

ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ

**ΤΜΗΜΑ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ
ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ**



**Αλγόριθμος Ανίχνευσης Σφαλμάτων σε Γραμμές
Μεταφοράς Ηλεκτρικής Ενέργειας με χρήση
κατάλληλα εξοπλισμένου Μη-Επανδρωμένου
Αεροσκάφους (UAV)**

Ζορμπάς Αλέξανδρος

ΕΞΕΤΑΣΤΙΚΗ ΕΠΙΤΡΟΠΗ

Καθηγητής Καλαϊτζάκης Κωνσταντίνος (Επιβλέπων)

Καθηγητής Ζερβάκης Μιχάλης

Αναπλ. Καθηγητής Παρτσινέβελος Παναγιώτης

Χανιά Μάρτιος 2020

Πρόλογος

Θα ήθελα να ευχαριστήσω, πρωτίστως, τους γονείς μου για την αδιάλειπτη ψυχολογική υποστήριξη κατά την εκπόνηση της παρούσας εργασίας.

Ευχαριστώ τον κ. Καλαϊτζάκη Κωνσταντίνο, Καθηγητή της Σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών Πολυτεχνείου Κρήτης για την υποστήριξη και συνεχόμενη εμπιστοσύνη του έως σήμερα σε εμένα και τις ιδέες μου.

Ευχαριστώ επίσης τον κ. Ζερβάκη Μιχάλη, Καθηγητή της Σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών Πολυτεχνείου Κρήτης για τη πολύτιμη βοήθεια του στη μεταπτυχιακή διατριβή.

Ευχαριστώ τον κ. Παρτσινέβελο Παναγιώτη, Αναπληρωτή Καθηγητή της Σχολής Μηχανικών Ορυκτών Πόρων Πολυτεχνείου Κρήτης για το ενδιαφέρον και τη προσφορά του εργαστηρίου SenseLab στη παρούσα εργασία.

Τέλος, θα ήθελα να ευχαριστήσω το κ. Πλοκαμάκη Γεώργιο, Τομέαρχη Δικτύου ΔΕΔΔΗΕ Χανίων, για την εμπιστοσύνη, τη συμβολή και τη στήριξη που παρείχε τόσο στη διπλωματική όσο στη μεταπτυχιακή διατριβή μου.

Περίληψη

Η επιθεώρηση και συντήρηση του δικτύου μεταφοράς και διανομής ηλεκτρικής ενέργειας ήταν και συνεχίζει να αποτελεί σημαντική πρόκληση για την εξασφάλιση σταθερότητας. Η παρούσα εργασία εξετάζει την αποτελεσματικότητα εφαρμογής σύγχρονων μεθόδων επεξεργασίας εικόνας και τεχνητής νοημοσύνης και την εξέταση των περιορισμών τους προς διευκόλυνση της επιθεώρησης. Η προτεινόμενη μεθοδολογία, γραμμένη σε γλώσσα Python, αποτελείται από τρία στάδια. Στο πρώτο γίνεται εντοπισμός των αγωγών μέσω ενός νευρωνικού δικτύου εκπαιδευμένου για τη συγκεκριμένη εφαρμογή. Στο δεύτερο στάδιο γίνεται προσπάθεια ανίχνευσης της τραβέρσας, αποκλειστικά στα κομμάτια της εικόνας που υπάρχουν αγωγοί. Το φίλτρο Gabor επιτρέπει τον εντοπισμό της σε διάφορες διευθύνσεις φιλτράροντας την εικόνα με αντίστοιχο kernel. Στο τρίτο και τελευταίο στάδιο, προτείνονται δύο επιμέρους μεθοδολογίες για τον εντοπισμό των μονωτήρων. Η μία βασίζεται σε φιλτράρισμα με μορφολογικούς συντελεστές και η δεύτερη στην εκπαίδευση ενός νευρωνικού δικτύου για τον εντοπισμό του σώματος του μονωτήρα. Τέλος, αντιστοιχούνται τα εντοπισμένα pixels στην εικόνα υπέρυθρου φάσματος για την εξαγωγή της θερμοκρασίας καθενός μονωτήρα και την αναζήτηση για σφάλμα.

Abstract

The inspection and maintenance of the electricity transmission and distribution network has been and continues to be a major issue to ensure its stability. This paper examines the effectiveness of modern methods of image processing and artificial intelligence and also examines their limitations for facilitating inspection. The proposed methodology, written in Python, consists of three stages. The first locates the powerlines through a neural network trained for the specific application. In the second stage, an attempt is made to detect the crossarms, exclusively in the parts of the image where powerlines have been detected. The Gabor filter allows the crossarm to be located in different directions by filtering the image with a corresponding kernel. In the third and final stage, two separate methodologies are proposed to detect the insulators. One is based on morphological filtering and the other on training a neural network to locate the body of the insulator. Finally, according to the detected pixels, the infrared image is searched to extract the temperature of each insulator and to detect errors if any.

Περιεχόμενα

1. ΕΙΣΑΓΩΓΗ	11
1.1 Ανασκόπηση της σχετικής βιβλιογραφίας	11
1.2 Στόχος και συνεισφορά της παρούσας Μεταπτυχιακής Διατριβής.....	12
1.3 Δομή Μεταπτυχιακής Διατριβής	12
2. ΔΙΚΤΥΑ ΜΕΤΑΦΟΡΑΣ ΚΑΙ ΔΙΑΝΟΜΗΣ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ	14
2.1 Ιστορική Αναδρομή	14
2.2 Σύγχρονα Συστήματα Ισχύος.....	15
2.2.1 Παραγωγή	15
2.2.2 Μεταφορά	17
2.2.3 Διανομή.....	19
2.2.4 Κατανάλωση.....	20
2.3 Δίκτυα Μέσης Τάσης	20
2.3.1 Ακτινικά δίκτυα μέσης τάσης.....	20
2.3.2 Βρογχοειδή δίκτυα μέσης τάσης	21
2.3.3 Καλώδια μέσης τάσης.....	22
2.3.4 Μονωτήρες	24
2.4 Σφάλματα Υπόγειων Δικτύων Μέσης Τάσης.....	26
2.5 Σφάλματα Εναέριων Δικτύων Μέσης Τάσης.....	27
2.5.1 Ρύπανση Μονωτήρων Εξωτερικού Χώρου	27
2.5.2 Αναγνώριση Ελαττωματικών Μονωτήρων	28
3. ΥΠΕΡΥΘΡΗ ΘΕΡΜΟΓΡΑΦΙΑ.....	33
3.1 Εισαγωγή	33
3.1.1 Υπέρυθρη Ακτινοβολία	33
3.1.2 Συντελεστής Εκπομπής (Emissivity)	35
3.1.3 Εφαρμογές Υπέρυθρης Θερμογραφίας	35
4. ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ.....	40
4.1 Εισαγωγικά	40
4.2 Convolutional Neural Networks (CNNs)	42
4.3 Image Classification	43
4.4 Image Sequence Classification	45
4.4.1 Long Short-Term Memory Recurrent Neural Networks (LSTM RNNs)	45
4.5 Object Detection	50
4.5.1 Region Convolutional Neural Networks (R-CNNs).....	50
4.5.2 Fast R-CNNs.....	51
4.5.3 Faster R-CNNs	52
4.5.4 Mask R-CNNs	53

5. ΜΕΘΟΔΟΛΟΓΙΑ ΕΝΤΟΠΙΣΜΟΥ ΣΦΑΛΜΑΤΟΣ	54
5.1 Εισαγωγικά	54
5.2 VGG16.....	55
5.3 Transfer Learning	57
5.4 Προτεινόμενη μεθοδολογία.....	58
5.4.1 Στάδιο 1 – Εντοπισμός Αγωγών	58
5.4.2 Στάδιο 2 – Εντοπισμός Τραβέρσας	75
5.4.3 Στάδιο 3 – Εντοπισμός Μονωτήρων	85
6. ΣΥΜΠΕΡΑΣΜΑΤΑ – ΜΕΛΛΟΝΤΙΚΕΣ ΕΠΕΚΤΑΣΕΙΣ	94
7. ΒΙΒΛΙΟΓΡΑΦΙΑ.....	96

ΚΑΤΑΛΟΓΟΣ ΕΙΚΟΝΩΝ

ΕΙΚΟΝΑ 1 ΣΤΑΤΟΡΑΣ – ΡΟΤΟΡΑΣ ΓΕΝΝΗΤΡΙΑΣ AC	16
ΕΙΚΟΝΑ 2 ΓΡΑΜΜΕΣ ΜΕΤΑΦΟΡΑΣ ΔΕΚΕΜΒΡΙΟΣ 2013 – Α.Δ.Μ.Η.Ε.....	17
ΕΙΚΟΝΑ 3 ΧΑΡΤΗΣ ΔΙΑΣΥΝΔΕΔΕΜΕΝΟΥ ΔΙΚΤΥΟΥ ΕΛΛΑΔΑΣ (ΠΗΓΗ: Α.Δ.Μ.Η.Ε.).....	18
ΕΙΚΟΝΑ 4 ΜΕΤΑΦΟΡΑ ΚΑΙ ΔΙΑΝΟΜΗ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ (ΠΗΓΗ: ΔΙΑΧΕΙΡΙΣΤΗΣ ΤΟΥ ΕΛΛΗΝΙΚΟΥ ΔΙΚΤΥΟΥ ΔΙΑΝΟΜΗΣ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ – Δ.Ε.Δ.Δ.Η.Ε.).....	19
ΕΙΚΟΝΑ 5 ΑΚΤΙΝΙΚΟ ΔΙΚΤΥΟ ΜΕΣΗΣ ΤΑΣΗΣ	21
ΕΙΚΟΝΑ 6 ΒΡΟΓΧΟΕΙΔΕΣ ΔΙΚΤΥΟ ΜΕΣΗΣ ΤΑΣΗΣ.....	22
ΕΙΚΟΝΑ 7 ΜΟΝΟΦΑΣΙΚΟ ΚΑΛΩΔΙΟ ΜΕΣΗΣ ΤΑΣΗΣ.....	23
ΕΙΚΟΝΑ 8 ΤΡΙΦΑΣΙΚΟ ΚΑΛΩΔΙΟ ΜΕΣΗΣ ΤΑΣΗΣ	23
ΕΙΚΟΝΑ 9 ΗΛΕΚΤΡΙΚΟ ΤΟΞΟ ΣΕ ΥΠΟΣΤΑΘΜΟ ΜΕΣΗΣ ΤΑΣΗΣ	27
ΕΙΚΟΝΑ 10 ΕΠΙΘΕΩΡΗΣΗ ΓΡΑΜΜΗΣ ΥΨΗΛΗΣ ΤΑΣΗΣ - ΕΛΙΚΟΠΤΕΡΟ	29
ΕΙΚΟΝΑ 11 ΕΠΙΘΕΩΡΗΣΗ ΜΕΣΩ ΣΜΗΕΑ	29
ΕΙΚΟΝΑ 12 ΣΑΠΙΣΜΕΝΗ ΚΟΡΥΦΗ ΞΥΛΙΝΟΥ ΣΤΥΛΟΥ.....	30
ΕΙΚΟΝΑ 13 ΘΕΡΜΟΚΑΜΕΡΑ ΧΕΙΡΟΣ FLIR	30
ΕΙΚΟΝΑ 14 ΕΙΚΟΝΑ ΘΕΡΜΙΚΟΥ ΦΑΣΜΑΤΟΣ ΤΡΑΒΕΡΣΑΣ ΞΥΛΙΝΟΥ ΣΤΥΛΟΥ ΜΕΣΗΣ ΤΑΣΗΣ	32
ΕΙΚΟΝΑ 15 ΗΛΕΚΤΡΟΜΑΓΝΗΤΙΚΟ ΦΑΣΜΑ	34
ΕΙΚΟΝΑ 16 ΘΕΡΜΟΓΡΑΦΙΚΗ ΕΠΙΘΕΩΡΗΣΗ ΚΤΙΡΙΟΥ.....	36
ΕΙΚΟΝΑ 17 ΘΕΡΜΟΓΡΑΦΙΚΗ ΕΠΙΘΕΩΡΗΣΗ ΦΩΤΟΒΟΛΤΑΪΚΟΥ ΠΑΡΚΟΥ	36
ΕΙΚΟΝΑ 18 ΕΝΤΟΠΙΣΜΟΣ ΑΝΘΡΩΠΙΝΟΥ ΣΩΜΑΤΟΣ	37
ΕΙΚΟΝΑ 19 ΘΕΡΜΙΚΗ ΑΠΕΙΚΟΝΙΣΗ ΤΜΗΜΑΤΟΣ ΠΛΑΚΕΤΑΣ	38
ΕΙΚΟΝΑ 20 ΘΕΡΜΙΚΗ ΕΙΚΟΝΑ ΜΕΤΑΣΧΗΜΑΤΙΣΤΗ ΥΠΟΣΤΑΘΜΟΥ.....	39
ΕΙΚΟΝΑ 21 ΘΕΡΜΙΚΗ ΕΙΚΟΝΑ ΠΥΛΩΝΑ.....	39
ΕΙΚΟΝΑ 22 (ΑΡΙΣΤΕΡΑ) ΠΡΟΣΕΓΓΙΣΤΙΚΟ ΜΟΝΤΕΛΟ ΒΙΟΛΟΓΙΚΟΥ ΝΕΥΡΩΝΑ - (ΔΕΞΙΑ) ΜΑΘΗΜΑΤΙΚΟ ΜΟΝΤΕΛΟ ΝΕΥΡΩΝΑ-ΚΟΜΒΟΥ	41
ΕΙΚΟΝΑ 23 (ΑΡΙΣΤΕΡΑ) SIGMOID - ΠΕΡΙΟΡΙΣΜΟΣ ΕΞΟΔΟΥ ΚΟΜΒΟΥ ΣΕ $[0,1]$ – (ΔΕΞΙΑ) ΤΑΝΗ - ΠΕΡΙΟΡΙΣΜΟΣ ΕΞΟΔΟΥ ΚΟΜΒΟΥ ΣΕ $[-1,1]$	41
ΕΙΚΟΝΑ 24 RELU - ΠΕΡΙΟΡΙΣΜΟΣ ΕΞΟΔΟΥ ΚΟΜΒΟΥ ΣΕ $[0,+\infty)$	42
ΕΙΚΟΝΑ 25 ΠΕΡΙΠΤΩΣΕΙΣ LAYERS ΣΕ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	42
ΕΙΚΟΝΑ 26 ΣΥΓΚΡΙΣΗ LAYERS NN (ΑΡΙΣΤΕΡΑ) – CNN (ΔΕΞΙΑ).....	43
ΕΙΚΟΝΑ 27 UNSUPERVISED CLASSIFICATION.....	44
ΕΙΚΟΝΑ 28 REPEATING MODULE LSTM.....	46
ΕΙΚΟΝΑ 29 ΣΤΑΔΙΟ 1 - LSTM.....	46
ΕΙΚΟΝΑ 30 ΣΤΑΔΙΟ 2 - LSTM.....	47
ΕΙΚΟΝΑ 31 ΣΤΑΔΙΟ 3 - LSTM.....	48
ΕΙΚΟΝΑ 32 ΣΤΑΔΙΟ 4 - LSTM.....	48

EIKONA 33 RNN CLASSIFICATION TYPES	49
EIKONA 34 ΑΛΥΣΙΔΩΤΗ ΔΟΜΗ LSTM (ΟΠΟΥ Α ΙΔΙΑ ΔΟΜΗ ΜΕ ΜΕΣΑΙΟ MODULE)	50
EIKONA 35 ΑΡΧΙΤΕΚΤΟΝΙΚΗ R-CNN	51
EIKONA 36 ΑΡΧΙΤΕΚΤΟΝΙΚΗ FAST R-CNN	52
EIKONA 37 ΑΡΧΙΤΕΚΤΟΝΙΚΗ FASTER R-CNN	52
EIKONA 38 ΑΡΧΙΤΕΚΤΟΝΙΚΗ VGG16.....	56
EIKONA 39 ΓΕΝΙΚΟ ΔΙΑΓΡΑΜΜΑ ΕΝΤΟΠΙΣΜΟΥ ΑΓΩΓΩΝ.....	58
EIKONA 40 ΑΡΧΙΤΕΚΤΟΝΙΚΗ ΕΩΣ BLOCK1 VGG16.....	59
EIKONA 41 BLOCK1 ACCURACY - LOSS.....	60
EIKONA 42 ΟΡΙΣΜΕΝΑ ΦΙΛΤΡΑ (KERNELS) ΤΟΥ BLOCK1_CONV2	62
EIKONA 43 TEST IMAGE.....	63
EIKONA 44 FEATURE MAPS BLOCK1_CONV2	64
EIKONA 45 ΑΡΧΙΤΕΚΤΟΝΙΚΗ ΕΩΣ BLOCK2 VGG16.....	65
EIKONA 46 BLOCK2 ACCURACY - LOSS.....	66
EIKONA 47 ΟΡΙΣΜΕΝΑ ΦΙΛΤΡΑ (KERNELS) ΤΟΥ BLOCK2_CONV2	68
EIKONA 48 FEATURE MAPS BLOCK2_CONV2	69
EIKONA 49 ΑΡΧΙΤΕΚΤΟΝΙΚΗ ΕΩΣ BLOCK3 VGG16.....	70
EIKONA 50 BLOCK3 ACCURACY - LOSS.....	71
EIKONA 51 KERNELS BLOCK3_CONV3.....	72
EIKONA 52 BLOCK4 ACCURACY - LOS	74
EIKONA 53 ΣΤΑΔΙΟ 2	75
EIKONA 54 GABOR KERNELS.....	77
EIKONA 55 ΕΙΚΟΝΕΣ ΜΕ ΤΡΑΒΕΡΣΑ ΞΥΛΙΝΟΥ ΣΤΥΛΟΥ ΜΕΣΗΣ ΤΑΣΗΣ ΣΕ ΟΡΙΖΟΝΤΙΑ ΚΑΙ ΔΙΑΓΩΝΙΑ ΔΙΕΥΘΥΝΣΗ.....	78
EIKONA 56 ΦΙΛΤΡΑΡΙΣΜΑ ΜΕ GABOR KERNELS.....	79
EIKONA 57 ΔΗΜΙΟΥΡΓΙΑ ROI ΓΥΡΩ ΑΠΟ ΕΝΤΟΠΙΣΜΕΝΗ ΤΡΑΒΕΡΣΑ	80
EIKONA 58 ΕΝΤΟΠΙΣΜΟΣ ΤΡΑΒΕΡΣΑΣ ΜΕΣΩ COLOR THRESHOLDING.....	81
EIKONA 59 HSV COLOR THRESHOLDING	82
EIKONA 60 CIE L*A*B* COLOR THRESHOLDING	83
EIKONA 61 YCBCR COLOR THRESHOLDING	84
EIKONA 62 ΔΗΜΙΟΥΡΓΙΑ ROI ΓΥΡΩ ΑΠΟ ΕΝΤΟΠΙΣΜΕΝΗ ΤΡΑΒΕΡΣΑ.....	85
EIKONA 63 HIGH VOLTAGE INSULATOR DETECTION ACCURACY - LOSS.....	86
EIKONA 64 ΑΡΧΙΤΕΚΤΟΝΙΚΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ HV INSULATOR DETECTION	87
EIKONA 65 ΠΑΡΑΔΕΙΓΜΑΤΑ ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗΣ ΕΙΚΟΝΩΝ ΓΙΑ ΜΟΝΩΤΗΡΕΣ ΥΨΗΛΗΣ ΤΑΣΗΣ ..88	
EIKONA 66 ΠΑΡΑΔΕΙΓΜΑΤΑ ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗΣ ΕΙΚΟΝΩΝ ΓΙΑ ΜΟΝΩΤΗΡΕΣ ΜΕΣΗΣ ΤΑΣΗΣ89	
EIKONA 67 IMAGE PROCESSING ΓΙΑ ΕΝΤΟΠΙΣΜΟ ΜΟΝΩΤΗΡΩΝ ΜΕΣΗΣ ΤΑΣΗΣ.....	90
EIKONA 68 ΤΜΗΜΑ ΤΩΝ ΜΟΝΩΤΗΡΩΝ ΧΩΡΙΣ ΤΗ ΤΡΑΒΕΡΣΑ.....	90

EIKONA 69 ADAPTIVE THRESHOLD.....	91
EIKONA 70 EROSION AND DILATION.....	91
EIKONA 71 SECOND DILATION	91
EIKONA 72 ΕΝΤΟΠΙΣΜΕΝΟΙ ΜΟΝΩΤΗΡΕΣ	92
EIKONA 73 ΕΝΤΟΠΙΣΜΟΣ «ΣΩΜΑΤΟΣ» ΜΟΝΩΤΗΡΑ.....	92
EIKONA 74 ΜΕΤΡΗΣΕΙΣ ΘΕΡΜΟΚΡΑΣΙΑΣ ΜΟΝΩΤΗΡΩΝ ΣΕ ΒΑΘΜΟΥΣ ΚΕΛΣΙΟΥ (ΣΦΑΛΜΑ ΣΤΟ ΚΑΤΩ ΑΡΙΣΤΕΡΑ).....	93

ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ

ΠΙΝΑΚΑΣ 1 ΣΤΟΙΧΕΙΑ ΕΚΠΑΙΔΕΥΣΗΣ ΕΩΣ BLOCK1	60
ΠΙΝΑΚΑΣ 2 ΑΠΟΤΕΛΕΣΜΑΤΑ ΕΚΠΑΙΔΕΥΣΗΣ ΕΩΣ BLOCK1	61
ΠΙΝΑΚΑΣ 3 ΣΤΟΙΧΕΙΑ ΕΚΠΑΙΔΕΥΣΗΣ ΕΩΣ BLOCK2	66
ΠΙΝΑΚΑΣ 4 ΑΠΟΤΕΛΕΣΜΑΤΑ ΕΚΠΑΙΔΕΥΣΗΣ ΕΩΣ BLOCK2	67
ΠΙΝΑΚΑΣ 5 ΣΤΟΙΧΕΙΑ ΕΚΠΑΙΔΕΥΣΗΣ ΕΩΣ BLOCK3	71
ΠΙΝΑΚΑΣ 6 ΑΠΟΤΕΛΕΣΜΑΤΑ ΕΚΠΑΙΔΕΥΣΗΣ ΕΩΣ BLOCK3	71
ΠΙΝΑΚΑΣ 7 ΣΤΟΙΧΕΙΑ ΕΚΠΑΙΔΕΥΣΗΣ ΕΩΣ BLOCK4	74
ΠΙΝΑΚΑΣ 8 ΑΠΟΤΕΛΕΣΜΑΤΑ ΕΚΠΑΙΔΕΥΣΗΣ ΕΩΣ BLOCK4	74
ΠΙΝΑΚΑΣ 9 ΣΤΟΙΧΕΙΑ ΕΚΠΑΙΔΕΥΣΗΣ – HV INSULATOR DETECTION	86
ΠΙΝΑΚΑΣ 10 ΑΠΟΤΕΛΕΣΜΑΤΑ ΕΚΠΑΙΔΕΥΣΗΣ – HV INSULATOR DETECTION	86

1.

