



ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ

**ΣΧΟΛΗ ΤΕΧΝΟΛΟΓΙΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΕΠΙΚΟΙΝΩΝΙΩΝ
ΤΜΗΜΑ ΨΗΦΙΑΚΩΝ ΣΥΣΤΗΜΑΤΩΝ**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

**Αναγνώριση Φωτοβολταϊκών εγκαταστάσεων και
οριοθέτηση της έκτασης τους με χρήση μεθόδων
αναγνώρισης εικόνας.**

Δραμιτινός Γεώργιος

**Επιβλέπων Καθηγητής:
Μιχαήλ Φιλιππάκης, Καθηγητής**

ΠΕΙΡΑΙΑΣ

ΟΚΤΩΒΡΙΟΣ 2024

ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

**Αναγνώριση Φωτοβολταϊκών εγκαταστάσεων και οριοθέτηση της έκτασης τους
με χρήση μεθόδων αναγνώρισης εικόνας.**

**Δραμιτινός Γεώργιος
Α.Μ.: ΜΕ2212**

ΠΕΡΙΛΗΨΗ

Η εργασία αναπτύσσει έναν αλγόριθμο με χρήση νευρωνικών δικτύων (U-Net) για την αναγνώριση και οριοθέτηση φωτοβολταϊκών πάνελ από δορυφορικές εικόνες, αξιοποιώντας δεδομένα σε έξι διαφορετικούς τύπους εδαφών. Με βάση την αρχιτεκτονική MobileNetV2 και τεχνικές προεπεξεργασίας δεδομένων, το μοντέλο εκπαιδεύτηκε και πέτυχε ακρίβεια αναγνώρισης 90-94%, οριοθετώντας τα πάνελ σε εικόνες με μεγάλη επιτυχία. Παρά μικρές αστοχίες, η εφαρμογή του μοντέλου προσφέρει δυνατότητες καταγραφής φωτοβολταϊκών εγκαταστάσεων, υπολογισμού κάλυψης και εκτίμησης ενεργειακής απόδοσης, με προοπτική βελτίωσης για γεωχωρικές εφαρμογές.

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ: Φωτοβολταϊκά, δορυφορικές εικόνες, U-Net, αναγνώριση αντικειμένων, τεχνητή νοημοσύνη

ABSTRACT

The study focuses on the development of an algorithm using neural networks (U-Net) for detecting and delineating solar panels in satellite images, utilizing data categorized into six different land types. Based on the MobileNetV2 architecture and preprocessing techniques, the model was trained to achieve an accuracy of 90-94%, effectively identifying and outlining solar panels in the images. Despite minor inaccuracies, the model offers capabilities for monitoring photovoltaic installations, calculating coverage, and estimating energy production, with potential for enhancements in geospatial applications.

KEYWORDS: Solar panels, satellite images, U-Net, object detection, artificial intelligence.

Περιεχόμενα

Περίληψη.....	6
Πρόλογος.....	7
1. Εισαγωγή.....	8
2. Σκοπός.....	8
3. Φωτοβολταϊκά Συστήματα.....	9
4. Τηλεπισκόπηση και ΑΠΕ.....	12
5. Νευρονικά Δίκτυα.....	13
6. Βιβλιογραφική Ανασκόπηση.....	14
7. Δεδομένα.....	17
8. Εισαγωγή και Διαμόρφωση Δεδομένων.....	17
9. Νευρωνικό Δίκτυο – Αλγόριθμος.....	19
10. Δίκτυα U-Net.....	18
11. Διαδικασία Ταξινόμησης.....	20
12. Αποτελέσματα.....	23
Εικόνες-Διαγράμματα.....	26
Συμπεράσματα.....	29
Κώδικας.....	30
Βιβλιογραφικές Αναφορές.....	35

Περίληψη

Η παρούσα πτυχιακή εργασία επικεντρώνεται στην ανάπτυξη ενός αλγορίθμου αναγνώρισης φωτοβολταϊκών εγκαταστάσεων και οριοθέτησης της έκτασής τους μέσω δορυφορικών εικόνων, χρησιμοποιώντας σύγχρονες τεχνικές μηχανικής μάθησης και τεχνητής νοημοσύνης. Η μεθοδολογία που ακολουθήθηκε βασίζεται στη χρήση νευρωνικών δικτύων τύπου U-Net, τα οποία έχουν αποδειχθεί ιδιαίτερα αποδοτικά στην ανάλυση εικόνας και την αναγνώριση αντικειμένων. Το μοντέλο εκπαιδεύτηκε με δορυφορικά δεδομένα έξι διαφορετικών τύπων εδαφών, αξιοποιώντας την αρχιτεκτονική MobileNetV2 σε συνδυασμό με τεχνικές προεπεξεργασίας δεδομένων, προκειμένου να βελτιωθεί η απόδοση της ταξινόμησης.

Τα αποτελέσματα της εκπαίδευσης έδειξαν ότι ο προτεινόμενος αλγόριθμος επιτυγχάνει ακρίβεια 90-94%, αναγνωρίζοντας με υψηλή επιτυχία τις περιοχές που καλύπτονται από φωτοβολταϊκά πάνελ. Παρά τις μικρές αστοχίες, η χρήση του μοντέλου μπορεί να συμβάλει σημαντικά στην αυτόματη χαρτογράφηση φωτοβολταϊκών εγκαταστάσεων, στον υπολογισμό της κάλυψης των ΑΠΕ και στην εκτίμηση της ενεργειακής παραγωγής των ηλιακών πάρκων.

Η εργασία αυτή αποτελεί μια καινοτόμο προσέγγιση που συνδυάζει τεχνολογίες τηλεπισκόπησης, νευρωνικών δικτύων και δορυφορικής ανάλυσης, με σκοπό τη δημιουργία ενός εργαλείου που θα μπορεί να χρησιμοποιηθεί τόσο από ερευνητικούς φορείς όσο και από οργανισμούς που δραστηριοποιούνται στην παρακολούθηση και διαχείριση των ανανεώσιμων πηγών ενέργειας. Επιπλέον, η έρευνα αυτή ανοίγει νέες προοπτικές για τη βελτίωση των γεωχωρικών εφαρμογών, προσφέροντας μια αποδοτική και αυτοματοποιημένη λύση για τη χαρτογράφηση των φωτοβολταϊκών εγκαταστάσεων σε παγκόσμια κλίμακα.

Πρόλογος

Η παρούσα εργασία ασχολείται με την εφαρμογή τεχνικών τεχνητής νοημοσύνης για την αναγνώριση φωτοβολταϊκών πάνελ σε δορυφορικές εικόνες. Η αξιοποίηση νευρωνικών δικτύων, όπως το U-Net, επιτρέπει την αυτοματοποιημένη επεξεργασία εικόνων με στόχο την ακριβή οριοθέτηση εγκαταστάσεων ανανεώσιμης ενέργειας. Μέσα από τη μελέτη αυτή, αναδεικνύεται η σημασία της σύγχρονης τεχνολογίας στη βιώσιμη ανάπτυξη και τη διαχείριση ενεργειακών πόρων, ανοίγοντας τον δρόμο για περαιτέρω έρευνα και καινοτομία στον τομέα.

1. Εισαγωγή

Η συνεχής αύξηση της παγκόσμιας ζήτησης για καθαρές και βιώσιμες μορφές ενέργειας έχει καταστήσει τις ανανεώσιμες πηγές ενέργειας, όπως τα φωτοβολταϊκά συστήματα, καθοριστικής σημασίας για το ενεργειακό μέλλον του πλανήτη. Παράλληλα, η πρόοδος στις τεχνολογίες δορυφορικής παρατήρησης και τεχνητής νοημοσύνης προσφέρει νέες δυνατότητες στον εντοπισμό και την παρακολούθηση τέτοιων εγκαταστάσεων, σε μεγάλη κλίμακα και με υψηλό βαθμό ακρίβειας.

Η παρούσα εργασία επικεντρώνεται στην ανάπτυξη ενός συστήματος αναγνώρισης φωτοβολταϊκών εγκαταστάσεων και στην οριοθέτηση της έκτασής τους, αξιοποιώντας τεχνικές αναγνώρισης εικόνας και βαθιάς μάθησης. Συγκεκριμένα, γίνεται χρήση του νευρωνικού δικτύου τύπου U-Net, το οποίο, σε συνδυασμό με την αρχιτεκτονική MobileNetV2, επιτυγχάνει αποτελεσματική ταξινόμηση και εντοπισμό φωτοβολταϊκών πάνελ από δορυφορικές εικόνες.

Μέσω της εφαρμογής αυτής, επιδιώκεται η δημιουργία ενός εργαλείου που θα μπορεί να αξιοποιηθεί σε ενεργειακό σχεδιασμό, παρακολούθηση της ανάπτυξης των ΑΠΕ και επιστημονική έρευνα με γεωχωρικά δεδομένα. Η καινοτομία του εγχειρήματος έγκειται στη συνδυασμένη χρήση ελεύθερα διαθέσιμων δορυφορικών δεδομένων, τεχνικών μηχανικής μάθησης και εξειδικευμένων αλγορίθμων επεξεργασίας εικόνας, με στόχο την αυτοματοποίηση μίας ιδιαίτερα χρονοβόρας και απαιτητικής διαδικασίας.

2. Σκοπός

Ο κύριος σκοπός αυτής της εργασίας είναι να αναπτύξει έναν καινοτόμο και αποδοτικό αλγόριθμο που θα μπορεί να ανιχνεύει αυτόματα φωτοβολταϊκά συστήματα μέσω της επεξεργασίας δορυφορικών εικόνων. Με αυτόν τον τρόπο, φιλοδοξεί να προσφέρει μια βιώσιμη λύση για την παρακολούθηση της εγκατάστασης και της ανάπτυξης ανανεώσιμων πηγών ενέργειας. Η συμβολή του έργου εστιάζει στην παροχή ενός εργαλείου που μπορεί να υποστηρίξει τη χάραξη στρατηγικών ενεργειακής πολιτικής, την παρακολούθηση της προόδου προς τους στόχους της βιωσιμότητας και τη διαχείριση ενεργειακών πόρων.

Οι βασικοί στόχοι που επιδιώκει η εργασία είναι οι εξής:

1. Αξιοποίηση δορυφορικών δεδομένων για τον εντοπισμό φωτοβολταϊκών συστημάτων

- Η εργασία εστιάζει στη χρήση εικόνων υψηλής ανάλυσης από δορυφόρους, οι οποίες περιέχουν πληθώρα πληροφοριών για τη γεωγραφική κατανομή και τη μορφολογία του εδάφους.
- Εξετάζονται διάφορες πηγές δορυφορικών δεδομένων, όπως εικόνες Landsat, Sentinel ή εικόνες από εμπορικούς

δορυφόρους, με σκοπό την επιλογή της κατάλληλης πηγής που θα διασφαλίσει την ακρίβεια του αλγορίθμου.

2. Προεπεξεργασία και ανάλυση δεδομένων

- Η προεπεξεργασία των δορυφορικών εικόνων είναι κρίσιμη για την απομόνωση των σχετικών χαρακτηριστικών και την ελαχιστοποίηση του θορύβου που μπορεί να παρεμβάλει στην ακρίβεια του αλγορίθμου.
- Η αναγνώριση χαρακτηριστικών, όπως χρώμα, σχήμα και υφή, τα οποία είναι μοναδικά για τα φωτοβολταϊκά πλαίσια, αποτελεί βασικό στόχο.

3. Ανάπτυξη αλγορίθμου εντοπισμού

- Η εργασία επικεντρώνεται στην εφαρμογή μεθόδων μηχανικής μάθησης, όπως η βαθιά μάθηση (Deep Learning) με τη χρήση συνελκτικών νευρωνικών δικτύων (CNNs) ή άλλων μεθόδων ταξινόμησης.
- Ο αλγόριθμος πρέπει να είναι ικανός να λειτουργεί σε διαφορετικά περιβάλλοντα (αστικές, αγροτικές ή βιομηχανικές περιοχές) και υπό διαφορετικές συνθήκες φωτισμού και καιρού.

