



**ΠΟΛΥΤΕΧΝΕΙΟ ΚΡΗΤΗΣ  
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ &  
ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ**

**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

**Ζαρκάδα Σαββούλα**

**A.M. 2010030025**

**ΘΕΜΑ**

**Μελέτη της Ενεργειακής Αποδοτικότητας με βάση την Υπέρυθρη  
Επιθεώρηση από μη Επανδρωμένα Αεροσκάφη**

**Study of Energy Building Efficiency based on Infrared Inspection by  
Unmanned Aerial Vehicles**

**ΕΞΕΤΑΣΤΙΚΗ ΕΠΙΤΡΟΠΗ:**

**Καθηγητής Γεώργιος Σταυρακάκης (Επιβλέπων)**

**Αναπληρωτής Καθηγητής Φώτιος Κανέλλος**

**Δρ Ελευθερία Σεργάκη (ΕΔΙΠ)**

**Χανιά, Οκτώβριος 2023**

## Table of Contents

Ευχαριστίες.....	6
Περίληψη.....	7
Λέξεις Κλειδιά.....	8
1 Εισαγωγή.....	10
1.1 Σκοπός της εργασίας.....	10
1.2 Δήλωση του προβλήματος.....	12
1.3 Διάρθρωση της εργασίας.....	13
2 Θερμογραφία στα Κτίρια:Ανάλυση,Μεθοδολογίες και Εφαρμογές.....	14
2.1 Η Θερμογραφία στα Κτίρια.....	14
2.2 Εισαγωγή στη Θερμογραφία και την Υπέρυθρη Επιθεώρηση.....	15
2.3 Θερμική ανάλυση.....	15
2.3.1 Τομείς θερμικής ανάλυσης.....	17
2.4 Προσδιορισμός μεθοδολογίας θερμογραφίας κτιρίων.....	18
2.4.1 Μεθόδοι ανάλυσης.....	18
Ενεργή θερμογραφία.....	18
Παθητική θερμογραφία.....	19
2.4.2 Μεθόδοι μέτρησης.....	19
2.4.3 Τοποθεσία.....	20
2.5 Εντοπίσιμα ελαττώματα.....	20
2.6 Μεθοδολογίες θερμογραφίας παθητικής κτιριακής εφαρμογής.....	21
2.6.1 Aerial surveys/Εναέριες έρευνες.....	21
2.6.2 Automated fly-past surveys/Αυτόματες έρευνες περιπολίας από αεροσκάφος.....	22
2.6.3 Street pass-by surveys/ Έρευνες διέλευσης από τους δρόμους.....	23
2.6.4 Παραδοσιακή παθητική θερμογραφία κτιρίων.....	24
Περιήγηση γύρω από το κτίριο (μόνο εξωτερικά)/Perimeter Walk Around Surveys (External only).....	24
Περιήγηση μέσα και έξω από το κτίριο/ Walk Through Surveys (Internal and External).....	24
2.6.5 Επαναλαμβανόμενες έρευνες/Repeat Surveys.....	25
2.6.6 Έρευνες σε χρονοληπτική ακολουθία / Time-Lapse Surveys.....	25
2.7 Η Κάμερα της Ερευνητικής Μου Εργασίας: Περιγραφή και Χαρακτηριστικά.....	26
3 Θερμογραφία και Μηχανική Μάθηση.....	29
3.1 Η θερμογραφία και στα συνελκτικά νευρωνικά δίκτυα (CNNs).....	29
3.2 Μηχανική Μάθηση.....	29
3.2.1 Ανάλυση.....	29
3.2.2 Είδη Μηχανικής Μάθησης.....	30
Επιβλεπόμενη Μάθηση (Supervised Learning):.....	30
Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning):.....	31
Ενισχυτική Μάθηση (Reinforcement Learning):.....	31
3.3 Deep Learning.....	31
3.3.1 Τεχνητά νευρωνικά δίκτυα.....	31
3.3.2 Αρχιτεκτονική Νευρωνικών Δικτύων.....	32
3.4 Τύποι νευρωνικών δικτύων.....	35
3.4.1 Συνελκτικά Νευρωνικά Δίκτυα (CNNs).....	35
Εισαγωγή στα CNNs.....	35
Ορισμός Αρχιτεκτονικής CNN.....	36
Επίπεδα στα CNNs.....	36

3.4.2 Μακροπρόθεσμη Μνήμη Ελάχιστης Επιτροπής (Long Short-Term Memory ).....	39
Εισαγωγή στις LSTM.....	39
Ορισμός Αρχιτεκτονικής LSTM.....	39
Επίπεδα στις LSTM.....	40
3.4.3 CNN + LSTM.....	42
3.5 Προβλήματα Νευρωνικών Δικτύων και Αντιμετώπιση.....	42
Υπερεκπαίδευση (Overfitting).....	42
Υποεκπαίδευση (Underfitting).....	43
Διάρκεια Εκπαίδευσης και Υπολογιστική Ισχύς.....	43
Προβλήματα Δεδομένων (Data Issues).....	43
4 Πειραματική Εφαρμογή.....	44
4.1 Εργαλεία και τεχνικές που χρησιμοποιήθηκαν στη διατριβή.....	44
4.1.1 Python.....	44
4.1.2 Pandas.....	45
4.1.3 TensorFlow.....	46
4.1.4 Keras.....	46
4.1.5 Dropout Regularization.....	47
4.1.6 Image Data Augmentation.....	47
4.1.7 Μετασχηματισμός Δεδομένων.....	47
4.1.8 MinMax Normalization.....	48
4.1.9 Oversampling and Undersampling techniques.....	49
4.1.10 Callbacks, EarlyStopping, model checkpoint.....	50
4.1.11 Optimizer.....	50
4.1.12 Sample weights.....	51
4.1.13 StratifiedShuffleSplit.....	52
4.1.15 Συναρτήσεις Ενεργοποίησης (Activation Functions).....	52
4.1.16 Συνάρτηση Απώλειας (Loss Function).....	53
4.1.17 Confusion Matrix και Classification Report.....	54
4.2 Δεδομένα.....	57
4.2.1 Περιγραφή του συνόλου δεδομένων.....	57
4.2.2 Προετοιμασία Δεδομένων.....	58
4.3 Εφαρμογή του Νευρωνικού Δικτύου.....	64
4.3.1 Προετοιμασία Δεδομένων στη Βαθιά Μάθηση(Deep Learning).....	64
4.3.2 Ορισμός και Αρχιτεκτονική του Μοντέλου.....	66
4.3.3 Εκπαίδευση του Μοντέλου.....	67
5 Αποτελέσματα και Ανάλυση.....	71
5.1 Εισαγωγή.....	71
5.2 Παρουσίαση των αποτελεσμάτων των μεθόδων.....	72
5.2.1 Μέθοδος 1η: Βασικό Μοντέλο.....	72
Αναλυτική Περιγραφή του Μοντέλου.....	73
Διάγραμμα απώλειας λάθους και ακρίβειας.....	74
Πίνακας confusion matrix.....	75
Πίνακας και Διάγραμμα classification report.....	75
5.2.2 Μέθοδος 2η: Υπερδειγματοληψία (Over-sampling).....	77
Αναλυτική Περιγραφή του Μοντέλου.....	78

Διαγραμμα απώλειας λάθους και ακρίβειας.....	79
Πίνακας confusion matrix.....	80
Πίνακας και Διάγραμμα classification report.....	80
5.2.3 Μέθοδος 3η: Υποδειγματοληψία (Under-sampling).....	82
Αναλυτική Περιγραφή του Μοντέλου.....	83
Διαγραμμα απώλειας λάθους και ακρίβειας.....	84
Πίνακας confusion matrix.....	85
Πίνακας και Διάγραμμα classification report.....	85
5.3 Παρουσίαση των αποτελεσμάτων στα αρχικά μας δεδομένα εφαρμόζοντας το CNN.....	88
6 Επίλογος.....	99
6.1 Συμπεράσματα.....	99
6.1.1 Εισαγωγή.....	99
6.1.2 Διαδικασία.....	99
6.1.3 Αποτελέσματα.....	105
6.1.4 Πιθανες λύσεις.....	106
6.2 Προτάσεις για Μελλοντική Έρευνα.....	107
Βιβλιογραφία.....	109

## Ευχαριστίες

Με την περάτωση της διπλωματικής μου εργασίας, θα ήθελα να εκφράσω τις θερμές μου ευχαριστίες σε όλους όσους συνέβαλλαν στην εκπόνησή της. Ιδιαίτερα, θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή μου, καθηγητή ΗΜΜΥ κ. Γεώργιο Σταυρακάκη, για την εμπιστοσύνη που μου έδειξε και για την ανάθεση της διπλωματικής μου εργασίας.

Θα ήθελα ακόμα να ευχαριστήσω πολύ τον αναπλήρωτή καθηγητή Φώτιο Κανέλλο, μέλος της τριμελούς επιτροπής, για τη συνεργασία και για την συμβολή του στη διεκπεραίωση της διπλωματικής μου εργασίας.

Επιπλέον, επιθυμώ να ευχαριστήσω και την δόκτωρ Ελευθερία Σεργάκη για την υπομονή της και την πολύτιμη βοήθειά της καθ' όλη τη διάρκεια της διπλωματικής μου εργασίας αλλά και για το χρόνο που αφιέρωσε για την επίλυση αποριών προκειμένου να ολοκληρωθεί η εν λόγω διπλωματική εργασία.

Θα ήθελα επίσης να ευχαριστήσω πολύ τον καθηγητή Παναγιώτη Παρτσινέβελο, καθώς και το εργαστήριο senselab για τη συλλογή των δεδομένων που χρησιμοποιήθηκαν στην εργασία, αλλά και για την επιστημονική τους υποστήριξη καθόλη τη διάρκεια της διπλωματικής μου εργασίας.

Τέλος, την οικογένεια και τους φίλους μου για τα εφόδια που μου προσέφεραν και συνεχίζουν να μου προσφέρουν, καθώς και για την ανιδιοτελή υποστήριξή τους.

## Περίληψη

Η θερμογραφία αποτελεί μια πολύτιμη μέθοδο διαγνωστικής εξέτασης στο πεδίο της ενεργειακής απόδοσης των κτιρίων. Με τη χρήση υπέρυθρων καμερών, είναι δυνατό να εντοπίσουμε και να ποσοτικοποιήσουμε τις απώλειες θερμότητας μέσω των δομικών στοιχείων των κτιρίων. Αυτό μας βοηθά να προσδιορίσουμε τις περιοχές όπου εμφανίζονται προβλήματα, όπως θερμογέφυρες ή κακή μόνωση, και να εφαρμόσουμε τις κατάλληλες επεμβάσεις για την αντιμετώπισή τους. Η παρούσα έρευνα επικεντρώνεται στην ανάλυση της ενεργειακής απόδοσης κτιρίων με τη χρήση παθητικής θερμογραφίας και ειδικότερα της υπέρυθρης επιθεώρησης, μιας τεχνικής που επιτρέπει τη μέτρηση της θερμοκρασίας επιφανειών μέσω της ανίχνευσης της υπέρυθρης ακτινοβολίας που εκπέμπουν τα αντικείμενα. Η θερμογραφία παρέχει μια εικόνα των θερμοκρασιακών προφίλ και μπορεί να αποκαλύψει περιοχές με ασυνήθιστη θερμότητα ή ψύχρα σε επιφάνειες επιτρέποντάς μας να εντοπίσουμε έτσι αποκλίσεις, ελλείψεις ή ακόμα και προβλήματα που σχετίζονται με την ενεργειακή συμπεριφορά ενός κτιρίου. Στην περίπτωση μας, εφαρμόζουμε δύο ειδικές μεθόδους ερεύνας συνδυαστικά: τις "Automated fly-past surveys" και τις "Time-lapse surveys". Συγκεκριμένα, λάβαμε 104 φωτογραφίες σε διάστημα δύο ημερών, σε περιόδους 15 λεπτών, επιτρέποντάς μας να παρακολουθήσουμε τις διακυμάνσεις στη θερμοκρασία του κτιρίου και να εντοπίσουμε πιθανές ανωμαλίες.

Η ερευνητική μελέτη που πραγματοποιείται χρησιμοποιεί έναν κώδικα που αναλύει εικόνες από θερμοκάμερες και ανιχνεύει ασυνήθιστες περιοχές με υπερβολικά θερμή ή ψυχρή θερμοκρασία. Αυτό επιτυγχάνεται μέσω της μεθόδου επιβλεπόμενης μάθησης, όπου ένα μοντέλο Convolutional Neural Network (CNN) εκπαιδεύεται να αναγνωρίζει αυτές τις ασυνήθιστες περιοχές στις εικόνες. Επομένως συνδυάζει και ποιοτική και ποσοτική ανάλυση. Ο κώδικας αυτός επίσης χρησιμοποιεί μεθόδους υπερδειγματοληψίας και υποδειγματοληψίας για να αντιμετωπίσει την ανισορροπία των κλάσεων στο σύνολο δεδομένων, ετικέτες (labels) που περιγράφουν τις περιοχές στις εικόνες, καθώς και ένα συνδυασμό διαφόρων τεχνικών βελτίωσης που επηρεάζουν την απόδοση των CNNs. Αυτές οι μέθοδοι είναι η Data Augmentation, η Dropout, το Stratified\_split τα callbacks. Κατά τη διάρκεια της εκπαίδευσης, το μοντέλο CNN εκπαιδεύεται να μάθει τα χαρακτηριστικά των ασυνήθιστων περιοχών, προκειμένου να τις αναγνωρίζει αποτελεσματικά. Επιπλέον, ο κώδικας περιλαμβάνει μια διαδικασία αξιολόγησης της απόδοσης του μοντέλου στο σύνολο ελέγχου. Με βάση την απόδοση αυτή, το καλύτερο μοντέλο αποθηκεύεται για μελλοντική χρήση. Αυτό επιτρέπει τη συνεχή βελτίωση της ακρίβειας και της αποτελεσματικότητας του μοντέλου. Τέλος, αξιολογούνται τα μοντέλα πρόβλεψης και αναλύονται οι αποφάσεις που πρέπει να παρθούν για την ομαλή λειτουργία των κτιρίων.

Συνολικά, η έρευνα αυτή αποτελεί μια σημαντική συνεισφορά στον τομέα της ενεργειακής απόδοσης κτιρίων. Η συνδυασμένη προσέγγιση της θερμογραφίας και της μηχανικής μάθησης μπορεί να οδηγήσει σε βελτιωμένες μεθόδους διαχείρισης ενέργειας, προωθώντας την επίτευξη πιο βιώσιμων και αποδοτικών κτιριακών συστημάτων. Αυτή η προσέγγιση μπορεί να βοηθήσει στον εντοπισμό

προβλημάτων, ανωμαλιών και ελλείψεων που σχετίζονται με την ενέργεια στα κτίρια, προάγοντας την υγεία και την αποδοτικότητα των κτιριακών συστημάτων.

## Λέξεις Κλειδιά

Θερμογραφία, παθητική θερμογραφία, ενεργειακή απόδοση κτιρίου, υπέρυθρη επιθεώρηση, θερμική κάμερα, Automated fly-past surveys, Time-lapse surveys, απώλειες θερμότητας, ανίχνευση ανωμαλιών, χρονοσειρά, βαθιά μάθηση, συνελκτικά νευρωνικά δίκτυα (CNN), υπερδειγματοληψία, υποδειγματοληψία, αύξηση δεδομένων, διαχείριση ενέργειας και υγεία των κτιρίων, δεδομένα εκπαίδευσης, δεδομένα επικύρωσης, απώλεια, ακρίβεια, υπερεκπαίδευση.

## Abstract

Thermography is a valuable method of diagnostic examination in the field of energy efficiency of buildings. By using infrared cameras, it is possible to detect and quantify heat loss through the structural elements of buildings. This helps us identify areas where problems occur, such as thermal bridges or poor insulation, and implement appropriate interventions to address them. The present research focuses on the analysis of the energy performance of buildings using passive thermography and in particular infrared inspection, a technique that allows the measurement of surface temperature by detecting the infrared radiation emitted by objects. Thermography provides a picture of temperature profiles and can reveal areas of unusual heat or cold on surfaces allowing us to identify deviations, deficiencies or even problems related to a building's energy performance. In our case, we apply two special research methods in combination: "Automated fly-past surveys" and "Time-lapse surveys". In particular, we received 104 photos over two days, at 15-minute intervals, allowing us to monitor the fluctuations in the building's temperature and identify potential anomalies.

The research study being carried out uses a code that analyzes images from thermal cameras and detects unusual areas of excessively hot or cold temperature. This is achieved through the supervised learning method, where a Convolutional Neural Network (CNN) model is trained to recognize these unusual regions in the images. It therefore combines both qualitative and quantitative analysis. This code also uses oversampling and undersampling methods to deal with the imbalance of classes in the dataset, labels that describe regions in images, and a combination of various enhancement techniques that affect the performance of CNNs. These methods are Data Augmentation, Dropout, Stratified\_split and callbacks. During training, the CNN model is trained to learn the features of unusual regions in order to recognize them effectively. In addition, the code includes a procedure to evaluate the performance of the model on the control set. Based on this performance, the best model is saved for future use. This allows for continuous improvement of the accuracy and efficiency of the model. Finally, the prediction models are evaluated and the decisions that must be made for the smooth operation of the buildings are analyzed.

Overall, this research is an important contribution to the field of building energy performance. The combined approach of thermography and machine learning can lead to improved methods of energy management, promoting the achievement of more sustainable and efficient building systems. This approach can help identify energy-related problems, anomalies and deficiencies in buildings, promoting the health and efficiency of building systems.

## **Keywords**

Thermography, passive thermography, building energy performance, infrared inspection, thermal camera, Automated fly-past surveys, Time-lapse surveys, heat losses, anomaly detection, time series, deep learning, convolutional neural networks (CNN), oversampling, undersampling, data augmentation, energy management and building health, training data, validation data, loss, accuracy, overtraining.



# 1 Εισαγωγή

## 1.1 Σκοπός της εργασίας

Η διπλωματική μας εργασία έχει ως στόχο την ανίχνευση και ερμηνεία ασυνήθιστων περιοχών σε ένα κτίριο μέσω της ανάλυσης θερμογραφικών εικόνων, εφαρμόζοντας παθητική θερμογραφία. Η επίτευξη αυτού του στόχου βασίζεται στην ανάπτυξη και την εφαρμογή ενός προηγμένου αλγορίθμου μηχανικής μάθησης που αποτελείται από ένα μοντέλο Δικτύων Συνελκτικών Νευρώνων (CNN), που είναι ικανό να αναγνωρίζει και να κατανοεί αυτές τις ασυνήθιστες περιοχές.

Αυτές οι ασυνήθιστες περιοχές μπορεί να υποδεικνύουν μια σειρά από πιθανές ανωμαλίες στη λειτουργία του κτιρίου, όπως ελλείψεις στη θερμομόνωση, ύπαρξη υγρασίας, θερμική μεταφορά θερμότητας μέσω αγωγίμων υλικών ή άλλες πηγές απώλειας θερμότητας. Ο έγκαιρος εντοπισμός αυτών των προβλημάτων μπορεί να βοηθήσει στην αύξηση της ενεργειακής απόδοσης του κτιρίου και στην ελαχιστοποίηση του αντίκτυπου στο περιβάλλον.

Η εφαρμογή αυτού του αλγορίθμου βασίζεται σε μια χρονοσειρά από 104 φωτογραφίες από ένα κτίριο στο ΜΗΧ.Ο.Π, νοτιοανατολικού προσανατολισμού, που συνελήφθησαν από μια θερμοκάμερα Flir Tau 2 core, η οποία τοποθετήθηκε σε ύψος 9 μέτρων από το έδαφος και 30 μέτρα από τον τοίχο. Ωστόσο, είναι σημαντικό να σημειωθεί ότι η θερμοκάμερα αυτή λειτουργεί με την αρχή της υπέρυθρης ακτινοβολίας και το γυαλί της συμπεριφέρεται σαν καθρέφτης. Κατά τη διάρκεια της λήψης των εικόνων, το γυαλί θερμαίνεται, προκαλώντας θόρυβο και παραμόρφωση στα δεδομένα θερμοκρασίας. Αυτές οι φωτογραφίες λαμβάνονται σε περιόδους 15 λεπτών σε διάστημα δύο ημερών, ξεκινώντας την Πέμπτη 30 Ιουλίου 2020 στις 14.15 και τελειώνοντας Παρασκευή 31 Ιουλίου 2020 στις 16:00 το απόγευμα. Η εξωτερική θερμοκρασία κυμαίνεται από 22 έως 33 βαθμούς Κελσίου κατά τη διάρκεια αυτής της περιόδου, ενώ η εσωτερική θερμοκρασία παραμένει σταθερή στους 23 βαθμούς, χάρη στο σύστημα κλιματισμού.

Εφαρμόζουμε δύο ειδικές μεθόδους έρευνας συνδυαστικά: τις "Automated fly-past surveys" και τις "Time-lapse surveys". Οι "Automated fly-past surveys" πραγματοποιούνται συνήθως με τη χρήση drones, που πετούν κοντά στην επιφάνεια του κτιρίου που μελετάτε, συλλέγοντας φωτογραφίες και άλλα δεδομένα. Αυτή η μέθοδος είναι ιδιαίτερα χρήσιμη για την εκτέλεση επιθεωρήσεων σε υψηλά κτίρια, ενώ παρέχει και τη δυνατότητα να εξεταστούν οι διάφορες πτυχές του κτιρίου με λεπτομερή ακρίβεια. Ο τρόπος με τον οποίο έχει τοποθετηθεί η κάμερα, σε ύψος 9 μέτρων από το έδαφος και 30 μέτρα από τον τοίχο, παρέχει ένα πλάνο παρακολούθησης που μιμείται αυτό που θα έβλεπε κανείς εάν περνούσε με ένα μικρό αεροσκάφος δίπλα από το κτίριο. Οι εικόνες που λαμβάνονται από τη θερμοκάμερα στο ΜΗΧ.Ο.Π προσομοιώνουν αυτή την προσέγγιση, παρέχοντας στον χρήστη μια διαρκή και συνεχή προβολή του κτιρίου, όπως ακριβώς θα την είχε εάν πετούσε δίπλα του.

Από την άλλη πλευρά, οι "Time-lapse surveys" αναφέρονται στην τεχνική λήψης μιας σειράς φωτογραφιών σε συγκεκριμένα χρονικά διαστήματα, για να εξετάσετε την εξέλιξη κάποιου φαινομένου με την πάροδο του χρόνου. Εμείς εδώ έχουμε μια χρονοσειρά από 104 φωτογραφίες που λαμβάνονται σε περιόδους 15 λεπτών σε διάστημα δύο ημερών.

Αρχικά εφαρμόζουμε μια μέθοδο επεξεργασίας εικόνων για την ανίχνευση και την οπτικοποίηση θερμοκρασιακών αλλοιώσεων, και στη συνέχεια χρησιμοποιούμε επιβλεπόμενη μάθηση για την ταξινόμηση των εικόνων βάσει των ανακαλύψεων μας. Μέσα από τον παραπάνω κώδικα, χρησιμοποιούμε μια ποσοτική ανάλυση για να μετρήσουμε και να αναλύσουμε τις θερμοκρασίες σε διάφορα σημεία της εικόνας. Αυτό μας επιτρέπει να κατανοήσουμε τις ακριβείς τιμές και τις διακυμάνσεις των θερμοκρασιών στις εικόνες. Παράλληλα, με την ποιοτική ανάλυση, όπως η ετικετοποίηση των εικόνων βάσει των ασυνήθιστων περιοχών και η οπτικοποίηση, μπορούμε να ερμηνεύσουμε τα δεδομένα μας σε πρακτικό επίπεδο, αναγνωρίζοντας περιοχές ενδιαφέροντος και εξαγοντας χρήσιμες πληροφορίες. Ο συνδυασμός των δύο τύπων ανάλυσης μας επιτρέπει να έχουμε μια ολοκληρωμένη κατανόηση των δεδομένων, ενώ ταυτόχρονα βελτιστοποιούμε τις αποφάσεις μας βάσει των ευρημάτων μας.

Το μοντέλο μηχανικής μάθησης που αναπτύσσουμε και χρησιμοποιούμε επιδιώκει την αναγνώριση και κατανόηση των ασυνήθιστων περιοχών μέσω εκπαίδευσης σε φωτογραφίες, εφαρμόζοντας. Η εκπαίδευση αυτή περιλαμβάνει επίσης την επιβλεπόμενη μάθηση, ώστε το μοντέλο να μπορεί να αναγνωρίζει και να επεξεργάζεται αυτές τις περιοχές με ακρίβεια και αξιοπιστία. Ο αλγόριθμος βελτιστοποιεί την απόδοσή του μέσω της χρήσης τεχνικών όπως η Data Augmentation, η Dropout, το Stratified\_split, τα callbacks και regularizers, για να αποφύγει την υπερεκπαίδευση(overfitting). Επίσης χρησιμοποιεί μεθόδους υπερδειγματοληψίας και υποδειγματοληψίας για να αντιμετωπίσει την ανισορροπία των κλάσεων στο σύνολο δεδομένων, επίσης χρησιμοποιεί ετικέτες (labels) που περιγράφουν τις ασυνήθιστες περιοχές στις εικόνες. Αναλυτικότερα, επιλέχθηκε η Python δεδομένου ότι είναι μια δυναμική γλώσσα προγραμματισμού υψηλού επιπέδου η οποία παρέχει τη δυνατότητα χρήσης εξειδικευμένων πακέτων σε ότι αφορά όχι μόνο στα νευρωνικά δίκτυα αλλά και στην υλοποίηση πολύπλοκων μαθηματικών υπολογισμών. Αναφορικά με τα πακέτα (η αλλιώς βιβλιοθήκες ) χρησιμοποιήθηκαν το TensorFlow, το Keras, το sklearn και το imblearn τα οποία θα αναλυθούν στη συνέχεια.

Με αυτήν την προσέγγιση, επιδιώκουμε να δημιουργήσουμε ένα μοντέλο πρόβλεψης που θα μπορεί να βοηθήσει στην πρόβλεψη, το χειρισμό των θερμικών συνθηκών και στην αντιμετώπιση των προβλημάτων των κτιρίων, αυξάνοντας έτσι την αποδοτικότητα και τη βιωσιμότητά τους. Αυτό μπορεί να είναι ιδιαίτερα χρήσιμο για τη διατήρηση της ενεργειακής απόδοσης, την προστασία του περιβάλλοντος, αλλά και την εξασφάλιση της άνεσης και της ασφάλειας των χρηστών του κτιρίου.

## 1.2 Δήλωση του προβλήματος

Η σύγχρονη έρευνα στον τομέα της θερμογραφίας κτιρίων αποτελεί έναν δύσκολο και ενδιαφέροντα πυρήνα μελέτης, ο οποίος επιχειρεί να αντιμετωπίσει πολύπλοκα ερωτήματα σχετικά με την ενεργειακή απόδοση, την ασφάλεια και την εξοικονόμηση πόρων. Το πρόβλημα που αναφέρεται στην παρούσα εργασία είναι η προσπάθεια να κατανοήσουμε, να αναγνωρίσουμε και να αναλύσουμε ασυνήθιστες θερμοκρασιακές περιοχές σε κτίρια, μέσω της ανάλυσης εικόνων από θερμοκάμερες.

Στο πλαίσιο γενικότερου προβλήματος της θερμογραφίας στα κτίρια, υπάρχουν αρκετές προκλήσεις που πρέπει να αντιμετωπιστούν. Η πρώτη πρόκληση είναι η σωστή ερμηνεία των θερμοκρασιακών δεδομένων και η αναγνώριση ασυνήθιστων περιοχών. Αυτό απαιτεί εξειδικευμένες μεθόδους και αλγορίθμους επεξεργασίας εικόνων και μηχανικής μάθησης, που θα επιτρέψουν την αναγνώριση ανωμαλιών και την εξαγωγή συμπερασμάτων για την κατάσταση του κτιρίου.

Μια άλλη πρόκληση είναι η επίτευξη αξιόπιστων μετρήσεων, καθώς η θερμοκρασία μπορεί να επηρεαστεί από πολλούς παράγοντες, όπως η εξωτερική θερμοκρασία, η ποιότητα του κτιρίου, οι κλιματικές συνθήκες και ο τρόπος λειτουργίας των θερμοκαμερών. Απαιτείται η ανάλυση αυτών των παραμέτρων και η απομάκρυνση των παρασίτων πληροφοριών προκειμένου να εξασφαλιστούν αξιόπιστα αποτελέσματα.

Επιπλέον, το γεγονός ότι οι θερμοκάμερες λειτουργούν βάσει της υπέρυθρης ακτινοβολίας, κάνει το γυαλί να συμπεριφέρεται σαν καθρέφτης, προκαλώντας θόρυβο και παραμόρφωση στα δεδομένα θερμοκρασίας. Αυτό συνεπάγεται ότι οι μετρήσεις που προκύπτουν μπορεί να είναι ασταθείς ή ακριβέστερα αναξιόπιστες.

Τέλος, η υπερεκπαίδευση (overfitting) αποτελεί μια συνήθη πρόκληση στη μηχανική μάθηση, και ειδικά στη θερμογραφία κτιρίων, λόγω του περιορισμένου αριθμού διαθέσιμων δεδομένων. Αυτό επιδεινώνεται από την πολυπλοκότητα των εικόνων και την ποικιλία των ασυνήθιστων περιοχών που πρέπει να αναγνωριστούν. Η χρήση τεχνικών όπως η επιβλεπόμενη μάθηση, η υπερδειγματοληψία και η υποδειγματοληψία, σε συνδυασμό με την εφαρμογή τεχνικών βελτίωσης, μπορεί να βοηθήσει στην αντιμετώπιση αυτής της πρόκλησης.

Τα παραπάνω προβλήματα επιδιώκουμε να αντιμετωπίσουμε μέσω της εφαρμογής τεχνικών όπως η επιβλεπόμενη μάθηση, η υπερδειγματοληψία και η υποδειγματοληψία, οι οποίες βοηθούν στην καλύτερη αναγνώριση και επεξεργασία των εικόνων, καθώς και στην αντιμετώπιση της ανισορροπίας των κλάσεων στο σύνολο δεδομένων. Επιπλέον, έχουμε εφαρμόσει μια σειρά από τεχνικές βελτίωσης, που έχουν επηρεάσει θετικά την απόδοση των μοντέλων μας. Ανάμεσα σε αυτές τις τεχνικές συγκαταλέγονται η Data Augmentation, η οποία επιτρέπει τη δημιουργία νέων εικόνων από το αρχικό σύνολο δεδομένων, προσθέτοντας παραλλαγές όπως περιστροφές, μετατοπίσεις και αλλοιώσεις. Επίσης, η τεχνική Dropout εφαρμόζει την τυχαία απενεργοποίηση τυχαίων νευρώνων κατά τη διάρκεια της εκπαίδευσης, προκειμένου να αποφευχθεί η υπερεκπαίδευση και να βελτιστοποιηθεί η γενίκευση.

Αυτές οι μέθοδοι συμβάλλουν στην επίτευξη υψηλής ακρίβειας και αποτελεσματικότητας των μοντέλων μας.

Συνοψίζοντας, η θερμογραφία στα κτίρια αποτελεί έναν πολύπλοκο και σημαντικό τομέα έρευνας. Οι προκλήσεις που προκύπτουν από την ερμηνεία των δεδομένων, την αξιοπιστία των μετρήσεων και την υπερεκπαίδευση απαιτούν την εφαρμογή ποικίλων τεχνικών και μεθόδων, προκειμένου να επιτευχθεί ακρίβεια, αξιοπιστία και αποτελεσματικότητα στην ανάλυση των εικόνων θερμοκαμερών και την αναγνώριση των ασυνήθιστων περιοχών. Με τη συνεχή βελτίωση των μεθόδων και την ανάπτυξη εξειδικευμένων αλγορίθμων, ελπίζουμε να επιτύχουμε την αποτελεσματική διαχείριση και ανάπτυξη των κτιρίων για το μέλλον.

### 1.3 Διάρθρωση της εργασίας

1. **Εισαγωγή:** Το κεφάλαιο αυτό διατυπώνει τον σκοπό της εργασίας, δηλώνει το πρόβλημα που προσπαθεί να επιλύσει και περιγράφει τη δομή της εργασίας.
2. **Θερμογραφία στα Κτίρια: Ανάλυση, Μεθοδολογίες και Εφαρμογές:** Αναλύει τη θερμογραφία στα κτίρια, παρουσιάζει τη θερμική ανάλυση και περιγράφει τις διάφορες μεθοδολογίες και τεχνικές εφαρμογών θερμογραφίας στα κτίρια. Επίσης, αναλύονται μεθοδολογίες θερμογραφίας και τρόποι εντοπισμού ελαττωμάτων σε κτίρια.
3. **Θερμογραφία και Μηχανική Μάθηση:** Επεξεργάζεται την εφαρμογή της θερμογραφίας στα συνελκτικά νευρωνικά δίκτυα (CNNs) και περιγράφει διάφορους τύπους μηχανικής μάθησης. Εξετάζει επίσης τη βαθιά μάθηση και τους τύπους νευρωνικών δικτύων.
4. **Πειραματική Εφαρμογή:** Περιγράφει τα εργαλεία και τεχνικές που χρησιμοποιήθηκαν στη διατριβή, με επίκεντρο τη Python, την TensorFlow, τη Keras και τις τεχνικές προεπεξεργασίας δεδομένων. Το κεφάλαιο καταλήγει στην εφαρμογή του νευρωνικού δικτύου.
5. **Αποτελέσματα και Ανάλυση:** Παρουσιάζει και αναλύει τα αποτελέσματα των μεθόδων που εφαρμόστηκαν, περιλαμβανομένων της υπερδειγματοληψίας (over-sampling), υποδειγματοληψίας (under-sampling) και άλλων τεχνικών. Παρέχονται διαγράμματα, πίνακες και αναφέρονται τα συμπεράσματα που προκύπτουν από την εργασία.
6. **Επίλογος:** Το τελευταίο κεφάλαιο παρουσιάζει τα συμπεράσματα της εργασίας και προτάσεις για μελλοντική έρευνα στον τομέα της θερμογραφίας.

## **2 Θερμογραφία στα Κτίρια: Ανάλυση, Μεθοδολογίες και Εφαρμογές**

### **2.1 Η Θερμογραφία στα Κτίρια**

Η θερμογραφία αναδύεται ως σύγχρονη, μη καταστροφική μέθοδος διάγνωσης προβλημάτων στα κτίρια, επιτρέποντας τον εντοπισμό ενεργειακών απωλειών μέσω της ανάλυσης της θερμικής ακτινοβολίας. Σε μια εποχή όπου η κατανάλωση ενέργειας στα κτίρια αποτελεί μεγάλο μέρος του ενεργειακού ισοζυγίου των ανεπτυγμένων κρατών, ενώ ειδικότερα οι ενεργειακές απαιτήσεις για θέρμανση και ψύξη αποτελούν τις βασικές ενεργειακές ανάγκες μιας μέσης κατοικίας, η ανίχνευση ενεργειακών απωλειών καθίσταται ζωτικής σημασίας για την επίτευξη ενεργειακά αποδοτικών και άνετων κτιρίων.

Τα κτίρια εκτιμάται ότι είναι υπεύθυνα για το 40% της συνολικής κατανάλωσης ενέργειας στην ΕΕ [2]. Παρόλο που η ενεργειακή απόδοση έχει εστιαστεί περισσότερο σε σχέση με τα κατασκευαστικά ελαττώματα, η απώλεια θερμότητας από δομικά στοιχεία, όπως η θερμική γεφύρωση και τα ρεύματα, έχει άμεση σχέση με τη συνολική ενεργειακή απόδοση του κτιρίου [3, 4]. Ειδικότερα, η θέρμανση των χώρων αποτελεί σημαντικό μέρος της εγχώριας κατανάλωσης ενέργειας, και με την αύξηση των τιμών της ενέργειας, η εξοικονόμηση θερμότητας μπορεί να συμβάλει σε βελτιωμένα επίπεδα άνεσης, μειωμένους λογαριασμούς ενέργειας και λιγότερα νοικοκυριά που βιώνουν τη φτώχεια καυσίμων.

Σήμερα, υπάρχουν πολλές μη καταστρεπτικές μέθοδοι και εργαλεία διαθέσιμα για την έρευνα σχετικά με τη χρήση ενέργειας, όπως η μέτρηση της ροής θερμότητας, η αυτόματη ανάγνωση μετρητών, οι δοκιμές στεγανότητας και οι υπολογιστικές προσομοιώσεις. Ως μια αναδυόμενη τεχνολογία στην κατασκευαστική βιομηχανία, η θερμογραφία αποτελεί ένα ακόμα εργαλείο που μπορεί να χρησιμοποιηθεί για τον εντοπισμό κοινών πηγών απώλειας θερμότητας σε υφιστάμενα και νέα κτίρια, όπως ο αερισμός και η αγωγιμότητα.

Συνολικά, η θερμογραφία αναδεικνύεται ως ένα χρήσιμο εργαλείο στα χέρια των μηχανικών για τη διάγνωση και την παρακολούθηση των ενεργειακών απωλειών και των προβλημάτων υγρασίας στα κτίρια. Με τη βοήθεια της θερμογραφίας, μπορούν να ληφθούν αποφάσεις για την αποδοτική χρήση ενέργειας και την εκτέλεση απαραίτητων βελτιώσεων στην θερμομόνωση και τη δομική ακεραιότητα των κτιρίων. Μέσω της ανάλυσης της θερμικής ακτινοβολίας, η θερμογραφία αποκαλύπτει προβλήματα και επιτρέπει στους μηχανικούς να λάβουν τα απαραίτητα μέτρα για τη βελτίωση της ενεργειακής απόδοσης και την αποτελεσματική διαχείριση της θερμότητας στα κτίρια. Με αυτόν τον τρόπο, η θερμογραφία συνεισφέρει στην επίτευξη πιο αποδοτικών, άνετων και ενεργειακά αποδοτικών κτιρίων, προσφέροντας οφέλη στους κατοίκους, το περιβάλλον και την οικονομία ενέργειας.

## 2.2 Εισαγωγή στη Θερμογραφία και την Υπέρυθρη Επιθεώρηση

Η θερμογραφία και η υπέρυθρη επιθεώρηση είναι τεχνικές που χρησιμοποιούν την υπέρυθρη ακτινοβολία για να ανιχνεύσουν και να απεικονίσουν θερμικές διαφορές σε υλικά και αντικείμενα. Βασίζονται στην αρχή ότι οι ατέλειες ή οι ανωμαλίες στα υλικά εμφανίζουν τοπικές διαφορές θερμοκρασίας, προκαλούμενες από τις διαφορετικές θερμικές ιδιότητες των περιοχών αυτών.

Για την ανίχνευση της θερμικής ακτινοβολίας που εκπέμπεται από την επιφάνεια ενός υλικού, χρησιμοποιείται η θερμοκάμερα. Η θερμοκάμερα, ως το βασικό εργαλείο που χρησιμοποιείται στη θερμογραφία, αποτελεί έναν εξελιγμένο θερμικό αισθητήρα με την ικανότητα να ανιχνεύει ακόμη και πολύ μικρές διαφορές θερμοκρασίας στην επιφάνεια των αντικειμένων [1]. Αυτός ο αισθητήρας μετατρέπει τη θερμική ενέργεια που εκπέμπεται από τα αντικείμενα σε οπτικό σήμα, το οποίο αναπαρίσταται σε μια εικόνα με χρωματική απόδοση.

Η χρωματική απόδοση της εικόνας επιτρέπει την εύκολη αντίληψη και μετάφραση των θερμικών διαφορών. Συνήθως, στις θερμοκάμερες χρησιμοποιείται μια χρωματική κλίμακα, όπου το μπλε αντιστοιχεί σε περιοχές με χαμηλότερη θερμοκρασία, ενώ το κόκκινο αντιπροσωπεύει περιοχές με υψηλότερη θερμοκρασία. Με αυτόν τον τρόπο, οι χρήστες μπορούν να αναγνωρίζουν αμέσως τις περιοχές με θερμικές ανωμαλίες ή προβλήματα σε μια εικόνα, καθιστώντας πιο ευανάγνωστη και κατανοητή την ανάλυση της θερμικής κατάστασης των αντικειμένων.

