



ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΤΗΛΕΠΙΚΟΙΝΩΝΙΩΝ
ΠΜΣ ΤΕΧΝΗΤΗ ΝΟΗΜΟΣΥΝΗ ΚΑΙ ΕΦΑΡΜΟΓΕΣ

Μεταπτυχιακή Εργασία

**Ποσοτική Αξιολόγηση της Ανθεκτικότητας Κρίσιμων Οντοτήτων με τη
Χρήση Μοντέλων Μηχανικής Μάθησης και Συνθετικών Δεδομένων:
Εφαρμογή στο Πλαίσιο του Ν. 5236/2025 και του Ν. 5160/2024
[Οδηγίες (ΕΕ) CER 2022/2557 & NIS2 2022/2555]**

Σπυρίδων Δερβίσης

Πατρώνυμο: Ιωάννης

A.M.: 00024 / Ακαδημαϊκός Αριθμός: stu78136

Επιβλέπων:

Αναπληρωτής Καθηγητής

Κωνσταντίνος Κολομβάτσος

Λαμία, Αύγουστος 2026

Περίληψη

Η ανθεκτικότητα των κρίσιμων οντοτήτων, εντός των πλαισίων των Οδηγιών (ΕΕ) CER 2022/2557 και NIS2 2022/2555 και της ενσωμάτωσής τους στην Ελληνική νομοθεσία, με τους Ν. 5236/2025 και Ν. 5160/2024 αντίστοιχα, αποτελεί πλέον στρατηγική προτεραιότητα που δεν μπορεί να αξιολογείται μόνο με ποιοτικά, περιγραφικά κριτήρια. Η παρούσα έρευνα εξετάζει τη δυνατότητα ποσοτικής, δεδομενοκεντρικής αξιολόγησης της ανθεκτικότητας μέσω ενός Σύνθετου Δείκτη Ανθεκτικότητας (Composite Resilience Index - CRI), ο οποίος δημιουργείται ως σταθμισμένος συνδυασμός των τεσσάρων θεσμικών Διαστάσεων, Διακυβέρνηση, Αποδοτικότητα, Αποτελέσματα και Ευθυγράμμιση με το Πλαίσιο Sendai – Στόχος 4, όπως ορίζεται στο Παράρτημα ΣΤ' της Εθνικής Στρατηγικής Ανθεκτικότητας Κρίσιμων Οντοτήτων 2026 – 2030.

Το πειραματικό τμήμα της μελέτης διερευνά την ικανότητα πρόβλεψης της κλάσης ανθεκτικότητας μιας οντότητας, ταξινομημένης σε τέσσερις ισοπληθείς κατηγορίες: «Μη Κρίσιμο», «Χαμηλής Ανθεκτικότητας», «Κρίσιμο» και «Πολύ Κρίσιμο». Αυτή η πρόβλεψη βασίζεται σε έναν περιορισμένο αριθμό εύκολα προσβάσιμων δεικτών (συγκεκριμένα σε 7 από τους 22 επίσημα ορισμένους δείκτες που προβλέπονται στο κείμενο της Εθνικής Στρατηγικής), προσομοιώνοντας ένα πραγματικό σενάριο εποπτείας μερικής πληροφόρησης. Για τον σκοπό αυτό, εκπαιδεύτηκαν και συγκρίθηκαν τρία διαφορετικά μοντέλα για την ταξινόμηση των κλάσεων: η Logistic Regression (ως μοντέλο αναφοράς), το Random Forest και το XGBoost. Πραγματοποιήθηκε συστηματική βελτιστοποίηση υπερπαραμέτρων μέσω της μεθόδου RandomizedSearchCV και αξιολογήθηκαν οι επιδόσεις με χρήση της macro-F1 σε ένα ανεξάρτητο σύνολο ελέγχου, καθώς και μέσω μιας διαδικασίας 5-fold Stratified Cross-Validation. Η διαδικασία αυτή επαναλήφθηκε σε τέσσερα ανεξάρτητα συνθετικά σύνολα δεδομένων διαφορετικού μεγέθους ($n = 5.000, 10.000, 20.000$ και 40.000 οντότητες) με στόχο την αξιολόγηση της σταθερότητας (robustness) των αποτελεσμάτων. Επιπλέον, η ερμηνευσιμότητα των μοντέλων εξετάστηκε μέσω SHAP ανάλυσης, περιλαμβάνοντας διαγράμματα συνολικής σπουδαιότητας (Bar Plots) και κατεύθυνσης της επίδρασης (Beeswarm Plots).

Τα αποτελέσματα της έρευνας ανέδειξαν μια μέτρια αλλά σημαντική προγνωστική ικανότητα, με τις τιμές του macro-F1 να κυμαίνονται περίπου από 0.52 έως 0.55, υπερβαίνοντας το τυχαίο όριο του 0.25. Η σταθερότητα αυτών των αποτελεσμάτων είναι εμφανής σε όλα τα μεγέθη δείγματος, ωστόσο σημειώνεται σημαντική ασυμμετρία στην απόδοση μεταξύ των ακραίων κατηγοριών (με F1-score που κυμαίνεται από 0.63 έως 0.73) και των ενδιάμεσων (με F1-score μεταξύ 0.33 και 0.41). Αντίθετα από την αρχική υπόθεση της μελέτης, η απλή Logistic Regression απέδειξε ότι είναι είτε ισοδύναμη είτε ανώτερη από τα πιο σύνθετα μοντέλα δέντρων, Random Forest και XGBoost, σε όλες τις περιπτώσεις ελέγχου. Αυτό υποδηλώνει ότι η σχέση μεταξύ των διαθέσιμων χαρακτηριστικών και της κλάσης ανθεκτικότητας μπορεί να είναι κατά κύριο λόγο γραμμική. Επιπλέον, η ανάλυση SHAP κατέδειξε συστηματικά ότι οι τομείς δραστηριότητας όπως ο Τραπεζικός κλάδος, οι Υποδομές χρηματοπιστωτικών αγορών και η Ενέργεια, καθώς και δείκτες επιχειρησιακής ετοιμότητας όπως η πιστοποίηση ISO 22301

(B1), οι Ασκήσεις ετοιμότητας (B3) και η Έγκαιρη αναφορά περιστατικών (B5), αποτελούν τους κύριους προγνωστικούς παράγοντες. Αυτά τα ευρήματα ευθυγραμμίζονται πλήρως με τον μηχανισμό δημιουργίας των δεδομένων, ενισχύοντας την εγκυρότητα της μεθοδολογίας που χρησιμοποιήθηκε.

Η διεξαγωγή του πειράματος σε τέσσερα ανεξάρτητα δείγματα λειτούργησε ως έλεγχος για τη στιβαρότητα των αποτελεσμάτων. Το άνω όριο (ταβάνι) απόδοσης, που παρατηρήθηκε, τελικά αποδεικνύεται πως είναι ένα δομικό χαρακτηριστικό του προβλήματος, που οφείλεται στην εκ προθέσεως απόκρυψη πληροφορίας και στον εγγενή στοχαστικό θόρυβο, και όχι ζήτημα που μπορεί να διορθωθεί με μεγαλύτερο δείγμα. Η έρευνα καταλήγει στο συμπέρασμα ότι η χρήση ερμηνεύσιμων μοντέλων μηχανικής μάθησης μπορεί να ενισχύσει την αποτελεσματική κατανομή πόρων εποπτείας και την ιεράρχηση των προτεραιοτήτων από τις αρμόδιες αρχές. Όμως, δεν αντικαθιστά την ανθρώπινη κρίση στις ενδιάμεσες κλάσεις ταξινόμησης (Χαμηλής Ανθεκτικότητας και Κρίσιμο) που αποτελούν πιο σύνθετες περιπτώσεις κινδύνου. Προτείνεται η επικύρωση της μεθόδου χρησιμοποιώντας πραγματικά δεδομένα εποπτείας ως άμεση κατεύθυνση για μελλοντική έρευνα.

Λέξεις Κλειδιά:

Ανθεκτικότητα κρίσιμων οντοτήτων, Δείκτης Ανθεκτικότητας (CRI), Οδηγία CER (EE) 2022/2557, Οδηγία NIS2 (EE) 2022/2555, Μηχανική μάθηση, Ταξινόμηση κλάσης, Random Forest, XGBoost, Logistic Regression, Ερμηνευσιμότητα μοντέλων (SHAP), Συνθετικά δεδομένα, Κρίσιμες υποδομές.

Abstract

The resilience of critical entities, as guided by the EU Directives CER 2022/2557 and NIS2 2022/2555, and their integration into Greek law through Acts No. 5236/2025 and No. 5160/2024, has become a strategic priority that cannot be assessed solely with qualitative criteria. This research explores the potential for quantitatively evaluating resilience through a Data-Driven Composite Resilience Index (CRI). The CRI is a weighted combination of four institutional dimensions: Governance, Efficiency, Outcomes, and Alignment with the Sendai Framework - Target 4, as specified in Annex F of the National Resilience Strategy for Critical Entities 2026 – 2030.

The experimental component of this study explores the capacity to predict the resilience classification of an entity, divided into four equally sized categories: "Non-Critical," "Low Resilience," "Critical," and "Highly Critical." This prediction is grounded in a limited set of easily accessible indicators, specifically 7 out of the 22 officially designated indicators as outlined in the National Strategy document. This approach emulates a realistic partial-information supervision scenario. In pursuit of this goal, three distinct models were trained and compared for classifying these categories: Logistic Regression, serving as a baseline model, Random Forest, and XGBoost. Systematic hyperparameter optimization was conducted using the RandomizedSearchCV method, and performance evaluations were carried out utilizing macro-F1 scores on an independent test set, in conjunction with a 5-fold Stratified Cross-Validation process. This methodology was replicated across four independent synthetic datasets varying in size ($n = 5,000$; $10,000$; $20,000$; and $40,000$ entities) to assess the robustness of the results. Furthermore, the interpretability of the models was analyzed through SHAP analysis, including the use of bar plots for overall feature importance and beeswarm plots to illustrate the direction of impact.

The research findings highlighted a moderate yet important predictive ability, with macro-F1 scores ranging roughly from 0.52 to 0.55, notably surpassing the random threshold of 0.25. There's a noticeable consistency in these results across all sample sizes; however, a significant asymmetry in performance is evident between the extreme categories (with F1-scores ranging from 0.63 to 0.73) and the intermediate ones (with F1-scores between 0.33 and 0.41). Contrary to the initial hypothesis of the study, simple Logistic Regression proved to be either equivalent or superior to more complex tree models such as Random Forest and XGBoost across all control scenarios. This suggests that the relationship between the available features and resilience class is likely predominantly linear. Moreover, SHAP analysis consistently indicated that sectors like Banking, Financial Market Infrastructure, and Energy, alongside indicators of operational readiness such as ISO 22301 certification (B1), Readiness Exercises (B3), and Timely Incident Reporting (B5), are the main predictive factors. These findings fully align with the data generation mechanism, reinforcing the validity of the methodology used.

Conducting the experiment across four independent samples served as a validation for the robustness of the results. The performance ceiling observed turns out to be an inherent feature of the problem, attributed to deliberately hidden information and intrinsic stochastic noise,

rather than an issue that can be resolved by increasing the sample size. The research concludes that the use of interpretable machine learning models can enhance the effective allocation of supervisory resources and prioritize issues for relevant authorities. However, it does not replace human judgment in intermediate classification categories (Low Resilience and Critical) which present more complex risk scenarios. The study suggests validating the method using real supervisory data as an immediate direction for future research.

Keywords:

Resilience of Critical Entities, Critical Resilience Indicator (CRI), CER Directive (EU) 2022/2557, NIS2 Directive (EU) 2022/2555, Machine Learning, Classification, Random Forest, XGBoost, Logistic Regression, Model Interpretability (SHAP), Synthetic Data, Critical Infrastructures.

Περιεχόμενα

Περίληψη	ii
Abstract	iv
Περιεχόμενα	vi
1. ΚΕΦΑΛΑΙΟ 1 - Εισαγωγή και Θεωρητικό Υπόβαθρο	1
1.1. Ανθεκτικότητα Κρίσιμων Οντοτήτων, Προτεραιότητες και Συνέπειες	1
1.1.1. Κρίσιμες Οντότητες και Λειτουργική Σημασία	2
1.1.2. Ορισμός και Διαστάσεις της Ανθεκτικότητας	3
1.1.3. Η Ανάγκη για Ολοκληρωμένα Αναλυτικά Εργαλεία	5
1.2. Η Ολιστική Προσέγγιση των Οδηγιών CER & NIS2	6
1.2.1. Ο Κοινός Νομικός Πυρήνας σε Επίπεδο ΕΕ	6
1.2.2. Η Τεχνική ως Υπέρβαση της Νομικής Σύγκλισης	7
1.2.3. Η Σημασία της Ολιστικής Προσέγγισης ως Συγκλίνουσα Ασφάλεια	8
1.2.4. Το Πρακτικό Εμπόδιο και οι Προτεραιότητες	9
1.3. Ο Ρόλος της Τεχνητής Νοημοσύνης, τα Big Data και οι μη Γραμμικές Σχέσεις	9
1.3.1. Οι Διαρθρωτικοί Περιορισμοί της Παραδοσιακής Στατιστικής Ανάλυσης Κινδύνου	10
1.3.2. Η Πρόκληση και η Ευκαιρία των Μεγάλων Δεδομένων (Big Data)	12
1.4. Σκοπός, Ερευνητικά Ερωτήματα και Συμβολή της Εργασίας	12
2. ΚΕΦΑΛΑΙΟ 2 - Θεσμικό Πλαίσιο και Κρίσιμες Οντότητες	14
2.1. Η Ανθεκτικότητα ως Αναδυόμενη Κανονιστική αρχή	14
2.2. Το Έρεισμα της Ανθεκτικότητας στο Πρωτογενές Ενωσιακό Δίκαιο	15
2.3. Η Οδηγία (ΕΕ) 2022/2557 για την Ανθεκτικότητα των Κρίσιμων Οντοτήτων (CER)	16
2.4. Η Ελληνική ενσωμάτωση Οδηγίας CER και ο Ν. 5236/2025	18
2.5. Η Εθνική Στρατηγική Ανθεκτικότητας Κρίσιμων Οντοτήτων 2026-2030	19
2.5.1. Οι Έξι (6) Στρατηγικοί Στόχοι	19
2.5.2. Παρακολούθηση και Σύστημα Δεικτών	21
2.5.3. Τομείς, Ουσιώδεις Υπηρεσίες και Αρμόδιες Αρχές	22
2.5.4. Σύστημα δεικτών (KPIs και KRIs) για Υπολογισμό CRI	25
2.6. Κυβερνοασφάλεια, η Οδηγία (ΕΕ) 2022/2555 (NIS2) και ο Ν. 5160/2024	27
2.7. Τεχνητή Νοημοσύνη, ο Κανονισμός (ΕΕ) 2024/1689 (AI Act) και ο Ν. 5321/2026	28
2.8. Συστημική Αλληλεξάρτηση και Θεσμική Αρχιτεκτονική	29
2.9. Συνταγματικές Προεκτάσεις και Κριτική Αποτίμηση	29
2.10. Συμπερασματικές Παρατηρήσεις	30
3. ΚΕΦΑΛΑΙΟ 3 - Ανάπτυξη Μοντέλων Μηχανικής Μάθησης	31
3.1. Παραγωγή Συνθετικών Δεδομένων (Synthetic Data Generation) για Εφαρμογές Τεχνητής Νοημοσύνης	31
3.2. Επιλογή Κλάσεων Ταξινόμησης των Κρίσιμων Οντοτήτων	32
3.2.1. Το Θεμελιώδες Πρόβλημα – Η Κυκλική Εξάρτηση (Circularity) Στόχου-Χαρακτηριστικών	33
3.2.2. Η Επιλογή των Δεικτών για την Χρήση στα Μοντέλα Τεχνητής Νοημοσύνης	34
3.2.3. Η Επιλογή των Συγκεκριμένων (7) Δεικτών & η Επίδραση στη Μεθοδολογική Αξιοπιστία	34
3.2.4. Σύνοψη για την Επιλογή των Δεικτών της Έρευνας	35
3.3. Ο Σύνθετος Δείκτης Ανθεκτικότητας (Composite Resilience Index - CRI)	36
3.3.1. Μεθοδολογία & Μαθηματική Θεμελίωση Υπολογισμού του CRI	36
3.3.2. Πλεονεκτήματα της Μεθοδολογίας για Ακαδημαϊκή Έρευνα για Ακαδημαϊκή Έρευνα	42
3.3.3. Περιορισμοί και Απειλές Εγκυρότητας	43
3.4. Μοντέλο Βάσης (Baseline Model) – Πολυωνυμική Λογιστική Παλινδρόμηση (Multinomial Logistic Regression)	44
3.4.1. Εισαγωγή στη Multinomial Logistic Regression	44
3.4.2. Υπολογιστική Οικονομία και Απουσία Ανάγκης Εντατικού Tuning	45

3.4.3. Επιλογή Περιορισμένου Αριθμού Παραμέτρων σε Σχέση με το Σύνολο Δεδομένων.....	45
3.4.4. Αξιολόγηση Διάγνωσης – Έλεγχος της Γραμμικής Διαχωρισιμότητας.....	46
3.4.5. Κατανόηση και Συμμόρφωση με τις Κανονιστικές Απαιτήσεις.....	46
3.4.6. Στατιστική Θεμελίωση Κατώτατου Ορίου Απόδοσης (Lower-Bound Benchmark).....	46
3.4.7. Εφαρμογή της Multinomial Softmax Logistic Regression με L2 Regularization σε Pipeline με StandardScaler.....	47
3.5. Μοντέλο Τυχαίων Δασών (Random Forest) με χρήση RandomizedSearchCV για Βελτιστοποίηση Υπερπαραμέτρων και Ερμηνευσιμότητα SHAP.....	51
3.5.1. Εισαγωγή στο Μοντέλο Random Forest.....	51
3.5.2. Θεωρία Συνόλων Δέντρων Απόφασης (Ensemble Learning).....	52
3.5.3. Αντιμετώπιση Υπερεκπαίδευσης (Overfitting).....	55
3.5.4. Βελτιστοποίηση Υπερπαραμέτρων (Hyperparameter Tuning) - RandomizedSearchCV έναντι Grid Search.....	56
3.6. XGBoost (Extreme Gradient Boosting), Ανάλυση Ενίσχυσης Κλίσης με Βελτιστοποίηση Υπερπαραμέτρων και Ερμηνευσιμότητα SHAP.....	58
3.6.1. Εισαγωγή στο Μοντέλο XGBoost.....	58
3.6.2. Θεωρητική Βάση – Από το Gradient Boosting στο XGBoost.....	59
3.6.3. Βελτιστοποίηση Υπερπαραμέτρων (Hyperparameter Tuning) - RandomizedSearchCV έναντι Grid Search.....	64
3.7. Μετρικές Αξιολόγησης Μοντέλων Μηχανικής Μάθησης με Δείκτες Απόδοσης και Στατιστικής Επικύρωσης.....	64
4. ΚΕΦΑΛΑΙΟ 4 - Παρουσίαση Αποτελεσμάτων & Συζήτηση	73
4.1. Εισαγωγικό Πλαίσιο Παρουσίασης Αποτελεσμάτων.....	73
4.2. Αποτελέσματα Συνθετικού Συνόλου Δεδομένων $n = 5.000$ κρίσιμων οντοτήτων.....	78
4.2.1. Κατανομή Οντοτήτων ανά Κλάση Ανθεκτικότητας.....	78
4.2.2. Logistic Regression ως Baseline Μοντέλο.....	78
4.2.3. Random Forest με Hyperparameter Tuning.....	79
4.2.4. XGBoost με Hyperparameter Tuning.....	79
4.2.5. Συγκριτική Αξιολόγηση Μοντέλων για $n = 5.000$	80
4.2.6. Ερμηνευσιμότητα Μοντέλων (SHAP Analysis).....	81
4.3. Αποτελέσματα Συνθετικού Συνόλου Δεδομένων $n = 10.000$ κρίσιμων οντοτήτων.....	84
4.3.1. Κατανομή Οντοτήτων ανά Κλάση Ανθεκτικότητας.....	84
4.3.2. Logistic Regression ως Baseline Μοντέλο.....	84
4.3.3. Random Forest με Hyperparameter Tuning.....	85
4.3.4. XGBoost με Hyperparameter Tuning.....	85
4.3.5. Συγκριτική Αξιολόγηση Μοντέλων για $n = 10.000$	86
4.3.6. Ερμηνευσιμότητα Μοντέλων (SHAP Analysis).....	87
4.4. Αποτελέσματα Συνθετικού Συνόλου Δεδομένων $n = 20.000$ κρίσιμων οντοτήτων.....	90
4.4.1. Κατανομή Οντοτήτων ανά Κλάση Ανθεκτικότητας.....	90
4.4.2. Logistic Regression ως Baseline Μοντέλο.....	90
4.4.3. Random Forest με Hyperparameter Tuning.....	91
4.4.4. XGBoost με Hyperparameter Tuning.....	91
4.4.5. Συγκριτική Αξιολόγηση Μοντέλων για $n = 20.000$	92
4.4.6. Ερμηνευσιμότητα Μοντέλων (SHAP Analysis).....	93
4.5. Αποτελέσματα Συνθετικού Συνόλου Δεδομένων $n = 40.000$ κρίσιμων οντοτήτων.....	96
4.5.1. Κατανομή Οντοτήτων ανά Κλάση Ανθεκτικότητας.....	96
4.5.2. Logistic Regression ως Baseline Μοντέλο.....	96
4.5.3. Random Forest με Hyperparameter Tuning.....	96
4.5.4. XGBoost με Hyperparameter Tuning.....	97
4.5.5. Συγκριτική Αξιολόγηση Μοντέλων για $n = 40.000$	97
4.5.6. Ερμηνευσιμότητα Μοντέλων (SHAP Analysis).....	98
4.6. Συγκριτική Ανάλυση Αποτελεσμάτων Συνθετικών Συνόλων Δεδομένων $n = 5.000, 10.000, 20.000$ και 40.000 Κρίσιμων Οντοτήτων.....	101
4.6.1. Εισαγωγή και Σκοπός της Συγκριτικής Ανάλυσης.....	101
4.6.2. Συγκριτική Απόδοση Ταξινόμησης (macro-F1).....	102

4.6.3. Απόδοση ανά Κλάση Ανθεκτικότητας.....	103
4.6.4. Βέλτιστες Υπερπαράμετροι μη Γραμμικών Μοντέλων (RandomizedSearchCV).....	105
4.6.5. Συγκριτική Ανάλυση SHAP – Bar Plots (Συνολική Σπουδαιότητα).....	106
4.6.6. Συγκριτική Ανάλυση SHAP – Beeswarm Plots (Κλάση «Πολύ Κρίσιμο»).....	107
4.7. Συμπέρασμα Συγκριτικής Ανάλυσης.....	111
Επίλογος	112
Βιβλιογραφία	115
Παράρτημα Ι	122
Παράρτημα ΙΙ	134

ΚΕΦΑΛΑΙΟ 1

Εισαγωγή και Θεωρητικό Υπόβαθρο

1.1. Ανθεκτικότητα Κρίσιμων Οντοτήτων, Προτεραιότητες και Συνέπειες

Οι σύγχρονες κοινωνίες βασίζονται σε ένα πολύπλοκο δίκτυο διασυνδεδεμένων και κρίσιμων υποδομών και υπηρεσιών, που περιλαμβάνουν το ενεργειακό σύστημα, την παροχή νερού, τις μεταφορές, τις τηλεπικοινωνίες, το χρηματοπιστωτικό σύστημα, την υγειονομική περίθαλψη κλπ. Η ομαλή λειτουργία αυτών των δομών είναι απαραίτητη για τη συνοχή και την ασφάλεια της κοινωνίας. Παρόλο που αυτή η αλληλεξάρτηση έχει ιστορικά συμβάλει στην αποτελεσματικότητα και την ανάπτυξη, έχει επίσης αυξήσει τη συστημική ευπάθεια. Ένα τοπικό πρόβλημα, είτε είναι φυσικό, ψηφιακό είτε ανθρωπογενές, μπορεί να προκαλέσει αλυσιδωτές αντιδράσεις και να επηρεάσει απρόσμενους τομείς, αποδεικνύοντας ότι η ανθεκτικότητα αποτελεί βασική προϋπόθεση για την επιβίωση και τη σωστή λειτουργία του σύγχρονου τρόπου ζωής.

Η ανάγκη για ενίσχυση της ανθεκτικότητας επιτείνεται από τρεις μεγάλες τάσεις: α) την κλιματική αλλαγή, β) την ψηφιοποίηση των υποδομών και γ) την αύξηση γεωπολιτικών εντάσεων. Η κλιματική αλλαγή οδηγεί σε συχνότερα και πιο έντονα ακραία φαινόμενα, ενώ η ψηφιοποίηση αυξάνει την ευαλωτότητα σε κυβερνοαπειλές. Ταυτόχρονα, οι κρίσιμες υποδομές γίνονται στόχοι υβριδικών απειλών, που συνδυάζουν φυσικούς, ψηφιακούς και στρατηγικούς τρόπους πίεσης.

Το κόστος της μη συμμόρφωσης με τις προκλήσεις του κλίματος είναι ήδη εμφανές. Οι πλημμύρες (κακοκαιρία Bernd¹) που σημειώθηκαν στη Γερμανία και το Βέλγιο, τον Ιούνιο και Ιούλιο του 2021, οδήγησαν σε περισσότερους από 220 – 230 θανάτους και προκάλεσαν ζημιές που ανήλθαν περίπου σε 46 – 50 δισ. ευρώ στην ευρύτερη περιοχή. Αναλύσεις έδειξαν ότι οι ανθρώπινες δραστηριότητες αύξησαν την πιθανότητα τέτοιων καταστροφών. Παράλληλα, η χειμερινή καταιγίδα Uri² στο Τέξας, τον Φεβρουάριο του 2021, ανέδειξε τις επιπτώσεις της ελλιπούς προσαρμογής των ενεργειακών συστημάτων. Πάνω από 4,5 εκατομμύρια σπίτια έμειναν χωρίς ρεύμα, με τις οικονομικές απώλειες να έφτασαν περίπου τα 195 δισ. δολάρια. Στον ψηφιακό χώρο, η επίθεση ransomware στην Colonial Pipeline³, τον Μάιο του 2021, κατέδειξε πώς μια μοναδική παραβίαση μπορεί να διακόψει ζωτικές εφοδιαστικές αλυσίδες, οδηγώντας σε έλλειψη καυσίμων και αυξημένο λειτουργικό κόστος. Στην Ελλάδα, οι κακοκαιρίες Ianos, τον Σεπτέμβριο του 2020, και οι Daniel και Elias, τον

¹ Κατά τη διάρκεια του Ιουνίου και στις αρχές Ιουλίου 2021, στη δυτική Ευρώπη σημειώθηκαν έντονες βροχοπτώσεις, αποτέλεσμα μιας σειράς καλοκαιρινών καταιγίδων και ακραίων καιρικών συνθηκών που είναι γνωστά ως κακοκαιρία Bernd. <https://discomap.eea.europa.eu/climatechange/?page=Floods&views=Recent-events-->.

² Η καταιγίδα Uri τον Φεβρουάριο του 2021 αποκάλυψε τις αδυναμίες στο απομονωμένο ενεργειακό δίκτυο του Τέξας (ERCOT), το οποίο δεν είχε προετοιμαστεί κατάλληλα για να αντιμετωπίσει ακραίες πολικές θερμοκρασίες. <https://energy.utexas.edu/research/ercot-blackout-2021>.

³ Η κυβερνοεπίθεση στην Colonial Pipeline τον Μάιο του 2021 είναι ένα χαρακτηριστικό παράδειγμα του πώς η ψηφιακή ασφάλεια επηρεάζει άμεσα την επιβίωση και την οικονομία μιας χώρας. <https://www.logicom.gr/ti-didaskei-stis-epicheiriseis-to-pathima-tis-colonial-pipeline-gia-kyvernoasfaleia/>.



Σεπτέμβριο του 2023, αποτέλεσαν τυπικά παραδείγματα έντονων καιρικών φαινομένων με μεγάλες συνέπειες σε υποδομές, αγροτικές εκτάσεις και τοπικές κοινότητες. Ο Ianos επηρέασε κυρίως το Ιόνιο και τη Δυτική Ελλάδα, ενώ οι Daniel και Elias προκάλεσαν ευρείες πλημμύρες και καταστροφές στη Θεσσαλία και άλλες περιοχές, υπογραμμίζοντας την αυξανόμενη ανάγκη για πρόληψη, ανθεκτικότητα και άμεση πολιτική προστασία.

Σύμφωνα με έρευνα του Κοινού Κέντρου Ερευνών της Ευρωπαϊκής Επιτροπής⁴, οι ζημιές σε ευρωπαϊκές υποδομές από φυσικές καταστροφές και την κλιματική αλλαγή υπολογίζονται σήμερα σε περίπου 9,3 δισεκατομμύρια ευρώ ετησίως. Το ποσό αυτό αναμένεται να αυξηθεί στα 19,3 δισεκατομμύρια έως το 2050 και να φθάσει τα 37 δισεκατομμύρια μέχρι το τέλος του αιώνα, με τους τομείς ενέργειας και μεταφορών να πλήττονται ιδιαίτερα.

Πέρα από τις οικονομικές απώλειες, οι συνέπειες είναι ιδιαίτερα βαθιές σε κοινωνικό και θεσμικό επίπεδο. Η διακοπή βασικών υπηρεσιών θέτει τη δημόσια υγεία σε κίνδυνο, επηρεάζει ευπαθείς πληθυσμούς και μειώνει την εμπιστοσύνη των πολιτών στην ικανότητα του κράτους να προστατεύει και να διαχειρίζεται αποτελεσματικά την αντίδραση σε κρίσεις. Στα υβριδικά περιστατικά, η παραβίαση της πληροφορίας επιδεινώνει την κατάσταση, καθώς οι υπεύθυνοι δεν μπορούν πάντα να βασίζονται στα δεδομένα που διαθέτουν. Επίσης, η στρατηγική διάσταση είναι εξίσου σημαντική. Τα γεγονότα στους Nord Stream 1 και 2 και οι γνωστές κυβερνοεπιθέσεις σε ενεργειακά δίκτυα αναδεικνύουν ότι οι κρίσιμες υποδομές έχουν γίνει πεδίο υβριδικού ανταγωνισμού.

Αυτά τα δεδομένα δείχνουν ότι η νομοθετική παρέμβαση δεν οφείλει να στοχεύει σε μια αφηρημένη ή θεωρητική ανησυχία, αλλά σε έναν ποσοτικά τεκμηριωμένο και συνεχώς αυξανόμενο κίνδυνο. Η θεσμική απάντηση της ΕΕ μέσω των Οδηγιών CER (Critical Entities Resilience Directive) και NIS2 (Network & Information Security Directive) επισημαίνει αυτή την πραγματικότητα, θέτοντας ενιαίο κανονιστικό πλαίσιο, αξιολόγηση κινδύνου και βασικά πρότυπα κυβερνοασφάλειας. Μια πρωτοβουλία που αναδεικνύει πως η ανθεκτικότητα πρέπει να θεωρείται στρατηγική προτεραιότητα και όχι μια προαιρετική επιλογή.

1.1.1 Κρίσιμες Οντότητες και Λειτουργική Σημασία

Σύμφωνα με το Ευρωπαϊκό και το Ελληνικό κανονιστικό και ρυθμιστικό πλαίσιο, κρίσιμη οντότητα είναι ένας δημόσιος ή ιδιωτικός οργανισμός που προσφέρει ζωτικής σημασίας υπηρεσίες, απαραίτητες για τη διατήρηση θεμελιωδών κοινωνικών λειτουργιών και οικονομικών δραστηριοτήτων, καθώς και για την προστασία της δημόσιας υγείας, της ασφάλειας και του περιβάλλοντος. Σύμφωνα με τον Scholz et al. (2022), οι κρίσιμες οντότητες είναι ζωτικής σημασίας για την κοινωνία και την οικονομία, καθώς προσφέρουν θεμελιώδεις υπηρεσίες από τις οποίες εξαρτώνται πολλά άλλα συστήματα. Όταν αυτές οι

⁴ Έρευνες του Κοινού Κέντρου Ερευνών (JRC) της Ευρωπαϊκής Επιτροπής, ιδιαίτερα μέσω των προγραμμάτων που εστιάζουν στην αξιολόγηση των επιπτώσεων της κλιματικής αλλαγής: α) Η βασική επιστημονική δημοσίευση για τις επιπτώσεις των ακραίων φαινομένων στις υποδομές (Escalating impacts of climate extremes on critical infrastructures in Europe - 2018): <https://publications.jrc.ec.europa.eu/repository/handle/JRC108004> και β) Τα μοντέλα οικονομικού ρίσκου ανά ευρωπαϊκή περιοχή (Regional economic climate risks in Europe - 2025): <https://publications.jrc.ec.europa.eu/repository/handle/JRC143093>.

οντότητες αντιμετωπίζουν διακοπές, οι συνέπειες είναι συχνά αλυσιδωτές και επηρεάζουν όχι μόνο τον άμεσο τομέα τους αλλά και πολλούς άλλους που βασίζονται σταθερά στις προσφερόμενες υπηρεσίες, όπως υπογραμμίζουν οι Pursiainen & Kytömaa (2022).

Οι κρίσεις που πυροδοτήθηκαν από την πανδημία COVID-19, οι συγκρούσεις στην Ουκρανία και τη Μέση Ανατολή, καθώς και οι ενεργειακές κρίσεις, έχουν αναδείξει την ευαισθησία των υποδομών και των υπηρεσιών. Η μεταξύ τους αλληλεξάρτηση δείχνει καθαρά ότι η διαταραχή μιας μονάδας μπορεί να επηρεάσει πολλαπλούς τομείς και δίκτυα, όπως επισημαίνει ο Shkuropadska et al. (2025). Αυτό το δίκτυο αλληλεξάρτησης καθιστά απαραίτητη τη διατήρηση της ομαλής λειτουργίας τους, καθώς οποιαδήποτε διακοπή μπορεί να προκαλέσει σοβαρά προβλήματα στο ευρύτερο κοινωνικό και οικονομικό σύστημα.

Στο παρελθόν, η Ευρωπαϊκή Ένωση εστίαζε κυρίως στην προστασία κρίσιμων υποδομών, όπως μεμονωμένα κτίρια, αγωγοί ή γέφυρες. Στη σύγχρονη εποχή, όμως, με την έντονη ψηφιακή και φυσική διασύνδεση που χαρακτηρίζει τις δομές μας, η έμφαση έχει μετατοπιστεί προς τις οντότητες, δηλαδή τους οργανισμούς και τις εταιρείες. Η φιλοσοφία που στηρίζει αυτή τη μετατόπιση υπογραμμίζει ότι, ακόμα και αν μια υποδομή υποστεί ζημιά ή καταστροφή, ένας οργανισμός εξοπλισμένος με εναλλακτικές στρατηγικές και ικανός να συνεχίσει την παροχή βασικών υπηρεσιών, όπως το νερό, το ηλεκτρικό ρεύμα ή οι τηλεπικοινωνίες, θεωρείται ανθεκτικός. Οι Rostek et al. (2022) και Wisniewski et al. (2023) επισημαίνουν ότι πρέπει να δοθεί έμφαση στη διασφάλιση της συνέχειας των υπηρεσιών και όχι μόνο στην επιβίωση των φυσικών κατασκευών. Η ανελλιπής παροχή βασικών υπηρεσιών έχει αναδειχθεί ως κύριος στόχος της ενωσιακής πολιτικής, μια προσέγγιση που περιγράφεται στη βιβλιογραφία ως μετάβαση από μια υλικοκεντρική σε μια υπηρεσιοκεντρική θεώρηση, δίνοντας προτεραιότητα στην αποτροπή της διακοπής υπηρεσιών που θα προκαλούσαν σοβαρές κοινωνικές και οικονομικές συνέπειες.