4. Αξιολόγηση και βελτιστοποίηση απόδοσης

- Η αξιολόγηση της απόδοσης του αλγορίθμου γίνεται με βάση συγκεκριμένους δείκτες, όπως η ακρίβεια (accuracy), η ευαισθησία (sensitivity) και η εξειδίκευση (specificity).
- Εξετάζονται τρόποι βελτίωσης της ακρίβειας μέσω της ενσωμάτωσης μεγαλύτερου όγκου δεδομένων ή μέσω βελτιστοποίησης των υπαρχόντων παραμέτρων του αλγορίθμου.

5. Ανάπτυξη ενός ευέλικτου και επεκτάσιμου συστήματος

- Το σύστημα πρέπει να είναι εύκολα επεκτάσιμο για την κάλυψη διαφορετικών γεωγραφικών περιοχών και να μπορεί να χρησιμοποιηθεί σε παρεμφερείς εφαρμογές, όπως η παρακολούθηση υποδομών ή η χαρτογράφηση άλλων τύπων ανανεώσιμων πηγών ενέργειας.

Με την επίτευξη αυτών των στόχων, η εργασία επιδιώκει να προσφέρει ένα ουσιαστικό εργαλείο για την ενεργειακή βιωσιμότητα, συνδυάζοντας την επιστήμη των δεδομένων με την περιβαλλοντική διαχείριση.

3. Φωτοβολταϊκά Συστήματα

Τα φωτοβολταϊκά συστήματα αποτελούν μία από τις πιο διαδεδομένες τεχνολογίες ανανεώσιμης ενέργειας, αξιοποιώντας την ηλιακή ακτινοβολία για την παραγωγή ηλεκτρικής ενέργειας. Ανάλογα με την τεχνολογία κατασκευής τους, τα φωτοβολταϊκά πάνελ διακρίνονται σε **μονοκρυσταλλικά**, **πολυκρυσταλλικά** και **λεπτού υμενίου**, ενώ επιπλέον διαφοροποιούνται με

βάση τον τρόπο εγκατάστασης σε **σταθερά φωτοβολταϊκά και φωτοβολταϊκά με ηλιακούς ιχνηλάτες (solar trackers)**. Κάθε τύπος διαθέτει διαφορετικά χαρακτηριστικά, πλεονεκτήματα και μειονεκτήματα, καθιστώντας την επιλογή του κατάλληλου συστήματος κρίσιμη για τη βέλτιστη αξιοποίηση της ηλιακής ενέργειας.

Τύποι Φωτοβολταϊκών με Βάση την Τεχνολογία Κατασκευής

- 1. Μονοκρυσταλλικά Φωτοβολταϊκά (Monocrystalline Solar Panels)**
Τα μονοκρυσταλλικά πάνελ κατασκευάζονται από πυρίτιο υψηλής καθαρότητας, με τη δομή τους να αποτελείται από ένα ενιαίο (μονο) κρύσταλλο. Η τεχνολογία αυτή προσφέρει τη **μεγαλύτερη απόδοση**, κυμαινόμενη από **18% έως 24%**, γεγονός που επιτρέπει την παραγωγή περισσότερης ενέργειας σε μικρότερη επιφάνεια. Επιπλέον, χαρακτηρίζονται από **μεγάλη διάρκεια ζωής (25-30 έτη)** και υψηλή αντοχή σε δύσκολες περιβαλλοντικές συνθήκες. Ωστόσο, το **υψηλό κόστος παραγωγής και αγοράς** αποτελεί ένα από τα βασικά μειονεκτήματά τους.
- 2. Πολυκρυσταλλικά Φωτοβολταϊκά (Polycrystalline Solar Panels)**
Τα πολυκρυσταλλικά πάνελ κατασκευάζονται από πολλά μικρότερα κρυσταλλικά τμήματα πυριτίου, γεγονός που καθιστά τη διαδικασία παραγωγής τους οικονομικότερη. Έχουν **απόδοση μεταξύ 14% και 18%**, χαμηλότερη από τα μονοκρυσταλλικά, ενώ απαιτούν **μεγαλύτερη επιφάνεια** για την παραγωγή της ίδιας ποσότητας ενέργειας. Παρά το γεγονός ότι έχουν μικρότερο κόστος, η **λιγότερη αποδοτικότητά τους** καθιστά τα μονοκρυσταλλικά πιο ελκυστική επιλογή για περιοχές με περιορισμένο χώρο εγκατάστασης.
- 3. Φωτοβολταϊκά Λεπτού Υμενίου (Thin-Film Solar Panels)**
Τα φωτοβολταϊκά λεπτού υμενίου διαφέρουν από τα παραδοσιακά πάνελ, καθώς η φωτοβολταϊκή επίστρωση εφαρμόζεται σε λεπτές στρώσεις πάνω σε γυαλί, πλαστικό ή μέταλλο. Τα κύρια υλικά που χρησιμοποιούνται περιλαμβάνουν το **άμορφο πυρίτιο (a-Si)**, το **τελλουρίδιο του καδμίου (CdTe)** και το **δισελινιούχο χαλκό-ίνδιο-γάλλιο (CIGS)**. Το κύριο πλεονέκτημά τους είναι η **ευκαμψία και η χαμηλότερη παραγωγή κόστους**, ωστόσο, η **απόδοσή τους είναι αρκετά χαμηλή (7%-12%)**, γεγονός που τα καθιστά λιγότερο αποδοτικά από τις άλλες τεχνολογίες.
- 4. Φωτοβολταϊκά Περοβσκιτών (Perovskite Solar Cells) – Αναδυόμενη Τεχνολογία**
Τα τελευταία χρόνια, τα φωτοβολταϊκά περοβσκιτών κερδίζουν έδαφος ως μια υποσχόμενη τεχνολογία, καθώς προσφέρουν **δυναμικά υψηλή απόδοση (πάνω από 30%)**, χαμηλότερο κόστος παραγωγής και μεγαλύτερη ευελιξία στη χρήση τους. Ωστόσο, οι αντοχές τους στο χρόνο και η βιωσιμότητα της παραγωγής τους βρίσκονται ακόμη υπό έρευνα, καθώς επηρεάζονται σημαντικά από την υγρασία και τις ακραίες καιρικές συνθήκες.

Τύποι Φωτοβολταϊκών με Βάση τον Τρόπο Τοποθέτησης

1. Σταθερά Φωτοβολταϊκά (Fixed Solar Panels)

Τα σταθερά φωτοβολταϊκά είναι το πιο διαδεδομένο είδος εγκατάστασης, καθώς τοποθετούνται σε σταθερές βάσεις με προεπιλεγμένο προσανατολισμό, συνήθως προς τον νότο στο βόρειο ημισφαίριο, ώστε να μεγιστοποιηθεί η απορρόφηση της ηλιακής ακτινοβολίας. Παρόλο που αποτελούν την απλούστερη και οικονομικότερη λύση, η απόδοσή τους περιορίζεται από το γεγονός ότι δεν προσαρμόζονται στη θέση του ήλιου κατά τη διάρκεια της ημέρας.

Πλεονεκτήματα:

Χαμηλό κόστος εγκατάστασης και συντήρησης.

Απλή τεχνολογία χωρίς κινούμενα μέρη, άρα λιγότερη φθορά.

Σταθερή απόδοση χωρίς την ανάγκη συνεχούς παρακολούθησης.

Μειονεκτήματα:

Μειωμένη απόδοση σε σχέση με τα συστήματα ανίχνευσης της ηλιακής ακτινοβολίας.

Δεν αξιοποιείται πλήρως η ηλιακή ενέργεια καθ' όλη τη διάρκεια της ημέρας.

2. Φωτοβολταϊκά με Σύστημα Ανίχνευσης Ηλιακής Ακτινοβολίας (Solar Trackers)

- Τα φωτοβολταϊκά με σύστημα ανίχνευσης είναι εξοπλισμένα με μηχανισμούς που επιτρέπουν την περιστροφή των πάνελ ώστε να ακολουθούν την κίνηση του ήλιου. Υπάρχουν δύο βασικοί τύποι track συστημάτων ανίχνευσης :
- Μονοαξονικοί (Single-Axis Trackers): Τα πάνελ κινούνται γύρω από έναν οριζόντιο ή κατακόρυφο άξονα, ακολουθώντας την πορεία του ήλιου από την ανατολή προς τη δύση. Αυτά τα συστήματα αυξάνουν την απόδοση κατά 15-25% σε σχέση με τα σταθερά.

- Διπλού Άξονα (Dual-Axis Trackers): Επιτρέπουν στα πάνελ να περιστρέφονται τόσο οριζόντια όσο και κατακόρυφα, προσαρμοζόμενα πλήρως στη θέση του ήλιου κατά τη διάρκεια της ημέρας και των εποχών, επιτυγχάνοντας αύξηση της απόδοσης έως 30-40%.

Πλεονεκτήματα:

Μέγιστη δυνατή παραγωγή ενέργειας καθ' όλη τη διάρκεια της ημέρας.

Αύξηση της αποδοτικότητας χωρίς την ανάγκη εγκατάστασης περισσότερων πάνελ.

Μειονεκτήματα:

Υψηλότερο κόστος εγκατάστασης και συντήρησης.

Πολύπλοκος μηχανισμός που απαιτεί τακτική συντήρηση και πιθανές επισκευές.

Αυξημένη καταπόνηση λόγω κινούμενων μερών.

Η επιλογή του κατάλληλου τύπου φωτοβολταϊκών συστημάτων εξαρτάται από πολλούς παράγοντες, όπως η διαθεσιμότητα χώρου, οι ενεργειακές απαιτήσεις, το κλιματικό περιβάλλον και ο προϋπολογισμός της εγκατάστασης. Ενώ τα σταθερά φωτοβολταϊκά παραμένουν η πιο οικονομική και ανθεκτική λύση, τα συστήματα με σύστημα ανίχνευσης προσφέρουν αυξημένη παραγωγή ενέργειας, με μεγαλύτερο κόστος και ανάγκη για συντήρηση. Παράλληλα, η τεχνολογική πρόοδος στους τύπους φωτοβολταϊκών κυψελών, όπως τα διπλής όψης (bifacial) πάνελ και τα περοβσκιτικά ηλιακά κύτταρα, αναμένεται να αυξήσει ακόμα περισσότερο την αποδοτικότητα και τις δυνατότητες εφαρμογής της ηλιακής ενέργειας στο μέλλον.

4. Τηλεπισκόπηση και ΑΠΕ

Οι δορυφορικές εικόνες αποτελούν μια σημαντική πηγή δεδομένων για την κατανόηση και την ανάλυση της επιφάνειας της Γης. Χρησιμοποιούνται ευρέως σε διάφορους τομείς, όπως η γεωργία, η χαρτογράφηση υποδομών, η διαχείριση φυσικών πόρων, η πρόβλεψη καιρικών φαινομένων, και η παρακολούθηση περιβαλλοντικών αλλαγών. Μέσω της πολυφασματικής ανάλυσης, οι δορυφορικές εικόνες παρέχουν λεπτομερείς πληροφορίες σχετικά με τα χαρακτηριστικά των υλικών, τη βλάστηση, την υγρασία του εδάφους και άλλα φυσικά ή τεχνητά στοιχεία. Επιπλέον, η ευρεία γεωγραφική κάλυψη και η δυνατότητα συχνής λήψης δεδομένων καθιστούν τις δορυφορικές εικόνες ανεκτίμητες για την παρακολούθηση μεγάλων περιοχών και τη μελέτη δυναμικών φαινομένων. Παρότι οι προκλήσεις, όπως η επεξεργασία μεγάλου όγκου δεδομένων και οι περιβαλλοντικές επιδράσεις (π.χ., σύννεφα ή σκίαση), παραμένουν, η συνεχής εξέλιξη των τεχνολογιών τηλεπισκόπησης και ανάλυσης δεδομένων προσφέρει νέες δυνατότητες. Οι δορυφορικές εικόνες αποτελούν σήμερα μια καινοτόμο βάση για την έρευνα και την ανάπτυξη

εργαλείων που ενισχύουν τη βιώσιμη διαχείριση και τον σχεδιασμό σε παγκόσμια κλίμακα.

