

Ιόνιο Πανεπιστήμιο
Τμήμα Πληροφορικής



Εφαρμογές Βαθιάς Μάθησης Για Την Κατηγοριοποίηση
Δερμοσκοπικών Εικόνων

Αυγούστης Ανδρέας
Επιβλέπων : Θεμιστοκλής Έξαρχος

Επιβλέπων

Θεμιστοκλής Έξαρχος , Επίκουρος Καθηγητής,

Ιόνιο πανεπιστήμιο

Τριμελής Επιτροπή

Θεμιστοκλής Έξαρχος , Επίκουρος Καθηγητής,

Ιόνιο πανεπιστήμιο

Φοίβος Μυλωνάς, Αναπληρωτής Καθηγητής,

Ιόνιο πανεπιστήμιο

Κάτια – Λήδα Κερμανίδου, Αναπληρώτρια Καθηγήτρια,

Ιόνιο πανεπιστήμιο

Περίληψη

Οι καρκίνοι του δέρματος είναι οι πλέον συχνοί καρκίνοι. Μέσο της τεχνολογίας μπορούμε να εντοπίσουμε σε γρήγορο χρονικό διάστημα το σημείο στο οποίο είναι ο καρκίνος. Για την εκτίμηση του καρκίνου θα πρέπει να δημιουργήσουμε εικόνες στα σημεία του καρκίνου του δέρματος. Η δημιουργία των εικόνων είναι εύκολη διαδικασία. Η αξιολόγηση των εικόνων και η διάγνωση του καρκίνου απαιτεί χρόνο. Γι' αυτό χρησιμοποιούνται τεχνικές μηχανικής μάθησης και συγκεκριμένα στο πεδίο της βαθιά μάθησης με σκοπό την έγκαιρη διάγνωση.

Στην εργασία αυτή θα γίνει βιβλιογραφική ανασκόπηση σε ήδη υπάρχουσες έρευνες που έχουν επιτευχθεί στην διάγνωση του καρκίνου του δέρματος μέσω τεχνικών βαθιάς μάθησης, δημιουργία συνελκτικού νευρωνικού δικτύου για ταξινόμηση και κατηγοριοποίηση δερμοσκοπικών εικόνων σε γλώσσα pythοn με αξιοποίηση βιβλιοθηκών που χρησιμοποιούνται στην βαθιά μάθηση, εξαγωγή αποτελεσμάτων του συνελκτικού νευρωνικού δικτύου που αφορούν στην αξιοπιστία του μοντέλου, σύγκριση αποτελεσμάτων με τις ήδη υπάρχουσες έρευνες. Ο κώδικας του συνελκτικού θα είναι διαθέσιμος στο github(<https://github.com/p15avgo/colab>) και στο παράρτημα.

Πίνακας περιεχομένων

Περίληψη	3
Πίνακας περιεχομένων	4
Κατάλογος Σχημάτων	5
1.Εισαγωγή	6
1.1Μελάνωμα	6
1.2 Συμπτώματα	9
1.3 Διάγνωση	11
1.4 Θεραπεία.....	11
2.Εφαρμογή	12
2.1 Μηχανική Μάθηση	12
2.2 Βαθιά Μάθηση	13
3.Βιβλιογραφική Ανασκόπηση	16
4.Μεθοδολογία	22
4.1 Αρχιτεκτονική	22
4.2 Δεδομένα	23
4.3 Εργαλεία	23
4.4 Μέτρα απόδοσης	24
5.Συνελικτικό Νευρωνικό Δίκτυο	25
5.1 Επεξεργασία Δεδομένων	25
5.2 Αρχιτεκτονική μοντέλου	25
5.3 Εκπαίδευση μοντέλου	28
5.4 Πρόβλεψη	30
5.5 Πίνακας Σύγκρισης και Αποτελέσματα	31
6.Συγκριτικό Αποτελεσμάτων	34
6.1 Ποσοτικό	34
6.2 Ποιοτικό	36
7.Συμπεράσματα	36
8.Μελλοντικές Εφαρμογές.....	37
Παράρτημα	38
Βιβλιογραφία	43

Κατάλογος Σχημάτων

1 Εμφάνιση Μελανώματος	6
2 Διάφορες Μορφές Μελανώματος	9
3 Διαφορά Φυσιολογικού Σπίλου με Μελανώματος	10
4 ABCDE κανόνας για έγκαιρη ανίχνευση	11
5 Χειρουργική Επέμβαση Μελανώματος	12
6 Σταδιακή απεικονίσει της εξέλιξης της τεχνητής νοημοσύνης	13
7 Διαφορά μηχανικής με βαθιάς μάθησης	14
8 Παράδειγμα συνέλιξης 2 πινάκων	15
9 Παράδειγμα Αρχιτεκτονικής Αναδρομικού Νευρωνικού Δικτύου	16
10 Παράδειγμα Αρχιτεκτονικής Συνελικτικού Νευρωνικού Δικτύου	23
11 Σύνολο δεδομένων για το συνελικτικό από Jeremy Kawahara et al[10]	23
12 Αρχιτεκτονική Επεξεργασίας Δεδομένων	27
13 Αρχιτεκτονική Εκπαίδευσης	27
14 Σχήμα Μοντέλου με παραμέτρους	28
15 Δείγμα εκτέλεσης της εκπαίδευσης	29
16 Train vs Test στην Ακρίβεια	29
17 Train loss vs Test Loss	30
18 Ταξινομημένες κατηγορίες	30
19 Δείγματα εκτέλεσης πρόβλεψης.....	31
20 Δείγματα πίνακας σύγχυσης	32
21 Δείγματα Αποτελεσμάτων απόδοσης	33
22 Διαγραμματική Απεικόνιση	36

1 Εισαγωγή

Σε αυτό το κεφάλαιο θα γίνει εκτενής αναφορά στο μελάνωμα αλλά και στον τρόπο διάγνωσης και θεραπείας του.


1.1 Μελάνωμα

Οι καρκίνοι του δέρματος είναι οι πλέον συχνοί καρκίνοι. Μέσο της τεχνολογίας μπορούμε να εντοπίσουμε σε γρήγορο χρονικό διάστημα το σημείο στο οποίο είναι ο καρκίνος. Για την εκτίμηση του καρκίνου θα πρέπει να δημιουργήσουμε εικόνες στα σημεία του καρκίνου του δέρματος. Σύμφωνα με έρευνες υπάρχουν 3 είδη καρκίνων στο δέρμα:

- Καρκίνος βασικο-κυττάρων
- Καρκίνος πλακωδών
- Μελάνωμα

Ο καρκίνος βασικο-κυττάρων και ο καρκίνος πλακωδών είναι γνωστά ως καρκίνοι μη μελανώματος.

Το μελάνωμα είναι μια μορφή καρκίνου στο σώμα που αναπτύσσεται από τα μελανοκύτταρα. Το μελάνωμα μπορεί να εμφανιστεί σε οποιοδήποτε σημείο του σώματος που περιέχει μελανοκύτταρα, ακόμα και στα μάτια. Είναι επικίνδυνη μορφή καρκίνου σε περίπτωση που δεν το εντοπίσουμε και θεραπεύσουμε στα πρώτα στάδια. Συχνά, η πρώτη ένδειξη για το μελάνωμα είναι αλλαγή στο μέγεθος, σχήμα ή χρώμα ενός σπύλου (ελιάς). Οι σπίλοι είναι συνήθως μικροί και μπορεί να υπάρχει από τη γέννηση ή μπορεί να εμφανιστεί αργότερα.



Εικόνα 1 Εμφάνιση Μελανώματος

Παγκοσμίως, κρούσματα μελανώματος εμφανίζονται συχνότερα στην Αυστραλία και τη Νέα Ζηλανδία, όπου είναι 3 φορές συχνότερα από ό,τι στην Ευρώπη. Από την άλλη πλευρά, το μελάνωμα είναι πολύ σπάνιο σε αφρικανικές και ασιατικές χώρες.

Στην Ευρώπη, περίπου 1 ανά 100 ανθρώπους θα αναπτύξει μελάνωμα κάποια στιγμή στη ζωή του, αλλά υπάρχουν σημαντικές διαφοροποιήσεις από τη μία χώρα στην άλλη. Ετησίως, διαγιγνώσκονται με μελάνωμα περίπου 15 ανά 100.000 άνθρωποι. Αυτός ο αριθμός αυξάνεται σε όλες σχεδόν τις ευρωπαϊκές χώρες. Το μελάνωμα είναι ελαφρώς πιο συχνό στις γυναίκες από ό,τι στους άνδρες.

Το μελάνωμα είναι η πιο συχνή στην Ελβετία, την Ολλανδία και τις Σκανδιναβικές χώρες (Νορβηγία, Σουηδία και Δανία), όπου περίπου 20 ανά 100.000 ανθρώπους διαγιγνώσκονται κάθε χρόνο με μελάνωμα. και είναι λιγότερο συχνό στις Μεσογειακές χώρες όπου διαγιγνώσκονται 3-5 ανά 100.000 ανθρώπους κάθε χρόνο.


Σήμερα, δεν είναι σαφές γιατί εμφανίζεται το μελάνωμα. Ορισμένοι παράγοντες κινδύνου έχουν αναγνωριστεί. Ο παράγοντας κινδύνου αυξάνει τον κίνδυνο εμφάνισης καρκίνου, αλλά δεν είναι ούτε αναγκαίος ούτε επαρκής για να προκαλέσει καρκίνο. Ένας παράγοντας κινδύνου δεν αποτελεί από μόνος του ένα αίτιο.

Μερικοί άνθρωποι με αυτούς τους παράγοντες κινδύνου δεν θα αναπτύξουν ποτέ μελάνωμα ενώ άλλοι χωρίς κανένα από αυτούς τους παράγοντες κινδύνου θα αναπτύξουν μελάνωμα.

Οι κύριοι παράγοντες κινδύνου του μελανώματος είναι:

Τύπος δέρματος : άτομα με ανοιχτόχρωμο δέρμα έχουν μεγαλύτερο κίνδυνο να αναπτύξουν μελάνωμα από τους ανθρώπους με σκούρο χρώμα δέρματος. Ο μεγαλύτερος κίνδυνος αφορά τα άτομα με κόκκινα μαλλιά και φακίδες. Το μελάνωμα είναι πολύ σπάνιο σε μαύρους ή Ασιάτες. Όταν αυτό συμβαίνει, είναι συνήθως ένας ειδικός τύπος μελανώματος που ονομάζεται φακοειδές μελάνωμα το οποίο εμφανίζεται στα πέλματα, στις παλάμες, ή κάτω από τα νύχια.

Σπίλοι : ο σπίλος είναι ο ιατρικός όρος για τις ελιές. Η πλειοψηφία των σπίλων ποτέ δεν θα μετατραπεί σε καρκίνο, αλλά η παρουσία πολλών (πάνω από 100) ή η ύπαρξη άτυπων σπίλων υποδεικνύει αυξημένο ατομικό κίνδυνο ανάπτυξης μελανώματος.



Εικόνα 2 Διάφορες Μορφές Μελανώματος

Συνεπώς, όταν υπάρχουν πολλαπλοί κοινοί σπίλοι αυξάνεται ο κίνδυνος ανάπτυξης μελανώματος. Ο κίνδυνος αυξάνεται με τον αριθμό των σπύλων και είναι ιδιαίτερα υψηλός όταν ο αριθμός των σπύλων είναι πάνω από 100.