Η θερμογραφία μπορεί να χρησιμοποιηθεί με διάφορους τρόπους. Μπορεί να είναι παθητική, όπου απλώς καταγράφει τη θερμική ακτινοβολία που εκπέμπεται από το υλικό, ή ενεργή, όπου χρησιμοποιεί επιπρόσθετες πηγές θερμότητας, όπως θερμάστρες, για να προκαλέσει διαφορές θερμοκρασίας και να ανιχνεύσει ατέλειες με μεγαλύτερη ευκρίνεια.

Οι εικόνες που παράγονται από τη θερμογραφία, γνωστές και ως θερμογράφημα, μας επιτρέπουν να δούμε τις θερμικές απώλειες και τις ανωμαλίες σε ένα αντικείμενο. Χρησιμοποιώντας αυτές τις εικόνες, οι μηχανικοί μπορούν να διαγνώσουν προβλήματα, να προβλέψουν πιθανές βλάβες και να λάβουν μέτρα πρόληψης.

Συνοψίζοντας, η θερμογραφία και η υπέρυθρη επιθεώρηση είναι αποτελεσματικές τεχνικές που βασίζονται στην ανίχνευση και απεικόνιση θερμικών διαφορών σε υλικά και αντικείμενα. Με τη χρήση εξειδικευμένου εξοπλισμού, μπορούν να ανακαλυφθούν προβλήματα και ατέλειες που διαφεύγουν του ανθρώπινου ματιού, επιτρέποντας έτσι τη λήψη μέτρων για την αντιμετώπισή τους και την πρόληψη πιθανών προβλημάτων σε ποικίλους τομείς.

## 2.3 Θερμική ανάλυση

Η χρήση θερμικών καμερών έχει γίνει ένα βασικό εργαλείο στον κλάδο της ανίχνευσης ελαττωμάτων κτιρίων, χάρη στην ικανότητά τους να ανιχνεύουν και να αποτυπώνουν την υπέρυθρη ακτινοβολία, που

εκπέμπεται από την επιφάνεια αντικειμένων, σε θερμικές εικόνες [78]. Αυτό το εργαλείο αποδείχθηκε ως πολύτιμο στη γρήγορη ανίχνευση ελαττωμάτων, ειδικά σε περιπτώσεις όπου υπάρχει σημαντική διαφορά στη θερμότητα ή στη μεταφορά μάζας σε ένα υλικό ή κατασκευαστικό υλικό. Ένα από τα πλεονεκτήματα των σύγχρονων θερμικών καμερών είναι η ψηφιακή συλλογή εικόνων, η αξιολόγηση εντός της κάμερας, η μη επαφή, η πραγματικόχρονη λειτουργία και η δυνατότητα ανίχνευσης πολλών σημείων [79,80]. Όλα αυτά τα χαρακτηριστικά συνεισφέρουν στην αποτελεσματικότητα και την ευκολία χρήσης τους στην πρακτική χωρίς την ανάγκη για δαπανηρές και περιοριστικές φυσικές ερευνητικές εξετάσεις.

Ωστόσο, οι θερμικές κάμερες μετρούν την ακτινοβολία της επιφάνειας των αντικειμένων αντί της πραγματικής θερμοκρασίας τους. Αυτό συμβαίνει επειδή η θερμική ακτινοβολία που μετράται εξαρτάται από πολλούς παράγοντες, όπως η εκπομπή και η ανάκλαση της υπέρυθρης ακτινοβολίας, η επικάλυψη, η απορρόφηση και η μετάδοση της θερμότητας από το αντικείμενο.

Για τους θερμογράφους, η εμφανής θερμοκρασία που απεικονίζεται στην οθόνη της κάμερας είναι σημαντική. Αυτή η εμφανής θερμοκρασία αναφέρεται στη θερμοκρασία που φαίνεται στην κάμερα σε συγκεκριμένες συνθήκες της στιγμής. Είναι σημαντικό να σημειωθεί ότι η εμφανής θερμοκρασία αναφέρεται μόνο στην επιφάνεια του αντικειμένου που παρατηρείται από την κάμερα.

Οι παράγοντες που αναφέρθηκαν προηγουμένως μπορούν να δημιουργήσουν προκλήσεις στην ερμηνεία των θερμικών εικόνων. Οι αλλαγές στην εμφανή θερμοκρασία μπορούν να προκαλέσουν παρερμηνείες στα θερμικά μοτίβα και να δυσκολέψουν τον εντοπισμό ελαττωμάτων. Η αναγνώριση, η εντοπισμός και η κατηγοριοποίηση των ελαττωμάτων με βάση τα χαρακτηριστικά των μοτίβων τους αποτελούν ένα από τα πιο προκλητικά κομμάτια της θερμογραφίας.

Είναι σημαντικό να ληφθούν υπόψη οι επιρροές που μπορούν να επηρεάσουν την ποιότητα των θερμικών εικόνων. Οι κλιματικές συνθήκες, ο προσανατολισμός του αντικειμένου, καθώς και εσφαλμένες ρυθμίσεις της κάμερας, όπως η εκπομπή ή η ανακλαστική εμφανής θερμοκρασία, μπορούν να παράσχουν εσφαλμένες πληροφορίες και να επηρεάσουν την ερμηνεία των εικόνων.

Γενικά, για την αξιόπιστη ερμηνεία των θερμικών εικόνων, είναι σημαντικό να λαμβάνονται υπόψη οι παράγοντες που μπορεί να επηρεάσουν την εμφάνιση των θερμικών μοτίβων. Η εκπαίδευση και η εμπειρία είναι απαραίτητες για την αναγνώριση και τη σωστή ερμηνεία των θερμικών εικόνων, καθώς η παρερμηνεία μπορεί να οδηγήσει σε λανθασμένα συμπεράσματα και αναλύσεις. Οι ερευνητές Gonçalves et al. [82] και οι Brady [83] και Hart [81] υπογραμμίζουν την ανάγκη για προσοχή κατά την ερμηνεία των δεδομένων θερμογραφίας, ειδικότερα, για τον κίνδυνο υπερεξάρτησης από θερμικά μοτίβα και την επίδραση των ρυθμίσεων της κάμερας, όπως η εκπομπή ή η ανακλαστική εμφανής θερμοκρασία, στην ποιότητα των θερμικών εικόνων.

### 2.3.1 Τομείς θερμικής ανάλυσης

Η θερμική ανάλυση ενός αισθητήρα καθορίζει τη δυνατότητά του να εντοπίσει και να ανιχνεύσει ελαττώματα σε κτίρια, εκτός από τις επιστημονικές παραμέτρους. Σύμφωνα με τον Jensen [7], υπάρχουν τέσσερις βασικοί τομείς θερμικής ανάλυσης:

- **Φασματική ανάλυση:** Αναφέρεται στο εύρος των θερμοκρασιών που μπορεί να μετρήσει ο αισθητήρας. Οι κάμερες θερμογραφίας για την επιθεώρηση κτιρίων συνήθως χρησιμοποιούν φασματική ανάλυση με μακρύ κύμα υπέρυθρης ακτινοβολίας (8-14  $\mu\text{m}$ ) εντός του ηλεκτρομαγνητικού φάσματος. Αυτό το εύρος είναι λιγότερο επιρρεπές σε προβλήματα ανάκλασης από τον ήλιο [8].
- **Χωρική ανάλυση:** Αναφέρεται στον μικρότερο ανιχνεύσιμο στόχο που μπορεί να μετρήσει ο αισθητήρας [7]. Αν ο στόχος είναι πολύ μικρός, είναι πιθανό να μην ανιχνευθεί ή ο αισθητήρας να μην μπορεί να τον μετρήσει αρκετά ακριβώς [10]. Η χωρική ανάλυση επηρεάζεται από το μέγεθος του πίνακα των αισθητήρων, μεγαλύτερος αριθμός εικονοστοιχείων στον πίνακα οδηγεί σε βελτιωμένη χωρική ανάλυση [9]. Τυπικοί πίνακες αισθητήρων για κάμερες θερμογραφίας κατασκευαστικών έργων έχουν από 60x60 έως 640x480 εικονοστοιχεία.
- **Ακτινομετρική ανάλυση:** Αναφέρεται στη ελάχιστη θερμοκρασιακή διαφορά που μπορεί να αντιληφθεί από τα εικονοστοιχεία της κάμερας [12]. Είναι γνωστή και ως "θερμική ευαισθησία" και μετριέται με τον όρο "Θερμική Διαφορά Ισοδύναμου Θορύβου" (NETD) σε δεκαδικά τμήματα του βαθμού Κελσίου (mK) [13, 14]. Είναι σημαντικό να έχει μια υψηλή θερμική ευαισθησία (μικρή θερμική διαφορά ισοδύναμου θορύβου - NETD) για να ανιχνεύει ακριβώς τις μικρές θερμικές διαφορές. Συνήθως απαιτείται ένα NETD τουλάχιστον 100 mK για ικανοποιητική απόδοση του αισθητήρα [9].
- **Χρονική ανάλυση:** Σχετίζεται με τον ρυθμό ανανέωσης της εικόνας της κάμερας [7]. Ένας τυπικός ρυθμός καρέ είναι περίπου 25-30Hz, αλλά σε χαμηλότερες συχνότητες γίνεται δυσκολότερο να κρατηθεί η κάμερα σταθερή, με κίνδυνο δόνησης, θολώματος και μειωμένης ποιότητας εικόνας [12].

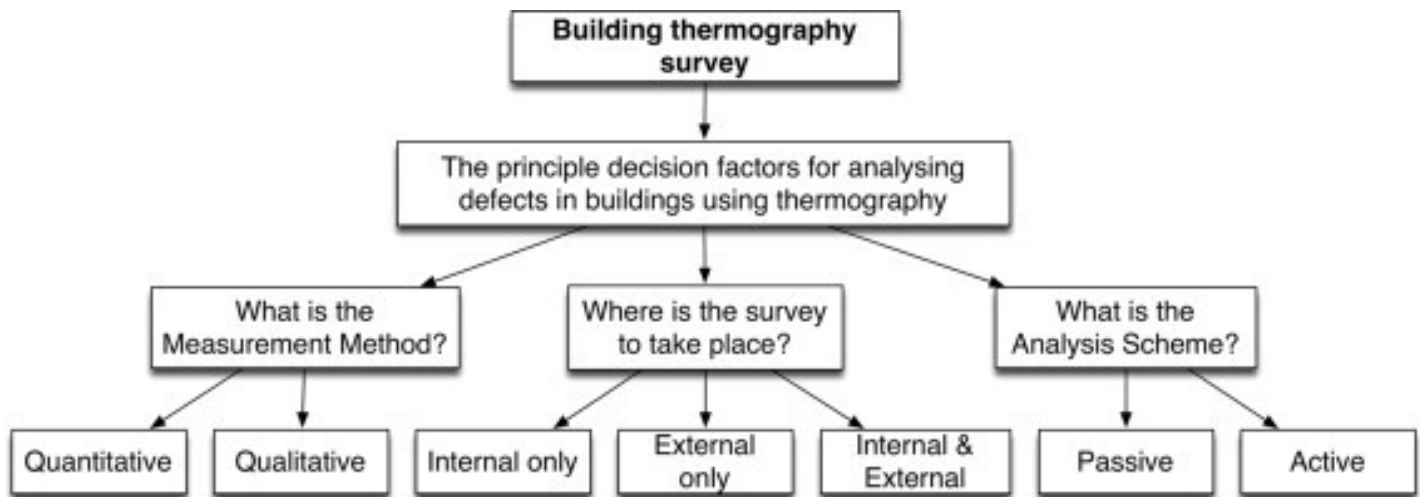
Οι δαπάνες αυξάνονται καθώς βελτιώνεται η θερμική ανάλυση [15]. Οι κάμερες θερμογραφίας με υψηλότερες προδιαγραφές έχουν συνήθως μεγαλύτερο κόστος. Κάμερες με χαμηλές προδιαγραφές (π.χ. 60x60 εικονοστοιχεία) μπορεί να είναι οικονομικότερες (κάτω από £1000) [16], αλλά μπορεί να είναι περιορισμένες στην επιθεώρηση μεγάλων κτιρίων λόγω των αποστάσεων και των επιπτώσεων της οπτικής διάχυσης [10]. Κάμερες που πληρούν τις συνιστώμενες ελάχιστες προδιαγραφές των



επαγγελματικών οργανισμών, όπως οι κάμερες μετρητής 640x480 εικονοστοιχεία και NETD τουλάχιστον 0,2 °C, μπορεί να κοστίζουν £5000 και άνω [8].

## 2.4 Προσδιορισμός μεθοδολογίας θερμογραφίας κτιρίων

Πριν από μια έρευνα θερμογραφίας κτιρίων, οι θερμογράφοι πρέπει πρώτα να αναρωτηθούν ποιες μέθοδοι θα χρησιμοποιήσουν για την ανάλυση, για την μέτρηση όπως και που θα λάβει χώρα. Αυτή η διαδικασία λήψης αποφάσεων θα διαμορφωθεί από τα ερωτήματα που προτείνονται στο σχήμα 1.



Σχήμα 2.1 Βασική διαδικασία λήψης αποφάσεων για τον προσδιορισμό της μεθοδολογίας θερμογραφίας κτιρίου.

### 2.4.1 Μέθοδοι ανάλυσης

Υπάρχουν δύο κύριες μέθοδοι ανάλυσης στη θερμογραφία κτιρίων: η παθητική και η ενεργή θερμογραφία.

#### Ενεργή θερμογραφία

Στην ενεργή θερμογραφία, ασκείται ένας εξωτερικός παράγοντας, όπως μια έκρηξη ή μια σταδιακή αύξηση της θερμότητας, στο παρατηρούμενο αντικείμενο [23, 24] . Αυτό δημιουργεί μια επίδραση στο υλικό, που μπορεί να βοηθήσει στον εντοπισμό κρυμμένων ελαττωμάτων ή ανωμαλιών [18, 19] . Η ενεργή θερμογραφία μπορεί να παρέχει πιο λεπτομερή εικόνα των υποεπιφανειακών ελαττωμάτων[21] , αλλά συνήθως απαιτεί προγνώση της ύπαρξης των ελαττωμάτων πριν από την ανάλυση.Επιπλέον, συνήθως επικεντρώνεται σε εξειδικευμένες περιοχές για λεπτομερή εξέταση, αντί για μια γενική επισκόπηση.υτό μπορεί να περιλαμβάνει ελλείψεις υλικού, στρεβλώσεις, συντρίμια ή άλλες ανωμαλίες που μπορεί να επηρεάζουν τη θερμική απόδοση του κτιρίου.

## Παθητική θερμογραφία

Στην παθητική θερμογραφία, το παρατηρούμενο αντικείμενο βρίσκεται στη φυσιολογική του κατάσταση θερμοκρασίας [20]. Η θερμική εικόνα αποτυπώνει τη θερμική εκπομπή των αντικειμένων χωρίς την επίδραση εξωτερικών παραγόντων. Αυτή η μέθοδος είναι χρήσιμη για τον εντοπισμό θερμικών ανωμαλιών σε ολόκληρο τον κτιριακό ιστό και αποκαλύπτει ενδείξεις πιθανών προβλημάτων στη θερμομόνωση, τις διαρροές αέρα και υγρασίας και τις ενεργειακές απώλειες.

Παρόλο που και οι δύο μέθοδοι έχουν τα πλεονεκτήματά τους, πρέπει να σημειωθεί ότι η παθητική θερμογραφία είναι ευρύτερα αποδεκτή για την καθολική ανάλυση των κτιριακών δομών, καθώς συνήθως προσφέρει μια γενική εικόνα χωρίς την ανάγκη προειδοποίησης για την ύπαρξη ελαττωμάτων. Η ενεργή θερμογραφία μπορεί να είναι χρήσιμη για τον εντοπισμό ελαττωμάτων υποεπιφάνειας, αλλά η παθητική θερμογραφία είναι πιο κατάλληλη για γενική επιθεώρηση και εντοπισμό ασυνήθιστων θερμικών σημείων. Ωστόσο, επειδή οι περισσότερες έρευνες θερμογραφίας κτιρίων παρατηρούν ολόκληρο τον κτιριακό ιστό, αναζητώντας άγνωστα ελαττώματα, χωρίς τη βοήθεια τεχνητού ερεθίσματος (εκτός από το εσωτερικό κλιματικό έλεγχο που συνήθως χαρακτηρίζει τη φυσιολογική συμπεριφορά των κατοίκων), θεωρείται [20, 25] ότι οι κανονικές έρευνες θερμογραφίας κτιρίων πραγματοποιούνται υπό παθητική μέθοδο.

### 2.4.2 Μέθοδοι μέτρησης

Οι προσεγγίσεις για την ανάλυση των θερμικών εικόνων που παράγονται από θερμογραφικές κάμερες διακρίνονται κυρίως σε δύο κατηγορίες: την ποιοτική και την ποσοτική ανάλυση.

Η ποιοτική ανάλυση στη θερμογραφία αποτελεί την οπτική αξιολόγηση των χρωματικών μοτίβων που εμφανίζονται στην θερμική εικόνα [10]. Τα χρωματικά αυτά μοτίβα αντιπροσωπεύουν τις διαφορές στην ακτινοβολία που μετράται από την θερμογραφική κάμερα. Οι θερμογράφοι πρέπει να μπορούν να αναγνωρίζουν τα διάφορα θερμικά μοτίβα που εμφανίζονται στις εικόνες και να αποφασίζουν εάν αυτά τα μοτίβα αντιστοιχούν σε πιθανά προβλήματα.

Από την άλλη πλευρά, η ποσοτική ανάλυση στη θερμογραφία προχωρά ένα βήμα παραπέρα από την ποιοτική ανάλυση, προσπαθώντας να αποκτήσει αριθμητικές τιμές από την θερμική εικόνα [8]. Κάθε εικονοστοιχείο (pixel) σε μια θερμική εικόνα μπορεί να παράγει μια υπολογίσιμη τιμή ακτινοβολίας, επιτρέποντας την ποσοτική ανάλυση. Αυτή η μέθοδος χρησιμοποιείται συχνά για την ανάλυση κτιρίων, συμπεριλαμβανομένης της εκτίμησης της θερμικής διαπερατότητας [26, 27].

Ωστόσο, αν και η ποσοτική ανάλυση μπορεί να φαίνεται ελκυστική για την εξαγωγή αριθμητικών δεδομένων, υπάρχουν πολλές προκλήσεις που συνδέονται με την ακρίβεια και την ερμηνεία των αποτελεσμάτων [28]. Σε πολλές περιπτώσεις, το περιβάλλον μεταβάλλεται και δεν παραμένει σε σταθερή κατάσταση, γεγονός που μπορεί να επηρεάσει τις μετρήσεις.

Συνεπώς, η θερμογραφία αποτελεί ένα πολύτιμο εργαλείο για την ανίχνευση και την ανάλυση θερμικών διαφορών, αλλά η χρήση της πρέπει να γίνεται με κατανόηση των περιορισμών και των

προκλήσεων που εμπεριέχει. Και η ποιοτική και η ποσοτική ανάλυση έχουν τη θέση τους στην εργαλειοθήκη του θερμογράφου, αλλά η επιλογή της σωστής μεθόδου εξαρτάται από την εφαρμογή και το περιβάλλον που εξετάζεται.

### 2.4.3 Τοποθεσία

Η εφαρμογή της μπορεί να γίνει τόσο εξωτερικά όσο και εσωτερικά, με κάθε προσέγγιση να έχει τα δικά της πλεονεκτήματα και αναπτύξεις.

Η εξωτερική θερμογραφία πραγματοποιείται στον εξωτερικό χώρο του κτιρίου και είναι ιδιαίτερα ευάλωτη στις κλιματικές συνθήκες, περιλαμβάνοντας την θερμοκρασία, την υγρασία και την ηλιοφάνεια [29]. Αυτές οι συνθήκες μπορεί να επηρεάσουν τα αποτελέσματα της θερμογραφίας, δημιουργώντας πιθανές ανακρίβειες.

Από την άλλη πλευρά, η εσωτερική θερμογραφία παρέχει ένα πιο ελεγχόμενο περιβάλλον για την θερμογραφία. Αυτό επειδή οι εσωτερικοί χώροι των κτιρίων δεν εκτίθενται τόσο άμεσα στις αλλαγές του κλίματος, επιτρέποντας την παρατήρηση των θερμικών στοιχείων με λιγότερη παρεμβολή [29]. Ωστόσο, η εσωτερική θερμογραφία απαιτεί την άδεια των κατοίκων για την πρόσβαση σε συγκεκριμένα μέρη του κτιρίου και χαρακτηριστικά όπως βιβλιοθήκες και εικόνες μπορεί να επηρεάσουν τη δυνατότητα απόκτησης χρήσιμων θερμικών εικόνων.

Παρόλα αυτά, οι ειδικοί συμβουλεύουν ότι οι περιοχές απώλειας θερμότητας που παρατηρούνται εξωτερικά μπορεί να είναι πιο ευδιάκριτες κατά την εσωτερική θερμογραφία [25]. Αυτό είναι ιδιαίτερα σημαντικό για την ενεργειακή αξιολόγηση, καθώς η ικανότητα ανίχνευσης και αντιμετώπισης των σημείων απώλειας θερμότητας μπορεί να επιφέρει σημαντικές εξοικονομήσεις ενέργειας.

## 2.5 Εντοπίσιμα ελαττώματα

Η θερμογραφία κτιρίων είναι μια τεχνική που χρησιμοποιείται για τον έλεγχο της θερμικής απόδοσης και την ανίχνευση ελαττωμάτων σε κτίρια. Υπάρχουν δύο κύριες εφαρμογές της θερμογραφίας κτιρίων: εκτιμήσεις υφιστάμενων κτιρίων και έλεγχος ποιότητας νέων κατασκευών/ανακαινίσεων [12]. Στις εκτιμήσεις υφιστάμενων κτιρίων, η θερμογραφία κτιρίων χρησιμοποιείται για την αναγνώριση διαφόρων ενεργειακών ελαττωμάτων και πτυχών απόδοσης. Ορισμένες από αυτές τις αναγνωρίσεις περιλαμβάνουν:

- **Απώλειες αερισμού:** Οι απώλειες αερισμού αποτελούν σημαντικό μέρος της ενεργειακής κατανάλωσης ενός κτιρίου. Η θερμογραφία μπορεί να χρησιμοποιηθεί για τον εντοπισμό των περιοχών διαρροής αέρα γύρω από παράθυρα, πόρτες και συνδέσεις, καθώς και για τον έλεγχο της ποιότητας της μόνωσης σε αυτά.
- **Έλεγχος μόνωσης και εντοπισμός θερμικών γεφυρών:** Η θερμογραφία μπορεί να χρησιμοποιηθεί για τον έλεγχο της μόνωσης των κατασκευαστικών στοιχείων, όπως τοίχοι και

στέγες, και για τον εντοπισμό θερμικών γεφυρών, που συνήθως εμφανίζονται σε σημεία σύνδεσης και γωνίες.

- **Ελαττωματικές υπηρεσίες:** Η θερμογραφία μπορεί να χρησιμοποιηθεί για τον εντοπισμό θαμμένων ή ελαττωματικών υπηρεσιών σε παλιά κτίρια, όταν δεν υπάρχει επαρκής τεκμηρίωση π.χ κρυμμένες διαρροές νερού, κακής ποιότητας ή φθαρμένα ηλεκτρικά καλώδια κ.λ.π [31] .
- **Εισροή υγρασίας:** Η διείσδυση και η ανάβαση της υγρασίας, συνήθως από το εξωτερικό περιβάλλον ενός κτιρίου, μπορεί να προκαλέσει υγρασία σε μέρη του κτιριακού ιστού ή στον χώρο διαβίωσης [33]. Καθώς η υγρασία διέρχεται μέσω υλικών, η εισροή υγρασίας μπορεί να καταστρέψει τα υλικά [34] και να επηρεάσει την θερμική απόδοση του κτιρίου. Τομείς με χαμηλότερη θερμική αγωγιμότητα και ανεπιθύμητες διαρροές αέρα [32] μπορεί να προκαλέσουν συμπύκνωση υγρασίας και ανάπτυξη μούχλας, επηρεάζοντας την απόδοση του υλικού και τη συνολική διάρκεια ζωής του κτιρίου. Η θερμογραφία μπορεί να αναγνωρίσει τον βαθμό κινδύνου επιφανειακής υγρασίας, έναν τομέα εντοπισμού υγρασίας που είναι ιδιαίτερα σημαντικός [30].
- **Δομικά ελαττώματα:** Η ανίχνευση δομικών ελαττωμάτων, όπως ρωγμές στο σκυρόδεμα, διαρροές [8], μέσω θερμογραφίας, μπορεί να βοηθήσει στον περιορισμό επιπλέον ελαττωμάτων που μπορούν να αυξήσουν τις απώλειες ενέργειας

## 2.6 Μεθοδολογίες θερμογραφίας παθητικής κτιριακής εφαρμογής

Οι επτά μεθοδολογίες για την εφαρμογή παθητικής θερμογραφίας στα κτίρια για την ανίχνευση ελαττωμάτων μπορούν να οργανωθούν από την πιο γρήγορη στην πιο αργή μεθοδολογία ως εξής :

- Aerial surveys
- Automated fly-past surveys
- Street pass-by surveys
- Traditional perimeter walk around surveys (External only)
- Traditional walk through surveys (Internal and external)
- Repeat surveys
- Time-lapse surveys

### 2.6.1 Aerial surveys/Εναέριες έρευνες

Η αεροθερμογραφία αποτελεί μια ευρέως δοκιμασμένη μεθοδολογία, με σημαντική πρόοδο σημειωμένη τη δεκαετία του 1980 [26, 37-40]. Στην πραγματικότητα, η αεροθερμογραφία χρησιμοποιεί τεχνολογία θερμικής κάμερας, η οποία εγκαθίσταται σε αεροπλάνο ή ελικόπτερο και

καταγράφει θερμικές εικόνες καθώς πετά πάνω από την περιοχή που εξετάζεται [41]. Στόχος της αεροθερμογραφίας είναι η αποτίμηση των θερμικών απωλειών των κτιρίων, ειδικά μέσω των στεγών τους.

Η χρήση αεροπλάνων ή ελικοπτέρων επιτρέπει στην έρευνα να καλύψει μεγάλες εκτάσεις και πολλά κτίρια, όμως η χωρική ανάλυση των κανονικών θερμικών καμερών μπορεί να είναι ανεπαρκής, καθώς τα αεροσκάφη πρέπει να πετούν σε υψόμετρα 1200 - 1500 πόδια [41]. Σε αυτές τις περιπτώσεις, προτιμώνται πιο εξειδικευμένες κάμερες ή σαρωτές γραμμής, παρόλο που επιφέρουν μεγαλύτερο κόστος [42, 43].

Τα πλεονεκτήματα της αεροθερμογραφίας περιλαμβάνουν την ευρεία κάλυψη, την ταχεία συλλογή δεδομένων και τη δυνατότητα εντοπισμού προβλημάτων χωρίς ανάγκη πρόσβασης στα κτίρια, καθώς και τη δυνατότητα εντοπισμού προβλημάτων σε μεγάλα κτίρια με πιο αποτελεσματικό τρόπο [44] [44]. Επίσης, η αεροθερμογραφία έχει χρησιμοποιηθεί επιτυχώς για την ανίχνευση υγρασίας σε επίπεδες στέγες [45].

Ωστόσο, παρά τα προνόμια της, η αεροθερμογραφία παρουσιάζει και συγκεκριμένες προκλήσεις. Πολλοί παράγοντες, όπως η μορφή και η κλίση της στέγης, η θολούρα της εικόνας, οι εσωτερικές θερμοκρασίες, το κλίμα και η εκπομπή ακτινοβολίας, μπορούν να επηρεάσουν την αξιολόγηση των δεδομένων [15, 43]. Επιπλέον, η αεροθερμογραφία δεν επαρκεί για την ανίχνευση ελαττωμάτων σε τοίχους ή κουφώματα, πράγμα που οφείλεται στο ύψος και στην γωνία παρατήρησης από το αεροπλάνο προς το κτίριο

## **2.6.2 Automated fly-past surveys/Αυτόματες έρευνες περιπολίας από αεροσκάφος**

Η αεροθερμογραφία κτιρίων έχει γνωρίσει μια πιο πρόσφατη εξέλιξη με τη χρήση αυτόματων αεροσκαφών χωρίς πλήρωμα (UAV). Η συνδυασμένη χρήση θερμικών καμερών και τεχνολογίας UAV παρέχει ευκαιρίες για απομακρυσμένες και αυτόματες αεροερευνητικές δυνατότητες, επιτρέποντας την ευκολότερη πρόσβαση σε μη προσπελάσιμες ή δυνητικά επικίνδυνες περιοχές [46].

Μια ερευνητική εργασία που πραγματοποιήθηκε από τους Martínez-de Dios και Ollero [47] εξέτασε τη χρήση της παθητικής αεροθερμογραφίας κτιρίων με UAV για την ανίχνευση απώλειας θερμότητας από τα παράθυρα. Ωστόσο, παρά τις προσπάθειες επίλυσης γνωστών προβλημάτων σταθεροποίησης της εικόνας, οι δονήσεις από τις προπέλες του UAV απειλούσαν τη χωρική ανάλυση. Η σταθερότητα των UAV αποτελεί ένα από τα σημαντικότερα τεχνικά ζητήματα αυτής της μεθοδολογίας, καθώς οι επιδράσεις από τον άνεμο μπορούν επίσης να οδηγήσουν σε θολές εικόνες [48].

Παρά τους περιορισμούς που υπάρχουν, υπάρχει μεγάλη δυνατότητα για την εφαρμογή της μεθοδολογίας της παθητικής αεροθερμογραφίας κτιρίων με τη χρήση UAV. Η χρήση μιας θερμικής κάμερας που στερεώνεται σε ένα UAV μπορεί να προσφέρει καλύτερη γωνία θέασης προς ψηλά κτίρια και στέγες σε σύγκριση με τις υπάρχουσες ερευνητικές εργασίες που γίνονται σε επίπεδο εδάφους.

Αυτό είναι ιδιαίτερα σημαντικό, καθώς ένα UAV μπορεί να μετακινηθεί για να βελτιώσει τη γωνία θέασης και να μειώσει τις επιδράσεις της στην αντιλαμβανόμενη εικόνα. Επιπλέον, τα UAV μπορούν να πλησιάσουν πιο κοντά στον στόχο από ό,τι άλλα αεροσκάφη ή προσωπικό, βοηθώντας στην αύξηση της χωρικής ανάλυσης των ελαττωμάτων. Ερευνητές, όπως ο Eschmann και συνεργάτες [48], έχουν προτείνει τρόπους με τους οποίους τα UAV μπορούν να τεθούν σε αυτόματη πορεία πτήσης. Οι εικόνες που καταγράφονται μπορούν να συνδυαστούν αργότερα για τη δημιουργία μιας πιο αναλυτικής θερμικής εικόνας, αυξάνοντας έτσι τη χωρική ανάλυση σε σύγκριση με μια μεμονωμένη εικόνα.

Παράλληλα, υπάρχουν κάποιοι περιορισμοί που περιορίζουν την ευρεία χρήση της παθητικής αεροθερμογραφίας κτιρίων με UAV. Οι περιορισμοί αυτοί περιλαμβάνουν το κόστος του εξοπλισμού, με τα βασικά UAV να ξεκινούν από περίπου 1.500 λίρες [49], καθώς και τους περιορισμούς των αδειών [50]. Για παράδειγμα, η Αρχή Πολιτικής Αεροπορίας (CAA) έχει θεσπίσει κανονισμούς που ελέγχουν προσεκτικά τη χρήση μη επανδρωμένων αεροσκαφών παρακολούθησης. Απαιτείται άδεια από την CAA για την πτήση ενός μικρού μη επανδρωμένου αεροσκάφους για σκοπούς αεροπορικών εργασιών, για την πτήση πάνω από ή κοντά σε συνωστισμένες περιοχές ή χώρους συνάθροισης πολλών ατόμων, καθώς και για την πτήση σε απόσταση 50 μέτρων από ένα άτομο [50]. Επιπλέον, υπάρχουν περιορισμοί όπως η μέγιστη απόσταση πτήσης από το έδαφος (400 μέτρα), η ανάγκη εξασφάλισης ασφαλούς πτήσης από τον πιλότο και η απευθείας οπτική επαφή με το αεροσκάφος κατά τη διάρκεια της πτήσης.

Συνοψίζοντας, η εφαρμογή της παθητικής αεροθερμογραφίας κτιρίων με τη χρήση UAV προσφέρει σημαντικά πλεονεκτήματα, όπως βελτιωμένη γωνία θέασης, αυξημένη χωρική ανάλυση και απομακρυσμένη πρόσβαση σε δυσπρόσιτες περιοχές. Παρόλα αυτά, οι περιορισμοί σε θέματα κόστους εξοπλισμού και άδειας παραμένουν προκλήσεις που πρέπει να αντιμετωπιστούν για την ευρύτερη υιοθέτηση αυτής της μεθοδολογίας.

### **2.6.3 Street pass-by surveys/ Έρευνες διέλευσης από τους δρόμους**

Η εισαγωγή του Google Street View το 2007 ενέπνευσε ερευνητές και επαγγελματίες στον τομέα της θερμογραφίας κτιρίων να εξετάσουν τη χρήση μιας παρόμοιας μεθοδολογίας "παρελαύνοντας" για τη θερμογραφία κτιρίων [52]. Οι μεθοδολογίες παρελαύνοντας έχουν ως στόχο την επιτάχυνση της θερμογραφικής ανάλυσης κτιρίων. Ωστόσο, υπάρχουν ειδικοί που προειδοποιούν για τα περιορισμένα αποτελέσματα που μπορούν να προκύψουν από αυτήν τη μεθοδολογία. Περιορισμοί περιλαμβάνουν μεταβολές στην εκπομπή θερμότητας καθώς ο φωτισμός, η ηλιακή ακτινοβολία και άλλες πηγές θερμότητας μπορούν να επηρεάσουν τα αποτελέσματα της θερμογραφικής ανάλυσης, αφού επηρεάζουν τις θερμοκρασίες που καταγράφονται στο κτίριο, αλλαγές στη γωνία θέασης, η διαφορετική θερμική μάζα των υλικών στην κατασκευή του κτιρίου μπορεί να προκαλέσει διαφορετικές θερμοκρασίες σε διαφορετικά σημεία του κτιρίου και άγνωστες συνήθειες κατοίκησης που μπορεί να προκαλούν διαφορετικές εσωτερικές θερμοκρασίες. Επιπλέον, η μεθοδολογία

παρελαύνοντας φαίνεται να καταγράφει μόνο μία πλευρά του κτιρίου, περιορίζοντας την πληροφορία που μπορεί να αποκομίσει για το σύνολο της κατοικίας.

Παρά τις προειδοποιήσεις, η μεθοδολογία παρελαύνοντας μπορεί να είναι χρήσιμη για τον γρήγορο εντοπισμό συγκεκριμένων ελαττωμάτων, όπως η απώλεια αερισμού και μόνωσης σε ένα κτίριο [53].

#### **2.6.4 Παραδοσιακή παθητική θερμογραφία κτιρίων**

Υπάρχουν δύο επίπεδα έρευνας παθητικής θερμογραφίας κτιρίων που συνήθως χρησιμοποιούν οι επαγγελματίες θερμογράφοι κτιρίων: η περιήγηση γύρω από το κτίριο και η περιήγηση μέσα και έξω από αυτό. Λόγω της ευρείας χρήσης τους, αναφέρονται σε αυτό το άρθρο ως "παραδοσιακές" μεθοδολογίες παθητικής θερμογραφίας κτιρίων. Και οι δύο μορφές παραδοσιακής παθητικής θερμογραφίας περιλαμβάνουν την απόκτηση πολλαπλών εικόνων από γύρω από το κτίριο, καταγράφοντας συγκεκριμένα ενδιαφέροντα σημεία. Οι θερμογράφοι συνήθως συντάσσουν αναφορές [8], οι οποίες πρέπει να περιλαμβάνουν πληροφορίες για τα κατασκευαστικά χαρακτηριστικά και τις κλιματικές συνθήκες που καταγράφονται κατά τη διάρκεια και πριν από την πραγματοποίηση της έρευνας [28].

#### **Περιήγηση γύρω από το κτίριο (μόνο εξωτερικά)/Perimeter Walk Around Surveys (External only)**

Η περιήγηση γύρω από το κτίριο, γνωστή και ως "Perimeter Walk Around Surveys" (εξωτερική έρευνα), αφορά την απαθανάτιση εικόνων μόνο από το εξωτερικό μέρος του κτιρίου. Αυτή η μέθοδος επιτρέπει στον θερμογράφο να επισκεφθεί και να εξετάσει κάθε εξωτερική πλευρά του κτιρίου. Η περιήγηση γύρω από το κτίριο είναι συνήθως πιο γρήγορη και οικονομική από την περιήγηση μέσα και έξω από το κτίριο [61]. Ωστόσο, με αυτήν τη μέθοδο δεν είναι δυνατή η ανίχνευση προβλημάτων που αφορούν το εσωτερικό του κτιρίου, όπως προβλήματα μόνωσης στη σοφίτα. Επιπλέον, η εξωτερική θερμογραφία μπορεί να επηρεαστεί από κλιματικές συνθήκες, δηλαδή οι διαφορετικές προσανατολίσεις της πρόσοψης θα παράσχουν διαφορετικά αποτελέσματα ανάλογα με την έκθεση στον ήλιο, τον άνεμο ή την υγρασία [9,24]. Υπάρχουν όμως και μερικά ελαττώματα που δεν μπορούν να ανιχνευθούν μόνο με αυτήν τη μεθοδολογία. Ένα παράδειγμα είναι ο έλεγχος της μόνωσης της σοφίτας, όπου λόγω της γωνίας θέασης από το επίπεδο του δρόμου προς την κεκλιμένη στέγη, τα ελαττώματα της μόνωσης δεν είναι πάντα ανιχνεύσιμα [63].

#### **Περιήγηση μέσα και έξω από το κτίριο/ Walk Through Surveys (Internal and External)**

Η περιήγηση μέσα και έξω από το κτίριο, γνωστή και ως "Walk Through Surveys" (εσωτερική και εξωτερική έρευνα), αποτελεί μια πιο αναλυτική μέθοδο επιθεώρησης [25]. Ο θερμογράφος καταγράφει εικόνες τόσο από το εσωτερικό όσο και από το εξωτερικό μέρος του κτιρίου, παρέχοντας μια πιο πλήρη εικόνα των θερμικών ελαττωμάτων και προβλημάτων, καταγράφοντας πιθανά ελαττώματα από διάφορες γωνίες [64]. Αυτή η μέθοδος απαιτεί περισσότερο χρόνο και πόρους συγκριτικά με την απλή

εξωτερική έρευνα, λόγω των πολλών δωματίων, τοίχων και δαπέδων που μπορεί να απαιτούν εικονοληψία [63]. Ωστόσο, η εσωτερική καταγραφή επιτρέπει την ανίχνευση προβλημάτων που αφορούν το εσωτερικό του κτιρίου και ενισχύει την αξιολόγηση που προκύπτει από την εξωτερική θερμογραφία, μπορεί να υποστηριχθεί ότι η εξωτερική θερμογραφία πρέπει να πραγματοποιείται πρώτα για να παράσχει μια επισκόπηση για περαιτέρω λεπτομερείς εσωτερικές θερμογραφίες [9, 11, 61, 64].

### **2.6.5 Επαναλαμβανόμενες έρευνες/Repeat Surveys**

Οι κτιριακές δομές διαβρώνονται με τον χρόνο. Αυτή η διάβρωση ή υποβάθμιση μπορεί να διαφέρει ανάλογα με μια πληθώρα παραγόντων, όπως τις προδιαγραφές του υλικού, την τοποθεσία, την επίδραση του κλίματος, τη ρύπανση, τις λεπτομέρειες της κατασκευής και τη συντήρηση [4, 66].