Ο εντοπισμός φωτοβολταϊκών συστημάτων μέσω δορυφορικών εικόνων αποτελεί μια καινοτόμο προσέγγιση που συνδυάζει τεχνολογίες αιχμής για την ανάλυση δεδομένων από το διάστημα. Στη σύγχρονη εποχή, όπου η ενεργειακή μετάβαση από συμβατικές σε ανανεώσιμες πηγές ενέργειας βρίσκεται στο επίκεντρο της παγκόσμιας ατζέντας, η παρακολούθηση και καταγραφή των εγκαταστάσεων που σχετίζονται με ανανεώσιμες πηγές, όπως τα φωτοβολταϊκά, είναι κρίσιμη. Ο ρυθμός εγκατάστασης φωτοβολταϊκών πλαισίων έχει αυξηθεί δραματικά τις τελευταίες δύο δεκαετίες, αντανακλώντας τις παγκόσμιες προσπάθειες για μείωση των εκπομπών άνθρακα και την προώθηση καθαρής ενέργειας.

Η παρακολούθηση αυτών των εγκαταστάσεων παρουσιάζει σημαντικές προκλήσεις, ιδιαίτερα σε περιοχές με μεγάλη πυκνότητα εγκαταστάσεων ή σε απομακρυσμένες τοποθεσίες. Οι παραδοσιακές μέθοδοι, που βασίζονται σε χειροκίνητη καταγραφή ή σε επίγειες έρευνες, είναι χρονοβόρες, απαιτούν μεγάλο όγκο ανθρώπινων και οικονομικών πόρων, και συχνά δεν μπορούν να παρέχουν επικαιροποιημένες πληροφορίες. Επιπλέον, οι υπάρχουσες τεχνικές που βασίζονται στη χρήση γεωγραφικών συστημάτων πληροφοριών (GIS) έχουν περιορισμένη δυνατότητα ανάλυσης σε παγκόσμια κλίμακα και δυσκολία στην αυτόματη ταυτοποίηση φωτοβολταϊκών σε περιβάλλοντα με πολύπλοκες γεωμορφολογικές δομές.

Η αξιοποίηση δορυφορικών εικόνων, σε συνδυασμό με την πρόοδο στις τεχνολογίες μηχανικής μάθησης (Machine Learning) και τεχνητής νοημοσύνης (AI), ανοίγει νέους δρόμους για την αυτοματοποιημένη και αξιόπιστη ανάλυση αυτών των δεδομένων. Οι δορυφόροι παρέχουν εικόνες υψηλής ανάλυσης, οι οποίες μπορούν να αναλυθούν με τη χρήση προηγμένων αλγορίθμων για τον εντοπισμό χαρακτηριστικών που σχετίζονται με φωτοβολταϊκά πλαίσια. Τέτοιες τεχνικές επιτρέπουν την ταχεία χαρτογράφηση μεγάλων γεωγραφικών περιοχών, παρέχοντας μια πολύτιμη πηγή δεδομένων για τη χάραξη ενεργειακών πολιτικών, την παρακολούθηση της υλοποίησης περιβαλλοντικών στόχων και τη στρατηγική ανάπτυξη νέων εγκαταστάσεων.

Η παρούσα εργασία επικεντρώνεται στην ανάπτυξη ενός αλγορίθμου που αξιοποιεί σύγχρονες τεχνικές επεξεργασίας εικόνας και μηχανικής μάθησης για τον εντοπισμό φωτοβολταϊκών πλαισίων σε δορυφορικές εικόνες. Ο στόχος είναι η δημιουργία ενός συστήματος που μπορεί να παρέχει υψηλή ακρίβεια και αποδοτικότητα, ενώ παραμένει ευέλικτο για την ανάλυση διαφορετικών περιβαλλόντων και συνθηκών.

5. Νευρωνικά Δίκτυα

Τα νευρωνικά δίκτυα είναι υπολογιστικά μοντέλα που βασίζονται στη δομή και τη λειτουργία των νευρώνων του ανθρώπινου εγκεφάλου, σχεδιασμένα ώστε να μαθαίνουν από δεδομένα. Αποτελούνται από ένα σύνολο τεχνητών νευρώνων, οι οποίοι οργανώνονται σε πολλαπλά στρώματα (εισόδου, κρυφά και εξόδου). Οι νευρώνες συνδέονται μεταξύ τους με βάρη, που καθορίζουν τη σημαντικότητα των συνδέσεων κατά τη διαδικασία της μάθησης. Η βασική ιδέα πίσω από τα νευρωνικά δίκτυα είναι η δυνατότητά τους να αναγνωρίζουν περίπλοκα πρότυπα μέσα από την επεξεργασία μεγάλου όγκου πληροφοριών.

Ιστορικά, η προέλευση των νευρωνικών δικτύων εντοπίζεται στη δεκαετία του 1940, με την πρόταση του πρώτου μοντέλου από τους Warren McCulloch και Walter Pitts το 1943, οι οποίοι πρότειναν ένα απλό μαθηματικό μοντέλο του νευρώνα. Το 1958, ο Frank Rosenblatt ανέπτυξε το perceptron, ένα μοντέλο που μπορούσε να εκπαιδευτεί και να προσαρμόζεται με βάση τα δεδομένα εισόδου. Ωστόσο, λόγω περιορισμών στις υπολογιστικές δυνατότητες της εποχής, τα νευρωνικά δίκτυα γνώρισαν μια περίοδο στασιμότητας μέχρι τη δεκαετία του 1980, όταν αναπτύχθηκε ο αλγόριθμος οπισθοδιάδοσης σφάλματος (backpropagation). Αυτός ο αλγόριθμος επέτρεψε την αποτελεσματική εκπαίδευση πολυστρωματικών νευρωνικών δικτύων. Η σημαντικότερη πρόοδος, ωστόσο, ήρθε μετά το 2010, με την άνοδο της βαθιάς μάθησης (deep learning), που βασίζεται στην ύπαρξη πολλών κρυφών στρωμάτων και επιτρέπει την ανάλυση εξαιρετικά σύνθετων δεδομένων με πολύ υψηλή ακρίβεια.

Ένας από τους πιο σημαντικούς τομείς εφαρμογής των νευρωνικών δικτύων είναι ο εντοπισμός και η αναγνώριση εικόνων (image detection). Σε αυτή την περιοχή, κυρίαρχο ρόλο έχουν τα συνελκτικά νευρωνικά δίκτυα (CNNs - Convolutional Neural Networks), που έχουν σχεδιαστεί ειδικά για την ανάλυση εικόνων. Τα CNNs χρησιμοποιούν συνελκτικές πράξεις που επιτρέπουν στο δίκτυο να εντοπίζει χαρακτηριστικά όπως σχήματα, χρώματα και υφές, κάτι που μιμείται τον τρόπο που λειτουργεί το οπτικό σύστημα του ανθρώπου. Με την εκπαίδευσή τους σε μεγάλα σύνολα εικόνων (datasets), τα CNNs είναι πλέον ικανά να αναγνωρίζουν και να εντοπίζουν αντικείμενα, πρόσωπα ή ακόμα και συναισθήματα με πολύ υψηλή ακρίβεια. Η εξέλιξη αυτή έχει φέρει σημαντικές αλλαγές σε κλάδους όπως η ιατρική διάγνωση (π.χ. ανίχνευση όγκων), η ρομποτική (π.χ. αυτόνομη πλοήγηση) και τα συστήματα ασφαλείας (π.χ. αναγνώριση προσώπων για έλεγχο πρόσβασης).

6. Βιβλιογραφική Ανασκόπηση

Στη βιβλιογραφική ανασκόπηση αυτή εξετάζεται η σημασία των φωτοβολταϊκών συστημάτων και η συμβολή της δορυφορικής τηλεπισκόπησης στην καταγραφή και ανάλυση της εγκατάστασής τους. Στη συνέχεια, παρουσιάζονται οι πιο πρόσφατες μελέτες που έχουν αξιοποιήσει τεχνικές μηχανικής μάθησης, όπως τα συνελκτικά νευρωνικά δίκτυα (CNNs), για την ταξινόμηση και την ανίχνευση φωτοβολταϊκών μέσω δορυφορικών εικόνων. Παράλληλα, αναλύονται συγκριτικά οι διαφορετικές προσεγγίσεις που έχουν εφαρμοστεί, επισημαίνοντας τις προκλήσεις που αντιμετωπίζουν οι ερευνητές, όπως η ανάγκη για υψηλής ανάλυσης δεδομένα, η αντιμετώπιση της ποικιλίας των εγκαταστάσεων και η ακρίβεια στην ταξινόμηση των δεδομένων. Επιπλέον, παρουσιάζονται οι τρέχουσες τάσεις και οι τεχνολογικές εξελίξεις στον τομέα, όπως η χρήση μοντέλων βαθιάς μάθησης (Deep Learning), η ενσωμάτωση πολυφασματικών και υπερφασματικών δεδομένων και η αξιοποίηση δεδομένων από πολλαπλές πηγές, όπως μη επανδρωμένα αεροσκάφη (UAVs) και δίκτυα αισθητήρων. Τέλος, συζητούνται οι προοπτικές και οι μελλοντικές κατευθύνσεις που θα μπορούσαν να βελτιώσουν την

αποδοτικότητα και την ακρίβεια των υπαρχόντων συστημάτων, ενισχύοντας τον ρόλο των φωτοβολταϊκών στην ενεργειακή μετάβαση και την αειφόρο ανάπτυξη.

Η βιβλιογραφική ανασκόπηση αυτή αποτελεί μια συστηματική καταγραφή της σχετικής επιστημονικής γνώσης, με στόχο τη δημιουργία μιας στέρεης βάσης για τη μεθοδολογία που θα ακολουθηθεί στην παρούσα εργασία. Μέσα από την ανάλυση των υπαρχουσών ερευνητικών προσεγγίσεων, αναδεικνύεται η σημασία της δορυφορικής τηλεπισκόπησης και των σύγχρονων τεχνικών ανάλυσης δεδομένων στη μελέτη και παρακολούθηση των φωτοβολταϊκών συστημάτων.

1. Φωτοβολταϊκά Συστήματα και Δορυφορική Τηλεπισκόπηση

Η αναγνώριση φωτοβολταϊκών εγκαταστάσεων μέσω δορυφορικών εικόνων αποτελεί σημαντικό εργαλείο για τη χαρτογράφηση των ανανεώσιμων πηγών ενέργειας, την εκτίμηση της ενεργειακής απόδοσης και τη διαμόρφωση πολιτικών βιώσιμης ανάπτυξης. Σύμφωνα με μελέτες όπως των **Chuvieco & Huete (2010)** και του **Sentinel-2 User Handbook (ESA)**, η χρήση πολυφασματικών δορυφορικών δεδομένων παρέχει αξιόπιστα αποτελέσματα για την ανάλυση γεωχωρικών χαρακτηριστικών, καθώς τα φωτοβολταϊκά πάνελ έχουν ιδιαίτερη φασματική απόκριση στο υπέρυθρο και στο ορατό φως. Οι δορυφορικές εικόνες υψηλής ανάλυσης, όπως αυτές από τους δορυφόρους **Sentinel-2, Landsat-8 και εμπορικούς δορυφόρους όπως το Maxar και το PlanetScope**, παρέχουν πολύτιμα δεδομένα για την αναγνώριση των φωτοβολταϊκών συστημάτων. Μέσω της εφαρμογής τεχνικών ανάλυσης εικόνας και μηχανικής μάθησης, η αναγνώριση φωτοβολταϊκών μπορεί να πραγματοποιηθεί με μεγάλη ακρίβεια, εντοπίζοντας τα γεωμετρικά και φασματικά χαρακτηριστικά των ηλιακών πλαισίων.