ΕΙΣΑΓΩΓΗ

1.1 Ανασκόπηση της σχετικής βιβλιογραφίας

Είναι σύνηθες φαινόμενο η διακοπή παροχής ηλεκτρικής ενέργειας να οφείλεται σε κάποιο σφάλμα μέσα στο δίκτυο μεταφοράς και διανομής της. Η επιθεώρηση του δικτύου πραγματοποιείται κυρίως με χρήση εναέριων μέσων όπως ελικόπτερα, ακόμα και μέσω ανεπτυγμένων ρομποτικών συστημάτων συγκεκριμένα για το σκοπό αυτό [1]. Η εδραίωση των Συστημάτων μη-Επανδρωμένων Αεροσκαφών έχει διευρύνει τις εφαρμογές τους, συμπεριλαμβάνοντας τον τομέα της ενέργειας. Το γεγονός αυτό οδήγησε στην ανάπτυξη μεθόδων επεξεργασίας εικόνας για τον εντοπισμό τμημάτων του δικτύου. Σημαντικό ρόλο εμφανίζεται να έχει ο μετασχηματισμός Hough στον εντοπισμό των αγωγών ως ευθείες, όπως έχει προκύψει από τη δημοσίευση της διπλωματικής εργασίας του φοιτητή [2], λόγω της συνέχειας ως γραμμή, της ομοιότητας του αντικειμένου και της διαφοροποίησης από την υπόλοιπη εικόνα και άλλων παραπλήσιων μεθοδολογιών που τον αξιοποιούν [3] [4]. Συνεχίζοντας ένα βήμα παραπέρα, έγιναν προσπάθειες ενσωμάτωσης των νευρωνικών δικτύων στον εντοπισμό αγωγών. Έχοντας ήδη ως βάση την επιτυχή εξαγωγή ακμών από εικόνα μέσω Convolutional Neural Networks [5] [6], η εκπαίδευση τους για ανίχνευση αγωγών ήταν το επόμενο στάδιο [7] [8] [9]. Η δημιουργία νέας αρχιτεκτονικής δικτύων, των Deep Neural Networks, με μεγαλύτερη ακρίβεια στη κατηγοριοποίηση από τα κλασσικά Convolutional [10], άρχισε να τραβά προσοχή με αποτέλεσμα να αναπτυχθούν μοντέλα και dataset για τον εντοπισμό των μονωτήρων [11] [12] [13] [14]. Αυτό οφείλεται στην ικανότητα τους να εντοπίζουν πιο πολύπλοκα μοτίβα όσο πιο πολλά layers διαθέτουν.

1.2 Στόχος και συνεισφορά της παρούσας Μεταπτυχιακής Διατριβής

Τα νευρωνικά δίκτυα συνδέονται αδιαμφισβήτητα με τον τομέα επεξεργασίας εικόνας μέσω της συνέλιξης και της κατηγοριοποίησης εικόνων. Η εξέλιξη των καρτών γραφικών για τους υπολογιστές επέτρεψε την υλοποίηση και εκπαίδευση αρχιτεκτονικών νευρωνικών δικτύων. Η παρούσα εργασία επικεντρώνει το ενδιαφέρον της στην εκπαίδευση νευρωνικών δικτύων μέσω transfer learning για την επιθεώρηση του δικτύου μεταφοράς ηλεκτρικής ενέργειας και συγκεκριμένα τον εντοπισμό σφάλματος σε μονωτήρες μέσης τάσης. Για να επιτευχθεί κάτι τέτοιο, κρίθηκε απαραίτητη η δημιουργία τριών επιμέρους σταδίων: (α) για την ανίχνευση των αγωγών μέσης τάσης, (β) της τραβέρσας και τέλος (γ) των μονωτήρων. Στο Η απουσία διαθέσιμων εικόνων τραβέρσας και μονωτήρων μέσης τάσης, οδήγησε στην εφαρμογή μεθόδων επεξεργασίας εικόνας για να επιτευχθεί ο στόχος τους. Το νευρωνικό δίκτυο που εκπαιδεύτηκε, ωστόσο, για ανίχνευση μονωτήρων υψηλής τάσης, φαίνεται να πετυχαίνει σε μερικό βαθμό τον εντοπισμό της μέσης. Αυτό συμβαίνει λόγω της παρόμοιας μορφολογίας που παρουσιάζουν οι μονωτήρες και η διάκριση τους από το γύρω περιβάλλον.

Τελικοί στόχοι της μεταπτυχιακής διατριβής είναι η δημιουργία μιας μεθοδολογίας εντοπισμού (α) των αγωγών μεταφοράς ηλεκτρικής ενέργειας, (β) της τραβέρσας, (γ) των μονωτήρων μέσης τάσης προς εύρεση σφαλμάτων και η εύρεση περιορισμών στο συνδυασμό μεθόδων επεξεργασίας εικόνας με πιο προηγμένες τεχνικές επεξεργασίας.

1.3 Δομή Μεταπτυχιακής Διατριβής

Στο Κεφάλαιο 2 – Δίκτυα Μεταφοράς και Διανομής Ηλεκτρικής Ενέργειας παρουσιάζονται τα βασικά στοιχεία των σύγχρονων συστημάτων ισχύος, πώς παράγεται, μεταφέρεται και διανέμεται η ηλεκτρική ενέργεια, τι τύποι κατανάλωσης υπάρχουν και μία σύντομη περιγραφή των δικτύων μέσης τάσης μαζί με τα σφάλματα τους.

Στο Κεφάλαιο 3 – Υπέρυθρη Θερμογραφία πραγματοποιείται μια εισαγωγή στο αντικείμενο της Υπέρυθρης Θερμογραφίας. Περιγράφεται η σημασία του συντελεστή εκπομπής και ορισμένες από τις πιο διαδεδομένες εφαρμογές της.

Στο *Κεφάλαιο 4 – Νευρωνικά Δίκτυα* παρουσιάζεται το απαραίτητο γνωστικό υπόβαθρο για τη κατανόηση της λειτουργίας των νευρικών δικτύων. Αναλύονται τα Convolutional Neural Networks και περιγράφονται σύγχρονες τεχνικές Image Classification και Object Detection.

Στο *Κεφάλαιο 5 – Μεθοδολογία Εντοπισμού Σφάλματος* περιγράφεται στο σύνολο της η προτεινόμενη μεθοδολογία. Πιο συγκεκριμένα, στα υποκεφάλαια 5.2 – 5.3 περιγράφεται η αρχιτεκτονική του νευρωνικού δικτύου VGG16 που χρησιμοποιήθηκε. Στη συνέχεια, στο υποκεφάλαιο 5.4.1 αναλύεται το πρώτο στάδιο της μεθοδολογίας που έχει ως στόχο τον εντοπισμό των αγωγών μέσα στην εικόνα εκπαιδεύοντας και χρησιμοποιώντας ένα μέρος από το VGG16. Το υποκεφάλαιο 5.4.2 αφορά το δεύτερο στάδιο που είναι υπεύθυνο για την ανίχνευση της τραβέρσας αναλύοντας δύο πιθανούς τρόπους ανίχνευσης μέσω χρήσης φίλτρων Gabor και μέσω color thresholding. Στο υποκεφάλαιο 5.4.3 περιγράφεται το τελευταίο στάδιο της μεθοδολογίας, το οποίο περιέχει τον εντοπισμό των μονωτήρων υψηλής και μέσης τάσης μέσω της χρήσης του VGG16.

Στο *Κεφάλαιο 6 – Συμπεράσματα – Μελλοντικές Επεκτάσεις* παρουσιάζεται μια τελική ανασκόπηση των σταδίων της προτεινόμενης μεθοδολογίας και της απόδοσης τους. Ταυτόχρονα προτείνονται πιθανές επεκτάσεις και βελτιώσεις της μεθοδολογίας που βασίζονται πρωτίστως στην ύπαρξη dataset με εικόνες από τραβέρσες και μονωτήρες, μέσω της χρήσης του οποίου επεκτείνεται η απόδοση των νευρωνικών δικτύων αντικαθιστώντας τις πιο πολλές τεχνικές επεξεργασίας εικόνας.

2.

ΔΙΚΤΥΑ ΜΕΤΑΦΟΡΑΣ ΚΑΙ ΔΙΑΝΟΜΗΣ ΗΛΕΚΤΡΙΚΗΣ ΕΝΕΡΓΕΙΑΣ

2.1 Ιστορική Αναδρομή

Οι τρόποι και τα μέσα μεταφοράς και διανομής της ηλεκτρικής ενέργειας χρονολογούνται από το 19^ο αιώνα. Έως τότε υπήρχαν τρεις τρόποι μεταφοράς της, (α) τηλεδυναμικά (αγωγός σε κίνηση), (β) πνευματικά (πεπιεσμένος αέρας) και (γ) υδραυλικά (πεπιεσμένο υγρό). Λόγω των διαφορετικών απαιτήσεων τάσης συσκευών, εγκαθιστούσαν ειδικά διαμορφωμένες γεννήτριες που όφειλαν να βρίσκονται σε κοντινή απόσταση. Ήταν γνωστό ότι η μεταφορά ηλεκτρικής ενέργειας σε μακρινές αποστάσεις ήταν εφικτή σε υψηλή τάση, αρκεί να γινόταν η μετατροπή της τάσης αποδοτικά. Η προτίμηση ενός δικτύου εναλλασσόμενου ρεύματος (AC) έναντι του εγκατεστημένου συνεχούς (DC) έγινε στο τέλος του 19^{ου} αιώνα χάρη στη κατασκευή των μετασχηματιστών. Η μετατροπή σε DC γινόταν μέσω rotary converters και mercury-arc βαλβίδων. Ήταν πλέον δυνατή η δημιουργία εργοστασίων παραγωγής για διανομή σε

καταναλωτές και για κάθε τύπο φορτίου, ακόμα και αν η συχνότητα λειτουργίας ήταν διαφορετική (μέσω rotary converter).

Η απότομη εκβιομηχάνιση στις αρχές του 20^{ου} αιώνα κατέστησε τα δίκτυα μεταφοράς ηλεκτρικής ενέργειας σημαντικό κριτήριο για την οικονομική (και όχι μόνο) πρόοδο των πόλεων. Η περαιτέρω εγκατάσταση πυλώνων υψηλής τάσης και μεγάλων σταθμών παραγωγής που ώθησαν ιστορικά γεγονότα, όπως ο Πρώτος Παγκόσμιος Πόλεμος, διαδραμάτισαν καθοριστικό ρόλο στην εξέλιξη της τεχνολογίας για πιο αποδοτική παροχή ενέργειας.

2.2 Σύγχρονα Συστήματα Ισχύος

Ένα σύστημα ισχύος είναι ένα δίκτυο όπου παράγεται, μεταφέρεται, διανέμεται και καταναλώνεται ηλεκτρική ενέργεια. Για τη σωστή λειτουργία του απαιτείται η παροχή της να γίνεται με το ελάχιστο δυνατό κόστος, επιβαρύνοντας όσο δυνατόν λιγότερο το περιβάλλον για να εξασφαλίσει αξιόπιστη τροφοδότηση. Η δομή του φαίνεται ως εξής:


1. Παραγωγή
2. Μεταφορά
3. Διανομή
4. Κατανάλωση

2.2.1 Παραγωγή

Η παραγωγή ηλεκτρικής ενέργειας πραγματοποιείται κατά βάση με την επεξεργασία ορυκτών πρωτογενούς ενέργειας, όπως λιγνίτης και πετρέλαιο. Πιο συγκεκριμένα, δε διατίθεται «ελεύθερη» στο φυσικό περιβάλλον, αλλά είναι το αποτέλεσμα της μετατροπής από άλλη μορφή ενέργειας σε εργοστάσια ηλεκτρισμού. Υπάρχουν διαφορετικοί τύποι εργοστασίων, όπως θερμικά (καύση άνθρακα) και υδροηλεκτρικοί σταθμοί (αξιοποίηση ροής νερού – υδατοπτώσεις). Οι τελευταίοι αποτελούνται από ένα φράγμα, που συγκρατεί το νερό ώστε να ρέει προς τα κάτω. Στο κάτω μέρος του φράγματος τοποθετούνται υδατοφράκτες για τη ρύθμιση της ποσότητας ροής νερού προς τη τουρμπίνα. Η τουρμπίνα διαθέτει ειδικά πτερύγια χάρη στα οποία η κινητική ενέργεια του νερού μετατρέπεται σε περιστροφική. Στον άξονα της βρίσκεται συνδεδεμένη μια γεννήτρια, έτσι μετατρέπεται η κινητική ενέργεια του νερού σε ηλεκτρική.

Ιδιαίτερα σημαντικοί είναι οι σταθμοί παραγωγής που βασίζονται σε κάποια μορφή ανανεώσιμων πηγών ενέργειας όπως ηλιακή ακτινοβολία και αιολική ενέργεια.

Ένα από τα βασικά στοιχεία των συστημάτων ισχύος είναι η τριφασική γεννήτρια εναλλασσόμενου ρεύματος. Οι σύγχρονες γεννήτριες διαθέτουν δύο πεδία που περιστρέφονται συγχρονισμένα. Το πρώτο πεδίο παράγεται από το ρότορα που διεγείρεται από ρεύμα DC, ενώ το δεύτερο από τριφασικά ρεύματα στις περιελίξεις του πηνίου του στάτη. Στο ρότορα, το DC ρεύμα παράγεται από το σύστημα διέγερσης. Χρησιμοποιούν γεννήτριες εναλλασσόμενου ρεύματος με περιστρεφόμενους ανορθωτές, ενώ διατηρεί τη τάση της γεννήτριας και ελέγχει την άεργο ισχύ. Είναι ικανές να παράγουν υψηλή ισχύ σε υψηλή τάση (έως 30kV) και το μέγεθος τους ποικίλει από 50MW έως 1500MW σε μονάδα παραγωγής.



Εικόνα 1 Στάτορας – Ρότορας Γεννήτριας AC

Η προέλευση της κινητικής ενέργειας είναι πιθανόν να προέρχεται από υδραυλικές τουρμπίνες, ατμοστρόβιλους κλπ. Οι τελευταίοι λειτουργούν σε υψηλές ταχύτητες της τάξεως των 1800 ή 3600 στροφών ανά λεπτό, σε αντίθεση με τις υδραυλικές τουρμπίνες που έχουν αρκετά χαμηλότερες. Όποιος είναι ο τύπος της γεννήτριας, συνδέονται παράλληλα και μεταξύ τους σε ένα κοινό σημείο, τον κόμβο.

Εξίσου σημαντικό συστατικό είναι ο μετασχηματιστής. Στόχος του είναι η μεταφορά ισχύος από ένα επίπεδο τάσης σε άλλο. Στο δεύτερο επίπεδο, η ισχύς δεν είναι ακριβώς ίση με το πρώτο λόγω απωλειών κατά τη μεταφορά μέσα στο μετασχηματιστή. Ως αποτέλεσμα, χρησιμοποιώντας ένα μετασχηματιστή ανύψωσης με λόγο μετασχηματισμού a , το ρεύμα στο δεύτερο επίπεδο μειώνεται με αναλογία $1/a$. Μειώνονται έτσι οι απώλειες της γραμμής, επιτρέποντας τη μεταφορά ενέργειας σε μεγάλες αποστάσεις.

Ο σχεδιασμός γεννητριών περιορίζει τη παραγόμενη τάση σε χαμηλές τιμές (έως 30kV) κυρίως λόγω των απαιτήσεων σε μόνωση. Έτσι για τη μεταφορά ενέργειας σε υψηλά επίπεδα τάσης χρησιμοποιούνται μετασχηματιστές ανύψωσης. Στο τέλος των γραμμών μεταφοράς τοποθετούνται μετασχηματιστές υποβιβασμού για να μειώσουν τη τάση σε κατάλληλη τιμή προς διανομή ή κατανάλωση.

2.2.2 Μεταφορά

Η μεταφορά ηλεκτρικής ενέργειας από τους σταθμούς παραγωγής στους διάφορους υποσταθμούς πραγματοποιείται μέσω του εναέριου δικτύου αγωγών μεταφοράς. Το επίπεδο τάσης χαμηλώνεται ώστε να συνεχιστεί η μεταφορά από τους υποσταθμούς προς τους καταναλωτές μέσω διασυνδεδεμένων αγωγών μεταφοράς.

Στην Ελλάδα, το διασυνδεδεμένο σύστημα μεταφοράς διαθέτει γραμμές των 400kV, εναέριες, υπόγειες γραμμές και υποβρύχια καλώδια των 150kV που συνδέουν τα νησιά της Δυτικής Ελλάδας με το σύστημα και μια υποβρύχια σύνδεση στα 66kV Κέρκυρα-Ηγουμενίτσα (πηγή: Ανεξάρτητος Διαχειριστής Μεταφοράς Ηλεκτρικής Ενέργειας – Α.Δ.Μ.Η.Ε.).

ΓΡΑΜΜΕΣ ΜΕΤΑΦΟΡΑΣ (χλμ. οδευσης)					
	400kV	Σ.Ρ. (D.C.) 400kV	150 kV	66 kV	ΣΥΝΟΛΟ
ΕΝΑΕΡΙΕΣ	2.647	107	8.152	39	10.945
ΥΠΟΒΡΥΧΙΕΣ	0,58		140	15	155
ΥΠΟΓΕΙΕΣ	30		101		131
ΣΥΝΟΛΟ	2.677	107	8.393	54	11.232

Εικόνα 2 Γραμμές Μεταφοράς Δεκέμβριος 2013 – Α.Δ.Μ.Η.Ε

Το σύστημα αποτελείται από δίκτυα υψηλής τάσης, υποσταθμούς ζεύξης δικτύων υψηλής τάσης και υποσταθμούς μετασχηματισμού στα διάφορα επίπεδα τάσης των καταναλωτών. Είναι αναγκαίο οι τάσεις των τριών φάσεων να είναι συμμετρικές και γενικά η τάση σταθερή για να εξασφαλιστεί αξιόπιστη παροχή στο δίκτυο.



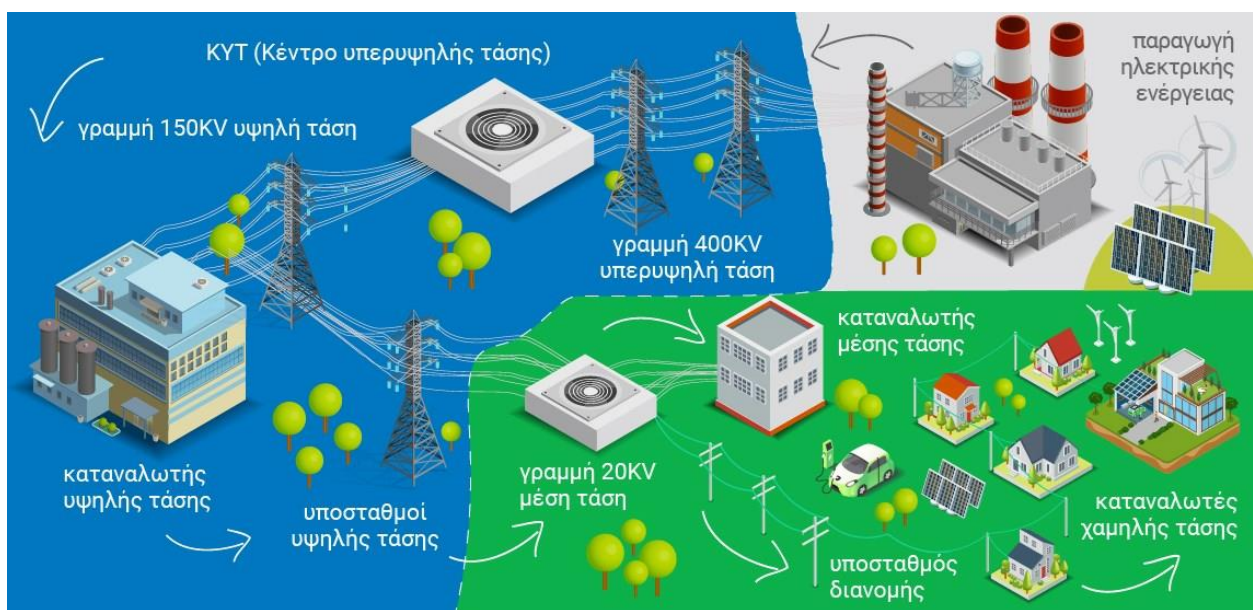
Εικόνα 3 Χάρτης Διασυνδεδεμένου Δικτύου Ελλάδας (πηγή: Α.Δ.Μ.Η.Ε.)