Όταν υπάρχουν 3 ή περισσότεροι άτυποι σπίλοι αυξάνεται ο κίνδυνος ανάπτυξης μελανώματος. Ένας άτυπος σπίλος ορίζεται ως ο σπίλος που παρουσιάζει τουλάχιστον 3 από τα ακόλουθα «ABCD» χαρακτηριστικά: Ασυμμετρία στο σχήμα του, Ανώμαλο ή ασαφές περίγραμμα, Χρώμα που ποικίλλει από τη μια περιοχή στην άλλη και Δυναμική διαχρονική εξέλιξη σχετικά με το σχήμα, το χρώμα ή το μέγεθος, δηλαδή οποιαδήποτε αλλαγή σχήματος, χρώματος ή μεγέθους με τον χρόνο.

Οι συγγενείς σπίλοι είναι ελιές που υπάρχουν από τη γέννηση. Μεγάλοι (>5 εκατοστά) συγγενείς σπίλοι έχουν αυξημένο κίνδυνο να μετατραπούν σε μελάνωμα. Άτομα με μεγάλους συγγενείς σπίλους πρέπει να παρακολουθούνται σε τακτική βάση.

Έκθεση στον ήλιο: η φυσική έκθεση στην υπεριώδη (UV) ακτινοβολία που εκπέμπεται από τον ήλιο είναι ένας σημαντικός παράγοντας κινδύνου για ανάπτυξη μελανώματος. Οι παρακάτω παράγοντες αυξάνουν τον κίνδυνο σε κάθε στάδιο της ζωής, αλλά είναι δυσμενέστεροι όταν η έκθεση συμβαίνει κατά την πρώιμη παιδική ηλικία. Η διαλείπουσα έκθεση στον ήλιο, συνήθως για λόγους αναψυχής, αυξάνει τον κίνδυνο ανάπτυξης μελανώματος.

Το ηλιακό έγκαυμα αυξάνει σημαντικά τον κίνδυνο ανάπτυξης μελανώματος, και ιδιαίτερα τα ηλιακά εγκαύματα, κατά τη διάρκεια της παιδικής ηλικίας..

Η χρήση αντηλιακού μπορεί φυσικά να μειώσει τον κίνδυνο ανάπτυξης μελανώματος θα πρέπει όμως να συνδυάζεται με άλλους απλούς κανόνες όπως η αποφυγή της έκθεσης στον ήλιο μεταξύ 11π.μ. και 3μ.μ.(ώρα μέγιστης ηλιακής

έκθεσης), και η κάλυψη με ρούχα, καπέλο και γυαλιά ηλίου, κατά την έκθεση στον ήλιο (ακόμη και σε σημεία έμμεσης έκθεσης όπως π.χ. κάτω από την ομπρέλα).

Τεχνητό Μαύρισμα: Η έκθεση σε τεχνητή ακτινοβολία UV για μαύρισμα αυξάνει τον κίνδυνο ανάπτυξης μελανώματος ιδιαίτερα όταν αυτό γίνεται πριν από την ηλικία των 30 ετών.

Ιστορικό μελανώματος: Η ύπαρξη ατομικού ιστορικού μελανώματος αυξάνει τον κίνδυνο υποτροπής ή επανεμφάνισης μελανώματος σε άλλο σημείο του σώματος. Η ύπαρξη συγγενούς πρώτου βαθμού (γονείς, αδέρφια, παιδιά) με ιστορικό μελανώματος αυξάνει επίσης την πιθανότητα εμφάνισης. Είναι γνωστές κάποιες κληρονομούμενες γονιδιακές μεταλλάξεις όπως η μετάλλαξη CDKN2A, αλλά τέτοιες γονιδιακές μεταλλάξεις ανευρίσκονται σε ποσοστό λιγότερο από το 50% σε οικογένειες με μελάνωμα.

Ηλικία: Ο κίνδυνος του μελανώματος αυξάνει αναλογικά με την ηλικία παρά του ότι το μελάνωμα σχετίζεται λιγότερο με την ηλικία συγκριτικά με άλλους τύπους καρκίνου και μπορεί να εμφανιστεί σε ηλικίες μικρότερες των 30 ετών.

Φύλο: Στη Λατινική Αμερική, την Ωκεανία και το Ισραήλ οι άντρες έχουν μεγαλύτερο κίνδυνο ανάπτυξης μελανώματος, ενώ στην Ευρώπη ο κίνδυνος είναι ελαφρώς μεγαλύτερος στις γυναίκες.


Ανοσοκαταστολή: Άτομα με μειωμένη ανοσία έχουν μεγαλύτερο κίνδυνο να αναπτύξουν μελάνωμα. Η ανοσία μπορεί να είναι μειωμένη λόγω κάποιας νόσου όπως το AIDS ή λόγω φαρμάκων που χορηγούνται μετά τη μεταμόσχευση οργάνων.

Αποχρωματική ξηροδερμία: Είναι μία σπάνια κληρονομική νόσος στην οποία υπάρχει αδυναμία της επιδιόρθωσης των βλαβών που προκαλούνται από την υπεριώδη ακτινοβολία. Σε αυτά τα άτομα η πιθανότητα εμφάνισης μελανώματος είναι υπερβολικά αυξημένη.

1.2 Συμπτώματα

Συμπτώματα δεν εμφανίζονται πάντα στο μελάνωμα. Μία ένδειξη μπορεί να είναι κάποια ελιά που ματώνει. Σε αρχικά στάδια η ελιά είναι σαν όλες τις άλλες. Το 20-30% των μελανωμάτων προέρχονται από προϋπάρχουσες ελιές, ενώ το 70-80% δημιουργούνται σε υγιές δέρμα.

Για να είναι επίφοβη μια ελιά θα πρέπει να είναι ασύμμετρη ή τα όριά της να είναι ασαφή ή η διάμετρος να είναι πάνω από 6 χιλιοστά, να υπάρχει ανομοιομορφία στο χρώμα ή αν αλλάζει με την πάροδο του χρόνου και δε μοιάζει με τις υπόλοιπες.




Εικόνα 3 Διαφορά Φυσιολογικού Σπίλου με Μελανώματος

Οι σπίλοι συνήθως είναι ακίνδυνοι. Ωστόσο, τα άτομα που έχουν πάνω από 100 ελιές στο σώμα τους έχουν αυξημένο κίνδυνο να αναπτύξουν μελάνωμα. Τα πρώτα συμπτώματα εμφανίζονται σε έναν ή και περισσότερους άτυπους σπίλους (ελιές). Γι' αυτό γίνεται χρήση του ABCDE στους σπίλους (γνωστό ως αλφαβήτα του μελανώματος) για σημάδια μελανώματος.

Τα αρχικά ABCDE είναι:

- **A- Asymmetry** δηλαδή η ελιά που θα παρουσιαστεί δεν είναι συμμετρική
- **B- Border** δηλαδή τα όριά της δεν είναι σαφή
- **C-Colour** δηλαδή το χρώμα της δεν είναι ίδιο σε όλη την επιφάνεια. Όταν υπάρχει πολυχρωμία ή σε κάποια σημεία είναι αποχρωματισμένα, κόκκινη, λευκή ή μπλε θα πρέπει να εξεταστεί από δερματολόγο
- **D- Diameter** δηλαδή η διάμετρός της είναι μεγαλύτερη από 6 χιλιοστά. Συνήθως οι ακίνδυνοι σπίλοι είναι μικρότεροι σε διάμετρο από αυτή τη διάσταση.
- **E-Evolving** δηλαδή ότι αναπτύσσεται και αυξάνεται σε μέγεθος.



Εικόνα 4 ABCDE κανόνες για έγκαιρη ανίχνευση


1.3 Διάγνωση

Η διάγνωση του μελανώματος γίνεται με την αφαίρεση του όγκου(ελιάς) και εξετάζεται σε μικροσκόπιο. Στο επόμενο στάδιο καθορίζεται η έκταση του και αυτό γίνεται με τη μέτρηση του πάχους του, το βάθος στο οποίο έχει φτάσει στο δέρμα και ανάλογα με το εάν υπάρχουν μεταστάσεις στους παρακείμενους λεμφαδένες ή σε άλλα όργανα του σώματος. Όταν καθοριστεί το στάδιο, τότε σχεδιάζεται ανάλογα και η θεραπεία, λαμβάνοντας επί πλέον υπ' όψη και την ηλικία και τη γενική υγεία του ασθενή.

Η έγκαιρη διάγνωση και θεραπεία είναι απαραίτητη διότι όσο πιο έγκαιρα διαγιγνώσκεται τόσο πιο πιθανότερη είναι η πλήρης ίαση. Γι' αυτό θα πρέπει να γίνεται τακτική εξέταση του δέρματος και για οποιαδήποτε αλλαγή σε σπίλο ή εμφάνιση καινούργιου θα πρέπει να γίνει επίσκεψη σε δερματολόγο.

1.4 Θεραπεία

Οι περισσότεροι ασθενείς του μελανώματος αντιμετωπίζονται με χειρουργική επέμβαση. Στην χειρουργική επέμβαση γίνεται αφαίρεση του σπίλου αλλά και υγιούς δέρματος γύρω απ' αυτό. Μερικές φορές γίνεται και τοποθέτηση ενός μοσχεύματος (κομμάτι δέρματος από άλλο σημείο). Η χειρουργική επέμβαση στις περισσότερες φορές προκαλεί εμφάνιση ουλών.



Εικόνα 5 Χειρουργική Επέμβαση Μελανώματος

Σε ασθενείς με μελάνωμα που έχει φτάσει σε βάθος ή έχει εξαπλωθεί, υπάρχει ο κίνδυνος της υποτροπής παρ' όλη την αφαίρεση. Τότε, μπορεί να γίνει και η λεγόμενη υποστηρικτική θεραπεία με χημειοθεραπεία (αντικαρκινικά φάρμακα). Επειδή τα υπάρχοντα σήμερα φάρμακα δεν είναι πολύ δραστικά σε περιπτώσεις προχωρημένης νόσου, γίνονται συνεχώς έρευνες και μελετώνται νέες θεραπείες.

Ένα καινούργιο θεραπευτικό κεφάλαιο που γίνεται χρήση φυσικών ουσιών από την παραγωγή του ίδιου του οργανισμού λέγεται βιοθεραπεία. Σκοπός της είναι η ενίσχυση ή η αποκατάσταση του αμυντικού συστήματος του οργανισμού ώστε να καταπολεμήσει τη νόσο πιο αποτελεσματικά. Τέτοιες ουσίες είναι η ιντερλευκίνη-2 και η ιντερφερόνη.

Μερικές φορές θα χρειαστούν και ακτινοβολίες με τις οποίες θα γίνει η καταστροφή της ικανότητας των καρκινικών κυττάρων να αυξάνονται και να πολλαπλασιάζονται. Η συγκεκριμένη θεραπεία χρησιμοποιείται κυρίως στην απάλυνση του πόνου

2 Εφαρμογή


Σε αυτό το κεφάλαιο θα γίνει αναφορά συσχέτισης διάγνωσης μελανώματος με χρήση τεχνικών μηχανικής μάθησης για καλύτερο και γρηγορότερο αποτέλεσμα.

