



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΜΑΚΕΔΟΝΙΑΣ

ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ

ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ

Χρήση τεχνητής νοημοσύνης στην ιατρική.

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

ΑΝΤΩΝΗ ΚΟΝΙΝΙ

(ΑΕΜ:2513)

Επιβλέπων : ΣΙΝΑΤΚΑΣ ΙΩΑΝΝΗΣ ΚΑΘΗΓΗΤΗΣ

ΚΑΣΤΟΡΙΑ ΟΚΤΩΒΡΙΟΣ 2024



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΜΑΚΕΔΟΝΙΑΣ

ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ

ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ

Χρήση τεχνητής νοημοσύνης στην ιατρική.

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

ΑΝΤΩΝΗ ΚΟΝΙΝΙ

(ΑΕΜ:2513)

Επιβλέπων : ΣΙΝΑΤΚΑΣ ΙΩΑΝΝΗΣ ΚΑΘΗΓΗΤΗΣ

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την

.....

Ον/μο Μέλους

Ιδιότητα Μέλους

.....

Ον/μο Μέλους

Ιδιότητα Μέλους

.....

Ον/μο

Ιδιότητα Μέλους

ΚΑΣΤΟΡΙΑ ΟΚΤΩΒΡΙΟΣ 2024

Copyright © 2024 – ΑΝΤΩΝΗΣ ΚΟΝΙΝΙ

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν αποκλειστικά τον συγγραφέα και δεν αντιπροσωπεύουν τις επίσημες θέσεις του Πανεπιστημίου Δυτικής Μακεδονίας. Ως συγγραφέας της παρούσας εργασίας δηλώνω πως η παρούσα εργασία δεν αποτελεί προϊόν λογοκλοπής και δεν περιέχει υλικό από μη αναφερόμενες πηγές.

Ευχαριστίες

Πρώτα απ' όλα, θα ήθελα να εκφράσω τις ευχαριστίες μου στον επιβλέποντα καθηγητή κ. Ιωάννη Σινάτκα, για την καθοδήγηση, την αμέριστη βοήθεια και τις ουσιαστικές του παρατηρήσεις καθ' όλη τη διάρκεια της εκπόνησης της εργασίας αυτής. Η εμπιστοσύνη του και οι πολύτιμες συμβουλές του αποτέλεσαν πηγή έμπνευσης για την ολοκλήρωση αυτής της προσπάθειας.

Επίσης, θα ήθελα να ευχαριστήσω την οικογένειά μου για την αδιάκοπη υποστήριξη και την ενθάρρυνση που μου προσέφεραν καθ' όλη τη διάρκεια των σπουδών μου.

Περίληψη

Το θέμα της πτυχιακής εργασίας είναι η χρήση της τεχνητής νοημοσύνης στον τομέα της ιατρικής για τη διεξαγωγή διαγνώσεων. Χρησιμοποιούνται αλγόριθμοι μηχανικής όρασης Transfer Learning και αλγόριθμοι μηχανικής μάθησης για τη δημιουργία διαγνωστικών συστημάτων με τη χρήση μάθησης με επίβλεψη. Εξηγείται η μεθοδολογία που ακολουθούν τα συστήματα μάθησης με επίβλεψη, εξηγείται η σημαντικότητα των δεδομένων για τη δημιουργία αλγορίθμων T.N. και η ανάγκη ενσωμάτωσης τεχνικών T.N. στην ιατρική για την εξόρυξη δεδομένων. Τέλος, αναφέρονται οι αποδόσεις των αλγορίθμων του κάθε συστήματος διεξαγωγής διαγνώσεων και η μέση απόδοση των αλγορίθμων βάσει των δεδομένων που χρησιμοποιήθηκαν.

Λέξεις Κλειδιά: Τεχνητή Νοημοσύνη, Μηχανική όραση, Διάγνωση, Μάθηση με επίβλεψη, Transfer learning .

Abstract

The subject of this thesis is the application of artificial intelligence in the medical field for diagnostic purposes. Specifically, Transfer Learning algorithms from computer vision and machine learning algorithms are utilized to develop diagnostic systems through supervised learning. The methodology followed by supervised learning systems is thoroughly analyzed, along with the significance of data in the development of AI algorithms. Additionally, the necessity of incorporating AI techniques in the medical field for data extraction is emphasized. Lastly, the performance metrics of the algorithms employed in each diagnostic system are presented, including the average performance based on the data utilized.

Key Words: Artificial Intelligence, Computer Vision, Diagnosis, Supervised Learning, Transfer Learning.

Πίνακας Περιεχομένων

ΚΑΣΤΟΡΙΑ ΟΚΤΩΒΡΙΟΣ 2024.....	1
ΚΑΣΤΟΡΙΑ ΟΚΤΩΒΡΙΟΣ 2024.....	3
Εισαγωγή.....	12
1.2)Μετρήσης αποδόσεων.....	15
2.Χρήση προεκπαιδευμένων αρχιτεκτονικών νευρωνικών δικτύων.....	17
2.1 EfficientNet.....	17
2.2 DenseNet201.....	17
2.3 VGG 16-19.....	18
2.4 ResNet50.....	18
2.5 Inception.....	18
2.6 Xception.....	18
3)Χρήση αλγορίθμων T.N. για τη διεξαγωγή ιατρικών διαγνώσεων.....	18
4. Χρήση transfer learning και μηχανικής μάθησης για τη δημιουργία διαγνωστικών συστημάτων.....	21
Εφαρμογή 4.1 Διάγνωση καρκίνου στον πνεύμονα.....	21
4.1 Αποτελέσματα Εφαρμογής.....	22
4.2 Εφαρμογή : Διάγνωση Καρκίνου του παχέος εντέρου.....	24
4.3 Εφαρμογή : Διάγνωση Καρκίνου του πνεύμονα.....	26
Παρακάτω αναγράφονται οι αποδοτικότητες των μοντέλων:.....	28
4.3 Αποτελέσματα Εφαρμογής.....	28
4.4 Εφαρμογή : Διάγνωση καρκίνου στον εγκέφαλο.....	29
4.4 Αποτελέσματα Εφαρμογής.....	30
4.5 Εφαρμογή : Διάγνωση καρκίνου στο στήθος.....	32
4.5 Αποτελέσματα Εφαρμογής.....	33
4.6 Εφαρμογή :Διάγνωση Πνευμονίας Διάγνωση πνευμονίας χρησιμοποιώντας X-ray Scans του θώρακα.....	35
4.6 Αποτελέσματα Εφαρμογής.....	37
4.7 Εφαρμογή : Κατάταξη γονιδίων που εκφράζουν καρκίνο στον εγκέφαλο.....	38
4.7 Αποτελέσματα Εφαρμογής.....	39
4.8 Εφαρμογή Πρόβλεψη εγκεφαλικού.....	39
Για την δημιουργία του συστήματος χρησιμοποιήθηκαν δεδομένα από τους παρακάτω φορείς: [31], [32], [33]. Τα δεδομένα που χρησιμοποιούνται είναι ένα αρχείο CSV που περιέχει 5110 δείγματα (γραμμές) και 8 στήλες με τα παρακάτω χαρακτηριστικά:.....	39
Παρακάτω αναγράφεται το σύστημα με τις βέλτιστες αποδόσεις και οι εκάστοτε μετρήσεις των αποδόσεων.....	40
4.8 Αποτελέσματα: Εφαρμογής.....	40
4.9 Εφαρμογή : Διάγνωση οφθαλμικών παθήσεων.....	40
4.9.1 Εφαρμογή: Διάγνωση Καταρράκτη.....	42
4.9.2 Εφαρμογή : Διάγνωση Σακχαρώδη διαβήτη.....	43
4.9.3 Εφαρμογή : Διάγνωση Γλαυκώματος.....	44
4.9.4 Αποτελέσματα Εφαρμογής Διάγνωσης Υπέρτασης.....	46
4.9.5 Αποτελέσματα Εφαρμογής Διάγνωσης Μυωπίας.....	48
4.9.6 Εφαρμογή : Διάγνωση οφθαλμικών Προβλήματων λόγου ηλικίας.....	49

4.9.7 Εφαρμογή : Διάγνωση Άλλων οφθαλμικών παθήσεων.....	50
4.10 Εφαρμογή : Διάγνωση Αλτσχάιμερ 2D.....	52
4.10.2 Binary Classification.....	54
4.11 Εφαρμογή : Διάγνωση χρόνιας νεφρικής νόσου.....	56
4.11 Αποτελέσματα Εφαρμογής.....	58
4.12 Εφαρμογή : Διάγνωση του Συνδρόμου της Πολυκυστικής Ωοθήκης (Polycystic Ovary Syndrome).....	58
4.12 Αποτελέσματα Εφαρμογής.....	60
4.13 Εφαρμογή : Διάγνωση Οστεοαρθρίτιδας.....	60
4.13 Αποτελέσματα Εφαρμογής.....	61
4.14 Εφαρμογή Διάγνωση Ελονοσίας.....	63
4.14 Αποτελέσματα Εφαρμογής.....	64
4.15 Εφαρμογή : Διάγνωση Καρκίνου - Πέτρας - Λάσπης στα Νεφρά.....	64
4.15.1 Εφαρμογή Δυαδική κατάταξης: Διάγνωση καρκίνου στα νεφρά.....	67
4.15.2 Εφαρμογή Δυαδική κατάταξης: Διάγνωση πέτρας στα νεφρά.....	68
4.15.3 Εφαρμογή : Δυαδική κατάταξη: Διάγνωση λάσπης στα νεφρά.....	69
5. Μέσος όρος απόδοσης αλγόριθμων	71
.....	71
7) Σχετικές Έρευνες.....	72
8) Διαδικτυακή εφαρμογή “ Διαδικτυακές Διαγνώσεις”.....	73
9) Αναφορές.....	74
Αναφορές Κώδικα.....	81

Λίστα Εικόνων

Table of Figures

Εικόνα 1: Δείγμα εικόνας Αξονικής πνεύμονα.....	23
Εικόνα 2: Δείγμα εικόνας : Ιστοπαθολογική εικόνα παχέου εντέρου.....	26
Εικόνα 3: Δείγμα ιστοπαθολογικής εικόνας πνεύμονα.....	28
Εικόνα 4: Δείγμα εικόνας Αξονικής τομογραφίας εγκεφάλου. Πηγή: https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification	31
Εικόνα 5: Δείγμα εικόνας υπέρηχου στήθους.....	34
Εικόνα 6: Δείγμα εικόνας αξονικής πνεύμονα.....	37
Εικόνα 7: Δείγμα Οφθαλμικής εικόνας Πηγή: https://www.kaggle.com/datasets/andrewmvd/ocular-disease-recognition-odir5k	42
Εικόνα 8: Δείγμα εικόνας Μαγνητικής τομογραφίας εγκεφάλου.....	53
Εικόνα 9 : Δείγμα εικόνας: Υπερηχογράφηματος Ωοθηκών.....	60
Εικόνα 10: Δείγμα εικόνας αξονικής γονάτος.....	62
Εικόνα 11: Δείγμα εικόνας Κύτταρο μολυσμένο με ελονοσία πηγή: https://www.kaggle.com/datasets/itsdaniyal/malerial-cell-classification-dataset	64
Εικόνα 12: Δείγμα εικόνας Αξονικής νεφρών. https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone	67
Εικόνα 13: index.html.....	77
Εικόνα 14: login.html.....	78
Εικόνα 15: Signup.html.....	79

Εικόνα 16: Result.html.....	80
Εικόνα 17: result_list.html.....	81
Εικόνα 18: upload.html.....	82

Λίστα Πινάκων

Πίνακας 1: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης καρκίνου στον πνεύμονα.....	24
Πίνακας 2: Πίνακας αποτελεσμάτων αρχιτεκτονικής Densnet201 αποδοτικότητα διάγνωσης καρκίνου του πνεύμονα.....	24
Πίνακας 3: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning Διάγνωσης καρκίνου του παχέου εντέρου.....	27
Πίνακας 4: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης καρκίνου του πνεύμονα.....	29
Πίνακας 5: Πίνακας αποτελεσμάτων αρχιτεκτονικής Xception αποδοτικότητα διάγνωσης καρκίνου του πνεύμονα ανά κλάση ξεχωριστά.....	30
Πίνακας 6: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης καρκίνου του εγκεφάλου.....	32
Πίνακας 7: Πίνακας αποτελεσμάτων αρχιτεκτονικής Xception αποδοτικότητα διάγνωσης καρκίνου στον εγκέφαλο ανά κλάση ξεχωριστά.....	33
Πίνακας 8: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης καρκίνου στο στήθος.....	35
Πίνακας 9: Πίνακας αποτελεσμάτων αρχιτεκτονικής DenseNet201 αποδοτικότητα διάγνωσης καρκίνου στο στήθος ανά κλάση ξεχωριστά.....	36
Πίνακας 10: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης πνευμονίας.....	38
Πίνακας 11: Πίνακας αποτελεσμάτων αρχιτεκτονικής InceptionV3 αποδοτικότητα διάγνωσης πνευμονίας ανά κλάση ξεχωριστά.....	39
Πίνακας 12: Πίνακας αποτελεσμάτων κατάταξης γονιδίων που εκφράζουν καρκίνο στον εγκέφαλο.....	40
Πίνακας 13: Πίνακας αποτελεσμάτων πρόβλεψης εγκεφαλικού.....	41
Πίνακας 14: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης καταρράκτη.....	43
Πίνακας 15: Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50 αποδοτικότητα διάγνωσης καταρράκτη ανά κλάση ξεχωριστά.....	44
Πίνακας 16: Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50 αποδοτικότητα διάγνωσης καταρράκτη ανά κλάση ξεχωριστά.....	44
Πίνακας 17: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης Σακχαρώδη διαβήτη.....	44
Πίνακας 18: Πίνακας αποτελεσμάτων αρχιτεκτονικής VGG16 αποδοτικότητα διάγνωσης Σακχαρώδη διαβήτη ανά κλάση ξεχωριστά.....	45
Πίνακας 19: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης γλαυκώματος...	45
Πίνακας 20: Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50 αποδοτικότητα διάγνωσης γλαυκώματος ανά κλάση ξεχωριστά.....	46
Πίνακας 21: : Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50 χρήση διαφορετικών βελτιστοποιητών διάγνωση γλαυκώματος.....	47
Πίνακας 22: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης υπέρτασης.....	48
Πίνακας 23: Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50 αποδοτικότητα διάγνωσης υπέρτασης ανά κλάση ξεχωριστά.....	48
Πίνακας 24: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης Μυωπίας.....	49
Πίνακας 25: Πίνακας αποτελεσμάτων αρχιτεκτονικής VGG19 αποδοτικότητα διάγνωσης Μυωπίας ανά κλάση ξεχωριστά.....	50
Πίνακας 26: Πίνακας αποτελεσμάτων αρχιτεκτονικής VGG16 αποδοτικότητα διάγνωσης οφθαλμικών Προβλημάτων λόγου ηλικίας.....	50
Πίνακας 27: αποτελεσμάτων αρχιτεκτονικής VGG16 αποδοτικότητα διάγνωσης Οφθαλμικών Προβλημάτων λόγου ηλικίας ανά κλάση ξεχωριστά.....	51

Πίνακας 28: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης οφθαλμικών παθήσεων.....	52
Πίνακας 29: Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50. αποδοτικότητα διάγνωσης οφθαλμικών παθήσεων ανά κλάση ξεχωριστά.....	52
Πίνακας 30: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης αλτσχαιμερ.....	54
Πίνακας 31: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης αλτσχαιμερ δυαδική ταξινόμηση(1-Ασθενής , 0 Υγιές δείγμα).....	56
Πίνακας 32: Πίνακας αποτελεσμάτων αρχιτεκτονικής Xception αποδοτικότητα διάγνωσης αλτσχαιμερ ανά κλάση ξεχωριστά.....	57
Πίνακας 33: Πίνακας αποτελεσμάτων διάγνωσης χρόνιας νεφρικής νόσου.....	58
Πίνακας 34: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης του συνδρόμου της πολυκυστικής ωοθήκης.....	61
Πίνακας 35: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης οστεοαρθρίτιδας.....	63
Πίνακας 36: Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50 αποδοτικότητα διάγνωσης οστεοαρθρίτιδας ανά κλάση ξεχωριστά.....	63
Πίνακας 37: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης ελονοσίας.....	65
Πίνακας 38: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης καρκίνου στα νεφρά.....	68
Πίνακας 39: Πίνακας αποτελεσμάτων αρχιτεκτονικής DenseNet201, αποδοτικότητα διάγνωσης καρκίνου στα νεφρά ανά κλάση ξεχωριστά.	69
Πίνακας 40: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης πέτρας στα νεφρά.....	69
Πίνακας 41 : Πίνακας αποτελεσμάτων αρχιτεκτονικής EfficientNetB3 αποδοτικότητα διάγνωσης πέτρας στα νεφρά ανά κλάση ξεχωριστά.....	70
Πίνακας 42: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης λάσπης στα νεφρά.....	71
Πίνακας 43: Πίνακας αποτελεσμάτων αρχιτεκτονικής EfficientNetB1 αποδοτικότητα διάγνωσης λάσπης στα νεφρά ανά κλάση ξεχωριστά.....	71
Πίνακας 44: Πίνακας αποτελεσμάτων αρχιτεκτονικής InceptionV3 αποδοτικότητα διάγνωσης λάσπης στα νεφρά ανά κλάση ξεχωριστά.....	72
Πίνακας 45: Μέση απόδοση αλγορίθμων.....	72

Εισαγωγή

Ζούμε σε μια εποχή με πληθώρα δεδομένων και απίστευτα δυνατή υπολογιστική ισχύ, δημιουργώντας τη δυνατότητα εύρεσης νοητικά ευφυών αλγορίθμων επίλυσης δύσκολων προβλημάτων. Ο τρόπος επίλυσης τέτοιων προβλημάτων γίνεται με τη χρήση της πληθώρας δεδομένων που έχουμε στη διάθεσή μας και τη χρήση τους για την εκπαίδευση αλγορίθμων Τ.Ν. Ο τομέας της Τεχνητής Νοημοσύνης αναπτύσσεται με μεγάλη ταχύτητα, και όλο και περισσότεροι τομείς θα επωφεληθούν από την εξέλιξή της. Ειδικότερα, ένας από τους πιο επωφελούμενους τομείς είναι η επιστήμη της ιατρικής. Με τη χρήση αλγορίθμων τεχνητής νοημοσύνης, θα μπορούμε να αυτοματοποιήσουμε διεργασίες όπως η διάγνωση. Δημιουργώντας συστήματα Τ.Ν. που θα αυτοματοποιούν τη διαδικασία, θα έχει ως αποτέλεσμα τη μείωση του κόστους διεξαγωγής των εξετάσεων, την ταχύτερη εξυπηρέτηση και τη μείωση του συνολικού χρόνου που θα χρειάζεται να περνάμε στο νοσοκομείο. Αυτήν τη στιγμή, κάνοντας μια εξέταση, π.χ. μια αξονική, θα πρέπει να επιδειξουμε τα αποτελέσματα των εξετάσεων σε έναν γιατρό για να μας δώσει το πόρισμα. Αυτή η μέθοδος χρησιμοποιεί περισσότερο ανθρώπινο δυναμικό, αλλά είναι και δύσχρηστη για τους ασθενείς, διότι αναγκάζονται να περιφέρονται στα νοσοκομεία, με αποτέλεσμα να χάνουν πολύτιμο χρόνο και να δημιουργούνται τεράστιες ουρές αναμονής στα ιατρεία. Η ανάγκη ενσωμάτωσης της Τ.Ν. σε πολλούς τομείς της ιατρικής είναι τεράστια και θα συμβάλει σημαντικά στη μείωση του συνολικού κόστους της θεραπείας, αλλά και στην ποιοτικότερη αποτελεσματικότητά της. Η ανάγκη ενσωμάτωσης τεχνολογιών Τ.Ν. στην ιατρική δεν έχει να κάνει μόνο με τη συνολικά καλύτερη εξυπηρέτησή μας στα ιατρεία. Ο κύριος λόγος είναι η εξόρυξη δεδομένων. Ενσωματώνοντας τεχνικές Τ.Ν. σε διάφορους τομείς στα ιατρεία, θα διευκολυνθεί η εξόρυξη δεδομένων, πράγμα που θα συμβάλει σημαντικά στη βελτιστοποίηση των αλγορίθμων αλλά και στην καλύτερη κατανόηση του ανθρώπινου σώματος και της φύσης των ασθενειών.