Αυτός ο παράγοντας διάβρωσης προκαλεί μεγάλο ενδιαφέρον, καθώς προκαλεί ελαττώματα που μπορούν να επιδράσουν αρνητικά στην απόδοση των κτιρίων. Προκειμένου να αντιμετωπιστεί αυτό το πρόβλημα, οι επιστήμονες έχουν αρχίσει να χρησιμοποιούν την επαναλαμβανόμενη θερμογραφία ως μέσο παρακολούθησης της απόδοσης των κτιρίων και του έγκαιρου εντοπισμού πιθανών ελαττωμάτων [67].

Ένα σημαντικό πεδίο εφαρμογής της επαναλαμβανόμενης θερμογραφίας είναι η παρακολούθηση των αεροστεγών και υπερμονωμένων κτιρίων. Σε αυτά τα κτίρια, η διάβρωση της μόνωσης ή η ζημιά της σφράγισης μπορεί να επηρεάσουν σημαντικά την ενεργειακή κατανάλωση της κατοικίας, δεδομένων των προηγούμενων υποδείξεων ότι οι απώλειες από εξαερισμό μπορεί να αντιστοιχούν σε περισσότερο από το ήμισυ της ενεργειακής κατανάλωσης ενός κτιρίου.[49]. Άλλη σημαντική χρήση της επαναλαμβανόμενης θερμογραφίας είναι ο έλεγχος της υγρασίας της στέγης [68, 69].

Ακόμη, η επαναλαμβανόμενη θερμογραφία μπορεί να χρησιμοποιηθεί για την εντοπισμό προβληματικών περιοχών στα κτίρια πριν και μετά τις επισκευές, αξιολογώντας την αποτελεσματικότητα των επισκευών [8, 70].

Η επαναληπτική θερμογραφία προσφέρει μια εξαιρετικά χρήσιμη μέθοδο για την παρακολούθηση και τη βελτίωση της ποιότητας των κτιρίων. Είναι ιδιαίτερα πολύτιμο τόσο για την κατασκευή νέων κτιρίων όσο και για την ανακαίνιση παλαιών, επιτρέποντας την αξιολόγηση της κατασκευαστικής αποτελεσματικότητας και των πρακτικών συντήρησης.

### **2.6.6 Έρευνες σε χρονοληπτική ακολουθία / Time-Lapse Surveys**

Η παθητική θερμογραφία είναι μια προηγμένη μέθοδος που επιτρέπει την αναλυτική εξέταση της θερμικής απώλειας σε κτιριακές κατασκευές. Συνήθως αποτυπώνει μια σταθερή αντίληψη της θερμικής απώλειας, διευκολύνοντας την αξιολόγηση της θερμικής ροής μέσα από την κατασκευή μέσω



σταθερών θερμοκρασιακών διαφορών [15]. Ωστόσο, αυτή η προσέγγιση μπορεί να οδηγήσει σε παρανοήσεις, καθώς οι συνθήκες εσωτερικού και εξωτερικού δεν είναι πάντα σταθερές.

Μεταβαλλόμενες συνθήκες, όπως η υγρασία στους τοίχους η οποία μπορεί να προκαλέσει ζημιά και να μειώσει την συνολική απόδοση της κατασκευής [73] ή η θερμότητα που αποθηκεύεται στα θερμικά μαζικά κτιριακά στοιχεία, μπορεί να προκαλέσουν αλλαγές στις ιδιότητες των υλικών [15]. Αυτές οι παροδικές συνθήκες δεν είναι πάντα ορατές στις στιγμιαίες θερμικές εικόνες που παράγει η θερμογραφία [25], λόγω των μεγάλων χρονικών κλιμάκων που απαιτούνται για ορισμένες περιβαλλοντικές αλλαγές. Ωστόσο, η πρακτική της λήψης στιγμιαίων εικόνων παραμένει ευρέως διαδεδομένη, με τις παροδικές κλιματικές αλλαγές να αγνοούνται συχνά [8,23,75].

Η αδυναμία αυτή να εκλάβει πλήρως τις παροδικές συνθήκες μπορεί να επηρεάσει αρνητικά την ανίχνευση των ελαττωμάτων, ιδιαίτερα σε βαριά κτίρια, τα οποία απαιτούν περίπου 24 ώρες χωρίς ηλιακή ακτινοβολία για μια ακριβή θερμογραφική έρευνα [35].

Ορισμένες σύγχρονες θερμικές κάμερες ενσωματώνουν λειτουργίες εγγραφής βίντεο και χρονοληπτικής ακολουθίας εικόνων, επιτρέποντας την παρατήρηση των αλλαγών στην κατάσταση της επιφάνειας των υλικών σε διάστημα δευτερολέπτων, λεπτών ή ωρών [21,74]. Παρόλο που οι χρονοληπτικές έρευνες παθητικής θερμογραφίας επιδιώκουν να ποσοτικοποιήσουν την απόδοση, παραμένει ανοιχτό το ζήτημα της ικανότητάς τους να αναλύσουν πλήρως την δυναμική συμπεριφορά των κτιριακών στοιχείων υπό διάφορες συνθήκες. Είναι δύσκολο να διεξαχθούν εκτενείς μελέτες που να λαμβάνουν υπόψη ολόκληρο το φάσμα των δυνατών περιβαλλοντικών συνθηκών και των διαφορετικών τύπων κτιρίων και κατασκευαστικών υλικών. Επιπλέον, η θερμογραφία εξακολουθεί να είναι μια τεχνολογία που βασίζεται σε οπτικές εκτιμήσεις και ερμηνείες, οι οποίες μπορεί να διαφέρουν ανάλογα με την εμπειρία και την κατάρτιση του χρήστη.

## 2.7 Η Κάμερα της Ερευνητικής Μου Εργασίας: Περιγραφή και Χαρακτηριστικά



Εικόνα 2.2 Longwave Infrared Thermal Camera Module Tau 2

Το μοντέλο Tau 640, με φακό 50 mm f/1.2, κατασκευάζεται στις ΗΠΑ και προσφέρει μια σειρά από χαρακτηριστικά που την καθιστούν ιδανική για πολύπλοκες και απαιτητικές εφαρμογές.

Αυτή η κάμερα προσφέρει έναν απaráμιλλο συνδυασμό αξιοπιστίας και χαρακτηριστικών, καθιστώντας την κατάλληλη για δύσκολες καταστάσεις, όπως την επισκόπηση με μη επανδρωμένα οχήματα, τα θερμικά σκοπευτικά και τις φορητές συσκευές απεικόνισης. Τα βελτιωμένα της ηλεκτρονικά συστήματα παρέχουν ισχυρές λειτουργίες επεξεργασίας εικόνας που βελτιώνουν δραματικά τη λεπτομέρεια και την αντίθεση μέσω της συνεχούς εξισορρόπησης ιστογράμματος.

Η ραδιομετρία της Tau 2 είναι διαθέσιμη σε κάθε pixel για αναλύσεις  $640 \times 512$  και  $336 \times 256$ , προσφέροντας μια ακρίβεια και λεπτομέρεια ανεπανάληπτη για την κατηγορία της. Διατίθεται σε εμπορικές, επιδόσεις και βιομηχανικές παραλλαγές, καθεμία με μοναδικά όρια ευαισθησίας και λειτουργικότητας pixel για την κάλυψη λειτουργικών απαιτήσεων. Η ενσωματωμένη ραδιομετρία είναι μια προαιρετική δυνατότητα για τις κάμερες ποιότητας απόδοσης, αλλά τυπική για τις βιομηχανικές εκδοχές της.

Όλες οι διαμορφώσεις Tau 2 μοιράζονται ηλεκτρικές, μηχανικές και οπτικές διεπαφές που επιτρέπουν τη σχεδίαση ενσωματώσεων που λειτουργούν απρόσκοπτα με όλες τις μορφές [84].

Feature	Specification
IR Resolution	640 × 480 (NTSC); 640 × 512 (PAL)
Pixel Size	17 μm
Frame Rate Options	30/60 Hz (NTSC) 25/50 Hz (PAL)
Thermal Sensitivity/NETD	Industrial: <30mK Performance: <50 mK Commercial: <60mK
Scene Temperature Range	-25°C to +100°C -40°C to +550°C
Temperature Measurement	Improved accuracy, moveable spot meter, image metric data, T-Linear (digital output) AR requires a separate calibration that must be performed during camera manufacture. The AR capability is captured in the camera part number. An additional fee is charged for this feature.

**Ανάλυση υπερύθρων (640 × 480 για NTSC, 640 × 512 για PAL):** Αυτό αναφέρεται στην ανάλυση της κάμερας υπερύθρων. Η υψηλότερη ανάλυση παρέχει συνήθως μια πιο λεπτομερή θερμική εικόνα, βοηθώντας στον ακριβέστερο εντοπισμό και τη διάγνωση προβλημάτων. Η ανάλυση εδώ είναι αρκετά καλή για μια θερμική κάμερα, επιτρέποντας λεπτομερείς εικόνες.

**Μέγεθος pixel (17  $\mu\text{m}$ ):** Αυτό είναι το μέγεθος των pixel στον αισθητήρα της κάμερας. Τα μικρότερα μεγέθη pixel συνήθως επιτρέπουν υψηλότερη ανάλυση στο ίδιο μέγεθος αισθητήρα. Ένα μέγεθος pixel 17 μικρομέτρων είναι αρκετά τυπικό για θερμικές κάμερες και μπορεί να προσφέρει καλή ποιότητα εικόνας.

**Επιλογές ρυθμού καρέ (30/60 Hz για NTSC, 25/50 Hz για PAL):** Αυτό αναφέρεται στο πόσα καρέ ανά δευτερόλεπτο μπορεί να εγγράψει η κάμερα. Οι υψηλότεροι ρυθμοί καρέ μπορούν να αποτυπώσουν πιο καθαρά αντικείμενα που κινούνται γρήγορα. Οι τιμές που παρέχονται εδώ είναι τυπικές για εγγραφή βίντεο και θα πρέπει να είναι περισσότερο από επαρκείς για τις περισσότερες βιομηχανικές ή εμπορικές χρήσεις. Οι επιλογές για την περιοχή NTSC είναι 30/60 καρέ ανά δευτερόλεπτο, ενώ για την περιοχή PAL είναι 25/50 καρέ ανά δευτερόλεπτο.

**Θερμική ευαισθησία/NETD (Βιομηχανική: <30mK, Απόδοση: <50 mK, Εμπορική: <60mK):** Η διαφορά θερμοκρασίας ισοδύναμου θορύβου (NETD) είναι ένα μέτρο του πόσο καλά ένας ανιχνευτής θερμικής απεικόνισης μπορεί να διακρίνει μεταξύ πολύ μικρών διαφορών στη θερμική ακτινοβολία στην εικόνα. Οι χαμηλότερες τιμές σημαίνουν ότι η κάμερα μπορεί να ανιχνεύσει μικρότερες διαφορές στη θερμοκρασία, παρέχοντας μια πιο ακριβή και ευαίσθητη εικόνα. Οι τιμές εδώ υποδεικνύουν καλή θερμική ευαισθησία, ειδικά στη Βιομηχανική ρύθμιση.

**Εύρος θερμοκρασίας σκηνής (-25°C έως +100°C, -40°C έως +550°C):** Αυτό είναι το εύρος θερμοκρασιών που μπορεί να μετρήσει με ακρίβεια η κάμερα. Το δεδομένο εύρος είναι αρκετά μεγάλο, υποδηλώνοντας ότι η κάμερα μπορεί να χρησιμοποιηθεί σε διάφορα περιβάλλοντα, από κρύο έως πολύ ζεστό, κάτι που είναι καλό.

**Μέτρηση θερμοκρασίας:** Η κάμερα παρέχει βελτιωμένη ακρίβεια στη μέτρηση θερμοκρασίας. Έχει επίσης δυνατότητες όπως κινούμενος μετρητής σημείου, μετρήσεις μετρικών δεδομένων εικόνας και T-Linear (ψηφιακή έξοδο). Η AR (Επαυξημένη Πραγματικότητα) απαιτεί ξεχωριστή βαθμονόμηση που πρέπει να γίνει κατά την κατασκευή της κάμερας. Η δυνατότητα AR καθορίζεται από τον αριθμό μοντέλου της κάμερας. Επιβάλλεται επιπλέον χρέωση για αυτήν τη δυνατότητα.

## 3 Θερμογραφία και Μηχανική Μάθηση

### 3.1 Η θερμογραφία και στα συνελκτικά νευρωνικά δίκτυα (CNNs)

Η θερμογραφία κτιρίων αναφέρεται στη χρήση θερμικών καμερών για την ανίχνευση και την εικονογράφηση της θερμοκρασίας της επιφάνειας ενός κτιρίου. Τα δεδομένα αυτά μπορούν να χρησιμοποιηθούν για την εντοπισμό προβλημάτων μόνωσης, υγρασίας, διαρροών αέρα και άλλων προβλημάτων που σχετίζονται με την ενεργειακή απόδοση ενός κτιρίου.

Τα βαθιά νευρωνικά δίκτυα (Deep Learning) και τα συνελκτικά νευρωνικά δίκτυα (CNNs) είναι πολύ εξελιγμένες μέθοδοι μηχανικής μάθησης που μπορούν να εκπαιδευτούν να αναγνωρίζουν πολύπλοκα μοτίβα και δομές σε μεγάλους όγκους δεδομένων χρησιμοποιώντας πολλαπλά επίπεδα διαδοχικών συνελκτικών φίλτρων.

Εφαρμόζοντας τα CNN στη θερμογραφία κτιρίων, θα μπορούσαμε να αναπτύξουμε συστήματα που να μπορούν να εντοπίζουν αυτόματα τις περιοχές που παρουσιάζουν προβλήματα. Για παράδειγμα, ένα CNN μπορεί να εκπαιδευτεί να αναγνωρίζει τις χαρακτηριστικές θερμογραφικές "υπογραφές" των διαρροών αέρα ή της κακής μόνωσης. Αυτό θα μπορούσε να γίνει εκπαιδευοντας το δίκτυο με μεγάλη ποικιλία θερμογραφικών εικόνων από κτίρια, με κάθε εικόνα να είναι ετικετοποιημένη με πληροφορίες σχετικά με την θερμική της κατάσταση. Το CNN θα "μάθει" τότε να συσχετίζει τα θερμικά μοτίβα που βλέπει με τις ετικέτες που έχουν δοθεί, επιτρέποντάς του να προβλέψει την θερμική κατάσταση ενός κτιρίου από μια νέα θερμογραφική εικόνα.

Αυτό μπορεί να έχει μεγάλη εφαρμογή στην ενεργειακή αποδοτικότητα και να κάνει την επιθεώρηση κτιρίων πιο αποδοτική και λιγότερο χρονοβόρα, καθώς η δυνατότητα αναγνώρισης και ταξινόμησης των περιοχών που χρειάζονται βελτίωση θα μπορούσε να επιτρέψει την εξοικονόμηση ενέργειας και να βελτιώσει την ενεργειακή απόδοση των κτιρίων.

### 3.2 Μηχανική Μάθηση

#### 3.2.1 Ανάλυση

Πίσω από την εκπαίδευση μηχανών, υπάρχει η ιδέα ότι μια μηχανή μπορεί να μάθει και να εξελιχθεί, παρόμοια με τον τρόπο που εκπαιδεύουμε έναν άνθρωπο. Η εκπαίδευση αυτή επιτυγχάνεται χρησιμοποιώντας αλγορίθμους και δεδομένα, με σκοπό η μηχανή να αποκτήσει τη δυνατότητα να εκμάθει και να προσαρμοστεί μόνη της. Το γεγονός αυτό αποτελεί τη βάση της μοντέρνας τεχνητής

νοημοσύνης και αποδίδεται στον Arthur Samuel, ο οποίος κατάφερε να "διδάξει" έναν υπολογιστή να παίζει checkers [85].

Ένα από τα πιο ενδιαφέροντα και πολύπλοκα εργαλεία που χρησιμοποιούνται στην εκπαίδευση των μηχανών είναι τα νευρωνικά δίκτυα. Τα νευρωνικά δίκτυα είναι υπολογιστικά συστήματα εμπνευσμένα από τον τρόπο που λειτουργεί ο ανθρώπινος εγκέφαλος, με σκοπό να απομιμηθούν την ικανότητά του για μάθηση.

Επιτρέπουν την επεξεργασία και την εκμάθηση μεγάλων ποσοτήτων πολύπλοκων δεδομένων και την παραγωγή αποτελεσμάτων με βάση αυτά τα δεδομένα. Κάθε "νευρώνας" στο δίκτυο δέχεται είσοδο, επεξεργάζεται την πληροφορία και την περνάει στον επόμενο νευρώνα. Αυτή η διαδικασία επαναλαμβάνεται εκατοντάδες, χιλιάδες ή ακόμη εκατομμύρια φορές, επιτρέποντας την εκμάθηση από τα δεδομένα και την προσαρμογή σε νέες καταστάσεις.

Όπως και στην ανθρώπινη εκπαίδευση, τα νευρωνικά δίκτυα χρειάζονται χρόνο για να "μάθουν" και να ανταποκριθούν αποτελεσματικά σε νέα δεδομένα. Οι αλγόριθμοι και οι τεχνικές που χρησιμοποιούνται σε αυτήν τη διαδικασία είναι πολύπλοκοι και απαιτούν τόσο προηγμένη επιστημονική γνώση όσο και τεχνικές δεξιότητες.

Συνολικά, η εκπαίδευση των μηχανών, ιδιαίτερα μέσω των νευρωνικών δικτύων, αποτελεί μια συναρπαστική και δυναμική πεδίο της τεχνητής νοημοσύνης, με απροσδόριστες δυνατότητες για το μέλλον.

### 3.2.2 Είδη Μηχανικής Μάθησης

Εν γένει, ο τομέας της Μηχανικής Μάθησης αναπτύσσει τρεις τρόπους μάθησης, ανάλογους με τους τρόπους με τους οποίους μαθαίνει ο άνθρωπος: επιβλεπόμενη μάθηση, μη επιβλεπόμενη μάθηση και ενισχυτική μάθηση. Πιο αναλυτικά:

#### Επιβλεπόμενη Μάθηση (Supervised Learning):

- Είναι η διαδικασία κατασκευής μιας συνάρτησης που απεικονίζει εισόδους σε γνωστές εξόδους.
- Στόχος είναι η γενίκευση της συνάρτησης για εισόδους με άγνωστη έξοδο.
- Χρησιμοποιείται σε:
  - Ταξινόμησης (Classification)
  - Πρόγνωσης (Prediction)
  - Διερμηνείας (Interpretation)

### **Μη Επιβλεπόμενη Μάθηση (Unsupervised Learning):**

- Ο αλγόριθμος κατασκευάζει ένα μοντέλο για εισόδους χωρίς να γνωρίζει τις επιθυμητές εξόδους.
- Χρησιμοποιείται σε:
  - Ανάλυσης Συσχετισμών (Association Analysis)
  - Ομαδοποίησης (Clustering)

### **Ενισχυτική Μάθηση (Reinforcement Learning):**

- Ο αλγόριθμος μαθαίνει μια στρατηγική ενεργειών μέσα από άμεση αλληλεπίδραση με το περιβάλλον.
- Χρησιμοποιείται κυρίως σε:
  - Σχεδιασμού (Planning), όπως ο έλεγχος κίνησης ρομπότ και η βελτιστοποίηση εργασιών σε εργοστασιακούς χώρους.

Για κάθε πρόβλημα που αντιμετωπίζεται στην Μηχανική Μάθηση, υπάρχει ένας κατάλληλος τρόπος μάθησης και για κάθε τρόπο μάθησης, τουλάχιστον ένας κατάλληλος αλγόριθμος μπορεί να εφαρμοστεί [86].

## **3.3 Deep Learning**


### **3.3.1 Τεχνητά νευρωνικά δίκτυα**

Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks - ANN) αποτελούν προηγμένα μοντέλα που προσομοιώνουν το κεντρικό νευρικό σύστημα των ζώντων οργανισμών, συμπεριλαμβανομένου του ανθρώπινου εγκεφάλου. Μιμούνται τη λειτουργία των βιολογικών νευρώνων και τη δομή των βιολογικών νευρωνικών δικτύων, επιτρέποντας τη συνδυασμένη χρήση της ανθρώπινης εγκεφαλικής λειτουργίας με τον αφηρημένο μαθηματικό τρόπο σκέψης.

Ένα Τεχνητό Νευρωνικό Δίκτυο είναι ικανό να μάθει, να εκπαιδευτεί, να θυμάται και να αντιδράσει σε διάφορες πληροφορίες, αντιγράφοντας ικανότητες που μέχρι πρότινος αποδίδονταν μόνο στην ανθρώπινη σκέψη. Το ANN αποκτά μια μεγάλη συλλογή μονάδων που συνδέονται μεταξύ τους με κάποιο μοτίβο για να επιτρέπουν την επικοινωνία μεταξύ των μονάδων. Αυτές οι μονάδες, που αναφέρονται επίσης ως κόμβοι ή νευρώνες, είναι απλοί επεξεργαστές που λειτουργούν παράλληλα. Με τη χρήση τους, μπορούμε να εκτελέσουμε πολύπλοκες λειτουργίες, όπως αναγνώριση προτύπων, πρόβλεψη, αποφάσεις και αναίρεση πληροφορίας [92].

Τα Τεχνητά Νευρωνικά Δίκτυα αποτελούνται από διασυνδεδεμένες υπολογιστικές μονάδες, γνωστές ως νευρώνες, που λειτουργούν σαν τα βασικά δομικά στοιχεία. Κάθε νευρώνας επεξεργάζεται πληροφορίες και ανταλλάσσει ηλεκτρικά σήματα με άλλους νευρώνες, προσφέροντας τη δυνατότητα παράλληλης επεξεργασίας και κατανομής της πληροφορίας [87]. Κάθε νευρώνας συνδέεται με άλλο νευρώνα μέσω μιας σύνδεσης σύνδεσης. Κάθε σύνδεσμος σύνδεσης σχετίζεται με ένα βάρος που έχει πληροφορίες για το σήμα εισόδου. Αυτή είναι η πιο χρήσιμη πληροφορία για τους νευρώνες για την επίλυση ενός συγκεκριμένου προβλήματος, επειδή το βάρος συνήθως διεγείρει ή αναστέλλει το σήμα που μεταδίδεται. Κάθε νευρώνας έχει μια εσωτερική κατάσταση, η οποία ονομάζεται σήμα ενεργοποίησης ή συνάρτηση ενεργοποίησης. Τα σήματα εξόδου, τα οποία παράγονται μετά από συνδυασμό των σημάτων εισόδου και του κανόνα ενεργοποίησης, μπορούν να σταλούν σε άλλες μονάδες [92].

Συνοψίζοντας, τα Τεχνητά Νευρωνικά Δίκτυα είναι προηγμένα υπολογιστικά μοντέλα που μιμούνται τη λειτουργία των βιολογικών νευρωνικών δικτύων. Με την ικανότητά τους να μάθουν, να εκπαιδευτούν και να ανταποκριθούν σε πληροφορίες, ανοίγουν νέους ορίζοντες στην επιστήμη και την τεχνολογία, παρέχοντας προηγμένες δυνατότητες για την επίλυση πολύπλοκων προβλημάτων.



Σχήμα 3.1 Μοντέλο ενός απλού νευρωνικού.

### 3.3.2 Αρχιτεκτονική Νευρωνικών Δικτύων

Από την παραπάνω εξήγηση μπορούμε να συμπεράνουμε ότι ένα νευρωνικό δίκτυο αποτελείται από νευρώνες και όταν εκπαιδεύουμε ένα νευρωνικό δίκτυο, θέλουμε οι νευρώνες να ενεργοποιούνται

όποτε μαθαίνουν συγκεκριμένα μοτίβα από τα δεδομένα και μοντελοποιούμε τον ρυθμό πυρκαγιάς χρησιμοποιώντας μια συνάρτηση ενεργοποίησης [93].


Έτσι, η βασική αρχιτεκτονική και οι αρχές ενός νευρωνικού δικτύου είναι οι εξής:

- **Input Nodes (input layer):** Δεν γίνεται υπολογισμός εδώ σε αυτό το επίπεδο. Απλώς περνούν τις πληροφορίες στο επόμενο επίπεδο (κρυφό στρώμα τις περισσότερες φορές). Ένα μπλοκ κόμβων ονομάζεται επίσης επίπεδο. [93]
- **Hidden nodes (hidden layer):** Στα κρυφά επίπεδα γίνεται η ενδιάμεση επεξεργασία ή υπολογισμός. Εκτελούν υπολογισμούς και στη συνέχεια μεταφέρουν τα βάρη (σήματα ή πληροφορίες) από το επίπεδο εισόδου στο επόμενο επίπεδο (άλλο κρυφό στρώμα ή στο επίπεδο εξόδου). Είναι δυνατό να έχουμε ένα νευρωνικό δίκτυο χωρίς κρυφό στρώμα. [93]
- **Output Nodes (output layer):** Εδώ τελικά χρησιμοποιούμε μια συνάρτηση ενεργοποίησης που αντιστοιχίζεται στην επιθυμητή μορφή εξόδου (π.χ. softmax for classification). [93]
- **Connections and weights:** Το δίκτυο αποτελείται από συνδέσεις, όπου κάθε σύνδεση μεταφέρει την έξοδο ενός νευρώνα  $i$  στην είσοδο ενός νευρώνα  $j$ . Υπό αυτή την έννοια, το  $i$  είναι ο προκάτοχος του  $j$  και είναι ο διάδοχος του  $i$ . Σε κάθε σύνδεση εκχωρείται ένα βάρος  $W_{ij}$ . [93]
- **Activation function:** Η συνάρτηση ενεργοποίησης ενός κόμβου καθορίζει την έξοδο αυτού του κόμβου με δεδομένη μια είσοδο ή ένα σύνολο εισόδων. Ένα τυπικό κύκλωμα τσιπ υπολογιστή μπορεί να θεωρηθεί ως ένα ψηφιακό δίκτυο λειτουργιών ενεργοποίησης που μπορεί να είναι "ON" (1) ή "OFF" (0), ανάλογα με την είσοδο. Αυτό είναι παρόμοιο με τη συμπεριφορά του γραμμικού perceptron στα νευρωνικά δίκτυα. Ωστόσο, είναι η μη γραμμική συνάρτηση ενεργοποίησης που επιτρέπει σε τέτοια δίκτυα να υπολογίζουν μη τετριμμένα προβλήματα χρησιμοποιώντας μόνο έναν μικρό αριθμό κόμβων. Στα τεχνητά νευρωνικά δίκτυα αυτή η λειτουργία ονομάζεται επίσης συνάρτηση μεταφοράς. [93]
- **Learning rule:** Ο κανόνας μάθησης είναι ένας κανόνας ή ένας αλγόριθμος που τροποποιεί τις παραμέτρους του νευρωνικού δικτύου, προκειμένου μια δεδομένη είσοδος στο δίκτυο να παράγει μια προτιμώμενη έξοδο. Αυτή η διαδικασία μάθησης συνήθως ισοδυναμεί με την τροποποίηση των βαρών και των ορίων. [93]
- **Forward propagation:** Η προς τα εμπρός διάδοση είναι η διαδικασία κίνησης προς τα εμπρός μέσω του νευρωνικού δικτύου. Ο στόχος της προς τα εμπρός διάδοσης είναι να υπολογιστούν οι ενεργοποιήσεις σε κάθε νευρώνα για κάθε διαδοχικό κρυφό στρώμα μέχρι να φτάσει στην έξοδο [94]. Στην προώθηση (forward propagation), τα δεδομένα περνάνε από το εισαγωγικό



στρώμα του δικτύου προς τα εμπρός, μέσα από όλα τα κρυφά στρώματα, μέχρι να φτάσουν στο εξαγωγικό στρώμα. Σε κάθε στρώμα, η είσοδος από το προηγούμενο στρώμα πολλαπλασιάζεται με τα βάρη του τρέχοντος στρώματος και στη συνέχεια προστίθεται η παραμορφωσιακή ποσότητα (bias). Το αποτέλεσμα διέρχεται στη συνέχεια μέσα από μια συνάρτηση ενεργοποίησης, που δίνει την έξοδο για το στρώμα.

- **Backpropagation:** Η οπίσθια διάδοση είναι το αντίστροφο της προς τα εμπρός διάδοσης. Εκτός από το σήμα αντί για σήμα, μετακινούμε το σφάλμα προς τα πίσω μέσω του μοντέλου μας. Βασικά, η backpropagation υπολογίζει το σφάλμα που μπορεί να αποδοθεί σε κάθε νευρώνα και αυτό με τη σειρά του υπολογίζει τις μερικές παραγώγους και τελικά τη διαβάθμιση έτσι ώστε να μπορεί να χρησιμοποιήσει την gradient descent [94]. Η ανάδραση (backpropagation) είναι η διαδικασία μέσω της οποίας το δίκτυο μαθαίνει και προσαρμόζει τα βάρη του. Στο τέλος κάθε προώθησης, υπολογίζεται η διαφορά μεταξύ της προβλεπόμενης εξόδου του δικτύου και της πραγματικής εξόδου (το λάθος). Το λάθος αυτό διαδίδεται πίσω στο δίκτυο, με την επιρροή του να μειώνεται καθώς προχωρά προς τα πίσω, ώστε τα βάρη να προσαρμοστούν ανάλογα.
- **Gradient Descent:** Η διαδικασία της καθοδικής διάβασης (gradient descent) είναι η μέθοδος με την οποία ενημερώνονται τα βάρη του δικτύου κατά την ανάδραση. Υπολογίζεται η κλίση της συνάρτησης κόστους (μια μέτρηση του λάθους) σχετικά με τα βάρη, και τα βάρη ενημερώνονται στην αντίθετη κατεύθυνση της κλίσης. Αυτό σημαίνει ότι τα βάρη μειώνονται εάν η κλίση είναι θετική, και αυξάνονται εάν η κλίση είναι αρνητική, με στόχο τη μείωση της συνάρτησης κόστους.



Σχήμα 3.2 Βασική αρχιτεκτονική ANN

- **Βάρη (Weights):** Τα βάρη είναι οι παράμετροι που προσαρμόζουν το βάρος της εισόδου κάθε νευρώνα. Επηρεάζουν τον τρόπο με τον οποίο κάθε νευρώνας αντιδρά στις εισροές. Κάθε σύνδεση μεταξύ των νευρώνων σε ένα νευρωνικό δίκτυο έχει ένα "βάρος" που αντιστοιχεί σε αυτήν. Το βάρος είναι ένας αριθμητικός συντελεστής που διέπει πόσο πολύ επηρεάζει ένας νευρώνας τον επόμενο κατά την προώθηση. Τα βάρη προσαρμόζονται κατά τη διάρκεια της

εκπαίδευσης μέσω της διαδικασίας της καθοδικής διάβασης (gradient descent), ώστε να μειωθεί το σφάλμα της πρόβλεψης του μοντέλου σε σχέση με την πραγματική εξόδο.

- **Bias (Παραμορφωσιακές ποσότητες):** Τα bias είναι άλλη μια μορφή παραμέτρων που εκπαιδεύονται σε ένα νευρωνικό δίκτυο. Ενώ τα βάρη ελέγχουν πόσο ισχυρά θα ενεργοποιηθεί ένας νευρώνας από την είσοδο, το "bias" είναι μια πρόσθετη παράμετρος που επιτρέπει στον νευρώνα να είναι πιο ευέλικτος στον έλεγχο της ενεργοποίησης. Προσθέτουν μια σταθερά τιμή στην είσοδο του νευρώνα, επιτρέποντας του να αντιδρά διαφορετικά ανεξάρτητα από τις εισόδους του. Μπορείτε να σκεφτείτε το bias ως το "σημείο εκκίνησης" για τον νευρώνα. Εάν, για παράδειγμα, ένας νευρώνας έχει υψηλό bias, τότε απαιτείται λιγότερη είσοδος για να "ενεργοποιηθεί" ή να εξαπολύσει ένα ισχυρό σήμα. Τα bias επιτρέπουν στο δίκτυο να αντιμετωπίζει πιο πολύπλοκα μοτίβα δεδομένων. Όπως και τα βάρη, τα bias προσαρμόζονται κατά τη διάρκεια της εκπαίδευσης για να μειωθεί το σφάλμα του μοντέλου.

## 3.4 Τύποι νευρωνικών δικτύων

### 3.4.1 Συνελικτικά Νευρωνικά Δίκτυα (CNNs)

#### Εισαγωγή στα CNNs

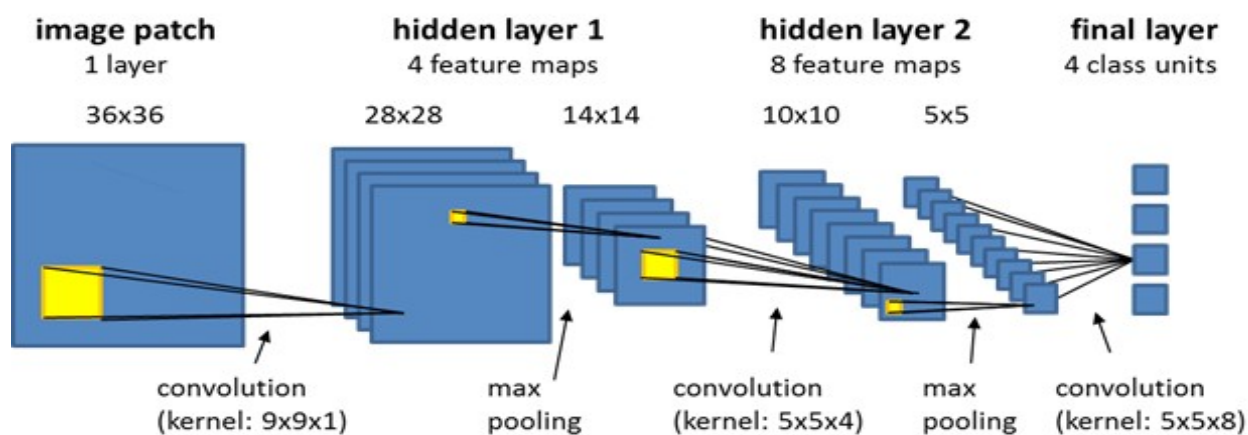
Τα τελευταία χρόνια στον κλάδο της πληροφορικής, έχει εμφανιστεί τεράστια ζήτηση για μια ιδιαίτερη δεξιότητα γνωστή ως Βαθιά Μάθηση (Deep Learning). Η Βαθιά Μάθηση είναι ένα υποσύνολο της Μηχανικής Μάθησης, που αποτελείται από αλγόριθμους εμπνευσμένους από τη λειτουργία του ανθρώπινου εγκεφάλου ή των νευρωνικών δικτύων .

Ένας συγκεκριμένος τύπος μοντέλου που έχει συμβάλει σημαντικά στον τομέα της ανάλυσης εικόνων και της υπολογιστικής όρασης είναι τα Συνελικτικά Νευρικά Δίκτυα (Convolutional Neural Networks - CNN). Τα CNN είναι ιδιαίτερα χρήσιμα, καθώς μειώνουν την ανθρώπινη προσπάθεια εντοπίζοντας αυτόματα τα χαρακτηριστικά των εικόνων. Εφαρμόζονται ευρέως σε αναγνώριση εικόνων και βίντεο, ταξινόμηση εικόνων, ανάλυση ιατρικών εικόνων, υπολογιστική όραση και επεξεργασία φυσικής γλώσσας

Η εφαρμογή των CNN εκτείνεται σε ποικίλες βιομηχανίες, όπως η ανάλυση ιατρικών εικόνων, τηλεφωνία, ασφάλεια, συστήματα προτάσεων κ.ά. Επιπλέον, λόγω της υψηλής ακρίβειάς τους, είναι ιδιαίτερα χρήσιμα στην αναγνώριση εικόνων. Η "συνέλιξη" στα CNN αναφέρεται στη μαθηματική λειτουργία της συνέλιξης, μια ειδική γραμμική πράξη, όπου δύο συναρτήσεις πολλαπλασιάζονται για να παράγουν μια τρίτη συνάρτηση που εκφράζει πώς η μορφή μιας συνάρτησης τροποποιείται από την άλλη. Το αποτέλεσμα χρησιμοποιείται για την εξαγωγή χαρακτηριστικών από την εικόνα [91].

## Ορισμός Αρχιτεκτονικής CNN

Η αρχιτεκτονική ενός Συνελικτικού Νευρωνικού Δικτύου (CNN) είναι εξαιρετικά σημαντική για την κατανόηση της λειτουργίας του. Αρχιτεκτονική CNN (Συνελικτικό Νευρωνικό Δίκτυο) αναφέρεται στη δομή και την οργάνωση ενός Συνελικτικού Νευρωνικού Δικτύου. Αυτή η δομή έχει σχεδιαστεί ειδικά για την επεξεργασία δεδομένων με γεωμετρική δομή, όπως εικόνες. Η αρχιτεκτονική ενός νευρωνικού δικτύου αναφέρεται στον τρόπο διάταξης και σύνδεσης των επιπέδων του. Αυτό περιλαμβάνει τον αριθμό των επιπέδων, τον τύπο κάθε επιπέδου, τον αριθμό των νευρώνων σε κάθε επίπεδο, τον τρόπο που συνδέονται τα επίπεδα μεταξύ τους



Σχήμα 3.3 Αρχιτεκτονική Convolutional neural network.

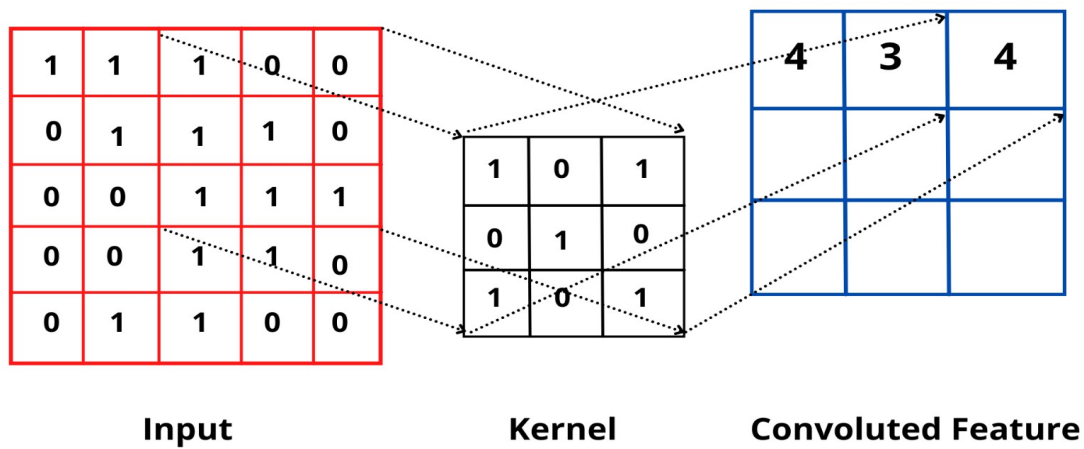
## Επίπεδα στα CNNs

Μια τυπική αρχιτεκτονική CNN περιλαμβάνει τα εξής είδη επιπέδων:

**1. Επίπεδο εισόδου (Input Layer):** Εδώ το δίκτυο λαμβάνει τις εικόνες εισόδου σε συγκεκριμένο χρωματικό χώρο. Υπάρχει ένας αριθμός τέτοιων χώρων όπως RGB, HSV, Grayscale, CMYK κ.λπ. Όταν οι εικόνες αποκτούν πολύ μεγάλες διαστάσεις, ο αριθμός των υπολογισμών που λαμβάνουν χώρα στο δίκτυο γίνεται πολύ μεγάλος. Έτσι, το CNN έρχεται να μειώσει τις εικόνες σε μια μορφή που είναι πιο εύκολη στην επεξεργασία, χωρίς να λείπουν χαρακτηριστικά που είναι κρίσιμα για την επίτευξη έγκυρης πρόβλεψης.