2.1 Μηχανική Μάθηση

Η διάγνωση του μελανώματος είναι δύσκολο να εντοπιστεί και ο δερματολόγος δεν μπορεί να πάρει την ανάλογη απόφαση για τον ασθενή. Θα μπορούσε να γίνει πιο αποτελεσματική και γρήγορη χρησιμοποιώντας τεχνικές μηχανικής μάθησης.

Η μηχανική μάθηση(Machine Learning)[44] μπορεί με εφαρμογή αλγορίθμων τεχνητής νοημοσύνης να βοηθήσει των δερματολόγο στην έγκαιρη διάγνωση του μελανώματος.

Κάθε αλγόριθμος μηχανικής μάθησης για να χρησιμοποιηθεί χρειάζεται δεδομένα. Στη διάγνωση του μελανώματος χρειάζεται εικόνα του όγκου. Για την επεξεργασία και αξιολόγηση της εικόνας συχνά χρησιμοποιείται ειδική κατηγορία της μηχανικής μάθησης, η βαθιά μάθηση(Deep Learning)[24].




Εικόνα 6 Σταδιακή απεικονίζει της εξέλιξης της τεχνητής νοημοσύνης

2.2 Βαθιά Μάθηση

Η βαθιά μάθηση είναι μια κατηγορία αλγορίθμων μηχανικής μάθησης που χρησιμοποιεί πολλαπλά επίπεδα για να εξάγει χαρακτηριστικά υψηλότερου επιπέδου από την ακατέργαστη είσοδο. Οι αλγόριθμοι της βαθιάς μάθησης έχουν βελτιώσει σε μεγάλο βαθμό την εξέλιξη της τεχνολογίας.

Η διαφορά που υπάρχει ανάμεσα στην βαθιά μάθηση με την μηχανική μάθηση δεν φαίνεται στην εκτέλεση του αλγορίθμου αλλά στην προ-επεξεργασία των δεδομένων.



Εικόνα 7 Διαφορά μηχανικής με βαθιάς μάθησης

Η βαθιά μάθηση ανακαλύπτει μια περίπλοκη δομή σε μεγάλα σύνολα δεδομένων για να υποδείξει πως ένα μηχάνημα θα πρέπει να αλλάξει τις εσωτερικές παραμέτρους που χρησιμοποιούνται για υπολογισμό της αναπαράστασης σε κάθε επίπεδο (στρώμα) από την αναπαράσταση στο προηγούμενο. Στην περίπτωση αυτή γίνεται εξειδίκευση σε βαθιά νευρωνικά δίκτυα (Deep Neural Networks).

Υπάρχουν 2 κατηγορίες βαθιών νευρωνικών δικτύων :

- Συνελικτικά νευρωνικά δίκτυα (Convolutional Neural Networks)
- Αναδρομικά νευρωνικά δίκτυα (Recurrent Neural Networks)


Τα συνελικτικά νευρωνικά δίκτυα εφαρμόζονται σε :

- αναγνώριση εικόνων και βίντεο
- recommendation systems
- ταξινόμηση εικόνων
- ανάλυση ιατρικών εικόνων και επεξεργασία φυσικής γλώσσας

Επίσης δέχονται διαφόρων ειδών δεδομένα όπως είναι :

- χρονοσειρές
- σήματα και ακολουθίες
- εικόνες που μπορούν να θεωρηθούν ως ένα 2d πλέγμα
- βίντεο 3d πλέγμα

Η διαφορά σε σχέση με τα απλά βαθιά νευρωνικά δίκτυα είναι ότι χρησιμοποιούν συνέλιξη αντί για πολλαπλασιασμό πινάκων σε τουλάχιστον ένα από τα στρώματα τους




Εικόνα 8 Παράδειγμα συνέλιξης 2 πινάκων

Η δεύτερη κατηγορία, τα αναδρομικά νευρωνικά δίκτυα, αποτελούν ένα ισχυρό είδος νευρωνικών δικτύων και συνδυάζουν 2 ιδιότητες:

- Αποτελούνται από την κρυφή κατάσταση όπου μπορούν να αποθηκεύουν μεγάλο μέρος πληροφόρησης από παλαιότερα αποτελέσματα
- Έχουν μη γραμμική δυναμική που επιτρέπει την ενημέρωση της κρυφής κατάστασης με πολλούς τρόπους

Στα αναδρομικά νευρωνικά δίκτυα η πληροφορία περνάει απ' όλους τους κύκλους του δικτύου με αποτέλεσμα όταν λαμβάνει μια απόφαση να μπορεί να λαμβάνει απόφαση και πέραν της τρέχουσας εισόδου και η πληροφορία να αποθηκεύεται. Αυτό το αναδρομικό νευρωνικό δίκτυο έχει βραχυπρόθεσμη μνήμη δηλαδή δέχεται 2 εισόδους, μια είσοδος που αφορά την τωρινή πληροφορία και μια για την παρελθοντική. Αυτές οι εξάρτησεις ονομάζεται «Μακροχρόνιες Εξαρτήσεις» (Long Term Dependencies).



Εικόνα 9 Παράδειγμα Αρχιτεκτονικής Αναδρομικού Νευρωνικού Δικτύου

Το κύριο χαρακτηριστικό τέτοιων νευρωνικών δικτύων είναι η ικανότητα μάθησης. Η μάθηση μπορεί να οριστεί ως η σταδιακή βελτίωση της ικανότητας του δικτύου να επιλύει κάποιο πρόβλημα.

Η μάθηση επιτυγχάνεται μέσω της εκπαίδευσης, μίας επαναληπτικής διαδικασίας σταδιακής προσαρμογής των παραμέτρων του δικτύου (συνήθως των βαρών και της πόλωσης του) σε τιμές κατάλληλες ώστε να επιλύεται με επαρκή επιτυχία το προς εξέταση πρόβλημα. Αφού ένα δίκτυο εκπαιδευτεί, οι παράμετροί του συνήθως «παγώνουν» στις κατάλληλες τιμές και από εκεί κι έπειτα είναι σε λειτουργική κατάσταση.

Το ζητούμενο είναι το λειτουργικό δίκτυο να χαρακτηρίζεται από μία ικανότητα γενίκευσης: αυτό σημαίνει πως δίνει ορθές εξόδους για εισόδους καινοφανείς και διαφορετικές από αυτές με τις οποίες εκπαιδεύτηκε.

Σε αυτή την έρευνα θα γίνει η χρήση του συνελκτικού νευρωνικού δικτύου όπου αναλύεται περαιτέρω στο κεφάλαιο 4

3 Βιβλιογραφική Ανασκόπηση

Σε αυτό το κεφάλαιο θα γίνει η βιβλιογραφική ανασκόπηση 10 σύγχρονων ερευνών-εφαρμογών στο κομμάτι της μηχανικής-βαθιάς μάθησης που έχουν επιτευχθεί και απεικόνιση των αποτελεσμάτων τους.

Το αντικείμενο της έρευνας [4] είναι η παρουσίαση του μη επιβλεπόμενου αλγορίθμου SDI+(Segmenting Dermoscopic Images). Η μεθοδολογία είναι να χωρίσουν σε τμήματα της εικόνες που είχαν στοιχεία μελανώματος. Για δεδομένα χρησιμοποιήθηκαν από το ISCI 2017 όπου τα 600 ήταν test set. Μέθοδος αξιολόγησης που χρησιμοποιήθηκε δεν αναγράφεται αλλά τα αποτελέσματα που έβγαλαν είναι:

- Ακρίβεια 88.8%
- Ευαισθησία 81.3%
- Εξειδίκευση 92.7%

Το αντικείμενο της έρευνας [5] είναι μια εκτενέστερη μελέτη ενός αυτοματοποιημένου συστήματος εντοπισμού κάκωσης. Η μεθοδολογία που χρησιμοποιήθηκε ήταν η δημιουργία ενός συνελκτικού νευρωνικού δικτύου ώστε να γίνει η κατηγοριοποίηση των εικόνων των κακώσεων. Τα δεδομένα που χρησιμοποιήθηκαν από το ISBI Challenge 2017 και συγκεκριμένα χρησιμοποιήθηκαν από τις 2000 εικόνες όπου 374 ήταν για το μελάνωμα για train και από της 600 όπου η 117 ήταν για το μελάνωμα για test. Για την αξιολόγηση του μοντέλου χρησιμοποιήθηκαν οι 150 εικόνες όπου η 30 είναι για το μελάνωμα και 5-fold cross validation. Παρακάτω φαίνονται τα αποτελέσματα της αξιολόγησης:

Ακρίβεια	Ευαισθησία	Εξειδίκευση
93.4%	82.5%	97.5%

Το αντικείμενο της έρευνας [6] είναι η παρουσίαση ενός πλήρες λειτουργικού συνελκτικού νευρωνικού δικτύου και της αποτελεσματικότητας του στην αναζήτηση κλινικών δερματολογικών εικόνων.

Η μεθοδολογία που χρησιμοποιήθηκε ήταν η κατηγοριοποίηση των μεγάλων εικόνων με την χρήση του νευρωνικού δικτύου. Τα δεδομένα που χρησιμοποιήθηκαν ήταν 2000 εικόνες από το ISIC-ISBI Challenge όπου με 1700 έγινε η εκπαίδευση του νευρωνικού δικτύου και οι υπόλοιπες 300 για τεστ. Παρακάτω φαίνονται τα αποτελέσματα :

Ακρίβεια	Ευαισθησία	Εξειδίκευση
98.0%	54.2%	98.1%

Το αντικείμενο της έρευνας [7] είναι η παρουσίαση ενός βοηθητικού διαγνωστικού συστήματος για τον εντοπισμό του μελανώματος σε δερματολογικές εικόνες. Η μεθοδολογία που χρησιμοποιήθηκε ήταν ο διαχωρισμός και στην συνέχεια η κατηγοριοποίηση των εικόνων για τον εντοπισμό του μελανώματος. Σε αυτήν την εργασία χρησιμοποιήθηκαν 2 διαφορετικά σύνολα δεδομένων. Τα σύνολα δεδομένων είναι:

- Ένα δημόσιο PH² σύνολο όπου από 200 εικόνες η 40 ήταν για το μελάνωμα

- Ένα δημόσιο ISIC σύνολο όπου περιέχει 10000 εικόνες και χρησιμοποιήθηκαν οι 900

Χρησιμοποιήθηκαν 2 αλγόριθμοι μηχανικής μάθησης:

1. Support Vector Machines
2. K Nearest Neighbor (σε αυτήν την εργασία το $k=1$)

Η μέθοδος αξιολόγησης που χρησιμοποιήθηκε ήταν 10-fold cross validation και παρακάτω φαίνονται τα αποτελέσματα και για τα 2 σύνολα δεδομένων

	SVM	KNN
PH ²	82.25%	74%
ISIC	80.6%	79.7%

Το αντικείμενο της έρευνας [8] είναι η παρουσίαση ενός δερματολογικού γνωστικού δικτυού. Η μεθοδολογία που χρησιμοποιήθηκε ήταν :

1. Η δημιουργία ενός διαχωρισμού δικτύου κάκωσης
2. Η χρησιμοποίηση του δικτύου με το module αύξησης δεδομένων
3. Στην συνέχεια γίνεται η χρησιμοποίηση ενός δερματολογικού δομημένων διαχωρισμού δικτύου
4. Τα δεδομένα που βγαίνουν από το δερματολογικό δίκτυο περνάνε από το διαγνωστικό δίκτυο
5. Εάν υπάρχουν μη δεδομένα εικόνων (φύλο ,ηλικία, κτλ) τότε γίνεται η χρησιμοποίηση αλγορίθμων κατηγοριοποίησης

Το σύνολο δεδομένων που χρησιμοποιήθηκε ήταν 2750 δερματολογικές εικόνες από το ISBI Challenge όπου χρησιμοποιήθηκαν 375 εικόνες μελανώματος για training και οι ίδιες εικόνες για test. Μόνο που χρησιμοποιήθηκε επίσης για training και άλλα σύνολα δεδομένων όπως:

- Σύνολα Δεδομένων που συλλέχτηκαν από το EDRA Interactive Atlas of Dermoscopy όπου περιέχει 724 μελανοκυτταρικές κακώσεις και η 220 απ' αυτές είναι κατηγορίας μελανώματος
- Σύνολα Δεδομένων που συλλέχτηκαν από το ISIC όπου χρησιμοποιήθηκαν 2104 εικόνες και η 466 απ' αυτές είναι κατηγορίας μελανώματος

Η μέθοδος αξιολόγησης που χρησιμοποιήθηκε δεν αναγράφεται αλλά παρακάτω υπάρχει αποτέλεσμα στην εξειδίκευση που είναι 46%.