1.1.2 Ορισμός και Διαστάσεις της Ανθεκτικότητας

Η ανθεκτικότητα των κρίσιμων οντοτήτων είναι βασικής σημασίας για την πολιτική προστασία, την Εθνική ασφάλεια και τη διαχείριση κινδύνων στην Ευρωπαϊκή Ένωση. Αυτό αντιπροσωπεύει μια ουσιαστική αλλαγή στον τρόπο με τον οποίο η Ευρώπη εξασφαλίζει τη συνέχιση των ζωτικών της λειτουργιών μπροστά στις σύγχρονες απειλές, όπως φυσικές καταστροφές, δολιοφθορές, τρομοκρατία, πανδημίες και κυβερνοαπειλές.

Σε θεωρητικό επίπεδο, η ανθεκτικότητα δεν πρέπει να ταυτίζεται με την απλή ευπάθεια ή την αξιοπιστία. Η ευπάθεια υποδεικνύει πόσο εύκολα μπορεί ένα σύστημα να υποστεί ζημιά, ενώ η αξιοπιστία σχετίζεται κυρίως με την πιθανότητα σωστής λειτουργίας του υπό συγκεκριμένες συνθήκες. Η ανθεκτικότητα, από την άλλη μεριά, είναι μια πιο ευρεία και δυναμική έννοια, καθώς πρόκειται για την ικανότητα μιας κρίσιμης οντότητας να προλαμβάνει, να προστατεύει, να αντιδρά, να αντιστέκεται, να μετριάξει τις επιπτώσεις, να απορροφά κραδασμούς, να προσαρμόζεται και να ανακάμπτει από περιστατικά που διαταράσσουν την παροχή βασικών υπηρεσιών, όπως αναφέρουν οι Mottahedi et al. (2021) και Carlson et al. (2012). Αυτή η προσέγγιση αναγνωρίζει πως δεν είναι μόνο σημαντική η

αποτροπή ενός συμβάντος, αλλά και η διατήρηση της λειτουργίας, η ελεγχόμενη αποδιοργάνωση, η γρήγορη αποκατάσταση και η μάθηση για βελτίωση στο μέλλον.

Επιπλέον, ο Carlson et al. (2012) υιοθετεί μια ακόμα πιο διευρυμένη οπτική, ενσωματώνοντας την πρόβλεψη, την αντίσταση και την ανταπόκριση, ώστε η ανθεκτικότητα να σημαίνει όχι μόνο ανάκαμψη μετά την κρίση αλλά και ενεργή ετοιμότητα πριν από αυτήν. Για τις κρίσιμες οντότητες, αυτό έχει ιδιαίτερη σημασία, καθώς η αποτυχία τους μπορεί να προκαλέσει όχι μόνο εσωτερικά λειτουργικά κόστη, αλλά και να οδηγήσει σε αλυσιδωτές συνέπειες σε άλλους τομείς, κοινωνικές αναταράξεις και συστημική αποσταθεροποίηση.



Εικόνα 1.1: Η ομπρέλα της ανθεκτικότητας για τη διαχείριση κινδύνου στην επιχειρησιακή συνέχεια και η καμπύλη ανθεκτικότητας (resilience curve). [πηγή: Almaleh⁵, A. (2023)]

Ο Darkow (2018), ο Duchek (2019) και οι Adobor & McMullen (2018), Koh et al. (2023) και Scholten et al. (2019) περιέγραψαν τον κύκλο της οργανωσιακής ανθεκτικότητας των κρίσιμων υποδομών. Αυτή η προσέγγιση στην ανθεκτικότητα στηρίζεται σε μια ακολουθία τεσσάρων βασικών φάσεων: α) πρόληψη/προετοιμασία, β) απορρόφηση/αντίσταση, γ) αποκατάσταση/ανάκαμψη και δ) μάθηση/προσαρμογή.

Στην πρώτη φάση, η κύρια επιδίωξη είναι η μείωση της πιθανότητας και της ευπάθειας μέσω εκτίμησης κινδύνων, παρακολούθησης του περιβάλλοντος και σχεδιασμού δοκιμών ετοιμότητας. Ανθεκτικοί οργανισμοί επενδύουν στην πρόληψη και την προετοιμασία πριν από την εκδήλωση ενός συμβάντος. Αυτή η προληπτική φάση συνδέεται με ειδικά προσαρμοσμένες ενέργειες για διάφορα διαταρακτικά γεγονότα. Τα ιστορικά στοιχεία και τα στατιστικά μοντέλα από μόνα τους δεν είναι αρκετά χωρίς την υποστήριξη εκτεταμένων δυνατοτήτων και εξειδικευμένων σχεδιαστικών μεθόδων.

⁵ Almaleh, A. (2023). Measuring Resilience in Smart Infrastructures: A Comprehensive Review of Metrics and Methods. *Applied Sciences*, 13(11), 6452. <https://doi.org/10.3390/app13116452>.

Στη δεύτερη φάση, δίνεται προτεραιότητα στην απορρόφηση των επιπτώσεων και στη διατήρηση των κρίσιμων λειτουργιών, έστω και αν αυτές λειτουργούν σε μειωμένο επίπεδο. Αυτό επιτυγχάνεται μέσω ενεργοποίησης, ανταπόκρισης και επιχειρησιακής ευελιξίας. Η φάση της ανταπόκρισης περιλαμβάνει σημαντικές διαδικασίες, όπως η ανίχνευση, η ενεργοποίηση και η αξιολόγηση. Για τη συνέχιση της δραστηριότητάς μας, στηρίζομαστε στη στρατηγική της επιχειρηματικής συνέχειας και σε δοκιμασμένες μεθόδους ανταπόκρισης, πέρα από τους διαθέσιμους πόρους. Στις αλυσίδες εφοδιασμού, οι πιο αποτελεσματικές ανταποκρίσεις επιτυγχάνονται με συνεργασία και ευελιξία στη λειτουργία.

Στην τρίτη φάση, η ανθεκτικότητα εκτιμάται κυρίως με βάση το χρόνο αποκατάστασης και την ποιότητα της ανάκαμψης, δηλαδή πόσο γρήγορα επανέρχονται τα κρίσιμα επίπεδα λειτουργίας. Η διαδικασία της ανάκαμψης συχνά δεν λαμβάνει την προσοχή που της αξίζει στη θεωρία, αν και είναι καθοριστικής σημασίας για την πρακτική ανθεκτικότητα. Ποσοτικά μοντέλα ανθεκτικότητας χρησιμοποιούν τη μείωση του λειτουργικού επιπέδου, το χρόνο επαναλειτουργίας και το χρόνο αποκατάστασης ως θεμελιώδεις παράγοντες. Στις αλυσίδες εφοδιασμού, μια γρήγορη ανάκαμψη απαιτεί όχι μόνο αποτελεσματικότητα, αλλά και ένα μίγμα προσαρμοστικών και μετασχηματιστικών δράσεων.

Στην τέταρτη φάση, η οντότητα μετατρέπει το συμβάν σε οργανωσιακή μάθηση, ενσωματώνοντας τις αποκτηθείσες γνώσεις σε καθημερινές πρακτικές, δομές και στρατηγικές με στόχο τη μελλοντική ετοιμότητα. Η διαδικασία της μάθησης δεν περιορίζεται μόνο στο στάδιο της κρίσης, αλλά επηρεάζει όλα τα επίπεδα ανθεκτικότητας. Η πιο αποδοτική μορφή ανθεκτικότητας δεν είναι απλώς η επιστροφή στην κατάσταση πριν από τη διαταραχή, αλλά η βελτίωση και αναβάθμιση των ικανοτήτων μετά από την πρόκληση. Παρόλα αυτά, παρατηρείται ένα κενό μεταξύ της συλλογής γνώσεων από τις εμπειρίες και της ενσωμάτωσής τους σε υπάρχουσες οργανωτικές πρακτικές.

1.1.3 Η Ανάγκη για Ολοκληρωμένα Αναλυτικά Εργαλεία

Από τα παραπάνω συνάγεται ότι η ανθεκτικότητα δεν μπορεί πλέον να θεωρείται ως μία ακίνητη και περιγραφική ιδιότητα που αξιολογείται μεμονωμένα μέσω δεικτών. Η πολυπλοκότητα των σύγχρονων κρίσιμων συστημάτων, το εκτεταμένο τους μέγεθος, οι διασυνδέσεις με άλλες υποδομές, και η συνεχώς αυξανόμενη παραγωγή λειτουργικών δεδομένων, απαιτούν τη μετάβαση σε ολοκληρωμένα αναλυτικά πλαίσια. Αυτά τα πλαίσια θα πρέπει να είναι σε θέση να ενοποιούν πολλαπλά κριτήρια, ποικίλες πηγές δεδομένων και δυναμικά μοντέλα προσομοίωσης ώστε να παρέχουν μια ενιαία, ποσοτικά τεκμηριωμένη εκτίμηση. Η απλή σύνθεση επιμέρους ποιοτικών αξιολογήσεων δεν επαρκεί για την αποτύπωση της πολυεπίπεδης και μη γραμμικής φύσης της σύγχρονης επικινδυνότητας. Σε αυτό το σημείο ανακύπτει η ανάγκη αξιοποίησης εργαλείων μοντελοποίησης και τεχνητής νοημοσύνης τα οποία, όπως αναλύεται στην ενότητα 1.3, παρέχουν τη μεθοδολογική βάση για τη μετατροπή της θεωρητικής έννοιας της ανθεκτικότητας σε ένα λειτουργικό, μετρήσιμο και επαναλήψιμο πλαίσιο αξιολόγησης.

1.2. Η Ολιστική Προσέγγιση των Οδηγιών CER & NIS2

Η Ευρωπαϊκή Ένωση, στις 14 Δεκεμβρίου 2022, ενέκρινε ταυτόχρονα την Οδηγία (ΕΕ) 2022/2555 (NIS2⁶), η οποία καθορίζει απαιτήσεις για την ενίσχυση της κυβερνοασφάλειας σε ολόκληρη την Ένωση με στόχο τη βελτίωση της εσωτερικής αγοράς, και την Οδηγία (ΕΕ) 2022/2557 (CER⁷). Αυτή η δεύτερη οδηγία προβλέπει τα εξής: α) τις υποχρεώσεις των κρατών μελών να λαμβάνουν συγκεκριμένα μέτρα που εξασφαλίζουν την απρόσκοπτη παροχή σημαντικών υπηρεσιών που είναι απαραίτητες για τη διατήρηση ζωτικών κοινωνικών και οικονομικών λειτουργιών, β) τις υποχρεώσεις των κρίσιμων οργανισμών (οντοτήτων) να ενισχύσουν την ανθεκτικότητα και την ικανότητά τους να προσφέρουν αυτές τις βασικές υπηρεσίες εντός της εσωτερικής αγοράς, γ) τους κανονισμούς για την εποπτεία των κρίσιμων οντοτήτων και την επιβολή της νομοθεσίας, την αναγνώριση κρίσιμων οντοτήτων με ιδιαίτερη σημασία για την Ευρώπη και τις συμβουλευτικές αποστολές για αξιολόγηση των μέτρων που έχουν εφαρμόσει οι οργανισμοί, δ) τις διαδικασίες συνεργασίας και υποβολής εκθέσεων και ε) τα μέτρα που διασφαλίζουν την υψηλή ανθεκτικότητα των κρίσιμων οντοτήτων.


1.2.1. Ο Κοινός Νομικός Πυρήνας σε Επίπεδο ΕΕ

Οι οδηγίες CER και NIS2 αναπτύσσονται παράλληλα και αλληλοσυμπληρώνονται, ωστόσο η έρευνα υπογραμμίζει ότι η αποτελεσματική ανθεκτικότητα απαιτεί πιο βαθιά ενοποίηση από αυτή που προβλέπει η τρέχουσα νομική τους διάσταση. Η νομική σύνδεση μεταξύ των δύο κανονισμών επιτυγχάνεται μέσω του άρθρου 3(1)(στ) της οδηγίας NIS2, το οποίο αναγνωρίζει ως βασικές οντότητες όλες εκείνες που έχουν ήδη χαρακτηριστεί ως κρίσιμες βάσει του κανονισμού CER. Επομένως, ο χαρακτηρισμός μιας οντότητας ως «κρίσιμη» στο πλαίσιο του CER, την αναβαθμίζει αυτομάτως σε «βασική» στο πλαίσιο του NIS2.

Οι δύο οδηγίες λειτουργούν ως ξεχωριστά νομικά εργαλεία με ξεχωριστές αρχές, αλλά στην πράξη βασίζονται στην ίδια θεωρητική δομή διακυβέρνησης, αναφορικά με την αξιολόγηση κινδύνων, τα σχέδια συνέχειας λειτουργίας, την ασφάλεια της εφοδιαστικής αλυσίδας και την υπευθυνότητα σε διοικητικό επίπεδο. Αυτό υποδεικνύει ότι η Ευρωπαϊκή Ένωση έχει τη δυνατότητα, και ουσιαστικά πρέπει, να αναπτύξει ένα ολοκληρωμένο πρόγραμμα συμμόρφωσης, αντί να διατηρεί δύο ξεχωριστά συστήματα.

⁶ Οδηγία (ΕΕ) 2022/2555 του Ευρωπαϊκού Κοινοβουλίου και του Συμβουλίου της 14ης Δεκεμβρίου 2022 σχετικά με μέτρα για υψηλό κοινό επίπεδο κυβερνοασφάλειας σε ολόκληρη την Ένωση, την τροποποίηση του κανονισμού (ΕΕ) αριθ. 910/2014 και της οδηγίας (ΕΕ) 2018/1972, και για την κατάργηση της οδηγίας (ΕΕ) 2016/1148 (οδηγία NIS2). <https://eur-lex.europa.eu/legal-content/EL/TXT/?uri=CELEX:32022L2555>.

⁷ Οδηγία (ΕΕ) 2022/2557 του Ευρωπαϊκού Κοινοβουλίου και του Συμβουλίου της 14ης Δεκεμβρίου 2022 για την ανθεκτικότητα των κρίσιμων οντοτήτων και την κατάργηση της οδηγίας 2008/114/ΕΚ του Συμβουλίου. <https://eur-lex.europa.eu/eli/dir/2022/2557/oj?locale=el>.



Εικόνα 1.2: Ολιστική σύγκλιση φυσικής ασφάλειας (physical security) και κυβερνοασφάλειας (cybersecurity) στις κρίσιμες υποδομές.

1.2.2. Η Τεχνική ως Υπέρβαση της Νομικής Σύγκλισης

Η συνεχώς αυξανόμενη σύνδεση μεταξύ φυσικών και ψηφιακών συστημάτων έχει καταστήσει τη διάκριση «φυσική ασφάλεια εδώ, κυβερνοασφάλεια εκεί» παρωχημένη σε επιχειρησιακό επίπεδο. Οι επιτιθέμενοι εκμεταλλεύονται την αλληλεξάρτηση μεταξύ φυσικής πρόσβασης και ψηφιακών συστημάτων για να διεισδύσουν σε εγκαταστάσεις και συστήματα κρίσιμων οντοτήτων. Αυτό είναι ιδιαίτερα ανησυχητικό, καθώς τα κέντρα δεδομένων και άλλες υποδομές θεωρούνται βασικές οντότητες σύμφωνα με το NIS2.

Οι Kayan et al. (2021), Longo et al. (2025) και Raich et al. (2025) συμμερίζονται αυτή την άποψη, καθώς οι σύγχρονες κρίσιμες οντότητες συνδέουν φυσικούς πόρους, δικτυωμένα πληροφοριακά συστήματα (IT - Information Technology) και ανθρώπινες λειτουργίες (OT - Operational Technology) εντός κυβερνοφυσικών συστημάτων (CPS). Ως αποτέλεσμα, μια επίθεση σε ένα επίπεδο μπορεί να έχει άμεσες συνέπειες και σε άλλα. Η αυξημένη συνδεσιμότητα και η σύγκλιση τεχνολογιών πληροφοριών και λειτουργιών (IT-OT) διευρύνουν την επιφάνεια επιθέσεων. Η έρευνα των Ojo et al. (2024) και De Soto et al. (2022) καταδεικνύει ότι οι βλάβες σε τομείς όπως η ενέργεια, οι τηλεπικοινωνίες ή οι μεταφορές μπορούν να επηρεάσουν γρήγορα άλλα συστήματα, οδηγώντας σε ένα αλυσιδωτό φαινόμενο κατάρρευσης (cascading failure). Παράλληλα, πολλά ξεπερασμένα περιβάλλοντα λειτουργικής τεχνολογίας δυσκολεύονται πλέον να ενημερωθούν ώστε να αντιμετωπίσουν το σημερινό εξελισσόμενο τοπίο απειλών.

Σύμφωνα με τις μελέτες των Mikac (2023), Longo et al. (2025) και Potcovaru & Mustata (2026), ο ακόλουθος πίνακας αποκαλύπτει ότι η λειτουργία των CER και NIS2 σε κρίσιμες οντότητες είναι αφενός συμπληρωματική, αλλά ταυτόχρονα διατηρούν κάποιες από τις ξεχωριστές τους ιδιότητες.



Πίνακας 1.1: Η πρωταρχική σύγκλιση των οδηγιών CER και NIS2.

Διάσταση	CER	NIS2	Σημασία Σύγκλισης
Κύριο αντικείμενο	Συνέχεια υπηρεσιών	Ασφάλεια NIS	Καλύπτουν διαφορετικές αλλά αλληλεξαρτώμενες όψεις
Λογική προστασίας	Φυσική και οργανωσιακή ανθεκτικότητα	Ψηφιακή ακεραιότητα και αξιοπιστία	Η οντότητα χρειάζεται και τις δύο
Σχέση μεταξύ τους	Παράλληλη εφαρμογή με αμοιβαίες αναφορές	Παράλληλη εφαρμογή με αμοιβαίες αναφορές	Οι αδυναμίες του ενός επηρεάζουν και το άλλο
Κύριο κενό	Η πράξη παραμένει συχνά διαχωρισμένη	Η πράξη παραμένει συχνά διαχωρισμένη	Απαιτείται ενοποιημένη διακυβέρνηση
Ρυθμιστική κατεύθυνση	Ανθεκτικότητα πέρα από συμμόρφωση	Διεύρυνση υποχρεώσεων κυβερνοασφάλειας	Μετάβαση σε risk- and resilience-based μοντέλο

1.2.3. Η Σημασία της Ολιστικής Προσέγγισης ως Συγκλίνουσα Ασφάλεια

Η έννοια της «ολιστικής προσέγγισης» επεκτείνεται πέρα από τη θεωρητική συζήτηση και αποκτά εφαρμοσμένη διάσταση μέσω ενός εξειδικευμένου τεχνικού μηχανισμού. Οι Hromada et al. (2023 & 2021) και Manuilov (2026) υποστηρίζουν ενεργά αυτή την άποψη, προτείνοντας ότι η ολιστική προσέγγιση, γνωστή ως συγκλίνουσα ασφάλεια, επιτυγχάνει την ενοποίηση της φυσικής ασφάλειας και της κυβερνοασφάλειας με ενσωμάτωση σε ένα συγκεντρωμένο σύστημα πληροφόρησης και επιχειρησιακής επίγνωσης. Αυτή η σύνθετη προσέγγιση χρησιμοποιεί έναν κεντρικό μηχανισμό για τη συσχέτιση δεδομένων που προέρχονται από αισθητήρες, συστήματα ασφαλείας και άλλα περιστατικά/συμβάντα. Μέσω αυτής της διασύνδεσης, παρέχεται η δυνατότητα αποτελεσματικής βελτίωσης στην έγκαιρη ανίχνευση κινδύνων, στη συνεχή επίγνωση της κατάστασης και στην ικανότητα αντίδρασης κατά την αποκατάσταση/ανάκαμψη της οντότητας.

Οι Raich et al. (2025), Ojo et al. (2024) και Qudus (2025) επισημαίνουν ότι σε τεχνικό επίπεδο, απαιτούνται αρχιτεκτονικές ασφαλείας που εστιάζουν στην πολυεπίπεδη και εις βάθος άμυνα, με ιδιαίτερη έμφαση στη διαστροφμάτωση, στις αρχές μηδενικής εμπιστοσύνης, στην παρακολούθηση ανωμαλιών, στην ανίχνευση βασισμένη σε τεχνητή νοημοσύνη και στη βελτίωση της πληροφόρησης σχετικά με απειλές στα όρια των τεχνολογιών IT, OT και φυσικής ασφάλειας. Επιπλέον, η Srivastava (2025) προσθέτει ότι στο επίπεδο του σχεδιασμού, η ανθεκτικότητα πρέπει να περιλαμβάνει την εφαρμογή της πλεονάζουσας δυνατότητας, της ποικιλίας, της αρθρωτότητας και της συγκέντρωσης. Αυτές οι αρχές βοηθούν στην αποφυγή μονοσήμαντων σημείων αποτυχίας και περιορίζουν τη διάδοση τυχόν βλαβών.

1.2.4. Το Πρακτικό Εμπόδιο και οι Προτεραιότητες

Παρόλο που υπάρχει συμφωνία σε κυβερνητικό/νομικό επίπεδο, οι δύο οδηγίες εξακολουθούν να εμφανίζουν διαφορές σε τεχνικό επίπεδο. Οι τεχνικές διατάξεις για τα μέτρα ανθεκτικότητας φυσικής ασφάλειας των κρίσιμων οντοτήτων (άρθρο 13 CER) και τα μέτρα διαχείρισης κινδύνων στον τομέα της κυβερνοασφάλειας (άρθρο 21 NIS2) λειτουργούν ανεξάρτητα από τις αρμόδιες αρχές τους. Αυτός ο διαχωρισμός προκαλεί σε πολλές οργανώσεις φαινόμενα «κόπωσης συμμόρφωσης» εξαιτίας επαναλαμβανόμενων ελέγχων και συγκεχυμένων απαιτήσεων τεκμηρίωσης. Πρόκειται για μια διάσταση που αποτελεί μόνιμη αδυναμία, γνωστή ως οργανωτικός κατακερματισμός, όπως αναφέρουν οι Raich et al. (2025), Hromada et al. (2021) και Fitzgerald & Morisset (2024). Η πολυπλοκότητα που προκύπτει από τη διαχείριση IT, OT και φυσικής ασφάλειας μέσω διαφόρων ομάδων, πολιτικών και μοντέλων διακυβέρνησης καθιστά δύσκολη την ολοκληρωμένη εκτίμηση κινδύνου και τη συντονισμένη αντίδραση. Επιπλέον, οι ασάφειες, οι επικαλυπτόμενες αρμοδιότητες και η ανεπαρκής διασύνδεση μεταξύ διαφορετικών μεθοδολογιών αξιολόγησης θέτουν εμπόδια και υπονομεύουν την αντικειμενική κατανόηση της ανθεκτικότητας των κρίσιμων οντοτήτων.

Οι βασικές προτεραιότητες για την αντιμετώπιση της τρέχουσας κατάστασης πρέπει να περιλαμβάνουν την κοινή διακυβέρνηση σύμφωνα με τις οδηγίες CER και NIS2, την καθιέρωση υποχρεωτικών ελέγχων ανθεκτικότητας, καθώς και τη διεξαγωγή ασκήσεων και εκπαιδεύσεων πολλαπλών ειδικοτήτων. Παράλληλα, είναι σημαντική η ανταλλαγή πληροφοριών μεταξύ δημόσιου και ιδιωτικού τομέα, καθώς και η χρήση εργαλείων μοντελοποίησης ή δοκιμαστικών πλατφορμών που αναδεικνύουν τις επιπτώσεις από το επίπεδο των συστημάτων έως τις διοικητικές ομάδες. Αυτή η στρατηγική πρέπει επίσης να περιλαμβάνει νέες απειλές, όπως η παραβίαση της εφοδιαστικής αλυσίδας, οι επιθέσεις τεχνητής νοημοσύνης και οι μελλοντικοί κίνδυνοι που συνδέονται με την κβαντική τεχνολογία. Τέτοιες απειλές δεν μπορούν να περιοριστούν σε παραδοσιακά ή καθαρά κανονιστικά πλαίσια.

Συνεπώς, η ολιστική προσέγγιση CER και NIS2 υποδεικνύει ότι η φυσική ασφάλεια (physical security) και η κυβερνοασφάλεια (cybersecurity) πρέπει να αντιμετωπίζονται ως ένα ενιαίο ζήτημα ασφάλειας (integrated security), όχι ως δύο ξεχωριστά πεδία. Αυτή η σύγκλιση φαίνεται να κερδίζει έδαφος στη βιβλιογραφία, σύμφωνα με τον Förster et al. (2026). Το κύριο ανοιχτό ερώτημα είναι το πώς θα μετασχηματιστεί από συμπληρωματική νομοθεσία σε πραγματικά ενοποιημένη επιχειρησιακή πρακτική.

1.3. Ο Ρόλος της Τεχνητής Νοημοσύνης, τα Big Data και οι μη Γραμμικές Σχέσεις

Οι παραδοσιακές στατιστικές μέθοδοι, όπως η γραμμική και λογιστική παλινδρόμηση και τα μοντέλα αναλογικού κινδύνου, βασίζονται σε υποθέσεις γραμμικότητας και προσθετικότητας μεταβλητών, οι οποίες σπάνια ανταποκρίνονται στην πραγματικότητα. Επίσης, δυσκολεύονται να επεξεργαστούν αποτελεσματικά τον μεγάλο όγκο δεδομένων. Αντίθετα, η τεχνητή νοημοσύνη, μέσω της μηχανικής και βαθιάς μάθησης, ξεπερνά αυτούς τους περιορισμούς, καθώς αποκαλύπτει μη γραμμικές αλληλεπιδράσεις και πολυεπίπεδες σχέσεις,

όπως τα φαινόμενα αλυσιδωτών αστοχιών μεταξύ διαφορετικών κλάδων οντοτήτων, οι οποίες παραμένουν αόρατες με τις παραδοσιακές στατιστικές προσεγγίσεις.

1.3.1. Οι Διαρθρωτικοί Περιορισμοί της Παραδοσιακής Στατιστικής Ανάλυσης Κινδύνου

Η πιθανοτική ανάλυση κινδύνου (PRA - Probabilistic Risk Analysis) εφαρμόστηκε σε συστήματα με περιορισμένα διαθέσιμα δεδομένα λειτουργίας. Ως εκ τούτου, η εκτίμηση των πιθανοτήτων αστοχίας στηριζόταν σε παραδοχές σχετικά με τη μορφή της κατανομής, όπως η κανονικότητα, η γραμμικότητα και η ανεξαρτησία των μεταβλητών και σε μικρό αριθμό παρατηρήσεων. Σύμφωνα με τον Guikema (2009), τα σύγχρονα συστήματα κρίσιμων οντοτήτων εκτείνονται σε εκτεταμένες γεωγραφικές περιοχές και περιλαμβάνουν χιλιάδες επιμέρους στοιχεία οργανωμένα σε δίκτυα, τα οποία παρακολουθούνται συνεχώς μέσω τεχνολογιών πληροφορικής. Αυτό δημιουργεί μια τεράστια ποσότητα λεπτομερών δεδομένων καθιστώντας αδύνατη τη χρήση της παραδοσιακής PRA για την εκτέλεση ολοκληρωμένων αναλύσεων ολόκληρου του συστήματος, παρά μόνο για μικρά υποσύνολα. Επομένως, το πρόβλημα κινδύνου έχει μετατοπιστεί από την έλλειψη επαρκών διαθέσιμων δεδομένων σε μια κατάσταση υπερβολικής ποσότητας δεδομένων από τα οποία μπορούν να εξαχθούν χρήσιμες πληροφορίες σχετικά με την πιθανότητα βλάβης και τις εκτιμήσεις των συνεπειών της.

Οι παραδοσιακές στατιστικές μέθοδοι αντιμετωπίζουν προβλήματα κυρίως όταν τα δεδομένα είναι πολυδιάστατα, παραβιάζουν υποθέσεις όπως η γραμμικότητα και η κανονικότητα ή παράγονται σε τέτοιο όγκο, ποικιλία και ταχύτητα που οι κλασικές τεχνικές αδυνατούν να εφαρμοστούν αποτελεσματικά. Η μεθοδολογική θεμελίωση των παραδοσιακών στατιστικών μοντέλων, όπως η γραμμική και η λογιστική παλινδρόμηση, τα μοντέλα αναλογικού κινδύνου Cox⁸ και τα γενικευμένα γραμμικά μοντέλα, βασίζεται σε παραδοχές που σπανίως τηρούνται στα πραγματικά δεδομένα κρίσιμων οντοτήτων, πέρα από το θέμα της κλίμακας. Αυτές οι μέθοδοι συνήθως απαιτούν πρόσθετη αλληλεπίδραση μεταξύ των μεταβλητών κινδύνου, όμως οι αλληλεπιδράσεις αυτές σπανίως εμφανίζονται ως γραμμικές στην πραγματική εφαρμογή. Μερικές μεταβλητές δύνανται να αποκτήσουν ή να χάσουν στατιστική σημασία ανάλογα με την παρουσία ή την απουσία άλλων παραγόντων. Ως εκ τούτου, οι μέθοδοι αυτές δυσκολεύονται να διαχειριστούν μεγάλους όγκους δεδομένων, καθώς και σύνθετες αλληλεπιδράσεις και πολυεπίπεδες εξαρτήσεις. Σύμφωνα με τις διαπιστώσεις του Min (2013), αυτό προκαλεί σημαντικούς περιορισμούς στην ικανότητα ρεαλιστικής προσομοίωσης διαδοχικών αστοχιών, ετερογενών συμπεριφορών και αμοιβαίων ή ανατροφοδοτούμενων εξαρτήσεων σε συστήματα κρίσης οντοτήτων.

Οι Kyriazos & Poga (2024) και Grebovic et al. (2022) συμφωνούν με την άποψη ότι οι κλασικές προσεγγίσεις βασίζονται σε θεωρητικές υποθέσεις και σχετικά απλές δομές

⁸ Το μοντέλο αναλογικού κινδύνου του **Cox** (Cox Proportional Hazards Model) αποτελεί ένα σημαντικό ημι-παραμετρικό στατιστικό εργαλείο το οποίο εφαρμόζεται για την ανάλυση δεδομένων επιβίωσης. Σκοπός του είναι να αξιολογήσει τη σχέση ανάμεσα σε μια ή περισσότερες ανεξάρτητες μεταβλητές, οι οποίες αποκαλούνται παράγοντες κινδύνου, και στον ρυθμό κινδύνου εκδήλωσης ενός συγκεκριμένου συμβάντος καθώς ο χρόνος εξελίσσεται.

σχέσεων. Τα σύγχρονα δεδομένα παρουσιάζουν ετερογένεια, θόρυβο και πολύπλοκες αλληλεπιδράσεις, καθιστώντας τα γραμμικά μοντέλα συχνά ανεπαρκή στην ανίχνευση μη γραμμικών αλληλεπιδράσεων και threshold effects. Τα μοντέλα μηχανικής μάθησης (ML - Machine Learning) και βαθιάς μάθησης (DL - Deep Learning) έχουν την ικανότητα να αναπροσαρμόζουν δυναμικά τα κριτήρια διαχωρισμού τους, να εντοπίζουν σύνθετα πρότυπα και σχέσεις και να κλιμακώνονται καλύτερα σε μεγάλα και πολύπλοκα σύνολα δεδομένων επισημαίνοντας μη γραμμικές αλληλεπιδράσεις οι οποίες συχνά παραμένουν ακατανόητες με τις παραδοσιακές μεθόδους, σύμφωνα με τους Janiesch et al. (2021) και Gandomi et al. (2023). Αυτό τους επιτρέπει να αναδεικνύουν μη γραμμικές αλληλεπιδράσεις που συχνά δεν είναι δυνατόν να κατανοηθούν πλήρως με παραδοσιακές μεθόδους. Ο Rahmani et al. (2021) αναφέρει ότι η τεχνητή νοημοσύνη διαχειρίζεται τα μεγάλα δεδομένα συνδυάζοντας αλγορίθμους μάθησης με υποδομές κατανομημένης επεξεργασίας, όπως τα Apache Hadoop και Spark⁹, ώστε τα δεδομένα να αναλύονται κατανομημένα και σε κλίμακα. Αυτή η σύζευξη επιταχύνει την ανάλυση, αυτοματοποιεί επαναλαμβανόμενα βήματα και συχνά βελτιώνει την ακρίβεια και την επεκτασιμότητα των αποτελεσμάτων.

Η εφαρμογή των αρχών της βαθιάς μάθησης στην ενίσχυση της ανθεκτικότητας κρίσιμων οντοτήτων υπερβαίνει τα προβλήματα που αφορούν μόνο τη δικτυακή τοπολογία. Ο Dick et al. (2019) εισήγαγε την αξιοποίηση μεθόδων βαθιάς μάθησης ειδικά για την ανθεκτικότητα τέτοιων οντοτήτων, ενώ οι κατοπινές έρευνες εξελίχθηκαν με τη χρήση νευρωνικών δικτύων που βελτιστοποιούνται για να ενισχύσουν τόσο την εκπαιδευτική αποτελεσματικότητα όσο και την ικανότητα πρόβλεψης. Αυτές οι εξελίξεις περιλαμβάνουν τεχνικές αξιολόγησης σπουδαιότητας χαρακτηριστικών, οι οποίες αναβαθμίζουν όχι μόνο την ακρίβεια αλλά και την ικανότητα ερμηνείας του μοντέλου και αναγνώρισης των κρίσιμων παραγόντων κινδύνου. Αυτό είναι ιδιαίτερα σημαντικό, καθώς τα μοντέλα μηχανικής και βαθιάς μάθησης συχνά θεωρούνται ως «μαύρα κουτιά» (black box), γεγονός που συνιστά έναν φραγμό στην υιοθέτησή τους στα κανονιστικά και επιχειρησιακά πλαίσια όπου απαιτείται καταγραφή και αιτιολόγηση των αποφάσεων.

Είναι εξίσου σημαντικό να σημειωθεί ότι τα μοντέλα μηχανικής και βαθιάς μάθησης λειτουργούν με βάση δεδομένα και δεν απαιτούν τις αυστηρές κατανομικές ή δομικές προϋποθέσεις που συχνά συναντάμε σε πολλές παραδοσιακές μεθόδους. Μοντέλα όπως SVMs, Random Forests, Decision Trees, CNNs, RNNs, Transformers και LSTMs είναι ιδανικά για την αναγνώριση σύνθετων προτύπων σε δεδομένα υψηλής διάστασης, πολλών μορφών και μη δομημένα, όπως εικόνες, γλώσσα, βίντεο και χρονοσειρές, σύμφωνα με τους Rahmani et al. (2021) και Zaripova et al. (2023).

⁹ Το **Apache Hadoop** αποτελεί ένα λογισμικό ανοικτού κώδικα, το οποίο έχει σχεδιαστεί για την κατανομημένη αποθήκευση και επεξεργασία τεράστιων ποσοτήτων δεδομένων σε συστάδες αποτελούμενες από απλούς υπολογιστές. Εναλλακτικά, το **Apache Spark** είναι μια πιο σύγχρονη πλατφόρμα επεξεργασίας μεγάλων δεδομένων, επίσης ανοικτού κώδικα, η οποία έχει αναπτυχθεί με σκοπό να υπερβεί τα προβλήματα ταχύτητας του Hadoop MapReduce. Το Spark δίνει ιδιαίτερη έμφαση στην αποδοτική επίδοση, ιδιαίτερα σε εφαρμογές Τεχνητής Νοημοσύνης και Μηχανικής Μάθησης.

1.3.2. Η Πρόκληση και η Ευκαιρία των Μεγάλων Δεδομένων (Big Data)

Η αυξημένη διαθεσιμότητα δεδομένων σε κρίσιμες υποδομές μέσω αισθητήρων SCADA/IoT, συστημάτων παρακολούθησης σε πραγματικό χρόνο και αρχείων βλαβών και συντήρησης, καθώς και ανοιχτών δεδομένων, δημιουργεί τόσο ευκαιρίες όσο και προκλήσεις. Από τη μία πλευρά, σύμφωνα με τους Choi και Lambert (2017) και Khatib et al. (2023), τα μεγάλα δεδομένα παρέχουν περισσότερες πληροφορίες, βελτιωμένη χρονική ανάλυση και ετερογενείς πηγές, οι οποίες μπορούν να ενισχύσουν την πρόβλεψη και την έγκαιρη ανίχνευση κινδύνων. Από την άλλη πλευρά, ο Wells et al. (2022) σημειώνει ότι αυτή η πληθώρα δεδομένων αποτελεί πρόκληση, καθώς οι υπάρχουσες μέθοδοι συχνά αδυνατούν να μοντελοποιήσουν με ακρίβεια τα σύνθετα δεδομένα και τις πολυεπίπεδες εξαρτήσεις στις κρίσιμες υποδομές.

