




ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ
ΚΑΙ ΗΛΕΚΤΡΟΝΙΚΩΝ ΣΥΣΤΗΜΑΤΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

«Επεξηγήσιμη Τεχνητή Νοημοσύνη για Πρόβλεψη
Πυρκαγιών από Μετεωρολογικά Δεδομένα»



Της φοιτήτριας
Παπαχρήστου Αθηνά
Αρ. Μητρώου: 27/2024

Επιβλέπων
Ονοματεπώνυμο Διαμαντάρας
Κωνσταντίνος
Βαθμίδα Καθηγητής

Ημερομηνία 14/06/2026

Τίτλος Δ.Ε. Επεξηγήσιμη Τεχνητή Νοημοσύνη για Πρόβλεψη Πυρκαγιών από Μετεωρολογικά
Δεδομένα

Κωδικός Δ.Ε. 25290

Ονοματεπώνυμο φοιτητή/τών Παπαχρήστου Αθηνά

Ονοματεπώνυμο εισηγητή Διαμαντάρας Κωνσταντίνος

Ημερομηνία ανάληψης Δ.Ε. 21/07/2025

Ημερομηνία περάτωσης Δ.Ε. 14/06/2026

Βεβαιώνω ότι είμαι ο συγγραφέας αυτής της εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, έχω καταγράψει τις όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών, εικόνων και κειμένου, είτε αυτές αναφέρονται ακριβώς είτε παραφρασμένες. Επιπλέον, βεβαιώνω ότι αυτή η εργασία προετοιμάστηκε από εμένα προσωπικά, ειδικά ως διπλωματική εργασία, στο Τμήμα Μηχανικών Πληροφορικής και Ηλεκτρονικών Συστημάτων του ΔΙ.ΠΑ.Ε.

Η παρούσα εργασία αποτελεί πνευματική ιδιοκτησία της φοιτήτριας Παπαχρήστου Αθηνάς που την εκπόνησε. Στο πλαίσιο της πολιτικής ανοικτής πρόσβασης, ο συγγραφέας/δημιουργός εκχωρεί στο Διεθνές Πανεπιστήμιο της Ελλάδος άδεια χρήσης του δικαιώματος αναπαραγωγής, δανεισμού, παρουσίασης στο κοινό και ψηφιακής διάχυσης της εργασίας διεθνώς, σε ηλεκτρονική μορφή και σε οποιοδήποτε μέσο, για διδακτικούς και ερευνητικούς σκοπούς, άνευ ανταλλάγματος. Η ανοικτή πρόσβαση στο πλήρες κείμενο της εργασίας, δεν σημαίνει καθ' οιονδήποτε τρόπο παραχώρηση δικαιωμάτων διανοητικής ιδιοκτησίας του συγγραφέα/δημιουργού, ούτε επιτρέπει την αναπαραγωγή, αναδημοσίευση, αντιγραφή, πώληση, εμπορική χρήση, διανομή, έκδοση, μεταφόρτωση (downloading), ανάρτηση (uploading), μετάφραση, τροποποίηση με οποιονδήποτε τρόπο, τμηματικά ή περιληπτικά της εργασίας, χωρίς τη ρητή προηγούμενη έγγραφη συναίνεση του συγγραφέα/δημιουργού.

Η έγκριση της διπλωματικής εργασίας από το Τμήμα Μηχανικών Πληροφορικής και Ηλεκτρονικών Συστημάτων του Διεθνούς Πανεπιστημίου της Ελλάδος, δεν υποδηλώνει απαραίτητως και αποδοχή των απόψεων του συγγραφέα, εκ μέρους του Τμήματος.

Πρόλογος

Η επιλογή του θέματος της εργασίας προέκυψε από το ενδιαφέρον μου για την εύρεση και διαχείριση ανοικτών δεδομένων (open data) και την εφαρμογή τους στη μηχανική μάθηση. Στην Ελλάδα σχεδόν κάθε καλοκαίρι στα μέσα μαζικής ενημέρωσης παρουσιάζεται το φαινόμενο της πυρκαγιάς, έτσι προέκυψε και το θέμα της πρόβλεψης των δασικών πυρκαγιών. Πρόκειται για ένα σύνθετο φαινόμενο που επηρεάζεται από πολλούς μετεωρολογικούς και περιβαλλοντικούς παράγοντες και έχει σημαντικές επιπτώσεις. Για τον λόγο αυτό, η πρόβλεψη του κινδύνου πυρκαγιάς αποτελεί ένα πεδίο όπου οι μέθοδοι μηχανικής μάθησης μπορούν να προσφέρουν χρήσιμα εργαλεία ανάλυσης και υποστήριξης αποφάσεων.

Μέσα από την εργασία αυτή μελέτησα τη δημιουργία και επεξεργασία χωροχρονικών δεδομένων, την εκπαίδευση διαφορετικών μοντέλων μηχανικής και βαθιάς μάθησης, καθώς και τη χρήση τεχνικών επεξηγησιμότητας και εκτίμησης αβεβαιότητας. Ιδιαίτερη έμφαση δόθηκε όχι μόνο στην αριθμητική απόδοση των μοντέλων, αλλά και στην ερμηνεία των προβλέψεων και στους περιορισμούς που εμφανίζονται όταν ένα μοντέλο μεταφέρεται σε διαφορετικό σύνολο δεδομένων.

Η εκπόνηση της εργασίας αποτελεί για μένα μια ουσιαστική διαδικασία εμβάθυνσης σε θέματα τεχνητής νοημοσύνης, περιβαλλοντικής μοντελοποίησης και αξιολόγησης προγνωστικών συστημάτων. Παράλληλα, ανέδειξε τη σημασία της προσεκτικής διαχείρισης των δεδομένων, της σωστής επιλογής μετρικών και της κριτικής ερμηνείας των αποτελεσμάτων.

Περίληψη

Η παρούσα διπλωματική εργασία εξετάζει τη διαχείριση των ανοικτών δεδομένων και την αξιοποίησή τους με τεχνικές μηχανικής μάθησης, βαθιάς μάθησης και τεχνητής νοημοσύνης. Βρέθηκαν μετεωρολογικά και περιβαλλοντικά δεδομένα για την Ελλάδα σε μορφή χωρικού πλέγματος, όπου κάθε κελί αντιστοιχεί σε μία μικρή περιοχή, δηλαδή σε ένα σημείο του χωρικού πλέγματος στον χάρτη. Τα δεδομένα αυτά αντιστοιχίστηκαν χωρικά και χρονικά με πυρκαγιές που συνέβησαν στα αντίστοιχα κελιά. Έτσι δημιουργήθηκε και επεξεργάστηκε ένα σύνολο δεδομένων που συνδυάζει καταγραφές πυρκαγιών, δορυφορικές ανιχνεύσεις ενεργών εστιών και μετεωρολογικές μεταβλητές, όπως θερμοκρασία, σημείο δρόσου, βροχόπτωση, άνεμος, Fire Weather Index και δείκτες ξηρασίας.

Με βάση αυτό το σύνολο, εκπαιδεύτηκαν και συγκρίθηκαν διαφορετικές οικογένειες μοντέλων, από tabular προσεγγίσεις μηχανικής μάθησης έως χωροχρονικά μοντέλα βαθιάς μάθησης, όπως U-Net, ConvLSTM, Vision Transformer, ConvNeXt-UNet και MiniRocket. Τα αποτελέσματα έδειξαν ότι τα μετεωρολογικά και ξηροθερμικά χαρακτηριστικά περιέχουν χρήσιμο προγνωστικό σήμα και μπορούν να υποστηρίξουν την παραγωγή χαρτών κινδύνου. Παράλληλα, εφαρμόστηκαν τεχνικές επεξηγησιμότητας, όπως SHAP, LIME, Integrated Gradients, Saliency και Grad-CAM, ώστε να εξεταστεί αν οι προβλέψεις βασίζονται σε φυσικά εύλογους παράγοντες.

Επιπλέον, μελετήθηκε η εκτίμηση αβεβαιότητας μέσω Monte Carlo Dropout και residual-cVAE, καθώς και η βαθμονόμηση των πιθανοτήτων για πιο αξιόπιστη ερμηνεία των χαρτών κινδύνου. Συνολικά, η εργασία δείχνει ότι η μηχανική μάθηση μπορεί να συμβάλει στην πρόβλεψη πυρκαγιών, υπό την προϋπόθεση ότι τα αποτελέσματα αξιολογούνται με κατάλληλες μετρικές, ερμηνεύονται προσεκτικά και συνοδεύονται από έλεγχο αβεβαιότητας και γενίκευσης.

« Explainable Artificial Intelligence for Wildfire Prediction Using Meteorological Data »

«Athina Papachristou»

Abstract

This thesis examines the management of open data and their use through machine learning, deep learning, and artificial intelligence techniques. Meteorological and environmental data for Greece were collected in grid format, where each cell corresponds to a specific area of Greece on the map. These data were then matched with wildfire events that occurred within the corresponding grid cells. In this way, a dataset was created and processed, combining wildfire records, satellite detections of active fire hotspots, and meteorological variables such as temperature, dew point, precipitation, wind, the Fire Weather Index, and drought indicators.

Based on this dataset, different families of models were trained and compared, ranging from tabular machine learning approaches to spatio-temporal deep learning models, such as U-Net, ConvLSTM, Vision Transformer, ConvNeXt-UNet, and MiniRocket. The results showed that meteorological and drought-related features contain useful predictive signals and can support the production of wildfire risk maps. At the same time, explainability techniques such as SHAP, LIME, Integrated Gradients, Saliency, and Grad-CAM were applied to examine whether the model predictions were based on physically meaningful factors.

In addition, uncertainty estimation was studied through Monte Carlo Dropout and residual-cVAE, along with probability calibration for a more reliable interpretation of the risk maps. Overall, this thesis demonstrates that machine learning can contribute to wildfire prediction, provided that the results are evaluated with appropriate metrics, interpreted carefully, and accompanied by uncertainty and generalization analysis.

Ευχαριστίες

Θα ήθελα να ευχαριστήσω θερμά τον επιβλέποντα καθηγητή μου για την καθοδήγηση, την υποστήριξη και τις ουσιαστικές παρατηρήσεις του καθ' όλη τη διάρκεια εκπόνησης της διπλωματικής εργασίας. Ευχαριστώ επίσης τον υποψήφιο διδάκτορα για τη συνεχή βοήθεια, τη διαθεσιμότητα και τη συμβολή του στην ολοκλήρωση της μελέτης.

Περιεχόμενα

Πρόλογος.....	iii
Περίληψη	iv
Abstract	v
Ευχαριστίες	vi
Περιεχόμενα	vii
Κατάλογος Σχημάτων.....	x
Κατάλογος Εικόνων.....	xi
Κατάλογος Πινάκων	xi
Συντομογραφίες	xiii
1 Εισαγωγή	1
1.1 Εκτελεστική σύνοψη.....	1
1.2 Πλαίσιο και διατύπωση του προβλήματος.....	1
1.3 Βιβλιογραφική θεμελίωση και ερευνητικό κενό.....	1
1.4 Δεδομένα, μεταβλητές και συνοπτική μεθοδολογία.....	2
2 Θεωρητικό υπόβαθρο και σχετική βιβλιογραφία.....	3
2.1 Επιστήμη των πυρκαγιών και πυρομετεωρολογικές σχέσεις	3
2.2 Μηχανική μάθηση για την πρόβλεψη πυρκαγιών	4
2.3 Αρχιτεκτονικές βαθιάς μάθησης.....	4
2.4 Επεξηγησιμότητα στην περιβαλλοντική μοντελοποίηση.....	5
2.5 Μεταφορά μάθησης και προσαρμογή πεδίου	6
2.6 Μετρικές αξιολόγησης και σύνολα αναφοράς	6
3 Δεδομένα, προεπεξεργασία και αναπαράσταση του προβλήματος	7
3.1 Εκτελεστική σύνοψη.....	7
3.2 Περιγραφή συνόλου δεδομένων	8
3.3 Πηγές δεδομένων και πρόσβαση.....	9
3.4 Βήματα προεπεξεργασίας	11
3.5 Πρωτογενείς μεταβλητές και μονάδες.....	14
3.6 Παράγωγα χαρακτηριστικά και τύποι	15
3.7 Ορισμός στόχου και διαδικασία επισημείωσης.....	17
3.8 Διαχωρισμοί και εξισορρόπηση	18
3.9 Αναπαραστάσεις, εναρμόνιση και διαχωρισμοί.....	18
3.9.1 Tabular αναπαράσταση για classical ML	18
3.9.2 Χωροχρονική αναπαράσταση για deep models	18

4	Βασικά μοντέλα σε μορφή πίνακα για την πρόβλεψη πυρκαγιών	19
4.1	Στόχοι και πειραματικό πλαίσιο.....	19
4.2	Πρωτόκολλο εκπαίδευσης και αξιολόγησης.....	20
4.3	Συγκριτικά αποτελέσματα και ερμηνεία	20
5	Χωροχρονικά μοντέλα βαθιάς μάθησης.....	22
5.1	Στόχος και ερευνητικό πλαίσιο	22
5.2	Χωροχρονική αναπαράσταση εισόδου και διατύπωση του προβλήματος.....	23
5.3	ConvLSTM2D ως χωροχρονικό baseline	24
5.4	Spatio-Temporal Vision Transformer	26
5.5	U-Net για πυκνή ημερήσια χαρτογράφηση κινδύνου	29
5.5.1	Εκτίμηση αβεβαιότητας και βαθμονόμηση του U-Net.....	30
5.5.2	Εξωτερική αξιολόγηση	34
5.5.3	Αξιολόγηση U-Net με zone-mask και σύγκριση με FWI baseline	35
5.5.4	Συμπεράσματα U-Net	37
5.6	ConvNeXt και υβριδικό ConvNeXt - Unet	38
5.7	MiniRocket και υβριδικό MiniRocket για χρονική κατάταξη κινδύνου	41
5.8	Συγκριτική αποτίμηση των αρχιτεκτονικών	42
6	Επεξηγησιμότητα, αβεβαιότητα και αξιοπιστία των προβλέψεων.....	44
6.1	Εισαγωγή στην επεξηγησιμότητα και την αξιοπιστία των προβλέψεων.....	44
6.2	Τεχνικές επεξηγησιμότητας που εφαρμόστηκαν	45
6.3	Καθολική σημασία χαρακτηριστικών στο κύριο σύνολο δεδομένων	45
6.4	Τοπικές εξηγήσεις σε επίπεδο κελιού και χρονικού παραθύρου	48
6.5	Χωρικές εξηγήσεις των βαθιών μοντέλων	51
6.6	Επεξηγησιμότητα στο FireCube και επίδραση του domain shift.....	55
6.7	Σύγκριση ερμηνευτικής συμπεριφοράς U-Net, ViT, ConvNeXt και ConvNeXt-UNet ...	60
6.8	Εκτίμηση αβεβαιότητας με Monte Carlo Dropout και residual-cVAE.....	62
6.9	Σχέση αβεβαιότητας, σφάλματος και selective prediction	64
6.10	Βαθμονόμηση πιθανοτήτων και decision-aware risk mapping	66
7	Εξωτερική αξιολόγηση και μεταφορά σε νέο domain.....	69
7.1	Περιγραφή του σεναρίου FireCube	69
7.2	Εναρμόνιση δεδομένων και προεπεξεργασία για μεταφορά.....	70
7.3	Fine-tuning και αξιολόγηση του U-Net στο FireCube	71
7.4	Fine-tuning του ConvNeXt-UNet στο FireCube	72
8	Συμπεράσματα και Μελλοντική Εργασία	74
8.1	Απαντήσεις στα ερευνητικά ερωτήματα	74
8.2	Βασικά επιστημονικά και πρακτικά ευρήματα	75
8.3	Περιορισμοί της εργασίας	76

8.4 Προτάσεις για μελλοντική έρευνα	78
ΒΙΒΛΙΟΓΡΑΦΙΑ.....	79

Κατάλογος Σχημάτων

Σχήμα 1.1 Στάδια εργασίας	3
Σχήμα 2.1 Διάγραμμα ροής του θεωρητικού πλαισίου	7
Σχήμα 3.1 Διάγραμμα επεξεργασίας δεδομένων	12
Σχήμα 5.1 Reliability diagram των πιθανοτικών εξόδων του U-Net. Η σύγκριση raw, temperature-scaled και isotonic προβλέψεων δείχνει τη βελτίωση της βαθμονόμησης μετά από post-hoc calibration.....	33
Σχήμα 5.2 Καμπύλες ROC για αξιολόγηση με zone-mask	36
Σχήμα 5.3 Καμπύλες Precision - Recall για την zone-mask αξιολόγηση του ConvNeXt.....	40
Σχήμα 5.4 Καμπύλες ROC για την zone-mask αξιολόγηση του ConvNeXt.....	40
Σχήμα 6.1 SHAP feature importance για το κύριο CSV μοντέλο	46
Σχήμα 6.2 Integrated Gradients feature importance για το κύριο CSV μοντέλο	47
Σχήμα 6.3 Συγκεντρωτική σύγκριση feature importance για το κύριο CSV μοντέλο	48
Σχήμα 6.4 Τοπική εξήγηση LIME για το κύριο CSV μοντέλο συγκεκριμένο κελί.....	50
Σχήμα 6.5 Integrated Gradients feature importance στο FireCube	56
Σχήμα 6.6 SHAP feature importance στο FireCube.....	57
Σχήμα 6.7 Saliency feature importance στο FireCube	58
Σχήμα 6.8 Τοπική εξήγηση LIME στο FireCube.	59
Σχήμα 6.9 Συγκεντρωτική σύγκριση Integrated Gradients, SHAP, Saliency και LIME στο FireCube ..	59
Σχήμα 6.10 Risk-coverage curve.....	65
Σχήμα 6.11 F1-coverage curve.....	65
Σχήμα 6.12 Reliability diagram για τις πιθανοτικές εξόδους του U-Net	67

Κατάλογος Εικόνων

Εικόνα 3.1 Σημεία του dataset.....	9
Εικόνα 5.1 Παράδειγμα πολυκαναλικής εισόδου και στόχου εκπαίδευσης για το Spatio-Temporal Vision Transformer.	27
Εικόνα 5.2 Παράδειγμα τύπου πυκνής πρόβλεψης του Spatio-Temporal ViT.	28
Εικόνα 5.3 Σχέση αβεβαιότητας και απόλυτου σφάλματος για το U-Net με Monte Carlo Dropout.	31
Εικόνα 5.4 Πιθανοκρατική έξοδος U-Net με Monte Carlo Dropout. Από αριστερά προς τα δεξιά παρουσιάζονται ο πραγματικός χάρτης πυρκαγιάς, ο μέσος χάρτης πιθανότητας και ο χάρτης αβεβαιότητας.	32
Εικόνα 5.5 Residual-cVAE επέκταση του U-Net. Το μοντέλο παράγει πολλαπλά πιθανά σενάρια κινδύνου, από τα οποία υπολογίζονται η μέση πιθανότητα και η χωρική αβεβαιότητα.	32
Εικόνα 5.6 Παράδειγμα πρόβλεψης του fine-tuned U-Net στο FireCube.....	34
Εικόνα 5.7 Zone-mask αξιολόγηση του U-Net στο CSV holdout target 2023-2025	36
Εικόνα 5.8 Zone-mask αξιολόγηση του U-Net στο FireCube target 2018-2021.	37
Εικόνα 6.1 Saliency feature importance για το κύριο CSV μοντέλο	47
Εικόνα 6.2 Τοπική ερμηνεία της πρόβλεψης του U-Net σε άξονα χρόνου και χαρακτηριστικών	49
Εικόνα 6.3 Τοπική ερμηνεία πρόβλεψης του Spatio-Temporal ViT σε άξονα χρόνου και χαρακτηριστικών	50
Εικόνα 6.4 Χωρική ερμηνεία με Integrated Gradients για το κύριο CSV-based U-Net.....	51
Εικόνα 6.5 Χωρικός χάρτης SHAP για το κύριο CSV-based U-Net	52
Εικόνα 6.6 Grad-CAM χάρτης για το U-Net.....	53
Εικόνα 6.7 Χωρικές εξηγήσεις U-Net και ViT με Integrated Gradients και Gradient $\times$ Input.....	54
Εικόνα 6.8 Σύγκριση πραγματικής εστίας και προβλεπόμενων πιθανοτήτων για ViT και U-Net	55
Εικόνα 6.9 Χωρική απόδοση Integrated Gradients στο FireCube.....	56
Εικόνα 6.10 Χωρική απόδοση SHAP στο FireCube	57
Εικόνα 6.11 Monte Carlo Dropout στο U-Net. Παρουσιάζει το πραγματικό fire map	62
Εικόνα 6.12 residual-cVAE πάνω στο U-Net.....	63
Εικόνα 6.13 Σχέση αβεβαιότητας και απόλυτου σφάλματος.	64
Εικόνα 6.14 Decision-aware χάρτης κινδύνου μετά από βαθμονόμηση και χρήση αβεβαιότητας.....	68

Κατάλογος Πινάκων

Πίνακας 1.1 Σύνοψη των βασικών συνόλων δεδομένων που χρησιμοποιήθηκαν στην εργασία.....	2
Πίνακας 2.1 Σύνοψη δομικών χαρακτηριστικών μοντέλων	4
Πίνακας 3.1 Ανάλυση Dataset	8
Πίνακας 3.2 Κύριες πηγές δεδομένων και τρόποι πρόσβασης.....	9
Πίνακας 3.3 Λίστα πρωτογενών μεταβλητών με τις μονάδες τους	14
Πίνακας 3.4 Παράγωγα χαρακτηριστικά και ερμηνεία	16
Πίνακας 3.5 Σύγκριση του κύριου dataset με το FireCube ως προς τον στόχο και τη χωρική μονάδα .	18
Πίνακας 3.6 Αναπαραστάσεις του ίδιου προβλήματος ανά οικογένεια μοντέλων	19
Πίνακας 4.1 Tabular μοντέλα	21

Πίνακας 5.1 Αποτελέσματα διάφορων εκδοχών U-Net	38
Πίνακας 5.2 Αποτελέσματα διάφορων εκδοχών ConvNext	39
Πίνακας 5.3 Αποτελέσματα MiniRocket.....	41
Πίνακας 5.4 Συλλογικά αποτελέσματα	43
Πίνακας 6.1 Συλλογική σύγκριση	61
Πίνακας 6.2 Σύγκριση μεθόδων βαθμονόμησης των πιθανοτικών εξόδων του U-Net στο validation set	67
Πίνακας 6.3 Ποσοστιαία κατανομή pixels στις τελικές decision-aware κατηγορίες κινδύνου.....	69
Πίνακας 7.1 Απόδοση του fine-tuned U-Net στο FireCube test set	72
Πίνακας 7.2 Απόδοση του ConvNeXt-UNet στο FireCube validation και test set.	73
Πίνακας 7.3 Σύγκριση fine-tuned U-Net και ConvNeXt-UNet στο FireCube test set.....	74

Συντομογραφίες

ML	Machine Learning
DL	Deep Learning
XAI	Explainable Artificial Intelligence
CNN	Convolutional Neural Network
RNN	Recurrent Neural Network
LSTM	Long Short-Term Memory
ConvLSTM	Convolutional Long Short-Term Memory
U-Net	Encoder-Decoder συνελκτική αρχιτεκτονική για πυκνή χωρική πρόβλεψη
ViT	Vision Transformer
MiniRocket	Time-series classification transform
MC Dropout	Monte Carlo Dropout
cVAE	Conditional Variational Autoencoder
residual-cVAE	Residual Conditional Variational Autoencoder
SHAP	SHapley Additive exPlanations
LIME	Local Interpretable Model-agnostic Explanations
Grad-CAM	Gradient-weighted Class Activation Mapping
IG	Integrated Gradients
FWI	Fire Weather Index
KBDI	Keetch-Byram Drought Index
SPEI	Standardized Precipitation Evapotranspiration Index
PET	Potential Evapotranspiration
D	Δείκτης υδατικού ισοζυγίου / Water Balance Deficit
t2m	Θερμοκρασία αέρα στα 2 μέτρα
d2m	Θερμοκρασία σημείου δρόσου στα 2 μέτρα
u10	Ανατολική/δυτική συνιστώσα ανέμου στα 10 μέτρα
v10	Βόρεια/νότια συνιστώσα ανέμου στα 10 μέτρα
tp	Συνολική βροχόπτωση
ERA5	ECMWF Reanalysis v5

ERA5-Land	Επανάλυση επιφανειακών μεταβλητών ξηράς του ERA5
ECMWF	European Centre for Medium-Range Weather Forecasts
CDS	Climate Data Store
EFFIS	European Forest Fire Information System
FIRMS	Fire Information for Resource Management System
MODIS	Moderate Resolution Imaging Spectroradiometer
VIIRS	Visible Infrared Imaging Radiometer Suite
FireCube	Ελληνικό ημερήσιο datacube για πρόβλεψη κινδύνου πυρκαγιάς
PR-AUC	Area Under the Precision-Recall Curve
ROC-AUC	Area Under the Receiver Operating Characteristic Curve
F1	Αρμονικός μέσος precision και recall
ECE	Expected Calibration Error
Brier	Brier Score
TP	True Positive
TN	True Negative
FP	False Positive
FN	False Negative
CSV	Comma-Separated Values
NetCDF	Network Common Data Form
API	Application Programming Interface
GPU	Graphics Processing Unit

1 Εισαγωγή

1.1 Εκτελεστική σύνοψη

Η εργασία αυτή επικεντρώνεται στην πρόβλεψη πυρκαγιών στην Ελλάδα, χρησιμοποιώντας ανοικτά δεδομένα και μετεωρολογικές μεταβλητές. Το πρόβλημα αυτό αντιμετωπίζεται ως ένα χωροχρονικό πρόβλημα εκτίμησης κινδύνου, όπου η ποιότητα της πιθανότητας, η δυνατότητα ερμηνείας και η συμπεριφορά του μοντέλου σε νέο πεδίο εφαρμογής έχουν ιδιαίτερη σημασία.

Σε μεθοδολογικό επίπεδο, η εργασία δεν περιορίζεται σε ένα μόνο είδος μοντέλου. Αντιθέτως, συγκρίνει κλασικά μοντέλα tabular μηχανικής μάθησης, βαθιά χωροχρονικά μοντέλα και τεχνικές χρονοσειρών, ενώ παράλληλα ενσωματώνει αναλύσεις επεξηγησιμότητας και ποσοτικοποίησης αβεβαιότητας.

1.2 Πλαίσιο και διατύπωση του προβλήματος

Οι δασικές πυρκαγιές είναι ένα πολύπλοκο πρόβλημα που επηρεάζεται από πολλούς παράγοντες, όπως τη διαθεσιμότητα καύσιμης ύλης, τις καιρικές συνθήκες και την ξηρότητα. Στη διεθνή βιβλιογραφία, υπάρχουν διάφοροι παράγοντες που συνδέονται με τον κίνδυνο πυρκαγιάς, όπως η θερμοκρασία, η υγρασία, η βροχόπτωση, ο άνεμος και η σωρευμένη ξηρότητα [10], [23], [29].

Τα μετεωρολογικά δεδομένα είναι πολύ χρήσιμα για την πρόβλεψη πυρκαγιάς, επειδή είναι διαθέσιμα πριν από την εκδήλωση του συμβάντος και μπορούν να οργανωθούν σε ροές δεδομένων. Υπάρχουν διάφορες υπηρεσίες ανοικτών δεδομένων που παρέχουν σχετικές πληροφορίες, όπως το EFFIS για την Ευρώπη, το ERA5 και το ERA5-Land για μακροχρόνια ανάλυση ατμοσφαιρικών και επιφανειακών μεταβλητών, και τα προϊόντα FIRMS για ενεργές ανιχνεύσεις πυρκαγιάς.

Το πρόβλημα εργασίας είναι να εκτιμηθεί η πιθανότητα εκδήλωσης πυρκαγιάς για συγκεκριμένη περιοχή και χρονική στιγμή, με βάση ακολουθίες ημερήσιων μετεωρολογικών και παράγωγων μεταβλητών. Στην κύρια U-Net διατύπωση, η χρονική στιγμή αυτή αντιστοιχεί στην τελευταία ημέρα του παραθύρου εισόδου, επομένως το πείραμα ερμηνεύεται ως same-day risk estimation. Τα πειράματα που αφορούν next-day spread ή persistence παρουσιάζονται χωριστά, επειδή έχουν διαφορετικό ορισμό στόχου. Αυτό το πρόβλημα έχει τρία χαρακτηριστικά:

- πρόκειται για πρόβλημα με ανισορροπία κλάσεων.
- είναι χωροχρονικό πρόβλημα, επειδή η πληροφορία δεν περιορίζεται στη μεμονωμένη τιμή μιας ημέρας αλλά στη διαδοχή συνθηκών και στη χωρική τους οργάνωση.
- η ζητούμενη έξοδος δεν είναι απλώς μια σωστή ετικέτα, αλλά μια πρόβλεψη που να μπορεί να υποστηρίξει ιεράρχηση κινδύνου, να ελεγχθεί ως προς την αξιοπιστία της και να εξηγηθεί με τρόπο συμβατό με το φυσικό υπόβαθρο του φαινομένου [6], [31].

1.3 Βιβλιογραφική θεμελίωση και ερευνητικό κενό

Η βιβλιογραφία της πρόβλεψης πυρκαγιών έχει εξελιχθεί από τους παραδοσιακούς πυρομετεωρολογικούς δείκτες και τα κλασικά στατιστικά υποδείγματα προς πιο σύνθετες προσεγγίσεις μηχανικής μάθησης και βαθιάς μάθησης. Τα tabular μοντέλα και ιδιαίτερα τα ensemble δέντρα

παραμένουν ισχυρές γραμμές βάσης όταν η πληροφορία έχει ήδη επιμεληθεί σε δομημένη μορφή [27], [13].

Η έρευνα έχει στραφεί σε αρχιτεκτονικές που μπορούν να αξιοποιήσουν ρητά τη χωρική και χρονική δομή των δεδομένων, όπως το ConvLSTM, το U-Net και το Vision Transformer. Παράλληλα, έχει ενισχυθεί και η ανάγκη για επεξηγησιμότητα, με προσεγγίσεις όπως το LIME, το SHAP και το Grad-CAM.

Ένα βασικό ζήτημα είναι η μεταφορά μάθησης και η προσαρμογή πεδίου, δηλαδή η ικανότητα ενός μοντέλου που εκπαιδεύτηκε σε ένα σύνολο δεδομένων ή σε μια περιοχή να διατηρεί χρήσιμη επίδοση σε διαφορετικό πεδίο εφαρμογής. Η αξιολόγηση μοντέλων δεν μπορεί να βασίζεται αποκλειστικά στην ακρίβεια, αλλά πρέπει να λαμβάνει υπόψη και άλλες μετρικές, όπως οι καμπύλες precision-recall και οι μετρικές που εστιάζουν στη σπάνια θετική κλάση [17], [14].

Το ερευνητικό κενό που επιχειρεί να καλύψει αυτή η εργασία δεν αφορά μία και μόνη τεχνική, αλλά τον συνδυασμό πολλών απαιτήσεων στο ίδιο ερευνητικό σχήμα.

1.4 Δεδομένα, μεταβλητές και συνοπτική μεθοδολογία

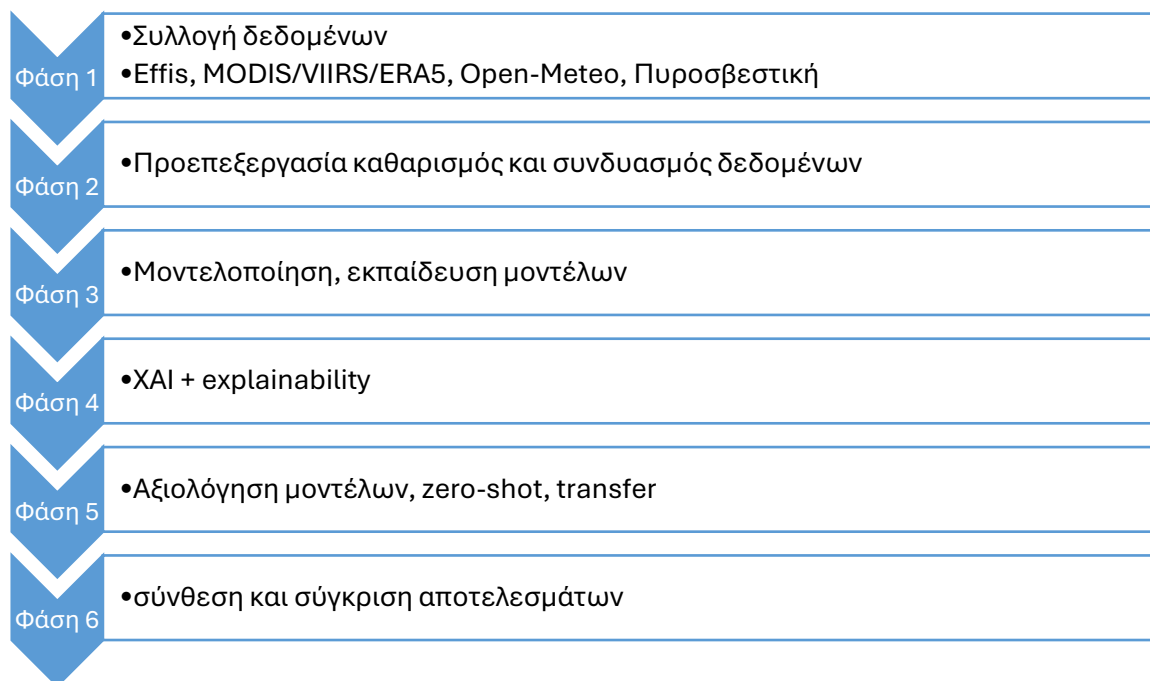
Η εμπειρική βάση της εργασίας είναι πολυπηγική. Τα ιστορικά γεγονότα πυρκαγιάς χρησιμοποιούνται για τη συγκρότηση των ετικετών, οι δορυφορικοί εντοπισμοί ενεργών εστιών για επιβεβαίωση και χωρική συμπλήρωση των συμβάντων, ενώ τα μετεωρολογικά πεδία και οι δείκτες ξηρασίας λειτουργούν ως προγνωστικές μεταβλητές.

Για τα χωροχρονικά μοντέλα χρησιμοποιήθηκαν παράθυρα 7 ημερών. Στο βασικό U-Net, ο στόχος αντιστοιχεί στην τελευταία ημέρα του ίδιου παραθύρου, επομένως η αξιολόγηση αφορά ημερήσια εκτίμηση κινδύνου πυρκαγιάς και όχι αυστηρή πρόγνωση επόμενης ημέρας. Αντίθετα, όπου χρησιμοποιείται `current_fire` ή ιστορικό φωτιάς για την πρόβλεψη της επόμενης κατάστασης, το πρόβλημα δηλώνεται χωριστά ως `next-day spread/persistence`.

Πίνακας 1.1 Σύνοψη των βασικών συνόλων δεδομένων που χρησιμοποιήθηκαν στην εργασία

Πηγή	Περίοδος κάλυψης	Χωρική ανάλυση /μορφή	Μεταβλητές ή ρόλος στη μελέτη
EFFIS + αρχεία Ελληνικής Πυροσβεστικής	2015 - 2025	συμβαντοκεντρικές εγγραφές / περίμετροι, εναρμονισμένες σε ημερήσιο πλέγμα $\sim 0,25^\circ$	ημερομηνία και θέση συμβάντος, ετικέτες fire / no-fire
NASA FIRMS MODIS	χρησιμοποιήθηκε για 2015-2025	1 km active-fire pixels	thermal anomalies, active fire detections
NASA FIRMS VIIRS	2015 - 2025	375 m active-fire pixels	ενεργές εστίες, πιο λεπτή χωρική ανίχνευση
ERA5	2015 - 2025	$0,25^\circ$ regular grid	t2m, d2m, tp, u10, v10 και βάση για παράγωγα features
Open-Meteo	ιστορικά δεδομένα έως το παρελθόν πολλών δεκαετιών, χρήση 2015 - 2025	$0,1^\circ$ ή $0,25^\circ$ ανά endpoint / ~ 9 km από νεότερα μοντέλα	συμπληρωματικά μετεωρολογικά πεδία και έλεγχος συνέπειας

Το ακόλουθο διάγραμμα συνοψίζει τα στάδια της ερευνητικής διαδικασίας, από τη συλλογή και εναρμόνιση των δεδομένων έως τη συγγραφή και σύνθεση των αποτελεσμάτων.



Σχήμα 1.1 Στάδια εργασίας

2 Θεωρητικό υπόβαθρο και σχετική βιβλιογραφία

2.1 Επιστήμη των πυρκαγιών και πυρομετεωρολογικές σχέσεις

Η πρόβλεψη πυρκαγιών βασίζεται σε μια συνδυασμένη προσέγγιση. Αυτή η προσέγγιση περιλαμβάνει την καύσιμη ύλη, τις συνθήκες ανάφλεξης και το ατμοσφαιρικό περιβάλλον. Οι επιστήμονες που μελετούν τις πυρκαγιές και τον καιρό, επισημαίνουν ότι η θερμοκρασία, η υγρασία, η βροχόπτωση και ο άνεμος είναι οι κύριοι παράγοντες που επηρεάζουν τον κίνδυνο πυρκαγιάς. Η σωρευμένη ξηρότητα παίζει επίσης σημαντικό ρόλο, επειδή μεταφέρει τη μνήμη προηγούμενων καιρικών συνθηκών στο παρόν επίπεδο επικινδυνότητας [1], [5], [23], [29].

Ο Καναδικός Δείκτης Καιρού Πυρκαγιάς (FWI) είναι ένα από τα πιο γνωστά πλαίσια που συνδυάζει αυτές τις μεταβλητές. Οι επιστήμονες έχουν δείξει ότι η αύξηση της διάρκειας και της έντασης ευνοϊκών συνθηκών για πυρκαγιές συνδέεται με την αύξηση του συνολικού κινδύνου πυρκαγιάς [10].

Η υποδομή των δεδομένων που στηρίζει τη σύγχρονη έρευνα βασίζεται στην ενοποίηση πολλών πηγών. Τα συστήματα EFFIS και FIRMS παρέχουν δεδομένα για δραστηριότητα πυρκαγιάς. Τα ERA5 και ERA5-Land δίνουν χωρικά και χρονικά συνεπή πεδία μετεωρολογικής επανάλυσης. Έτσι, η πρόβλεψη πυρκαγιάς δεν γίνεται πλέον με τη χρήση λίγων μεταβλητών, αλλά με την ολοκλήρωση ετερογενών πηγών που έχουν κοινή χωρική και χρονική αναφορά.

2.2 Μηχανική μάθηση για την πρόβλεψη πυρκαγιών

Η μηχανική μάθηση για την πρόβλεψη πυρκαγιών χωρίζεται σε δύο μεγάλες κατηγορίες. Η πρώτη κατηγορία αφορά τα κλασικά μοντέλα μηχανικής. Σε αυτή την περίπτωση, η χωρική μονάδα ανάλυσης είναι συνήθως ένα κελί, ένα πολύγωνο ή ένα σημείο, και οι μεταβλητές ορίζονται σε μορφή πίνακα. Παρά την εξάπλωση της βαθιάς μάθησης, αυτές οι προσεγγίσεις παραμένουν σημαντικές, επειδή προσφέρουν χαμηλότερο υπολογιστικό κόστος, ευκολότερη επιθεώρηση των χαρακτηριστικών και συχνά πολύ ισχυρή απόδοση.

Η δεύτερη κατηγορία μετακινείται προς πιο σύνθετες μορφές πρόβλεψης, όπου το ζητούμενο δεν είναι μόνο η επιδεκτικότητα μιας περιοχής, αλλά η ημερήσια μεταβολή του κινδύνου ή ακόμη και η πρόβλεψη εξάπλωσης. Σε αυτή την εκδοχή, οι μελέτες δεν εγκαταλείπουν αναγκαστικά τη λογική του πίνακα, αλλά δείχνουν ότι η ποιότητα της πρόβλεψης εξαρτάται όλο και περισσότερο από τη διατήρηση της χωρικής και χρονικής δομής των δεδομένων.

Υπάρχει επίσης μια κρίσιμη διάκριση ανάμεσα σε τρεις μορφές προβλήματος. Η πρώτη μορφή είναι η πρόβλεψη περιστατικού ή κινδύνου, όπου ζητείται πιθανότητα εκδήλωσης. Η δεύτερη μορφή είναι η πρόβλεψη της εξάπλωσης, όπου το ερώτημα αφορά τη χωρική εξέλιξη της φωτιάς μετά την έναυση. Η τρίτη μορφή είναι οι προσεγγίσεις ταξινόμησης ή ανίχνευσης, όπου το μοντέλο καλείται να αναγνωρίσει μοτίβα φωτιάς σε εικόνες. Αυτή η διάκριση είναι κρίσιμη, επειδή διαφορετικές αρχιτεκτονικές είναι καταλληλότερες για διαφορετικές μορφές στόχου.

