθοδος επιλογής χαρακτηριστικών. Η μέθοδος mRMR δημιούργησε χαρακτηριστικά τα οποία είχαν υψηλότερη ακρίβεια όταν εξετάζονταν η παρατηρούμενη μέγιστη ακρίβεια σε όλα τα μοντέλα. Τα αποτελέσματα της ταξινόμησης βασισμένης σε ReliefF έδειξαν ελαφρώς κατώτερη απόδοση σε σύγκριση με σχήματα βασισμένα σε mRMR, υποστηρίζοντας την καταλληλότητα της επιλογής mRMR σε αυτή τη μελέτη.

5.3.3 Κανονικοποίηση και Διασταυρούμενη Επικύρωση

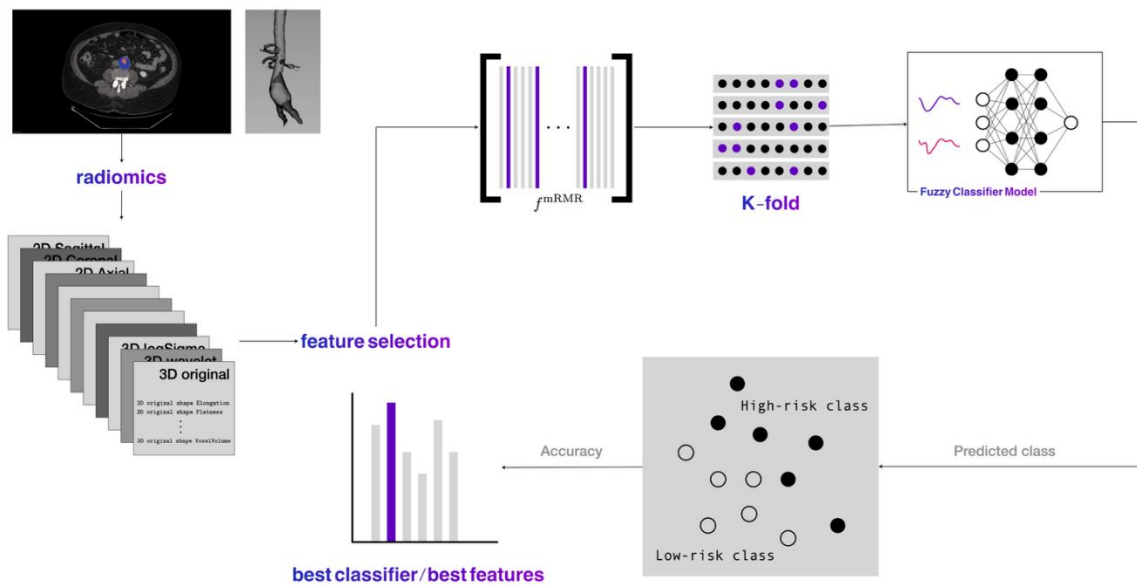
Για την εκπαίδευση των ασαφών ταξινομητών, όλα τα χαρακτηριστικά απεικονίστηκαν στο διάστημα $[0,1]$ χρησιμοποιώντας την τεχνική κανονικοποίησης min-max. Αυτή η μέθοδος αποδεικνύεται ωφέλιμη στην περίπτωση όπου τα χαρακτηριστικά βρίσκονται σε διαφορετικές κλίμακες που ποικίλλουν κατά τάξεις μεγέθους, δηλαδή το χαρακτηριστικό με μεγάλη μεταβλητότητα θα κυριαρχήσει όσον αφορά την προβλεπτική επιρροή. Στη μελέτη που πραγματοποιήθηκε εξετάστηκαν και εναλλακτικές μέθοδοι κανονικοποίησης δεδομένων για την αξιολόγηση της πιθανής επίδρασής τους στην απόδοση. Οι τεχνικές που αξιολογήθηκαν περιλαμβάνουν το Z-score και τις μεθόδους κλιμάκωσης διανύσματος μονάδας. Τα αποτελέσματα που ελήφθησαν ήταν πανομοιότυπα, με τη μέγιστη παρατηρούμενη διαφορά στην ακρίβεια να είναι μικρότερη από 0.3%. Κατά συνέπεια, και υπό το πρίσμα της υπολογιστικής αποδοτικότητας που παρέχει το σχήμα κανονικοποίησης min-max στη διαδικασία βελτιστοποίησης των ασαφών μοντέλων, υιοθετήθηκε σε όλη αυτή τη μελέτη.