2. Εφαρμογή Νευρωνικών Δικτύων και Μηχανικής Μάθησης στην Αναγνώριση Φωτοβολταϊκών

Η αναγνώριση φωτοβολταϊκών εγκαταστάσεων μέσω τηλεπισκόπησης έχει ενισχυθεί σημαντικά από την πρόοδο των αλγορίθμων βαθιάς μάθησης (Deep Learning) και ειδικότερα των συνελικτικών νευρωνικών δικτύων (CNNs).

Μελέτες όπως αυτή των **Ronneberger et al. (2015)** περιγράφουν τη χρήση του **U-Net**, ενός νευρωνικού δικτύου για την ανάλυση εικόνας και την αναγνώριση αντικειμένων σε δορυφορικές λήψεις.

Η χρήση αρχιτεκτονικών όπως το **MobileNetV2 (Sandler et al., 2018)** έχει αποδειχθεί ιδιαίτερα αποτελεσματική για την ταξινόμηση και την αναγνώριση φωτοβολταϊκών εγκαταστάσεων λόγω της χαμηλής υπολογιστικής απαίτησης και της υψηλής ακρίβειας που προσφέρει. Σε συνδυασμό με τεχνικές προεπεξεργασίας δεδομένων, όπως η εξισορρόπηση του χρώματος, η εξαγωγή φασματικών δεικτών και η βελτίωση αντίθεσης, η ακρίβεια της αναγνώρισης μπορεί να αυξηθεί σημαντικά.

Επιπλέον, τεχνικές όπως ο **συντελεστής Dice (Dice Coefficient)**, που αναφέρεται από τους **Sudre et al. (2017)**, και οι συνάρτησεις βελτιστοποίησης όπως η **Dice Loss**, επιτρέπουν την καλύτερη απόδοση των μοντέλων στην ταξινόμηση και την οριοθέτηση των φωτοβολταϊκών εγκαταστάσεων.

3. Σύγκριση Μεθόδων και Αποτελεσματικότητα Αλγορίθμων

Η αποδοτικότητα των νευρωνικών δικτύων στη συγκεκριμένη εφαρμογή έχει συγκριθεί με παραδοσιακές τεχνικές αναγνώρισης εικόνων, όπως οι Random Forests, οι Support Vector Machines (SVMs) και οι μέθοδοι thresholding σε πολυφασματικά δεδομένα (**Chuvieco & Huete, 2010**). Οι μέθοδοι βαθιάς μάθησης, αν και απαιτούν μεγάλο όγκο δεδομένων για εκπαίδευση, υπερτερούν λόγω της ικανότητάς τους να μαθαίνουν πολυπλοκότερες δομές στις εικόνες και να προσαρμόζονται καλύτερα σε διαφορετικές συνθήκες φωτισμού και περιβάλλοντος.

Οι πιο πρόσφατες μελέτες, όπως αυτή των **Milletari et al. (2016)**, προτείνουν τη χρήση δικτύων όπως το **V-Net**, το οποίο είναι βελτιστοποιημένο για τη σημασιολογική τμηματοποίηση εικόνων και μπορεί να εφαρμοστεί σε πολύπλοκα δεδομένα, όπως οι δορυφορικές εικόνες. Η τεχνική του **Early Stopping**, που περιγράφεται από τους **Prechelt (1998)** και **Patil et al. (2018)**, έχει χρησιμοποιηθεί επίσης για τη βελτίωση της γενίκευσης των μοντέλων και την αποφυγή υπερπροσαρμογής (overfitting).

4. Προκλήσεις και Μελλοντικές Προοπτικές

Παρότι η τεχνολογία αναγνώρισης φωτοβολταϊκών μέσω δορυφορικών εικόνων έχει παρουσιάσει σημαντική πρόοδο, εξακολουθούν να υπάρχουν προκλήσεις που πρέπει να αντιμετωπιστούν. Η παρουσία αντικειμένων με παρόμοια φασματικά χαρακτηριστικά, όπως ορισμένες στέγες ή μεταλλικές κατασκευές, μπορεί να προκαλέσει ψευδώς θετικά αποτελέσματα. Επιπλέον, η διαφοροποίηση της ανάλυσης εικόνας ανάλογα με την περιοχή (αστικά, αγροτικά ή βιομηχανικά περιβάλλοντα) απαιτεί εξειδικευμένα μοντέλα που λαμβάνουν υπόψη τη γεωγραφική ποικιλομορφία.

Η ενσωμάτωση **διπλής όψης φωτοβολταϊκών (bifacial solar panels)** και η χρήση δεδομένων από **πηητικά μέσα (UAVs - drones)** μπορεί να ενισχύσει περαιτέρω την ακρίβεια και τη λεπτομέρεια της χαρτογράφησης. Επιπλέον, οι εξελίξεις στα **περοβσκιτικά φωτοβολταϊκά (Perovskite Solar Cells)** αναμένεται να αλλάξουν τη γεωγραφική κατανομή των εγκαταστάσεων, δημιουργώντας την ανάγκη για νέα προσαρμοσμένα μοντέλα αναγνώρισης. Τέλος, οι εξελίξεις στη **συγχώνευση δεδομένων από πολλαπλές πηγές**, όπως τα γεωγραφικά συστήματα πληροφοριών (GIS), οι μετεωρολογικοί σταθμοί και οι αισθητήρες IoT, αναμένεται να προσφέρουν πιο ακριβείς εκτιμήσεις για την παραγωγή και την απόδοση των φωτοβολταϊκών συστημάτων.

5. Συμπέρασμα

Η επιστημονική κοινότητα έχει σημειώσει σημαντική πρόοδο στην αναγνώριση φωτοβολταϊκών εγκαταστάσεων μέσω δορυφορικών εικόνων και τεχνητής νοημοσύνης. Οι πιο σύγχρονες μεθοδολογίες, όπως η χρήση βαθιών νευρωνικών δικτύων και πολυφασματικών δορυφορικών δεδομένων, έχουν βελτιώσει σημαντικά την ακρίβεια και την αποδοτικότητα των αλγορίθμων. Ωστόσο, παραμένουν προκλήσεις που σχετίζονται με την ποιότητα των δεδομένων, τις γεωγραφικές διαφορές και τη διαχείριση μεγάλων όγκων εικόνων. Η περαιτέρω ανάπτυξη νέων τεχνολογιών και η συνδυασμένη χρήση πολλαπλών πηγών δεδομένων αναμένεται να ενισχύσουν τη δυνατότητα αυτοματοποιημένης χαρτογράφησης φωτοβολταϊκών εγκαταστάσεων, συμβάλλοντας στη βιώσιμη ενεργειακή διαχείριση και την ανάπτυξη των ανανεώσιμων πηγών ενέργειας.

7. Δεδομένα

Τα δεδομένα που χρησιμοποιήσαμε είναι δορυφορικές εικόνες που απεικονίζουν ηλιακά πάνελ και εικόνων που λειτουργούν ως μάσκα για την οριοθέτηση αυτών. Αυτές οι φωτογραφίες θα χρησιμοποιηθούν στην συνέχεια ως εισροές για την εκπαίδευση του μοντέλου που θα χρησιμοποιήσουμε για την ανίχνευση των πάνελ στην κάθε εικόνα. Τα δεδομένα μας ήταν διαθέσιμα στο διαδίκτυο δωρεάν. Πρόκειται για αρχεία τύπου bmp διαστάσεων 1024X1024 και τα οποία υπάρχουν διαθέσιμα στο <https://zenodo.org/records/5171712> . Τα δεδομένα μας αποτελούνται από έξι κατηγορίες πάνελ χωρισμένα σε έξι φακέλους με το όνομα της κάθε κατηγορίας. Οι κατηγορίες είναι οι εξής:

- Φωτοβολταϊκά πάνελ σε καλλιεργήσιμη γη.
- Φωτοβολταϊκά πάνελ σε στέγη
- Φωτοβολταϊκά πάνελ σε γρασίδι
- Φωτοβολταϊκά πάνελ σε αλατούχο αλκαλικό έδαφος
- Φωτοβολταϊκά πάνελ σε θαμνώδες έδαφος
- Φωτοβολταϊκά πάνελ σε επιφάνια με νερό

Ο κάθε φάκελος περιέχει τις δορυφορικές φωτογραφίες και τις φωτογραφίες με τις μάσκες. Για κάθε εικόνα υπάρχει η αντίστοιχη φωτογραφία με την μάσκα με το ίδιο όνομα και την λέξη 'label' στο τέλος. Για την σωστή εκπαίδευση του μοντέλου μας έτσι ώστε να γίνει περισσότερο αποτελεσματικό στον εντοπισμό αντικειμένων είναι πολύ σημαντικό να υπάρχει αρκετή ποικιλομορφία στις εικόνες έτσι ώστε να μπορεί να εντοπιστεί το αντικείμενο σε όσο το δυνατό περισσότερες και διαφορετικές περιπτώσεις.

8. Εισαγωγή και Διαμόρφωση Δεδομένων

Αρχικά έγινε εισαγωγή των δεδομένων στο google drive ώστε να υπάρχει εύκολη πρόσβαση μέσω του colab που είναι το πρόγραμμα στο οποίο έγινε αρχικά ο αλγόριθμος του μοντέλου. Στη συνέχεια δημιουργούμε δυο συναρτήσεις μια για την προετοιμασία του πίνακα δεδομένων μας (Κώδικας: 1)

και μια για την προβολή των εικόνων των δεδομένων μας (Κώδικας: 2). Η συνάρτηση 1(Κώδικας: 1) `prepare_dataframe` δημιουργεί έναν DataFrame από εικόνες που βρίσκονται σε έναν φάκελο. Διατρέχει όλους τους υποφακέλους χρησιμοποιώντας την `os.walk`, συλλέγοντας τις πλήρεις διαδρομές των αρχείων και εξάγοντας μοναδικά αναγνωριστικά (`solar_ids`) από τα ονόματά τους. Αυτά αποθηκεύονται σε δύο λίστες, οι οποίες στη συνέχεια συνδυάζονται σε ένα λεξικό όπου οι ταυτότητες (`solar_ids`) είναι τα κλειδιά και οι διαδρομές οι τιμές. Το λεξικό μετατρέπεται σε DataFrame, με το `solar_id` ως δείκτη, και επιστρέφεται

για οργανωμένη διαχείριση και ανάλυση των εικόνων. Η συνάρτηση 2 (Κώδικας: 2) `display` εμφανίζει μια λίστα από εικόνες σε μορφή διαγράμματος χρησιμοποιώντας τη βιβλιοθήκη `Matplotlib`. Δημιουργεί μια μεγάλη γραφική παράσταση (15x15 ίντσες) και προσθέτει σε αυτήν τις εικόνες από τη λίστα `display_list`. Οι τίτλοι κάθε εικόνας είναι προ-καθορισμένοι ως `Input Image`, `True Mask`, και `Predicted Mask`. Για κάθε εικόνα στη λίστα, δημιουργεί ένα υπο-διάγραμμα, ορίζει τον τίτλο, μετατρέπει το πίνακα της εικόνας σε μορφή συμβατή για εμφάνιση, και απενεργοποιεί τους άξονες. Τέλος, εμφανίζει όλες τις εικόνες ταυτόχρονα.

Για τις ανάγκες του μοντέλου έπρεπε να γίνει μια προ επεξεργασία των εικόνων. Δημιουργήθηκε μια λίστα με τις διευθύνσεις όλων των αρχείων έτσι ώστε να γίνει ένας επαναδιαστασιοποίηση στο μέγεθος τους σε μέγεθος (256 X 256) και η μετατροπή τους σε `rgb` αρχεία. Ουσιαστικά η εισαγωγή των δεδομένων προκύπτει από την δημιουργία μιας λίστας με τις διευθύνσεις των ζευγών εικόνας και μάσκας και την προσπέλαση αυτής (Κώδικας: 3).