2.3 Αρχιτεκτονικές βαθιάς μάθησης

Οι αρχιτεκτονικές βαθιάς μάθησης που σχετίζονται περισσότερο με το παρόν αντικείμενο μπορούν να ταξινομηθούν σε τέσσερις μεγάλες ομάδες. Η πρώτη είναι η οικογένεια encoder - decoder με πιο χαρακτηριστικό παράδειγμα το U-Net, το οποίο αναπτύχθηκε αρχικά για διαχωρισμό και παραμένει εξαιρετικά χρήσιμο όταν ζητείται πυκνή χωρική χαρτογράφηση εξόδου. Η δεύτερη είναι οι recurrent spatio-temporal αρχιτεκτονικές, με πιο κλασικό παράδειγμα το ConvLSTM, όπου η χρονική μνήμη συνδυάζεται με συνελκτικές μεταβάσεις ώστε να διατηρείται η δομή των χωρικών πεδίων. Η τρίτη είναι οι μηχανισμοί προσοχής σε επίπεδο χωρικών τμημάτων (patch-based attention μοντέλα), με θεμελιώδες παράδειγμα το Vision Transformer, το οποίο αντιμετωπίζει την εικόνα ως ακολουθία τοπικών tokens και ευνοεί την αποτύπωση μακρινών εξαρτήσεων. Η τέταρτη είναι η πιο μοντέρνα εκδοχή των ConvNet backbones, όπως η οικογένεια ConvNeXt/ConvNeXtV2, που επιχειρεί να διατηρήσει τα πλεονεκτήματα του συνελκτικού μοντέλου σε μια σχεδιαστική λογική μετασχηματισμένη από την transformer περίοδο [33], [35], [39], [32].

Πίνακας 2.1 Σύνοψη δομικών χαρακτηριστικών μοντέλων

Αρχιτεκτονική	Τύπος εισόδου	Χρονική μοντελοποίηση	Παραμετρική αποδοτικότητα	Συνήθη καθήκοντα	Πλεονεκτήματα	Περιορισμοί
UNet	Πολυκαναλικά χωρικά πλέγματα, στοίβα ημερών ως κανάλια	Όχι εκ γενετής, ο χρόνος συνήθως κωδικοποιείται στα κανάλια	Μέτρια	Risk mapping, segmentation-like πρόβλεψη, burned-area ή fire-mask εκτίμηση	Ισχυρή χωρική εντόπιση, συνεκτικές εξοδοί	Δεν διαθέτει φυσικό recurrent μηχανισμό, άρα η χρονική δομή εξαρτάται από την αναπαράσταση εισόδου

ConvLSTM	Ακολουθίες raster frames	Ναι, μέσω recurrent state	Μέτρια προς χαμηλή σε μεγάλες ακολουθίες	Nowcasting, hotspot prediction, sequence forecasting	Διατηρεί ταυτόχρονα χώρο και χρόνο, κατάλληλο για ημερήσιες ακολουθίες	Υψηλότερο sequential κόστος, λιγότερο φυσική αποτύπωση πολύ μακρινών εξαρτήσεων
ViT	Patchified raster ή image tokens	Μέσω self-attention και positional encoding	Συχνά χαμηλότερη data efficiency από CNNs	Image/raster classification, global context modeling	Καλή σύλληψη μακρινών χωρικών συσχετίσεων και global context	Μεγαλύτερες απαιτήσεις σε δεδομένα και κανονικοποίηση, ασθενέστερο τοπικό inductive bias
ConvNeXt	Εικόνες ή multichannel rasters	Όχι εκ γενετής, απαιτεί πρόσθετο temporal module σε sequence tasks	Καλή σε modern CNN deployment settings	Classification, detection, encoder backbone για hybrid σχήματα	Ισχυρός συνελκτικός prior, σταθερότητα, καλύτερη αξιοποίηση ως encoder	Δεν μοντελοποιεί από μόνο του ακολουθίες, θέλει επιπλέον σχεδιασμό για πλήρως χωροχρονικά καθήκοντα

Η παραπάνω σύγκριση συνοψίζει τα δομικά χαρακτηριστικά των αρχιτεκτονικών, όπως παρουσιάζονται στις πρωτογενείς εργασίες των αντίστοιχων οικογενειών και στη σχετική βιβλιογραφία για wildfire detection και transfer learning

2.4 Επεξηγησιμότητα στην περιβαλλοντική μοντελοποίηση

Στις εφαρμογές που αφορούν τις πυρκαγιές, η επεξηγησιμότητα δεν είναι απλά ένα βοηθητικό εργαλείο. Είναι απαραίτητη για να κατανοήσουμε αν το μοντέλο βασίζεται σε φυσικά εύλογους παράγοντες κινδύνου ή αν βασίζεται σε ασταθείς συσχετισμούς. Σε αυτό το πλαίσιο, το LIME αντιπροσωπεύει την τοπική, surrogate-based επεξηγησιμότητα, ενώ το Grad-CAM αντιπροσωπεύει την οπτική, gradient-based localization για συνελκτικά δίκτυα.

Από την πλευρά της εφαρμογής, η σχετική βιβλιογραφία δείχνει ότι η επεξηγησιμότητα είναι πλέον ένα τμήμα της ίδιας της μοντελοποίησης και όχι ένα πρόσθετο στοιχείο. Η ανάλυση αβεβαιότητας, παρότι δεν ταυτίζεται με την επεξηγησιμότητα, λειτουργεί συμπληρωματικά, επειδή μας επιτρέπει να διακρίνουμε όχι μόνο το πού το μοντέλο δίνει υψηλή πιθανότητα συμβάντος, αλλά και το πόσο σταθερή είναι αυτή η εκτίμηση. Στο πλαίσιο αυτό, το MC Dropout συνδέει τη βαθιά μάθηση με μια πρακτική προσέγγιση ποσοτικοποίησης της αβεβαιότητας [13], [19], [38].

Για τους σκοπούς της παρούσας εργασίας, οι εξηγήσεις πρέπει να διασταυρώνονται. Δηλαδή, οι τοπικές εξηγήσεις, οι χωρικοί χάρτες σημασίας και οι αναλύσεις αβεβαιότητας είναι πιο χρήσιμες όταν δεν ερμηνεύονται απομονωμένα, αλλά ως διαφορετικές όψεις του ίδιου συστήματος ερμηνείας. Με τον

τρόπο αυτό, η επεξηγησιμότητα υποστηρίζει τόσο την επιστημονική κατανόηση των μοντέλων όσο και την πρακτική εμπιστοσύνη στις επιχειρησιακές τους χρήσεις.

2.5 Μεταφορά μάθησης και προσαρμογή πεδίου

Η μεταφορά μάθησης αφορά την αξιοποίηση γνώσης που έχει αποκτήσει ένα μοντέλο σε ένα αρχικό σύνολο δεδομένων, ώστε να εφαρμοστεί σε ένα διαφορετικό αλλά σχετικό σύνολο. Στην πρόβλεψη πυρκαγιών, αυτό είναι ιδιαίτερα σημαντικό, επειδή τα διαθέσιμα σύνολα δεδομένων μπορεί να διαφέρουν ως προς τη χωρική ανάλυση, τις μεταβλητές εισόδου, τον τρόπο ορισμού της ετικέτας πυρκαγιάς και την αναλογία fire/no-fire περιπτώσεων [17], [16].

Το ζήτημα αυτό εξετάζεται μέσω της μεταφοράς ενός προεκπαιδευμένου U-Net στο ανεξάρτητο σύνολο FireCube. Η διαδικασία δεν περιορίστηκε στην απλή εφαρμογή των ήδη εκπαιδευμένων βαρών, αλλά απαιτούσε εναρμόνιση των χαρακτηριστικών, διόρθωση μονάδων, χωρική αναπροσαρμογή, ανακατασκευή παραγώγων μεταβλητών και επανακανονικοποίηση των εισόδων. Παρά τα βήματα αυτά, η αρχική zero-shot αξιολόγηση έδειξε χαμηλή απόδοση, γεγονός που ανέδειξε την ύπαρξη ουσιαστικής μετατόπισης μεταξύ των δύο πεδίων.


Για τον λόγο αυτό εφαρμόστηκε προσαρμογή πεδίου μέσω fine-tuning. Το μοντέλο επανεκπαιδεύτηκε σταδιακά στο FireCube, αρχικά με πάγωμα μέρους της αρχιτεκτονικής και στη συνέχεια με πλήρη αποδέσμευση των βαρών σε μικρότερο ρυθμό μάθησης. Η χρήση focal loss ήταν απαραίτητη λόγω της έντονης ανισορροπίας των κλάσεων [37].

2.6 Μετρικές αξιολόγησης και σύνολα αναφοράς

Η αξιολόγηση σε προβλήματα πυρκαγιάς απαιτεί μετρικές και πρωτόκολλα που να λαμβάνουν σοβαρά υπόψη τη σπανιότητα των θετικών συμβάντων. Σε τέτοια περιβάλλοντα, η απλή accuracy μπορεί να είναι παραπλανητική, επειδή ένα μοντέλο που προβλέπει σχεδόν παντού “μη πυρκαγιά” μπορεί να φαίνεται ισχυρό χωρίς να είναι χρήσιμο. Για τον λόγο αυτό, η βιβλιογραφία δίνει ιδιαίτερη έμφαση στις **precision - recall** μετρικές, στην **PR-AUC**, καθώς και στα εξαρτημένα από κατώφλι (threshold) μεγέθη precision, recall και F1 [31].

Η προβληματική της αξιολόγησης γίνεται ακόμη πιο απαιτητική όταν τα δεδομένα είναι χωρικά ή χωροχρονικά συσχετισμένα. Τα τυχαία splits μπορούν να υπερεκτιμήσουν τη γενίκευση όταν υπάρχει spatial ή temporal dependence, επειδή εκπαίδευση και test σύνολα παραμένουν υπερβολικά όμοια. Για αυτόν τον λόγο, σε περιβαλλοντικές εφαρμογές προτιμώνται spatial ή temporal blocking στρατηγικές, καθώς και εξωτερικά benchmarks που λειτουργούν ως πραγματικό τεστ μεταφοράς.

Από θεωρητική πλευρά, η σωστή αξιολόγηση δεν αφορά μόνο το αν ένα μοντέλο ταξινομεί καλά, αλλά το αν διατηρεί χρησιμότητα όταν αλλάζουν η γεωγραφία, η χρονική περίοδος, η πυκνότητα των θετικών παραδειγμάτων και η μορφή της εισόδου. Συνεπώς, οι μετρικές, τα splits και τα benchmarks δεν είναι απλές τεχνικές λεπτομέρειες, αλλά αναπόσπαστο μέρος του ίδιου του θεωρητικού πλαισίου της πρόβλεψης πυρκαγιών.



Σχήμα 2.1 Διάγραμμα ροής του θεωρητικού πλαισίου

3 Δεδομένα, προεπεξεργασία και αναπαράσταση του προβλήματος

3.1 Εκτελεστική σύνοψη

Το παρόν κεφάλαιο περιγράφει τη δημιουργία του συνόλου δεδομένων της εργασίας, από τις πηγές συλλογής, τον ορισμό του στόχου και τη διαδικασία επισημείωσης έως τη μηχανική χαρακτηριστικών, τη δημιουργία των αναπαραστάσεων εισόδου και τις στρατηγικές διαχωρισμού των συνόλων εκπαίδευσης και αξιολόγησης. Η βασική επιδίωξη ήταν η κατασκευή ενός ενοποιημένου συνόλου δεδομένων για την Ελλάδα, ικανού να στηρίζει τόσο κλασικά μοντέλα μηχανικής μάθησης σε μορφή πίνακα όσο και χωροχρονικές αρχιτεκτονικές βαθιάς μάθησης. Ως αποτέλεσμα, διαμορφώθηκε ένας ημερήσιος πίνακας πλέγματος για την περίοδο 2015 - 2025, με δυαδικό στόχο εμφάνισης πυρκαγιάς, καθώς και ισοδύναμες χωρικές/ακολουθιακές αναπαραστάσεις για μορφή πίνακα με ConvLSTM, U-Net και Vision Transformer.

Η μεθοδολογία οργανώθηκε γύρω από πέντε αρχές. Πρώτον, σύνθεση πολλών πηγών όπως δεδομένα πυρκαγιών από EFFIS και αρχεία της Ελληνικής Πυροσβεστικής Υπηρεσίας, θερμικές ανιχνεύσεις

από NASA MODIS/VIIRS και μετεωρολογικά πεδία από προϊόντα ERA5/ERA5-Land της ECMWF μέσω του Copernicus Climate Data Store και, συμπληρωματικά, μέσω του Open-Meteo. Δεύτερον, αυστηρή χρονική και χωρική εναρμόνιση σε κοινό ημερήσιο πλέγμα. Τρίτον, φυσικά ερμηνεύσιμη μηχανική χαρακτηριστικών με δείκτες όπως FWI, KBDI, SPEI, PET και όρους υδατικού ισοζυγίου. Τέταρτον, αναπαραστάσεις που χρησιμοποιούν αποκλειστικά επτάημερα παράθυρα χωρίς πληροφορία μεταγενέστερη της ημέρας-στόχου, ώστε να αποφεύγεται η χρονική διαρροή. Πέμπτον, ρεαλιστική αξιολόγηση με χωρικούς και χρονικούς διαχωρισμούς, επειδή τα τυχαία i.i.d. split τείνουν να υπερεκτιμούν τη γενίκευση σε χωρικά εξαρτημένα περιβαλλοντικά δεδομένα [16].

3.2 Περιγραφή συνόλου δεδομένων

Το βασικό σύνολο δεδομένων της εργασίας συγκροτήθηκε ως ένα ημερήσιο, πλεγματοποιημένο σύνολο για την Ελλάδα, με χρονική κάλυψη από το 2015 έως το 2025, ώστε να υποστηρίζει τόσο κλασικά μοντέλα μηχανικής μάθησης σε μορφή πίνακα όσο και βαθιά χωροχρονικά μοντέλα. Η σύνθεσή του βασίστηκε σε πέντε οικογένειες πηγών: ιστορικά συμβάντα πυρκαγιάς από το EFFIS, εθνικά αρχεία της Ελληνικής Πυροσβεστικής, ενεργές δορυφορικές ανιχνεύσεις από MODIS και VIIRS μέσω NASA FIRMS, μετεωρολογικά πεδία από ERA5 και ERA5-Land, καθώς και συμπληρωματική ανάκτηση ιστορικού καιρού μέσω Open-Meteo.

Το τελικό αρχείο `training_dataset_final_prepared.csv` καλύπτει το διάστημα 2015-01-02 έως 2025-08-22, περιλαμβάνει 108200 γραμμές, 3432 μοναδικές ημερομηνίες και 3402 μοναδικά κελιά (lat, lon). Από αυτές τις εγγραφές, 26835 έχουν `y_fire = 1` και 81365 έχουν `y_fire = 0`, το ποσοστό της θετικής κλάσης είναι 24,80% και της αρνητικής 75,20%.


Πίνακας 3.1 Ανάλυση Dataset

Πεδίο	Τιμή
Χρονικό εύρος	2015-01-02 έως 2025-08-22
Αριθμός γραμμών	108.200
Μοναδικές ημερομηνίες	3.432
Μοναδικά κελιά (lat, lon)	3.402
Θετικά <code>y_fire = 1</code>	26.835
Αρνητικά <code>y_fire = 0</code>	81.365
Θετικός λόγος	24,80%
Αρνητικός λόγος	75,20%

Η ετήσια κατανομή, όπως δίνεται στο υλικό, είναι η εξής: 2015, 11290 παρατηρήσεις και 2848 πυρκαγιές, 25.23%, 2016, 12600 και 3136, 24.89%, 2017, 11997 και 3065, 25.55%, 2018, 8885 και 2120, 23.86%, 2019, 10731 και 2785, 25.95%, 2020, 10591 και 2579, 24.35%, 2021, 10208 και 2479, 24.28%, 2022, 9694 και 2326, 23.99%, 2023, 10372 και 2696, 25.99%, 2024, 8658 και 2026, 23.40%, 2025, 3174 και 775, 24.42%. Για το 2025 διευκρινίζεται ρητά ότι η κάλυψη είναι μερική, έως 22 Αυγούστου 2025, επομένως οι απόλυτοι αριθμοί του τελευταίου έτους δεν είναι άμεσα συγκρίσιμοι με πλήρη ημερολογιακά έτη.

Σε επίπεδο χωρικής περίληψης, επειδή στο τελικό αρχείο δεν υπήρχε διοικητικός κωδικός Περιφέρειας, η αποτύπωση οργανώθηκε σε τέσσερις μακρο-περιοχές με διαχωρισμό ως προς τη διάμεσο των συντεταγμένων, (`lat_med = 39,4`) και (`lon_med = 24,2`). Οι τιμές που δίνονται είναι: Βόρεια-Ανατολική 22.370 παρατηρήσεις και 2.767 πυρκαγιές, 12,37%, Βόρεια-Δυτική 31.906 και 10.103, 31,66%, Νότια-Ανατολική 32.046 και 1334, 4,16%, Νότια-Δυτική 21878 και 12631, 57,73%. Η κατηγοριοποίηση αυτή δηλώνεται ρητά ως στατιστική και όχι διοικητική.

Το σύνολο δεδομένων όπως φαίνεται στην εικόνα 3.1 καλύπτει όλη την Ελλάδα. Τα πράσινα σημεία αντιστοιχούν στα χωρικά κελιά για τα οποία υπάρχουν διαθέσιμες εγγραφές.



Εικόνα 3.1 Σημεία του dataset

3.3 Πηγές δεδομένων και πρόσβαση

Η ενοποίηση των δεδομένων στηρίχθηκε σε πέντε κύριες οικογένειες πηγών: καταγραφές ιστορικών πυρκαγιών, ενεργές δορυφορικές ανιχνεύσεις, μετεωρολογικά πεδία επανάλυσης, παράγωγους δείκτες κινδύνου πυρκαγιάς και εξωτερικά δεδομένα μεταφοράς/επαλήθευσης. Η προσέγγιση αυτή είναι σύμφωνη με τη διεθνή βιβλιογραφία, όπου η πρόβλεψη πυρκαγιάς αντιμετωπίζεται ως πολυπαραγοντικό πρόβλημα που απαιτεί συνδυασμό συμβαντολογικής, δορυφορικής και ατμοσφαιρικής πληροφορίας [6], [20].

Πίνακας 3.2 Κύριες πηγές δεδομένων και τρόποι πρόσβασης

Πηγή	Φορέας/ Πλατφόρμα	Περιεχόμενο	Τρόπος πρόσβασης
EFFIS	Copernicus / European Commission	Burnt areas, active fires, annual statistics, fire danger layers	Web services, country totals, shapefile,

			SpatiaLite, data request
Αρχεία συμβάντων στην σελίδα της πυροσβεστικής	Ελληνική Πυροσβεστική Υπηρεσία	Συμβάντα και ιστορικά αρχεία	xls/xlsx open-data αρχεία
MODIS / VIIRS FIRMS	NASA FIRMS	Active fire / hotspot detections, confidence, FRP, acquisition date/time	SHP, KML, TXT, WMS, fire map
ERA5 / ERA5-Land	ECMWF / Copernicus CDS	2m temperature, dewpoint, precipitation, 10m winds, pressure κ.ά	CDS portal / API
Open-Meteo	Open-Meteo API	Historical weather API, ως πρακτικό layer πρόσβασης σε reanalysis/historical products	REST API

Το EFFIS υποστηρίζει τις υπηρεσίες προστασίας των δασών στην Ευρώπη και διαθέτει υπηρεσίες λήψης δεδομένων, συμπεριλαμβανομένων country totals σε xls, πραγματικού χρόνου burnt-area database σε shapefile/SpatiaLite και ξεχωριστής διαδικασίας data request για ιστορικά αποσπάσματα ή raw perimeters.

Η Ελληνική Πυροσβεστική διαθέτει ανοιχτά μηχαναγνώσιμα σύνολα δεδομένων συμβάντων σε xls/xlsx, με δημοσιευμένα τα έτη 2014-2023. Τα δεδομένα αυτά δεν ήταν αρχικά οργανωμένα σε πλεγματική μορφή, αλλά σε μορφή συμβάντων, δηλαδή ως καταγραφές με ημερομηνία, τοποθεσία και πληροφορίες για κάθε περιστατικό. Για να καταστούν συμβατά με τα μετεωρολογικά δεδομένα, κάθε συμβάν αντιστοιχίστηκε χωρικά στο πλησιέστερο κελί του πλέγματος και χρονικά στην αντίστοιχη ημερομηνία παρατήρησης. Με αυτόν τον τρόπο, οι σημειακές καταγραφές μετατράπηκαν σε δυαδικές ετικέτες fire/no-fire σε επίπεδο grid cell και ημέρας.

Στη συνέχεια, οι ετικέτες αυτές συνδυάστηκαν με τα μετεωρολογικά και περιβαλλοντικά χαρακτηριστικά του ίδιου κελιού και της ίδιας χρονικής περιόδου. Η διαδικασία αυτή επέτρεψε τη διασταύρωση των εθνικών αρχείων συμβάντων με τις ευρωπαϊκές και δορυφορικές πηγές, καθώς και τον καθαρισμό περιπτώσεων με ασαφή χωρική ή χρονική σήμανση.

Για τις ενεργές πυρκαγιές χρησιμοποιήθηκαν προϊόντα FIRMS. Η πλατφόρμα FIRMS διανέμει near-real-time ενεργές ανιχνεύσεις από MODIS (Aqua/Terra) και VIIRS (Suomi NPP, NOAA-20, NOAA-21), σε παγκόσμια κλίμακα εντός λίγων ωρών από την παρατήρηση, ενώ παρέχει τα δεδομένα σε SHP, KML, TXT και WMS. Στο επίπεδο μεταβλητών, τα active-fire products περιλαμβάνουν χωρική θέση, χρόνο λήψης, confidence και FRP για το MODIS η φωτεινή ανωμαλία αντιστοιχεί σε pixel περίπου 1 km, ενώ για το VIIRS I-band σε nominal 375 m, με καλύτερη απόκριση σε μικρότερες εστίες και καλύτερη νυχτερινή απόδοση [26], [15].

Για τη μετεωρολογία, η εργασία στηρίχθηκε κυρίως στα προϊόντα ERA5 και ERA5-Land. Το ERA5 είναι η πέμπτη γενιά παγκόσμιας ανάλυσης του ECMWF, διαθέσιμη από το 1940 και μετά, και συνδυάζει προγνωστικό μοντέλο με παρατηρήσεις μέσω data assimilation δημιουργώντας χωρικά και χρονικά συνεπές αρχείο. Το ERA5 παρέχει ωριαίες εκτιμήσεις για μεγάλο πλήθος ατμοσφαιρικών και επιφανειακών ποσοτήτων, ενώ το ERA5-Land διατίθεται ως ξεχωριστό σύνολο δεδομένων με δική του DOI και είναι ιδιαίτερα χρήσιμο για χερσαίες εφαρμογές υψηλότερης χωρικής λεπτομέρειας [25].


Το Open-Meteo δεν διαχειρίστηκε ως ανεξάρτητη επιστημονική πηγή, αλλά ως πρακτικό επίπεδο πρόσβασης και γρήγορης ανάκτησης ιστορικού καιρού. Η επίσημη τεκμηρίωση του Open-Meteo αναφέρει ότι, για αναλύσεις πολλών δεκαετιών, είναι προτιμητέα η επιλογή ERA5 ή ERA5-Land, με διαθέσιμα δεδομένα από το 1940 σε 0.1° ή 0.25° αναλύσεις, και διαθέτει ρητή επιστημονική παραπομπή λογισμικού μέσω Zenodo [2]. Τα δεδομένα του χρησιμοποιήθηκαν ως συμπληρωματικό επίπεδο ανάκτησης ιστορικών μετεωρολογικών πεδίων.

Για την αξιολόγηση της μεταφοράς σε εξωτερικά δεδομένα χρησιμοποιήθηκε το FireCube. Σύμφωνα με την επίσημη τεκμηρίωσή του στο Zenodo, πρόκειται για έναν ημερήσιο κύβο δεδομένων χωρικής ανάλυσης $1 \text{ km} \times 1 \text{ km}$, ο οποίος καλύπτει την Ελλάδα για τα έτη 2009 - 2021, και περιλαμβάνει μετεωρολογικά πεδία ERA5-Land, FWI, ignition points, burned areas, MODIS vegetation products, land surface temperature, Corine Land Cover fractions, EU-DEM, population density και άλλα στατικά/δυναμικά χαρακτηριστικά. Το ignition target του FireCube προκύπτει από τομή ενεργών MODIS fires με EFFIS burned areas, γεγονός που το καθιστά ιδιαίτερα κατάλληλο για αυστηρή εξωτερική αξιολόγηση και domain adaptation [6], [20].

3.4 Βήματα προεπεξεργασίας

Η προεπεξεργασία οργανώθηκε σε διαδοχικά στάδια, με στόχο οι ετερογενείς πηγές να εναρμονιστούν σε ένα κοινό ημερήσιο και χωρικό υπόβαθρο. Η ροή περιλάμβανε φόρτωση όλων των πηγών, τυποποίηση του συστήματος αναφοράς συντεταγμένων (CRS), των χρονικών σφραγίδων, των ονομάτων πεδίων και των μονάδων μέτρησης, καθώς και κατασκευή κοινού χωρικού πλέγματος για την Ελλάδα. Στη συνέχεια, τα δεδομένα EFFIS και τα εθνικά αρχεία της Πυροσβεστικής συγχωνεύθηκαν σε ενιαίο κατάλογο συμβάντων, ενώ τα MODIS/VIIIRS hotspots χρησιμοποιήθηκαν ως βοηθητική χωροχρονική ένδειξη για την υποστήριξη της επισημείωσης. Κάθε συμβάν αντιστοιχίστηκε σε ζεύγος (grid cell, day), ενώ τα μετεωρολογικά πεδία συγκεντρώθηκαν ανά χωρικό κελί και ημέρα. Ακολούθησαν μετατροπές μονάδων, παραγωγή παραγώγων χαρακτηριστικών, δημιουργία κυκλικών και κυλιόμενων χαρακτηριστικών, απομάκρυνση εγγραφών με κρίσιμες ελλείψεις και συμπλήρωση των υπόλοιπων αριθμητικών κενών αρχικά με βάση γειτονικές χωρικές ή χρονικές παρατηρήσεις. Τέλος, αποθηκεύτηκαν τα παραγόμενα artifacts και οι ορισμοί των train, validation και test διαχωρισμών. Οι θερμοκρασίες μετατράπηκαν από Kelvin σε Celsius μόνο όπου ήταν απαραίτητο για παράγωγους υπολογισμούς, ενώ η βροχόπτωση μετασχηματίστηκε σε ημερήσιο ισοδύναμο σε χιλιοστά.

Ο χειρισμός των ελλειπόν τιμών ακολουθεί επίσης μια σαφή λογική. Εγγραφές χωρίς κρίσιμα αναγνωριστικά ή χωρίς χωρική θέση αποκλείστηκαν. Για τις μεταβλητές συσσώρευσης, ειδικά τις SPEI_30, SPEI_90 και SPEI_180, τα κενά των πρώτων χρονικών βημάτων αντιμετωπίστηκαν ως αναμενόμενο warm-up period και είτε αφαιρέθηκαν πριν από τη δημιουργία ακολουθιών είτε συμπληρώθηκαν με στατιστικά ειδικά για κάθε split, ώστε να αποφεύγεται διαρροή πληροφορίας προς validation ή test.



Σχήμα 3.1 Διάγραμμα επεξεργασίας δεδομένων

Τέλος, η προεπεξεργασία μπορεί να αναπαραχθεί με τον ακόλουθο αλγόριθμο υψηλού επιπέδου.

Input:

EFFIS events, Fire Service records, MODIS/VIIRS hotspots,
ERA5/ERA5-Land/Open-Meteo meteorology, optional FireCube NetCDF

Output:

tabular dataset, grid tensors, sequence tensors

- 1: Load all sources
- 2: Standardize CRS, timestamps, field names, units
- 3: Build canonical daily grid over Greece
- 4: Merge EFFIS and Fire Service events into unified event catalogue
- 5: Use MODIS/VIIRS hotspots as auxiliary spatio-temporal support
- 6: Assign each event to (grid cell, day) and create binary target `y_fire`
- 7: Aggregate meteorological variables per (cell, day)
- 8: Convert units where needed:
 - temperatures K -> °C for derived formulas
 - precipitation -> daily mm-equivalent
- 9: Compute engineered features:
 - `wind_speed`, `temp_dew_diff`, `PET`, `D`, `KBDI`, `SPEI_30/90/180`
- 10: Compute cyclic seasonal features `sin_doy`, `cos_doy`
- 11: Compute 7-day rolling means/sums using only past and present data
- 12: Remove records with missing critical identifiers or labels
- 13: Impute remaining numeric missing values with training-split medians
- 14: If representation == tabular:
 - return one row per (cell, day)
- 15: If representation == sequence-grid:
 - bin coordinates to fixed H x W grid
 - create `X_t = frames[t-6:t]`, `Y_t = fire_map[t]`
- 16: If external dataset == FireCube:
 - spatially regrid to training grid
 - reconstruct `PET/KBDI/SPEI`
 - normalize with original training mean/std
- 17: Create i.i.d., spatial and temporal splits without leakage

3.5 Πρωτογενείς μεταβλητές και μονάδες

Τα βασικά πρωτογενή χαρακτηριστικά του τελικού συνόλου δεδομένων φαίνονται στον επόμενο πίνακα. Σημαντικό είναι ότι εδώ γίνεται διάκριση ανάμεσα στις μονάδες πηγής και στις μονάδες εργασίας. Για παράδειγμα, θερμοκρασίες ERA5/ERA5-Land διατίθενται σε Kelvin, αλλά σε παράγωγους δείκτες όπως PET και thermal dryness χρησιμοποιήθηκε μετατροπή σε °C. Αντίστοιχα, το συνολικό ύψος βροχόπτωσης στα reanalysis products παράγεται συχνά σε μέτρα νερού και μετασχηματίζεται σε ημερήσια mm-equivalent για τη μηχανική χαρακτηριστικών.

Πίνακας 3.3 Λίστα πρωτογενών μεταβλητών με τις μονάδες τους

Μεταβλητή	Μονάδα πηγής	Μονάδα μέτρησης	Περιγραφή	Προέλευση
(t2m)	K	K ή °C (όπου απαιτείται)	Θερμοκρασία αέρα στα 2 m	ERA5 / ERA5-Land / Open-Meteo
(d2m)	K	K ή °C (όπου απαιτείται)	Θερμοκρασία σημείου δρόσου στα 2 m	ERA5 / ERA5-Land / Open-Meteo
(tp)	m ή daily accumulation	mm/day-equivalent	Συνολική ημερήσια βροχόπτωση	ERA5 / ERA5-Land / Open-Meteo
(u10)	m/s	m/s	Ζωνική συνιστώσα ανέμου στα 10 m	ERA5 / ERA5-Land / Open-Meteo
(v10)	m/s	m/s	Μεσημβρινή συνιστώσα ανέμου στα 10 m	ERA5 / ERA5-Land / Open-Meteo
(fwi)	unitless	unitless	Fire Weather Index	Copernicus CEMS / EFFIS
(lat), (lon)	degrees	degrees	Συντεταγμένες κελιού/ centroid	Canonical grid
date	Διάφορες πηγές με διάφορες ζώνες ώρας	Ημερομηνία GMT+3		Όλες

Ο Fire Weather Index αποτελεί καθιερωμένο, μετεωρολογικά βασισμένο δείκτη κινδύνου πυρκαγιάς, ο οποίος συνοψίζει τις επιδράσεις θερμοκρασίας, υγρασίας, ανέμου και βροχόπτωσης στη συμπεριφορά καύσιμης ύλης. Η ιστορική ευρωπαϊκή έκδοσή του στο Copernicus υπολογίζεται από ERA5 forcing για

το EFFIS/CEMS, ενώ παραμένει διεθνώς ίσως ο πιο διαδεδομένος μετεωρολογικός δείκτης κινδύνου πυρκαγιάς [1].

3.6 Παράγωγα χαρακτηριστικά και τύποι

Η πρώτη ομάδα παραγώγων χαρακτηριστικών αφορούσε άμεσες φυσικές μετασχηματίσεις των μετεωρολογικών πεδίων:

$$ws_t = \sqrt{u10_t^2 + v10_t^2} \quad (3.1)$$

$$\Delta T_{dew,t} = T_{2m,t} - D_{2m,t} \quad (3.2)$$

όπου (ws_t) είναι η ταχύτητα ανέμου και ($\Delta T_{dew,t}$) η διαφορά θερμοκρασίας - σημείου δρόσου, η οποία λειτουργεί ως δείκτης ατμοσφαιρικής ξηρότητας: όσο υψηλότερη, τόσο χαμηλότερη η σχετική υγρασία του αέρα. Αυτοί οι δύο μετασχηματισμοί χρησιμοποιήθηκαν συστηματικά σε όλα τα πειράματα, επειδή διατηρούν άμεση φυσική ερμηνεία και ταυτόχρονα βελτιώνουν την ικανότητα των μοντέλων να διακρίνουν wind-driven και drought-driven συνθήκες.

Η δεύτερη ομάδα χαρακτηριστικών αφορούσε εξατμισοδιαπνοή, υδατικό ισοζύγιο και ξηρασία. Θεωρητικά, το reference evapotranspiration (ET_0) ορίζεται συνήθως με το σχήμα FAO Penman - Monteith [12]. Στην παρούσα εργασία, όμως, για λόγους επιχειρησιακής απλότητας και διαθεσιμότητας μεταβλητών, χρησιμοποιήθηκε προσέγγιση μόνο βάσει θερμοκρασίας (temperature-only approach):

$$PET_t \approx 0.4 \cdot \max(T_t, 0) \quad (3.3)$$

με (T_t) σε °C. Η προσέγγιση αυτή δεν υποκαθιστά φυσικά το πλήρες Penman - Monteith, αλλά λειτουργεί ως σταθερή, αναπαραγωγίμη προσέγγιση evaporative demand μέσα στη ροή μηχανικής χαρακτηριστικών.

Στη συνέχεια ορίστηκε ο όρος υδατικού ισοζυγίου:

$$D_t = P_t - PET_t \quad (3.4)$$

όπου (P_t) είναι η βροχόπτωση στην κατάλληλη ημερήσια μονάδα εργασίας. Οι αρνητικές τιμές ερμηνεύονται ως έλλειμμα υγρασίας. Στην πράξη, ο όρος (D) χρησιμοποιήθηκε είτε απευθείας είτε σε κανονικοποιημένη μορφή, ανάλογα με τη ροή επεξεργασίας και την οικογένεια μοντέλων.

Για την αναπαράσταση της ξηρασίας χρησιμοποιήθηκαν τρεις SPEI-like μεταβλητές, δηλαδή $SPEI_{30}$, $SPEI_{90}$ και $SPEI_{180}$. Ο επίσημος SPEI προτάθηκε από τους Vicente-Serrano, Beguería και López-Moreno [30] ως δείκτης ξηρασίας βασισμένος στο υδατικό ισοζύγιο $P - PET$, ώστε να ενσωματώνει τόσο τη διαθέσιμη υγρασία όσο και την ατμοσφαιρική ζήτηση. Στην παρούσα εργασία, οι μεταβλητές αυτές δεν χρησιμοποιούνται ως επίσημο προϊόν SPEI, αλλά ως προσεγγιστικά χαρακτηριστικά ξηρότητας εμπνευσμένα από τη λογική του SPEI. Υπολογίστηκαν από το $P - PET$ σε κυλιόμενα χρονικά παράθυρα 30, 90 και 180 ημερών.

Για τον KBDI χρησιμοποιήθηκε μία απλοποιημένη μορφή σύμφωνα με τη λογική Keetch - Byram, αντί για πλήρη υλοποίηση [11]. Σε ημέρες με ουσιαστική βροχή εφαρμόστηκε απομείωση του δείκτη, ενώ σε ξηρές/θερμές ημέρες αυξητική αναδρομή με upper bound:

$$KBDI_t = \max(0, KBDI_{t-1} - 0.5(P_t - 5)) \text{ με συνθήκη } P_t > 5.$$

$$\Delta KBDI_t = 0.1 \cdot \max(T_t, 0) \quad (3.5)$$

$$KBDI_t = \min(800, KBDI_{t-1} + \Delta KBDI_t) \text{ με συνθήκη } P_t \leq 5.$$

Η κανονική σύλληψη του KBDI είναι να μετρά το έλλειμμα υγρασίας εδάφους/duff σε κλίμακα 0 - 800, δηλαδή από πλήρη κορεσμό έως ακραία ξηρασία. Στην παρούσα εργασία ενδιαφέρει κυρίως η μονοτονική, θερμο-υετική συμπεριφορά του feature και όχι η αυστηρά επιχειρησιακή αντιστοίχιση με δασοπυροσβεστικές κλάσεις.

Η τρίτη ομάδα περιλάμβανε χρονική μηχανική χαρακτηριστικών. Η εποχικότητα κωδικοποιήθηκε κυκλικά:

$$\text{Sin}_{doy,t} = \sin\left(\frac{2\pi \cdot doy_t}{365}\right) \quad (3.6)$$

$$\text{Cos}_{doy,t} = \cos\left(\frac{2\pi \cdot doy_t}{365}\right) \quad (3.7)$$

ώστε να διατηρείται η περιοδικότητα του ετήσιου κύκλου χωρίς τεχνητές ασυνέχειες στο πέρασμα Δεκεμβρίου - Ιανουαρίου. Παράλληλα, για επιλεγμένα πεδία υπολογίστηκαν 7ήμερα rolling averages ή rolling sums, με τυπική μορφή:

$$\bar{x}_t^{(7)} = \frac{1}{7} \sum_{i=0}^6 x_{t-i} \quad (3.8)$$

Αντίστοιχα, για μεταβλητές όπως η βροχύπτωση υπολογίστηκαν κυλιόμενα αθροίσματα. Αυτό είναι κρίσιμο, επειδή η ανάφλεξη δεν εξαρτάται μόνο από την κατάσταση του καιρού σε μία συγκεκριμένη ημέρα, αλλά και από τη συσσώρευση θερμών, ξηρών και ανεμωδών συνθηκών στο προηγούμενο χρονικό διάστημα.

Πίνακας 3.4 Παράγωγα χαρακτηριστικά και ερμηνεία

Feature	Μονάδα	Τύπος/ιδέα	Ρόλος στην πρόβλεψη
wind_speed	m/s	$(\sqrt{u10^2 + v10^2})$	Δυναμικό εξάπλωσης
temp_dew_diff	K ή °C diff	(t2m-d2m)	Ατμοσφαιρική ξηρότητα
PET	mm/day approx.	$(0.4 \cdot \max(T, 0))$	εξατμισοδιαπνοή
D	water-balance term	(P-PET)	Έλλειμμα/πλεόνασμα υγρασίας
KBDI	unitless or KBDI scale	bounded recurrence	Συσσωρευτική ξηρασία καυσίμων
SPEI_30	unitless	SPEI σε 30 ημέρες	Βραχυπρόθεσμη ξηρασία

SPEI_90	unitless	SPEI σε 90 ημέρες	Εποχική ξηρασία
SPEI_180	unitless	SPEI σε 180 ημέρες	Μεσοπρόθεσμη υδρολογική ξηρασία

3.7 Ορισμός στόχου και διαδικασία επισημείωσης

Το πρόβλημα ορίστηκε ως δυαδική πρόβλεψη εμφάνισης πυρκαγιάς σε επίπεδο κελιού και ημέρας. Για κάθε κελί (g) και κάθε ημέρα (t), ο στόχος γράφεται ως:

$$y_{g,t} = \begin{cases} 1, & \text{if a fire is assigned to cell } g \text{ on day } t \\ 0, & \text{otherwise} \end{cases} \quad (3.9)$$

Ο κατάλογος συμβάντων προέκυψε από τον συνδυασμό ιστορικών καταγραφών EFFIS και εθνικών αρχείων της Πυροσβεστικής, ενώ οι ανιχνεύσεις MODIS/VIIRS αξιοποιήθηκαν ως βοηθητική, χωροχρονική ένδειξη παρουσίας και έντασης θερμικού συμβάντος. Σκοπός αυτής της σύνθεσης δεν ήταν να αντικαταστήσει την επίσημη καταγραφή συμβάντος με το δορυφορικό hotspot, αλλά να βελτιώσει τη χωρική και χρονική ερμηνεία των συμβάντων σε περιπτώσεις αβεβαιότητας ή μη πλήρους συμβατότητας μεταξύ πηγών.

Σε λειτουργικό επίπεδο, η επισημείωση ακολούθησε τέσσερα βασικά βήματα:

- Κάθε καταγραφή φωτιάς μετασχηματίστηκε σε κοινή χωρική αναφορά και ημερήσια χρονική σφραγίδα.
- Στη συνέχεια, έγινε αντιστοίχιση σε κελί πλέγματος με βάση χωρική τομή ή με χρήση του πλησιέστερου κελιού.
- Πολλαπλές εγγραφές της ίδιας ημέρας και του ίδιου κελιού συγχωνεύθηκαν σε μία θετική ετικέτα.
- Οι ημέρες και τα κελιά χωρίς επαληθευμένο συμβάν επισημάνθηκαν ως αρνητικά, ενώ η τελική δυαδική μεταβλητή στόχου ονομάστηκε y_{fire} στο σύνολο δεδομένων σε μορφή πίνακα.

Για τα χωροχρονικά μοντέλα χρησιμοποιήθηκαν παράθυρα εισόδου 7 ημερών. Στο βασικό U-Net, το παράθυρο εισόδου καταλήγει στην ημέρα-στόχο και η έξοδος αντιστοιχεί στην ίδια ημέρα. Δηλαδή, αν το παράθυρο συμβολιστεί ως $[t - 6, \dots, t]$, τότε ο στόχος είναι y_t και όχι y_{t+1} . Επομένως, το συγκεκριμένο πείραμα ερμηνεύεται ως ημερήσια εκτίμηση κινδύνου πυρκαγιάς ή same-day wildfire risk estimation και όχι ως αυστηρό next-day forecasting. Η διάκριση αυτή είναι σημαντική, επειδή οι μετεωρολογικές μεταβλητές της ημέρας-στόχου μπορούν να περιέχονται στο παράθυρο εισόδου.