Επιπροσθέτως, υιοθετήθηκε η τεχνική της διασταυρούμενης επικύρωσης (Cross-Validation - CV), συγκεκριμένα ένα σχήμα K-fold, για την εκτίμηση της απόδοσης γενίκευσης των προβλεπτικών μοντέλων. Η γενίκευση αναφέρεται στη μέση απόδοση που υπολογίζεται σε διαφορετικά σύνολα δεδομένων που δεν συμμετέχουν στη διαδικασία εκπαίδευσης. Δεδομένου ενός μικρού συνόλου δεδομένων, η διασταυρούμενη επικύρωση K-fold είναι μια ευρέως αναγνωρισμένη μέθοδος για την εκτίμηση της απόδοσης γενίκευσης ενός μοντέλου. Στην προτεινόμενη μεθοδολογία, πολλαπλοί ασαφείς ταξινομητές εκπαιδεύτηκαν και δοκιμάστηκαν σε πολυάριθμες τυχαίες K μη επικαλυπτόμενες διαμερίσεις των αρχικών δεδομένων. Κατά συνέπεια, το σφάλμα δοκιμής εκτιμάται συγκεντρώνοντας τις προβλέψεις που δημιουργούνται από καθένα από τα K μοντέλα. Για τη διατήρηση των ίδιων αναλογιών κλάσης σε κάθε πτυχή (fold), θεωρήθηκε στρωματοποιημένο (stratified) σχήμα διασταυρούμενης επικύρωσης.

5.3.4 Πρακτικές Λεπτομέρειες Μεθοδολογίας και Αποτελέσματα

Σε αυτή την ενότητα θα παρουσιαστούν οι λεπτομέρειες των παραμέτρων των προβλεπτικών μοντέλων, καθώς επίσης και το γενικότερο πλαίσιο της μεθοδολογίας, η οποία αναπαρίσταται

γραφικά στην επόμενη εικόνα. Επιπροσθέτως, θα παρουσιαστούν τα αποτελέσματα της εφαρμογής των ασαφών ταξινομητών στο πρόβλημα ταξινόμησης των ΑΚΑ.



Εικόνα 12 Flowchart της προτεινόμενης μεθοδολογίας.