Συνοψίζοντας, οι παραδοσιακές στατιστικές μέθοδοι δεν αποδίδουν καλά σε υψηλοδιάστατα, μη γραμμικά και μεγάλης κλίμακας προβλήματα. Η τεχνητή νοημοσύνη λειτουργεί ως αναλυτικό εργαλείο, καθώς επεξεργάζεται μεγάλα και ποικιλόμορφα δεδομένα από αισθητήρες, συστήματα παρακολούθησης και αρχεία συμβάντων, προσφέροντας μια ακριβέστερη εικόνα της κατάστασης μιας κρίσιμης οντότητας. Η ενσωμάτωση των ψηφιακών διδύμων και της τεχνητής νοημοσύνης στις υποδομές έχει οδηγήσει σε αύξηση του αριθμού των σχετικών δημοσιεύσεων και αναφορών τα τελευταία χρόνια. Αυτό αντικατοπτρίζει την αυξανόμενη αναγνώριση βασικών μελετών που εστιάζουν στην ενοποίηση δεδομένων για ψηφιακά δίδυμα, στη μηχανική μάθηση για την πρόβλεψη κινδύνων και στα μοντέλα ανάκαμψης που βασίζονται στην προσομοίωση.

Η αξιοποίηση μεθόδων μηχανικής και βαθιάς μάθησης επιτρέπει την αναγνώριση περίπλοκων σχέσεων, αλληλεξαρτήσεων και μοτίβων κινδύνου, τα οποία συχνά παραμένουν ανεξερεύνητα μέσω παραδοσιακών στατιστικών προσεγγίσεων. Αυτές οι τεχνολογίες συμβάλλουν σημαντικά στην πρόβλεψη προβλημάτων, την εκτίμηση του χρόνου αποκατάστασης και τον καθορισμό δεικτών ανθεκτικότητας με έναν ποσοτικό και τεκμηριωμένο τρόπο. Η αξία τους δεν έγκειται στην αντικατάσταση του ανθρώπου, αλλά στην ενίσχυση τη διαδικασία λήψης αποφάσεων, την έγκαιρη ανίχνευση ανωμαλιών και την επιχειρησιακή ετοιμότητα. Μετασχηματίζουν την έννοια της ανθεκτικότητας από μια γενική ποιοτική προσέγγιση σε ένα μετρήσιμο πλαίσιο παρακολούθησης, πρόγνωσης και βελτίωσης.

Το πιο καθοριστικό ζήτημα δεν έγκειται στην επιλογή μεταξύ παραδοσιακών στατιστικών μεθόδων και τεχνητής νοημοσύνης. Αντιθέτως, αφορά την ενοποίηση της στατιστικής ακρίβειας με την προσαρμοστικότητα της τεχνητής νοημοσύνης. Αυτή η σύνθεση εξασφαλίζει τόσο την αξιοπιστία των αναλυτικών διαδικασιών όσο και την αποτελεσματικότητα στη λήψη αποφάσεων.

1.4. Σκοπός, Ερευνητικά Ερωτήματα και Συμβολή της Εργασίας

Η παρούσα εργασία στοχεύει στη διερεύνηση και ποσοτική αποτίμηση της ανθεκτικότητας κρίσιμων οντοτήτων, ενσωματώνοντας τη φυσική ασφάλεια και την κυβερνοασφάλεια. Εξετάζεται επίσης η συμβολή των μεθόδων τεχνητής νοημοσύνης στην ανάλυση πολύπλοκων



και αλληλεξαρτώμενων δεδομένων. Η παρούσα εργασία εξετάζει τη μετάβαση από τις παραδοσιακές, ποιοτικές, και αποσπασματικές πρακτικές, όπως υπαγορεύονται από τις οδηγίες της Ευρωπαϊκής Ένωσης και την Ελληνική νομοθεσία, σε ένα συνολικό και δεδομενοκεντρικό πλαίσιο που στοχεύει στην αξιολόγηση της ανθεκτικότητας κρίσιμων οντοτήτων.

Τα κύρια ερευνητικά ερωτήματα εξετάζονται ως εξής:

1. Ποιοι είναι οι πιο Κρίσιμοι παράγοντες που επηρεάζουν την ανθεκτικότητα μιας κρίσιμης οντότητας;
2. Μπορούμε να προβλέψουμε αξιόπιστα την κλάση ανθεκτικότητας μιας οντότητας χρησιμοποιώντας μόνο τους δείκτες που είναι εύκολα διαθέσιμοι/αυτοαναφερόμενοι, χωρίς να χρειαστεί πλήρης επιθεώρηση για όλους τους 22 δείκτες;
3. Πώς μπορεί να ποσοτικοποιηθεί η ανθεκτικότητα μέσω δεικτών που συνδυάζουν φυσικές, λειτουργικές και ψηφιακές διαστάσεις των κρίσιμων οντοτήτων;
4. Σε ποιο βαθμό υπερέχουν οι μέθοδοι τεχνητής νοημοσύνης έναντι των παραδοσιακών στατιστικών προσεγγίσεων στην ανάλυση κινδύνου και ανθεκτικότητας των κρίσιμων οντοτήτων;
5. Πώς μπορούμε να υποστηρίξουμε μια ενοποιημένη μεθοδολογία που συνδυάζει τις απαιτήσεις των CER και NIS2 με επιχειρησιακά μετρήσιμα αποτελέσματα;

ΚΕΦΑΛΑΙΟ 2

Θεσμικό Πλαίσιο και Κρίσιμες Οντότητες

2.1. Η Ανθεκτικότητα ως Αναδύομενη Κανονιστική αρχή

Τα τελευταία επτά χρόνια έχουν αναδείξει με έμφαση τη σημασία της ανθεκτικότητας των οργανισμών και των κρίσιμων υπηρεσιών. Οι πανδημικές κρίσεις, οι ενεργειακοί εκβιασμοί, οι υβριδικές απειλές, οι κυβερνοεπιθέσεις και οι ακραίες καιρικές συνθήκες έχουν καταδείξει ότι η ασφάλεια ενός σύγχρονου κράτους δεν περιορίζεται πλέον στη συμβατική έννοια της εθνικής άμυνας. Αντίθετα, αφορά επίσης τη συνεχή λειτουργία των συστημάτων που είναι απαραίτητα για την καθημερινή ζωή, όπως η ενέργεια, οι μεταφορές, το τραπεζικό σύστημα, η υγεία, η υδροδότηση, οι ψηφιακές υποδομές κλπ. Σε απάντηση αυτών των προκλήσεων, η Ευρωπαϊκή Ένωση έχει δημιουργήσει ένα νέο ρυθμιστικό πλαίσιο που διαμορφώνει σταδιακά ένα συνολικό μοντέλο «ολιστικής ανθεκτικότητας», συνδυάζοντας τη φυσική προστασία κρίσιμων οντοτήτων¹⁰ (CER), την κυβερνοασφάλεια (NIS2) και πλέον, τη ρύθμιση της τεχνητής νοημοσύνης (AI Act¹¹).

Είναι σημαντικό να σημειωθεί ότι η έννοια της ανθεκτικότητας δεν εμφανίζεται ρητά στις θεμελιώδεις Συνθήκες της Ευρωπαϊκής Ένωσης. Ωστόσο, καθιερώθηκε σταδιακά ως κεντρική πολιτική έννοια μέσω των ετήσιων Εκθέσεων Στρατηγικής Προοπτικής της Ευρωπαϊκής Επιτροπής, ιδιαιτέρως μετά την εξάπλωση της πανδημίας COVID-19. Η ανθεκτικότητα συνδέεται στενά με τον στόχο της κλιματικής ουδετερότητας¹² έως το 2050 και δεν περιορίζεται μόνο στην ικανότητα να αντέχει κανείς σε διαταραχές. Αντιθέτως, προϋποθέτει μια ευρύτερη ικανότητα μετασχηματισμού και προσαρμογής στα νέα δεδομένα με βιώσιμο, δίκαιο, δημοκρατικό τρόπο, σεβόμενη παράλληλα τους πολίτες. Η πρόοδος προς

¹⁰ Στον Κανονισμό CER, ο οποίος υιοθετεί μια προσέγγιση που λαμβάνει υπόψη «όλους τους κινδύνους», και επικεντρώνεται στην ανθεκτικότητα των οντοτήτων σε φυσικούς, επιχειρησιακούς και οργανωτικούς κινδύνους, εντάσσονται οι Οδηγίες: α) 2012/18/ΕΕ που είναι ευρύτερα γνωστή ως Οδηγία Seveso III, αποτελεί το βασικό νομοθετικό πλαίσιο της Ευρωπαϊκής Ένωσης για την πρόληψη μεγάλων βιομηχανικών ατυχημάτων και τον περιορισμό των συνεπειών τους στην ανθρώπινη υγεία και το περιβάλλον και β) 2007/60/ΕΚ που είναι γνωστή ως Οδηγία για τις Πλημμύρες, θεσπίζει ένα ενιαίο πλαίσιο για την αξιολόγηση και τη διαχείριση των κινδύνων πλημμύρας σε επίπεδο Ευρωπαϊκής Ένωσης, με στόχο τη μείωση των αρνητικών συνεπειών στην ανθρώπινη υγεία, το περιβάλλον, την πολιτιστική κληρονομιά και την οικονομική δραστηριότητα και οι Κανονισμοί (ΕΕ): α) 2019/941, που θεσπίζει το νομικό πλαίσιο της Ευρωπαϊκής Ένωσης για την πρόληψη, την προετοιμασία και τη διαχείριση κρίσεων στον εφοδιασμό ηλεκτρικής ενέργειας, ενισχύοντας την περιφερειακή συνεργασία και την αλληλεγγύη μεταξύ των κρατών μελών και β) 2017/1938, που αποτελεί το κεντρικό νομοθετικό εργαλείο της Ευρωπαϊκής Ένωσης για την πρόληψη, τον συντονισμό και την αντιμετώπιση κρίσεων στον εφοδιασμό με φυσικό αέριο, διασφαλίζοντας την προστασία των καταναλωτών σε περίπτωση σοβαρών διαταραχών στην αγορά.

¹¹ Κανονισμός (ΕΕ) 2024/1689 του Ευρωπαϊκού Κοινοβουλίου και του Συμβουλίου, της 13ης Ιουνίου 2024 [Κανονισμός για την Τεχνητή Νοημοσύνη], για τη θέσπιση εναρμονισμένων κανόνων σχετικά με την τεχνητή νοημοσύνη και την τροποποίηση των Κανονισμών (ΕΚ) αριθ. 300/2008, (ΕΕ) αριθ. 167/2013, (ΕΕ) αριθ. 168/2013, (ΕΕ) 2018/858, (ΕΕ) 2018/1139 και (ΕΕ) 2019/2144 και των Οδηγιών 2014/90/ΕΕ, (ΕΕ) 2016/797 και (ΕΕ) 2020/1828. https://eur-lex.europa.eu/legal-content/EL/TXT/PDF/?uri=OJ:L_202401689.

¹² Κλιματική αλλαγή: Η δράση της ΕΕ. Οι χώρες της ΕΕ εργάζονται για την καταπολέμηση της κλιματικής αλλαγής και την επίτευξη κλιματικής ουδετερότητας έως το 2050. <https://www.consilium.europa.eu/el/policies/climate-change/>.

αυτήν την κατεύθυνση παρακολουθείται μέσω των Πινάκων Ελέγχου Ανθεκτικότητας¹³ της Επιτροπής, οι οποίοι συγκρίνουν τις δυνατότητες και τις αδυναμίες κάθε κράτους μέλους.

2.2. Το Έρεισμα της Ανθεκτικότητας στο Πρωτογενές Ενωσιακό Δίκαιο

Η νομική βάση της ανθεκτικότητας μπορεί να εντοπιστεί σε διάφορες διατάξεις του πρωτογενούς δικαίου. Καταρχάς, το άρθρο 3 της Συνθήκης για την Ευρωπαϊκή Ένωση¹⁴ (ΣΕΕ) αναδεικνύει την αποστολή, τις αξίες και τους στόχους της Ένωσης, παρέχοντας ένα ευρύτερο πλαίσιο ερμηνείας που περιλαμβάνει την προστασία των πολιτών από συστημικούς κινδύνους. Επιπλέον, το άρθρο 191 της Συνθήκης για τη Λειτουργία της Ευρωπαϊκής Ένωσης¹⁵ (ΣΛΕΕ), το οποίο καθορίζει τις αρχές της περιβαλλοντικής πολιτικής, σχετίζεται έμμεσα με την ανθεκτικότητα. Η βιώσιμη διαχείριση των φυσικών πόρων και η αντιμετώπιση της κλιματικής αλλαγής αποτελούν σημαντικές προϋποθέσεις για τη λειτουργική ακεραιότητα των κρίσιμων οντοτήτων.

Ένα, σαφώς, καθοριστικό σημείο είναι η περίφημη ρήτρα αλληλεγγύης του άρθρου 222 της Συνθήκης για τη Λειτουργία της Ευρωπαϊκής Ένωσης (ΣΛΕΕ), η οποία υποχρεώνει τα κράτη μέλη να ενεργούν από κοινού όταν ένα κράτος μέλος υφίσταται τρομοκρατική επίθεση ή πλήττεται από φυσική ή ανθρωπογενή καταστροφή. Αυτή η διάταξη αποτελεί στην ουσία το πρωταρχικό θεμέλιο της αλληλεγγύης της Ένωσης σε περιόδους κρίσης, προσφέροντας ερμηνευτική βάση και για τη μετέπειτα νομοθεσία σχετικά με την ανθεκτικότητα των κρίσιμων οντοτήτων. Επιπλέον, το άρθρο 42 της Συνθήκης για την Ευρωπαϊκή Ένωση (ΣΕΕ), ενώ επικεντρώνεται κυρίως στην κοινή πολιτική ασφάλειας και άμυνας, δίνει έμφαση στην αντιμετώπιση απειλών και κρίσεων μέσω συλλογικής δράσης, ενισχύοντας έτσι το ερμηνευτικό πλαίσιο στο οποίο βασίζεται η σύγχρονη ενωσιακή πολιτική ανθεκτικότητας.

Εκτός από το πρωτογενές δίκαιο, η έννοια της ανθεκτικότητας έχει ήδη ενσωματωθεί σε μια σειρά δευτερογενών νομοθετημάτων. Ένα παράδειγμα είναι ο Κανονισμός για το Ταμείο Ανάκαμψης και Ανθεκτικότητας, ο οποίος θέτει ως στόχο την οικονομική, κοινωνική και περιβαλλοντική ενδυνάμωση των κρατών μελών μέσω πράσινων και ψηφιακών μεταρρυθμίσεων. Επιπλέον, ο Κανονισμός (ΕΕ) 2022/1032¹⁶ στοχεύει στην ενεργειακή

¹³ Πίνακες ανθεκτικότητας: https://commission.europa.eu/strategy-and-policy/strategic-foresight/2020-strategic-foresight-report/resilience-dashboards_el.

¹⁴ Το άρθρο 3 της Συνθήκης της Ευρωπαϊκής Ένωσης (ΣΕΕ) αποτελεί τον βασικό ερμηνευτικό πυλώνα και το στρατηγικό πλαίσιο πολιτικής που αποσκοπεί στην προστασία των πολιτών από σύγχρονες συστημικές απειλές. Παράλληλα, το άρθρο 42 της ίδιας συνθήκης θεμελιώνει την Κοινή Πολιτική Ασφάλειας και Άμυνας (ΚΠΑΑ), ενώ η παράγραφος 7 του άρθρου περιλαμβάνει τη ρήτρα αμοιβαίας συνδρομής. Σύμφωνα με αυτήν, εάν ένα κράτος-μέλος δεχθεί ένοπλη επίθεση στην επικράτειά του, τα υπόλοιπα κράτη-μέλη υποχρεούνται να παρέχουν βοήθεια και στήριξη με όλα τα διαθέσιμα μέσα. <https://eur-lex.europa.eu/legal-content/EL/TXT/PDF/?uri=OJ:C:2016:202:FULL>.

¹⁵ Το άρθρο 191 (πρώην άρθρο 174 της ΣΕΚ) της Συνθήκης για τη Λειτουργία της Ευρωπαϊκής Ένωσης (ΣΛΕΕ) διαδραματίζει κρίσιμο ρόλο στην επίτευξη περιβαλλοντικής βιωσιμότητας και κλιματικής ανθεκτικότητας, καθώς παρέχει τις νομικές βάσεις για την πρόληψη και τη διαχείριση κινδύνων. Παράλληλα, η ρήτρα αλληλεγγύης του άρθρου 222 της ίδιας Συνθήκης απαιτεί από την Ένωση και τα κράτη μέλη να ενεργούν συλλογικά με πνεύμα αλληλεγγύης, σε περιπτώσεις τρομοκρατικών επιθέσεων ή σοβαρών φυσικών ή ανθρωπογενών καταστροφών που πλήττουν ένα κράτος μέλος. https://eur-lex.europa.eu/eli/treaty/tfeu_2008/art_191/oj.

¹⁶ Ο Κανονισμός (ΕΕ) 2022/1032, που θεσπίστηκε στις 29 Ιουνίου 2022, αποτελεί ένα νομοθετικό πλαίσιο της Ευρωπαϊκής Ένωσης το οποίο ρυθμίζει ζητήματα σχετικά με την αποθήκευση φυσικού αερίου, διασφαλίζοντας παράλληλα την

ασφάλεια μέσω της μείωσης της εξάρτησης από τρίτους προμηθευτές. Το ίδιο ισχύει και για τον Κανονισμό (ΕΕ) 2024/1991¹⁷ για την αποκατάσταση της φύσης, που συνδέει την ανθεκτικότητα των οικοσυστημάτων με τη γενικότερη κλιματική ανθεκτικότητα της Ένωσης. Αυτά τα θεσπίσματα καταδεικνύουν ότι η ανθεκτικότητα δεν είναι μεμονωμένη ρυθμιστική επιλογή, αλλά αποτελεί πλέον μια οριζόντια πολιτική αρχή που διαπερνά σχεδόν κάθε τομέα δράσης της Ένωσης.

2.3. Η Οδηγία (ΕΕ) 2022/2557 για την Ανθεκτικότητα των Κρίσιμων Οντοτήτων (CER)

Στην καρδιά του νέου ρυθμιστικού πλαισίου βρίσκεται η Οδηγία (ΕΕ) 2022/2557 του Ευρωπαϊκού Κοινοβουλίου και του Συμβουλίου, γνωστή και ως Οδηγία CER. Αυτή αντικατέστησε το προηγούμενο καθεστώς της Οδηγίας 2008/114/ΕΚ για τις Ευρωπαϊκές υποδομές ζωτικής σημασίας και την αξιολόγηση της ανάγκης βελτίωσης της προστασίας τους. Αυτή η αλλαγή δεν είναι απλώς τεχνική, αλλά σηματοδοτεί μια μετατόπιση στη φιλοσοφία. Ενώ το προηγούμενο καθεστώς εστίαζε στην προστασία συγκεκριμένων φυσικών υποδομών, η οδηγία CER επικεντρώνεται στην ανθεκτικότητα ολόκληρων οντοτήτων. Αναγνωρίζεται πλέον ότι οι σύγχρονες υποδομές είναι βαθιά διασυνδεδεμένες και ότι μια διαταραχή σε έναν τομέα, όπως για παράδειγμα στην ενέργεια, μπορεί να έχει αλυσιδωτές συνέπειες σε πολλούς άλλους, από τις μεταφορές μέχρι το τραπεζικό τομέα.

Η Οδηγία προσδιορίζει έντεκα¹⁸ (11) βασικούς τομείς όπου εντοπίζονται κρίσιμες οντότητες, όπως η ενέργεια, οι μεταφορές, οι τράπεζες, οι χρηματοοικονομικές υποδομές, η υγεία, το πόσιμο νερό, τα λύματα, οι ψηφιακές υποδομές, η δημόσια διοίκηση, οι διαστημικές υποδομές και η παραγωγή, επεξεργασία και διανομή τροφίμων. Για καθεμία από αυτές τις κρίσιμες οντότητες, η Οδηγία καθορίζει επτά (7) κύριες κατηγορίες υποχρεώσεων, όπως την εκτίμηση κινδύνου, την εφαρμογή κατάλληλων τεχνικών καθώς και οργανωτικών και διοικητικών μέτρων για εξασφάλιση ανθεκτικότητας (όπως την προστασία των εγκαταστάσεων και την εκπαίδευση του προσωπικού), την άμεση ενημέρωση των αρμόδιων αρχών για περιστατικά που διαταράσσουν ή απειλούν να διαταράξουν βασικές υπηρεσίες, την ένταξη τους σε καθεστώς τακτικής εποπτείας και κυρώσεων, την ανάπτυξη και περιοδική επικαιροποίηση επίσημων σχεδίων ανθεκτικότητας, τον καθορισμό συγκεκριμένου σημείου επαφής με τις εθνικές αρχές και τη διενέργεια ελέγχων ιστορικού για το προσωπικό που κατέχει ευαίσθητες θέσεις ως μέτρο πρόληψης έναντι εσωτερικών απειλών.

ενεργειακή επάρκεια και την ασφάλεια του εφοδιασμού. <https://eur-lex.europa.eu/legal-content/EL/TXT/PDF/?uri=CELEX:32022R1032>.

¹⁷ Ο Κανονισμός (ΕΕ) 2024/1991 αποτελεί τον ευρωπαϊκό νόμο για την αποκατάσταση της φύσης, με βασικό στόχο την ανάκαμψη των υποβαθμισμένων οικοσυστημάτων σε όλη την επικράτεια της Ευρωπαϊκής Ένωσης. https://eur-lex.europa.eu/legal-content/EL/TXT/PDF/?uri=OJ:L_202401991.

¹⁸ Η Εθνική Στρατηγική για την Ανθεκτικότητα Κρίσιμων Οντοτήτων 2026-2030, εφαρμόζεται σε δώδεκα (12) τομείς, όπως αναφέρονται στο Παράρτημα του Ν. 5236/2025. Έντεκα (11) από αυτούς ευθυγραμμίζονται με τους τομείς της Οδηγίας (ΕΕ) 2022/2557, η οποία αφορά την ανθεκτικότητα των κρίσιμων οντοτήτων - CER. Ο δωδέκατος τομέας, που σχετίζεται με τα αστικά απόβλητα, αποτελεί εθνική προσθήκη, υπογραμμίζοντας τη σημασία της διαχείρισης μεγάλου όγκου αστικών αποβλήτων για τη δημόσια υγεία, την προστασία του περιβάλλοντος, και την βιωσιμότητα των πόλεων.

Η οικονομική πτυχή του εγχειρήματος δεν είναι αμελητέα. Σύμφωνα με έρευνα του Κοινού Κέντρου Ερευνών της Ευρωπαϊκής Επιτροπής¹⁹, οι ζημιές σε ευρωπαϊκές υποδομές από φυσικές καταστροφές και την κλιματική αλλαγή υπολογίζονται σήμερα σε περίπου 9,3 δισεκατομμύρια ευρώ ετησίως. Το ποσό αυτό αναμένεται να αυξηθεί στα 19,3 δισεκατομμύρια έως το 2050 και να φθάσει τα 37 δισεκατομμύρια μέχρι το τέλος του αιώνα, με τους τομείς ενέργειας και μεταφορών να πλήττονται ιδιαίτερα. Αυτά τα δεδομένα δείχνουν ότι η νομοθετική παρέμβαση δεν στοχεύει σε μια αφηρημένη ή θεωρητική ανησυχία, αλλά σε έναν ποσοτικά τεκμηριωμένο και συνεχώς αυξανόμενο κίνδυνο.

Αναφορικά με το χρονοδιάγραμμα εφαρμογής, η προθεσμία για την ενσωμάτωση της Οδηγίας έληξε στις 17 Οκτωβρίου 2024. Κατά συνέπεια, κάθε κράτος μέλος ήταν υποχρεωμένο να διαμορφώσει, σε διαβούλευση με τους ενδιαφερόμενους φορείς, μια Εθνική στρατηγική που να ενισχύει την ανθεκτικότητα των κρίσιμων οντοτήτων έως τις 17 Ιανουαρίου 2026. Ειδικότερα για την Ελλάδα, η διαδικασία ενσωμάτωσης της Οδηγίας CER καθυστέρησε σημαντικά, προκαλώντας την αποστολή προειδοποίησης από την Ευρωπαϊκή Επιτροπή προς την Ελλάδα και άλλα κράτη μέλη στα τέλη Φεβρουαρίου 2025. Η προειδοποίηση εστίασε στην ανάγκη λήψης των αναγκαίων μέτρων εναρμόνισης, διαφορετικά θα ξεκινούσαν οι σχετικές διαδικασίες παραβίασης. Επιπροσθέτως, είναι απαραίτητο να επισημανθεί ένα ζήτημα που συχνά δημιουργεί σύγχυση. Ο Ν. 5160/2024 ενσωμάτωσε στο Ελληνικό δίκαιο την Οδηγία (ΕΕ) 2022/2555 (NIS2), και όχι την Οδηγία CER (2022/2557). Οι δύο αυτές νομοθετικές πράξεις είναι διακριτές, αν και συνδέονται αμφότερες, παρουσιάζοντας μεν επικαλυπτόμενα αλλά όχι ταυτόσημα πεδία εφαρμογής. Αυτή η διάκριση εξηγεί εν μέρει την μεταγενέστερη, ανεξάρτητη Ελληνική νομοθέτηση για την ανθεκτικότητα των κρίσιμων οντοτήτων μέσω του Ν. 5236/2025.

Ένα σημαντικό ορόσημο για την εφαρμογή του CER είναι η απαίτηση από τα κράτη μέλη να προσδιορίσουν τις κρίσιμες οντότητες²⁰ έως τις 17 Ιουλίου 2026. Από τη στιγμή που οριστούν αυτές οι οντότητες, οι περισσότερες από αυτές θα έχουν στη διάθεσή τους δέκα μήνες πριν αρχίσουν να ισχύουν οι ουσιαστικές υποχρεώσεις ανθεκτικότητας του CER. Επομένως, οι οργανισμοί που δραστηριοποιούνται σε τομείς που καλύπτονται από το CER πρέπει να αρχίσουν να αξιολογούν αν είναι πιθανόν να εμπίπτουν στο πεδίο εφαρμογής, να εξετάζουν και πάλι τα υφιστάμενα πλαίσια ανθεκτικότητάς τους και να εντοπίζουν τυχόν παραλείψεις που πρέπει να διορθώσουν για να συμμορφωθούν.

¹⁹ Έρευνες του Κοινού Κέντρου Ερευνών (JRC) της Ευρωπαϊκής Επιτροπής, ιδιαίτερα μέσω των προγραμμάτων που εστιάζουν στην αξιολόγηση των επιπτώσεων της κλιματικής αλλαγής: α) Η βασική επιστημονική δημοσίευση για τις επιπτώσεις των ακραίων φαινομένων στις υποδομές (Escalating impacts of climate extremes on critical infrastructures in Europe - 2018): <https://publications.jrc.ec.europa.eu/repository/handle/JRC108004> και β) Τα μοντέλα οικονομικού ρίσκου ανά ευρωπαϊκή περιοχή (Regional economic climate risks in Europe - 2025): <https://publications.jrc.ec.europa.eu/repository/handle/JRC143093>.

²⁰ Στις 14 Ιουλίου 2026 αναρτήθηκε προς Διαβούλευση το OpenGov η Εθνική Στρατηγική για την Ανθεκτικότητα Κρίσιμων Οντοτήτων (άρθρο 5 του Ν. 5236/2025), η οποία ολοκληρώθηκε στις 23 Ιουλίου 2026 και εκκρεμεί η ψήφιση του στην Βουλή των Ελλήνων. https://opengov.gr/minocp/deliberations/enarxi-dimosias-diavoyleysis-gia-tin-ethniki-stratigiki-gia-tin-anthektikotita-ton-krisimon/?show_intro=1.

2.4. Η Ελληνική Ενσωμάτωση Οδηγίας CER και ο Ν. 5236/2025

Ο Ν. 5236/2025 αποτελεί την Ελληνική νομοθετική απάντηση στις απαιτήσεις της Οδηγίας CER²¹. Σύμφωνα με το άρθρο 1 του νόμου, ο στόχος του είναι η ενίσχυση της ανθεκτικότητας των κρίσιμων οντοτήτων που παρέχουν βασικές υπηρεσίες, έναντι κινδύνων ανθρώπινης ή φυσικής προέλευσης. Το πεδίο εφαρμογής του, όπως προσδιορίζεται στο άρθρο 3, ακολουθεί πιστά την Ευρωπαϊκή απαρίθμηση τομέων: ενέργειας, μεταφορών, τραπεζικού συστήματος, χρηματοπιστωτικών αγορών, υγείας, ύδρευσης/πόσιμου νερού, λυμάτων/αποχέτευσης, ψηφιακών υποδομών, δημόσιας διοίκησης, διαστήματος και παραγωγής, μεταποίησης και διανομής τροφίμων, εξασφαλίζοντας πλήρη εναρμόνιση με το Ευρωπαϊκό πρότυπο.

Στο επίπεδο των επιμέρους υποχρεώσεων, το άρθρο 13 του νόμου επαναλαμβάνει και εξειδικεύει τον πυρήνα των υποχρεώσεων της Οδηγίας, καθώς περιλαμβάνει την εκτίμηση κινδύνων, την αξιολόγηση φυσικών και ανθρωπογενών απειλών, με ειδική έμφαση στους υβριδικούς και τρομοκρατικούς κινδύνους, τη λήψη συγκεκριμένων μέτρων ανθεκτικότητας και το σχεδιασμό επιχειρησιακής συνέχειας. Σχετικά με την θεσμική αρχιτεκτονική, το άρθρο 10 ορίζει τη Γενική Γραμματεία Προστασίας Κρίσιμων Οντοτήτων²² (Γ.Γ.Π.Κ.Ο.) ως αρμόδια αρχή, η οποία συνεργάζεται με την Εθνική Αρχή Κυβερνοασφάλειας και τις κατά τομέα εποπτικές αρχές, δημιουργώντας έτσι ένα πολυεπίπεδο σύστημα συντονισμού μεταξύ δημόσιου και ιδιωτικού τομέα.

Από τη συνταγματική οπτική, σύμφωνα με την Παλαιολόγου²³ (2026), ο νόμος ενισχύει την αρχή της πρόληψης, την αναλογικότητα και την υποχρέωση του κράτους να διασφαλίζει τη δημόσια ασφάλεια. Αποτελεί μέρος του ευρύτερου πλαισίου του Συντάγματος, όπως καθορίζεται στο άρθρο 5 για την προστασία της ζωής²⁴ και την ελεύθερη ανάπτυξη της προσωπικότητας και στο άρθρο 25 για το κοινωνικό κράτος δικαίου²⁵. Αυτή είναι η πρώτη φορά που η Ελληνική νομοθεσία εισάγει μια σαφή υποχρέωση κρατικής πρόληψης απέναντι σε συστημικούς κινδύνους, αντί για απλή αντίδραση εκ των υστέρων. Ωστόσο, αυτή η μετατόπιση έχει τις προκλήσεις της, διότι η εφαρμογή του νόμου απαιτεί μεγάλη προσοχή ώστε τα επιβαλλόμενα μέτρα ελέγχου και ασφαλείας στις κρίσιμες οντότητες να μη θίγουν υπερβολικά το δικαίωμα προστασίας προσωπικών δεδομένων, την οικονομική ελευθερία ή την αυτονομία των επιχειρήσεων που εμπίπτουν σε αυτόν.

²¹ Ν. 5236/2025, άρθρα 1, 3, 5, 10, 13, 24 (ΦΕΚ Α' 175/2025).

²² Σύμφωνα με την παρ. 3 του άρθρου 10 του Ν. 5236/2025, η Γενική Γραμματεία Προστασίας Καταναλωτή Οντοτήτων υποχρεούται, έως τις 17 Ιουλίου 2028 και στη συνέχεια κάθε δύο (2) έτη, να υποβάλλει συνοπτική έκθεση στην Ευρωπαϊκή Επιτροπή και στην ομάδα που ασχολείται με την ανθεκτικότητα των κρίσιμων οντοτήτων, όπως ορίζεται στο άρθρο 20. Η έκθεση αυτή πρέπει να περιλαμβάνει τις κοινοποιήσεις των υποβαλλόμενων εκθέσεων από τις κρίσιμες οντότητες σύμφωνα με τις προβλεπόμενες υποχρεώσεις τους βάσει του νόμου.

²³ Παλαιολόγου, Ν. (2026), «Η ανθεκτικότητα των κρίσιμων οντοτήτων και υπηρεσιών: Η ευρωπαϊκή νομοθεσία», Νόμος και Φύση. <https://europedirect.gr/wp-content/uploads/2026/01/i-anthektikotita-ton-krisimon-ypodomon-kai-ypiresion-i-eyropaiki-nomothesia.pdf>.

²⁴ Σύνταγμα - ΜΕΡΟΣ ΔΕΥΤΕΡΟ - Ατομικά και κοινωνικά δικαιώματα, Άρθρο 5: (Ελεύθερη ανάπτυξη της προσωπικότητας, προσωπική ελευθερία) <https://www.hellenicparliament.gr/vouli-ton-ellinon/to-politevma/syntagma/article-5/>.

²⁵ Σύνταγμα - ΜΕΡΟΣ ΔΕΥΤΕΡΟ - Ατομικά και κοινωνικά δικαιώματα, Άρθρο 10: (Δικαίωμα αναφοράς προς τις αρχές) <https://www.hellenicparliament.gr/vouli-ton-ellinon/to-politevma/syntagma/article-10/>.

2.5. Η Εθνική Στρατηγική Ανθεκτικότητας Κρίσιμων Οντοτήτων 2026-2030

Η νομοθετική ρύθμιση ενισχύεται από την Εθνική Στρατηγική Ανθεκτικότητας Κρίσιμων Οντοτήτων²⁶ για το διάστημα 2026-2030, η οποία, βάσει του άρθρου 5 του Ν. 5236/2025, λειτουργεί ως βασικό εργαλείο για την εφαρμογή του νόμου. Η Στρατηγική περιλαμβάνει εκτίμηση Εθνικών κινδύνων, διαδικασίες για τον προσδιορισμό των κρίσιμων οντοτήτων, μέτρα στήριξης, μηχανισμούς συνεργασίας μεταξύ του δημόσιου και ιδιωτικού τομέα, καθώς και συντονισμό με το πλαίσιο κυβερνοασφάλειας της NIS2. Οι βασικοί πυλώνες της προσέγγισης εκτείνονται από την προστασία ζωτικής σημασίας οντοτήτων και την ενίσχυση της ανθεκτικότητας των εφοδιαστικών αλυσίδων, έως τη συστημική διαχείριση κρίσεων, την εφαρμογή μέτρων φυσικής ασφάλειας και την προετοιμασία απέναντι σε υβριδικές απειλές. Αυτοί οι τομείς καλύπτουν ολοκληρωμένα τον κύκλο της ανθεκτικότητας, συγκροτώντας μια ενιαία και συνεκτική δομή, η οποία υποστηρίζεται από τους αντίστοιχους δείκτες παρακολούθησης για την αξιολόγηση και διασφάλιση της αποτελεσματικότητάς της.