Το FireCube χρησιμοποιήθηκε συμπληρωματικά ως εξωτερικό πεδίο αξιολόγησης. Η χρήση του είχε διερευνητικό χαρακτήρα, επειδή διαφέρει ουσιαστικά από το βασικό. Το αρχικό σύνολο δεδομένων είναι εμπλουτισμένο ως προς τα συμβάντα πυρκαγιάς και οργανώνεται σε ημερήσιες εγγραφές ανά χωρικό κελί, με χωρική ανάλυση περίπου $0,25^\circ$. Αντίθετα, το FireCube αποτελεί έναν πυκνό ημερήσιο raster κύβο δεδομένων ανάλυσης $1 \text{ km} \times 1 \text{ km}$, διαφοροποιείται ως προς τον ορισμό της μεταβλητής-στόχου και χαρακτηρίζεται από πολύ πιο αραιή θετική κλάση. Για τον λόγο αυτό, εφαρμόστηκαν βήματα εναρμόνισης, τα οποία θα αναφερθούν στα επόμενα κεφάλαια. Παρ' όλα αυτά, η αξιολόγηση στο FireCube ερμηνεύεται κυρίως ως έλεγχος domain shift και όχι ως πλήρως ισοδύναμη σύγκριση.

Σε ορισμένα πειράματα με χωρικούς χάρτες φωτιάς χρησιμοποιήθηκε επίσης γειτονική επισημείωση μικρής ακτίνας, ώστε να απορροφηθεί η αβεβαιότητα γεωεντοπισμού του ignition pixel. Η επιλογή αυτή είναι εύλογη όταν ο στόχος είναι η χωρική εκτίμηση κινδύνου και όχι η αυστηρά σημειακή ανίχνευση ενός μοναδικού pixel ανάφλεξης.

Πίνακας 3.5 Σύγκριση του κύριου dataset με το FireCube ως προς τον στόχο και τη χωρική μονάδα

Άξονας σύγκρισης	Κύριο dataset της εργασίας	FireCube
Χρονική κάλυψη	2015 - 2025	2009 - 2021
Χωρική μονάδα	Grid cell / day	1 km × 1 km pixel / day
Κύριος στόχος	y_fire	ignition_points
Ρόλος στην εργασία	Primary training/evaluation corpus	External transfer / domain adaptation corpus
Θετικότητα κλάσης	Μέτρια, event-enriched	Ακραία χαμηλή

3.8 Διαχωρισμοί και εξισορρόπηση

Η αξιολόγηση οργανώθηκε γύρω από τρεις στρατηγικές διαχωρισμού. Το i.i.d. random split χρησιμοποιήθηκε ως αρχικό, αισιόδοξο baseline. Το spatial split ήταν το βασικό πρωτόκολλο, με σχήματα Βορράς - Νότος, Ανατολή - Δύση, τεταρτημόρια και grouping με k-means πάνω στα (lat, lon), ώστε το test set να αντιστοιχεί σε γεωγραφικές περιοχές που δεν έχουν χρησιμοποιηθεί στην εκπαίδευση. Τέλος, το temporal split χρησιμοποιήθηκε ως συμπληρωματική μορφή out-of-time ελέγχου. Η επιλογή blocked και spatial στρατηγικών είναι συμβατή με τη βιβλιογραφία για δεδομένα με χωρική και χρονική δομή [45].

Η αντιμετώπιση της ανισορροπίας διαφοροποιήθηκε ανά αναπαράσταση. Στο κύριο σύνολο δεδομένων το βάρος δόθηκε σε threshold tuning και στις μετρικές precision, recall, F1 και PR-AUC. Στα deep raster πειράματα και ειδικά στο FireCube, όπου όπου το ποσοστό θετικών pixels ήταν περίπου 0,056%, χρησιμοποιήθηκε focal loss και validation-based thresholds αντί το σταθερό κατώφλι (threshold) 0,5. Η επιλογή αυτή έγινε επειδή η επιχειρησιακή βελτιστοποίηση της σπάνιας θετικής κλάσης θεωρήθηκε σημαντικότερη από μια συμμετρική απόφαση.

3.9 Αναπαραστάσεις, εναρμόνιση και διαχωρισμοί

3.9.1 Tabular αναπαράσταση για classical ML

Η tabular αναπαράσταση ακολούθησε τον κανόνα μία εγγραφή ανά κελί και ημέρα. Έτσι, κάθε γραμμή των δεδομένων εισόδου περιλάμβανε: ημερομηνία, χωρικές συντεταγμένες (lat, lon), πρωτογενείς μετεωρολογικές μεταβλητές, δείκτες ξηρασίας/υδατικού ισοζυγίου, ενδεχόμενα rolling/seasonal features και τον στόχο y_fire. Αυτή η μορφή ήταν κατάλληλη για Logistic Regression, Random Forest, XGBoost, LightGBM και MLP, δηλαδή για όλα τα tabular baselines της εργασίας.

3.9.2 Χωροχρονική αναπαράσταση για deep models

Για τα χωροχρονικά μοντέλα, οι συνεχείς συντεταγμένες χαρτογραφήθηκαν σε σταθερό χωρικό πλέγμα. Στα ConvLSTM πειράματα της εργασίας, η canonical χωρική διάταξη είχε διαστάσεις $H = 27$ και $W = 34$, ενώ κάθε ημερήσιο frame αναπαρίσταται ως tensor με πολλαπλά κανάλια $H \times W \times C$.

Στη βασική διατύπωση του προβλήματος, για την εκτίμηση κινδύνου την ημέρα t , η είσοδος προκύπτει από 7ήμερο παράθυρο που καταλήγει στην ίδια ημέρα:

$$X_t = \{frame_{t-6}, frame_{t-5}, \dots, frame_t\} \quad (3.10)$$

Επομένως, για τα sequence-based μοντέλα η γενική είσοδος γράφεται ως:

$$X \in \mathbb{R}^{N \times 7 \times H \times W \times C} \quad (3.11)$$

και ο στόχος ως:

$$Y \in \{0,1\}^{N \times H \times W \times 1} \quad (3.12)$$

όπου το Y αντιστοιχεί στον χάρτη πυρκαγιάς της ημέρας t . Συνεπώς, για το βασικό U-Net και τις αντίστοιχες αναπαραστάσεις, το πρόβλημα ερμηνεύεται ως ημερήσια εκτίμηση κινδύνου πυρκαγιάς, δηλαδή same-day wildfire risk estimation, και όχι ως αυστηρό next-day forecasting. Η διάκριση αυτή είναι σημαντική, επειδή το παράθυρο εισόδου μπορεί να περιλαμβάνει μετεωρολογικές μεταβλητές της ίδιας ημέρας με τον στόχο.

Η δομή αυτή υποστηρίζει ConvLSTM και sequence-ViT αρχιτεκτονικές. Για U-Net-style μοντέλα, το ίδιο 7ήμερο παράθυρο μπορεί να καταρρεύσει κατά μήκος του channel axis σε tensor:

$$X \in \mathbb{R}^{N \times H \times W \times (7C)} \quad (3.13)$$

Με αυτόν τον τρόπο διατηρείται η ίδια πληροφορία, αλλά αλλάζει ο τρόπος με τον οποίο την καταναλώνει το δίκτυο. Αντί να επεξεργάζεται ρητά τη χρονική διάσταση ως sequence, το U-Net λαμβάνει τις ημέρες του παραθύρου ως διακριτά κανάλια εισόδου.

Πίνακας 3.6 Αναπαραστάσεις του ίδιου προβλήματος ανά οικογένεια μοντέλων

Αναπαράσταση	Μονάδα δείγματος	Σχήμα	Ενδεικτικά μοντέλα
Tabular	cell-day row	$(N \times p)$	LR, RF, XGBoost, LightGBM, MLP
Sequence-grid	7-day cube	$(N \times 7 \times H \times W \times C)$	ConvLSTM, sequence-ViT
Collapsed-temporal grid	stacked 7-day channels ending at day t	$(N \times H \times W \times (7C))$	UNet, U-Net + residual-cVAE

4 Βασικά μοντέλα σε μορφή πίνακα για την πρόβλεψη πυρκαγιών

4.1 Στόχοι και πειραματικό πλαίσιο

Το παρόν κεφάλαιο θεμελιώνει το πειραματικό σημείο αναφοράς της εργασίας μέσω κλασικών και σύγχρονων μοντέλων μηχανικής μάθησης σε tabular μορφή. Ο ρόλος τους δεν είναι δευτερεύων σε προβλήματα πρόβλεψης πυρκαγιών. Τα tabular baselines παραμένουν ιδιαίτερα ισχυρά, επειδή οι σημαντικότερες πληροφορίες προέρχονται συχνά από μετεωρολογικές, ξηροθερμικές και γεωχωρικές μεταβλητές που μπορούν να κωδικοποιηθούν αποτελεσματικά σε δομημένες στήλες. Η σχετική βιβλιογραφία δείχνει σταθερά ότι τα ensemble δένδρα και ιδίως οι boosting μέθοδοι αποτελούν πολύ ανταγωνιστικές προσεγγίσεις για wildfire susceptibility και fire occurrence prediction, συχνά ανώτερες από απλά γραμμικά μοντέλα και συχνά δυσκολότερες να ξεπεραστούν ακόμη και από πιο σύνθετες νευρωνικές αρχιτεκτονικές, όταν τα δεδομένα είναι καθαρά και καλά εναρμονισμένα.

Το κεφάλαιο εξετάζει εάν ένα σύνολο μετεωρολογικών και παράγωγων ξηροθερμικών δεικτών αρκεί, από μόνο του, για αξιόπιστη πρόβλεψη του δυαδικού στόχου fire/non-fire. Παράλληλα, απομονώνει την επίδραση του πρωτοκόλλου αξιολόγησης, συγκρίνοντας i.i.d. split και spatial split. Με αυτόν τον τρόπο

διαμορφώνεται ένα ισχυρό, επεξηγήσιμο και υπολογιστικά ελαφρύ tabular baseline, βασισμένο στο σύνολο δεδομένων που αναλύθηκε στο Κεφάλαιο 3.

4.2 Πρωτόκολλο εκπαίδευσης και αξιολόγησης

Η εκπαίδευση των μοντέλων ακολούθησε μια τυπική αλληλουχία. Ξεκίνησε με τον καθαρισμό και την εναρμόνιση των δεδομένων. Μετά, ακολούθησε η μηχανική χαρακτηριστικών. Τα δεδομένα χωρίστηκαν σε τμήματα για εκπαίδευση, επικύρωση και δοκιμή. Έγινε βελτιστοποίηση των υπερπαραμέτρων και επιλογή του κατωφλίου για την ταξινόμηση. Τέλος, πραγματοποιήθηκε η τελική αξιολόγηση.

Στα πειράματα, εξετάστηκαν δύο βασικά σενάρια:

- Τυχαίος διαχωρισμός: χρησιμοποιήθηκε ως σημείο αναφοράς.
- Χωρικός διαχωρισμός: σε αυτό το σενάριο, το σύνολο δοκιμής αντιστοιχούσε σε περιοχές που δεν είχαν παρατηρηθεί προηγουμένως.

Η επιλογή των υπερπαραμέτρων έγινε με ένα ανεξάρτητο σύνολο επικύρωσης. Οι τελικές ρυθμίσεις για κάθε μοντέλο και τα κατώφλια για την ταξινόμηση επιλέχθηκαν με βάση την επίδοσή τους στο σύνολο επικύρωσης. Αυτό έγινε πριν από την αξιολόγηση στο τελικό σύνολο δοκιμής. Αυτή η διαδικασία εξασφάλισε ότι η αξιολόγηση έγινε σε δεδομένα που δεν είχαν χρησιμοποιηθεί κατά τη φάση της βελτιστοποίησης.

Για την αξιολόγηση των μοντέλων χρησιμοποιήθηκαν οι μετρικές accuracy, precision, recall και F1-score, ενώ όπου ήταν εφικτό υπολογίστηκε και ο δείκτης ROC-AUC. Επειδή η πρόβλεψη πυρκαγιών χαρακτηρίζεται από έντονη ανισορροπία κλάσεων, δόθηκε ιδιαίτερη έμφαση στο recall και στο F1-score. Η επιλογή αυτή συνδέεται με το γεγονός ότι, σε επιχειρησιακό επίπεδο, η αποτυχία εντοπισμού μιας πραγματικής πυρκαγιάς είναι συνήθως πιο κρίσιμη από την παραγωγή μιας ψευδούς ειδοποίησης [31].

Τέλος, τα tabular μοντέλα επιλέχθηκαν ως αρχικές γραμμές αναφοράς λόγω της χαμηλής υπολογιστικής τους πολυπλοκότητας και της δυνατότητας γρήγορης εκπαίδευσης. Αυτά τα μοντέλα είναι ιδιαίτερα χρήσιμα για την αξιολόγηση και τη διερεύνηση των παραγόντων που σχετίζονται με τον κίνδυνο πυρκαγιάς.

4.3 Συγκριτικά αποτελέσματα και ερμηνεία

Στον Πίνακα 4.1 παρουσιάζονται οι επιδόσεις ενός συνόλου βασικών αλγορίθμων μηχανικής μάθησης που εφαρμόστηκαν στο πρόβλημα της πρόβλεψης πυρκαγιών. Συγκεκριμένα, συμπεριλαμβάνονται: Logistic Regression (γραμμικό baseline), Random Forest (σύνολο δέντρων απόφασης), XGBoost (gradient boosting), LightGBM (gradient boosting με histogram-based διαίρεση), MLP (πολυστρωματικό νευρωνικό δίκτυο) και Ensemble LightGBM + TabNet (συνδυαστικό μοντέλο). Για κάθε μοντέλο παρατίθενται οι μετρικές Accuracy, Precision, Recall και F1-score, υπολογισμένες στο σετ ελέγχου. Όπως έχει επισημανθεί στη βιβλιογραφία για αντίστοιχες εργασίες πρόβλεψης πυρκαγιών, τα παραπάνω μοντέλα καλύπτουν τις κύριες κατηγορίες (γραμμικά, δέντρα αποφάσεων, νευρωνικά δίκτυα) που έχουν μελετηθεί ευρέως για αυτήν την εφαρμογή. Η τελευταία στήλη του πίνακα παρουσιάζει σύντομα σχόλια για τη χωρική γενίκευση (spatial generalization) του κάθε μοντέλου στις δοκιμαζόμενες ρυθμίσεις.

Πίνακας 4.1 Tabular μοντέλα

Μοντέλο	Accuracy	Precision	Recall	F1-score	Σχόλια χωρικής γενίκευσης
Logistic Regression	0.5223	0.7079	0.5509	0.6196	Απλό γραμμικό baseline. Χαμηλή απόδοση λόγω γραμμικής υπόθεσης, με αδυναμία σύλληψης πολύπλοκων χωρικών σχέσεων.
Random Forest	0.6699	0.7071	0.9091	0.7955	Ισχυρό μη-γραμμικό σύνολο δέντρων. Πολύ υψηλό Recall (0.91) - εντοπίζει σχεδόν όλες τις πυρκαγιές. Υψηλό F1, αλλά πιθανά υπερπροσαρμοσμένο και δύσκολη γενίκευση σε νέες χωρικές περιοχές.
XGBoost	0.5496	0.7035	0.6262	0.6626	Gradient boosting baseline. Μέτρια επίδοση επηρεάζεται από ανισορροπία κλάσεων, υπολειπόμενο τόσο σε Precision όσο και σε Recall σε σχέση με RF και LGBM στο βασικό σενάριο.
LightGBM (αρχικό)	0.6004	0.7062	0.7436	0.7244	Σταθερό boosting μοντέλο (baseline A2). Καλύτερη απόδοση από XGBoost στην αρχική διαμόρφωση, αλλά κάτω του Random Forest στο ανισόρροπο σενάριο.
MLP (Neural Network)	0.5223	0.6910	0.5855	0.6339	Πολυστρωματικό νευρωνικό δίκτυο. Χαμηλή απόδοση σε σύγκριση με τα μοντέλα δέντρων. Συχνά τα MLP υπολειτουργούν σε tabular δεδομένα χωρίς εκτενή ρύθμιση υπερπαραμέτρων.
LightGBM (χωρικό baseline)	0.9200	0.9300	0.9400	0.9400	Σενάριο C1 (χωρικό baseline). Σημαντική βελτίωση (Accuracy=0.92). Διατηρεί υψηλή επίδοση σε χωρικό διαχωρισμό, ένδειξη καλύτερης γεωγραφικής γενίκευσης.
LightGBM (χωρικό, βελτιστοποιημένο)	0.9700	0.9700	0.9800	0.9700	Σενάριο C2 (χωρικό, tuned). Τελική λύση: πολύ υψηλή ακρίβεια/ανάκληση, με ελάχιστα ψευδώς αρνητικά/θετικά (threshold=0.30) - ισχυρή χωρική γενίκευση.

Ensemble (LightGBM+TabNet)	0.9700	0.9700	0.9800	0.9700	Σενάριο C3. Συνδυασμός LightGBM και TabNet στο βέλτιστο βάρος ($w=1.0$) συμπίπτει με καθαρό LightGBM. Δεν βελτιώνει περαιτέρω - το LightGBM υπερέχει μόνο του.
-------------------------------	--------	--------	--------	--------	--

Όπως φαίνεται από τον Πίνακα 4.1, το Logistic Regression λειτουργεί μόνο ως απλό baseline, με σχετικά χαμηλές επιδόσεις (Accuracy ≈ 0.52 , $F1 \approx 0.62$), επιβεβαιώνοντας ότι το γραμμικό μοντέλο αδυνατεί να αποδώσει σε πολύπλοκα, μη γραμμικά προβλήματα (όπως έχει ήδη διαπιστωθεί σε παρόμοιες μελέτες πρόβλεψης πυρκαγιών). Αντίθετα, τα μη γραμμικά δέντρα αποφάσεων (Random Forest, XGBoost, LightGBM) παρουσιάζουν σαφώς καλύτερες επιδόσεις: το Random Forest επιτυγχάνει πολύ υψηλό Recall (0.9091) και $F1=0.7955$, δείχνοντας ικανότητα να εντοπίζει σχεδόν όλα τα συμβάντα πυρκαγιάς. Ωστόσο, το πολυδαιδαλικό του σχήμα καθιστά πιθανή την υπερπροσαρμογή και μειώνει τη χωρική γενίκευση. Το XGBoost εμφανίζει μέτρια επίδοση (Accuracy ≈ 0.55 , $F1 \approx 0.66$), πιθανώς λόγω της ανισορροπίας των κλάσεων, ενώ το αρχικό LightGBM βελτιώνει ελαφρώς τις επιδόσεις (Accuracy ≈ 0.60 , $F1 \approx 0.72$). Συνολικά, τα μοντέλα gradient boosting έχουν αποδειχθεί ιδιαίτερα αποτελεσματικά στην πρόβλεψη πυρκαγιών, αν και στο βασικό σενάριο (A-series) τα αποτελέσματά τους παραμένουν συγκρίσιμα ή ελαφρώς υποδεέστερα του Random Forest. Τέλος, το MLP (παραδοσιακό MLP) παρουσιάζει τις χαμηλότερες επιδόσεις μεταξύ των δοκιμασμένων ($F1 \approx 0.63$), γεγονός που συμφωνεί με παρατηρήσεις ότι τα συμβατικά νευρωνικά δίκτυα δυσκολεύονται με πολύπλοκα structured δεδομένα χωρίς εκτενή ρύθμιση.

Το LightGBM χρησιμοποιήθηκε ως βασικό tabular μοντέλο αναφοράς και αξιολογήθηκε σε διαφορετικά σενάρια χωρικού διαχωρισμού και ρύθμισης κατωφλίου. Στο χωρικό baseline (C1), το μοντέλο πέτυχε Accuracy 0.92 και F1-score 0.94, γεγονός που δείχνει ότι οι μετεωρολογικές και παράγωγες μεταβλητές περιέχουν ισχυρό προγνωστικό σήμα ακόμη και σε γεωγραφικά διαχωρισμένη αξιολόγηση.

Με τη βελτιστοποίηση του κατωφλίου ταξινόμησης (C2), η απόδοση βελτιώθηκε περαιτέρω, φτάνοντας Accuracy 0.97 και F1-score 0.97. Το αποτέλεσμα αυτό υποδηλώνει ότι η επιλογή κατάλληλου threshold είναι κρίσιμη σε προβλήματα ανισόρροπων κλάσεων, καθώς επηρεάζει άμεσα την ισορροπία μεταξύ ψευδώς θετικών και ψευδώς αρνητικών προβλέψεων.

Το συνδυαστικό μοντέλο LightGBM+TabNet (C3) δεν παρέχει περαιτέρω βελτίωση (οι μετρικές είναι ταυτόσημες με το βελτιστοποιημένο LightGBM για $w=1.0$), επιβεβαιώνοντας ότι στο παρόν πρόβλημα το LightGBM προσφέρει ήδη την κορυφαία απόδοση. Τα παραπάνω αποτελέσματα υποδηλώνουν ότι η κατάλληλη αξιοποίηση χωρικών σχέσεων και η προσεκτική ρύθμιση του μοντέλου οδηγούν σε σημαντική ενίσχυση της επίδοσης σε επίπεδο πρόβλεψης πυρκαγιών.

5 Χωροχρονικά μοντέλα βαθιάς μάθησης

5.1 Στόχος και ερευνητικό πλαίσιο

Το κεφάλαιο αυτό αποτελεί τον κεντρικό πυρήνα της μοντελοποίησης, όπου η εκτίμηση κινδύνου πυρκαγιάς αντιμετωπίζεται ως χωροχρονικό πρόβλημα. Τα δεδομένα εισόδου είναι ημερήσια πλέγματα μετεωρολογικών και υδρολογικών μεταβλητών, όπως θερμοκρασία, σημείο δρόσου, άνεμος και

βροχόπτωση, καθώς και παράγωγων δεικτών επικινδυνότητας, όπως Fire Weather Index, Keetch-Byram Drought Index, SPEI και PET. Τα δεδομένα αυτά προέρχονται από προϊόντα επανάλυσης, όπως ERA5/ERA5-Land και από πρόσθετες πηγές ή υπολογισμένους δείκτες που περιγράφηκαν στο Κεφάλαιο 3.

Η στόχευση fire/non-fire βασίζεται σε καταγραφές πυρκαγιών και ενεργών εστιών, οι οποίες αντιστοιχίστηκαν σε χωρικά κελιά και ημερομηνίες. Στο βασικό U-Net και στα αντίστοιχα χωροχρονικά πειράματα, η έξοδος αντιστοιχεί στην ημέρα-στόχο του 7ήμερου παραθύρου εισόδου. Επομένως, τα αποτελέσματα αυτής της διατύπωσης ερμηνεύονται ως ημερήσια εκτίμηση κινδύνου πυρκαγιάς, δηλαδή same-day wildfire risk estimation, και όχι ως αυστηρή πρόγνωση επόμενης ημέρας.

Η διάκριση αυτή είναι σημαντική, επειδή το 7ήμερο παράθυρο μπορεί να περιλαμβάνει μετεωρολογική πληροφορία της ίδιας ημέρας με τον στόχο. Αντίθετα, τα πειράματα που χρησιμοποιούν μεταβλητές όπως current_fire, fire neighbours ή fire history έχουν διαφορετικό ορισμό προβλήματος και σχετίζονται περισσότερο με next-day fire spread ή persistence prediction. Για τον λόγο αυτό, τα αποτελέσματα των διαφορετικών αρχιτεκτονικών ερμηνεύονται σε σχέση με τον αντίστοιχο ορισμό στόχου και δεν αντιμετωπίζονται όλα ως ισοδύναμα επιχειρησιακά forecasting σενάρια.

Λόγω της ανισορροπίας των κλάσεων, χρησιμοποιήθηκαν τεχνικές όπως focal loss, ενώ η αξιολόγηση δίνει ιδιαίτερη έμφαση σε precision-recall μετρικές. Σε τέτοια προβλήματα, το PR-AUC είναι συχνά πιο ενδεικτικό από το ROC-AUC, επειδή αποτυπώνει καλύτερα την ικανότητα ανίχνευσης της σπάνιας θετικής κλάσης.

5.2 Χωροχρονική αναπαράσταση εισόδου και διατύπωση του προβλήματος

Η βασική πληροφορία για τα χωροχρονικά μοντέλα δεν αντιμετωπίζεται ως απλός πίνακας εγγραφών, αλλά ως ακολουθία ημερήσιων γεωχωρικών πεδίων. Για κάθε ημέρα, οι μετεωρολογικές και παράγωγες μεταβλητές μετατρέπονται σε ένα κανονικοποιημένο πλέγμα που καλύπτει την ελληνική επικράτεια. Κάθε κελί του πλέγματος αντιστοιχεί σε συγκεκριμένη χωρική περιοχή και περιέχει τις τιμές των διαθέσιμων χαρακτηριστικών για τη συγκεκριμένη ημερομηνία.

Τα μοντέλα εκπαιδεύτηκαν πάνω στο ενοποιημένο σύνολο χαρακτηριστικών που περιγράφηκε στο Κεφάλαιο 3. Το σύνολο αυτό περιλαμβάνει βασικές μετεωρολογικές μεταβλητές, όπως θερμοκρασία, σημείο δρόσου, βροχόπτωση και άνεμο, καθώς και παράγωγους δείκτες πυρομετεωρολογικού και ξηροθερμικού κινδύνου όπως αναφέρεται στο Κεφάλαιο 3. Η είσοδος των μοντέλων αποτυπώνει τόσο τις άμεσες ημερήσιες συνθήκες όσο και τις βραχυπρόθεσμες ή μακροπρόθεσμες περιβαλλοντικές τάσεις.

Για να κωδικοποιηθεί η χρονική εξέλιξη πριν από την πυρκαγιά, χρησιμοποιήθηκαν κυλιόμενα παράθυρα επτά ημερών. Στη βασική διατύπωση του U-Net, κάθε δείγμα εισόδου αντιστοιχεί σε ακολουθία επτά διαδοχικών ημερήσιων grids που καταλήγει στην ημέρα-στόχο. Αν το παράθυρο συμβολιστεί ως $[t - 6, \dots, t]$, τότε η έξοδος είναι ο χάρτης πυρκαγιάς της ημέρας t και όχι της ημέρας $t + 1$. Επομένως, η συγκεκριμένη διατύπωση αντιστοιχεί σε same-day wildfire risk estimation.

Η ίδια βασική πληροφορία αναπαρίσταται διαφορετικά ανάλογα με την αρχιτεκτονική. Στο ConvLSTM2D, κάθε ημέρα αποτελεί ένα χωρικό frame και το μοντέλο λαμβάνει ακολουθία επτά τέτοιων frames, διατηρώντας τη χρονική διάσταση ως ξεχωριστή δομή. Αντίθετα, στα U-Net-style μοντέλα, το ίδιο 7ήμερο παράθυρο μπορεί να καταρρεύσει στον άξονα των καναλιών, ώστε η είσοδος

να έχει μορφή πολυκαναλικού grid. Σε αυτή την περίπτωση, το μοντέλο δεν διαθέτει ρητό recurrent μηχανισμό, αλλά αξιοποιεί τη χρονική πληροφορία ως διαφορετικά κανάλια εισόδου.

Η διατύπωση του στόχου είναι δυαδική σε επίπεδο pixel ή grid cell. Για κάθε κελί και κάθε ημέρα, η ετικέτα παίρνει τιμή 1 όταν υπάρχει καταγεγραμμένη πυρκαγιά ή ενεργή εστία και 0 όταν δεν υπάρχει. Επομένως, το ζητούμενο είναι η εκτίμηση μιας πιθανότητας $p(y_{\text{fire}}=1|X)$, όπου το X αντιστοιχεί στο επτάήμερο χωροχρονικό παράθυρο εισόδου.

Το πρόβλημα της ανισορροπίας των κλάσεων είναι ένα βασικό πρόβλημα της αναπαράστασης. Τα περισσότερα χωρικά κελιά στις περισσότερες ημέρες δεν περιέχουν πυρκαγιά, άρα η θετική κλάση είναι σπάνια. Αυτό σημαίνει ότι η απλή ακρίβεια μπορεί να γίνει παραπλανητική, επειδή ένα μοντέλο που προβλέπει σχεδόν πάντα no-fire μπορεί να εμφανίζει υψηλή συνολική ακρίβεια χωρίς να έχει πραγματική ικανότητα ανίχνευσης πυρκαγιών.

Συνολικά η διατύπωση του προβλήματος στην εργασία οργανώνεται σε τρία επίπεδα:

- Κάθε ημέρα μετατρέπεται σε πολυκαναλικό γεωχωρικό grid.
- Επτά διαδοχικές ημέρες ενώνονται σε χωροχρονικό παράθυρο.
- Το μοντέλο παράγει είτε pixel-level χάρτη πιθανότητας είτε κατάταξη κινδύνου.

Αυτή η αναπαράσταση επέτρεψε τη συγκριτική αξιολόγηση διαφορετικών οικογενειών μοντέλων.

5.3 ConvLSTM2D ως χωροχρονικό baseline

Ο ConvLSTM2D χρησιμοποιήθηκε στην εργασία ως το βασικό χωροχρονικό σημείο αναφοράς, επειδή αποτελεί μια αρχιτεκτονική που σχεδιάστηκε ακριβώς για δεδομένα που μεταβάλλονται ταυτόχρονα στον χώρο και στον χρόνο. Σε αντίθεση με ένα απλό LSTM, το οποίο δέχεται συνήθως μονοδιάστατες ακολουθίες χαρακτηριστικών, ο ConvLSTM διατηρεί τη χωρική μορφή της εισόδου σε κάθε χρονικό βήμα. Η βασική ιδέα είναι ότι οι μεταβάσεις εισόδου-κατάστασης και κατάστασης-κατάστασης δεν γίνονται με πλήρως συνδεδεμένα επίπεδα, αλλά με συνελίξεις [33]. Έτσι, το μοντέλο δεν βλέπει την κάθε ημέρα ως έναν απλό πίνακα αριθμών, αλλά ως χάρτη με γειτονικές περιοχές, χωρικές συσχετίσεις και τοπικά μοτίβα.

Αυτή η ιδιότητα είναι ιδιαίτερα σημαντική διότι η πυρκαγιά δεν εξαρτάται μόνο από την τιμή μιας μεταβλητής σε ένα μεμονωμένο κελί. Εξαρτάται από τη συνύπαρξη και την εξέλιξη πολλών παραγόντων σε γειτονικές περιοχές. Μια περίοδος υψηλής θερμοκρασίας, χαμηλού σημείου δρόσου, αυξημένης δυνητικής εξατμισοδιαπνοής και υψηλού FWI μπορεί να δημιουργήσει σταδιακά ευνοϊκές συνθήκες ανάφλεξης. Για τον λόγο αυτό, το ConvLSTM2D είναι κατάλληλο ως πρώτο βαθύ χωροχρονικό μοντέλο: μπορεί να παρακολουθεί πώς μεταβάλλεται το ίδιο γεωγραφικό πλέγμα μέσα σε διαδοχικές ημέρες και να μαθαίνει αν η εξέλιξη αυτή οδηγεί σε αυξημένη πιθανότητα πυρκαγιάς.

Στην υλοποίηση της εργασίας, κάθε δείγμα εισόδου οργανώθηκε ως ακολουθία επτά ημερήσιων γεωχωρικών πλαισίων. Το σχήμα εισόδου ήταν της μορφής $7 \times H \times W \times C$, όπου οι επτά ημέρες αντιστοιχούν στο χρονικό παράθυρο, τα H και W στις χωρικές διαστάσεις του πλέγματος, και το C στα χαρακτηριστικά εισόδου, όπως $t2m$, $d2m$, tp , $u10$, $v10$, FWI , $KBDI$, PET , D και $SPEI$. Το μοντέλο προβλέπει έναν δυαδικό χάρτη εμφάνισης πυρκαγιάς για την τελευταία ημέρα της ακολουθίας, δηλαδή μετατρέπει την προηγούμενη μετεωρολογική ιστορία σε χωρικό χάρτη κινδύνου.

Η αρχιτεκτονική που χρησιμοποιήθηκε ήταν σχετικά καθαρή και λειτουργική. Το πρώτο επίπεδο ConvLSTM2D είχε 32 φίλτρα, πυρήνα 3×3 , ίδια συμπλήρωση και `return_sequences=True`, ώστε να διατηρείται ολόκληρη η χρονική ακολουθία και να εξάγονται χωρικά μοτίβα σε κάθε ημέρα.

Ακολούθησε κανονικοποίηση παρτίδας (batch normalization), η οποία σταθεροποίησε την εκπαίδευση. Το δεύτερο επίπεδο ConvLSTM2D, επίσης με 32 φίλτρα και πυρήνα 3×3 , χρησιμοποίησε `return_sequences=False`, ώστε να συμπυκνώσει την πληροφορία των επτά ημερών στην τελική χρονική κατάσταση. Στη συνέχεια, ένα Conv2D επίπεδο με ενεργοποίηση ReLU βελτίωσε τα χωρικά χαρακτηριστικά που είχαν μάθει τα recurrent-convolutional επίπεδα, ενώ το τελικό Conv2D επίπεδο με 1×1 πυρήνα και σιγμοειδή ενεργοποίηση παρήγαγε τον τελικό χάρτη πιθανότητας πυρκαγιάς.

Από αρχιτεκτονική άποψη, το σημαντικό πλεονέκτημα του ConvLSTM2D είναι ότι διαβάζει το φαινόμενο σαν μια μικρή «ταινία» επτά ημερών. Δεν αποφασίζει μόνο από το σημερινό στιγμιότυπο, αλλά από τη διαδοχή των συνθηκών. Αυτό έχει φυσική σημασία για τις πυρκαγιές, επειδή οι πιο κρίσιμες καταστάσεις συχνά δημιουργούνται από συσσώρευση: λίγες συνεχόμενες ημέρες χωρίς βροχή, σταδιακή αύξηση θερμοκρασίας, μείωση υγρασίας και επιμονή ανέμων μπορούν να αυξήσουν τον κίνδυνο περισσότερο από μία μεμονωμένη ακραία τιμή. Έτσι, το ConvLSTM2D λειτουργεί ως μοντέλο μνήμης συγκρατεί την πρόσφατη εξέλιξη των μετεωρολογικών συνθηκών και τη συνδέει με τον τελικό χάρτη πρόβλεψης.

Η ανάλυση σημαντικότητας στο χρόνο έδειξε ότι το μοντέλο πράγματι αξιοποίησε τη χρονική διάσταση με εύλογο τρόπο. Η μέση απόλυτη τιμή gradient ανά ημέρα του input sequence εμφάνισε φθίνουσα τάση, με τις πιο πρόσφατες ημέρες να έχουν μεγαλύτερη επίδραση στην τελική πρόβλεψη. Αυτό δείχνει ότι το ConvLSTM2D δεν αντιμετώπισε τις επτά ημέρες ως ισοδύναμες, αλλά έμαθε ότι οι τελευταίες 48 - 72 ώρες έχουν ισχυρότερο προγνωστικό βάρος. Το εύρημα αυτό είναι συνεπές με τη φυσική του προβλήματος, καθώς οι άμεσες συνθήκες θερμότητας, ξηρότητας και ανέμου επηρεάζουν περισσότερο την πιθανότητα εκδήλωσης πυρκαγιάς.

Παράλληλα, η χωρική ανάλυση occlusion έδειξε ότι το μοντέλο δεν χρησιμοποιεί ομοιόμορφα όλο το πλέγμα. Όταν αποκρύπτονταν συγκεκριμένες χωρικές περιοχές, η πρόβλεψη μεταβαλλόταν περισσότερο σε γεωγραφικές ζώνες που αντιστοιχούσαν σε σημαντικά hotspots. Αυτό σημαίνει ότι το ConvLSTM2D έμαθε να δίνει μεγαλύτερο βάρος σε περιοχές που ιστορικά ή μετεωρολογικά συνδέονται περισσότερο με πυρκαγιές, αντί να αντιμετωπίζει όλα τα pixels ως ισοδύναμα. Με άλλα λόγια, το μοντέλο ανέπτυξε χωρική ευαισθησία, όχι μόνο χρονική μνήμη.

Στα πειραματικά αποτελέσματα, το ConvLSTM2D παρουσίασε πολύ υψηλή συνολική απόδοση. Σε μία από τις κύριες εκτελέσεις, η τελική test accuracy έφτασε περίπου το 0.9996, τιμή που δείχνει ότι το μοντέλο μπόρεσε να μάθει πολύ ισχυρά διαχωριστικά μοτίβα στα χωροχρονικά δεδομένα. Οι εσωτερικές κατατάξεις σημαντικότητας έδειξαν επίσης ότι το μοντέλο δεν βασίστηκε σε τυχαίους συσχετισμούς, αλλά ανέδειξε ως σημαντικές μεταβλητές το d2m, το PET, το t2m, το FWI και το u10, δηλαδή παράγοντες που συνδέονται φυσικά με την υγρασία, τη θερμική καταπόνηση, την εξατμιστική ζήτηση και τον πυρομετεωρολογικό κίνδυνο.

Ένας περιορισμός είναι η ερμηνευσιμότητα. Παρότι μπορούν να εφαρμοστούν τεχνικές όπως gradient-based importance και occlusion maps, το ConvLSTM2D δεν παρέχει από μόνο του μηχανισμό εξήγησης. Αντίθετα, ένα transformer μπορεί να δώσει πρόσθετη πληροφορία μέσω attention weights, ενώ ένα U-Net μπορεί να αναλυθεί πιο άμεσα με χωρικές τεχνικές ενεργοποίησης και χάρτες σημασίας. Επομένως, το ConvLSTM2D είναι ισχυρό ως μοντέλο πρόβλεψης, αλλά λιγότερο διαφανές ως προς τον ακριβή τρόπο με τον οποίο συνδυάζει τη χρονική μνήμη με τις χωρικές δομές.

Συνολικά, ο ρόλος του ConvLSTM2D στην εργασία είναι να αποδείξει ότι η ρητή χωροχρονική μοντελοποίηση έχει πραγματική αξία για το πρόβλημα της πρόβλεψης πυρκαγιών. Τα αποτελέσματα

δείχνουν ότι οι ακολουθίες ημερήσιων μετεωρολογικών πλεγμάτων περιέχουν ισχυρό σήμα και ότι ένα recurrent-convolutional μοντέλο μπορεί να το αξιοποιήσει αποτελεσματικά.

5.4 Spatio-Temporal Vision Transformer


Ο Spatio-Temporal Vision Transformer χρησιμοποιήθηκε στην εργασία ως μια εναλλακτική αρχιτεκτονική απέναντι στα συνελκτικά μοντέλα, με στόχο να εξεταστεί αν ο μηχανισμός αυτοπροσοχής μπορεί να αξιοποιήσει καλύτερα τις μακρινές χωρικές και χρονικές εξαρτήσεις που εμφανίζονται στο πρόβλημα της πρόβλεψης πυρκαγιάς. Η αρχική ιδέα του Vision Transformer είναι ότι μια εικόνα δεν επεξεργάζεται απαραίτητα με συνελκτικά φίλτρα, αλλά μπορεί να χωριστεί σε μικρά, μη επικαλυπτόμενα τμήματα, δηλαδή patches, τα οποία μετατρέπονται σε διανύσματα και αντιμετωπίζονται ως ακολουθία tokens [39]. Με αυτόν τον τρόπο, το μοντέλο μπορεί να συγκρίνει κάθε τμήμα της εικόνας με όλα τα υπόλοιπα, χωρίς να περιορίζεται από το τοπικό οπτικό πεδίο μιας συνέλιξης.

Η λογική αυτή προσαρμόστηκε σε χωροχρονικά μετεωρολογικά δεδομένα. Το μοντέλο δεν εκπαιδεύτηκε με φυσικές φωτογραφίες ή δορυφορικές εικόνες RGB, αλλά με ημερήσια πολυκαναλικά μετεωρολογικά πλέγματα. Κάθε ημέρα αναπαρίσταται ως χάρτης τιμών πάνω στο πλέγμα της Ελλάδας. Κάθε μεταβλητή αποτελεί διαφορετικό κανάλι του ίδιου ημερήσιου grid. Ενδεικτικά, τα κανάλια εισόδου μπορούν να αποτελούνται από μετεωρολογικές παραμέτρους (θερμοκρασία αέρα στα 2 μέτρα, σημείο δρόσου, βροχόπτωση, συνιστώσες ανέμου) και ειδικούς πυροσβεστικούς δείκτες, όπως ο FWI και οι δείκτες ξηρασίας. Έτσι, η είσοδος του ViT δεν είναι μία απλή εικόνα, αλλά μια ακολουθία ημερήσιων χαρτών που περιέχουν φυσικά και μετεωρολογικά χαρακτηριστικά.