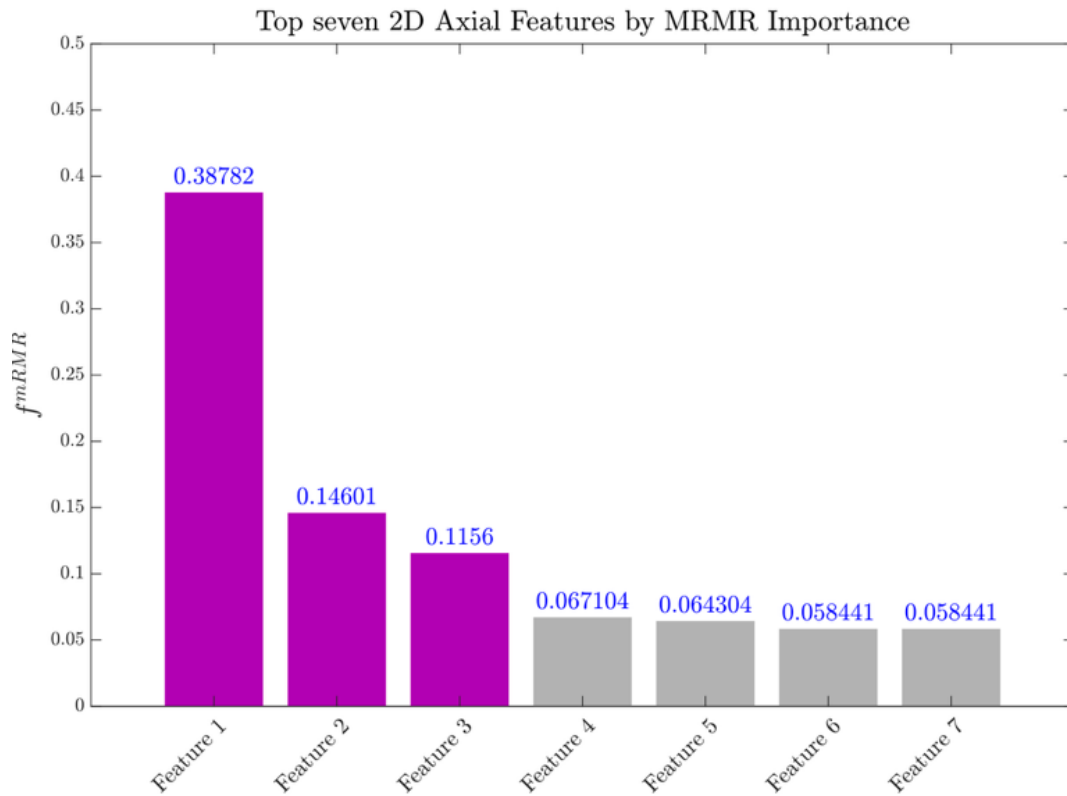
Συνολικά 66 ασθενείς περιλαμβάνονται σε αυτή τη μελέτη, ο καθένας σχετιζόμενος με 5635 ραδιομικά χαρακτηριστικά. Τα δεδομένα περιλαμβάνουν πληροφορίες σχετικά με τις μέγιστες διαμέτρους αορτής των ασθενών, η οποία θεωρείται η μεταβλητή στόχος του προβλήματος επιβλεπόμενης μάθησης. Το σύνολο δεδομένων κατασκευάζεται αντιστοιχίζοντας τα χαρακτηριστικά που δημιουργούνται από radiomics στη μεταβλητή στόχο y , που αντιπροσωπεύει τη μέγιστη διάμετρο αορτής. Στο πρόβλημα δυαδικής ταξινόμησης η κλάση χαμηλού κινδύνου αντιστοιχεί σε $y = 0$ και η κλάση υψηλού κινδύνου αντιστοιχεί σε $y = 1$. Ομαδοποιούμε τις διαμέτρους των ασθενών εντός των δύο κλάσεων, δηλαδή όταν $y \geq 55$, ορίζουμε το y στη μονάδα, ενώ όταν $y < 55$, ορίζουμε το y σε μηδέν. Ασθενείς χωρίς καταγεγραμμένες μετρήσεις διαμέτρου αποκλείστηκαν από την ανάλυση. Μετά την αφαίρεση ασθενών με ελλείπουσες τιμές (missing values), ο συνολικός αριθμός συμμετεχόντων ήταν 44. Τα δεδομένα περιλάμβαναν 42 άνδρες και 2 γυναίκες ασθενείς. Δεδομένου ότι οι κλάσεις υψηλού κινδύνου διαφέρουν σε διάμετρο μεταξύ ανδρών και γυναικών, οι γυναίκες ασθενείς αποκλείστηκαν για να αποφευχθεί η εισαγωγή μεροληψίας στα δεδομένα. Αυτή η απόφαση ελήφθη για να διασφαλιστεί ότι το σύνολο δεδομένων διατήρησε συνεπή επισήμανση. Κατά συνέπεια, και μετά τον τελευταίο αποκλεισμό, το τελικό σύνολο δεδομένων περιλάμβανε έναν πίνακα 42×5635 . Στα τελευταία δεδομένα, 19 περιπτώσεις αντιστοιχούσαν στην κλάση υψηλού κινδύνου, ενώ 23 στην κλάση χαμηλού κινδύνου.