1. Η Μάθηση σε εφαρμογές Τεχνητής νοημοσύνης

Ένα μέρος της Τεχνητής Νοημοσύνης αποτελείται από αλγορίθμους μηχανικής μάθησης και νευρωνικών δικτύων. Οι αλγόριθμοι μηχανικής μάθησης και νευρωνικών δικτύων επιλύουν κάποια βασικά είδη προβλημάτων. Μερικά από αυτά είναι προβλήματα παλινδρόμησης, όπου ο αλγόριθμος προσπαθεί να προβλέψει μια διακριτή τιμή, για παράδειγμα τη μείωση του ιϊκού φορτίου σε έναν ασθενή, δεδομένης μιας φαρμακευτικής αγωγής. Προβλήματα ταξινόμησης κλάσεων, παραδείγματος χάρι, η κατάταξη του καρκινικού σταδίου. Και γεννήτριες δεδομένων, π.χ., παραγωγή ψηφιακού κλώνου για την εκπαίδευση χειρουργικού προσωπικού σε προσομοιώσεις σε περιβάλλον εικονικής πραγματικότητας.

Στην μάθηση με επίβλεψη δίνουμε το επιθυμητό αποτέλεσμα ως είσοδο, γνωρίζοντας το εξ αρχής, με σκοπό την εκμάθηση του τρόπου διαχώρησης των δειγμάτων μέσω εύρεσης μοτίβων και χαρακτηριστικών των κλάσεων από τον αλγόριθμό μας. Έστω ότι έχουμε στη διάθεσή μας μαγνητικές τομογραφίες 200 ασθενών πασχόντων από καρκίνο διαφορετικών σταδίων στον εγκέφαλο. Φορτώνοντας τα δεδομένα στον αλγόριθμο, δίνοντάς του και την πληροφορία για το στάδιο που βρίσκεται ο καρκίνος για τον κάθε ασθενή, το επιθυμητό αποτέλεσμα που θέλουμε να παραγάγουμε είναι δίνοντας καινούριες μαγνητικές τομογραφίες εγκεφάλων, ο αλγόριθμος να κατατάσσει το στάδιο στο οποίο βρίσκεται ο καρκίνος στον πάσχοντα με επιτυχία. Η μάθηση χωρίς επίβλεψη, στην οποία φορτώνοντας τα δεδομένα περιμένουμε από τον αλγόριθμό μας να τα ομαδοποιεί ανάλογα με κάποιο κριτήριο. Η διαδικασία αυτή ονομάζεται Clustering. Παραδείγματος χάριν, δοκιμάζουμε ένα πειραματικό φάρμακο και θέλουμε να χωρίσουμε σε διάφορες ομάδες το δείγμα ανάλογα με την ηλικία, το ύψος, το βάρος, καρδιακούς παλμούς/λεπτό και το ιατρικό ιστορικό τους. Ας υποθέσουμε ότι έχουμε 2000 εθελοντές και θέλουμε να τους χωρίσουμε σε 20 ομάδες ανάλογα με αυτά τα κριτήρια. Οι ομάδες αυτές δεν χρειάζεται να είναι ισάριθμες, αλλά η ομαδοποίησή τους να γίνεται μόνο με βάση αυτά τα κριτήρια για να εξάγουμε πληροφορίες για κάθε ομάδα ξεχωριστά ή να ξεχωρίζουμε τις δόσολογίες της θεραπείας για κάθε ομάδα.

Μηχανική όραση είναι η χρήση αλγορίθμων βαθέων νευρωνικών δικτύων για την αναγνώριση χαρακτηριστικών σε δεδομένα εικόνας. Οι υπολογιστές δεν “βλέπουν” τις εικόνες όπως οι άνθρωποι ή τα ζώα. Ο υπολογιστής βλέπει την εικόνα ως έναν αριθμητικό πίνακα γραμμικής άλγεβρας, με αριθμούς από το 0 ως το 255, που είναι το πόσο έντονα είναι τα χρώματα σε κάθε σημείο του πίνακα, ενώ κάθε σημείο του πίνακα αντιπροσωπεύει ένα πίξελ στην οθόνη. Με τη χρήση αλγορίθμων βαθέων νευρωνικών δικτύων, τα συστήματα μηχανικής όρασης μπορούν να καταλάβουν και να διαχωρίσουν γεωμετρικά σχήματα, χρώματα ή μοτίβα στα δεδομένα, με αποτέλεσμα να μπορούν να αναγνωρίσουν ή να διαχωρίσουν σε κατηγορίες τα δείγματα. Η χρήση αλγορίθμων μηχανικής όρασης στην ιατρική και

ειδικότερα για τη διάγνωση ασθενειών είναι πολύ αποτελεσματική. Αν ένας ειδικευόμενος ιατρός μπορεί με τη χρήση της όρασής του να διαγνώσει μια ασθένεια, τότε τα συστήματα μηχανικής όρασης με την κατάλληλη εκπαίδευση μπορούν να κάνουν τη διάγνωση με μεγαλύτερη ακρίβεια.

Τα νευρωνικά δίκτυα και η μηχανική μάθηση λειτουργούν ως αλγόριθμοι ελαχιστοποίησης. Όταν μιλάμε για μηχανική μάθηση και νευρωνικά δίκτυα μάθησης με επίβλεψη, είναι μια συνάρτηση που θέλουμε να ελαχιστοποιήσουμε. Η συνάρτηση αυτή ονομάζεται κόστος του αλγορίθμου. Με τη χρήση της συνάρτησης κόστους υπολογίζουμε και βελτιώνουμε την απόδοση του αλγορίθμου μας. Παραδείγματος χάριν, διεξάγοντας ένα πείραμα όπου έχουμε 100 ασθενείς με πνευμονία και 100 υγιείς εθελοντές καταγράφοντας τη μαγνητική πνεύμονα όλου του δείγματος έχουμε τα δεδομένα καταχωρημένα σε αυτές τις δύο ομάδες. Αν ο αλγόριθμός μας καταφέρει να κατατάξει επιτυχώς τα 100 από τα 200 δείγματα στις σωστές κατηγορίες "κλάσης", τότε έχουμε κόστος ύψους 50%, ένα αρκετά μεγάλο κόστος που πρέπει να βρούμε κάποιον τρόπο να μειωθεί. Η βελτιστοποίηση του αλγορίθμου γίνεται χρησιμοποιώντας τις εφαρμογές της παραγώγου. Όταν βρίσκουμε την παράγωγο, υπολογίζουμε την καμπύλη της συνάρτησης σε ένα συγκεκριμένο σημείο, στην περίπτωση μας την συνάρτηση κόστους. Τα νευρωνικά δίκτυα είναι ένα σύνολο νευρώνων διασυνδεδεμένο το ένα με το άλλο, όπου κάθε νευρώνας έχει ένα συγκεκριμένο βάρος, το οποίο χρησιμοποιείται σαν μια υπόθεση για την επίλυση του προβλήματος. Τα νευρωνικά δίκτυα έχουν πλάτος και βάθος νευρώνων και παραγωγίζοντας μερικώς τη συνάρτηση κόστους ως προς αυτά. Παραδείγματος χάριν, έχοντας τον νευρώνα με πλάτος (4) και βάθος (3), το βάρος του νευρώνα είναι: $w(4,3)=2$. Η συνάρτηση κόστους μας: $Cost=30\%$. Έστω ότι αλλάζει το βάρος αυτού του νευρώνα σε: $w(4,3)=2,0001$ και παρατηρείται η διαφορά στη συνάρτηση κόστους. Έτσι έχουμε παραγάγει μερικώς τη συνάρτηση κόστους ως προς το βάρος του νευρώνα: $w(4,3)$. Επαναλαμβάνοντας αυτή τη διαδικασία για όλους τους νευρώνες ώστε να ρυθμίσουν τα βάρη τους για να ελαχιστοποιήσουμε τη συνάρτηση κόστους, βελτιώνοντας έτσι την αποτελεσματικότητα του αλγορίθμου. Ο τρόπος βελτιστοποίησης γίνεται με την προσέγγιση του αλγορίθμου Gradient Descent και αλγορίθμους εμπνευσμένους από αυτόν όπως Stochastic Gradient Descent, Mini Batch Gradient Descent χρησιμοποιώντας τη λογική προσέγγιση που αναφέρθηκε παραπάνω. Για την εκπαίδευση μοντέλων μηχανικής μάθησης και νευρωνικών δικτύων στη μάθηση με επίβλεψη χρησιμοποιείται η μέθοδος train/test/split. Στη μέθοδο αυτή χωρίζονται τα δεδομένα σε δύο μέρη, το μέρος της εκπαίδευσης και το μέρος της εξέτασης. Στο μέρος της εκπαίδευσης δίνεται η δυνατότητα στον αλγόριθμο να επαναλάβει όλα τα βήματα για την εύρεση του βάρους κάθε νευρώνα για την ελαχιστοποίηση της συνάρτησης κόστους. Όσο ρυθμίζονται τα βάρη των νευρώνων με στόχο την ελαχιστοποίηση της συνάρτησης κόστους, φτάνουμε σε ένα σημείο που είμαστε ευχαριστημένοι με την απόδοση του αλγορίθμου στο μέρος και στα δεδομένα εκπαίδευσης, έτσι περνάμε στο μέρος της εξέτασης του αλγορίθμου. Στο μέρος της εξέτασης εξετάζεται η γνώση που έχει αποκτήσει ο

αλγόριθμος στο στάδιο της εκπαίδευσης. Εξετάζεται η λειτουργικότητα του αλγορίθμου σε καινούργια δεδομένα ίδιου τύπου με μεγάλη προσοχή να μην υπάρχουν διπλότυπα δεδομένα γιατί τότε ο αλγόριθμος μας δεν μαθαίνει αλλά απομνημονεύει. Θέλουμε ουσιαστικά να δούμε αν καταφέρνει να γενικεύσει την γνώση που πήρε στο στάδιο της εκπαίδευσης. Παραδείγματος χάριν, έχουμε εκατό δείγματα τομογραφίας εγκεφάλου χωρισμένα σε δύο ομάδες Υγιείς - Καρκινοπαθείς. Χωρίζοντας το δείγμα με ρυθμό εξέτασης 0,2 έχουμε 80 δείγματα για το στάδιο της εκπαίδευσης και 20 δείγματα για το στάδιο της εξέτασης. Για την βέλτιστη χρήση του αλγορίθμου θα πρέπει να είναι ισοκατανεμημένα τα δεδομένα στις κλάσεις τους (Υγιής-καρκινοπαθείς) και στο στάδιο εκπαίδευσης αλλά και στο στάδιο εξέτασης. Ξεκινώντας με την εκπαίδευση του αλγορίθμου, φορτώνουμε τα δεδομένα στον αλγόριθμο και ο αλγόριθμος κάνει μια υπόθεση για τη διαχώριση των δύο κλάσεων και βλέπει το αποτέλεσμα αυτής της υπόθεσης μέσω της συνάρτησης κόστους. Ο αλγόριθμος θα συνεχίσει να κάνει υποθέσεις μέχρι να ρυθμιστούν τα βάρη με τέτοιο τρόπο ώστε να μπορεί από τα δεδομένα της εκπαίδευσης να διαχωρίζει την κλάση στην οποία ανήκουν. Εφόσον “έμαθε” να διαχωρίζει τις κλάσεις στο πλαίσιο της εκπαίδευσης, πάμε τώρα να τον εξετάσουμε στο μέρος της εξέτασης. Δηλαδή στο υπόλοιπο 20% των δεδομένων που δεν έχει δει ποτέ ο αλγόριθμος μας. Ουσιαστικά θέλουμε δεδομένη την ικανότητα να διαχωρίζει σε κλάσεις τα 80 δεδομένα που είχαμε για το στάδιο εκπαίδευσης, ποια ικανότητα έχει να διαχωρίζει σε κλάσεις τα υπόλοιπα 20 καινούργια δεδομένα που δεν έχει ξαναδεί. Όταν ένας αλγόριθμος αδυνατεί να μάθει να διαχωρίζει τις κλάσεις και στο στάδιο της εκπαίδευσης αλλά και στο στάδιο της εξέτασης τότε το μοντέλο πάσχει από το φαινόμενο Underfitting. Ενώ όταν ο αλγόριθμος μας καταφέρνει να διαχωρίζει σε κλάσεις τα δεδομένα στο στάδιο της εκπαίδευσης αλλά αδυνατεί να γενικεύσει τις γνώσεις του στο στάδιο της εξέτασης, τότε το μοντέλο πάσχει από το φαινόμενο Overfitting.

1.2)Μετρήσης αποδόσεων.

Ακρίβεια (precision) :

Η ακρίβεια (Precision) είναι ένας δείκτης που χρησιμοποιείται για την αξιολόγηση μοντέλων ταξινόμησης. Μετρά την ακρίβεια των θετικών προβλέψεων που κάνει ένα μοντέλο, υποδηλώνοντας πόσα από τα περιστατικά που προβλέπονται ως θετικά είναι πραγματικά αληθινά θετικά. Η ακρίβεια υπολογίζεται χρησιμοποιώντας τον παρακάτω τύπο:

$$\text{Ακρίβεια} = \frac{\text{Πραγματικά Θετικά}}{\text{Πραγματικά Θετικά} + \text{Ψευδή Θετικά}}$$

Ανάκληση (recall):

Η ανάκληση (Recall) είναι ένας δείκτης που χρησιμοποιείται για την αξιολόγηση μοντέλων ταξινόμησης, μετρά την ικανότητα ενός μοντέλου να ανιχνεύει όλα τα πραγματικά θετικά περιστατικά. Η ανάκληση υπολογίζεται χρησιμοποιώντας τον παρακάτω τύπο:

$$\text{Ανάκληση} = \frac{\text{Πραγματικά Θετικά}}{\text{Πραγματικά Θετικά} + \text{Ψευδή Αρνητικά}}$$

Βαθμός F1 (F1 Score):

Ο Βαθμός F1 (F1 Score) είναι ένας συνδυασμένος δείκτης που λαμβάνει υπόψη τόσο την ακρίβεια όσο και την ανάκληση του μοντέλου. Χρησιμοποιείται για την αξιολόγηση της συνολικής απόδοσης σε προβλήματα ταξινόμησης. Υπολογίζεται χρησιμοποιώντας τον παρακάτω τύπο:

$$\text{Βαθμός F1} = \frac{2 \cdot \text{Ακρίβεια} \cdot \text{Ανάκληση}}{\text{Ακρίβεια} + \text{Ανάκληση}}$$

Βαθμός AUC (AUC Score) :

Ο Βαθμός AUC (AUC Score) αναφέρεται στο εμβαδόν κάτω από την καμπύλη ROC (Receiver Operating Characteristic) και χρησιμοποιείται για την αξιολόγηση της ικανότητας ενός μοντέλου να ξεχωρίζει μεταξύ των κλάσεων σε προβλήματα ταξινόμησης. Ο βαθμός AUC είναι ένας αριθμός μεταξύ

0 και 1, όπου μια τιμή 1 υποδηλώνει τέλεια διάκριση μεταξύ των κλάσεων, ενώ μια τιμή 0.5 υποδηλώνει τυχαία διάκριση.

2.Χρήση προεκπαιδευμένων αρχιτεκτονικών νευρωνικών δικτύων.

Η μέθοδος Transfer learning μας δίνει τη δυνατότητα να εκπαιδεύσουμε ένα νευρωνικό δίκτυο σε μια αρχιτεκτονική που έχει ήδη εκπαιδευτεί σε υπερυπολογιστές για διάφορα προβλήματα ταξινόμησης, κάνοντάς τον αλγόριθμο αρκετά ικανό να λύνει αρκετά διαφορετικά προβλήματα ταξινόμησης. Χρησιμοποιούμε τη γενική ικανότητα του αλγορίθμου για την εύρεση μοτίβων και χαρακτηριστικών για την επιτυχή ταξινόμηση κλάσεων που έχει αποκτήσει εκπαιδευόμενος σε χιλιάδες προβλήματα και χιλιάδες ώρες εκπαίδευσης. Ο αλγόριθμος προσαρμόζεται στο δικό μας πρόβλημα, κάνοντάς έτσι τη βελτιστοποίηση του σε πολύ μικρό χρονικό διάστημα και με αρκετά οικονομική υπολογιστική ισχύ σε σύγκριση με την εξ ολοκλήρου εκπαίδευση του αλγορίθμου.

ImageNet Competition: Το ImageNet Competition είναι ένας διαγωνισμός που βασίζεται σε μια βάση δεδομένων που έχει 14 εκατομμύρια φωτογραφίες που ανήκουν σε 1000 αξιολογές κλάσεις. Ερευνητές και οργανισμοί βελτιστοποιούν τους αλγορίθμους μηχανικής όρασης εκπαιδύοντας τους σε αυτόν τον τεράστιο όγκο δεδομένων και ανταγωνίζονται για τις καλύτερες επιδόσεις. Οι αρχιτεκτονικές Transfer learning εκπαιδεύονται χιλιάδες ώρες σε υπερυπολογιστές για την ορθή ταξινόμηση των 1000 κλάσεων της βάσης, κάνοντάς τους υπερ-εργαλεία που θα μπορούσαν κάλλιστα να λύσουν οποιοδήποτε πρόβλημα μηχανικής όρασης σύντομα και οικονομικά. Παρακάτω αναφέρονται μερικές αρχιτεκτονικές προ-εκπαιδευμένων νευρωνικών δικτύων.

2.1 EfficientNet

Το EfficientNet είναι μια σειρά από νευρωνικά δίκτυα συνελίξης (CNNs) που παρουσιάστηκε στο άρθρο [2] . Το άρθρο έχει ως στόχο να αντιμετωπίσει την πρόκληση της επίτευξης βελτιωμένης απόδοσης μειώνοντας το συνολο του υπολογιστικού κόστους.

2.2 DenseNet201

DenseNet-201 αναφέρεται σε μια συγκεκριμένη παραλλαγή της αρχιτεκτονικής DenseNet με 201 στρώματα(layers). Η αρχιτεκτονική παρουσιάστηκε στο άρθρο [3]

2.3 VGG 16-19

Οι αλγόριθμοι VGG16-19 είναι δύο αρχιτεκτονικές νευρωνικών δικτύων συνέλιξης που προτάθηκαν από το Visual Graphics Group (VGG) στο Πανεπιστήμιο της Οξφόρδης. Οι αρχιτεκτονικές παρουσιάστηκαν στο άρθρο: [4]

2.4 ResNet50

Το ResNet50 είναι μια αρχιτεκτονική νευρωνικού δικτύου συνέλιξης (CNN) που ανήκει στην οικογένεια των ResNet (Residual Networks). Προτάθηκε από το άρθρο [5]

“Παρουσιάζουμε ένα πλαίσιο υπολειπόμενης μάθησης για να διευκολύνουμε την εκπαίδευση δικτύων που είναι σημαντικά βαθύτερα από αυτά που χρησιμοποιήθηκαν προηγουμένως. Παρέχουμε περιεκτικά εμπειρικά δεδομένα που δείχνουν ότι αυτά τα υπολειπόμενα δίκτυα είναι ευκολότερα να βελτιστοποιηθούν και μπορούν να έχουν μεγαλύτερη ακρίβεια από δίκτυα σημαντικά αυξημένου βάθους..” Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun

2.5 Inception

Η αρχιτεκτονική Inception, επίσης γνωστή ως GoogLeNet, έχει παρουσιάσει “πρωταθλητικές” επιδόσεις στον διαγωνισμό ImageNet το 2014 με συνολικό σφάλμα 6,67%, σφάλμα το οποίο με τα χρόνια ολοένα και μειώνεται με τις νέες εκδόσεις όπως Inception V4 με σφάλμα 3,08%. Παρουσιάστηκε στο άρθρο [6].