Η οπτική μορφή αυτής της αναπαράστασης μπορεί να παρουσιαστεί μέσα από heatmaps, όπως ο χάρτης FWI για συγκεκριμένη ημερομηνία και ο αντίστοιχος ground truth fire map. Ο πρώτος δείχνει πώς αποτυπώνεται ένα input feature σε μορφή χωρικού πλέγματος, ενώ ο δεύτερος δείχνει τον στόχο που προσπαθεί να μάθει το μοντέλο, δηλαδή σε ποια κελιά υπήρξε πυρκαγιά. Με αυτή τη λογική, η εκπαίδευση του μοντέλου μπορεί να περιγραφεί ως αντιστοίχιση μιας ακολουθίας επτά ημερήσιων πολυκαναλικών μετεωρολογικών χαρτών σε έναν τελικό χάρτη πιθανότητας πυρκαγιάς. Για παράδειγμα στην εικόνα 5.1 υπάρχει FWI heatmap και ground truth fire map για την ίδια ημερομηνία, το οποίο μπορεί να χρησιμοποιηθεί ως σχήμα για να εξηγηθεί η είσοδος και η ετικέτα εκπαίδευσης.

Στο συγκεκριμένο πείραμα, η είσοδος του ViT οργανώθηκε έτσι ώστε κάθε δείγμα να αντιστοιχεί σε χωροχρονικό παράθυρο επτά ημερών. Για κάθε ημέρα του παραθύρου δημιουργήθηκε ένα grid, το οποίο περιλάμβανε τις βασικές μετεωρολογικές μεταβλητές, παράγωγους δείκτες κινδύνου και επιπλέον χωρικά βοηθητικά κανάλια. Ενδεικτικά, χρησιμοποιήθηκαν ο αρχικός χάρτης FWI, χωρικές συναθροίσεις του FWI σε γειτονία 3×3 , όπως ο μέσος όρος και η μέγιστη τιμή, η μάσκα ξηράς, η θερμοκρασία αέρα, η βροχόπτωση και οι συνιστώσες ανέμου. Η χρήση των 3×3 συναθροίσεων του FWI είχε σκοπό να δώσει στο μοντέλο μια πιο άμεση εικόνα του τοπικού περιβάλλοντος γύρω από κάθε κελί. Έτσι, το ViT δεν λαμβάνει μόνο την τιμή ενός απομονωμένου pixel, αλλά και ένδειξη για το αν η γειτονική περιοχή εμφανίζει αυξημένο πυρομετεωρολογικό κίνδυνο.

Ιδιαίτερη σημασία είχε και η χρήση land mask. Επειδή το πλέγμα καλύπτει γεωγραφική περιοχή όπου υπάρχουν τόσο χερσαία όσο και θαλάσσια κελιά, η μάσκα ξηράς χρησιμοποιήθηκε ώστε το μοντέλο να μη μαθαίνει άσχετα μοτίβα από περιοχές όπου δεν μπορεί να εμφανιστεί πυρκαγιά. Με αυτόν τον τρόπο η είσοδος γίνεται πιο φυσικά συνεπής, καθώς το μοντέλο εστιάζει στο γεωγραφικό πεδίο όπου η πρόβλεψη έχει πραγματικό νόημα.




Εικόνα 5.1 Παράδειγμα πολυκαναλικής εισόδου και στόχου εκπαίδευσης για το Spatio-Temporal Vision Transformer.

Ο στόχος εκπαίδευσης δεν ορίστηκε αποκλειστικά ως ένα μοναδικό θετικό pixel στην ακριβή θέση της πυρκαγιάς. Χρησιμοποιήθηκε fire target με ακτίνα γύρω από την πραγματική εστία, ώστε να ληφθεί υπόψη η χωρική αβεβαιότητα της καταγραφής. Αυτό είναι σημαντικό επειδή οι ετικέτες πυρκαγιάς, είτε προέρχονται από δορυφορικές ανιχνεύσεις είτε από συμβαντολογικά αρχεία, δεν έχουν πάντα απόλυτη χωρική ακρίβεια σε επίπεδο grid cell. Η διεύρυνση του στόχου σε μικρή ακτίνα κάνει τη μάθηση πιο ρεαλιστική, καθώς επιτρέπει στο μοντέλο να θεωρεί ως θετική όχι μόνο την ακριβή θέση, αλλά και τη γύρω περιοχή υψηλής επικινδυνότητας.

Αφού δημιουργηθούν τα ημερήσια grids, το ViT τα μετατρέπει σε patches. Κάθε patch αντιστοιχεί σε μια μικρή χωρική περιοχή του χάρτη και περιέχει τις τιμές όλων των καναλιών για τη συγκεκριμένη περιοχή. Στη συνέχεια, κάθε patch μετατρέπεται σε token. Επειδή το μοντέλο επεξεργάζεται ακολουθία επτά ημερών, τα tokens δεν έχουν μόνο χωρική θέση αλλά και χρονική θέση. Για τον λόγο αυτό προστίθενται κωδικοποιήσεις θέσης, ώστε το μοντέλο να μπορεί να διακρίνει αν ένα χωρικό τμήμα του πλέγματος προέρχεται από παλαιότερη ή πιο πρόσφατη ημέρα του χρονικού παραθύρου. Αυτή η πληροφορία είναι κρίσιμη, επειδή μια ακραία τιμή FWI ή θερμοκρασίας την τελευταία ημέρα πριν από το συμβάν μπορεί να έχει διαφορετική σημασία από την ίδια τιμή έξι ημέρες πριν.

Η διαδικασία αυτή επιτρέπει στο ViT να μάθει όχι μόνο ποια χαρακτηριστικά είναι σημαντικά, αλλά και σε ποια χρονική στιγμή αποκτούν μεγαλύτερη βαρύτητα. Στην πρόβλεψη πυρκαγιών, η χρονική σειρά των συνθηκών έχει ιδιαίτερη σημασία. Μια πυρκαγιά μπορεί να συνδέεται με διαδοχικές ημέρες ξηρασίας, αυξανόμενη θερμοκρασία, χαμηλή υγρασία, αυξημένη δυνητική εξατμισοδιαπνοή και ενισχυμένο FWI. Το ViT επιχειρεί να μάθει αυτές τις σχέσεις μέσα από την αυτοπροσοχή, δηλαδή εξετάζοντας ποιες περιοχές και ποιες ημέρες της ακολουθίας σχετίζονται περισσότερο με την τελική πιθανότητα πυρκαγιάς.

Στην υλοποίηση της εργασίας, ο ViT σχεδιάστηκε ως μοντέλο τύπου πυκνής πρόβλεψης και όχι ως απλός ταξινομητής ημέρας. Αυτό σημαίνει ότι ο στόχος του δεν ήταν απλώς να προβλέψει αν μια ημέρα έχει ή δεν έχει πυρκαγιά συνολικά, αλλά να παράγει χωρικό χάρτη πιθανότητας σε επίπεδο κελιού. Για τον λόγο αυτό, μετά τον transformer encoder χρησιμοποιήθηκε έξοδος τύπου segmentation, ώστε οι αναπαραστάσεις των patches να μετασχηματιστούν ξανά σε χωρικό πλέγμα. Το τελικό αποτέλεσμα είναι ένας χάρτης πιθανότητας πυρκαγιάς, όπου κάθε κελί παίρνει μία τιμή κινδύνου.



Εικόνα 5.2 Παράδειγμα τύπου πυκνής πρόβλεψης του Spatio-Temporal ViT.

Τα αποτελέσματα του ViT έδειξαν ότι το μοντέλο μπορεί να μάθει ισχυρή διαχωριστική πληροφορία από τα χωροχρονικά μετεωρολογικά δεδομένα. Στην εσωτερική αξιολόγηση πέτυχε πολύ υψηλές τιμές ROC-AUC, πάνω από 0.998, γεγονός που δείχνει ότι μπορεί να διαχωρίζει συνολικά τα fire από τα no-fire pixels. Ωστόσο, επειδή το πρόβλημα είναι έντονα ανισόρροπο, η αξιολόγηση δεν μπορεί να βασιστεί αποκλειστικά στο ROC-AUC. Για τον λόγο αυτό εξετάστηκε και η PR-AUC, η οποία είναι πιο κατάλληλη όταν η θετική κλάση είναι σπάνια. Στο precision - recall πεδίο, η PR-AUC του ViT ήταν περίπου 0.869, τιμή που δείχνει ότι το μοντέλο έχει ουσιαστική ικανότητα ανίχνευσης, αλλά παραμένει ευαίσθητο στη σπανιότητα των θετικών pixels.

Σε επίπεδο threshold-based αξιολόγησης, με κατώφλι περίπου 0.62, το ViT πέτυχε precision περίπου 0.816, recall περίπου 0.747 και F1-score περίπου 0.780. Οι τιμές αυτές δείχνουν ότι το μοντέλο έχει αρκετά καλή ισορροπία ανάμεσα στην ακρίβεια των θετικών προβλέψεων και στην ικανότητα εντοπισμού των πραγματικών εστιών. Το precision 0.816 σημαίνει ότι μεγάλο ποσοστό των pixels που προβλέφθηκαν ως fire αντιστοιχούσε πράγματι σε θετική ετικέτα, ενώ το recall 0.747 δείχνει ότι το μοντέλο εντόπισε σημαντικό μέρος των πραγματικών fire pixels, αν και όχι όλα. Το F1-score 0.780 συνοψίζει αυτή την ισορροπία και επιβεβαιώνει ότι ο ViT λειτουργεί ικανοποιητικά ως χωροχρονικό μοντέλο πυκνής πρόβλεψης, αλλά εξακολουθεί να επηρεάζεται από τη δυσκολία του σπάνιου συμβάντος.

Το βασικό πλεονέκτημα του ViT είναι ότι μπορεί να συλλάβει πιο ευρείες εξαρτήσεις σε σχέση με ένα καθαρά συνεκτικό μοντέλο. Οι συνελίξεις είναι πολύ ισχυρές για τοπικά μοτίβα, αλλά η πληροφορία μεταφέρεται σταδιακά από επίπεδο σε επίπεδο. Αντίθετα, στον ViT, η αυτοπροσοχή επιτρέπει σε κάθε token να συγκριθεί άμεσα με όλα τα υπόλοιπα tokens. Αυτό δίνει στο μοντέλο τη δυνατότητα να μάθει σχέσεις μεγάλης απόστασης, κάτι που είναι χρήσιμο όταν ο κίνδυνος πυρκαγιάς εξαρτάται από ευρύτερα κλιματικά μοτίβα και όχι μόνο από γειτονικά pixels.

Ένας σημαντικός περιορισμός του ViT είναι η ευαισθησία του στη διατύπωση του προβλήματος. Χρειάζεται προσεκτική διαμόρφωση της εισόδου. Το μέγεθος των patches, ο τρόπος ενσωμάτωσης του χρόνου, και η επιλογή του decoder επηρεάζουν σημαντικά την τελική απόδοση. Αυτό φάνηκε ιδιαίτερα στη μεταφορά στο FireCube. Όταν το ViT μεταφέρθηκε στο FireCube ως μοντέλο πυκνής χωρικής πρόβλεψης, δηλαδή με στόχο την παραγωγή πρόβλεψης για κάθε κελί του πλέγματος, η απόδοσή του ήταν περιορισμένη. Το μοντέλο κατέρρευσε σε σχεδόν καθολικά αρνητικές προβλέψεις, με πολύ χαμηλό PR-AUC, ROC-AUC κοντά ή και κάτω από το τυχαίο επίπεδο, μηδενικό recall σε λογικά thresholds και μηδενική top-1% precision.

Συνολικά, ο Spatio-Temporal Vision Transformer προσφέρει μια πλούσια αλλά πιο απαιτητική προσέγγιση για την πρόβλεψη πυρκαγιών. Η βασική του αξία είναι ότι μπορεί να συλλάβει μακρινές

χωρικές σχέσεις και πιο αφηρημένα χρονικά ή κλιματικά μοτίβα. Τα αποτελέσματα δείχνουν πολύ υψηλό ROC-AUC και φυσικά εύλογες εξηγήσεις, άρα το μοντέλο πράγματι μαθαίνει χρήσιμη πληροφορία. Ωστόσο, η χαμηλότερη PR-AUC σε σχέση με το U-Net, η ευαισθησία στο task formulation και η δυσκολία μεταφοράς στο FireCube δείχνουν ότι δεν είναι η πιο σταθερή λύση για επιχειρησιακή pixel-level ανίχνευση σπάνιων πυρκαγιών. Για τον λόγο αυτό, στην παρούσα εργασία ο ViT ερμηνεύεται ως συμπληρωματική αρχιτεκτονική που εμπλουτίζει τη σύγκριση με ικανότητα σύλληψης ευρύτερων χωρικών και χρονικών σχέσεων.

5.5 U-Net για πυκνή ημερήσια χαρτογράφηση κινδύνου

Ο U-Net χρησιμοποιήθηκε στην εργασία ως βασικό μοντέλο πυκνής χωρικής πρόβλεψης, δηλαδή ως μοντέλο που δεν προβλέπει απλώς αν μια ημέρα είναι επικίνδυνη συνολικά, αλλά παράγει χάρτη πιθανότητας πυρκαγιάς σε επίπεδο κελιού. Η αρχιτεκτονική U-Net προτάθηκε αρχικά από τους Ronneberger et al. για προβλήματα τμηματοποίησης εικόνας και έχει χαρακτηριστική μορφή encoder – decoder [35]. Το πρώτο μέρος, δηλαδή ο encoder, δηλαδή το συστατικό μονοπάτι, μειώνει σταδιακά τη χωρική ανάλυση και μαθαίνει πιο αφηρημένες αναπαραστάσεις. Το δεύτερο μέρος, ο decoder, δηλαδή το επεκτατικό μονοπάτι, ανακατασκευάζει τη χωρική ανάλυση και οδηγεί ξανά σε έξοδο ίδιων διαστάσεων με την είσοδο. Το κρίσιμο στοιχείο της αρχιτεκτονικής είναι οι skip connections, οι οποίες μεταφέρουν πληροφορία από τα πρώτα επίπεδα του encoder στα αντίστοιχα επίπεδα του decoder. Έτσι, το μοντέλο συνδυάζει βαθύτερη σημασιολογική πληροφορία με λεπτομερή χωρική πληροφορία.

Στο πρόβλημα της πρόβλεψης πυρκαγιών, αυτή η δομή είναι ιδιαίτερα κατάλληλη, επειδή το ζητούμενο δεν είναι μόνο να εντοπιστεί αν υπάρχουν συνθήκες υψηλού κινδύνου, αλλά και να χαρτογραφηθεί πού ακριβώς εμφανίζονται. Κάθε είσοδος του μοντέλου αποτελείται από πολυκαναλικά μετεωρολογικά πλέγματα, στα οποία οι επτά ημέρες του παραθύρου εισόδου ενσωματώνονται ως επιπλέον κανάλια. Με άλλα λόγια, το U-Net δεν επεξεργάζεται φυσικές εικόνες RGB, αλλά χωρικούς χάρτες μεταβλητών όπως θερμοκρασία αέρα, σημείο δρόσου, βροχόπτωση, άνεμος, FWI, KBDI, PET, D και SPEI. Η έξοδος είναι ένας χάρτης πιθανότητας, όπου κάθε κελί παίρνει τιμή μεταξύ 0 και 1 και εκφράζει την εκτιμώμενη πιθανότητα εμφάνισης πυρκαγιάς.

Στη βασική διατύπωση του U-Net, το παράθυρο εισόδου καταλήγει στην ημέρα-στόχο. Δηλαδή, αν η είσοδος συμβολιστεί ως $[t - 6, \dots, t]$, τότε η έξοδος αντιστοιχεί στον χάρτη πυρκαγιάς της ημέρας t και όχι της ημέρας $t + 1$. Επομένως, τα αποτελέσματα του βασικού U-Net ερμηνεύονται ως ημερήσια εκτίμηση κινδύνου πυρκαγιάς, δηλαδή same-day wildfire risk estimation, και όχι ως αυστηρό next-day forecasting. Η διάκριση αυτή είναι σημαντική, επειδή το παράθυρο εισόδου μπορεί να περιλαμβάνει μετεωρολογική πληροφορία της ίδιας ημέρας με τον στόχο.

Σε αντίθεση με το ConvLSTM2D, το U-Net δεν έχει ενσωματωμένο αναδρομικό μηχανισμό μνήμης. Η χρονική πληροφορία δεν μοντελοποιείται ως ακολουθία βημάτων, αλλά συμπυκνώνεται στα κανάλια εισόδου. Παρότι αυτή η προσέγγιση δεν είναι ρητά χρονική, αποδείχθηκε ιδιαίτερα αποτελεσματική στην πράξη, επειδή επιτρέπει στο μοντέλο να συσχετίζει τις πρόσφατες και παλαιότερες τιμές των μεταβλητών με τη χωρική θέση του κινδύνου. Το τελικό αποτέλεσμα είναι ένα μοντέλο που δίνει έμφαση στην ακριβή χωρική εντόπιση, δηλαδή στο pixel-level risk mapping.

Η υλοποίηση του U-Net βασίστηκε σε επαναλαμβανόμενες συνελκτικές μονάδες στο τμήμα κωδικοποίησης και σε αντίστοιχες μονάδες υπερδεδειγματοληψίας στο τμήμα αποκωδικοποίησης. Τα πρώτα επίπεδα μαθαίνουν πιο τοπικά μοτίβα, όπως μικρές περιοχές αυξημένου FWI ή τοπικές μεταβολές θερμοκρασίας και υγρασίας. Τα βαθύτερα επίπεδα μαθαίνουν πιο αφηρημένες χωρικές

συσχετίσεις, όπως ευρύτερες περιοχές ξηρότητας ή συνδυασμούς συνθηκών που συνδέονται με αυξημένο κίνδυνο.


Η εκπαίδευση έγινε με στόχο τη δυαδική πρόβλεψη fire/no-fire σε επίπεδο κελιού. Λόγω της ανισορροπίας του συνόλου δεδομένων, δόθηκε ιδιαίτερη βαρύτητα σε μετρικές όπως PR-AUC, precision, recall και F1-score, και όχι μόνο στη γενική accuracy. Η χρήση focal loss είναι σημαντική σε τέτοια προβλήματα, επειδή περιορίζει την κυριαρχία των εύκολων αρνητικών παραδειγμάτων και αναγκάζει το μοντέλο να μάθει καλύτερα τα σπάνια θετικά συμβάντα.

Στα βασικά πειράματα, το ντετερμινιστικό U-Net πέτυχε πολύ υψηλές επιδόσεις. Σε επίπεδο pixel ranking, το PR-AUC ήταν 0.966394 και το ROC-AUC 0.999042, γεγονός που δείχνει ισχυρή ικανότητα διάκρισης μεταξύ fire και no-fire pixels στο συγκεκριμένο σύνολο αξιολόγησης. Στη threshold-based αξιολόγηση, το μοντέλο πέτυχε precision 0.981927, recall 1.0 και F1-score 0.990881. Οι τιμές αυτές δείχνουν ότι, για το συγκεκριμένο πειραματικό σενάριο και το επιλεγμένο κατώφλι, το μοντέλο εντόπισε όλα τα θετικά pixels, διατηρώντας παράλληλα περιορισμένο αριθμό ψευδώς θετικών προβλέψεων.

Οι υψηλές επιδόσεις του U-Net υποδηλώνουν ότι το μοντέλο έχει μάθει αποτελεσματικά τη χωρική και μετεωρολογική δομή του αρχικού συνόλου δεδομένων. Παρ' όλα αυτά, δεν συνιστούν άμεση τεκμηρίωση επιχειρησιακής απόδοσης σε πραγματικό πλαίσιο πρόγνωσης κινδύνου για την επόμενη ημέρα.

5.5.1 Εκτίμηση αβεβαιότητας και βαθμονόμηση του U-Net

Στην εργασία εφαρμόστηκε επίσης Monte Carlo Dropout, ώστε το U-Net να μην παράγει μόνο μία σταθερή πρόβλεψη, αλλά και εκτίμηση αβεβαιότητας. Κατά την εξαγωγή συμπερασμάτων, το dropout διατηρείται ενεργό και το ίδιο δείγμα περνά πολλαπλές φορές από το μοντέλο. Από αυτές τις πολλαπλές προβλέψεις υπολογίζεται ο μέσος χάρτης πιθανότητας και η τυπική απόκλιση ανά pixel. Ο μέσος χάρτης εκφράζει την τελική πιθανότητα πυρκαγιάς, ενώ ο χάρτης τυπικής απόκλισης εκφράζει την αβεβαιότητα του μοντέλου.




Εικόνα 5.3 Σχέση αβεβαιότητας και απόλυτου σφάλματος για το U-Net με Monte Carlo Dropout.

Η πιθανοκρατική εκδοχή του U-Net διατήρησε και βελτίωσε οριακά τις βασικές ranking μετρικές. Συγκεκριμένα, το U-Net με MC Dropout mean για $K=30$ στοχαστικά περάσματα πέτυχε PR-AUC 0.966777 και ROC-AUC 0.999204. Το αποτέλεσμα αυτό δείχνει ότι η εισαγωγή αβεβαιότητας δεν μείωσε την προγνωστική ισχύ του μοντέλου. Αντίθετα, πρόσθεσε ένα δεύτερο επίπεδο πληροφορίας: όχι μόνο πού προβλέπεται υψηλός κίνδυνος, αλλά και πόσο βέβαιο είναι το μοντέλο για αυτή την πρόβλεψη.


Ένας απλός χάρτης πιθανότητας μπορεί να δείχνει περιοχή υψηλού κινδύνου, αλλά δεν δείχνει αν το μοντέλο είναι σταθερό σε αυτή την εκτίμηση. Ο χάρτης αβεβαιότητας παρέχει αυτή τη συμπληρωματική πληροφορία. Περιοχές με υψηλή πιθανότητα και χαμηλή αβεβαιότητα μπορούν να θεωρηθούν πιο αξιόπιστα σημεία κινδύνου. Αντίθετα, περιοχές με υψηλή πιθανότητα αλλά και υψηλή αβεβαιότητα χρειάζονται πιο προσεκτική ερμηνεία.

Εκτός από το MC Dropout, εξετάστηκε και η ενσωμάτωση residual conditional VAE πάνω στην έξοδο του U-Net. Η λογική αυτής της προσέγγισης είναι ότι το αρχικό U-Net δίνει έναν βασικό χάρτη πιθανότητας, ενώ το residual-cVAE μαθαίνει την κατανομή του υπολειμματικού σφάλματος μεταξύ πρόβλεψης και πραγματικής ετικέτας. Κατά την πρόβλεψη, γίνεται πολλαπλή δειγματοληψία από τον λανθάνοντα χώρο, ώστε να παραχθούν εναλλακτικά πιθανά σενάρια κινδύνου. Ο τελικός χάρτης προκύπτει ως μέσος όρος αυτών των σεναρίων, ενώ η αβεβαιότητα εκτιμάται μέσω της χωρικής τυπικής απόκλισης.



Εικόνα 5.4 Πιθανοκρατική έξοδος U-Net με Monte Carlo Dropout. Από αριστερά προς τα δεξιά παρουσιάζονται ο πραγματικός χάρτης πυρκαγιάς, ο μέσος χάρτης πιθανότητας και ο χάρτης αβεβαιότητας.


Η ενσωμάτωση του residual-cVAE επέτρεψε τη μετάβαση από καθαρά ντετερμινιστική πρόβλεψη σε πιθανοκρατική εκτίμηση κινδύνου, χωρίς ουσιαστική απώλεια στην ακρίβεια. Στα αποτελέσματα της συγκεκριμένης εκδοχής του μοντέλου αναφέρεται recall 1.0 και precision περίπου 0.994, γεγονός που δείχνει ότι η επέκταση διατήρησε την ικανότητα εντοπισμού των πραγματικών εστιών και ταυτόχρονα κράτησε χαμηλό τον αριθμό ψευδώς θετικών προβλέψεων.



Εικόνα 5.5 Residual-cVAE επέκταση του U-Net. Το μοντέλο παράγει πολλαπλά πιθανά σενάρια κινδύνου, από τα οποία υπολογίζονται η μέση πιθανότητα και η χωρική αβεβαιότητα.

Επιπλέον, πραγματοποιήθηκε αξιολόγηση βαθμονόμησης των πιθανοτικών εξόδων. Η βαθμονόμηση εξετάζει αν οι πιθανότητες που δίνει το μοντέλο αντιστοιχούν πράγματι σε εμπειρικές συχνότητες εμφάνισης πυρκαγιάς. Στα αποτελέσματα, οι raw προβλέψεις είχαν ήδη καλή βαθμονόμηση, με Brier score 0.000861 και ECE 0.00443. Η temperature scaling βελτίωσε ελαφρώς το ECE σε 0.00350, ενώ η isotonic regression έδωσε σχεδόν τέλεια βαθμονόμηση, με Brier score 0.000742 και ECE περίπου 0.00000.

Το αποτέλεσμα της isotonic regression πρέπει να ερμηνευθεί προσεκτικά. Ο calibrator προσαρμόστηκε στο validation set που χρησιμοποιήθηκε και για την αξιολόγηση της βαθμονόμησης. Επομένως, το ECE περίπου 0 δεν αποτελεί ανεξάρτητη απόδειξη γενίκευσης της βαθμονόμησης, αλλά δείχνει ότι η isotonic regression μπορεί να προσαρμόσει πολύ καλά τις πιθανότητες στο συγκεκριμένο σύνολο. Για ασφαλέστερο συμπέρασμα θα απαιτούνταν ξεχωριστό calibration set ή ανεξάρτητο test set.



Σχήμα 5.1 Reliability diagram των πιθανοτικών εξόδων του U-Net. Η σύγκριση raw, temperature-scaled και isotonic προβλέψεων δείχνει τη βελτίωση της βαθμονόμησης μετά από post-hoc calibration.

Σε επόμενο στάδιο, η ανάλυση επικεντρώθηκε στη σύνδεση αβεβαιότητας και σφάλματος. Στο C1 uncertainty validation, το μοντέλο πέτυχε PR-AUC 0.966507, ROC-AUC 0.999182, Brier score 0.000531 και ECE 0.004143. Επιπλέον, η συσχέτιση μεταξύ αβεβαιότητας και απόλυτου σφάλματος ήταν 0.730, τιμή που δείχνει ότι η αβεβαιότητα δεν είναι τυχαία ή διακοσμητική έξοδος, αλλά σχετίζεται ουσιαστικά με το πού το μοντέλο είναι πιθανότερο να κάνει λάθος.

Αυτό επιτρέπει την πρόβλεψη με δυνατότητα αποχής από περιοχές υψηλής αβεβαιότητας. Στο decision-aware risk mapping, όταν κρατήθηκε μόνο το πιο αξιόπιστο 50% των pixels, το μοντέλο πέτυχε precision 0.9979, recall 0.9959 και F1-score 0.9969. Ακόμη και όταν κρατήθηκε το 99% των pixels, οι μετρικές παρέμειναν πολύ υψηλές, με precision 0.9953, recall 0.9938 και F1-score 0.9945. Αυτό δείχνει ότι η αβεβαιότητα μπορεί να χρησιμοποιηθεί πρακτικά για να φιλτράρει αβέβαιες προβλέψεις και να αυξάνει την αξιοπιστία των τελικών χαρτών κινδύνου.


Στο ίδιο πλαίσιο, ορίστηκε και επιχειρησιακή ταξινόμηση κινδύνου σε επίπεδα. Τα pixels ταξινομήθηκαν σε πράσινη, κίτρινη, πορτοκαλί και κόκκινη ζώνη με βάση κατώφλια πιθανότητας, ενώ περιοχές με αβεβαιότητα πάνω από συγκεκριμένο ποσοστημόριο χαρακτηρίστηκαν ως abstain/unknown. Με αυτόν τον τρόπο, η έξοδος του U-Net μετατράπηκε από απλό probability map σε πιο πρακτικό χάρτη λήψης απόφασης. Στο συγκεκριμένο πείραμα, το 5% των pixels χαρακτηρίστηκε

ως αβέβαιο/unknown, περίπου το 94.87% ως πράσινη ζώνη και περίπου το 0.127% ως κόκκινη ζώνη υψηλού κινδύνου.

5.5.2 Εξωτερική αξιολόγηση

Η εξωτερική αξιολόγηση στο FireCube αποτέλεσε ξεχωριστό και αυστηρότερο πείραμα μεταφοράς σε νέο domain. Δεν ερμηνεύεται ως απλή συνέχεια της εσωτερικής αξιολόγησης του βασικού U-Net, επειδή το FireCube έχει διαφορετική χωρική ανάλυση, διαφορετικό ορισμό στόχου και πολύ χαμηλότερο ποσοστό θετικών pixels. Για τον λόγο αυτό, χρησιμοποιείται κυρίως ως έλεγχος domain shift και όχι ως άμεσα ισοδύναμο test set.

Το προεκπαιδευμένο U-Net αξιολογήθηκε αρχικά χωρίς επανεκπαίδευση, δηλαδή σε zero-shot transfer. Παρά την εναρμόνιση των δεδομένων, η απόδοση ήταν πολύ χαμηλή, με PR-AUC περίπου 0.0007 και ROC-AUC περίπου 0.56. Το μοντέλο παρήγαγε σχεδόν μηδενικές πιθανότητες για τα περισσότερα pixels, γεγονός που δείχνει σοβαρή ασυμφωνία κατανομής μεταξύ του αρχικού συνόλου εκπαίδευσης και του FireCube.



Εικόνα 5.6 Παράδειγμα πρόβλεψης του fine-tuned U-Net στο FireCube.

Για να αντιμετωπιστεί αυτό, εφαρμόστηκε two-stage fine-tuning. Στο πρώτο στάδιο πάγωσε ο encoder και εκπαιδεύτηκαν κυρίως τα στρώματα του decoder, ώστε το μοντέλο να προσαρμόσει την έξοδο στο νέο domain. Στο δεύτερο στάδιο ξεπάγωσε ολόκληρο το δίκτυο και συνεχίστηκε η εκπαίδευση με χαμηλότερο ρυθμό μάθησης. Η προεπεξεργασία του FireCube περιλάμβανε χωρική αναπροσαρμογή πλέγματος, δημιουργία επταήμερων χρονικών παραθύρων, ανακατασκευή χαρακτηριστικών όπως PET, KBDI και SPEI, διόρθωση μονάδων, κυρίως μετατροπή θερμοκρασιών από Kelvin σε Celsius, και κανονικοποίηση με τα στατιστικά του αρχικού training set. Η αξιολόγηση έγινε σε υποσύνολο 2018 - 2021 και μόνο για τη wildfire season, από Μάιο έως Σεπτέμβριο.

Μετά το fine-tuning, η απόδοση βελτιώθηκε σημαντικά. Το U-Net στο FireCube πέτυχε PR-AUC 0.009679 και ROC-AUC 0.822776. Στο κατώφλι 0.05 πέτυχε precision 0.00265, recall 0.9422 και F1-score 0.00529. Η precision φαίνεται πολύ χαμηλή σε απόλυτη τιμή, αλλά αυτό οφείλεται στην ακραία σπανιότητα της θετικής κλάσης στο FireCube, όπου το positive rate είναι περίπου 0.056%. Το υψηλό recall δείχνει ότι το fine-tuned U-Net εντόπισε την πλειονότητα των fire pixels, ενώ η PR-AUC και το ROC-AUC δείχνουν ότι απέκτησε ουσιαστική ικανότητα κατάταξης κινδύνου στο νέο πεδίο δεδομένων.

Ένα ιδιαίτερα σημαντικό αποτέλεσμα του FireCube ήταν η αξιολόγηση στο ανώτερο ποσοστημόριο προβλέψεων. Στο ανώτερο 1% των προβλέψεων υψηλότερου κινδύνου, το fine-tuned U-Net πέτυχε

precision περίπου 2.24%, δηλαδή περίπου 40 φορές υψηλότερο από το base rate του συνόλου δεδομένων. Αυτό δείχνει ότι, παρότι η απόλυτη precision παραμένει χαμηλή λόγω της σπανιότητας των θετικών pixels, το μοντέλο μπορεί να λειτουργήσει χρήσιμα ως σύστημα κατάταξης κινδύνου. Δηλαδή μπορεί να βοηθήσει στην ιεράρχηση των περιοχών που αξίζει να εξεταστούν πρώτες από ένα επιχειρησιακό σύστημα.

Η εξωτερική αξιολόγηση επιβεβαιώνει ότι η καλή εσωτερική απόδοση του U-Net δεν μεταφέρεται αυτόματα σε διαφορετικό σύνολο δεδομένων. Η μεταφορά σε νέο domain απαιτεί εναρμόνιση χαρακτηριστικών, fine-tuning, επαναρύθμιση thresholds και προσεκτική ερμηνεία των μετρικών. Τα αναλυτικά στοιχεία της μεταφοράς στο FireCube παρουσιάζονται εκτενέστερα στο Κεφάλαιο 7.


5.5.3 Αξιολόγηση U-Net με zone-mask και σύγκριση με FWI baseline

Πέρα από την αρχική αξιολόγηση του U-Net σε επίπεδο pixel, πραγματοποιήθηκε και μια πιο εστιασμένη αξιολόγηση με χρήση zone-mask. Η λογική αυτής της αξιολόγησης ήταν να εξεταστεί η απόδοση του μοντέλου όχι σε όλα τα διαθέσιμα pixels του πλέγματος, αλλά σε χωρικές ζώνες ενδιαφέροντος. Με αυτόν τον τρόπο, η σύγκριση γίνεται πιο κοντά σε ένα επιχειρησιακό σενάριο, όπου το ζητούμενο δεν είναι η ταξινόμηση κάθε πιθανού κελιού, αλλά η σωστή κατάταξη περιοχών που έχουν μεγαλύτερη σχέση με τον κίνδυνο πυρκαγιάς.

Η αξιολόγηση έγινε σε δύο διαφορετικούς στόχους. Ο πρώτος ήταν ο στόχος του FireCube, το οποίο αποτελεί εξωτερικό domain και άρα πιο δύσκολη δοκιμή γενίκευσης. Ο δεύτερος ήταν ο στόχος του CSV holdout για την περίοδο 2023 - 2025, το οποίο βρίσκεται πιο κοντά στον αρχικό χώρο χαρακτηριστικών της εργασίας. Η διάκριση αυτή είναι σημαντική, επειδή επιτρέπει να φανεί αν το U-Net αποδίδει καλά μόνο όταν το test set μοιάζει με τα δεδομένα εκπαίδευσης ή αν μπορεί να γενικεύσει και σε ανεξάρτητη πηγή δεδομένων.

Στο κύριο σύνολο δεδομένων, το U-Net πέτυχε καλύτερη απόδοση από τον FWI baseline. Στις καμπύλες Precision-Recall, το U-Net πέτυχε AP περίπου 0.436, ενώ ο FWI baseline έφτασε περίπου 0.263. Αντίστοιχα, στις καμπύλες ROC, το U-Net πέτυχε AUC περίπου 0.782, ενώ ο FWI baseline είχε AUC περίπου 0.563. Τα αποτελέσματα αυτά δείχνουν ότι, όταν το μοντέλο αξιολογείται σε συγγενές σύνολο δεδομένων, μπορεί να αξιοποιήσει αποτελεσματικά τη συνδυαστική πληροφορία των μετεωρολογικών και παράγωγων χαρακτηριστικών. Δεν περιορίζεται δηλαδή στη λογική ενός απλού

δείκτη κινδύνου, αλλά μαθαίνει πιο σύνθετες χωρικές σχέσεις.
ROC curves - zone-mask evaluation




Σχήμα 5.2 Καμπύλες ROC για αξιολόγηση με zone-mask

Πέρα από τις αριθμητικές μετρικές PR-AUC και ROC-AUC, εξετάστηκε και η χωρική μορφή των προβλέψεων του U-Net μέσω zone-mask χαρτών. Η ανάλυση αυτή είναι χρήσιμη, επειδή δείχνει αν το μοντέλο παράγει χωρικά συνεκτικούς χάρτες κινδύνου ή αν οι υψηλές πιθανότητες εμφανίζονται τυχαία στο πλέγμα. Το αποτέλεσμα δείχνει ότι το U-Net δεν μαθαίνει μόνο μεμονωμένες εστίες, αλλά σχηματίζει μια πιο γενική χωρική εκτίμηση επικινδυνότητας.

Η χωρική αυτή απεικόνιση συμπληρώνει τις καμπύλες PR και ROC. Ενώ οι καμπύλες δείχνουν τη συνολική διακριτική ικανότητα του μοντέλου, ο χάρτης δείχνει αν η πρόβλεψη έχει χαρτογραφική συνοχή. Στο CSV holdout, το U-Net φαίνεται να παράγει πιο ομαλό και γεωγραφικά συνεκτικό χάρτη κινδύνου, κάτι που είναι σημαντικό για επιχειρησιακή χρήση, επειδή ένας χάρτης κινδύνου πρέπει να είναι αναγνώσιμος και όχι απλώς αριθμητικά σωστός. Επομένως, η επιτυχία του U-Net δεν περιορίζεται στις μετρικές, αλλά φαίνεται και οπτικά μέσα από τη χωρική κατανομή των προβλέψεων.

Zone-mask evaluation - CSV holdout target (2023-2025 test split)




Εικόνα 5.7 Zone-mask αξιολόγηση του U-Net στο CSV holdout target 2023-2025

Αντίθετα, στο FireCube η εικόνα ήταν διαφορετική. Εκεί ο FWI baseline εμφάνισε καλύτερη απόδοση από το U-Net, με AP περίπου 0.400 έναντι 0.227 και ROC-AUC περίπου 0.740 έναντι 0.474. Το αποτέλεσμα αυτό δείχνει ότι η απευθείας εφαρμογή του U-Net σε διαφορετικό domain δεν είναι σταθερή χωρίς προσαρμογή. Παρότι το U-Net έχει μάθει ισχυρές αναπαραστάσεις στο αρχικό σύνολο

δεδομένων, η αλλαγή στη χωρική ανάλυση, στον τρόπο κατασκευής των ετικετών, στις κατανομές των χαρακτηριστικών και στη θετική συχνότητα των fire pixels επηρεάζει σημαντικά την απόδοση.

Η ίδια συμπεριφορά φαίνεται και στη χωρική αξιολόγηση. Ο χάρτης του U-Net παρουσιάζει εκτεταμένες περιοχές αυξημένου προβλεπόμενου κινδύνου, χωρίς όμως η κατανομή αυτή να ταυτίζεται πλήρως με τις πραγματικές ζώνες καμένων και μη καμένων περιοχών του FireCube. Αντίθετα, ο FWI baseline παράγει έναν πιο έντονα χωρικά δομημένο χάρτη κινδύνου, ο οποίος στο συγκεκριμένο εξωτερικό domain εμφανίζεται πιο κοντά στη χωρική συμπεριφορά του target. Αυτό εξηγεί γιατί, στις αριθμητικές μετρικές του FireCube, ο FWI baseline υπερέχει του μη πλήρως προσαρμοσμένου U-Net.



Εικόνα 5.8 Zone-mask αξιολόγηση του U-Net στο FireCube target 2018-2021.

Το συμπέρασμα από τους χάρτες αυτούς είναι ότι το U-Net λειτουργεί πολύ καλά όταν το πεδίο αξιολόγησης είναι κοντά στο αρχικό training domain, αλλά η μεταφορά του στο FireCube είναι πιο δύσκολη. Η δυσκολία δεν φαίνεται μόνο στις μετρικές, αλλά και στη χωρική μορφή του risk map. Το μοντέλο εξακολουθεί να παράγει συνεκτική εκτίμηση κινδύνου, όμως η κατανομή της πιθανότητας δεν ευθυγραμμίζεται το ίδιο καθαρά με το εξωτερικό στόχο αξιολόγησης. Αυτό ενισχύει το βασικό συμπέρασμα του υποκεφαλαίου, ότι το U-Net είναι ισχυρό μοντέλο πυκνής χαρτογράφησης, αλλά για αξιόπιστη χρήση σε διαφορετικά δεδομένα απαιτείται domain adaptation, fine-tuning και επαναβαθμολόγηση.

Η συμπεριφορά αυτή δεν ακυρώνει την αξία του U-Net. Αντίθετα, δείχνει ένα κρίσιμο σημείο για την επιχειρησιακή χρήση βαθιών μοντέλων στην πρόβλεψη πυρκαγιών: η καλή εσωτερική επίδοση δεν εγγυάται αυτόματη μεταφορά σε νέο σύνολο δεδομένων. Ένα βαθύ μοντέλο μπορεί να μάθει πολύ αποτελεσματικά τα μοτίβα του αρχικού πεδίου, αλλά όταν αλλάζει το target domain χρειάζεται εναρμόνιση χαρακτηριστικών, fine-tuning και επαναρύθμιση κατωφλίων. Ο FWI, επειδή είναι φυσικός δείκτης και όχι εκπαιδευμένο μοντέλο πάνω σε συγκεκριμένη κατανομή, μπορεί σε ορισμένες περιπτώσεις να εμφανίζεται πιο σταθερός σε εξωτερική μεταφορά.

5.5.4 Συμπεράσματα U-Net

Συνολικά, το U-Net αποτέλεσε το ισχυρότερο μοντέλο για την πυκνή ημερήσια χαρτογράφηση κινδύνου στο βασικό σύνολο δεδομένων της εργασίας. Η αρχιτεκτονική encoder-decoder επέτρεψε στο μοντέλο να συνδυάσει ευρύτερο χωρικό πλαίσιο με λεπτομερή τοπική πληροφορία, παράγοντας χάρτες πιθανότητας σε επίπεδο κελιού.