2.2.3 Διανομή

Η ηλεκτρική ενέργεια μεταφέρεται στους υποσταθμούς μεταφοράς, μέσω δικτύων μέσης τάσης (20kV). Στη συνέχεια, μέσω γραμμών διανομών καταλήγει σε υποσταθμούς διανομής όπου γίνεται υποβιβασμός της μέσης τάσης σε χαμηλή (380/220V) για να διανεμηθεί σε καταναλωτές.

Το δίκτυο διανομής περιλαμβάνει:

1. Το δίκτυο διανομής μέσης τάσης (20kV) που μεταφέρει την ηλεκτρική ενέργεια από τους υποσταθμούς μεταφοράς στους υποσταθμούς διανομής.
2. Το δίκτυο διανομής χαμηλής τάσης (380/220V) που μεταφέρει την ηλεκτρική ενέργεια από τους υποσταθμούς διανομής στους καταναλωτές



Εικόνα 4 Μεταφορά και Διανομή ηλεκτρικής ενέργειας (πηγή: Διαχειριστής του Ελληνικού Δικτύου Διανομής Ηλεκτρικής Ενέργειας – Δ.Ε.Δ.Δ.Η.Ε.)

Το δίκτυο διανομής φθάνει έως τον εκάστοτε μετρητή ενέργειας του καταναλωτή. Ύστερα ξεκινά η εσωτερική ηλεκτρική εγκατάσταση που είναι ξεχωριστή για κάθε καταναλωτή ανάλογα με τις ανάγκες του.

2.2.4 Κατανάλωση

Το φορτίο συστημάτων ισχύος μπορεί να χωριστεί στις εξής κατηγορίες:

1. Βιομηχανικό
2. Εμπορικό
3. Οικιακό

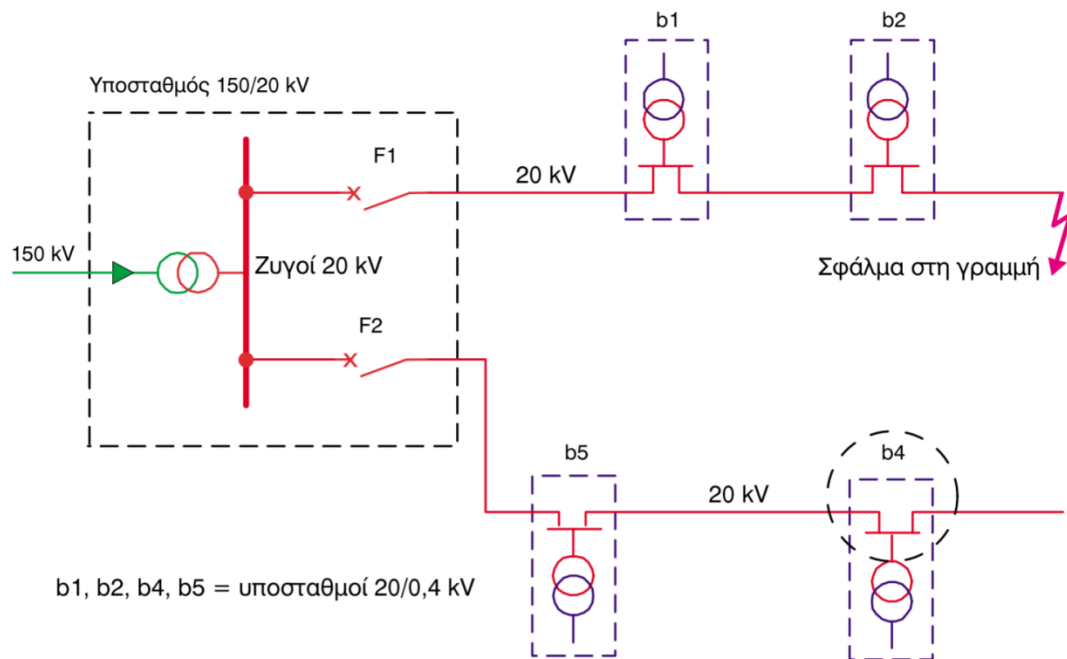
Στο βιομηχανικό εντάσσονται λόγω χάρη κινητήρες επαγωγής εργοστασίων, ενώ στους υπόλοιπους δύο τύπους ανήκουν φωτισμός, θέρμανση και ψύξη ως βασικά φορτία.

2.3 Δίκτυα Μέσης Τάσης

2.3.1 Ακτινικά δίκτυα μέσης τάσης

Οι εναέριες γραμμές 20kV έχοντας ως αφετηρία υποσταθμό 150/20kV απλώνονται προς καταναλωτές μέσης τάσης και υποσταθμούς υποβιβασμού σαν τις ακτίνες ενός κύκλου. Στην αρχή των γραμμών τοποθετείται διακόπτης ισχύος, ο οποίος σε περίπτωση σφάλματος ανοίγει. Αυτό έχει ως αποτέλεσμα κατά μήκος της γραμμής να διακόπτεται η παροχή ενέργειας. Οι συνέπειες της απώλειας μέσης τάσης είναι κρίσιμες και αρκετές φορές επικίνδυνες. Έτσι σε εγκαταστάσεις όπως νοσοκομεία, χημικές βιομηχανίες και στρατόπεδα, που είναι επιτακτικό να μη μένουν χωρίς ενέργεια για μεγάλο χρονικό διάστημα, εγκαθίσταται ένα τοπικό ηλεκτροπαραγωγικό ζεύγος (γεννήτρια 400V με μηχανή πετρελαίου). Το ζεύγος είναι υπεύθυνο για τη παροχή ενέργειας σε κρίσιμα φορτία έως ότου αποκατασταθεί η βλάβη στη γραμμή μέσης τάσης.

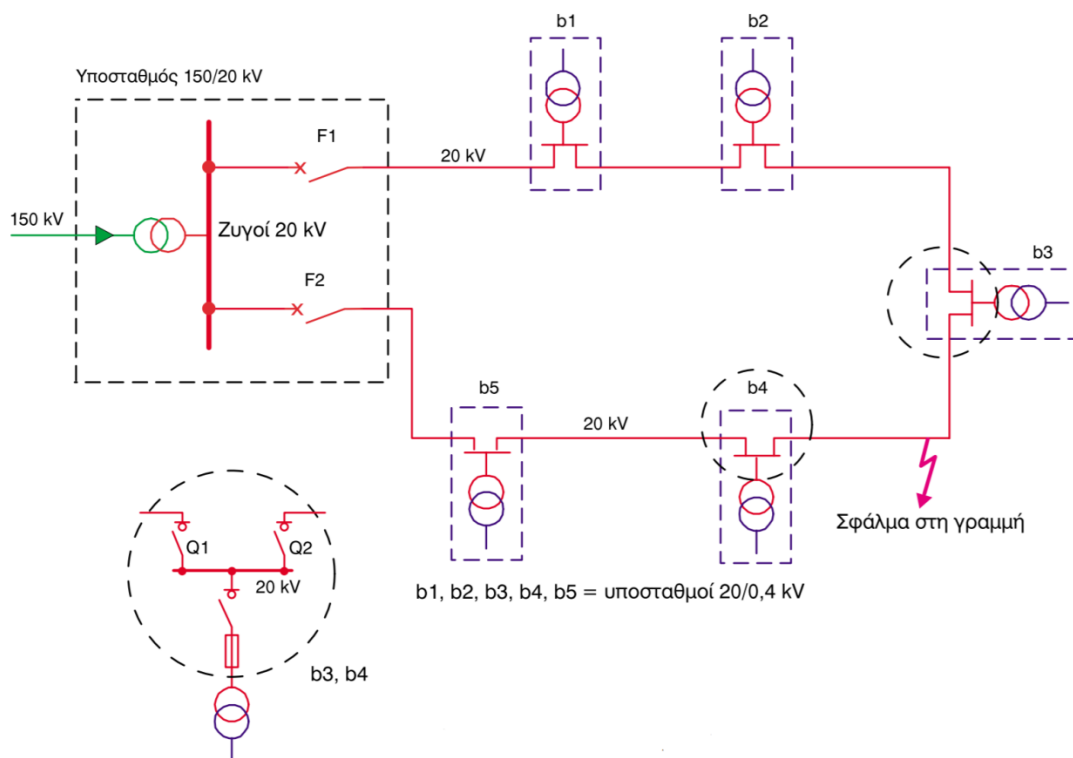
Για το λόγο αυτό, τα ακτινικά δίκτυα δεν είναι ιδιαίτερα διαδεδομένα στη μέση τάση. Το σύνολο των δικτύων στη χαμηλή τάση, ωστόσο, είναι ακτινικού τύπου.



Εικόνα 5 Ακτινικό δίκτυο μέσης τάσης

2.3.2 Βρογχοειδή δίκτυα μέσης τάσης

Σε αντίθεση με τα ακτινικά, στα βρογχοειδή οι γραμμές 20kV σχηματίζουν κλειστό βρόχο ξεκινώντας από τον υποσταθμό και καταλήγοντας ξανά στον ίδιο. Κατά μήκος συνδέονται καταναλωτές σε σειρά ενώ στην αρχή και το τέλος των γραμμών τοποθετούνται διακόπτες ισχύος. Το πλεονέκτημα των βρογχοειδών δικτύων είναι ότι στη περίπτωση ύπαρξης σφάλματος, αφού πρώτα εντοπιστεί το σημείο, ενεργοποιούνται οι διακόπτες φορτίου εκατέρωθεν του σφάλματος διακόπτοντας τη παροχή ενέργειας τοπικά. Αυτό επιτρέπει την ομαλή λειτουργία του υπόλοιπου βρόχου μιας και οι διακόπτες ισχύος κλείνουν όταν ανοίξουν οι απαιτούμενοι διακόπτες φορτίου.




Εικόνα 6 Βρογχοειδές δίκτυο μέσης τάσης

2.3.3 Καλώδια μέσης τάσης

Τα καλώδια μέσης τάσης χωρίζονται σε δύο βασικές κατηγορίες, τα μονοφασικά και τα τριφασικά. Χαρακτηριστικό των τριφασικών είναι ότι κάθε φάση είναι αυτόνομη και μπορεί είτε να είναι συνεστραμμένα μεταξύ τους είτε να εγκαθίστανται ανεξάρτητα το ένα από το άλλο.


Η διαφορά των δύο κατηγοριών είναι πως τα τριφασικά μπορεί να αποτελούνται είτε από ένα κοινό περίβλημα ή να έχει η κάθε φάση ξεχωριστό. Στη περίπτωση του ενιαίου περιβλήματος, υπάρχει ξεχωριστή μόνωση για κάθε καλώδιο. Στη δεύτερη περίπτωση, κάτω από το ξεχωριστό περίβλημα υπάρχει επίσης μόνωση.



Εικόνα 7 Μονοφασικό καλώδιο μέσης τάσης

Τα μέρη του μονοφασικού καλωδίου, όπως φαίνονται παραπάνω είναι τα εξής:

1. Πολύκλωνος στρογγυλός αγωγός (χαλκού ή αλουμινίου)
2. Εσωτερικό ημιαγώγιμο στρώμα
3. Μόνωση
4. Εξωτερικό ημιαγώγιμο στρώμα
5. Ηλεκτρική θωράκιση
6. Πλαστική ταινία προαιρετική
7. Εξωτερικό περίβλημα (μανδύας)



Εικόνα 8 Τριφασικό καλώδιο μέσης τάσης

Τα μέρη του τριφασικού καλωδίου μέσης τάσης είναι :

1. Πολύκλωνος στρογγυλός αγωγός (χαλκού ή αλουμινίου)
2. Εσωτερικό ημιαγώγιμο στρώμα

3. Μόνωση
4. Εξωτερικό ημιαγώγιμο στρώμα
5. Ηλεκτρική θωράκιση
6. Γεμίσματα από πολυπροπυλένιο
7. Πλαστικές ταινίες
8. Εξωτερικό περίβλημα

2.3.4 Μονωτήρες

Η μόνωση μιας γραμμής μεταφοράς καθορίζεται από τις ελάχιστες αποστάσεις μέσα στον αέρα μεταξύ των φάσεων ή μεταξύ των φάσεων και του δυναμικού της γης. Ο ατμοσφαιρικός αέρας αποτελεί από μόνος του ένα μέσο μόνωσης υπαίθριων εγκαταστάσεων υψηλής και μέσης τάσης, όμως απαιτούνται επιπλέον διατάξεις για τη μόνωση των ηλεκτροφόρων στοιχείων μιας εγκατάστασης από τα μη ηλεκτροφόρα. Για το λόγο αυτό χρησιμοποιούνται οι μονωτήρες στα δίκτυα μεταφοράς και διανομής ηλεκτρικής ενέργειας, ώστε να στηρίζουν και να διαχωρίζουν αγωγούς τάσης.

Οι μονωτήρες διακρίνονται σε κατηγορίες ανάλογα το υλικό κατασκευής τους. Οι δύο βασικές είναι οι κεραμικοί και οι συνθετικοί. Οι πρώτοι έχουν κέλυφος κατασκευασμένο από πορσελάνη ή γυαλί και οι συνθετικοί υλικά όπως silicone rubber. Οι κεραμικοί μονωτήρες ήταν η συνήθης επιλογή στα δίκτυα υψηλής τάσης μέχρι τη δεκαετία του 1990. Το 1960 κατασκευάστηκαν οι πρώτοι συνθετικοί μονωτήρες, όμως η αποδοχή της υπεροχής τους έναντι των κεραμικών έγινε αρκετά μετά. Οι συνθετικοί μονωτήρες, εκτός του μειωμένου βάρους, εμφάνισαν καλύτερη απόδοση σε συνθήκες ρύπανσης από τους κεραμικούς.

Εμβαθύνοντας στις κατηγορίες ανάλογα με το υλικό κατασκευής, υπάρχουν:

1. Πορσελάνης: Σύνθετη ύλη από αργίλιο, πυρίτιο και μαγνήσιο. Η πορώδης επιφάνεια των μονωτήρων πορσελάνης καλύπτεται με διηλεκτρικά υλικά κρυσταλλικής μορφής ελαττώνοντας της απώλειες ώστε να επιτευχθεί μείωση της επίδρασης του περιβάλλοντος και ομογενές ηλεκτρικό πεδίο.

2. Γυαλιού: Είναι μίγμα διαφόρων πυριτικών αλάτων και χρησιμοποιείται διότι έχει χαρακτηριστικά μονωτικού υλικού όπως σχετικά μεγάλη διηλεκτρική σταθερά μαζί με ειδική αντίσταση και μικρό θερμικό συντελεστή.
3. Κεραμικών υψηλής συχνότητας: Χαρακτηριστικό παράδειγμα ο στεατίτης. Ανάλογα την περίπτωση χρήσης διακρίνονται σε μονωτήρες για υψίσυχνες κεραίες, εξαρτήματα στήριξης, κεραμικά πυκνωτών, πορώδη κεραμικά.
4. Εποξειδικής ρητίνης: Είναι φθηνότερη από τη πορσελάνη και δε παρουσιάζει τεχνικά προβλήματα στη κατασκευή μονωτήρων. Το μειονέκτημα είναι πως όταν υπόκειται σε ηλεκτρικό πεδίο σε συνδυασμό με τις ατμοσφαιρικές συνθήκες, απελευθερώνεται άνθρακας κοντά στους οπλισμούς του μονωτήρα.

Κατηγορίες ανάλογα με τον τρόπο σύνδεσης:

1. Ανάρτησης: Σε γραμμές μεταφοράς υψηλής τάσης και αποτελούνται μία ή δύο σειρές δισκοειδών μονωτήρων. Το πλήθος τους εξαρτάται από τη τάση λειτουργίας της γραμμής και τη διηλεκτρική αντοχή κάθε μονωτήρα.
2. Στήριξης: Χρησιμοποιούνται για τη στήριξη των αγωγών υψηλής τάσης και χωρίζονται σε μονωτήρες μεταφοράς και σταθμών.
3. Γραμμής: Στις γραμμές διανομής ηλεκτρικής ενέργειας μέχρι 70kV.
4. Διέλευσης: Στις θέσεις εξόδου των αγωγών από τους μετασχηματιστές.

Κατηγορίες ανάλογα τους χώρους χρήσης:

1. Τύπου ομίχλης: Σε περιοχές όπου επικρατούν συνθήκες έντονης ρύπανσης. Έχουν μεγάλο μήκος ερπυσμού και κατάλληλη διαμόρφωση εξωτερικής επιφάνειας ώστε να παρέχεται η καλύτερη δυνατή προστασία από τυχόν ακαθαρσίες.
2. Κανονικού τύπου: Χρησιμοποιούνται για ένα σύνηθες περιβάλλον με ακραίες συνθήκες που έχουν προβλεφθεί.
3. Εσωτερικού τύπου: Για κλειστούς υποσταθμούς, σε εσωτερικό χώρο.

Κατηγορίες ανάλογα με το σχήμα και τη χρήση των μονωτήρων:

4. Πορσελάνης τύπου πείρων (pin): Ξεκίνησε από τηλεφωνικές γραμμές και αλεξικέραυνα. Τροποποιήθηκε για να χρησιμοποιηθεί στις γραμμές μεταφοράς ηλεκτρικής ενέργειας
5. Τύπου καλυμμάτων (cap) & pin: Κατασκευάζονται από πορσελάνη ή γυαλί. Είναι αλυσίδες μονωτήρων που σχηματίζονται από μια σειρά χαλύβδινων καλυμμάτων και πείρων.
6. Στήριξης: Αποτελούνται από ένα συμπαγή κύλινδρο πορσελάνης με κυματοειδείς πτυχές και από μεταλλικά ηλεκτρόδια σε κάθε άκρη.
7. Διέλευσης: Από πορσελάνη για αγωγούς υψηλής τάσης.
8. Πορσελάνης μεγάλου μήκους: Οι συγκεκριμένοι είναι παρόμοιοι με τους μονωτήρες στήριξης αλλά ελαφρύτεροι, λεπτότεροι και χρησιμοποιούνται ως μονωτήρες ανάρτησης.
9. Σύνθετοι πολυμερείς: Ο πυρήνας τους αποτελείται από ίνες γυαλιού σε μάζα ρητίνης και περιβάλλεται από ελαστομερές περίβλημα για προστασία από καιρικές συνθήκες. Οι δίσκοι είναι κι εκείνοι ελαστομερείς ώστε να αντέχουν στις εντάσεις του συστήματος. Διαθέτουν μια διακοπτόμενη διαδρομή για την αποστράγγιση από το νερό.
10. Κυκλοαλειφατικής εποξειδικής ρητίνης: Χρησιμοποιούνται για διανομή τάσεων αλλά σε κακές καιρικές συνθήκες οι επιφάνειες τους γίνονται τραχιές επηρεάζοντας αρνητικά την αποτελεσματικότητά τους.

2.4 Σφάλματα Υπόγειων Δικτύων Μέσης Τάσης

Για λόγους κυρίως πρακτικούς, τα δίκτυα μέσης τάσης σε αστικές περιοχές όπως τα κέντρα πόλεων, είναι υπόγεια. Οι αγωγοί 20kV κατευθύνονται μέσω υπόγειων καναλιών σε ολόκληρη τη πόλη για παροχή ηλεκτρικής ενέργειας. Τα σφάλματα σε αυτού του τύπου δίκτυα οφείλονται σε τυχόν αστοχίες κατά τη κατασκευή τους. Συχνότερα, ωστόσο, είναι τα σφάλματα που προκαλούνται από εκτελούμενες εργασίες συνεργείων άλλων υπηρεσιών που εκτελούνται κοντά στους αγωγούς του δικτύου. Άλλη περίπτωση σφάλματος είναι λόγω εμφάνισης υπερτάσεων στα ακροκιβώτια που συνδέονται με τις εναέριες γραμμές. Οι υπερτάσεις είναι κατά κανόνα ατμοσφαιρικής προέλευσης όπως κεραυνοί, γι' αυτό χρησιμοποιούνται απαγωγείς τάσης για την εκτόνωση προς τη γη αντί του υπόγειου καλωδίου.