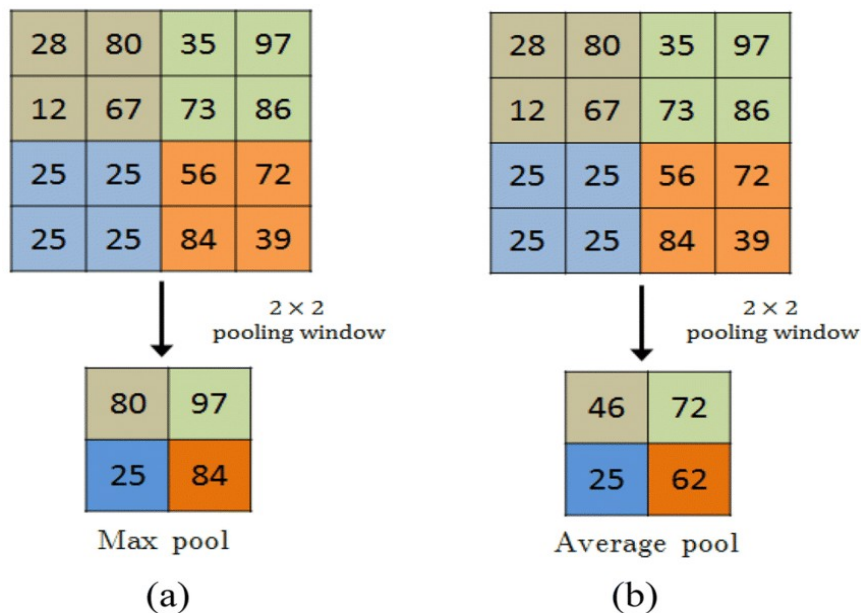
**2. Εξαγωγή χαρακτηριστικών (feature extraction) :** Αυτό το μέρος του δικτύου είναι υπεύθυνο για την αναγνώριση των διάφορων χαρακτηριστικών μιας εικόνας. Αποτελείται από πολλά ζεύγη συνελικτικών ή στρωμάτων συμπίκνωσης (pooling).

- **Συνελικτικά στρώματα (Convolutional layers):** Αυτά τα στρώματα χρησιμοποιούν τη λειτουργία συνέλιξης για την εξαγωγή χαρακτηριστικών από την εικόνα. Τα φίλτρα που διαφέρουν σε μέγεθος και μορφή κυλούν πάνω από την εικόνα και εξάγουν χαρακτηριστικά.



Σχήμα 3.4 Παράδειγμα για επίπεδο Convolutional

- Στρώματα συμπύκνωσης (Pooling layers):** Αυτά τα στρώματα είναι υπεύθυνα για τη μείωση της διαστατικότητας των χαρακτηριστικών που εξάγονται από τα συνελκτικά στρώματα και κατά συνέπεια μειώνει το υπολογιστικό φόρτο και βοηθάει στην ανίχνευση σημαντικών χαρακτηριστικών της εικόνας. Το πιο συνηθισμένο είναι το Max Pooling, που κρατά την μέγιστη τιμή από κάθε τοπικό παράθυρο [91].



Σχήμα 3.5 Παράδειγμα για επίπεδο Pooling

**3. Normalization layers:** Τα επίπεδα κανονικοποίησης χρησιμοποιούνται για να διασφαλίσουν ότι η διανομή των εισόδων μέσα στο δίκτυο παραμένει σταθερή. Στα Convolutional Neural Networks (CNNs), τα επίπεδα κανονικοποίησης παίζουν κρίσιμο ρόλο στην βελτίωση της απόδοσης και της σταθερότητας των δικτύων. Ειδικά στα βαθιά νευρωνικά δίκτυα, η κανονικοποίηση μπορεί να βοηθήσει στην αποφυγή προβλημάτων, όπως η εξαφάνιση ή η έκρηξη των gradients. Η Κανονικοποίηση δέσμης (Batch Normalization) είναι μια συχνά χρησιμοποιούμενη τεχνική.

**4. Activation layers:** Κάθε νευρώνας σε ένα CNN περιλαμβάνει μια συνάρτηση ενεργοποίησης που μετασχηματίζει την είσοδο σε μια μορφή που μπορεί να χειριστεί το δίκτυο. Οι συναρτήσεις ενεργοποίησης, όπως η συνάρτηση ReLU (Rectified Linear Unit), τα στρώματα Sigmoid ή Tanh, βοηθούν στην προσθήκη μη γραμμικότητας στο μοντέλο, επιτρέποντας του να μάθει πιο σύνθετες αναπαραστάσεις.

**5. Dropout layers:** Τα στρώματα Dropout αποτελούν μια τεχνική για την πρόληψη της υπερεκπαίδευσης. Κατά την εκπαίδευση, τα στρώματα Dropout "απενεργοποιούν" τυχαία μερικούς νευρώνες στο δίκτυο, διασπείροντας έτσι την πληροφορία και αποτρέποντας το δίκτυο από το να εξαρτάται υπερβολικά από οποιοδήποτε συγκεκριμένο νευρώνα.

**6. Flatten layer:** Μετά τη διαδικασία εξαγωγής χαρακτηριστικών, τα δεδομένα έχουν τη μορφή μιας τρισδιάστατης δομής (ύψος, πλάτος, βάθος). Πριν αυτά τα δεδομένα προωθηθούν στα πλήρως συνδεδεμένα (Dense) στρώματα, χρειάζεται να τα μετατρέψουμε σε μια μονοδιάστατη δομή. Αυτό γίνεται μέσω του Flatten Layer. Το Flatten Layer απλώνει ή "εξομαλύνει" την τρισδιάστατη δομή σε μια μονοδιάστατη, ώστε να μπορεί να προωθηθεί στα Dense layers. Το Flatten Layer δεν επηρεάζει την εκμάθηση του μοντέλου, απλά αλλάζει τη δομή των δεδομένων ώστε να μπορούν να προωθηθούν στα Dense layers για την τελική ταξινόμηση. Αυτό το επίπεδο είναι κρίσιμο για τη σύνδεση των στρωμάτων εξαγωγής χαρακτηριστικών (Convolutional και Pooling layers) με τα Dense layers.

**7. Πλήρως συνδεδεμένα στρώματα (Fully Connected layers) ή Dense Στρώματα:** Αυτό το μέρος του δικτύου χρησιμοποιεί τα χαρακτηριστικά που εξάγονται από την εξαγωγή χαρακτηριστικών για να προβλέψει την κλάση της εικόνας. Κάθε νευρώνας σε αυτά τα στρώματα είναι συνδεδεμένος με όλους τους νευρώνες του προηγούμενου στρώματος, δημιουργώντας ένα πλήρως διασυνδεδεμένο δίκτυο. Στην τελική φάση του CNN, μετά την εξαγωγή χαρακτηριστικών από τα στρώματα συνέλιξης και pooling, τα δεδομένα που είναι πλέον σε πιο επιτελεστική, συμπυκνωμένη μορφή, προωθούνται σε ένα ή περισσότερα πλήρως συνδεδεμένα στρώματα. Αυτά τα στρώματα εργάζονται ως κλασικά,

πολυεπίπεδα νευρωνικά δίκτυα, εκπαιδεύοντας το μοντέλο για την τελική ταξινόμηση. Το τελευταίο Dense layer συνήθως έχει τόσους νευρώνες όσες είναι και οι κατηγορίες της ταξινόμησης [91].

### **3.4.2 Μακροπρόθεσμη Μνήμη Ελάχιστης Επιτροπής (Long Short-Term Memory )**

#### **Εισαγωγή στις LSTM**

Η μακροπρόθεσμη μνήμη LSTMs είναι ένας τύπος επαναλαμβανόμενου νευρωνικού δικτύου RNN που μπορεί να συγκρατήσει μακροπρόθεσμες εξαρτήσεις σε διαδοχικά δεδομένα. Τα LSTM είναι σε θέση να επεξεργάζονται και να αναλύουν διαδοχικά δεδομένα, όπως χρονοσειρές, κείμενο και ομιλία. Χρησιμοποιούν ένα κελί μνήμης και πύλες για να ελέγχουν τη ροή των πληροφοριών, επιτρέποντάς τους να διατηρούν επιλεκτικά ή να απορρίπτουν πληροφορίες όπως απαιτείται και έτσι να αποφεύγουν το πρόβλημα της ολίσθησης της κλίσης που μαστίζει τα παραδοσιακά RNN. Τα LSTM χρησιμοποιούνται ευρέως σε διάφορες εφαρμογές όπως η επεξεργασία φυσικής γλώσσας, η αναγνώριση ομιλίας και η πρόβλεψη χρονοσειρών [95].

#### **Ορισμός Αρχιτεκτονικής LSTM**

Το LSTM (Long Short-Term Memory) είναι ένας τύπος επαναλαμβανόμενου νευρωνικού δικτύου (RNN) σχεδιασμένο για την επεξεργασία και την ανάλυση διαδοχικών δεδομένων με την ικανότητα να αναγνωρίζει μακροπρόθεσμες εξαρτήσεις. Η αρχιτεκτονική του LSTM αποτελείται από μια σειρά κυψελών, η κάθε μία από τις οποίες διαθέτει τρεις κύριες πύλες: την πύλη εισόδου, την πύλη λήθης και την πύλη εξόδου [95].

Κάθε πύλη ελέγχει τη ροή των πληροφοριών προς και από την κυψέλη, επιτρέποντας την επιλεκτική διατήρηση ή απώλεια πληροφοριών από προηγούμενα χρονικά βήματα. Αυτό επιτρέπει στο δίκτυο να "θυμάται" μακροπρόθεσμα πληροφορίες που είναι σημαντικές για την ερμηνεία των τρέχοντων και μελλοντικών δεδομένων [95].

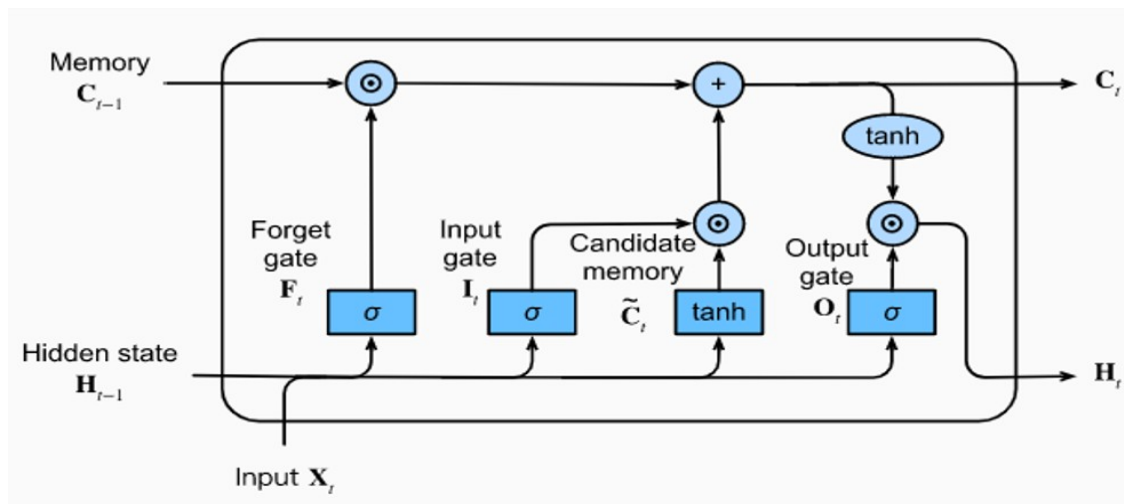
Το κεντρικό στοιχείο της κυψέλης LSTM είναι το κελί μνήμης, το οποίο αποθηκεύει πληροφορίες από προηγούμενα χρονικά βήματα και χρησιμοποιεί αυτές τις πληροφορίες για να επηρεάσει την έξοδο της κυψέλης στο τρέχον χρονικό βήμα. Οι πληροφορίες αυτές μεταβιβάζονται στην επόμενη κυψέλη του δικτύου, επιτρέποντας έτσι στο LSTM να επεξεργάζεται δεδομένα σε διαδοχικά χρονικά βήματα [95].

Πέρα από τη μακροπρόθεσμη μνήμη, το LSTM διαθέτει επίσης βραχυπρόθεσμη μνήμη που αποθηκεύεται στην κρυφή κατάσταση. Η κρυφή κατάσταση περιλαμβάνει πληροφορίες από τα πιο πρόσφατα βήματα υπολογισμού και χρησιμοποιείται στην επόμενη επανάληψη του δικτύου μαζί με την τρέχουσα είσοδο. Αυτή η δυνατότητα να αποθηκεύει τόσο μακροπρόθεσμες όσο και βραχυπρόθεσμες πληροφορίες καθιστά τα δίκτυα LSTM ιδανικά για εφαρμογές όπως την επεξεργασία φυσικής γλώσσας, την αναγνώριση ομιλίας και την πρόβλεψη χρονοσειρών [96].

## Επίπεδα στις LSTM

Το LSTM έχει μια πιο σύνθετη αρχιτεκτονική από τα απλά RNN. Η βασική του ιδέα είναι να χρησιμοποιήσει πύλες για να ελέγξει τη ροή της πληροφορίας μέσα στο δίκτυο [96, 97, 98].

1. Πύλη Λήθης (Forget Gate): Αποφασίζει ποιες πληροφορίες από την προηγούμενη κατάσταση πρέπει να ξεχαστούν και ποιες πρέπει να διατηρηθούν. Αυτή η πύλη χρησιμοποιεί μια σιγμοειδή συνάρτηση για να παράγει μια τιμή ανάμεσα στο 0 και το 1 για κάθε πληροφορία.
2. Πύλη Εισόδου (Input Gate): Αποφασίζει ποιες νέες πληροφορίες πρέπει να προστεθούν στην τρέχουσα κατάσταση. Αυτή η πύλη χρησιμοποιεί επίσης μια σιγμοειδή(sigmoid) συνάρτηση και μια συνάρτηση tanh για να παράξει τιμές ανάμεσα στο 0 και το 1 για κάθε πληροφορία.
3. Πύλη Εξόδου (Output Gate): Αποφασίζει ποιες πληροφορίες από την τρέχουσα κατάσταση πρέπει να χρησιμοποιηθούν για την παραγωγή της τελικής έξοδου. Αυτή η πύλη χρησιμοποιεί μια σιγμοειδή(sigmoid) συνάρτηση και μια συνάρτηση tanh για να παράξει τιμές ανάμεσα στο 0 και το 1 για κάθε πληροφορία.



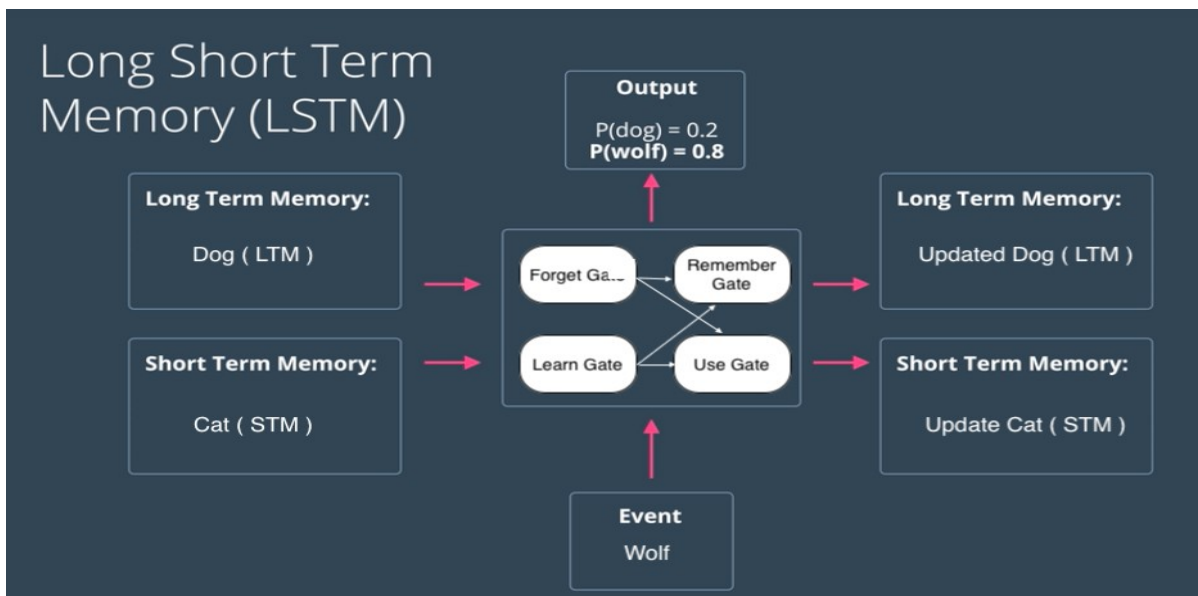
Σχήμα 3.6 Αρχιτεκτονική LSTM neural network.

Επιπρόσθετα, το LSTM διατηρεί μια κρυφή κατάσταση (hidden state) που λειτουργεί ως μια εσωτερική αναπαράσταση της μνήμης του δικτύου. Η κρυφή κατάσταση ενημερώνεται με βάση τις πληροφορίες που περνούν από τις πύλες.

Χρήση, Εκμάθηση και Θυμηση της Κρυφής Κατάστασης. Στο LSTM, υπάρχουν τρεις πύλες που παίζουν έναν σημαντικό ρόλο στη χρήση, την εκμάθηση και τη θυμηση της κρυφής κατάστασης:

1. Πύλη Χρήσης (Use Gate): Αυτή η πύλη αποφασίζει πόση από την τρέχουσα κρυφή κατάσταση πρέπει να χρησιμοποιηθεί για την πρόβλεψη της τρέχουσας εξόδου. Από την κρυφή κατάσταση προέρχονται πληροφορίες που είναι χρήσιμες για την επίλυση του τρέχοντος προβλήματος.
2. Πύλη Εκμάθησης (Learn Gate): Αυτή η πύλη αποφασίζει ποιες πληροφορίες από την τρέχουσα είσοδο και την προηγούμενη κρυφή κατάσταση πρέπει να προστεθούν στην κρυφή κατάσταση για να ενημερωθεί. Αυτή η πύλη είναι υπεύθυνη για την ενημέρωση της κρυφής κατάστασης με νέες πληροφορίες που μπορεί να είναι σημαντικές για την επόμενη πρόβλεψη.
3. Πύλη Θυμήσεων (Remember Gate): Αυτή η πύλη αποφασίζει ποιες πληροφορίες από την τρέχουσα κρυφή κατάσταση πρέπει να αποθηκευτούν στην μακροπρόθεσμη μνήμη (Long-Term Memory - LTM). Αυτή η πύλη αποφασίζει ποιες πληροφορίες είναι χρήσιμες και πρέπει να διατηρηθούν για μελλοντική χρήση.

Οι τρεις αυτές πύλες συνεργάζονται με τις προηγούμενες πύλες (πύλη λήθης, πύλη εισόδου και πύλη εξόδου) για να επιλέξουν ποιες πληροφορίες πρέπει να χρησιμοποιηθούν, να μάθουν και να θυμηθούν κατά την επεξεργασία της ακολουθίας. Με αυτόν τον τρόπο, το LSTM μπορεί να εξάγει και να διατηρήσει σημαντικές πληροφορίες για μακροπρόθεσμη εξάρτηση και πρόβλεψη.



Σχήμα 3.7 Κρυφή Κατάσταση (hidden state)

Το LSTM είναι μια ισχυρή επέκταση των αναδραστικών νευρωνικών δικτύων που επιτρέπει τη χρήση μνήμης με μακρά διάρκεια για την αντιμετώπιση ακολουθιακών δεδομένων. Με τις πύλες του, το LSTM μπορεί να ελέγχει ποιες πληροφορίες πρέπει να διατηρηθούν, να μάθουν και να θυμηθούν κατά



την επεξεργασία της ακολουθίας. Αυτό το καθιστά ένα ιδιαίτερα αποτελεσματικό μοντέλο για προβλήματα όπου η μακροπρόθεσμη εξάρτηση και η ανάκληση της πληροφορίας είναι σημαντικές.

### 3.4.3 CNN + LSTM

Η πολυπλοκότητα μιας χρονοσειράς, ιδιαίτερα όταν η καταγραφή των δεδομένων γίνεται ανά 30 ή και 15 λεπτά, καθιστά την πρόβλεψη μια δύσκολη και πολύπλοκη διαδικασία. Όπως προαναφέρθηκε, τα LSTMs είναι ευρέως χρησιμοποιούμενα μοντέλα για προβλέψεις σε χρονοσειρές. Ωστόσο, βελτιωμένη ακρίβεια προβλέψεων μπορεί να επιτευχθεί με τον συνδυασμό ορισμένων μεθόδων από αυτές που αναφέρθηκαν παραπάνω. Ένα μοντέλο που μπορεί να χρησιμοποιηθεί για την πρόβλεψη χρονοσειρών περιλαμβάνει συνελικτικά επίπεδα των οποίων η έξοδος τροφοδοτείται σε δίκτυα LSTM (αρχιτεκτονική CNN-LSTMs). Τα CNN LSTMs αναπτύχθηκαν για προβλήματα πρόβλεψης οπτικών χρονοσειρών και τη δημιουργία περιγραφικών κειμένων από ακολουθίες εικόνων (π.χ. βίντεο), καθώς επίσης και στην επεξεργασία φωνής και φυσικής γλώσσας. Ένα μοντέλο σαν αυτό, μπορεί να θεωρηθεί ως συνδυασμός δύο μοντέλων, ενός CNN, το οποίο είναι υπεύθυνο για την εξαγωγή χαρακτηριστικών, καθώς και μοντέλων LSTM για την ερμηνεία αυτών των χαρακτηριστικών. Το πλεονέκτημα αυτού του μοντέλου είναι ότι μπορεί να υποστηρίξει πολύ μεγάλες ακολουθίες εισόδου, που μπορούν να διαβαστούν ως υπο-ακολουθίες από το μοντέλο CNN και στη συνέχεια να συγκεντρωθούν από το μοντέλο LSTM [99].

## 3.5 Προβλήματα Νευρωνικών Δικτύων και Αντιμετώπιση

Νευρωνικά δίκτυα είναι ισχυρά εργαλεία μηχανικής μάθησης, αλλά έρχονται με μια σειρά από προκλήσεις και προβλήματα. Εδώ είναι μερικά κοινά προβλήματα και πιθανές λύσεις:

### Υπερεκπαίδευση (Overfitting)

Είναι μια κοινή πρόκληση, όπου το μοντέλο "μαθαίνει" τα δεδομένα εκπαίδευσης τόσο καλά που δεν μπορεί να γενικεύσει καλά σε νέα, αδιάθετα δεδομένα. Η υπερεκπαίδευση μπορεί να προκληθεί από διάφορους λόγους, όπως το υπερβολικά σύνθετο μοντέλο σε σχέση με την ποσότητα των δεδομένων, την εκπαίδευση για υπερβολικά πολύ χρόνο χωρίς να ελέγχεται η απόδοση στα δεδομένα δοκιμής και άλλους παράγοντες. Τεχνικές όπως η κανονικοποίηση (regularization), το dropout, ή η αύξηση δεδομένων (data augmentation) ή το early stopping μπορούν να βοηθήσουν στην αντιμετώπιση της υπερεκπαίδευσης.

## Υποεκπαίδευση (Underfitting)


Αυτό συμβαίνει όταν το μοντέλο δεν μπορεί να "μάθει" επαρκώς από τα δεδομένα εκπαίδευσης και έτσι δεν μπορεί να παράγει ακριβείς προβλέψεις. Αυτό μπορεί να οφείλεται σε ανεπαρκή αρχιτεκτονική δικτύου, σε πολύ μικρή διάρκεια εκπαίδευσης ή τα χαμηλής ποιότητας και ανεπαρκή δεδομένα. Η αύξηση της πολυπλοκότητας του μοντέλου, η χρήση περισσότερων δεδομένων εκπαίδευσης, ή η χρήση πιο εξελιγμένων τεχνικών προεπεξεργασίας μπορεί να αντιμετωπίσει την υποεκπαίδευση.

## Διάρκεια Εκπαίδευσης και Υπολογιστική Ισχύς

Τα νευρωνικά δίκτυα μπορεί να απαιτούν μεγάλο όγκο δεδομένων και χρόνο για την εκπαίδευση, καθώς και σημαντική υπολογιστική ισχύ. Η χρήση τεχνικών όπως το Transfer Learning, το Distributed Training ή η χρήση πιο εξειδικευμένων υλικών (για παράδειγμα, GPUs) μπορεί να βοηθήσει στην αντιμετώπιση αυτού του προβλήματος.

## Προβλήματα Δεδομένων (Data Issues)

Η εκπαίδευση των νευρωνικών δικτύων απαιτεί μεγάλες ποσότητες δεδομένων. Εάν τα δεδομένα είναι περιορισμένα, παραπλανητικά ή προκατειλημμένα, τα δίκτυα μπορεί να μην λειτουργούν καλά. Οι τεχνικές της αύξησης δεδομένων (data augmentation) και της μεταφοράς μάθησης (transfer learning) μπορούν να βοηθήσουν στην αντιμετώπιση αυτών των προβλημάτων.



Σχήμα 3.8 Overfitting και Underfitting

## 4 Πειραματική Εφαρμογή

### 4.1 Εργαλεία και τεχνικές που χρησιμοποιήθηκαν στη διατριβή

#### 4.1.1 Python

Η Python είναι μια γλώσσα προγραμματισμού ανοιχτού κώδικα, ερμηνευόμενη και υψηλού επιπέδου που χρησιμοποιείται ευρέως για μια ποικιλία εφαρμογών, συμπεριλαμβανομένων της ανάλυσης δεδομένων, της επεξεργασίας εικόνων, της μηχανικής μάθησης και άλλων. Με την ευκρινή και ευανάγνωστη σύνταξή της, η Python είναι ιδιαίτερα αρεστή σε αρχάριους προγραμματιστές.

Κατά τη διάρκεια της ανάπτυξης, χρησιμοποίησα Python 3.8.5 και διάφορες βιβλιοθήκες.

Μερικές από τις πιο σημαντικές βιβλιοθήκες που χρησιμοποιήθηκαν κατά τη διάρκεια αυτού του έργου περιλαμβάνουν:

1. **Scikit-learn:** Πρόκειται για μια από τις πιο δημοφιλείς βιβλιοθήκες μηχανικής μάθησης στη γλώσσα προγραμματισμού Python. Παρέχει ευρεία ποικιλία αλγορίθμων μηχανικής μάθησης, όπως ταξινόμηση, παλινδρόμηση, συσταδοποίηση, καθώς και εργαλεία για την προεπεξεργασία των δεδομένων και την αξιολόγηση των μοντέλων.
2. **Skimage:** Αυτή η βιβλιοθήκη παρέχει μια σειρά λειτουργιών για την επεξεργασία εικόνων στο Python.
3. **Matplotlib:** Είναι μια γραφική βιβλιοθήκη που χρησιμοποιείται για την δημιουργία ποιοτικών σχεδίων και γραφημάτων στην Python.
4. **Datetime:** Αυτή η βιβλιοθήκη παρέχει εργαλεία για τη διαχείριση ημερομηνιών και χρόνων, επιτρέποντας τη δημιουργία, επεξεργασία και απεικόνιση ημερομηνιών και χρόνων στην Python.
5. **OS:** Η βιβλιοθήκη OS είναι σχεδιασμένη για τη διαχείριση λειτουργικών συστημάτων στο Python, παρέχοντας εργαλεία για τη δημιουργία, μετακίνηση, και διαγραφή αρχείων και φακέλων, καθώς και για τη διαχείριση περιβαλλοντικών μεταβλητών και άλλων ρυθμίσεων του συστήματος.
6. **Numpy:** Είναι μια βιβλιοθήκη σχεδιασμένη για να υποστηρίξει μεγάλες, πολυδιάστατες διατάξεις και πίνακες, καθώς και να προσφέρει εκτεταμένες βιβλιοθήκες (εργαλειοθήκες) μαθηματικών συναρτήσεων που μπορούν να λειτουργήσουν σε αυτά τα πολυδιάστατα σύνολα.

7. **Seaborn:** Το Seaborn είναι μια βιβλιοθήκη οπτικοποίησης δεδομένων Python που βασίζεται στο Matplotlib. Παρέχει μια διεπαφή υψηλού επιπέδου για τη σχεδίαση ελκυστικών και ενημερωτικών στατιστικών γραφικών [105].
8. **Imbalanced-learn (ή imblearn):** Είναι μια βιβλιοθήκη Python που προσφέρει εργαλεία για την αντιμετώπιση προβλημάτων μη ισορροπημένης ταξινόμησης. Σε πολλές πραγματικές εφαρμογές μηχανικής μάθησης, τα δεδομένα μπορεί να είναι μη ισορροπημένα, δηλαδή ένας ή περισσότεροι κλάσεις μπορεί να εκπροσωπούνται δυσανάλογα σε σύγκριση με άλλες.

#### 4.1.2 Pandas

Το pandas είναι ένα πακέτο χειρισμού δεδομένων στην Python που επιτρέπει την εύκολη και αποτελεσματική ανάλυση, μετασχηματισμό και οργάνωση δεδομένων σε μορφή πινάκων. Το βασικό στοιχείο του pandas είναι το DataFrame, που αποτελεί μια διδιάστατη δομή δεδομένων με στήλες και γραμμές [102, 103].

Το DataFrame στο pandas περιέχει τρία κύρια στοιχεία:

- **Δεδομένα:** Τα δεδομένα αναπαρίστανται στο DataFrame σε μια οργανωμένη μορφή πίνακα, όπου κάθε στήλη αναπαριστά ένα χαρακτηριστικό ή μια μεταβλητή, και κάθε γραμμή αναπαριστά μια εγγραφή ή μια παρατήρηση.
- **Ευρετήριο:** Το ευρετήριο αναπαριστά τις ετικέτες για τις γραμμές στο DataFrame. Κάθε γραμμή έχει μια μοναδική ετικέτα που την αναγνωρίζει.
- **Στήλες:** Οι στήλες αναπαριστούν τις ετικέτες για τα χαρακτηριστικά ή τις μεταβλητές στο DataFrame. Κάθε στήλη έχει μια μοναδική ετικέτα που την αναγνωρίζει.

Το pandas DataFrame μας παρέχει πολλές λειτουργίες και μεθόδους για τον χειρισμό και την επεξεργασία των δεδομένων. Μπορούμε να εκτελέσουμε απλές ή πολύπλοκες λειτουργίες όπως ταξινόμηση, φιλτράρισμα, ομαδοποίηση, συνδυασμός, μετασχηματισμός, ανάλυση στατιστικών και πολλά άλλα.

Με το pandas, μπορούμε επίσης να εισάγουμε και να εξάγουμε δεδομένα από πολλές πηγές, όπως αρχεία CSV, Excel, βάσεις δεδομένων και πολλές άλλες μορφές δεδομένων.

Το pandas είναι ένα πολύ ισχυρό εργαλείο για την ανάλυση δεδομένων και χρησιμοποιείται ευρέως σε πολλούς τομείς όπως η επιστήμη δεδομένων, η οικονομία, οι χρηματοοικονομικές αγορές, η βιομηχανία και άλλοι. Με την εκτεταμένη λειτουργικότητά του, το pandas μας επιτρέπει να εκτελούμε πολλές απαιτητικές αναλύσεις και επεξεργασίες δεδομένων με λίγες γραμμές κώδικα.

### 4.1.3 TensorFlow

Καθώς η τεχνητή νοημοσύνη (AI) και η μηχανική μάθηση (ML) προοδεύουν με επιτυχία, εμφανίζονται ισχυρά εργαλεία και πλατφόρμες για να υποστηρίξουν αυτήν την ταχεία εξέλιξη. Ένα από αυτά τα εργαλεία είναι το TensorFlow, μια βιβλιοθήκη ανοιχτού κώδικα αριθμητικών υπολογισμών, που αναπτύχθηκε αρχικά από την ομάδα Brain Team της Google.

Το όνομα "TensorFlow" προέρχεται από την ικανότητά του να χειρίζεται τανυστές, που είναι πολυδιάστατοι πίνακες δεδομένων. Με την χρήση γραφημάτων ροής δεδομένων, η TensorFlow δημιουργεί μαθηματικές πράξεις, με τους κόμβους στο γράφημα να αντιπροσωπεύουν αυτές τις πράξεις και τις ακμές του γραφήματος να αντιπροσωπεύουν τους πίνακες των δεδομένων που επικοινωνούν μεταξύ τους.

Η TensorFlow προσφέρει ένα εξαιρετικά ευέλικτο πλαίσιο, που επιτρέπει την εκτέλεση υπολογισμών σε διάφορα συστήματα - από επιτραπέζιους υπολογιστές και διακομιστές, έως φορητές συσκευές, χρησιμοποιώντας CPU ή GPU και των προσαρμοσμένων σχεδιασμένων ASIC γνωστών ως Tensor Processing Units (TPU).

Σε σύνοψη, το TensorFlow είναι ένα εξαιρετικά δυναμικό και προσαρμόσιμο εργαλείο για την ανάπτυξη και την εφαρμογή της μηχανικής μάθησης. Με την αυξανόμενη χρήση της AI και της ML σε ένα ευρύ φάσμα τομέων, το TensorFlow πιθανότατα θα συνεχίσει να είναι μια πολύτιμη προσθήκη στο εργαλειοθήκη κάθε επιστήμονα δεδομένων [101].

### 4.1.4 Keras

Η Python είναι μια πολύ δημοφιλής γλώσσα προγραμματισμού με πληθώρα βιβλιοθηκών και εργαλείων για διάφορες εφαρμογές. Ένα από τα πιο ισχυρά εργαλεία που συνδυάζει την ευκολία χρήσης της Python με την ισχύ των βαθιών νευρωνικών δικτύων είναι το Keras.

Το Keras είναι μια ανοιχτού κώδικα βιβλιοθήκη υψηλού επιπέδου που προσφέρει έναν απλό και ευέλικτο τρόπο για τη δημιουργία, την εκπαίδευση και την αξιολόγηση βαθιών νευρωνικών δικτύων. Η βιβλιοθήκη είναι γραμμένη σε Python και μπορεί να εκτελείται πάνω σε διάφορα πλαίσια εργασίας όπως ο TensorFlow, ο Theano και ο CNTK.

Ένα από τα βασικά χαρακτηριστικά του Keras είναι η φιλικότητα προς το χρήστη. Οι προγραμματιστές μπορούν να δημιουργήσουν νευρωνικά δίκτυα με λίγες γραμμές κώδικα, χρησιμοποιώντας έναν υψηλού επιπέδου αφαιρετικό τρόπο περιγραφής του μοντέλου. Αυτό διευκολύνει τον ταχύ πειραματισμό με διάφορες αρχιτεκτονικές και υπερπαραμέτρους.

Το Keras δεν περιορίζεται μόνο σε συνελκτικά και επαναλαμβανόμενα νευρωνικά δίκτυα, αλλά επιτρέπει και τον συνδυασμό τους. Αυτό επιτρέπει την ανάπτυξη πολύπλοκων μοντέλων που μπορούν να αντιμετωπίσουν διάφορα είδη εισόδου και να επιλύσουν διάφορα προβλήματα.

Συνοψίζοντας, το Keras είναι μια ισχυρή βιβλιοθήκη για την ανάπτυξη βαθιών νευρωνικών δικτύων με την χρήση της Python. Με την υποστήριξη πολλών πλατυσίων εργασίας, φιλική προς το χρήστη παραγωγή κώδικα και την ευελιξία της, έχει καταφέρει να γίνει μια από τις προτιμώμενες επιλογές για τους ερευνητές και τους επαγγελματίες στον τομέα της μηχανικής μάθησης και της τεχνητής νοημοσύνης [104].

#### **4.1.5 Dropout Regularization**

Η τακτοποίηση εγκατάλειψης είναι ένας υπολογιστικά φθηνός τρόπος για να τακτοποιήσετε ένα βαθύ νευρωνικό δίκτυο. Η εγκατάλειψη λειτουργεί με πιθανολογική κατάργηση ή "αποβολή" των εισόδων σε ένα επίπεδο, οι οποίες μπορεί να είναι μεταβλητές εισόδου στο δείγμα δεδομένων ή ενεργοποιήσεις από ένα προηγούμενο επίπεδο. Προσμοιώνει μεγάλο αριθμό δικτύων με πολύ διαφορετικές δομές δικτύου και, με τη σειρά του, καθιστά τους κόμβους στο δίκτυο γενικά πιο ισχυρούς στις εισόδους. Συνήθως, μια μικρή ποσότητα εγκατάλειψης μπορεί να εφαρμοστεί μετά από κάθε συνελικτική στρώση, με μεγαλύτερη εγκατάλειψη να εφαρμόζεται στα πλήρως συνδεδεμένα στρώματα κοντά στο στρώμα εξόδου του μοντέλου [106].

#### **4.1.6 Image Data Augmentation**

Η επαύξηση δεδομένων εικόνας είναι μια τεχνική που μπορεί να χρησιμοποιηθεί για να μεγεθύνει τεχνητά το μέγεθος ενός συνόλου δεδομένων εκπαίδευσης δημιουργώντας τροποποιημένες εκδόσεις εικόνων στο σύνολο δεδομένων. Η εκπαίδευση μοντέλων νευρωνικών δικτύων βαθιάς μάθησης σε περισσότερα δεδομένα μπορεί να οδηγήσει σε πιο αποτελεσματικά μοντέλα. Οι τεχνικές αύξησης μπορούν να παράγουν τροποποιήσεις των εικόνων που μπορούν να ενισχύσουν την ικανότητα των μοντέλων προσαρμογής να γενικεύουν όσα έχουν μάθει σε νέες εικόνες. Η αύξηση δεδομένων μπορεί επίσης να λειτουργήσει ως τεχνική τακτοποίησης, προσθέτοντας θόρυβο στα δεδομένα εκπαίδευσης και βοηθώντας το μοντέλο να μάθει τα ίδια χαρακτηριστικά, αμετάβλητα στη θέση του στην είσοδο. Μέτριες αλλαγές στις φωτογραφίες εισόδου μπορεί να είναι χρήσιμες για το πρόβλημα, όπως μικρές μετατοπίσεις και οριζόντιες ανατροπές. Αυτές οι επαυξήσεις μπορούν να οριστούν ως ορίσματα στο ImageDataGenerator που χρησιμοποιείται για το σύνολο δεδομένων εκπαίδευσης. Οι επαυξήσεις δεν θα πρέπει να χρησιμοποιούνται για το σύνολο δεδομένων δοκιμής, προκειμένου να αξιολογηθεί η απόδοση του μοντέλου στις μη τροποποιημένες εικόνες [106].

#### **4.1.7 Μετασχηματισμός Δεδομένων**

Ο μετασχηματισμός δεδομένων είναι μια κρίσιμη διαδικασία στην προετοιμασία των δεδομένων για τη μηχανική μάθηση. Αυτό συμβαίνει γιατί τα δεδομένα στον πραγματικό κόσμο συχνά δεν είναι σε

μια μορφή που μπορεί να γίνει κατευθείαν αντιληπτή ή χρησιμοποιηθεί από ένα μοντέλο μηχανικής μάθησης.

Ο μετασχηματισμός δεδομένων μπορεί να περιλαμβάνει διάφορες τεχνικές και διαδικασίες, όπως:

- **Καθαρισμός Δεδομένων:** Αφαίρεση ή διόρθωση των ατελών ή λανθασμένων τιμών στα δεδομένα.
- **Κανονικοποίηση:** Τα δεδομένα συχνά πρέπει να τυποποιηθούν ή να κανονικοποιηθούν ώστε να βρίσκονται σε μια συγκεκριμένη κλίμακα. Αυτό μπορεί να βοηθήσει στην βελτίωση της απόδοσης και της σταθερότητας των αλγορίθμων μηχανικής μάθησης.
- **Κωδικοποίηση:** Οι κατηγορικές μεταβλητές, όπως οι χρωματικές ετικέτες, πρέπει συχνά να μετατραπούν σε αριθμητικές τιμές.
- **Επιλογή Χαρακτηριστικών:** Η επιλογή των πιο σχετικών χαρακτηριστικών για την πρόβλεψη μπορεί να βελτιώσει την απόδοση του μοντέλου.
- **Επικάλυπτοντα δεδομένα (oversampling) ή μείωση δεδομένων (undersampling):** Αυτό είναι συχνά απαραίτητο όταν τα δεδομένα είναι ανισορροπημένα.