Τα υψηλά αποτελέσματα σε PR-AUC, ROC-AUC, precision, recall και F1 δείχνουν ότι το μοντέλο μπορεί να εντοπίζει αποτελεσματικά fire pixels. Ωστόσο, τα αποτελέσματα αυτά πρέπει να ερμηνεύονται με βάση δύο βασικούς περιορισμούς. Πρώτον, το βασικό U-Net χρησιμοποιεί επταήμερο παράθυρο που καταλήγει στην ημέρα-στόχο, άρα η διατύπωση αφορά same-day wildfire risk estimation και όχι αυστηρό next-day forecasting (πρόβλεψη επόμενης μέρας). Δεύτερον, το βασικό σύνολο

δεδομένων έχει εμπλουτιστεί με βάση τα συμβάντα πυρκαγιάς, με αποτέλεσμα να παρουσιάζει υψηλότερη αναλογία θετικών περιπτώσεων από ένα πλήρες επιχειρησιακό raster σύνολο δεδομένων.

Η προσθήκη MC Dropout και residual-cVAE ενίσχυσε περαιτέρω το μοντέλο, επειδή επέτρεψε την παραγωγή όχι μόνο χαρτών κινδύνου αλλά και χαρτών αβεβαιότητας. Έτσι, το U-Net δεν λειτουργεί απλώς ως μοντέλο εκτίμησης πιθανότητας, αλλά ως εργαλείο υποστήριξης απόφασης που μπορεί να δείχνει πού υπάρχει αυξημένος κίνδυνος και πόσο αξιόπιστη είναι αυτή η εκτίμηση.

Η εξωτερική αξιολόγηση στο FireCube έδειξε ότι η μεταφορά σε νέο πεδίο δεδομένων είναι απαιτητική. Η zero-shot εφαρμογή δεν ήταν επαρκής, ενώ το fine-tuning βελτίωσε ουσιαστικά την ικανότητα κατάταξης κινδύνου του μοντέλου. Συνεπώς, το βασικό συμπέρασμα δεν είναι ότι το U-Net γενικεύει αυτόματα σε κάθε επιχειρησιακό περιβάλλον, αλλά ότι αποτελεί ισχυρή αρχιτεκτονική χωρικής χαρτογράφησης, η οποία χρειάζεται domain adaptation και επαναβαθμονόμηση όταν μεταφέρεται σε διαφορετικά δεδομένα.

Πίνακας 5.1 Αποτελέσματα διάφορων εκδοχών U-Net

U-Net πείραμα	Σενάριο αξιολόγησης	ROC-AUC	PR-AUC	Precision	Recall	F1-score
U-Net deterministic	Same-day pixel-level risk estimation	0.9990	0.9664	0.9819	1.0000	0.9909
U-Net MC Dropout	Same-day pixel-level risk estimation με αβεβαιότητα	0.9992	0.9668	0.9819	1.0000	0.9909
U-Net masked improved	Same-day masked αξιολόγηση	0.9640	0.8560	0.7076	0.8557	0.7740
U-Net zone evaluation	Zone-mask αξιολόγηση	0.7820	0.4360	-	-	0.5520
Decision-aware U-Net	Selective/decision-aware αξιολόγηση	0.9992	0.9665	0.9715	0.7421	0.8415

5.6 ConvNeXt και υβριδικό ConvNeXt - Unet

Ο ConvNeXt είναι μια σύγχρονη αρχιτεκτονική που συνδυάζει τις ιδέες των κλασικών ConvNets με αυτές των Vision Transformers. Η βασική του λογική είναι να ανασχεδιάσει τον τρόπο με τον οποίο οργανώνονται τα συνελκτικά blocks, η κανονικοποίηση και η χωρική επεξεργασία. Αυτό επιτυγχάνεται με τη χρήση μεγαλύτερων πυρήνων, inverted bottleneck σχεδίασης, GELU ενεργοποιήσεων, layer normalization και απλοποιημένης ιεραρχικής δομής [19].

Χρησιμοποιήθηκε ως ενδιάμεση επιλογή ανάμεσα στα κλασικά συνελκτικά μοντέλα και τους Transformers. Η επιλογή του είχε συγκεκριμένη λογική: οι πυρκαγιές εμφανίζονται ως χωρικά οργανωμένα μοτίβα κινδύνου, άρα ένα μοντέλο που διατηρεί τη συνελκτική επεξεργασία μπορεί να είναι πιο σταθερό από έναν καθαρό Transformer σε μικρά ή ανισόρροπα δεδομένα. Ταυτόχρονα, επειδή ο ConvNeXt διαθέτει πιο μοντέρνα blocks από ένα κλασικό CNN, μπορεί να μάθει πιο πλούσιες ιεραρχικές χωρικές αναπαραστάσεις.

Σε επίπεδο εισόδου, τροφοδοτήθηκε με την ίδια λογική πολυκαναλικών χωρικών πλεγμάτων που χρησιμοποιήθηκε και στα υπόλοιπα βαθιά μοντέλα. Δεν λειτουργεί πάνω σε φυσικές εικόνες, αλλά πάνω σε μετεωρολογικούς χάρτες πολλών καναλιών. Αυτό σημαίνει ότι ο ConvNeXt έχει τη δυνατότητα να επεξεργαστεί και να μάθει από χωρικές σχέσεις.

Το ConvNeXt χρησιμοποιήθηκε αρχικά ως ισχυρός χωρικός ταξινομητής για να ελεγχθεί αν μια πιο σύγχρονη αρχιτεκτονική μπορεί να μάθει καλύτερα τα χωρικά μοτίβα κινδύνου από ένα απλούστερο CNN. Η κύρια δύναμή του είναι ότι εξάγει ιεραρχικά χαρακτηριστικά: στα πρώτα επίπεδα μαθαίνει μικρές τοπικές μεταβολές, ενώ στα βαθύτερα επίπεδα μπορεί να συλλάβει πιο σύνθετες χωρικές δομές.

Παρά τα πλεονεκτήματά του, το καθαρό ConvNeXt δεν είναι από μόνο του ιδανικό για πλήρη πυκνή χαρτογράφηση κινδύνου. Αν χρησιμοποιηθεί κυρίως ως ταξινομητής, μπορεί να συμπυκνώσει υπερβολικά τη χωρική πληροφορία και να δυσκολευτεί να επαναφέρει με ακρίβεια την τελική έξοδο. Για τον λόγο αυτό εξετάστηκε και το υβριδικό σχήμα ConvNeXt - UNet.

Στο υβριδικό ConvNeXt - UNet, ο ConvNeXt χρησιμοποιείται ως encoder/backbone. Από τη μία, ο ConvNeXt παρέχει ισχυρή, βαθιά και ιεραρχική αναπαράσταση των μετεωρολογικών πλεγμάτων. Από την άλλη, ο U-Net αποκωδικοποιητής επιτρέπει την παραγωγή λεπτομερούς χάρτη πιθανότητας πυρκαγιάς σε επίπεδο κελιού. Έτσι, το μοντέλο δεν περιορίζεται σε μια συνολική εκτίμηση κινδύνου, αλλά διατηρεί την ικανότητα παραγωγής χάρτη κινδύνου.

Στα πειράματα της εργασίας, το υβριδικό ConvNeXt - UNet έδωσε πολύ ισχυρή επίδοση στο same-day 0.25° σενάριο. Συγκεκριμένα, πέτυχε ROC-AUC 0.970, PR-AUC 0.895 και F1-score 0.807, με ποσοστό θετικής κλάσης 18.8%. Τα αποτελέσματα αυτά δείχνουν ότι το υβριδικό μοντέλο αξιοποίησε αποτελεσματικά τόσο τη χωρική αναπαράσταση του ConvNeXt όσο και την πυκνή ανακατασκευή του U-Net decoder.

Παράλληλα, έγινε και zone-mask αξιολόγηση για το καθαρό ConvNeXt, με σύγκριση απέναντι στον FWI baseline. Η αξιολόγηση αυτή είναι χρήσιμη επειδή ελέγχει τη συμπεριφορά του μοντέλου σε χωρικές ζώνες ενδιαφέροντος και όχι απλώς σε όλα τα pixels. Τα αποτελέσματα δείχνουν ότι η συμπεριφορά του ConvNeXt εξαρτάται έντονα από το πεδίο αξιολόγησης.


Στο κεντρικό σύνολο δεδομένων για την περίοδο 2023 - 2025, το ConvNeXt πέτυχε PR-AUC 0.247 και ROC-AUC 0.606. Ο FWI baseline στο ίδιο σενάριο είχε PR-AUC 0.263 και ROC-AUC 0.563. Αυτό σημαίνει ότι το ConvNeXt είχε ελαφρώς χαμηλότερη απόδοση στο precision - recall πεδίο, αλλά καλύτερη διακριτική ικανότητα στο ROC.

Στο FireCube στόχος, η εικόνα ήταν πιο αδύναμη για το ConvNeXt. Το μοντέλο πέτυχε PR-AUC 0.161 και ROC-AUC 0.332, ενώ ο FWI baseline πέτυχε PR-AUC 0.400 και ROC-AUC 0.740. Το αποτέλεσμα αυτό δείχνει ότι η απευθείας μεταφορά του καθαρού ConvNeXt σε εξωτερικό πεδίο δεδομένων δεν ήταν επιτυχής. Το μοντέλο δεν κατάφερε να διατηρήσει σταθερή κατάταξη κινδύνου όταν άλλαξε η κατανομή των δεδομένων, η χωρική ανάλυση και ο τρόπος κατασκευής του στόχου. Αυτό είναι τυπικό σύμπτωμα domain shift, ένα μοντέλο που έχει μάθει σύνθετες αναπαραστάσεις στην αρχική του εκπαίδευση μπορεί να χάσει την αποτελεσματικότητά του όταν εφαρμοστεί σε διαφορετικό πεδίο δεδομένων χωρίς κατάλληλη προσαρμογή.


Πίνακας 5.2 Αποτελέσματα διάφορων εκδοχών ConvNext

Μοντέλο / Baseline	Target	ROC-AUC	PR-AUC
ConvNeXt	CSV holdout 2023 - 2025	0.606	0.247
FWI baseline	CSV holdout 2023 - 2025	0.563	0.263
ConvNeXt	FireCube target	0.332	0.161
FWI baseline	FireCube target	0.740	0.400

Τα αποτελέσματα αυτά οδηγούν σε δύο συμπεράσματα. Πρώτον, το καθαρό ConvNeXt έχει χρήσιμη διακριτική ικανότητα στο συγγενές CSV holdout, αλλά δεν είναι από μόνο του αρκετό για σταθερή εξωτερική μεταφορά. Δεύτερον, το υβριδικό ConvNeXt - UNet είναι πιο κατάλληλο για το βασικό πρόβλημα της εργασίας, επειδή συνδυάζει τον ισχυρό encoder με decoder πυκνής χωρικής πρόβλεψης. Η διαφορά αυτή είναι σημαντική: το ConvNeXt ως backbone μαθαίνει καλά χαρακτηριστικά, αλλά το U-Net τμήμα είναι αυτό που επιτρέπει να μετατραπούν αυτά τα χαρακτηριστικά σε χρήσιμο χωρικό χάρτη κινδύνου.



Σχήμα 5.3 Καμπύλες Precision - Recall για την zone-mask αξιολόγηση του ConvNeXt



Σχήμα 5.4 Καμπύλες ROC για την zone-mask αξιολόγηση του ConvNeXt

Συνολικά, ο ConvNeXt και το υβριδικό ConvNeXt - UNet προσθέτουν στην εργασία ένα ενδιάμεσο αρχιτεκτονικό επίπεδο μεταξύ κλασικών CNN, U-Net και Transformer. Ο ConvNeXt διατηρεί τη σταθερότητα και την τοπική χωρική προκατάληψη των συνελκτικών δικτύων, αλλά με πιο σύγχρονη σχεδίαση. Το ConvNeXt - UNet αξιοποιεί αυτή τη δυνατότητα ως encoder και την ενώνει με τη χωρική ακρίβεια του U-Net decoder. Για τον λόγο αυτό, το υβριδικό μοντέλο αποτελεί πιο ολοκληρωμένη λύση για πυκνή χαρτογράφηση κινδύνου, ενώ το καθαρό ConvNeXt λειτουργεί περισσότερο ως χρήσιμο πείραμα ελέγχου της μεταφερσιμότητας μιας σύγχρονης συνελκτικής αναπαράστασης.

5.7 MiniRocket και υβριδικό MiniRocket για χρονική κατάταξη κινδύνου

Στο τελευταίο μέρος των χωροχρονικών πειραμάτων εξετάστηκε η χρήση του MiniRocket ως υπολογιστικά ελαφριάς μεθόδου ταξινόμησης χρονοσειρών. Η επιλογή αυτή έγινε επειδή το πρόβλημα της πρόβλεψης πυρκαγιάς δεν έχει μόνο χωρική διάσταση, αλλά και καθαρά χρονική. Για κάθε κελί του πλέγματος υπάρχει μια μικρή ακολουθία ημερών, μέσα στην οποία μεταβάλλονται η θερμοκρασία, το σημείο δρόσου, η βροχόπτωση, ο άνεμος, ο FWI, το KBDI, το PET και οι δείκτες ξηρασίας. Επομένως, κάθε κελί μπορεί να αντιμετωπιστεί όχι μόνο ως σημείο ενός χάρτη, αλλά και ως πολυμεταβλητή χρονοσειρά επτά ημερών.

Στην υλοποίηση, το MiniRocket εφαρμόστηκε σε επίπεδο κελιού. Για κάθε χωρικό κελί, οι επτά ημέρες εισόδου οργανώθηκαν ως πολυμεταβλητή χρονοσειρά. Δηλαδή, αντί το μοντέλο να βλέπει ολόκληρο τον χάρτη όπως το U-Net, βλέπει την εξέλιξη των χαρακτηριστικών ενός συγκεκριμένου σημείου στον χρόνο. Η είσοδος περιλαμβάνει τις ίδιες βασικές μεταβλητές που χρησιμοποιήθηκαν στα υπόλοιπα μοντέλα, όπως t2m, d2m, u10, v10, tp, FWI, KBDI, PET, D και SPEI. Με αυτόν τον τρόπο, το MiniRocket ελέγχει αν η χρονική εξέλιξη των μετεωρολογικών συνθηκών σε ένα σημείο αρκεί για να παραχθεί χρήσιμος δείκτης κινδύνου.

Η διαδικασία ήταν διαφορετική από αυτή των CNN μοντέλων. Το MiniRocket δεν εκπαιδεύει βαθιά επίπεδα, δεν χρησιμοποιεί αποκωδικοποίηση και δεν παράγει από μόνο του χωρικό χάρτη μέσω συνελκτικής ανακατασκευής. Αντίθετα, εφαρμόζει έναν μεγάλο αριθμό σταθερών μονοδιάστατων συνελκτικών πυρήνων πάνω στις χρονοσειρές και εξάγει χαρακτηριστικά με βάση τη μορφή της χρονικής απόκρισης. Στη συνέχεια, τα χαρακτηριστικά αυτά εισάγονται σε έναν απλό γραμμικό ταξινομητή, όπως ridge classifier ή logistic regression. Η απλότητα αυτή είναι το βασικό πλεονέκτημα του MiniRocket: το μοντέλο είναι πολύ γρήγορο, σχετικά σταθερό και εύκολο να επανεκπαιδευτεί σε νέο σύνολο δεδομένων.

Για το βασικό same-day σενάριο 0,25°, το MiniRocket πέτυχε ROC-AUC περίπου 0.950 και PR-AUC περίπου 0.600. Σε αξιολόγηση με κατώφλι, η precision ήταν περίπου 0.650, η recall περίπου 0.520 και το F1-score περίπου 0.580, με θετική κλάση περίπου 18.8%. Τα αποτελέσματα αυτά δείχνουν ότι το MiniRocket μαθαίνει ουσιαστικό χρονικό σήμα από τις επταήμερες ακολουθίες, αλλά η ανίχνευση των πραγματικών fire pixels παραμένει δυσκολότερη σε σχέση με τα χωρικά μοντέλα. Η σχετικά χαμηλότερη recall δείχνει ότι το μοντέλο χάνει μέρος των πραγματικών συμβάντων, κάτι αναμενόμενο επειδή δεν αξιοποιεί άμεσα τη γειτονική χωρική πληροφορία.

Πίνακας 5.3 Αποτελέσματα MiniRocket

Μοντέλο	Σενάριο	ROC-AUC	PR-AUC	Precision	Recall	F1-score	Positive rate
MiniRocket	Same-day 0.25°	0.950	0.600	0.650	0.520	0.580	18.8%
Hybrid MiniRocket + ConvNeXt-UNet	Same-day 0.25°	0.974	0.900	0.850	0.770	0.810	18.8%

Το MiniRocket εξετάστηκε επίσης στο πλαίσιο του FireCube, δηλαδή σε πιο αυστηρό εξωτερικό σύνολο δεδομένων με έντονο domain shift και ακραία ανισορροπία. Στο εναρμονισμένο υποσύνολο 2018-2021, το Hybrid MiniRocket έδωσε PR-AUC περίπου 0.0096 και ROC-AUC περίπου 0.822. Το αποτέλεσμα αυτό δείχνει ότι το μοντέλο μπορούσε να παράγει κάποια χρήσιμη κατάταξη κινδύνου ακόμη και σε δύσκολο εξωτερικό domain. Ωστόσο, οι απόλυτες τιμές precision παρέμειναν χαμηλές

λόγω της πολύ μικρής συχνότητας θετικών pixels στο FireCube. Στην αξιολόγηση στο ανώτερο 1% των προβλέψεων, το MiniRocket πέτυχε precision περίπου 1.39%, δηλαδή αρκετά υψηλότερο από το base rate, αλλά όχι αρκετό για να αποτελέσει αυτοτελές επιχειρησιακό μοντέλο. Σε συγκεκριμένο κατώφλι πέτυχε precision περίπου 4.5%, όμως η recall ήταν μόλις περίπου 1.36%. Με χαμηλότερα κατώφλια η recall μπορούσε να αυξηθεί έως περίπου 27%, αλλά με αντίστοιχη πτώση της precision.

Ο βασικός λόγος που το MiniRocket τελικά δεν επιλέχθηκε ως κύρια λύση είναι ότι δεν αξιοποιεί τη χωρική δομή του προβλήματος. Η πυρκαγιά δεν είναι απλώς αποτέλεσμα της χρονικής εξέλιξης ενός μεμονωμένου κελιού. Εξαρτάται και από τη γύρω χωρική περιοχή, από γειτονικά μοτίβα ξηρότητας, από περιφερειακές συνθήκες ανέμου και από ευρύτερες ζώνες υψηλού πυρομετεωρολογικού κινδύνου. Επειδή το MiniRocket αντιμετωπίζει κάθε pixel κυρίως ως ανεξάρτητη χρονοσειρά, χάνει αυτή τη χωρική συνέχεια. Έτσι, μπορεί να αναγνωρίζει αν ένα κελί έχει επικίνδυνο πρόσφατο ιστορικό, αλλά δεν μπορεί να κατασκευάσει με την ίδια συνέπεια έναν χωρικά ομαλό και επιχειρησιακά χρήσιμο χάρτη κινδύνου.

5.8 Συγκριτική αποτίμηση των αρχιτεκτονικών

Η συγκριτική αποτίμηση των αρχιτεκτονικών δείχνει ότι κανένα μοντέλο δεν υπερέχει απόλυτα σε όλα τα σενάρια. Κάθε προσέγγιση εμφανίζει διαφορετικά δυνατά σημεία, ανάλογα με τον ορισμό του προβλήματος, τη μορφή της εισόδου, το επίπεδο ανισορροπίας και το είδος της αξιολόγησης.

Ο Spatio-Temporal ViT παρουσίασε πολύ υψηλό ROC-AUC, γεγονός που δείχνει ισχυρή ικανότητα διάκρισης μεταξύ fire και no-fire pixels. Ωστόσο, το χαμηλότερο PR-AUC σε σχέση με το U-Net δείχνει ότι, σε συνθήκες έντονης ανισορροπίας, η απόδοσή του στη θετική κλάση ήταν πιο περιορισμένη. Αυτό είναι αναμενόμενο, καθώς τα transformer-based μοντέλα χρειάζονται συνήθως μεγαλύτερο όγκο δεδομένων και είναι πιο ευαίσθητα στην κατανομή των θετικών παραδειγμάτων.

Το U-Net deterministic εμφάνισε την υψηλότερη απόδοση στην αρχική pixel-level αξιολόγηση, με PR-AUC περίπου 0.966 και ROC-AUC περίπου 0.999. Στο συγκεκριμένο πειραματικό σενάριο πέτυχε precision 0.9819, recall 1.0 και F1-score 0.9909, δείχνοντας ότι μπορεί να αποδώσει πολύ καλά στη λεπτομερή χωρική χαρτογράφηση κινδύνου. Ωστόσο, όπως αναφέρθηκε προηγουμένως, τα αποτελέσματα αυτά αφορούν το συγκεκριμένο πλαίσιο εκτίμησης κινδύνου για την ίδια ημέρα και το συγκεκριμένο σύνολο δεδομένων, και δεν πρέπει να ερμηνεύονται ως άμεση απόδειξη επιχειρησιακής πρόγνωσης για την επόμενη ημέρα.

Η εκδοχή U-Net με Monte Carlo Dropout διατήρησε πρακτικά την ίδια απόδοση με το deterministic U-Net, με ελαφρά βελτίωση στο ROC-AUC και στο PR-AUC. Η βασική της συνεισφορά δεν ήταν η αύξηση της ακρίβειας, αλλά η παραγωγή χαρτών αβεβαιότητας. Με αυτόν τον τρόπο, το μοντέλο δεν παρέχει μόνο πιθανότητα κινδύνου, αλλά και ένδειξη για το πόσο σταθερή είναι η εκτίμηση.

Το U-Net masked improved αποτελεί πιο ρεαλιστική εκδοχή αξιολόγησης σε σχέση με την αρχική pixel-level αξιολόγηση. Εκεί οι μετρικές μειώθηκαν, με PR-AUC 0.856 και F1-score 0.774, αλλά παρέμειναν ισχυρές. Η πτώση αυτή είναι χρήσιμη, γιατί δείχνει ότι η αρχική σχεδόν τέλεια pixel-level απόδοση δεν πρέπει να ερμηνεύεται απομονωμένα. Όταν η αξιολόγηση γίνεται πιο κοντά σε επιχειρησιακό πλαίσιο, η εικόνα γίνεται πιο συγκρατημένη αλλά ακόμη θετική.

Η zone-mask αξιολόγηση του U-Net στο CSV holdout 2023–2025 έδωσε ROC-AUC 0.782 και PR-AUC 0.436. Οι τιμές αυτές είναι χαμηλότερες από τις αρχικές pixel-level μετρικές, αλλά είναι πιο ενδεικτικές για το πώς συμπεριφέρεται το μοντέλο όταν αξιολογείται σε χωρικές ζώνες ενδιαφέροντος

και όχι σε κάθε pixel μεμονωμένα. Το αποτέλεσμα δείχνει ότι το U-Net παραμένει χρήσιμο για χωρική κατάταξη κινδύνου, αλλά η απόδοσή του εξαρτάται από το πρωτόκολλο αξιολόγησης.

Το υβριδικό ConvNeXt-UNet παρουσίασε ισχυρή συνολική απόδοση, με ROC-AUC 0.970, PR-AUC 0.895 και F1-score περίπου 0.807. Το αποτέλεσμα αυτό δείχνει ότι η χρήση ConvNeXt ως ισχυρού συνελκτικού backbone μπορεί να ενισχύσει την αναπαράσταση χωρικών χαρακτηριστικών. Ωστόσο, επειδή το συγκεκριμένο σχήμα χρησιμοποιεί διαφορετικό task formulation, ειδικά όταν περιλαμβάνει current_fire, fire history ή fire neighbours, πρέπει να ερμηνεύεται ως διαφορετικό πρόβλημα από το βασικό same-day U-Net.

Το Hybrid MiniRocket πέτυχε επίσης πολύ ισχυρή απόδοση, με ROC-AUC 0.974, PR-AUC 0.900 και F1-score περίπου 0.810. Η επίδοση αυτή είναι ιδιαίτερα σημαντική, επειδή δείχνει ότι μια πιο ελαφριά προσέγγιση χρονοσειρών μπορεί να ανταγωνιστεί πιο σύνθετες βαθιές αρχιτεκτονικές σε συγκεκριμένα σενάρια. Το MiniRocket δεν παρέχει την ίδια χωρική ερμηνευσιμότητα ή χαρτογράφηση αβεβαιότητας με το U-Net, αλλά αποτελεί ισχυρή επιλογή όταν ο στόχος είναι κυρίως η κατάταξη κινδύνου με χαμηλότερο υπολογιστικό κόστος.

Συνολικά, η επιλογή αρχιτεκτονικής εξαρτάται από τον επιδιωκόμενο στόχο. Αν προέχει η πυκνή χωρική χαρτογράφηση και η παραγωγή χάρτη κινδύνου σε επίπεδο pixel, το U-Net είναι η κατάλληλη επιλογή στο βασικό σύνολο δεδομένων. Αν προέχει η αξιοποίηση ευρύτερων χωρικών ή κλιματικών μοτίβων, ο ViT προσφέρει χρήσιμη εναλλακτική, αν και εμφανίζει μεγαλύτερη ευαισθησία στην ανισορροπία. Αν ζητείται ισχυρό συνελκτικό backbone με καλή γενίκευση, το ConvNeXt-UNet αποτελεί ανταγωνιστική λύση. Τέλος, αν ο στόχος είναι αποδοτική χρονική κατάταξη κινδύνου με μικρότερο κόστος, το Hybrid MiniRocket εμφανίζεται ιδιαίτερα αποτελεσματικό.

Πίνακας 5.4 Συλλογικά αποτελέσματα

Μοντέλο	Κύριο σενάριο αξιολόγησης	ROC-AUC	PR-AUC	Βασική παρατήρηση
Spatio-Temporal ViT	Εσωτερική pixel-level αξιολόγηση	0.9987	0.8640	Ισχυρή διάκριση, χαμηλότερη PR από U-Net
U-Net deterministic	Same-day pixel-level risk estimation	0.9990	0.9664	Καλύτερη αρχική pixel-level απόδοση
U-Net MC Dropout	Same-day risk estimation με αβεβαιότητα	0.9992	0.9668	Διατηρεί απόδοση και προσθέτει uncertainty maps
U-Net masked improved	Same-day masked αξιολόγηση	0.9640	0.8560	Πιο ρεαλιστική αλλά χαμηλότερη απόδοση
U-Net zone-mask	CSV holdout 2023–2025	0.7820	0.4360	Έλεγχος χωρικής κατάταξης σε ζώνες
ConvNeXt-UNet Hybrid	Hybrid spatial/deep αξιολόγηση	0.9700	0.8950	Ισχυρό CNN backbone, διαφορετική διατύπωση προβλήματος
Hybrid MiniRocket	Time-series risk ranking	0.9740	0.9000	Πολύ καλή κατάταξη με χαμηλότερη πολυπλοκότητα

6 Επεξηγησιμότητα, αβεβαιότητα και αξιοπιστία των προβλέψεων

6.1 Εισαγωγή στην επεξηγησιμότητα και την αξιοπιστία των προβλέψεων

Η πρόβλεψη πυρκαγιών με χρήση μοντέλων βαθιάς μάθησης δεν αξιολογείται μόνο με βάση αριθμητικές μετρικές απόδοσης. Σε προβλήματα όπως η εκτίμηση κινδύνου πυρκαγιάς, ο στόχος δεν είναι απλώς η παραγωγή ενός χάρτη πιθανότητας. Ο στόχος είναι να ελεγχθεί αν η πρόβλεψη βασίζεται σε λογικούς παράγοντες, αν η κατανομή του κινδύνου έχει νόημα και αν το μοντέλο είναι βέβαιο για τις περιοχές που χαρακτηρίζει ως υψηλού κινδύνου.

Για αυτόν τον λόγο, η επεξηγησιμότητα και η αβεβαιότητα είναι πολύ σημαντικές σε αυτή την εργασία. Στα προηγούμενα κεφάλαια, εξετάστηκαν διάφορες αρχιτεκτονικές για την πρόβλεψη πυρκαγιάς, όπως U-Net, Spatio-Temporal ViT, ConvNeXt, υβριδικό ConvNeXt-UNet και MiniRocket. Αυτά τα μοντέλα παράγουν διαφορετικές εξόδους και έχουν διαφορετική εσωτερική λειτουργία.

Το U-Net παράγει πυκνούς χάρτες πιθανότητας. Το ViT χρησιμοποιεί μηχανισμό αυτοπροσοχής για χωροχρονικές συσχετίσεις. Το ConvNeXt και το υβριδικό ConvNeXt-UNet βασίζονται σε συνελικτική αναπαράσταση. Ανεξάρτητα από την αρχιτεκτονική, υπάρχει ένα βασικό ερώτημα: ποιοι παράγοντες οδηγούν το μοντέλο να χαρακτηρίσει μια περιοχή ως επικίνδυνη;

Για να απαντηθεί αυτό το ερώτημα, χρησιμοποιήθηκαν πολλαπλές τεχνικές επεξηγησιμότητας. Οι τεχνικές αυτές εφαρμόστηκαν μετά την εκπαίδευση των μοντέλων, χωρίς να αλλάξει η αρχιτεκτονική τους. Συγκεκριμένα, χρησιμοποιήθηκαν μέθοδοι όπως SHAP, LIME, Grad-CAM, Integrated Gradients, Gradient $\times$ Input, Saliency maps και Occlusion.

Η χρήση πολλών μεθόδων ήταν απαραίτητη, επειδή κάθε τεχνική ερμηνεύει διαφορετική πλευρά του μοντέλου. Ορισμένες μέθοδοι παρέχουν μια συνολική κατάταξη σπουδαιότητας των χαρακτηριστικών (global feature importance), ενώ άλλες προσφέρουν τοπική ερμηνεία, αναδεικνύοντας τους παράγοντες που καθόρισαν μια συγκεκριμένη πρόβλεψη. Επιπλέον, υπάρχουν μέθοδοι που επιτρέπουν τη χωρική αποτύπωση των περιοχών που επηρέασαν καθοριστικά το τελικό αποτέλεσμα.

Η ανάλυση πραγματοποιήθηκε στο κύριο σύνολο δεδομένων και στο εξωτερικό FireCube. Αυτή η διάκριση είναι σημαντική, επειδή επιτρέπει να εξεταστεί αν οι εξηγήσεις παραμένουν σταθερές όταν αλλάζει το πεδίο εφαρμογής.

Στο αρχικό σύνολο δεδομένων, οι μέθοδοι επεξηγησιμότητας ανέδειξαν κυρίως παράγοντες όπως η θερμοκρασία αέρα, το σημείο δρόσου, η δυνητική εξατμισοδιαπνοή, ο FWI, οι δείκτες ξηρασίας και η εποχικότητα. Στο FireCube, η εικόνα εμπλουτίστηκε με επιπλέον παράγοντες, όπως η κλίση εδάφους, το υψόμετρο, η κάλυψη γης, η απόσταση από δρόμους και οι δείκτες βλάστησης.

Επιπλέον, εξετάστηκε και η αξιοπιστία των εξόδων. Ένας χάρτης κινδύνου είναι χρήσιμος μόνο όταν οι πιθανότητες που παράγει μπορούν να ερμηνευτούν με εμπιστοσύνη. Για τον λόγο αυτό, εφαρμόστηκαν τεχνικές εκτίμησης αβεβαιότητας, όπως Monte Carlo Dropout και residual conditional VAE.

Η επεξηγησιμότητα, η αβεβαιότητα και η βαθμονόμηση είναι τρεις συμπληρωματικοί άξονες. Η επεξηγησιμότητα απαντά στο ερώτημα «γιατί το μοντέλο προβλέπει υψηλό κίνδυνο». Η αβεβαιότητα απαντά στο ερώτημα «πόσο σταθερή είναι αυτή η πρόβλεψη». Η βαθμονόμηση απαντά στο ερώτημα «αν η πιθανότητα που δίνει το μοντέλο μπορεί να χρησιμοποιηθεί ως αξιόπιστη εκτίμηση κινδύνου».

Ο συνδυασμός αυτών των τριών επιπέδων μετατρέπει το μοντέλο από απλό εργαλείο πρόβλεψης σε ολοκληρωμένο σύστημα ανάλυσης και υποστήριξης αποφάσεων.

6.2 Τεχνικές επεξηγησιμότητας που εφαρμόστηκαν

Στην εργασία εφαρμόστηκαν τεχνικές SHAP, LIME-like local surrogates, Grad-CAM, Integrated Gradients, Gradient $\times$ Input, Saliency maps και Occlusion. Οι μέθοδοι αυτές χρησιμοποιήθηκαν κυρίως για την ανάλυση των U-Net, ViT, ConvNeXt και ConvNeXt-UNet, αλλά και για τη σύγκριση της συμπεριφοράς των μοντέλων μεταξύ του βασικού συνόλου δεδομένων και του εξωτερικού FireCube. Με αυτόν τον τρόπο, η επεξηγησιμότητα δεν χρησιμοποιήθηκε μόνο ως εργαλείο παρουσίασης, αλλά και ως τρόπος ελέγχου του αν τα μοντέλα βασίζονται σε φυσικά εύλογες μεταβλητές.

Το SHAP χρησιμοποιήθηκε για την εκτίμηση της συνολικής σημασίας των χαρακτηριστικών. Η βασική ιδέα είναι ότι κάθε πρόβλεψη μπορεί να αναλυθεί ως άθροισμα επιμέρους συνεισφορών των μεταβλητών εισόδου. Στο πλαίσιο της εργασίας, το SHAP βοήθησε να εντοπιστούν τα χαρακτηριστικά που επηρεάζουν περισσότερο τη συνολική συμπεριφορά του μοντέλου, όπως η θερμοκρασία αέρα στα 2 μέτρα, το σημείο δρόσου, η δυνητική εξατμισοδιαπνοή, ο FWI, οι δείκτες ξηρασίας και η εποχικότητα. Επιπλέον, οι χωρικοί SHAP χάρτες χρησιμοποιήθηκαν για να φανεί αν η συνεισφορά των χαρακτηριστικών συγκεντρώνεται σε περιοχές με πραγματικό ενδιαφέρον ή αν εμφανίζεται τυχαία στο πλέγμα [44].

Οι τοπικοί επεξηγητές τύπου LIME εφαρμόστηκαν σε μεμονωμένες προβλέψεις, ώστε να εξεταστεί η επίδραση κάθε χαρακτηριστικού μέσα στο χρονικό παράθυρο των 7 ημερών. Τα αποτελέσματα παρουσιάστηκαν ως heatmaps χρόνου $\times$ χαρακτηριστικών, επιτρέποντας την ανάλυση όχι μόνο του ποια μεταβλητή ήταν σημαντική, αλλά και σε ποια χρονική στιγμή επηρέασε περισσότερο την πρόβλεψη [36].

Για τα βαθιά χωρικά μοντέλα εφαρμόστηκαν Grad-CAM, Integrated Gradients, Gradient $\times$ Input και Saliency maps. Οι τεχνικές αυτές παρήγαγαν χωρικούς χάρτες σημαντικότητας, οι οποίοι χρησιμοποιήθηκαν για να εξεταστεί σε ποιες περιοχές του πλέγματος εστίαζαν τα μοντέλα κατά την πρόβλεψη υψηλού κινδύνου. Το Grad-CAM εφαρμόστηκε κυρίως σε συνελκτικά επίπεδα του U-Net και του ConvNeXt-UNet, ενώ τα Integrated Gradients και τα Saliency maps χρησιμοποιήθηκαν για λεπτομερέστερη ανάλυση της ευαισθησίας της πρόβλεψης ως προς τις εισόδους.

Τέλος, η Occlusion χρησιμοποιήθηκε ως πρακτικός έλεγχος ευαισθησίας. Με την απόκρυψη επιλεγμένων περιοχών, χαρακτηριστικών ή χρονικών βημάτων, εξετάστηκε αν η αφαίρεση συγκεκριμένης πληροφορίας μεταβάλλει ουσιαστικά την πιθανότητα πρόβλεψης πυρκαγιάς. Με αυτόν τον τρόπο, η occlusion ανάλυση λειτούργησε συμπληρωματικά προς τις gradient-based τεχνικές.

Συνολικά, η επεξηγησιμότητα δεν χρησιμοποιήθηκε μόνο για την παραγωγή οπτικοποιήσεων, αλλά ως εργαλείο ελέγχου της συμπεριφοράς των μοντέλων. Η σύγκριση διαφορετικών μεθόδων σε μεταβλητές που σχετίζονται με τη θερμοκρασία, την υγρασία, την εξατμιστική ζήτηση, τον άνεμο και την ξηρασία ενισχύει την ερμηνευτική αξιοπιστία των προβλέψεων.


6.3 Καθολική σημασία χαρακτηριστικών στο κύριο σύνολο δεδομένων

Μετά την εφαρμογή των επιμέρους post-hoc τεχνικών, εξετάστηκε η καθολική σημασία των χαρακτηριστικών στο κύριο σύνολο δεδομένων. Ο στόχος αυτής της ανάλυσης ήταν να διαπιστωθεί αν το μοντέλο βασίζεται σε μεταβλητές με φυσική σχέση με την εμφάνιση πυρκαγιάς ή αν η πρόβλεψη επηρεάζεται από τυχαία ή μη ερμηνεύσιμα σήματα. Για τον λόγο αυτό, συγκρίθηκαν οι σημαντικότητες

που προέκυψαν από διαφορετικές μεθόδους επεξηγησιμότητας, κυρίως SHAP, Integrated Gradients, Saliency και LIME-like τοπικές εξηγήσεις.


Η ανάλυση έδειξε ότι το μοντέλο δεν στηρίζεται σε έναν μόνο παράγοντα, αλλά σε συνδυασμό εποχικών, θερμοδυναμικών και πυρομετεωρολογικών μεταβλητών. Στα περισσότερα διαγράμματα σημαντικότητας εμφανίζονται σταθερά υψηλά η εποχικότητα, η θερμοκρασία αέρα, το σημείο δρόσου, η δυνητική εξατμισοδιαπνοή, ο FWI και χαρακτηριστικά που σχετίζονται με τους δείκτες SPEI. Αυτό είναι σημαντικό, επειδή οι συγκεκριμένες μεταβλητές συνδέονται άμεσα ή έμμεσα με τις φυσικές συνθήκες που ευνοούν την ανάφλεξη και τη διατήρηση πυρκαγιάς: υψηλή θερμοκρασία, ξηρή ατμόσφαιρα, αυξημένη εξατμιστική ζήτηση, μειωμένη υγρασία και εποχικότητα της αντιπυρικής περιόδου.

Στο διάγραμμα SHAP feature importance, οι υψηλότερες συνεισφορές εμφανίζονται σε μεταβλητές όπως η εποχικότητα, η θερμοκρασία, το σημείο δρόσου, η δυνητική εξατμισοδιαπνοή και οι δείκτες ξηρασίας. Η παρουσία των μεταβλητών εποχικότητας, όπως οι κυκλικές αναπαραστάσεις της ημέρας του έτους, δείχνει ότι το μοντέλο αξιοποιεί τη χρονική θέση κάθε παρατήρησης μέσα στο έτος. Αυτό είναι αναμενόμενο, καθώς ο κίνδυνος πυρκαγιάς στην Ελλάδα δεν είναι ομοιόμορφος σε όλες τις εποχές, αλλά αυξάνεται κυρίως κατά τους θερμούς και ξηρούς μήνες. Παράλληλα, η υψηλή σημασία της θερμοκρασίας και του σημείου δρόσου δείχνει ότι το μοντέλο συσχετίζει τον κίνδυνο με τις άμεσες ατμοσφαιρικές συνθήκες.



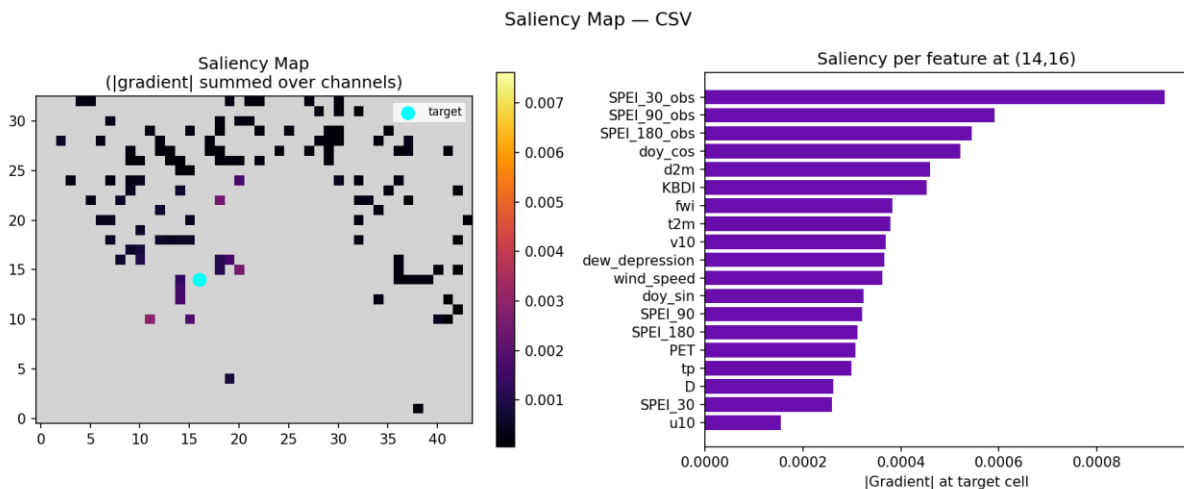
Σχήμα 6.1 SHAP feature importance για το κύριο CSV μοντέλο

Τα Integrated Gradients έδωσαν παρόμοια εικόνα, αλλά με ελαφρώς διαφορετική κατανομή βαρών. Η μέθοδος αυτή είναι χρήσιμη επειδή αποδίδει την πρόβλεψη στα χαρακτηριστικά εισόδου μέσω της ολοκλήρωσης των gradients από μια ουδέτερη είσοδο αναφοράς έως το πραγματικό δείγμα. Στο αντίστοιχο διάγραμμα, σημαντικές εμφανίζονται μεταβλητές που σχετίζονται με τη θερμική κατάσταση της ατμόσφαιρας, τη δυνητική εξατμισοδιαπνοή, τον FWI και τους δείκτες SPEI. Η συμφωνία με το SHAP ενισχύει την αξιοπιστία της ερμηνείας, επειδή δύο διαφορετικές τεχνικές αποδίδουν υψηλή σημασία σε παρόμοιες κατηγορίες χαρακτηριστικών.