Το αντικείμενο της έρευνας [9] είναι η παρουσίαση ενός Quad Tree συστήματος εντοπισμού μελανώματος βασισμένο στο χρώμα. Η μεθοδολογία που χρησιμοποιήθηκε ήταν η εξής:

1. Η προεπεξεργασία των εικόνων
2. Ο διαχωρισμός των κακώσεων
3. Η κατασκευή πέντε μορίων επικάλυψης
4. Η κατασκευή των χρωμάτων παλετών
5. Η συλλογή των Quad Tree
6. Η συλλογή των παλετών Quad Tree

Το σύνολο δεδομένων που χρησιμοποιήθηκε ήταν 825 δερματολογικές εικόνες όπου οι 644 εικόνες ήταν καλοήθες ενώ η 181 ήταν κακοήθες. Οι αλγόριθμοι κατηγοριοποίησης που χρησιμοποιήθηκαν ήταν:

- Support Vector Machines(SVM)
- Τεχνητό Νευρωνικό Δίκτυο(ANN)
- Γραμμική διακριτική ανάλυση(LDA)
- Random Forests(RF)

Οι μέθοδοι αξιολόγησης ήταν :

1. 70% training και 30% testing για όλους τους αλγόριθμους κατηγοριοποίησης
2. 10-fold cross validation για όλους τους αλγόριθμους κατηγοριοποίησης

Παρακάτω φαίνονται τα αποτελέσματα από τον SVM αλγόριθμο όπου η ευαισθησία είναι 80.5% και η εξειδίκευση είναι 58.4%.

Το αντικείμενο της έρευνας [10] είναι η παρουσίαση ενός λειτουργικού συνελκτικού νευρωνικού δικτύου εκπαιδευμένο με δεδομένα δερματολογικών εικόνων, κλινικών, μεταδεδομένα από ασθενείς για την κατηγοριοποίηση των 7-point μελανωμάτων και να γίνει η σωστή διάγνωση.

Η μεθοδολογία που χρησιμοποιήθηκε ήταν η ανάλυση κάθε κατηγορίας εικόνων ώστε να εκπαιδευτεί το δίκτυο. Το σύνολο δεδομένων που χρησιμοποιήθηκε ήταν 1011 cases (εικόνες) όπου οι 413 χρησιμοποιήθηκαν για την εκπαίδευση του δικτύου, 203 για την επικύρωση και σχεδίαση αποφάσεων ενώ τα υπόλοιπα 395 για τεστ. Η μέθοδος αξιολόγησης ήταν 2-fold cross validation και αυτή η μέθοδος εκτελέστηκε 5 φορές. Τα αποτελέσματα ήταν:

Ακρίβεια	Ευσαιθησία	Εξειδίκευση
80.8%	64.9%	84.8%

Το αντικείμενο της έρευνας [11] είναι η παρουσίαση ενός μη συνελκτικού δικτύου για τον διαχωρισμό δερματικών κακώσεων. Η μεθοδολογία που χρησιμοποιήθηκε ήταν:

1. Η κωδικοποίηση και μη του δικτύου
2. Το αρχικό δίκτυο διασπάτε σε 4 μικρότερα δίκτυα
3. Τα 4 μικρότερα δίκτυα αποτελούνται από μη συνελκτικά δίκτυα

Τα σύνολο δεδομένων που χρησιμοποιήθηκαν είναι δερματολογικές εικόνες από το ISBI Challenge και συγκεκριμένα:

- Το σύνολο δεδομένων του ISBI 2016 όπου τα 900 χρησιμοποιήθηκαν για εκπαίδευση και τα υπόλοιπα 379 για τεστ
- Το σύνολο δεδομένων του ISBI 2017 όπου τα 200 χρησιμοποιήθηκαν για τεστ και τα υπόλοιπα 900 για εκπαίδευση

Η μέθοδος αξιολόγησης που χρησιμοποιήθηκε δεν αναγράφεται αλλά αναγράφονται τα αποτελέσματα του δικτύου σύμφωνα με την ακρίβεια:

ISBI 2016	95.9%
ISBI 2017	93.9%

Το αντικείμενο της έρευνας [19] είναι η βελτίωση στη σύγκριση των αλγορίθμων ταξινόμησης εικόνων της τεχνητή νοημοσύνη με την ταξινόμηση των εικόνων που γίνονται από τους δερματολόγους. Για αυτή τη εργασία χρησιμοποιήθηκαν 4204 εικόνες μελανώματος για την εκπαίδευση ενός συνελκτικού νευρικού δικτύου (CNN) αλλά έγινε και χρήση νέων τεχνικών βαθιάς μάθησης και χρησιμοποιήθηκαν 804 δερματοσκοπικές εικόνες μελανώματος οι οποίες παρουσιάστηκαν σε

δερματολόγους των εννέα Γερμανικά πανεπιστημιακά νοσοκομεία, τα οποία αξιολόγησαν την ποιότητα κάθε εικόνας.

Η σύγκριση των αποτελεσμάτων των δοκιμαστικών δοκιμασιών του CNN όσον αφορά την ευαισθησία, την εξειδίκευση και τη συνολική ορθότητα ήταν προκαθορισμένα ως τα κυριότερα αποτελέσματα. Παρακάτω αναγράφονται τα αποτελέσματα της σύγκρισης:

	Ευαισθησία	Εξειδίκευση
Δερματολόγοι	67.2%	62.2%
CNN	82.3%	77.9%

Το αντικείμενο της έρευνας [20] είναι η σύγκριση της απόδοσης ενός συνελκτικού νευρωνικού δικτύου το οποίο είναι εκπαιδευμένο με δερματοσκοπικές εικόνες αποκλειστικά για την αναγνώριση του μελανώματος σε κλινικές φωτογραφίες με τη χειροκίνητη ταξινόμηση των ίδιων εικόνων από τους δερματολόγους.

Έγινε σύγκριση της αυτόματης ταξινόμησης ψηφιακού μελανώματος με την απόδοση των 145 δερματολόγων 12 Γερμανικών πανεπιστημιακών νοσοκομείων. Χρησιμοποιήθηκε μεθόδους από ενισχυμένη βαθιά μάθηση μαθαίνοντας να την εκπαίδευση ενός συνελκτικού νευρωνικού δικτύου με 12.378 δερματοσκοπικές εικόνες ανοιχτού κώδικα.

Χρησιμοποιήθηκαν 100 κλινικές εικόνες για να συγκρίνουν τις επιδόσεις του συνελκτικού νευρωνικού δικτύου με εκείνη των δερματολόγων.

Παρακάτω αναγράφεται ο μέσος όρος των αποτελέσματα (ευαισθησία, εξειδίκευση) μεταξύ της σύγκρισης:

	Ευαισθησία	Εξειδίκευση
Δερματολόγοι	92.8%	57.7%
Συνελκτικού Νευρωνικού	92.8%	61.1%

4 Μεθοδολογία

Σε αυτό το κεφάλαιο θα γίνει η αναφορά της μεθοδολογίας που ακολουθήθηκε, τα δεδομένα που χρησιμοποιήθηκαν για το συνελκτικό νευρωνικό δίκτυο ,τα

εργαλεία, η γλώσσα προγραμματισμού και οι βιβλιοθήκες που χρησιμοποιήθηκαν στην ανάπτυξη του συνελικτικού και στα μέτρα απόδοσης που αναλύθηκαν για την αξιολόγηση των αποτελεσμάτων.

4.1 Αρχιτεκτονική

Το δίκτυο αποτελείται από τα εξής layers:

- Convolutional
- Pooling
- Dropout
- Flatten
- Dense

Το Convolutional layer παίρνει ως είσοδο εικόνα με τα ακόλουθα χαρακτηριστικά:

- Τον αριθμό των εικόνων
- Το μέγεθος των εικόνων (ύψος και πλάτος)
- Τα κανάλια εισόδου (χρώματα)


Στη συνέχεια περνάνε στο feature maps όπου θα πρέπει να έχουν τα ίδια χαρακτηριστικά με το παραπάνω layer. Με το πέρας της επεξεργασίας αυτής τα δεδομένα μεταφέρονται στο pooling layer

Το Pooling layer είναι ο συνδυασμός των συστάδων νευρώνων σε ένα στρώμα με έναν νευρώνα. Συνήθως τέτοιες συστάδες είναι μικροί πίνακες 2 x 2 και συγκεκριμένα η μεταβλητή max pooling χρησιμοποιεί τη μέγιστη τιμή από κάθε ένα σύμπλεγμα νευρώνων στο προηγούμενο στρώμα.

Το Dropout layer χρησιμοποιείται κατά την εκπαίδευση του μοντέλου με σκοπό την αποφυγή της υπερβολικής εκπαίδευσης του μοντέλου, δηλαδή να μην μπορέσει να μάθει νέα δεδομένα.

Το Flatten layer χρησιμοποιείται στη μετατρέπει τον feature maps σε μία στήλη που περνά στο πλήρως συνδεδεμένο επίπεδο.

Το Dense layer χρησιμοποιείται στην σύνδεση των παραπάνω layers με τις εξόδους του νευρωνικού δικτύου.



Εικόνα 10 Παράδειγμα Αρχιτεκτονικής Συνελικτικού Νευρωνικού Δικτύου

4.2 Δεδομένα

Για να γίνει η εκτέλεση του συνελικτικού νευρωνικού δικτύου έπρεπε να χρησιμοποιηθούν δεδομένα. Τα δεδομένα τα οποία χρησιμοποιήθηκαν ήταν 2013 εικόνες μελανώματος χωρισμένες σε 34 κατηγορίες[10]. Οι εικόνες έπρεπε να μεταφερθούν σε 64 x 64 διαστάσεις ώστε να γίνει σωστά η επεξεργασία τους.



Εικόνα 11 Σύνολο δεδομένων για το συνελικτικό από Jeremy Kawahara et al[10]

4.3 Εργαλεία

Για την δημιουργία του συνελικτικού νευρωνικού δικτύου, την εκπαίδευση του αλλά και την αξιολόγηση του χρησιμοποιήθηκε η γλώσσα προγραμματισμού python και οι παρακάτω βιβλιοθήκες που διαθέτει η γλώσσα:

- Tensorflow
- Keras
- Numpy
- Sklearn
- Matplotlib

Η **Tensorflow**[1,22,38] είναι μια δωρεάν βιβλιοθήκη λογισμικού ανοιχτού κώδικα οι οποία εκτελεί γρήγορους αριθμητικούς υπολογισμούς και είναι η κατάλληλη για εφαρμογές βαθιάς μάθησης.