2.6 Xception

Η αρχιτεκτονική Xception (Extreme Inception) έχει μοντελοποιηθεί από τον αλγόριθμο Inception και ενώ διαθέτουν τον ίδιο αριθμό παραμέτρων και πολυπλοκότητας με το Inception V3, το Xception χρησιμοποιεί καλύτερα τους πόρους και παρουσιάζει καλύτερη απόδοση. Παρουσιάστηκε από τον François Chollet στο άρθρο: [7]

3)Χρήση αλγορίθμων T.N. για τη διεξαγωγή ιατρικών διαγνώσεων.

Η χρήση αλγορίθμων μηχανικής μάθησης και μοντέλων βαθιών νευρωνικών δικτύων για τη διάγνωση ασθενειών θα αποτελεί ένα πολύ μεγάλο κομμάτι της ιατρικής στο κοντινό μέλλον. Τροφοδοτώντας έναν αλγόριθμο μηχανικής όρασης σε ένα σύστημα τεχνητής νοημοσύνης, μάθησης με επίβλεψη, με δεδομένα από εικόνες διαφόρων κατηγοριών, το σύστημα θα μπορεί να διαγνώσει με μεγάλη ακρίβεια διάφορες ασθένειες.

Παραδείγματα χρήσης:

Διάγνωση ιγμορίτιδας: Έχοντας αρκετά δεδομένα αξονικής τομογραφίας του προσώπου από υγιείς και ασθενείς με ιγμορίτιδα, θα μπορούμε να δημιουργήσουμε ένα σύστημα που θα μπορεί να κάνει τη διάγνωση αυτόνομα με σχεδόν τέλεια ακρίβεια. Το σύστημα, "βλέποντας" τις εικόνες των δύο κατηγοριών (υγιείς-ιγμορίτιδα), μπορεί σιγά σιγά, μέσω της βελτιστοποίησης των παραμέτρων και της μείωσης της συνάρτησης κόστους κατά τη διάρκεια της εκπαίδευσης, να "καταλάβει" από τα μοτίβα των δεδομένων ποια είναι τα χαρακτηριστικά της ιγμορίτιδας και να τη διαγιγνώσκει με επιτυχία.

Έλεγχος οστών: Με τη χρήση δεδομένων υγιών οστών και οστών με σπάσιμο, ράγισμα ή γενικότερα κάποιο πρόβλημα, θα μπορούμε να εκπαιδεύσουμε έναν αλγόριθμο μηχανικής όρασης για τη διάγνωση του προβλήματος.

Επιπλοκές γέννας: Έχοντας αρκετά δεδομένα υπερήχων κοιλιάς από υγιείς ή από δείγματα που εμφανίζουν επιπλοκές στη γέννα, θα μπορούμε να εκπαιδεύσουμε ένα σύστημα μηχανικής όρασης να προβλέπει αν η γέννα θα είναι ομαλή ή θα υπάρξουν επιπλοκές. Επίσης, είναι αρκετά σημαντικό διότι τα συστήματα θα μπορούν να καταλάβουν μοτίβα στα δεδομένα για τη μελλοντική εξέλιξη της γέννας. Δηλαδή, να μπορούν να διαγνώσουν μοτίβα που μπορεί να οδηγήσουν σε επιπλοκές στο μέλλον, ενώ δεν έχουν εμφανιστεί ακόμα.

Έλεγχος βιωσιμότητας οργάνων: Με τη χρήση δεδομένων υπερήχων, αξονικών τομογραφιών και μαγνητικών τομογραφιών οργάνων, τα συστήματα θα μπορούν να διαγιγνώσκουν ασθένειες ή ανωμαλίες στα όργανα. Παραδείγματα αυτών μπορεί να είναι: ασθένειες ή ανωμαλίες στην παρωτίδα, στον εγκέφαλο, στα νεφρά, στους πνεύμονες, στο στομάχι, στα μάτια, στο παχύ και στο λεπτό έντερο, στο συκώτι, στο πάγκρεας, στη σπλήνα, στον θυρεοειδή αδένα, στον προστάτη, στη μήτρα, στους όρχεις, κ.ά. Τροφοδοτώντας το σύστημα με δεδομένα υγιών δειγμάτων και ασθενών για κάθε όργανο, θα μπορούμε να αυτοματοποιήσουμε έναν μεγάλο αριθμό διαγνωστικών εργασιών.

Για τις **διαγνώσεις ασθενειών** με μεθόδους μηχανικής μάθησης, θα μπορούμε να διαγιγνώσκουμε ασθένειες, ίώσεις και χρόνια νοσήματα, όπου η διαδικασία της διάγνωσης δεν έχει να κάνει με την όραση αλλά με την κατανόηση τιμών ιατρικών αποτελεσμάτων, όπως οι εξετάσεις αίματος. Έχοντας ιατρικές εξετάσεις από υγιή ή ασθενή δείγματα, θα μπορούμε για κάθε ασθένεια ή ίωση να δημιουργήσουμε ένα σύστημα που θα ξεχωρίζει το δείγμα σε υγιές ή ασθενές. **Παράδειγμα χρήσης μηχανικής μάθησης για διάγνωση:**

Διαβήτης: Τροφοδοτώντας ένα σύστημα με δεδομένα αιματολογικών εξετάσεων ανθρώπων με διαβήτη και υγιών δειγμάτων, θα μπορούμε να εκπαιδεύσουμε έναν αλγόριθμο μάθησης με επίβλεψη για τη διάγνωση του διαβήτη. Κατά τη διάρκεια της εκπαίδευσης, καθώς ο αλγόριθμος προσπαθεί να βελτιστοποιήσει την απόδοσή του, αρχίζει να "καταλαβαίνει" ποιες τιμές έχουν περισσότερο "βάρος" στην "εξίσωση" και τα μοτίβα τιμών στα πεδία που δημιουργούν τον διαβήτη. Π.χ., το ζάχαρο: Ένας αλγόριθμος μηχανικής μάθησης θα έβλεπε την τιμή ζαχάρου και, καθώς έκανε υποθέσεις, θα

Χρήση Τεχνητής Νοημοσύνης στην Ιατρική - Αντώνης Κονι

"καταλάβαινε" ότι η υψηλή τιμή του ζαχάρου στο αίμα είναι ένας από τους "δείκτες" που πρέπει να προσέχει για να διαγιγνώσκει με επιτυχία τα δείγματα.

Προκειμένου να αξιολογηθεί η χρήση αλγορίθμων μηχανικής μάθησης και μηχανικής όρασης για τη διάγνωση ασθενειών, πραγματοποιήθηκαν πειράματα για την ανάπτυξη διαγνωστικών συστημάτων για διάφορες παθήσεις, με τη χρήση κατάλληλων ιατρικών δεδομένων.

4. Χρήση transfer learning και μηχανικής μάθησης για τη δημιουργία διαγνωστικών συστημάτων.

Για την ανάπτυξη των διαγνωστικών συστημάτων που παρουσιάζονται παρακάτω, εξετάστηκαν οι ακόλουθοι αλγόριθμοι μηχανικής μάθησης: HistGradientBoosting, Random Forest, Logistic Regression, K-Neighbors, XGBoost (Extreme Gradient Boosting) και Support Vector Machines (SVM). Επιπλέον, χρησιμοποιήθηκαν μοντέλα νευρωνικών δικτύων μηχανικής όρασης βασισμένα στη μεταφορά μάθησης (transfer learning), και συγκεκριμένα: EfficientNet B1, EfficientNet B2, EfficientNet B3, EfficientNet B4, EfficientNet B5, EfficientNet B6, EfficientNet B7, VGG 16, VGG 19, ResNet 50, DenseNet201, InceptionV3, και Xception. Οι αποδόσεις των αλγορίθμων αξιολογήθηκαν με τη χρήση των ακόλουθων δεικτών : Ακρίβεια (Precision), Ανάκληση (Recall), F1 Score και AUC ROC.

Εφαρμογή 4.1 Διάγνωση καρκίνου στον πνεύμονα


Διάγνωση καρκίνου του πνεύμονα με χρήση δεδομένων αξονικής τομογραφίας. Για τη δημιουργία του διαγνωστικού προγράμματος χρησιμοποιήθηκαν τα δεδομένα από τους παρακάτω φορείς : **[8]** , **[9]** , **[10]**

Τα δεδομένα που χρησιμοποιούνται είναι εικόνες αξονικής τομογραφίας του θώρακα.

Ο αριθμός εικόνων είναι: 1097

Κλάσεις προς κατάταξη: 3

- Καλοήθης καρκίνος (120 εικονες)
- Κακοήθης καρκίνος (561 εικονες)
- Υγιες Πνευμονας (416 εικονες)



Εικόνα 1: Δείγμα εικόνας Αξονικής πνεύμονα.

Πηγή : <https://www.kaggle.com/datasets/hamdallak/the-iqothnccd-lung-cancer-dataset>

Το 80% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 20% για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων. Ακολούθως παρατίθενται οι αποδόσεις των μοντέλων:

4.1 Αποτελέσματα Εφαρμογής

Πίνακας 1: Πίνακας αποτελεσμάτων αλγορίθμων Transfer Learning διάγνωσης καρκίνου στον πνεύμονα.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.9461	0.9792	0.9612	0.9988
EfficientNetB2	0.9187	0.9723	0.9407	0.9984
EfficientNetB3	0.9737	0.98	0.976	0.9959
EfficientNetB4	0.9808	0.9727	0.9762	0.9989
EfficientNetB5	0.8646	0.943	0.8906	0.9943
EfficientNetB6	0.8739	0.9328	0.897	0.99
EfficientNetB7	0.8757	0.9385	0.8998	0.9898
VGG19	0.7711	0.7631	0.7636	0.973
VGG16	0.8447	0.9041	0.8628	0.9907
RESNET-50	0.7099	0.6381	0.6291	0.9267
DenseNet201	0.9729	0.9873	0.9798	0.9981
InceptionV3	0.9266	0.945	0.9352	0.9969
Xception	0.9461	0.9792	0.9612	0.9984

Η αρχιτεκτονική Transfer Learning που επέφερε τη βέλτιστη αποδοτικότητα είναι η DenseNet 201.

Χαρακτηριστικά μοντέλου: Χρήση Adam βελτιστοποιητή με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για κάθε κλάση.

Πίνακας 2: Πίνακας αποτελεσμάτων αρχιτεκτονικής Densnet201 αποδοτικότητας διάγνωσης καρκίνου του πνεύμονα.

```

DenseNet Metrics
+-----+-----+-----+-----+
| Class | Precision | Recall | F1 Score | AUC |
+-----+-----+-----+-----+
| Benign | 0.9545454545454546 | 1.0 | 0.9767441860465117 | 1.0 |
| Malignant | 1.0 | 0.9743589743589743 | 0.9870129870129869 | 0.9993361546759605 |
| Normal | 0.9642857142857143 | 0.9878048780487805 | 0.9759036144578312 | 0.9950512540603747 |
+-----+-----+-----+-----+
    
```


4.2 Εφαρμογή : Διάγνωση Καρκίνου του παχέος εντέρου


Διάγνωση καρκίνου του παχέος εντέρου με τη χρήση Ιστοπαθολογικών εικόνων. Για τη δημιουργία του διαγνωστικού προγράμματος χρησιμοποιήθηκαν τα δεδομένα από τους παρακάτω φορείς. **[11]** , **[12]** , **[13]**

Τα δεδομένα είναι ιστοπαθολογικές εικόνες του παχέος εντέρου. Ο αριθμός εικόνων είναι: 10.000.

Κλάσεις προς κατάταξη:2

Δείγμα με καρκίνο παχέος εντέρου (5.000 εικόνες)

Υγιές Δείγμα (5.000 εικόνες)



Εικόνα 2: Δείγμα εικόνας : Ιστοπαθολογική εικόνα παχέου εντέρου.

Πηγή : <https://www.kaggle.com/datasets/andrewmvd/lung-and-colon-cancer-histopathological-images>

Οι εικόνες είναι διαστάσεων (768 x 768) pixel και μεγέθους 89,8 KB. Για τη δημιουργία του συστήματος διαγνώσεων χρησιμοποιήθηκε το 20% του συνόλου των δεδομένων (2000) ισάριθμα διαμερισμένα στις παραπάνω κλάσεις. Το συνολικό μέγεθος της βάσης δεδομένων που χρησιμοποιήθηκαν είναι 177,7 MB. Πριν τη χρήση των εικόνων στους αλγορίθμους γίνονται οι εξής παραμετροποιήσεις για τη βέλτιστη απόδοση των αλγορίθμων αλλά και για λόγους εξοικονόμησης υπολογιστικής ισχύος:

- Διάμετρος εικόνας: (224, 224)
- Κανονικοποίηση τιμών για κάθε pixel με εύρος τιμών από 0 έως 1.

Το 80% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 20% για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων.

Παρακάτω αναφέρονται οι αποδοτικότητες των μοντέλων:

4.2 Αποτελέσματα Εφαρμογής

Πίνακας 3: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning Διάγνωσης καρκίνου του παχέου εντέρου.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	1.0	1.0	1.0	1.0
EfficientNetB2	0.9921	0.9921	0.9921	0.9921
EfficientNetB3	0.9901	0.9901	0.9901	0.9901
EfficientNetB4	1.0	1.0	1.0	1.0
EfficientNetB5	0.9921	0.9921	0.9921	0.9921
EfficientNetB6	0.9951	0.9950	0.9951	0.9950
EfficientNetB7	1.0	1.0	1.0	1.0
VGG19	1.0	1.0	1.0	1.0
VGG16	0.9921	0.9921	0.9921	0.9921
RESNET-50	0,8235	0,8235	0,8235	0,8235
DenseNet201	1.0	1.0	1.0	1.0
InceptionV3	0.9901	0.9901	0.9901	0.9901
Xception	0.9843	0.9843	0.9843	0.9843

Οι αρχιτεκτονικές EfficientNet B1, EfficientNet B4, EfficientNet B7, VGG19 και DenseNet201 επέφεραν τέλεια απόδοση. Χαρακτηριστικά μοντέλων: Χρήση Adam βελτιστοποιητή με παραμέτρους : learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size= 126, Επαναλήψεις= 100

4.3 Εφαρμογή : Διάγνωση Καρκίνου του πνεύμονα


Διάγνωση καρκίνου του πνεύμονα με τη χρήση Ιστοπαθολογικών εικόνων. Για τη δημιουργία του

διαγνωστικού προγράμματος χρησιμοποιήθηκαν τα δεδομένα από τους παρακάτω φορείς. [\[11\]](#) , [\[12\]](#) , [\[13\]](#)

Τα δεδομένα που χρησιμοποιούνται είναι ιστοπαθολογικές εικόνες του πνεύμονα. Ο αριθμός εικόνων είναι: 15.000

Κλασεις προς καταταξη : 3

- Ακανθοκυτταρικό καρκίνωμα πνεύμονα (5 χιλ εικονες)
- Αδενοκαρκίνωμα πνεύμονα (5 χιλ εικονες)
- Καλοήθης ιστός του πνεύμονα (5 χιλ εικονες)



Εικόνα 3: Δείγμα ιστοπαθολογικής εικόνας πνεύμονα.

Πηγή : <https://www.kaggle.com/datasets/andrewmvd/lung-and-colon-cancer-histopathological-images>

Οι εικόνες είναι διαστάσεων (768 x 768) pixel και μεγέθους 78,8 KB. Για τη δημιουργία του συστήματος διάγνωσης χρησιμοποιήθηκαν 1800 δείγματα ισάριθμα διαμερισμένα στις παραπάνω κλάσεις. Το συνολικό μέγεθος της βάσης δεδομένων που χρησιμοποιήθηκαν είναι 120,4 MB. Πριν τη

χρήση των εικόνων στους αλγορίθμους γίνονται οι εξής παραμετροποιήσεις για τη βέλτιστη απόδοση των αλγορίθμων αλλά και για λόγους εξοικονόμησης υπολογιστικής ισχύος:

- Διάμετρος εικόνας: (224, 224)
- Κανονικοποίηση τιμών για κάθε pixel με εύρος τιμών από 0 έως 1.

Το 80% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 20% για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων.

Παρακάτω αναγράφονται οι αποδοτικότητες των μοντέλων:

4.3 Αποτελέσματα Εφαρμογής

Πίνακας 4: Πίνακας αποτελεσμάτων αλγορίθμων *Transfer Learning* διάγνωσης καρκίνου του πνεύμονα.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.8102	0.7964	0.7845	0.9571
EfficientNetB2	0.8497	0.8281	0.829	0.9664
EfficientNetB3	0.8876	0.8896	0.8882	0.97
EfficientNetB4	0.9258	0.9055	0.9108	0.9852
EfficientNetB5	0.8827	0.8792	0.8801	0.9722
EfficientNetB6	0.8995	0.8999	0.8989	0.9833
EfficientNetB7	0.8603	0.8552	0.8543	0.9681
VGG19	0.9206	0.8885	0.8995	0.9899
VGG16	0.8448	0.8282	0.8121	0.9662
RESNET-50	0.6209	0.5736	0.5501	0.8248
DenseNet201	0.8376	0.8059	0.8047	0.969
InceptionV3	0.9189	0.8817	0.8885	0.9798
Xception	0.9458	0.939	0.9416	0.9947

Η αρχιτεκτονική *Transfer Learning* που επέφερε την βέλτιστη αποδοτικότητα είναι η Xception. Χαρακτηριστικά μοντέλου: Χρήση του βελτιστοποιητή Adam με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100,

Παρακάτω αναγράφονται οι αποδοτικότητες του αλγορίθμου για κάθε κλάση.

Πίνακας 5: Πίνακας αποτελεσμάτων αρχιτεκτονικής Xception αποδοτικότητα διάγνωσης καρκίνου του πνεύμονα ανά κλάση ξεχωριστά.

Xception Metrics:

Class	Precision	Recall	F1 Score	AUC
lung_aca	0.9285714285714286	0.8666666666666667	0.896551724137931	0.9893279297534617
lung_n	1.0	0.9782608695652174	0.989010989010989	0.999970898085094
lung_scc	0.9090909090909091	0.9722222222222222	0.9395973154362416	0.9949988568815729

4.4 Εφαρμογή : Διάγνωση καρκίνου στον εγκέφαλο


Διάγνωση καρκίνου στον εγκέφαλο με χρήση δεδομένων αξονικής τομογραφίας εγκεφάλου. Για τη δημιουργία του διαγνωστικού προγράμματος χρησιμοποιήθηκαν τα δεδομένα από τους παρακάτω φορείς. [14], [15], [16], [17], [18], [19]

Τα δεδομένα που χρησιμοποιούνται είναι αξονικές τομογραφίες εγκεφάλου.

Ο αριθμός εικόνων είναι: 2870.

Κλάσεις προς κατάταξη: 4

- όγκος γλοιώματος (826 εικονες)
- όγκος μηνιγγίωμα (822 εικονες)
- Υγιες Δειγμα (395 εικονες)
- βλεννογόνο ογκος (827 εικονες)



Εικόνα 4: Δείγμα εικόνας Αξονικής τομογραφίας εγκεφάλου.