Σχήμα 6.2 Integrated Gradients feature importance για το κύριο CSV μοντέλο

Η ανάλυση με Saliency maps προσφέρει διαφορετική οπτική. Ενώ το SHAP και τα Integrated Gradients εκτιμούν τη συνεισφορά των χαρακτηριστικών με πιο συγκεντρωτικό τρόπο, το Saliency δείχνει την τοπική ευαισθησία της εξόδου ως προς μικρές μεταβολές της εισόδου. Τα αποτελέσματα δείχνουν ότι η πρόβλεψη είναι ιδιαίτερα ευαίσθητη σε μεταβλητές που σχετίζονται με ξηρότητα, θερμοκρασία, υγρασία και άνεμο. Αυτό σημαίνει ότι μικρές μεταβολές σε αυτές τις εισόδους μπορούν να επηρεάσουν την εκτιμώμενη πιθανότητα πυρκαγιάς, ειδικά όταν το δείγμα βρίσκεται κοντά σε περιοχή υψηλού κινδύνου.



Εικόνα 6.1 Saliency feature importance για το κύριο CSV μοντέλο

Ιδιαίτερη σημασία έχει το συγκεντρωτικό διάγραμμα feature importance, στο οποίο παρουσιάζονται μαζί τα αποτελέσματα των SHAP, Integrated Gradients, Saliency και LIME-like εξηγήσεων. Το διάγραμμα αυτό δεν πρέπει να διαβαστεί ως απόλυτη κατάταξη, αλλά ως έλεγχος σύγκλισης μεταξύ διαφορετικών μεθόδων. Όταν πολλές μέθοδοι αναδεικνύουν παρόμοιες μεταβλητές, τότε η ερμηνεία θεωρείται πιο σταθερή. Η σύγκλιση γύρω από χαρακτηριστικά όπως η θερμοκρασία, το σημείο δρόσου, η δυνητική εξατμισοδιαπνοή, ο FWI και η εποχικότητα δείχνει ότι το μοντέλο έχει μάθει σχέσεις που είναι φυσικά συμβατές με το φαινόμενο των πυρκαγιών.



Σχήμα 6.3 Συγκεντρωτική σύγκριση feature importance για το κύριο CSV μοντέλο

Η ύπαρξη των SPEI-related χαρακτηριστικών στις πρώτες θέσεις χρειάζεται προσεκτική ερμηνεία. Από τη μία πλευρά, οι δείκτες SPEI εκφράζουν συνθήκες ξηρασίας σε διαφορετικές χρονικές κλίμακες και επομένως έχουν φυσική σχέση με την πιθανότητα πυρκαγιάς. Από την άλλη πλευρά, όταν εμφανίζονται δείκτες πληρότητας των SPEI μεταβλητών, πρέπει να εξετάζεται αν το μοντέλο μαθαίνει πραγματικό περιβαλλοντικό σήμα ή αν αξιοποιεί δομική πληροφορία. Για τον λόγο αυτό, τα αποτελέσματα των SHAP και Integrated Gradients δεν ερμηνεύονται μεμονωμένα, αλλά συνδυάζονται με τοπικές και χωρικές εξηγήσεις στα επόμενα υποκεφάλαια.

Συνολικά, η καθολική ανάλυση χαρακτηριστικών στο κύριο CSV μοντέλο δείχνει ότι οι προβλέψεις βασίζονται κυρίως σε μεταβλητές με σαφή φυσική σημασία. Η θερμοκρασία αέρα και το σημείο δρόσου αποτυπώνουν την άμεση θερμοϋγρομετρική κατάσταση. Η δυνητική εξατμισοδιαπνοή συνδέεται με την ατμοσφαιρική ζήτηση υγρασίας. Ο FWI συμπυκνώνει βασικούς πυρομετεωρολογικούς παράγοντες, όπως θερμοκρασία, υγρασία, άνεμο και βροχόπτωση. Οι δείκτες SPEI προσθέτουν πληροφορία ξηρασίας σε διαφορετικές χρονικές κλίμακες. Η εποχικότητα λειτουργεί ως πλαίσιο που βοηθά το μοντέλο να διακρίνει περιόδους χαμηλού και υψηλού κινδύνου. Επομένως, τα αποτελέσματα της καθολικής επεξηγησιμότητας υποστηρίζουν ότι το μοντέλο δεν βασίζεται σε αυθαίρετα μοτίβα, αλλά σε συνδυασμό μεταβλητών που συνδέονται με τη φυσική λογική του προβλήματος.


6.4 Τοπικές εξηγήσεις σε επίπεδο κελιού και χρονικού παραθύρου

Στην προηγούμενη ενότητα εξετάστηκε η καθολική σημασία των χαρακτηριστικών. Ωστόσο, στην πρόβλεψη πυρκαγιών δεν αρκεί μόνο να γνωρίζουμε ότι μια μεταβλητή είναι γενικά σημαντική, χρειάζεται να εξεταστεί τι συνέβη σε μια συγκεκριμένη πρόβλεψη, για ένα συγκεκριμένο κελί του πλέγματος και για το συγκεκριμένο επταήμερο παράθυρο εισόδου. Για τον λόγο αυτό εφαρμόστηκαν τοπικές τεχνικές επεξήγησης, κυρίως LIME-like local surrogate μοντέλα και heatmaps χρόνου $\times$ χαρακτηριστικών.

Η λογική αυτής της ανάλυσης ήταν να αντιμετωπιστεί κάθε πρόβλεψη όχι μόνο ως τελικό αποτέλεσμα, αλλά ως απόφαση που προκύπτει από συγκεκριμένες μεταβλητές σε συγκεκριμένες ημέρες. Επειδή κάθε δείγμα εισόδου περιλαμβάνει ένα επταήμερο ιστορικό μετεωρολογικών και περιβαλλοντικών

μεταβλητών. Η πρόβλεψη για ένα κελί δεν εξαρτάται μόνο από το ποια χαρακτηριστικά υπάρχουν, αλλά και από το πότε εμφανίζονται.

Για την τοπική ερμηνεία, επιλέχθηκε ένα κελί ενδιαφέροντος, συνήθως κελί με υψηλή προβλεπόμενη πιθανότητα ή πραγματική θετική ετικέτα. Γύρω από αυτό το δείγμα δημιουργήθηκαν παραλλαγές της εισόδου και στη συνέχεια προσαρμόστηκε ένα απλό τοπικό γραμμικό μοντέλο, το οποίο προσεγγίζει τη συμπεριφορά του βαθιού μοντέλου μόνο στη γειτονιά του συγκεκριμένου δείγματος. Από αυτό το τοπικό μοντέλο προέκυψαν βάρη για κάθε χαρακτηριστικό και για κάθε ημέρα του χρονικού παραθύρου. Τα βάρη αυτά οργανώθηκαν σε heatmap, όπου ο οριζόντιος άξονας αντιστοιχεί στις μεταβλητές και ο κατακόρυφος άξονας στις ημέρες του παραθύρου, από t-6 έως t.




Εικόνα 6.2 Τοπική ερμηνεία της πρόβλεψης του U-Net σε άξονα χρόνου και χαρακτηριστικών

Η ανάλυση του τοπικού heatmap δείχνει ότι η μεγαλύτερη συνεισφορά συγκεντρώνεται κυρίως στην πιο πρόσφατη ημέρα, δηλαδή στο t-0. Αυτό σημαίνει ότι το μοντέλο δίνει ιδιαίτερη βαρύτητα στις τρέχουσες ή άμεσα προηγούμενες συνθήκες πριν από την πρόβλεψη. Στο U-Net, οι μεταβλητές που εμφανίζονται εντονότερες είναι κυρίως η θερμοκρασία αέρα στα 2 μέτρα και το σημείο δρόσου. Η συμπεριφορά αυτή είναι φυσικά εύλογη, επειδή οι μεταβλητές αυτές περιγράφουν την άμεση θερμοϋδρομετρική κατάσταση της ατμόσφαιρας. Υψηλή θερμοκρασία και χαμηλή ατμοσφαιρική υγρασία μπορούν να ενισχύσουν την ξήρανση της καύσιμης ύλης και να αυξήσουν την πιθανότητα ανάφλεξης ή εξάπλωσης.


Παράλληλα, εμφανίζεται συνεισφορά από μεταβλητές όπως ο FWI, η δυνητική εξατμισοδιαπνοή και οι συνιστώσες ανέμου. Αυτές οι μεταβλητές δεν έχουν πάντα την ίδια ένταση σε κάθε δείγμα, αλλά λειτουργούν συμπληρωματικά. Ο FWI συνοψίζει πυρομετεωρολογικές συνθήκες, η PET εκφράζει τη ζήτηση υγρασίας από την ατμόσφαιρα, ενώ οι συνιστώσες ανέμου συνδέονται με τη δυναμική διάδοσης της φωτιάς. Η τοπική εξήγηση δείχνει ότι το μοντέλο δεν βασίζεται μηχανικά σε ένα μόνο χαρακτηριστικό, αλλά συνδυάζει διαφορετικές πληροφορίες ανάλογα με τη χρονική στιγμή και τη θέση του κελιού.

Αντίθετα, δείκτες μεγαλύτερης χρονικής κλίμακας, όπως ο SPEI_180, εμφανίζουν μικρότερη άμεση επίδραση στο συγκεκριμένο ερμηνευόμενο pixel. Αυτό δεν σημαίνει ότι η μακροχρόνια ξηρασία είναι ασήμαντη. Σημαίνει ότι, για τη συγκεκριμένη πρόβλεψη, το μοντέλο έδωσε μεγαλύτερη βαρύτητα στις πρόσφατες μετεωρολογικές συνθήκες.



Εικόνα 6.3 Τοπική ερμηνεία πρόβλεψης του Spatio-Temporal ViT σε άξονα χρόνου και χαρακτηριστικών

Στο ViT παρατηρείται παρόμοια αλλά όχι ταυτόσημη συμπεριφορά. Η σημαντικότητα εξακολουθεί να συγκεντρώνεται κυρίως στις πιο πρόσφατες ημέρες, αλλά η κατανομή των βαρών μπορεί να είναι πιο απλωμένη σε χαρακτηριστικά που σχετίζονται με ευρύτερες κλιματικές ή εποχικές συνθήκες. Αυτό είναι συμβατό με τη λογική του transformer, ο οποίος δεν περιορίζεται μόνο σε τοπική συνελικτική επεξεργασία, αλλά μπορεί να μάθει συσχετίσεις μεταξύ διαφορετικών θέσεων και χρονικών στιγμών. Έτσι, ενώ το U-Net δίνει πιο καθαρή εικόνα τοπικής χωρικής εξάρτησης, το ViT μπορεί να ενσωματώνει πιο διάχυτες χωροχρονικές σχέσεις.



Σχήμα 6.4 Τοπική εξήγηση LIME για το κύριο CSV μοντέλο συγκεκριμένο κελί.

Στο συγκεκριμένο LIME παράδειγμα (Σχήμα 6.4), η προβλεπόμενη πιθανότητα είναι πολύ υψηλή και η πραγματική ετικέτα είναι θετική. Αυτό κάνει την εξήγηση ιδιαίτερα χρήσιμη, επειδή επιτρέπει να εξεταστεί ποια χαρακτηριστικά οδήγησαν το μοντέλο στη σωστή θετική πρόβλεψη. Παρατηρείται ότι διαφορετικές χρονικές εκδοχές των μεταβλητών έχουν διαφορετική επίδραση. Για παράδειγμα, κάποια χαρακτηριστικά προηγούμενων ημερών και εποχικότητας ωθούν την πρόβλεψη προς fire, ενώ ορισμένες τιμές υδατικού ισοζυγίου, KBDI ή χαρακτηριστικών που σχετίζονται με SPEI μπορούν να

λειτουργούν ανασταλτικά. Αυτό δείχνει ότι το μοντέλο δεν ακολουθεί έναν απλό κανόνα του τύπου «υψηλή θερμοκρασία σημαίνει πάντα φωτιά», αλλά αξιολογεί συνδυασμούς τιμών μέσα στο χρονικό παράθυρο.


Συνολικά, οι τοπικές εξηγήσεις σε επίπεδο κελιού και χρονικού παραθύρου έδειξαν ότι η πρόβλεψη πυρκαγιάς εξαρτάται κυρίως από τις πιο πρόσφατες ημέρες του επταήμερου παραθύρου και από μεταβλητές που περιγράφουν την άμεση θερμοϋδρομετρική κατάσταση, την ξηρότητα και τον πυρομετεωρολογικό κίνδυνο. Οι χρονικοί χάρτες σημαντικότητας τύπου surrogate βοήθησαν να φανεί η χρονική διάσταση της ερμηνείας, ενώ το ραβδόγραμμα LIME έδωσε κατεύθυνση επίδρασης για μια συγκεκριμένη πρόβλεψη. Με αυτόν τον τρόπο, η ανάλυση δεν περιορίστηκε στο ερώτημα «ποια μεταβλητή είναι σημαντική γενικά», αλλά προχώρησε στο ερώτημα «ποια μεταβλητή, σε ποια ημέρα και με ποια κατεύθυνση επηρέασε τη συγκεκριμένη πρόβλεψη».

6.5 Χωρικές εξηγήσεις των βαθιών μοντέλων

Μετά την καθολική ανάλυση σημαντικότητας χαρακτηριστικών, η ερμηνεία των βαθιών μοντέλων επεκτάθηκε στο χωρικό επίπεδο. Στόχος της ενότητας αυτής δεν είναι να επαναληφθεί ποια μεταβλητή είναι συνολικά σημαντική, αλλά να εξεταστεί αν οι περιοχές που επηρεάζουν την πρόβλεψη βρίσκονται κοντά στις πραγματικές ή προβλεπόμενες εστίες πυρκαγιάς.


Για τον σκοπό αυτό χρησιμοποιήθηκαν χωρικοί χάρτες επεξήγησης από Integrated Gradients, SHAP, Saliency και Grad-CAM. Οι μέθοδοι αυτές δεν ερμηνεύονται εδώ ως απόλυτη αιτιακή απόδειξη, αλλά ως εργαλεία ελέγχου της χωρικής συμπεριφοράς του μοντέλου. Αν οι υψηλές τιμές attribution συγκεντρώνονται γύρω από τις πραγματικές εστίες πυρκαγιάς ή γύρω από περιοχές υψηλής προβλεπόμενης πιθανότητας, τότε η πρόβλεψη θεωρείται πιο συνεπής. Αντίθετα, αν οι χάρτες δείχνουν έντονη σημασία σε άσχετες ή θαλάσσιες περιοχές, τότε υπάρχει ένδειξη ότι το μοντέλο πιθανόν αξιοποιεί μη επιθυμητά χωρικά artifacts.

Οι χάρτες έδειξαν ότι η μεγαλύτερη συνεισφορά συγκεντρώνεται γύρω από το κελί στόχο και τη γειτονική περιοχή υψηλού κινδύνου. Το εύρημα αυτό είναι σημαντικό, επειδή το U-Net δεν παράγει απλώς μια μεμονωμένη πιθανότητα, αλλά έναν πυκνό χάρτη κινδύνου σε επίπεδο κελιού. Επομένως, η χωρική ερμηνεία πρέπει να αξιολογείται σε σχέση με το αν η σημασία οργάνωνεται γύρω από περιοχές που έχουν σχέση με την πραγματική ή προβλεπόμενη φωτιά. Οι χάρτες Integrated Gradients και SHAP για το CSV μοντέλο δείχνουν ακριβώς αυτή τη συμπεριφορά: η σημαντικότητα δεν είναι πλήρως τυχαία, αλλά εμφανίζει χωρική συγκέντρωση γύρω από το κελί ενδιαφέροντος.



Εικόνα 6.4 Χωρική ερμηνεία με Integrated Gradients για το κύριο CSV-based U-Net

Στο συγκεκριμένο παράδειγμα (Εικόνα 6.4), η υψηλή τιμή βρίσκεται κοντά στο κελί στόχο και όχι σε απομακρυσμένες τυχαίες περιοχές. Αυτό δείχνει ότι το μοντέλο δεν αντιμετωπίζει το grid ως απλό πίνακα αριθμών, αλλά έχει μάθει μια χωρική σχέση ανάμεσα στη γειτονική περιοχή και την πρόβλεψη κινδύνου.




Εικόνα 6.5 Χωρικός χάρτης SHAP για το κύριο CSV-based U-Net

Ο χωρικός χάρτης SHAP δίνει παρόμοια εικόνα, αλλά με διαφορετική λογική υπολογισμού. Ενώ τα Integrated Gradients βασίζονται στα παράγωγα του μοντέλου, το SHAP εκτιμά τη συνεισφορά κάθε στοιχείου εισόδου ως προς την αλλαγή της πρόβλεψης. Στο συγκεκριμένο SHAP map (Εικόνα 6.5), οι υψηλότερες τιμές δεν είναι διάσπαρτες σε όλο το πλέγμα, αλλά οργανώνονται γύρω από την περιοχή του κελιού-στόχου. Αυτό ενισχύει την ερμηνεία ότι το μοντέλο αξιοποιεί τοπικό χωρικό πλαίσιο και όχι μεμονωμένο ή τυχαίο pixel. Το αποτέλεσμα είναι συνεπές με τα συνολικά ευρήματα της εργασίας, σύμφωνα με τα οποία το U-Net δίνει πιο καθαρή χωρική συμπεριφορά και είναι πιο κατάλληλο για τη χαρτογράφηση κινδύνου σε επίπεδο pixel.

Ο χάρτης Saliency όπως φαίνεται στην εικόνα 6.1, εξετάζει διαφορετική πλευρά της συμπεριφοράς του μοντέλου. Δεν δείχνει απλώς ποια περιοχή συνέβαλε περισσότερο στην υπάρχουσα πρόβλεψη, αλλά σε ποια σημεία η έξοδος είναι πιο ευαίσθητη σε μικρές μεταβολές της εισόδου. Η αυξημένη ευαισθησία εντοπίζεται πάλι κοντά στο κελί-στόχο και σε γειτονικά κελιά. Αυτό σημαίνει ότι η πρόβλεψη του μοντέλου εξαρτάται έντονα από τις τοπικές χωρικές συνθήκες γύρω από την περιοχή ενδιαφέροντος. Η συμπεριφορά αυτή είναι επιθυμητή σε πρόβλημα πρόβλεψης πυρκαγιάς, επειδή η παρουσία κινδύνου δεν είναι ανεξάρτητη από το γειτονικό περιβάλλον.

Συμπληρωματικά προς τους χάρτες Integrated Gradients, SHAP και Saliency, εφαρμόστηκε και Grad-CAM στο U-Net. Η μέθοδος αυτή είναι ιδιαίτερα κατάλληλη για συνελκτικές αρχιτεκτονικές, επειδή δεν εξετάζει απευθείας μόνο την είσοδο, αλλά τις ενεργοποιήσεις εσωτερικών συνελκτικών στρώσεων.


Με αυτόν τον τρόπο παράγει έναν πιο αδρό χάρτη χωρικής προσοχής, ο οποίος δείχνει ποιες περιοχές της ενδιάμεσης αναπαράστασης συνέβαλαν περισσότερο στην τελική πρόβλεψη.



Εικόνα 6.6 Grad-CAM χάρτης για το U-Net

Στο Grad-CAM του U-Net παρατηρείται ότι οι ενεργοποιήσεις δεν κατανέμονται ομοιόμορφα σε όλο το πλέγμα, αλλά συγκεντρώνονται σε συγκεκριμένες περιοχές. Η μορφή αυτή είναι αναμενόμενη, επειδή το Grad-CAM λειτουργεί σε βαθύτερο επίπεδο του δικτύου και επομένως δίνει πιο γενική, λιγότερο λεπτομερή χωρική εικόνα σε σχέση με τα Integrated Gradients ή το SHAP. Παρόλα αυτά, ο χάρτης παραμένει χρήσιμος, επειδή δείχνει ότι το U-Net δεν ενεργοποιείται τυχαία, αλλά σε χωρικές ζώνες που σχετίζονται με αυξημένη πιθανότητα πυρκαγιάς.


Η σύγκριση των χωρικών εξηγήσεων μεταξύ U-Net και Spatio-Temporal ViT δίνει επιπλέον πληροφορία για τη διαφορετική συμπεριφορά των δύο αρχιτεκτονικών. Το U-Net εμφανίζει πιο καθαρή χωρική συνέχεια γύρω από την περιοχή ενδιαφέροντος. Αντίθετα, το ViT φαίνεται να εστιάζει πιο επιλεκτικά σε συγκεκριμένα σημεία του πλέγματος. Επομένως και τα δύο μοντέλα εστιάζουν κοντά στην πραγματική περιοχή ανάφλεξης, όμως το U-Net αναδεικνύει επιπλέον ευρύτερες περιοχές επιρρεπείς σε πυρκαγιά.



Εικόνα 6.7 Χωρικές εξηγήσεις U-Net και ViT με Integrated Gradients και Gradient $\times$ Input

Στην εικόνα 6.7, οι χάρτες Integrated Gradients και Gradient $\times$ Input λειτουργούν ως δύο συμπληρωματικοί τρόποι ελέγχου της ίδιας ιδέας: αν η πρόβλεψη του μοντέλου επηρεάζεται από χωρικά λογικές περιοχές. Τα Integrated Gradients δίνουν πιο σταθερή εκτίμηση της συνεισφοράς, επειδή υπολογίζουν τα gradients κατά μήκος μιας διαδρομής από baseline είσοδο έως την πραγματική είσοδο. Το Gradient $\times$ Input είναι πιο άμεσο και δείχνει την τοπική ευαισθησία στα πραγματικά ενεργά σημεία της εισόδου. Όταν οι δύο χάρτες δείχνουν παρόμοια χωρική συγκέντρωση, αυξάνεται η εμπιστοσύνη ότι η εξήγηση δεν είναι τυχαίο αποτέλεσμα μιας μόνο μεθόδου.

Η οπτική σύγκριση με τον πραγματικό χάρτη πυρκαγιάς και τους χάρτες προβλεπόμενης πιθανότητας είναι επίσης σημαντική. Στο σχετικό παράδειγμα, οι υψηλές πιθανότητες του U-Net και του ViT εμφανίζονται κοντά στην πραγματική εστία. Το U-Net, όμως, δίνει πιο συνεκτική και χαρτογραφικά αναγνώσιμη περιοχή κινδύνου, ενώ το ViT εμφανίζει πιο συγκεντρωμένη απόκριση γύρω από επιμέρους σημεία. Αυτό δείχνει ότι το U-Net είναι πιο κατάλληλο όταν ο στόχος είναι η παραγωγή συνεχούς κινδύνου, ενώ το ViT μπορεί να προσφέρει συμπληρωματική πληροφορία για πιο επιλεκτικές χωροχρονικές συσχετίσεις.



Εικόνα 6.8 Σύγκριση πραγματικής εστίας και προβλεπόμενων πιθανοτήτων για ViT και U-Net


Το βασικό συμπέρασμα της ενότητας είναι ότι το U-Net παρουσιάζει την πιο καθαρή χωρική συμπεριφορά. Η αρχιτεκτονική του φαίνεται να βοηθά στη διατήρηση τοπικής πληροφορίας και στη δημιουργία συνεκτικών περιοχών κινδύνου. Το ViT, από την άλλη πλευρά, δίνει πιο επιλεκτική χωρική απόκριση και μπορεί να αποτυπώνει πιο αφαιρετικές σχέσεις μέσα στο πλέγμα.

6.6 Επεξηγησιμότητα στο FireCube και επίδραση του domain shift

Μετά την ανάλυση των χωρικών εξηγήσεων στο κύριο σύνολο δεδομένων, η ίδια λογική εφαρμόστηκε και στο FireCube [6]. Η υποενότητα αυτή έχει διαφορετικό σκοπό από τις προηγούμενες. Δεν εξετάζει μόνο αν το μοντέλο παράγει ερμηνεύσιμες προβλέψεις, αλλά αν οι εξηγήσεις παραμένουν ίδιες όταν το μοντέλο μεταφέρεται σε διαφορετικό σύνολο δεδομένων. Το FireCube αποτελεί εξωτερικό domain, με διαφορετική χωρική ανάλυση, διαφορετική δομή χαρακτηριστικών, διαφορετική κατασκευή ετικετών και πολύ πιο έντονη ανισορροπία της θετικής κλάσης. Για τον λόγο αυτό, η ερμηνεία των προβλέψεων στο FireCube λειτουργεί ως έλεγχος μεταφερσιμότητας και όχι μόνο ως κλασική XAI ανάλυση.


Η μεταφορά στο FireCube δεν ήταν απλή. Το προεκπαιδευμένο U-Net δοκιμάστηκε αρχικά στο νέο πεδίο, αλλά η απευθείας εφαρμογή του δεν ήταν επαρκής. Στο στάδιο του fine-tuning, το FireCube χρησιμοποιήθηκε με παράθυρο 7 ημερών, είσοδο διαστάσεων $33 \times 42 \times 84$ και διφασική εκπαίδευση, πρώτα με learning rate 0.0001 και στη συνέχεια με 0.00001. Μετά την προσαρμογή, το μοντέλο πέτυχε ROC-AUC περίπου 0.823 και PR-AUC περίπου 0.0097. Οι τιμές αυτές δείχνουν ότι το fine-tuning βελτίωσε ουσιαστικά την ικανότητα κατάταξης κινδύνου στο νέο πεδίο δεδομένων, χωρίς όμως να εξαλείψει πλήρως τις επιπτώσεις της μετατόπισης πεδίου. Η χαμηλή PR-AUC πρέπει να ερμηνευθεί σε σχέση με την ακραία ανισορροπία του FireCube, όπου η θετική κλάση είναι πολύ σπάνια. Επομένως, η επίδοση δεν δείχνει ότι το μοντέλο μπορεί να λειτουργήσει ως απόλυτος ανιχνευτής πυρκαγιάς, αλλά ότι μετά την προσαρμογή αποκτά ικανότητα να κατατάσσει ορισμένες περιοχές ως υψηλότερου κινδύνου σε σχέση με το υπόλοιπο πλέγμα.

Στα Integrated Gradients του FireCube, οι κυρίαρχες μεταβλητές είναι το avg_d2m και το avg_t2m. Το εύρημα αυτό είναι φυσικά εύλογο, επειδή το σημείο δρόσου και η θερμοκρασία περιγράφουν την άμεση θερμοϋδρομετρική κατάσταση της ατμόσφαιρας. Σε πρόβλημα πυρκαγιάς, η σχέση αυτή είναι κρίσιμη: θερμές και ξηρές συνθήκες αυξάνουν την ευφλεκτότητα της καύσιμης ύλης και συνδέονται με μεγαλύτερη πιθανότητα εμφάνισης ή ενίσχυσης πυρκαγιάς. Μετά τις δύο αυτές μεταβλητές, εμφανίζονται χαρακτηριστικά όπως SLOPE, CLC_2018_7, fwi, ROAD_DISTANCE, env, smian, avg_rh και DEM. Η παρουσία αυτών των παραγόντων δείχνει ότι το μοντέλο στο FireCube δεν λειτουργεί μόνο ως μετεωρολογικός ταξινομητής, αλλά ενσωματώνει και πληροφορία τοπίου.




Σχήμα 6.5 Integrated Gradients feature importance στο FireCube

Ο χωρικός χάρτης Integrated Gradients στο FireCube δείχνει πώς κατανέμεται η συνεισφορά πάνω στο πλέγμα. Στην αντίστοιχη εικόνα, η υψηλή συνεισφορά συγκεντρώνεται γύρω από το κελί-στόχο και αντιστοιχεί σε περιοχή όπου το μοντέλο προβλέπει υψηλή πιθανότητα πυρκαγιάς. Η σύγκριση των τριών πάνελ, δηλαδή attribution map, predicted probability και ground truth, βοηθά να ελεγχθεί αν η ερμηνεία είναι χωρικά συμβατή με την πραγματική ετικέτα. Το σημαντικό εδώ δεν είναι μόνο ότι το μοντέλο προβλέπει υψηλό κίνδυνο, αλλά ότι η ερμηνεία του κινδύνου εντοπίζεται χωρικά κοντά στο σημείο ενδιαφέροντος.




Εικόνα 6.9 Χωρική απόδοση Integrated Gradients στο FireCube

Το SHAP στο FireCube δίνει μια συμπληρωματική, πιο συνολική εικόνα. Στο αντίστοιχο feature importance διάγραμμα, το avg_d2m παραμένει στην κορυφή, αλλά ακολουθούν χαρακτηριστικά όπως SLOPE, CLC_2018_7, ROAD_DISTANCE, ndvi, DEM, avg_rh, max_wind_speed, avg_t2m και fwi. Η κατάταξη αυτή είναι σημαντική, επειδή δείχνει ότι το FireCube εισάγει ισχυρότερη εξάρτηση από χαρακτηριστικά τοπίου σε σχέση με το βασικό σύνολο δεδομένων. Η κλίση, το υψόμετρο, η κάλυψη γης και η βλάστηση δεν αντικαθιστούν τη μετεωρολογία, αλλά λειτουργούν μαζί της. Έτσι, το μοντέλο φαίνεται να αξιοποιεί ένα πιο πλήρες περιβαλλοντικό πλαίσιο κινδύνου.




Σχήμα 6.6 SHAP feature importance στο FireCube

Ο χωρικός χάρτης SHAP επιβεβαιώνει ότι η συνεισφορά δεν είναι τυχαία κατανομημένη στο πλέγμα. Η υψηλότερη απόδοση εμφανίζεται γύρω από την περιοχή του κελί-στόχου και ευθυγραμμίζεται με τη ζώνη υψηλής προβλεπόμενης πιθανότητας. Οι FireCube εξηγήσεις είναι πιο έντονα συνδεδεμένες με τη χωρική μορφολογία του κινδύνου από το αρχικό σύνολο εισόδου. Αυτό είναι αναμενόμενο, επειδή το FireCube περιλαμβάνει λεπτότερα γεωχωρικά χαρακτηριστικά και όχι μόνο ημερήσια μετεωρολογικά πεδία.




Εικόνα 6.10 Χωρική απόδοση SHAP στο FireCube



Σχήμα 6.7 Saliency feature importance στο FireCube


Ο χωρικός saliency χάρτης (σχήμα 6.7) δείχνει αντίστοιχη συγκέντρωση γύρω από την περιοχή ενδιαφέροντος. Επειδή το saliency είναι ευαίσθητο σε τοπικές μεταβολές, ο χάρτης αυτός δεν πρέπει να ερμηνεύεται ως καθολική εξήγηση του μοντέλου. Αντίθετα, δείχνει σε ποια σημεία η έξοδος θα άλλαζε περισσότερο αν μεταβάλλονταν ελαφρά οι είσοδοι. Στο FireCube, η χωρική συγκέντρωση γύρω από το κελί-στόχο δείχνει ότι το fine-tuned μοντέλο διατηρεί ένα βαθμό χωρικής συνέπειας στο εξωτερικό domain.

Η τοπική εξήγηση LIME στο FireCube δίνει πιο αναλυτική εικόνα για μία συγκεκριμένη πρόβλεψη. Στο σχήμα LIME για το κελί ενδιαφέροντος, οι κόκκινες μπάρες δείχνουν όρους που ωθούν την πρόβλεψη προς fire, ενώ οι μπλε μπάρες όρους που την ωθούν προς no-fire. Οι ισχυρές θετικές συνεισφορές περιλαμβάνουν κυρίως θερμοκρασιακές και υγρομετρικές μεταβλητές προηγούμενων ημερών, όπως avg_t2m και avg_d2m, ενώ εμφανίζονται επίσης γεωχωρικοί όροι όπως DEM, ROAD_DISTANCE, land-cover μεταβλητές και άνεμος. Αυτό επιβεβαιώνει ότι στο FireCube η πρόβλεψη δεν εξηγείται από μία μόνο κατηγορία δεδομένων, αλλά από συνδυασμό καιρού, τοπίου, βλάστησης και χωρικού πλαισίου.



Σχήμα 6.8 Τοπική εξήγηση LIME στο FireCube.

Το πιο σημαντικό σχήμα της ενότητας είναι το παρκάτω συγκεντρωτικό στην εικόνα Σχήμα 6.9. Εκεί φαίνεται καθαρά ότι οι διαφορετικές ΧΑΙ μέθοδοι δεν συμφωνούν πλήρως, αλλά αναδεικνύουν συμπληρωματικές όψεις της ίδιας πρόβλεψης. Τα Integrated Gradients δίνουν ιδιαίτερα υψηλή σημασία στο avg_d2m και στο avg_t2m. Το SHAP αναδεικνύει επίσης το avg_d2m, αλλά δίνει μεγάλη βαρύτητα σε SLOPE, land-cover, ROAD_DISTANCE, NDVI, DEM και avg_rh. Το Saliency εμφανίζει υψηλή ευαισθησία σε μεταβλητές πρόσφατης φωτιάς, γειτονικής φωτιάς, βλάστησης και ανέμου. Αυτή η διαφοροποίηση δεν είναι πρόβλημα. Αντίθετα, δείχνει ότι η ερμηνεία στο FireCube είναι πολυπαραγοντική και ότι κάθε μέθοδος φωτίζει διαφορετικό επίπεδο της απόφασης.



Σχήμα 6.9 Συγκεντρωτική σύγκριση Integrated Gradients, SHAP, Saliency και LIME στο FireCube

Το βασικό συμπέρασμα από την επεξηγησιμότητα στο FireCube είναι ότι το μοντέλο δεν μεταφέρει αυτούσια την ίδια λογική από το αρχικό σύνολο δεδομένων. Στο κύριο, η ερμηνεία κυριαρχείται περισσότερο από εποχικότητα, θερμοκρασία, σημείο δρόσου, PET, FWI και δείκτες ξηρασίας. Στο FireCube, οι θερμοϋδρομετρικές μεταβλητές παραμένουν σημαντικές, αλλά το μοντέλο δίνει πλέον μεγαλύτερη βαρύτητα και σε χαρακτηριστικά τοπίου, όπως κλίση, υψόμετρο, κάλυψη γης, βλάστηση, απόσταση από δρόμους και γειτονικό ιστορικό πυρικής δραστηριότητας. Αυτό αποτελεί ένδειξη domain shift: όταν αλλάζει το πεδίο δεδομένων, αλλάζει και ο τρόπος με τον οποίο το μοντέλο οργανώνει την πρόβλεψη.

Η παρατήρηση αυτή έχει άμεση μεθοδολογική σημασία. Αν η αξιολόγηση περιοριζόταν μόνο σε PR-AUC ή ROC-AUC, θα γνωρίζαμε ότι το fine-tuning βελτιώνει τη διακριτική ικανότητα του μοντέλου, αλλά δεν θα γνωρίζαμε γιατί. Οι XAI τεχνικές δείχνουν ότι η βελτίωση δεν οφείλεται απλώς σε αριθμητική προσαρμογή των βαρών, αλλά σε αλλαγή του ερμηνευτικού μηχανισμού: το μοντέλο μαθαίνει να συνδυάζει τις μετεωρολογικές συνθήκες με πιο λεπτομερή γεωχωρικά χαρακτηριστικά. Αυτό εξηγεί γιατί η προσαρμογή πεδίου είναι κρίσιμη για πραγματική επιχειρησιακή χρήση.

6.7 Σύγκριση ερμηνευτικής συμπεριφοράς U-Net, ViT, ConvNeXt και ConvNeXt-UNet

Μετά την ανάλυση των επιμέρους τεχνικών επεξηγησιμότητας, είναι χρήσιμο να συγκριθεί συνολικά η ερμηνευτική συμπεριφορά των βασικών βαθιών μοντέλων που εξετάστηκαν στην εργασία. Η σύγκριση αυτή δεν αφορά μόνο το ποιο μοντέλο πέτυχε καλύτερες αριθμητικές μετρικές, αλλά κυρίως το πώς φαίνεται να «σκέφτεται» κάθε αρχιτεκτονική. Δηλαδή, ποια μορφή πληροφορίας αξιοποιεί περισσότερο, πόσο χωρικά συνεκτικές είναι οι εξηγήσεις της και αν η συμπεριφορά της είναι συμβατή με τη φυσική λογική του φαινομένου των πυρκαγιών.

Στην περίπτωση του U-Net, οι εξηγήσεις δείχνουν πιο καθαρή τοπική και χωρική συμπεριφορά. Το μοντέλο βασίζεται έντονα σε κοντινές μετεωρολογικές συνθήκες και σε χωρικές περιοχές γύρω από το κελί ενδιαφέροντος. Έτσι, οι προβλέψεις του U-Net δεν εμφανίζονται μόνο ως μεμονωμένα ενεργά pixels, αλλά ως πιο συνεκτικές περιοχές κινδύνου.

Τα αποτελέσματα των spatial attribution maps ενισχύουν αυτή την εικόνα. Τόσο το U-Net όσο και το ViT εστιάζουν κοντά στην πραγματική περιοχή ανάφλεξης, όμως το U-Net αναδεικνύει επιπλέον ευρύτερες περιοχές με φωτιά, κάτι που δείχνει ότι έχει μάθει χωρικό πλαίσιο πέρα από το απλό σημείο της εστίας.

Επειδή η αρχιτεκτονική του ViT βασίζεται στον μηχανισμό αυτοπροσοχής, το μοντέλο έχει μεγαλύτερη δυνατότητα να συνδέει πληροφορίες από διαφορετικά σημεία του πλέγματος και από διαφορετικές χρονικές στιγμές. Στην πράξη, οι εξηγήσεις του ViT φαίνεται να δίνουν μεγαλύτερη σημασία σε ευρύτερα χωροχρονικά ή κλιματικά μοτίβα, όπως η δυνητική εξατμισοδιαπνοή, οι δείκτες ξηρασίας, η θερμοκρασία και ο FWI. Στα διαθέσιμα αποτελέσματα αναφέρεται ότι το ViT τείνει να βασίζεται περισσότερο σε climate-driven μεταβλητές, ενώ το U-Net δίνει μεγαλύτερη έμφαση σε near-surface μετεωρολογικές συνθήκες, κάτι που αντανάκλα πιο ισχυρή τοπική μετεωρολογική εξάρτηση για το U-Net.

Η διαφορά αυτή δεν σημαίνει ότι το ViT είναι λανθασμένο. Αντίθετα, δείχνει ότι η αρχιτεκτονική του μπορεί να συλλάβει πιο αφαιρετικές σχέσεις και πιο εκτεταμένα μοτίβα. Ωστόσο, στο συγκεκριμένο πρόβλημα, όπου ο στόχος είναι η παραγωγή χάρτη κινδύνου σε επίπεδο κελιού, αυτή η πιο αφαιρετική συμπεριφορά δεν μεταφράζεται πάντα σε καλύτερη ακρίβεια. Το ViT μπορεί να είναι χρήσιμο για την κατανόηση ευρύτερων κλιματικών επιδράσεων, αλλά το U-Net παραμένει πιο άμεσα κατάλληλο για

λεπτομερή χωρική χαρτογράφηση. Αυτό συμφωνεί και με τη συνολική σύγκριση της εργασίας, όπου το U-Net εμφανίζεται ισχυρότερο σε precision-recall συμπεριφορά και spatial precision, ενώ το ViT αναδεικνύει καλύτερα μακροπρόθεσμη κλιματική πληροφορία και χρονική αφαίρεση.

Ο ConvNeXt από ερμηνευτική άποψη, παραμένει χωρικό μοντέλο, αλλά η αναπαράστασή του είναι πιο βαθιά και πιο αφαιρετική από ένα απλό CNN. Η ερμηνεία του επομένως πρέπει να διαβαστεί περισσότερο ως ιεραρχική χωρική αναπαράσταση και λιγότερο ως άμεση τοπική αντιστοίχιση χαρακτηριστικού-κελιού.

Στα πειράματα zone-mask, το ConvNeXt έδειξε ότι μπορεί να μάθει χωρικά πρότυπα, αλλά ήταν πιο ευαίσθητο στη μεταφορά μεταξύ διαφορετικών στόχων ή domains. Αυτό φάνηκε κυρίως όταν συγκρίθηκαν οι καμπύλες PR και ROC. Στο κύριο σύνολο δεδομένων παρουσίασε κάποια διακριτική ικανότητα, αλλά στο FireCube η επίδοση μειώθηκε, δείχνοντας ότι η απλή μεταφορά της χωρικής αναπαράστασης δεν είναι πάντα σταθερή. Ερμηνευτικά, αυτό δείχνει ότι το ConvNeXt μπορεί να αποτυπώνει ισχυρά χωρικά μοτίβα στο domain εκπαίδευσης, αλλά χρειάζεται προσεκτική βαθμονόμηση και πιθανόν προσαρμογή όταν αλλάζει η κατανομή των δεδομένων.