2.5 Σφάλματα Εναέριων Δικτύων Μέσης Τάσης

Ακραίες καιρικές συνθήκες όπως δυνατός άνεμος και πάγος μπορούν να φέρουν σε επαφή τους αγωγούς των εναέριων γραμμών μεταφοράς, δημιουργώντας ένα προσωρινό βραχυκύκλωμα μεταξύ των φάσεων ή μεταξύ φάσης-γης. Αντίστοιχα, η αστοχία μόνωσης ραγισμένων μονωτήρων σε συνδυασμό με σκόνη που επικάθεται είναι ικανή να δημιουργήσει υπερπηδήσεις, προκαλώντας πάλι βραχυκύκλωμα. Αρκετές φορές τέτοια σφάλματα είναι αυτοκαθαριζόμενα,

δηλαδή το ίδιο το σφάλμα αποκαθιστά, δίχως ανθρώπινη παρέμβαση, τη λειτουργία του δικτύου, όπως π.χ. λιώσιμο πάγου από την έντονη ζέστη του ηλεκτρικού τόξου.

2.5.1 Ρύπανση Μονωτήρων Εξωτερικού Χώρου

Μία από τις βασικές αιτίες διακοπής παροχής ηλεκτρικής ενέργειας είναι η ελαττωματική λειτουργία μονωτήρων. Ο κύριος παράγοντας που επηρεάζει τη μονωτική τους ικανότητα είναι η ρύπανση. Ο συγκεκριμένος όρος εμπεριέχει την επικάθιση ακαθαρσιών στην επιφάνεια τους που αιωρούνται στην ατμόσφαιρα (βιομηχανική ρύπανση) ή θαλασσινού αλατιού (θαλάσσια ρύπανση). Η περίπτωση συνύπαρξης των δύο ειδών ρύπανσης και ομίχλης ή σιγανής βροχής, αποτελεί αντίξοη συνθήκη λειτουργίας των μονωτικών υλικών με αποτέλεσμα τον υποβιβασμό της μονωτικής ικανότητας (από 40% έως 80%) δημιουργώντας ηλεκτρικό τόξο.



Εικόνα 9 Ηλεκτρικό τόξο σε υποσταθμό μέσης τάσης

Ο ευρέως αποδεκτός τρόπος αντιμετώπισης των αστοχιών των μονωτήρων είναι η καθιέρωση ενός αξιόπιστου προγράμματος καθαρισμού και συντήρησης τους.

Σύμφωνα με το πρότυπο IEC 815/1986, έχουν καθοριστεί τέσσερα επίπεδα ρύπανσης ανάλογα με το ποσοστό ρύπανσης κάθε περιοχής:

1. Ελαφριά: Είναι περιοχές χωρίς βιομηχανίες, με μικρή πυκνότητα κατοικιών εξοπλισμένων με εγκατάσταση θέρμανσης, αγροτικές και ορεινές περιοχές.
2. Μεσαία: Περιοχές με βιομηχανίες, που δε παράγουν ιδιαίτερα ρυπασμένο καπνό, με μέση πυκνότητα κατοικιών εξοπλισμένων με εγκατάσταση θέρμανσης και περιοχές εκτεθειμένες σε ανέμους από θάλασσα αλλά όχι κοντά σε ακτή.
3. Βαριά: Περιοχές με υψηλή πυκνότητα βιομηχανιών και προάστια μεγάλων πόλεων με υψηλή πυκνότητα εγκαταστάσεων θέρμανσης και περιοχές κοντά στη θάλασσα (έκθεση σε σχετικά ισχυρούς ανέμους από τη θάλασσα).
4. Πολύ Βαριά: Περιοχές περιορισμένης έκτασης, εκτεθειμένες σε αγωγίμη σκόνη και βιομηχανικό καπνό, κοντά σε ακτή με έκθεση σε ρυπασμένο θαλασσινό αέρα και περιοχές ερήμου με έλλειψη βροχής για μεγάλη χρονική περίοδο.

Η ρύπανση οδηγεί στη μείωση της τάσης υπερπήδησης των μονωτήρων, ελαττώνοντας την αξιοπιστία τους και αυξάνοντας τη πιθανότητα εμφάνισης βλάβης.

2.5.2 Αναγνώριση Ελαττωματικών Μονωτήρων

Πριν την ανάπτυξη των Συστημάτων μη-Επανδρωμένων Αεροσκαφών (ΣμηΕΑ), η επίβλεψη των μονωτήρων και γενικότερα του δικτύου μεταφοράς ηλεκτρικής ενέργειας γινόταν με τη χρήση ελικοπτέρου (για πυλώνες υψηλής τάσης). Εκτός της περίπτωσης προγραμματισμένης συντήρησης, η ύπαρξη σφάλματος οποιασδήποτε φύσεως απαιτεί την άμεση κινητοποίηση του συνεργείου με το εναέριο μέσο για τον εντοπισμό και επισκευή του. Τέτοιου είδους πτήσεις είναι δυνατόν να διαρκέσουν από μερικά λεπτά έως και αρκετές ώρες ανάλογα με το σφάλμα και σίγουρα το χρόνο εντοπισμού του, θέτοντας σε επικίνδυνες συνθήκες ανθρώπινες ζωές.

Τα τελευταία χρόνια, μέσα στις εφαρμογές των ΣμηΕΑ εντάχθηκε και η επιθεώρηση του δικτύου μεταφοράς ηλεκτρικής ενέργειας. Το χαμηλό κόστος κατασκευής, η ευελιξία πτήσης και

η δυνατότητα απομακρυσμένου χειρισμού σε σχέση με τα μεγάλα αεροσκάφη κατέστησαν τα μη-επανδρωμένα αντικείμενα έρευνας για περαιτέρω εξέλιξη.



Εικόνα 10 Επιθεώρηση Γραμμής Υψηλής Τάσης - Ελικόπτερο

Επιπλέον πλεονέκτημα των ΣμηΕΑ είναι η χρήση τους σε δίκτυα μέσης τάσης, πέρα από την υψηλή. Η δυνατότητα κάλυψης χιλιομέτρων γραμμών μεταφοράς ηλεκτρικής ενέργειας, ιδιαίτερα σε δύσβατες περιοχές (όπως βουνοπλαγιές), καθιστά ευρέως αποδεκτή τη συνεισφορά τους σε επιθεωρήσεις.



Εικόνα 11 Επιθεώρηση μέσω ΣμηΕΑ.

Τόσο τα ελικόπτερα όσο τα ΣμηΕΑ επιθεώρησης είναι εξοπλισμένα με τουλάχιστον μια κάμερα ορατού φάσματος υψηλής ανάλυσης. Ραγισμένοι μονωτήρες, τραυματισμένοι ξύλινοι στύλοι μέσης τάσης και φθαρμένοι αγωγοί είναι ορισμένα παραδείγματα που φαίνονται με γυμνό μάτι είτε από τον αέρα είτε από το έδαφος.



Εικόνα 12 Σαπισμένη κορυφή ξύλινου στύλου

Είναι αρκετά σύνηθες να φέρουν επιπλέον μια κάμερα υπέρυθρου φάσματος για την ανάλυση των εγκαταστάσεων σε φάσμα μη-ορατό στο ανθρώπινο μάτι. Ωστόσο, ορισμένα μέρη μπορούν να επιθεωρηθούν από το έδαφος με θερμική κάμερα χειρός.



Εικόνα 13 Θερμοκάμερα χειρός FLIR

Μέσω της υπέρυθρης θερμογραφίας (Infrared Thermography), είναι δυνατή η ανίχνευση των απωλειών θερμότητας μονωτήρων και άλλως εξαρτημάτων βοηθώντας στη πρόβλεψη και άμεση εύρεση ελαττωματικών μονωτήρων.

Στη μέση τάση, για τον εντοπισμό σφάλματος από μονωτήρα μέσω θερμοκάμερας γίνεται σύγκριση των θερμοκρασιών μεταξύ των μονωτήρων των τριών φάσεων και της θερμοκρασίας περιβάλλοντος. Οι διαφορετικές καιρικές συνθήκες που επικρατούν σε κάθε περιοχή είναι σίγουρο ότι διαφοροποιούν τη θερμοκρασία τους. Για το λόγο αυτό, δεν έχει οριστεί γενικό όριο θερμοκρασίας πάνω από το οποίο ένας μονωτήρας προκαλεί σφάλμα. Η απόλυτη θερμοκρασία που καταγράφεται στη κάμερα ποικίλει ανάλογα με το υλικό κατασκευής και τις επικρατούσες καιρικές συνθήκες (π.χ. χειμώνας, καλοκαίρι).

Η διαφορά θερμοκρασίας του μεταλλικού συνδέσμου ενός μονωτήρα με του φυσικού περιβάλλοντος και με κάθε έναν από τους υπόλοιπους είναι τα κριτήρια αναγνώρισης σφάλματος, ειδικά όταν η οπτική επιθεώρηση με γυμνό μάτι δε προσφέρει αποτέλεσμα. Οι μονωτήρες δε παρουσιάζουν την ίδια θερμοκρασία λειτουργίας όταν δεν υπάρχει σφάλμα. Πάντα υπάρχει διαφορά από 0.5 έως και 3 βαθμούς Κελσίου, που θεωρείται φυσιολογικό φαινόμενο. Είναι πιθανό η θερμοκρασία του συνδέσμου από ελαττωματικό μονωτήρα να είναι τρεις ή και τέσσερις φορές μεγαλύτερη από του περιβάλλοντος.

Η αστοχία του υλικού οδηγεί στον υποβιβασμό της μονωτικής ικανότητας με αποτέλεσμα η διαφορά θερμοκρασίας να αυξάνεται σε μεγάλο βαθμό. Τότε θεωρείται ελαττωματικός ο μονωτήρας και χρήζει άμεσης συντήρησης ή αντικατάστασης αν είναι αναγκαίο.



Εικόνα 14 Εικόνα Θερμικού Φάσματος Τραβέρσας Ξύλινου Στύλου Μέσης Τάσης

3.


ΥΠΕΡΥΘΡΗ ΘΕΡΜΟΓΡΑΦΙΑ

3.1 Εισαγωγή

Η υπέρυθρη θερμογραφία έχει ως αντικείμενο την επεξεργασία και μελέτη της πληροφορίας θερμότητας που λαμβάνεται από συσκευές μέτρησης δίχως επαφή. Επιτρέπει την απεικόνιση φαινομένων που δε μπορεί να ανιχνεύσει το ανθρώπινο μάτι μόνο του.

3.1.1 Υπέρυθρη Ακτινοβολία

Το ορατό φως, μαζί με τα υπόλοιπα είδη ηλεκτρομαγνητικής ακτινοβολίας μελετώνται και περιγράφονται ως κύματα. Τα ηλεκτρομαγνητικά κύματα είναι ηλεκτρικά και μαγνητικά πεδία που ταλαντώνονται σε κάθετα επίπεδα μεταξύ τους και κάθετα προς τη διεύθυνση μετάδοσης.



Εικόνα 15 Ηλεκτρομαγνητικό Φάσμα

Η εξίσωση κίνησης είναι η εξής:

$$c = \nu * \lambda$$

Όπου c η ταχύτητα μετάδοσης, ν συχνότητα ταλάντωσης και λ το μήκος κύματος.

Η υπέρυθρη είναι το είδος ηλεκτρομαγνητικής ακτινοβολίας που διαθέτει μήκος κύματος μεγαλύτερο από του ορατού φάσματος, από 700 nanometers (nm) έως περίπου 1 millimeter (mm). Εκπέμπεται και απορροφάται από τα μόρια όταν αλλάζουν συχνότητα κίνησης, που σχετίζεται με τη θερμική ενέργεια του σώματος. Σχεδόν όλα τα σώματα εκπέμπουν υπέρυθρη ακτινοβολία διότι διαθέτουν ορισμένη θερμοκρασία (ανώτερη του απόλυτου μηδενός). Όσα έχουν μεγάλη θερμοκρασία εκπέμπουν περισσότερο από ό,τι άλλα με μικρότερη. Χωρίζεται σε επιμέρους κατηγορίες οι οποίες είναι :

1. Near-infrared (NIR) από 0.8 micrometers (μm) έως 1.7μm
2. Short-wavelength infrared (SWIR) από 1μm έως 2.5μm
3. Mid-wavelength infrared (MWIR) από 2μm έως 5μm
4. Long-wavelength infrared (LWIR) από 8μm έως 14μm

3.1.2 Συντελεστής Εκπομπής (Emissivity)

Το μέλαν σώμα είναι ένα ιδανικό σώμα που απορροφά όλη την ηλεκτρομαγνητική ακτινοβολία που δέχεται. Αυτό έχει ως αποτέλεσμα να μην ανακλά, να μη διαχέει ούτε να το διαπερνά το προσπίπτον σε αυτό φως. Εκπέμπει ηλεκτρομαγνητική ακτινοβολία σύμφωνα με τη θερμοκρασία του. Επινοήθηκε για τη διευκόλυνση της μελέτης της θερμικής ακτινοβολίας των πραγματικών σωμάτων. Σε κάποια μη μηδενική θερμοκρασία, οποιοδήποτε σώμα εκπέμπει θερμική ακτινοβολία.


Ως συντελεστής εκπομπής (emissivity) ορίζεται ο λόγος της ακτινοβολουμένης ενέργειας από το σώμα σε σχέση με εκείνη ενός μελανού σώματος στην ίδια θερμοκρασία. Ο συντελεστής εκπομπής του μελανού σώματος είναι ίσος με τη μονάδα, ενώ για κάθε άλλο πραγματικό και μη-ιδανικό σώμα είναι πάντα μικρότερος της μονάδας και θετικός. Όσο πιο μικρό το emissivity, τόσο λιγότερη η εκπομπή ηλεκτρομαγνητικής ακτινοβολίας.

Για τη μέτρηση του συντελεστή εκπομπής ενός αντικειμένου ακολουθείται η εξής διαδικασία. Το αντικείμενο πρέπει να έρθει σε θερμοκρασία συνθηκών υπό κανονική λειτουργία. Στη συνέχεια ένα θερμοστοιχείο λαμβάνει μια θερμοκρασία αναφοράς, παρόλο που σε μικρές θερμοκρασίες είναι σύνηθες να χρησιμοποιείται η ίδια συσκευή μέτρησης που χρησιμοποιείται για μέτρηση θερμοκρασίας. Αυτό γίνεται κολλώντας ένα κομμάτι μαύρης μονωτικής ταινίας με γνωστό emissivity πάνω στο αντικείμενο και λαμβάνοντας τη μέτρηση της ύστερα. Τέλος γίνεται μια δεύτερη μέτρηση αλλά αυτή τη φορά πάνω στο αντικείμενο και όχι στη ταινία. Ο συντελεστής έτσι μεταβάλλεται μέχρις ότου ταιριάζει με τη πραγματική θερμοκρασία του αντικειμένου.

3.1.3 Εφαρμογές Υπέρυθρης Θερμογραφίας

Επιθεώρηση Κτιρίων


Οι απώλειες ενέργειας των κτιρίων έχουν μεγάλες επιπτώσεις στο γύρω φυσικό περιβάλλον. Η υπέρυθρη θερμογραφία βοηθά στη βελτίωση της ενεργειακής τους απόδοσης εντοπίζοντας άμεσα προβλήματα μόνωσης.



Εικόνα 16 Θερμογραφική Επιθεώρηση Κτιρίου

Επιθεώρηση Φωτοβολταϊκών Εγκαταστάσεων

Με την ανάπτυξη των ανανεώσιμων πηγών ενέργειας, ολοένα και περισσότερα φωτοβολταϊκά εγκαθίστανται για εκμετάλλευση της ηλιακής ακτινοβολίας. Με τη πάροδο του χρόνου και τις επικρατούσες καιρικές συνθήκες η απόδοση τους μειώνεται λόγω βλάβης του πάνελ ή ακόμα και ο inverter να μη λειτουργεί στη μέγιστη απόδοση. Ως αποτέλεσμα, δε μετατρέπεται βέλτιστα η ηλιακή ακτινοβολία σε ηλεκτρική ενέργεια. Με τη χρήση όμως θερμοκάμερας μπορούν να εντοπιστούν τα σημεία βλάβης ώστε να επισκευαστούν και να αποκατασταθεί η λειτουργία.



Εικόνα 17 Θερμογραφική Επιθεώρηση Φωτοβολταϊκού Πάρκου

Ασφάλεια


Η αναγνώριση και εντοπισμός του ανθρώπινου σώματος σε εικόνα του υπέρυθρου φάσματος είναι εφικτός λόγω της θερμότητας του. Έχοντας αναπτυχθεί σύγχρονες τεχνικές επεξεργασίας εικόνas αλλά και σε συνδυασμό με κάμερες ορατού φάσματος, ο εντοπισμός γίνεται με μεγαλύτερη ακρίβεια. Έτσι η υπέρυθη θερμογραφία επηρεάζει και το τομέα της ασφάλειας έναντι εγκληματιών και προστασίας στρατιωτικών εγκαταστάσεων.



Εικόνα 18 Εντοπισμός Ανθρώπινου Σώματος

Μικρο-Θερμογραφία

Η διαχείριση της θερμότητας σε ηλεκτρονικά συστήματα και αρχιτεκτονικές αποτελεί καίριο παράγοντα ομαλής λειτουργίας τους. Όσο μικραίνουν σε μέγεθος, τόσο μεγαλύτερο εξελίσσεται το πρόβλημα διαχείρισης της θερμότητας που αυξάνει. Η μικρο-θερμογραφία επιτρέπει την ανάλυση και εξέταση διατάξεων της τάξης μικρομέτρων, παρέχοντας αναλυτική απεικόνιση της κατανομής θερμοκρασιών επί αυτών.




Εικόνα 19 Θερμική Απεικόνιση Τμήματος Πλακέτας

Ιατρική

Τόσο στους ανθρώπους όσο και στα ζώα, η υπέρυθη θερμογραφία αποτελεί μια ανέπαφη και μη-επεμβατική μέθοδο διάγνωσης ποικίλων παθήσεων. Η θερμοκρασία του ανθρώπινου σώματος είναι βασικό κριτήριο εξέτασης παθήσεων, έτσι παρέχεται αναλυτική περιγραφή της κατανομής θερμοκρασιών ακόμη και σε ολόκληρο το σώμα. Μπορεί να αποδειχθεί οικονομικότερη (χρηματικά) στη διάγνωση ορισμένων παθήσεων αλλά και να μελετηθεί η αποτελεσματικότητα χορήγησης αγωγής ή θεραπείας στους ασθενείς με λήψη εικόνων πριν και μετά.


Επιθεώρηση Εγκαταστάσεων Μεταφοράς και Διανομής Ηλεκτρικής Ενέργειας

Ελαττωματικά εξαρτήματα προκαλούν μεγάλο ποσοστό των σφαλμάτων σε εγκαταστάσεις ηλεκτρικής ενέργειας. Αυξάνεται χαρακτηριστικά η θερμοκρασία τους και για το λόγο αυτό η χρήση κατάλληλων θερμοκαμερών βοηθά στον εντοπισμό τους. Η άμεση αποκατάσταση παροχής ηλεκτρικής ενέργειας είναι κρίσιμη ανεξαρτήτως γεωγραφικής περιοχής. Οι βλάβες σε υποσταθμούς (διανομής/μεταφοράς/παραγωγής) είναι δυνατόν να εντοπισθούν εύκολα μέσω της υπέρυθρης θερμογραφίας.



Εικόνα 20 Θερμική Εικόνα Μετασχηματιστή Υποσταθμού

Εξίσου αποτελεσματική είναι και στην ανίχνευση σφαλμάτων επί των γραμμών μεταφοράς ηλεκτρικής ενέργειας και των πυλώνων (ή στύλων για τη μέση τάση).



Εικόνα 21 Θερμική Εικόνα Πυλώνα


4.

ΝΕΥΡΩΝΙΚΑ

ΔΙΚΤΥΑ

4.1 Εισαγωγικά

Τα Νευρωνικά Δίκτυα (NNs) είναι ένα σύνολο συνδεδεμένων κόμβων (νευρώνων) που μιμούνται τη βασική λειτουργία των νευρώνων του ανθρώπινου εγκεφάλου. Πιο συγκεκριμένα, ένας κόμβος σε νευρωνικό δίκτυο δέχεται πολλαπλές εισόδους και παράγει μια έξοδο, η οποία συνεχίζει ως είσοδος σε επόμενους κόμβους. Κάθε είσοδος διαθέτει ένα συντελεστή-βάρους (weight w) που αντιπροσωπεύει το βαθμό επιρροής που θα έχει στο σήμα που λαμβάνεται. Στο κυρίως κομμάτι του κόμβου, αθροίζονται τα γινόμενα των εισόδων με τους συντελεστές. Συγκρίνοντας το αποτέλεσμα με ένα όριο (threshold) ανάλογα την εφαρμογή, τότε ο κόμβος παράγει έξοδο μέσω μιας συνάρτησης f (activation function).