Ο μετασχηματισμός δεδομένων είναι συχνά ένα επαναλαμβανόμενο και επιμελητικό έργο, αλλά είναι κρίσιμης σημασίας για τη δημιουργία επιτυχημένων μοντέλων μηχανικής μάθησης.

#### 4.1.8 MinMax Normalization

Το min-maxing αποτελεί μία σημαντική στατιστική τεχνική με σκοπό την επανακλιμάκωση των τιμών σε ένα εύρος από  $[0,1]$ . Φανταστείτε, για παράδειγμα, βαθμολογίες άλμπουμ που κυμαίνονται από 70 έως 150. Με την τεχνική του min-maxing, κάθε βαθμολογία αναδιαμορφώνεται ώστε να βρίσκεται μεταξύ 0 και 1, με την αναλογία μεταξύ των βαθμολογιών να παραμένει αμετάβλητη. Αυτή η διαδικασία είναι μία προσέγγιση της ομαλοποίησης δεδομένων.

Σε πολλές περιπτώσεις, ιδιαίτερα στον τομέα της επιστήμης των δεδομένων, το min-maxing γίνεται απαραίτητο. Όταν, για παράδειγμα, θέλουμε να εκπαιδεύσουμε ένα μοντέλο μηχανικής μάθησης, όπως αυτά που χρησιμοποιούνται για ομαδοποίηση ή γραμμική παλινδρόμηση, είναι ουσιαστικό όλα τα χαρακτηριστικά να έχουν παρόμοια κλίμακα. Έτσι, αποφεύγουμε την υπερβολική επίδραση χαρακτηριστικών με μεγάλες τιμές στο τελικό μοντέλο.

Στην πράξη, το min-maxing είναι αρκετά απλό στην εφαρμογή του. Καταρχάς, εντοπίζουμε την ελάχιστη και τη μέγιστη τιμή της σειράς των δεδομένων. Αυτές οι δύο τιμές αποτελούν τα "άκρα" του εύρους: το 0 και το 1 αντίστοιχα. Η επανακλιμάκωση των υπόλοιπων τιμών που βρίσκονται μεταξύ αυτών των δύο "άκρων" απαιτεί λίγη περισσότερη προσοχή, αλλά με τη σωστή εφαρμογή, τα αποτελέσματα είναι αξιοσημείωτα και βελτιστοποιούν την απόδοση των μοντέλων μας [116].

#### 4.1.9 Oversampling and Undersampling techniques

Τα μη ισορροπημένα σύνολα δεδομένων είναι εκείνα όπου υπάρχει σοβαρή απόκλιση στην κατανομή της κλάσης, όπως παραδείγματα 1:100 ή 1:1000 στην τάξη μειοψηφίας προς την τάξη της πλειοψηφίας.

Αυτή η μεροληψία στο σύνολο δεδομένων εκπαίδευσης μπορεί να επηρεάσει πολλούς αλγόριθμους μηχανικής μάθησης, με αποτέλεσμα ορισμένοι να αγνοούν εντελώς την κατηγορία μειοψηφίας. Αυτό είναι ένα πρόβλημα καθώς είναι συνήθως η μειοψηφική τάξη στην οποία οι προβλέψεις είναι πιο σημαντικές.

Μια προσέγγιση για την αντιμετώπιση του προβλήματος της ανισορροπίας τάξης είναι η τυχαία επαναδειγματοληψία του συνόλου εκπαίδευσης. Οι δύο κύριες προσεγγίσεις για την τυχαία επαναδειγματοληψία ενός μη ισορροπημένου συνόλου δεδομένων είναι η διαγραφή παραδειγμάτων από την κλάση πλειοψηφίας, που ονομάζεται υποδειγματοληψία, και η αντιγραφή παραδειγμάτων από την κατηγορία μειοψηφίας, που ονομάζεται υπερδειγματοληψία. Οι τεχνικές υπερδειγματοληψίας (oversampling) και υποδειγματοληψίας (undersampling) είναι δύο δημοφιλείς μέθοδοι για την αντιμετώπιση της ανισορροπίας στα δεδομένα. Και οι δύο τεχνικές έχουν ως στόχο τη δημιουργία ενός πιο ισορροπημένου συνόλου δεδομένων για την εκπαίδευση των μοντέλων μηχανικής εκμάθησης [114].

- **Oversampling:** Η τεχνική της υπερδειγματοληψίας αυξάνει τον αριθμό των δειγμάτων της μειονοτικής κατηγορίας (η κατηγορία με τα λιγότερα δείγματα) μέχρι να φθάσει τον αριθμό των δειγμάτων της πλειονοτικής κατηγορίας. Αυτό μπορεί να επιτευχθεί είτε απλώς επαναλαμβάνοντας υπάρχοντα δείγματα, είτε παράγοντας νέα δείγματα από τα υπάρχοντα.
- **Undersampling:** Η τεχνική της υποδειγματοληψίας μειώνει τον αριθμό των δειγμάτων της πλειονοτικής κατηγορίας για να επιτύχει την ισορροπία με την μειονοτική κατηγορία. Αυτό μπορεί να επιτευχθεί απλά αφαιρώντας δείγματα, αλλά πρέπει να γίνει με προσοχή για να μην χάσετε σημαντικές πληροφορίες.

Και οι δύο τεχνικές έχουν τα πλεονεκτήματα και τα μειονεκτήματά τους. Το oversampling μπορεί να οδηγήσει σε υπερεκπαίδευση, καθώς τα πολλαπλά δείγματα της μειονοτικής κατηγορίας μπορεί να έχουν υψηλή παρόμοια πληροφορία. Από την άλλη πλευρά, το undersampling μπορεί να προκαλέσει απώλεια πληροφοριών, καθώς αφαιρούνται δείγματα από το σύνολο δεδομένων [114].



#### 4.1.10 Callbacks, EarlyStopping, model checkpoint

- **Επανακλήσεις (Callbacks):** Οι επανακλήσεις αποτελούν σύνολο λειτουργιών που εφαρμόζονται σε συγκεκριμένα στάδια της διαδικασίας εκπαίδευσης, όπως στο τέλος κάθε εποχής. Αυτές οι λειτουργίες προσφέρουν μια ισχυρή ευελιξία και προσαρμοστικότητα στην εκπαίδευση των μοντέλων. Μπορούν να αξιοποιηθούν για να πραγματοποιήσουμε διάφορες ενέργειες, όπως η διακοπή της προπόνησης σε συγκεκριμένη στιγμή, η αποθήκευση του μοντέλου κατά τη διάρκεια της εκπαίδευσης, η ρύθμιση της ταχύτητας εκμάθησης και πολλά άλλα [107].
- **Πρόωρη Διακοπή (Early Stopping):** Είναι μια τεχνική για να αποφύγουμε την υπερεκπαίδευση (overfitting), τερματίζοντας την εκπαίδευση νωρίς όταν ανιχνεύεται ότι δεν υπάρχει βελτίωση. Ρυθμίζει το πότε θα σταματήσει η διαδικασία εκπαίδευσης με βάση τις παραμέτρους όπως: monitor (π.χ. val\_loss, val\_accuracy), min\_delta (ελάχιστη αλλαγή που απαιτείται για να θεωρηθεί ως βελτίωση), patience (αριθμός εποχών χωρίς βελτίωση πριν τη διακοπή), restore\_best\_weights (διατήρηση των καλύτερων βαρών μετά τη διακοπή) [107].
- **Σημείο Ελέγχου του Μοντέλου (Model Checkpoint):** Αποθηκεύει το μοντέλο κατά τη διάρκεια της εκπαίδευσης, σε κάθε εποχή ή όταν επιτευχθεί κάποια συγκεκριμένη απόδοση. Ρυθμίζει τις παραμέτρους όπως: filepath (το μονοπάτι όπου θα αποθηκευτεί το μοντέλο), monitor (π.χ. val\_loss, val\_accuracy), save\_best\_only (αποθήκευση μόνο του καλύτερου μοντέλου), mode (ελάχιστη ή μέγιστη τιμή για την παρακολουθούμενη τιμή) [107].

#### 4.1.11 Optimizer

Οι βελτιστοποιητές στη βαθιά εκμάθηση είναι καίριοι για την προσαρμογή των παραμέτρων ενός μοντέλου, με σκοπό την ελαχιστοποίηση της συνάρτησης απώλειας. Η απόδοση και η ταχύτητα εκπαίδευσης ενός μοντέλου μπορεί να επηρεαστεί σημαντικά από την επιλογή του βελτιστοποιητή. Συχνά χρησιμοποιούμενοι βελτιστοποιητές:

- Stochastic Gradient Descent (SGD)
- Momentum

- Adagrad
- Adadelta
- Adam
- RMSprop
- AdamW

Κάθε βελτιστοποιητής έχει τα δικά του μοναδικά χαρακτηριστικά, πλεονεκτήματα και αδυναμίες και ορισμένοι μπορεί να ταιριάζουν καλύτερα σε συγκεκριμένα προβλήματα και αρχιτεκτονικές. Η επιλογή του κατάλληλου βελτιστοποιητή εξαρτάται από το συγκεκριμένο πρόβλημα και την αρχιτεκτονική του μοντέλου και είναι σημαντική, καθώς μπορεί να επηρεάσει την απόδοσή του [108].

#### 4.1.12 Sample weights

Στον κόσμο της εποπτευόμενης μηχανικής εκμάθησης, τα ισορροπημένα δεδομένα διαδραματίζουν έναν καθοριστικό ρόλο στην εκπαίδευση ενός αποτελεσματικού μοντέλου. Αυτό είναι εξαιρετικά σημαντικό, καθώς θέλουμε το μοντέλο μας να είναι εξίσου ενημερωμένο για όλες τις κατηγορίες των δεδομένων.

Τα βάρη των κλάσεων είναι μια τεχνική που δίνει μεγαλύτερη ή μικρότερη σημασία σε κάθε κατηγορία, ανάλογα με την αναλογία της παρουσίας της στο σύνολο δεδομένων. Πολλοί ταξινομητές, όπως αυτοί του Scikit-Learn, προσφέρουν μια παράμετρο `class_weights` που μπορεί να ισορροπήσει αυτομάτως τα βάρη των κατηγοριών, ή να ρυθμιστεί χειροκίνητα για να αντικατοπτρίσει την επιθυμητή σημασία κάθε κατηγορίας [109].

Αυτή η τεχνική λειτουργεί αλλάζοντας την επίδραση που έχει το σφάλμα κάθε σημείου στη συνάρτηση απώλειας, η οποία είναι αυτή που επιχειρεί να ελαχιστοποιήσει το μοντέλο κατά τη διάρκεια της εκπαίδευσης. Συγκεκριμένα, το σφάλμα κάθε σημείου πολλαπλασιάζεται με το βάρος της αντίστοιχης κατηγορίας. Αυτό σημαίνει ότι το μοντέλο θα προσπαθήσει περισσότερο να διορθώσει τα λάθη στις κατηγορίες με τα υψηλότερα βάρη, καθώς αυτά θα αυξάνουν περισσότερο τη συνολική απώλεια.

Χωρίς τη ρύθμιση βαρών, το μοντέλο θα αντιμετώπιζε κάθε σημείο δεδομένων ως ισοδύναμο, πράγμα που μπορεί να οδηγήσει σε παραποιημένα αποτελέσματα εάν οι κατηγορίες δεν είναι ισορροπημένες. Η χρήση βαρών κλάσης είναι λοιπόν μια ισχυρή στρατηγική για τη βελτίωση της απόδοσης των μοντέλων εκπαίδευσης σε μη ισορροπημένα δεδομένα [109].

#### 4.1.13 StratifiedShuffleSplit

Το StratifiedShuffleSplit είναι μια συνδυαστική μέθοδος των ShuffleSplit και StratifiedKFold. Χρησιμοποιώντας το StratifiedShuffleSplit, ο λόγος κατανομής των κλάσεων ετικετών είναι σχεδόν ισόρροπος ανάμεσα στα σετ εκπαίδευσης και δοκιμής. Η κύρια διαφορά μεταξύ StratifiedShuffleSplit και StratifiedKFold (shuffle=True) είναι ότι στο StratifiedKFold, το σύνολο δεδομένων ανακατεύεται μόνο μια φορά στην αρχή και στη συνέχεια χωρίζεται σε τον αριθμό προκαθορισμένων φύλλων (folds). Αυτό απορρίπτει οποιαδήποτε πιθανότητα επικάλυψης των συνόλων εκπαίδευσης και δοκιμής. Ωστόσο, στο StratifiedShuffleSplit, τα δεδομένα ανακατεύονται κάθε φορά πριν γίνει η διαχωριστική διαδικασία και αυτός είναι ο λόγος που υπάρχει μεγαλύτερη πιθανότητα να υπάρχει επικάλυψη μεταξύ των σετ εκπαίδευσης και δοκιμής. Αυτό δεν είναι απαραίτητα αρνητικό, ανάλογα με τον τρόπο που χρησιμοποιείτε τα δεδομένα σας. Οι διαρροές δεδομένων μπορούν να είναι πρόβλημα όταν τα δεδομένα στα σετ εκπαίδευσης, επικύρωσης ή δοκιμής προέρχονται από τις ίδιες πηγές και υπάρχει η πιθανότητα οι πληροφορίες να "διαρρεύσουν" ανάμεσα στα σετ. Ωστόσο, στο StratifiedShuffleSplit, η διαδικασία τυχαιοποίησης πριν από τον διαχωρισμό μειώνει τον κίνδυνο τέτοιων διαρροών [115].

#### 4.1.14 L2 Τεχνική τακτοποίησης

Η τεχνική τακτοποίησης L2 (regularizers l2) εμπίπτει στην κατηγορία της τακτοποίησης βάρους/παραμέτρου. Αυτός ο τύπος τακτοποίησης διατηρεί τα βάρη του νευρωνικού δικτύου μικρά (σχεδόν μηδέν) προσθέτοντας έναν όρο τιμωρίας στη συνάρτηση απώλειας. Τα μεγάλα βάρη δίνουν υπερβολική έμφαση σε ορισμένες εισόδους που μπορεί να είναι σημαντικές κατά την εκπαίδευση των μοντέλων, αλλά λιγότερο σημαντικές κατά τη δοκιμή του μοντέλου σε νέα αόρατα δεδομένα. Αυτό θα έχει ως αποτέλεσμα υψηλή διακύμανση και υπερβολική προσαρμογή στο μοντέλο. Διατηρώντας τα βάρη του δικτύου μικρά, οι μέθοδοι τακτοποίησης L2 προσπαθεί να μειώσει την υπερπροσαρμογή. Τα νευρωνικά δίκτυα με μικρές τιμές βάρους δεν είναι πολύ ευαίσθητα στον θόρυβο που υπάρχει στα δεδομένα εισόδου [113].

#### 4.1.15 Συναρτήσεις Ενεργοποίησης (Activation Functions)

Οι συναρτήσεις ενεργοποίησης είναι μαθηματικές συναρτήσεις που εφαρμόζονται στις εισόδους ενός νευρωνικού δικτύου για να προσδώσουν μη γραμμικότητα και να επιτρέψουν την εκμάθηση πιο περίπλοκων συσχετίσεων μεταξύ των δεδομένων εισόδου. Οι διάφοροι τύποι συναρτήσεων ενεργοποίησης σε νευρωνικά δίκτυα περιλαμβάνουν [100]:

1. **Συναρτήσεις Ενεργοποίησης Sigmoid:** Η συνάρτηση Sigmoid λαμβάνει ως είσοδο μια πραγματική τιμή και επιστρέφει μια τιμή μεταξύ 0 και 1. Η συνάρτηση αυτή αντιστοιχεί τιμές εισόδου στο εύρος  $(-\infty, \infty)$  στο εύρος  $(0, 1)$ .
2. **Συναρτήσεις Ενεργοποίησης Tanh:** Η συνάρτηση Tanh είναι μια μη γραμμική συνάρτηση ενεργοποίησης που αντιστοιχεί τιμές εισόδου στο εύρος  $(-\infty, \infty)$  στο εύρος  $(-1, 1)$ .

3. **Συναρτήσεις Ενεργοποίησης ReLU:** Η συνάρτηση ReLU εφαρμόζει την απλή φόρμουλα  $\max(0, z)$ . Προσφέρει τα ίδια πλεονεκτήματα με την συνάρτηση Sigmoid, αλλά με καλύτερη απόδοση.
4. **Leaky ReLU:** Είναι μια παραλλαγή της ReLU. Αντί για την τιμή 0 όταν  $z < 0$ , η Leaky ReLU επιτρέπει μια μικρή, μη μηδενική, σταθερή κλίση  $\alpha$  (συνήθως  $\alpha=0.01$ ).
5. **Parametric ReLU:** Η Parametric ReLU επιτρέπει στους νευρώνες να επιλέγουν την καλύτερη κλίση στην αρνητική περιοχή.
6. **Συναρτήσεις Ενεργοποίησης Maxout:** Η Maxout είναι γενίκευση των συναρτήσεων ReLU και Leaky ReLU. Είναι μια τμηματικά γραμμική συνάρτηση που επιστρέφει το μέγιστο των εισόδων.
7. **Συναρτήσεις Ενεργοποίησης ELU:** Η ELU (Exponential Linear Unit) είναι μια συνάρτηση που τείνει να συγκλίνει γρηγορότερα και να παράγει πιο ακριβή αποτελέσματα.
8. **Συναρτήσεις Ενεργοποίησης Softmax:** Υπολογίζει την κατανομή των πιθανοτήτων για 'n' διάφορα γεγονότα. Χρήσιμη στην κατηγοριοποίηση πολλαπλών κατηγοριών, επιτρέπει την πρόβλεψη της πιο πιθανής κατηγορίας και της βεβαιότητας αυτής της πρόβλεψης.

Οι επιλογές σχετικά με την συνάρτηση ενεργοποίησης που θα χρησιμοποιηθεί, εξαρτώνται από τον τύπο του προβλήματος και το εύρος της αναμενόμενης εξόδου. Όσον αφορά τα κρυφά επίπεδα, ως γενική οδηγία, θα πρέπει να χρησιμοποιούμε τη συνάρτηση ενεργοποίησης ReLU. Η softmax είναι επίσης σημαντική στην εκπαίδευση νευρωνικών δικτύων, καθώς χρησιμοποιείται συχνά ως συνάρτηση ενεργοποίησης στην τελευταία στρώση ενός ταξινομητή πολλών κατηγοριών, που εκτιμά τις πιθανότητες κάθε κατηγορίας για μια είσοδο.

#### 4.1.16 Συνάρτηση Απώλειας (Loss Function)

Οι συναρτήσεις απώλειας είναι ένας από τους πιο σημαντικούς παράγοντες των νευρωνικών δικτύων, καθώς (μαζί με τις συναρτήσεις βελτιστοποίησης) είναι άμεσα υπεύθυνες για την εκμάθηση του μοντέλου στα δεδομένα εκπαίδευσης.

Οι συναρτήσεις απώλειας συγκρίνουν τις στοχευόμενες και προβλεπόμενες τιμές εξόδου, μετρώντας πόσο καλά το νευρωνικό δίκτυο μοντελοποιεί τα δεδομένα εκπαίδευσης. Στην εκπαίδευση, στοχεύουμε να ελαχιστοποιήσουμε αυτήν την απώλεια. Υπάρχουν δύο κύριες τύποι συναρτήσεων απώλειας και είναι αυτές που συνδέονται με τους 2 κύριους τύπους νευρωνικών δικτύων: συναρτήσεις απώλειας παλινδρόμησης (regression) και ταξινόμησης (classification) [110].

- **Mean Squared Error (MSE):** Οι συναρτήσεις απώλειας παλινδρόμησης χρησιμοποιούνται σε νευρωνικά δίκτυα παλινδρόμησης, όπου το μοντέλο προβλέπει μια αντίστοιχη τιμή εξόδου (αντί για προεπιλεγμένες ετικέτες), π.χ. Μέσο Τετραγωνικό Σφάλμα, Μέσο Απόλυτο Σφάλμα.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4.1)$$

Οι συναρτήσεις απώλειας ταξινόμησης χρησιμοποιούνται σε νευρωνικά δίκτυα ταξινόμησης, όπου το νευρωνικό δίκτυο παράγει ένα διάνυσμα πιθανοτήτων που ανήκει σε διάφορες προκαθορισμένες κατηγορίες, π.χ. Δυαδική Διασταυρούμενη Εντροπία, Κατηγορική Διασταυρούμενη Εντροπία [110].

- **Binary Cross-Entropy/Log Loss:** Οι συναρτήσεις απώλειας διασταυρούμενης εντροπίας χρησιμοποιούνται σε μοντέλα ταξινόμησης, όπου το μοντέλο πρέπει να ταξινομήσει μια είσοδο σε μία από δύο προκαθορισμένες κατηγορίες. Στη δυαδική ταξινόμηση, υπάρχουν μόνο δύο πιθανές πραγματικές τιμές του  $y$  0 ή 1.

$$\log loss = \frac{1}{N} \sum_{i=1}^N -(y_i * \log(p_i) + (1 - y_i) * \log(1 - p_i)) \quad (4.2)$$

- **Categorical Cross-Entropy Loss:** Σε περιπτώσεις όπου ο αριθμός των κατηγοριών είναι μεγαλύτερος από δύο, χρησιμοποιούμε την κατηγορική διασταυρούμενη εντροπία.

$$Loss = - \sum_{j=1}^K y_j \log(\hat{y}_j) \quad (4.3)$$

where  $k$  is number of classes in the data

#### 4.1.17 Confusion Matrix και Classification Report

Ταξινόμηση είναι το έργο της ανάθεσης μιας παρατήρησης σε μια κατηγορία με βάση συγκεκριμένα κριτήρια. Στη μηχανική μάθηση, η ταξινόμηση είναι μέρος της εποπτευόμενης μάθησης, πράγμα που σημαίνει ότι τα δεδομένα που χρησιμοποιούνται για την εκπαίδευση του μοντέλου έχουν ετικέτες που προσδιορίζουν κάθε κατηγορία. Ένα κρίσιμο βήμα στον κύκλο ζωής ενός μοντέλου μηχανικής μάθησης είναι η αξιολόγηση της απόδοσής του.

Δύο τεχνικές που χρησιμοποιούνται για την αξιολόγηση ενός μοντέλου ταξινόμησης είναι ο πίνακας σύγχυσης και η αναφορά ταξινόμησης. Πίνακας σύγχυσης και έκθεση ταξινόμησης

Ο **πίνακας σύγχυσης (confusion matrix)** είναι ένας πίνακας  $N \times N$  (όπου  $N$  είναι ο αριθμός των κλάσεων) που περιέχει τον αριθμό των σωστών και εσφαλμένων προβλέψεων του μοντέλου ταξινόμησης. Για να δημιουργήσουμε τον πίνακα σύγχυσης, μπορούμε να χρησιμοποιήσουμε το `sklearn confusion_matrix()`, το οποίο παίρνει τις πραγματικές τιμές ( $y_{test}$ ) και τις προβλεπόμενες τιμές ( $y_{predict}$ ). Μπορούμε να χρησιμοποιήσουμε το `seaborn` για να εκτυπώσουμε έναν θερμικό χάρτη του πίνακα σύγχυσης [111].

Οι σειρές του πίνακα αντιπροσωπεύουν τις πραγματικές κλάσεις, ενώ οι στήλες τις προβλεπόμενες κλάσεις. Οι τιμές που επιστρέφονται από τον πίνακα σύγχυσης χωρίζονται στις ακόλουθες κατηγορίες:

- True Positive (TP): Το μοντέλο προέβλεψε θετικό και η πραγματική τιμή είναι θετική.
- True Negative (TN): Το μοντέλο προέβλεψε αρνητικό και η πραγματική τιμή είναι αρνητική.
- False Positive (FP): Το μοντέλο προέβλεψε θετικό, αλλά η πραγματική τιμή είναι αρνητική (σφάλμα τύπου I).
- False Negative (FN): Το μοντέλο προέβλεψε αρνητικό, αλλά η πραγματική τιμή είναι θετική (σφάλμα τύπου II).

Η διαγώνιος από πάνω αριστερά προς τα κάτω δεξιά περιέχει τις παρατηρήσεις που έχουν προβλεφθεί σωστά.

		Predicted	
		Negative (N) -	Positive (P) +
Actual	Negative -	True Negative (TN)	False Positive (FP) Type I Error
	Positive +	False Negative (FN) Type II Error	True Positive (TP)

Σχήμα 4.4 Πίνακας Confusion Matrix

Μετρικές για την αξιολόγηση ενός **μοντέλου ταξινόμησης(Classification Report)** [111]:

- **Accuracy:** Η ακρίβεια επιστρέφει το ποσοστό των σωστών προβλέψεων.

$$Accuracy = (TP + TN) / (TP + TN + FP + FN) \quad (4.4)$$

- **Precision:** Η ακρίβεια επιστρέφει την αναλογία των αληθινών θετικών μεταξύ όλων των τιμών που προβλέπονται ως θετικές.

$$Precision = TP / (TP + FP) \quad (4.5)$$

- **Recall:** Η ανάκληση επιστρέφει το ποσοστό των θετικών τιμών που έχουν προβλεφθεί σωστά.

$$Recall = TP / (TP + FN) \quad (4.6)$$

- **Specificity:** Η ειδικότητα επιστρέφει την αναλογία των αρνητικών τιμών που έχουν προβλεφθεί σωστά.

$$Specificity = TN / (TN + FP) \quad (4.7)$$

- **F1-score:** Η βαθμολογία f1 είναι η αρμονική μέση ακρίβεια(precision) και ανάκληση(recall). Συχνά χρησιμοποιείται για τη σύγκριση ταξινομητών. Η αρμονική μέση τιμή δίνει μεγαλύτερη βαρύτητα στη χαμηλότερη τιμή, επομένως μια υψηλή βαθμολογία F1 σημαίνει ότι τόσο η ακρίβεια όσο και η ανάκληση είναι υψηλή.

$$F_1 - score = (2 \times Precision \times Recall) / (Precision + Recall) \quad (4.8)$$

Μπορούμε να χρησιμοποιήσουμε το sklearn για να υπολογίσουμε τις παραπάνω μετρήσεις. Εκτός από τις μετρήσεις αξιολόγησης, η αναφορά ταξινόμησης περιλαμβάνει ορισμένες πρόσθετες πληροφορίες:

- **Support:** αριθμός παρατηρήσεων για κάθε τάξη.
- **Macro average:** ο αριθμητικός μέσος όρος μιας μέτρησης μεταξύ των κατηγοριών.

$$Macro\ average(precision) = (p_0 + p_1) / s_i \quad (4.9)$$

- **Weighted average:** ο σταθμισμένος μέσος όρος υπολογίζεται διαιρώντας το άθροισμα (μετρική ενδιαφέροντος x βάρος) με το άθροισμα (βάρη). Εδώ τα βάρη είναι ο αριθμός παρατήρησης για κάθε τάξη  $s$ .

$$Weighted\ average(precision) = (p_0 \times s_0) + (p_1 \times s_1) / (s_0 + s_1) \quad (4.10)$$

## 4.2 Δεδομένα

### 4.2.1 Περιγραφή του συνόλου δεδομένων

Η ομάδα του SenseLab, με τη σημαντική συνεισφορά του κ. Παναγιώτη Παρτσινέβελου και των συνεργατών του, συνέλεξαν τα δεδομένα για αυτήν την έρευνα. Χρησιμοποίησαν ένα εξελιγμένο εργαλείο, τη θερμική κάμερα Flir Tau 2 core, που τοποθετήθηκε σε ύψος 9 μέτρων από το έδαφος και 30 μέτρα από τον τοίχο ενός κτιρίου στο ΜΗΧ.Ο.Π, νοτιοανατολικού προσανατολισμού.




Εικόνα 4.5 Οπτική εικόνα του κτιρίου στο ΜΗΧ.Ο.Π όπου έλαβε χώρα η έρευνά μας

Είναι αξιοσημείωτο ότι αυτή η θερμική κάμερα λειτουργεί βασιζόμενη στην αρχή της υπέρυθρης ακτινοβολίας, με το γυαλί της να λειτουργεί σαν καθρέφτης. Κατά τη διάρκεια της λήψης εικόνων, το γυαλί θερμαίνεται, δημιουργώντας θόρυβο και παραμόρφωση στα δεδομένα της θερμοκρασίας.

Στο διάστημα δύο ημερών, συγκεντρώθηκε μια χρονοσειρά από 104 φωτογραφίες σε διαστήματα 15 λεπτών, από την Πέμπτη 30 Ιουλίου 2020 στις 14.15 έως και την Παρασκευή 31 Ιουλίου 2020 στις 16:00. Κατά τη διάρκεια αυτής της περιόδου, η εξωτερική θερμοκρασία κυμαίνεται από 22 έως 33



βαθμούς Κελσίου, ενώ η εσωτερική θερμοκρασία παρέμεινε σταθερή στους 23 βαθμούς, χάρη στο σύστημα κλιματισμού του κτιρίου.



Εικόνα 4.6 Διάγραμμα εξωτερικής θερμοκρασίας και καιρικών συνθηκών συναρτήσει της ώρας στα δεδομένα μας.

Η έρευνα μας, μέσω της ανάλυσης θερμογραφικών εικόνων, αποκάλυψε ασυνήθιστες περιοχές στο κτίριο, με τη χρήση της παθητικής θερμογραφίας. Αυτές οι περιοχές μπορεί να δείχνουν μια σειρά από πιθανές ανωμαλίες, όπως ελλείψεις στη θερμομόνωση, προβλήματα με το σύστημα κλιματισμού ή άλλες πηγές απώλειας θερμότητας.

Προκειμένου να εισαχθούν τα δεδομένα στο νευρωνικό δίκτυο, υπήρξε ανάγκη για προεπεξεργασία τους. Αυτό ήταν απαραίτητο για να αποφευχθεί η υπερεκπαίδευση λόγω του περιορισμένου αριθμού δεδομένων, όπως θα εξηγηθεί παρακάτω.

## 4.2.2 Προετοιμασία Δεδομένων

Σε ένα πρόγραμμα επεξεργασίας δεδομένων, η προεπεξεργασία αποτελεί μια ζωτική φάση, καθώς είναι η διαδικασία μέσω της οποίας τα ακατέργαστα δεδομένα μετατρέπονται σε μια μορφή που είναι κατανοητή και προσβάσιμη για τα αναλυτικά εργαλεία και τα μοντέλα. Η διαδικασία αυτή μπορεί να περιλαμβάνει τον καθαρισμό δεδομένων, την αφαίρεση των περιττών χαρακτηριστικών, την εξαγωγή χρήσιμων χαρακτηριστικών και την κανονικοποίηση των τιμών.

Στην περίπτωσή μας, η προεπεξεργασία είναι ουσιαστική για την επεξεργασία και την ανάλυση των εικόνων θερμοκρασίας. Οι εικόνες αυτές περιέχουν μια πληθώρα πληροφοριών, όπως τις τιμές της θερμοκρασίας σε κάθε pixel. Προκειμένου να εξάγουμε αυτές τις πληροφορίες και να τις χρησιμοποιήσουμε για την αναγνώριση των ασυνήθιστων περιοχών σε κάθε εικόνα, εφαρμόζουμε μια σειρά διαδοχικών βημάτων προεπεξεργασίας.

Σε αυτά τα βήματα συμπεριλαμβάνονται τα εξής:

- 1. Φόρτωση εικόνων και εξαγωγή χρονοσημάνσεων:** Φόρτωση των εικόνων και μετατροπή αυτών σε πίνακες numpy, διαβάζουμε τιν εικόνες χρησιμοποιώντας την συνάρτηση `imread` από το πακέτο `io` και την κόβουμε για να διατηρήσουμε μόνο την περιοχή που μας ενδιαφέρει (ROI). Από 512x640 γίνεται 200x600. Εκτός από την επεξεργασία των εικόνων, εξάγουμε επίσης το χρονικό στίγμα τροποποίησης του κάθε αρχείου (timestamp) . Αυτό επιτρέπει τη χρονολογική παρακολούθηση των εικόνων και την κατανόηση των δυνητικών τάσεων ή προτύπων που εμφανίζονται κατά τη διάρκεια του χρόνου. Η χρονοσήμανση αυτή είναι ιδιαίτερα σημαντική για την κατανόηση της εξέλιξης των φαινομένων που παρατηρούμε. Τέλος, οι εικόνες μας είναι μονόχρωμες (greyscale) και όχι RGB. Αυτό είναι σωστό, εφόσον οι εικόνες θερμικής απεικόνισης συνήθως είναι μονόχρωμες, καθώς η πληροφορία χρώματος δεν χρησιμοποιείται για να κωδικοποιήσει τη θερμοκρασία. Έτσι, κάθε pixel στην εικόνα αντιστοιχεί σε μια τιμή θερμοκρασίας και απεικονίζεται με μια απόχρωση του γκρι.
- 2. Μετατροπή Θερμοκρασίας:** Η λίστα `external_temperatures` περιέχει τιμές της εξωτερικής θερμοκρασίας σε Φαρενάιτ καθόλη τη διάρκεια της έρευνας ,τις οποίες αποκτήσαμε από μετεωρολογικό σταθμό [112]. Μετατρέπουμε αυτές τις θερμοκρασίες σε Κελσίου με τον τύπο  $(temp - 32) * 5/9$ . Επίσης, αναθέτουμε την εσωτερική θερμοκρασία σε Κελσίου (23°C) σε μια μεταβλητή.
- 3. Μετατροπή και Κανονικοποίηση Εικόνων:** Μετατρέπουμε τις φορτωμένες εικόνες μας (που είναι σε Κέλβιν) σε Κελσίου με τον τύπο  $0.04 * images\_np - 273.15$ . Αυτό είναι ένα ουσιώδες βήμα, καθώς η αναπαράσταση των θερμοκρασιών σε Κελσίου είναι πιο κατανοητή και διαχειρίσιμη στο πλαίσιο της ανάλυσής μας. Με τις συναρτήσεις `np.min` και `np.max` βρίσκει την ελάχιστη και την μέγιστη τιμή της θερμοκρασίας αντίστοιχα, στο σύνολο των εικόνων. Στο επόμενο βήμα, οι τιμές των εικόνων κανονικοποιούνται ώστε να βρίσκονται στο διάστημα [0,1]. Αυτό επιτυγχάνεται αφαιρώντας την ελάχιστη τιμή από κάθε pixel και διαιρώντας με τη διαφορά της μέγιστης και της ελάχιστης τιμής. Αν οι δύο αυτές τιμές είναι ίδιες (πράγμα που σημαίνει ότι όλοι τα pixels έχουν την ίδια τιμή) εκτυπώνεται μια προειδοποίηση και οι εικόνες μετατρέπονται απλώς αφαιρώντας την ελάχιστη τιμή. Συνοψίζοντας, ο κώδικάς μας μετατρέπει τις τιμές των εικόνων από Kelvin σε Celsius, βρίσκει το εύρος των τιμών και στη συνέχεια κανονικοποιεί τις εικόνες ώστε να έχουν τιμές μεταξύ 0 και 1, με βάση της μεθόδου Min-Max κανονικοποίησης (Min-Max normalization) για εικόνες που παριστάνουν θερμοκρασίες σε Celsius.
- 4. Ετικέτες Εικόνων (labels):** Βασισμένοι στην ανάλυση των δεδομένων θερμοκρασίας στην εικόνα, αναθέτουμε μια ετικέτα σε κάθε εικόνα. Αυτό γίνεται με τα εξής βήματα:

**a. Υπολογισμός της συνολικής μέσης θερμοκρασίας:** Απολαβαίνοντας το υψηλό επίπεδο τεχνολογίας της θερμογραφίας, μπορούμε να υπολογίσουμε τη μέση εμφανή θερμοκρασία μιας θερμικής εικόνας. Η εξαγωγή της μέσης(εμφανούς) θερμοκρασίας από μια θερμική εικόνα είναι μια σημαντική διαδικασία για την ανάλυση και την κατανόηση των δεδομένων που περιέχει. Κάθε pixel στην εικόνα αντιστοιχεί σε μια συγκεκριμένη τιμή θερμοκρασίας. Έτσι, για να υπολογίσουμε τη μέση θερμοκρασία της εικόνας, πρέπει να λάβουμε υπόψη μας τις τιμές θερμοκρασίας όλων των pixels. Αυτό σημαίνει ότι πρέπει να αθροίσουμε τις τιμές θερμοκρασίας όλων των pixels και στη συνέχεια να διαιρέσουμε με τον συνολικό αριθμό των pixels. Το αποτέλεσμα θα είναι η μέση θερμοκρασία της εικόνας. Είναι σημαντικό να σημειωθεί ότι η εμφανής θερμοκρασία αναφέρεται στην εμφανή θερμοκρασία του αντικειμένου όπως αντιλαμβάνεται από τον αισθητήρα, και μπορεί να διαφέρει από την πραγματική θερμοκρασία λόγω διάφορων παραγόντων.

**b. Υπολογισμός της μέσης τιμής και της τυπικής απόκλισης για ασυνήθιστες περιοχές:** Για την ανίχνευση ασυνήθιστα κρύων και θερμών περιοχών, ορίζουμε κατώφλι εμπιστοσύνης. Το κατώφλι αυτό λαμβάνει υπόψη την τυπική απόκλιση της θερμοκρασίας στις κρύες και ζεστές περιοχές, προκειμένου να προσδιορίσουμε τι θεωρείται ασυνήθιστα κρύο ή θερμό. Η τυπική απόκλιση παρέχει πληροφορίες για το πόσο συγκεντρωμένες ή αποκλίνουσες είναι οι τιμές θερμοκρασίας από τη μέση τιμή. Όταν η τυπική απόκλιση είναι μεγαλύτερη, τότε οι τιμές θερμοκρασίας αποκλίνουν περισσότερο από τη μέση τιμή. Συνεπώς, μπορούμε να θεωρήσουμε μια περιοχή ως ασυνήθιστα κρύα ή θερμή, εάν ένα pixel σε αυτή την περιοχή έχει θερμοκρασία που βρίσκεται πολύ κάτω ή πολύ πάνω από τη μέση τιμή των κρύων ή ζεστών περιοχών αντίστοιχα. Για να υπολογίσουμε τη μέση τιμή και την τυπική απόκλιση για ασυνήθιστες περιοχές, ακολουθούμε τα εξής βήματα:

- Εντοπίζουμε περιοχές που είναι πιο κρύες ή πιο ζεστές από τη συνολική μέση θερμοκρασία.
- Υπολογίζουμε τη μέση τιμή των τιμών θερμοκρασίας σε αυτές τις περιοχές. Η μέση τιμή αντιπροσωπεύει τις περιοχές που είναι χαμηλότερες ή μεγαλύτερες από τη συνολική μέση θερμοκρασία .
- Υπολογίζουμε την τυπική απόκλιση των τιμών θερμοκρασίας σε αυτές τις περιοχές. Η τυπική απόκλιση παρέχει μια μέτρηση για το πόσο διαφοροποιούνται οι τιμές θερμοκρασίας από τη μέση τιμή. Όσο υψηλότερη είναι η τυπική απόκλιση, τόσο μεγαλύτερη είναι η διακύμανση των τιμών γύρω από το μέσο όρο.
- Χρησιμοποιούμε τη μέση τιμή και την τυπική απόκλιση για να καθορίσουμε ένα κατώφλι εμπιστοσύνης. Αν ένα pixel έχει θερμοκρασία πολύ χαμηλότερη ή πολύ υψηλότερη από τη μέση τιμή, με βάση αυτό το κατώφλι εμπιστοσύνης, θεωρείται ασυνήθιστη περιοχή.