Το υβριδικό ConvNeXt-U-Net συνδυάζει τα πλεονεκτήματα των δύο προσεγγίσεων. Από τη μία πλευρά, ο ConvNeXt encoder λειτουργεί ως ισχυρός εξαγωγέας χωρικών χαρακτηριστικών. Από την άλλη πλευρά, ο U-Net decoder επιτρέπει την ανακατασκευή πυκνού χάρτη κινδύνου. Ερμηνευτικά, αυτό το σχήμα είναι πιο κατάλληλο από έναν καθαρό ταξινομητή ConvNeXt, επειδή η έξοδος παραμένει χωρικά οργανωμένη. Το μοντέλο δεν περιορίζεται στο να αποφασίσει αν μια ημέρα ή μια περιοχή έχει υψηλό κίνδυνο, αλλά προσπαθεί να αποδώσει αυτόν τον κίνδυνο ξανά στο πλέγμα.

Το βασικό συμπέρασμα της σύγκρισης είναι ότι η επεξηγησιμότητα δεν δείχνει μόνο αν ένα μοντέλο είναι «σωστό», αλλά και τι είδους πληροφορία μαθαίνει. Για την παρούσα εργασία, το U-Net παραμένει το πιο καθαρά ερμηνεύσιμο μοντέλο για pixel-level χαρτογράφηση κινδύνου, επειδή οι χωρικές του εξηγήσεις είναι πιο συνεκτικές και πιο εύκολα συνδέσιμες με πραγματικές περιοχές κινδύνου. Το ViT προσθέτει χρήσιμη πληροφορία για ευρύτερες χωροχρονικές και κλιματικές σχέσεις, ενώ το ConvNeXt-U-Net αποτελεί μια ενδιάμεση λύση που αξιοποιεί ισχυρή χωρική αναπαράσταση χωρίς να εγκαταλείπει την ανάγκη για πυκνό χάρτη πρόβλεψης.

Πίνακας 6.1 Συλλογική σύγκριση

Μοντέλο	Κυρίαρχη ερμηνευτική συμπεριφορά	Τι δείχνουν οι εξηγήσεις	Περιορισμός
U-Net	Τοπική μετεωρολογική και χωρική εξάρτηση	Καθαρή συγκέντρωση γύρω από fire-susceptible περιοχές	Περιορισμένη ρητή χρονική μοντελοποίηση
ViT	Ευρύτερη χωροχρονική και κλιματική συσχέτιση	Έμφαση σε PET, θερμοκρασία, FWI και δείκτες ξηρασίας	Λιγότερο άμεση χωρική ερμηνεία σε επίπεδο pixel
ConvNeXt	Ιεραρχική συνελκτική χωρική αναπαράσταση	Μαθαίνει χωρικά μοτίβα υψηλού κινδύνου	Ευαίσθησία σε domain shift στα zone-mask πειράματα
ConvNeXt-U-Net	Συνδυασμός ισχυρού encoder και πυκνού decoder	Καλύτερη σύνδεση βαθιών χωρικών χαρακτηριστικών με risk map	Πιο σύνθετη ερμηνεία λόγω υβριδικής αρχιτεκτονικής


6.8 Εκτίμηση αβεβαιότητας με Monte Carlo Dropout και residual-cVAE

Μετά την ανάλυση της επεξηγησιμότητας, η εργασία περνά στο ζήτημα της αβεβαιότητας των προβλέψεων. Η αβεβαιότητα απαντά σε διαφορετικό ερώτημα: πόσο σταθερή και αξιόπιστη είναι αυτή η πρόβλεψη. Σε ένα επιχειρησιακό σύστημα πρόβλεψης πυρκαγιών, αυτό είναι κρίσιμο, γιατί δύο περιοχές μπορεί να έχουν παρόμοια προβλεπόμενη πιθανότητα, αλλά διαφορετικό επίπεδο βεβαιότητας.

Εφαρμόστηκαν δύο βασικές προσεγγίσεις uncertainty-aware πρόβλεψης πάνω στο U-Net: Monte Carlo Dropout και residual conditional Variational Autoencoder. Και οι δύο προσεγγίσεις είχαν ως στόχο να μετατρέψουν το μοντέλο από απλό ντετερμινιστικό σύστημα, το οποίο παράγει μία μοναδική πιθανότητα ανά κελί, σε πιθανοκρατικό σύστημα, το οποίο παράγει τόσο μέση πιθανότητα κινδύνου όσο και χάρτη αβεβαιότητας.

Η πρώτη προσέγγιση ήταν το Monte Carlo Dropout. Στην κλασική χρήση του, το dropout απενεργοποιεί τυχαία νευρώνες κατά την εκπαίδευση, ώστε να μειωθεί η υπερπροσαρμογή. Στην παρούσα εργασία, το dropout διατηρήθηκε ενεργό και κατά την εξαγωγή προβλέψεων. Το ίδιο δείγμα εισόδου πέρασε πολλαπλές φορές από το μοντέλο, με διαφορετικές τυχαίες ενεργοποιήσεις dropout. Έτσι, αντί να παραχθεί μία μόνο πρόβλεψη, παράχθηκε ένα σύνολο προβλέψεων. Ο μέσος όρος αυτών των προβλέψεων αποτέλεσε τον τελικό χάρτη πιθανότητας, ενώ η τυπική απόκλιση αποτέλεσε τον χάρτη αβεβαιότητας.

Στα πειράματα του U-Net με Monte Carlo Dropout χρησιμοποιήθηκαν 30 επαναλήψεις πρόβλεψης. Το ντετερμινιστικό U-Net πέτυχε PR-AUC 0.9664 και ROC-AUC 0.9990, ενώ το MC-Dropout mean διατήρησε πρακτικά την ίδια, ελαφρώς βελτιωμένη, απόδοση με PR-AUC 0.9668 και ROC-AUC 0.9992. Αυτό δείχνει ότι η προσθήκη uncertainty-aware εξόδου δεν μείωσε την ικανότητα διάκρισης του μοντέλου στο συγκεκριμένο πειραματικό σύνολο. Αντίθετα, πρόσθεσε δεύτερο επίπεδο πληροφορίας: όχι μόνο πού εκτιμάται υψηλός κίνδυνος, αλλά και πόσο σταθερή είναι η εκτίμηση του μοντέλου.




Εικόνα 6.11 Monte Carlo Dropout στο U-Net. Παρουσιάζει το πραγματικό fire map

Το σημαντικό στοιχείο στην εικόνα 6.11 είναι ότι η αβεβαιότητα δεν εμφανίζεται ως τυχαίος θόρυβος σε όλο το πλέγμα. Αντίθετα, συγκεντρώνεται σε περιοχές όπου το μοντέλο χρειάζεται περισσότερη προσοχή, κυρίως κοντά σε πιθανές εστίες ή σε περιοχές όπου η πρόβλεψη είναι πιο δύσκολη. Αυτό είναι χρήσιμο επιχειρησιακά, επειδή ένα σύστημα έγκαιρης προειδοποίησης δεν πρέπει να εμφανίζει μόνο κόκκινες ζώνες κινδύνου, αλλά και ζώνες όπου η εμπιστοσύνη του μοντέλου είναι χαμηλότερη.

Η δεύτερη προσέγγιση ήταν η ενσωμάτωση ενός residual conditional VAE πάνω στο αρχικό U-Net. Η βασική ιδέα ήταν ότι το U-Net παράγει έναν αρχικό χάρτη πιθανότητας, ενώ το residual-cVAE μαθαίνει

την κατανομή του υπολειμματικού σφάλματος ανάμεσα στην πρόβλεψη και την πραγματική ετικέτα. Με άλλα λόγια, το residual-cVAE δεν αντικαθιστά το U-Net, αλλά λειτουργεί συμπληρωματικά: προσπαθεί να μοντελοποιήσει το μέρος της πρόβλεψης που παραμένει αβέβαιο ή μη πλήρως εξηγημένο από το βασικό μοντέλο.

Κατά την εκπαίδευση, ο residual-cVAE βελτιστοποιήθηκε με συνδυασμό απώλειας ανακατασκευής και απόκλισης Kullback–Leibler (KL-divergence). Κατά την εξαγωγή των προβλέψεων, πραγματοποιήθηκε επαναλαμβανόμενη δειγματοληψία από τον λανθάνοντα χώρο, παράγοντας εναλλακτικά πιθανά σενάρια χαρτών κινδύνου. Ο μέσος όρος των σεναρίων χρησιμοποιήθηκε ως τελική πιθανότητα, ενώ η τυπική απόκλιση των σεναρίων χρησιμοποιήθηκε ως χάρτης αβεβαιότητας. Κατά την διαδικασία αυτή παρατηρήθηκε ότι η ενσωμάτωση του residual-cVAE επέτρεψε τη μετάβαση από καθαρά ντετερμινιστική πρόβλεψη σε πιθανοκρατικό πλαίσιο χωρίς ουσιαστική απώλεια ακρίβειας στο συγκεκριμένο



Εικόνα 6.12 residual-cVAE πάνω στο U-Net

Η αξία του residual-cVAE είναι ότι μεταφέρει την αβεβαιότητα σε πιο δομημένο πιθανοκρατικό πλαίσιο. Ενώ το MC Dropout εκτιμά αβεβαιότητα μέσα από stochastic περάσματα του ίδιου δικτύου, το residual-cVAE μαθαίνει μια κατανομή πιθανών διορθώσεων πάνω στην έξοδο του U-Net. Αυτό επιτρέπει στο σύστημα να παράγει πολλαπλά εναλλακτικά σενάρια και να εκτιμά πού οι προβλέψεις είναι σταθερές ή ασταθείς. Στα αποτελέσματα του project αναφέρεται ότι η προσέγγιση αυτή πέτυχε υψηλή ακρίβεια, με recall 1.0 και precision περίπου 0.994, ενώ οι χάρτες αβεβαιότητας ανέδειξαν αυξημένη επιφύλαξη κυρίως στις περιοχές υψηλού κινδύνου.


Η αβεβαιότητα δεν αντικαθιστά την επεξηγησιμότητα. Οι XAI μέθοδοι των προηγούμενων ενοτήτων δείχνουν ποια χαρακτηριστικά, ποιες χρονικές στιγμές και ποιες χωρικές περιοχές επηρέασαν την πρόβλεψη. Η αβεβαιότητα δείχνει πόσο σταθερή είναι η πρόβλεψη όταν το μοντέλο εκτεθεί σε στοχαστικές παραλλαγές ή σε δειγματοληψία πιθανών εξόδων. Αυτά τα δύο επίπεδα είναι συμπληρωματικά. Μια πρόβλεψη μπορεί να είναι ερμηνεύσιμη αλλά αβέβαιη, ή βέβαιη αλλά να χρειάζεται έλεγχο ως προς το αν βασίζεται σε φυσικά σωστές μεταβλητές.

Συνολικά, η προσθήκη Monte Carlo Dropout και residual-cVAE ενίσχυσε τη χρησιμότητα του U-Net ως εργαλείου υποστήριξης αποφάσεων. Το μοντέλο δεν περιορίζεται πλέον στην παραγωγή ενός χάρτη κινδύνου, αλλά παρέχει και χάρτη εμπιστοσύνης. Αυτό είναι ιδιαίτερα σημαντικό στην πρόβλεψη πυρκαγιών, όπου οι ψευδώς αρνητικές προβλέψεις μπορεί να έχουν υψηλό κόστος, αλλά και οι υπερβολικές ψευδείς ειδοποιήσεις μπορούν να μειώσουν την πρακτική αξία του συστήματος. Η uncertainty-aware χαρτογράφηση επιτρέπει πιο προσεκτική χρήση των προβλέψεων, ειδικά όταν αυτές πρόκειται να αξιοποιηθούν σε επιχειρησιακό πλαίσιο πολιτικής προστασίας.

6.9 Σχέση αβεβαιότητας, σφάλματος και selective prediction

Μετά την παραγωγή χαρτών αβεβαιότητας, εξετάστηκε αν η αβεβαιότητα έχει πραγματική διαγνωστική αξία ή αν αποτελεί απλώς ένα πρόσθετο οπτικό αποτέλεσμα. Για τον σκοπό αυτό, η αβεβαιότητα συγκρίθηκε με το απόλυτο σφάλμα της πρόβλεψης σε επίπεδο pixel. Η βασική υπόθεση ήταν ότι, αν η εκτίμηση αβεβαιότητας είναι χρήσιμη, τότε τα σημεία όπου το μοντέλο είναι πιο αβέβαιο θα πρέπει να συνδέονται συχνότερα με μεγαλύτερα σφάλματα πρόβλεψης.

Η σχέση αυτή εξετάστηκε με το διάγραμμα στην εικόνα 6.13, όπου κάθε σημείο αντιστοιχεί σε ένα pixel. Στον οριζόντιο άξονα παρουσιάζεται η αβεβαιότητα, όπως υπολογίστηκε από την τυπική απόκλιση των πολλαπλών προβλέψεων, ενώ στον κατακόρυφο άξονα παρουσιάζεται το απόλυτο σφάλμα ανάμεσα στην πραγματική ετικέτα και την προβλεπόμενη πιθανότητα. Στα αποτελέσματα της εργασίας παρατηρήθηκε θετική συσχέτιση ανάμεσα στην αβεβαιότητα και στο σφάλμα, με τιμή περίπου 0.73.




Εικόνα 6.13 Σχέση αβεβαιότητας και απόλυτου σφάλματος.

Το σημαντικό συμπέρασμα από το διάγραμμα είναι ότι η αβεβαιότητα δεν είναι τυχαία. Αν τα σημεία υψηλής αβεβαιότητας δεν σχετίζονταν με αυξημένο σφάλμα, τότε ο χάρτης uncertainty θα είχε μικρή πρακτική αξία. Αντίθετα, η θετική συσχέτιση δείχνει ότι το μοντέλο τείνει να είναι πιο αβέβαιο ακριβώς σε περιοχές όπου η πρόβλεψη είναι δυσκολότερη. Αυτό κάνει την αβεβαιότητα χρήσιμη όχι μόνο για ερμηνεία, αλλά και για επιχειρησιακό φιλτράρισμα των προβλέψεων.


Με βάση αυτή την παρατήρηση εφαρμόστηκε selective prediction. Η ιδέα είναι ότι το σύστημα δεν είναι υποχρεωμένο να δώσει απόφαση για όλα τα pixels με τον ίδιο βαθμό εμπιστοσύνης. Αντίθετα, μπορεί να κρατήσει τις πιο βέβαιες προβλέψεις και να χαρακτηρίσει τις πιο αβέβαιες ως περιπτώσεις που χρειάζονται επιπλέον έλεγχο ή αποχή. Στην πράξη, αυτό σημαίνει ότι τα pixels ταξινομούνται με βάση την αβεβαιότητα και στη συνέχεια αξιολογείται η απόδοση όταν κρατάμε μόνο ένα ποσοστό των πιο βέβαιων προβλέψεων.

Η λογική αυτή αποτυπώνεται στις καμπύλες στα σχήματα 6.10 και 6.11. Η κάλυψη δείχνει ποιο ποσοστό των pixels κρατά το σύστημα για αυτόματη απόφαση, ενώ το ρίσκο ή το F1 δείχνουν πόσο καλά

αποδίδει το μοντέλο σε αυτό το υποσύνολο. Όταν η κάλυψη μειώνεται, δηλαδή όταν αφαιρούνται τα πιο αβέβαια pixels, αναμένεται η απόδοση στα υπόλοιπα pixels να βελτιώνεται. Αυτό είναι βασικό κριτήριο για να θεωρηθεί η αβεβαιότητα χρήσιμη.



Σχήμα 6.10 Risk-coverage curve.



Σχήμα 6.11 F1-coverage curve

Τα αποτελέσματα του πειράματος επιβεβαιώνουν αυτή τη συμπεριφορά. Όταν κρατήθηκαν μόνο τα πιο βέβαια pixels, οι μετρικές έγιναν πολύ υψηλές. Για παράδειγμα, στο `keep_q = 0.50`, δηλαδή κρατώντας περίπου το 50% των πιο βέβαιων pixels, το μοντέλο πέτυχε precision περίπου **0.998**, recall περίπου

0.996 και F1 περίπου **0.997**. Αντίστοιχα, ακόμη και σε μεγαλύτερη κάλυψη, όπως $\text{keep_q} = 0.90$ ή 0.95 , οι μετρικές παρέμειναν πολύ υψηλές.


Αυτό δείχνει ότι η αβεβαιότητα μπορεί να λειτουργήσει ως μηχανισμός ελέγχου αξιοπιστίας. Το μοντέλο δεν χρειάζεται να αντιμετωπίζει όλες τις προβλέψεις ως ισοδύναμα αξιόπιστες. Αντίθετα, μπορεί να παράγει τρεις τύπους πληροφορίας: πρόβλεψη κινδύνου, βαθμό αβεβαιότητας και ένδειξη για το αν η πρόβλεψη είναι αρκετά ασφαλής ώστε να χρησιμοποιηθεί αυτόματα. Σε επιχειρησιακό περιβάλλον, αυτό είναι ιδιαίτερα χρήσιμο, επειδή οι περιοχές υψηλής αβεβαιότητας μπορούν να προωθούνται για ανθρώπινο έλεγχο ή για συνδυασμό με επιπλέον πηγές δεδομένων.

Συνολικά, η ανάλυση αβεβαιότητας έδειξε ότι τα uncertainty maps δεν αποτελούν απλή συνοδευτική απεικόνιση. Η θετική σχέση αβεβαιότητας και σφάλματος δείχνει ότι η αβεβαιότητα περιέχει πραγματική πληροφορία για την ποιότητα της πρόβλεψης. Οι καμπύλες risk-coverage και F1-coverage έδειξαν ότι αυτή η πληροφορία μπορεί να αξιοποιηθεί πρακτικά, επιτρέποντας στο σύστημα να κρατά τις πιο αξιόπιστες προβλέψεις και να επισημαίνει τις πιο αβέβαιες περιοχές για περαιτέρω έλεγχο.

6.10 Βαθμονόμηση πιθανοτήτων και decision-aware risk mapping

Μετά την εκτίμηση αβεβαιότητας και την αξιολόγηση selective prediction, εξετάστηκε αν οι πιθανότητες που παράγει το μοντέλο μπορούν να ερμηνευθούν με αξιόπιστο τρόπο. Ένα μοντέλο μπορεί να διαχωρίζει καλά τα fire από τα no-fire pixels, αλλά οι αριθμητικές πιθανότητες που δίνει να μην αντιστοιχούν σε πραγματική συχνότητα εμφάνισης πυρκαγιάς.

Για τον λόγο αυτό εφαρμόστηκε βαθμονόμηση των πιθανοτήτων. Η βαθμονόμηση δεν αλλάζει τη βασική αρχιτεκτονική του U-Net και δεν απαιτεί επανεκπαίδευση του μοντέλου από την αρχή. Αντίθετα, προσαρμόζει τις τελικές πιθανότητες πάνω στο validation set, ώστε οι εκτιμώμενες πιθανότητες να αντιστοιχούν καλύτερα στις πραγματικές συχνότητες. Η ποιότητα της βαθμονόμησης αξιολογήθηκε με δύο μετρικές: το Brier score και το Expected Calibration Error, ενώ οπτικά παρουσιάστηκε με reliability diagram.



Σχήμα 6.12 Reliability diagram για τις πιθανοτικές εξόδους του U-Net

Στα αποτελέσματα οι αρχικές, μη βαθμονομημένες προβλέψεις ήταν ήδη αρκετά καλά βαθμονομημένες, με Brier score 0.000861 και ECE 0.00443. Το temperature scaling βελτίωσε ελαφρά την επίδοση, με Brier score 0.000856 και ECE 0.00350. Η isotonic regression έδωσε Brier score 0.000742 και ECE περίπου 0.00000.

Το αποτέλεσμα της isotonic regression πρέπει να ερμηνευθεί με προσοχή. Η isotonic regression προσαρμόστηκε στο validation set και η βαθμονόμηση αξιολογήθηκε στο ίδιο σύνολο. Επομένως, το ECE περίπου 0 δεν αποτελεί ανεξάρτητη απόδειξη γενίκευσης της βαθμονόμησης. Δείχνει κυρίως ότι η isotonic regression μπορεί να προσαρμόσει πολύ καλά τις πιθανότητες στο συγκεκριμένο validation set. Για ασφαλέστερο συμπέρασμα θα απαιτούνταν ξεχωριστό calibration set ή ανεξάρτητο test set.

Πίνακας 6.2 Σύγκριση μεθόδων βαθμονόμησης των πιθανοτικών εξόδων του U-Net στο validation set


Εκδοχή πιθανοτήτων	Brier score	ECE	Ερμηνεία
-----------------------	----------------	-----	----------

Raw	0.000861	0.00443	Ήδη καλά βαθμονομημένο
Temperature scaling	0.000856	0.00350	Μικρή αλλά σταθερή βελτίωση
Isotonic regression	0.000742	0.00000	Πολύ καλή προσαρμογή στο validation set, όχι ανεξάρτητη απόδειξη γενίκευσης

Το Brier score μετρά πόσο κοντά είναι οι προβλεπόμενες πιθανότητες στις πραγματικές δυαδικές ετικέτες, ενώ το ECE μετρά τη διαφορά ανάμεσα στην προβλεπόμενη εμπιστοσύνη και την πραγματική ακρίβεια ανά διαστήματα πιθανοτήτων. Χαμηλότερες τιμές και στις δύο μετρικές δείχνουν καλύτερη βαθμονόμηση. Η βελτίωση μετά τη βαθμονόμηση δείχνει ότι οι έξοδοι του U-Net μπορούν να μετασχηματιστούν σε πιο συνεπείς πιθανότητες στο συγκεκριμένο validation set, αλλά δεν πρέπει να ερμηνεύεται ως πλήρης απόδειξη επιχειρησιακής αξιοπιστίας.

Μετά τη βαθμονόμηση εφαρμόστηκε decision-aware risk mapping. Η ιδέα εδώ είναι ότι ο τελικός χάρτης δεν πρέπει να δείχνει μόνο συνεχείς τιμές πιθανότητας, αλλά να μεταφράζει αυτές τις πιθανότητες σε επιχειρησιακές κατηγορίες. Για τον σκοπό αυτό χρησιμοποιήθηκαν κατώφλια κινδύνου και κατώφλι αβεβαιότητας.

Στο κατώφλι (threshold) 0.72, το μοντέλο πέτυχε precision 0.9715, recall 0.7421 και F1-score 0.8415. Αυτό δείχνει ότι το τελικό κατώφλι λειτουργεί συντηρητικά: όταν το σύστημα χαρακτηρίζει ένα pixel ως υψηλού κινδύνου, η πρόβλεψη είναι πολύ αξιόπιστη ως προς τα ψευδώς θετικά, αλλά δεν καλύπτει όλες τις πιθανές εστίες. Αυτή η επιλογή είναι λογική για ένα decision-aware σύστημα, επειδή το κατώφλι μπορεί να ρυθμιστεί ανάλογα με το επιχειρησιακό σενάριο. Αν ο στόχος είναι η αποφυγή ψευδών συναγερμών, επιλέγεται υψηλότερο κατώφλι. Αν ο στόχος είναι η μέγιστη ανίχνευση, μπορεί να επιλεγεί χαμηλότερο κατώφλι με αποδοχή περισσότερων ψευδώς θετικών.



Εικόνα 6.14 Decision-aware χάρτης κινδύνου μετά από βαθμονόμηση και χρήση αβεβαιότητας

Η εικόνα 6.14 είναι σημαντική γιατί μετατρέπει το μοντέλο από απλή μηχανή πρόβλεψης σε εργαλείο υποστήριξης απόφασης. Ένας συνεχής χάρτης πιθανότητας είναι χρήσιμος για επιστημονική αξιολόγηση, αλλά σε επιχειρησιακό περιβάλλον χρειάζεται πιο καθαρή αναπαράσταση. Οι κατηγορίες πράσινο, κίτρινο, πορτοκαλί, κόκκινο και άγνωστο επιτρέπουν στο σύστημα να διαχωρίζει τις ασφαλείς περιοχές, τις περιοχές αυξημένου κινδύνου και τις περιοχές όπου το μοντέλο δεν έχει αρκετή βεβαιότητα. Έτσι, η αβεβαιότητα δεν μένει απλώς ως ξεχωριστό διάγραμμα, αλλά ενσωματώνεται στη λήψη απόφασης.

Σε αυτό το πείραμα, το 5% των pixels χαρακτηρίστηκε ως άγνωστα λόγω υψηλής αβεβαιότητας, περίπου το 94.87% ως πράσινη και περίπου το 0.127% ως κόκκινη. Δεν εμφανίστηκαν κίτρινες ή πορτοκαλί περιοχές στο συγκεκριμένο παράδειγμα, κάτι που δείχνει ότι, με τα συγκεκριμένα κατώφλια, οι περισσότερες προβλέψεις συγκεντρώθηκαν είτε στη χαμηλή είτε στην πολύ υψηλή κατηγορία κινδύνου.

Πίνακας 6.3 Ποσοστιαία κατανομή pixels στις τελικές decision-aware κατηγορίες κινδύνου.

Κατηγορία	Ερμηνεία	Ποσοστό pixels
Unknown / abstain	Υψηλή αβεβαιότητα, αποχή από αυτόματη απόφαση	5.00%
Πράσινο	Χαμηλός προβλεπόμενος κίνδυνος	94.87%
Κίτρινο	Μέτριος κίνδυνος	0.00%
Πορτοκαλί	Υψηλός κίνδυνος	0.00%
Κόκκινο	Πολύ υψηλός κίνδυνος	0.127%

Συνολικά, η βαθμονόμηση, η selective prediction και το decision-aware risk mapping λειτουργούν ως τελικό επίπεδο αξιοπιστίας πάνω από το U-Net. Η βαθμονόμηση ελέγχει αν οι πιθανότητες του μοντέλου μπορούν να διαβαστούν ως συνεπείς εκτιμήσεις κινδύνου στο validation set. Οι μετρικές Brier και ECE δίνουν ποσοτικό έλεγχο, ενώ το reliability diagram δίνει οπτική ένδειξη της αντιστοίχισης προβλεπόμενων πιθανοτήτων και παρατηρούμενων συχνοτήτων. Τέλος, ο decision-aware χάρτης μεταφράζει τις πιθανότητες και την αβεβαιότητα σε κατηγορίες που μπορούν να χρησιμοποιηθούν πρακτικά. Με αυτόν τον τρόπο, η έξοδος του U-Net δεν παραμένει ένας αφηρημένος χάρτης πιθανότητας, αλλά γίνεται πιο κοντά σε εργαλείο χαρτογράφησης κινδύνου με ένδειξη αξιοπιστίας.

7 Εξωτερική αξιολόγηση και μεταφορά σε νέο domain

7.1 Περιγραφή του σεναρίου FireCube

Η εξωτερική αξιολόγηση της εργασίας πραγματοποιήθηκε με χρήση του FireCube [6], το οποίο αντιμετωπίστηκε ως ανεξάρτητο σύνολο δεδομένων και όχι ως απλή συνέχεια του αρχικού συνόλου δεδομένων. Ο λόγος που χρησιμοποιήθηκε ήταν να εξεταστεί αν ένα μοντέλο που έχει εκπαιδευτεί στο αρχικό περιβάλλον μπορεί να μεταφερθεί σε διαφορετικό domain, με διαφορετική χωρική ανάλυση, διαφορετική δομή μεταβλητών και διαφορετικό τρόπο κατασκευής του στόχου. Με αυτόν τον τρόπο, το πείραμα δεν ελέγχει μόνο την απόδοση του μοντέλου, αλλά κυρίως τη γενικευσιμότητά του.

Το αρχικό σύνολο δεδομένων της εργασίας είχε οργανωθεί σε ημερήσιο πλέγμα για την Ελλάδα, με χωρική ανάλυση περίπου 0,25° και με βασικές μετεωρολογικές και παράγωγες μεταβλητές, όπως θερμοκρασία αέρα, σημείο δρόσου, βροχόπτωση, άνεμος, FWI, KBDI, PET, SPEI και χρονικές κωδικοποιήσεις. Αντίθετα, το FireCube είναι γεωχωρικό datacube υψηλότερης χωρικής ανάλυσης, με ημερήσια χωρική πληροφορία 1 km × 1 km για την Ελλάδα και με πλουσιότερο σύνολο περιβαλλοντικών μεταβλητών. Στο FireCube περιλαμβάνονται όχι μόνο μετεωρολογικά χαρακτηριστικά, αλλά και στοιχεία που σχετίζονται με τοπογραφία, βλάστηση, κάλυψη γης και χωρικό περιβάλλον, όπως υψόμετρο, κλίση, NDVI, land-cover κατηγορίες και απόσταση από δρόμους.

Το FireCube δεν χρησιμοποιήθηκε για την αρχική εκπαίδευση των μοντέλων, αλλά για εξωτερική αξιολόγηση και προσαρμογή. Η αξιολόγηση περιορίστηκε σε υποσύνολο τεσσάρων ετών, από το 2018 έως το 2021, και στους μήνες της αντιπυρικής περιόδου, δηλαδή Μάιο έως Σεπτέμβριο. Ο περιορισμός αυτός έγινε για πρακτικούς λόγους μνήμης και υπολογιστικού κόστους, αλλά και επειδή η περίοδος αυτή συγκεντρώνει το μεγαλύτερο επιχειρησιακό ενδιαφέρον για την πρόβλεψη πυρκαγιών. Στο αντίστοιχο αρχείο πειραμάτων αναφέρεται ότι η αξιολόγηση έγινε στο διάστημα 2018-2021, με χρονικό παράθυρο 7 ημερών και με διαχωρισμό train, validation και test.

Για τον λόγο αυτό, το FireCube δεν αξιολογήθηκε μόνο με κλασική accuracy. Η accuracy σε ανισόρροπα δεδομένα μπορεί να είναι παραπλανητική, επειδή ένα μοντέλο που προβλέπει σχεδόν παντού no-fire μπορεί να φαίνεται καλό αριθμητικά, χωρίς να είναι χρήσιμο. Αντίθετα, η αξιολόγηση βασίστηκε κυρίως σε PR-AUC, ROC-AUC, recall, precision, F1-score και top-percentile ανάλυση. Ιδιαίτερα η PR-AUC και η top-1% precision είναι σημαντικές, επειδή εξετάζουν αν το μοντέλο μπορεί να κατατάξει σωστά τις πιο επικίνδυνες περιοχές, ακόμη και όταν η απόλυτη συχνότητα της θετικής κλάσης είναι πολύ μικρή.

Συνολικά, το σενάριο FireCube σχεδιάστηκε ως αυστηρός έλεγχος εξωτερικής γενίκευσης. Δεν είχε ως στόχο να επιβεβαιώσει απλώς ότι το μοντέλο αποδίδει καλά στο ίδιο είδος δεδομένων, αλλά να δείξει τι συμβαίνει όταν το μοντέλο μεταφέρεται σε νέο πεδίο.

7.2 Εναρμόνιση δεδομένων και προεπεξεργασία για μεταφορά

Για να αξιολογηθεί το προεκπαιδευμένο U-Net στο FireCube, δεν ήταν δυνατό να χρησιμοποιηθούν τα δεδομένα απευθείας στη μορφή που παρέχονται. Το αρχικό μοντέλο είχε εκπαιδευτεί σε διαφορετικό σύνολο δεδομένων, με συγκεκριμένη χωρική ανάλυση, συγκεκριμένη διάταξη χαρακτηριστικών, συγκεκριμένο χρονικό παράθυρο και συγκεκριμένα στατιστικά κανονικοποίησης. Επομένως, πριν από την αξιολόγηση ή το fine-tuning, έπρεπε να δημιουργηθεί μία ροή εναρμόνισης, ώστε το FireCube να μετατραπεί όσο γίνεται πιο κοντά στο αρχικό σύνολο δεδομένων.

Η εναρμόνιση είχε ως πρώτο στόχο τη χωρική συμβατότητα. Τα δεδομένα επαναπροσαρμόστηκαν χωρικά στο κοινό πλέγμα της εργασίας, ώστε τα FireCube πεδία να αντιστοιχιστούν στις διαστάσεις που μπορούσε να δεχτεί το U-Net. Στα τελικά tensors του πειράματος, τα δεδομένα εισόδου για το fine-tuning οργανώθηκαν σε χωρικό πλέγμα 33×42 , με είσοδο 84 καναλιών, που αντιστοιχεί σε επτάμερο παράθυρο με πολλαπλά χαρακτηριστικά ανά ημέρα.

Το δεύτερο βήμα ήταν η χρονική εναρμόνιση. Το FireCube μετατράπηκε σε ακολουθίες επτά ημερών. Για κάθε ημέρα στόχο, το μοντέλο λάμβανε ως είσοδο τις προηγούμενες ημέρες μετεωρολογικών και περιβαλλοντικών συνθηκών. Με αυτόν τον τρόπο διατηρήθηκε η ίδια λογική που είχε χρησιμοποιηθεί στην αρχική εκπαίδευση.

Το τρίτο βήμα ήταν η ανακατασκευή ή αντιστοίχιση χαρακτηριστικών. Το FireCube δεν είχε ακριβώς την ίδια μορφή μεταβλητών με το αρχικό σύνολο δεδομένων. Για να μειωθεί αυτή η διαφορά, ανακατασκευάστηκαν ή προσεγγίστηκαν χαρακτηριστικά που υπήρχαν στο αρχικό, όπως PET, KBDI και SPEI, όπου αυτό ήταν εφικτό. Παράλληλα, χρησιμοποιήθηκαν μετεωρολογικές μεταβλητές όπως θερμοκρασία, σημείο δρόσου, άνεμος, βροχόπτωση και FWI, ώστε το μοντέλο να δει εισόδους νοηματικά συγγενείς με εκείνες της αρχικής εκπαίδευσης.

Ιδιαίτερη προσοχή χρειάστηκε και στις μονάδες μέτρησης. Μία κρίσιμη διόρθωση ήταν η μετατροπή θερμοκρασιακών μεταβλητών από Kelvin σε Celsius, ώστε οι τιμές να είναι συμβατές με τον τρόπο με τον οποίο είχαν υπολογιστεί τα χαρακτηριστικά στο αρχικό.

Μετά την αντιστοίχιση χαρακτηριστικών εφαρμόστηκε κανονικοποίηση με βάση τα στατιστικά του αρχικού training set. Αυτό ήταν απαραίτητο επειδή το U-Net είχε μάθει να επεξεργάζεται εισόδους με συγκεκριμένη κατανομή τιμών. Αν το FireCube κανονικοποιούνταν ανεξάρτητα, το μοντέλο θα έβλεπε διαφορετική κλίμακα εισόδων από αυτήν στην οποία είχε εκπαιδευτεί. Επομένως, χρησιμοποιήθηκαν οι αρχικές μέσες τιμές και τυπικές αποκλίσεις, ώστε το FireCube να προβληθεί στο ίδιο αριθμητικό πλαίσιο με το source domain.

Ο στόχος μετατράπηκε επίσης σε συμβατή μορφή. Για κάθε ημέρα και κάθε κελί του πλέγματος δημιουργήθηκε δυαδικός χάρτης, όπου η τιμή 1 αντιστοιχεί σε παρουσία πυρκαγιάς ή ignition point και η τιμή 0 σε απουσία πυρκαγιάς. Έτσι, το πρόβλημα παρέμεινε segmentation-like, όπως και στο αρχικό U-Net: το μοντέλο δεν προβλέπει μία συνολική ετικέτα ημέρας, αλλά έναν χωρικό χάρτη πιθανότητας πυρκαγιάς.

Μετά την εναρμόνιση, το τελικό FireCube υποσύνολο διαχωρίστηκε σε train, validation και test. Στα πειράματα χρησιμοποιήθηκε αναλογία περίπου 70% / 15% / 15%, με 401 δείγματα για εκπαίδευση, 86 για validation και 87 για test. Το μοντέλο εκπαιδεύτηκε με batch size 4, αρχικά για 5 εποχές στο πρώτο στάδιο και στη συνέχεια για 10 εποχές στο δεύτερο στάδιο fine-tuning.

Η διαδικασία αυτή δεν εξάλειψε πλήρως τη μετατόπιση μεταξύ των δύο πεδίων δεδομένων. Αντίθετα, έδειξε ότι ακόμη και με προσεκτική εναρμόνιση, το FireCube παραμένει διαφορετικό πεδίο δεδομένων. Η διαφορά στη χωρική ανάλυση, στη συχνότητα των θετικών pixels, στη σύνθεση των χαρακτηριστικών και στον τρόπο κατασκευής του στόχου επηρεάζει ουσιαστικά τη συμπεριφορά του μοντέλου. Για αυτόν τον λόγο, η εναρμόνιση θεωρήθηκε αναγκαία αλλά όχι επαρκής συνθήκη. Χρειάστηκε επιπλέον fine-tuning, ώστε το U-Net να προσαρμόσει τις αναπαραστάσεις του στο νέο πεδίο δεδομένων.

7.3 Fine-tuning και αξιολόγηση του U-Net στο FireCube

Η μεταφορά του U-Net στο FireCube δεν αποτελεί άμεση τεκμηρίωση της ικανότητας γενίκευσης του αρχικού U-Net σε επιχειρησιακό πλαίσιο πρόγνωσης κινδύνου για την επόμενη ημέρα. Αντίθετα, αξιοποιείται ως πειραματική διαδικασία για την εξέταση του βαθμού προσαρμογής μιας προεκπαιδευμένης χωρικής αρχιτεκτονικής σε διαφορετικό πεδίο δεδομένων μετά από αναπροσαρμογή των παραμέτρων της.

Μετά την αποτυχημένη zero-shot μεταφορά, το U-Net προσαρμόστηκε στο FireCube μέσω fine-tuning. Η διαδικασία δεν ξεκίνησε από μηδενική εκπαίδευση, αλλά χρησιμοποίησε το pretrained U-Net ως αρχικό σημείο, με σκοπό να διατηρηθούν οι βασικές χωρικές αναπαραστάσεις και να προσαρμοστούν στη διαφορετική κατανομή του FireCube.

Η εκπαίδευση πραγματοποιήθηκε σε δύο στάδια. Αρχικά, ο κωδικοποιητής του U-Net πάγωσε και εκπαιδεύτηκαν κυρίως τα αποκωδικοποιητικά στρώματα, ώστε να προσαρμοστεί η έξοδος του μοντέλου στις νέες ετικέτες. Στη συνέχεια, ξεπάγωσε ολόκληρο το δίκτυο και η εκπαίδευση συνεχίστηκε με χαμηλότερο ρυθμό μάθησης. Συγκεκριμένα, χρησιμοποιήθηκαν 5 εποχές για το πρώτο στάδιο και 10 εποχές για το δεύτερο, με τιμές 0.0001 και 0.00001 αντίστοιχα.

Για την εκπαίδευση χρησιμοποιήθηκε focal loss, λόγω της ακραίας ανισορροπίας κλάσεων στο FireCube. Η θετική κλάση, δηλαδή τα pixels με πυρκαγιά, είναι εξαιρετικά σπάνια σε σχέση με τα no-fire pixels. Η focal loss μειώνει την επίδραση των εύκολων αρνητικών παραδειγμάτων και δίνει μεγαλύτερη έμφαση στα δύσκολα ή σπάνια θετικά δείγματα.

Μετά το fine-tuning, η απόδοση του U-Net βελτιώθηκε σημαντικά σε σχέση με το zero-shot σενάριο. Η PR-AUC αυξήθηκε από περίπου 0.0007 σε 0.0097, ενώ η ROC-AUC αυξήθηκε από περίπου 0.56 σε 0.823. Το αποτέλεσμα αυτό δείχνει ότι το pretrained μοντέλο περιείχε μεταφέρσιμες χωρικές αναπαραστάσεις, αλλά απαιτούσε προσαρμογή στο νέο domain.

Στην threshold-based αξιολόγηση, με κατώφλι 0.05, το fine-tuned U-Net πέτυχε recall 0.942, precision 0.00265 και F1-score 0.00529. Η confusion matrix έδειξε 163 true positives, 10 false negatives και μεγάλο αριθμό false positives, γεγονός που εξηγεί τη χαμηλή precision. Η συμπεριφορά αυτή είναι αναμενόμενη λόγω του εξαιρετικά χαμηλού positive rate του Firecube.

Πίνακας 7.1 Απόδοση του fine-tuned U-Net στο FireCube test set

Μετρική	Fine-tuned U-Net στο Firecube
PR-AUC	0.0097
ROC-AUC	0.823
Threshold	0.05
Precision	0.00265
Recall	0.942
F1-score	0.00529

Η υψηλή recall δείχνει ότι το μοντέλο εντόπισε τη μεγάλη πλειονότητα των πραγματικών fire pixels, στοιχείο σημαντικό για εφαρμογές έγκαιρης προειδοποίησης. Ωστόσο, η πολύ χαμηλή precision δείχνει ότι το μοντέλο δεν πρέπει να ερμηνευθεί ως αυστηρός δυαδικός ταξινομητής. Αντίθετα, στο FireCube λειτουργεί καλύτερα ως σύστημα κατάταξης περιοχών κινδύνου.