Η **Keras**[2,21,39] είναι μια API(application programming interface) βαθιάς μάθησης και τρέχει πάνω στην βιβλιοθήκη Tensorflow και είναι σχεδιασμένο για να εκτελεί γρήγορα πειράματα για βαθιά μάθηση. Οι βασικές δομές δεδομένων του είναι τα στρώματα και τα μοντέλα.

Η **Numpy**[18] είναι μια βιβλιοθήκη για επεξεργασία πολυδιάστατων στηλών και πινάκων και αποτελείται από μαθηματικές συναρτήσεις υψηλού επιπέδου για εφαρμογή σε στήλες και πίνακες.

Η **Matplotlib**[49] είναι μια βιβλιοθήκη για σχεδίαση και αναπαράσταση διαγραμμάτων και αποτελεσμάτων στατιστικών.

Η **Sklearn**[17-18] είναι μια βιβλιοθήκη μηχανικής εκμάθησης λογισμικού και ίσως η πιο σημαντική βιβλιοθήκη για την εξαγωγή αποτελεσμάτων μηχανικής μάθησης.

Για την εκτέλεση του συνελκτικού έπρεπε να γίνει η εκτέλεση αξιοποιώντας cloud εφαρμογές που διαθέτει η google όπως είναι το **google drive** ,όπου εκεί είναι αποθηκευμένα τα δεδομένα (εικόνες) για την εκπαίδευση του μοντέλου, το **google colab**[3] όπου είναι μια εφαρμογή που μπορούν να γίνουν εκτελέσεις μηχανικής και βαθιάς μάθησης χωρίς να γίνεται χρήση του ηλεκτρονικού υπολογιστή (κάρτες γραφικών) αλλά σε cloud server που διαθέτει η google.

4.4 Μέτρα απόδοσης

Στο κομμάτι της αξιολόγησης των μοντέλων βαθιάς μάθησης γίνεται χρήση κάποιων μέτρων απόδοσης, έτσι και στο δικό μας συνελκτικό νευρωνικό γίνεται χρήση τέτοιων μέτρων.

Τα μέτρα τα οποία χρησιμοποιούνται είναι :

- Ο **πίνακας σύγχυσης(Confusion Matrix)** όπου μας δίνει με σχηματικό τρόπο το αποτέλεσμα της ταξινόμησης. Είναι πίνακας 2d και αποτελείται από το πραγματικό αποτέλεσμα και το προβλεπόμενο αποτέλεσμα. Τα πραγματικά αποτελέσματα είναι στις στήλες και τα προβλεπόμενα στις γραμμές. Οι τιμές

που δίνει χρησιμοποιούνται και στα άλλα μέτρα απόδοσης. Αυτές οι τιμές είναι :

- **True Positive(TP)** : Το πραγματικό αποτέλεσμα είναι το ίδιο με το προβλεπόμενο στο θετικό κομμάτι (δηλαδή ότι έγινε σωστά η πρόβλεψη σε θετικό αποτέλεσμα)
- **True Negative(TN)** : Το πραγματικό αποτέλεσμα είναι το ίδιο με το προβλεπόμενο στο αρνητικό κομμάτι (δηλαδή ότι έγινε σωστά η πρόβλεψη σε αρνητικό αποτέλεσμα)
- **False Negative (FN)** : Το πραγματικό αποτέλεσμα είναι αρνητικό αλλά το προβλεπόμενο αποτέλεσμα βγήκε θετικό (δηλαδή ότι έγινε λάθος η πρόβλεψη σε αρνητικό αποτέλεσμα)
- **False Positive (FP)** : Το πραγματικό αποτέλεσμα είναι θετικό αλλά το προβλεπόμενο αποτέλεσμα βγήκε αρνητικό (δηλαδή ότι έγινε λάθος η πρόβλεψη σε θετικό αποτέλεσμα)
- Η **συνολική ακρίβεια(Accuracy)** και είναι το συνολικό ποσοστό των σωστών ταξινομημένων και υπολογίζεται από τον εξής τύπο:
 - $Accuracy = (TP + TN) / (SUM(MATRIX))$
 - $SUM(MATRIX) = TP + TN + FN + FP$
- Η **ακρίβεια(Precision)** και είναι το ποσοστό των σωστά ταξινομημένων θετικών αποτελεσμάτων και υπολογίζεται από τον εξής τύπο :
 - $Precision = TP / (TP + FP)$
- Η **ευαισθησία(Sensitivity)** ή **ανάκληση(Recall)** και είναι ο συνολικός αριθμός που των σχετικών περιπτώσεων που έχουν ανακτηθεί και είναι και το πραγματικό και το προβλεπόμενο αποτέλεσμα θετικό και υπολογίζεται από τον εξής τύπο :
 - $Recall = TP / (TP + FN)$
- Η **F1 score** είναι ο αρμονικός μέσος της ανάκλησης και της ακρίβειας και υπολογίζεται από τον εξής τύπο:
 - $F1-score : (2 * Precision * Recall) / (Precision + Recall)$

5 Συνελικτικό Νευρωνικό Δίκτυο

Σε αυτό το κεφάλαιο θα γίνει η αναλυτική περιγραφή του μοντέλου με τα επιμέρους αποτελέσματα τα οποία εξάγει.

5.1 Επεξεργασία δεδομένων

Αρχικά θα πρέπει να δηλώσουμε την διεύθυνση που είναι αποθηκευμένα τα δεδομένα.

Εφόσον τα δεδομένα είναι αποθηκευμένα στο google drive απαιτείται να γίνει εξουσιοδοτημένη πρόσβαση δηλαδή απαιτείται την άδεια να δώσει πρόσβαση το google colab στο google drive.

Αφού επιτευχθεί αυτό το επόμενο βήμα είναι η επεξεργασία και ο διαχωρισμός των εικόνων ώστε να μπορέσουν να χρησιμοποιηθούν στο μοντέλο. Η επεξεργασία των εικόνων αποτελούσε το πιο σημαντικό κομμάτι για την εκτέλεση του μοντέλου. Οι εικόνες έπρεπε να αλλάξουν διαστάσεις ώστε να γίνει σωστά η εκτέλεση του μοντέλου. Οι διαστάσεις που τοποθετήθηκαν ήταν 64*64 .

Το επόμενο βήμα ήταν ο διαχωρισμός των δεδομένων ώστε να γίνει και η εκπαίδευση του μοντέλου αλλά και η αξιολόγηση του. Ο διαχωρισμός των δεδομένων έγινε ως 70%(1420) των εικόνων να πάνε για εκπαίδευση του μοντέλου και το υπόλοιπο 30%(593) για αξιολόγηση του μοντέλου.

5.2 Αρχιτεκτονική μοντέλου

Μετά την επεξεργασία και των διαχωρισμό των εικόνων έπρεπε να δημιουργηθεί η αρχιτεκτονική του δικτύου

Το συνελικτικό νευρωνικό δίκτυο είναι 3 επίπεδα όπου το καθένα αποτελούνται από :

1. Το convolutional layer σε 2d διαστάσεων μαζί με την συνάρτηση ενεργοποίησης relu[37]
2. Το πίνακα maxpooling και αυτό σε 2d διαστάσεων
3. Το dropout layer για την αποφυγή overfitting

Σε κάθε επίπεδο το convolutional layer πρέπει να μειώνεται στο μισό μετά από το 1το επίπεδο.

```

model.add(layers.Conv2D(128, (3, 3), activation='relu', input_shape=(64, 64, 3)))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Dropout(0.5))

model.add(layers.Conv2D(64, (3, 3), activation='relu'))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Dropout(0.5))

model.add(layers.Conv2D(32, (3, 3), activation='relu'))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Dropout(0.5))

```

Εικόνα 12 Αρχιτεκτονική Επεξεργασίας Δεδομένων

Τα παραπάνω layers αποτελούν σημαντικό κομμάτι στην επεξεργασία των εικόνων αλλά και στο κομμάτι της εκπαίδευσης.

Αφού επιτευχθεί η χρήση αυτών των επιπέδων θα πρέπει να ξεκινήσει η διαδικασία της εκπαίδευσης του μοντέλου. Για το κομμάτι της εκπαίδευσης γίνεται η δημιουργία των επιπέδων flatten ώστε να γίνει η σύνδεση του προηγούμενου επιπέδου με το dense layer όπου γίνεται η εκπαίδευση του μοντέλου. Σε κάθε layer υπάρχει και το ανάλογο dropout layer που αυξάνει την εκπαίδευση του μοντέλου και μειώνει την ταχύτητα εκτέλεσης.

```

model.add(layers.Flatten())
model.add(layers.Dense(units=512, activation='relu'))
model.add(layers.Dropout(0.2))
model.add(layers.Dense(units=256, activation='relu'))
model.add(layers.Dropout(0.2))
model.add(layers.Dense(units=34, activation='softmax'))

```

Εικόνα 13 Αρχιτεκτονική Εκπαίδευσης

Με βάση την παραπάνω θα σχηματιστεί η αρχιτεκτονική του μοντέλου με τις παρακάτω παραμέτρους.

Layer (type)	Output Shape	Param #
conv2d (Conv2D)	(None, 62, 62, 128)	3584
max_pooling2d (MaxPooling2D)	(None, 31, 31, 128)	0
dropout (Dropout)	(None, 31, 31, 128)	0
conv2d_1 (Conv2D)	(None, 29, 29, 64)	73792
max_pooling2d_1 (MaxPooling2D)	(None, 14, 14, 64)	0
dropout_1 (Dropout)	(None, 14, 14, 64)	0
conv2d_2 (Conv2D)	(None, 12, 12, 32)	18464
max_pooling2d_2 (MaxPooling2D)	(None, 6, 6, 32)	0
dropout_2 (Dropout)	(None, 6, 6, 32)	0
flatten (Flatten)	(None, 1152)	0
dense (Dense)	(None, 512)	590336
dropout_3 (Dropout)	(None, 512)	0
dense_1 (Dense)	(None, 256)	131328
dropout_4 (Dropout)	(None, 256)	0
dense_2 (Dense)	(None, 34)	8738
Total params: 826,242		
Trainable params: 826,242		

Εικόνα 14 Σχήμα Μοντέλου με παραμέτρους

5.3 Εκπαίδευση Μοντέλου

Αφού ολοκληρώθηκε η αρχιτεκτονική του μοντέλου τώρα θα πρέπει να δηλώσουμε τον κατάλληλο βελτιστοποιητή και τις κατάλληλες μετρικές απόδοσης για την εκπαίδευση του μοντέλου. Στο συγκεκριμένο μοντέλο χρησιμοποιείται ο adam[23] ως βελτιστοποιητή και μετρική απόδοση η ακρίβεια.

Η ακρίβεια δηλώνει την αποτελεσματικότητα του μοντέλου κατά την εκπαίδευση και την αξιολόγηση και δείχνει το πόσο ακριβές είναι τα αποτελέσματα που θα μας δώσει μετά την εκτέλεση του. Επίσης στο στάδιο της εκτέλεσης μπορούμε να καταλάβει αν στο μοντέλο μας έχει γίνει overfitting.