9. Δίκτυα U-Net

Το τύπος νευρωνικού δικτιού που χρησιμοποιήθηκε για αυτή την εργασία είναι το U-Net. Το U-Net είναι είδος αρχιτεκτονικής νευρωνικών δικτύων που αναπτύχθηκε αρχικά για την αυτόματη σημασιολογική τμηματοποίηση των εικόνων, κυρίως στον τομέα της ιατρικής εικόνας. Η αρχιτεκτονική U-Net δημιουργήθηκε από τους `Olaf Ronneberger`, `Philipp Fischer` και `Thomas Brox` και δημοσιεύτηκε το 2015. Το όνομά της προέρχεται από το γεγονός ότι η αρχιτεκτονική του μοντέλου έχει μια μορφή που μοιάζει με το γράμμα "U".

Η κύρια ιδέα πίσω από το U-Net είναι η χρήση μιας εντελώς συνελικτικής νευρωνικής αρχιτεκτονικής που είναι σε θέση να λαμβάνει ως είσοδο μια εικόνα και να παράγει μια εικόνα του ίδιου μεγέθους ως έξοδο. Το U-Net αποτελείται από δύο κύρια τμήματα:

Τους κωδικοποιητές (Encoders): Αυτά τα τμήματα αποτελούνται από συνελικτικά επίπεδα που χρησιμοποιούνται για την εξαγωγή χαρακτηριστικών από την είσοδο. Καθένας από αυτούς τους οδηγούς συνελίσεων συνοδεύεται από επίπεδα υποδειγματοληψίας (`downsampling`) που μειώνουν τις διαστάσεις των εξόδων τους.

Και τους Αναστολείς (Decoders): Αυτά τα τμήματα αποτελούνται από επίπεδα αποσυμπίεσης (`upsampling`) που αυξάνουν τις διαστάσεις των εξόδων και τα συνελικτικά επίπεδα που χρησιμοποιούνται για την σύνθεση πληροφορίας από τους οδηγούς και την παραγωγή της τελικής εικόνας εξόδου.

Το κύριο χαρακτηριστικό του U-Net είναι η χρήση συνδέσμων συνόλων από χαρακτηριστικά μεταξύ των οδηγών και των αναστολέων. Αυτοί οι σύνδεσμοι επιτρέπουν στο μοντέλο να έχει πρόσβαση σε πληροφορίες των

χαρακτηριστικών σε διαφορετικά επίπεδα και να διατηρεί την πληροφορία για την τελική πρόβλεψη.

Το U-Net έχει ευρύ φάσμα εφαρμογών σε πεδία όπως η ιατρική εικόνα, η επεξεργασία φυσικής εικόνας, η ανίχνευση αντικειμένων και πολλά άλλα. Η απλότητά του και η ικανότητά του να λειτουργεί αποτελεσματικά με μικρές ποσότητες δεδομένων καθιστούν το U-Net ένα από τα πιο δημοφιλή μοντέλα για αυτόματη επεξεργασία εικόνων.

10. Νευρωνικό Δίκτυο – Αλγόριθμος

Για την δημιουργία του νευρωνικού έχει ως στόχο την ευκολία χρήσης, την ευελιξία και την ταχύτητα. Οι χρήστες μπορούν να δημιουργήσουν διάφορα είδη νευρωνικών δικτύων, όπως πολυεπίπεδα νευρωνικά δίκτυα (MLPs), αναδρομικά νευρωνικά δίκτυα (RNNs), συνελκτικά νευρωνικά δίκτυα (CNNs) και πολλά άλλα, χρησιμοποιώντας μια απλή και ευανάγνωστη σύνταξη.

Το Keras είναι μία βιβλιοθήκη λογισμικού για την κατασκευή και εκπαίδευση τεχνητών νευρωνικών δικτύων, η οποία είναι ενσωματωμένη στο περιβάλλον του TensorFlow. Παρέχει ένα φιλικό και ευέλικτο περιβάλλον ανάπτυξης μοντέλων μηχανικής μάθησης, επιτρέποντας στον χρήστη να δημιουργεί πολύπλοκες αρχιτεκτονικές με απλό και κατανοητό τρόπο. Μέσω του Keras, μπορούν να υλοποιηθούν διάφοροι τύποι νευρωνικών δικτύων, όπως πολυεπίπεδα, συνελκτικά και αναδρομικά, καθώς και πιο εξειδικευμένα όπως το U-Net. Η βιβλιοθήκη αυτή είναι ιδανική για εκπαιδευτικούς, ερευνητές και επαγγελματίες, καθώς υποστηρίζει προσαρμοσμένες συναρτήσεις και μοντέλα, ενώ παράλληλα διαθέτει εκτενή τεκμηρίωση και μεγάλη κοινότητα υποστήριξης. Στην παρούσα εργασία, το Keras χρησιμοποιήθηκε για την ανάπτυξη και εκπαίδευση του αλγορίθμου αναγνώρισης φωτοβολταϊκών εγκαταστάσεων.

Το Keras μπορεί να λειτουργήσει πάνω από διάφορα υποβάθρα, συμπεριλαμβανομένων των TensorFlow, Theano και Microsoft Cognitive Toolkit (CNTK), που το καθιστά ευέλικτο για χρήστες που εργάζονται σε διάφορα περιβάλλοντα. Το TensorFlow 2.0 κατασκευάστηκε επίσης με το Keras ως προεπιλεγμένο API για τη δημιουργία και εκπαίδευση μοντέλων, κάνοντας το Keras ακόμα πιο ολοκληρωμένο στην οικοσύστημα του TensorFlow.

Οι λόγοι για τους οποίους θα μπορούσε κάποιος να χρησιμοποιήσει το Keras για την ανίχνευση εικόνων:

1. ****Ευκολία χρήσης:**** Το Keras προσφέρει μια απλή και ευανάγνωστη σύνταξη, καθιστώντας το ιδανικό για αρχάριους και προχωρημένους χρήστες. Αυτό μπορεί να βοηθήσει στην επιτάχυνση της διαδικασίας ανάπτυξης μοντέλων.

2. ****Ευελιξία:**** Το Keras επιτρέπει την εύκολη δημιουργία και προσαρμογή των νευρωνικών δικτύων σας. Μπορείτε να δημιουργήσετε διάφορα είδη μοντέλων, από απλά πολυεπίπεδα νευρωνικά δίκτυα (MLPs) έως πιο πολύπλοκες αρχιτεκτονικές όπως συνελκτικά νευρωνικά δίκτυα (CNNs) και αναδρομικά νευρωνικά δίκτυα (RNNs), καθώς και δίκτυα τύπου (U-Net) που είναι και ο τύπος που χρησιμοποιήσαμε.

3. ****Συμβατότητα:**** Το Keras έχει ενσωματωθεί στο TensorFlow ως το προεπιλεγμένο του API, προσφέροντας έτσι μια ολοκληρωμένη εμπειρία ανάπτυξης μοντέλων εντός της του TensorFlow.

4. ****Εκτεταμένη κοινότητα:**** Το Keras έχει μια μεγάλη και ενεργή κοινότητα χρηστών, η οποία προσφέρει υποστήριξη, πόρους και εργαλεία για την ανάπτυξη και την επίλυση προβλημάτων.

Συνολικά, το Keras είναι μια ισχυρή επιλογή για την ανίχνευση εικόνων λόγω της ευκολίας χρήσης, της ευελιξίας και της ολοκληρωμένης υποστήριξης που προσφέρει.

Στο πλαίσιο των νευρωνικών δικτύων, ο όρος "εποχές" αναφέρεται στην προπαίδευση ενός μοντέλου με ένα σύνολο δεδομένων. Κάθε εποχή αντιπροσωπεύει ένα πλήρες πέρασμα από όλα τα δεδομένα εκπαίδευσης μέσα από το μοντέλο. Κατά τη διάρκεια μιας εποχής, τα δεδομένα διαιρούνται σε μικρότερα τμήματα που ονομάζονται παρτίδες ή δέσμες, και το μοντέλο εκπαιδεύεται με κάθε ένα από αυτά τα τμήματα. Μετά από κάθε εποχή, το μοντέλο αξιολογείται συνήθως σε ένα σύνολο ελέγχου για να εκτιμηθεί η απόδοσή του. Η εκπαίδευση συνήθως συνεχίζεται μέχρις ότου ο αριθμός των εποχών που έχουν προκαθοριστεί φτάσει ή μέχρις ότου η απόδοση του μοντέλου στα δεδομένα ελέγχου σταματήσει να βελτιώνεται.

11. Διαδικασία Ταξινόμησης

Το κύριο μέρος του αλγορίθμου περιλαμβάνει ουσιαστικά την Διαδικασία της ταξινόμησης που πραγματοποιεί το νευρωνικό δίκτυο έτσι ώστε να γίνει η εκπαίδευση και η δημιουργία του μοντέλου.

Αρχικά κάναμε διαχωρισμό των δεδομένων μας σε δεδομένα εκπαίδευσης και επικύρωσης (Κώδικας: 4). Όστε να χρησιμοποιήσουμε τα δεδομένα της εκπαίδευσης για την δημιουργία του μοντέλου και τις επικύρωσης για να δούμε κατά πόσο λειτουργεί και σε ποιο βαθμό. Για την ταξινόμηση χρησιμοποιήσαμε την μέθοδο διαχωρισμού σε υποσύνολα δεδομένων (batches).

Στη συνέχεια φορτώνουμε ένα προ εκπαιδευμένο μοντέλο MobileNetV2. Το `input_shape=[256, 256, 3]` καθορίζει το σχήμα των εικόνων που αναμένει αυτό το μοντέλο (256x256 pixels με 3 κανάλια χρώματος για RGB). Το `include_top=False` σημαίνει ότι οι πλήρως συνδεδεμένοι επίπεδοι στην κορυφή

του δικτύου, που είναι υπεύθυνοι για την ταξινόμηση, δεν περιλαμβάνονται. Αυτό συμβαίνει επειδή θέλουμε να χρησιμοποιήσουμε τα χαρακτηριστικά που εξάγονται από τα συνελκτικά επίπεδα αντί να πραγματοποιήσουμε ταξινόμηση. Ορίζουμε μια λίστα με ονόματα επιπέδων που μας ενδιαφέρουν. Αυτά τα επίπεδα επιλέγονται με βάση το βάθος τους στο δίκτυο και τις χωρικές τους αναλύσεις (64x64, 32x32, κλπ.). Στη συνέχεια, χρησιμοποιώντας συμπύεση λίστας, εξάγονται οι έξοδοι αυτών των συγκεκριμένων επιπέδων από το `base_model` χρησιμοποιώντας τη συνάρτηση `get_layer()`. Δημιουργείται ένα νέο μοντέλο Keras με όνομα `down_stack`, το οποίο παίρνει την είσοδο από το αρχικό μοντέλο `MobileNetV2` (`base_model.input`) και εξάγει τα χαρακτηριστικά που εξάγονται από τα επίπεδα που καθορίστηκαν στο `base_model_outputs`. Με τον καθορισμό του `trainable=False`, βεβαιωνόμαστε ότι τα βάρη των επιπέδων στο `down_stack` παραμένουν σταθερά κατά τη διάρκεια της εκπαίδευσης. (Κώδικας: 5)

Αφού ολοκληρωθεί προηγούμενη διαδικασία, δημηγορούμε μια συνάρτηση για την αντίστροφη διαδικασία, να μετατρέπει από μικρότερη ανάλυση την εικόνα σε μεγαλύτερη (Κώδικας: 6). Αυτή η διαδικασία χρησιμοποιείται σε αρχιτεκτονικές δικτύων αναγνώρισης εικόνας (U-Net).

Αυτός ο μηχανισμός είναι σημαντικός σε αλγόριθμους εντοπισμού αντικειμένων όπου πρέπει να γίνει αντίστροφη διαδικασία από τις χαμηλότερες σε υψηλότερες επιπέδων ανάλυσης εικόνας.

Για την διαδικασία επιλογής του μοντέλου εκπαίδευσης επιλέξαμε τη δημιουργία ενός μοντέλου U-Net για αναγνώριση εικόνων (Κώδικας: 7). Ο U-Net είναι ένα είδος αρχιτεκτονικής δικτύου που είναι ευρέως χρησιμοποιούμενο σε εφαρμογές επεξεργασίας εικόνας και εντοπισμού αντικειμένων.