Πηγή: <https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification>.

Οι εικόνες είναι διαστάσεων (512 x 512) pixel και μεγέθους 21,1 KB. Το συνολικό μέγεθος της βάσης δεδομένων που χρησιμοποιήθηκε είναι 79,8 MB. Πριν τη χρήση των εικόνων στους αλγορίθμους γίνονται οι ακόλουθες παραμετροποιήσεις:

- Διάμετρος εικόνας: (128,128)
- Κανονικοποίηση τιμών για κάθε pixel με εύρος τιμών από 0 έως 1.

Το 80% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 20% για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων. Παρακάτω αναγράφονται οι αποδόσεις των μοντέλων:

4.4 Αποτελέσματα Εφαρμογής

Πίνακας 6: Πίνακας αποτελεσμάτων αλγορίθμων *Transfer Learning* διάγνωσης καρκίνου του εγκέφαλου.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.9584	0.95817	0.9579	0.9933
EfficientNetB2	0.9368	0.93	0.9324	0.9929
EfficientNetB3	0.9538	0.9536	0.9536	0.9949
EfficientNetB4	0.958	0.9579	0.9576	0.9937
EfficientNetB5	0.9416	0.9409	0.9527	0.9918
EfficientNetB6	0.9342	0.9233	0.9281	0.9917
EfficientNetB7	0.9051	0.8812	0.8877	0.9821
VGG19	0.8579	0.8571	0.8544	0.9759
VGG16	0.9264	0.9289	0.9274	0.9876
RESNET-50	0.7106	0.7166	0.7054	0.8912
DenseNet201	0.9578	0.9611	0.9593	0.993
InceptionV3	0.94315	0.9403	0.9415	0.9926
Xception	0.9599	0.9603	0.96	0.9928

Η αρχιτεκτονική *Transfer Learning* που επέφερε τη βέλτιστη αποδοτικότητα είναι η *Xception*. Χαρακτηριστικά μοντέλου: Χρήση του βελτιστοποιητή *Adam* με παραμέτρους *learning rate* = 0.002, *beta 1* = 0.9, *beta 2* = 0.999, *epsilon* = $1e-8$, Μέγεθος δέσμης (*batch size*) = 126, Επαναλήψεις = 100

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για κάθε κλάση.

Πίνακας 7: Πίνακας αποτελεσμάτων αρχιτεκτονικής Xception αποδοτικότητα διάγνωσης καρκίνου στον εγκέφαλο ανά κλάση ξεχωριστά.

Xception Metrics:

Class	Precision	Recall	F1 Score	AUC
glioma_tumor	0.9631901840490797	0.9691358024691358	0.966153846153846	0.9972581805106077
meningioma_tumor	0.9182389937106918	0.948051948051948	0.9329873482428114	0.9855905998763141
no_tumor	0.9767441860465116	0.9767441860465116	0.9767441860465116	0.9952821197102555
pituitary_tumor	0.9819277108433735	0.9476744186046512	0.9644970414201183	0.9936509313895638

4.5 Εφαρμογή : Διάγνωση καρκίνου στο στήθος


Διάγνωση καρκίνου στο στήθος χρησιμοποιώντας εικόνες υπερηχογραφίας του στήθους. Για τη δημιουργία του διαγνωστικού συστήματος χρησιμοποιήθηκαν τα δεδομένα από τους παρακάτω φορείς. [\[20\]](#),[\[21\]](#)

Τα δεδομένα που χρησιμοποιούνται είναι εικόνες υπερηχογραφίας του στήθους.

Ο αριθμός εικόνων είναι: 1578.

Κλάσεις προς κατάταξη: 3

- Καλοήθης καρκίνος (891 εικονες)
- Κακοήθης καρκίνος (421 εικονες)
- Υγιες Πνευμονας (266 εικονες)



Εικόνα 5: Δείγμα εικόνας υπέρηχου στήθους

Πηγή :

<https://www.kaggle.com/datasets/aryashah2k/breast-ultrasound-images-dataset>

Οι εικόνες είναι διαστάσεων (562 x 471) pixel και μεγέθους 334,3 KB. Το συνολικό μέγεθος της βάσης δεδομένων που χρησιμοποιήθηκε είναι 266,3 MB. Πριν τη χρήση των εικόνων στους αλγορίθμους γίνονται οι εξής παραμετροποιήσεις στις εικόνες:

- Διάμετρος εικόνας: (128, 128)
- Κανονικοποίηση τιμών για κάθε pixel με εύρος τιμών από 0 έως 1.

Το 80% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 20% για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων.

Παρακάτω αναγράφονται οι αποδόσεις των μοντέλων:

4.5 Αποτελέσματα Εφαρμογής

Πίνακας 8: Πίνακας αποτελεσμάτων αλγορίθμων *Transfer Learning* διάγνωσης καρκίνου στο στήθος.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.9578	0.9196	0.9373	0.988
EfficientNetB2	0.9427	0.9232	0.9326	0.9861
EfficientNetB3	0.9088	0.9263	0.9166	0.9904
EfficientNetB4	0.9409	0.9361	0.9382	0.9894
EfficientNetB5	0.9473	0.9481	0.9475	0.9847
EfficientNetB6	0.8817	0.9058	0.8923	0.9798
EfficientNetB7	0.8712	0.902	0.8639	0.9723
VGG19	0.8742	0.9122	0.8911	0.9794
VGG16	0.7825	0.875	0.8147	0.9783
RESNET-50	0.889	0.7439	0.7883	0.9364
DenseNet201	0.9793	0.9354	0.9556	0.9921
InceptionV3	0.9724	0.9405	0.9329	0.9866
Xception	0.9653	0.9167	0.9389	0.9848

Η αρχιτεκτονική *Transfer Learning* που επέφερε τη βέλτιστη αποδοτικότητα είναι η DenseNet 201.

Χαρακτηριστικά μοντέλου:

Χρήση του βελτιστοποιητή Adam με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = $1e-8$. ,Μέγεθος πακέτου (batch size) = 126. ,Επαναλήψεις = 100.

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για κάθε κλάση.

Πίνακας 9: Πίνακας αποτελεσμάτων αρχιτεκτονικής DenseNet201 αποδοτικότητα διάγνωσης καρκίνου στο στήθος ανά κλάση ξεχωριστά.

DenseNet Metrics				
Class	Precision	Recall	F1 Score	AUC
benign	0.9521531100478469	0.995	0.9731051344743276	0.9918965517241379
malignant	0.9859154929577465	0.9333333333333333	0.9589041095890412	0.9875518672199171
normal	1.0	0.8780487804878049	0.9350649350649352	0.9970731707317073

4.6 Εφαρμογή :Διάγνωση Πνευμονίας Διάγνωση πνευμονίας χρησιμοποιώντας X-ray Scans του θώρακα.

Για τη δημιουργία του διαγνωστικού συστήματος χρησιμοποιήθηκαν δεδομένα από τους παρακάτω φορείς [22],[23],[24]

Τα δεδομένα που χρησιμοποιούνται είναι 3448 εικόνες. Οι κλάσεις προς καταταξη είναι:

- Πνευμονία (2107 εικόνες)
- Υγιείς Πνεύμονες (1341 εικόνες)



Εικόνα 6: Δείγμα εικόνας αξονικής πνεύμονα.

Πηγή :

<https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>

Οι εικόνες είναι διαστάσεων 2090 x 1858 pixels και μεγέθους 870,8 KB. Το συνολικό μέγεθος της βάσης δεδομένων που χρησιμοποιήθηκε είναι 1 GB. Πριν τη χρήση των εικόνων γίνονται οι εξής παραμετροποιήσεις:

- Διάμετρος εικόνας: (128,128)
- Κανονικοποίηση τιμών για κάθε pixel με εύρος τιμών από 0 έως 1.

Το 80% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 20% για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων

Παρακάτω αναγράφονται οι αποδόσεις των μοντέλων:

4.6 Αποτελέσματα Εφαρμογής

Πίνακας 10: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης πνευμονίας

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.9492	0.9492	0.9492	0.9492
EfficientNetB2	0.9936	0.9335	0.9336	0.9335
EfficientNetB3	0.9687	0.9687	0.9687	0.9687
EfficientNetB4	0.9375	0.9375	0.9375	0.9375
EfficientNetB5	0.9219	0.9218	0.9218	0.9218
EfficientNetB6	0.9287	0.9285	0.9285	0.9285
EfficientNetB7	0.9257	0.9257	0.9257	0.9257
VGG19	0.9453	0.9453	0.9453	0.9453
VGG16	0.9453	0.9453	0.9453	0.9453
RESNET-50	0.8984	0.8984	0.8984	0.8984
DenseNet201	0.9531	0.9531	0.9531	0.9531
InceptionV3	0.9591	0.9591	0.9591	0.9591
Xception	0.9257	0.9257	0.9257	0.9257

Η αρχιτεκτονική Transfer Learning που επεφερε την βελτιστη αποδοτικότητα είναι η Inception V3. Χαρακτηριστικά μοντέλου : Χρήση Adam Βελτιστοποιήτη με παραμετρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναληψεις = 100

Παρακατω Αναγραφονται οι αποδοσεις του αλγοριθμου για την καθε κλαση.

Πίνακας 11: Πίνακας αποτελεσμάτων αρχιτεκτονικής InceptionV3 αποδοτικότητα διάγνωσης πνευμονίας ανά κλάση ξεχωριστά.

Inception Metrics:

Class	Precision	Recall	F1 Score	AUC
NORMAL	0.9591836734693877	0.9591836734693877	0.9591836734693877	0.9591836734693877
PNEUMONIA	0.9591836734693877	0.9591836734693877	0.9591836734693877	0.9591836734693877

4.7 Εφαρμογή : Κατάταξη γονιδίων που εκφράζουν καρκίνο στον εγκέφαλο

Η Βάση Δεδομένων Μικροσωματιδίων (**CuMiDa**), είναι ένας αποθηκευτικός χώρος που περιλαμβάνει 78 επιλεγμένα σύνολα δεδομένων μικροσωματιδίων καρκίνου, εκτενώς συντηρημένα από **30.000** μελέτες από το Gene Expression Omnibus (GEO).

Για την δημιουργία του συστήματος χρησιμοποιήθηκαν δεδομένα από τους παρακάτω φορείς [\[25\],\[26\],\[27\],\[28\],\[29\],\[30\]](#)

Τα δεδομένα που χρησιμοποιούνται είναι ένα αρχείο CSV που περιέχει τα επίπεδα έκφρασης καρκίνο στον εγκέφαλο για 54.676 γονίδια (στήλες) από 130 δείγματα (γραμμές). Υπάρχουν 4 διαφορετικοί τύποι καρκίνου του εγκεφάλου (συν ένα υγιές ιστό).

Κλασεις προς καταταξη : 5

- επενδυμώμα (46)
- γλιοβλάστωμα (34)
- μεδουλοβλαστώμα (22)
- πιλοκυτικό αστροκύτταρομα
- υγιες (13)

Επεξεργασία δεδομένων:

Πραγματοποιείται κανονικοποίηση των δεδομένων με εύρος τιμών 0 έως 1 χρησιμοποιώντας την κανονικοποίηση MinMaxScaler. Το 70% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 30% για την εξέταση του αλγορίθμου και την διεξαγωγή μετρήσεων.

4.7 Αποτελέσματα Εφαρμογής

Παρακάτω αναγράφεται το σύστημα με τις βέλτιστες αποδόσεις και οι εκάστοτε μετρήσεις των αποδόσεων. Ο αλγόριθμος μηχανικής μάθησης που επέφερε την βέλτιστη αποδοτικότητα είναι ο XGBoost (Extreme Gradient Boosting). Υπερ-παράμετροι αλγορίθμου:

n_estimators=50, learning_rate=0.001, max_depth=3, min_child_weight=1, gamma=1, subsample=1, colsample_bytree=1, reg_alpha=0, reg_lambda=0, scale_pos_weight=1

Πίνακας 12: Πίνακας αποτελεσμάτων κατάταξης γονιδίων που εκφράζουν καρκίνο στον εγκέφαλο.

XGBClassifier Metrics:

Metric	Score
Training Accuracy	1.0
Testing Accuracy	0.9487179487179487
Precision	0.9572649572649573
Recall	0.9487179487179487
F1 Score	0.9476301476301475
ROC-AUC Score	0.9896759298872758

4.8 Εφαρμογή Πρόβλεψη εγκεφαλικού

Για την δημιουργία του συστήματος χρησιμοποιήθηκαν δεδομένα από τους παρακάτω φορείς: [31], [32], [33]. Τα δεδομένα που χρησιμοποιούνται είναι ένα αρχείο CSV που περιέχει 5110 δείγματα (γραμμές) και 8 στήλες με τα παρακάτω χαρακτηριστικά:

1. **gender**: Φύλο του ασθενούς ("Ανδρας", "Γυναίκα" ή "Άλλο").
2. **age**: Ηλικία του ασθενούς.
3. **hypertension**: 0 αν ο ασθενής δεν έχει υπέρταση, 1 αν ο ασθενής έχει υπέρταση.
4. **heart disease**: 0 αν ο ασθενής δεν έχει καρδιακή νόσο, 1 αν ο ασθενής έχει καρδιακή νόσο.
5. **avg glucose level**: Μέση συγκέντρωση γλυκόζης στο αίμα.
6. **bmi**: Δείκτης μάζας σώματος.
7. **smoking status**: "Πρώην Καπνιστής", "Ποτέ Δεν Κάπνισε", "Καπνίζει" ή "Άγνωστο".

8. stroke: 1 αν ο ασθενής είχε εγκεφαλικό επεισόδιο, 0 αν δεν είχε.

Επεξεργασία δεδομένων:

Πραγματοποιείται κανονικοποίηση των δεδομένων με εύρος τιμών 0 έως 1, χρησιμοποιώντας την κανονικοποίηση MinMaxScaler. Το 70% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου, ενώ το υπόλοιπο 30% χρησιμοποιείται για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων.

Παρακάτω αναγράφεται το σύστημα με τις βέλτιστες αποδόσεις και οι εκάστοτε μετρήσεις των αποδόσεων.

4.8 Αποτελέσματα: Εφαρμογής

Ο αλγόριθμος μηχανικής μάθησης που επέφερε την βέλτιστη αποδοτικότητα είναι ο Random Forest με n-estimators=1000.

Πινάκας 13: Πινάκας αποτελεσμάτων πρόβλεψης εγκεφαλικού

Random Forest Classifier Metrics With Normalized Data :

Metric	Value
Train Accuracy	1.0
Test Accuracy	0.8
AUC (Test)	0.8609035326086957
Precision (Test)	0.7142857142857143
Recall (Test)	0.8695652173913043
F1 Score(Test)	0.7843137254901961

4.9 Εφαρμογή : Διάγνωση οφθαλμικών παθήσεων

Διάγνωση οφθαλμικών παθήσεων με χρήση οφθαλμικών εικόνων. Για τη δημιουργία των διαγνωστικών συστημάτων χρησιμοποιήθηκαν δεδομένα από τους παρακάτω φορείς:[\[34\]](#)

Ο αριθμός εικόνων είναι : 4960

Κλάσεις προς κατάταξη : 8

- Κανονική όραση(700 εικονες)
- Καταρράκτης (594 εικονες)
- Σακχαρώδης διαβήτης (1818 εικονες)
- Γλαύκωμα (610)

- Υπέρταση (374)
- Μυωπία (479)
- Προβλήματα ηλικίας (551)
- Άλλο (324)



Εικόνα 7: Δείγμα Οφθαλμικής εικόνας
Πηγή: <https://www.kaggle.com/datasets/andrewmvd/ocular-disease-recognition-odir5k>

Οι εικόνες είναι διαμέτρων (512 x 512) pixel και μεγέθους 42,6 KB, το συνολικό μέγεθος της βάσης δεδομένων που χρησιμοποιήθηκαν είναι 397,1 MB. Πριν τη χρήση των εικόνων στους αλγορίθμους, γίνονται οι εξής παραμετροποιήσεις στις εικόνες:

- Διάμετρος εικόνας: (224, 224)
- Κανονικοποίηση τιμών για κάθε pixel με εύρος τιμών από 0 έως 1.

Το 85% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 15% για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων. Τα δεδομένα χωρίστηκαν κατάλληλα ώστε να πραγματοποιηθεί δυαδική ταξινόμηση για τη διάγνωση της κάθε ασθένειας μεμονωμένα, ώστε να πάρουμε βέλτιστα αποτελέσματα. Παρακάτω αναγράφονται οι αποδόσεις των αλγορίθμων για τη δυαδική ταξινόμηση για κάθε μία από τις παραπάνω κλάσεις.

4.9.1 Εφαρμογή: Διάγνωση Καταρράκτη

Πίνακας 14: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης καταρράκτη.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.255	0.5	0.335	0.5
EfficientNetB2	0.505	0.499	0.344	0.5
EfficientNetB3	0.255	0.5	0.335	0.5
EfficientNetB4	0.435	0.485	0.355	0.49
EfficientNetB5	0.385	0.45	0.36	0.45
EfficientNetB6	0.5	0.495	0.385	0.5
EfficientNetB7	0.49	0.49	0.49	0.49
VGG19	0.96	0.96	0.963	0.963
VGG16	0.976	0.976	0.976	0.976
RESNET-50	0.972	0.972	0.972	0.972
DenseNet201	0.92	0.9	0.9	0.9
InceptionV3	0.875	0.875	0.875	0.875
Xception	0.917	0.917	0.917	0.917

Η αρχιτεκτονική Transfer Learning που επέφερε την βέλτιστη αποδοτικότητα είναι η VGG16. Χαρακτηριστικά μοντέλου: Χρήση Adam βελτιστοποίησης με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100.

Παρακατω Αναγραφονται οι αποδόσεις του αλγόριθμου για την κάθε κλάση

Πίνακας 16: Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50 αποδοτικότητα διάγνωσης καταρράκτη ανά κλάση ξεχωριστά.

Resnet50 Metrics:

Class	Precision	Recall	F1 Score	AUC
Normal	0.963302752293578	0.9813084112149533	0.9722222222222222	0.9726361875894586
Cataract	0.981651376146789	0.963963963963964	0.9727272727272728	0.9726361875894586

4.9.2 Εφαρμογή : Διάγνωση Σακχαρώδη διαβήτη

Πίνακας 17: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης Σακχαρώδη διαβήτη

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.535	0.527	0.455	0.527
EfficientNetB2	0.28	0.475	0.35	0.476
EfficientNetB3	0.535	0.505	0.345	0.507
EfficientNetB4	0.62	0.61	0.61	0.612
EfficientNetB5	0.52	0.52	0.52	0.523
EfficientNetB6	0.515	0.505	0.41	0.508
EfficientNetB7	0.545	0.53	0.5	0.532
VGG19	0.83	0.84	0.83	0.844
VGG16	0.86	0.86	0.86	0.869
RESNET-50	0.87	0.87	0.87	0.87
DenseNet201	0.765	0.74	0.72	0.752
InceptionV3	0.71	0.71	0.71	0.716
Xception	0.775	0.775	0.775	0.775

Η αρχιτεκτονική Transfer Learning που επέφερε την βέλτιστη αποδοτικότητα είναι η VGG16. Χαρακτηριστικά μοντέλου: Χρήση Adam βελτιστοποίησης με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100.

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για την κάθε κλάση.

Πίνακας 18: Πίνακας αποτελεσμάτων αρχιτεκτονικής VGG16 αποδοτικότητα διάγνωσης Σακχαρώδη διαβήτη ανά κλάση ξεχωριστά.