Εικόνα 22 (Αριστερά) Προσεγγιστικό Μοντέλο Βιολογικού Νευρώνα - (Δεξιά) Μαθηματικό Μοντέλο Νευρώνα-Κόμβου

Όπου:


$$S = \sum_i w_i x_i + b$$

Ορισμένες από τις πιο διαδεδομένες activation functions για ένα πραγματικό αριθμό x , είναι η sigmoid, η tanh και η ReLU (Rectified Linear Unit).


$$\text{Sigmoid function: } \sigma(x) = \frac{1}{1 + e^{-x}}$$

$$\text{Tanh function: } 2 * \sigma(2x) - 1$$

$$\text{ReLU function: } \max(0, x)$$




Εικόνα 23 (Αριστερά) Sigmoid - Περιορισμός Εξόδου Κόμβου σε $[0,1]$ – (Δεξιά) Tanh - Περιορισμός Εξόδου Κόμβου σε $[-1,1]$



Εικόνα 24 ReLU - Περιορισμός Εξόδου Κόμβου σε $[0, +\infty)$

Το σύνολο των νευρώνων είναι κατανομημένο σε επιμέρους ομάδες που ονομάζονται layers. Οι κόμβοι που δέχονται εξωτερική είσοδο (εκτός νευρωνικού δικτύου) σχηματίζουν το *input layer*. Αντίστοιχα ο κόμβος ή οι κόμβοι που παράγουν την έξοδο του δικτύου αποτελούν το *output layer*. Ανάμεσα στα 2 προηγούμενα layers, συμπεριλαμβάνονται ένα ή περισσότερα και ονομάζονται *hidden layers*. Σε περίπτωση που το πλήθος των *hidden layers* είναι άνω του ενός, τότε το νευρωνικό δίκτυο φέρει συχνά την ονομασία *Deep Convolutional Neural Network (DCNN/DNN)*.



Εικόνα 25 Περιπτώσεις Layers σε Νευρωνικά Δίκτυα


4.2 Convolutional Neural Networks (CNNs)

Τα *Convolutional Neural Networks (CNNs)* είναι ένα είδος NN που δέχεται ως είσοδο pixels από εικόνες. Οι κόμβοι σε κάθε layer είναι κατανομημένοι διαφορετικά από το κλασικό τρόπο,

χωρίς απαραίτητα να είναι όλοι συνδεδεμένοι μεταξύ τους. Εφόσον η είσοδος είναι 3 διαστάσεων, κάθε layer διατηρεί τον ίδιο αριθμό διαστάσεων αλλά το μέγεθος τους μεταβάλλεται από layer σε layer.

Υπάρχουν συγκεκριμένες κατηγορίες layers για το σχηματισμό CNNs:


1. Layer Εισόδου (INPUT), όπου βρίσκονται όλα τα pixels της εικόνας
2. Layer Συνέλιξης (CONV LAYER), όπου γίνεται συνέλιξη συγκεκριμένων κομματιών της εικόνας με φίλτρα που έχουν επιλεγεί εξ αρχής
3. Layer RELU, όπου εφαρμόζεται η συνάρτηση ReLU
4. POOL Layer, όπου μειώνεται το μέγεθος διαστάσεων (downsampling)
5. FULLY CONNECTED LAYER (FC), όπου τελικά υπολογίζεται το αποτέλεσμα της εικόνας εισόδου για κάθε κλάση που έχει οριστεί. Η έξοδος έχει διάσταση ίση με τον αριθμό των κλάσεων.



Εικόνα 26 Σύγκριση layers NN (αριστερά) – CNN (δεξιά)

4.3 Image Classification

Η κατηγοριοποίηση εικόνας (image classification) είναι μία διαδικασία που αντιστοιχεί μία εικόνα, ανάλογα με το περιεχόμενο που δείχνει, σε κάποια κατηγορία. Υπάρχουν δύο είδη, η unsupervised και η supervised classification. Στην unsupervised η ανάθεση κατηγορίας γίνεται αυτοματοποιημένα. Ο χρήστης ορίζει τον αριθμό των κλάσεων (κατηγοριών) και οι χωρικές κλάσεις δημιουργούνται σύμφωνα με τα διαθέσιμα αριθμητικά δεδομένα, όπως φαίνεται παρακάτω.



Εικόνα 27 Unsupervised Classification

Εκτός του αριθμού κλάσεων, του μέγιστου αριθμού επαναλήψεων και του ορίου λήξης κατηγοριοποίησης, δεν υπάρχουν άλλοι παράμετροι προς ρύθμιση. Είναι γρήγορη στην εκτέλεση και βασίζεται κυρίως στη χωρική σχέση των δεδομένων.

Χρησιμοποιούνται δυο βασικοί μέθοδοι για unsupervised classification, οι principal component και cluster analysis. Η ανάλυση κύριων συνιστωσών (principal component analysis) αποτελεί μια γραμμική μέθοδο συμπίεσης δεδομένων. Έχει ως στόχο τον επαναπροσδιορισμό των συντεταγμένων ενός συνόλου δεδομένων σε ένα διαφορετικό σύστημα συντεταγμένων, καταλληλότερο για την εκάστοτε ανάλυση δεδομένων. Οι νέες συντεταγμένες είναι το αποτέλεσμα ενός γραμμικού συνδυασμού από τις αρχικές μεταβλητές σε ορθογώνιο άξονα, ενώ τα επικείμενα σημεία διατηρούν φθίνουσα σειρά σχετικά με τη τιμή διακύμανσης τους. Για το λόγο αυτό, το πρώτο κύριο συστατικό (principal component) διατηρεί περισσότερες πληροφορίες δεδομένων σε σχέση με το δεύτερο που δε διατηρεί πληροφορίες οι οποίες έχουν εισέλθει νωρίτερα. Ο συνολικός αριθμός των principal components είναι ίσος με το πλήθος των αρχικών μεταβλητών. Τέλος, επιτρέπει τη μείωση του συνόλου των μεταβλητών καθώς τα πρώτα συστατικά διατηρούν περισσότερο από το 90% των στατιστικών δεδομένων των αρχικών δεδομένων.

Η ανάλυση συμπλέγματος (cluster analysis) είναι η διαδικασία ομαδοποίησης δεδομένων ώστε όσα είναι σε μια ομάδα (cluster) να σχετίζονται περισσότερο μεταξύ τους παρά με δεδομένα άλλου cluster. Μπορεί να θεωρηθεί ως ένα πρόβλημα βελτιστοποίησης πολλαπλών στόχων. Υπάρχουν διάφοροι αλγόριθμοι clustering, όπως hierarchical, centroid-based (k-means), distribution-based και density-based clustering.


Από την άλλη μεριά, στη supervised classification απαιτείται ο χρήστης να παρέχει παραδείγματα για κάθε κλάση που έχει ορίσει, ώστε να χρησιμοποιηθούν ως αναφορές στη διαδικασία εκπαίδευσης. Ουσιαστικά μαθαίνει μια συνάρτηση να αντιστοιχεί κάποια είσοδο σε κάποια έξοδο σύμφωνα με ήδη γνωστά ζεύγη εισόδου-εξόδου. Στόχος είναι η αντιστοίχιση άγνωστης εισόδου στη σωστή έξοδο (κλάση). Όταν υπάρχει περιορισμένο πλήθος ζευγών εισόδου-εξόδου για αναφορά, τότε είναι σχεδόν σίγουρο ότι η κατηγοριοποίηση εισόδων εκτός αυτής, θα είναι ως επί το πλείστον λανθασμένη. Όσο περισσότερα δεδομένα αναφοράς (training set) υπάρχουν διαθέσιμα, επιτρέπει την βελτίωση των επιτυχημένων κατηγοριοποιήσεων σε άγνωστες εισόδους.

4.4 Image Sequence Classification

4.4.1 Long Short-Term Memory Recurrent Neural Networks (LSTM RNNs)

Τα *Long Short-Term Memory Recurrent Neural Networks (LSTM RNNs)* είναι ένα είδος νευρωνικού δικτύου που υποστηρίζουν τη κατηγοριοποίηση data sequences, όπως speech recognition και video classification. Διαθέτουν μεγαλύτερο εύρος μνήμης από τα κλασσικά RNNs, γεγονός που τα καθιστά ιδανικά σε περιπτώσεις που αναζητείται μια πληροφορία (π.χ. frame) αρκετά πιο πίσω χρονικά από το παρόν.

Η γενική μορφολογία του repeating module σε ένα LSTM είναι η εξής:



Εικόνα 28 Repeating Module LSTM


Όπου:

x_t : είσοδος τη χρονική στιγμή t ,

h_t : έξοδος τη χρονική στιγμή t ,

A : νευρώνας

Αρχικά αποφασίζεται ποια πληροφορία πρέπει να διαγραφεί από τη τρέχουσα κατάσταση. Αυτό γίνεται στο *forget gate layer* που αποτελείται από μια sigmoid συνάρτηση. Το αποτέλεσμα «1» κρατά τη πληροφορία, αλλιώς με «0» τη ξεχνά.



Εικόνα 29 Στάδιο 1 - LSTM

Όπου:

$$f_t = \sigma(W_f * [h_{t-1}] + b_f)$$


σ : sigmoid,

W : weight matrix

h_{t-1} : έξοδος τη χρονική στιγμή t-1

b : bias vector

Στη συνέχεια, κρίνεται ποια νέα πληροφορία χρειάζεται να αποθηκευτεί στη τρέχουσα κατάσταση μέσω του *input gate layer* που είναι πάλι μια sigmoid. Δημιουργούνται πιθανές τιμές για την εκχώρηση στη τρέχουσα κατάσταση ως εξής:



Εικόνα 30 Στάδιο 2 - LSTM

Όπου:


$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c)$$

i : η τιμή (πληροφορία) προς ενημέρωση

C_t : διάνυσμα των υποψηφίων νέων καταστάσεων

Ύστερα ενημερώνεται η τρέχουσα κατάσταση, έχοντας κρίνει τι πρέπει να ξεχαστεί και τι όχι:




Εικόνα 31 Στάδιο 3 - LSTM

Όπου:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

Τέλος, κρίνεται η έξοδος πρώτα μέσω μιας sigmoid για το ποια μέρη της κατάστασης θα σταλούν και ύστερα πολλαπλασιασμός με tanh της κατάστασης .



Εικόνα 32 Στάδιο 4 - LSTM


Όπου:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$$


$$h_t = o_t * \tanh(C_t)$$

Χρησιμοποιώντας τα RNNs είναι δυνατόν η κατηγοριοποίηση δεδομένων (sequence ή μη) να γίνει με πολλαπλούς τρόπους:

1. Ένα-προς-ένα κατηγοριοποίηση. Η κλασσική περίπτωση που μία είσοδος (κόκκινο) κατηγοριοποιείται (μπλε) μέσω ενός συνόλου νευρώνων (πράσινο)
2. Ένα-προς-πολλά. Χρησιμοποιείται σε περιπτώσεις αναγνώρισης κειμένου, είσοδος το κείμενο και έξοδος ένα σύνολο λέξεων.
3. Πολλά-προς-ένα. Αρχιτεκτονική για ανάλυση συναισθημάτων. Είσοδος κείμενο και έξοδος λέξη (συναίσθημα) που προκαλείται από την είσοδο.
4. Πολλά-προς-πολλά. Χαρακτηριστικό παράδειγμα η μετάφραση κειμένου από μια γλώσσα σε άλλη.
5. Πολλά-προς-πολλά. Είσοδος και έξοδος είναι συγχρονισμένες ακολουθίες. Χρησιμοποιείται στην αναγνώριση κίνησης σε βίντεο.



Εικόνα 33 RNN Classification Types



Εικόνα 34 Αλυσιδωτή δομή LSTM (όπου A ίδια δομή με μεσαίο module)

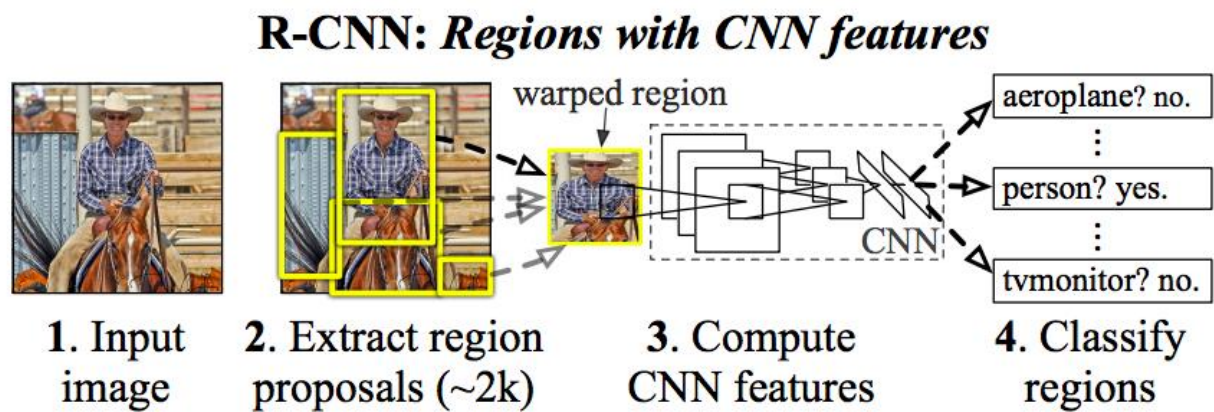
4.5 Object Detection

Το Object Detection αφορά την αναζήτηση και εντοπισμό σε εικόνες αντικειμένων ενδιαφέροντος. Περιλαμβάνει το Image Classification και τη δημιουργία bounding box γύρω από το εντοπισμένο αντικείμενο. Δηλαδή, πρώτα αναθέτει μια κλάση και ύστερα εμπεριέχει σε ένα κουτί ενδιαφέροντος το εντοπισμένο αντικείμενο μαζί με το όνομα της κλάσης. Στη συνέχεια αναλύονται οι βασικότερες αρχιτεκτονικές για object detection.

4.5.1 Region Convolutional Neural Networks (R-CNNs)

Τα R-CNNs εισάγουν την έννοια των region proposals και τη συνδυάζουν με τα χαρακτηριστικά των CNNs. Επιλέγονται περίπου 2000 υποπεριοχές (regions από αλγόριθμο Selective Search) της εικόνας εισόδου στο CNN και γίνεται προσπάθεια εξαγωγής χαρακτηριστικών του κάθε region μέσα σε αυτό. Στο τέλος, μέσω ενός Support Vector Machine (SVM) ανιχνεύεται η ύπαρξη επιθυμητών αντικειμένων μέσα στα regions.

Χρησιμοποιεί Deep CNNs όπως το VGG16, έχοντας μεγάλο κόστος σε χρόνο εκπαίδευσης και χώρο δεδομένων. Η διαδικασία του object detection είναι γενικά αργή, διότι περνάει κάθε region proposal μέσα από το CNN προς εύρεση χαρακτηριστικών, ανεξάρτητα αν τελικά ανήκει σε κάποια κλάση ή όχι.




Εικόνα 35 Αρχιτεκτονική R-CNN

4.5.2 Fast R-CNNs

Ο αρκετά μεγάλος αριθμός *regions* ανά εικόνα για classification (περίπου 2000) που οδηγεί σε αργή επεξεργασία χρονικά ανά εικόνα, όπως επίσης, ο αλγόριθμος Selective Search που είναι fixed χωρίς να υπάρχει δυνατότητα μάθησης προς βελτίωση του, είναι ορισμένα βασικά μειονεκτήματα των R-CNNs.


Στη προσπάθεια εξέλιξης τους, δημιουργήθηκαν τα Fast R-CNNs. Στη προκειμένη περίπτωση, αφού εξαχθούν τα *regions*, εισάγονται στο CNN και εξάγεται ένας *convolutional feature map*. Στη συνέχεια, ανιχνεύονται και διοχετεύονται τα *regions* σε ένα Fully Connected layer, μέσω ενός Region Of Interest pooling layer. Τέλος, εφαρμόζεται ο αλγόριθμος *softmax* για την εύρεση της κλάσης του *region*. Το βασικότερο πλεονέκτημα έγκειται στο ότι δε γίνεται συνέλιξη σε 2000 *regions* ανά εικόνα, αλλά σε όλη την εικόνα μία φορά, γεγονός που βελτιώνει σημαντικά το χρόνο επεξεργασίας.



Εικόνα 36 Αρχιτεκτονική Fast R-CNN

4.5.3 Faster R-CNNs

Η σημαντικότερη διαφορά τους από τα Fast RCNNs είναι στο τρόπο δημιουργίας *regions*. Δηλαδή, ο αλγόριθμος Selective Search, αντικαθίσταται από ένα νευρωνικό δίκτυο (Region Proposal Network – RPN) υπεύθυνο για τη πρόβλεψη των *regions*. Ως αποτέλεσμα, είναι εφικτή η εκμάθηση των *regions*, καθώς επίσης μειώνεται ο χρόνος επεξεργασίας καθιστώντας το ιδανικό για real time εφαρμογές.



Εικόνα 37 Αρχιτεκτονική Faster R-CNN

Η αρχιτεκτονική αποτελείται από τρία βασικά κομμάτια. Αρχικά βρίσκονται convolutional layers που έχουν ως στόχο την εξαγωγή και μάθηση των χαρακτηριστικών της εικόνας εισόδου. Στη συνέχεια βρίσκεται το Region Proposal Network (RPN) που είναι ένα μικρό σε μέγεθος νευρωνικό δίκτυο που με τη τεχνική sliding window αναζητά στο feature map (έξοδος από conv layers) την ύπαρξη ή μη αντικειμένων, προβλέποντας μαζί το αντίστοιχο bounding box. Τρίτο και τελευταίο κομμάτι αποτελεί ένα νευρωνικό δίκτυο με Fully Connected Layers, που δέχεται ως είσοδο, εκτός από το feature map, τις προβλέψεις κλάσεων και bounding box από το RPN.

4.5.4 Mask R-CNNs

Ως περαιτέρω εξέλιξη των Faster R-CNNs, τα Mask R-CNNs εισάγουν την έννοια της ευθυγράμμισης των pixels της εισόδου με τα pixels εξόδου του δικτύου. Το layer RoIAlign (Region of Interest Align) επιτελεί το στόχο αυτό, διατηρώντας τις χωρικές σχέσεις των pixels εισόδου έως την έξοδο, σε αντίθεση με το RoIPool των Faster R-CNNs που κάνει pooling των pixels για feature extraction. Υιοθετούν τη νοοτροπία του παράλληλου bounding box classification και regression των Faster R-CNNs, αλλά πέραν της κλάσης εξάγει μία τετραγωνική μάσκα για κάθε RoI. Με τον τρόπο αυτό, διατηρούνται οι χωρικές αναλογίες του εκάστοτε εικονιζόμενου αντικειμένου δίχως την ανάγκη μετατροπής του σε μονοδιάστατο διάνυσμα.

5.

ΜΕΘΟΔΟΛΟΓΙΑ ΕΝΤΟΠΙΣΜΟΥ ΣΦΑΛΜΑΤΟΣ

5.1 Εισαγωγικά

Με στόχο την αναγνώριση σφάλματος στους μονωτήρες των αγωγών ηλεκτρικής ενέργειας μέσης τάσης, προτείνεται η παρακάτω μεθοδολογία, αποτελούμενη από 3 στάδια. Αξιοποιείται το Deep ConvNet *Visual Geometry Group* με 16 convolutional layers (VGG16) μέσω της τεχνικής *Transfer Learning*.

Στο αρχικό στάδιο, αξιοποιείται ένα νευρωνικό δίκτυο που έχει ως στόχο τον εντοπισμό των αγωγών μέσα στην εικόνα του ορατού φάσματος. Χωρίζεται η εικόνα σε επιμέρους περιοχές (blocks) και ύστερα γίνεται κατηγοριοποίηση σε 2 κλάσεις, *absent_line* και *present_line*. Η πρώτη κλάση αντιπροσωπεύει την απουσία αγωγού/αγωγών από το block, ενώ η δεύτερη ακριβώς το αντίθετο.