Στη συνέχεια πρέπει να υπολογίσουμε έτσι ώστε να συμπεριλάβουμε τις μετρικές συναρτήσεις και τις συναρτήσεις των απωλειών έτσι ώστε να τις συμπεριλάβουμε στο μοντέλο. Αρχικά υπολογίσαμε τη συνάρτηση `dice_coef` (Dice Coefficient) αυτή η συνάρτηση υπολογίζει το συντελεστή Dice (Dice Coefficient) (Κώδικας: 8), ο οποίος είναι ένα μέτρο ομοιότητας μεταξύ δύο δυαδικών δειγμάτων, συνήθως χρησιμοποιούμενο σε προβλήματα σημασιολογικής εντοπισμού εικόνας. Η συνάρτηση δέχεται ως είσοδο τις πραγματικές ετικέτες `y_true` και τις προβλεπόμενες ετικέτες `y_pred`. Αυτός ο υπολογισμός έγινε ακολουθώντας τα παρακάτω βήματα:

- Υπολογισμός του αριθμού των ψηφιδών που ταυτίζονται σε κάθε εικόνα, πολλαπλασιάζοντας τα δύο σύνολα `y_true` και `y_pred`, και στη συνέχεια προσθέτοντας τα αποτελέσματα κατά μήκος των διαστάσεων των αξόνων 1, 2 και 3 (δηλαδή τους άξονες χρώου).
- Υπολογισμός του αριθμού των pixels που ανήκουν σε οποιοδήποτε από τα δύο δείγματα, προσθέτοντας τα `y_true` και `y_pred`.
- Υπολογισμός του δείκτη ομοιότητας Dice χρησιμοποιώντας τις παραπάνω τιμές και εφαρμόζοντας τον αντίστοιχο τύπο.
- Επιστροφή του μέσου όρου του δείκτη ομοιότητας Dice μεταξύ όλων των δειγμάτων (δηλαδή, για όλα τα pixels).

Επίσης υπολογίσαμε τη συνάρτηση `dice_loss` (Dice Loss). Αυτή η συνάρτηση υπολογίζει την τιμή απώλειας με βάση τον συντελεστή Dice (Κώδικας: 8). Η απώλεια υπολογίζεται από τη διαφορά της τιμής 1 και του συντελεστή Dice. Είναι συνήθως χρήσιμη ως συνάρτηση βελτιστοποίησης κατά την εκπαίδευση του μοντέλου, καθώς προσπαθούμε να μεγιστοποιήσουμε την ομοιότητα μεταξύ των πραγματικών και προβλεπόμενων ετικετών. Αυτή η διαδικασία γίνεται για να συμπεριλάβουμε τις συναρτήσεις αυτές στο μοντέλο. Έτσι ορίζουμε το μοντέλο U-Net με ένα κανάλι εξόδου (λόγω της παραμέτρου `output_channels`). Η συνάρτηση απώλειας ορίζεται ως `dice_loss`, ενώ οι μετρικές που θα παρακολουθηθούν κατά τη διάρκεια της εκπαίδευσης είναι ο `dice_coef` και η `binary_accuracy`.

Η μέθοδος `summary()` υπολογίζουμε μέσω της βιβλιοθήκης TensorFlow Keras και εμφανίζουμε μια σύνοψη της αρχιτεκτονικής του μοντέλου, περιλαμβανομένων του συνολικού αριθμού των παραμέτρων που πρέπει να εκπαιδευτούν και των εξόδων σε κάθε επίπεδο (Εικόνα 2).

Στο τελευταίο στάδιο της διαδικασίας της εκπαίδευσης αφού έχουμε θέσει όλες τις παραμέτρους μας και ορίσει όλες τις συναρτήσεις μας εκτελούμε την εκπαίδευση του μοντέλου μας. Η `custom callback` χρησιμοποιείται για να παρακολουθήσει την πρόοδο της εκπαίδευσης κάθε 5 εποχές. Συγκεκριμένα, καλεί τη συνάρτηση `show_predictions`, η οποία οπτικοποιεί μια πρόβλεψη του μοντέλου σε ένα δείγμα εικόνων από το σύνολο εκπαίδευσης. Αυτό μας επιτρέπει να δούμε πώς βελτιώνεται η πρόβλεψη κατά τη διάρκεια της εκπαίδευσης. Τέλος, το μοντέλο εκπαιδεύεται με τη χρήση των `callbacks` που ορίστηκαν, χρησιμοποιώντας τη μέθοδο `fit()`. Τα δεδομένα εκπαίδευσης παρέχονται από το `train_dataset`, τα δεδομένα επικύρωσης από το `valid_dataset`, και οι εκπαιδευτικοί παράμετροι ορίζονται όπως η παρτίδα (`batch_size`) και ο αριθμός των εποχών (EPOCHS). Η `EarlyStopping callback` διακόπτει τη διαδικασία εκπαίδευσης αν δεν υπάρχει βελτίωση στην απόδοση του μοντέλου για έναν συγκεκριμένο αριθμό εποχών (Κώδικας: 9).

Στο πλαίσιο των νευρωνικών δικτύων, ο όρος "εποχές" αναφέρεται στην προπαίδευση ενός μοντέλου με ένα σύνολο δεδομένων. Κάθε εποχή αντιπροσωπεύει ένα πλήρες πέρασμα από όλα τα δεδομένα εκπαίδευσης μέσα από το μοντέλο. Κατά τη διάρκεια μιας εποχής, τα δεδομένα διαιρούνται σε μικρότερα τμήματα που ονομάζονται παρτίδες ή δέσμες, και το μοντέλο εκπαιδεύεται με κάθε ένα από αυτά τα τμήματα. Μετά από κάθε εποχή, το μοντέλο αξιολογείται συνήθως σε ένα σύνολο ελέγχου για να εκτιμηθεί η απόδοσή του. Η εκπαίδευση συνήθως συνεχίζεται μέχρις ότου ο αριθμός των εποχών που έχουν προκαθοριστεί φτάσει ή μέχρις ότου η απόδοση του μοντέλου στα δεδομένα ελέγχου σταματήσει να βελτιώνεται.

Αφού ολοκληρωθεί η διαδικασία της εκπαίδευσης πλέον μπορούμε να χρησιμοποιήσουμε το μοντέλο μας για την ανίχνευση των πάνελ στις εικόνες. Για αυτό και δημιουργήσαμε ένα κομμάτι κώδικα που ουσιαστικά χρησιμοποιεί το μοντέλο για να εντοπίσει τα πάνελ και να τα οριοθετήσει με ένα πλαίσιο (Κώδικας: 10).

12. Αποτελέσματα

Μετά την ολοκλήρωση της εκπαίδευσης το μοντέλο γίνεται αποθήκευση τοπικά ώστε να μπορεί να επαναχρησιμοποιηθεί για μελλοντική χρήση. Τα αποτελέσματα των εικόνων από τη δημιουργία του μοντέλου είναι σε μορφή εικόνας jpeg. Με την χρήση των δορυφορικών εικόνων και των εικόνων με την μάσκα γίνεται η οριοθέτηση της περιοχής των πάνελ. Η εικόνα με την μάσκα σε συνδυασμό με τη δορυφορική εικόνα και την χρήση του νευρωνικού δικτύου μας δημιουργία μια νέας εικόνας στην οποία τα ηλιακά πάνελ είναι οριοθετημένα με κίτρινο χρώμα. Κατά την διάρκεια της διαδικασίας της εκπαίδευσης όπως παρατηρούμε από τις εκτυπώσεις του αλγορίθμου ότι όσο προχωράει η διαδικασία οι εικόνες γίνονται πιο ευκρινής και η αναγνώριση πιο αποτελεσματική (Εικόνα 3, 4). Σε όλη την διάρκεια της εκπαίδευσης γίνεται εκτύπωση των εικόνων (δορυφορική εικόνα, εικόνα μάσκας και πρόβλεψη). Έτσι έχουμε και οπτική απεικόνιση των εικόνων σε όλα τα στάδια.

Όπως φαίνεται και στα στατιστικά του μοντέλου, η ακρίβεια της πρόβλεψης μετά από κάθε εποχή του μοντέλου κυμαίνεται μεταξύ 0.9 και 0.94. Η ακρίβεια της πρόβλεψης του μοντέλου είναι αρκετά καλή και η μόνη αστοχία που μπορούμε να προσέξουμε στις εικόνες με την πρόβλεψη είναι ότι υπάρχουν ιδικά στις πρώτες εποχές του μοντέλου κάποιες κηλίδες που αποτελούν σφάλμα. Οι κηλίδες αυτές μονώνετε όσο το μοντέλο προχωράει η κηλίδες εξαλείφονται.

Epoch 1/30

20/20 [=====] - 217s 11s/step - loss: 0.5344 - dice_coef: 0.4656 - binary_accuracy: 0.6183 - val_loss: 0.3260 - val_dice_coef: 0.6709 - val_binary_accuracy: 0.8677

Epoch 2/30

20/20 [=====] - 204s 11s/step - loss: 0.2910 - dice_coef: 0.6914 - binary_accuracy: 0.9355 - val_loss: 0.2810 - val_dice_coef: 0.7169 - val_binary_accuracy: 0.8676

Epoch 3/30

20/20 [=====] - 202s 10s/step - loss: 0.2202 - dice_coef: 0.7765 - binary_accuracy: 0.9405 - val_loss: 0.2064 - val_dice_coef: 0.7931 - val_binary_accuracy: 0.9074

Epoch 4/30

20/20 [=====] - 202s 10s/step - loss: 0.1822 - dice_coef: 0.8082 - binary_accuracy: 0.9480 - val_loss: 0.1736 - val_dice_coef: 0.8269 - val_binary_accuracy: 0.9226

1/1 [=====] - 0s 161ms/step

Epoch 5/30

20/20 [=====] - 189s 9s/step - loss: 0.1663 - dice_coef: 0.8375 - binary_accuracy: 0.9514 - val_loss: 0.1758 - val_dice_coef: 0.8246 - val_binary_accuracy: 0.9177

Epoch 6/30

20/20 [=====] - 203s 10s/step - loss: 0.1565 -
dice_coef: 0.8445 - binary_accuracy: 0.9532 - val_loss: 0.1370 - val_dice_coef:
0.8637 - val_binary_accuracy: 0.9452

Epoch 7/30

20/20 [=====] - 201s 10s/step - loss: 0.1530 -
dice_coef: 0.8501 - binary_accuracy: 0.9515 - val_loss: 0.1378 - val_dice_coef:
0.8626 - val_binary_accuracy: 0.9457

Epoch 8/30

20/20 [=====] - 203s 10s/step - loss: 0.1429 -
dice_coef: 0.8489 - binary_accuracy: 0.9498 - val_loss: 0.1331 - val_dice_coef:
0.8673 - val_binary_accuracy: 0.9494

Epoch 9/30

20/20 [=====] - 203s 10s/step - loss: 0.1486 -
dice_coef: 0.8203 - binary_accuracy: 0.9573 - val_loss: 0.1469 - val_dice_coef:
0.8537 - val_binary_accuracy: 0.9446

1/1 [=====] - 0s 151ms/step

Epoch 10/30

20/20 [=====] - 203s 10s/step - loss: 0.1489 -
dice_coef: 0.8529 - binary_accuracy: 0.9510 - val_loss: 0.1338 - val_dice_coef:
0.8669 - val_binary_accuracy: 0.9477

Epoch 11/30

20/20 [=====] - 191s 10s/step - loss: 0.1231 -
dice_coef: 0.8429 - binary_accuracy: 0.9557 - val_loss: 0.1673 - val_dice_coef:
0.8332 - val_binary_accuracy: 0.9306

Epoch 12/30

20/20 [=====] - 204s 10s/step - loss: 0.1277 -
dice_coef: 0.8729 - binary_accuracy: 0.9571 - val_loss: 0.1368 - val_dice_coef:
0.8636 - val_binary_accuracy: 0.9484

Όπως βλέπουμε και στο παρακάτω διάγραμμα η ακρίβεια του μοντέλου αρχικά αυξάνετε με αρκετά μεγάλο ρυθμό και στη συνέχεια σταθεροποιείτε και αυξάνει πολύ ομαλά. Αυτό θα μπορούσε να συμβαίνει διότι.