Τα μοντέλο για να εξάγει αποτελέσματα έπρεπε το βήμα της εκπαίδευσης να γίνει για 70 εποχές(epochs) που η κάθε εποχή περιείχε 45 κομμάτια εικόνων(batches). Όλες εκτέλεσης πραγματοποιήθηκαν στο google colab με χρήση GPU.


```

Epoch 1/70
45/45 [=====] - 387s 9s/step - loss: 3.4883 - accuracy: 0.0402 - val_loss: 3.4900 - val_accuracy: 0.0438
Epoch 2/70
45/45 [=====] - 71s 2s/step - loss: 3.4382 - accuracy: 0.0367 - val_loss: 3.4716 - val_accuracy: 0.0405
Epoch 3/70
45/45 [=====] - 35s 786ms/step - loss: 3.4351 - accuracy: 0.0436 - val_loss: 3.4244 - val_accuracy: 0.0422
Epoch 4/70
45/45 [=====] - 16s 362ms/step - loss: 3.4044 - accuracy: 0.0455 - val_loss: 3.3489 - val_accuracy: 0.0961
Epoch 5/70
45/45 [=====] - 14s 313ms/step - loss: 3.2648 - accuracy: 0.0892 - val_loss: 3.0818 - val_accuracy: 0.1029
Epoch 6/70
45/45 [=====] - 14s 304ms/step - loss: 2.9515 - accuracy: 0.1260 - val_loss: 2.7946 - val_accuracy: 0.1248
Epoch 7/70
45/45 [=====] - 13s 299ms/step - loss: 2.7377 - accuracy: 0.1506 - val_loss: 2.6318 - val_accuracy: 0.1669
Epoch 8/70
45/45 [=====] - 14s 303ms/step - loss: 2.5593 - accuracy: 0.1875 - val_loss: 2.3672 - val_accuracy: 0.2445
Epoch 9/70
45/45 [=====] - 14s 308ms/step - loss: 2.4240 - accuracy: 0.2252 - val_loss: 2.2739 - val_accuracy: 0.2648
Epoch 10/70
45/45 [=====] - 14s 302ms/step - loss: 2.3852 - accuracy: 0.2412 - val_loss: 2.2488 - val_accuracy: 0.2732
Epoch 11/70
45/45 [=====] - 14s 302ms/step - loss: 2.3145 - accuracy: 0.2391 - val_loss: 2.1498 - val_accuracy: 0.3069
Epoch 12/70
45/45 [=====] - 13s 299ms/step - loss: 2.2574 - accuracy: 0.2552 - val_loss: 2.0433 - val_accuracy: 0.3035
Epoch 13/70
45/45 [=====] - 13s 300ms/step - loss: 2.2226 - accuracy: 0.2656 - val_loss: 2.0368 - val_accuracy: 0.3069
Epoch 14/70
45/45 [=====] - 13s 299ms/step - loss: 2.1520 - accuracy: 0.2731 - val_loss: 2.0239 - val_accuracy: 0.3187
Epoch 15/70
45/45 [=====] - 13s 299ms/step - loss: 2.1287 - accuracy: 0.2838 - val_loss: 1.9884 - val_accuracy: 0.3508
Epoch 16/70
45/45 [=====] - 13s 301ms/step - loss: 2.0781 - accuracy: 0.2894 - val_loss: 1.9166 - val_accuracy: 0.3423


```

Εικόνα 15 Δείγμα εκτέλεσης της εκπαίδευσης

Κατά την εκτέλεση του διαπιστώνουμε την αύξηση της ακρίβειας στο κομμάτι της επαλήθευσης της και μείωση του χρόνου κόστους για να γίνει η επαλήθευση. Αυτό είναι καλό διότι δείχνει την αποτελεσματικότητα του μοντέλου στα δοθέντα δεδομένα.



Εικόνα 16 Train vs Test στην Ακρίβεια



Εικόνα 17 Train loss vs Test Loss

Ο χρόνος που χρειάστηκε για την εκτέλεση του μοντέλου στο google colab είναι 15 λεπτά δίνοντας ακρίβεια(validation accuracy) 89% σε όλο το σύνολο των δεδομένων.

5.4 Πρόβλεψη

Μετά την εκτέλεση του μοντέλου ερχόμαστε στο στάδιο της εκτέλεσης των αποτελεσμάτων. Δηλαδή θα πρέπει να γίνει η πρόβλεψη ενός κομματιού των δεδομένων ώστε να δούμε αν το μοντέλο ανταποκρίνεται σωστά στα δεδομένα που λαμβάνει.

Πριν φτάσουμε σε αυτό το στάδιο θα πρέπει να γίνει μια μικρή ταξινόμηση των κατηγοριών με σκοπό την καλύτερη εξαγωγή των αποτελεσμάτων σε σχηματικό επίπεδο.


```
array(['A1L', 'A2L', 'A3L', 'Adl', 'Ael', 'Fal', 'Fbl', 'Fcl', 'Fd1',
      'Fel', 'Ffl', 'Fgl', 'Fhl', 'Fil', 'Fll', 'Fml', 'Gal', 'Gbl',
      'Gcl', 'Gdl', 'Ggl', 'Gzl', 'Nal', 'Nbl', 'Ncl', 'Ndl', 'Nel',
      'Nfl', 'Ngl', 'Nhl', 'Nil', 'Nll', 'Nml', 'New'], dtype='<U3')
```

Εικόνα 18 Ταξινομημένες κατηγορίες

Από τη στιγμή που έγινε και η ταξινόμηση των κατηγοριών τώρα μπορούμε να κάνουμε την πρόβλεψη ενός δείγματος των δεδομένων. Στο κομμάτι της εκτέλεσης της πρόβλεψης μπορούμε να διακρίνουμε ένα μικρό ποσοστό της ακρίβειας και της ανάκλησης που αποδίδει το μοντέλο.

Η πρόβλεψη γίνεται σε 32 τυχαίες εικόνες από διαφορετικές κατηγορίες ή και ίδιες κατηγορίες. Το μοντέλο διαλέγει τυχαία τις εικόνες που θα προβλέψει και μέσο αυτού μπορεί να γίνει η πρόβλεψη.

Η σωστή πρόβλεψη φαίνεται όταν η κατηγορία της εικόνας θα είναι με πράσινο χρώμα ενώ για λανθασμένη πρόβλεψη η κατηγορία της εικόνας θα είναι με κόκκινο χρώμα.




Εικόνα 19 Δείγματα εκτέλεσης πρόβλεψης

5.5 Πίνακας Σύγχυσης και Αποτελέσματα

Μετά την πρόβλεψη το επόμενο βήμα είναι η δημιουργία του πίνακα σύγχυσης με τα αποτελέσματα της πρόβλεψης.

Ο πίνακας σύγχυσης αποτελεί ένα από τα σημαντικότερα κομμάτια στη δημιουργία αξιολογών αποτελεσμάτων

Ο πίνακας που θα σχηματιστεί θα είναι 2d διαστάσεων όπου θα είναι στις στήλες οι πραγματικές τιμές των εικόνων και στις γραμμές οι προβλεπόμενες τιμές των εικόνων. Ο αριθμός των στηλών και των γραμμών δεν είναι σταθερός διότι περιέχει τυχαιότητα στο κομμάτι της πρόβλεψης των αποτελεσμάτων.



Εικόνα 20 Δείγματα πίνακας σύγχυσης

Με τον πίνακα σύγχυσης μπορούμε να εξάγουμε αποτελέσματα χρησιμοποιώντας τα παρακάτω μέτρα απόδοσης:

- Συνολική ακρίβεια(Accuracy)
- Ακρίβεια(Precision)
- Ευαισθησία(Sensitivity) ή αλλιώς ανάκληση(Recall)
- F1 score

	precision	recall	f1-score	support
0	0.50	0.50	0.50	2
1	0.00	0.00	0.00	1
2	1.00	0.50	0.67	2
3	1.00	1.00	1.00	1
4	0.60	1.00	0.75	3
6	1.00	1.00	1.00	2
7	1.00	1.00	1.00	1
8	1.00	1.00	1.00	1
9	1.00	1.00	1.00	1
10	1.00	1.00	1.00	1
12	1.00	1.00	1.00	1
13	1.00	1.00	1.00	1
22	1.00	1.00	1.00	2
23	1.00	1.00	1.00	1
24	1.00	1.00	1.00	3
26	1.00	1.00	1.00	1
28	0.00	0.00	0.00	1
30	1.00	1.00	1.00	3
31	1.00	1.00	1.00	2
32	0.67	1.00	0.80	2
accuracy			0.88	32
macro avg	0.84	0.85	0.84	32
weighted avg	0.85	0.88	0.85	32

	precision	recall	f1-score	support
0	1.00	0.50	0.67	2
1	0.00	0.00	0.00	0
2	1.00	0.67	0.80	3
4	0.75	1.00	0.86	3
6	1.00	1.00	1.00	3
9	1.00	1.00	1.00	1
11	1.00	1.00	1.00	1
12	1.00	1.00	1.00	1
14	1.00	1.00	1.00	1
16	1.00	1.00	1.00	1
20	1.00	1.00	1.00	2
21	1.00	1.00	1.00	1
22	1.00	1.00	1.00	2
23	1.00	1.00	1.00	2
25	1.00	1.00	1.00	2
27	1.00	1.00	1.00	1
28	1.00	1.00	1.00	2
30	1.00	1.00	1.00	3
32	1.00	1.00	1.00	1
accuracy			0.94	32
macro avg	0.93	0.90	0.91	32
weighted avg	0.98	0.94	0.95	32

Εικόνα 21 Δείγματα Αποτελεσμάτων απόδοσης

Τα αποτελέσματα όπως και ο πίνακας σύγχυσης σε κάθε εκτέλεση του μοντέλου μπορεί να είναι διαφορετική. Όμως για να γίνει καλύτερη ανάλυση των αποτελεσμάτων θα πρέπει να γίνει 100 εκτελέσεις του μοντέλου. Με αποτέλεσμα να δημιουργηθούν διαφορετικά αποτελέσματα στον πίνακα σύγχυσης και στα αποτελέσματα απόδοσης.

Συγκριτικό Αποτελεσμάτων

Σε αυτό το κεφάλαιο θα γίνει σύγκριση των αποτελεσμάτων με τις παρόμοιες έρευνες που αναλύθηκαν στο κεφάλαιο 3 και με τα αποτελέσματα που εξάγει το συνελικτικό μοντέλο τόσο σε ποσοτικό επίπεδο όσο και σε ποιοτικό επίπεδο όπου είναι εφικτό.

Ποσοτικό


Το ποσοτικό κομμάτι περιλαμβάνει έναν συγκεντρωτικό πίνακα που δείχνει τα αποτελέσματα των ήδη υπάρχοντα ερευνών με το δικό μας το συνελικτικό και διαγραμματική απεικόνιση της συνολικής ακρίβειας και της ευαισθησίας.