2.5.1. Οι Έξι (6) Στρατηγικοί Στόχοι

Στόχος 1: Πρόληψη, Πρόβλεψη και Επίγνωση κινδύνου

Η ενίσχυση της ανθεκτικότητας κρίσιμων οντοτήτων επιτυγχάνεται μέσω της άμεσης αναγνώρισης, αξιολόγησης και χαρτογράφησης Εθνικών και διατομεακών κινδύνων. Παράλληλα, δίνεται έμφαση στην ανάπτυξη μηχανισμών έγκαιρης προειδοποίησης, με στόχο τη διαμόρφωση μιας συλλογικής κουλτούρας ασφάλειας και την πρόληψη αλυσιδωτών επιπτώσεων με άξονες δράσης:

- Εθνική αξιολόγηση κινδύνων που ανανεώνεται τουλάχιστον κάθε τέσσερα (4) χρόνια.
- Δίκτυα για ασφαλή ανταλλαγή πληροφοριών και έγκαιρη προειδοποίηση, όπως τα δίκτυα TISN.
- Σύστημα δεικτών Κρίσιμου κινδύνου με ελάχιστα όρια ενεργοποίησης, παράλληλα με την καλλιέργεια κουλτούρας ανθεκτικότητας μέσω ενημέρωσης.

Στόχος 2: Προστασία και Θωράκιση

Η ενίσχυση της ανθεκτικότητας μέσω στοχευμένων μέτρων ασφάλειας (φυσικά, τεχνικά, οργανωτικά και ανθρώπινα) στοχεύοντας στην δραστική μείωση έκθεσης σε απειλές και τρωτότητες για απρόσκοπτη λειτουργία των κρίσιμων οντοτήτων, προστασία του προσωπικού, των εφοδιαστικών αλυσίδων και των πληροφοριακών συστημάτων με άξονες δράσης:

²⁶ Εθνική Στρατηγική Ανθεκτικότητας Κρίσιμων Οντοτήτων 2026-2030 σε εφαρμογή του άρθρου 5 του ν.5236/2025 (Α' 175), με τον οποίο ενσωματώθηκε η Οδηγία (ΕΕ) 2022/2557 (CER) του Ευρωπαϊκού Κοινοβουλίου και του Συμβουλίου, της 14ης Δεκεμβρίου 2022, για την ανθεκτικότητα των κρίσιμων οντοτήτων (L 333/164, 27.12.2022). <https://opengov.gr/minocp/wp-content/uploads/sites/51/2026/07/%CE%9A%CE%9F.%CE%95%CE%98%CE%9D%CE%99%CE%9A%CE%97-%CE%A3%CE%A4%CE%A1%CE%91%CE%A4%CE%97%CE%93%CE%99%CE%9A%CE%97.%CF%83%CF%87%CE%AD%CE%B4%CE%B9%CE%BF-%CF%80%CF%81%CE%BF%CF%82-%CE%B4%CE%B9%CE%B1%CE%B2%CE%BF%CF%8D%CE%BB%CE%B5%CF%85%CF%83%CE%B7.14.07.26.pdf>.



- Υποχρεωτική κατάρτιση Σχεδίων Ανθεκτικότητας για κάθε οργανισμό, περιλαμβάνοντας ελάχιστα απαιτούμενα μέτρα ανά τομέα.
- Ενίσχυση μέσα από εκπαίδευση του προσωπικού και τακτικούς ελέγχους αξιοπιστίας, καθώς και μέτρα προστασίας για τις φυσικές υποδομές.
- Εναρμόνιση και σύνδεση της φυσικής ανθεκτικότητας με την ψηφιακή.
- Εφαρμογή και συμμόρφωση με διεθνώς αναγνωρισμένα πρότυπα.

Στόχος 3: Ανταπόκριση και Διαχείριση Περιστατικών και Κρίσεων

Η ανάπτυξη μηχανισμών έγκαιρης, συντονισμένης και αναλογικής δράσης σε συμβάντα/περιστατικά με σαφείς διαδικασίες διοίκησης, λήψης αποφάσεων, αποτελεσματικής επικοινωνίας, έγκαιρης ενημέρωσης και κατάλληλης κλιμάκωσης σε Εθνικό, Διεθνές και τομεακό επίπεδο. Άμεση προτεραιότητα αντιμετώπισης περιστατικών διπλής φύσης, δηλαδή φυσικής και ψηφιακής προσβολής με άξονες δράσης:

- Λειτουργία Κέντρου Αναφοράς Συμβάντων σε 24ωρη βάση (24/7) εντός της αρμόδιας δομής στη Γενική Γραμματεία Πολιτικής Κρίσεων και Οργανωτικής (Γ.Γ.Π.Κ.Ο.).
- Δημιουργία κοινής ομάδας για την αξιολόγηση περιστατικών μικτής φύσης (ψηφιακής και φυσικής).
- Εντός 24 ωρών, πρώτη κλιμακούμενη ενημέρωση και ορισμός υπεύθυνου εκπροσώπου που θα λειτουργεί ως σημείο επικοινωνίας της κρίσιμης οντότητας.
- Συμμετοχή στα συναφή εθνικά και ευρωπαϊκά συστήματα διαχείρισης περιστατικών και κρίσεων.

Στόχος 4: Αποκατάσταση, Συνέχεια και Προσαρμογή

Η εξασφάλιση γρήγορης ανάκαμψης βασικών λειτουργικών και η συνέχιση παροχής ουσιαστικών υπηρεσιών μετά από διαταραχές. Περιλαμβάνει επιχειρησιακή συνέχεια, ανάπτυξη εφεδρικών σχεδίων και εναλλακτικών επιλογών με αξιοποίηση εμπειριών και προσαρμογή σε συστημικούς και νέους κινδύνους, όπως η κλιματική αλλαγή, η τεχνητή νοημοσύνη, οι υβριδικές απειλές και η παραπλάνηση από ξένους παράγοντες με άξονες δράσης:

- Εκπόνηση σχεδίων επιχειρησιακής συνέχειας, συνοδευόμενη από την ανάπτυξη εναλλακτικών αλυσίδων εφοδιασμού για τη διασφάλιση της απρόσκοπτης λειτουργίας σε περιπτώσεις έκτακτων περιστάσεων.
- Υιοθέτηση συστηματικής διαδικασίας αποτίμησης περιστατικών (After Action Review - AAR), που περιλαμβάνει την αξιολόγηση και την αναλυτική τεκμηρίωση των αποτελεσμάτων της διαχείρισης κρίσεων, με στόχο τη βελτίωση των πρακτικών και τη μελλοντική πρόληψη.
- Θεσμοθέτηση ενός Εθνικού προγράμματος ασκήσεων ετοιμότητας και διενέργειας stress tests, με σκοπό τη δοκιμή της αποτελεσματικότητας των υφιστάμενων μηχανισμών και την ενίσχυση της ανθεκτικότητας των συστημάτων.



- Σύνταξη και διάδοση εξειδικευμένων οδηγιών, εκπαιδευτικού καθοδηγητικού υλικού, πρότυπων ανθεκτικότητας, καθώς και ελαχίστων απαιτήσεων ασφάλειας, τα οποία απευθύνονται σε κρίσιμες οντότητες, προκειμένου να ενισχυθεί η συνολική τους ικανότητα ανταπόκρισης σε κρίσεις.

Στόχος 5: Διακυβέρνηση, Συντονισμός και Διεθνή Διασύνδεση

Η εγκαθίδρυση ενός συνεκτικού πλαισίου διακυβέρνησης που περιλαμβάνει σαφή κατανομή αρμοδιοτήτων, αποτελεσματικό συντονισμό και ουσιαστική συνεργασία μεταξύ δημόσιου και ιδιωτικού τομέα. Αυτό συνεπάγεται τη σύνδεση πολιτικών ανθεκτικότητας, κυβερνοασφάλειας και διαχείρισης κρίσεων, ενώ εξασφαλίζει τη δραστήρια συμμετοχή της χώρας σε ευρωπαϊκούς και διεθνείς μηχανισμούς, όπως το CERG, το NATO, καθώς και σε διμερείς και περιφερειακές συνεργασίες με τρίτες χώρες με άξονες δράσης:

- Δυνατότητα κατάρτισης συμφωνιών συνεργασίας, όπως με την Ε.Α.Κ., για τη ενίσχυση της φυσικής και ψηφιακής ανθεκτικότητας. Αυτό περιλαμβάνει τη συνολική διαχείριση κινδύνων και το συντονισμό κρίσιμων οντοτήτων που αντιμετωπίζουν διπλές απειλές. Επίσης, μπορεί να γίνει συνεργασία με την Τράπεζα της Ελλάδος και την Επιτροπή Κεφαλαιαγοράς, σύμφωνα με τον Κανονισμό DORA.
- Εναρμονισμένη Εθνική εκπροσώπηση σε ΕΕ και NATO, ενσωματώνοντας τον έλεγχο άμεσων ξένων επενδύσεων.
- Παρακολούθηση και αξιολόγηση των κρίσιμων οντοτήτων.

Στόχος 6: Ικανότητες, Πόροι και Χρηματοδότηση

Η ενίσχυση των ανθρώπινων, οργανωτικών, τεχνολογικών και χρηματοδοτικών δυνατοτήτων που είναι απαραίτητες για την εφαρμογή της Στρατηγικής περιλαμβάνει την ανάπτυξη εξειδικευμένου εργατικού δυναμικού, τη συστηματική εκπαίδευση και άσκηση, καθώς και την αξιοποίηση σύγχρονων εργαλείων και εξοπλισμού. Επίσης, διασφαλίζεται η ύπαρξη επαρκών και βιώσιμων Εθνικών και Ευρωπαϊκών πόρων, αξιοποιώντας το προτεινόμενο Εθνικό Ταμείο Ανθεκτικότητας Κρίσιμων Οντοτήτων με άξονες δράσης:

- Εφαρμογή του Εθνικού Προγράμματος Εκπαίδευσης και Πιστοποίησης για το αρμόδιο προσωπικό των κρίσιμων οντοτήτων και των ελεγκτών/επιθεωρητών στο πλαίσιο των Κρίσιμων Οντοτήτων, όπως ορίζεται στο άρθρο 24, παράγραφος 7 του νόμου 5236/2025.
- Εστίαση στην αξιοποίηση Εθνικών και Ευρωπαϊκών πόρων, περιλαμβάνοντας την κατηγορία 1,5% των αμυντικών δαπανών σύμφωνα με τις υποχρεώσεις του NATO.
- Δημιουργία Εθνικού Ταμείου Ανθεκτικότητας Κρίσιμων Οντοτήτων (υπό πρόταση).

2.5.2. Παρακολούθηση και Σύστημα Δεικτών

Δημιουργία ολοκληρωμένου Συστήματος Δεικτών Παρακολούθησης, το οποίο περιλαμβάνει δείκτες απόδοσης και κινδύνου. Οι δείκτες αυτοί κατηγοριοποιούνται σε τέσσερις (4) κύριες διαστάσεις και συνδέονται άμεσα με τους έξι στρατηγικούς στόχους που διατυπώνονται στην υποενότητα 2.5.1.



- **Διάσταση Α, Διακυβέρνηση:** Αξιολόγηση της θεσμικής και οργανωτικής ωριμότητας των αρμόδιων φορέων.
- **Διάσταση Β, Αποδοτικότητα οντοτήτων:** Αξιολόγηση της επιχειρησιακής ετοιμότητας και του βαθμού συμμόρφωσης κρίσιμων οντοτήτων.
- **Διάσταση Γ, Αποτελέσματα:** Μέτρηση της πραγματικής ανθεκτικότητας των υπηρεσιών σε επίπεδο συστήματος.
- **Διάσταση Δ, Ευθυγράμμιση με το πλαίσιο SENDAI²⁷:** Προσαρμογή στις απαιτήσεις του 4ου στόχου του πλαισίου SENDAI των Ηνωμένων Εθνών για τη μείωση των επιπτώσεων σε κρίσιμες υποδομές.

Το σύστημα είναι επίσης συμβατό με τον Δείκτη Διακυβέρνησης Υποδομών του ΟΟΣΑ και συμπληρώνεται από έναν Σύνθετο Δείκτη Ανθεκτικότητας με βαθμολογία από 0 έως 100. Στην υποενότητα 2.5.4 περιλαμβάνεται κατάλογος των δεικτών και ο πίνακας αντιστοίχισης με τους στρατηγικούς στόχους. Ιδιαίτερη μνεία γίνεται στις βασικές τιμές, τις τιμές-στόχους, τους συντελεστές στάθμισης και τα κατώτατα όρια ενεργοποίησης που θα αναφέρονται στο Σχέδιο Υλοποίησης. Οι αρχικές τιμές καθορίζονται με την πρώτη συνολική συλλογή δεδομένων κατά το πρώτο δωδεκάμηνο πλήρους λειτουργίας της Γενικής Γραμματείας Πολιτικής και Κοινωνικής Οργάνωσης (Γ.Γ.Π.Κ.Ο.), ενώ οι τιμές-στόχοι έχουν χρονικό πλαίσιο μέχρι το 2030.

2.5.3. Τομείς, Ουσιώδεις Υπηρεσίες και Αρμόδιες Αρχές

Στον πίνακα 2.1 παρουσιάζονται οι δώδεκα (12) τομείς που περιλαμβάνονται στο Παράρτημα του Ν. 5236/2025 (ΦΕΚ Α' 175) και στο Παράρτημα Β' του Σχεδίου Εθνικής Στρατηγικής Ανθεκτικότητας Κρίσιμων Οντοτήτων 2026-2030 και περιέχει ενδεικτικές βασικές υπηρεσίες, ενώ ο κατάλογος αυτός δεν είναι πλήρης. Η λεπτομερής κατηγοριοποίηση των υποτομέων θα παρουσιάζεται εκτενώς στο Σχέδιο Υλοποίησης.

Πίνακας 2.1: Ενοποιημένος Πίνακας, Παράρτημα Β' Εθνικής Στρατηγικής Ανθεκτικότητας Κρίσιμων Οντοτήτων 2026–2030 & Παράρτημα Οδηγίας (ΕΕ) 2022/2557.

Τομέας	Υποτομείς (Οδηγία (ΕΕ) 2022/2557)	Ουσιώδεις Υπηρεσίες (Εθνική Στρατηγική)	Τομεακή Αρμόδια Αρχή	Αρμόδιο Υπουργείο
1. Ενέργεια	α) Ηλεκτρική ενέργεια β) Τηλεθέρμανση και τηλεψύξη	Παροχή ηλεκτρικής ενέργειας στον τελικό καταναλωτή, συστήματα μεταφοράς και διανομής ηλεκτρισμού, τηλεθέρμανσης/τηλεψύξης, παραγωγή,	Ρυθμιστική Αρχή Αποβλήτων, Ενέργειας και Υδάτων (Ρ.Α.Α.Ε.Υ.)	Υ.Π.ΕΝ.

²⁷ Το Πλαίσιο Sendai αποτελεί διεθνή συμφωνία των Ηνωμένων Εθνών, η οποία τέθηκε σε ισχύ τον Μάρτιο του 2015 στην πόλη Σεντάι της Ιαπωνίας, κατά την 3η Παγκόσμια Διάσκεψη του ΟΗΕ για τη Μείωση του Κινδύνου Καταστροφών. Αντικατέστησε το προηγούμενο Πλαίσιο Δράσης του Hyogo που εφαρμόστηκε από το 2005 έως το 2015. Βασικός στόχος του είναι η σημαντική μείωση των κινδύνων που συνδέονται με καταστροφές και η ελαχιστοποίηση των απωλειών σε ανθρώπινες ζωές, μέσα βιοπορισμού, υγεία, οικονομία, καθώς και σε φυσικούς, κοινωνικούς, πολιτιστικούς και περιβαλλοντικούς πόρους που επηρεάζουν άτομα, επιχειρήσεις, κοινότητες και χώρες. Οι 4 προτεραιότητες δράσης του είναι: 1) Κατανόηση του κινδύνου καταστροφών – δεδομένα, έρευνα, εκτίμηση τρωτότητας, 2) Ενίσχυση της διακυβέρνησης του κινδύνου καταστροφών – θεσμικά πλαίσια, πολιτικές, 3) Επενδύσεις στη μείωση κινδύνου για ανθεκτικότητα – οικονομικές, δομικές, μη-δομικές επενδύσεις, και 4) Ενίσχυση ετοιμότητας για αποτελεσματική ανταπόκριση και ανασυγκρότηση – “Build Back Better”.



Τομέας	Υποτομείς (Οδηγία (ΕΕ) 2022/2557)	Ουσιώδεις Υπηρεσίες (Εθνική Στρατηγική)	Τομεακή Αρμόδια Αρχή	Αρμόδιο Υπουργείο
	γ) Πετρέλαιο δ) Αέριο ε) Υδρογόνο	αποθήκευση, μεταφορά και διανομή πετρελαίου, φυσικού αερίου και υδρογόνου.		
2. Μεταφορές	α) Αεροπορικές β) Σιδηροδρομικές γ) Πλωτές δ) Οδικές ε) Δημόσιες μεταφορές	Αεροπορικές, σιδηροδρομικές, θαλάσσιες και οδικές μεταφορές επιβατών και εμπορευμάτων, λειτουργία αερολιμένων, λιμένων και σιδηροδρομικής υποδομής, έλεγχος κυκλοφορίας και ναυσιπλοΐας.	Α.Π.Α. (αεροπορικές), Ρ.Α.Σ. (σιδηροδρομικές), Γεν. Γραμματεία Ναυτιλίας και Λιμένων-Δ.Λ.Π. (πλωτές), Γεν. Δ/νση Μεταφορών (οδικές)	ΥΠΟ.ΜΕ. / Υ.ΝΑ.Ν.Π.
3. Τραπεζικός κλάδος	Πιστωτικά ιδρύματα (άρθ. 4 σημ. 1 Καν. (ΕΕ) 575/2013) — δεν προβλέπονται επιμέρους υποτομείς	Βασικές τραπεζικές υπηρεσίες, λήψη καταθέσεων, χορήγηση πιστώσεων και υπηρεσίες πληρωμών, στο μέτρο που δεν εμπίπτουν στο πλαίσιο του DORA.	Τράπεζα της Ελλάδος (Τ.τ.Ε.)	ΥΠ.ΟΙΚ. (συνεργασία, όχι εποπτεία βάσει Καταστατικού Ευρωσυστήματος/ ΕΚΤ)
4. Υποδομές χρηματοπιστωτικών αγορών	Διαχειριστές τόπων διαπραγμάτευσης — δεν προβλέπονται επιμέρους υποτομείς Κεντρικοί αντισυμβαλλόμενοι (CCP)	Λειτουργία οργανωμένων αγορών και τόπων διαπραγμάτευσης, υπηρεσίες εκκαθάρισης και διακανονισμού μέσω κεντρικών αντισυμβαλλομένων.	Επιτροπή Κεφαλαιαγοράς (Ε.Κ.)	ΥΠ.ΟΙΚ. (θεσμική εποπτεία, νομοθετικού χαρακτήρα)
5. Υγεία	Πάροχοι υγειονομικής περίθαλψης Εργαστήρια αναφοράς της ΕΕ Οντότητες Ε&Α φαρμάκων Κατασκευαστές βασικών φαρμακευτικών προϊόντων (NACE 21) Κατασκευαστές κρίσιμων ιατροτεχνολογικών προϊόντων Κάτοχοι άδειας χονδρικής πώλησης φαρμάκων	Υγειονομική περίθαλψη, λειτουργία νοσοκομειακών και διαγνωστικών μονάδων, παραγωγή, προμήθεια και διανομή φαρμάκων και ιατροτεχνολογικών προϊόντων, εργαστήρια αναφοράς δημόσιας υγείας.	Γενική Διεύθυνση Υπηρεσιών Υγείας	Υ.Υ.
6. Πόσιμο νερό	Προμηθευτές και διανομείς νερού ανθρώπινης κατανάλωσης — δεν προβλέπονται	Παροχή, επεξεργασία και διανομή ύδατος ανθρώπινης κατανάλωσης, με ποιοτικό έλεγχο και διασφάλιση επάρκειας υδροδότησης.	Ρ.Α.Α.Ε.Υ. και Γεν. Γραμματεία Φυσικού Περιβάλλοντος και	Υ.Π.ΕΝ.



Τομέας	Υποτομείς (Οδηγία (ΕΕ) 2022/2557)	Ουσιώδεις Υπηρεσίες (Εθνική Στρατηγική)	Τομεακή Αρμόδια Αρχή	Αρμόδιο Υπουργείο
	επιμέρους υποτομείς		Υδάτων	
7. Λύματα	Επιχειρήσεις συλλογής/διάθεσης/επεξεργασίας αστικών, οικιακών ή βιομηχανικών λυμάτων — δεν προβλέπονται επιμέρους υποτομείς	Συλλογή, μεταφορά, επεξεργασία και διάθεση αστικών και βιομηχανικών λυμάτων μέσω των αντίστοιχων δικτύων και εγκαταστάσεων.	Διεύθυνση Υδάτων και Περιφερειακές-Τοπικές Αρχές	Υ.Π.ΕΝ.
8. Αστικά απόβλητα *	Δεν προβλέπεται στην Οδηγία (ΕΕ) 2022/2557 — πρόσθετος εθνικός τομέας	Συλλογή, μεταφορά, επεξεργασία, ανακύκλωση και τελική διάθεση αστικών αποβλήτων, λειτουργία εγκαταστάσεων διαχείρισης και ενεργειακής αξιοποίησης.	Γενική Διεύθυνση Διαχείρισης Αποβλήτων	Υ.Π.ΕΝ.
9. Ψηφιακές υποδομές	Πάροχοι IXP Πάροχοι υπηρεσιών DNS Μητρώα ονομάτων τομέα ανωτάτου επιπέδου (TLD) Πάροχοι νεφοϋπολογιστικής Πάροχοι κέντρου δεδομένων Πάροχοι δικτύου διανομής περιεχομένου (CDN) Πάροχοι υπηρεσιών εμπιστοσύνης Πάροχοι δημόσιου δικτύου ηλ. επικοινωνιών Πάροχοι υπηρεσιών ηλ. επικοινωνιών (δημόσια διαθέσιμων)	Κέντρα δεδομένων, υπηρεσίες υπολογιστικού νέφους, DNS, σημεία διασύνδεσης (IXP), μητρώα ονομάτων τομέα, δίκτυα ηλεκτρονικών επικοινωνιών και υπηρεσίες εμπιστοσύνης.	Εθνική Επιτροπή Τηλεπικοινωνιών και Ταχυδρομείων (Ε.Ε.Τ.Τ.) και Ε.Α.Κ.	Υ.ΨΗ.Δ.
10. Δημόσια διοίκηση	Φορείς δημόσιας διοίκησης εθνικών κυβερνήσεων, όπως καθορίζονται κατά το εθνικό δίκαιο — δεν προβλέπονται επιμέρους υποτομείς	Κεντρικές διοικητικές υπηρεσίες και κρίσιμα δημόσια συστήματα, βασικά μητρώα, συστήματα ταυτοποίησης και πιστοποίησης, διοικητική υποστήριξη του κράτους.	Γενική Γραμματεία Δημόσιας Διοίκησης (Γ.Γ.Δ.Δ.), Γ.Γ.Π.Σ.Δ.Δ.	ΥΠ.ΕΣ. / Υ.ΨΗ.Δ.
11. Διάστημα	Διαχειριστές επίγειων υποδομών (κρατικών ή ιδιωτικών) που υποστηρίζουν	Λειτουργία και υποστήριξη επίγειων υποδομών για διαστημικές υπηρεσίες, δορυφορική πλοήγηση, επικοινωνίες και	Ελληνικό Κέντρο Διαστήματος (ΕΛ.ΚΕ.Δ.)	Υ.ΨΗ.Δ.



Τομέας	Υποτομείς (Οδηγία (ΕΕ) 2022/2557)	Ουσιώδεις Υπηρεσίες (Εθνική Στρατηγική)	Τομεακή Αρμόδια Αρχή	Αρμόδιο Υπουργείο
	διαστημικές υπηρεσίες — δεν προβλέπονται επιμέρους υποτομείς	παρατήρηση γης.		
12. Παραγωγή, μεταποίηση και διανομή τροφίμων	Επιχειρήσεις τροφίμων (εφοδιαστική, χονδρική πώληση, βιομηχανική παραγωγή/μεταποίηση μεγάλης κλίμακας) — δεν προβλέπονται επιμέρους υποτομείς	Παραγωγή, επεξεργασία, μεταποίηση και διανομή τροφίμων ευρείας κατανάλωσης, λειτουργία κρίσιμων αλυσίδων εφοδιασμού και κέντρων χονδρικής διανομής.	Ε.Φ.Ε.Τ. και Γενική Διεύθυνση Τροφίμων (ΥΠ.Α.Α.Τ.)	ΥΠ.Α.Α.Τ.

* Ο τομέας «Αστικά απόβλητα» δεν περιλαμβάνεται στο Παράρτημα της Οδηγίας (ΕΕ) 2022/2557 προστέθηκε ως πρόσθετος 12ος Εθνικός τομέας στο πλαίσιο του Ν. 5236/2025 και συνδέεται άμεσα με το όραμα της αδιάλειπτης λειτουργίας της κοινωνίας.

2.5.4. Σύστημα Δεικτών (KPIs και KRIs) για Υπολογισμό CRI

Αυτή η υποενότητα παρουσιάζει το σύστημα δεικτών παρακολούθησης, που περιλαμβάνει Δείκτες Απόδοσης (KPIs) και Δείκτες Κρίσιμου Κινδύνου (KRIs), για τον υπολογισμό του Σύνθετου Δείκτη Ανθεκτικότητας (CRI). Επιπλέον, γίνεται αντιστοίχιση των εν λόγω δεικτών με τους έξι (6) στρατηγικούς στόχους που αναφέρονται στην υποενότητα 2.5.1. Οι τιμές βάσης θα καθοριστούν μετά την πλήρη έναρξη λειτουργίας της Γ.Γ.Π.Κ.Ο., αφού συγκεντρωθούν τα πρώτα ολοκληρωμένα δεδομένα. Για κάθε δείκτη, το Σχέδιο Υλοποίησης θα ορίζει την πηγή των δεδομένων, τη συχνότητα μέτρησης, τον υπεύθυνο φορέα, τη μεθοδολογία υπολογισμού, καθώς και τις τιμές βάσης και στόχου.

Πίνακας 2.2: Διάσταση Α΄, Διακυβέρνηση και Θεσμική Ωριμότητα.

Κωδ.	Δείκτης
A1	Ποσοστό κρίσιμων οντοτήτων που έχουν χαρακτηριστεί
A2	Ποσοστό οντοτήτων με εγκεκριμένο Σχέδιο Ανθεκτικότητας
A3	Μέσος χρόνος έγκρισης Σχεδίου Ανθεκτικότητας
A4	Ποσοστό Τομέων με λειτουργική Τομεακή Αρμόδια Αρχή
A5	Λειτουργία σημείου επαφής
A6	Λειτουργία Δικτύων TISN

Πίνακας 2.3: Διάσταση Β΄, Αποδοτικότητα Οντοτήτων.

Κωδ.	Δείκτης
B1	Ποσοστό οντοτήτων με πιστοποίηση ²⁸ ISO 22301
B2	Ποσοστό Υπευθύνων Ανθεκτικότητας & στελεχών κρίσιμων λειτουργιών με κατάρτιση

²⁸ Το **ISO 22301** αποτελεί το διεθνώς αναγνωρισμένο πρότυπο που ορίζει τις απαιτήσεις για την εγκαθίδρυση ενός Συστήματος Διαχείρισης Επιχειρησιακής Συνέχειας (Business Continuity Management System - BCMS). Αρχικά εκδόθηκε το 2012, ενώ το 2019 υπεβλήθη σε αναθεώρηση, αντικαθιστώντας το βρετανικό πρότυπο BS 25999, από το οποίο αντλήθηκε η πρωταρχική του δομή. Ο πρωταρχικός σκοπός του εν λόγω προτύπου είναι να ενισχύσει τη δυνατότητα των οργανισμών στον σχεδιασμό, την αντίδραση και την ανάκαμψη από διαταρακτικά γεγονότα, όπως φυσικές καταστροφές, κυβερνοεπιθέσεις, πανδημίες, καθώς και διακοπές στην εφοδιαστική αλυσίδα, διασφαλίζοντας τη συνέχιση των κρίσιμων λειτουργιών τους.



Κωδ.	Δείκτης
B3	Μέσος αριθμός ασκήσεων ετησίως ανά οντότητα
B4	Ποσοστό υλοποίησης του ετήσιου προγράμματος επιθεωρήσεων
B5	Ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών
B6	Κρίσιμες υποδομές με ψηφιακό δίδυμο (πilotική εφαρμογή)

Πίνακας 2.4: Διάσταση Γ', Αποτελέσματα.

Κωδ.	Δείκτης
Γ1	Μέσος χρόνος αποκατάστασης βλάβης (MTTR) ανά τομέα
Γ2	Αριθμός σημαντικών συμβάντων με σοβαρές επιπτώσεις
Γ3	Συνολικές οικονομικές επιπτώσεις από διαταραχές
Γ4	Δείκτης ικανοποίησης χρηστών ουσιαστών υπηρεσιών
Γ5	Αριθμός ασφαλιστικών απαιτήσεων από διαταραχές

Πίνακας 2.5: Διάσταση Δ', Ευθυγράμμιση με τον 4ο Στόχο του Πλαισίου SENDAI.

Κωδ.	Δείκτης
Δ1	Ζημίες σε κρίσιμες υποδομές από καταστροφές
Δ2	Ημέρες διακοπής υπηρεσιών υγείας
Δ3	Ημέρες διακοπής υπηρεσιών εκπαίδευσης
Δ4	Πληθυσμός εκτεθειμένος σε διακοπή ηλεκτρισμού άνω των 24 ωρών
Δ5	Πληθυσμός εκτεθειμένος σε διακοπή πόσιμου νερού άνω των 24 ωρών

Οι δείκτες της Διάστασης Δ' ευθυγραμμίζονται με εκείνους του 4ου Στόχου του πλαισίου SENDAI που έχει υιοθετήσει ο Ο.Η.Ε. Παρόλο που η εκπαίδευση (δείκτης Δ3) δεν περιλαμβάνεται ως τομέας εφαρμογής του Ν. 5236/2025, καταγράφεται και παρακολουθείται ως παράμετρος κοινωνικής ανθεκτικότητας. Η διαδικασία υλοποιείται σε συνεργασία με τις αρμόδιες αρχές, χωρίς ωστόσο να δημιουργεί δεσμεύσεις στο πλαίσιο της υφιστάμενης στρατηγικής.

Σύνθετος Δείκτης Ανθεκτικότητας (CRI)

Ο σύνθετος δείκτης, ο οποίος κινείται σε κλίμακα από 0 έως 100, υπολογίζεται ως σταθμισμένος μέσος όρος των τεσσάρων διαστάσεων που περιλαμβάνει. Η παρακολούθηση του πραγματοποιείται σε ετήσια βάση και λειτουργεί ως συνολικός δείκτης αξιολόγησης της προόδου του Εθνικού συστήματος ανθεκτικότητας. Οι συντελεστές βαρύτητας, η αρχική τιμή αναφοράς, καθώς και η επιθυμητή τιμή-στόχος του Δείκτη Ανθεκτικότητας (CRI), θα καθοριστούν και θα αναθεωρούνται σύμφωνα με τις προβλέψεις του Σχεδίου Υλοποίησης.

Δείκτες Κρίσιμου Κινδύνου (KRIs) και Κατώτατα Όρια Ενεργοποίησης

Οι Δείκτες Κινδύνου (KRIs) λειτουργούν ως σύστημα έγκαιρης προειδοποίησης. Αν ξεπεραστούν τα καθορισμένα όρια, γίνεται άμεση παρέμβαση από τη Γενική Γραμματεία Πολιτικής Προστασίας και Κρίσεων (Γ.Γ.Π.Κ.Ο.), σε συνεργασία με τις αρμόδιες τομεακές αρχές και υπηρεσίες. Τα όρια ενεργοποίησης για κάθε δείκτη θα οριστούν στο Σχέδιο Υλοποίησης.



Πίνακας 2.6: Δείκτες Κρίσιμου Κινδύνου (KRIs).

Κωδ.	Δείκτης Κινδύνου	Ενδεικτική Παρέμβαση
K1	Αύξηση συχνότητας/σοβαρότητας συμβάντων ανά τομέα	Τομεακή επανεκτίμηση κινδύνου
K2	Συγκέντρωση κινδύνου σε μεμονωμένο πάροχο ή υποδομή	Εξέταση εφεδρειών/εναλλακτικών
K3	Ένταση διατομεακών αλυσιδωτών επιπτώσεων	Διατομεακή ανασκόπηση
K4	Επιδείνωση χρόνων απόκρισης/αποκατάστασης	Διορθωτικό σχέδιο οντότητας/τομέα
K5	Εξάρτηση από μη εναλλακτικές κρίσιμες υπηρεσίες	Προτεραιοποίηση επένδυσης

Αντιστοίχιση Δεικτών με τους Στρατηγικούς Στόχους

Η Γενική Γραμματεία Πολιτικής και Κοινωνικής Οικονομίας (Γ.Γ.Π.Κ.Ο.) παρακολουθεί την πρόοδο για κάθε στρατηγικό στόχο ξεχωριστά και καταρτίζει μια ετήσια συνολική ανάλυση. Για την αποτύπωση της συλλογικής προόδου επιστρατεύεται ο Σύνθετος Δείκτης Ανθεκτικότητας (CRI).

Πίνακας 2.7: Διάσταση Δ', Ευθυγράμμιση με τον 4ο Στόχο του Πλαισίου SENDAI.

Στρατηγικός Στόχος	Δείκτες Παρακολούθησης
Στόχος 1: Πρόληψη, πρόβλεψη και επίγνωση κινδύνου	A1, A6, B5, Γ2, K1, K2, K3
Στόχος 2: Προστασία και θωράκιση	A2, B1, B6, Δ4, Δ5
Στόχος 3: Ανταπόκριση και διαχείριση περιστατικών και κρίσεων	B3, Γ1, Γ2, K4
Στόχος 4: Αποκατάσταση, συνέχεια και προσαρμογή	Γ1, Γ3, Δ1, Δ2, Δ3, K4, K5
Στόχος 5: Διακυβέρνηση, συντονισμός και διεθνής διασύνδεση	A4, A5, A6, Γ4
Στόχος 6: Ικανότητες, πόροι και χρηματοδότηση	A3, B2, B4, Γ5

Η σημασία της Στρατηγικής δεν είναι απλώς μια τεχνική προσέγγιση. Αντίθετα, στο πολιτικό επίπεδο, αντανακλά τη σύγχρονη θεώρηση της «προληπτικής κρατικής ασφάλειας». Για να είναι Συνταγματικά αποδεκτή, αυτή η Στρατηγική πρέπει πάντα να εφαρμόζεται μέσα στα όρια της νομιμότητας, σύμφωνα με τις αρχές της αναλογικότητας και τις εγγυήσεις του κράτους δικαίου. Ο κίνδυνος που ελλοχεύει σε αυτή την προσέγγιση είναι η πιθανότητα η προληπτική λογική να οδηγήσει σε συνεχή διεύρυνση των εποπτικών εξουσιών του κράτους, χωρίς την ανάλογη ενίσχυση των μηχανισμών λογοδοσίας και δικαστικού ελέγχου.

2.6. Κυβερνοασφάλεια, η Οδηγία (ΕΕ) 2022/2555 (NIS2) και ο Ν. 5160/2024

Παράλληλα με την φυσική ανθεκτικότητα, η Ένωση έχει υιοθετήσει ένα εξίσου φιλόδοξο πλαίσιο για την κυβερνοασφάλεια, μέσω της Οδηγίας (ΕΕ) 2022/2555, ευρύτερα γνωστής ως NIS2. Αυτή στοχεύει να εξασφαλίσει υψηλά και ενιαία επίπεδα κυβερνοασφάλειας σε ολόκληρη την Ένωση. Σε σύγκριση με το προηγούμενο καθεστώς, η NIS2 εισάγει σημαντικές αλλαγές, όπως αυξημένες απαιτήσεις για τις διοικήσεις των οργανισμών, υποχρεωτική διαχείριση κινδύνων και αναφορά περιστατικών, πιο αυστηρές κυρώσεις και άμεση προσωπική ευθύνη των διοικητικών συμβουλίων για τη συμμόρφωση του οργανισμού.