Η αρχική ταχεία αύξηση της ακρίβειας ή της απόδοσης κατά την εκπαίδευση ενός νευρωνικού δικτύου μπορεί να οφείλεται σε αρκετούς παράγοντες. Ας εξετάσουμε μερικούς από αυτούς:

- Αρχική παραμετροποίηση: Η απόδοση του μοντέλου στις πρώτες εποχές εκπαίδευσης εξαρτάται σε μεγάλο βαθμό από την αρχική παραμετροποίηση του

δικτύου. Αν οι αρχικές τιμές των βαρών είναι καλά επιλεγμένες, το μοντέλο μπορεί να μάθει γρήγορα.

- Αρχιτεκτονική του μοντέλου: Μια σωστά σχεδιασμένη αρχιτεκτονική μπορεί να επιτρέψει στο μοντέλο να μάθει γρήγορα από τα δεδομένα.
- Μέγεθος του συνόλου εκπαίδευσης: Αν το μέγεθος του συνόλου εκπαίδευσης είναι μικρό, το μοντέλο μπορεί να μάθει γρήγορα από τα δεδομένα.

Ωστόσο, η πτώση του ρυθμού αύξησης μετά από μια σημαντική αύξηση μπορεί να οφείλεται σε διάφορους παράγοντες:

- Υπερπροσαρμογή (Overfitting): Καθώς το μοντέλο εκπαιδεύεται περαιτέρω, μπορεί να αρχίσει να μαθαίνει τα θορύβους και τις λεπτομέρειες του συνόλου εκπαίδευσης, αντί για τα γενικά χαρακτηριστικά των δεδομένων.
- Μη επαρκής ποικιλομορφία δεδομένων: Αν το σύνολο εκπαίδευσης δεν καλύπτει επαρκώς την ποικιλομορφία των δεδομένων που θα συναντήσει το μοντέλο στην πραγματική εφαρμογή, τότε το μοντέλο μπορεί να μην εκπαιδεύεται αποτελεσματικά.

Μείωση του ρυθμού εκπαίδευσης (Learning Rate Decay): Συχνά, ο ρυθμός εκπαίδευσης μειώνεται καθώς το μοντέλο εκπαιδεύεται για να βοηθήσει στη σύγκλιση σε ένα καλό σημείο.

Η ακρίβεια του μοντέλου είναι αρκετά καλή ξεκινάει από το 60% στους πρώτους κύκλους εκπαίδευσης και φτάνει να ξεπερνάει το 90% (Διάγραμμα 1). Πράγμα λογικό αφού όσο περνάνε οι εποχές υπάρχουν περισσότεροι κύκλοι εκπαίδευσης πράγμα που κάνει το μοντέλο ακριβέστερο.

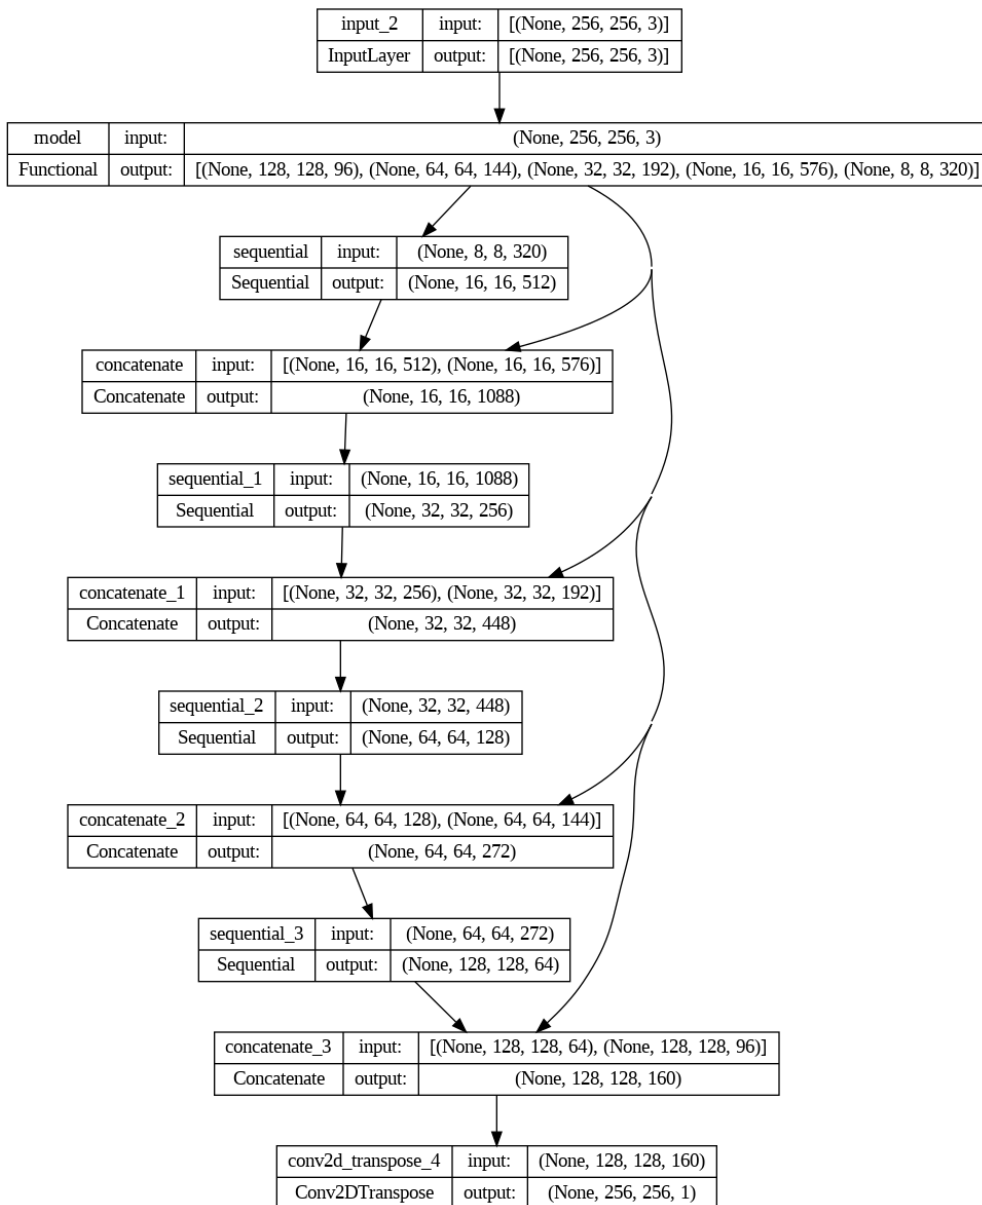
Μετα το πέρας των εποχών γίνεται απεικόνιση των αποτελεσμάτων με το εκπαιδευμένο πλέον μοντέλο σε τυχαίες εικόνες από τα δεδομένα μας. Όπως βλέπουμε και στο παράδειγμα η εικόνα της πρόβλεψης έχει οριοθετήσει πλέον τα πάνελ με αρκετά μεγάλη ακρίβεια. Ταυτόχρονα εκτυπώνετε η δορυφορική φωτογραφία αλλά και η μάσκα ώστε να γίνει η σχετική συσχέτιση μεταξύ των εικόνων. (Εικόνα 5)

Στο τέλος τις διαδικασίας εφαρμόζουμε το πλέον εκπαιδευμένο μοντέλο σε μια τυχαία δορυφορική εικόνα και δημιουργούμε ένα πλαίσιο γύρο από τα πάνελ. Όπως βλέπουμε στην εικόνα το πλαίσιο έχει σχηματιστεί γύρο από την περιοχή που βρίσκετε το πάνελ. (Εικόνα 6) Επίσης παρατηρούμε και κάποιες μικρές αστοχίες του μοντέλου καθώς έχει σχηματίσει και κάποια μικρά πολύγωνα σε περιοχές που δεν υπάρχουν πάνελ πράγμα το οποίο αποτελεί σφάλμα.

Το μοντέλο παρόλο τις ελάχιστες σφάλματα σε κάποια αντικείμενα που μοιάζουν ενδεχομένως με πάνελ και πιθανόν να υπάρχει κάποια δισερμηνία που

δικαιολογεί το ποσοστό ακρίβειας στο 95%. Σε γενικές γραμμές σε οποία εικόνα υπήρχαν πάνελ τα εντόπισε και τα οριοθέτησε με επιτυχία.

Εικόνες-Διαγράμματα




Εικόνα 1 Σχήμα Μοντέλου Νευρωνικού δικτύου

Model: "model_1"


Layer (type)	Output Shape	Param #	Connected to
input_2 (InputLayer)	[(None, 256, 256, 3)]	0	[]
model (Functional)	[(None, 128, 128, 96), (None, 64, 64, 144), (None, 32, 32, 192), (None, 16, 16, 576), (None, 8, 8, 320)]	1841984	['input_2[0][0]']
sequential (Sequential)	(None, 16, 16, 512)	1476608	['model[0][4]']
concatenate (Concatenate)	(None, 16, 16, 1088)	0	['sequential[0][0]', 'model[0][3]']
sequential_1 (Sequential)	(None, 32, 32, 256)	2507776	['concatenate[0][0]']
concatenate_1 (Concatenate)	(None, 32, 32, 448)	0	['sequential_1[0][0]', 'model[0][2]']
sequential_2 (Sequential)	(None, 64, 64, 128)	516608	['concatenate_1[0][0]']
concatenate_2 (Concatenate)	(None, 64, 64, 272)	0	['sequential_2[0][0]', 'model[0][1]']
sequential_3 (Sequential)	(None, 128, 128, 64)	156928	['concatenate_2[0][0]']
concatenate_3 (Concatenate)	(None, 128, 128, 160)	0	['sequential_3[0][0]', 'model[0][0]']
conv2d_transpose_4 (Conv2D Transpose)	(None, 256, 256, 1)	1441	['concatenate_3[0][0]']

Total params: 6501345 (24.80 MB)
Trainable params: 4657441 (17.77 MB)
Non-trainable params: 1843904 (7.03 MB)

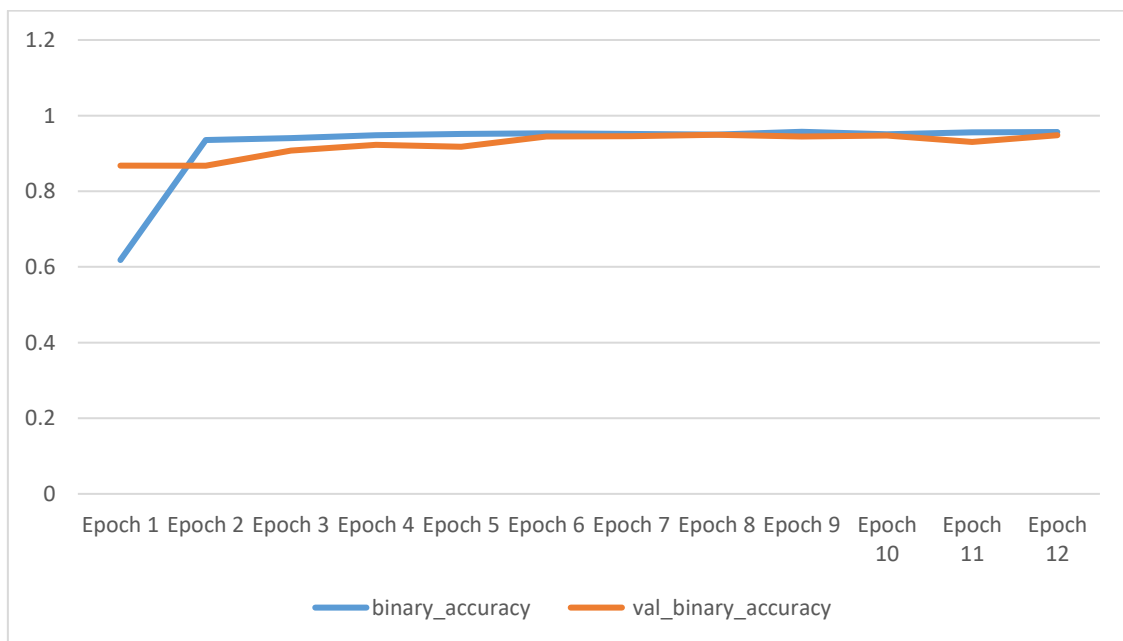
Εικόνα 2 Σύνοψη Παραμέτρων Μοντέλου.