Με την παραπάνω μεθοδολογία, μπορούμε να ανιχνεύσουμε ασυνήθιστα κρύες και θερμές περιοχές βάσει της συγκριτικής ανάλυσης της θερμοκρασίας σε σχέση με την παγκόσμια μέση θερμοκρασία.

$$\sigma = \sqrt{\frac{\sum (x_i - \mu)^2}{N}} \quad (4.11)$$





$\sigma$ : Population standard deviation

$x$ : Datapoint value

$\mu$ : Population mean


$N$ : Population size

- c. **Δημιουργία μασκών:** Βάσει των καθορισμένων κατωφλίων, δημιουργούμε μάσκες που επισημαίνουν pixels που θεωρούνται ασυνήθιστα κρύα ή ζεστά. υγκεκριμένα μπλε για κρύες και κόκκινο για ζεστές.
- d. **Υπολογισμός της μέσης θερμοκρασίας σε ασυνήθιστες περιοχές:** Υπολογίζουμε τη μέση θερμοκρασία σε αυτές τις ασυνήθιστες κρύες και ζεστές περιοχές.
- e. **Ανάθεση ετικετών:** Βάσει της παρουσίας ασυνήθιστων κρύων και/ή ζεστών περιοχών, αναθέτουμε μια ετικέτα σε κάθε εικόνα (1 για κρύο, 2 για ζεστό, 3 για και τα δύο, και 0 για κανένα).
5. **Οπτικοποίηση και Αποθήκευση:** Οπτικοποιούμε κάθε εικόνα με διάφορα χρώματα που επισημαίνουν ασυνήθιστα κρύες και ζεστές περιοχές. Στη συνέχεια, αποθηκεύουμε αυτές τις εικόνες με επιπλέον πληροφορίες όπως το χρονικό στίγμα, τον αριθμό των κρύων/ζεστών pixels, το εύρος θερμοκρασίας, την εξωτερική/εσωτερική θερμοκρασία, την παγκόσμια μέση θερμοκρασία, τη μέση θερμοκρασία σε ασυνήθιστες περιοχές, και εάν η εικόνα περιέχει οποιεσδήποτε ασυνήθιστες περιοχές.



Σχήμα 4.8 Παράδειγμα εικόνων μετά την ετικέτοποίηση στα δεδομένα μας. Εικόνες με label 1 εντοπίζει μόνο κρύες περιοχές, με label 3 και κρύες και ζεστές.

Παρακάτω παρουσιάζεται ένα ιστόγραμμα που αναπαριστά την κατανομή των ετικετών στον άξονα των  $x$  και τον αριθμό εμφάνισής τους στον άξονα των  $y$ . Το ιστόγραμμα δίνει μια εικόνα της συχνότητας εμφάνισης κάθε ετικέτας στο dataset ή στο πρόβλημα που αναλύεται. Μπορεί να υπάρχουν ετικέτες που εμφανίζονται περισσότερο συγκριτικά με άλλες, προκαλώντας ένα έμφαση σε συγκεκριμένες κατηγορίες. Γενικά, το ιστόγραμμα μπορεί να χρησιμοποιηθεί για να αναγνωριστούν τάσεις, ανισορροπίες ή παρατηρήσεις στα δεδομένα. Αυτή η προεπεξεργασία των δεδομένων μπορεί να προετοιμάσει το έδαφος για περαιτέρω ανάλυση και αξιολόγηση του προβλήματος.



Σχήμα 4.9 Παράδειγμα ιστογράμματος του προβλήματός μας. Η ετικέτα 1 αντιπροσωπεύει τις κρύες περιοχές , η 2 τις ζεστές, η 3 είναι και για τα δύο, και 0 για κανένα από τα δύο.

Βασιζόμενοι στην ανάλυση του ιστογράμματος, παρατηρούμε ότι οι ετικέτες 1 και 3 διαφέρουν σημαντικά από τις ετικέτες 0 και 2 σε ό,τι αφορά τη συχνότητα εμφάνισής τους.

Η ετικέτα 1 εμφανίζεται στο εύρος από το 40% έως το 50% του συνόλου των εικόνων. Η ετικέτα 3 εμφανίζεται κοντά στο 60% του συνόλου των εικόνων. Αυτό υποδηλώνει ότι οι συγκεκριμένες κατηγορίες είναι επίσης σημαντικές και απαρτίζουν μεγάλο ποσοστό του dataset.

Από την άλλη πλευρά, οι ετικέτες 0 και 2 δεν έχουν καμία εμφάνιση στο ιστόγραμμα. Αυτό υποδηλώνει ότι αυτές οι κατηγορίες απουσιάζουν εντελώς από το dataset εικόνων.

Με βάση αυτά τα στοιχεία, το συμπέρασμα που μπορούμε να βγάλουμε είναι ότι οι ετικέτες 1 και 3 αποτελούν σημαντικές κατηγορίες στο πρόβλημα που αναλύεται. Από την άλλη πλευρά, οι ετικέτες 0 και 2 δεν παρουσιάζουν σημαντική παρουσία στα δεδομένα. Επίσης παρατηρούμε μια ανισορροπία μεταξύ των ετικετών 1 και 3 στο πρόβλημα που αναλύουμε. Αυτό το συμπέρασμα είναι σημαντικό για τον καθορισμό των προτεραιοτήτων κατά την ανάπτυξη μοντέλων μηχανικής μάθησης ή την εκτέλεση περαιτέρω αναλύσεων. Μπορεί να είναι απαραίτητο να ληφθούν ειδικά μέτρα για να αντιμετωπιστεί η ανισορροπία αυτή, όπως η χρήση τεχνικών όπως η υποδειγματοληψία (undersampling) ή υπερδειγματοληψία (oversampling) των δεδομένων.

Συνολικά, η ανισορροπία μεταξύ των ετικετών 1 και 3 προσδίδει σημασία στην επιλογή και την εφαρμογή ανάλογων τεχνικών επεξεργασίας δεδομένων, προκειμένου να επιτευχθεί μια ισορροπημένη και αξιόπιστη ανάλυση του προβλήματος.

Τέλος αυτό είναι το εύρος τιμών θερμοκρασίας των label, με βάση το οποίο κατηγοριοποιήθηκε η κάθε εικόνα σε ένα label:

Temperature Range for Label 0 (No Regions): **No regions**

Temperature Range for Label 1 (Cold Labels): **23.77 to 41.33 Celsius**

Temperature Range for Label 2 (Hot Regions): **No hot regions**

Temperature Range for Label 3 (Cold and Hot Regions): **30.61 to 75.21 Celsius**

## 4.3 Εφαρμογή του Νευρωνικού Δικτύου

### 4.3.1 Προετοιμασία Δεδομένων στη Βαθιά Μάθηση(Deep Learning)

Παρουσίαση των βημάτων που ακολουθήσαμε για την προετοιμασία των δεδομένων, με βάση την προεπεξεργασία μας:

1. **StratifiedShuffleSplit**: Το StratifiedShuffleSplit είναι ένας διαχωριστής του Scikit-learn που χρησιμοποιείται για την τυχαία διαίρεση των δεδομένων εικόνας σε σύνολα εκπαίδευσης, επικύρωσης και ελέγχου με διατηρούμενη ισορροπία των κλάσεων. Δεδομένου ότι οι αρχικές εικόνες είναι 104, με ένα test\_size του 0.4 (ή 40%), τα δεδομένα διαχωρίζονται σε 62 εικόνες εκπαίδευσης και 42 προσωρινές εικόνες. Οι προσωρινές εικόνες στη συνέχεια διαχωρίζονται ξανά με ένα test\_size του 0.5 (ή 50%), σε 21 εικόνες επικύρωσης και 21 εικόνες ελέγχου. Με αυτόν τον τρόπο, διασφαλίζουμε ότι οι κλάσεις των ετικετών (image\_labels) διατηρούν την αρχική κατανομή τους και στο σετ εκπαίδευσης, και στο σετ επικύρωσης, και στο σετ δοκιμής. Αυτό εξασφαλίζει ότι δεν υπάρχει διαρροή πληροφοριών από τα σετ επικύρωσης και δοκιμής προς το σετ εκπαίδευσης κατά τη διάρκεια της εκπαίδευσης του μοντέλου σας. Ο τρόπος που διαχωρίζουμε τα δεδομένα σε τρία σύνολα (εκπαίδευσης, επικύρωσης και δοκιμής) εξασφαλίζει ότι τα δείγματα σε κάθε σύνολο προέρχονται από τις ίδιες κατηγορίες με την αρχική κατανομή, αποτρέποντας έτσι τη διαρροή δεδομένων.
2. **ImageDataGenerator**: Αυτή η κλάση από την βιβλιοθήκη Keras είναι ένα εργαλείο για τη δημιουργία δυναμικά επανειλημμένων δεδομένων εικόνας κατά τη διάρκεια της εκπαίδευσης μέσω τεχνικών διαστρέβλωσης εικόνων. Οι παραμέτροι που χρησιμοποιούνται περιλαμβάνουν:

Περιστροφές εικόνας (rotation\_range).

Οριζόντια και κατακόρυφα μετατοπίσεις (width\_shift\_range, height\_shift\_range).

Παραμόρφωση (shear\_range).





Ζουμ (zoom\_range).

Αναστροφή εικόνας οριζόντια και κατακόρυφα (horizontal\_flip, vertical\_flip).

Αλλαγή στα κανάλια χρωμάτων (channel\_shift\_range).


Μετά την ενίσχυση, τα δεδομένα εκπαίδευσης αυξάνονται σε 1200 εικόνες, ενώ τα δεδομένα επικύρωσης και ελέγχου αυξάνονται σε 150 και 100 εικόνες αντίστοιχα. Ο αρχικός αριθμός εικόνων αυξάνεται επομένως με αυτήν την τεχνική. Για παράδειγμα, εάν υπολογίσουμε τον αριθμό των δειγμάτων που πρέπει να παραχθούν από κάθε εικόνα ώστε να επιτευχθεί ο στόχος των 1200 δειγμάτων εκπαίδευσης, πρέπει να παράγουμε 19 αυξημένες εικόνες για κάθε αρχική εικόνα. Ανάλογα, για τα δείγματα επικύρωσης και ελέγχου, οι αριθμοί θα είναι διαφορετικοί. Το "augment\_ratio" αναφέρεται στο ποσοστό ή στην αναλογία της επαύξησης των δεδομένων εικόνας.

$$\text{augment\_ratio} = (\text{Συνολικές εικόνες} / \text{Αρχικές εικόνες})$$



Σχήμα 4.10 Παράδειγματα εικόνων grayscale με colormap μετά την εφαρμογή του ImageDataGenerator στα δεδομένα μας.





Σχήμα 4.11 Παράδειγματα εικόνων grayscale σε ασπρόμαυρη μορφή μετά την εφαρμογή του ImageDataGenerator στα δεδομένα μας.

### 3. Δειγματοληψία

**Oversampling (RandomOverSampler):** Είναι η τεχνική όπου αυξάνουμε τον αριθμό των δειγμάτων της μειονεκτικής κλάσης για να ταιριάζει με την πλειονεκτική. Αυτό επιτυγχάνεται μέσω της δημιουργίας αντιγράφων των υπάρχοντων δειγμάτων της μειονεκτικής κλάσης, προκειμένου να ισορροπήσει η κατανομή των δειγμάτων ανάμεσα στις κλάσεις. Ωστόσο, το κύριο μειονέκτημα της τεχνικής αυτής είναι ότι μπορεί να προκαλέσει υπερεκπαίδευση, καθώς τα ίδια δείγματα επαναλαμβάνονται.

**Undersampling (RandomUnderSampler):** Στην τεχνική υποδειγματοληψίας, μειώνουμε τον αριθμό των δειγμάτων της πλειονεκτικής κλάσης για να ταιριάζει με την μειονεκτική. Αυτό επιτυγχάνεται διαλέγοντας τυχαία ένα υποσύνολο της πλειονεκτικής κλάσης. Το κύριο μειονέκτημα είναι ότι μπορεί να χαθεί πολύτιμη πληροφορία λόγω της αφαίρεσης δειγμάτων.

## 4.3.2 Ορισμός και Αρχιτεκτονική του Μοντέλου

Για την εκπαίδευση του δικτύου, χρησιμοποιήσαμε ένα σειριακό νευρωνικό δίκτυο (Sequential model). Η αρχιτεκτονική του δικτύου αποτελείται από τα εξής επίπεδα:

1. **Επίπεδα Συνέλιξης (Convolutional Layers):** Το μοντέλο περιέχει πέντε επίπεδα συνέλιξης (Conv2D). Διατρέχουν τις εικόνες με δισδιάστατα φίλτρα, αναγνωρίζοντας τοπικά χαρακτηριστικά μέσω της μαθηματικής λειτουργίας της συνέλιξης. Τα τρία πρώτα έχουν 32, 64, και 128 φίλτρα αντίστοιχα, ενώ τα δύο επόμενα περιέχουν 256 φίλτρα. Όλα τα φίλτρα

έχουν διαστάσεις (3, 3), χρησιμοποιούν τη συνάρτηση ενεργοποίησης 'relu' και την κανονικοποίηση L2 (L2 Regularization) για την αποφυγή υπερεκπαίδευσης.

2. **Επίπεδα Pooling:** Η συνάρτηση αυτή μειώνει τις διαστάσεις των χαρακτηριστικών χαρτών, διατηρώντας τις πληροφορίες. Μετά από κάθε επίπεδο συνέλιξης υπάρχει ένα επίπεδο MaxPooling (MaxPooling2D) με μέγεθος πίσινας (2, 2) .
3. **Επίπεδα Επίπεδοποίησης και Μορφοποίησης:** Το δίκτυο συνεχίζει με ένα επίπεδο Flatten για την επίπεδοποίηση των χαρακτηριστικών χαρτών σε ένα επίπεδο διάνυσμα, το οποίο μπορεί να τροφοδοτηθεί σε πυκνά επίπεδα ή άλλες δομές. και στη συνέχεια αναδιαμορφώνεται χρησιμοποιώντας το επίπεδο Reshape για την προετοιμασία των δεδομένων για το επόμενο επίπεδο LSTM.
4. **Επίπεδο LSTM:** Τα LSTM είναι ένας τύπος επαναληπτικών νευρωνικών δικτύων (RNN) και είναι κατάλληλα για χρονοσειρές ή δεδομένα με ακολουθία. Συμπεριλαμβάνεται ένα επίπεδο LSTM με 256 νευρώνες.
5. **Πυκνά Επίπεδα (Dense Layers):** Συνδέουν κάθε νευρώνα με όλους τους άλλους νευρώνες του επόμενου επιπέδου, επιτρέποντας την εκμάθηση παγκόσμιων σχέσεων μεταξύ χαρακτηριστικών. Το μοντέλο ολοκληρώνεται με έξι πυκνά επίπεδα (Dense). Τα πρώτα πέντε επίπεδα έχουν 256, 256, 128, 64, και 32 νευρώνες αντίστοιχα και χρησιμοποιούν τη συνάρτηση ενεργοποίησης 'relu' με την κανονικοποίηση L2. Επιπλέον, μετά από κάθε ένα από αυτά τα πυκνά επίπεδα υπάρχει ένα επίπεδο Dropout με ποσοστό 0.5 για την αποφυγή υπερεκπαίδευσης. Το τελευταίο επίπεδο περιέχει 4 νευρώνες και χρησιμοποιεί τη συνάρτηση ενεργοποίησης 'softmax'.

#### 4.3.3 Εκπαίδευση του Μοντέλου

Στον δύσκολο κόσμο της βελτιστοποίησης νευρωνικών δικτύων, η επιλογή του κατάλληλου βελτιστοποιητή και των σχετικών παραμέτρων μπορεί να καθορίσει την επιτυχία ή την αποτυχία ενός μοντέλου. Στο πλαίσιο αυτό, υιοθετήσαμε τον Lookahead AdamW, έναν πρωτοποριακό βελτιστοποιητή, σε συνδυασμό με προσεκτικά επιλεγμένες παραμέτρους για την εκπαίδευση του μοντέλου μας.

Κατά τη διάρκεια της εκπαίδευσης του νευρωνικού δικτύου, επιλέξαμε τον βελτιστοποιητή Lookahead AdamW με συγκεκριμένες παραμέτρους που σκοπεύαμε να βελτιστοποιήσουμε την απόδοση του δικτύου. Παρακάτω, αναλύουμε τη διαδικασία που ακολουθήσαμε, επεξηγώντας τον ρόλο κάθε παραμέτρου και την επίδρασή της στην τελική απόδοση του δικτύου.

## Ο Βελτιστοποιητής Lookahead AdamW

- **AdamW:** Ο AdamW είναι μια τροποποιημένη έκδοση του βελτιστοποιητή Adam που συνδυάζει τη βαθμονόμηση και την υποστήριξη υπερβολικής βαρύτητας (L2 regularization), προσφέροντας βελτιωμένες επιδόσεις σε ορισμένες περιπτώσεις
- **Lookahead:** Συνδυάσαμε αυτόν τον βελτιστοποιητή με την τεχνική **Lookahead**, η οποία είναι μια τεχνική βελτίωσης που μπορεί να συνδυαστεί με πολλούς βελτιστοποιητές. διατηρεί δύο σετ βαρών κατά την εκπαίδευση και τα ενημερώνει βάσει της πρόοδου που έχει πραγματοποιηθεί, επιτρέποντας ένα είδος "προεπισκόπησης" της πρόοδου, προκειμένου να καθοδηγηθεί ο βελτιστοποιητής πιο αποτελεσματικά.

## Επιλογή Παραμέτρων

- **weight\_decay=1e-4:** Αυτό είναι ένας συντελεστής που εφαρμόζεται στην υποστήριξη υπερβολικής βαρύτητας (L2 regularization) των βαρών. Πρόκειται για μια τεχνική που βοηθά στην πρόληψη της υπερεκπαίδευσης προσθέτοντας έναν ποινικό όρο στην συνάρτηση κόστους. Πρακτικά προσθέτει έναν ελαφρύ περιορισμό στα βάρη του δικτύου, αποτρέποντας τα να πάρουν υπερβολικά μεγάλες τιμές. Η τιμή του  $1e-4$  σημαίνει ότι η τιμή είναι αρκετά μικρή ώστε να μην επηρεάζει υπερβολικά την εκπαίδευση, αλλά αρκετά μεγάλη ώστε να προσφέρει κάποια μορφή προστασίας από υπερεκπαίδευση.
- **learning\_rate=0.0001:** Ο ρυθμός εκμάθησης ελέγχει πόσο μεγάλο βήμα θα πραγματοποιήσει ο βελτιστοποιητής σε κάθε ενημέρωση. Μια πολύ χαμηλή τιμή μπορεί να καταλήξει σε πολύ αργή εκπαίδευση, ενώ μια πολύ υψηλή τιμή μπορεί να προκαλέσει την εκπαίδευση να "αναπηδά" γύρω από το οπτικό ελάχιστο. Η επιλογή του 0.0001 υποδηλώνει μια σχετικά χαμηλή τιμή που είναι κατάλληλη για πολλά προβλήματα, ειδικά όταν χρησιμοποιούνται βελτιωμένοι βελτιστοποιητές όπως ο AdamW.
- **loss:** Εδώ καθορίζουμε τη συνάρτηση απώλειας (loss function) που θα χρησιμοποιηθεί κατά την εκπαίδευσή μας. Στην περίπτωσή μας, χρησιμοποιούμε την 'sparse\_categorical\_crossentropy', που είναι κατάλληλη για προβλήματα πολυταξινόμησης όπου οι ετικέτες είναι ακέραιοι αριθμοί και όχι one-hot encoded διανύσματα.
- **metrics:** Εδώ ορίζουμε τις μετρικές (metrics) που θέλουμε να παρακολουθούμε κατά τη διάρκεια της εκπαίδευσης. Στην περίπτωση μας, παρακολουθούμε μόνο την ακρίβεια (accuracy) του μοντέλου
- **compute\_sample\_weight:** Η συνάρτηση compute\_sample\_weight με την επιλογή 'balanced' στοχεύει στην αυτόματη υπολογιστική προσαρμογή των βαρών των δειγμάτων με βάση τον αριθμό των δειγμάτων που υπάρχουν σε κάθε κλάση. Ο βασικός σκοπός είναι να αντισταθμίσει το μοντέλο ώστε να μην προκαταλαμβάνεται από τις πιο συχνές κλάσεις και να δίνει μεγαλύτερη σημασία στις λιγότερο αντιπροσωπευτικές κλάσεις κατά την εκπαίδευση. Δίνοντας

βάρη στα δείγματα, βοηθάμε το μοντέλο να εκτιμά καλύτερα την πληροφορία από τις λιγότερο αντιπροσωπευτικές κλάσεις, βελτιώνοντας τη γενική του απόδοση σε αυτές τις κλάσεις.

Συνολικά, η εκπαίδευση του μοντέλου πραγματοποιήθηκε για **200 εποχές** με **batch size 40**, ενώ χρησιμοποιήσαμε και ένα **σύνολο επαλήθευσης** για να παρακολουθούμε την απόδοση και να αποφύγουμε περαιτέρω υπερεκπαίδευση.

### **Στασιμότητα Απώλειας και Πρόωρη Διακοπή στην Εκπαίδευση Νευρωνικών Δικτύων**

**CombinedCallback:** Το CombinedCallback είναι μια προσαρμοσμένη υλοποίηση της κλάσης Callback της βιβλιοθήκης Keras. Χρησιμοποιείται για να παρέχει πρόσθετο έλεγχο στη διαδικασία εκπαίδευσης του μοντέλου. Σε αυτήν την περίπτωση, το CombinedCallback παρακολουθεί την απώλεια της επικύρωσης (val\_loss) και την ακρίβεια της επικύρωσης (val\_accuracy) του μοντέλου στα δεδομένα επικύρωσης. Αν η απώλεια δεν βελτιώνεται για έναν καθορισμένο αριθμό εποχών (που ορίζεται από την patience, π.χ., 3 εποχές) και η ακρίβεια έχει φτάσει στο επιθυμητό επίπεδο (desired\_accuracy, π.χ., 0.85), τότε η εκπαίδευση του μοντέλου διακόπτεται πρόωρα.

Κατά τη διάρκεια της εκπαίδευσης του μοντέλου, η συνεχής παρακολούθηση της απόδοσης και η δυνατότητα αποθήκευσης των καλύτερων εκδόσεων του μοντέλου είναι κρίσιμης σημασίας. Για αυτό το σκοπό, χρησιμοποιήσαμε δύο διαφορετικά checkpoints:

1. **Checkpoint για την Ακρίβεια:** Αυτό το checkpoint παρακολουθεί την ακρίβεια του συνόλου επαλήθευσης (val\_accuracy) και αποθηκεύει την έκδοση του μοντέλου που επιτυγχάνει την υψηλότερη ακρίβεια.
2. **Checkpoint για την Απώλεια:** Αντίστοιχα, αυτό το checkpoint παρακολουθεί την απώλεια του συνόλου επαλήθευσης (val\_loss) και αποθηκεύει το μοντέλο με τη χαμηλότερη απώλεια.

Εκτός από τα παραπάνω checkpoints, χρησιμοποιήσαμε ένα προσαρμοσμένο callback, το CombinedCallback, που συνδυάζει τόσο την παρακολούθηση της απώλειας όσο και της ακρίβειας. Αυτό το callback επεκτείνει τη λειτουργικότητα παρακολούθησης, επιτρέποντάς μας να καθορίσουμε ένα επιθυμητό επίπεδο ακρίβειας (desired\_accuracy) και να διακόψουμε την εκπαίδευση αν το μοντέλο δεν βελτιώνεται μετά από έναν ορισμένο αριθμό εποχών (patience).

Όταν μιλάμε για "στασιμότητα στην απώλεια", αναφερόμαστε στο φαινόμενο κατά το οποίο η απώλεια (ή το κόστος) που υπολογίζεται κατά τη διάρκεια της εκπαίδευσης δεν παρουσιάζει σημαντικές βελτιώσεις μετά από έναν ορισμένο αριθμό εποχών.

Στην πρακτική, αν ένα μοντέλο δεν δείχνει βελτίωση στην απώλεια του συνόλου επαλήθευσης μετά από, π.χ. 3 εποχές, αυτό μπορεί να είναι ένδειξη ότι το μοντέλο έχει φτάσει σε ένα σημείο όπου δεν εκμαθαίνει πλέον αποτελεσματικά από τα δεδομένα. Αυτό μπορεί να οδηγήσει σε υπερεκπαίδευση, καθώς το μοντέλο μπορεί να αρχίσει να "αποστηθίζει" τα δεδομένα εκπαίδευσης αντί να γενικεύει σε νέες, αδιάθετες περιπτώσεις.

Για να αντιμετωπιστεί αυτό το πρόβλημα, χρησιμοποιούμε μια τεχνική που ονομάζεται "πρόωρη διακοπή" (early stopping). Με αυτήν την τεχνική, η εκπαίδευση του μοντέλου σταματά αυτόματα αν δεν παρατηρηθεί βελτίωση στην απώλεια για έναν προκαθορισμένο αριθμό εποχών. Η λογική πίσω από αυτό είναι ότι, αν το μοντέλο δεν βελτιώνεται πλέον, δεν έχει νόημα να συνεχίσουμε την εκπαίδευση, καθώς αυτό θα αυξήσει απλώς τον χρόνο εκπαίδευσης χωρίς σημαντικά οφέλη στην απόδοση του μοντέλου.

Τέλος, όταν το μοντέλο που επιτυγχάνει την υψηλότερη ακρίβεια ή τη χαμηλότερη απώλεια (ανάλογα με τον τύπο checkpoint που χρησιμοποιήσατε) θα αποθηκευτεί στην τοποθεσία που έχουμε ορίσει με τη μεταβλητή `model_path`. Αυτό είναι σημαντικό, διότι μετά την εκπαίδευση, θα έχουμε πρόσβαση στο καλύτερο μοντέλο που έχουμε εκπαιδεύσει, το οποίο μπορούμε να χρησιμοποιήσουμε για μελλοντικές προβλέψεις ή αξιολογήσεις.

## 5 Αποτελέσματα και Ανάλυση

### 5.1 Εισαγωγή

Στο πλαίσιο αυτής της διπλωματικής εργασίας, πραγματοποιήσαμε μια ενδελεχή ανάλυση της ικανότητας των νευρωνικών δικτύων στην αναγνώριση και κατηγοριοποίηση διαφορετικών θερμοκρασιών μέσω θερμογραφικών εικόνων.

Οι εικόνες που αξιοποιήσαμε αναπαριστούν την υπερυθρή ακτινοβολία που εκπέμπουν διάφορα αντικείμενα και περιβάλλοντα, με συγκεκριμένες θερμοκρασίες αποτυπωμένες σε κάθε εικόνα.

Η κατηγοριοποίηση των εικόνων πραγματοποιήθηκε με βάση ετικέτες που αντιστοιχούν σε διάφορες κατηγορίες θερμοκρασιών. Έτσι, δημιουργήσαμε τέσσερις κατηγορίες που αντιστοιχούν σε χαμηλές θερμοκρασίες, υψηλές θερμοκρασίες, μια συνδυασμό των δύο, καθώς και μια κατηγορία για τις περιοχές που δεν μπορούν να εντοπίσουν απώλειες.

Η απόδοση του νευρωνικού δικτύου αξιολογήθηκε μέσω τριών διαφορετικών στρατηγικών επεξεργασίας δεδομένων: βασικής εκπαίδευσης, υπερδειγματοληψίας και υποδειγματοληψίας. Σε κάθε μία από τις παραπάνω περιπτώσεις, εφαρμόζονται διάφορες τεχνικές προκειμένου να αποφευχθούν φαινόμενα overfitting ή underfitting. Το **ImageDataGenerator** βοηθά στην επαύξηση των δεδομένων, δίνοντας στο δίκτυο μεγαλύτερη ποικιλία για να μάθει. Η **L2 Regularization** εφαρμόζει ποινές στα βάρη των νευρώνων, περιορίζοντας την πολυπλοκότητα του δικτύου. Τέλος, το **Dropout** απενεργοποιεί τυχαία νευρώνες κατά τη διάρκεια της εκπαίδευσης, διασφαλίζοντας έτσι τη γενίκευση του μοντέλου.

Θα αναλύσουμε τα αποτελέσματα χρησιμοποιώντας το confusion matrix και το classification report. Αυτά τα δύο εργαλεία μας παρέχουν σημαντικές πληροφορίες σχετικά με την απόδοση του μοντέλου μας.

Το confusion matrix είναι ένας πίνακας που δείχνει τις προβλέψεις του μοντέλου σε σύγκριση με τις πραγματικές τιμές. Μας επιτρέπει να εντοπίσουμε τα προβλήματα που προκύπτουν από την αναγνώριση συγκεκριμένων κλάσεων και να καταλάβουμε καλύτερα πού κάνει λάθη το μοντέλο μας.

Γενικά, τα αποτελέσματα εμπίπτουν σε μία από τις ακόλουθες τέσσερις κατηγορίες: αληθινό αρνητικό (TN), αληθές θετικό (TP), ψευδώς αρνητικό, FN ή ψευδώς θετικό FP όπως περιγράφεται παραπάνω. Οι δύο σημαντικές πραγματικές καταστάσεις είναι:

- **TN (True Negative)** για την ετικέτα "1": Πραγματικά κρύες περιοχές που προβλέφθηκαν ως κρύες περιοχές. Βρίσκεται στη θέση (1,1) του πίνακα.
- **FN (False Negative)** για την ετικέτα "3": Κρύες και θερμές περιοχές που προβλέφθηκαν ως κρύες περιοχές. Βρίσκεται στη θέση (3,1) του πίνακα.

- **FP (False Positive)** για την ετικέτα "1": Περιοχές που πραγματικά είναι κρύες, αλλά προβλέφθηκαν ως κρύες και θερμές. Βρίσκεται στη θέση (1,3) του πίνακα.
- **TP (True Positive)** για την ετικέτα "3": Περιοχές που είναι πραγματικά κρύες και θερμές και προβλέφθηκαν σωστά ως τέτοιες. Βρίσκεται στη θέση (3,3) του πίνακα.

Το classification report παρέχει μια πιο λεπτομερή εικόνα της απόδοσης του μοντέλου. Περιλαμβάνει μετρήσεις όπως η ακρίβεια (precision), η ανάκληση (recall), η F1 βαθμολογία (F1 score). Μέσω αυτών των μετρήσεων, μπορούμε να κατανοήσουμε την ικανότητα του μοντέλου να διαχωρίζει τις κλάσεις και να τις αναγνωρίζει σωστά.

Με την ανάλυση αυτών των αποτελεσμάτων, θα μπορέσουμε να βελτιώσουμε περαιτέρω την απόδοση του μοντέλου μας, αναζητώντας τρόπους για να αντιμετωπίσουμε τα συγκεκριμένα προβλήματα που εντοπίζονται. Τα αποτελέσματα μας έδειξαν πολύτιμες πληροφορίες για το πώς μπορεί να βελτιωθεί η γενίκευση του μοντέλου, αποτελώντας ένα σημαντικό βήμα προς τη βελτιστοποίηση της απόδοσής του στο μέλλον.

## 5.2 Παρουσίαση των αποτελεσμάτων των μεθόδων

### 5.2.1 Μέθοδος 1η: Βασικό Μοντέλο

**Βασικό Μοντέλο:** Στην πρώτη περίπτωση, το μοντέλο μας εκπαιδεύεται χωρίς τη χρήση τεχνικών υπερδειγματοληψίας ή υποδειγματοληψίας. Αντ' αυτού, το δίκτυο μαθαίνει από τα δεδομένα που έχουν υποστεί μόνο τεχνικές επαύξησης δεδομένων, ώστε να αυξηθεί η ποικιλία και η γενίκευσή τους. Αυτό επιτρέπει στο δίκτυο να εκπαιδευτεί πάνω σε μια ευρύτερη γκάμα δειγμάτων χωρίς την ανάγκη για επεμβάσεις στην κατανομή των κλάσεων.

## Αναλυτική Περιγραφή του Μοντέλου

Parameter	Value
Model	best_model_smtn.h5
Optimizer	Lookahead AdamW optimizer
Loss Function	sparse_categorical_crossentropy
Metrics	Accuracy
Epochs	200
Batch Size	40
Duration	0 hours and 8 minutes
Best Loss Epoch	139
Best Acc Epoch	37
Training Loss	0.5322
Training Accuracy	0.9677
Validation Loss	0.4268
Validation Accuracy	0.9894
Test Loss	0.5511
Test Accuracy	0.9365
Total Training Images	1302
Total Validation Images	189
Total Testing Images	126
Distribution of Classes in Training Data	[ 0 567 0 735]
Distribution of Classes in Validation Data	[ 0 81 0 108]
Distribution of Classes in Test Data	[ 0 54 0 72]
Model Saving Status	Success

Πίνακας 5.2.1 Ανάλυση Αποτελεσμάτων του Νευρωνικού Δικτύου του βασικού μας μοντέλου στα δεδομένα μας.

**Μοντέλο:** Το χρησιμοποιημένο μοντέλο αποθηκεύτηκε ως "best\_model\_smtn.h5".

**Βελτιστοποιητής:** Κατά τη διάρκεια της εκπαίδευσης, χρησιμοποιήθηκε ο Lookahead AdamW optimizer.

**Συνάρτηση Απώλειας:** Η συνάρτηση απώλειας που επιλέχθηκε ήταν η sparse\_categorical\_crossentropy.

**Μετρικές:** Το κύριο κριτήριο αξιολόγησης της απόδοσης του μοντέλου ήταν η ακρίβεια (Accuracy).

**Εποχές:** Η εκπαίδευση του μοντέλου διήρκεσε για 200 εποχές με μέγεθος δέσμης (batch size) 40 εικόνες. Η διάρκεια αυτής της διαδικασίας ήταν 8 λεπτά.

Στην εποχή 139 παρατηρήθηκε η χαμηλότερη τιμή απώλειας ενώ η καλύτερη ακρίβεια επιτεύχθηκε στην εποχή 37.



### Αποτελέσματα Εκπαίδευσης:

- Απώλεια Εκπαίδευσης: 0.5322
- Ακρίβεια Εκπαίδευσης: 96.77%

### Αποτελέσματα Επικύρωσης:

- Απώλεια Επικύρωσης: 0.4268
- Ακρίβεια Επικύρωσης: 98.94%


### Αποτελέσματα Δοκιμής:

- Απώλεια Δοκιμής: 0.5511
- Ακρίβεια Δοκιμής: 93.65%

Όσον αφορά τη διανομή των κατηγοριών στα δεδομένα, υπάρχουν 1302 εικόνες εκπαίδευσης, 189 εικόνες επικύρωσης και 126 εικόνες δοκιμής. Ειδικότερα, στο σύνολο εκπαίδευσης, 567 εικόνες ανήκουν στην κατηγορία 1 και 735 στην κατηγορία 3. Στο σύνολο επικύρωσης, 81 εικόνες ανήκουν στην κατηγορία 1 και 108 στην κατηγορία 3. Τέλος, στο σύνολο δοκιμής, 54 εικόνες ανήκουν στην κατηγορία 1 και 72 στην κατηγορία 3.

Τέλος, το μοντέλο αποθηκεύτηκε επιτυχώς.

### Διάγραμμα απώλειας λάθους και ακρίβειας




(α) Γράφημα ακρίβειας εκπαίδευσης και επικύρωσης στα δεδομένα μας, (β) Διάγραμμα απώλειας εκπαίδευσης και επικύρωσης στα δεδομένα μας.

### Πίνακας confusion matrix

Μετά την πρόβλεψη με το σύνολο των 126 «νέων» εικόνων, τα TP, TN, FP και FN μετρήθηκαν ως :

TN = 50, TP = 68

FN = 4, FP = 4



Εικόνα 5.2.1 Πίνακας confusion matrix της Μεθόδου 1 στα δεδομένα μας.

### Πίνακας και Διάγραμμα classification report

	precision	recall	f1-score	support
1	0.9259	0.9259	0.9259	54
3	0.9444	0.9444	0.9444	72
macro avg	0.9352	0.9352	0.9352	126
weighted avg	0.9365	0.9365	0.9365	126
accuracy	0.9365	0.9365	0.9365	126

Πίνακας 5.2.2 Ανάλυση Αποτελεσμάτων classification report στα δεδομένα μας.

### Κλάση 1:

- **Ακρίβεια (Precision):** Η ακρίβεια είναι 0.9259, πράγμα που σημαίνει ότι από τα παραδείγματα που ταξινομήθηκαν ως κλάση 1, το 92.59% πράγματι ήταν από την κλάση 1.
- **Ανακληση (Recall):** Η ανακληση είναι 0.9259, σημαίνοντας ότι από όλα τα παραδείγματα της κλάσης 1, το 92.59% αναγνωρίστηκε σωστά.
- **F1-Σκορ (F1-score):** Το F1-σκορ, μια συνδυαστική μετρική ακρίβειας και ανακλήσεως, είναι 0.9259.
- **Support:** Υπάρχουν συνολικά 54 παραδείγματα στην κλάση 1.

### 2. Κλάση 3:


- **Ακρίβεια (Precision):** Η ακρίβεια για αυτή την κλάση είναι 0.9444.
- **Ανακληση (Recall):** Η ανακληση είναι 0.9444.
- **F1-Σκορ (F1-score):** Το F1-σκορ είναι 0.9444.
- **Support:** Υπάρχουν συνολικά 72 παραδείγματα στην κλάση 3.

**Μέσες τιμές (macro avg):** - Η μέση ακρίβεια, ανακληση και F1-σκορ για τις δύο κλάσεις είναι 0.9352.

**Σταθμισμένες μέσες τιμές (weighted avg):** - Όταν λαμβάνουμε υπόψη τον αριθμό των παραδειγμάτων ανά κλάση, οι σταθμισμένες τιμές είναι 0.9365 για ακρίβεια, ανακληση και F1-σκορ.

**Συνολική Ακρίβεια (accuracy):** - Το μοντέλο είχε συνολική ακρίβεια 0.9365 στο σύνολο των δεδομένων ελέγχου που είναι 126 παραδείγματα.

Τα αποτελέσματα δείχνουν ότι το μοντέλο επιτυγχάνει πολύ καλή απόδοση στο σύνολο των δεδομένων ελέγχου με υψηλά ποσοστά ακρίβειας, ανακλήσεως και F1-σκορ.



Εικόνα 5.2.2 Διάγραμμα classification report της Μεθόδου 1 στα δεδομένα μας.

## 5.2.2 Μέθοδος 2η: Υπερδειγματοληψία (Over-sampling)

**Υπερδειγματοληψία (Over-sampling):** Σε αυτήν την περίπτωση, εφαρμόζουμε την τεχνική της υπερδειγματοληψίας, όπου τα λιγότερο αντιπροσωπευτικά δείγματα στο σύνολο δεδομένων αυξάνονται, ώστε να έχουμε ένα πιο ισορροπημένο σύνολο. Αυτό μπορεί να βοηθήσει στην παρεμπόδιση του δικτύου από το να είναι προκατειλημμένο προς τις πιο συχνές κλάσεις.

## Αναλυτική Περιγραφή του Μοντέλου

Parameter	Value
Model	best_model_smtn.h5
Optimizer	Lookahead AdamW optimizer
Loss Function	sparse_categorical_crossentropy
Metrics	Accuracy
Epochs	200
Batch Size	40
Duration	0 hours and 6 minutes
Best Loss Epoch	101
Best Acc Epoch	101
Training Loss	0.6701
Training Accuracy	0.9755
Validation Loss	0.5581
Validation Accuracy	0.9947
Test Loss	0.6718
Test Accuracy	0.9444
Total Training Images	1470
Total Validation Images	189
Total Testing Images	126
Distribution of Classes in Training Data	[ 0 735 0 735]
Distribution of Classes in Validation Data	[ 0 81 0 108]
Distribution of Classes in Test Data	[ 0 54 0 72]
Model Saving Status	Success

Πίνακας 5.2.2 Ανάλυση Αποτελεσμάτων του Νευρωνικού Δικτύου με υπερδειγματοληψία στα δεδομένα μας.