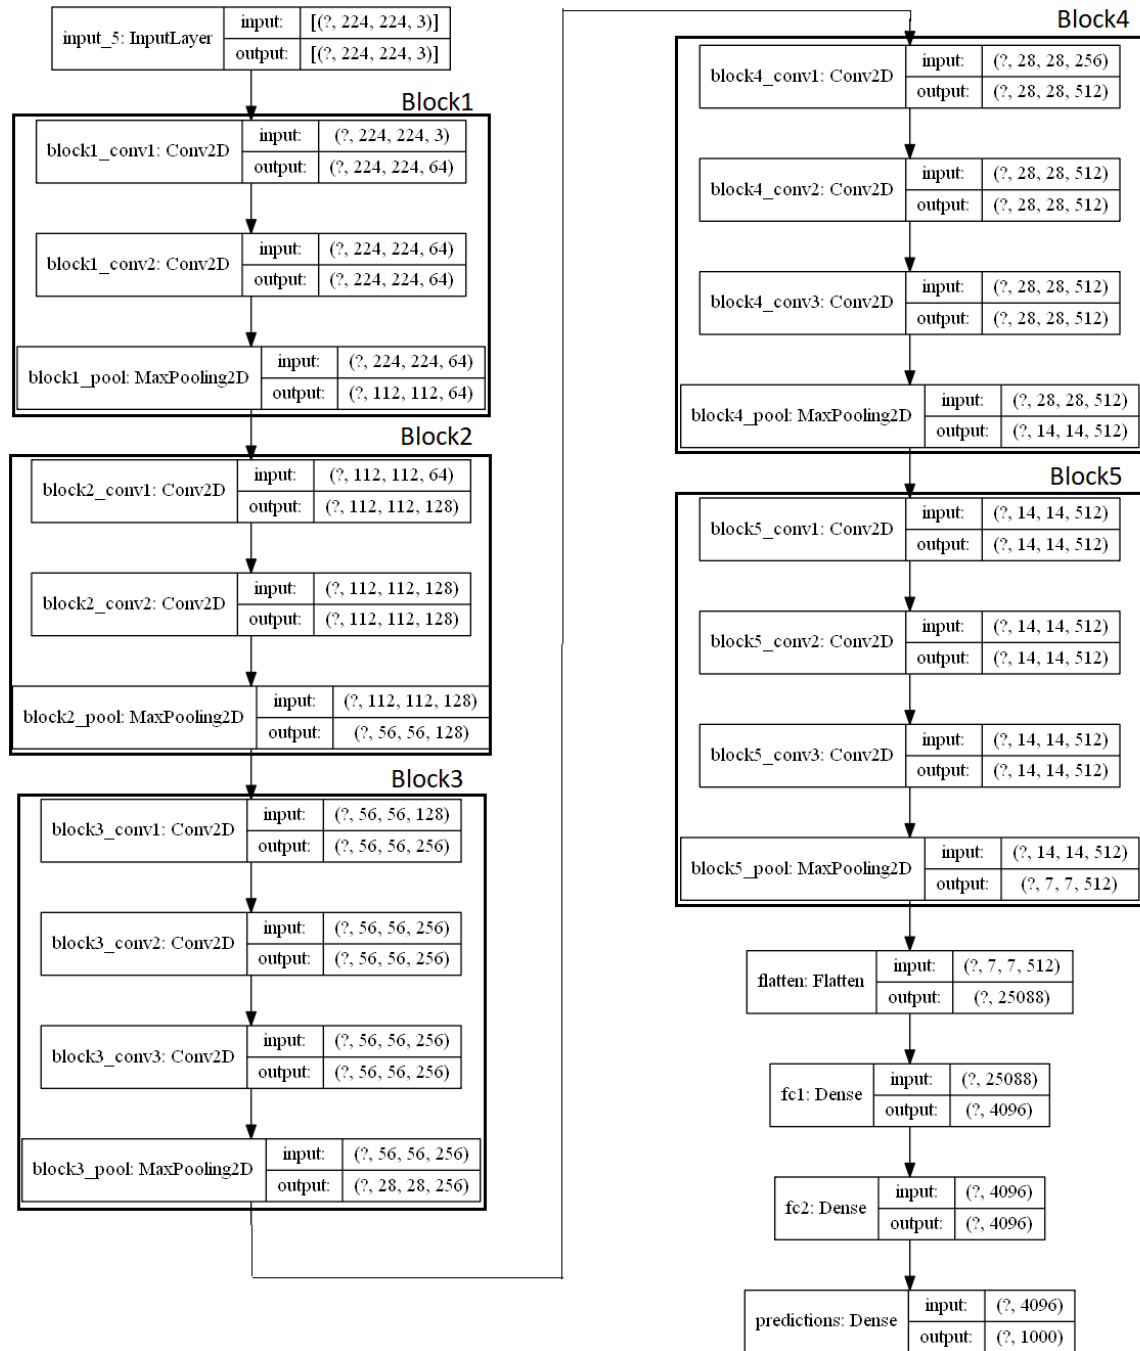
Έχοντας διαθέσιμα τα blocks της κλάσης *present_line*, στο δεύτερο στάδιο γίνεται επεξεργασία αυτών μέσω *image processing* με σκοπό τον εντοπισμό της τραβέρσας. Σε περίπτωση που

βρεθεί, δημιουργείται περιοχή ενδιαφέροντος γύρω της (Region of Interest – RoI) που να περιλαμβάνει τους μονωτήρες.

Στο τρίτο και τελευταίο στάδιο γίνεται εντοπισμός των μονωτήρων στο RoI σε ορατό φάσμα, επιτρέποντας τον εντοπισμό τους στο θερμικό. Το πρόγραμμα είναι γραμμένο σε Python 3 (Jupyter Notebook) χρησιμοποιώντας το Keras, που είναι open source βιβλιοθήκη νευρωνικών δικτύων σε Python και το Tensorflow, open source βιβλιοθήκη τεχνητής νοημοσύνης.

5.2 VGG16

Το VGG16 είναι ένα Deep Convolutional Network που περιλαμβάνει 16 convolutional layers με αρκετά μικρά receptive fields (3x3). Αποτελείται από 5 max-pooling layers, 3 fully-connected layers και το top layer ως soft-max. Ως activation function χρησιμοποιείται η ReLU.



Εικόνα 38 Αρχιτεκτονική VGG16

Δέχεται ως είσοδο εικόνες διαστάσεων 224x224 pixels 3 καναλιών, ο χρήστης ωστόσο μπορεί να ορίσει προσαρμοσμένο μέγεθος στις ανάγκες του, διαφορετικό από το προκαθορισμένο. Αφού η εικόνα περάσει από τα διαδοχικά convolutional layers και τα εκάστοτε max pooling (σε 2x2 pixel window με stride 2), καταλήγει στα Fully Connected Layers αφού πρώτα υποστεί

flattening. Τα δύο πριν το τέλος διαθέτουν 4096 κανάλια, ενώ το τρίτο που είναι ο classifier αναθέτει μία από τις 1000 κλάσεις του ImageNet Large Scale Visual Recognition Challenge (ILSVRC).

Το ImageNet αποτελεί μία εκτενή βάση δεδομένων εικόνων που χρησιμοποιούνται για έρευνα μεθόδων object recognition. Διαθέτει πάνω από 14 εκατομμύρια εικόνες που είναι κατηγοριοποιημένες σε 20 χιλιάδες κλάσεις. Κάθε χρόνο διαδραματίζεται ο διαγωνισμός ILSVRC με μόνο 1000 κλάσεις από το ImageNet, καθιστώντας ένα από τα πιο δημοφιλή κριτήρια αξιολόγησης της απόδοσης νέων αρχιτεκτονικών.

5.3 Transfer Learning

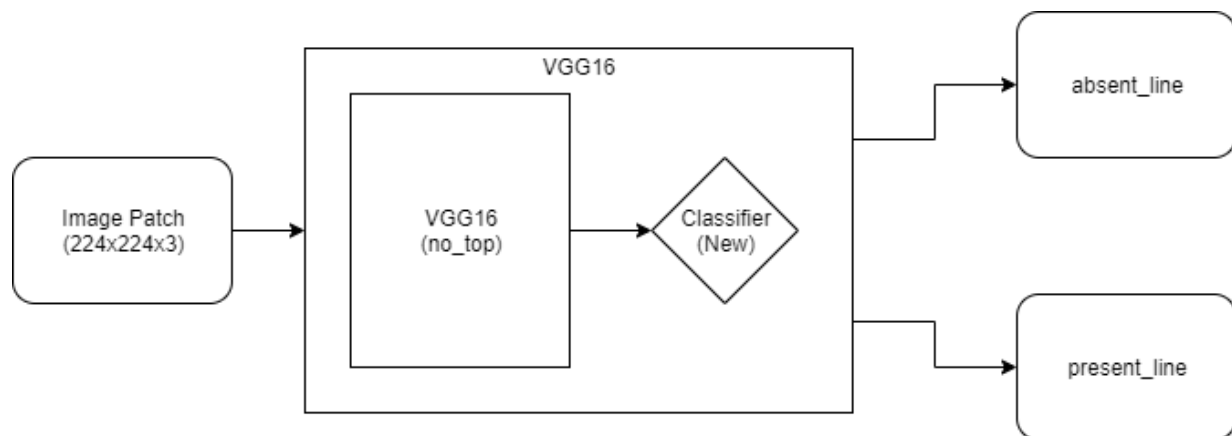
Η γνώση που έχει αποκτηθεί από τη μελέτη και λύση ενός προβλήματος, είναι πιθανόν να χρησιμοποιηθεί στη λύση ενός παρεμφερούς προβλήματος. Η τεχνική transfer learning έχει ως στόχο την αξιοποίηση αποκτημένης γνώσης και την εφαρμογή της σε διαφορετικές περιπτώσεις.

Τα νευρωνικά δίκτυα εκπαιδεύονται στη λύση προβλημάτων, προσαρμόζοντας τα weights των νευρώνων σε κάθε επανάληψη (κυρίως μέσω backpropagation). Διατηρώντας τα weights και αλλάζοντας τον τελευταίο classifier, είναι το πρώτο βήμα επαναχρησιμοποίησης της γνώσης αυτής. Ειδικά όταν η επανεκπαίδευση όλων των layers εκτενών νευρωνικών δικτύων, όπως είναι το VGG16, δεν υποστηρίζεται από το διαθέσιμο εξοπλισμό, επιλέγεται η τεχνική transfer learning. Τα περισσότερα σύγχρονα deep convolutional neural networks είναι προεκπαιδευμένα με ένα εκτενές dataset σαν το ImageNet, που περιέχει μεγάλο αριθμό εικόνων και κλάσεων. Αυτό σημαίνει ότι παρόλο που είναι αδύνατο να συμπεριληφθούν όλα τα πιθανά προβλήματα κάθε τομέα επιστήμης σε ένα dataset, είναι αρκετά πιθανό να έχει λυθεί κάποιο παρεμφερές πρόβλημα με το ζητούμενο. «Παγώνοντας», λοιπόν, τα αρχικά layers (weights) του επιλεγμένου νευρωνικού δικτύου, αφαιρείται ο classifier που διέθετε αρχικά, ώστε να αντικατασταθεί με έναν που αφορά την εκάστοτε εφαρμογή και να εκπαιδευθεί αποκλειστικά αυτός. Αυτό επιτρέπει την εκτέλεση αρχιτεκτονικών σε αρκετά μικρότερα συστήματα από ό,τι εκπαιδεύτηκαν και την εκπαίδευση τους μέσω transfer learning.

5.4 Προτεινόμενη μεθοδολογία

5.4.1 Στάδιο 1 – Εντοπισμός Αγωγών

Για τον εντοπισμό των αγωγών χρησιμοποιήθηκε το VGG16, προεκπαιδευμένο στο ImageNet dataset, με αλλαγή του τελευταίου classifier. Το dataset που χρησιμοποιήθηκε περιλαμβάνει συνολικά 8000 εικόνες μεγέθους 128x128 pixels, εκ των οποίων οι 4000 είναι στο ορατό φάσμα και οι υπόλοιπες στο υπέρυθρο. Σε κάθε φάσμα, οι 2000 εικόνες περιλαμβάνουν αγωγούς και οι περισσευούμενες όχι. Με αναλογία 7:1,5:1,5 χωρίστηκαν οι εικόνες σε training, validation και test dataset. Ο νέος classifier αναθέτει δύο κλάσεις, `absent_line` και `present_line` που αφορούν στην απουσία και παρουσία αγωγών στην εικόνα αντίστοιχα.

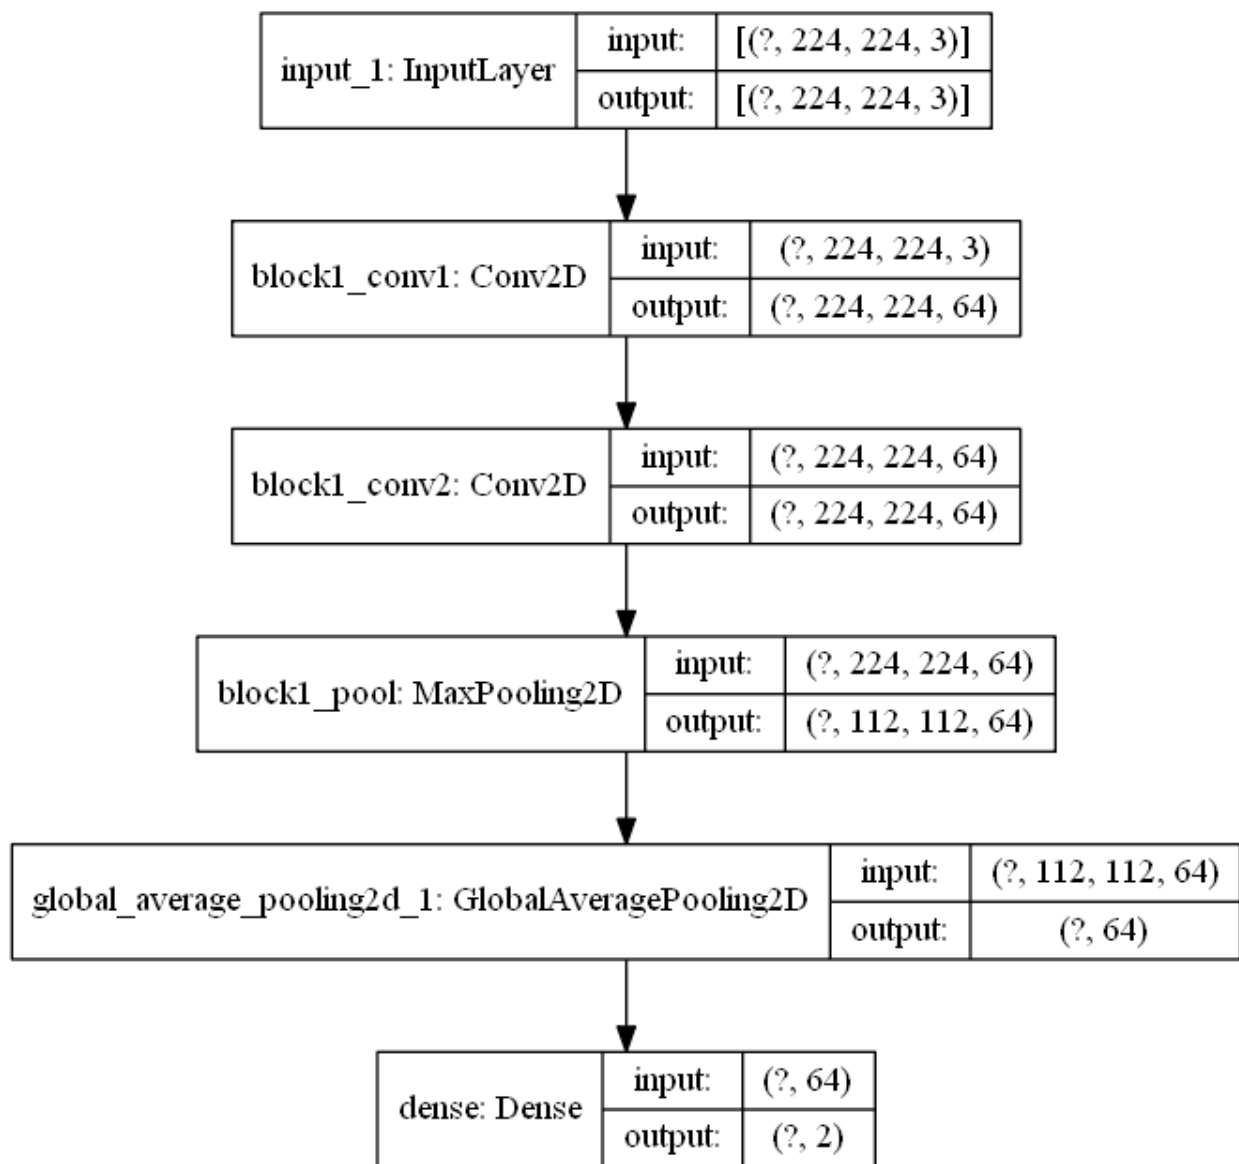


Εικόνα 39 Γενικό Διάγραμμα Εντοπισμού Αγωγών

Τα νευρωνικά δίκτυα μαθαίνουν χαρακτηριστικά των εικόνων με τις οποίες εκπαιδεύονται και τα χρησιμοποιούν ως γνώμονα για να κατηγοριοποιήσουν άλλες που δεν έχουν ξαναδεί. Στα αρχικά convolutional layers εξάγονται απλά χαρακτηριστικά, όπως ακμές (edges) και χρώματα. Όσο μεγαλώνει το βάθος των layers εξάγονται πιο abstract και πολύπλοκα χαρακτηριστικά, ανάλογα την εφαρμογή, όπως το σχήμα μιας γάτας, χαρακτηριστικά σκύλου, μορφές καρκίνου, κλπ. Οι αγωγοί μέσης τάσης που αφορά τη παρούσα εργασία, είναι πάντα ευθείες παράλληλες μεταξύ τους με το χρώμα να αλλάζει αναλόγως τις επικρατούσες καιρικές συνθήκες. Επειδή δεν είναι πολύπλοκα μοτίβα, είναι αναμενόμενο να μην απαιτείται ολόκληρη η αρχιτεκτονική του VGG16. Μπορεί να χρησιμοποιηθεί, δηλαδή, μέρος του και να έχει παρόμοια αποτελέσματα με

τη περίπτωση χρήσης όλου του δικτύου. Ακολουθεί η διαδικασία επιλογής του κατάλληλου block από το οποίο και μετά δε παρουσιάζεται μεγάλη βελτίωση κατηγοριοποίησης.


Ξεκινώντας από το Block1, ακολουθούν τα αποτελέσματα εκπαίδευσης ενός νευρωνικού δικτύου που το περιέχει μαζί αποκλειστικά με το καινούριο classifier.



Εικόνα 40 Αρχιτεκτονική έως Block1 VGG16

Έχοντας ορίσει checkpoints κατά τη διάρκεια εκπαίδευσης, με κριτήριο το ελάχιστο validation loss ανά εποχή, τα στοιχεία της και το βέλτιστο αποτέλεσμα που παρουσιάζεται είναι τα εξής

Η εκπαίδευση σταματά περίπου στην 130^η εποχή, επειδή το validation loss δε βελτιωνόταν αρκετά, όπως φαίνεται στη παρακάτω εικόνα:



Εικόνα 41 Block1 Accuracy - Loss


Total Parameters	38,850
Trainable Parameters	130
Epochs	200
Steps per epoch (training/validation)	10
Batch Size – training	16
Batch Size – validation	8
Optimizer	Adam
Learning Rate	0.001

Πίνακας 1 Στοιχεία Εκπαίδευσης έως Block1

Training Accuracy	0.5750
Training Loss	0.6747
Validation Accuracy	0.6000
Validation Loss	0.6652

Πίνακας 2 Αποτελέσματα Εκπαίδευσης έως Block1

Τα αποτελέσματα δεν είναι ικανοποιητικά, δεδομένης της σχετικά απλής μορφολογίας των αγωγών. Στη συνέχεια, φαίνονται 16 από τα 64 kernels 3x3 μεγέθους που βρίσκονται στο block1_conv2 της *Εικόνας 40*. Κάθε στήλη αντιστοιχεί στα κανάλια χρωμάτων BGR (Blue Green Red) από αριστερά προς τα δεξιά.




Εικόνα 42 Ορισμένα φίλτρα (kernels) του *block1_conv2*

Εισάγοντας τη παρακάτω εικόνα μεγέθους 224x224 στο συγκεκριμένο layer:



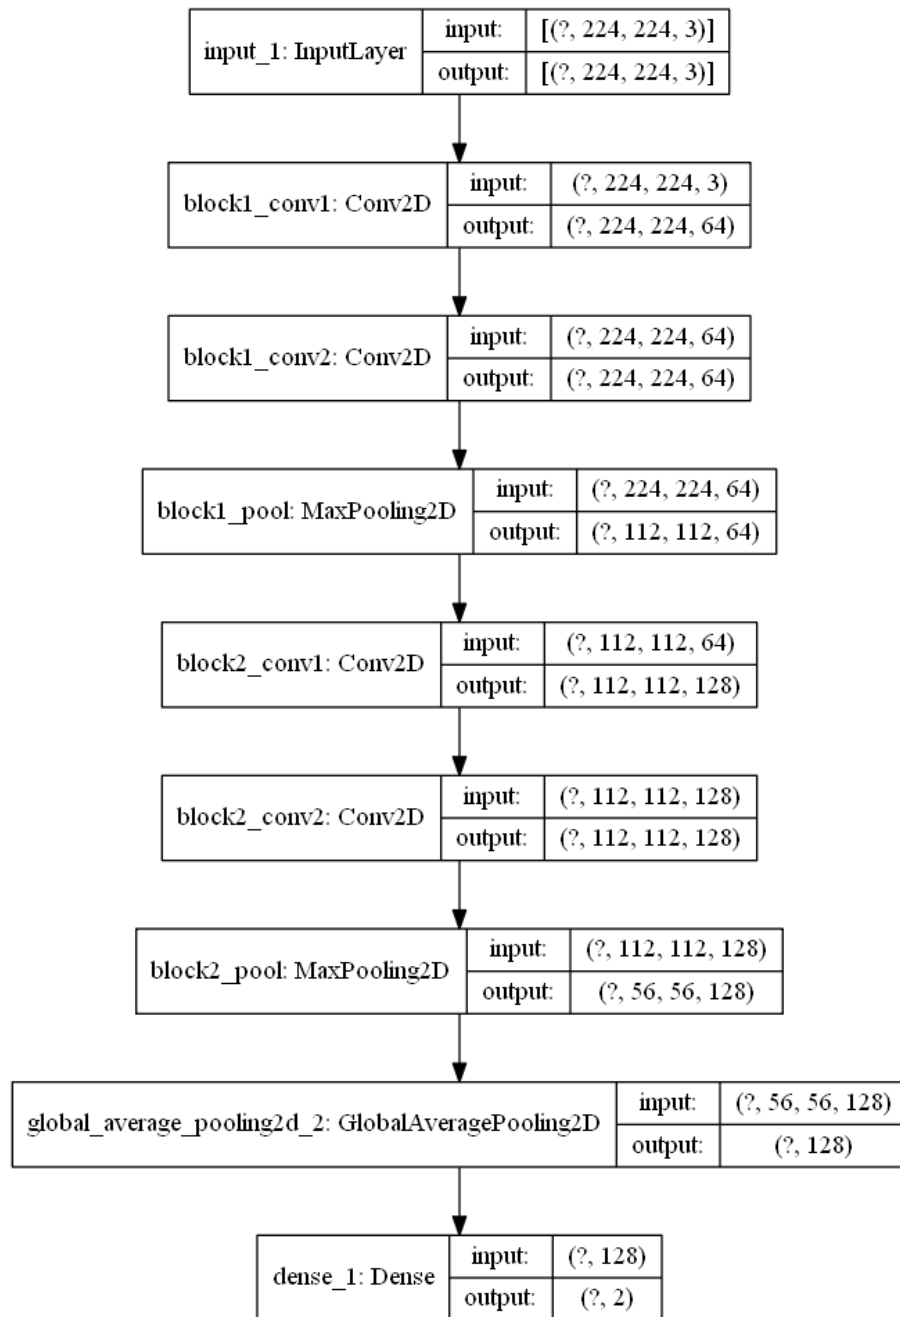
Εικόνα 43 Test Image

Βγαίνουν ως αποτελέσματα τα παρακάτω feature maps από το φιλτράρισμα με τους kernels της εικόνας 42.