Η ενσωμάτωση της Οδηγίας NIS2²⁹ στην Ελληνική νομοθεσία έγινε μέσω του Ν. 5160/2024. Στο άρθρο 1, ορίζεται ότι ο στόχος είναι να επιτευχθεί υψηλό επίπεδο κυβερνοασφάλειας στη χώρα. Παράλληλα, το άρθρο 2 ασχολείται με την Εθνική Στρατηγική Κυβερνοασφάλειας, καθώς και με τον καθορισμό αρμόδιων αρχών, τη διαχείριση κυβερνοκρίσεων, τις υποχρεώσεις αναφοράς περιστατικών και τα μέτρα διαχείρισης κινδύνου. Σημαντικό στοιχείο είναι η περιγραφή των κρίσιμων οντοτήτων στο άρθρο 4, η οποία παραπέμπει άμεσα στην Οδηγία CER, δείχνοντας τη σκόπιμη σύνδεση μεταξύ αυτών των δύο νομοθετικών πλαισίων.

Ο Ν. 5236/2025 και ο Ν. 5160/2024 συνδέονται με έναν συμπληρωματικό, όχι ανταγωνιστικό τρόπο. Ο πρώτος επικεντρώνεται στη φυσική ανθεκτικότητα και τη συνέχιση της λειτουργίας κρίσιμων οντοτήτων, ενώ ο δεύτερος ασχολείται με την κυβερνοασφάλεια και την ψηφιακή ανθεκτικότητα. Επιπλέον, το άρθρο 10 του Ν. 5236/2025 καθιερώνει μια συγκεκριμένη συνεργασία μεταξύ της αρμόδιας αρχής για την CER και της Εθνικής Αρχής Κυβερνοασφάλειας, αποσκοπώντας στην αποφυγή αλληλοεπικαλύψεων και κενών στην εποπτεία. Από συνταγματική άποψη, η κυβερνοασφάλεια συνδέεται στενά με την προστασία προσωπικών δεδομένων, το απόρρητο των επικοινωνιών, την ασφάλεια δικτύων και πληροφοριών, καθώς και με τη λειτουργία του δημοκρατικού συστήματος. Οι σύγχρονες κυβερνοεπιθέσεις μπορούν να απειλήσουν εκλογικές διαδικασίες και κρίσιμες δημόσιες υπηρεσίες.

2.7. Τεχνητή Νοημοσύνη, ο Κανονισμός (ΕΕ) 2024/1689 (AI Act) και ο Ν. 5321/2026

Το τρίτο μέρος του νεότερου κανονιστικού συστήματος επικεντρώνεται στη διοίκηση των συστημάτων Τεχνητής Νοημοσύνης μέσα από τον Κανονισμό (ΕΕ) 2024/1689, γνωστό και ως AI Act. Αυτός ο κανονισμός αποτελεί το πρώτο πλήρες ρυθμιστικό πλαίσιο παγκοσμίως για την τεχνητή νοημοσύνη. Ο Εθνικός εφαρμοστικός Ν. 5321/2026 οργανώνει τους μηχανισμούς εποπτείας και την εφαρμογή του Κανονισμού στην Ελληνική νομοθεσία, ορίζοντας τις αρμόδιες Εθνικές αρχές και τις διαδικασίες συμμόρφωσης.

Η κεντρική φιλοσοφία του AI Act βασίζεται σε μια προσέγγιση που αξιολογεί τον κίνδυνο, διαχωρίζοντας τα συστήματα σε απαγορευμένα, υψηλού κινδύνου, περιορισμένου κινδύνου και ελάχιστου κινδύνου. Στην κατηγορία των υψηλού κινδύνου περιλαμβάνονται παραδείγματα όπως συστήματα που χρησιμοποιούνται σε τομείς όπως η υγεία, η εκπαίδευση, οι κρίσιμες υποδομές, ο τραπεζικός τομέας, η απασχόληση και οι δημόσιες αρχές. Αυτοί οι τομείς συχνά συμπίπτουν με εκείνους που ήδη εμπίπτουν στην κανονιστική ομπρέλα της CER, ενισχύοντας έτσι το προφίλ ενός συνεκτικού και διασυνδεδεμένου Κανονιστικού Πλαισίου.

Η συνταγματική διάσταση του AI Act είναι εξαιρετικά ευαίσθητη, καθώς οι νέοι κανονισμοί αγγίζουν πτυχές όπως η ανθρώπινη αξιοπρέπεια, η ιδιωτικότητα, η προστασία προσωπικών δεδομένων, η ισότητα, η διαφάνεια της διοικητικής δράσης και το δικαίωμα δικαστικής προστασίας. Το βασικό συνταγματικό ζήτημα που προκύπτει είναι κατά πόσον αποφάσεις που

²⁹ Ν. 5160/2024, άρθρα 1, 2, 4, 10, 30 (ΦΕΚ Α' 195/2024).

μπορεί να είναι καθοριστικές για τη ζωή του πολίτη μπορούν να λαμβάνονται από αλγοριθμικά συστήματα χωρίς ουσιαστικό ανθρώπινο έλεγχο. Είναι σημαντικό να καθοριστούν εγγυήσεις ώστε ο πολίτης να έχει πάντα τη δυνατότητα αποτελεσματικής προσφυγής κατά αποφάσεων που τον αφορούν.

2.8. Συστημική Αλληλεξάρτηση και Θεσμική Αρχιτεκτονική

Η ανασκόπηση των τριών νομοθετικών πυλώνων, CER (N. 5236/2025), NIS2 (N. 5160/2024) και AI Act (N. 5321/2026) αποκαλύπτει μια συνεκτική στρατηγική προσέγγιση από την Ευρωπαϊκή Ένωση, με στόχο τη δημιουργία ενός ολοκληρωμένου συστήματος «ολιστικής ανθεκτικότητας». Εδώ, η φυσική ασφάλεια, η κυβερνοασφάλεια και η ασφαλής χρήση της τεχνητής νοημοσύνης αντιμετωπίζονται ως συνδεδεμένες συνιστώσες μιας ενιαίας Εθνικής και Ευρωπαϊκής ασφάλειας, αντί για ανεξάρτητα και απομονωμένα θέματα. Αυτή η επιλογή αντικατοπτρίζει τη σύγχρονη πραγματικότητα όπου οι κρίσιμες υποδομές είναι ταυτόχρονα φυσικές, ψηφιακές και όλο και περισσότερο αλγοριθμικές, γεγονός που σημαίνει ότι οι απειλές μπορούν να εκδηλωθούν, να εξαπλωθούν ή να ενισχυθούν μέσω οποιασδήποτε από αυτές τις τρεις διαστάσεις.

Η θεσμική δομή που διαμορφώνεται είναι πολυεπίπεδη και προϋποθέτει στενή συνεργασία μεταξύ αρχών με διαφορετική εξειδίκευση. Η Γενική Γραμματεία Προστασίας Κρίσιμων Οντοτήτων επικεντρώνεται στην φυσική ανθεκτικότητα, η Εθνική Αρχή Κυβερνοασφάλειας καλύπτει την ψηφιακή πλευρά, και οι Εθνικές Αρχές Εποπτείας Τεχνητής Νοημοσύνης ασχολούνται με την αλγοριθμική διακυβέρνηση, όλα υπό τον συντονισμό των αρμόδιων τομεακών αρχών. Η αποτελεσματικότητα του συστήματος εξαρτάται από την ποιότητα αυτού του συντονισμού, καθώς ο κατακερματισμός των επιμέρους ρυθμίσεων μπορεί να προκαλέσει επικαλύψεις αρμοδιοτήτων, αυξημένο κανονιστικό κόστος για τις επιχειρήσεις και σημαντικά κενά εποπτείας στις συνδέσεις μεταξύ φυσικής, ψηφιακής και αλγοριθμικής ανθεκτικότητας.

2.9. Συνταγματικές Προεκτάσεις και Κριτική Αποτίμηση

Το νέο ρυθμιστικό πλαίσιο αντιπροσωπεύει μια αλλαγή από μια προσέγγιση που βασίζεται σε κρατική αντίδραση, σε μια περισσότερο προληπτική στρατηγική από την πλευρά του κράτους, με σαφείς συνταγματικές επιπτώσεις. Αυτή η μετάβαση ενισχύει την αρχή της πρόληψης και τη δέσμευση του κράτους να εξασφαλίζει τη δημόσια ασφάλεια και τη συνέχιση των κοινωνικών υπηρεσιών, ενσωματώνοντας σχετικούς νόμους στο γενικότερο πλαίσιο του κοινωνικού κράτους δικαίου. Παράλληλα, εγείρονται σημαντικά ζητήματα σχετικά με την αναλογικότητα, καθώς η αύξηση των υποχρεώσεων επιτήρησης, ελέγχου ιστορικού προσωπικού, υποχρεωτικής αναφοράς περιστατικών και συμμόρφωσης δεν πρέπει να οδηγήσει σε υπερβολικό περιορισμό της οικονομικής ελευθερίας, της επιχειρηματικής αυτονομίας ή των δικαιωμάτων προστασίας προσωπικών δεδομένων των ατόμων που εργάζονται ή δραστηριοποιούνται σε κρίσιμες οντότητες.

Στο πεδίο πρακτικής εφαρμογής, τόσο η βιβλιογραφία όσο και η αντίστοιχη νομολογία επισημαίνουν μια σειρά από προκλήσεις, όπως τα άνισα επίπεδα ετοιμότητας μεταξύ διάφορων κρίσιμων οργανισμών, το κόστος συμμόρφωσης, ειδικά για μικρότερους φορείς, η αναγκαιότητα μιας πολυτομεακής δομής διακυβέρνησης για τη διαχείριση γηράσκουσων υποδομών, καθώς και οι αναπόφευκτες αλληλεπικαλύψεις με άλλες περιβαλλοντικές νομοθεσίες. Αυτές περιλαμβάνουν την Οδηγία-Πλαίσιο για τα Νερά, την Οδηγία για τις Πλημμύρες, την Οδηγία για την επεξεργασία αστικών λυμάτων και τον Κανονισμό για την αποκατάσταση της φύσης. Ένα χαρακτηριστικό παράδειγμα της ανάγκης για συντονισμό είναι η χρήση λύσεων που βασίζονται στη φύση, όπως η αποκατάσταση υγροτόπων για προστασία από πλημμύρες, οι οποίες μπορούν να συμπληρώσουν τα τεχνικά μέτρα ανθεκτικότητας που προβλέπει η CER, συνδυάζοντας οικονομική αποτελεσματικότητα με περιβαλλοντικά και κοινωνικά οφέλη.

Στην Ελλάδα, η καθυστέρηση στην πλήρη υιοθέτηση της Οδηγίας CER, μαζί με την πίεση από την Ευρωπαϊκή Επιτροπή, φανερώνει ένα ευρύτερο ζήτημα σχετικά με την έγκαιρη και ποιοτική ενσωμάτωση του Ενωσιακού δικαίου. Αυτό συνδέεται επίσης με τις ευρύτερες συστάσεις της Επιτροπής προς τη χώρα για τις οικονομικές, κοινωνικές και διαρθρωτικές πολιτικές της. Η καθυστέρηση αυτή ξεπερνά τα διοικητικά ή τεχνικά θέματα, δημιουργώντας τον κίνδυνο η χώρα να είναι πιο εκτεθειμένη σε συστημικούς κινδύνους για μεγαλύτερο διάστημα απ' όσο θα επέτρεπε μια έγκαιρη εφαρμογή του ευρωπαϊκού πλαισίου, με συνέπειες τόσο για τη δημόσια ασφάλεια όσο και για την πιθανή κρατική ευθύνη.

2.10. Συμπερασματικές Παρατηρήσεις

Το νέο ρυθμιστικό πλαίσιο σε Ευρωπαϊκό και Εθνικό επίπεδο για την ανθεκτικότητα βασίζεται σε τρεις αλληλεξαρτώμενους πυλώνες: την Οδηγία CER και τον Ν. 5236/2025 για τη φυσική ανθεκτικότητα κρίσιμων οντοτήτων, την Οδηγία NIS2 και τον Ν. 5160/2024 για την κυβερνοασφάλεια, καθώς και τον Κανονισμό AI Act με τον Ν. 5321/2026 για την ασφαλή και αξιόπιστη χρήση της τεχνητής νοημοσύνης. Η στρατηγική της Ευρωπαϊκής Ένωσης στοχεύει στη δημιουργία ενός ενιαίου συστήματος «ολικής ανθεκτικότητας», όπου η φυσική ασφάλεια, η κυβερνοασφάλεια και η τεχνητή νοημοσύνη αλληλεπιδράση ως ενιαία στοιχεία της εθνικής και ευρωπαϊκής ασφάλειας.

Η ορθή εξισορρόπηση μεταξύ της αναγκαιότητας αυτής της προληπτικής κρατικής μέριμνας και του σεβασμού των θεμελιωδών δικαιωμάτων, όπως η προστασία των προσωπικών δεδομένων, η οικονομική ελευθερία, η επιχειρηματική αυτονομία και η δικαστική προστασία παραμένει το πιο Κρίσιμο συνταγματικό ζήτημα της επόμενης δεκαετίας. Η επιτυχία του νέου αυτού Κανονιστικού Πλαισίου δεν θα αξιολογηθεί μόνο βάσει της τυπικής εναρμόνισης του Ελληνικού νομικού συστήματος με το Ευρωπαϊκό δίκαιο, αλλά κυρίως από την ικανότητα του κράτους να εφαρμόσει αυτές τις νέες υποχρεώσεις με αναλογικότητα, διαφάνεια και ουσιαστικό έλεγχο. Με αυτόν τον τρόπο, η επιδιωκόμενη ανθεκτικότητα των κρίσιμων οντοτήτων δεν θα πρέπει να οδηγήσει σε διεύρυνση των εξουσιών ελέγχου του κράτους σε βάρος των πολιτικών δικαιωμάτων.

ΚΕΦΑΛΑΙΟ 3

Ανάπτυξη Μοντέλων Μηχανικής Μάθησης

3.1. Παραγωγή Συνθετικών Δεδομένων (Synthetic Data Generation) για Εφαρμογές Τεχνητής Νοημοσύνης

Για ακαδημαϊκή έρευνα χωρίς διαθέσιμο πραγματικό σύνολο δεδομένων, η πλέον κατάλληλη μεθοδολογία μπορεί να διαχωριστεί σε τρία (3) στάδια: α) δημιουργία συνθετικών δεδομένων, β) εκπαίδευση μοντέλων, όπως Logistic Regression, Random Forest ή XGBoost, και γ) αξιολόγηση της πιστότητας, της χρησιμότητας και του κινδύνου. Οι Pezoulas et al. (2024), Lu et al. (2023) και Fonseca & Bação (2023) υποδεικνύουν ότι τα συνθετικά δεδομένα είναι αποτελεσματικά όταν τα δεδομένα είναι εμπιστευτικά, δυσεύρετα ή ελλιπή. Ωστόσο, η αξία τους εξαρτάται από την ενδελεχή αξιολόγηση των κατανομών, των σχέσεων και της απόδοσης των εφαρμοζόμενων μοντέλων.

Για την αξιολόγηση της ανθεκτικότητας κρίσιμων οντοτήτων, μια αποτελεσματική προσέγγιση είναι η παραγωγή συνθετικών δεδομένων που χαρακτηρίζονται από παράγοντες όπως η έκθεση, η τρωτότητα, οι έλεγχοι και οι επιπτώσεις. Στη συνέχεια, αυτά τα δεδομένα μπορούν να χρησιμοποιηθούν για την εκπαίδευση μοντέλων μηχανικής μάθησης, όπως Logistic Regression, Random Forest και XGBoost. Σύμφωνα με τις έρευνες των Berry et al. (2026), Kabir et al. (2025) και Alazab et al. (2024), το XGBoost επιτυγχάνει υψηλές αποδόσεις σε μελέτες ανίχνευσης κινδύνου ή απειλών, υπερέχοντας σε μέτρα όπως το Accuracy/F1/ROC-AUC. Εν τω μεταξύ, η Logistic Regression παραμένει χρήσιμη για βαθμονόμηση και ερμηνευσιμότητα, και το Random Forest συχνά προτείνεται ως δεύτερο Baseline μοντέλο. Η Logistic Regression αποτελεί ένα σαφές και ξεκάθαρο Baseline μοντέλο και σε ορισμένες περιπτώσεις παρουσιάζει καλύτερη βαθμονόμηση έναντι πιο ισχυρών συνδυαστικών μοντέλων, όπως σημειώνουν οι Kabir et al. (2025) και Arif et al. (2026). Το Random Forest αποδίδει καλά σε προκλήσεις ανθεκτικότητας ή πρόβλεψης υποδομών, και σε πολλές περιπτώσεις αποτελεί το κατάλληλο μοντέλο με βάση τα χαρακτηριστικά του προβλήματος, όπως επισημαίνει ο Arif et al. (2026).

Σε ερευνητικό επίπεδο, λόγω της απουσίας δημόσια προσβάσιμων δεδομένων σχετικά με την ανθεκτικότητα κρίσιμων οντοτήτων (κατάσταση που προκύπτει από τον απόρρητο ή διαβαθμισμένο χαρακτήρα αυτών των στοιχείων στο πλαίσιο των CER/NIS2), συνήθως υιοθετείται η χρήση συνθετικών δεδομένων που παράγονται μέσω παραμετρικής στατιστικής προσομοίωσης. Η παρούσα εργασία εντάσσεται στην κατηγορία της επιβλεπόμενης μάθησης, ειδικότερα στο πλαίσιο της ταξινόμησης πολλαπλών κλάσεων (multi-class classification). Αναλυτικότερα, η συνάρτηση `pd.qcut()` χρησιμοποιείται για να μετατρέψει τα δεδομένα σε κατηγορική μεταβλητή με τέσσερις διακριτές κλάσεις (Μη Κρίσιμο, Χαμηλή Ανθεκτικότητα, Κρίσιμο και Πολύ Κρίσιμο). Αυτή η μεταβλητή αποθηκεύεται στη στήλη `resilience_class` και αποτελεί τη μεταβλητή-στόχο (Y) που καλούνται να προβλέψουν τα εφαρμοζόμενα μοντέλα. Τα ποσοτικά αποτελέσματα από τη σύγκριση των μοντέλων μηχανικής μάθησης



αντικατοπτρίζουν συνεπώς τη σχετική ικανότητα κάθε αλγορίθμου στην αναγνώριση προκαθορισμένων στατιστικών δομών, και όχι την απόδοσή τους σε πραγματικά επιχειρησιακά δεδομένα. Η εφαρμογή των ευρημάτων σε ρεαλιστικό πλαίσιο απαιτεί μελλοντική επικύρωση μέσω πραγματικών δεδομένων, χρησιμοποιώντας μεθόδους ανωνυμοποίησης.

Πίνακας 3.1: Η έλλειψη πραγματικών δεδομένων για υπολογισμό ανθεκτικότητας κρίσιμων οντοτήτων.

Αίτια Έλλειψης Δεδομένων	Εξήγηση στο Πλαίσιο Κρίσιμων Οντοτήτων
Απόρρητο/Διαβαθμισμένο	Πληροφορίες σχετικά με την ευπάθεια υποδομών, όπως τα ακριβή σημεία αστοχίας, ο μέσος χρόνος αποκατάστασης (MTTR), και οι υλικές ζημιές, χαρακτηρίζονται ως ευαίσθητα δεδομένα εθνικής ασφάλειας. Συχνά αποτελούν αντικείμενο διαβάθμισης σύμφωνα με τους κανονισμούς CER και NIS2.
Επιχειρηματικό Απόρρητο	Ιδιωτικοί οργανισμοί, όπως οι τράπεζες και οι ενεργειακές εταιρείες, αποφεύγουν τη δημοσιοποίηση δεικτών που αφορούν την απόδοση ή τις αδυναμίες τους, εξαιτίας του κινδύνου ανταγωνιστικού μειονεκτήματος που μπορεί να προκύψει από τέτοιες αποκαλύψεις.
Νομικοί Περιορισμοί	Το GDPR και η Εθνική νομοθεσία περιορίζουν τη διάθεση δεδομένων που ενδέχεται έμμεσα να αποκαλύψουν προσωπικά στοιχεία εργαζομένων ή πολιτών.
Πρόσφατη Θεσμοθέτηση	Η Οδηγία CER (ΕΕ 2022/2557) και ο Νόμος 5236/2025 είναι καινούργια και δεν έχει ακόμη συγκεντρωθεί εμπειρική βάση δεδομένων.
Ετερογένεια Μετρήσεων	Οι δώδεκα (12) τομείς, όπως η ενέργεια, η ύδρευση και ο τραπεζικός τομέας κλπ., δεν έχουν καθιερωμένα και τυποποιημένα συστήματα για την καταγραφή δεικτών ανθεκτικότητας.

3.2. Επιλογή Κλάσεων Ταξινόμησης των Κρίσιμων Οντοτήτων

Ο LabelEncoder, που χρησιμοποιείται ως εργαλείο προεπεξεργασίας της scikit-learn, μετατρέπει μια κατηγορική μεταβλητή-στόχο εκφρασμένη με κείμενο (strings) σε ακέραιους αριθμούς, διευκολύνοντας έτσι τη χρήση της από αλγορίθμους μηχανικής μάθησης που απαιτούν αριθμητική είσοδο και δεν επεξεργάζονται απευθείας τις ετικέτες κειμένου. Σε αυτήν την εργασία, η μεταβλητή-στόχος `resilience_class` περιλαμβάνει τέσσερις κλάσεις ετικετών: Μη Κρίσιμο, Χαμηλή Ανθεκτικότητα, Κρίσιμο, Πολύ κρίσιμο. Αυτές πρέπει να κωδικοποιηθούν αριθμητικά πριν από την εκπαίδευση των μοντέλων, γι' αυτό χρησιμοποιείται το LabelEncoder μέσω της μεθόδου `le.fit_transform(y)`.

Είναι κρίσιμο να σημειώσουμε ότι ο LabelEncoder δεν αναγνωρίζει τη φυσική ή λογική σειρά σοβαρότητας των κατηγοριών όπως καθορίζεται στη λίστα `CLASS_LABELS`: [Μη Κρίσιμο, Χαμηλή Ανθεκτικότητα, Κρίσιμο, Πολύ κρίσιμο]. Αντίθετα, αντιστοιχίζει τους ακέραιους αριθμούς με βάση την αλφαβητική σειρά των ονομάτων των ετικετών. Αυτό οδηγεί σε μια μη προφανή αντιστοίχιση: **0 = Κρίσιμο, 1 = Μη Κρίσιμο, 2 = Πολύ Κρίσιμο, 3 = Χαμηλή Ανθεκτικότητα**. Παρόλα αυτά, αυτή η λειτουργία, δεν προκαλεί πρόβλημα ορθότητας στη Logistic Regression της sklearn, η οποία εσωτερικά αντιμετωπίζει τα labels ως αυθαίρετες κλάσεις μέσω softmax/multinomial. Επίσης, η αλφαβητική αρίθμηση που παράγει ο LabelEncoder δεν επηρεάζει την ακρίβεια ούτε του Random Forest, ούτε του XGBoost,

παρότι ο τρόπος λειτουργίας κάθε μοντέλου είναι διαφορετικός. Στο Random Forest, κάθε δέντρο επιλέγει διαχωρισμούς βάσει μετρικών καθαρότητας κόμβου, όπως το Gini Impurity ή η Εντροπία. Αυτές υπολογίζονται με βάση την κατανομή συχνοτήτων των κλάσεων σε κάθε κόμβο και είναι συμμετρικές απέναντι σε οποιαδήποτε εναλλαγή αριθμητικών ετικετών. Η τελική πρόβλεψη προκύπτει μέσω απλής πλειοψηφίας στα φύλλα, μια διαδικασία που βασίζεται σε καθαρά κατηγορική λογική.

Από την άλλη, στο XGBoost, η ρύθμιση με `objective='multi:softprob'` μιμείται τη λογική της πολυωνυμικής Logistic Regression. Εκπαιδεύει ένα ξεχωριστό σύνολο δέντρων (boosting ensemble) για κάθε κλάση και μετατρέπει τα επιμέρους scores σε πιθανότητες χρησιμοποιώντας τη συνάρτηση softmax. Η συνάρτηση απώλειας mlogloss συγκρίνει την προβλεπόμενη κατανομή με τα πραγματικά labels που έχουν κωδικοποιηθεί με one-hot encoding, χωρίς να λαμβάνει υπόψη την αριθμητική απόσταση μεταξύ των ετικετών.

Το κοινό συμπέρασμα και για τα τρία μοντέλα είναι ότι παρόλο που δεν επηρεάζονται από την αυθαίρετη αρίθμηση των κλάσεων, διότι αντιμετωπίζουν το πρόβλημα ως καθαρά ονομαστικό πρόβλημα πολυκλάσης (nominal multiclass classification). Επιπλέον, σημαίνει ότι κανένα από τα μοντέλα δεν δίνει μεγαλύτερη βαρύτητα σε λάθη ταξινόμησης που απέχουν περισσότερο στην κλίμακα (π.χ. πρόβλεψη Μη Κρίσιμο αντί Πολύ Κρίσιμο), αντίθετα με ένα κοντινότερο λάθος (π.χ. Κρίσιμο αντί Πολύ Κρίσιμο). Η καλύτερη αντιμετώπιση ενός τέτοιου ζητήματος απαιτεί τη χρήση τουλάχιστον μετρικών αξιολόγησης που λαμβάνουν υπόψη τέτοια ιεραρχία, όπως το δοκιμασμένο macro-F1 που χρησιμοποιείται στον κώδικα του Παραρτήματος I.

3.2.1. Το Θεμελιώδες Πρόβλημα – Η Κυκλική Εξάρτηση (Circularity) Στόχου-Χαρακτηριστικών

Η μεταβλητή-στόχος Y (resilience_class) δεν αποτελεί μια ανεξάρτητη μέτρηση, αλλά προκύπτει απευθείας ως συνάρτηση των 22 δεικτών που περιλαμβάνονται στις παρακάτω διαστάσεις: Διάσταση Α' (Διακυβέρνηση και Θεσμική Ωριμότητα), Διάσταση Β' (Αποδοτικότητα Οντοτήτων), Διάσταση Γ' (Αποτελέσματα) και Διάσταση Δ' (Ευθυγράμμιση με τον 4ο στόχο του Πλαισίου SENDAI (CRI_LEVELS), σύμφωνα με το Παράρτημα ΣΤ' της Εθνικής Στρατηγικής για την Ανθεκτικότητα Κρίσιμων Οντοτήτων 2026-2030.

Σε περίπτωση που χρησιμοποιούνταν και οι 22 δείκτες ως χαρακτηριστικά εισόδου X , το μοντέλο δεν θα εκπαιδευόταν πραγματικά για να προβλέπει την ανθεκτικότητα. Αντίθετα, θα αναπαρήγαγε έναν ήδη γνωστό ντετερμινιστικό μαθηματικό τύπο, ο οποίος βασίζεται στον σταθμισμένο μέσο όρο και στα κατώφλια του qcut. Αυτό αποτελεί ένα κλασικό πρόβλημα διαρροής δεδομένων μέσω χαρακτηριστικών που προέρχονται από τον στόχο. Το μοντέλο θα επιτύγχανε ένα σχεδόν τέλει macro-F1 skor (κοντά στο 1.0), όπου η ακρίβεια θα περιοριζόταν μόνο από τον προστιθέμενο θόρυβο και την ποινή λόγω αλληλεπιδράσεων (interaction_penalty). Ωστόσο, αυτή η υψηλή επίδοση δεν θα ήταν αποτέλεσμα κατανόησης της σχέσης με την ανθεκτικότητα, αλλά αντίθετα θα οφειλόταν στην απλή αποκωδικοποίηση ορισμού του στόχου.

3.2.2. Η Επιλογή των Δεικτών για την Χρήση στα Μοντέλα Τεχνητής Νοημοσύνης

Σε ένα πραγματικό σύστημα CER/NIS2, η αρμόδια αρχή που είναι υπεύθυνη για τους ελέγχους δεν έχει πάντα άμεση πρόσβαση σε όλους τους 22 δείκτες μιας οντότητας, προτού η ίδια η οντότητα υποβάλει την επίσημη τεχνική έκθεση για την ενημέρωση της εποπτεύουσας αρχής. Πολλοί από αυτούς τους δείκτες απαιτούν λεπτομερείς και επιτόπιες επιθεωρήσεις, όπως για παράδειγμα ο μέσος χρόνος αξιολόγησης και έγκρισης του Σχεδίου Ανθεκτικότητας (A3_appr_time), οι ζημιές σε κρίσιμες υποδομές λόγω καταστροφών (D1_infra_damage) ή οι συνολικές οικονομικές επιπτώσεις από διαταραχές (C3_financial_loss σε ευρώ) κλπ. Τέτοιου είδους διαδικασίες είναι τόσο χρονοβόρες όσο και δαπανηρές, ιδιαίτερα αν λάβουμε υπόψη ότι αυτές εφαρμόζονται σε 12 τομείς και αφορούν εκατοντάδες ή χιλιάδες οντότητες. Αυτό μετασχηματίζει το πρόβλημα από μια απλή αριθμητική ανάλυση σε ένα περισσότερο σύνθετο ζήτημα πρόβλεψης μέσω μοντελοποίησης με σημαντική πρακτική αξία. Εάν ένα μοντέλο τεχνητής νοημοσύνης επιτύχει ικανοποιητική απόδοση χρησιμοποιώντας μόνο 7 από τους 22 δείκτες, τότε παρέχεται ισχυρό κίνητρο για την αξιοποίηση της τεχνολογίας αυτής ως εργαλείου προτεραιοποίησης των πόρων ελέγχου. Με πιο απλά λόγια, τα μοντέλα αυτά μπορούν να συμβάλλουν στον εντοπισμό των οντοτήτων που πιθανόν κατατάσσονται στις κλάσεις Κρίσιμο ή Πολύ Κρίσιμο, βασιζόμενα αποκλειστικά σε προσιτά και εύκολα διαθέσιμα δεδομένα, επιτρέποντας έτσι τη στοχευμένη και πιο αποδοτική κατανομή των πόρων για επιθεωρήσεις.

Αυτή η προσέγγιση είναι παραπλήσια με τη χρήση αναπληρωματικών μεταβλητών (proxy variables) σε διάφορους τομείς της επιστήμης. Αντί να ενσωματωθούν όλοι οι θεωρητικά συναφείς δείκτες, οι οποίοι συχνά είναι ακριβοί ή δύσκολα μετρήσιμοι, επιλέγεται ένα μικρότερο σύνολο ευκολότερα παρατηρήσιμων μεταβλητών που παρουσιάζουν συσχέτιση με το υπό εξέταση φαινόμενο, χωρίς όμως να το εξηγούν πλήρως ή ντετερμινιστικά. Το ενδιαφέρον της έρευνας μετακινείται από την «ακριβή αναπαραγωγή του στόχου» στη «ρεαλιστική πρόβλεψη βασισμένη σε ελλιπή δεδομένα», κάτι που αποτελεί ένα ρεαλιστικό και συχνά απαραίτητο τρόπο αντιμετώπισης στις επιχειρησιακές εφαρμογές της τεχνητής νοημοσύνης.

3.2.3. Η Επιλογή των Συγκεκριμένων (7) Δεικτών & η Επίδραση στη Μεθοδολογική Αξιοπιστία

Κατά την ανάλυση των δεικτών που περιλαμβάνονται στο AVAILABLE_SUBSET σε σύγκριση με εκείνους που αποκλείονται, προκύπτει ένα σαφή κριτήριο επιλογής που βασίζεται στο κόστος και στον τρόπο συλλογής. Αυτό αποδεικνύει ότι η επιλογή δεν είναι αυθαίρετη, αλλά αντανακλά με ακρίβεια τους πραγματικούς περιορισμούς δεδομένων που υπάρχουν σε ένα σύστημα έγκαιρης αξιολόγησης κινδύνου.

Η επιλογή ενός υποσυνόλου δεδομένων μετατρέπει το πρόβλημα σε ένα αυθεντικό ζήτημα εποπτευόμενης μάθησης, το οποίο χαρακτηρίζεται από ουσιώδη αβεβαιότητα. Σε αυτό το πλαίσιο, η σύγκριση μεταξύ Logistic Regression, Random Forest και XGBoost αποκτά νόημα. Εάν όλοι οι 22 δείκτες περιλαμβάνονται στο σύνολο δεδομένων, τα μοντέλα θα



συγκλίνουν σχεδόν σε τέλεια απόδοση. Κατά συνέπεια, οποιαδήποτε προσπάθεια κριτικής αξιολόγησής τους υπό αυτές τις συνθήκες θα ήταν επιστημονικά ασήμαντη.

Πίνακας 3.2: Επιλογή δεικτών βάσει κόστους / τρόπου συλλογής.

Περιλαμβάνονται (AVAILABLE_SUBSET)	Γιατί είναι εύκολα διαθέσιμα	Αποκλείονται (Μόνο στο CRI_LEVELS)	Γιατί απαιτούν επιθεώρηση / βαθύτερη έρευνα
A2_plan_appr_pct	Διοικητικό αρχείο (έγκριση σχεδίου)	A3_appr_time A5_contact_point A6_tisn_net	Θεσμικά/διαδικαστικά στοιχεία σε επίπεδο Πολιτείας, όχι οντότητας
B1_iso_pct B2_training_pct	Πιστοποιήσεις/μητρώα εκπαίδευσης, εύκολα δηλούμενα	B4_inspection_pct B6_digital_twin	Απαιτούν επιτόπια επαλήθευση ή τεχνική αξιολόγηση υποδομής
B3_exercises_num B5_incident_rep_pct	Αυτοαναφερόμενα διοικητικά στοιχεία	C2_major_incidents C3_financial_loss C5_insurance_claims	Ευαίσθητα οικονομικά/ νομικά δεδομένα, δύσκολα προσβάσιμα ή απόρρητα
C1_mttr C4_user_satisfaction	Λειτουργικά στοιχεία/έρευνες ικανοποίησης	Όλη η Διάσταση Δ' (SENDAI)	Απαιτούν εξωτερική αξιολόγηση καταστροφών, δεδομένα πληθυσμού

Παρόλα αυτά προκύπτει μια σημαντική παρατήρηση. Παρότι η μη γραμμική ποινή αλληλεπίδρασης (interaction_penalty) μεταξύ των Διαστάσεων Α' και Β' υπολογίζεται βάσει των `dim_scores["dim_A_governance"]` και `dim_scores["dim_B_efficiency"]`, οι τιμές αυτές εμπεριέχουν δείκτες που δεν περιλαμβάνονται στο AVAILABLE_SUBSET (όπως A1_char_pct, A3_appr_time, B4_inspection_pct και B6_digital_twin). Αυτό σημαίνει ότι μέρη της πληροφορίας που συμβάλλουν στον προσδιορισμό του CRI_score παραμένουν πλήρως αδιάθετα στο μοντέλο. Παρά το γεγονός ότι αυτή η παράμετρος είναι επιθυμητή διότι αποτρέπει φαινόμενα κυκλικότητας, οδηγεί επίσης στο συμπέρασμα ότι υπάρχει ένα θεωρητικό ανώτατο όριο ακρίβειας απόδοσης (irreducible error). Αυτό το όριο δεν δύναται να υπερβεί οποιοδήποτε μοντέλο, ακόμη και το πλέον εξελιγμένο XGBoost, ανεξαρτήτως των βελτιστοποιήσεων των παραμέτρων του. Ο λόγος είναι ότι ένα μέρος της μεταβλητότητας του στόχου εξαρτάται από δεδομένα τα οποία παραμένουν εξωτερικά στο παρατηρήσιμο σύνολο χαρακτηριστικών X .

3.2.4. Σύνοψη για την Επιλογή των Δεικτών της Έρευνας

Συνοψίζοντας τα ανωτέρω, η επιλογή του υποσυνόλου AVAILABLE_SUBSET έναντι του πλήρους CRI_LEVELS εξυπηρετεί πέντε συνδεδεμένους μεθοδολογικούς στόχους.

Πρώτον, αποφεύγει το πρόβλημα της διαρροής δεδομένων (data leakage), το οποίο θα προέκυπτε από την κυκλικότητα μεταξύ στόχου και χαρακτηριστικών. Δεδομένου ότι η μεταβλητή-στόχος είναι μια ντετερμινιστική συνάρτηση των 22 δεικτών, η χρήση όλων αυτών ως predictors θα καθιστούσε το πρόβλημα τετριμμένο, αφού το μοντέλο απλώς θα



αντέστρεφε έναν ήδη γνωστό μαθηματικό τύπο, χωρίς να μάθει μια πραγματική προγνωστική σχέση.