Εικόνα 3 Αποτέλεσμα μοντέλου στις Πρώτες εποχές



Εικόνα 4 Αποτέλεσμα μοντέλου στις τελευταίες εποχές



Διάγραμμα 1 ακρίβεια του μοντέλου



Εικόνα 5 Τελικό αποτέλεσμα εκπαίδευσης



Εικόνα 6 Εφαρμογή του μοντέλου

Συμπεράσματα

Δημιουργήθηκε ένα λειτουργικό μοντέλο με αρκετά καλή ακρίβεια που μπορεί να χρησιμοποιηθεί σε αρκετές εφαρμογές. Όπως στον εντοπισμό των ηλιακών πάνελ σε δορυφορικές εικόνες και αεροφωτογραφίες για την καταγραφή αυτών σε μια περιοχή. Επίσης θα μπορούσαμε να υπολογίσουμε από το εμβαδόν των ορίων των τετραγώνων το ποσοστό κάλυψης από φωτοβολτακά πάνελ στην κάθε περιοχή, όπως και να υπολογίσουμε μια σχετική τιμή για την παραγωγή ενέργειας από ΑΠΕ. Με μερικές προσθήκες ο αλγόριθμος αυτός θα μπορούσε να εμπλουτιστεί στο μέλλον και να επεκταθεί, προσθέτοντας σε αυτόν γεωαναφερμένες εικόνες και με την χρήση βιβλιοθηκών που μπορούν να εξάγουν πολύγωνα σε αρχεία που να περιέχουν γεωμετρία θα μπορούσε να γίνει ένα μέσω εξαγωγής δεδομένων που θα τροφοδοτήσουν άλλα σύνολα δεδομένων με γεωχωρική πληροφορία για τα πάνελ αυτά.

Κώδικας

```
def prepare_dataframe(image_path, name):
    solar_ids = []
    paths = []
    for dirname, _, filenames in os.walk(image_path):
        for filename in filenames:
            path = os.path.join(dirname, filename)
            paths.append(path)

            solar_id = filename.split(".")[0]
            solar_ids.append(solar_id)

    d = {"id": solar_ids, "name": paths}
    df = pd.DataFrame(data = d)
    df = df.set_index('id')
    return df
```

Κώδικας: 1

```
def display(display_list):
    plt.figure(figsize=(15, 15))

    title = ['Input Image', 'True Mask', 'Predicted Mask']

    for i in range(len(display_list)):
        plt.subplot(1, len(display_list), i+1)
        plt.title(title[i])
        plt.imshow(tf.keras.preprocessing.image.array_to_img(display_list[i]))
        plt.axis('off')
    plt.show()
```

Κώδικας: 2

```
root_dir = dataset_path
resolution = 'PV01'
data_dir = os.path.join(root_dir)

image_root = '/content/drive/MyDrive/images_n/pos/'
label_root = '/content/drive/MyDrive/images_n/neg/'
if not os.path.isdir(image_root):
    os.mkdir(image_root)
if not os.path.isdir(label_root):
    os.mkdir(label_root)

images = list()
labels = list()
```

```

for (dirpath, dirnames, filenames) in os.walk(data_dir):

    images += [os.path.join(dirpath, file) for file in filenames]

labels += [i for i in filter(lambda score: '_label.bmp' in score,
images)]
images = [i for i in filter(lambda score: '_label.bmp' not in
score, images)]

for img_path in images:
    src_path = img_path
    dst_path = os.path.join(image_root, os.path.basename(img_path))
    img = Image.open(src_path)
    new_img = img.resize( (256, 256) )
    new_img.save( dst_path[:-4]+'.png', 'png')

for label_path in labels:
    src_path = label_path
    file_name = os.path.basename(label_path).replace('_label', '')
    dst_path = os.path.join(label_root, file_name)
    img = Image.open(src_path)
    new_img = img.resize( (256, 256) )
    new_img.save( dst_path[:-4]+'.png', 'png')

```

Κώδικας: 3

```

train_df, valid_df = train_test_split(df, random_state=42,
test_size=.25)
train = create_dataset(train_df, train = True)
valid = create_dataset(valid_df)

```

Κώδικας: 4

```

base_model = tf.keras.applications.MobileNetV2(input_shape=[256,
256, 3], include_top=False)
layer_names = [
    'block_1_expand_relu',
    'block_3_expand_relu',
    'block_6_expand_relu',
    'block_13_expand_relu',
    'block_16_project',
]
base_model_outputs = [base_model.get_layer(name).output for name
in layer_names]

down_stack = tf.keras.Model(inputs=base_model.input,
outputs=base_model_outputs)

```

```
down_stack.trainable = False
```

Κώδικας: 5

```
def upsample(filters, size, norm_type='batchnorm',
             apply_dropout=False):
    initializer = tf.random_normal_initializer(0., 0.02)

    result = tf.keras.Sequential()
    result.add(
        tf.keras.layers.Conv2DTranspose(filters, size, strides=2,
                                       padding='same',
                                       kernel_initializer=initializ
er,
                                       use_bias=False))

    if norm_type.lower() == 'batchnorm':
        result.add(tf.keras.layers.BatchNormalization())
    elif norm_type.lower() == 'instancenorm':
        result.add(InstanceNormalization())

    if apply_dropout:
        result.add(tf.keras.layers.Dropout(0.5))

    result.add(tf.keras.layers.ReLU())

    return result

up_stack = [
    upsample(512, 3),
    upsample(256, 3),
    upsample(128, 3),
    upsample(64, 3),
```

Κώδικας: 6

```
def unet_model(output_channels):
    inputs = tf.keras.layers.Input(shape=[256, 256, 3])

    skips = down_stack(inputs)
    x = skips[-1]
    skips = reversed(skips[:-1])

    for up, skip in zip(up_stack, skips):
        x = up(x)
        concat = tf.keras.layers.Concatenate()
        x = concat([x, skip])
```

```

last = tf.keras.layers.Conv2DTranspose(
    output_channels, 3, strides=2, activation='sigmoid',
    padding='same')

x = last(x)

return tf.keras.Model(inputs=inputs, outputs=x)

```

Κώδικας: 7

```

def dice_coef(y_true, y_pred, smooth=1):
    intersection = K.sum(y_true * y_pred, axis=[1,2,3])
    union = K.sum(y_true, axis=[1,2,3]) + K.sum(y_pred,
axis=[1,2,3])
    return K.mean( (2. * intersection + smooth) / (union +
smooth), axis=0)

def dice_loss(in_gt, in_pred):
    return 1-dice_coef(in_gt, in_pred)

model = unet_model(1)

model.compile(optimizer='adam',
              loss = dice_loss,
              metrics=[dice_coef, 'binary_accuracy'])

tf.keras.utils.plot_model(model, show_shapes=True)

```

Κώδικας: 8

```

early_stop =
tf.keras.callbacks.EarlyStopping(patience=4, restore_best_weights=True)

# Let's observe how the model improves while it is training.
# To accomplish this task, a callback function is defined below.
class DisplayCallback(tf.keras.callbacks.Callback):
    def on_epoch_begin(self, epoch, logs=None):
        if (epoch + 1) % 5 == 0:
            show_predictions(sample_image, sample_mask)

EPOCHS = 30
STEPS_PER_EPOCH = TRAIN_LENGTH // BATCH_SIZE
batch_size = 32

early_stop = tf.keras.callbacks.EarlyStopping(patience=4,
restore_best_weights=True)
display_cb = DisplayCallback()

```

```

history = model.fit(
    train_dataset,
    batch_size=batch_size,
    epochs=EPOCHS,
    steps_per_epoch=STEPS_PER_EPOCH,
    validation_data=valid_dataset,
    callbacks=[display_cb, early_stop]
)

```

Κώδικας: 9

```

def detect_solar_panels(image_path):
    # Load and preprocess the image
    img = Image.open(image_path)
    img = img.resize((256, 256))
    img_array = np.array(img) / 255.0

    # Perform prediction
    # Load your trained model here if not loaded before
    # model =
    tf.keras.models.load_model('/content/drive/MyDrive/model.h5')
    prediction = model.predict(np.expand_dims(img_array, axis=0))
    predicted_mask = prediction[0] # Extract the predicted mask

    # Threshold the predicted mask
    threshold = 0.5 # You can adjust the threshold as needed
    binary_mask = (predicted_mask > threshold).astype(np.uint8)

    # Resize the binary mask to match the original image size
    overlay_mask = cv2.resize(binary_mask, (img.width,
img.height))

    # Convert binary mask for overlaying on the original image
    overlay_mask = np.expand_dims(overlay_mask, axis=2)
    overlay_mask = np.concatenate([overlay_mask] * 3, axis=2) #
Convert to 3-channel format

    # Convert img_array and overlay_mask to the same data type
    img_array = (img_array * 255).astype(np.uint8)
    overlay_mask = (overlay_mask * 255).astype(np.uint8)

    # Overlay the mask on the original image
    overlay_image = cv2.addWeighted(img_array, 0.7, overlay_mask,
0.3, 0)

    # Plot the original image and the overlay
    plt.figure(figsize=(10, 10))

```

```

plt.subplot(1, 2, 1)
plt.imshow(img)
plt.title('Original Image')
plt.axis('off')

plt.subplot(1, 2, 2)
plt.imshow(overlay_image)
plt.title('Solar Panel Detection')
plt.axis('off')

plt.show()

# Example usage:
image_path =
'/content/drive/MyDrive/PV01/PV01_Rooftop_Brick/PV01_324942_120384
2.bmp'
detect_solar_panels(image_path)

```

Κώδικας: 10

Βιβλιογραφικές Αναφορές

- [1] Chollet, F. et al. (2015). "Keras". [Online]. Available: <https://keras.io>
- [2] Ronneberger, O., Fischer, P., & Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In International Conference on Medical image computing and computer-assisted intervention (pp. 234-241). Springer, Cham.
- [3] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). Mobilenetv2: Inverted residuals and linear bottlenecks. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 4510-4520).
- [4] Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... & Adam, H. (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. arXiv preprint arXiv:1704.04861.
- [5] Sudre, C. H., Li, W., Vercauteren, T., Ourselin, S., & Cardoso, M. J. (2017). Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations. In Deep learning in medical image analysis and multimodal learning for clinical decision support (pp. 240-248). Springer, Cham.
- [6] Milletari, F., Navab, N., & Ahmadi, S. A. (2016). V-net: Fully convolutional neural networks for volumetric medical image segmentation. In 2016 Fourth International Conference on 3D Vision (3DV) (pp. 565-571). IEEE.
- [7] Prechelt, L. (1998). Early stopping - but when?. In Neural Networks: Tricks of the Trade (pp. 55-69). Springer, Berlin, Heidelberg.
- [8] Patil, R., Rajasekaran, M. P., & Tari, S. (2018). Early stopping of neural network using Bayesian theorem. Procedia Computer Science, 132, 216-223.

- [9] **Chuvieco, E., & Huete, A. (2010).** *Fundamentals of Satellite Remote Sensing*. CRC Press.
- [10] **Sentinel-2 User Handbook.** European Space Agency (ESA). Εγχειρίδιο χρήσης του δορυφόρου Sentinel-2, διαθέσιμο στον ιστότοπο της ESA: <https://sentinel.esa.int>.