VGG16 Metrics:

Class	Precision	Recall	F1 Score	AUC
Normal	0.7692307692307693	0.6122448979591837	0.6818181818181818	0.7676609105180534
Diabetes	0.8503937007874016	0.9230769230769231	0.8852459016393444	0.7676609105180534

4.9.3 Εφαρμογή : Διάγνωση Γλαυκώματος

Πίνακας 19: Πίνακας αποτελεσμάτων αλγορίθμων Transfer Learning διάγνωσης γλαυκώματος

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.535	0.527	0.455	0.527
EfficientNetB2	0.28	0.475	0.35	0.476
EfficientNetB3	0.535	0.505	0.345	0.507
EfficientNetB4	0.62	0.61	0.61	0.612
EfficientNetB5	0.52	0.52	0.52	0.523
EfficientNetB6	0.515	0.505	0.41	0.508
EfficientNetB7	0.545	0.53	0.5	0.532
VGG19	0.83	0.84	0.83	0.844
VGG16	0.86	0.86	0.86	0.869
RESNET-50	0.87	0.87	0.87	0.87
DenseNet201	0.765	0.74	0.72	0.752
InceptionV3	0.71	0.71	0.71	0.716
Xception	0.775	0.775	0.775	0.775

Η αρχιτεκτονική Transfer Learning που επεφερε την βελτιστη αποδοτικότητα είναι η RESNET50 .Χαρακτηριστικά μοντελου :Χρήση Adam Βελτιστοποιήτ με παραμετρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8 ,Batch size = 126 ,Επαναληψεις = 100Παρακατω Αναγραφονται οι αποδοσεις του αλγοριθμου για την καθε κλαση.

Πίνακας 20: Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50 αποδοτικότητα διάγνωσης γλαυκώματος ανά κλάση ξεχωριστά.

Resnet50 Metrics:

Class	Precision	Recall	F1 Score	AUC
Normal	0.9393939393939394	0.8266666666666667	0.8794326241134751	0.8776190476190476
Glaucoma	0.8	0.9285714285714286	0.859504132231405	0.8776190476190476

Εξετάστηκε η απόδοση με την χρήση των παρακάτω βελτιστοποιητών.

Πίνακας 21: : Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50 χρήση διαφορετικών βελτιστοποιητών διάγνωση γλαυκώματος.

	Precision	Recall	F1 Score	AUC
Proximal Adagrad	0.865	0.87	0.86	0.87
Lamb	0.895	0.915	0.905	0.915
Rectified Adam	0.875	0.875	0.873	0.879
Adamax	0.865	0.87	0.86	0.87
Nadam	0.885	0.88	0.88	0.88
RmsProp	0.825	0.835	0.825	0.837
LookAhead	0.795	0.8	0.795	0.801

4.9.4 Αποτελέσματα Εφαρμογής Διάγνωσης Υπέρτασης

Πίνακας 22: Πίνακας αποτελεσμάτων αλγόριθμων Transfer Learning διάγνωσης υπέρτασης.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.515	0.5	0.475	0.508
EfficientNetB2	0.485	0.49	0.44	0.496
EfficientNetB3	0.6	0.5	0.425	0.504
EfficientNetB4	0.35	0.5	0.41	0.5
EfficientNetB5	0.61	0.555	0.555	0.563
EfficientNetB6	0.455	0.49	0.425	0.492
EfficientNetB7	0.455	0.455	0.455	0.46
VGG19	0.89	0.897	0.89	0.901
VGG16	0.885	0.897	0.89	0.901
RESNET-50	0.905	0.915	0.905	0.915
DenseNet201	0.795	0.795	0.795	0.799
InceptionV3	0.72	0.745	0.73	0.753
Xception	0.73	0.73	0.73	0.742

Η αρχιτεκτονική Transfer Learning που επεφερε την βελτιστη αποδοτικότητα είναι η RESNET50. Χαρακτηριστικά μοντέλου : Χρήση Adam Βελτιστοποιήτη με παραμετρους learning rate = 0.001, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8 ,Batch size = 126 ,Επαναληψεις = 100

Παρακατω Αναγραφονται οι αποδοσεις του αλγοριθμου για την καθε κλαση.

Πίνακας 23: Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50 αποδοτικότητα διάγνωσης υπέρτασης ανά κλάση ξεχωριστά.

Resnet50 Metrics:

Class	Precision	Recall	F1 Score	AUC
Normal	0.9530201342281879	0.9403973509933775	0.9466666666666667	0.9155111754966888
Hypertension	0.8636363636363636	0.890625	0.8769230769230768	0.9155111754966888

4.9.5 Αποτελέσματα Εφαρμογής Διάγνωσης Μυωπίας

Πίνακας 24: Πίνακας αποτελεσμάτων αλγόριθμων *Transfer Learning* διάγνωσης Μυωπίας

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.25	0.5	0.335	0.5
EfficientNetB2	0.505	0.505	0.475	0.508
EfficientNetB3	0.535	0.54	0.365	0.501
EfficientNetB4	0.755	0.51	0.381	0.51
EfficientNetB5	0.475	0.49	0.41	0.49
EfficientNetB6	0.525	0.52	0.5	0.522
EfficientNetB7	0.39	0.415	0.39	0.415
VGG19	1.0	1.0	1.0	1.0
VGG16	0.98	0.98	0.98	0.982
RESNET-50	0.995	0.996	0.995	0.996
DenseNet201	0.98	0.98	0.98	0.982
InceptionV3	0.955	0.955	0.95	0.955
Xception	0.93	0.935	0.93	0.937

Η αρχιτεκτονική *Transfer Learning* που επέφερε την βέλτιστη αποδοτικότητα είναι η VGG19. Χαρακτηριστικά μοντέλου: Χρήση Adam βελτιστοποίησης με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100.

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για την κάθε κλάση.

Πίνακας 25: Πίνακας αποτελεσμάτων αρχιτεκτονικής VGG19 αποδοτικότητα διάγνωσης Μυωπίας ανά κλάση ξεχωριστά.

VGG19 Metrics:

```

+-----+-----+-----+-----+-----+
| Class | Precision | Recall | F1 Score | AUC |
+-----+-----+-----+-----+-----+
| Normal | 1.0 | 1.0 | 1.0 | 1.0 |
| Myopia | 1.0 | 1.0 | 1.0 | 1.0 |
+-----+-----+-----+-----+-----+
    
```

4.9.6 Εφαρμογή : Διάγνωση οφθαλμικών Προβλημάτων λόγω ηλικίας.

Πίνακας 26: Πίνακας αποτελεσμάτων αρχιτεκτονικής VGG16 αποδοτικότητα διάγνωσης οφθαλμικών Προβλημάτων λόγω ηλικίας.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.495	0.495	0.455	0.497
EfficientNetB2	0.56	0.535	0.47	0.53
EfficientNetB3	0.455	0.49	0.345	0.49
EfficientNetB4	0.495	0.498	0.33	0.49
EfficientNetB5	0.495	0.49	0.425	0.498
EfficientNetB6	0.42	0.46	0.38	0.46
EfficientNetB7	0.495	0.491	0.595	0.496
VGG19	0.885	0.89	0.89	0.893
VGG16	0.91	0.91	0.91	0.91
RESNET-50	0.9	0.9	0.9	0.904
DenseNet201	0.82	0.82	0.82	0.82
InceptionV3	0.695	0.69	0.705	0.692
Xception	0.73	0.65	0.607	0.654

Η αρχιτεκτονική Transfer Learning που επέφερε την βέλτιστη αποδοτικότητα είναι η VGG16.

Χαρακτηριστικά μοντέλου: Χρήση Adam βελτιστοποιητή με παραμέτρους learning rate = 0.001,

Χρήση Τεχνητής Νοημοσύνης στην Ιατρική - Αντώνης Κονι

beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100.

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για την κάθε κλάση.

Πίνακας 27: αποτελεσμάτων αρχιτεκτονικής VGG16 αποδοτικότητα διάγνωσης Οφθαλμικών Προβλημάτων λόγω ηλικίας ανά κλάση ξεχωριστά.

VGG16 Metrics:

Class	Precision	Recall	F1 Score	AUC
Normal	0.9037037037037037	0.9312977099236641	0.9172932330827067	0.9114821882951654
Age Issues	0.9224137931034483	0.8916666666666667	0.9067796610169492	0.9114821882951654

4.9.7 Εφαρμογή : Διάγνωση Άλλων οφθαλμικών παθήσεων.

Πίνακας 28: Πίνακας αποτελεσμάτων αλγορίθμων Transfer Learning διάγνωσης οφθαλμικών παθήσεων.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.415	0.465	0.415	0.47
EfficientNetB2	0.49	0.495	0.439	0.498
EfficientNetB3	0.34	0.485	0.4	0.489
EfficientNetB4	0.495	0.495	0.42	0.5
EfficientNetB5	0.3	0.49	0.4	0.492
EfficientNetB6	0.41	0.48	0.4	0.486
EfficientNetB7	0.34	0.485	0.4	0.489
VGG19	0.856	0.87	0.86	0.875
VGG16	0.85	0.85	0.85	0.853
RESNET-50	0.89	0.87	0.88	0.871
DenseNet201	0.84	0.775	0.795	0.776
InceptionV3	0.665	0.575	0.575	0.583
Xception	0.835	0.805	0.815	0.809

Η αρχιτεκτονική Transfer Learning που επέφερε την βέλτιστη αποδοτικότητα είναι η RESNET50.

Χαρακτηριστικά μοντέλου: Χρήση Adam βελτιστοποιητή με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100.

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για την κάθε κλάση.

Πίνακας 29: Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50. αποδοτικότητα διάγνωσης οφθαλμικών παθήσεων ανά κλάση ξεχωριστά.

Resnet50 Metrics:

Class	Precision	Recall	F1 Score	AUC
Normal	0.910958904109589	0.95	0.93006993006993	0.8718253968253967
Other	0.8771929824561403	0.7936507936507936	0.8333333333333334	0.8718253968253967


4.10 Εφαρμογή : Διάγνωση Αλτσχάιμερ 2D

Διάγνωση της νόσου Αλτσχάιμερ με την χρήση εικόνων Μαγνητικής τομογραφίας του εγκεφάλου. Για την δημιουργία του διαγνωστικού συστήματος χρησιμοποιήθηκαν δεδομένα από τους παρακάτω φορείς:[35],[36]

Τα δεδομένα που χρησιμοποιούνται είναι εικόνες υπερηχου του στήθους.
Ο αριθμος εικονων ειναι : 33984

Κλασεις προς καταταξη :

- •Ήπια άνοια(8960εικονες)
- Μέτρια άνοια (6464 εικονες)
- Υγιες δειγμα (9600 εικονες)
- Πολύ ήπια άνοια (8960)



Εικόνα 8: Δείγμα εικόνας Μαγνητικής τομογραφίας εγκεφάλου.

Πηγή :

<https://www.kaggle.com/datasets/sachinkumar413/alzheimer-mri-dataset>

Οι εικόνες είναι διαμέτρου (180 x 180) pixel και μεγέθους 10,6 KB. Το συνολικό μέγεθος της βάσης δεδομένων που χρησιμοποιήθηκε είναι 368,5 MB. Πριν την χρήση των εικόνων στους αλγορίθμους γίνονται οι εξής παραμετροποιήσεις στις εικόνες:

- Διάμετρος εικόνας (128,128)
- Κανονικοποίηση τιμών για κάθε pixel με εύρος τιμών από 0 έως 1.

Το 80% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 20% για την εξέταση του αλγορίθμου και την διεξαγωγή μετρήσεων. Αρχικά παρουσιάζονται τα αποτελέσματα για Κατηγοριοποίηση πολλαπλών κλάσεων (4 παραπάνω κλάσεις) και ύστερα παρουσιάζονται αποτελέσματα για την δυαδική κατηγοριοποίηση (Υγιές Δείγμα, Δείγμα με οποιοδήποτε βαθμό άνοιας).

Πίνακας 30: Πίνακας αποτελεσμάτων αλγόριθμων *Transfer Learning* διάγνωσης αλτσχαιμερ.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.932	0.902	0.902	0.98
EfficientNetB2	0.895	0.897	0.892	0.975
EfficientNetB3	0.902	0.905	0.905	0.985
EfficientNetB4	0.822	0.83	0.82	0.955
EfficientNetB5	0.71	0.74	0.722	0.912
EfficientNetB6	0.682	0.675	0.665	0.885
EfficientNetB7	0.622	0.652	0.612	0.867
VGG19	0.742	0.744	0.744	0.9155
VGG16	0.772	0.776	0.771	0.93
RESNET-50	0.61	0.595	0.567	0.832
DenseNet201	0.937	0.935	0.935	0.988
InceptionV3	0.79	0.795	0.785	0.937
Xception	0.877	0.875	0.877	0.97

Η αρχιτεκτονική *Transfer Learning* που επέφερε την βέλτιστη αποδοτικότητα είναι η *DenseNet201*. Χαρακτηριστικά μοντέλου: Χρήση *Adam* βελτιστοποιητή με παραμέτρους $\text{learning rate} = 0.002$, $\text{beta 1} = 0.9$, $\text{beta 2} = 0.999$, $\text{epsilon} = 1e-8$, $\text{Batch size} = 126$, $\text{Επαναλήψεις} = 100$.

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για την κάθε κλάση.

Πίνακας 30: Πίνακας αποτελεσμάτων αρχιτεκτονικής DensNet201 αποδοτικότητα διάγνωσης αλτσχαιμερ ανά κλάση ξεχωριστά

DenseNet Metrics				
Class	Precision	Recall	F1 Score	AUC
MildDemented	0.9504678040726472	0.9696799550814149	0.9599777654252363	0.9972740794869109
ModerateDemented	0.9991823385118561	0.9943043124491456	0.9967373572593801	0.9999900629424914
NonDemented	0.8790436005625879	0.9541984732824428	0.9150805270863835	0.9903275238865579
VeryMildDemented	0.9482758620689655	0.845225027442371	0.8937899013348811	0.9879640794532487

4.10.2 Binary Classification

Πίνακας 31: Πίνακας αποτελεσμάτων αλγορίθμων Transfer Learning διάγνωσης αλτσχαιμερ δυαδική ταξινόμηση(1-Ασθενής , 0 Υγιές δείγμα).

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.825	0.825	0.832	0.832
EfficientNetB2	0.855	0.855	0.855	0.855
EfficientNetB3	0.859	0.859	0.859	0.859
EfficientNetB4	0.816	0.815	0.816	0.816
EfficientNetB5	0.792	0.792	0.792	0.792
EfficientNetB6	0.8	0.8	0.8	0.8
EfficientNetB7	0.781	0.781	0.781	0.781
VGG19	0.773	0.773	0.773	0.773
VGG16	0.8	0.8	0.8	0.8
RESNET-50	0.781	0.781	0.781	0.781
DenseNet201	0.878	0.878	0.878	0.878
InceptionV3	0.851	0.851	0.851	0.851
Xception	0.882	0.882	0.882	0.882

Η αρχιτεκτονική Transfer Learning που επέφερε την βέλτιστη αποδοτικότητα είναι η Xception.

Χαρακτηριστικά μοντέλου: Χρήση Adam βελτιστοποιητή με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100.

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για την κάθε κλάση.

Πίνακας 32: Πίνακας αποτελεσμάτων αρχιτεκτονικής Xception αποδοτικότητα διάγνωσης αλτσχαιμερ ανά κλάση ξεχωριστά.

Xception Metrics:

Class	Precision	Recall	F1 Score	AUC
0	0.8828125	0.8828125	0.8828125	0.8828125
1	0.8828125	0.8828125	0.8828125	0.8828125

4.11 Εφαρμογή : Διάγνωση χρόνιας νεφρικής νόσου.

Διάγνωση χρόνιας νεφρικής νόσου με την χρήση δεδομένων σε μορφή CSV. Για την δημιουργία του διαγνωστικού συστήματος χρησιμοποιήθηκαν δεδομένα από τους παρακάτω φορείς: [\[37\]](#), [\[38\]](#), [\[39\]](#)

Τα δεδομένα που χρησιμοποιούνται είναι ένα αρχείο CSV που περιέχει 400 δείγματα (γραμμές) και 14 στήλες με τα παρακάτω χαρακτηριστικά:

1. bp - αρτηριακή πίεση (blood pressure)
2. sg - ειδική βαρύτητα (specific gravity)

3. al - αλβουμίνη (albumin)

4. su - ζάχαρη (sugar)

5. rbc - κόκκινα αιμοσφαίρια (red blood cells)

6. ba - βακτήρια (bacteria)

7. bu - ούρα αίματος (blood urea)

8. sc - κρεατινίνη ορού (serum creatinine)

9. sod - νάτριο (sodium)

10.pot - κάλιο (potassium)

11. hemo - αιμοσφαιρίνη (hemoglobin)

12.rc - μέτρηση κόκκινων αιμοσφαιρίων (red blood cell count) **13.htn** - υπέρταση (hypertension)

14.class κατηγορία (class)

Επεξεργασία δεδομένων:

Πραγματοποιείται κανονικοποίηση των δεδομένων με εύρος τιμών 0 ως 1, χρησιμοποιώντας την κανονικοποίηση MinMaxScaler της βιβλιοθήκης sklearn. Το 70% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 30% για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων.

Παρακάτω αναγράφεται το σύστημα με τις βέλτιστες αποδόσεις και οι εκάστοτε μετρήσεις των αποδόσεων.

Πίνακας 33: Πίνακας αποτελεσμάτων διάγνωσης χρόνιας νεφρικής νόσου.

Random Forest Classifier Metrics With Normalized Data:

Metric	Value
Train Accuracy	1.0
Test Accuracy	1.0
True Negatives (Test)	44
False Positives (Test)	0
False Negatives (Test)	0
True Positives (Test)	76
AUC (Test)	1.0
Precision (Test)	1.0
Recall (Test)	1.0
F1 Score(Test)	1.0

4.11 Αποτελέσματα Εφαρμογής

Ο αλγόριθμος μηχανικής μάθησης που επέφερε την βέλτιστη, και μάλιστα με τέλεια ακρίβεια, είναι ο Random Forest με $n_estimators=10000$. Ο οποίος στην περίπτωση μας κατατάσσει όλα τα δείγματα στην σωστή κλάση.

4.12 Εφαρμογή : Διάγνωση του Συνδρόμου της Πολυκυστικής Ωοθήκης (Polycystic Ovary Syndrome)

Διάγνωση του συνδρόμου της πολυκυστικής ωοθήκης με την χρήση εικόνων υπερήχου ωοθηκών.


Για την δημιουργία του διαγνωστικού συστήματος χρησιμοποιήθηκαν δεδομένα από τους παρακάτω φορείς: [\[40\]](#),[\[41\]](#)

Τα δεδομένα που χρησιμοποιούνται είναι Υπερηχογράφημα Ωοθηκών. Ο αριθμός εικόνων είναι

3570.

Κλάσεις προς κατάταξη:

- Υγιές δείγμα (2002 εικόνες)
- Δείγμα με σύνδρομο πολυκυστικής ωοθήκης (1568 εικόνες)



Εικόνα 9 : Δείγμα εικόνας: Υπερηχογράφηματος Ωοθηκών.

Πηγή :

<https://www.kaggle.com/datasets/anaghachoudhari/pcos-detection-using-ultrasound-images>

Οι εικόνες είναι διαμέτρου (343 x 343) pixels και μεγέθους 21,3 KB. Το συνολικό μέγεθος της βάσης δεδομένων που χρησιμοποιήθηκε είναι 121,6 MB. Πριν την χρήση των εικόνων στους αλγορίθμους γίνονται οι εξής παραμετροποιήσεις για την βέλτιστη απόδοση των αλγορίθμων, αλλά και για λόγους εξοικονόμησης υπολογιστικής ισχύος την ώρα της μάθησης:

- Διάμετρος εικόνας: (128,128)
- Κανονικοποίηση τιμών για κάθε pixel με εύρος τιμών από 0 έως 1.