Συνολικά μελετήθηκαν τέσσερις ασαφείς ταξινομητές: όλα τα ασαφή προβλεπτικά μοντέλα χρησιμοποίησαν Γκαουσιανές συναρτήσεις συμμετοχής για την παραγωγή των ασαφών διαμερίσεων εισόδου και εξόδου (για τα Mamdani συστήματα), ενώ για τα νευρο-ασαφή συστήματα υιοθετήθηκαν μηδενικής τάξης συναρτήσεις επακόλουθων. Η χρήση των

Γκαουσιανών συναρτήσεων, οφείλεται στον ελάχιστο αριθμό παραμέτρων έναντι άλλων συναρτήσεων συμμετοχής. Για τα Mamdani συστήματα υιοθετήθηκαν *minimum* τριγωνικές νόρμες, που αφορούσαν στα ασαφή συνδετικά όπως επίσης και στην ασαφή συνεπαγωγή. Η συνάθροιση των ασαφών συνόλων εξόδου, του κάθε κανόνα, υλοποιήθηκε με χρήση *maximum* τριγωνικής κονόρμας. Για τα νεύρο-ασαφή συστήματα (ANFIS), θεωρήθηκαν ασαφή συνδετικά με χρήση τριγωνικής νόρμας γινομένου, ενώ οι διαμερίσεις του χώρου εισόδου παρήχθησαν μέσω τανυστικών γινομένων των ασαφών συνόλων εισόδου. Για τη βελτιστοποίηση της απόδοσης του ασαφούς ταξινομητή, το σχήμα *DE/Best/1/bin* της διαφορικής εξέλιξης για να διευκολύνουμε την πρώιμη εξερεύνηση υποσχόμενων λύσεων εντός του χώρου αναζήτησης. Υποθέτουμε έναν μέγιστο αριθμό τριάντα γενεών, αρκετά επαρκή για το μελετημένο πρόβλημα, και ταυτόχρονα διασφαλίζει δίκαιη σύγκριση με την επανάληψη που εξετάστηκε για την εκπαίδευση ANFIS. Οι μεταβλητές απόφασης, που σχετίζονται με το πρόβλημα βελτιστοποίησης, αποτελούνται από όλους τους πυρήνες και τις τυπικές αποκλίσεις κάθε ασαφούς συνόλου στις διαμερίσεις εισόδου και εξόδου ασαφούς. Το μέγεθος πληθυσμού ορίζεται ως δεκαπλάσιο του αριθμού των μεταβλητών απόφασης. Οι υπερπαραμέτροι διαφορικής εξέλιξης, δηλαδή η κλιμάκωση μετάλλαξης και η πιθανότητα διασταύρωσης, ορίζονται ως $F = 0.5$ και $pcr = 0.9$, αντίστοιχα, ακολουθώντας τις κατευθυντήριες γραμμές στη βιβλιογραφία. Όσον αφορά το πρόβλημα ταξινόμησης, οι υπολογισμένες έξοδοι που δημιουργούνται από κάθε ασαφές μοντέλο υποβάλλονται σε κατωφλίωση (thresholded) για τη δημιουργία μιας δυαδικής εξόδου, δηλαδή $\{0, 1\}$. Υπό την προϋπόθεση ότι ο τομέας εξόδου βρίσκεται στο $[0, 1]$, η τιμή κατωφλίου είναι 0.5, ως εκ τούτου οι τιμές κάτω από αυτό το όριο θεωρούνται περιπτώσεις χαμηλού κινδύνου, ενώ οι μεγαλύτερες τιμές αντιστοιχίζονται στην κλάση υψηλού κινδύνου.