Δεύτερον, η επιλογή αυτή αντικατοπτρίζει μια ρεαλιστική επιχειρησιακή υπόθεση, καθώς προσομοιώνει μια κατάσταση όπου η αρμόδια αρχή δεν έχει πλήρη πρόσβαση σε δεδομένα επιθεώρησης για κάθε κρίσιμη οντότητα, αλλά μόνο σε δεδομένα που είναι εύκολα διαθέσιμα χωρίς επιτόπια επιθεώρηση.

Τρίτον, αυτή η προσέγγιση προσθέτει αξία στο πρόβλημα πρόβλεψης, καθώς διατηρεί τη σημασία στη σύγκριση των τριών μοντέλων (Logistic Regression, Random Forest, XGBoost). Μια σύγκριση που θα ήταν επιστημονικά ανούσια εάν όλα τα μοντέλα προσέγγιζαν σχεδόν τέλεια απόδοση λόγω πλήρους πρόσβασης στα στοιχεία του στόχου.

Τέταρτον, η προσέγγιση ακολουθεί τη λογική των υποκατάστατων μεταβλητών (proxy variables), όπως εφαρμόζεται και σε άλλα επιστημονικά πεδία (π.χ. οικονομετρία, επιδημιολογία), όπου αντί για ακριβείς ή επιτόπιες μετρήσεις χρησιμοποιούνται τετριμμένα, εύκολα προσβάσιμα υποκατάστατα που σχετίζονται με το υποκείμενο φαινόμενο χωρίς να το ορίζουν πλήρως.

3.3. Ο Σύνθετος Δείκτης Ανθεκτικότητας (Composite Resilience Index - CRI)

Ο CRI, σύμφωνα με τις μελέτες των Marzi et al. (2019) και Camacho et al. (2025), αποτελεί ένα ποσοτικό εργαλείο που ενσωματώνει πολλαπλούς δείκτες για να αξιολογήσει την ικανότητα κοινοτήτων, συστημάτων ή οργανισμών να αντιμετωπίζουν και να ανακάμπτουν από δυσμενή γεγονότα. Ο Sono et al. (2021) σημειώνει ότι ο CRI εφαρμόζεται σε διάφορους τομείς όπως η μείωση του κινδύνου καταστροφών, η κλιματική αλλαγή, η δημόσια υγεία, η κυβερνοασφάλεια και οι υποδομές, δίνοντας έμφαση στη συγκεκριμένη προσέγγιση του δείκτη για κάθε πεδίο και στους συγκεκριμένους παράγοντες πίεσης και τις χωρικές κλίμακες του. Σύμφωνα με τον Amer et al. (2022), ο υπολογισμός του CRI στηρίζεται σε μια μεθοδική προσέγγιση κατασκευής σύνθετων δεικτών η οποία περιλαμβάνει τρεις (3) φάσεις: α) την αναγνώριση δεικτών, υποδεικτών και μεταβλητών, β) τον μετασχηματισμό και την κανονικοποίηση δεδομένων, και γ) τη συγχώνευση σε ένα ενιαίο μέτρο. Η διαδικασία κατασκευής του CRI ακολουθεί είτε μια ιεραρχική είτε μια επαγωγική προσέγγιση, ξεκινώντας από μια θεωρητική βάση που καθορίζει τις διαστάσεις της ανθεκτικότητας, όπως αναφέρει ο Marzi et al. (2019).

3.3.1. Μεθοδολογία & Μαθηματική Θεμελίωση Υπολογισμού του CRI

Η διαδικασία υπολογισμού του CRI στον κώδικα³⁰ περιλαμβάνει τρία (3) διαδοχικά στάδια. Ξεκινά με τη δημιουργία επιμέρους δεικτών σε επίπεδο οντότητας και ολοκληρώνεται με την τελική ταξινόμηση σε τέσσερις κλάσεις ανθεκτικότητας.

³⁰ Συνάρτηση `generate_synthetic_dataset_cri()`. Ο κώδικας παρουσιάζεται στο ΠΑΡΑΡΤΗΜΑ Ι.

Στάδιο 1ο: Παραγωγή Επιμέρους Δεικτών (22 KPIs / KRIs³¹)

Στο πρώτο στάδιο της διαδικασίας, παράγεται μία τιμή για κάθε έναν από τους 22 επιμέρους δείκτες (KPIs/KRIs) για τις 5.000 συνθετικές οντότητες³² που εξετάζονται στο Παράρτημα ΣΤ' της Εθνικής Στρατηγικής. Η παραγωγή αυτών των τιμών δεν γίνεται μέσω απλής τυχαιοποίησης, αλλά από τον συνδυασμό τριών βασικών παραμέτρων. Αρχικά, υπάρχει μία βασική τιμή που προκύπτει από μια κατανομή Beta, η οποία προσομοιώνει μια ρεαλιστική και μερικώς ασύμμετρη κατανομή εντός του εύρους 0 έως 100, με τάση οι περισσότερες οντότητες να συγκεντρώνονται σε μέτρια επίπεδα αντί να κατανέμονται ομοιόμορφα. Επιπλέον, προστίθεται μια ποσότητα σταθερής μετατόπισης, η οποία εξαρτάται από τον τομέα δραστηριότητας της κάθε οντότητας. Έτσι, κλάδοι όπως ο τραπεζικός εμφανίζουν υψηλότερες τιμές λόγω μεγαλύτερης θεσμικής ωριμότητας, ενώ άλλοι όπως τα λύματα εμφανίζουν χαμηλότερες τιμές. Τέλος, προστίθεται ένας τυχαίος θόρυβος μέτρησης που αναπαριστά τη φυσική διακύμανση και την αβεβαιότητα στις τιμές. Το τελικό άθροισμα αυτών των παραγόντων περιορίζεται τεχνητά ώστε να διατηρείται εντός των λογικών ορίων 0 έως 100.

Για κάθε δείκτη $s \in \text{ALL_CRI_INDICATORS}$ (22 δείκτες συνολικά, κατανεμημένοι στις 4 Διαστάσεις A-B-C-D) και για κάθε $i = 1, 2, \dots, n$ με $n = 5.000$:

Κατανομή Βήτα (Beta Distribution) για τους Επιμέρους Δείκτες

$$b_{i,s} \sim \text{Beta}(\alpha = 2.2, \beta = 2.0) \times 100 \quad (1)$$

Επιλέχθηκε η κατανομή Beta έναντι της κανονικής κατανομής λόγω της ικανότητας της να παράγει ρεαλιστική ασυμμετρία εντός του διαστήματος [0-100]. Η συγκεκριμένη συγκέντρωση των τιμών στα μέτρια επίπεδα επιτυγχάνεται μέσω των παραμέτρων σχήματος $\alpha = 2.2$ και $\beta = 2.0$, οι οποίες παράγουν μια ελαφρώς δεξιά-ασύμμετρη, μονοκόρυφη κατανομή³³ με το μέγιστο σημείο της να κυμαίνεται γύρω στο 52-55%. Αυτό αντικατοπτρίζει τη ρεαλιστική προβολή ότι οι περισσότερες οντότητες βρίσκονται σε μέτριο επίπεδο ωριμότητας ως προς την ανθεκτικότητα, με λιγότερες στους ακραίους πόλους (πολύ αδύναμες ή πολύ ισχυρές). Αντί αυτού, μια ομοιόμορφη κατανομή σε όλο το εύρος [0,100] θα ήταν στατιστικά μη ρεαλιστική.

³¹ Οι Βασικοί Δείκτες Απόδοσης (Key Performance Indicators - KPIs) αξιολογούν την πρόοδο και την αποτελεσματικότητα μιας επιχείρησης στην επίτευξη των στόχων της, ενώ οι Βασικοί Δείκτες Κινδύνου (Key Risk Indicators - KRIs) λειτουργούν ως προειδοποιητικά σήματα για πιθανές απειλές και κινδύνους που ενδέχεται να έχουν αρνητική επίδραση στη λειτουργία της.

³² Προκειμένου να εξαχθούν ευρύτερα συμπεράσματα σε αυτή την έρευνα, η διαδικασία επαναληπτικής ανάλυσης εφαρμόστηκε για δείγματα μεγέθους $n = 10.000$, $n = 20.000$ και $n = 40.000$, πέραν των αρχικών συνθηκών με $n = 5.000$.

³³ Ο όρος «ελαφρώς δεξιά κατανομή» (γνωστή ως θετικά ασύμμετρη κατανομή) υποδηλώνει ότι το διάγραμμα της κατανομής έχει μια εκτεταμένη «ουρά» προς τα δεξιά, δηλαδή προς τις υψηλότερες τιμές. Αυτό υπονοεί πως η πλειονότητα των δεδομένων βρίσκεται στην αριστερή πλευρά (δηλαδή στις χαμηλότερες έως μέσες τιμές), ενώ οι πολύ υψηλές τιμές εμφανίζονται πιο σπάνια. Στο διάστημα [0, 100], η κατανομή Beta με παραμέτρους $\alpha = 2.2$ και $\beta = 2.0$ παρουσιάζει την ακόλουθη ασυμμετρία: $\alpha > \beta$: Η κατανομή είναι λοξή προς τα αριστερά (αρνητικά ασύμμετρη), με την κορυφή να μετατοπίζεται προς το 100. Η «κορυφή» (Mode) της κατανομής, ή το πιο συχνό αποτέλεσμα, εντοπίζεται ελαφρώς αριστερά του κέντρου (περίπου 54.5), ενώ «ουρά» (Tail) εκτείνεται προς τα δεξιά (προς το 0).

Ντετερμινιστική Τομεακή Μετατόπιση (Sector Baseline Offset)

$$\delta_i = \text{sector_baseline}(\text{sector}_i) \in \{-8, -7, -6, -5, -3, 0, 3, 5, 8, 10\} \quad (2)$$

όπου η συνάρτηση `sector_baseline` αποδίδει, σε καθέναν από τους 12 τομείς, μια σταθερή μετατόπιση δ , η οποία ανήκει στο σύνολο $\{-8, -7, -6, -5, -3, 0, 3, 5, 8, 10\}$. Αυτές οι μετατοπίσεις αντανakλούν συστηματικές διαφορές στην θεσμική ή τεχνολογική ωριμότητα που εντοπίζονται σε κάθε τομέα. Για παράδειγμα, ο Τραπεζικός κλάδος έχει μετατόπιση +10, ενώ ο τομέας Λύματα έχει μετατόπιση - 8.

Η εν λόγω παράμετρος δεν αποτελεί μια στοχαστική συνιστώσα, αλλά μια από πριν καθορισμένη ντετερμινιστική μεταβλητή ανά τομέα. Αυτή αντιπροσωπεύει μια καλά δομημένη υπόθεση βασισμένη στη γνώση ότι κάποιοι τομείς, όπως ο τραπεζικός (ο οποίος διέπεται από ισχυρό ρυθμιστικό καθεστώς, όπως εκείνο της Βασιλείας III και του DORA), διακρίνονται για την συστηματικά υψηλότερη ωριμότητα τους στην ανθεκτικότητα σε σύγκριση με άλλους, όπως για παράδειγμα, ο τομέας των λυμάτων, ο οποίος ιστορικά έχει επενδύσει λιγότερο στην ψηφιακή ή θεσμική ετοιμότητα. Η μεθοδολογική αυτή επιλογή αντανakλά την εισαγωγή εξειδικευμένης γνώσης πεδίου στη διαδικασία δημιουργίας συνθετικών δεδομένων, μια πρακτική που συνιστάται τακτικά στη βιβλιογραφία. Συνεπώς, η βαθμονόμηση των συνθετικών γεννητριών μέσω της αξιοποίησης ειδικής γνώσης καθιστά τα δημιουργούμενα δεδομένα ρεαλιστικά και δομημένα, αντί για απλώς τυχαία στατιστικά στοιχεία.

Στοχαστικός Θόρυβος Μέτρησης (Gaussian Noise)

$$\varepsilon_{i,s} \sim \mathcal{N}(0, 4^2) \quad (3)$$

Η μέτρηση του στοχαστικού θορύβου συμβολίζεται από την τυχαία μεταβλητή $\varepsilon_{i,s}$, η οποία ακολουθεί την κανονική κατανομή με μηδενική μέση τιμή και διακύμανση ίση με 16. Αυτή η μαθηματική περιγραφή σημαίνει ότι οι αποκλίσεις του θορύβου από τη μέση τιμή, που προκύπτουν κατά τη διάρκεια της μέτρησης, είναι τυχαίες και συμμετρικές γύρω από το μηδέν, ενώ η ένταση του θορύβου καθορίζεται από την τιμή της διακύμανσης.

Τελική Τιμή Δείκτη με Περικοπή (Clipping)

Η τελική τιμή δείκτη με περικοπή αναφέρεται στη διαδικασία κατά την οποία οι τιμές ενός δείκτη περιορίζονται σε ένα προκαθορισμένο αποδεκτό εύρος $[\min, \max]$. Αυτή η προσέγγιση αποτρέπει την εμφάνιση ακραίων τιμών ή την υπέρβαση των καθορισμένων ορίων.

$$x_{i,s} = \text{clip}(b_{i,s} + \delta_i + \varepsilon_{i,s}, 0, 100) \quad (4)$$

όπου $\text{clip}(v, a, b) = \max(a, \min(v, b)) \rightarrow \text{clip}(v, 0, 100) = \max(0, \min(v, 100))$ διασφαλίζει ότι οποιαδήποτε τιμή v περιορίζεται αυστηρά εντός του κλειστού διαστήματος $[0, 100]$.

- Αν $v < 0$: Η $\min(v, 100)$ επιστρέφει v και η $\max(0, v)$ επιστρέφει 0.
- Αν $v > 100$: Η $\min(v, 100)$ επιστρέφει 100 και η $\max(0, 100)$ επιστρέφει 100.
- Αν $0 \leq v \leq 100$: Η $\min(v, 100)$ επιστρέφει v και η $\max(0, v)$ επιστρέφει την ίδια τιμή v .

Στάδιο 2ο: Βαθμολογία Διάστασης (Dimension Score)

Στο δεύτερο στάδιο, οι 22 επιμέρους δείκτες κατηγοριοποιούνται σε τέσσερις θεματικές διαστάσεις στο πλαίσιο: Α) Διακυβέρνηση, Β) Αποδοτικότητα, Γ) Αποτελέσματα & Επιπτώσεις και Δ) Ευθυγράμμιση με το πλαίσιο Sendai. Για κάθε διάσταση, υπολογίζεται μια συνολική βαθμολογία, η οποία προκύπτει ως ο απλός αριθμητικός μέσος όρος όλων των δεικτών που την συνθέτουν. Σημαντικό είναι ότι δεν εφαρμόζεται εσωτερική στάθμιση μεταξύ των δεικτών, γεγονός που συνεπάγεται πως όλοι οι δείκτες μιας διάστασης συμβάλλουν ισότιμα στη συνολική της αξιολόγηση.

Καθεμιά από τις τέσσερις (4) Διαστάσεις $d \in \{A, B, C, D\}$ εμπεριέχει και ένα υποσύνολο δεικτών $S_d \subset ALL_CRI_INDICATORS$. Έτσι το $S_A = \{A_1, A_2, \dots, A_6\}$ έχει 6 δείκτες, ομοίως το S_B έχει 6 δείκτες, ενώ τα S_C και S_D έχουν από 5 δείκτες. Οι βαθμολογίες των Διαστάσεων καθορίζονται ως μη σταθμισμένοι (ισοβαρής) μέσοι όροι των δεικτών που τις συστήνουν.

$$Dim_{i,d} = \frac{1}{|S_d|} \cdot \sum_{s \in S_d} x_{i,s} \quad (5)$$

Αναλυτικά, με βάση τον αριθμό δεικτών ανά διάσταση:

$$Dim_{i,A} = \frac{1}{6} \cdot \sum_{s=A1}^{A6} x_{i,s}, Dim_{i,B} = \frac{1}{6} \cdot \sum_{s=B1}^{B6} x_{i,s}, Dim_{i,C} = \frac{1}{5} \cdot \sum_{s=C1}^{C5} x_{i,s}, Dim_{i,D} = \frac{1}{5} \cdot \sum_{s=D1}^{D5} x_{i,s}$$

Στάδιο 2α: Γραμμικό Μέρος του CRI (Σταθμισμένος Μέσος Όρος Διαστάσεων)

Στα επιμέρους στάδια του δεύτερου σταδίου της διαδικασίας αξιολόγησης, οι τέσσερις (4) επιμέρους βαθμολογίες των Διαστάσεων ενοποιούνται σε ένα συνολικό σκορ μέσω μιας μεθόδου σταθμισμένου αθροίσματος. Σε αυτή τη μέθοδο, οι Διαστάσεις συνεισφέρουν στο τελικό αποτέλεσμα βάσει της θεσμικής τους βαρύτητας: η Αποδοτικότητα διατηρεί το μεγαλύτερο βάρος με 30%, ενώ η Ευθυγράμμιση με το Πλαίσιο του Sendai κατέχει το μικρότερο βάρος, μόλις 20%. Εντωμεταξύ, η Διακυβέρνηση και τα Αποτελέσματα έχουν ίσο βάρος στο 25% το καθένα. Για οντότητες που λαμβάνουν χαμηλές βαθμολογίες ταυτόχρονα στη Διακυβέρνηση και την Αποδοτικότητα, δηλαδή κάτω από το όριο του 40, εφαρμόζεται μια ειδική ποινή οκτώ μονάδων. Αυτή η ποινή υποδηλώνει ότι η ταυτόχρονη παρουσία πολλαπλών αδυναμιών μειώνει δυσανάλογα την ανθεκτικότητα της οντότητας πέρα από την απλή άθροιση των μεμονωμένων αδυναμιών. Επιπλέον, ένας στοχαστικός όρος θορύβου προστίθεται στο συνολικό σκορ για να προσομοιωθεί η αβεβαιότητα μέτρησης που ενδέχεται

να υφίσταται σε επίπεδο συνολικού δείκτη. Το τελικό σκορ περιορίζεται μεταξύ του εύρους 0 έως 100, διατηρώντας την ερμηνευτική του σαφήνεια ως ποσοστιαία κλίμακα.

Οι τέσσερις (4) διαστάσεις συνδυάζονται μέσω ενός σταθμισμένου γραμμικού συνδυασμού, όπου τα βάρη w_d καθορίζονται στο CRI_LEVELS:

$$w_A = 0.25, w_B = 0.30, w_C = 0.25, w_D = 0.20, \sum_d w_d = 1.0$$

$$CRI_i^{linear} = \sum_{d \in \{A,B,C,D\}} w_d \cdot Dim_{i,d} = 0.25 \cdot Dim_{i,A} + 0.30 \cdot Dim_{i,B} + 0.25 \cdot Dim_{i,C} + 0.20 \cdot Dim_{i,D} \quad (6)$$

Στάδιο 2β: Μη Γραμμική Ποινή Συνδυαστικής Αλληλεπίδρασης (Interaction Penalty)

Μια μη γραμμική ποινή εισάγεται για να αναδείξει τη δυσανάλογη επιδείνωση που προκύπτει όταν υπάρχουν ταυτόχρονα ελλείψεις σε δύο σημαντικές διαστάσεις:

$$Penalty_i = \begin{cases} -8.0 & \text{εάν } Dim_{i,A} < 40 \text{ και } Dim_{i,B} < 40 \\ 0.0 & \text{διαφορατικά} \end{cases} \quad (7)$$

Μαθηματικά αποτυπώνεται με την εξίσωση:

$$Penalty_i = -8.0 \cdot 1[(Dim_{i,A} < 40) \wedge (Dim_{i,B} < 40)] \quad (8)$$

Ο όρος αυτός προσθέτει ένα φαινόμενο αλληλεπίδρασης κατωφλίου μεταξύ Διακυβέρνησης και Αποδοτικότητας, το οποίο δεν μπορεί να αναπαρασταθεί από γραμμικά μοντέλα χωρίς την προσθήκη ενός ρητού όρου αλληλεπίδρασης.

Αυτή η συνιστώσα δεν βασίζεται σε στατιστική κατανομή, αλλά είναι το αποτέλεσμα ενός συγκεκριμένου αλγοριθμικού κανόνα. Αποτελεί ένα είδος υβριδικής στατιστικής-αλγοριθμικής προσομοίωσης, στο οποίο ενώ το κύριο μέρος της παραγωγής δεδομένων είναι τυχαίο και βασίζεται σε πιθανότητες, περιλαμβάνει και έναν ντετερμινιστικό όρο που βασίζεται σε κανόνα. Αυτός ο όρος αναπαριστά μια αναγνωρισμένη θεωρητική σχέση, όπως η μη γραμμική ενίσχυση των επιπτώσεων λόγω ταυτόχρονων αδυναμιών, η οποία δεν θα μπορούσε να προκύψει από απλή γραμμική σύνθεση τυχαίων μεταβλητών. Η προσέγγιση αυτή είναι ιδιαίτερα σημαντική μεθοδολογικά, καθώς επιτρέπει στο συνθετικό σύνολο δεδομένων να ενσωματώσει εκ των προτέρων γνωστή πολυπλοκότητα. Αυτή η πολυπλοκότητα είναι χρήσιμη για την αξιολόγηση της ικανότητας των μοντέλων τεχνητής νοημοσύνης ειδικά των μη γραμμικών, όπως το Random Forest και το XGBoost να την προσδιορίσουν εκ νέου από τα δεδομένα.

Στάδιο 2γ: Τελικός Στοχαστικός Θόρυβος

$$\eta_i \sim \mathcal{N}(0, 3.5^2) \quad (9)$$

Αυτό αναφέρεται στον επιπρόσθετο θόρυβο που προστίθεται στη συνολική βαθμολογία, ο οποίος διαφέρει από τον αρχικό θόρυβο ($\varepsilon_{i,s}$) που είχε ήδη εφαρμοστεί σε κάθε επιμέρους δείκτη κατά το πρώτο βήμα.

Στάδιο 2δ: Τελικός Τύπος CRI Score

$$CRI_i = clip(CRI_i^{linear} + Penalty_i + \eta_i, 0, 100) \quad (10)$$

Και αναλυτικά σε πλήρη ανάπτυξη ο τύπος είναι:

$$CRI_i = clip\left(\sum_d w_d \cdot \frac{1}{|S_d|} \sum_{s \in S_d} clip(b_{i,s} + \delta_i + \varepsilon_{i,s}, 0, 100) - 8.0 \cdot 1[(Dim_{i,A} < 40) \wedge (Dim_{i,B} < 40)] + \eta_i, 0, 100\right) \quad (11)$$

Στάδιο 3ο: Μετατροπή του Συνεχούς CRI σε Διακριτές Κλάσεις (Quartile Binning)

Στο τρίτο και τελευταίο στάδιο, το συνεχές σκορ CRI μετασχηματίζεται σε τέσσερις ξεχωριστές, ιεραρχικά δομημένες κλάσεις ανθεκτικότητας μέσω κατανομής σε τεταρτημόρια. Οι οντότητες κατανέμονται σε τέσσερις ίσες ομάδες σύμφωνα με την κατανομή του σκορ τους μέσα στο δείγμα. Το κατώτερο τεταρτημόριο χαρακτηρίζεται ως Μη Κρίσιμο, ενώ το ανώτερο ως Πολύ Κρίσιμο. Τα όρια αυτών των τεταρτημορίων προσδιορίζονται δυναμικά από την κατανομή των δεδομένων και δεν στηρίζονται σε σταθερά προαποφασισμένα όρια, με αποτέλεσμα η τελική κατανομή των τεσσάρων κατηγοριών να είναι σχεδόν ίση. Αυτό επιβεβαιώνεται με έναν έλεγχο εγκυρότητας, που εξασφαλίζει την παρουσία και των τεσσάρων αναμενόμενων κατηγοριών, χωρίς καμία να έχει συμπτυχθεί λόγω επικαλυπτόμενων ορίων.

$$Y_i = Class_k \rightarrow Q_{k-1} \leq CRI_i \leq Q_k, \quad k = 1, 2, 3, 4$$

Στο πλαίσιο αυτό, $Q_0 = 0$ και $Q_4 = 100$. Αντίστοιχα, οι τιμές Q_1 , Q_2 και Q_3 αντιπροσωπεύουν το 25ο, το 50ο και το 75ο εκατοστημόριο της εμπειρικής κατανομής του δείκτη CRI_i σε αυτό το δείγμα. Αυτά τα ποσοστιαία σημεία προσδιορίζονται δυναμικά μέσω της ανάλυσης των δεδομένων, αντί να καθορίζονται ως προκαθορισμένα σταθερά όρια (π.χ. Πολύ Κρίσιμο $CRI < 25$, Κρίσιμο $25 \leq CRI < 50$, Χαμηλής Ανθεκτικότητας $50 \leq CRI < 75$ και Μη Κρίσιμο $CRI \geq 75$). Με τη χρήση της μεθόδου `pd.qcut` (quartile cut) υπολογίζεται το 25ο, 50ο και 75ο εκατοστημόριο της κατανομής των 5.000 τιμών του CRI_score που προέκυψαν από την ανάλυση, προσδιορίζοντας έτσι τα όρια σε εκείνα τα σημεία, ανεξαρτήτως των ακριβών αριθμητικών τιμών που αυτά αντιπροσωπεύουν. Έτσι, αντί να προκαθορίσουμε ποιες τιμές αντιστοιχούν σε τι, επιτρέπουμε στα δεδομένα να ορίσουν μόνα τους τα όρια, με κύριο στόχο τη δημιουργία ομάδων ίδιου μεγέθους. Ο κανόνας είναι ότι κάθε τιμή-όριο ανήκει μόνο στην επόμενη κλάση, όχι στην προηγούμενη.

$[Q_0, Q_1) \rightarrow$ όλα τα CRI από Q_0 έως ακριβώς κάτω από Q_1 .

$[Q_1, Q_2) \rightarrow$ το Q_1 «μεταπηδά» σε αυτή την κλάση και όχι στην προηγούμενη.

$[Q_2, Q_3) \rightarrow$ το Q_2 «μεταπηδά» σε αυτή την κλάση και όχι στην προηγούμενη.

$[Q_3, Q_4] \rightarrow$ σε αυτή την περίπτωση και τα δύο άκρα είναι κλειστά, γιατί είναι η τελευταία κλάση, συνεπώς πρέπει να περιλαμβάνει και το ίδιο το μέγιστο.

Ας υποθέσουμε ότι μετά την εκτέλεση του κώδικα, η κατανομή του CRI_score σε $n = 5.000$ οντότητες παράγει τα ακόλουθα εκατοστημόρια: $Q_1 = 41.3$, $Q_2 = 54.7$ και $Q_3 = 67.9$. Σε αυτήν την περίπτωση, τα όρια των κλάσεων θα είναι ακριβώς αυτά τα νούμερα (41.3, 54.7, 67.9) αντί για στρογγυλεμένα, προκαθορισμένα ποσοστά όπως 25/50/75. Ωστόσο, εάν αλλάξει ο σπόρος τυχαιότητας (random_state) ή οι παράμετροι παραγωγής θορύβου, η νέα κατανομή ενδέχεται να οδηγήσει σε διαφορετικά Q_1, Q_2 και Q_3 , καθώς τα όρια προσαρμόζονται στη νέα εμπειρική κατανομή με στόχο να προκύπτουν τέσσερις ισομεγέθεις ομάδες (~ 1.250 οντότητες η καθεμία).

Δεδομένου ότι τα Q_k ορίζονται ως εκατοστημόρια, και όχι ως σταθερά, προκαθορισμένα όρια όπως π.χ. $CRI < 40 =$ Πολύ Κρίσιμο, η κατανομή των τεσσάρων κλάσεων είναι εξ ορισμού περίπου ισοκατανεμημένη, με κάθε κλάση να αντιπροσωπεύει περίπου το 25% του πληθυσμού. Αυτό εξηγεί την ισορροπημένη φύση του συνόλου δεδομένων, όπως έχει συζητηθεί σε προηγούμενη υποενότητα. Εάν το σύνολο δεδομένων επεκταθεί με την προσθήκη για παράδειγμα 5.000, 15.000 ή 35.000 επιπλέον οντοτήτων, με πολύ υψηλότερη συνολική ανθεκτικότητα, οι ίδιες τιμές CRI_score πιθανόν να ταξινομηθούν διαφορετικά, καθώς αλλαγές στο σημείο αναφοράς της κατανομής του νέου, μεγαλύτερου δείγματος επηρεάζουν την κλάση. Ο κώδικας διασφαλίζει ξεκάθαρα τη δημιουργία ακριβώς τεσσάρων (4) διακριτών κλάσεων. Αυτό είναι σημαντικό, καθώς η χρήση του `duplicates='drop'` στο `pd.qcut` θα μπορούσε σιωπηλά να οδηγήσει σε λιγότερες κλάσεις, εάν τα όρια των τεταρτημορίων συνέπιπταν λόγω συγκέντρωσης τιμών σε συγκεκριμένα σημεία.

Συγκεντρωτική Ροή Υπολογισμού (Μορφή Pipeline)

$$\begin{aligned} & \underbrace{22 \text{ δείκτες}}_{\mathbf{x}_{i,s}} \xrightarrow{\text{μέσος όρος ανά Διάσταση}} \underbrace{\text{Dim}_{i,d}}_{d = A, B, C, D} \xrightarrow{\text{σταθμισμένο άθροισμα } w_d} CRI_i^{\text{linear}} \longrightarrow \\ & \xrightarrow{+ \text{Penalty}_i + \eta_i, \text{ clip}} CRI_i \xrightarrow{\text{pd.qcut}(q=4)} Y_i \in \{1, 2, 3, 4\} \end{aligned}$$

3.3.2. Πλεονεκτήματα της Μεθοδολογίας για Ακαδημαϊκή Έρευνα

Η ανωτέρω μεθοδολογία για την παραγωγή Συνθετικού Συνόλου Δεδομένων και του τρόπου υπολογισμού του CRI παρουσιάζει αρκετά πλεονεκτήματα.



Πίνακας 3.3: Πλεονεκτήματα της μεθοδολογίας.

Πλεονεκτήματα	Εξήγηση για το Πλαίσιο Ανθεκτικότητας Κρίσιμων Οντοτήτων
Πλήρης αποφυγή ζητημάτων απορρήτου/διαβάθμισης	Καμία Κρίσιμη Οντότητα δεν εκτίθεται, καθώς δεν χρησιμοποιούνται πραγματικά στοιχεία που συνδέονται με αυτές.
Επιβεβαιωμένη πραγματικότητα εδάφους (ground truth)	Επειδή, η συγκεκριμένη μεθοδολογία, πρόκειται για μια υποκειμενική δομή υπολογισμού του CRI_score, συμπεριλαμβανομένων των βαρών, της ποινής και του θορύβου, υπάρχει η δυνατότητα αξιολόγησης με αντικειμενικότητα εάν τα μοντέλα Τεχνητής Νοημοσύνης καταφέρνουν να προσδιορίσουν ορθά αυτή την υποκείμενη δομή. Αυτή η διαδικασία αξιολόγησης θα ήταν ανέφικτη με πραγματικά δεδομένα, καθώς η πραγματική GDP ³⁴ (Data Generating Process) παραμένει άγνωστη.
Πλήρης αναπαραγωγικότητα (reproducibility)	Ερευνητικά, υπάρχει η δυνατότητα να τροποποιηθούν συστηματικά παράμετροι, όπως η ένταση του θορύβου ή τα βάρη των διαστάσεων, παρακολουθώντας έτσι τις αλλαγές στην επίδοση των μοντέλων. Αυτό καθίσταται ανέφικτο όταν εργάζεται κανείς με ένα στατικό, πραγματικό σύνολο δεδομένων.
Δυνατότητα ελεγχόμενων πειραμάτων ευαισθησίας (sensitivity analysis)	Ερευνητικά, υπάρχει η δυνατότητα να τροποποιεί συστηματικά διάφορες παραμέτρους, όπως η ένταση του θορύβου ή τα βάρη στις διαστάσεις, και να εξετάζει τον τρόπο με τον οποίο αυτές οι αλλαγές επηρεάζουν την απόδοση των μοντέλων. Αυτό είναι δύσκολο να επιτευχθεί όταν χρησιμοποιείται ένα στατικό πραγματικό σύνολο δεδομένων.
Δυνατότητα παραγωγής αυθαίρετα μεγάλου δείγματος	Το $n = 5.000$ μπορεί να αυξηθεί σε $n = 40.000$ χωρίς να απαιτηθούν πρόσθετο κόστος συλλογής των δεδομένων, επιτρέποντας έτσι τη μελέτη της συμπεριφοράς των μοντέλων.

3.3.3. Περιορισμοί και Απειλές Εγκυρότητας

Παρά τα πλεονεκτήματα της παρούσας μεθοδολογίας, που αναπτύχθηκαν στην προηγούμενη υποενότητα, λόγοι ακαδημαϊκής ακεραιότητας επιτάσσουν την σαφή αναγνώριση των περιορισμών αυτής της προσεγγιστικής μεθοδολογίας.

1. Εξωτερική Εγκυρότητα (External Validity)

Τα αποτελέσματα από τη σύγκριση των μοντέλων, όπως για παράδειγμα η πιθανή διαπίστωση ότι το XBoost υπερέχει της Logistic Regression κατά ένα συγκεκριμένο ποσοστό (X%), ισχύουν μόνο για τη συγκεκριμένη τεχνητά σχεδιασμένη δομή δεδομένων. Δεν μπορεί να εγγυηθεί ότι τα συμπεράσματα αυτά θα ισχύουν σε πραγματικά δεδομένα κρίσιμων οντοτήτων, όπου η πραγματική DGP μπορεί να παρουσιάζει εντελώς διαφορετικά χαρακτηριστικά, όπως διαφορετικές κατανομές, άλλες μη γραμμικές αλληλεπιδράσεις, ετεροσκεδαστικότητα και άλλα.

³⁴ Ο όρος DGP (Data Generating Process) αναφέρεται στον πραγματικό μηχανισμό που δημιουργεί τα δεδομένα που παρατηρούμε, δηλαδή στην αυθεντική μαθηματική, φυσική ή κοινωνική σχέση που συνδέει τις μεταβλητές, ανεξάρτητα από το αν είμαστε σε θέση να την αναγνωρίσουμε. Στο πλαίσιο του προβλήματός μας, η «πραγματική DGP» αντιστοιχεί στην αληθινή σχέση που συνδέει τους 22 δείκτες μιας ουσιαστικής Κρίσιμης Οντότητας με το αντικειμενικό επίπεδο ανθεκτικότητάς της. Αυτή η σχέση υπάρχει στην πραγματικότητα, καθώς η ανθεκτικότητα μιας υποδομής εξαρτάται πράγματι από παράγοντες όπως η διακυβέρνηση και η αποδοτικότητα. Ωστόσο, η ακριβής φύση αυτής της σχέσης παραμένει άγνωστη τόσο στο συντάκτη της παρούσας εργασίας, όσο και για τις αρμόδιες αρχές.

2. Κίνδυνος Κυκλικής Επιβεβαίωσης (Circular Validation)

Δεδομένου ότι η μη γραμμικότητα (interaction_penalty), έχει σχεδιαστεί εκ των προτέρων κατά την ερευνητική διαδικασία, το πιθανό εύρημα ότι «τα μη γραμμικά μοντέλα επιδεικνύουν ανώτερη απόδοση» είναι σε μεγάλο βαθμό προβλέψιμο λόγω της αρχικής τους διαμόρφωσης. Αυτό δεν συνιστά μια ανεξάρτητη ανακάλυψη για την εγγενή φύση του φαινομένου.

3. Υποκειμενικότητα της Βαθμονόμησης (Calibration)

Οι συγκεκριμένες τιμές Beta ($\alpha = 2.2$ και $\beta = 2.0$), οι μετατοπίσεις από -8 έως $+10$, το κατώφλι ποινής 40 και η ένταση θορύβου με $\sigma = 4$, αποτελούν προσωπικές επιλογές κατά την ερευνητική διαδικασία, χωρίς να έχουν ρητή υποστήριξη από τη βιβλιογραφία ή εμπειρικά δεδομένα. Όπως αναφέρθηκε σε προηγούμενη ανάλυση σχετικά με το κατώφλι 40, ο ρεαλισμός του συνόλου δεδομένων είναι εκ των πραγμάτων περιορισμένος από την υποκειμενικότητα της κατασκευής του.