Το 80% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 20% για την εξέταση του αλγορίθμου και την διεξαγωγή μετρήσεων.

Παρακατω αναγράφονται οι αποδοσεις των αλγορίθμων :

4.12 Αποτελέσματα Εφαρμογής

Πίνακας 34: Πίνακας αποτελεσμάτων αλγορίθμων *Transfer Learning* διάγνωσης του συνδρόμου της πολυκυστικής ωοθήκης.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	1.0	1.0	1.0	1.0
EfficientNetB2	1.0	1.0	1.0	1.0
EfficientNetB3	1.0	1.0	1.0	1.0
EfficientNetB4	1.0	1.0	1.0	1.0
EfficientNetB5	1.0	1.0	1.0	1.0
EfficientNetB6	1.0	1.0	1.0	1.0
EfficientNetB7	1.0	1.0	1.0	1.0
VGG19	1.0	1.0	1.0	1.0
VGG16	1.0	1.0	1.0	1.0
RESNET-50	1.0	1.0	1.0	1.0
DenseNet201	1.0	1.0	1.0	1.0
InceptionV3	1.0	1.0	1.0	1.0
Xception	1.0	1.0	1.0	1.0

Όλες οι αρχιτεκτονικές επέφεραν τέλεια απόδοση.

Χαρακτηριστικά μοντέλων : Χρήση Adam Βελτιστοποιητή με παραμέτρους learning rate = 0.002,

beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100

4.13 Εφαρμογή : Διάγνωση Οστεοαρθρίτιδας

Διάγνωση οστεοαρθρίτιδας με την χρήση εικόνων X-ray του γόνατος. Για την δημιουργία του διαγνωστικού συστήματος χρησιμοποιήθηκαν δεδομένα από τους παρακάτω φορείς: [42] ,[43]

Τα δεδομένα που χρησιμοποιούνται είναι εικόνες X-ray του γόνατος. Ο αριθμός εικόνων είναι 3570.

Κλάσεις προς κατάταξη: 2

- Υγιες δειγμα (2925 εικονες)
- Δειγμα με οστεοαρθριτιδας (3673 εικονες)



Εικόνα 10: Δείγμα εικόνας αξονικής γονάτος.

Πηγή:

<https://www.kaggle.com/datasets/tommyngx/knee-0a>

Οι εικόνες είναι διαμέτρου (224 x 224) pixel και μεγέθους 18,8 KB. Το συνολικό μέγεθος της βάσης δεδομένων που χρησιμοποιήθηκε είναι 143,3 MB. Πριν την χρήση των εικόνων στους αλγορίθμους γίνονται οι εξής παραμετροποιήσεις για την βέλτιστη απόδοση των αλγορίθμων, αλλά και για λόγους εξοικονόμησης υπολογιστικής ισχύος την ώρα της μάθησης:

- Διάμετρος εικόνας: (128,128)
- Κανονικοποίηση τιμών για κάθε pixel με εύρος τιμών από 0 έως 1.

Το 80% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 20% για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων.

Παρακάτω αναγράφονται οι αποδόσεις των αλγορίθμων:

4.13 Αποτελέσματα Εφαρμογής

Πίνακας 35: Πίνακας αποτελεσμάτων αλγορίθμων *Transfer Learning* διάγνωσης οστεοαρθρίτιδας.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.6757	0.6757	0.6757	0.6757
EfficientNetB2	0.6523	0.6523	0.6522	0.6523
EfficientNetB3	0.7148	0.7148	0.7148	0.7148
EfficientNetB4	0.6523	0.6523	0.6523	0.6523
EfficientNetB5	0.7187	0.7187	0.7187	0.7187
EfficientNetB6	0.621	0.621	0.621	0.621
EfficientNetB7	0.6835	0.6835	0.6835	0.6835
VGG19	0.6212	0.6212	0.6212	0.6212
VGG16	0.6015	0.6015	0.6015	0.6015
RESNET-50	0.7473	0.746	0.7475	0.7460
DenseNet201	0.6876	0.6874	0.6874	0.6875
InceptionV3	0.6835	0.6835	0.6835	0.6835
Xception	0.5703	0.5703	0.5702	0.5703

Η αρχιτεκτονική *Transfer Learning* που επέφερε την βέλτιστη αποδοτικότητα είναι η RESNET50.

Χαρακτηριστικά μοντέλου: Χρήση Adam Βελτιστοποιητή με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για κάθε κλάση.

Πίνακας 36: Πίνακας αποτελεσμάτων αρχιτεκτονικής RESNET50 αποδοτικότητα διάγνωσης οστεοαρθρίτιδας ανά κλάση ξεχωριστά.

Resnet50 Metrics:

Class	Precision	Recall	F1 Score	AUC
0	0.7647058823529411	0.7109375	0.7368421052631579	0.74609375
1	0.7299270072992701	0.78125	0.7547169811320755	0.74609375


Παραγωγή και χρήση αποτελεσμάτων

Για την δημιουργία του διαγνωστικού συστήματος χρησιμοποιήθηκαν δεδομένα από τους παρακάτω φορείς: [\[44\]](#), [\[45\]](#), [\[46\]](#)

Τα δεδομένα που χρησιμοποιούνται είναι εικόνες κυττάρων αίματος. Ο αριθμός εικόνων είναι: 27,560

Κλάσεις προς κατάταξη: 2

- Υγιές δείγμα (13,780 εικόνες)
- Ελονοσία (13,780 εικόνες)



Εικόνα 11: Δείγμα εικόνας Κύτταρο μολυσμένο με ελονοσία
πηγή: <https://www.kaggle.com/datasets/itsdaniyal/malaria-cell-classification-dataset>

Οι εικόνες είναι διαμέτρου (124 x 127) pixel και μεγέθους 12,9 KB. Το συνολικό μέγεθος της βάσης δεδομένων που χρησιμοποιήθηκε είναι 353,1 MB. Πριν την χρήση των εικόνων στους αλγορίθμους γίνονται οι εξής παραμετροποιήσεις για την βέλτιστη απόδοση των αλγορίθμων, αλλά και για λόγους εξοικονόμησης υπολογιστικής ισχύος την ώρα της μάθησης:

- Διάμετρος εικόνας: (128,128)
- Κανονικοποίηση τιμών για κάθε pixel με εύρος τιμών από 0 έως 1.

Το 80% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 20% για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων.

Παρακάτω αναγράφονται οι αποδόσεις των αλγορίθμων:

4.14 Αποτελέσματα Εφαρμογής

Πίνακας 37: Πίνακας αποτελεσμάτων αλγόριθμων *Transfer Learning* διάγνωσης ελονοσίας.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.9921	0.9921	0.9921	0.9921
EfficientNetB2	0.9843	0.9843	0.9843	0.9843
EfficientNetB3	0.9901	0.9901	0.9901	0.9901
EfficientNetB4	0.996	0.996	0.996	0.996
EfficientNetB5	1.0	1.0	1.0	1.0
EfficientNetB6	0.9509	0.9509	0.9509	0.9509
EfficientNetB7	0.9921	0.9921	0.9921	0.9921
VGG19	1.0	1.0	1.0	1.0
VGG16	0.9843	0.9843	0.9843	0.9843
RESNET-50	0.773	0.773	0.773	0.773
DenseNet201	0.9921	0.9921	0.9921	0.9921
InceptionV3	1.0	1.0	1.0	1.0
Xception	0,98825	0,98825	0,98825	0,98825

Οι αρχιτεκτονικές EfficientNetB5, VGG19 και InceptionV3 επέφεραν τέλεια απόδοση.

Χαρακτηριστικά μοντέλων: Χρήση Adam Βελτιστοποιητή με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100

4.15 Εφαρμογή : Διάγνωση Καρκίνου - Πέτρας - Λάσπης στα Νεφρά.

Για την δημιουργία του διαγνωστικού συστήματος χρησιμοποιήθηκαν δεδομένα από τους παρακάτω φορείς:[47].


Τα δεδομένα που χρησιμοποιούνται είναι εικόνες αξονικής τομογραφίας. Ο αριθμός εικόνων είναι: 12,446

Κλάσεις προς κατάταξη: 4

- Υγιές δείγμα (5077 εικόνες)
- Δείγμα με καρκίνο (2283 εικόνες)

Χρήση Τεχνητής Νοημοσύνης στην Ιατρική - Αντώνης Κονιγι

- Δείγμα με πέτρα στα νεφρά (1377 εικόνες)
- Δείγμα με λάσπη στα νεφρά (3709 εικόνες)



Εικόνα 12: Δείγμα εικόνας Αξονικής νεφρών. <https://www.kaggle.com/datasets/nazmul0087/ct-kidney-dataset-normal-cyst-tumor-and-stone>

Οι εικόνες είναι διαμέτρων (705 x 569) pixel και μεγέθους 165,3 KB. Το συνολικό μέγεθος της βάσης δεδομένων που χρησιμοποιήθηκε είναι 1,7 GB. Πριν τη χρήση των εικόνων στους αλγορίθμους, γίνονται οι εξής παραμετροποιήσεις για τη βέλτιστη απόδοση των αλγορίθμων, αλλά και για λόγους εξοικονόμησης υπολογιστικής ισχύος την ώρα της μάθησης :

- Διάμετρος εικόνας: (224,224)
- Κανονικοποίηση τιμών για κάθε pixel με εύρος τιμών από 0 έως 1.

Το 80% των δεδομένων χρησιμοποιείται για την εκπαίδευση του αλγορίθμου και το υπόλοιπο 20% για την εξέταση του αλγορίθμου και τη διεξαγωγή μετρήσεων.

4.15.1 Εφαρμογή Δυαδική κατάταξης: Διάγνωση καρκίνου στα νεφρά

Πίνακας 38: Πίνακας αποτελεσμάτων αλγορίθμων *Transfer Learning* διάγνωσης καρκίνου στα νεφρά.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.8	0.8	0.8	0.8
EfficientNetB2	0.781	0.781	0.781	0.781
EfficientNetB3	0.675	0.675	0.675	0.675
EfficientNetB4	0.761	0.761	0.761	0.761
EfficientNetB5	0.812	0.812	0.812	0.812
EfficientNetB6	0.734	0.734	0.734	0.734
EfficientNetB7	0.73	0.73	0.73	0.73
VGG19	0.742	0.742	0.742	0.742
VGG16	0.585	0.585	0.585	0.585
RESNET-50	0.703	0.703	0.703	0.703
DenseNet201	0.835	0.835	0.835	0.835
InceptionV3	0.66	0.66	0.66	0.66
Xception	0.808	0.808	0.808	0.808

Η αρχιτεκτονική Transfer Learning που επέφερε την βέλτιστη αποδοτικότητα είναι η DenseNet201. Χαρακτηριστικά μοντέλου: Χρήση Adam Βελτιστοποιητή με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126, Επαναλήψεις = 100

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για κάθε κλάση.

Πίνακας 39: Πίνακας αποτελεσμάτων αρχιτεκτονικής DenseNet201, αποδοτικότητα διάγνωσης καρκίνου στα νεφρά ανά κλάση ξεχωριστά.

```
DenseNet201 Metrics:
+-----+-----+-----+-----+-----+
| Class | Precision | Recall | F1 Score | AUC |
+-----+-----+-----+-----+-----+
| Normal | 0.8359375 | 0.8359375 | 0.8359375 | 0.8359375 |
| Tumor | 0.8359375 | 0.8359375 | 0.8359375 | 0.8359375 |
+-----+-----+-----+-----+-----+
```

4.15.2 Εφαρμογή Δυαδική κατάταξης: Διάγνωση πέτρας στα νεφρά.

Πίνακας 40: Πίνακας αποτελεσμάτων αλγορίθμων *Transfer Learning* διάγνωσης πέτρας στα νεφρά.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.835	0.835	0.839	0.839
EfficientNetB2	0.775	0.775	0.775	0.781
EfficientNetB3	0.914	0.914	0.914	0.914
EfficientNetB4	0.789	0.789	0.789	0.789
EfficientNetB5	0.77	0.77	0.77	0.773
EfficientNetB6	0.825	0.825	0.82	0.828
EfficientNetB7	0,875	0.878	0.878	0.878
VGG19	0.9	0.9	0.9	0.9
VGG16	0.88	0.88	0.886	0.886
RESNET-50	0.781	0.781	0.781	0.781
DenseNet201	0.845	0.845	0.847	0.847
InceptionV3	0.859	0.859	0.859	0.859
Xception	0.84	0.84	0.843	0.843

Η αρχιτεκτονική *Transfer Learning* που επέφερε την βέλτιστη αποδοτικότητα είναι η EfficientNetB3. Χαρακτηριστικά μοντέλου: Χρήση Adam Βελτιστοποιητή με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126

Παρακάτω αναγράφονται οι αποδόσεις του αλγορίθμου για κάθε κλάση.

Πίνακας 41 : Πίνακας αποτελεσμάτων αρχιτεκτονικής EfficientNetB3 αποδοτικότητα διάγνωσης πέτρας στα νεφρά ανά κλάση ξεχωριστά.

EfficientNetB3 Metrics:

Class	Precision	Recall	F1 Score	AUC
Normal	0.9140625	0.9140625	0.9140625	0.9140625
stone	0.9140625	0.9140625	0.9140625	0.9140625

4.15.3 Εφαρμογή : Δυαδική κατάταξη: Διάγνωση λάσπης στα νεφρά

Πίνακας 42: Πίνακας αποτελεσμάτων αλγορίθμων Transfer Learning διάγνωσης λάσπης στα νεφρά.

	PRECISION	RECALL	F1- SCORE	AUC
EfficientNetB1	0.917	0.917	0.917	0.917
EfficientNetB2	0.86	0.86	0.86	0.863
EfficientNetB3	0.81	0.815	0.816	0.816
EfficientNetB4	0.875	0.875	0.875	0.875
EfficientNetB5	0.85	0.85	0.85	0.851
EfficientNetB6	0.8	0.8	0.8	0.8
EfficientNetB7	0.91	0.91	0.91	0.91
VGG19	0.87	0.87	0.87	0.87
VGG16	0.812	0.812	0.812	0.812
RESNET-50	0.812	0.812	0.812	0.812
DenseNet201	0.906	0.906	0.906	0.906
InceptionV3	0.917	0.917	0.917	0.917
Xception	0.886	0.886	0.8786	0.886

Οι αρχιτεκτονικές Transfer Learning που επέφεραν την βέλτιστη αποδοτικότητα είναι η EfficientNetB1 και InceptionV3. Χαρακτηριστικά μοντέλου: Χρήση Adam Βελτιστοποιητή με παραμέτρους learning rate = 0.002, beta 1 = 0.9, beta 2 = 0.999, epsilon = 1e-8, Batch size = 126

Παρακάτω αναγράφονται οι αποδόσεις των 2 αλγορίθμων για κάθε κλάση.

Πίνακας 43: Πίνακας αποτελεσμάτων αρχιτεκτονικής EfficientNetB1 αποδοτικότητα διάγνωσης λάσπης στα νεφρά ανά κλάση ξεχωριστά.

EfficientNetB1 Metrics:

```

+-----+-----+-----+-----+
| Class | Precision | Recall | F1 Score | AUC |
+-----+-----+-----+-----+
| Normal | 0.9212598425196851 | 0.9140625 | 0.9176470588235294 | 0.91796875 |
| Cyst | 0.9147286821705426 | 0.921875 | 0.9182879377431907 | 0.91796875 |
+-----+-----+-----+-----+
    
```

Πίνακας 44: Πίνακας αποτελεσμάτων αρχιτεκτονικής InceptionV3 αποδοτικότητα διάγνωσης λήσσης στα νεφρά ανά κλάση ξεχωριστά.

Inception Metrics:

Class	Precision	Recall	F1 Score	AUC
Normal	0.9212598425196851	0.9140625	0.9176470588235294	0.91796875
Cyst	0.9147286821705426	0.921875	0.9182879377431907	0.91796875

5. Μέσος όρος απόδοσης αλγόριθμων .

Πίνακας 45: Μέση απόδοση αλγορίθμων.

	mean PRECISION	mean RECALL	F1 - SCORE	mean AUC
EfficientNetB1	0.74	0.77	0.74	0.79
EfficientNetB2	0.75	0.76	0.73	0.78
EfficientNetB3	0.75	0.77	0.73	0.78
EfficientNetB4	0.78	0.77	0.74	0.79
EfficientNetB5	0.74	0.76	0.74	0.78
EfficientNetB6	0.74	0.75	0.72	0.77
EfficientNetB7	0.73	0.74	0.74	0.77
VGG 19	0.86	0.86	0.86	0.9
VGG 16	0.87	0.87	0.87	0.91
RESNET50	0.81	0.8	0.8	0.85
DENSENET201	0.88	0.87	0.87	0.89
INCEPTION	0.88	0.84	0.83	0.86
XCEPTION	0.87	0.86	0.86	0.87

6) Συμπεράσματα και κίνδυνοι

Οι αποδόσεις των αλγορίθμων μηχανικής μάθησης και των αρχιτεκτονικών Transfer Learning διαφέρουν ανάλογα με το πρόβλημα και τα δεδομένα που κατέχουμε για την επίλυση τους. Οι αποδόσεις συστημάτων TN για τη διαδικασία της διάγνωσης είναι αρκετά ελπιδοφόρες, σιτεύοντας μεγάλη ακρίβεια ακόμα και με τον περιορισμένο όγκο δεδομένων που έχουμε στη διάθεσή μας. Η χρήση της TN στη διαδικασία της διάγνωσης θα αποφέρει δεδομένα που θα συμβάλουν στην τελειοποίηση της αποδοτικότητας τέτοιων εφαρμογών. Το κύριο συστατικό για τη δημιουργία και την βέλτιστη απόδοση εφαρμογών TN είναι η ποιότητα και η ποσότητα των δεδομένων που κατέχουμε. Συμπεραίνουμε ότι η χρήση TN στην ιατρική επιφέρει σημαντικές αποδόσεις και η χρήση τέτοιων εφαρμογών θα βοηθήσει το έργο των γιατρών, όμως η πραγματική αξία των εφαρμογών κρύβεται στην εξόρυξη δεδομένων. Η ενσωμάτωση της χρήσης τεχνικών TN στην ιατρική για την εξόρυξη ιατρικών δεδομένων καθιστά βασικό παράγοντα για τη δημιουργία και βελτιστοποίηση των εφαρμογών.

Με την υπολογιστική ισχύ που έχουμε στη διάθεσή μας, η τεχνητή νοημοσύνη πρόκειται να εξελιχθεί και να ενσωματωθεί στην καθημερινή μας ζωή σε πολλαπλούς τομείς πολύ σύντομα. Πολλοί τομείς όπως η ιατρική θα επωφεληθούν χρυσά.

Καθώς η ενσωμάτωση τεχνολογιών TN στην ιατρική είναι πλέον κρίσιμη, θα πρέπει όμως να μην βιαστούμε με την ενσωμάτωση και τη χρήση τεχνολογιών και πρακτικών της μέχρι να είμαστε απολύτως σίγουροι ότι τα συστήματα είναι ασφαλή για χρήση. Ένα μεγάλο πρόβλημα που θα πρέπει επίσης να βρούμε λύση είναι η εκπαίδευση των ιατρών και των χειρουργών στις νέες τεχνολογίες και η διασφάλιση των θέσεων εργασίας τους, διότι όλη αυτή η αυτοματοποίηση ενδέχεται να δημιουργήσει πρόβλημα σε αρκετό ιατρικό προσωπικό με κατάληξη να χάσει αρκετός κόσμος τη δουλειά του. Διασφαλίζοντας μια ομαλή μετάβαση στις τεχνολογίες αιχμής όπου οι γιατροί διαθέτουν χρήσιμα εργαλεία "να τους λύνουν τα χέρια" και όλη τους η ενέργεια και γνώση να προσανατολίζεται στην έρευνα της ίασης των ασθενών.