Εικόνα 44 Feature Maps block1_conv2

Συνεχίζοντας, γίνεται δοκιμή της αρχιτεκτονικής που συμπεριλαμβάνει το block2 του VGG16.



Εικόνα 45 Αρχιτεκτονική έως Block2 VGG16

Ακολουθούν οι μετρήσεις αποτελεσμάτων εκπαίδευσης:



Εικόνα 46 Block2 Accuracy - Loss

Η εκπαίδευση διακόπτεται στην 165^η εποχή γιατί δε βελτιώνεται άλλο το validation loss

Total Parameters	260,418
Trainable Parameters	258
Epochs	200
Steps per epoch (training/validation)	10
Batch Size – training	16
Batch Size – validation	8
Optimizer	Adam
Learning Rate	0.001

Πίνακας 3 Στοιχεία Εκπαίδευσης έως Block2

Training Accuracy	0.9125
Training Loss	0.2581
Validation Accuracy	0.9375
Validation Loss	0.1922


Πίνακας 4 Αποτελέσματα Εκπαίδευσης έως Block2

Αν και το validation accuracy έφτασε 93.75%, η τιμή του validation loss στο 19.22% δεν είναι ικανοποιητική. Ενδεικτικά, ακολουθούν τα πρώτα 16 από τα 256 φίλτρα του block2_conv2 layer. Κάθε στήλη αντιστοιχεί στα χρώματα BGR από αριστερά προς τα δεξιά.



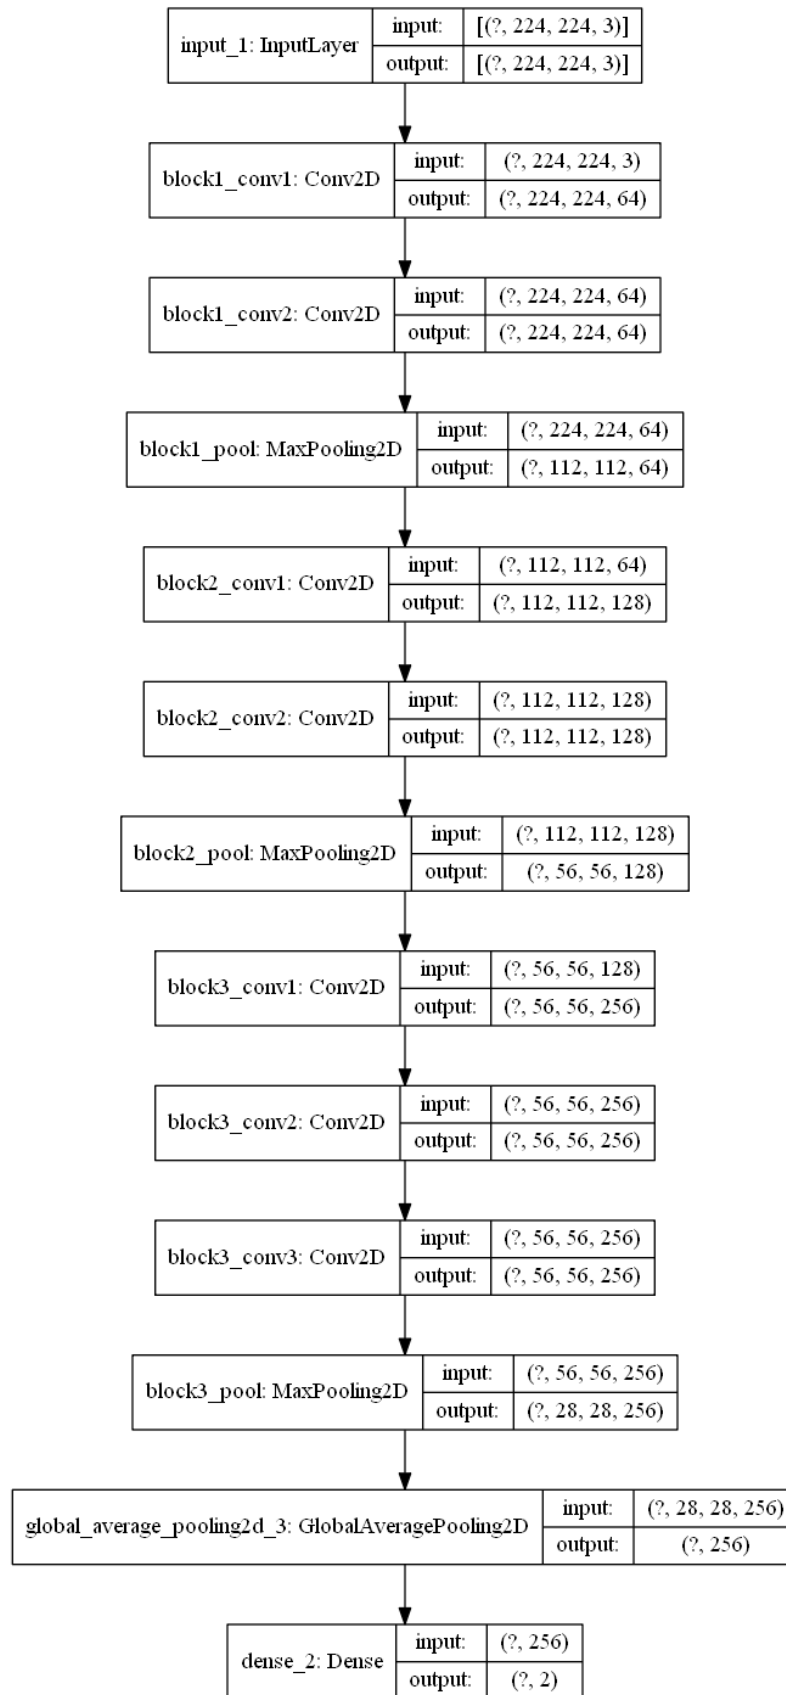
Εικόνα 47 Ορισμένα φίλτρα (kernels) του block2_conv2

Περνώντας η εικόνα 43 από το εν λόγω layer δίνει τα εξής feature maps:




Εικόνα 48 Feature Maps block2_conv2

Ακολουθεί το σχεδιάγραμμα της αρχιτεκτονικής αφού συμπεριληφθεί το block3:



Εικόνα 49 Αρχιτεκτονική έως Block3 VGG16

Στοιχεία και αποτελέσματα εκπαίδευσης για έως το block3:



Εικόνα 50 Block3 Accuracy - Loss


Total Parameters	1,736,002
Trainable Parameters	514
Epochs	200
Steps per epoch (training/validation)	10
Batch Size – training	16
Batch Size – validation	8
Optimizer	Adam
Learning Rate	0.001

Πίνακας 5 Στοιχεία εκπαίδευσης έως Block3

Training Accuracy	0.9625
Training Loss	0.1036
Validation Accuracy	0.9500
Validation Loss	0.1119


Πίνακας 6 Αποτελέσματα εκπαίδευσης έως Block3

Ορισμένα αρχικά kernels από τα 256 που περιέχει το layer block3_conv3 είναι τα παρακάτω:




Εικόνα 51 Kernels block3_conv3

Τα αντίστοιχα feature maps είναι:



Εικόνα 52 Feature Maps block3_conv3

Εξετάζοντας, τέλος, τη συμπερίληψη του block4, τα στοιχεία και αποτελέσματα εκπαίδευσης είναι:



Εικόνα 52 Block4 Accuracy - Los

Total Parameters	7,636,290
Trainable Parameters	1026
Epochs	200
Steps per epoch (training/validation)	10
Batch Size – training	16
Batch Size – validation	8
Optimizer	Adam
Learning Rate	0.001

Πίνακας 7 Στοιχεία εκπαίδευσης έως Block4

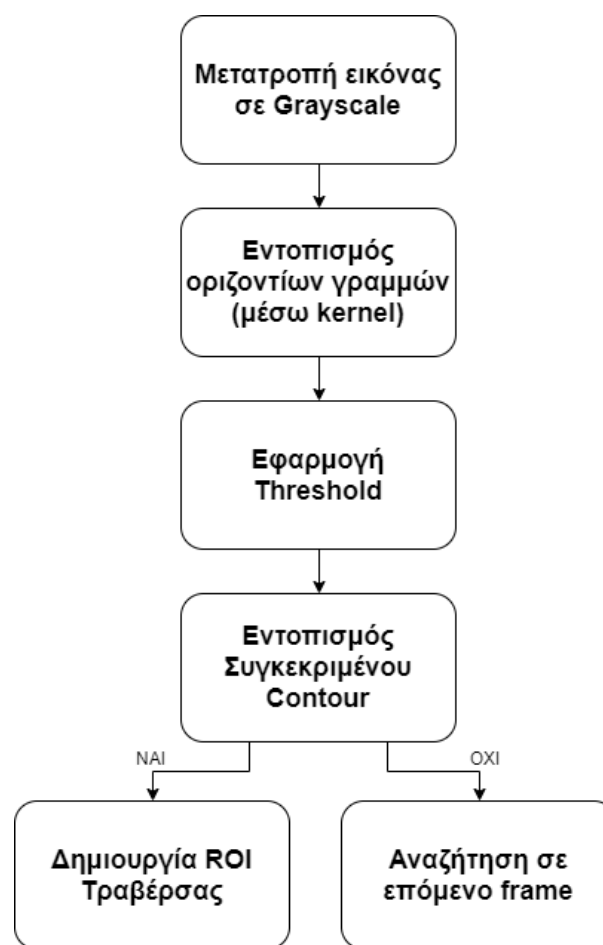
Training Accuracy	0.9625
Training Loss	0.1021
Validation Accuracy	0.9625
Validation Loss	0.1098

Πίνακας 8 Αποτελέσματα εκπαίδευσης έως Block4

Συγκρίνοντας τα αποτελέσματα των δύο τελευταίων αρχιτεκτονικών είναι εμφανές ότι η απόδοση του δικτύου δεν έχει μεγάλες διαφορές (σύγκριση Πίνακα 6 με Πίνακα 8). Για το λόγο αυτό, προτιμήθηκε η αρχιτεκτονική που περιλαμβάνει όλα τα blocks έως και το block3, μιας και η παρουσία επιπλέον blocks δε προσδίδει καλύτερα επίπεδα ακρίβειας μετρήσεων.

5.4.2 Στάδιο 2 – Εντοπισμός Τραβέρσας

Δεδομένου ότι στο προηγούμενο στάδιο έχουν εξαχθεί επιτυχώς όλα τα blocks που περιέχουν αγωγούς, η διαδικασία εντοπισμού της τραβέρσας είναι η εξής:



Εικόνα 53 Στάδιο 2

Ακριβώς πριν την αναζήτηση contours, εφαρμόζεται threshold το 1/3 της μέγιστης έντασης των pixels, στη προσπάθεια απαλοιφής περιοχών που δεν ανήκουν στη τραβέρσα. Τα contours έτσι

που θα εντοπιστούν, είναι σχεδόν πάντα, αποκλειστικά η τραβέρσα. Ωστόσο είναι δυνατή η εύρεση πολλαπλών contours. Για το λόγο αυτό, αναζητούνται και επιλέγονται εκείνα που είναι αρκετά κοντά μεταξύ τους και έχουν σχεδόν ίδιο μέγεθος. Αυτό έχει ως αποτέλεσμα τον εντοπισμό της τραβέρσας και τη δημιουργία RoI γύρω της.

Φίλτρο Gabor

Το φίλτρο Gabor είναι ένα bandpass φίλτρο που αποτελείται από ένα ημιτονοειδές σήμα συγκεκριμένης συχνότητας και προσανατολισμού, διαμορφωμένο με ένα Gaussian wave. Το φίλτρο έχει πραγματικό και φανταστικό μέρος που μπορούν να συνδυαστούν (complex eq) ή να χρησιμοποιηθούν ξεχωριστά.

Complex:

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp(i(2\pi \frac{x'}{\lambda} + \psi))$$

Real:

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos(2\pi \frac{x'}{\lambda} + \psi)$$

Imaginary:

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \sin(2\pi \frac{x'}{\lambda} + \psi)$$

Όπου : $x' = x \cos \theta + y \sin \theta$ $y' = -x \sin \theta + y \cos \theta$

λ , μήκος κύματος ημιτονοειδούς σήματος,


θ , προσανατολισμός φίλτρου,

ψ , διαφορά φάσης ημιτονοειδούς σήματος

σ , τυπική απόκλιση του σήματος Gauss,

γ , καμπυλότητα φίλτρου (0 καθόλου καμπυλότητα, 1 κύκλος)


Τα φίλτρα που χρησιμοποιήθηκαν για τον εντοπισμό της τραβέρσας είναι τα εξής:



Εικόνα 54 Gabor Kernels


Τα πρώτα 2 έχουν διαστάσεις 15x7 pixels, $\sigma=8$, $\lambda=8$, $\gamma=0$, $\psi=0$ και $\theta=45$, $\theta=-45$ αντίστοιχα. Βοηθάνε στον εντοπισμό τραβέρσας που είναι υπό κλίση στην εικόνα, όχι οριζόντια. Το τρίτο εντοπίζει οριζόντιες γραμμές (άρα και οριζόντια τραβέρσα) έχει μέγεθος 21x5 με $\sigma=1.6$, $\lambda=3$, $\gamma=0$, $\psi=0$ και $\theta=\pi/2$.

Στη συνέχεια, εφαρμόζεται η μεθοδολογία εντοπισμού οριζόντιας και διαγώνιας τραβέρσας:




*Εικόνα 55 Εικόνες με τραβέρσα ξύλινου στύλου μέσης τάσης
σε οριζόντια και διαγώνια διεύθυνση*

Φιλτράρισμα με αντίστοιχους gabor kernels Εικόνας 55 και εφαρμογή threshold:



Εικόνα 56 Φιλτράρισμα με Gabor Kernels.

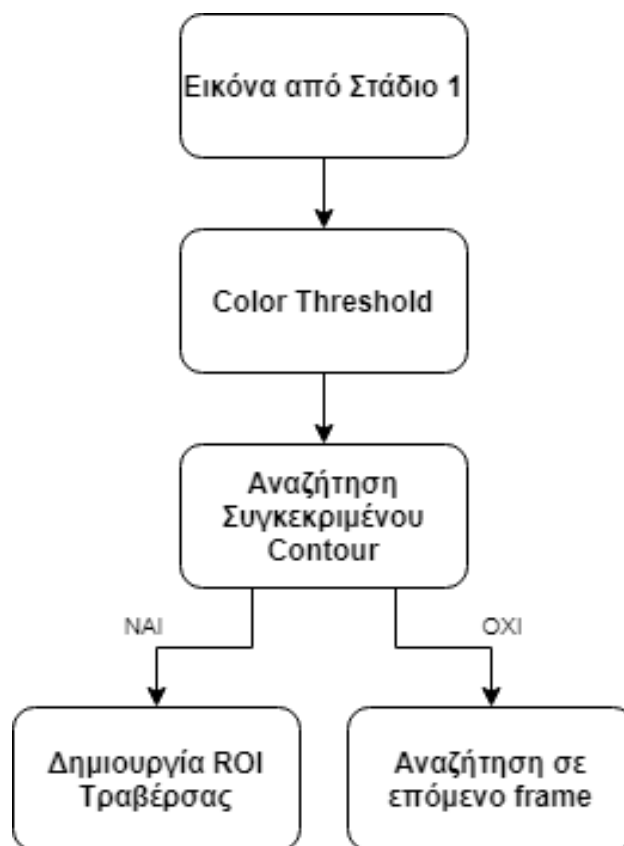
Αναζήτηση μακριών και πλατιών contours (μεταβλητές h, w μεθόδου για contours), όπως επίσης να βρίσκονται κοντά οι συντεταγμένες τους. Αποτελέσματα αναζήτησης μέσω δημιουργίας RoI:



Εικόνα 57 Δημιουργία RoI γύρω από εντοπισμένη τραβέρσα

Color Thresholding

Ο εντοπισμός της μεταλλικής τραβέρσας στους πόλους μέσης τάσης είναι δυνατόν να επιτευχθεί και μέσω color thresholding. Η δυσκολία στη συγκεκριμένη τεχνική έγκειται στο διαφορετικό φωτισμό λόγω ηλίου που τυγχάνει σε κάθε πτήση ΣμηΕΑ. Για το λόγο αυτό, δοκιμάζοντας 3 color spaces, αναζητείται στην εικόνα ένα εύρος χρώματος και όχι συγκεκριμένη τιμή (στη συγκεκριμένη περίπτωση εύρος χρώματος γκρι).




Εικόνα 58 Εντοπισμός Τραβέρσας μέσω color thresholding.

Hue-Saturation-Value (HSV)

Ο χώρος χρωμάτων HSV αποτελεί εναλλακτική απεικόνιση του μοντέλου Red-Green-Blue (RGB). Αναλύει το χρώμα σε τρεις παραμέτρους:

1. Χροιά (Hue), δηλαδή τη θέση στο χρωματικό κύκλο (0-360 μοίρες)
2. Κορεσμός (Saturation), δηλαδή ένταση του χρώματος (0-100%)
3. Αξία (Value), δηλαδή ένταση της λαμπρότητας του χρώματος (0-100%)

Οι εικόνες που επεξεργάζονται (Εικόνα 56) έχουν βάθος χρώματος 8-bit. Οπότε το 100% των παραπάνω παραμέτρων είναι ίσο με 255. Εφαρμόζοντας ως κάτω όριο τις τιμές [0, 0, 133] και ως άνω όριο [179, 20, 220] για Hue, Saturation, Value αντίστοιχα, το αποτέλεσμα είναι το παρακάτω:




Εικόνα 59 HSV Color Thresholding

CIE L*a*b*

Κάθε εικονοστοιχείο αναλύεται στις παραμέτρους L, a, b και χρησιμοποιούνται συντεταγμένες τετραγωνικής ρίζας για την απεικόνιση χρωμάτων:

1. Ένταση φωτεινότητας (L – Luminosity)
2. Χρωματική θέση ανάμεσα στο κόκκινο και το συμπληρωματικό του πράσινου (a)
3. Χρωματική θέση ανάμεσα στο μπλε και το συμπληρωματικό του κίτρινου (b)

Η διαβάθμιση του είναι από τις πληρέστερες προς την ανθρώπινη αντίληψη. Εφαρμόζοντας κάτω όριο [180, 125, 125] και άνω όριο [255, 140, 140] για L, a, b αντίστοιχα:




*Εικόνα 60 CIE L*a*b* Color Thresholding*

YCbCr

Στο συγκεκριμένο μοντέλο, υπάρχουν οι παράμετροι:


1. Y, που είναι η φωτεινότητα (luma)
2. Cb, το μπλε μέρος από luma
3. Cr, το κόκκινο μέρος από luma

Εφαρμόζοντας κάτω όριο [160, 120, 120] και άνω όριο [220, 140, 140] για Y, Cb, Cr αντίστοιχα:



Εικόνα 61 YCbCr Color Thresholding

Κάνοντας, τέλος, αναζήτηση contours σε ένα από τα παραπάνω color thresholded αποτελέσματα, (βέλτιστο το HSV), η τραβέρσα εντοπίζεται πάλι ως εξής:




Εικόνα 62 Δημιουργία RoI γύρω από εντοπισμένη τραβέρσα

5.4.3 Στάδιο 3 – Εντοπισμός Μονωτήρων

Μονωτήρες Υψηλής Τάσης

Η ύπαρξη διαθέσιμου dataset εικόνων μονωτήρων υψηλής τάσης (Chinese Power Line Insulator Dataset), επιτρέπει την εκπαίδευση του VGG16 στην ανίχνευση τους. Το συγκεκριμένο dataset διαθέτει 600 εικόνες με μονωτήρες, εκ των οποίων οι 420 χρησιμοποιήθηκαν για training, οι 90 για validation και οι τελευταίες 90 ως test set. Ο classifier του VGG16 αντικαταστάθηκε με νέο που κατηγοριοποιεί τις εικόνες σε δύο κλάσεις, absent_ins και present_ins αντιπροσωπεύοντας την απουσία και παρουσία μονωτήρων υψηλής τάσης στην εκάστοτε εικόνα αντίστοιχα. Η αρχιτεκτονική του μοντέλου, τα στοιχεία εκπαίδευσης και αποτελέσματα ακολουθούν:



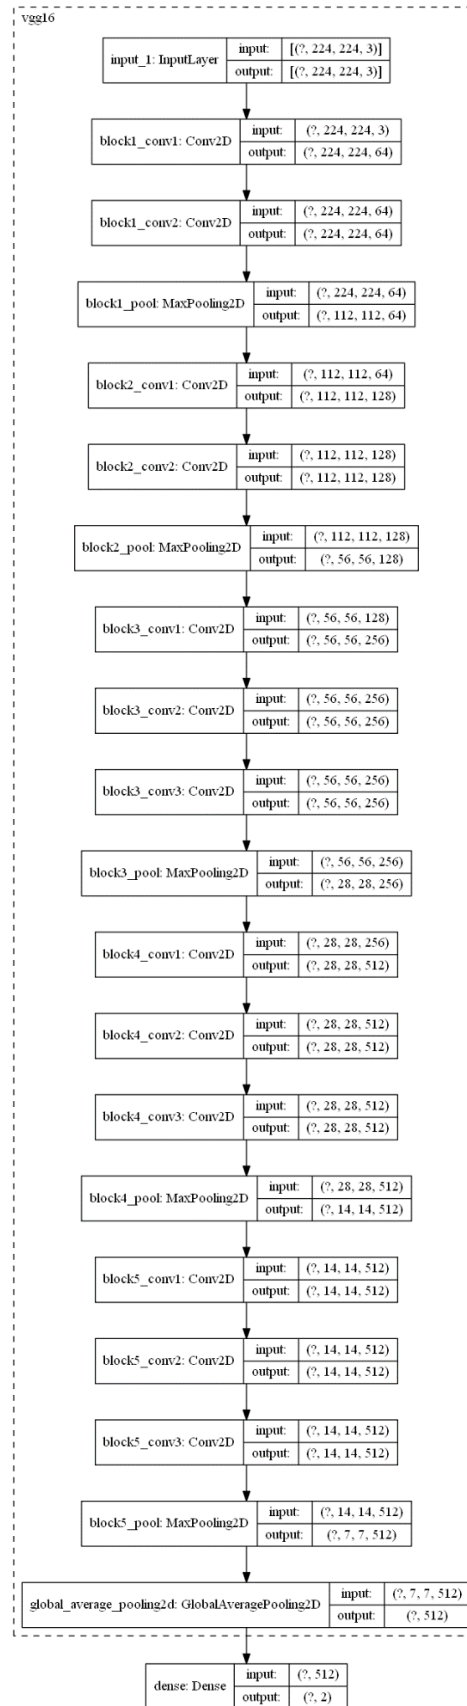
Εικόνα 63 High Voltage Insulator Detection Accuracy - Loss

Epochs	200
Steps per epoch (training/validation)	10
Batch Size – training	16
Batch Size – validation	8
Optimizer	Adam
Learning Rate	0.001

Πίνακας 9 Στοιχεία Εκπαίδευσης – HV Insulator Detection

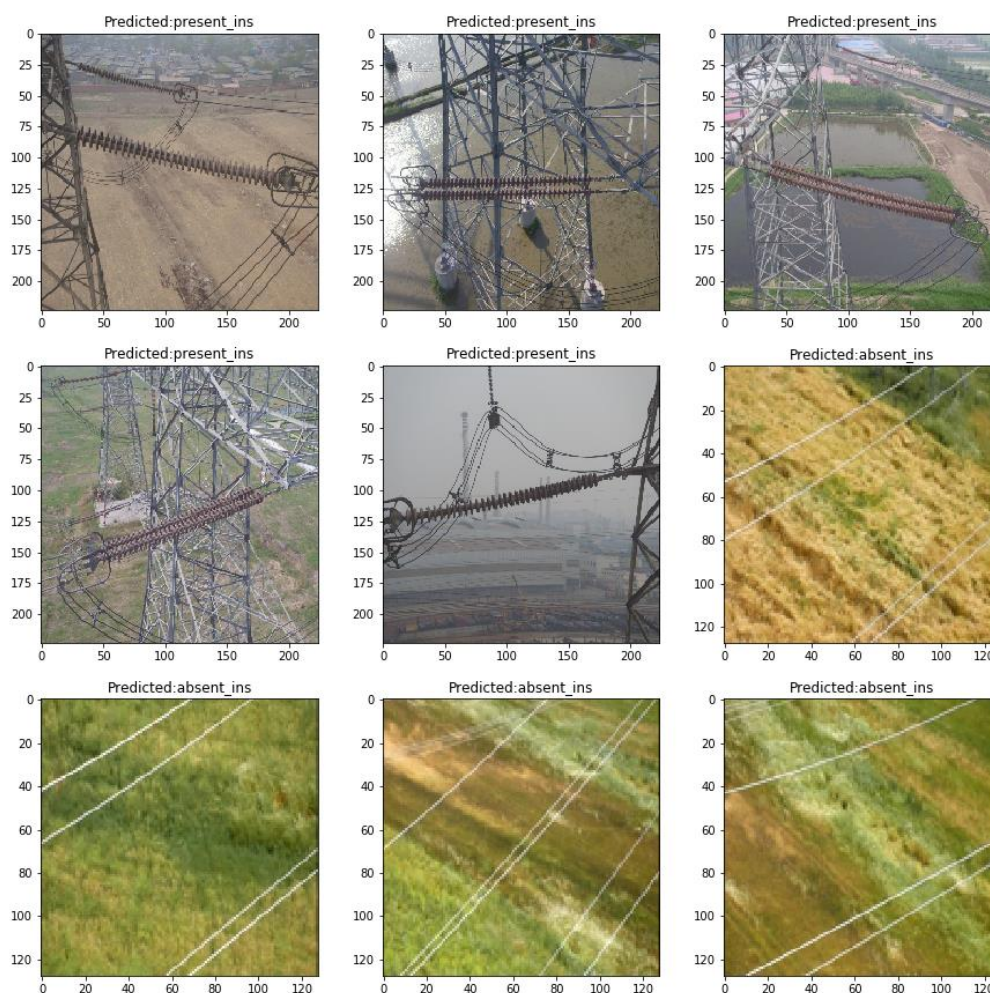
Training accuracy	0.9868
Training loss	0.0516
Validation accuracy	0.9675
Validation loss	0.0506

Πίνακας 10 Αποτελέσματα Εκπαίδευσης – HV Insulator Detection



Εικόνα 64 Αρχιτεκτονική Νευρωνικού Δικτύου HV Insulator Detection

Ακολουθούν ενδεικτικά αποτελέσματα κατηγοριοποίησης εικόνων με και χωρίς μονωτήρες υψηλής τάσης:



*Εικόνα 65 Παραδείγματα Κατηγοριοποίησης Εικόνων
για μονωτήρες υψηλής τάσης*

Μονωτήρες Μέσης Τάσης

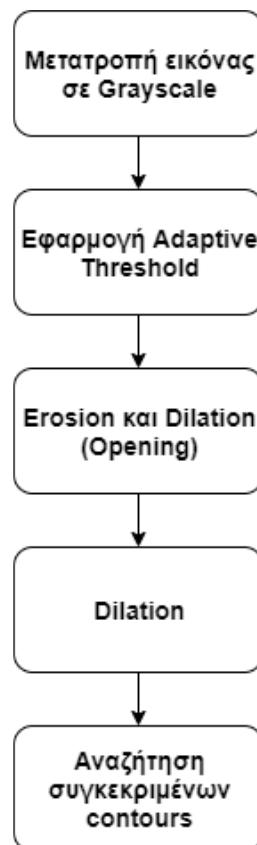
Λόγω της απουσίας διαθέσιμου dataset εικόνων μονωτήρων μέσης τάσης, εντάχθηκαν σχεδόν 100 φωτογραφίες αυτών στο dataset μονωτήρων υψηλής. Σίγουρα οι τελευταίοι έχουν αρκετά μεγαλύτερο φυσικό μέγεθος αλλά η μορφολογία είναι παρόμοια με των μέσης. Παρακάτω, εμφανίζονται αποτελέσματα επεξεργασίας της εικόνας εντοπισμένης τραβέρσας για μονωτήρες.



*Εικόνα 66 Παραδείγματα Κατηγοριοποίησης Εικόνων
για μονωτήρες μέσης τάσης*

Όπως είναι φανερό, ο εντοπισμός των μονωτήρων είναι επιτυχής, ωστόσο υπάρχουν ορισμένα false positives, που έχει εντοπιστεί κομμάτι ου αγωγού ως μονωτήρας. Αυτό οφείλεται στην έλλειψη εικόνων μονωτήρων μέσης τάσης προς εκπαίδευση του νευρωνικού δικτύου.

Εκτός του νευρωνικού δικτύου, η ανίχνευση τους είναι δυνατόν να επιτευχθεί και μέσω μιας σειράς μεθόδων επεξεργασίας εικόνων.



Εικόνα 67 Image Processing για εντοπισμό μονωτήρων μέσης τάσης

Ενδεικτικό παράδειγμα της μεθόδου είναι το εξής:




Εικόνα 68 Τμήμα των μονωτήρων χωρίς τη τραβέρσα

Εφαρμόζεται adaptive threshold με blocksize 7x7:




Εικόνα 69 Adaptive Threshold

Morphological opening (erosion και dilation) με kernel μεγέθους 5x5:



Εικόνα 70 Erosion and Dilation

Επανάληψη dilation με ίδιο kernel:




Εικόνα 71 Second Dilation

Αναζήτηση contours και εντοπισμός μονωτήρων:




Εικόνα 72 Εντοπισμένοι Μονωτήρες

Παρόλο που η ανίχνευση των μονωτήρων επιτυγχάνεται μέσω των συγκεκριμένων μεθόδων επεξεργασίας εικόνας στη παραπάνω περίπτωση, δεν αποτελεί βέλτιστη λύση του προβλήματος εντοπισμού τους, διότι δεν εξάγεται ιδανικά η μορφολογία των μονωτήρων. Για το λόγο αυτό, προτιμάται το νευρωνικό δίκτυο. Τέλος, για την απόκτηση της θερμοκρασίας της συνδεσμολογίας του κάθε μονωτήρα, απαραίτητη είναι η ανίχνευση του «σώματος» του. Εφαρμόζοντας color threshold στο RGB colorspace κάτω όριο $[150, 150, 150]$ και άνω $[200, 200, 200]$ στα blocks εξόδου του προηγούμενου σταδίου απομονώνεται σχεδόν ολόκληρος ο μονωτήρας από την υπόλοιπη εικόνα. Ύστερα, εφαρμόζεται morphological opening με kernel διαστάσεων 1×2 για απαλοιφή τυχών διάσπαρτων pixels και αντιστοιχίζονται τα pixels στη θερμική εικόνα για λήψη μέγιστης θερμοκρασίας. Ακολουθεί ενδεικτικό παράδειγμα:



Εικόνα 73 Εντοπισμός «Σώματος» Μονωτήρα



*Εικόνα 74 Μετρήσεις θερμοκρασίας μονωτήρων σε βαθμούς Κελσίου
(Σφάλμα στο κάτω αριστερά)*

6.

ΣΥΜΠΕΡΑΣΜΑΤΑ – ΜΕΛΛΟΝΤΙΚΕΣ ΕΠΕΚΤΑΣΕΙΣ

Τα νευρωνικά δίκτυα σε συνδυασμό με κατάλληλο dataset δεδομένων είναι ικανά να λύσουν αρκετά σύγχρονα προβλήματα. Η παρούσα εργασία έδειξε ότι μία πραγματική εφαρμογή όπως είναι η συντήρηση του δικτύου μεταφοράς ηλεκτρικής ενέργειας έχει να διευκολυνθεί σε μεγάλο βαθμό με την εφαρμογή τους.

Αντικαθιστώντας αντίστοιχες μεθόδους image processing, στο πρώτο στάδιο της μεθοδολογίας εξάγονται οι αγωγοί (όπου και εάν υπάρχουν) μέσω ενός δικτύου που περιέχει layers από το VGG16. Οι καιρικές συνθήκες και το background κάθε φορά αλλάζουν, οπότε είναι σημαντικό να ληφθούν επιπλέον φωτογραφίες αγωγών για εμπλουτισμό του training set.

Στο δεύτερο στάδιο εξάγεται η τραβέρσα με μεθόδους image processing μιας και δεν υπάρχει διαθέσιμο dataset. Η προφανής βελτίωση στο συγκεκριμένο στάδιο είναι η αντικατάσταση των μεθόδων του με κάποιο deep neural network, αφού πρώτα υπάρξει dataset. Έτσι θα αυξηθεί σε μεγάλο βαθμό η ακρίβεια εντοπισμού τραβέρσας.

Στο τρίτο στάδιο προτείνονται δύο μέθοδοι ανίχνευσης μονωτήρων, ένας με νευρωνικό δίκτυο (VGG16) και ένας με image processing. Κατέστη σαφές ότι το VGG16 είναι σίγουρα αποδοτικότερο στον εντοπισμό, παρά την έλλειψη εικόνων μονωτήρων μέσης τάσης. Μια πιθανή βελτίωση θα ήταν η συγχώνευση των σταδίων δύο και τρία, ειδικά στη περίπτωση απόκτησης ευρύτερου dataset μονωτήρων.

Τέλος, παρόλο που χρησιμοποιήθηκε το VGG16 ως βάση, η γενική μεθοδολογία μπορεί να βελτιωθεί με την ενίσχυση από LSTMs για επεξεργασία πολλαπλών frames τη φορά, σε αντίθεση με το ένα frame που υποστηρίζει μέχρι τώρα.

Σκοπός της εργασίας αποτελεί την έρευνα και εφαρμογή σύγχρονων μεθόδων επεξεργασίας εικόνας και τεχνητής νοημοσύνης για να λύσει προβλήματα που αντιμετωπίζονται με συμβατικές, περιορισμένες, μη-οικονομικές και μερικές φορές επικίνδυνες για τον άνθρωπο μεθόδους, όπως η επιθεώρηση του δικτύου μεταφοράς και διανομής ηλεκτρικής ενέργειας.

7.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] L. Wang, F. Liu, Z. Wang, S. Xu, S. Cheng and J. Zhang, “Development of a practical power transmission line inspection robot based on a novel line walking mechanism”, IEEE/RSJ International Conference on Intelligent Robots and Systems, October 2010.
- [2] A. Zormpas, K. Moirogiorgou, K. Kalaitzakis, G. A. Plokamakis, P. Partsinevelos, G. Giakos and M. Zervakis, "Power transmission lines inspection using properly equipped Unmanned Aerial Vehicle (UAV)", in IEEE International Conference on Imaging Systems and Techniques, 2018.
- [3] Y. Liu, Z. Li, R. Hayward, R. Walker, H. Jin, “Classification of Airborne LIDAR Intensity Data Using Statistical Analysis and Hough Transform with Application to Power Line Corridors”, 2009
- [4] Q. Ma, D. S. Goshi, L. Bui and M. Sun, “An Algorithm for Radar Power Line Detection with Tracking
- [5] R. Wang, “Edge Detection using Convolutional Neural Network”, International Symposium on Neural Networks, 2016
- [6] El-Sayed, Mohamed & Estaitia, Yarub & Khafagy, Mohamed. (2013). Edge Detection Using Convolutional Neural Network. International Journal of Advanced Computer Science and Applications. 4. 11-17.

- [7] S. J. Lee, J. P. Yun, H. Choi, W. Kwon, G. Koo and S. W. Kim, "Weakly supervised learning with convolutional neural networks for power line localization," 2017 IEEE Symposium Series on Computational Intelligence (SSCI), Honolulu, HI, 2017, pp. 1-8.
- [8] Y. Wu, Y. Luo, G. Zhao, J. Hu, F. Gao and S. Wang, "A novel line position recognition method in transmission line patrolling with UAV using machine learning algorithms," 2018 IEEE International Symposium on Electromagnetic Compatibility and 2018 IEEE Asia-Pacific Symposium on Electromagnetic Compatibility (EMC/APEMC), Singapore, 2018, pp. 491-495.
- [9] Z. Li, Y. Liu, R. Hayward, J. Zhang and J. Cai, "Knowledge-based power line detection for UAV surveillance and inspection systems," 2008 23rd International Conference Image and Vision Computing New Zealand, Christchurch, 2008, pp. 1-6.
- [10] J. Gubbi, A. Varghese and P. Balamuralidhar, "A new deep learning architecture for detection of long linear infrastructure," 2017 Fifteenth IAPR International Conference on Machine Vision Applications (MVA), Nagoya, 2017, pp. 207-210.
- [11] Yue Liu, Jun Yong, Liang Liu, Jinlong Zhao and Zongyu Li, "The method of insulator recognition based on deep learning," 2016 4th International Conference on Applied Robotics for the Power Industry (CARPI), Jinan, 2016, pp. 1-5.
- [12] Babenko, Artem & Lempitsky, Victor. (2015). Aggregating Deep Convolutional Features for Image Retrieval. ICCV.
- [13] Zhang, W.; Witharana, C.; Li, W.; Zhang, C.; Li, X.; Parent, J. Using Deep Learning to Identify Utility Poles with Crossarms and Estimate Their Locations from Google Street View Images. Sensors 2018, 18, 2484.
- [14] Z. Zhao, G. Xu, Y. Qi, N. Liu and T. Zhang, "Multi-patch deep features for power line insulator status classification from aerial images," 2016 International Joint Conference on Neural Networks (IJCNN), Vancouver, BC, 2016, pp. 3187-3194.
- [15] Yetgin, Ömer Emre; GEREK, Ömer Nezih (2019), "Powerline Image Dataset (Infrared-IR and Visible Light-VL)", Mendeley Data, v8
- [16] António Raimundo, "Insulator Data Set - Chinese Power Line Insulator Dataset (CPLID)", IEEE Dataport, 2020.

- [17] Usamentiaga, Rubén & Pablo, Venegas & Guerediaga, Jon & Vega, Laura & Molleda, Julio & Bulnes, Francisco. (2014). Infrared Thermography for Temperature Measurement and Non-Destructive Testing. Sensors (Basel, Switzerland). 14.
- [18] Ιωάννης Βαρδαξής, "Σχεδιασμός και υλοποίηση συστήματος ανίχνευσης βλαβών στις γραμμές μεταφοράς ηλεκτρικής ενέργειας με χρήση drone εξοπλισμένου με θερμική κάμερα", Διπλωματική Εργασία, Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών, Πολυτεχνείο Κρήτης, Χανιά, Ελλάς, 2018
- [19] Mu, Chao & Yu, Jie & Feng, Yanming & Cai, Jinhai. (2009). Power lines extraction from aerial images based on Gabor filter. Proc SPIE. 7492.
- [20] C. Sampedro, C. Martinez, A. Chauhan and P. Campoy, "A supervised approach to electric tower detection and classification for power line inspection," 2014 International Joint Conference on Neural Networks (IJCNN), Beijing, 2014, pp. 1970-1977.
- [21] Simonyan, Karen & Zisserman, Andrew. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. arXiv 1409.1556.
- [22] Srikanth Tammima (2019); Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images; International Journal of Scientific and Research Publications (IJSRP) 9(10)
- [23] Ming Liang and Xiaolin Hu, "Recurrent convolutional neural network for object recognition," 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Boston, MA, 2015, pp. 3367-3375.
- [24] Girshick, Ross. (2015). Fast r-cnn. 10.1109/ICCV.2015.169.
- [25] Ren, Shaoqing & He, Kaiming & Girshick, Ross & Sun, Jian. (2015). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. IEEE Transactions on Pattern Analysis and Machine Intelligence. 39.
- [26] He, Kaiming & Gkioxari, Georgia & Dollár, Piotr & Girshick, Ross. (2017). Mask R-CNN.
- [27] Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. Neural Computation, 9, 1735-1780.

- [28] Y. Liu, Z. Tang and Y. Xu, "Detection of ice thickness of high voltage transmission line by image processing," 2017 IEEE 2nd Advanced Information Technology, Electronic and Automation Control Conference (IAEAC), Chongqing, 2017, pp. 2191-2194.
- [29] Ö. E. Yetgin and Ö. N. Gerek, "PLD: Power line detection system for aircrafts," 2017 International Artificial Intelligence and Data Processing Symposium (IDAP), Malatya, 2017, pp. 1-5.
- [30] X. Hu, X. Zhou, D. Zuo, H. Hu, X. Hou, J. Xu, W. Song, H. Liu, "Extraction of High Voltage Transmission Lines based on Morphological Processing", IEEE International Conference on Information and Automation (ICIA), 2016.
- [31] G. Zhou, J. Yuan, I. Yen, F. Bastani, "Robust Real-Time UAV Based Power Line Detection and Tracking", IEEE International Conference on Image Processing (ICIP), 2016.
- [32] Dan Playforth, «Infrared Thermography Electrical Inspections»
- [33] "Power Line Infrared Thermography Inspection." Martechical. Martechical, n.d. Web. 05 Feb. 2015