4. Απουσία Πραγματικής Ετερογένειας Δομών Σφάλματος

Η υπόθεση ότι ο θόρυβος Gaussian είναι ομοιογενής σε όλους τους δείκτες ή τομείς αγνοεί την πιθανότητα ετεροσκεδαστικότητας που μπορεί να υπάρχει στα πραγματικά δεδομένα. Για παράδειγμα, μπορεί να υπάρχει μεγαλύτερη αβεβαιότητα στη μέτρηση σε τομείς που είναι μικρότεροι ή λιγότερο ψηφιοποιημένοι.

3.4. Μοντέλο Βάσης (Baseline Model) – Πολυωνυμική Λογιστική Παλινδρόμηση (Multinomial Logistic Regression)

3.4.1. Εισαγωγή στη Multinomial Logistic Regression

Η λογιστική παλινδρόμηση αποτελεί μια μέθοδο μοντέλου που εφαρμόζεται για τη μελέτη δυαδικών αποτελεσμάτων, αξιοποιώντας τη συνάρτηση logit. Η συγκεκριμένη συνάρτηση επιτρέπει τη συσχέτιση μιας γραμμικής συνάρτησης των χαρακτηριστικών με την πιθανότητα εμφάνισης ενός συμβάντος, περιορίζοντας την τιμή της πιθανότητας στο διάστημα $[0 - 1]$. Όπως επισημαίνει ο Zabor et al. (2021), η λογιστική παλινδρόμηση χρησιμεύει τόσο για την εκτίμηση πιθανοτήτων όσο και για την επίλυση προβλημάτων ταξινόμησης. Στην περίπτωση της τελευταίας, η τελική κλάση καθορίζεται με βάση την εφαρμογή ενός προκαθορισμένου κατωφλίου στην προβλεπόμενη πιθανότητα. Η λογιστική παλινδρόμηση αποτελεί διαδεδομένο μοντέλο βάσης (Baseline model) λόγω της απλότητας, της υπολογιστικής της αποδοτικότητας, της ευκολίας αναπαραγωγής και της ικανότητάς της να παρέχει αξιόπιστες και καλά βαθμονομημένες πιθανότητες σε προβλήματα δυαδικής ταξινόμησης, όπως αναφέρεται από τους Zou et al. (2019) και Ulya et al. (2025).

Η Πολυωνυμική Λογιστική Παλινδρόμηση (Multinomial Logistic Regression – MLR) επεκτείνει το πεδίο εφαρμογής της δυαδικής λογιστικής παλινδρόμησης ώστε να καλύπτει καταστάσεις με τρεις ή περισσότερες μη διατεταγμένες κλάσεις. Αυτό επιτυγχάνεται μοντελοποιώντας τις λογαριθμικές πιθανότητες κάθε κλάσης σε σύγκριση με μια επιλεγμένη κλάση αναφοράς (βασική), όπως έχει αναφερθεί από τους El-Habil (2012) και Mohamad et al. (2016). Για k κλάσεις απόκρισης, το μοντέλο δημιουργεί $k - 1$ δυαδικές λογαριθμικές

εξισώσεις, καθεμία από τις οποίες εκτιμά τα προγνωστικά στοιχεία επηρεάζουν την πιθανότητα ένταξης σε μια συγκεκριμένη κλάση σε σχέση με την κλάση αναφοράς.

Σύμφωνα με τους Agresti (2003) και Li et al. (2024), η μέθοδος της λογαριθμικής ανάλυσης κλάσης βάσης σηματοδοτεί την επιλογή μιας κλάσης ως αναφοράς, κατασκευάζοντας όλες τις λογαριθμικές σχέσεις με βάση αυτήν, διατηρώντας το άθροισμα των προβλεπόμενων πιθανοτήτων όλων των κατηγοριών στο 100%. Οποιαδήποτε κλάση μπορεί να χρησιμοποιηθεί ως βάση, καθώς οι ονομαστικές κλάσεις δεν ακολουθούν φυσική σειρά.

Ως πρότυπο για τη σύγκριση γραμμικών και μη γραμμικών μοντέλων, όπως το Random Forest και το XGBoost, επιλέχθηκε η πολυωνμική λογιστική παλινδρόμηση (MLR) με κανονικοποίηση ενσωματωμένη σε ένα pipeline προεπεξεργασίας – εκπαίδευσης. Η επιλογή αυτή δικαιολογείται από την ικανότητα αντιμετώπισης κυρτών προβλημάτων βελτιστοποίησης, τη μειωμένη υπολογιστική πολυπλοκότητα και τη διευκόλυνση στην ερμηνεία των αποτελεσμάτων, ιδιότητες οι οποίες είναι κρίσιμες για τον καθορισμό ενός στατιστικά θεμελιωμένου κατωφλίου απόδοσης. Η ανάλυση προσεγγίζεται σε δύο κύριους άξονες:

1. Πρώτον, αναλύονται τα ιδιαίτερα πλεονεκτήματα αυτής της μεθόδου στο πλαίσιο του συγκεκριμένου προβλήματος.
2. Δεύτερον, αναλύεται σε πλήρες μαθηματικό βάθος η ακριβής μεθοδολογία (Multinomial Softmax Regression, κανονικοποίηση, Pipeline με StandardScaler) όπως υλοποιείται στον κώδικα του Παραρτήματος Ι.

3.4.2. Υπολογιστική Οικονομία και Απουσία Ανάγκης Εντατικού Tuning

Η ανάλυση με Logistic Regression επιλύει ένα κυρτό πρόβλημα βελτιστοποίησης, εξασφαλίζοντας τη σύγκλιση σε ένα καθολικό βέλτιστο χωρίς την ανάγκη εξερεύνηση πολλών συνδυασμών υπερπαραμέτρων. Αντίθετα, οι μέθοδοι όπως ο Random Forest και το XGBoost απαιτούν εφαρμογή του RandomizedSearchCV, οδηγώντας σε σημαντικά αυξημένο υπολογιστικό κόστος. Αυτή η διαφορά δεν οφείλεται σε τυχαία σχεδιαστική επιλογή, αλλά αναδεικνύει τη βασική λειτουργία ενός Baseline μοντέλου, ως ένα οικονομικό και άμεσα αντιληπτό σημείο αναφοράς.

3.4.3. Επιλογή Περιορισμένου Αριθμού Παραμέτρων σε Σχέση με το Σύνολο Δεδομένων

Ο πίνακας χαρακτηριστικών περιλαμβάνει $p = 19$ μεταβλητές, από τις οποίες οι 7 είναι KPIs του AVAILABLE_SUBSET και οι υπόλοιπες 12 αφορούν sector dummies. Σε πραγματικές συνθήκες, όπου ο αριθμός καταγεγραμμένων κρίσιμων οντοτήτων ανά τομέα είναι συχνά περιορισμένος λόγω του νομοθετικού πλαισίου CER/NIS2, υπάρχει κίνδυνος ένα ευέλικτο μοντέλο όπως το Random Forest να υπερπροσαρμοστεί στον θόρυβο, ειδικά στη σπανιότερη κλάση Πολύ Κρίσιμο. Αντιθέτως, η Logistic Regression με τη χρήση L2 κανονικοποίησης μπορεί να αντισταθεί στο overfitting αποτελεσματικά, καθιστώντας την πιο αξιόπιστη για περιπτώσεις όπου το δείγμα είναι περιορισμένο.

3.4.4. Αξιολόγηση Διάγνωσης – Έλεγχος της Γραμμικής Διαχωρισιμότητας

Το Logistic Regression στηρίζεται στην υπόθεση ότι τα όρια απόφασης ακολουθούν μια γραμμική μορφή όταν εκφράζονται στο επίπεδο των λογαριθμικών πιθανοτήτων (log-odds). Ως εκ τούτου, η σύγκριση της με μη γραμμικά μοντέλα λειτουργεί ως ένας έμμεσος στατιστικός έλεγχος για την ανίχνευση μη γραμμικών σχέσεων στα δεδομένα. Σε αυτό το πλαίσιο, η γεννήτρια συνθετικών δεδομένων (`generate_synthetic_dataset_cri()`) εισάγει έναν συγκεκριμένο όρο μη γραμμικής αλληλεπίδρασης: $Penalty_i = -8.0 \cdot 1[(Dim_{i,A} < 40) \wedge (Dim_{i,B} < 40)]$, τον οποίο η γραμμική προσέγγιση της Logistic Regression αδυνατεί να εκφράσει πλήρως σχεσιακές συνδέσεις χωρίς την άμεση ενσωμάτωση ενός όρου αλληλεπίδρασης, η οποία επιτυγχάνεται μέσω τεχνικών δημιουργίας χαρακτηριστικών. Εάν το macro-F1 score των Random Forest ή XGBoost υπερβαίνει αισθητά το Baseline, αυτό αποτελεί ένδειξη για την πρακτική σημασία τέτοιων μη γραμμικών δομών στο συγκεκριμένο πρόβλημα.

3.4.5. Κατανόηση και Συμμόρφωση με τις Κανονιστικές Απαιτήσεις

Σε σύγκριση με τις τεχνικές Random Forest και XGBoost, που συχνά βασίζονται σε μεταγενέστερες επεξηγήσεις μέσω SHAP (όπως οι διαδικασίες `compute_shap()` και `TreeExplainer`), η Logistic Regression παρέχει άμεση και εγγενή ερμηνευσιμότητα μέσω των συντελεστών της και των αντίστοιχων αναλογιών πιθανότητας (odds ratios) e^{β_j} . Σε περιπτώσεις όπου οι ταξινομήσεις μπορεί να συνεπάγονται κανονιστικές υποχρεώσεις, όπως αυτές ορίζονται από τους Ν. 5236/2025 και Ν. 5160/2024, η ικανότητα παροχής άμεσης αιτιολόγησης των αποφάσεων του μοντέλου χωρίς την ανάγκη προσεγγιστικών εργαλείων είναι ένα ουσιαστικό πλεονέκτημα για τη διασφάλιση της διαφάνειας.

3.4.6. Στατιστική Θεμελίωση Κατώτατου Ορίου Απόδοσης (Lower-Bound Benchmark)

Η αναφορά τόσο του hold-out F1-score όσο και της 5-fold CV mean/std στον κώδικα επιτρέπει τη σύγκριση για να διαπιστωθεί αν η βελτίωση στην απόδοση των πιο σύνθετων μοντέλων είναι στατιστικά σημαντική ή αν βρίσκεται εντός του εύρους τυχαίας διακύμανσης λόγω δειγματοληψίας. Αυτή η πληροφορία είναι κρίσιμη για την τεκμηριωμένη επιλογή μοντέλου που θα χρησιμοποιηθεί μελλοντικά μετά την ολοκλήρωση του Σχεδίου Υλοποίησης της Εθνικής Στρατηγικής για την Ανθεκτικότητα Κρίσιμων Οντοτήτων 2026-2030.

3.4.7. Εφαρμογή της Multinomial Softmax Logistic Regression με L2 Regularization σε Pipeline με StandardScaler

1. Η Αρχιτεκτονική του Pipeline

Το Pipeline³⁵ περιλαμβάνει την εφαρμογή δύο διαδοχικών, αυστηρά διακεκριμένων μετασχηματισμών:

$$X \xrightarrow{\text{StandardScaler (fit στο Train)}} X' \xrightarrow{\text{Multinomial Logistic Regression}} \hat{P}(Y|X')$$

Με μια κρίσιμη μεθοδολογική εγγύηση, το εργαλείο StandardScaler εκτελεί την προσαρμογή (fit) μόνο στο σύνολο εκπαίδευσης και πραγματοποιεί μετασχηματισμό (transform) τόσο στο σύνολο εκπαίδευσης, όσο και στο σύνολο ελέγχου. Η συγκεκριμένη μέθοδος αποτρέπει τη μεταφορά στατιστικών δεδομένων, όπως ο μέσος όρος και η τυπική απόκλιση, από το στάδιο δοκιμής στο στάδιο εκπαίδευσης.

Το Στάδιο Τυποποίησης – Προεπεξεργασία

Έστω $X \in \mathbb{R}^{n \times p}$ είναι ο πίνακας των χαρακτηριστικών ($n = 5.000, p = 19$), όπου $p = p_1 + p_2$ με $p_1 = 7$ KPIs συνεχή λειτουργικά χαρακτηριστικά και $p_2 = 12$ δυαδικές δείκτριες sector dummies $\{0,1\}$. Επίσης, έστω $y \in \{1, 2, \dots, K\}^n$, $K = 4$, το διάνυσμα των ετικετών {Μη Κρίσιμο, Χαμηλής Ανθεκτικότητας, Κρίσιμο, Πολύ Κρίσιμο}, κωδικοποιημένες αριθμητικά χωρίς να υποθέτουν διάταξη (nominal encoding, LabelEncoder).

Κάθε χαρακτηριστικό κανονικοποιήθηκε (z-score normalization) βασισμένο σε στατιστικά που εκτιμήθηκαν αποκλειστικά από το σύνολο εκπαίδευσης (μ_j, σ_j εκτιμημένα σε X_{train}), ώστε να αποφευχθεί η διαρροή πληροφορίας (data leakage) από το σύνολο ελέγχου, σύμφωνα με τον Kaufman et al. (2011).

$$\mu_j = \frac{1}{n_{train}} \sum_{i=1}^{n_{train}} x_{ij}, \quad \sigma_j = \sqrt{\frac{1}{n_{train}} \sum_{i=1}^{n_{train}} (x_{ij} - \mu_j)^2}, \quad x'_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \quad (12)$$

Η τυποποίηση εφαρμόστηκε ως το αρχικό στάδιο ενός ενιαίου Pipeline, όπως περιγράφεται από τον Pedregosa et al. (2011). Αυτή η διαδικασία διασφαλίζει ότι οι παράμετροι μ_j και σ_j υπολογίζονται εκ νέου αυτόματα σε κάθε αναδίπλωση (fold) της διασταυρούμενης επικύρωσης.

³⁵ `Baseline_pipeline = make_pipeline(StandardScaler(), LogisticRegression(max_iter=2000, random_state=RANDOM_STATE))`. Δημιουργία Pipeline για την κανονικοποίηση των χαρακτηριστικών χρησιμοποιώντας το StandardScaler: Πρώτα γίνεται κανονικοποίηση των χαρακτηριστικών και, στη συνέχεια, προχωράμε στην εφαρμογή της λογιστικής παλινδρόμησης. Αυτό το βήμα είναι κρίσιμο, καθώς η λογιστική παλινδρόμηση επηρεάζεται από την κλίμακα των μεταβλητών.

2. Η Δομή του Multinomial (Softmax) Μοντέλου

Για κάθε κλάση $k \in \{1, 2, \dots, K\}$ ορίζεται γραμμικός δείκτης απόφασης (logit score). Για $K = 4$ κλάσεις, το μοντέλο εκτιμά ανεξάρτητο διάνυσμα συντελεστών $\beta_k \in \mathbb{R}^{19}$ και intercept³⁶ $\beta_{0,k}$ για κάθε κλάση $k = 1, 2, 3, 4$:

$$z_{i,k} = \beta_{0,k} + \beta_k^T x'_i \quad (13)$$

Το σύνολο των παραμέτρων σχηματίζει πίνακα $B \in \mathbb{R}^{4 \times 19}$ και η πιθανότητα της κάθε κλάσης υπολογίζεται μέσω της συνάρτησης Softmax, η οποία αποτελεί γενίκευση της σιγμοειδούς συνάρτησης για περιπτώσεις με πολλές κλάσεις:

$$P(Y_i = k | x'_i; B) = \frac{\exp(z_{i,k})}{\sum_{m=1}^4 \exp(z_{i,m})} \quad (14)$$

$$\text{με } \sum_{k=1}^4 P(Y_i = k | x'_i) = 1$$

Η τελική ταξινόμηση προκύπτει από την εξίσωση:

$$\hat{y}_i = \arg \max_{k \in \{1,2,3,4\}} P(Y_i = k | x'_i; B) \quad (15)$$

3. Το Ζήτημα της Ταυτοποίησης (Identifiability)

Η δομή Softmax είναι εγγενώς υπερπαραμετροποιημένη. Εάν προσθέσουμε μια σταθερά c σε όλα τα $z_{i,k}$ ταυτόχρονα, η Softmax παραμένει αμετάβλητη. Δεν υπάρχει δηλαδή «φυσική» κλάση αναφοράς με μηδενικούς συντελεστές. Αυτό το θέμα επιλύεται αποκλειστικά μέσω της L2 ποινής, η οποία σταθεροποιεί αριθμητικά τη λύση χωρίς να χρειάζεται ένα ρητό reference-class constraint³⁷. Μία άμεση συνέπεια είναι πως οι συντελεστές β_k στη sklearn ερμηνεύονται ως η σχετική συνεισφορά στο συνολικό σκορ του Softmax και όχι ως log-odds συγκριτικά με κάποια σταθερή κλάση αναφοράς.

4. Η Αντικειμενική Συνάρτηση – Categorical Cross-Entropy με L2 Ποινή

Έστω $t_{i,k} = 1(y_i = k)$ είναι η one-hot αναπαράσταση της πραγματικής κλάσης. Οι παράμετροι $B = \{\beta_{0,k}, \beta_k\}_{k=1}^K$ εκτιμήθηκαν μέσω ελαχιστοποίησης της αρνητικής

³⁶ Ο σταθερός όρος ή το σημείο τομής μιας συνάρτησης αναφέρεται στη θέση όπου η ευθεία τέμνει έναν από τους άξονες συντεταγμένων. Στον χώρο της στατιστικής, πρόκειται για την τιμή της εξαρτημένης μεταβλητής όταν όλες οι ανεξάρτητες μεταβλητές έχουν μηδενική τιμή.

³⁷ Ο περιορισμός της κλάσης αναφοράς αναφέρεται σε έναν περιορισμό ή έναν κανόνα που εφαρμόζεται σε μια συγκεκριμένη κλάση ή ομάδα μέσα σε μια ευρύτερη ταξινόμηση. Αυτή η έννοια χρησιμοποιείται συχνά σε τομείς όπως η πιθανότητα και η στατιστική, όπου βοηθά να διασφαλιστεί ότι οι προβλέψεις ή οι αναλύσεις είναι σχετικές με το κατάλληλο πλαίσιο. Ουσιαστικά, απαιτεί οι συγκρίσεις ή οι αξιολογήσεις να γίνονται μέσα σε ένα καθορισμένο σύνολο, διατηρώντας τη συνέπεια και τη σχετικότητα με την ιδιαίτερη ομάδα που αξιολογείται.

λογαριθμικής πιθανοφάνειας (regularized negative log-likelihood³⁸ ή categorical cross-entropy):

$$\ell(B) = - \sum_{i=1}^{n_{train}} \sum_{k=1}^K t_{i,k} \ln P(Y_i = k | x'_i; B) = - \sum_{i=1}^{n_{train}} \ln P(Y_i = y_i | x'_i; B) \quad (16)$$

Η πλήρης αντικειμενική συνάρτηση που ελαχιστοποιεί η sklearn (default penalty='l2') είναι:

$$\begin{aligned} J(B) &= -C \sum_{i=1}^{n_{train}} \sum_{k=1}^K 1(y_i = k) \ln P(y_i = k | x'_i) + \frac{1}{2} \sum_{k=1}^K \|\beta_k\|_2^2 \quad \rightarrow \\ J(B) &= C \cdot \ell(B) + \frac{1}{2} \sum_{k=1}^4 \sum_{j=1}^{19} \beta_{k,j}^2 \end{aligned} \quad (17)$$

Η παράμετρος αντίστροφης ρύθμισης διατηρήθηκε στην προεπιλεγμένη (default) τιμή $C = 1.0$, χωρίς να γίνει κάποια βελτιστοποίηση μέσω αναζήτησης πλέγματος. Έτσι, το Baseline μοντέλο αντιπροσωπεύει την επίδοση του χωρίς επιπλέον υπολογιστική επένδυση, σε αντίθεση με τα βελτιστοποιημένα (tuned) μοντέλα σύγκρισης. Επίσης, πρέπει να σημειωθεί ότι η ποινή L2 (Ridge) εφαρμόστηκε αποκλειστικά στους συντελεστές κλίσης $\beta_{k,j}$ και όχι στα intercepts $\beta_{0,k}$. Αυτή η προσέγγιση ακολουθεί την εδραιωμένη πρακτική που χρησιμοποιείται στα γενικευμένα γραμμικά μοντέλα.

$$B^* = \arg \min_{B \in \mathbb{R}^{4 \times 19}} J(B) \quad (18)$$

Η συνάρτηση $J(B)$ είναι αυστηρά κυρτή, καθώς αποτελείται από το άθροισμα μιας κυρτής δομής log-sum-exp και μιας κυρτής τετραγωνικής ποινής. Αυτό εγγυάται την ύπαρξη ενός μοναδικού ελαχίστου (global minimum), το οποίο δεν εξαρτάται από την αρχικοποίηση.

5. Η Αριθμητική Επίλυση μέσω Solver L-BFGS³⁹

Η αριθμητική επίλυση έγινε χρησιμοποιώντας τον αλγόριθμο L-BFGS, μια μέθοδο περιορισμένης μνήμης τύπου quasi-Newton. Προβλέφθηκε ανώτατο όριο 5.000 επαναλήψεων για να διασφαλιστεί η σύγκλιση, λαμβάνοντας υπόψη το μέγεθος του χώρου παραμέτρων και τις γραμμικά εξαρτώμενες δείκτριες sector μεταβλητές.

³⁸ Negative Log-Likelihood (NLL): Το αρνητικό πρόσημο του λογαρίθμου της πιθανότητας (likelihood) των παρατηρήσεων. Στόχος είναι να μεγιστοποιηθεί η πιθανότητα (likelihood) των σωστών ετικετών, άρα ελαχιστοποιείται το NLL. Categorical Cross-Entropy (CCE): Η διασταυρούμενη εντροπία μεταξύ της πραγματικής κατανομής πιθανότητας (τα labels) και της προβλεπόμενης κατανομής από το μοντέλο. Στη μηχανική μάθηση, η επιτηρούμενη ταξινόμηση χρησιμοποιεί τη Negative Log-Likelihood (NLL) και τη Categorical Cross-Entropy (CCE) να είναι η ίδια μαθηματική έννοια. Μετρούν πόσο καλά ένα μοντέλο ταξινόμησης προβλέπει τη σωστή κλάση, υπολογίζοντας το αρνητικό λογάριθμο της πιθανότητας που δίνει το μοντέλο στη σωστή απάντηση.

³⁹ Η μέθοδος L-BFGS (Limited-memory Broyden-Fletcher-Goldfarb-Shanno) αποτελεί έναν καταξιωμένο επαναληπτικό αλγόριθμο βελτιστοποίησης που εφαρμόζεται ευρέως για τον προσδιορισμό του ελάχιστου ή του μέγιστου μιας συνάρτησης πολλαπλών μεταβλητών. Ένα από τα σημαντικά πλεονεκτήματα του L-BFGS είναι η ικανότητά του να εξοικονομεί μνήμη, κάνοντας τον πιο αποτελεσματικό σε σύγκριση με άλλες μεθόδους βελτιστοποίησης.

$$\frac{\partial J}{\partial \beta_{k,j}} = C \sum_{i=1}^{n_{train}} (P(Y_i = k | x'_i) - t_{i,k}) x'_{i,j} + \beta_{k,j} \rightarrow$$

$$B^{(t+1)} = B^{(t)} - \eta_t H_t^{-1} \nabla J(B^{(t)}) \quad (19)$$

όπου H_t^{-1} είναι η αντίστροφη Hessian (limited-memory, του solver L-BFGS). Η επιλογή της παραμέτρου $\max_iter = 2000$, αντί για το default 100, διασφαλίζει ότι θα υπάρξει αρκετός αριθμός επαναλήψεων ώστε να επιτευχθεί το κριτήριο σύγκλισης $\|\nabla J(B^{(t)})\|_{\infty} < tol$. Αυτό είναι σημαντικό λόγω της σχετικά υψηλής διαστατικότητας και της ύπαρξης σχεδόν συγγραμμικών sector dummies που επιβραδύνουν τη διαδικασία σύγκλισης.

6. Η Επίδραση της Κανονικοποίησης Sector Dummies στη Δομή του Προβλήματος

Κατά τη μετατροπή του τομέα με 12 κλάσεις σε 12 δυαδικές (0/1) στήλες, κάθε οντότητα παρουσιάζεται με 1 στην αντίστοιχη στήλη του δικού της τομέα και 0 στις υπόλοιπες. Αυτό συνεπάγεται ότι το άθροισμα των 12 στηλών είναι πάντα ακριβώς 1 για κάθε γραμμή. Έτσι, γνωρίζοντας τις τιμές των 11 στηλών, μπορούμε να υπολογίσουμε την 12η με απόλυτη βεβαιότητα χρησιμοποιώντας την εξίσωση: $Column_{12} = 1 - \sum_{j=1}^{11} Column_j$ (το άθροισμα των τιμών των στηλών 1 έως 11). Αυτή η ντετερμινιστική και τέλεια γραμμική εξάρτηση ονομάζεται πολυσυγγραμμικότητα, καθιστώντας τη 12η στήλη μαθηματικά περιττή, καθώς δεν προσφέρει νέα πληροφορία. Στην κλασσική Μέθοδο Ελαχίστων Τετραγώνων (OLS), αυτό θα έκανε τον πίνακα $X^T X$ μη αντιστρέψιμο. Ωστόσο, στην κανονικοποιημένη Πολυωνυμική Λογιστική Παλινδρόμηση (Multinomial Logistic Regression), η χρήση της ποινής L2 εξαλείφει το πρόβλημα που οδηγεί σε σφάλμα υπολογισμού.

7. Το Πλήρες Ενοποιημένο Πρόβλημα Βελτιστοποίησης

Η πλήρης εξίσωση του προβλήματος βελτιστοποίησης με ενοποιημένο τρόπο δίνεται από την εξίσωση:

$$B^* = \arg \min_B \left\{ -C \sum_{i=1}^{n_{train}} \ln \left(\frac{\exp(\beta_{0,y_i} + \beta_{y_i}^T x'_i)}{\sum_{m=1}^4 \exp(\beta_{0,m} + \beta_m^T x'_i)} \right) + \frac{1}{2} \sum_{k=1}^4 \|\beta_k\|_2^2 \right\} \quad (20)$$

όπου x'_i είναι αποτέλεσμα τυποποίησης εντός του Pipeline, ενώ η βελτιστοποίηση πραγματοποιείται χρησιμοποιώντας τη μέθοδο L-BFGS με μέγιστο αριθμό 2000 επαναλήψεων.

Πίνακας 3.4: Αποτίμηση χρήσης MLR με ρόλο Baseline μοντέλου.

Χαρακτηριστικό	Συνέπεια για τον ρόλο Baseline μοντέλου
Κυρτότητα $J(B)$	Η διασφάλιση ταχείας σύγκλισης χωρίς την ανάγκη συχνών επανεκκινήσεων αιτιολογεί την έλλειψη ανάγκης για λεπτομερή ρύθμιση (απουσία tuning).
Ποινή L2 σε $\beta_{k,j}$	Αποτελεσματική προστασία από το overfitting, ιδιαίτερα χρήσιμη όταν χειρίζεστε 12 ενδεχομένως αλληλοσυσχετιζόμενες κλάσεις τομέων.
Γραμμική δομή στο log-odds	Πραγματοποιεί διαγνωστικό έλεγχο για τη μη γραμμικότητα σε σύγκριση με Random Forest και XGBoost.
Απευθείας ερμηνεύσιμοι β_k	Συμμόρφωση με τις κανονιστικές απαιτήσεις διαφάνειας χωρίς τη χρήση του εργαλείου SHAP.

3.5. Μοντέλο Τυχαίων Δασών (Random Forest) με χρήση RandomizedSearchCV για Βελτιστοποίηση Υπερπαραμέτρων και Ερμηνευσιμότητα SHAP

3.5.1. Εισαγωγή στο Μοντέλο Random Forest

Η μηχανική μάθηση έχει φέρει επανάσταση στην ανάλυση δεδομένων και στη διαδικασία λήψης αποφάσεων. Ένας από τους πλέον ισχυρούς και ευέλικτους αλγορίθμους που χρησιμοποιούνται επί του παρόντος είναι ο Random Forest (RF). Η μέθοδος Random Forest, την οποία ανέπτυξε ο Breiman⁴⁰ το 2001, ενσωματώνει πολλαπλά δέντρα απόφασης μέσω τυχαίας δειγματοληψίας και επιλογής μεταβλητών. Αυτό προσφέρει υψηλή ακρίβεια και είναι ανθεκτικό στον θόρυβο.

Στην παρούσα έρευνα, η ανάλυση του Random Forest εστιάζει σε τρία βασικά ερωτήματα: α) τον μηχανισμό συνόλου (ensemble mechanism⁴¹ ή ensemble learning), β) τον έλεγχο υπερεκπαίδευσης (overfitting) και γ) την ερμηνευσιμότητα μέσω SHAP στα πλαίσια της Επεξηγηματικής⁴² Τεχνητής Νοημοσύνης (Explainable AI – XAI). Για την ταξινόμηση σε τέσσερις κλάσεις με τη χρήση αριθμητικών δεδομένων και one-hot κωδικοποιημένων χαρακτηριστικών, οι Probst et al. (2018), Scornet et al. (2014) και Biau & Scornet (2015) προτείνουν το Random Forest ως ένα αξιόπιστο μη παραμετρικό μοντέλο γι' αυτόν το σκοπό. Αυτό το μοντέλο δίνει έμφαση στη μείωση της διακύμανσης, στη ρύθμιση της συσχέτισης μεταξύ των δέντρων και στην εξήγηση προβλέψεων με βάση τα χαρακτηριστικά.

⁴⁰ Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/a:1010933404324>.

⁴¹ Στη μηχανική μάθηση, ένας μηχανισμός συνόλου (ensemble learning) συνδυάζει πολλαπλά ατομικά μοντέλα, συχνά γνωστά ως "αδύναμοι μαθητές", για να δημιουργήσει ένα ενιαίο, ισχυρό προγνωστικό σύστημα. Μέσω της συγκέντρωσης διαφορετικών αποτελεσμάτων με ψήφο, μεσοτιμίες ή ενός επιπλέον μετα-μοντέλου, επιτυγχάνεται μείωση των σφαλμάτων, αποφυγή της υπερπροσαρμογής και αύξηση της συνολικής ακρίβειας.

⁴² Η έννοια της επεξηγηματικής τεχνητής νοημοσύνης (Explainable AI) αναφέρεται στην ανάπτυξη συστημάτων Τεχνητής Νοημοσύνης που προσφέρουν διαφάνεια και κατανοητές εξηγήσεις σχετικά με τον τρόπο που λαμβάνουν αποφάσεις. Σε έναν κόσμο όπου τα μοντέλα AI καθίστανται ολοένα και πιο περίπλοκα, η ικανότητα κατανόησης των διαδικασιών και των λόγων πίσω από τις προβλέψεις και τους υπολογισμούς τους είναι ουσιαστική. Αυτή η διαφάνεια είναι ιδιαίτερα σημαντική σε κρίσιμους τομείς όπως η ανθεκτικότητα κρίσιμων οντοτήτων, η χρηματοδότηση και η άμυνα όπου οι αποφάσεις μπορούν να έχουν σοβαρές επιπτώσεις. Η επεξηγηματική AI βοηθάει στη δημιουργία εμπιστοσύνης στους χρήστες και εξασφαλίζει δικαιοσύνη και υπεύθυνη χρήση της τεχνολογίας.

Σύμφωνα με τις μελέτες των Liaw & Wiener (2002) και Liu & Mazumder (2024), η μέθοδος των Random Forest αναβαθμίζει την τεχνική bagging. Αυτή η διαδικασία περιλαμβάνει τη δημιουργία πολλαπλών αποφασιστικών δέντρων από δείγματα που προέρχονται από τη μέθοδο bootstrap. Οι προβλέψεις που παράγονται από αυτά τα δέντρα συνδυάζονται είτε μέσω ψηφοφορίας στις περιπτώσεις ταξινόμησης είτε μέσω υπολογισμού του μέσου όρου για την επίλυση προβλημάτων παλινδρόμησης. Το Random Forest αποτελεί μια μη παραμετρική προσέγγιση που δεν προϋποθέτει προκαθορισμένες υποθέσεις σχετικά με τη μορφή της σχέσης ανάμεσα στις προγνωστικές μεταβλητές και την απόκριση. Η απόδοσή του βασίζεται στην ύπαρξη ισχυρών και διαφορετικών δέντρων, όχι απλώς στον μεγάλο αριθμό δέντρων. Αυτή η τεχνική είναι ιδιαίτερα αποτελεσματική σε δεδομένα υψηλής διάστασης και σύνθετης δομής.

Το Random Forest παρουσιάζει γενική αντοχή στην υπερεκπαίδευση σε σύγκριση με ένα μεμονωμένο δέντρο, δεδομένου ότι η προσέγγιση της συναθροιστικής μάθησης μειώνει τη διασπορά και βελτιώνει το σφάλμα γενίκευσης, όπως υποδεικνύεται από τις έρευνες των Liaw & Wiener (2002), Halabaku & Bytyçi (2024). Ωστόσο, η ανθεκτικότητα αυτή δεν υπονοεί αδιαφορία ως προς τη ρύθμιση, διότι οι υπερπαραμέτροι που ελέγχουν το βάθος των δέντρων, το μέγεθος των φύλλων και τον αριθμό των δέντρων έχουν καθοριστική επίδραση τόσο στην απόδοση όσο και στην πιθανότητα της υπερπροσαρμογής. Στην πρακτική εφαρμογή του στην παρούσα έρευνα, σύμφωνα με τους Probst et al. (2018) και Bernal et al. (2025), ο έλεγχος της υπερεκπαίδευσης βασίζεται κυρίως στη βελτιστοποίηση (tuning) μέσω διαδικασιών διασταυρούμενης επικύρωσης (cross-validation) και την επιλογή υπερπαραμέτρων που περιορίζουν την πολυπλοκότητα των επιμέρους δέντρων.

Στο μοντέλο Random Forest, σύμφωνα με τον Lundberg et al. (2017, 2018) το SHAP (SHapley Additive exPlanations) παρέχει ερμηνείες σε επίπεδο ατομικής πρόβλεψης, αποδίδοντας μια τιμή συνεισφοράς σε κάθε χαρακτηριστικό για το συγκεκριμένο αποτέλεσμα. Στα σύνολα δέντρων (tree ensembles), οι ακριβείς τιμές SHAP μπορούν να υπολογιστούν αποτελεσματικά με το TreeSHAP, κάνοντας δυνατή την ερμηνεία ακόμα και για μεγάλα σύνολα δέντρων και ολόκληρα datasets. Αυτό είναι ζωτικής σημασίας, καθώς επιτρέπει τόσο μια συνολική ανάλυση της σχετικής σημασίας των 7 δεικτών και των 12 τομεακών μεταβλητών όσο και μια τοπική ερμηνεία γιατί μια οντότητα ταξινομήθηκε σε συγκεκριμένη κλάση ανθεκτικότητας.