7) Σχετικές Έρευνες

Στην μελέτη [48] Αναφέρονται στη δημιουργία ενός βαθιού νευρωνικού δικτύου μηχανικής όρασης για την αναγνώριση και την κατηγοριοποίηση της νόσου Αλτσχάιμερ σε τρισδιάστατες εικόνες. Η χρήση τρισδιάστατων εικόνων για την εκπαίδευση νευρωνικών δικτύων είναι ένα αναγκαίο βήμα για

την αυτοματοποίηση της διαδικασίας της διάγνωσης, διότι οι αξονικές-μαγνητικές εξετάσεις που κάνουμε επιστρέφουν μια τρισδιάστατη εικόνα. Οι τρισδιάστατες εικόνες είναι αρκετά δύσκολο να χρησιμοποιηθούν για την εκπαίδευση νευρωνικών δικτύων γιατί η υπολογιστική ισχύς που χρειάζεται είναι σχεδόν χίλιες φορές μεγαλύτερη από τη χρήση δισδιάστατων εικόνων.

Αποτελέσματα έρευνας:

“Η προτεινόμενη μέθοδος πέτυχε ακρίβεια 97,35% για τη διάκριση των ασθενών με Αλτσχάιμερ, και για τη νοσο MCI 87,82% έναντι των υγιών ατόμων ”

Στην μελέτη [49] Αναφέρονται στη δημιουργία αλγορίθμου μηχανικής μάθησης που θα διαγιγνώσκει την έκθεση σε υπερδυναμικό σοκ.

Αποτελέσματα έρευνας:

“Χρησιμοποιήθηκε στην διαχρονική πρόβλεψη του σοκ στις 0, 3, 6 και 12 ώρες, \ Το μοντέλο πέτυχε μέσο όρο κάτω από την καμπύλη χαρακτηριστικής λειτουργίας του δέκτη (AUC) 75% στις 0 ώρες (ταξινόμηση), 77% στις 3 ώρες (πρόβλεψη) και 69% στις 12 ώρες (πρόβλεψη) αντίστοιχα. “

Επειδή το αιμοδυναμικό σοκ είναι συχνά θανατηφόρο, η έρευνα παρουσιάζει ένα οικονομικό, μη επεμβατικό και διαγνωστικό σύστημα για την αξιόπιστη ανίχνευση και πρόβλεψή του, προσφέροντας ένα σημαντικό χρονικό προβάδισμα στους γιατρούς για την καταπολέμηση μιας ιατρικής κρίσης στους ασθενείς.

8) Διαδικτυακή εφαρμογή “ Διαδικτυακές Διαγνώσεις’.

Για την πτυχιακή εργασία, έχω αναπτύξει μια διαδικτυακή εφαρμογή για την διεξαγωγή διαγνωστικών εξετάσεων χρησιμοποιώντας αλγόριθμους Βαθυ νευρωνικών δικτύων τύπου Transfer Learning . Η εφαρμογή είναι κατασκευασμένη με το Django framework χρησιμοποιώντας την γλώσσα προγραμματισμού Python για το backend και χρησιμοποιεί HTML, CSS και JavaScript για το frontend. Η βάση δεδομένων που χρησιμοποιείται στην εφαρμογή είναι η sqlite3.

Η εφαρμογή υποστηρίζει τη δημιουργία και διαχείριση χρηστών, με τους κωδικούς των χρηστών να κρυπτογραφούνται χρησιμοποιώντας τον αλγόριθμο κρυπτογράφησης pbkdf2_sha256 (το PBKDF2 χρησιμοποιείται ως συνάρτηση παραγωγής κλειδιών, με το HMAC-SHA256 ως συνάρτηση κατακερματισμού.). Το Σύστημα κρυπτογράφησης προσθέτει αλάτι και κρυπτογραφεί τα δεδομένα ύστερα επαναλαμβάνει αυτήν την διαδικασία 720 χιλιάδες φορές για την εξασφάλιση της ασφάλειας της βάσης δεδομένων. Στην εφαρμογή διαθέτετε μενού διαγνωστικών εξετάσεων, που προτρέπει τους χρήστες να κάνουν έξι διαφορετικές διαγνωστικές εξετάσεις, καθεμία από τις οποίες χρησιμοποιεί έναν συγκεκριμένο αλγόριθμο Transfer Learning . Οι αλγόριθμοι που χρησιμοποιούνται για κάθε εξέταση είναι οι εξής:

VGG19 για διάγνωση καρκίνου παχέος εντέρου,

Xception για διάγνωση καρκίνου εγκεφάλου

DenseNet 201 για καρκίνου πνεύμονα

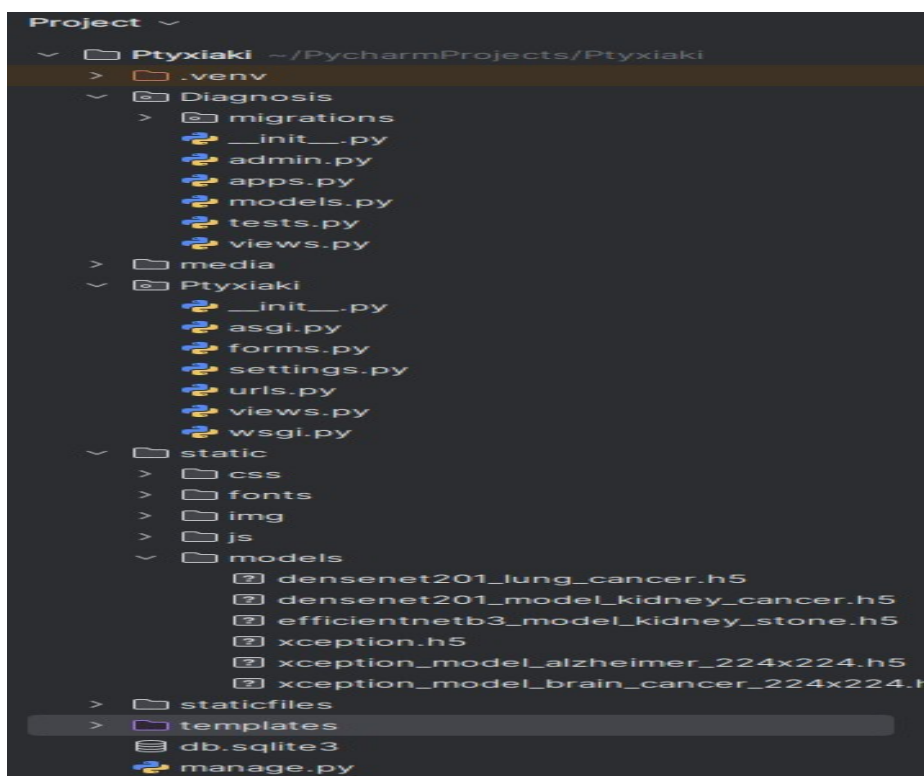
Xception για διάγνωση Αλτσχάιμερ

EfficientNet B3 για διάγνωση πέτρες νεφρών.

DenseNet 201 για διάγνωση καρκίνου νεφρών.

Οι χρήστες χρειάζεται μόνο να ανεβάσουν μια εικόνα για κάθε εξέταση, και το σύστημα επεξεργάζεται την εικόνα για να την προσαρμόσει στις απαιτούμενες διαστάσεις για είσοδο στο νευρωνικό δίκτυο, εξασφαλίζοντας συμβατότητα ανεξαρτήτως μεγέθους εικόνας. Κάθε χρήστης έχει πρόσβαση μόνο στο δικό του ιστορικό εξετάσεων, με την εφαρμογή να φιλτράρει και να εμφανίζει μόνο τα αρχεία εξετάσεων που αφορούν τον συγκεκριμένο χρήστη, εξασφαλίζοντας την ιδιωτικότητα και την ασφάλεια των δεδομένων.

8.1) Δομή εφαρμογής



1. Κεντρικός Φάκελος Ptyxiaki (Root Directory): Ο κεντρικός φάκελος περιλαμβάνει τα βασικά αρχεία διαχείρισης του project, Το manage.py λειτουργεί ως βασικό εργαλείο γραμμής εντολών για τη διαχείριση του project, και το db.sqlite3 αντιπροσωπεύει τη βάση δεδομένων SQLite.

2. `.venv`: Περιέχει το εικονικό περιβάλλον (virtual environment) το οποίο απομονώνει τις απαιτούμενες εξαρτήσεις της εφαρμογής. Η χρήση του εικονικού περιβάλλοντος διασφαλίζει την αποφυγή συγκρούσεων με το γενικό περιβάλλον της Python.

3. Εφαρμογή `Diagnosis`: Ο υποφάκελος `Diagnosis` συνιστά την κύρια εφαρμογή του project και περιλαμβάνει:

- `migrations`: Φάκελος που αποθηκεύει τα αρχεία που χρησιμοποιούνται από το Django για την παρακολούθηση και εφαρμογή αλλαγών στο σχήμα της βάσης δεδομένων.
- `admin.py`: Αρχείο που ρυθμίζει τη διαμόρφωση της διεπαφής διαχειριστή της εφαρμογής.
- `apps.py`: Περιέχει την κλάση ρυθμίσεων της εφαρμογής `Diagnosis`, επιτρέποντας την εύκολη διαχείρισή της.
- `models.py`: Περιγράφει τις δομές δεδομένων μέσω των μοντέλων, τα οποία μετασχηματίζονται σε σχήματα βάσης δεδομένων.
- `tests.py`: Παρέχει δομές για την ανάπτυξη δοκιμών μονάδας (unit tests), εξασφαλίζοντας την ακεραιότητα και αξιοπιστία του κώδικα.
- `views.py`: Περιλαμβάνει τη λογική για την επεξεργασία HTML αιτημάτων και την παροχή των κατάλληλων αποκρίσεων προς τον χρήστη.

4. `Ptychiaki`: Είναι ο κύριος φάκελος διαμόρφωσης της εφαρμογής, περιέχει:

- `__init__.py`: Αρχείο που χαρακτηρίζει τον φάκελο ως Python πακέτο.
- `asgi.py`: Ρυθμίσεις για το ASGI (Asynchronous Server Gateway Interface), για την υποστήριξη ασύγχρονων διαδικτυακών πρωτοκόλλων.
- `settings.py`: Αρχείο που περιέχει τις ρυθμίσεις της εφαρμογής, όπως οι εγκατεστημένες εφαρμογές, το middleware και οι παράμετροι της βάσης δεδομένων.
- `urls.py`: Χαρτογράφηση των URLs στις αντίστοιχες συναρτήσεις προβολών (views), για τη δρομολόγηση των αιτημάτων.
- `views.py`: Συμπληρωματικές συναρτήσεις αιτημάτων.
- `wsgi.py`: Ρυθμίσεις για το WSGI (Web Server Gateway Interface).

5. `media`: Ο φάκελος `media` χρησιμοποιείται για την αποθήκευση αρχείων που ανεβάζουν οι χρήστες.

6. `static`: Περιέχει στατικά αρχεία που χρησιμοποιούνται για το frontend της εφαρμογής, ταξινομημένα σε:

Χρήση Τεχνητής Νοημοσύνης στην Ιατρική - Αντώνης Κονι

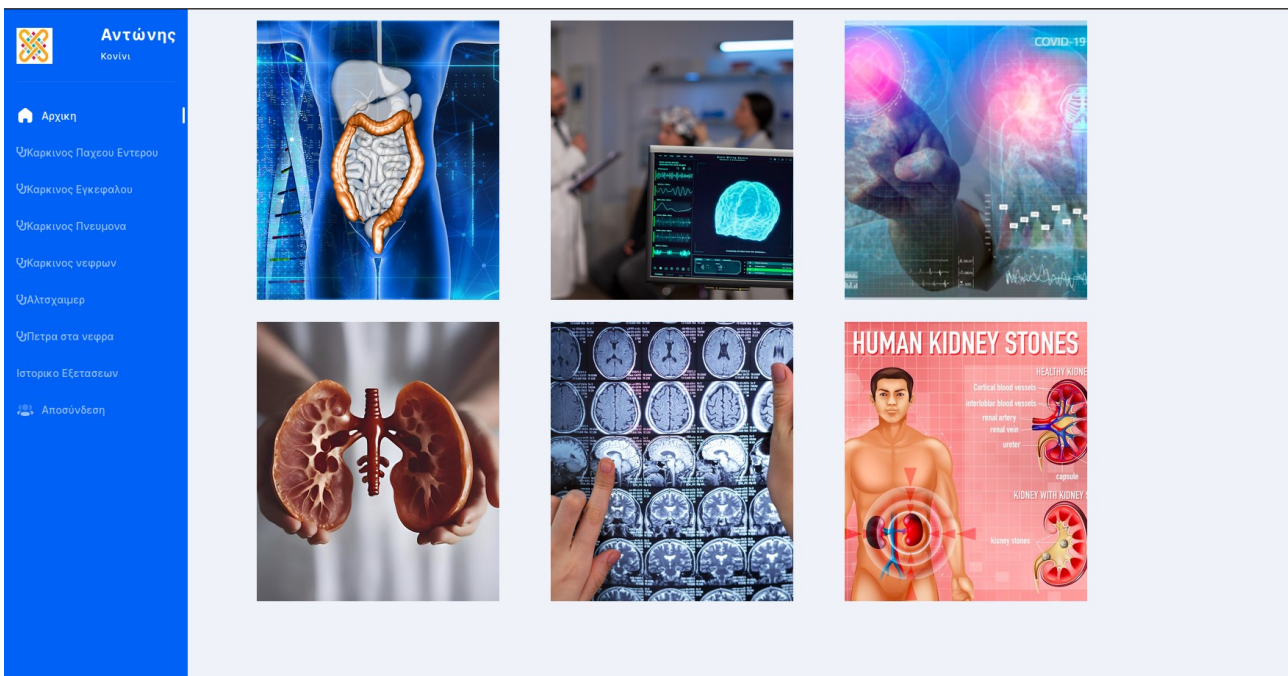
- css: Αρχεία css,
- fonts: Γραμματοσειρές.
- img: Εικόνες .
- js: Αρχεία JavaScript .
- models: Φάκελος που περιέχει προεκπαιδευμένα μοντέλα μηχανικής όρασης σε μορφή `.h5`, τα οποία χρησιμοποιούνται για την εκτέλεση διαγνώσεων ασθενειών.

7. staticfiles: Φάκελος που χρησιμοποιείται για τη συλλογή και παροχή στατικών αρχείων.

8. templates: Περιέχει τα αρχεία HTML που χρησιμοποιούνται για την παρουσίαση του frontend.

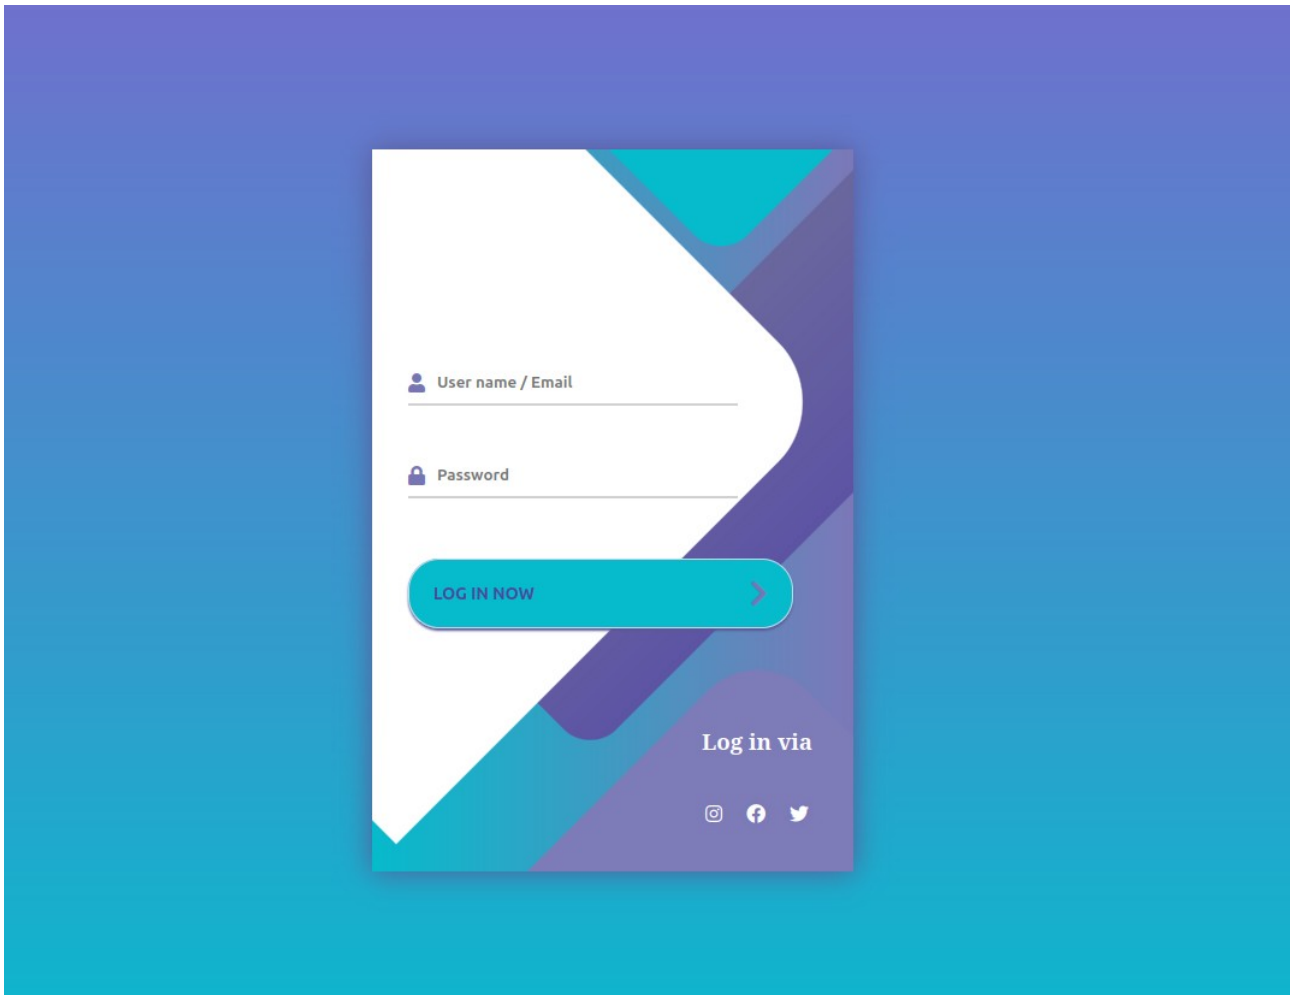
Αρχεία HTML:

index.html: Λειτουργεί ως η αρχική σελίδα (homepage) της εφαρμογής.