Για τον λόγο αυτό εξετάστηκε και η συμπεριφορά του μοντέλου στις υψηλότερες προβλεπόμενες πιθανότητες. Στο ανώτερο 1% των πιο επικίνδυνων προβλέψεων, το U-Net πέτυχε precision περίπου 2.24%, δηλαδή περίπου 40 φορές υψηλότερη από το base rate του FireCube. Αυτό αποτελεί πιο ουσιαστικό επιχειρησιακό εύρημα από την απλή threshold-based precision, καθώς δείχνει ότι το μοντέλο μπορεί να ιεραρχήσει περιοχές υψηλού κινδύνου, ακόμη και όταν οι απόλυτες πιθανότητες παραμένουν χαμηλές.

7.4 Fine-tuning του ConvNeXt-UNet στο FireCube

Εκτός από το fine-tuning του U-Net, εξετάστηκε και ένα υβριδικό μοντέλο ConvNeXt-UNet ειδικά για το FireCube. Το πείραμα αυτό είχε στόχο να αξιολογήσει αν μια ισχυρότερη συνελικτική αρχιτεκτονική, βασισμένη σε ConvNeXt blocks και decoder τύπου U-Net, μπορεί να αξιοποιήσει καλύτερα τη υψηλότερης ανάλυσης γεωχωρική πληροφορία του FireCube. Σε αντίθεση με το απλό U-Net, το οποίο μεταφέρθηκε από το αρχικό σύνολο δεδομένων, το ConvNeXt-UNet εκπαιδεύτηκε πάνω σε FireCube patches, χρησιμοποιώντας τα διαθέσιμα δυναμικά, στατικά και fire-spread χαρακτηριστικά.

Η είσοδος του μοντέλου οργανώθηκε σε patches διαστάσεων 32×32 pixels, που αντιστοιχούν σε χωρικά τμήματα 32×32 km σε ανάλυση 1 km. Για κάθε patch χρησιμοποιήθηκε χρονικό παράθυρο 7 ημερών. Κάθε ημέρα περιλάμβανε 20 χαρακτηριστικά, οδηγώντας σε συνολικά 140 κανάλια εισόδου. Τα χαρακτηριστικά χωρίστηκαν σε τρεις κατηγορίες: δυναμικές μετεωρολογικές/περιβαλλοντικές μεταβλητές, στατικά γεωχωρικά χαρακτηριστικά και χαρακτηριστικά πρόσφατης πυρικής δραστηριότητας. Ο κώδικας περιγράφει το μοντέλο ως FireCube_ConvNeXt_UNet, με patch size 32, window 7 και είσοδο $32 \times 32 \times 140$.

Οι δυναμικές μεταβλητές περιλάμβαναν avg_t2m, avg_d2m, avg_u10, avg_v10, avg_tp, max_wind_speed, avg_rh, fwi, evi, ndvi και smian. Τα στατικά χαρακτηριστικά περιλάμβαναν DEM, SLOPE, CLC_2018_6, CLC_2018_7 και ROAD_DISTANCE. Τα χαρακτηριστικά πρόσφατης πυρικής δραστηριότητας περιλάμβαναν current_fire, fire_neighbours, fire_2day και fire_3day. Η χρήση αυτών των ομάδων επέτρεψε στο μοντέλο να αξιοποιήσει όχι μόνο τον καιρό, αλλά και το ανάγλυφο, τη βλάστηση, την κάλυψη γης, την προσβασιμότητα και το πρόσφατο ιστορικό πυρικής δραστηριότητας.

Η εκπαίδευση έγινε με χρονικό διαχωρισμό: 2009-2016 για train, 2017-2018 για validation και 2019-2021 για test. Η επιλογή χρονικού split είναι σημαντική, επειδή αποφεύγει την τυχαία ανάμιξη ημερών και επιτρέπει πιο ρεαλιστική αξιολόγηση σε μεταγενέστερη περίοδο. Συνολικά δημιουργήθηκαν 31.963

train patches, 8.286 validation patches και 11.750 test patches. Το ποσοστό φωτιάς παρέμεινε πολύ χαμηλό, περίπου 0.21% στο train, 0.205% στο validation και 0.356% στο test, γεγονός που επιβεβαιώνει την ακραία ανισορροπία του προβλήματος.

Η αρχιτεκτονική βασίστηκε σε δομικά τμήματα τύπου ConvNeXt, τα οποία περιλάμβαναν depthwise συνελίξεις, κανονικοποίηση επιπέδου, συναρτήσεις ενεργοποίησης GELU και υπολειμματικές συνδέσεις. Ο encoder μείωνε σταδιακά τη χωρική διάσταση της πληροφορίας, ενώ ο αποκωδικοποιητής επανέφερε την αρχική ανάλυση διαδικασίας μέσω υπερδειγματοληψίας και συνδέσεων παράκαμψης. Επιπλέον, στο σημείο μέγιστης συμπίεσης της αρχιτεκτονικής ενσωματώθηκε μονάδα πυραμιδικής συγκέντρωσης, ώστε το μοντέλο να λαμβάνει υπόψη πληροφορία από διαφορετικές χωρικές κλίμακες. Η έξοδος ήταν ένας χάρτης πιθανοτήτων πυρκαγιάς ανά pixel του επιμέρους χωρικού τμήματος, ο οποίος παραγόταν με τελικό συνελκτικό στρώμα Conv2D και συνάρτηση ενεργοποίησης sigmoid.

Για την εκπαίδευση χρησιμοποιήθηκε συνδυασμός focal loss και dice loss. Η focal loss ήταν απαραίτητη λόγω της σπανιότητας της θετικής κλάσης, επειδή μειώνει την επίδραση των εύκολων αρνητικών pixels και δίνει μεγαλύτερη έμφαση στα δύσκολα ή θετικά παραδείγματα. Παράλληλα, το dice component βοήθησε στην αντιμετώπιση της ανισορροπίας σε επίπεδο χωρικής μάσκας. Χρησιμοποιήθηκαν επίσης transition weights, ώστε να δοθεί μεγαλύτερο βάρος σε περιοχές όπου εμφανίζεται νέα φωτιά σε σχέση με την προηγούμενη κατάσταση.

Στο validation set, το ConvNeXt-UNet πέτυχε PR-AUC 0.1725 και ROC-AUC 0.9712. Με κατώφλι 0.0494, το οποίο επιλέχθηκε βάσει validation, πέτυχε precision 0.2362, recall 0.2995 και F1-score 0.2641. Στο test set, χρησιμοποιώντας το ίδιο κατώφλι, το μοντέλο πέτυχε PR-AUC 0.1130, ROC-AUC 0.9277, precision 0.2288, recall 0.1769 και F1-score 0.1995.

Πίνακας 7.2 Απόδοση του ConvNeXt-UNet στο FireCube validation και test set.

Split	PR-AUC	ROC-AUC	Threshold	Precision	Recall	F1-score	Positives
Validation	0.1725	0.9712	0.0494	0.2362	0.2995	0.2641	17,400
Test	0.1130	0.9277	0.0494	0.2288	0.1769	0.1995	42,798

Η πτώση από το validation στο test δείχνει ότι το FireCube παραμένει δύσκολο. Το test set αφορά μεταγενέστερη περίοδο και έχει ελαφρώς υψηλότερο fire rate, γεγονός που κάνει την αξιολόγηση πιο απαιτητική. Παρ' όλα αυτά, η ROC-AUC 0.9277 δείχνει ότι το μοντέλο έχει ισχυρή ικανότητα κατάταξης, ενώ η PR-AUC 0.1130 είναι σημαντικά υψηλότερη από το base rate της θετικής κλάσης. Αυτό είναι ιδιαίτερα σημαντικό σε τόσο ανισόρροπα δεδομένα, όπου οι απόλυτες τιμές PR-AUC είναι συνήθως χαμηλές.

Το confusion matrix στο test set δείχνει 11.963.695 true negatives, 25.507 false positives, 35.229 false negatives και 7.569 true positives. Αυτό σημαίνει ότι το μοντέλο είναι αρκετά επιλεκτικό: δεν εντοπίζει όλες τις θετικές περιοχές, αλλά οι θετικές προβλέψεις του έχουν πολύ καλύτερη precision από το απλό fine-tuned U-Net. Επομένως, το ConvNeXt-UNet λειτουργεί περισσότερο ως μοντέλο παραγωγής αξιόπιστων alert zones παρά ως high-recall μοντέλο πλήρους κάλυψης.

Η σύγκριση με το fine-tuned U-Net στο FireCube δείχνει καθαρή διαφοροποίηση. Το fine-tuned U-Net πέτυχε υψηλή recall, περίπου 0.9422, αλλά με πολύ χαμηλή precision, περίπου 0.0027. Αντίθετα, το ConvNeXt-UNet πέτυχε πολύ υψηλότερη precision και F1-score, αλλά με χαμηλότερη recall. Αυτό σημαίνει ότι τα δύο μοντέλα έχουν διαφορετικό επιχειρησιακό προφίλ: το U-Net είναι πιο κατάλληλο

όταν προτεραιότητα είναι να μη χαθούν πιθανές εστίες, ενώ το ConvNeXt-UNet είναι καταλληλότερο όταν ζητούνται λιγότερες αλλά πιο αξιόπιστες προειδοποιήσεις.

Πίνακας 7.3 Σύγκριση fine-tuned U-Net και ConvNeXt-UNet στο FireCube test set.

Μοντέλο	PR-AUC	ROC-AUC	Threshold	Precision	Recall	F1-score
Fine-tuned U-Net	0.0097	0.8228	0.0500	0.0027	0.9422	0.0053
ConvNeXt-UNet	0.1130	0.9277	0.0494	0.2288	0.1769	0.1995

Το αποτέλεσμα αυτό δείχνει ότι η ειδική εκπαίδευση πάνω στο FireCube και η χρήση πλουσιότερων χωρικών χαρακτηριστικών βοήθησαν σημαντικά. Το ConvNeXt-UNet δεν προσπάθησε απλώς να μεταφέρει αναπαραστάσεις από τα αρχικά δεδομένα, αλλά έμαθε απευθείας πάνω στη δομή του FireCube. Έτσι μπόρεσε να αξιοποιήσει μεταβλητές όπως το υψόμετρο, η κλίση, η κάλυψη γης, η απόσταση από δρόμους, η βλάστηση και το πρόσφατο fire context, οι οποίες είναι κρίσιμες σε λεπτότερη γεωχωρική ανάλυση.

8 Συμπεράσματα και Μελλοντική Εργασία

8.1 Απαντήσεις στα ερευνητικά ερωτήματα

Η εργασία είχε ως στόχο να εξετάσει αν τα μετεωρολογικά, περιβαλλοντικά και γεωχωρικά δεδομένα μπορούν να χρησιμοποιηθούν από μοντέλα μηχανικής και βαθιάς μάθησης για την πρόβλεψη κινδύνου πυρκαγιάς στην Ελλάδα. Επίσης, εξετάστηκε αν οι προβλέψεις αυτές μπορούν να είναι επεξηγήσιμες, αξιόπιστες και χρήσιμες σε επιχειρησιακό επίπεδο.

Ερώτημα 1: Ποια μετεωρολογικά και περιβαλλοντικά δεδομένα μπορούν να χρησιμοποιηθούν αποτελεσματικά για την πρόβλεψη πυρκαγιάς;

Τα αποτελέσματα έδειξαν ότι τα δεδομένα αυτά περιέχουν ισχυρό προγνωστικό σήμα. Μεταβλητές όπως η θερμοκρασία αέρα, το σημείο δρόσου, η βροχόπτωση, ο άνεμος, ο FWI, η δυνητική εξατμισοδιαπνοή, οι δείκτες ξηρασίας και η εποχικότητα συνέβαλαν ουσιαστικά στις προβλέψεις των μοντέλων.

Ερώτημα 2: Ποιες αρχιτεκτονικές είναι καλύτερες για χωρική ή χωροχρονική πρόβλεψη πυρκαγιάς;

Το U-Net ήταν ισχυρότερο για πυκνή χαρτογράφηση κινδύνου, το ConvNeXt-U-Net έδωσε πολύ καλή επίδοση στο same-day σενάριο, ενώ το MiniRocket λειτούργησε περισσότερο ως ελαφριά μέθοδος χρονικής κατάταξης.

Ερώτημα 3: Οι προβλέψεις των βαθιών μοντέλων μπορούν να εξηγηθούν με τρόπο συμβατό με τη φυσική λογική του φαινομένου;

Οι τεχνικές SHAP, LIME, Integrated Gradients, Saliency, Grad-CAM και Occlusion έδειξαν ότι τα μοντέλα στηρίζονται κυρίως σε φυσικά εύλογες μεταβλητές.

Ερώτημα 4: Πόσο σημαντική είναι η αβεβαιότητα και η βαθμονόμηση στις προβλέψεις πυρκαγιάς;

Η ανάλυση έδειξε ότι η αβεβαιότητα είναι κρίσιμο στοιχείο για την επιχειρησιακή αξιοποίηση των χαρτών κινδύνου.

Ερώτημα 5: Τα μοντέλα μπορούν να μεταφερθούν αξιόπιστα σε νέο domain, όπως το FireCube;

Η απάντηση ήταν σύνθετη. Η zero-shot μεταφορά του pretrained U-Net στο FireCube δεν ήταν επαρκής, αλλά το fine-tuning του U-Net και το ConvNeXt-UNet βελτίωσαν σημαντικά την ικανότητα εντοπισμού θετικών περιοχών.

Συνολικά, τα ερευνητικά ερωτήματα απαντήθηκαν θετικά, αλλά με σαφείς περιορισμούς. Τα δεδομένα μπορούν να υποστηρίξουν πρόβλεψη πυρκαγιάς, τα βαθιά μοντέλα μπορούν να παράγουν χρήσιμους χάρτες κινδύνου, και οι ΧΑΙ τεχνικές μπορούν να κάνουν τις προβλέψεις πιο ελέγξιμες. Ωστόσο, η πραγματική αξιοποίηση απαιτεί προσοχή στη γενίκευση, στην αβεβαιότητα, στη βαθμονόμηση και στη μεταφορά σε διαφορετικά domains.

8.2 Βασικά επιστημονικά και πρακτικά ευρήματα

Η εργασία ανέδειξε ότι η πρόβλεψη πυρκαγιών μπορεί να αντιμετωπιστεί πιο αποτελεσματικά όταν το πρόβλημα δεν διατυπώνεται απλώς ως δυαδική ταξινόμηση, αλλά ως χωρική χαρτογράφηση κινδύνου. Η παραγωγή χαρτών πιθανότητας σε επίπεδο κελιού επιτρέπει στο μοντέλο να αποτυπώνει όχι μόνο αν υπάρχει πιθανότητα πυρκαγιάς, αλλά και πού συγκεντρώνεται ο κίνδυνος. Αυτό είναι ιδιαίτερα σημαντικό για εφαρμογές πολιτικής προστασίας, όπου η χωρική θέση της πρόβλεψης έχει μεγαλύτερη πρακτική αξία από μια συνολική πρόβλεψη ημέρας.

Ένα βασικό επιστημονικό εύρημα είναι ότι οι μετεωρολογικές και περιβαλλοντικές μεταβλητές περιέχουν ισχυρό προγνωστικό σήμα. Η θερμοκρασία αέρα, το σημείο δρόσου, η δυνητική εξατμισοδιαπνοή, ο FWI, οι δείκτες ξηρασίας και η εποχικότητα εμφανίστηκαν επανειλημμένα ως σημαντικοί παράγοντες στις τεχνικές επεξηγησιμότητας. Το γεγονός ότι διαφορετικές μέθοδοι, όπως SHAP, Integrated Gradients, Saliency και LIME-like εξηγήσεις, ανέδειξαν παρόμοιες κατηγορίες χαρακτηριστικών, δείχνει ότι τα μοντέλα έμαθαν σχέσεις συμβατές με τη φυσική λογική του φαινομένου και όχι τυχαία ή μη ερμηνεύσιμα μοτίβα.

Σε επίπεδο αρχιτεκτονικών, το U-Net αποδείχθηκε ιδιαίτερα κατάλληλο για πυκνή χαρτογράφηση κινδύνου, καθώς παράγει χωρικά συνεκτικές προβλέψεις και μπορεί να διατηρεί λεπτομέρεια σε επίπεδο pixel. Το ViT προσέφερε διαφορετική οπτική, επειδή αξιοποιεί ευρύτερες χωροχρονικές συσχετίσεις, αλλά ήταν πιο ευαίσθητο στη διατύπωση του προβλήματος και στην ανισορροπία της θετικής κλάσης. Το ConvNeXt-UNet, ειδικά στο FireCube, έδειξε ότι η χρήση ισχυρότερου encoder σε συνδυασμό με decoder τύπου U-Net μπορεί να βελτιώσει την απόδοση σε πιο απαιτητικό γεωχωρικό domain.

Ένα ακόμη σημαντικό εύρημα είναι ότι η επεξηγησιμότητα δεν αποτελεί απλή οπτική προσθήκη, αλλά λειτουργεί ως εργαλείο ελέγχου της αξιοπιστίας του μοντέλου. Οι χωρικοί χάρτες Grad-CAM, SHAP, Integrated Gradients και Saliency έδειξαν αν τα μοντέλα εστιάζουν κοντά σε πραγματικές ή προβλεπόμενες περιοχές κινδύνου. Ιδιαίτερα στο U-Net, οι εξηγήσεις έδειξαν πιο καθαρή χωρική συγκεντρωση γύρω από fire-susceptible περιοχές, κάτι που ενισχύει την καταλληλότητά του για χαρτογράφηση κινδύνου. Παράλληλα, οι τοπικές εξηγήσεις σε επίπεδο κελιού και χρονικού παραθύρου έδειξαν ότι η συμβολή κάθε μεταβλητής εξαρτάται από τη χρονική στιγμή μέσα στο επτάημερο παράθυρο, με τις πιο πρόσφατες ημέρες να έχουν συχνά μεγαλύτερη σημασία.

Η ανάλυση στο FireCube έδειξε ότι η μεταφορά σε νέο domain είναι δύσκολη και δεν μπορεί να θεωρηθεί δεδομένη. Η zero-shot αξιολόγηση του pretrained U-Net είχε πολύ χαμηλή απόδοση, γεγονός που επιβεβαίωσε την ύπαρξη έντονου domain shift. Με fine-tuning η συμπεριφορά βελτιώθηκε, κυρίως ως προς την ικανότητα εντοπισμού θετικών περιοχών. Το ConvNeXt-UNet που εκπαιδεύτηκε ειδικά στο FireCube πέτυχε καλύτερη ισορροπία precision και F1-score, δείχνοντας ότι η ειδική εκπαίδευση

στο πεδίο-στόχο και η αξιοποίηση χαρακτηριστικών που παρέχει το FireCube είναι κρίσιμες για εξωτερική γενίκευση.

Πρακτικά, η εργασία έδειξε ότι διαφορετικά μοντέλα μπορούν να εξυπηρετήσουν διαφορετικές ανάγκες. Ένα high-recall μοντέλο, όπως το fine-tuned U-Net στο FireCube, είναι χρήσιμο όταν προτεραιότητα είναι να μη χαθούν πιθανές εστίες. Ένα πιο επιλεκτικό μοντέλο, όπως το ConvNeXt-UNet, είναι χρησιμότερο όταν ζητούνται λιγότερες αλλά πιο αξιόπιστες ειδοποιήσεις. Το MiniRocket, παρότι δεν επιλέχθηκε ως κύρια λύση, επιβεβαίωσε ότι οι χρονικές ακολουθίες ανά κελί περιέχουν χρήσιμο σήμα και μπορεί να λειτουργήσει ως γρήγορο temporal baseline.

Με βάση το σύνολο των πειραμάτων, η τελική επιλογή της εργασίας δεν είναι ένα μόνο μοντέλο για όλα τα σενάρια, αλλά διαφοροποιείται ανάλογα με το πεδίο εφαρμογής. Για το κύριο σύστημα πρόβλεψης πυρκαγιάς επιλέχθηκε το U-Net με βαθμονομημένη και uncertainty-aware έξοδο, καθώς παρέχει υψηλή προβλεπτική απόδοση, παράγει πυκνούς χάρτες κινδύνου σε επίπεδο χωρικού κελιού, επιτρέπει σαφή χωρική ερμηνεία των αποτελεσμάτων και υποστηρίζει την εκτίμηση της αβεβαιότητας των προβλέψεων. Το U-Net υπερέχει του ViT στο precision-recall πεδίο, με PR-AUC περίπου 0.966 έναντι 0.869, και έδειξε πιο σταθερή συμπεριφορά στην ανίχνευση σπάνιων fire pixels. Επιπλέον, η χρήση MC Dropout και residual-cVAE επέτρεψε την παραγωγή χαρτών πιθανότητας και χαρτών αβεβαιότητας, ώστε το σύστημα να δείχνει όχι μόνο πού υπάρχει αυξημένος κίνδυνος, αλλά και πόσο αξιόπιστη είναι η πρόβλεψη.

Συνολικά, το βασικό εύρημα της εργασίας είναι ότι η πρόβλεψη πυρκαγιών με τεχνητή νοημοσύνη χρειάζεται τρία επίπεδα: ισχυρή προγνωστική μοντελοποίηση, ερμηνευσιμότητα των αποφάσεων και αξιολόγηση της αβεβαιότητας. Χωρίς το πρώτο, το σύστημα δεν έχει επαρκή απόδοση. Χωρίς το δεύτερο, δεν μπορεί να ελεγχθεί αν οι προβλέψεις έχουν φυσικό νόημα. Χωρίς το τρίτο, οι χάρτες κινδύνου δεν είναι αρκετά αξιόπιστοι για πρακτική χρήση.

8.3 Περιορισμοί της εργασίας

Παρότι η παρούσα εργασία κάλυψε τον βασικό στόχο της, δηλαδή την ανάπτυξη και αξιολόγηση επεξηγήσιμων μοντέλων τεχνητής νοημοσύνης για την πρόβλεψη πυρκαγιών με βάση κυρίως μετεωρολογικά δεδομένα, υπάρχουν ορισμένοι περιορισμοί που πρέπει να αναφερθούν. Οι περιορισμοί αυτοί δεν μειώνουν τη συμβολή της εργασίας, αλλά οριοθετούν το πεδίο εφαρμογής των αποτελεσμάτων και δείχνουν τα σημεία που μπορούν να βελτιωθούν σε μελλοντική έρευνα.

Ο πρώτος περιορισμός αφορά την ποιότητα και την πληρότητα των δεδομένων. Η εργασία βασίστηκε κυρίως σε μετεωρολογικές και πυρομετεωρολογικές μεταβλητές, οι οποίες έχουν άμεση σχέση με την πιθανότητα εκδήλωσης πυρκαγιάς. Παρόλα αυτά, η πραγματική εμφάνιση πυρκαγιάς επηρεάζεται και από άλλους παράγοντες, όπως η ανθρώπινη δραστηριότητα, η κατάσταση της καύσιμης ύλης, οι τοπικές χρήσεις γης, η διαχείριση της βλάστησης και η μικροτοπογραφία. Αυτοί οι παράγοντες δεν ενσωματώθηκαν στην ανάλυση με την ίδια λεπτομέρεια.

Ένας δεύτερος σημαντικός περιορισμός είναι η χωρική ανάλυση του συνόλου δεδομένων. Η εργασία χρησιμοποιούσε πλέγμα με ημερήσια χωρική αναπαράσταση περίπου $0,25^\circ$, το οποίο είναι χρήσιμο για περιφερειακή εκτίμηση κινδύνου, αλλά δεν μπορεί να αποτυπώσει όλες τις τοπικές διαφοροποιήσεις που επηρεάζουν μια πραγματική ανάφλεξη. Για παράδειγμα, μικρές αλλαγές στην κλίση, στη βλάστηση, στην πρόσβαση από δρόμους ή στην τοπική διεύθυνση του ανέμου μπορεί να έχουν σημασία σε πραγματικές συνθήκες, αλλά να μην διακρίνονται πλήρως σε πιο χονδρικό πλέγμα.

Ένας ακόμη περιορισμός αφορά την κατασκευή των ετικετών πυρκαγιάς. Οι ετικέτες δημιουργήθηκαν με βάση ιστορικά δεδομένα πυρκαγιών και δορυφορικούς εντοπισμούς ενεργών εστιών, οι οποίες είναι κατάλληλες για την έρευνα, αλλά όχι απαλλαγμένες από αβεβαιότητα. Υπάρχουν πιθανότητες για χρονικές αποκλίσεις, χωρικά σφάλματα, διαφορετικοί ορισμοί για ενεργές εστίες και καμένες περιοχές, καθώς και ελλειπείς ή θορυβώδεις καταγραφές. Αυτό σημαίνει ότι το μοντέλο εκπαιδεύεται πάνω σε μια προσεγγιστική αναπαράσταση του φαινομένου και όχι σε απόλυτα ακριβή καταγραφή.

Η ανισορροπία των κλάσεων αποτελεί επίσης σημαντικό περιορισμό. Οι πυρκαγιές είναι σπάνια γεγονότα σε σχέση με το σύνολο των ημερών και των χωρικών κελιών χωρίς πυρκαγιά. Για αυτόν τον λόγο, η απλή accuracy δεν επαρκεί για την αξιολόγηση των μοντέλων και μπορεί να οδηγήσει σε λανθασμένα συμπεράσματα. Η εργασία έδωσε έμφαση σε μετρικές όπως το PR-AUC, ROC-AUC, precision, recall και F1-score. Παρόλα αυτά, ειδικά στο FireCube, η πολύ χαμηλή συχνότητα θετικών pixels επηρέασε σημαντικά την precision, ακόμη και όταν τα μοντέλα διατηρούσαν ικανοποιητική ικανότητα κατάταξης περιοχών υψηλού κινδύνου.

Υπάρχει περιορισμός και στον τρόπο με τον οποίο μοντελοποιήθηκε ο χρόνος. Τα περισσότερα βαθιά μοντέλα χρησιμοποίησαν επταήμερο χρονικό παράθυρο για να αξιοποιηθούν οι πρόσφατες μετεωρολογικές συνθήκες πριν από το συμβάν. Αυτή η επιλογή είναι πρακτική, αλλά δεν καλύπτει πλήρως όλες τις μακροχρόνιες διεργασίες που σχετίζονται με την ξηρασία και την εποχική εξέλιξη της καύσιμης ύλης. Οι δείκτες SPEI και KBDI περιορίζουν εν μέρει αυτό το πρόβλημα, αλλά δεν αντικαθιστούν ένα πλήρες πολυκλιμακικό χρονικό μοντέλο.

Σε επίπεδο αρχιτεκτονικών, κάθε μοντέλο είχε διαφορετικούς περιορισμούς. Το U-Net αποδείχθηκε ιδιαίτερα χρήσιμο για πυκνή χαρτογράφηση κινδύνου, αλλά δεν διαθέτει εγγενή recurrent μηχανισμό για τη χρονική μνήμη. Το ViT μπορεί να συλλάβει μακρινές χωροχρονικές σχέσεις, αλλά είναι πιο ευαίσθητο στο μέγεθος των δεδομένων και στην ανισορροπία της θετικής κλάσης. Το MiniRocket ήταν γρήγορο και χρήσιμο ως temporal baseline, αλλά δεν αξιοποιεί ρητά τη χωρική συνέχεια. Το ConvNeXt-UNet έδειξε ισχυρή συμπεριφορά στο FireCube, αλλά απαιτεί ειδική εκπαίδευση στο target domain.

Ένας σημαντικός περιορισμός αφορά τον χρονικό ορισμό του στόχου στο βασικό U-Net. Το μοντέλο χρησιμοποιεί 7ήμερο παράθυρο που περιλαμβάνει την ημέρα-στόχο και επομένως η αξιολόγηση αφορά same-day wildfire risk estimation. Αυτό σημαίνει ότι τα αποτελέσματα δεν πρέπει να παρουσιάζονται ως αυστηρή επιχειρησιακή πρόγνωση επόμενης ημέρας. Η διάκριση αυτή είναι κρίσιμη, επειδή η χρήση μετεωρολογικών μεταβλητών της ίδιας ημέρας μπορεί να προσφέρει πληροφορία που δεν θα ήταν διαθέσιμη σε πραγματικό σενάριο πρόγνωσης επόμενης ημέρας.

Η μεταφορά σε νέο domain αποτέλεσε επίσης σημαντικό περιορισμό. Η αξιολόγηση στο FireCube έδειξε ότι η απλή εφαρμογή ενός pretrained μοντέλου δεν είναι επαρκής. Ακόμη και μετά από εναρμόνιση χαρακτηριστικών, οι διαφορές στη χωρική ανάλυση, στη στατιστική κατανομή των μεταβλητών, στον τρόπο κατασκευής των labels και στη συχνότητα των θετικών περιστατικών επηρέασαν σημαντικά την απόδοση. Αυτό δείχνει ότι τα μοντέλα πρόβλεψης πυρκαγιών χρειάζονται προσαρμογή και fine-tuning όταν εφαρμόζονται σε διαφορετικό σύνολο δεδομένων ή περιβάλλον.

Παρόλα αυτά, η εργασία επιτυγχάνει τον βασικό της στόχο: δείχνει ότι τα επεξηγήσιμα μοντέλα τεχνητής νοημοσύνης μπορούν να αξιοποιήσουν μετεωρολογικά και ιστορικά δεδομένα πυρκαγιών, να παράγουν χρήσιμες προβλέψεις κινδύνου και να προσφέρουν ερμηνείες που ενισχύουν την κατανόηση και την αξιοπιστία των αποτελεσμάτων.

8.4 Προτάσεις για μελλοντική έρευνα

Με βάση τα αποτελέσματα και τους περιορισμούς της εργασίας, υπάρχουν αρκετές κατευθύνσεις για μελλοντική έρευνα. Η πρώτη αφορά τον εμπλουτισμό των δεδομένων με περισσότερα γεωχωρικά και ανθρωπογενή χαρακτηριστικά. Εκτός από τις μετεωρολογικές μεταβλητές, θα ήταν χρήσιμη η ενσωμάτωση πιο λεπτομερών δεδομένων για τη βλάστηση, την καύσιμη ύλη, την κάλυψη γης, το οδικό δίκτυο, την απόσταση από οικισμούς και την ανθρώπινη δραστηριότητα. Τα αποτελέσματα στο FireCube έδειξαν ότι τέτοιες μεταβλητές, όπως το υψόμετρο, η κλίση, το NDVI και η απόσταση από δρόμους, μπορούν να επηρεάσουν σημαντικά την ερμηνεία και την απόδοση των μοντέλων.

Η uncertainty-aware χαρτογράφηση μπορεί να αναπτυχθεί περισσότερο. Μελλοντικά θα ήταν χρήσιμη η σύγκριση περισσότερων μεθόδων αβεβαιότητας, όπως deep ensembles, Bayesian neural networks ή evidential learning. Παράλληλα, η αβεβαιότητα μπορεί να ενσωματωθεί πιο άμεσα σε decision-aware συστήματα, όπου το μοντέλο δεν δίνει μόνο πιθανότητα πυρκαγιάς, αλλά και επίπεδο εμπιστοσύνης, κατηγορία κινδύνου και ένδειξη για το αν απαιτείται ανθρώπινος έλεγχος.

Μελλοντική εργασία θα μπορούσε επίσης να εξετάσει αυστηρό next-day forecasting, όπου η είσοδος θα περιορίζεται αποκλειστικά σε πληροφορία διαθέσιμη πριν από την ημέρα-στόχο. Επιπλέον, θα είχε αξία η αξιολόγηση των χαρτών κινδύνου από ειδικούς πολιτικής προστασίας ή δασοφυλάκους, ώστε να εξεταστεί αν οι προβλέψεις είναι πρακτικά αξιοποιήσιμες και όχι μόνο στατιστικά ισχυρές.

Συνολικά, η μελλοντική έρευνα μπορεί να κινηθεί προς ένα πιο ολοκληρωμένο, πολυπηγικό και επιχειρησιακά ελέγξιμο πλαίσιο πρόβλεψης. Η παρούσα εργασία δείχνει ότι τα επεξηγήσιμα μοντέλα τεχνητής νοημοσύνης μπορούν να υποστηρίξουν την πρόβλεψη πυρκαγιών, αλλά η επόμενη φάση πρέπει να εστιάσει στη γενίκευση, στη σύνδεση με πραγματικές προγνώσεις, στην αξιολόγηση από ειδικούς και στη μετατροπή των ερευνητικών χαρτών κινδύνου σε πρακτικά εργαλεία υποστήριξης αποφάσεων.

ΒΙΒΛΙΟΓΡΑΦΙΑ

Online sources / datasets / software

- [1] Copernicus Climate Change Service, “Fire Weather Index,” 2026. [Online]. Available: Copernicus Climate Data Store.
- [2] P. Zippenfenig, “Open-Meteo.com Weather API,” Zenodo, 2023.
- [3] Copernicus Emergency Management Service, “EFFIS data and services,” 2026. [Online]. Available: European Forest Fire Information System.
- [4] Copernicus Climate Change Service, “ERA5-Land hourly data from 1950 to present,” ECMWF Climate Data Store, 2026.
- [5] Copernicus Climate Change Service, “Fire danger indices historical data from the Copernicus Emergency Management Service,” ECMWF Climate Data Store, 2019.
- [6] I. Prapas, S. Kondylatos, and I. Papoutsis, “FireCube: A daily datacube for the modeling and analysis of wildfires in Greece,” Zenodo, May 2022.
- [7] NASA FIRMS, “Fire Information for Resource Management System,” 2026. [Online]. Available: NASA FIRMS.
- [8] NASA Earthdata, “VIIRS I-Band 375 m active fire data,” 2026. [Online]. Available: NASA Earthdata.
- [9] NASA Earthdata, “Active fire data attributes for MODIS and VIIRS,” 2026. [Online]. Available: NASA Earthdata.

Books / Reports / Manuals

- [10] C. E. Van Wagner, *Development and Structure of the Canadian Forest Fire Weather Index System*. Ottawa, Canada: Canadian Forestry Service, Forestry Technical Report 35, 1987.
- [11] J. J. Keetch and G. M. Byram, *A Drought Index for Forest Fire Control*, Research Paper SE-38. Asheville, NC, USA: U.S. Department of Agriculture, Forest Service, 1968.
- [12] R. G. Allen, L. S. Pereira, D. Raes, and M. Smith, *Crop Evapotranspiration: Guidelines for Computing Crop Water Requirements*, FAO Irrigation and Drainage Paper 56. Rome, Italy: FAO, 1998.

Journal articles

- [13] X. Yang et al., “Explainable artificial intelligence (XAI) framework using XGBoost and SHAP for assessing urban fire risk based on spatial distribution features,” *International Journal of Disaster Risk Reduction*, vol. 129, Art. no. 105798, 2025.
- [14] M. Wang and W. Deng, “Deep visual domain adaptation: A survey,” *Neurocomputing*, vol. 312, pp. 135–153, 2018.
- [15] W. Schroeder, P. Oliva, L. Giglio, and I. A. Csiszar, “The new VIIRS 375 m active fire detection data product: Algorithm description and initial assessment,” *Remote Sensing of Environment*, vol. 143, pp. 85–96, 2014.
- [16] D. R. Roberts et al., “Cross-validation strategies for data with temporal, spatial, hierarchical, or phylogenetic structure,” *Ecography*, vol. 40, no. 8, pp. 913–929, 2017.

- [17] S. J. Pan and Q. Yang, “A survey on transfer learning,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 22, no. 10, pp. 1345–1359, 2010.
- [18] M. Marjani, S. A. Ahmadi, and M. Mahdianpari, “FirePred: A hybrid multi-temporal convolutional neural network model for wildfire spread prediction,” *Ecological Informatics*, vol. 78, Art. no. 102282, 2023.
- [19] J. Liu et al., “Application of remote sensing and explainable artificial intelligence (XAI) for wildfire occurrence mapping in the mountainous region of Southwest China,” *Remote Sensing*, vol. 16, no. 19, Art. no. 3602, 2024.
- [20] S. Kondylatos et al., “Wildfire danger prediction and understanding with deep learning,” *Geophysical Research Letters*, vol. 49, no. 17, Art. no. e2022GL099368, 2022.
- [21] J. Klaise, A. Van Looveren, G. Vacanti, and A. Coca, “Alibi Explain: Algorithms for explaining machine learning models,” *Journal of Machine Learning Research*, vol. 22, no. 181, pp. 1–7, 2021.
- [22] K. Kakogeorgiou and K. Karantzalos, “Evaluating explainable artificial intelligence methods for multi-label deep learning classification tasks in remote sensing,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 177, pp. 192–214, 2021.
- [23] W. M. Jolly et al., “Climate-induced variations in global wildfire danger from 1979 to 2013,” *Nature Communications*, vol. 6, Art. no. 7537, 2015.
- [24] F. Huot, R. L. Hu, N. Goyal, T. Sankar, M. Ihme, and Y.-F. Chen, “Next day wildfire spread: A machine learning dataset to predict wildfire spreading from remote-sensing data,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, pp. 1–13, 2022.
- [25] H. Hersbach et al., “The ERA5 global reanalysis,” *Quarterly Journal of the Royal Meteorological Society*, vol. 146, no. 730, pp. 1999–2049, 2020.
- [26] L. Giglio, W. Schroeder, and C. O. Justice, “The Collection 6 MODIS active fire detection algorithm and fire products,” *Remote Sensing of Environment*, vol. 178, pp. 31–41, 2016.
- [27] O. Ghorbanzadeh, K. Valizadeh Kamran, T. Blaschke, J. Aryal, A. Naboureh, J. Einali, and J. Bian, “Spatial prediction of wildfire susceptibility using field survey GPS data and machine learning approaches,” *Fire*, vol. 2, no. 3, Art. no. 43, 2019.
- [28] N. Alizadeh, M. Mahdianpari, E. Hemmati, and M. Marjani, “FusionFireNet: A CNN-LSTM model for short-term wildfire hotspot prediction utilizing spatio-temporal datasets,” *Remote Sensing Applications: Society and Environment*, vol. 37, Art. no. 101436, 2025.
- [29] J. T. Abatzoglou and A. P. Williams, “Impact of anthropogenic climate change on wildfire across western US forests,” *Proceedings of the National Academy of Sciences*, vol. 113, no. 42, pp. 11770–11775, 2016.
- [30] S. M. Vicente-Serrano, S. Beguería, and J. I. López-Moreno, “A multiscalar drought index sensitive to global warming: The standardized precipitation evapotranspiration index,” *Journal of Climate*, vol. 23, no. 7, pp. 1696–1718, 2010.
- [31] T. Saito and M. Rehmsmeier, “The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets,” *PLOS ONE*, vol. 10, no. 3, Art. no. e0118432, 2015.
- [32] Y. Xu, J. Li, L. Zhang, H. Liu, and F. Zhang, “CNTCB-YOLOv7: An effective forest fire detection model based on ConvNeXtV2 and CBAM,” *Fire*, vol. 7, no. 2, Art. no. 54, Feb. 2024.

Conference papers

- [33] X. Shi, Z. Chen, H. Wang, D.-Y. Yeung, W.-K. Wong, and W.-C. Woo, “Convolutional LSTM network: A machine learning approach for precipitation nowcasting,” in *Advances in Neural Information Processing Systems*, 2015, vol. 28.
- [34] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, “Grad-CAM: Visual explanations from deep networks via gradient-based localization,” in *Proc. IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 618–626.
- [35] O. Ronneberger, P. Fischer, and T. Brox, “U-Net: Convolutional networks for biomedical image segmentation,” in *Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, 2015, pp. 234–241.
- [36] M. T. Ribeiro, S. Singh, and C. Guestrin, ““Why should I trust you?”: Explaining the predictions of any classifier,” in *Proc. ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD)*, 2016, pp. 1135–1144.
- [37] T.-Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollár, “Focal loss for dense object detection,” in *Proc. IEEE International Conference on Computer Vision (ICCV)*, 2017, pp. 2980–2988.
- [38] Y. Gal and Z. Ghahramani, “Dropout as a Bayesian approximation: Representing model uncertainty in deep learning,” in *Proc. International Conference on Machine Learning (ICML)*, 2016, pp. 1050–1059.
- [39] A. Dosovitskiy et al., “An image is worth 16×16 words: Transformers for image recognition at scale,” in *Proc. International Conference on Learning Representations (ICLR)*, 2021.
- [40] A. Dempster, D. F. Schmidt, and G. I. Webb, “MINIROCKET: A very fast almost deterministic transform for time series classification,” in *Proc. ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD)*, 2021.
- [41] J. Khan, A. H. Butt, M. A. Jamshed, and A. Jalal, “A multi-class confounder-aware deep learning framework for wildfire smoke and fire classification,” in *Proc. International Conference on IT and Industrial Technologies (ICIT)*, 2026, pp. 1–6.
- [42] M. Sundararajan, A. Taly, and Q. Yan, “Axiomatic attribution for deep networks,” in *Proc. International Conference on Machine Learning (ICML)*, 2017, pp. 3319–3328.
- [43] M. D. Zeiler and R. Fergus, “Visualizing and understanding convolutional networks,” in *Proc. European Conference on Computer Vision (ECCV)*, 2014, pp. 818–833.
- [44] S. M. Lundberg and S.-I. Lee, “A unified approach to interpreting model predictions,” in *Proc. Advances in Neural Information Processing Systems (NeurIPS)*, 2017, pp. 4768–4777.
- [45] K. Simonyan, A. Vedaldi, and A. Zisserman, “Deep inside convolutional networks: Visualising image classification models and saliency maps,” in *Proc. International Conference on Learning Representations (ICLR) Workshop*, 2014.

Preprint

- [46] R. Valavi, J. Elith, J. J. Lahoz-Monfort, and G. Guillera-Arroita, “blockCV: An R package for generating spatially or environmentally separated folds for k-fold cross-validation of species distribution models,” *bioRxiv*, 2018.