Εφαρμόστηκε ένα σχήμα επιλογής χαρακτηριστικών σε κάθε υποομάδα, με τα χαρακτηριστικά να κατατάσσονται με βάση τη σημασία τους όπως προσδιορίστηκε από τη μέθοδο Ελάχιστου Πλεονασμού Μέγιστης Συνάφειας (mRMR). Ακολουθώντας τη διαδικασία επιλογής χαρακτηριστικών, τα μοντέλα ταξινόμησης εκπαιδεύτηκαν και δοκιμάστηκαν, επεκτείνοντας προοδευτικά τον χώρο εισόδου, ξεκινώντας με $\{1, 2\}$, στη συνέχεια $\{1, 2, 3\}$ και ούτω καθεξής, μέχρι επτά εισόδους. Για παράδειγμα, ο συνδυασμός εισόδου $\{1, 2\}$ αποτελείται από το υψηλότερης κατάταξης και το δεύτερο υψηλότερης κατάταξης χαρακτηριστικό, σύμφωνα με το σχήμα mRMR. Για κάθε χώρο εισόδου, τα μοντέλα εκπαιδεύονται και δοκιμάζονται, και η απόδοσή τους σε κάθε υποσύνολο χαρακτηριστικών αξιολογείται χρησιμοποιώντας στρωματοποιημένη διασταυρούμενη επικύρωση. Με βάση την εκτενή αριθμητική μελέτη που πραγματοποιήθηκε, προσδιορίστηκε ότι τα χαρακτηριστικά που αποδίδουν την υψηλότερη ακρίβεια σε όλα τα προβλεπτικά μοντέλα αποτελούνται από τα χαρακτηριστικά 2D Axial.

Τα 2D Axial χαρακτηριστικά με την υψηλότερη κατάταξη, όπως υπολογίστηκαν βάσει της μεθόδου επιλογής χαρακτηριστικών mRMR, παρουσιάζονται στην επόμενη εικόνα.

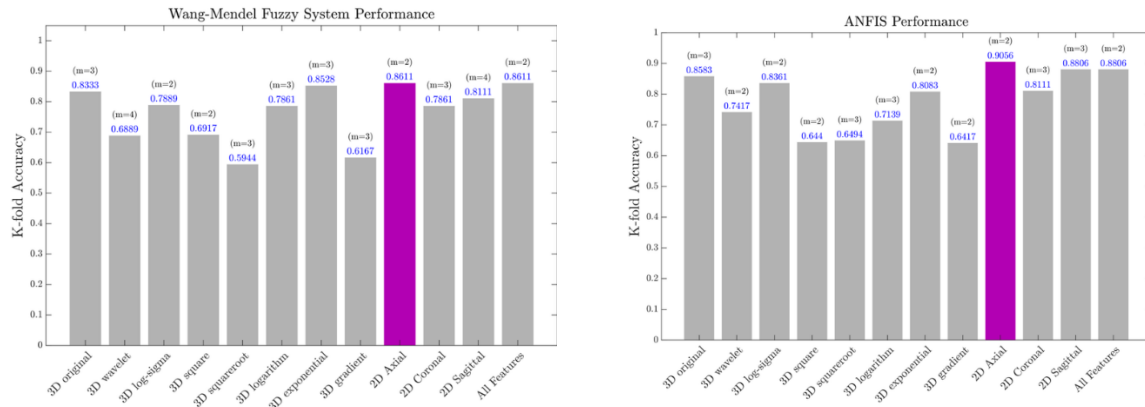


Εικόνα 13 2D Axial χαρακτηριστικά βάσει mRMR.