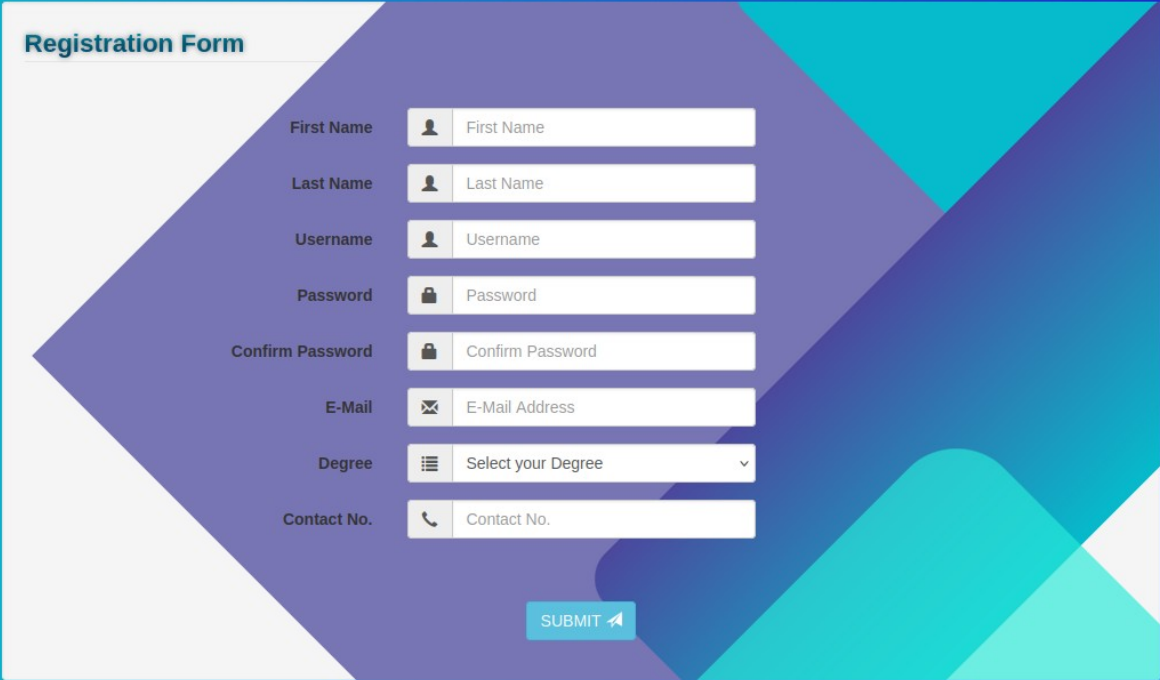
Εικόνα 13: index.html

login.html: Η σελίδα σύνδεσης (login page) επιτρέπει στους χρήστες να εισάγουν διαπιστευτήρια πρόσβασης για να συνδεθούν.



Εικόνα 14: login.html

signup.html: Η σελίδα εγγραφής (sign-up page) επιτρέπει στους νέους χρήστες να δημιουργήσουν έναν λογαριασμό.



The image shows a registration form titled "Registration Form" set against a blue and purple geometric background. The form contains the following fields:

- First Name: Input field with a person icon.
- Last Name: Input field with a person icon.
- Username: Input field with a person icon.
- Password: Input field with a lock icon.
- Confirm Password: Input field with a lock icon.
- E-Mail: Input field with an envelope icon.
- Degree: Dropdown menu with the text "Select your Degree".
- Contact No.: Input field with a telephone icon.

A blue "SUBMIT" button with a right-pointing arrow is located at the bottom right of the form.

Εικόνα 15: Signup.html

result.html - result6.html: οι σελίδες χρησιμοποιούνται για την προβολή αποτελεσμάτων διάγνωσης από τα διαφορετικά μοντέλα μηχανικής όρασης.

- **result.html:** Εμφανίζει αποτελέσματα για την πρώτη κατηγορία διάγνωσης, “καρκίνος του παχέος εντέρου”.
- **result2.html - result6.html:** Παρόμοια με την πρώτη σελίδα αποτελεσμάτων, αλλά κάθε μία εξυπηρετεί την παρουσίαση αποτελεσμάτων από διαφορετικό διαγνωστικό σύστημα.



Εικόνα 16: Result.html

results_list.html: Παρέχει μια συνοπτική λίστα των διαγνώσεων του χρήστη.

Αποτελεσματα Εξετασεων καρκινου του εγκεφάλου	
Date	Result
July 10, 2024, 12:38 p.m.	Predicted Class: 1
July 10, 2024, 12:41 p.m.	Predicted Class: 1
July 11, 2024, 7:41 a.m.	Predicted Class: 0
July 11, 2024, 11:37 a.m.	Predicted Class: 0
July 11, 2024, 12:24 p.m.	Predicted Class: 0
Oct. 3, 2024, 2:19 p.m.	Predicted Class: 0
Oct. 25, 2024, 12:30 p.m.	Predicted Class: 1
Oct. 25, 2024, 12:53 p.m.	Predicted Class: 0

Αποτελεσματα Εξετασεων καρκινου του πνευμονα	
Date	Result
July 10, 2024, 1:08 p.m.	Predicted Class: 1
July 11, 2024, 4:07 p.m.	Predicted Class: 0
Oct. 25, 2024, 12:31 p.m.	Predicted Class: 0
Oct. 25, 2024, 12:54 p.m.	Predicted Class: 1
Oct. 25, 2024, 1:25 p.m.	Predicted Class: 1
Oct. 25, 2024, 1:35 p.m.	Predicted Class: 1
Oct. 25, 2024, 2:44 p.m.	Predicted Class: 1

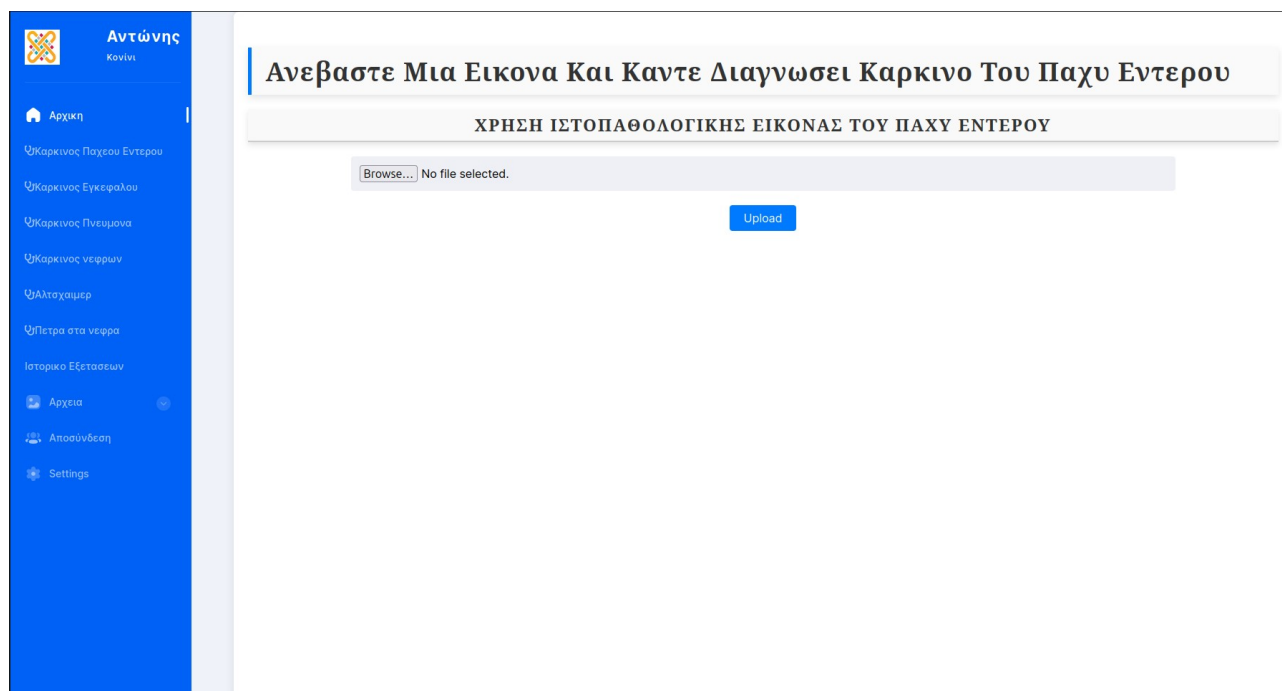
Αποτελεσματα Εξετασεων καρκινου των νεφρων	
Date	Result

Εικόνα 17: *result_list.html*

upload.html - upload6.html: Οι σελίδες είναι σχεδιασμένες για τη μεταφόρτωση εικόνων από τους χρήστες, οι οποίες στη συνέχεια επεξεργάζονται από τα αντίστοιχα μοντέλα μηχανικής όρασης.

- **upload.html:** Χρησιμοποιείται για τη μεταφόρτωση εικόνας για την διάγνωση “καρκίνου του παχέος εντέρου”.

upload2.html - upload6.html: Παρόμοια με την πρώτη σελίδα μεταφόρτωσης, αλλά κάθε μία προορίζεται για τη μεταφόρτωση εικόνων για διαφορετικές ασθένειες.



Εικόνα 18: upload.html

9) Αναφορές

- [1] Mingxing Tan και Quoc V. Le στην εργασία τους με τίτλο "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," η οποία παρουσιάστηκε στο Συνέδριο για τη Νευροπληροφορική (NeurIPS) το 2019.
<https://arxiv.org/abs/1905.11946>
<https://doi.org/10.48550/arXiv.1905.11946>
Ημερομηνία επίσκεψης: Μάιος 2024

[2] "Densely Connected Convolutional Networks" από τους Gao Huang, Zhuang Liu, Laurens van der Maaten και Kilian Q. Weinberger παρουσιάστηκε IEEE Conference on Computer Vision and Pattern Recognition (CVPR) το 2017.

<https://arxiv.org/abs/1608.06993>

<https://doi.org/10.48550arXiv.1608.06993>

Ημερομηνία επίσκεψης: Μάιος 2024

[3] "Very Deep Convolutional Networks for Large-Scale Image Recognition," των Karen Simonyan και Andrew Zisserman. Το άρθρο παρουσιάστηκε στο Διεθνές Συνέδριο για την Αναπαράσταση Μάθησης (International Conference on Learning Representations-ICLR) το 2015.

<https://arxiv.org/abs/1409.1556>

<https://doi.org/10.48550/arXiv.1409.1556>

Ημερομηνία επίσκεψης: Μάιος 2024

[4] Kaiming He, Xiangyu Zhang, Shaoqing Ren και Jian Sun στο άρθρο τους με τίτλο "Deep Residual Learning for Image Recognition," το οποίο παρουσιάστηκε στο IEEE Conference on Computer Vision and Pattern Recognition (CVPR) το 2016.

<https://arxiv.org/abs/1512.03385>

<https://arxiv.org/abs/1512.03385>

Ημερομηνία επίσκεψης: Μάιος 2024

[5] *Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke και Andrew Rabinovich. Το άρθρο με τίτλο "Going Deeper with Convolutions," που δημοσιεύτηκε στο Συνέδριο Οράσεως Υπολογιστών και Αναγνώρισης Προτύπων (IEEE Conference on Computer Vision and*

Pattern Recognition-CVPR) το 2014.

Ημερομηνία επίσκεψης: Μάιος 2024

[6] Xception: Deep Learning with Depthwise Separable Convolutions," το οποίο δημοσιεύτηκε στο IEEE Conference on Computer Vision and Pattern Recognition(CVPR) το 2017.

<https://arxiv.org/abs/161>

<https://doi.org/10.48550/arXiv.1610.02357>

Ημερομηνία επίσκεψης: Μάιος 2024

[7]- Diagnosis of lung cancer based on CT scans using CNN (H. F. Al-Yasriy, M. S. Al-Husieny, F. Y. Mohsen, E. A. Khalil, and Z. S. Hassan, "Diagnosis of Lung Cancer Based on CT Scans Using CNN," IOP Conference Series: Materials Science and Engineering, vol. 928, 2020.) Ημερομηνία επίσκεψης: Μάιος 2024

[8] - Evaluation of SVM performance in the detection of lung cancer in marked CT scan dataset (H. F. Kareem, M. S. A.-Husieny, F. Y. Mohsen, E. A. Khalil, and Z. S. Hassan, "Evaluation of SVM performance in the detection of lung cancer in marked CT scan dataset," Indonesian Journal of Electrical Engineering and Computer Science, vol. 21, no.3,pp.1731-1738,2021,doi:10.11591/ijeecs.v21.i3.pp1731-1738.)

Ημερομηνία επίσκεψης: Μάιος 2024

[9]- The IQ-OTH/NCCD lung cancer dataset (alyasriy, hamdalla; AL-Huseiny, Muayed (2023), "The IQ-OTH/NCCD lung cancer dataset", Mendeley Data, V4, doi: 10.17632/bhmdr45bh2.4)

Ημερομηνία επίσκεψης: Μάιος 2024

[10] Borkowski AA, Bui MM, Thomas LB, Wilson CP, DeLand LA, Mastorides SM. Lung and Colon Cancer Histopathological Image Dataset (LC25000). arXiv:1912.12142v1 [eess.IV],2019

<https://arxiv.org/abs/1912.12142v1>

Ημερομηνία επίσκεψης: Μάιος 2024

[11]<https://www.kaggle.com/datasets/andrewmvd/lung-and-colon-cancer-histopathological-images>

Ημερομηνία επίσκεψης: Μάιος 2024

[12] https://github.com/tampapath/lung_colon_image_set

Ημερομηνία επίσκεψης: Μάιος 2024

[13]<https://www.kaggle.com/datasets/prathamgrover/brain-tumor-classification?select=Training>

[14]https://app.dimensions.ai/discover/publication?and_subset_figshare_doi=10.6084%2Fm9.figshare.1512427

Ημερομηνία επίσκεψης: Μάιος 2024

[15]<https://www.kaggle.com/datasets/sartajbhuvaji/brain-tumor-classification-mri>

Ημερομηνία επίσκεψης: Μάιος 2024

[16]https://figshare.com/articles/dataset/brain_tumor_dataset/1512427

Ημερομηνία επίσκεψης: Μάιος 2024

[17][arXiv:2310.17720](https://arxiv.org/abs/2310.17720)

Ημερομηνία επίσκεψης: Μάιος 2024

[18]<https://doi.org/10.48550/arXiv.2310.17720>

Ημερομηνία επίσκεψης: Μάιος 2024

[19] [Al-Dhabyani W, Gomaa M, Khaled H, Fahmy A. Dataset of breast ultrasound images. Data in Brief. 2020 Feb;28:104863. DOI: 10.1016/j.dib.2019.104863](#)

Ημερομηνία επίσκεψης: Μάιος 2024

[20] https://www.kaggle.com/datasets/aryashah2k/breast-ultrasound-images_dataset

Ημερομηνία επίσκεψης: Μάιος 2024

[21] <https://www.kaggle.com/datasets/paultimothymooney/chest-xray-pneumonia>

Ημερομηνία επίσκεψης: Μάιος 2024

[22] [http://www.cell.com/cell/fulltext/S0092-8674\(18\)30154-5](http://www.cell.com/cell/fulltext/S0092-8674(18)30154-5)

Ημερομηνία επίσκεψης: Μάιος 2024

[23] Data: <https://data.mendeley.com/datasets/rscbjbr9sj/2>

License: [CC BY 4.0](#) Citation: [http://www.cell.com/cell/fulltext/S0092-8674\(18\)30154-5](http://www.cell.com/cell/fulltext/S0092-8674(18)30154-5)

Ημερομηνία επίσκεψης: Μάιος 2024

[24] Feltes, B.C.; Chandelier, E.B.; Grisci, B.I.; Dorn, M. (2019) *CuMiDa: An Extensively Curated Microarray Database for Benchmarking and Testing of Machine Learning Approaches in Cancer Research*. Journal of Computational Biology, 26 (4), 376-386.

[<https://doi.org/10.1089/cmb.2018.0238>]

Ημερομηνία

επίσκεψης:

Μάιος

2024

[25] Grisci, B. I., Feltes, B. C., & Dorn, M. (2019). *Neuroevolution as a tool for microarray gene expression pattern identification in cancer research*. Journal of biomedical informatics, 89, 122-133. [<https://doi.org/10.1016/j.jbi.2018.11.013>]

Ημερομηνία επίσκεψης: Μάιος 2024

[26]<http://sbcbr.inf.ufrgs.br/cumida>

Ημερομηνία επίσκεψης: Μάιος 2024

[27] <https://www.kaggle.com/datasets/brunogrisci/brain-cancer-gene-expression-cumida>

Ημερομηνία επίσκεψης: Μάιος 2024

[28]http://sbcbr.inf.ufrgs.br/carbm/static/cumida/Genes/Brain/GSE50161/Brain_GSE50161.csv

Ημερομηνία επίσκεψης: Μάιος 2024

[29]<http://sbcbr.inf.ufrgs.br/cumida>

Ημερομηνία επίσκεψης: Μάιος 2024

[30] Centers for Disease Control and prevention (CVC) <https://www.cdc.gov/>

[31] <https://www.kaggle.com/datasets/fedesoriano/stroke-prediction-dataset>

Ημερομηνία επίσκεψης: Μάιος 2024

[32] <https://catalog.data.gov/>

Ημερομηνία επίσκεψης: Μάιος 2024

[33] <https://www.kaggle.com/datasets/andrewmvd/ocular-disease-recognition-odir5k>

Ημερομηνία επίσκεψης: Μάιος 2024

[34] <https://adni.loni.usc.edu/>

Ημερομηνία επίσκεψης: Μάιος 2024

[35] <https://www.kaggle.com/datasets/sachinkumar413/alzheimermri-datasethttps://www.kaggle.com/datasets/uraninjo/augmented-alzheimer-mri-dataset>

Ημερομηνία επίσκεψης: Μάιος 2024

[36] https://archive.ics.uci.edu/ml/datasets/Chronic_Kidney_Disease
Ημερομηνία επίσκεψης: Μάιος 2024

[37] <https://www.kaggle.com/datasets/mansoordaku/ckdisease>

Ημερομηνία επίσκεψης: Μάιος 2024

[38] <https://www.kaggle.com/datasets/abhia1999/chronic-kidney-disease>

Ημερομηνία επίσκεψης: Μάιος 2024

[39] <https://www.kaggle.com/datasets/prasoonkottarathil/polycystic-ovary-syndrome-pcos>

Ημερομηνία επίσκεψης: Μάιος 2024

[40] <https://www.kaggle.com/datasets/anaghachoudhari/pcos-detection-using-ultrasound-images>

Ημερομηνία επίσκεψης: Μάιος 2024

[41] <https://www.kaggle.com/datasets/tommyngx/kneeoa>

Ημερομηνία επίσκεψης: Μάιος 2024

[42] Chen, Pingjun (2018), "Knee Osteoarthritis Severity Grading Dataset", Mendeley Data, V1, doi: [10.17632/56rmx5bjcr.1](https://doi.org/10.17632/56rmx5bjcr.1)

Ημερομηνία

επίσκεψης:

Μάιος

2024

[43] Rajaraman S, Antani SK, Poostchi M, Silamut K, Hossain MA, Maude, RJ, Jaeger S, Thoma GR. (2018) Pre-trained convolutional neural networks as feature extractors toward improved Malaria parasite detection in thin blood smear images.

[44] <https://doi.org/10.7717/peerj.4568>

[45] <https://www.kaggle.com/datasets/itsdaniyal/malerial-cell-classification-dataset>

[46] Islam MN, Hasan M, Hossain M, Alam M, Rabiul G, Uddin MZ, Soyly A. Vision transformer and explainable transfer learning models for auto detection of kidney cyst, stone and tumor from CT-radiography. Scientific Reports. 2022 Jul 6;12(1):1-4

[47] “ A 3D densely connected convolutional neural network with connection-wise attention mechanism for Alzheimer's disease classification “Author(s) IJie Zhang , Bowen Zheng , Ang Gao , Xin Feng , Dong Liang , Xiaojing Long

<https://doi.org/10.1016/j.mri.2021.02.001>

Ημερομηνία επίσκεψης: Μάιος 2024

[48] “ Nagori, A., Dhingra, L.S., Bhatnagar, A. et al. Predicting Hemodynamic Shock from Thermal Images using Machine Learning. Sci Rep 9, 91 (2019). “
<https://doi.org/10.1038/s41598-018-36586-8>

Ημερομηνία επίσκεψης: Μάιος 2024

Αναφορές Κώδικα

[1] <https://freefrontend.com/css-login-forms/>

Χρήση Τεχνητής Νοημοσύνης στην Ιατρική - Αντώνης Κονιλι

[2] <https://codepen.io/juff03/pen/OXaXRG>