Παρακάτω παρατίθεται ο συγκεντρωτικός πίνακας με τα αποτελέσματα(όσα κελιά περιέχουν – σημαίνει ότι δεν έγινε καμία αναφορά) από τις έρευνες και τα αποτελέσματα που εξάγει το συνελικτικό μοντέλο

Άρθρο	Μέθοδος Αλγόριθμος Μηχανικής Μάθησης	Σύνολα δεδομένων	Μέθοδος Αξιολόγησης	Συνολική Ακρίβεια	Ευαισθησία
Mario Rosario Guarracino[4]	SDI+ (Segmenting Dermoscopic Images)	ISCI 2017	–	88.8%	81.3%
Yading Yuan[5]	CNN	ISBI Challenge 2017 (2000)	5-fold cross validation	93.4%	82.5%
Jeremy Kawahara[6]	CNN	ISIC-ISBI Challenge (2000)	–	98.0%	54.2%
Farhan Riaz[7]	SVM KNN	PH2(200) ISIC (10000)	10-fold cross validation	82.25% 80.6% (SVM) 74% 79.7% (KNN)	–
Sahar Sabbaghi Mahmouei[9]	SVM	825 δερματολογικ ές εικόνες	70% training 30% testing 10-fold cross validation	–	80.5%

Jeremy Kawahara[10]	CNN	1011 cases (εικόνες)	2-fold cross validation (5 φορές)	80.8%	64.9%
Hang Li[11]	CNN	ISBI 2016 (1279) ISBI 2017 (1100)	—	95.9% 93.9%	—
Titus J. Brinker et al [19]	σύγκριση απόδοσης συνελκτικού νευρωνικού δικτύου CNN	(12.378) δερματοσκοπικές εικόνες ανοιχτού κώδικα	-	-	92.8%
Titus J. Brinker et al [20]	σύγκριση των αλγορίθμων ταξινόμησης εικόνων CNN	(4204) εικόνες δερματοσκοπικές	-	-	82.3%
ours	CNN	2013 εικόνες δερματοσκοπικές	70% training 30% testing	90%	87%

Εν συνεχεία γίνεται προβολή των αποτελεσμάτων και με διαγραμματική απεικόνιση στην ακρίβεια και στην ευαισθησία σε όσες έρευνες απαιτούνται



Εικόνα 22 Διαγραμματική Απεικόνιση

Ποιοτικό

Το ποιοτικό κομμάτι ασχολείται με τη σύγκριση των δεδομένων που χρησιμοποιήθηκαν στην εξαγωγή αποτελεσμάτων σύμφωνα με τις παραπάνω έρευνες αλλά και με το συνελκτικό νευρωνικό της δικιάς μας έρευνας. Οι συγκρίσεις μπορούν να γίνουν μόνο με όσους είχαν τα ίδια δεδομένα μεταξύ τους.

Σύμφωνα με τις έρευνες που έχουν ως δεδομένα ISBI Challenge η έρευνα του Yading Yuan[5] έχει πιο ακριβή αποτελέσματα σε σχέση με αυτή του Jeremy Kawahara[10] διότι η ευαισθησία είναι πολύ χαμηλή. Στις έρευνες του Titus J. Brinker et al η πρώτη έρευνα[19] χρησιμοποιεί περισσότερες εικόνες σε σχέση με την δεύτερη[20] οπότε είναι αναμενόμενο να υπάρχει διαφορά στο ποσοστό της ευαισθησίας παρόλα αυτά η δεύτερη έρευνα φαίνεται να έχει αξιόπιστα αποτελέσματα.

Συμπέρασμα

Το συμπέρασμα στο οποίο καταλήγουμε είναι ότι το μοντέλο είναι αξιόπιστο και στο κομμάτι της εκτέλεσης αλλά και στην εξαγωγή των αποτελεσμάτων κάτι που στις μέρες μας είναι αρκετά δύσκολο να επιτευχθεί με αποτέλεσμα να υπάρχει αξιοπιστία στην έγκαιρη διάγνωση του μελανώματος αλλά και στην θεραπεία του.

Μελλοντικές Εφαρμογές

Για μελλοντικές εφαρμογές που μπορούν να εξεταστούν συμπεριλαμβάνουν την υλοποίηση των πειραμάτων σε καλύτερο hardware με ισχυρότερες gpu ώστε τα πειράματα να διαρκέσουν λιγότερο αλλά και με περισσότερες εποχές στην εκτέλεση του μοντέλου.

Το συγκεκριμένο μοντέλο θα μπορούσε να εφαρμοστεί και σε παραπάνω σύνολα δεδομένων χωρίς περιορισμό κλάσεων για την καλύτερη διεξαγωγή των αποτελεσμάτων ώστε να μελετήσουμε καλύτερα την απόδοση τους. Επίσης θα μπορούσε να γίνει και συνδυασμός από περισσότερα νευρωνικά δίκτυα ώστε να γίνει καλύτερη αξιολόγηση των αποτελεσμάτων. Οπότε θα πρέπει να γίνει εκτενέστερη έρευνα και πειραματισμός σε περισσότερα δεδομένα.

Εκτός αυτού θα μπορούσε το μοντέλο να γίνει και εφαρμογή σε cloud ή standalone ώστε να μπορεί να γίνει αυτόματα η πρόγνωση του μελανώματος με μεγαλύτερη και ταχύτερη πιθανότητα θεραπείας του.

Παράρτημα

Neural Network code

```
# Importing all necessary libraries
from keras.preprocessing.image import ImageDataGenerator
from keras.models import Sequential
from tensorflow.keras import layers
from tensorflow.keras.layers import Conv2D, MaxPooling2D, BatchNormalization, Activation, Dropout, Flatten, Dense
from keras import backend as K
from sklearn.metrics import confusion_matrix, plot_confusion_matrix, multilabel_confusion_matrix
import itertools
from sklearn.model_selection import KFold
import matplotlib.pyplot as plt
import numpy as np
import tensorflow as tf
import tensorflow.keras as keras
from keras import backend
```

```
data_root = ('/content/drive/MyDrive/release_v0/images')
```

```
from google.colab import drive
drive.mount('/content/drive')
```

```
batch_size = 32
IMAGE_SHAPE = 64,64
```

```
image_generator = tf.keras.preprocessing.image.ImageDataGenerator(validation_split = 0.3, rescale=1/255)
image_data_train = image_generator.flow_from_directory(str(data_root), target_size=IMAGE_SHAPE)
```

```
train_image_generator = image_generator.flow_from_directory(str(data_root), subset='training', target_size=IMAGE_SHAPE, shuffle=True, batch_size=batch_size, class_mode='categorical') # Generator for our training data
validation_image_generator = image_generator.flow_from_directory(str(data_root), subset='validation', target_size=IMAGE_SHAPE, shuffle=True, batch_size=batch_size, class_mode='categorical') # Generator for our validation data
```

```
for image_batch, label_batch in image_data_train:
    print("Image batch shape: ", image_batch.shape)
    print("Label batch shape: ", label_batch.shape)
```

break

```
backend.set_image_data_format('channels_last')
classifier = tf.keras.Sequential()
model = tf.keras.Sequential()

model.add(layers.Conv2D(32, (3, 3), activation='relu', input_shape=(64, 64, 3)))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Dropout(0.5))

model.add(layers.Conv2D(64, (3, 3), activation='relu'))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Dropout(0.5))

model.add(layers.Conv2D(64, (3, 3), activation='relu'))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Dropout(0.2))

model.add(layers.Flatten())
model.add(layers.Dense(units=512, activation='relu'))
model.add(layers.Dropout(0.2))
model.add(layers.Dense(units=256, activation='relu'))
model.add(layers.Dropout(0.2))

model.add(layers.Dense(units=34, activation='softmax'))

model.summary()

predictions = model(image_batch)

predictions.shape

model.compile(loss=tf.keras.losses.CategoricalCrossentropy(from_logits=False),
              optimizer='Adam',
              metrics=['accuracy'])

class CollectBatchStats(tf.keras.callbacks.Callback):
    def __init__(self):
        self.batch_losses = []
        self.batch_acc = []

    def on_train_batch_end(self, batch, logs=None):
```

```

self.batch_losses.append(logs['loss'])
self.batch_acc.append(logs['accuracy'])
self.model.reset_metrics()

batch_stats_callback = CollectBatchStats()
history = model.fit(image_data_train,
                    steps_per_epoch=np.ceil(train_image_generator.n/batch_size),
                    validation_data = validation_image_generator,
                    epochs=70,callbacks = [batch_stats_callback],
                    verbose=1)

history.history

train_loss,train_acc = model.evaluate(train_image_generator,steps=45)
test_loss, test_acc = model.evaluate(validation_image_generator,steps=32)
print('Train: %.3f, Test: %.3f'%(train_acc,test_acc))

plt.plot(history.history['accuracy'])
plt.plot(history.history['val_accuracy'])
plt.title('model accuracy')
plt.ylabel('accuracy')
plt.xlabel('epoch')
plt.legend(['train', 'test'], loc='upper left')
plt.show()

plt.plot(history.history['loss'])
plt.plot(history.history['val_loss'])
plt.title('model loss')
plt.ylabel('loss')
plt.xlabel('epoch')
plt.legend(['train', 'test'], loc='upper left')
plt.show()

class_names = sorted(image_data_train.class_indices.items(), key=lambda pair:pair[1])
class_names = np.array([key.title() for key, value in class_names])
class_names

predicted_batch = model.predict(image_batch)
predicted_id = np.argmax(predicted_batch, axis=-1)
predicted_label_batch = class_names[predicted_id]

```

```
label_id = np.argmax(label_batch, axis=-1)
```

```
plt.figure(figsize=(10,10))
plt.subplots_adjust(hspace=0.5)
for n in range(32):
    plt.subplot(6,6,n+1)
    plt.imshow(image_batch[n])
    color = "green" if predicted_id[n] == label_id[n] else "red"
    plt.title(predicted_label_batch[n].title(), color=color)
    plt.axis('off')
_ = plt.suptitle("Model predictions (green: correct, red: incorrect)")
```

```
cm = confusion_matrix(y_true=label_id, y_pred=(predicted_id))
```

```
def plot_confusion_matrix(cm, classes,
                          normalize=False,
                          title='Confusion matrix',
                          cmap=plt.cm.Blues):
    """
    This function prints and plots the confusion matrix.
    Normalization can be applied by setting `normalize=True`.
    """
    plt.imshow(cm, interpolation='nearest', cmap=cmap)
    plt.title(title)
    plt.colorbar()
    tick_marks = np.arange(len(classes))
    plt.xticks(tick_marks, classes, rotation=45)
    plt.yticks(tick_marks, classes)

    if normalize:
        cm = cm.astype('float') / cm.sum(axis=1)[:, np.newaxis]
        print("Normalized confusion matrix")
    else:
        print('Confusion matrix, without normalization')

    print(cm)

    thresh = cm.max() / 2.
    for i, j in itertools.product(range(cm.shape[0]), range(cm.shape[1])):
        plt.text(j, i, cm[i, j],
                 horizontalalignment="center",
                 color="white" if cm[i, j] > thresh else "black")
```

```
plt.tight_layout()
plt.ylabel('True label')
plt.xlabel('Predicted label')

cm_plot_labels = []

plot_confusion_matrix(cm=cm ,classes=cm_plot_labels, title='Confusion Matrix')
```