**Μοντέλο:** Το χρησιμοποιημένο μοντέλο αποθηκεύτηκε ως "best\_model\_smtn.h5".

**Βελτιστοποιητής:** Κατά τη διάρκεια της εκπαίδευσης, χρησιμοποιήθηκε ο Lookahead AdamW optimizer.

**Συνάρτηση Απώλειας:** Η συνάρτηση απώλειας που επιλέχθηκε ήταν η sparse\_categorical\_crossentropy.

**Μετρικές:** Το κύριο κριτήριο αξιολόγησης της απόδοσης του μοντέλου ήταν η ακρίβεια (Accuracy).

**Εποχές:** Η εκπαίδευση του μοντέλου διήρκεσε για 200 εποχές με μέγεθος δέσμης (batch size) 40 εικόνες. Η διάρκεια αυτής της διαδικασίας ήταν 6 λεπτά.

Στην εποχή 101 παρατηρήθηκε η χαμηλότερη τιμή απώλειας καθώς και η καλύτερη ακρίβεια. .

### Αποτελέσματα Εκπαίδευσης:

- Απώλεια Εκπαίδευσης: 0.6701

- Ακρίβεια Εκπαίδευσης: 97.55%

#### Αποτελέσματα Επικύρωσης:

- Απώλεια Επικύρωσης: 0.5581
- Ακρίβεια Επικύρωσης: 99.47%


#### Αποτελέσματα Δοκιμής:

- Απώλεια Δοκιμής: 0.6718
- Ακρίβεια Δοκιμής: 94.44%

Όσον αφορά τη διανομή των κατηγοριών στα δεδομένα, υπάρχουν 1470 εικόνες εκπαίδευσης, 189 εικόνες επικύρωσης και 126 εικόνες δοκιμής. Ειδικότερα, στο σύνολο εκπαίδευσης, 735 εικόνες ανήκουν στην κατηγορία 1 και 735 στην κατηγορία 3. Στο σύνολο επικύρωσης, 81 εικόνες ανήκουν στην κατηγορία 1 και 108 στην κατηγορία 3. Τέλος, στο σύνολο δοκιμής, 54 εικόνες ανήκουν στην κατηγορία 1 και 72 στην κατηγορία 3.

Τέλος, το μοντέλο αποθηκεύτηκε επιτυχώς.

#### Διαγραμμα απώλειας λάθους και ακρίβειας




(α) Γράφημα ακρίβειας εκπαίδευσης και επικύρωσης στα δεδομένα μας, (β) Διάγραμμα απώλειας εκπαίδευσης και επικύρωσης στα δεδομένα μας.

### Πίνακας confusion matrix

Μετά την πρόβλεψη με το σύνολο των 126 «νέων» εικόνων, τα TP, TN, FP και FN μετρήθηκαν ως:  
TN = 51, TP = 68

FN = 4, FP = 3



Εικόνα 5.2.3 Πίνακας confusion matrix της Μεθόδου 2 στα δεδομένα μας.

### Πίνακας και Διάγραμμα classification report

	precision	recall	f1-score	support
1	0.9273	0.9444	0.9358	54
3	0.9577	0.9444	0.9510	72
macro avg	0.9425	0.9444	0.9434	126
weighted avg	0.9447	0.9444	0.9445	126
accuracy	0.9444	0.9444	0.9444	126

Πίνακας 5.2.4 Ανάλυση Αποτελεσμάτων classification report στα δεδομένα μας.

### Κλάση 1:

- **Ακρίβεια (Precision):** Η ακρίβεια είναι 0.9273 , πράγμα που σημαίνει ότι από τα παραδείγματα που ταξινομήθηκαν ως κλάση 1, το 92.73% πράγματι ήταν από την κλάση 1.
- **Ανακληση (Recall):** Η ανακληση είναι 0.9444, σημαίνοντας ότι από όλα τα παραδείγματα της κλάσης 1, το 94.44% αναγνωρίστηκε σωστά.
- **F1-Σκορ (F1-score):** Το F1-σκορ, μια συνδυαστική μετρική ακρίβειας και ανακλήσεως, είναι 0.9358.
- **Support:** Υπάρχουν συνολικά 54 παραδείγματα στην κλάση 1.

### 2. Κλάση 3:

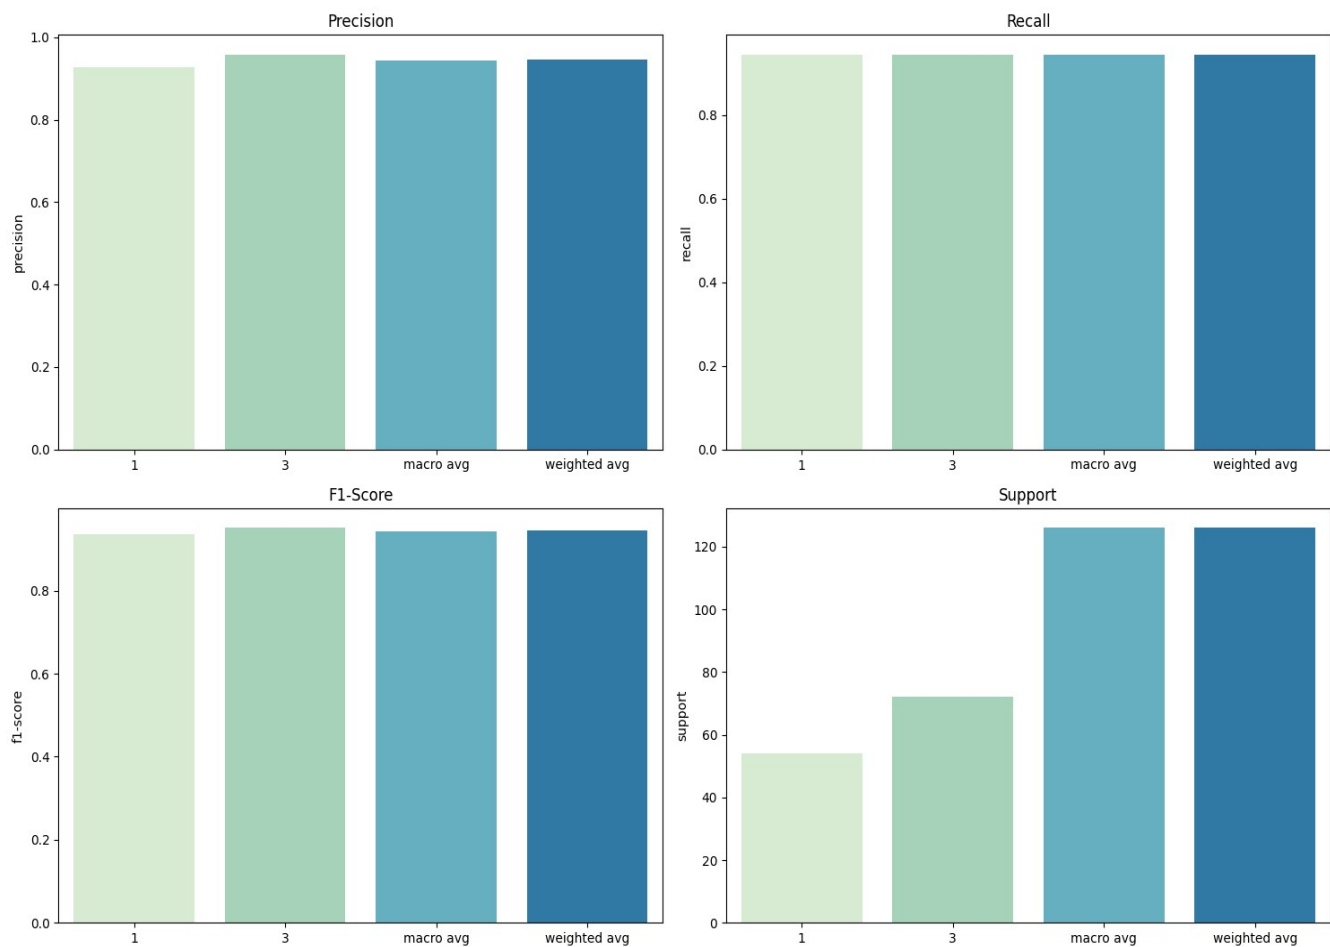
- **Ακρίβεια (Precision):** Η ακρίβεια για αυτή την κλάση είναι 0.9577.
- **Ανακληση (Recall):** Η ανακληση είναι 0.9444.
- **F1-Σκορ (F1-score):** Το F1-σκορ είναι 0.951.
- **Support:** Υπάρχουν συνολικά 72 παραδείγματα στην κλάση 3.

**Μέσες τιμές (macro avg):** - Η μέση ακρίβεια, ανακληση, και F1-σκορ για τις δύο κλάσεις είναι αντίστοιχα 0.9425, 0.9444, και 0.9434.

**Σταθμισμένες μέσες τιμές (weighted avg):** - Όταν λαμβάνουμε υπόψη τον αριθμό των παραδειγμάτων ανά κλάση, οι σταθμισμένες τιμές είναι 0.9447 για ακρίβεια, 0.9444 για ανακληση, και 0.9445 για F1-σκορ. .

**Συνολική Ακρίβεια (accuracy):** - Το μοντέλο είχε συνολική ακρίβεια 0.9444 στο σύνολο των δεδομένων ελέγχου. που είναι 126 παραδείγματα.





Εικόνα 5.2.4 Διάγραμμα classification report της Μεθόδου 2 στα δεδομένα μας.

Τα αποτελέσματα δείχνουν ότι το μοντέλο επιτυγχάνει πολύ καλή απόδοση στο σύνολο των δεδομένων ελέγχου με υψηλά ποσοστά ακρίβειας, ανακλήσεως και F1-σκορ.

### 5.2.3 Μέθοδος 3η: Υποδειγματοληψία (Under-sampling)

**Υποδειγματοληψία (Under-sampling):** Στην τρίτη περίπτωση, εφαρμόζουμε την τεχνική της υποδειγματοληψίας. Εδώ, τα πιο συχνά δείγματα στο σύνολο δεδομένων μειώνονται, προκειμένου να δημιουργηθεί ένα πιο ισορροπημένο σύνολο. Αυτός ο περιορισμός των πιο συχνών δειγμάτων μπορεί να βοηθήσει το δίκτυο να μην αγνοεί τις λιγότερο συχνές κλάσεις.

## Αναλυτική Περιγραφή του Μοντέλου

Parameter	Value
Model	best_model_smtn.h5
Optimizer	Lookahead AdamW optimizer
Loss Function	sparse_categorical_crossentropy
Metrics	Accuracy
Epochs	200
Batch Size	40
Duration	0 hours and 5 minutes
Best Loss Epoch	80
Best Acc Epoch	74
Training Loss	1.6818
Training Accuracy	0.9674
Validation Loss	1.6121
Validation Accuracy	0.9683
Test Loss	1.6796
Test Accuracy	0.9365
Total Training Images	1134
Total Validation Images	189
Total Testing Images	126
Distribution of Classes in Training Data	[ 0 567 0 567]
Distribution of Classes in Validation Data	[ 0 81 0 108]
Distribution of Classes in Test Data	[ 0 54 0 72]
Model Saving Status	Success

Πίνακας 5.2.3 Ανάλυση Αποτελεσμάτων του Νευρωνικού Δικτύου για υποδειγματοληψία στα δεδομένα μας.

**Μοντέλο:** Το χρησιμοποιημένο μοντέλο αποθηκεύτηκε ως "best\_model\_smtn.h5".

**Βελτιστοποιητής:** Κατά τη διάρκεια της εκπαίδευσης, χρησιμοποιήθηκε ο Lookahead AdamW optimizer.

**Συνάρτηση Απώλειας:** Η συνάρτηση απώλειας που επιλέχθηκε ήταν η sparse\_categorical\_crossentropy.

**Μετρικές:** Το κύριο κριτήριο αξιολόγησης της απόδοσης του μοντέλου ήταν η ακρίβεια (Accuracy).

**Εποχές:** Η εκπαίδευση του μοντέλου διήρκεσε για 200 εποχές με μέγεθος δέσμης (batch size) 40 εικόνες. Η διάρκεια αυτής της διαδικασίας ήταν 5 λεπτά.

Στην εποχή 80 παρατηρήθηκε η χαμηλότερη τιμή απώλειας ενώ η καλύτερη ακρίβεια επιτεύχθηκε στην εποχή 74.

### Αποτελέσματα Εκπαίδευσης:

- Απώλεια Εκπαίδευσης: 1.6818
- Ακρίβεια Εκπαίδευσης: 96.74%

### Αποτελέσματα Επικύρωσης:

- Απώλεια Επικύρωσης: 1.6121
- Ακρίβεια Επικύρωσης: 96.83%


### Αποτελέσματα Δοκιμής:

- Απώλεια Δοκιμής: 1.6796
- Ακρίβεια Δοκιμής: 93.65%

Όσον αφορά τη διανομή των κατηγοριών στα δεδομένα, υπάρχουν 1134 εικόνες εκπαίδευσης, 189 εικόνες επικύρωσης και 126 εικόνες δοκιμής. Ειδικότερα, στο σύνολο εκπαίδευσης, 567 εικόνες ανήκουν στην κατηγορία 1 και 567 στην κατηγορία 3. Στο σύνολο επικύρωσης, 81 εικόνες ανήκουν στην κατηγορία 1 και 108 στην κατηγορία 3. Τέλος, στο σύνολο δοκιμής, 54 εικόνες ανήκουν στην κατηγορία 1 και 72 στην κατηγορία 3.

Τέλος, το μοντέλο αποθηκεύτηκε επιτυχώς.

### Διαγραμμα απώλειας λάθους και ακρίβειας




(α) Γράφημα ακρίβειας εκπαίδευσης και επικύρωσης στα δεδομένα μας, (β) Διάγραμμα απώλειας εκπαίδευσης και επικύρωσης στα δεδομένα μας.

### Πίνακας confusion matrix

Μετά την πρόβλεψη με το σύνολο των 126 «νέων» εικόνων, τα TP, TN, FP και FN μετρήθηκαν ως:  
TN = 52, TP = 66

FN = 6, FP = 2



Εικόνα 5.2.5 Πίνακας confusion matrix της Μεθόδου 3 στα δεδομένα μας.

### Πίνακας και Διάγραμμα classification report

	precision	recall	f1-score	support
1	0.8966	0.963	0.9286	54
3	0.9706	0.9167	0.9429	72
macro avg	0.9336	0.9398	0.9357	126
weighted avg	0.9389	0.9365	0.9367	126
accuracy	0.9365	0.9365	0.9365	126

Πίνακας 5.2.6 Ανάλυση Αποτελεσμάτων classification report στα δεδομένα μας.

### Κλάση 1:

- **Ακρίβεια (Precision):** Η ακρίβεια είναι 0.8966 , πράγμα που σημαίνει ότι από τα παραδείγματα που ταξινομήθηκαν ως κλάση 1, το 89.66% πράγματι ήταν από την κλάση 1.
- **Ανακληση (Recall):** Η ανακληση είναι 0.963, σημαίνοντας ότι από όλα τα παραδείγματα της κλάσης 1, το 96.3% αναγνωρίστηκε σωστά.
- **F1-Σκορ (F1-score):** Το F1-σκορ, μια συνδυαστική μετρική ακρίβειας και ανακλήσεως, είναι 0.9286.
- **Support:** Υπάρχουν συνολικά 54 παραδείγματα στην κλάση 1.


### Κλάση 3:

- **Ακρίβεια (Precision):** Η ακρίβεια για αυτή την κλάση είναι 0.9706.
- **Ανακληση (Recall):** Η ανακληση είναι 0.9167.
- **F1-Σκορ (F1-score):** Το F1-σκορ είναι 0.9429.
- **Support:** Υπάρχουν συνολικά 72 παραδείγματα στην κλάση 3.

**Μέσες τιμές (macro avg):** - Η μέση ακρίβεια, ανακληση και F1-σκορ για τις δύο κλάσεις είναι αντίστοιχα 0.9336, 0.9398 και 0.9357.





**Σταθμισμένες μέσες τιμές (weighted avg):** - Όταν λαμβάνουμε υπόψη τον αριθμό των παραδειγμάτων ανά κλάση, οι σταθμισμένες τιμές είναι 0.9389 για ακρίβεια, 0.9365 για ανακληση και 0.9367 για F1-σκορ.

**Συνολική Ακρίβεια (accuracy):** - Το μοντέλο είχε συνολική ακρίβεια 0.9365 στο σύνολο των δεδομένων ελέγχου. που είναι 126 παραδείγματα.



Εικόνα 5.2.6 Διάγραμμα classification report της Μεθόδου 3 στα δεδομένα μας.

Τα αποτελέσματα δείχνουν ότι το μοντέλο επιτυγχάνει πολύ καλή απόδοση στο σύνολο των δεδομένων ελέγχου με υψηλά ποσοστά ακρίβειας, ανακλήσεως και F1-σκορ.



Εικόνα 5.2.7 Δείγμα εικόνων ελέγχου μετά την πρόβλεψη του CNN μοντέλου μας στα δεδομένα μας.

### 5.3 Παρουσίαση των αποτελεσμάτων στα αρχικά μας δεδομένα εφαρμόζοντας το CNN

το πλαίσιο της εργασίας μας, αναφερθήκαμε προηγουμένως ότι οι αρχικές μας εικόνες ανέρχονται σε 104. Αυτές οι εικόνες αποτέλεσαν το κύριο σετ δεδομένων για την εκπαίδευση και τον έλεγχο του μοντέλου μας. Το CNN (Συνελικτικά Δίκτυα) που χρησιμοποιήσαμε, παρέχει τη δυνατότητα να αναγνωρίζει και να "κατανοεί" τα χαρακτηριστικά των εικόνων, καθιστώντας το ιδανικό για τέτοιου είδους δεδομένα.

Στο τελευταίο στάδιο, εφαρμόσαμε την πρόβλεψη του μοντέλου μας σε τρεις περιπτώσεις, βασιζόμενοι στις αρχικές εικόνες. Ο στόχος μας ήταν να δούμε πώς αποδίδει το μοντέλο σε "πραγματικές" συνθήκες και αν οι προβλέψεις του είναι συνεπείς με τις πραγματικές κατηγορίες των εικόνων.


Για να αξιολογήσουμε περαιτέρω την απόδοση του μοντέλου μας στις αρχικές εικόνες, ανατρέξαμε σε δύο κύριες στατιστικές μεθόδους: τον πίνακα σύγχυσης (Confusion Matrix) και την αναφορά ταξινόμησης (Classification Report).

### Μέθοδος 1η: Βασικό Μοντέλο

#### Πίνακας confusion matrix

Μετά την πρόβλεψη με το σύνολο των 126 «νέων» εικόνων, τα TP, TN, FP και FN μετρήθηκαν ως:  
TN = 45, TP = 57

FN = 0, FP = 2



Εικόνα 5.3.1 Πίνακας confusion matrix της Μεθόδου 1 στα αρχικά μας δεδομένα.



## Πίνακας και Διάγραμμα classification report

	precision	recall	f1-score	support
1	1	0.9574	0.9783	47
3	0.9661	1	0.9828	57
macro avg	0.9831	0.9787	0.9805	104
weighted avg	0.9814	0.9808	0.9807	104
accuracy	0.9808	0.9808	0.9808	104

Πίνακας 5.3.2 Ανάλυση Αποτελεσμάτων classification report στα αρχικά μας δεδομένα.

### 1. Κλάση 1:

- **Ακρίβεια (Precision):** Η ακρίβεια για την κλάση 1 είναι 1 ή 100. Αυτό σημαίνει ότι όταν το μοντέλο προβλέπει ότι μια εικόνα ανήκει στην κλάση 1, είναι 100 σίγουρο ότι η πρόβλεψη είναι σωστή.
- **Ανακληση (Recall):** Η ανακληση για την κλάση 1 είναι 0.9574 ή 95.74. Αυτό σημαίνει ότι από όλες τις πραγματικές εικόνες της κλάσης 1, το μοντέλο αναγνώρισε σωστά το 95.74.
- **F1-Σκορ (F1-score):** Η συνδυαστική μετρική ακρίβειας και ανακλήσεως, είναι 0.9783 ή 97.83.
- **Support:** Υπάρχουν συνολικά 47 εικόνες στην κλάση 1.

### 2. Κλάση 3:

- **Ακρίβεια (Precision):** Η ακρίβεια για την κλάση 3 είναι 0.9661 ή 96.61.
- **Ανακληση (Recall):** Το μοντέλο αναγνώρισε σωστά όλες τις εικόνες της κλάσης 3, με ανακληση 1 ή 100.
- **F1-Σκορ (F1-score):** Το F1-σκορ για την κλάση 3 είναι 0.9828 ή 98.28.
- **Support:** Υπάρχουν συνολικά 57 εικόνες στην κλάση 3.


### Μέσες τιμές (macro avg):

- **Ακρίβεια:** Η μέση ακρίβεια για όλες τις κλάσεις είναι 0.9831 ή 98.31.
- **Ανακληση:** Η μέση ανακληση είναι 0.9787 ή 97.87.
- **F1-Σκορ:** Η μέση τιμή του F1-σκορ είναι 0.9805 ή 98.05.

### Σταθμισμένες μέσες τιμές (weighted avg):

- **Ακρίβεια:** 0.9814 ή 98.14.
- **Ανακληση:** 0.9808 ή 98.08.
- **F1-Σκορ:** 0.9807 ή 98.07.
- **Συνολική Ακρίβεια (Accuracy):** Το μοντέλο πέτυχε μια συνολική ακρίβεια του 0.9808 ή 98.08 στις αρχικές εικόνες, που είναι 104 συνολικά.

Τα παραπάνω αποτελέσματα είναι εξαιρετικά καλά, καθώς το μοντέλο αποδίδει με υψηλή ακρίβεια, ανακληση και F1-σκορ στις δύο κλάσεις. Αυτό υποδεικνύει ότι το μοντέλο είναι ικανό να ταξινομεί σωστά τις εικόνες με μεγάλη βεβαιότητα.




Εικόνα 5.3.2 Διάγραμμα classification report της Μεθόδου 1 στα αρχικά μας δεδομένα.

## Μέθοδος 2η: Υπερδειγματοληψία (Over-sampling)

### Πίνακας confusion matrix

Μετά την πρόβλεψη με το σύνολο των 126 «νέων» εικόνων, τα TP, TN, FP και FN μετρήθηκαν ως:  
TN = 51, TP = 68

FN = 0, FP = 3



Εικόνα 5.3.3 Πίνακας confusion matrix της Μεθόδου 2 στα αρχικά μας δεδομένα.

### Πίνακας και Διάγραμμα classification report

	precision	recall	f1-score	support
1	1	0.9362	0.9670	47
3	0.9500	1	0.9744	57
macro avg	0.975	0.9681	0.9707	104
weighted avg	0.9726	0.9712	0.971	104
accuracy	0.9712	0.9712	0.9712	104

Πίνακας 5.3.3 Ανάλυση Αποτελεσμάτων classification report στα αρχικά μας δεδομένα.

## 1. Κλάση 1:

- **Ακρίβεια (Precision):** Η ακρίβεια για την κλάση 1 είναι 1 ή 100. Αυτό σημαίνει ότι όταν το μοντέλο προβλέπει ότι μια εικόνα ανήκει στην κλάση 1, είναι 100 σίγουρο ότι η πρόβλεψη είναι σωστή.
- **Ανακληση (Recall):** Η ανακληση για την κλάση 1 είναι 0.9362 ή 93.62. Αυτό σημαίνει ότι από όλες τις πραγματικές εικόνες της κλάσης 1, το μοντέλο αναγνώρισε σωστά το 93.62.
- **F1-Σκορ (F1-score):** Η συνδυαστική μετρική ακρίβειας και ανακλήσεως, είναι 0.967 ή 96.7.
- **Support:** Υπάρχουν συνολικά 47 εικόνες στην κλάση 1.

## 2. Κλάση 3:

- **Ακρίβεια (Precision):** Η ακρίβεια για την κλάση 3 είναι 0.95 ή 95.00.
- **Ανακληση (Recall):** Το μοντέλο αναγνώρισε σωστά όλες τις εικόνες της κλάσης 3, με ανακληση 1 ή 100.
- **F1-Σκορ (F1-score):** Το F1-σκορ για την κλάση 3 είναι 0.9744 ή 97.44.
- **Support:** Υπάρχουν συνολικά 57 εικόνες στην κλάση 3.

## Μέσες τιμές (macro avg):


- **Ακρίβεια:** Η μέση ακρίβεια για όλες τις κλάσεις είναι 0.975 ή 97.5.
- **Ανακληση:** Η μέση ανακληση είναι 0.968 ή 96.8.
- **F1-Σκορ:** Η μέση τιμή του F1-σκορ είναι 0.9707 ή 97.07.

## Σταθμισμένες μέσες τιμές (weighted avg):

- **Ακρίβεια:** 0.9726 ή 97.26.
- **Ανακληση:** 0.9712 ή 97.12.
- **F1-Σκορ:** 0.971 ή 97.1.

**Συνολική Ακρίβεια (Accuracy):** Το μοντέλο πέτυχε μια συνολική ακρίβεια του 0.9712 ή 97.12 στις αρχικές εικόνες, που είναι 104 συνολικά.

Τα παραπάνω αποτελέσματα είναι εξαιρετικά καλά, καθώς το μοντέλο αποδίδει με υψηλή ακρίβεια, ανακληση και F1-σκορ στις δύο κλάσεις. Αυτό υποδεικνύει ότι το μοντέλο είναι ικανό να ταξινομεί σωστά τις εικόνες με μεγάλη βεβαιότητα.




Εικόνα 5.3.4 Διάγραμμα classification report της Μεθόδου 2 στα αρχικά μας δεδομένα.

### Μέθοδος 3η: Υποδειγματοληψία (Under-sampling)

#### Πίνακας confusion matrix

Μετά την πρόβλεψη με το σύνολο των 126 «νέων» εικόνων, τα TP, TN, FP και FN μετρήθηκαν ως:  
 TN = 44, TP = 57

FN = 0, FP = 3



Εικόνα 5.3.5 Πίνακας confusion matrix της Μεθόδου 3 στα αρχικά μας δεδομένα.

### Πίνακας και Διάγραμμα classification report

	precision	recall	f1-score	support
<b>1</b>	<b>1</b>	<b>0.9360</b>	<b>0.9670</b>	<b>47</b>
<b>3</b>	<b>0.9500</b>	<b>1</b>	<b>0.9744</b>	<b>57</b>
<b>macro avg</b>	<b>0.9750</b>	<b>0.9680</b>	<b>0.9707</b>	<b>104</b>
<b>weighted avg</b>	<b>0.9726</b>	<b>0.9712</b>	<b>0.9710</b>	<b>104</b>
<b>accuracy</b>	<b>0.9712</b>	<b>0.9712</b>	<b>0.9712</b>	<b>104</b>

Πίνακας 5.3.5 Ανάλυση Αποτελεσμάτων classification report στα αρχικά μας δεδομένα.

## 1. Κλάση 1:

- **Ακρίβεια (Precision):** Η ακρίβεια για την κλάση 1 είναι 1 ή 100. Αυτό σημαίνει ότι όταν το μοντέλο προβλέπει ότι μια εικόνα ανήκει στην κλάση 1, είναι 100 σίγουρο ότι η πρόβλεψη είναι σωστή.
- **Ανακληση (Recall):** Η ανακληση για την κλάση 1 είναι 0.9360 ή 93.6. Αυτό σημαίνει ότι από όλες τις πραγματικές εικόνες της κλάσης 1, το μοντέλο αναγνώρισε σωστά το 93.6.
- **F1-Σκορ (F1-score):** Η συνδυαστική μετρική ακρίβειας και ανακλήσεως, είναι 0.9670 ή 96.7.
- **Support:** Υπάρχουν συνολικά 47 εικόνες στην κλάση 1.

## 2. Κλάση 3:

- **Ακρίβεια (Precision):** Η ακρίβεια για την κλάση 3 είναι 0.95 ή 95.00.
- **Ανακληση (Recall):** Το μοντέλο αναγνώρισε σωστά όλες τις εικόνες της κλάσης 3, με ανακληση 1 ή 100.
- **F1-Σκορ (F1-score):** Το F1-σκορ για την κλάση 3 είναι 0.9744 ή 97.44.
- **Support:** Υπάρχουν συνολικά 57 εικόνες στην κλάση 3.

## Μέσες τιμές (macro avg):


- **Ακρίβεια:** Η μέση ακρίβεια για όλες τις κλάσεις είναι 0.975 ή 97.5.
- **Ανακληση:** Η μέση ανακληση είναι 0.968 ή 96.8.
- **F1-Σκορ:** Η μέση τιμή του F1-σκορ είναι 0.9707 ή 97.07.

## Σταθμισμένες μέσες τιμές (weighted avg):

- **Ακρίβεια:** 0.9726 ή 97.26.
- **Ανακληση:** 0.9712 ή 97.12.
- **F1-Σκορ:** 0.971 ή 97.1.

**Συνολική Ακρίβεια (Accuracy):** Το μοντέλο πέτυχε μια συνολική ακρίβεια του 0.9712 ή 97.12 στις αρχικές εικόνες, που είναι 104 συνολικά.

Τα παραπάνω αποτελέσματα είναι εξαιρετικά καλά, καθώς το μοντέλο αποδίδει με υψηλή ακρίβεια, ανακληση και F1-σκορ στις δύο κλάσεις. Αυτό υποδεικνύει ότι το μοντέλο είναι ικανό να ταξινομεί σωστά τις εικόνες με μεγάλη βεβαιότητα.



Εικόνα 5.3.6 Διάγραμμα classification report της Μεθόδου 3 στα αρχικά μας δεδομένα.

Βλέπουμε λοιπόν ότι τα αρχικά μας δεδομένα παρουσιάζουν καλύτερα αποτελέσματα στις μετρήσεις μας σε σχέση με τα δεδομένα ελέγχου. Ας αναλύσουμε τους λόγους για το γιατί συμβαίνει αυτό:

- **Επαύξηση Δεδομένων (Data Augmentation):** Όταν χρησιμοποιούμε επαύξηση δεδομένων, δημιουργούμε παραλλαγές των αρχικών δεδομένων. Αυτό συχνά βοηθά το μοντέλο να γενικεύει καλύτερα σε νέα δεδομένα. Ωστόσο, εάν η επαύξηση γίνει με βάση τα αρχικά δεδομένα και το μοντέλο ελεγχθεί στα ίδια δεδομένα, τότε είναι πιθανό να έχουμε πολύ υψηλές επιδόσεις στα δεδομένα ελέγχου, καθώς έχουν μεγάλη ομοιότητα με τα δεδομένα εκπαίδευσης.



- **Παρατήρηση FP, FN:** Αν στον confusion matrix υπάρχουν λιγότερα false positives (FP) και false negatives (FN) στα αρχικά δεδομένα σε σχέση με τα δεδομένα ελέγχου, αυτό ενδέχεται να οφείλεται στην "οικειότητα" του μοντέλου με τα δεδομένα εκπαίδευσης. Τα μοντέλα μπορεί να γίνουν "υπερβολικά προσαρμοστικά" στα δεδομένα εκπαίδευσης, κάτι που ονομάζεται overfitting.

- **Classification Report:** Το classification report περιλαμβάνει μετρήσεις όπως η ακρίβεια (precision), η ανάκληση (recall) και η μετρική F1. Όταν το μοντέλο εκπαιδεύεται σε ένα σύνολο δεδομένων και μετά δοκιμάζεται στο ίδιο σύνολο ή σε παραλλαγές αυτού (όπως στην περίπτωση της επαύξησης δεδομένων), είναι πιθανό να δούμε πολύ υψηλές τιμές σε αυτές τις μετρήσεις.

- **Ποσότητα Δεδομένων:** Αν τα δεδομένα ελέγχου είναι λίγο περισσότερα από τα αρχικά μας δεδομένα, τότε αυτό μπορεί να επηρεάσει τη στατιστική ισχύ των μετρήσεων. Ένα μεγαλύτερο σύνολο δεδομένων ελέγχου μπορεί να περιλαμβάνει περισσότερες ποικιλίες ή περιπτώσεις που το μοντέλο δεν έχει δει κατά την εκπαίδευση, οδηγώντας σε χαμηλότερη απόδοση.

Ενώ ενδεχομένως να φαίνεται εντυπωσιακό να έχουμε υψηλές επιδόσεις στα δεδομένα εκπαίδευσης, αυτό δεν είναι πάντα επιθυμητό. Αυτό που πραγματικά θέλουμε είναι ένα μοντέλο που γενικεύει καλά σε νέα, αδιάθετα δεδομένα. Εάν το μοντέλο εμφανίζει πολύ υψηλή απόδοση στα δεδομένα εκπαίδευσης αλλά πολύ χαμηλότερη απόδοση σε νέα δεδομένα, τότε αυτό είναι ένα σημάδι υπερπροσαρμογής (overfitting).

## 6 Επίλογος

### 6.1 Συμπεράσματα

#### 6.1.1 Εισαγωγή

Η παρούσα διπλωματική ασχολείται με την ανάπτυξη και εκπαίδευση ενός προηγμένου μοντέλου τεχνητής νοημοσύνης, βασισμένου σε νευρωνικά δίκτυα συνέλιξης (CNN), για την ανίχνευση απωλειών ενέργειας σε κτίρια χρησιμοποιώντας υπερύθρες κάμερες. Ο σκοπός αυτού του μοντέλου είναι να μελετήσει και να αναδείξει τις περιοχές στο εσωτερικό του κτιρίου που υποφέρουν από απώλειες θερμότητας, είτε αυτές είναι θερμές νοημοσύνες ή κρύες περιοχές.

Η χρήση υπερύθρων καμερών αποτελεί μια προηγμένη τεχνική, η οποία επιτρέπει την καταγραφή θερμικών εικόνων του κτιρίου. Αυτό δίνει τη δυνατότητα στο μοντέλο μας να ανιχνεύει περιοχές με πιθανή απώλεια ενέργειας, διευκολύνοντας έτσι τους ενεργειακούς επαγγελματίες να αντιμετωπίσουν προληπτικά τις αδιορθώσιμες ενεργειακές διαρροές και να βελτιστοποιήσουν την ενεργειακή απόδοση των κτιρίων.

Με τη χρήση προηγμένων τεχνικών μηχανικής μάθησης, ο σχεδιασμός του μοντέλου μας βασίζεται στο να αξιοποιήσει αποτελεσματικά τις υπερύθρες εικόνες για να προβλέψει τις περιοχές απώλειας ενέργειας. Θέλουμε να επιτύχουμε μεγάλη ακρίβεια και αξιοπιστία στις προβλέψεις μας, προκειμένου να διευκολύνουμε τις διαδικασίες διαχείρισης και συντήρησης των κτιρίων.

#### 6.1.2 Διαδικασία

Στο πρώτο στάδιο, εισάγουμε τις αρχικές εικόνες που προέρχονται από υπερύθρες κάμερες στο CNN μοντέλο μας. Το μοντέλο είναι εκπαιδευμένο να αναγνωρίζει διάφορα μοτίβα και δομές στις εικόνες που δείχνουν πιθανές απωλείες ενέργειας. Οι προβλέψεις του μοντέλου μας βοηθούν να εντοπίσουμε τις περιοχές με απώλειες ενέργειας στο κτίριο. Στη συνέχεια, αντιστρέφουμε την κλιμάκωση της εικόνας προκειμένου να επιστρέψουμε στην αρχική κλίμακα της θερμοκρασίας. Αυτό μας επιτρέπει να έχουμε μια πιο ακριβή και ερμηνεύσιμη αναπαράσταση των θερμοκρασιών στο κτίριο. Χρησιμοποιούμε τις προβλέψεις του μοντέλου για να εντοπίσουμε τις περιοχές με απώλειες ενέργειας στο κτίριο. Αυτές οι περιοχές περιλαμβάνουν τις θερμές περιοχές, δηλαδή τις περιοχές με υψηλή θερμοκρασία, καθώς και τις κρύες περιοχές, δηλαδή τις περιοχές με χαμηλή θερμοκρασία. Αξιοποιούμε τις μάσκες για τις κρύες και θερμές περιοχές, και οπτικοποιούμε αυτές τις περιοχές με διακριτούς τρόπους. Καθώς ανιχνεύουμε διαφορετικές θερμοκρασιακές περιοχές, δημιουργούμε colorbars που αντιστοιχούν σε αυτές τις περιοχές. Οι colorbars μας βοηθούν να ερμηνεύσουμε τις διαφορές στις θερμοκρασίες και να έχουμε μια ολοκληρωμένη αντίληψη των απωλειών ενέργειας στο κτίριο.

Image 1  
 Timestamp: 2020-07-30 14:30:31  
 Number of cold pixels: 18116  
 Number of hot pixels: 4690  
 Temperature Range: 34.29 - 56.53°C  
 External Temperature: 33.00°C  
 Internal Temperature: 23.00°C  
 Global Mean Temperature: 39.42°C  
 Mean Temperature in Cold Regions: 36.43°C  
 Mean Temperature in Hot Regions: 49.77°C  
 Predicted Label: 3  
 Actual Label: 3




Image 24  
 Timestamp: 2020-07-30 20:15:33  
 Number of cold pixels: 16513  
 Number of hot pixels: 0  
 Temperature Range: 34.37 - 45.73°C  
 External Temperature: 27.78°C  
 Internal Temperature: 23.00°C  
 Global Mean Temperature: 39.85°C  
 Mean Temperature in Cold Regions: 38.54°C  
 Mean Temperature in Hot Regions: No hot regions  
 Predicted Label: 3  
 Actual Label: 1




Image 54  
 Timestamp: 2020-07-31 03:45:35  
 Number of cold pixels: 11515  
 Number of hot pixels: 0  
 Temperature Range: 26.01 - 34.49°C  
 External Temperature: 23.89°C  
 Internal Temperature: 23.00°C  
 Global Mean Temperature: 31.46°C  
 Mean Temperature in Cold Regions: 29.53°C  
 Mean Temperature in Hot Regions: No hot regions  
 Predicted Label: 1  
 Actual Label: 1



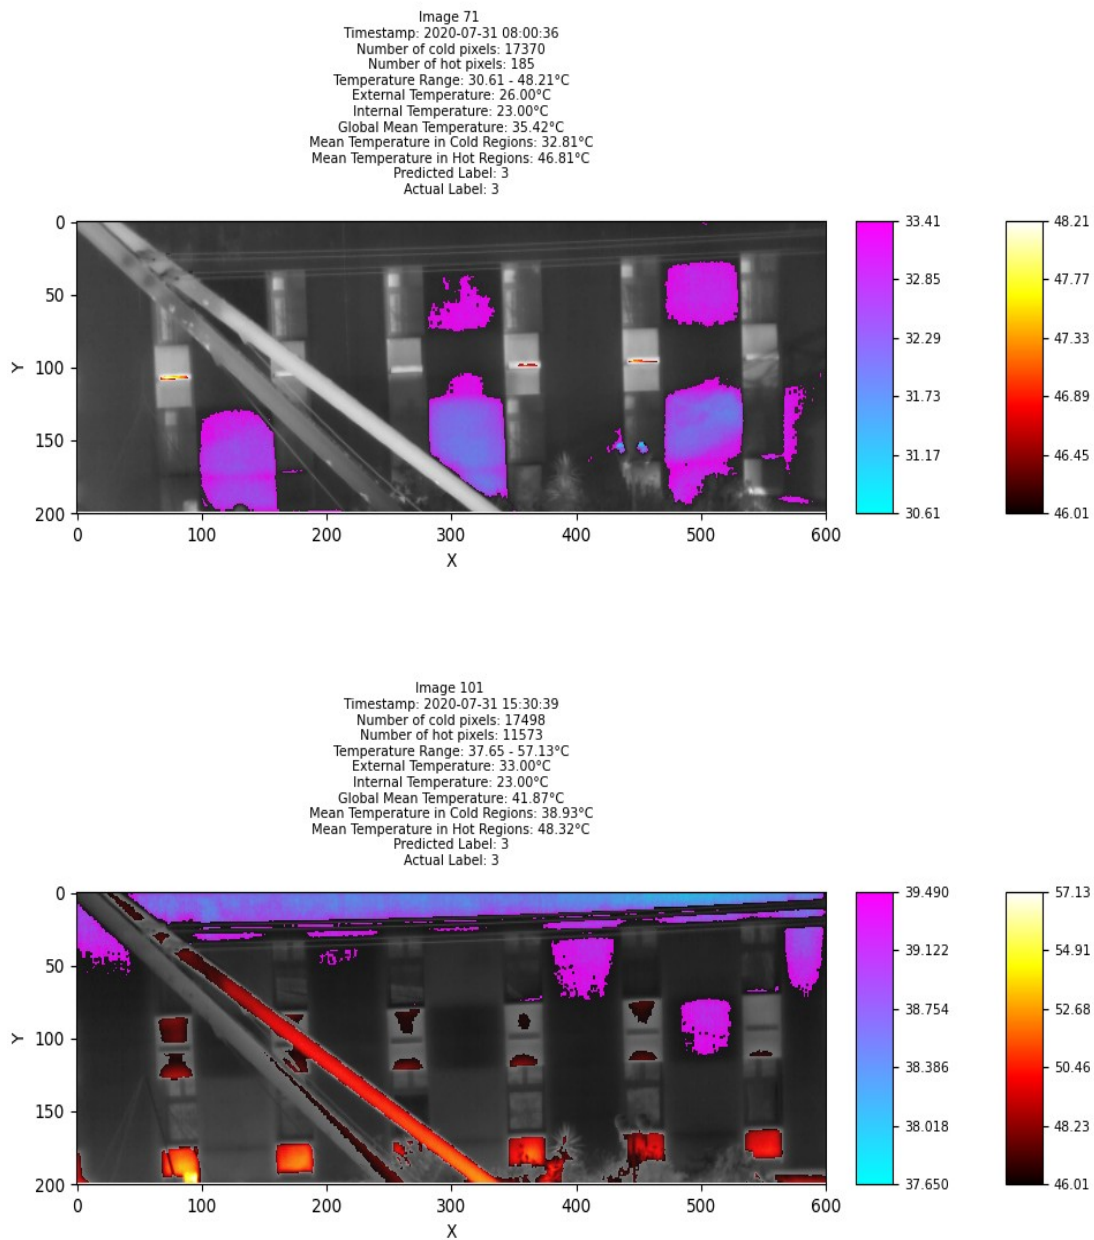


Image 67  
 Timestamp: 2020-07-31 07:00:36  
 Number of cold pixels: 16349  
 Number of hot pixels: 0  
 Temperature Range: 27.13 - 35.09°C  
 External Temperature: 23.00°C  
 Internal Temperature: 23.00°C  
 Global Mean Temperature: 31.74°C  
 Mean Temperature in Cold Regions: 30.29°C  
 Mean Temperature in Hot Regions: No hot regions  
 Predicted Label: 1  
 Actual Label: 1





Σχήμα 6.1.1: Θερμικές εικόνες που αποτυπώνουν απώλειες ενέργειας στα δεδομένα μας. Σημειώνεται ότι η ανατολή του ηλίου συνέβη στις 6:32 π.μ., ενώ η δύση του ηλίου σημειώθηκε στις 8:30 μ.μ.