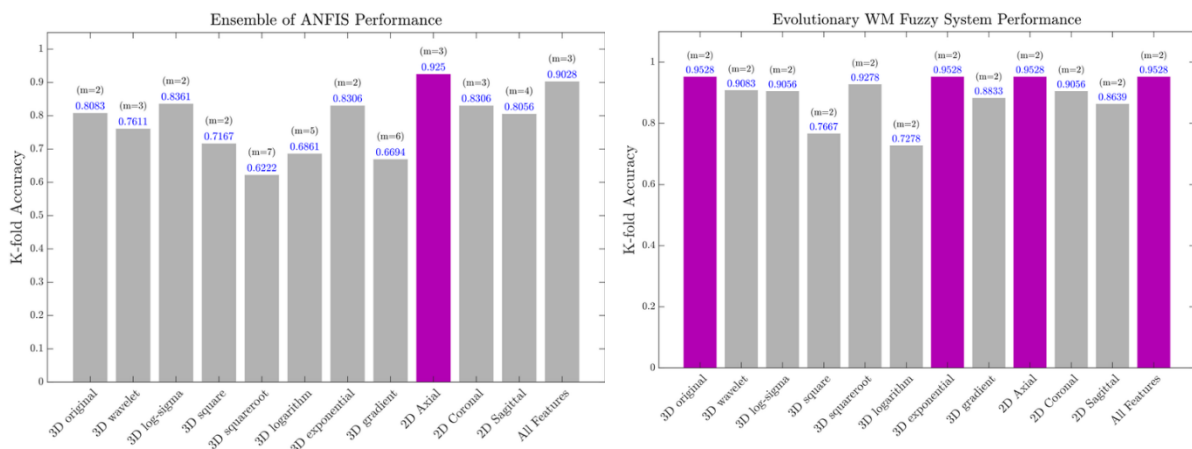
Τα επιλεγμένα χαρακτηριστικά από την μέθοδο mRMR, παρουσιάζονται στον επόμενο πίνακα.

Κατάταξη βάσει mRMR	2D Axial Ραδιομικό Χαρακτηριστικό
1	2D Axial exponential glrlm RunVariance
2	2D Axial log-sigma-3-0-mm-3D firstorder TotalEnergy
3	2D Axial exponential glgm LargeDependenceHighGrayLevelEmphasis
4	2D Axial exponential glrlm RunEntropy
5	2D Axial original shape LeastAxisLength
6	2D Axial wavelet-LL firstorder TotalEnergy
7	2D Axial gradient firstorder Minimum

Τα αποτελέσματα των ασαφών ταξινομητών δοκιμασμένα σε κάθε υποσύνολο ραδιομικών χαρακτηριστικών και για μεταβλητό αριθμό εισόδων, παρουσιάζονται στις επόμενες εικόνες. Πιο αναλυτικά, οι εικόνες παρουσιάζουν τη μέγιστη παρατηρούμενη ακρίβεια (accuracy), όταν τα ασαφή μοντέλα εκπαιδεύτηκαν πάνω σε μία εκ των έντεκα υποομάδων των χαρακτηριστικών.



Εικόνα 7 Μέση προβλεπτική ακρίβεια ταξινόμησης από διασταυρούμενη επικύρωση για κάθε υποσύνολο ραδιομικών χαρακτηριστικών. Αριστερά τα αποτελέσματα για τον WM ασαφή ταξινομητή. Δεξιά τα αποτελέσματα του νευρο-ασαφούς συστήματος.



Εικόνα 84 Μέση προβλεπτική ακρίβεια ταξινόμησης από διασταυρούμενη επικύρωση για κάθε υποσύνολο ραδιομικών χαρακτηριστικών. Αριστερά τα αποτελέσματα για τον Ensemble νευρο-ασαφή ταξινομητή. Δεξιά τα αποτελέσματα υβριδικού εξελικτικού ασαφούς συστήματος.

Όπως ανέδειξε η αριθμητική μελέτη η απόδοση του υβριδικού εξελικτικού ασαφούς ταξινομητή, είναι η υψηλότερη με βάση τη μέγιστη παρατηρούμενη ακρίβεια. Εκτός των άλλων είναι επίσης φανερό ότι στην πλειοψηφία των ασαφών προβλεπτικών μοντέλων, τα 2D Axial ραδιομικά χαρακτηριστικά οδηγούν στην υψηλότερη παρατηρούμενη ακρίβεια.