Βιβλιογραφία

- [1] Abadi, Marten; Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... others. (2016). Tensorflow: A system for large-scale machine learning. In 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16) (pp. 265–283).
- [2] Gulli, A., & Pal, S. (2017). Deep learning with Keras. Packt Publishing Ltd.
- [3] Bisong E. (2019) Google Colaboratory. In: Building Machine Learning and Deep Learning Models on Google Cloud Platform. Apress, Berkeley, CA. https://doi.org/10.1007/978-1-4842-4470-8_7
- [4] Mario Rosario Guarracino, Lucia Maddalena, SDI+: A Novel Algorithm for Segmenting Dermoscopic Images, 2019 IEEE Journal of Biomedical and Health Informatics, vol 23 issue 2, pp 481-488, March 2019
- [5] Yading Yuan, Yeh-Chi Lo, Improving Dermoscopic Image Segmentation With Enhanced Convolutional-Deconvolutional Networks, 2019 IEEE Journal of Biomedical and Health Informatics, vol 23 issue 2, pp 519-526, March 2019
- [6] Jeremy Kawahara, Ghassan Hamarneh, Fully Convolutional Neural Networks to Detect Clinical Dermoscopic Features, 2019 IEEE Journal of Biomedical and Health Informatics, vol 23 issue 2, pp 578-585, March 2019
- [7] Farhan Riaz, Sidra Naeem, Racheel Nawaz, Miguel Coimbra, Active Contours Based Segmentation and Lesion Periphery Analysis for Characterization of Skin Lesions in Dermoscopy Images, 2019 IEEE Journal of Biomedical and Health Informatics, vol 23 issue 2, pp 489-500, March 2019
- [8] Ivan Gonzalez-Diaz, DermaKNet: Incorporating the Knowledge of Dermatologists to Convolutional Neural Networks for Skin lesion Diagnosis, 2019 IEEE Journal of Biomedical and Health Informatics, vol 23 issue 2, pp 547-559, March 2019
- [9] Sahar Sabbaghi Mahmouei, Mohammad Aldeen, William V. Stoecker, Rahil Garnavi, Biologically Inspired QuadTree Color Detection in Dermoscopy Images of Melanoma, 2019 IEEE Journal of Biomedical and Health Informatics, vol 23 issue 2, pp 570-577, March 2019
- [10] Jeremy Kawahara, Sara Daneshvar, Giuseppe Argenziano, Ghassan Hamarneh, Seven-Point Checklist and Skin Lesion Classification Using Multitask Multimodal Neural Nets, 2019 IEEE Journal of Biomedical and Health Informatics, vol 23 issue 2, pp 538-546, March 2019

[11] Hang Li,Xinzi He,Feng Zhou ,Zhen Yu ,Dong Ni, Siping Chen,Tianfu Wang, and Baiying Lei, Dense Deconvolutional Network for Sking Lesion Segmentation, 2019 IEEE Journal of Biomedical and Health Informatics,vol 23 issue 2,pp 527-537,March 2019

[12] K. Korotkov, Josep Quintana , Ricard Campos , America Jes ´ us-Silva, Pablo Iglesias,Susana Puig, Josep Malvehy, and Rafael Garcia , An Improved Skin Lesion Matching Scheme in Total Body Photography, in IEEE Journal of Biomedical and Health Informatics, vol. 23, no. 2, pp. 586-598, March 2019, doi: 10.1109/JBHI.2018.2855409.

[13] F. Navarro, M. Escudero-Viñolo and J. Bescós, Accurate Segmentation and Registration of Skin Lesion Images to Evaluate Lesion Change, in IEEE Journal of Biomedical and Health Informatics, vol. 23, no. 2, pp. 501-508, March 2019, doi: 10.1109/JBHI.2018.2825251.

[14] M. Jahanifar, N. Zamani Tajeddin, B. Mohammadzadeh Asl and A. Gooya, Supervised Saliency Map Driven Segmentation of Lesions in Dermoscopic Images, in IEEE Journal of Biomedical and Health Informatics, vol. 23, no. 2, pp. 509-518, March 2019, doi: 10.1109/JBHI.2018.2839647.

[15] A. Sáez, B. Acha, A. Serrano and C. Serrano, Statistical Detection of Colors in Dermoscopic Images With a Texton-Based Estimation of Probabilities, in IEEE Journal of Biomedical and Health Informatics, vol. 23, no. 2, pp. 560-569, March 2019, doi: 10.1109/JBHI.2018.2823499.

[16] Fabian Pedregosa, Gaël Varoquaux, Alexandre Gramfort, Vincent Michel, Bertrand Thirion, Olivier Grisel, Mathieu Blondel, Peter Prettenhofer, Ron Weiss, Vincent Dubourg, Jake Vanderplas, Alexandre Passos, David Cournapeau, Matthieu Brucher, Matthieu Perrot, Édouard Duchesnay Scikit-learn: Machine Learning in Python 12(85):2825–2830, 2011

[17] Buitinck, Lars, et al. "API design for machine learning software: experiences from the scikit-learn project." arXiv preprint arXiv:1309.0238 (2013).

[18] Harris, C.R., Millman, K.J., van der Walt, S.J. et al. Array programming with NumPy. Nature 585, 357–362 (2020). <https://doi.org/10.1038/s41586-020-2649-2>

[19] Titus J. Brinker, Achim Heklera, Alexander H. Enkb, Carola Berkingc, Sebastian Haferkampd, Axel Hauschilde, Michael Weichenthale, Joachim Klodef, Dirk Schadendorff, Tim Holland-Letzg, Christof von Kallea, Stefan Fröhlinga, Bastian Schillingh,1, Jochen S. Utikali,j, Deep neural networks are superior to dermatologists in melanoma image classification, 2019 European Journal of Cancer 119 11-17 August 2019

- [20] Titus J. Brinker , Achim Hekler , Alexander H. Enk b,Joachim Klode , Axel Hauschild , Carola Berking , Bastian Schilling ,Sebastian Haferkamp , Dirk Schadendorf , Stefan Fröhlinga ,Jochen S. Utikal , Christof von Kalle ,A convolutional neural network trained with dermoscopic images performed on par with 145 dermatologists in a clinical melanoma image classification task, 2019 European Journal of Cancer 111 pp148-154, April 2019
- [21] Géron, Aurélien. Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems. O'Reilly Media, 2019.
- [22] Abadi, Martín, et al. "Tensorflow: Large-scale machine learning on heterogeneous distributed systems." arXiv preprint arXiv:1603.04467 (2016).
- [23] Kingma, D. P., and L. J. Ba. "Adam: A Method for Stochastic Optimization." (2015).
- [24] Goodfellow, Ian, et al. Deep learning. Vol. 1. No. 2. Cambridge: MIT press, 2016.
- [25] Buduma, Nikhil, and Nicholas Locascio. Fundamentals of deep learning: Designing next-generation machine intelligence algorithms. " O'Reilly Media, Inc.", 2017.
- [26] Wani, M. Arif, et al. Advances in deep learning. Springer, 2020.
- [27] Deisenroth, Marc Peter, A. Aldo Faisal, and Cheng Soon Ong. Mathematics for machine learning. Cambridge University Press, 2020.
- [28] Quinn, Joanne, et al. Dive into deep learning: Tools for engagement. Corwin Press, 2019.
- [29] Nielsen, Michael A. Neural networks and deep learning. Vol. 25. San Francisco, CA: Determination press, 2015.
- [30] Wang, H., Czerminski, R. and Jamieson, A.C. (2021), "Neural Networks and Deep Learning", Einhorn, M., Löffler, M., de Bellis, E., Herrmann, A. and Burghartz, P. (Ed.) The Machine Age of Customer Insight, Emerald Publishing Limited, Bingley, pp. 91-101.
- [31] Sewak, Mohit, Md Rezaul Karim, and Pradeep Pujari. Practical convolutional neural networks: implement advanced deep learning models using Python. Packt Publishing Ltd, 2018.
- [32] Agarap, Abien Fred. "Deep learning using rectified linear units (relu)." *arXiv preprint arXiv:1803.08375* (2018).

- [33] S. Alagu and K. Bhoopathy Bagan "Skin cancer classification in dermoscopy images using convolutional neural network" , AIP Conference Proceedings 2336, 040013 (2021) <https://doi.org/10.1063/5.0045757>
- [34] Celebi, M. Emre. "Dermoscopy image analysis in the age of deep learning." *Photonics in Dermatology and Plastic Surgery* 2021. Vol. 11618. International Society for Optics and Photonics, 2021.
- [35] Tognetti, Linda, et al. "A new deep learning approach integrated with clinical data for the dermoscopic differentiation of early melanomas from atypical nevi." *Journal of Dermatological Science* 101.2 (2021): 115-122.
- [36] Steppan, Josef, and Sten Hanke. "Analysis of skin lesion images with deep learning." *arXiv preprint arXiv:2101.03814* (2021).
- [37] Nwankpa, Chigozie, et al. "Activation functions: Comparison of trends in practice and research for deep learning." *arXiv preprint arXiv:1811.03378* (2018).
- [38] Zaccane, Giancarlo. *Getting started with TensorFlow*. Packt Publishing Ltd, 2016.
- [39] Moolayil, Jojo, Jojo Moolayil, and Suresh John. *Learn Keras for Deep Neural Networks*. Apress, 2019.
- [40] Salido, Julie Ann A., and C. Ruiz. "Using deep learning to detect melanoma in dermoscopy images." *Int. J. Mach. Learn. Comput* 8.1 (2018): 61-68.
- [41] Roslin, S. Emalda. "Classification of melanoma from Dermoscopic data using machine learning techniques." *Multimedia Tools and Applications* 79.5 (2020): 3713-3728.
- [42] Baig, Ramsha, et al. "Deep learning approaches towards skin lesion segmentation and classification from dermoscopic images-a review." *Current Medical Imaging* 16.5 (2020): 513-533.
- [43] Ghahfarrokhi, Sepehr Salem, and Hamed Khodadadi. "A Machine Learning Method Based on the Combination of Nonlinear and Texture Features to Diagnose Malignant Melanoma From Dermoscopic Images." (2021).
- [44] Γεωργούλη, Α., 2015. *Τεχνητή νοημοσύνη*. [ηλεκτρ. βιβλ.] Αθήνα:Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών. Διαθέσιμο στο: <http://hdl.handle.net/11419/3381>
- [45] Russell, Stuart J. (Stuart Jonathan). *Artificial Intelligence : a Modern Approach*. Upper Saddle River, N.J. :Prentice Hall, 2010.

[46] Καμπουρλάζος, Β., Παπακώστας, Γ., 2015. Εισαγωγή στην υπολογιστική νοημοσύνη. [ηλεκτρ. βιβλ.] Αθήνα:Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών. Διαθέσιμο στο: <http://hdl.handle.net/11419/3443>

[47] Κύρκος, Ε., 2015. Επιχειρηματική ευφυΐα και εξόρυξη δεδομένων. [ηλεκτρ. βιβλ.] Αθήνα:Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών. Διαθέσιμο στο: <http://hdl.handle.net/11419/1226>

[48] Παπαδόπουλος, Α., Μανωλόπουλος, Ι., Τσίχλας, Κ., 2015. *Ανάκτηση πληροφορίας*. [ηλεκτρ. βιβλ.] Αθήνα:Σύνδεσμος Ελληνικών Ακαδημαϊκών Βιβλιοθηκών. Διαθέσιμο στο: <http://hdl.handle.net/11419/4191>

[49] J. D. Hunter, "Matplotlib: A 2D Graphics Environment," in Computing in Science & Engineering, vol. 9, no. 3, pp. 90-95, May-June 2007, doi: 10.1109/MCSE.2007.55.