Σχήμα 6.1.2: Εικόνες RGB από το κτίριο μελέτης μας που λήφθηκαν από drones, αποτυπώνοντας εμφανή ελαττώματα.

### 6.1.3 Αποτελέσματα

Εστιάζοντας κυρίως στις εικόνες που παρήχθησαν μετά την εφαρμογή νευρωνικού δικτύου, παρατηρήσαμε έντονες διαφορές στις θερμοκρασίες, με υψηλές και χαμηλές θερμοκρασίες κατά τη διάρκεια της ημέρας και χαμηλές θερμοκρασίες κατά τη διάρκεια της νύχτας. Στόχος μας είναι να εντοπίσουμε τα ενδεχόμενα ελαττώματα ή απώλειες που σχετίζονται με αυτά τα φαινόμενα.

- **Ζεστές περιοχές κατά τη διάρκεια της ημέρας:** Εάν το κτίριο είναι νοτιοανατολικά προσανατολισμένο, οι περιοχές που εκτίθενται στον ήλιο κατά τις πρωινές ώρες μπορεί να θερμαίνονται πιο γρήγορα, αφού λαμβάνουν τη μεγαλύτερη ποσότητα ηλιακής ακτινοβολίας. Αναλόγως, οι περιοχές αυτές μπορεί να αντιμετωπίζουν πρόβλημα υπερθέρμανσης. Αυτό μπορεί να σημαίνει ότι υπάρχει άσχημη θερμομόνωση στο σημείο αυτό, επιτρέποντας στη θερμότητα από τον ήλιο να εισχωρήσει στο εσωτερικό του κτιρίου. Αν οι περιοχές αυτές είναι κοντά σε εξωτερικούς τοίχους, μπορεί να οφείλονται σε ελλιπή θερμομόνωση. Αν είναι κοντά σε κεντρικά σημεία του κτιρίου, μπορεί να οφείλονται σε διαρροές από θερμαντικά ή ψυκτικά συστήματα ή σε προβλήματα με τα υδραυλικά.
- **Κρύες περιοχές κατά τη διάρκεια της ημέρας:** Αυτό μπορεί να οφείλεται στη λειτουργία του κλιματιστικού. Τα κρύα σημεία μπορεί να αντικατοπτρίζουν περιοχές όπου ο κρύος αέρας "δραπετεύει" από το εσωτερικό του κτιρίου. Τα παλιά ή φθαρμένα παράθυρα και πόρτες μπορεί να μη σφραγίζουν σωστά, επιτρέποντας στον κρύο αέρα να εξέλθει. Κατά τη διάρκεια των πρώτων πρωινών ωρών, ενδέχεται να αντιμετωπίσουμε κρύες περιοχές λόγω της έλλειψης ηλιακής θέρμανσης. Ωστόσο, αυτή η ψύχρα θα εξαφανιστεί σχετικά γρήγορα με την ανατολή του ηλίου.
- **Κρύες περιοχές κατά τη διάρκεια της νύχτας:** Κατά τη νύχτα, η νοτιοανατολική πλευρά του κτιρίου μπορεί να αντιμετωπίζει υψηλή ευάλωτητα στο κρύο. Καθώς η ηλιακή θέρμανση εξανεμίζεται, η περιοχή χάνει τη θερμότητα που είχε συσσωρευτεί κατά τη διάρκεια της ημέρας. Η ανεπαρκής θερμομόνωση ενδέχεται να επιταχύνει αυτή την απώλεια θερμότητας, αφήνοντας το κρύο να εισέρχεται και τη θερμότητα να διαφεύγει. Ακόμα και μικρές ρωγμές μπορούν να προκαλέσουν σημαντικές απώλειες θερμότητας, δημιουργώντας μια διέξοδο για τον ψυχρό αέρα να εισέρχεται και να εξέρχεται. Επιπλέον, εάν υπάρχει υψηλή υγρασία στο περιβάλλον, αυτό μπορεί να αυξήσει την αίσθηση του κρύου, αφού το νερό λειτουργεί ως αποτελεσματικός αγωγός θερμότητας. Η υπερβολική υγρασία μπορεί να αναδείξει ενδεχόμενα προβλήματα στην αδιαβροχοποίηση ή τη σφράγιση του κτιρίου, επιτείνοντας την απώλεια θερμότητας και την αίσθηση του κρύου στο εσωτερικό χώρο. Είναι επίσης πιθανό ότι τα προβλήματα κρύου μπορούν να σχετίζονται με τη λειτουργία του κλιματιστικού. Σημεία με εντοπισμένες κρύες απωλείες μπορεί να υποδηλώνουν περιοχές όπου ο ψυχρός αέρας "δραπετεύει" από το εσωτερικό του κτιρίου. Ασθενή ή παλιά παράθυρα και πόρτες ενδέχεται να μην σφραγίζουν σωστά, επιτρέποντας στον ψυχρό αέρα να διεισδύσει.



Τέλος βλέπουμε ότι το νευρωνικό δίκτυο επιδίδεται καλύτερα από μια πιο απλή, βασισμένη σε κανόνες μέθοδο. Η χρήση νευρωνικού δικτύου για την επεξεργασία και ανάλυση δεδομένων και το γεγονός ότι ανακαλύπτει λιγότερες απώλειες σε σχέση με την αρχική μας μελέτη μπορεί να θεωρηθεί θετικό, καθώς υποδηλώνει ότι το νευρωνικό δίκτυο μπορεί να προσαρμοστεί καλύτερα στα δεδομένα και να παράγει πιο ακριβείς προβλέψεις. Οι χαμηλότερες απώλειες συνήθως σημαίνουν ότι το μοντέλο προβλέπει τα δεδομένα εκπαίδευσης με μεγαλύτερη ακρίβεια. Αν αυτό μεταφράζεται και σε καλές επιδόσεις στα δεδομένα ελέγχου, τότε το μοντέλο μας είναι πιθανότατα αξιόπιστο. Επίσης αν το δίκτυο παρουσιάζει χαμηλότερες απώλειες, αυτό μπορεί να υποδηλώνει ότι έχει "καταλάβει" καλύτερα τις διακυμάνσεις των δεδομένων. Ωστόσο, χαμηλές απώλειες στα δεδομένα εκπαίδευσης δεν σημαίνουν πάντα ότι το μοντέλο θα λειτουργεί καλά σε δεδομένα που δεν έχει δει ποτέ (δεδομένα ελέγχου). Υπάρχει πάντα ο κίνδυνος της υπερεκπαίδευσης, όπου το μοντέλο "μαθαίνει" τα δεδομένα εκπαίδευσης τόσο καλά που δεν μπορεί να γενικεύσει σε νέα δεδομένα. Γι' αυτό είναι σημαντικό να ελέγχουμε πάντα την απόδοση του μοντέλου σε δεδομένα ελέγχου.

Τα αποτελέσματα της διπλωματικής μας αναδεικνύουν με ακρίβεια τις περιοχές του κτιρίου που παρουσιάζουν απώλειες ενέργειας. Οι θερμές περιοχές και οι κρύες περιοχές εμφανίζονται με διαφορετικά χρώματα για ευκολότερη αναγνώριση. Η παρουσίαση των αποτελεσμάτων περιλαμβάνει πληροφορίες σχετικά με τη θερμοκρασία στο εσωτερικό και εξωτερικό του κτιρίου, καθώς και την πρόβλεψη του μοντέλου μας για την περιοχή απώλειας ενέργειας. Η παρουσίαση περιλαμβάνει επίσης μετρικές σχετικά με την επίδοση του μοντέλου μας, όπως η ακρίβεια και η απόδοση στο σύνολο των δεδομένων.

Στόχος μας είναι να αποδείξουμε την αποτελεσματικότητα και την πρακτικότητα του προτεινόμενου μοντέλου και να παρέχουμε στον κλάδο των ενεργειακών μελετών μια πολύτιμη εργαλειοθήκη για τη βελτιστοποίηση των διαδικασιών τους.

Συνοψίζοντας, η διπλωματική μας αντλεί από την τεχνολογία της υπερύθρων και την ισχύ της μηχανικής μάθησης, με στόχο να προσφέρει μια αποτελεσματική και καινοτόμο λύση για την ανίχνευση απωλειών ενέργειας σε κτίρια, με χρήση του προτεινόμενου CNN μοντέλου.

#### 6.1.4 Πιθανές λύσεις

1. **Βελτίωση Θερμομόνωσης:** Προσθέτουμε πρόσθετη θερμομόνωση σε περιοχές που εμφανίζουν ζεστές και κρύες ανωμαλίες. Αυτό μπορεί να γίνει μέσω της προσθήκης μονωτικών υλικών σε τοίχους, οροφές και δάπεδα.
2. **Βελτίωση στεγανότητας:** Ελέγχουμε την κατάσταση των παραθύρων και των πορτών. Αν υπάρχουν παλιά ή φθαρμένα παράθυρα, εξετάζουμε την αντικατάστασή τους με νέα παράθυρα που έχουν καλή σφράγιση και θερμομόνωση ή την επισκευή τους.

3. **Επισκευές και συντήρηση:** Ελέγχνουμε για ρωγμές, τρύπες ή άλλες διαρροές στο κτίριο και τις αντιμετωπίζουμε. Η καλή σφράγιση μπορεί να μειώσει την απώλεια θερμότητας.
4. **Επανεξέταση Υλικών:** Εξετάζουμε τα υλικά που χρησιμοποιούνται στην κατασκευή των εξωτερικών τοίχων και των παραθύρων. Ίσως χρειαστεί να αντικαταστήσουμε ή να βελτιώσουμε υλικά που δεν παρέχουν αρκετή θερμομόνωση.
5. **Ελέγχος της υγρασίας:** Βεβαιωνόμαστε ότι οι προστατευτικές στρώσεις και οι στεγανωτικοί χώροι του κτιρίου μας είναι σε καλή κατάσταση για να αποτρέψουν τις διαρροές νερού.

## 6.2 Προτάσεις για Μελλοντική Έρευνα

Βάσει των πληροφοριών που παρέχονται στην εργασία, προτάσεις για μελλοντική έρευνα μπορούν να επικεντρωθούν σε διάφορους τομείς. Ορισμένες προτάσεις που μπορούν να εξεταστούν είναι οι εξής:

1. **Βελτιστοποίηση μεθόδων εφαρμογής θερμογραφίας στα κτίρια:** Μπορεί να γίνει μελέτη και σύγκριση διαφόρων μεθοδολογιών χρήσης της θερμογραφίας σε κτίρια, όπως η ενεργή θερμογραφία, η παθητική θερμογραφία, οι επαναλαμβανόμενες έρευνες κ.λπ. Αυτή η έρευνα θα μπορούσε να αναδείξει τα πλεονεκτήματα και τους περιορισμούς κάθε μεθόδου και να προτείνει βέλτιστες πρακτικές.
2. **Επέκταση της Βάσης Δεδομένων:** Είναι σημαντικό να επεκταθεί η βάση δεδομένων με περισσότερες θερμογραφικές εικόνες από διαφορετικά κτίρια, περιβάλλοντα και κλιματικές συνθήκες, καθώς αυτό θα βελτιώσει τη γενίκευση των μοντέλων.
3. **Χρήση Διαφορετικών Τεχνικών Μηχανικής Μάθησης:** Μπορεί να δοκιμαστεί η χρήση διαφορετικών τεχνικών ή αρχιτεκτονικών νευρωνικών δικτύων για τη βελτίωση της ακρίβειας του μοντέλου.
4. **Εξατομικευμένες μέθοδοι ανάλυσης:** Μπορεί να εξεταστεί η ανάπτυξη μεθόδων που να λαμβάνουν υπόψη τις ειδικές απαιτήσεις και χαρακτηριστικά κάθε κτιρίου, για να επιτευχθεί πιο αποτελεσματική αναγνώριση ελαττωμάτων.

5. **Μη Επιβλεπόμενη Μάθηση και Αλγόριθμοι Συσταδοποίησης (Clustering):** Οι αλγόριθμοι συσταδοποίησης, όπως οι αλγόριθμοι k-means, μπορούν να χρησιμοποιηθούν για να αναγνωρίσουν περιοχές στις θερμογραφικές εικόνες με παρόμοια χαρακτηριστικά θερμοκρασίας. Αυτό μπορεί να βοηθήσει στον εντοπισμό ασυνήθιστων περιοχών χωρίς την ανάγκη για ετικέτες ή προηγούμενη επιβλεπόμενη εκπαίδευση . Η χρήση της μη επιβλεπόμενης μάθησης μπορεί να βοηθήσει στην ανακάλυψη ανωμαλιών και βελτίωση της αξιοπιστίας της ανάλυσης θερμογραφικών εικόνων σε κτίρια.

## Βιβλιογραφία

- [ 1] ΔΙΑΓΝΩΣΗ ΠΡΟΒΛΗΜΑΤΩΝ ΣΤΑ ΚΤΙΡΙΑ ΜΕ ΤΗ ΜΕΘΟΔΟ ΤΗΣ ΘΕΡΜΟΓΡΑΦΙΑΣ  
ΕΦΑΡΜΟΓΕΣ, ΤΕΧΝΙΚΕΣ & ΤΕΧΝΟΛΟΓΙΑ  
[https://ktirio.gr/el/%CE%B1%CF%81%CE%B8%CF%81%CE%B1/%CE%BC%CE%BF%CE%BD%CF%89%CF%83%CE%B7/download/1321\\_862dd491568c9331ac40cc822279a0e6](https://ktirio.gr/el/%CE%B1%CF%81%CE%B8%CF%81%CE%B1/%CE%BC%CE%BF%CE%BD%CF%89%CF%83%CE%B7/download/1321_862dd491568c9331ac40cc822279a0e6) Accessed:  
10/06/2023
- [2] Thermography methodologies for detecting energy related building defects  
[Thermography methodologies for detecting energy related building defects - ScienceDirect](#) Accessed:  
10/06/2023
- [3] ] Lloyd CR, Callau MF, Bishop T, Smith IJ. The efficacy of an energy efficient upgrade program in New Zealand. Energy and Buildings. 2008;40:1228-39. Accessed: 10/06/2023
- [4] Halliday S. Sustainable Construction. Oxford, UK: Butterworth-Heinemann; 2008.
- [5] ΥΠΕΡΥΘΡΗ ΘΕΡΜΟΓΡΑΦΙΑ ΩΣ ΕΡΓΑΛΕΙΟ ΜΗ ΚΑΤΑΣΤΡΟΦΙΚΟΥ ΕΛΕΓΧΟΥ ΣΕ ΘΕΜΑΤΑ  
ΕΝΔΙΑΦΕΡΟΝΤΟΣ ΠΟΛΙΤΙΚΟΥ ΜΗΧΑΝΙΚΟΥ  
<https://nemertes.library.upatras.gr/server/api/core/bitstreams/59fb4ac3-8513-4fdf-962c-bc60e7e1c93d/content> Accessed: 10/06/2023
- [6] Η θερμογραφία ως εργαλείο για τη συντήρηση μνημείων και έργων τέχνης  
<http://ikee.lib.auth.gr/record/290262/files/%CE%94%CE%99%CE%A0%CE%9B%CE%A9%CE%9C%CE%91%CE%A4%CE%99%CE%9A%CE%97.pdf>
- [7] Jensen JR. Remote Sensing of the Environment - An Earth Resource Perspective. New Jersey: Prentice Hall; 2000 Accessed: 10/06/2023
- [8] Walker NJ. Volume one - Principles and Practice: BINDT; 2004.
- [9] Schwoegler M. Buying a Thermal Imager for Building Applications. What Equipment Specifications Should You Consider: The Snell Group; 2011 Accessed: 10/06/2023
- [10] ] ITC. Thermography Level 1 Course Manual. Stockholm Sweden: Infrared Technology Centre, FLIR systems AB; 2006

- [11] Snell J. The Latest in Hot Shots. Infrared cameras are becoming affordable tools for building performance professionals. Home and Energy Magazine 2002 . Accessed: 12/06/2023
- [12] Holst GC. Common sense approach to thermal imaging. Bellingham, Washington USA: SPIE - The International Society for Optical Engineering; 2000. Accessed: 12/06/2023
- [13] Electrophysics. Understanding Infrared Camera Thermal Image Quality. Electrophysics Resource Center Scientific Imaging White Paper. Fairfield, New Jersey: Electrophysics Corp.; 2011. Accessed: 12/06/2023
- [14] Minkina W, Dudzik S. Infrared Thermography Errors and Uncertainties. Chichester, West Sussex, UK: John Wiley & Sons, Ltd; 2009
- [15] Phan LN. Automated Rapid Thermal Imaging Systems Technology. Massachusetts Massachusetts Institute of Technology; 2012. Accessed: 13/06/2023
- [16] FLIR. FLIR Webshop - Building Diagnostics. FLIR; 2014. Available from: <http://www.flirwebshop.com/en/building.html> Accessed: 13/06/2023
- [18] Asdrubali F, Baldinelli G, Bianchi F. A quantitative methodology to evaluate thermal bridges in buildings. Applied Energy. 2011 Accessed: 13/06/2023
- [19] Sharlon MR. Active Thermography: An Overview of Methods and Their Applications in Use Today. IR/INFO 2007. Orlando, Florida: Thermasearch, Inc.; 2007. Accessed: 16/06/2023
- [20] Kominsky JR, Luckino JS, Martin TF. Passive Infrared Thermography—A Qualitative Method for Detecting Moisture Anomalies in Building Envelopes. Tedford & Pond; 2007
- [21] Aggelis DG, Kordatos EZ, Soulioti DV, Matikas TE. Combined use of thermography and ultrasound for the characterization of subsurface cracks in concrete. Construction and Building Materials. 2010 Accessed: 16/06/2023
- [22] Maierhofer C, Rollig M, Krankenhagen R. Integration of active thermography into the assessment of cultural heritage buildings. Journal of Modern Optics. 2010;Vo. 57:1790 - 802 Accessed: 16/06/2023
- [23] Grys S. New thermal contrast definition for defect characterization by active thermography. Measurement. 2012;45:1885 - 92. Accessed: 16/06/2023
- [24] Spring R, Huff R, Schwoegler M. Infrared Thermography: A Versatile Nondestructive Testing Technique. The Snell Group; 2011.
- [25] Maldague X. Introduction to NDT by Active Infrared Thermography. Materials Evaluation. 2002;6:1060 -73. Accessed: 16/06/2023

- [26] Fokaides PA, Kalogirou SA. Application of infrared thermography for the determination of the overall heat transfer coefficient (U-Value) in building envelopes. *Applied Energy*. 2011;88:4358-65.
- [27] Madding R. Finding R-Values of Stud Frame Constructed Houses with IR Thermography. *InfraMation* 2008 2008. Accessed: 19/06/2023
- [28] Pearson C. Thermal Imaging of Building Fabric. A best practice guide for continuous insulation: BSRIA; 2002. Accessed: 19/06/2023
- [29] Balaras CA, Argiriou AA. Infrared thermography for building diagnostics. *Energy and Buildings*. 2002;34:171- 83. Accessed: 20/06/2023
- [30] ] Kalamees T. Air tightness and air leakages of new lightweight single-family detached houses in Estonia. Accessed: 20/06/2023
- [31] Titman DJ. Applications of thermography in non-destructive testing of structures. *NDT&E International* 34: Elsevier Science Ltd; 2001 Accessed: 20/06/2023
- [32] Burkinshaw R, Parrett M. Diagnosing Damp. Coventry: RICS Business Services Limited; 2003.
- [33] BRE. Diagnosing the causes of dampness. Good Repair Guide 5 Watford: Construction Research Communications Ltd; 1997. Accessed: 20/06/2023
- [34] Avdelidis NP, Moropoulou A, Theoulakis P. Detection of water deposits and movement in porous materials by infrared imaging. *Infrared Physics & Technology*. 2003;44:183 - 90
- [35] Chown GA, Burn KN. CBD-229. Thermographic Identification of Building Enclosure Effects and Deficiencies. National Research Council Canada; 1983.
- [36] SFHA. Carbon Portal Project Back to Take the Heat Out of Housing Emissions Across Scotland. Scottish Federation of Housing Associations; 2011. Available from: <http://www.sfha.co.uk/sfha/latest-news/carbonportal-project-back-to-take-the-heat-out-of-housing-emissions-across-scotland/menu-id-8.html> Accessed: 23/06/2023
- [37] ] Artis DA, Carnahan WH. Survey of Emissivity Variability in Thermography of Urban Areas. *Remote Sensing Of Environment*. 1982;12:313-29
- [38] Chang YM, Galowin LS. Aerial Thermography And Spot Radiometer Applications For Detecting Thermal Anomalies Of Office Buildings. In: Kantsios AG, editor. *Proc SPIE 0520, Thermosense VII: Thermal Infrared Sensing for Diagnostics and Control*. Cambridge1985. Accessed:23/06/2023
- [39] Schott JR, Biegel JD, Wilkinson EP. Quantitative Aerial Survey Of Building Heat Loss. In: Courville GE, editor. *Proc SPIE 0371, Thermosense V*. Detroit1983. Accessed: 23/06/2023

- [40] Treado SJ, Burch DM. Field Evaluation Of Aerial Infrared Surveys For Residential Applications. In: Grot RA, Wood JT, editors. Proc SPIE 0313, Thermal Infrared Sensing Applied to Energy Conservation in Building Envelopes. Ottawa, Canada: National Bureau of Standards (United States); 1982 Accessed: 23/06/2023
- [41] Stockton GR. Qualitative Infrared Roof Moisture Surveys – Who Performs Them, Who Buys Them, and Why. Thermal Solutions 2001. Orlando2001. p. 14. Accessed: 25/06/2023
- [42] Colantonio A, Theauvette M. Specifying Infrared Thermographic Services For Large Buildings. InfraMation 20072007 . Accessed: 25/06/2023
- [43] Allinson D. Evaluation of aerial thermography to discriminate loft insulation in residential housing: University of Nottingham; 2007 . Accessed: 25/06/2023
- [44] ] Stockton GR. Are you IR Challenged? Stockton Infrared White Paper. Randleman, NC: Stockton Infrared Thermographic Services; 2002. Accessed: 26/06/2023
- [45] ] Stockton GR. Methodologies of Finding, Analyzing and Prioritizing Moisture Problems in Roofing Materials Using Infrared Thermal Imaging. IR/INFO 20132013. Accessed: 26/06/2023
- [46] Micro-Epsilon. Lightweight thermal imager can be mounted to UAVs for 11-06-2013 aerial inspection tasks. Birkenhead, UK: Micro-Epsilon UK Ltd; 2013. Available from: [http://www.microepsilon.co.uk/news/2013/UK\\_187\\_TIM\\_Lightweight/index.html](http://www.microepsilon.co.uk/news/2013/UK_187_TIM_Lightweight/index.html) Accessed: 26/06/2023
- [47] Martinez-de Dios JR, Ollero A. Automatic Detection of Windows Thermal Heat Losses in Buildings Using UAVs. Automation Congress, 2006 WAC '06 World2006. p. 1-6.
- [48] Eschmann C, Kuo C-M, Kuo C-H, Boller C. Unmanned Aircraft Systems for Remote Building Inspection and Monitoring. 6th European Workshop on Structural Health Monitoring 2012.
- [49] Mikrocopter. MK Basic Sets. Mikrocopter - Shop. Moormerland, Germany: Mikrocopter; 2013. Available from: [https://www.mikrocontroller.com/index.php?main\\_page=index&cPath=80](https://www.mikrocontroller.com/index.php?main_page=index&cPath=80) Accessed: 27/06/2023
- [50] CAA. Air Navigation: The Order and the Regulations. In: Authority UCA, editor. London, UK: TSO (The Stationery Office) on behalf of the UK Civil Aviation Authority; 2012. p. 480. .
- [51] Olanoff D. Inside Google Street View: From Larry Page's Car To The Depths Of The Grand Canyon. techcrunch.com; 2013. Available from: <http://techcrunch.com/2013/03/08/inside-google-street-view-from-larrypages-car-to-the-depths-of-the-grand-canyon/> Accessed: 27/06/2023
- [52] Heaton B. 'Drive-By' Thermal Imaging Quantifies Energy Loss. Government Technology; 2011. Available from: <http://www.govtech.com/technology/Drive-By-Thermal-Imaging-Quantifies-Energy-Loss.html> Accessed: 27/06/2023

- [53] Shao EC. Detecting sources of heat loss in residential buildings from infrared Imaging. Massachusetts: Massachusetts Institute of Technology; 2011.
- [54] Dusto A. Mobile Infrared Camera Provides Energy Snapshots of City. Tech and Gadgets News: Discovery News; 2011. Available from: <http://news.discovery.com/tech/mobile-infrared-camera-provides-energysnapshots-of-city-110318.html> Accessed: 27/06/2023
- [55] Nusca A. MIT thermal imaging system captures energy loss in buildings, cities. SmartPlanet2011.
- [56] Chandler DL. The big picture on energy loss. MIT system, tested in Cambridge, gives comprehensive view of energy inefficiency across large areas. Massachusetts: MIT News; 2011. Available from: <http://web.mit.edu/newsoffice/2011/ir-scanning-energy-0316.html> Accessed: 27/06/2023
- [57] Lebwohl B. Sanjay Sarma performs first citywide energy audit. Interviews, Human World: EarthSky; 2011. Available from: <http://earthsky.org/human-world/sanjay-sarma-performs-first-citywide-energy-audit> Accessed: 27/06/2023
- [58] IRT surveys. IRT Surveys partner with the SFHA. News: IRT surveys; 2012. Available from: <http://www.irtsurveys.co.uk/news/7/IRT+Surveys+partner+with+the+SFHA> Accessed: 27/06/2023
- [59] Currie S. SFHA Carbon Portal –A Housing Associations Perspective. Clyde Valley Housing Association; 2012. Available from: [http://www.carbon-portal.org.uk/wp-content/uploads/2011/01/1102\\_Carbon-Portal\\_CVHA.pdf](http://www.carbon-portal.org.uk/wp-content/uploads/2011/01/1102_Carbon-Portal_CVHA.pdf)
- [60] Schwoegler M. Thermal Imaging of Cambridge, MA in the News. In: IRTalk, editor. IRTalk: The Snell Group; 2011. Available from: <http://www.thesnellgroup.com/community/ir-talk/f/8/p/1899/8050.aspx#8050> Accessed: 28/06/2023
- [61] Red-Current. Reduce Heat Loss with Building Thermography. Building Thermography: Red Current; 2012. Available from: <http://www.red-current.com/red-current-thermal-imaging-services/building-thermography> Accessed: 30/06/2023
- [62] Colantonio A. Infrared Thermographic Investigation Procedures For Four Types Of Generic Exterior Wall Assemblies. THERMOSENSE XXI. ORLANDO, FLORIDA1999.
- [63] Westerhold K. Is your Building Thermography Survey telling you what you want to know? Electronics. Petach Tikva, Israel: The Best of Tech; 2013. Available from: <http://www.thebestoftech.com/is-your-buildingthermography-survey-telling-you-what-you-want-to-know-3214451>



- [64] ASTM. Standard Practice for Thermographic Inspection of Insulation Installations in Envelope Cavities of Frame Buildings. In: American Society for Testing and Materials (ASTM), editor. West Conshohocken, PA, USA: ASTM; 1997 .
- [65] Mydin MAO, Ramli M, Awang H. Factors of Deterioration in Building and the Principles of Repair. *Analele Universității "Eftimie Murgu"*. 2012;ANUL XIX:345 - 52. Accessed: 30/06/2023
- [66] Harris B. Environmental Deterioration Of Building Materials. *Metallurgist & Materials Technologist*. 1981;13:405-10. Accessed: 30/06/2023
- [67] Lucier RD, Phillips L. Infrared Thermography for Metal Roof Inspections. *Metalmag*. July / August 2003 ed. Chicago, IL: Hanley Wood; 2003. p. 90 - 4.
- [68] Brost T. Thermographic-case-study. Ontario, Canada: Induspec; 2010. Available from: <http://www.induspec.ca/thermographic-case-study.pdf> Accessed: 30/06/2023
- [69] Tibbs AL. Using Infrared Thermography to Assess Building Problems. Cleveland, OH: Closer Look Inspections; 2004. Accessed: 30/06/2023
- [70] Hopper J, Littlewood JR, Taylor T, Counsell JAM, Thomas AM, Karani G, et al. Assessing retrofitted external wall insulation using infrared thermography. *Structural Survey*. 2012;Vol. 30:pp. 245 - 66.
- [71] Goodhew J, Goodhew S, Auburn T, Wilde PD, Pahl S. A preliminary investigation of the potential for thermographic images to influence householders understanding of home energy consumption. In: Dainty A, editor. 25th Annual ARCOM Conference. Nottingham, UK: Association of Researchers in Construction Management; 2009. p. 971-79. Accessed: 30/06/2023
- [72] Snell J, Schwoegler M. The Use of Infrared Thermal Imaging for Home Weatherization. The Snell Group; 2012. p. 6.
- [73] Mumovic D, Ridley I, Oreszczyn T, Davies M. Condensation risk: comparison of steady-state and transient methods. *Building Services Engineering Research and Technology*. 2006;27:219 - 33.
- [74] Drollette D. Infrared Thermography Heats Up. *Photonics Spectra Magazine*. Pittsfield, MA: Laurin Publishing Company, Inc.; 2001.
- [75] Lo TY, Choi KTW. Building defects diagnosis by infrared thermography. *Structural Survey*. 2004;Vol. 22:259 - 63. Accessed: 30/06/2023
- [76] Grinzato E, Cadelano G, Bison P. Moisture map by IR thermography. *Journal of Modern Optics*. 2010;57:1770-8. Accessed: 30/06/2023

- [77] Youcef MHAL, Feuillet V, Ibos L, Candau Y, Balcon P, Filloux A. In situ quantitative diagnosis of insulated building walls using passive infrared thermography. 11th International Conference on Quantitative InfraRed Thermography. Naples Italy2012 .
- [78] Hart JM. An introduction to infra-red thermography for building surveys. BRE Information Paper. 1990 .
- [79] Bursell D. Getting the Most From Your IR Camera. Evaluation Engineering; 2007. Available from: <http://www.evaluationengineering.com/articles/200712/getting-the-most-from-your-ir-camera.php> Accessed: 02/07/2023
- [80] Mobley RK. 8 - Thermography. An Introduction to Predictive Maintenance (Second Edition). Burlington: Butterworth-Heinemann; 2002. p. 172-201. Accessed: 02/07/2023
- [81] Hart JM. A practical guide to infra-red thermography for building surveys. Garston, Watford: Building Research Establishment; 1991. Accessed: 02/07/2023
- [82] Gonçalves MD, Gendron P, Colantonio A. Commissioning of Exterior Building Envelopes of Large Buildings for Air Leakage and Resultant Moisture Accumulation using Infrared Thermography and Other Diagnostic Tools. Thermal Solutions 2007. Sarasota, Florida2007 . Accessed: 05/07/2023
- [83] Brady J. Thermographic Inspection of Building and Roof Water Intrusion in the State of Florida. IR INFO 08: Brady Infrared Paper; 2008. p. 16 Accessed: 05/07/2023
- [84] FLIR <https://www.flir.eu/products/tau-2/?model=46640050H&vertical=lwir&segment=oem> Accessed: 05/07/2023
- [85] <https://pergamos.lib.uoa.gr/uoa/dl/frontend/file/lib/default/data/2758693/theFile>
- [86] Μηχανική Μάθηση  
[http://repfiles.kallipos.gr/html\\_books/93/04a-main.html](http://repfiles.kallipos.gr/html_books/93/04a-main.html) Accessed: 08/07/2023
- [87] Τεχνητά Νευρωνικά Δίκτυα και Εφαρμογή  
<https://hellanicus.lib.aegean.gr/bitstream/handle/11610/19590/%20%20%20%20%20%20%20%20%20%20%20%20%20.pdf?sequence=1> Accessed: 08/07/2023
- [89] A Gentle Introduction To Neural Networks Series — Part 1  
<https://towardsdatascience.com/a-gentle-introduction-to-neural-networks-series-part-1-2b90b87795bc>
- [90] ANN vs CNN vs RNN: Neural Networks Guide  
<https://levity.ai/blog/neural-networks-cnn-ann-rnn> Accessed: 08/07/2023
- [91] Basic CNN Architecture: Explaining 5 Layers of Convolutional Neural Network  
<https://www.upgrad.com/blog/basic-cnn-architecture/>

- [92] Tutorials Point, «Artificial Neural Network - Basic Concepts,» [Ηλεκτρονικό]. Available: [https://www.tutorialspoint.com/artificial\\_neural\\_network/artificial\\_neural\\_network\\_basic\\_concepts.htm](https://www.tutorialspoint.com/artificial_neural_network/artificial_neural_network_basic_concepts.htm). Accessed: 10/07/2023
- [93] D. Fumo, «A Gentle Introduction To Neural Networks Series — Part 1,» 4 August 2017. [Ηλεκτρονικό]. Available: <https://towardsdatascience.com/a-gentle-introduction-to-neural-networks-series-part-1-2b90b87795bc>. Accessed: 10/07/2023
- [94] T. Yiu, «Understanding Neural Networks,» Towards Data Science, 2 June 2019. [Ηλεκτρονικό]. Available: <https://towardsdatascience.com/understanding-neural-networks-19020b758230>.
- [95] Introduction to Long Short-Term Memory(LSTM)  
<https://www.simplilearn.com/tutorials/artificial-intelligence-tutorial/lstm> Accessed: 10/07/2023
- [96] Long Short-Term Memory Networks (LSTM)- simply explained!  
<https://databasecamp.de/en/ml/lstms> σε κείμενο Accessed: 10/07/2023
- [97] Understanding Architecture of LSTM  
<https://www.analyticsvidhya.com/blog/2021/01/understanding-architecture-of-lstm/>  
Accessed: 10/07/2023
- [98] A Complete Guide to LSTM Architecture and its Use in Text Classification  
<https://analyticsindiamag.com/a-complete-guide-to-lstm-architecture-and-its-use-in-text-classification/>  
Accessed: 10/07/2023
- [99] CNN Long Short-Term Memory Networks <https://machinelearningmastery.com/cnn-long-short-term-memory-networks/> Accessed: 10/07/2023
- [100] Activation Functions and their Derivatives – A Quick & Complete Guide  
<https://www.analyticsvidhya.com/blog/2021/04/activation-functions-and-their-derivatives-a-quick-complete-guide/> Accessed: 12/07/2023
- [101] Introduction to TensorFlow  
<https://www.geeksforgeeks.org/introduction-to-tensorflow/> Accessed: 12/07/2023
- [102] Pandas Tutorial: DataFrames in Python  
<https://www.datacamp.com/tutorial/pandas-tutorial-dataframe-python> Accessed: 12/07/2023
- [103] Python pandas tutorial: The ultimate guide for beginner  
<https://www.datacamp.com/tutorial/pandas> Accessed: 13/07/2023
- [104] Keras Tutorial  
<https://www.javatpoint.com/keras> Accessed: 13/07/2023
- [105] M. Waskom, «seaborn,» [Ηλεκτρονικό]. Available: <https://seaborn.pydata.org/>. Accessed: 14/07/2023

- [106] J. Brownlee, «MachineLearningMastery,» 3 October 2019. [Ηλεκτρονικό]. Available: <https://machinelearningmastery.com/how-to-develop-a-convolutional-neural-network-to-classify-photos-of-dogs-and-cats/>.
- [107] Keras Callbacks  
<https://www.kdnuggets.com/2019/08/keras-callbacks-explained-three-minutes.html> Accessed: 14/07/2023
- [108] Optimizers in Deep Learning  
<https://www.scaler.com/topics/deep-learning/optimizers-in-deep-learning/> Accessed: 15/07/2023
- [109] Why Weight? The Importance of Training on Balanced Datasets  
<https://towardsdatascience.com/why-weight-the-importance-of-training-on-balanced-datasets-f1e54688e7df> Accessed: 15/07/2023
- [110] Loss Functions and Their Use In Neural Networks  
<https://towardsdatascience.com/loss-functions-and-their-use-in-neural-networks-a470e703f1e9> Accessed: 15/07/2023
- [111] Confusion Matrix and Classification Report  
<https://medium.com/swlh/confusion-matrix-and-classification-report-88105288d48f> Accessed: 20/07/2023
- [112] Chania, Crete, Greece Weather Conditions  
<https://www.wunderground.com/history/daily/gr/mouzouras/LGSA/date/2020-7-20> Accessed: 11/12/2022
- [113] How to Apply L1 and L2 Regularization Techniques to Keras Models  
<https://medium.com/data-science-365/how-to-apply-l1-and-l2-regularization-techniques-to-keras-models-da6249d8a469> Accessed: 21/07/2023
- [114] Random Oversampling and Undersampling for Imbalanced  
<https://machinelearningmastery.com/random-oversampling-and-undersampling-for-imbalanced-classification/> Accessed: 21/07/2023
- [115] Sklearn.StratifiedShuffleSplit() function in Python  
<https://www.geeksforgeeks.org/sklearn-stratifiedshufflesplit-function-in-python/> Accessed: 23/07/2023
- [116] A Gentle Introduction To Min-Max Data Normalization  
<https://jonmce.medium.com/min-max-your-way-through-pandas-data-frames-18dc40b6b12f> Accessed: 23/07/2023