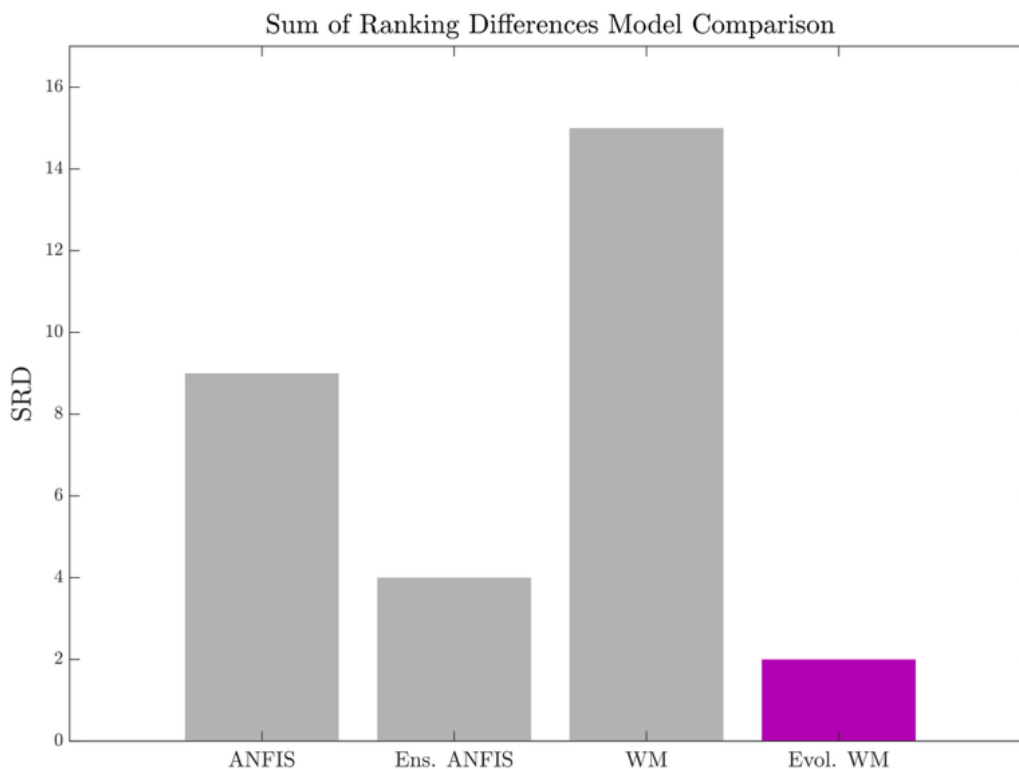
Ο επόμενος πίνακας παρουσιάζει όλα τα μέτρα ταξινόμησης, για τα τέσσερα προβλεπτικά μοντέλα.

Μέτρα απόδοσης για τα ασαφή προβλεπτικά μοντέλα ταξινόμησης πάνω στα 2D Axial χαρακτηριστικά.

Μοντέλο	Accuracy	F1	Recall	Specificity	Cohen's Kappa
ANFIS ⁽²⁾	0.9056	0.8833	0.8833	0.9200	0.8400
Ensemble ANFIS ⁽³⁾	0.9250	0.9143	0.9000	0.9500	0.8500
WM Ασαφής Ταξινομητής ⁽²⁾	0.8611	0.8325	0.8500	0.8700	0.7500
Υβριδικός WM Ασαφής Ταξινομητής ⁽²⁾	0.9528	0.9314	0.8833	1.0000	0.9200

Σημείωση: Ο εκθέτης δίπλα στο κάθε μοντέλο αναφέρεται στον αριθμό επιλεγμένων εισόδων του κάθε προβλεπτικού μοντέλου.

Υπό το πρίσμα πολλαπλών μέτρων απόδοσης της ταξινόμησης, υιοθετήθηκε η μέθοδος του SRD (Sum of Ranking Differences), η οποία παρέχει έναν μη-παραμετρικό μέτρο σύγκρισης για τα προβλεπτικά μοντέλα. Η μέθοδος βασίζεται στο υπολογισμένο SRD: όσο μικρότερη είναι η τιμή, τόσο καλύτερο είναι το μοντέλο. Σύμφωνα με τη μεθοδολογία SRD, ο υβριδικός εξελικτικός ασαφής ταξινομητής κατατάσσεται ως ο καλύτερος συγκρινόμενος με όλα τα ασαφή μοντέλα, ακολουθούμενος από το ensemble of ANFIS. Τα αποτελέσματα της σύγκρισης του SRD, παρουσιάζονται στην επόμενη εικόνα.



Εικόνα 15 Αποτελέσματα σύγκρισης SRD.

Σε σύγκριση με ένα ισχυρό μοντέλο μηχανικής μάθησης και συγκεκριμένα με ένα μοντέλο SVM ταξινόμησης με γραμμικό kernel, αναφέρουμε ότι η υψηλότερη απόδοση που παρατηρήθηκε ήταν 0.9528, πάνω στο σύνολο 2D Axial ραδιομικών χαρακτηριστικών, εντούτοις στο κόστος περισσότερων εισόδων και μειωμένης διερμηνευσιμότητας. Σε αντίθεση ο εξελικτικός ασαφής ταξινομητής παρουσίασε υψηλή προβλεπτική απόδοση για χαμηλότερο αριθμό εισόδων, ενώ η θεμελίωση του πάνω σε ασαφείς κανόνες παρέχει ένα αρχικό πλαίσιο συστηματικής μελέτης της διερμηνευσιμότητας.

5.3.5 Συμπεράσματα

Στην παρούσα μελέτη μελετήθηκαν συνολικά τέσσερις προβλεπτικές μέθοδοι της υπολογιστικής νοημοσύνης: το σύστημα ασαφούς συμπερασματολογίας Mamdani βασισμένο στη μέθοδο Wang-Mendel για τη δημιουργία ασαφών κανόνων, η υβριδική εξελικτικά

βελτιστοποιημένη έκδοση του τελευταίου και ένα προσαρμοστικό νεύρο-ασαφές σύστημα συμπερασμού για ταξινόμηση. Επιπλέον, αναπτύχθηκε ένα ensemble προσαρμοστικών συστημάτων ασαφούς συμπερασματολογίας βασισμένων σε δίκτυο, με στόχο την αύξηση της απόδοσης του μεμονωμένου μοντέλου. Η μελέτη εστίασε στην ανάπτυξη μίας καθολικής μεθοδολογίας μηχανικής μάθησης, περιλαμβάνοντας όλα τα στάδια: *feature extraction*, *data pre-processing*, *feature selection*, *data-handling*, *model development*, *model evaluation* (training and testing), καθώς και *model comparison*.

Εν κατακλείδι, όταν χρησιμοποιήθηκαν τα 2D Axial ραδιομικά χαρακτηριστικά τα μοντέλα οδήγησαν σε υψηλή ακρίβεια, η οποία εκτιμήθηκε σε μία βάση K-fold. Το μοντέλο με την υψηλότερη προβλεπτική απόδοση αφορούσε στο υβριδικό ασαφές μοντέλο που συνδύασε εξελικτικές μεθόδους βελτιστοποίησης και μεθόδους σχεδιασμού ασαφών συστημάτων από δεδομένα.

Είναι σημαντικό να αναφερθεί ότι αυτή η μελέτη επικεντρώνεται συγκεκριμένα στην ταξινόμηση της μέγιστης διαμέτρου του ανευρύσματος, χωρίς να λαμβάνει υπόψη έναν ακόμη σημαντικό παράγοντα για τη λήψη αποφάσεων, που είναι η εξέλιξη του ανευρύσματος σε σχέση με το χρόνο.

5.3.6 READ ME FOR SAFE-AORTA APP INSTALLATION INSTRUCTIONS

- Open the file **Safe_Aorta_Fuzzy_Classification**
- Double click the installer **MyAppInstaller_mcr** to install the MATLAB Runtime 2024a
- In the installation window, select a destination folder. Choose by clicking add shortcut to desktop
- Accept the terms of the license agreement
- Begin installation
- Once the **MyAppInstaller_mcr** is installed, go to the **for_testing** folder
- Double click on the **Safe_Aorta_Fuzzy_Classification** application
- The application opens the terminal and demonstrates the training of evolutionary and ensemble fuzzy classifiers in identifying high and low risk cases based on the maximum diameter of the abdominal aortic aneurysm using radiomics data
- Follow the instructions displayed on the terminal