3.5.2. Θεωρία Συνόλων Δέντρων Απόφασης (Ensemble Learning)

1. Δειγματοληψία με Επανατοποθέτηση (Bootstrap Sampling)

Έστω ένα σύνολο εκπαίδευσης $D = \{(x_i, y_i)\}_{i=1}^n$, όπου $x_i \in \mathbb{R}^p$ είναι το διάνυσμα χαρακτηριστικών (στον κώδικα, $p = 7$ οι αριθμητικοί δείκτες του AVAILABLE_SUBSET και 12 one-hot sector μεταβλητές από το `pd.get_dummies(df["sector"])`) και y_i είναι η ετικέτα κλάσης της ανθεκτικότητας. Για κάθε δέντρο $b = 1, 2, \dots, B$, δημιουργείται bootstrap δείγμα:

$$D_b = \left\{ \left(x_i^{(b)}, y_i^{(b)} \right) \right\}_{i=1}^n, \quad \text{με} \quad \left(x_i^{(b)}, y_i^{(b)} \right) \sim \text{Uniform}(D) \text{ με επανοτοποθέτηση}$$

όπου, D είναι το πλήρες σύνολο εκπαίδευσης X_{train} (το 75% του dataset μετά το `train_test_split`), με n παρατηρήσεις. Το D_b είναι το bootstrap δείγμα για το b -οστό δέντρο (από τα $B = n_{\text{estimators}}$ δέντρα συνολικά εξεταζόμενο στο εύρος $\{200, 400, 500\}$). Η σχέση μεταξύ $\sim \text{Uniform}(D)$ με επανατοποθέτηση σημαίνει ότι για να δημιουργήσουμε το D_b , επιλέγουμε τυχαία μία παρατήρηση n φορές από το σύνολο D , επιστρέφοντάς την στον «κουβά» κάθε φορά. Έτσι, η ίδια παρατήρηση μπορεί να επιλεγεί πολλές φορές και κάποιες άλλες παρατηρήσεις μπορεί να μην επιλεγούν καθόλου.

Κάθε δέντρο $h_b(x)$ εκπαιδεύεται ανεξάρτητα πάνω στο D_b . Η τελική πρόβλεψη προκύπτει από την πλειοψηφική ψηφοφορία $\hat{y} = \text{mode}\{h_1(x), h_2(x), \dots, h_B(x)\}$. Κάθε συνάρτηση $h_b(x)$ αντιπροσωπεύει την πρόβλεψη ενός μεμονωμένου δέντρου που έχει εκπαιδευτεί στο σύνολο D_b για μια νέα παρατήρηση x . Η συνάρτηση $\text{mode}\{\cdot\}$ επιστρέφει την πιο συχνά εμφανιζόμενη τιμή μέσα στο σύνολο. Δηλαδή, από τα B δέντρα, κερδίζει η κλάση (όπως Μη Κρίσιμο, Κρίσιμο κ.λπ.) που προτάθηκε από το μεγαλύτερο αριθμό δέντρων.

Σε επίπεδο πιθανοτήτων ανά κλάση k :

$$\hat{P}(y = k | x) = \frac{1}{B} \sum_{b=1}^B 1[h_b(x) = k] \quad (21)$$

όπου, $1[\cdot]$ είναι η δείκτρια συνάρτηση (indicator function), που παίρνει τιμή 1 αν το δέντρο b προέβλεψε την κλάση k , αλλιώς παίρνει την τιμή 0. Το άθροισμα $\sum_{b=1}^B (\dots)$ μετράει πόσα από τα B δέντρα «ψήφισαν» υπέρ της κλάσης k . Διαιρώντας με το B , μετατρέπουμε αυτή τη «καταμέτρηση ψήφων» σε ποσοστό, δηλαδή σε εκτιμώμενη πιθανότητα. Αυτό είναι ουσιαστικά το `predict_proba()` της βιβλιοθήκης `sklearn`, το οποίο χρησιμοποιείται εσωτερικά κατά τον υπολογισμό των πιθανοτήτων ανά κλάση στο `compute_shap()`.

2. Τυχαιοποίηση Χαρακτηριστικών (Feature Bagging) – Κριτήριο Διαχωρισμού Κόμβου (Δείκτης Gini)

Στην ανάλυση κάθε κόμβου διαχωρισμού t εντός του δέντρου, δεν εξετάζεται το πλήρες σύνολο των p χαρακτηριστικών. Αντί αυτών, γίνεται επιλογή ενός τυχαίου υποσυνόλου χαρακτηριστικών μεγέθους m (όπου $m < p$), το οποίο ελέγχεται από το `max_features` $\in \{\sqrt{p}, 0.4p, 0.6p\}$. Ο βέλτιστος διαχωρισμός επιτυγχάνεται ελαχιστοποιώντας τον δείκτη Gini Impurity:

$$\text{Gini}(t) = 1 - \sum_{k=1}^K p_k(t)^2 \quad (22)$$

όπου, με t συμβολίζεται ένας κόμβος του δέντρου, εκπροσωπώντας μια ομάδα παρατηρήσεων που έχουν φτάσει μέχρι εκεί μέσω προηγούμενων διαχωρισμών. Το $K = 4$ είναι το πλήθος των κλάσεων ανθεκτικότητας (`CLASS_LABELS`). Το $p_k(t)$ είναι το ποσοστό των παρατηρήσεων στον κόμβο t που ανήκουν στην κλάση k . Το $\sum_{k=1}^K p_k(t)^2$ υπολογίζει την πιθανότητα να τραβήξουμε τυχαία δύο φορές, ανεξάρτητα, την ίδια κλάση από τον κόμβο t .

Τέλος, το $1 - (\cdot)$ αντιστρέφει αυτή την ποσότητα σε ένα μέτρο «ανάμιξης». Δηλαδή, όταν ο κόμβος περιλαμβάνει μόνο μία κλάση (καθαρός κόμβος), τότε το $Gini(t) = 0$. Όταν οι κλάσεις είναι ίσα κατανομημένες (οδηγώντας σε μέγιστη «σύγχυση»), το Gini βρίσκεται στο μέγιστο επίπεδό του. Η βελτιστοποίηση μέσω διαχωρισμού, δίνεται από την εξίσωση:

$$\Delta Gini(t, j, s) = Gini(t) - \frac{n_L}{n_t} Gini(t_L) - \frac{n_R}{n_t} Gini(t_R) \quad (23)$$

όπου, ο κόμβος t με n_t παρατηρήσεις χωρίζεται σε δύο φύλλα, το αριστερό t_L με n_L παρατηρήσεις και το δεξί t_R με n_R παρατηρήσεις βάσει μια μεταβλητής j (π.χ. C1_mttr) και ενός κατωφλιού s (π.χ. C1_mttr ≤ 12 ώρες). Οι όροι n_L/n_t και n_R/n_t λειτουργούν ως σταθμίσεις, καθώς αποδίδουν μεγαλύτερο «βάρος» στο φύλλο/κόμβο που περιέχει περισσότερες παρατηρήσεις. Αυτό εξασφαλίζει ότι η σύγκριση μεταξύ των κόμβων γίνεται με δίκαιο και ισότιμο τρόπο.

Ο αλγόριθμος εξετάζει, μέσα σε ένα τυχαίο υποσύνολο από m μεταβλητές που ορίζεται από τη συνάρτηση max_features, διάφορα ζεύγη (j, s) και επιλέγει εκείνο που μεγιστοποιεί την $\Delta Gini$. Με άλλα λόγια, επιλέγει το ζεύγος που επιτυγχάνει τη μεγαλύτερη διαχωριστική ικανότητα μεταξύ των κλάσεων στους δύο νέα παιδιά-κόμβους.

3. Μείωση Διακύμανση μέσω Συσχέτισης Δέντρων

Η στατιστική δικαιολόγηση του ensemble, σύμφωνα με τον Breiman (2001), στηρίζεται στη σχέση διακύμανσης του μέσου όρου B των συσχετισμένων εκτιμητών με μέσο συντελεστή συσχέτισης ρ και κοινή διακύμανση σ^2 :

$$Var\left(\frac{1}{B} \sum_{b=1}^B h_b(x)\right) = \rho \sigma^2 + \frac{1-\rho}{B} \sigma^2 \quad (24)$$

όπου, σ^2 είναι η διακύμανση ενός μεμονωμένου δέντρου $h_b(x)$, το οποίο περιγράφει πόσο ασταθές ή ευαίσθητο είναι το δέντρο σε αλλαγές στα δεδομένα. Σημειώνεται ότι τα δέντρα απόφασης που δεν υπόκεινται σε περιορισμούς είναι γνωστά για την υψηλή διακύμανσή τους. Το ρ είναι ο μέσος συντελεστής συσχέτισης ($-1 \leq \rho \leq 1$) μεταξύ των προβλέψεων οποιωνδήποτε δύο δέντρων σε ένα δάσος. Εάν όλα τα δέντρα ήταν πανομοιότυπα, τότε $\rho = 1$. Ο πρώτος όρος, $\rho \sigma^2$ αποτελεί το κατώφλι που δεν μπορεί να μειωθεί, ανεξάρτητα από το πόσα δέντρα προσθέσουμε. Αυτό συμβαίνει γιατί εκφράζει τη διακύμανση που «μοιράζεται» από όλα τα δέντρα, καθώς αυτά προέρχονται από το ίδιο σύνολο δεδομένων. Ο δεύτερος όρος, $\left(1 - \rho/B\right) \sigma^2$ τείνει να μειώνεται καθώς αυξάνεται το B (n_estimators). Όσο μεγαλύτερο είναι το B , τόσο μικρότερος γίνεται αυτός ο όρος.

3.5.3. Αντιμετώπιση Υπερεκπαίδευσης (Overfitting)

1. Αντιστάθμιση Μεροληψίας – Διακύμανσης (Bias – Variance Tradeoff)

Οι υπερπαράμετροι του `rf_param_dist` λειτουργούν ως αυστηροί περιορισμοί και ελέγχονται από το `RandomizedSearchCV`.

- `max_depth` - $d \in \{None, 10, 15, 20\}$: Περιορίζει το βάθος δέντρου, άρα το πλήθος κόμβων-φύλλων $\leq 2^d$. Οι μικρές τιμές αυξάνουν τη μεροληψία, μειώνουν τη διακύμανση.
- `min_samples_split` - $n_{split} \in \{2, 4, 6\}$: Ελάχιστο πλήθος παρατηρήσεων για διαχωρισμό κόμβου. Ο διαχωρισμός επιτρέπεται μόνο αν $n_t \geq n_{split}$.
- `min_samples_leaf` - $n_{leaf} \in \{1, 2, 4\}$: Ελάχιστο πλήθος παρατηρήσεων ανά τελικό φύλλο, αποτρέποντας υπερβολικά εξειδικευμένους κανόνες. Κάθε φύλλο πρέπει να περιέχει $\geq n_{leaf}$.
- `max_features` $\in \{\sqrt{p}, 0.4p, 0.6p\}$: Περιορίζει τα υποψήφια χαρακτηριστικά ανά διαχωρισμό, ενισχύοντας την αποσυσχέτιση των δέντρων.
- `class_weight` = 'balanced': Αντισταθμίζει ανισοκατανομή κλάσεων, αποτρέποντας μεροληπτική προσαρμογή προς την πλειοψηφική κλάση.

Το αναμενόμενο τετραγωνικό σφάλμα πρόβλεψης αναλύεται κλασικά ως:

$$\mathbb{E}[(\hat{f}(x) - f(x))^2] = \underbrace{\text{Bias}[\hat{f}(x)]^2}_{\uparrow \text{ όσο μικραίνει το δέντρο}} + \underbrace{\text{Var}[\hat{f}(x)]}_{\downarrow \text{ όσο μικραίνει το δέντρο}} + \sigma_\varepsilon^2 \quad (25)$$

όπου, η συνάρτηση $f(x)$ αντιπροσωπεύει τη πραγματική σχέση μεταξύ χαρακτηριστικών και κλάσης ανθεκτικότητας, ενώ η εκτίμηση του μοντέλου μας, το εκπαιδευμένο Random Forest, εκφράζεται ως $\hat{f}(x)$. Το $\text{Bias}[\hat{f}(x)]$ είναι το συστηματικό σφάλμα και αφορά το μέσο επίπεδο απόκλισης του μοντέλου από τη σωστή κατεύθυνση. Ένα δέντρο με πολύ μικρό `max_depth` εμφανίζει υψηλή μεροληψία, καθώς η απλότητα του δεν επιτρέπει την κατανόηση σύνθετων σχέσεων, όπως αυτή που προκαλεί την μη γραμμική ποινή (`interaction_penalty`) στη δημιουργία του CRI. Το $\text{Var}[\hat{f}(x)]$ εκφράζει πόσο επηρεάζεται η πρόβλεψη αν επανεκπαιδύσουμε το μοντέλο σε άλλο σύνολο δεδομένων. Ένα πολύ βαθύ δέντρο, με μεγάλο `max_depth` και μικρό `min_samples_leaf` ανά δείγμα, έχει υψηλή διακύμανση, καθώς τείνει να «απομνημονεύει» τις ιδιαιτερότητες του συγκεκριμένου συνόλου εκπαίδευσης. Τέλος, το σ_ε^2 αποτελεί εγγενές χαρακτηριστικό των δεδομένων και δεν μπορεί να εξαλειφθεί από κανένα μοντέλο. Στον κώδικα, αυτό εκπροσωπείται σαφώς από το `noise = rng.normal(0, 3.5, ...)` που προστίθεται στο `CRI_score`.

Η πρακτική σημασία αυτής της εφαρμογής είναι ότι οι υπερπαράμετροι του `rf_param_dist` επιτρέπουν την προσαρμογή της ισορροπίας μεταξύ διακύμανσης και μεροληψίας στο μοντέλο. Ένα μικρότερο `max_depth` ή μεγαλύτερο `min_samples_leaf` τείνουν να μειώνουν τη διακύμανση και να αυξάνουν τη μεροληψία, μετακινώντας το μοντέλο προς τα δεξιά. Αντίθετα, επιλογές με μεγαλύτερο `max_depth` ή μικρότερο `min_samples_leaf` μετακινούν το μοντέλο προς τα αριστερά, αυξάνοντας τη διακύμανση και μειώνοντας τη μεροληψία.

2. Η Αντικειμενική Συνάρτηση του RandomizedSearchCV

Το RandomizedSearchCV προσπαθεί να βρει το σημείο που ελαχιστοποιεί το συνολικό άθροισμα των σφαλμάτων.

$$\theta^* = \arg \max_{\theta \in \{\theta_1, \theta_2, \dots, \theta_{10}\}} \frac{1}{3} \sum_{j=1}^3 F1_{macro}^{(j)}(\theta) \quad (26)$$

όπου, θ είναι ένας πλήρης συνδυασμός υπερπαραμέτρων, π.χ. $\theta = (n_estimators = 400, max_depth = 15, min_samples_split = 4, \dots)$. Αντί να εξεταστούν όλοι οι $3 \times 4 \times 3 \times 3 \times 3 = 324$ δυνατοί συνδυασμοί (grid search), γίνεται τυχαία δειγματοληψία μόνο 10 εξ' αυτών $\theta_1, \theta_2, \dots, \theta_{10}$, που αντιστοιχεί στο $n_iter = 10$. Για κάθε υποψήφιο θ_i , το σύνολο εκπαίδευσης χωρίζεται σε 3 κομμάτια (folds), που αντιστοιχεί στο $cv=3$. Κάθε φορά, το μοντέλο εκπαιδεύεται σε 2 fold και αξιολογείται στο 3ο, δίνοντας $F1_{macro}^{(j)}(\theta)$ για $j = 1, 2, 3$. Ο μέσος όρος $\frac{1}{3} \sum_{j=1}^3 F1_{macro}^{(j)}(\theta)$ δίνει την πιο αξιόπιστη εκτίμηση της απόδοσης του θ από ό,τι θα έδινε με μια μόνο δοκιμή, γιατί εξαλείφει την τύχη ενός μεμονωμένου διαχωρισμού. Το $\arg \max$ επιλέγει τελικά το θ με την υψηλότερη μέση απόδοση των 10 δοκιμασμένων, που αντιστοιχεί στο `rf_search.best_params_`.

3.5.4. Βελτιστοποίηση Υπερπαραμέτρων (Hyperparameter Tuning) - RandomizedSearchCV έναντι Grid Search

Σε αντίθεση με τις παραμέτρους ενός μοντέλου, όπως τα κατώφλια διαχωρισμού που προσδιορίζονται αυτόματα από τα δεδομένα κατά την εκπαίδευση, οι υπερπαραμέτροι είναι επιλογές που καθορίζονται πριν ξεκινήσει η εκπαίδευση. Αυτές οι επιλογές επηρεάζουν τη δομή, την πολυπλοκότητα και τη συμπεριφορά του αλγορίθμου. Δεν προέρχονται από τα δεδομένα, αλλά προσδιορίζονται μέσω μιας πειραματικής διαδικασίας, για παράδειγμα με τη χρήση RandomizedSearchCV στον κώδικα του Παραρτήματος Ι.

Στο Random Forest, οι υπερπαραμέτροι παίζουν καθοριστικό ρόλο καθώς ρυθμίζουν την ισορροπία μεταξύ μεροληψίας και διακύμανσης. Δέντρα που είναι πολύ «ελεύθερα», δηλαδή χωρίς περιορισμούς στο βάθος και με ελάχιστη τιμή για `min_samples_leaf`, συνήθως απομνημονεύουν τα δεδομένα εκπαίδευσης, οδηγώντας σε overfitting. Από την άλλη πλευρά, εξαιρετικά περιοριστικές ρυθμίσεις μπορούν να δημιουργήσουν υπερβολικά απλά δέντρα, τα οποία δεν καταφέρνουν να συλλάβουν τις βαθύτερες σχέσεις μέσα στα δεδομένα, γνωστό ως underfitting. Επιπλέον, ορισμένες υπερπαραμέτροι, όπως το `max_features`, επηρεάζουν όχι μόνο κάθε δέντρο μεμονωμένα αλλά και τη διαφοροποίηση μεταξύ των δέντρων, γεγονός που είναι Κρίσιμο για την απόδοση του ίδιου του μηχανισμού.

Ο πίνακας 3.5 παρουσιάζει τις υπερπαραμέτρους όπως ορίζονται στο `rf_param_dist` και στο `rf_base` του κώδικα, παρέχοντας και την πρακτική τους ερμηνεία.

Πίνακας 3.5: Ο ρόλος των υπερπαραμέτρων Random Forest.

Υπερπαραμέτρος	Τιμές στον Κώδικα	Ρόλος
n_estimators	{200, 400, 500}	Ελέγχει το πλήθος των δέντρων (B) στο δάσος. Περισσότερα δέντρα → μικρότερη διακύμανση πρόβλεψης (πιο σταθερό μοντέλο), αλλά με αυξανόμενο υπολογιστικό κόστος και φθίνουσα οριακή απόδοση πάνω από ένα σημείο.
max_depth	{None, 10, 15, 20}	Ελέγχει το μέγιστο βάθος του κάθε δέντρου. None = απεριόριστη ανάπτυξη μέχρι τα φύλλα να είναι «καθαρά» (υψηλός κίνδυνος overfitting). Οι μικρότερες τιμές (π.χ. 10) περιορίζουν την πολυπλοκότητα κάθε δέντρου, αυξάνοντας τη μεροληψία αλλά μειώνοντας τη διακύμανση
min_samples_split	{2, 4, 6}	Ελέγχει το ελάχιστο πλήθος παρατηρήσεων ου πρέπει να έχει ένας κόμβος για να επιτραπεί περαιτέρω διαχωρισμός. Υψηλότερη τιμή → πιο «συντηρητικά» δέντρα, αποτρέπει διαχωρισμούς βασισμένους σε πολύ λίγες (πιθανώς μη αντιπροσωπευτικές) παρατηρήσεις.
min_samples_leaf	{1, 2, 4}	Ελέγχει το ελάχιστο πλήθος παρατηρήσεων που πρέπει να καταλήγει σε κάθε τελικό φύλλο. Η υψηλότερη τιμή εξομαλύνει το μοντέλο, αποτρέποντας φύλλα που βασίζονται σε μεμονωμένα outliers και μειώνει τη διακύμανση.
max_features	{'sqrt', 0.4, 0.6}	Ελέγχει το πλήθος των χαρακτηριστικών που εξετάζονται τυχαία σε κάθε διαχωρισμό κόμβου. Μικρότερο υποσύνολο ($\sqrt{p}$) → μεγαλύτερη αποσυσχέτιση (decorrelation) μεταξύ δέντρων, ενισχύοντας το όφελος του bagging στη μείωση διακύμανσης, ενώ μεγαλύτερο ποσοστό (0.6) επιτρέπει πιο «ισχυρά» επιμέρους δέντρα αλλά με μεγαλύτερη συσχέτιση μεταξύ τους.
class_weight	'balanced' (σταθερή τιμή, εκτός RandomizedSearchCV)	Ελέγχει τη στάθμιση του σφάλματος ταξινόμησης ανά κλάση. Αντισταθμίζει την ανισοκατανομή των 4 κλάσεων ανθεκτικότητας, δίνοντας μεγαλύτερο «βάρος» σφάλματος στις μειοψηφικές κλάσεις (π.χ. «Πολύ Κρίσιμο»), ώστε το μοντέλο να μην τις αγνοεί υπέρ της πλειοψηφικής.
random_state	RANDOM_STATE (σταθερή τιμή, εκτός RandomizedSearchCV)	Είναι ο «σπόρος» τυχαιότητας για bootstrap δειγματοληψία και επιλογή χαρακτηριστικών. Διασφαλίζει αναπαραγωγικότητα. Έτσι, το ίδιο dataset με το ίδιο random_state παράγει πάντα το ίδιο εκπαιδευμένο μοντέλο.
n_jobs	-1 (σταθερή τιμή, εκτός RandomizedSearchCV)	Αποτελεί παραλληλισμό υπολογισμού. Χρησιμοποιεί όλους τους διαθέσιμους πυρήνες επεξεργαστή (υπολογιστική βελτιστοποίηση) και δεν επηρεάζει το αποτέλεσμα του μοντέλου.

Στη διαδικασία επιλογής, οι πρώτες πέντε παράμετροι (n_estimators, max_depth, min_samples_split, min_samples_leaf, max_features) είναι αυτές που πραγματικά εξερευνά το RandomizedSearchCV. Δοκιμάζει 10 τυχαίους συνδυασμούς από το χώρο των 324 πιθανών τιμών ($3 \times 4 \times 3 \times 3 \times 3 = 324$) με στόχο τη βελτιστοποίηση του macro-F1 σε 3-fold cross-

validation. Οι υπόλοιπες τρεις παράμετροι (class_weight, random_state, n_jobs) παραμένουν σταθερές καθ' όλη τη διάρκεια της αναζήτησης, όπως έχουν ήδη καθοριστεί στο rf_base.

3.6. XGBoost (Extreme Gradient Boosting), Ανάλυση Ενίσχυσης Κλίσης με Βελτιστοποίηση Υπερπαραμέτρων και Ερμηνευσιμότητα SHAP

3.6.1. Εισαγωγή στο Μοντέλο XGBoost

Το XGBoost αποτελεί μια κλιμακωτή τεχνική συνόλου που αξιοποιεί την ενίσχυση της κλίσης, δημιουργώντας διαδοχικά δέντρα αποφάσεων, σύμφωνα με τους Hussain et al. (2025) και Alhadidi & Hasoon (2024). Ο Chen (2016) επισημαίνει ότι η κυρίαρχη μέθοδος του XGBoost στον αλγόριθμό του βασίζεται σε ένα κανονικοποιημένο, προσθετικό σύνολο δέντρων παλινδρόμησης. Αυτό το σύνολο βελτιστοποιείται επαναληπτικά χρησιμοποιώντας πληροφορίες πρώτης και δεύτερης τάξης της συνάρτησης απώλειας (loss), πέρα από τα απλά κατάλοιπα (residuals). Δηλαδή, κάθε νέο δέντρο επιχειρεί να διορθώσει τα σφάλματα που παραμένουν από προηγούμενες επαναλήψεις. Ο αλγόριθμος του XGBoost, κατά τον Pellegrino et al. (2023), ενσωματώνει την κανονικοποίηση L1 και L2 στη συνάρτηση απώλειας για να αποτρέψει την υπερπροσαρμογή (overfitting), που είναι μια συχνή πρόκληση στην παραδοσιακή ενίσχυση κλίσης.

Η αλγοριθμική προσέγγιση του XGBoost για τη βελτιστοποίηση της συνάρτησης απώλειας στηρίζεται στην επέκταση Taylor δεύτερης τάξης. Αυτό παρέχει στους χρήστες τη δυνατότητα να διαμορφώνουν προσαρμοσμένες συναρτήσεις απώλειας, εισάγοντας παραμέτρους κλίσης και Hessian, όπως αναφέρουν οι Florek & Zagdanski (2023). Μια ιδιαίτερη παράμετρος, γνωστή ως γάμμα (gamma), καθορίζει το ελάχιστο όριο μείωσης της συνάρτησης απώλειας απαραίτητο για τη διάσπαση ενός κόμβου, εξισορροπώντας κατευθείαν τη πολυπλοκότητα του μοντέλου με τον κίνδυνο υπερπροσαρμογής. Ο αλγόριθμος διαίρεσης, σύμφωνα με τους Pellegrino et al. (2023) και Florek & Zagdanski (2023), με επίγνωση της αραιότητας των δεδομένων, διαχειρίζεται τις ελλείπουσες τιμές αγνοώντας αυτές κατά το στάδιο της διαίρεσης, επιτρέποντας την κατανομή τους σε οποιαδήποτε πλευρά των κόμβων. Αυτή η στρατηγική μειώνει αξιοσημείωτα τον χρόνο εκτέλεσης, συγκριτικά με άλλες υλοποιήσεις που δεν περιλαμβάνουν αντίστοιχες βελτιστοποιήσεις για αραιά δεδομένα.

Οι Bentéjac et al. (2023) και Boldini et al. (2023) υπογραμμίζουν τη σημασία της ορθής ρύθμισης των υπερπαραμέτρων για την επίτευξη υψηλών προγνωστικών επιδόσεων στο XGBoost. Οι υπερπαραμέτροι καθορίζουν τη δομή του μοντέλου, την πολυπλοκότητα των δέντρων και την ικανότητά του να γενικεύει. Κατά συνέπεια, τα μοντέλα που εκπαιδεύονται με τις προεπιλεγμένες παραμέτρους παρουσιάζουν αισθητή υστέρηση σε σύγκριση με εκείνα που έχουν βελτιστοποιηθεί. Δεδομένου ότι η συνάφεια και η επίδραση κάθε υπερπαραμέτρου ποικίλλει ανάλογα με το συγκεκριμένο σύνολο δεδομένων, η βελτίωση όσο το δυνατόν περισσότερων από αυτές θεωρείται ζωτικής σημασίας για την αύξηση της αποδοτικότητας του μοντέλου.

Το κύριο πλεονέκτημα της μεθόδου XGBoost δεν έγκειται μόνο στη λογική της ενίσχυσης (boosting), αλλά επιτυγχάνεται μέσω του συνδυασμού τακτικής κανονικοποίησης, βελτιστοποίησης δεύτερης τάξης και συστηματικών βελτιώσεων για παράλληλη, αραιή και εκτός μνήμης εκπαίδευση, σύμφωνα με τον Chen (2016). Η μεγαλύτερη ταχύτητα επιτυγχάνεται χάρη στα οργανωμένα μπλοκ στηλών, την παράλληλη συλλογή στατιστικών για διαχωριστικά σημεία, την αποτελεσματική χρήση της κρυφής μνήμης, την αναθεωρημένη τεχνική βαρών για ποσοστιαία κατανομή με σκοπό τον κατά προσέγγιση διαχωρισμό, καθώς και την αποδοτική διαχείριση αραιών δεδομένων. Σε σενάρια όπου τα δεδομένα είναι μεγάλα και αραιά, ο αλγόριθμος που λαμβάνει υπόψη την αραιότητα απέδειξε ότι είναι πάνω από 50 φορές πιο γρήγορος σε σύγκριση με μια απλοϊκή προσέγγιση. Επιπλέον, η βελτιστοποίηση που συνοψολογίζει τη χρήση της κρυφής μνήμης κατάφερε να διπλασιάσει την απόδοση σε μεγάλα σύνολα δεδομένων.

Ο συνδυασμός του XGBoost με το SHAP (SHapley Additive Explanations) μετατρέπει τα μοντέλα ενίσχυσης βαθμίδων από αδιαφανή σε διαφανή συστήματα, αναλύοντας ποσοτικά τη συνεισφορά κάθε χαρακτηριστικού σε κάθε χωριστή πρόβλεψη. Ο Kutlu et al. (2024) υποστηρίζει ότι το SHAP, το οποίο είναι βασισμένο στη θεωρία των συνεργατικών παιγνίων, αντιμετωπίζει κάθε χαρακτηριστικό ως συνεισφέρων παράγοντα και θεωρεί την τελική πρόβλεψη ως το σύνολο των τιμών SHAP όλων των χαρακτηριστικών μαζί με τη μέση πρόβλεψη. Ο αλγόριθμος TreeSHAP επιτρέπει τον αποτελεσματικό υπολογισμό των τιμών SHAP ειδικά για δέντρα απόφασης, καθιστώντας έτσι το XGBoost ένα από τα πλέον κατάλληλα μοντέλα για εφαρμογή με το SHAP, υποστηρίζει ο Li (2022).

3.6.2. Θεωρητική Βάση – Από το Gradient Boosting στο XGBoost

Το αντικείμενο της έρευνας αφορά την πρόκληση της πολυκλασικής ταξινόμησης με τέσσερις κλάσεις ($K = 4$ κλάσεις: Μη Κρίσιμο, Χαμηλής Ανθεκτικότητας, Κρίσιμο και Πολύ Κρίσιμο). Στόχος είναι η πρόβλεψη της κλάσης ανθεκτικότητας μιας Κρίσιμης Οντότητας χρησιμοποιώντας $p = 7$ δείκτες (AVAILABLE_SUBSET) και 12 κατηγορικές sector μεταβλητές. Εκτός από τη χρήση της Logistic Regression ως Baseline μοντέλου και της Random Forest, η ανάλυση επικεντρώθηκε επίσης στο XGBoost, εφαρμόζοντας το SHAP για την επεξήγηση των αποτελεσμάτων.

1. Προσθετικό Μοντέλο Ενίσχυσης

Το τελικό μοντέλο είναι άθροισμα K διαδοχικών δέντρων:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), \quad f_k \in \mathcal{F} \quad (27)$$

όπου, $\mathcal{F}$ είναι ο χώρος δέντρων παλινδρόμησης (CART⁴³ - Classification and Regression Trees) και x_i είναι το διάνυσμα των χαρακτηριστικών της οντότητας με τα 7 KPIs και τις 12

⁴³ Τα δέντρα παλινδρόμησης και ταξινόμησης (CART) συνιστούν μια δημοφιλή μη παραμετρική προσέγγιση μηχανικής μάθησης για την πρόβλεψη αριθμητικών τιμών ή κατηγοριών. Το σύνολο $\mathcal{F}$ αντιπροσωπεύει τον χώρο των ενδεχόμενων

κατηγορικές sector μεταβλητές. Η εξίσωση αυτή δεικνύει ότι η πρόβλεψη για την οντότητα i δεν προέρχεται από ένα μεμονωμένο μοντέλο, αλλά δημιουργείται μέσω του αθροίσματος πολλών μικρών δέντρων απόφασης. Κάθε f_k αντιπροσωπεύει ένα ξεχωριστό δέντρο απόφασης (το k -οστό από τα συνολικά K , δηλαδή τον αριθμό των $n_estimators$). Η λογική του boosting βασίζεται στο ότι το πρώτο δέντρο δίνει μια αρχική εκτίμηση, το επόμενο διορθώνει τα λάθη του προηγούμενου και ούτω καθεξής, ενώ το τελικό αποτέλεσμα προκύπτει από το άθροισμα και όχι από τον μέσο όρο, όπως γίνεται στο μοντέλο Random Forest.

Στην περίπτωση μας, που έχουμε πολυκλασική εκδοχή (`objective = 'multi:softprob'`, `num_class = 4`), εκπαιδεύονται K ξεχωριστά σύνολα δέντρων (ένα ανά κλάση) σε κάθε γύρο. Η τελική πιθανότητα υπολογίζεται μέσω της μεθόδου Softmax, σύμφωνα με την επόμενη εξίσωση:

$$P(y = c | x) = \frac{\exp(f_c(x))}{\sum_{j=1}^4 \exp(f_j(x))} \quad (28)$$

Εφόσον έχουμε 4 κλάσεις, δεν αρκεί να χρησιμοποιήσουμε απλώς ένα σύνολο δέντρων. Χρειάζονται τέσσερα παράλληλα σύνολα δέντρων, δηλαδή έναν υπολογισμό (score) $f_c(x)$ για κάθε κλάση. Η Softmax λειτουργία αναλαμβάνει να μετατρέψει αυτά τα τέσσερα ακατέργαστα αποτελέσματα σε πιθανότητες που αθροίζουν στο 1. Αυτό γίνεται λαμβάνοντας τον εκθετικό κάθε αποτελέσματος (ώστε να είναι πάντα θετικό) και στη συνέχεια καταμερίζοντας αυτόν τον αριθμό διαιρώντας τον με το άθροισμα όλων των εκθετικών. Έτσι, η κλάση με το μεγαλύτερο αποτέλεσμα λαμβάνει και την υψηλότερη πιθανότητα. Αυτή είναι ακριβώς η λειτουργία που υλοποιεί το `multi:softprob` στον κώδικα.

2. Αντικειμενική Συνάρτηση

Η αντικειμενική συνάρτηση δίνεται από την εξίσωση:

$$\mathcal{L}(\varphi) = \sum_i \ell(y_i, \hat{y}_i) + \sum_k \Omega(f_k) \quad (29)$$

Αυτό είναι το στοιχείο που προσπαθεί να ελαχιστοποιήσει ο αλγόριθμος. Αποτελείται από δύο μέρη:

1. $\sum_i \ell(y_i, \hat{y}_i)$ - Σφάλμα Πρόβλεψης: Το άθροισμα των σφαλμάτων πρόβλεψης για κάθε δεδομένο στο σύνολο δεδομένων. Αυτό αντιπροσωπεύει το πόσο λανθασμένα εκτιμά το μοντέλο την πρόβλεψη για κάθε οντότητα.
2. $\sum_k \Omega(f_k)$ - Ποινή Πολυπλοκότητας: Το άθροισμα της ποινής πολυπλοκότητας για κάθε δέντρο στο μοντέλο. Αυτή η ποινή προσθέτει ένα κόστος για την πολυπλοκότητα του μοντέλου, προάγοντας απλούστερες και πιο γενικές λύσεις.

Το δεύτερο χαρακτηριστικό (όρος κανονικοποίησης), που καθιστά το XGBoost ξεχωριστό, αφορά την ικανότητά του όχι μόνο να μειώνει το σφάλμα, αλλά να επιτυγχάνει αυτό το στόχο χωρίς να δημιουργεί υπερβολικά πολύπλοκα δέντρα, τα οποία θα μπορούσαν να οδηγούν σε υπερπροσαρμογή στα δεδομένα εκπαίδευσης.

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \|\omega\|^2 + \alpha \|\omega\|_1 \quad (30)$$

όπου, το T αντιπροσωπεύει τον αριθμό των φύλλων, το ω αναφέρεται στα βάρη των φύλλων, και γ δηλώνει την ποινή ανά φύλλο. Οπότε οι τρεις όροι ποινής είναι:

1. γT - ποινή ανά φύλλο. Όσο περισσότερα φύλλα T έχει ένα δέντρο, τόσο μεγαλύτερη είναι η ποινή. Αποθαρρύνει τα υπερβολικά «φουντωτά» δέντρα.
2. $\frac{1}{2} \lambda \|\omega\|^2$ - Η L2 (Ridge) κανονικοποίηση, στον κώδικα συμβολίζεται ως `reg_lambda`, επηρεάζει τα βάρη ή τις τιμές που αποδίδεται σε κάθε φύλλο. Με την προσθήκη του αθροίσματος των τετραγώνων των βαρών στο μοντέλο, αποφεύγονται οι ακραίες, υπερβολικές τιμές. Αυτό έχει ως αποτέλεσμα το μοντέλο να κάνει πιο «μετριοπαθείς» προβλέψεις για κάθε φύλλο, αντί για ακραίες εκτιμήσεις.
3. $\alpha \|\omega\|_1$ - Η L1 (Lasso) κανονικοποίηση, στον κώδικα συμβολίζεται ως `reg_alpha`, επιβάλλει ποινή στο άθροισμα των απόλυτων τιμών των βαρών. Αυτή η διαδικασία οδηγεί στην προώθηση ορισμένων βαρών προς το απόλυτο μηδέν, δημιουργώντας αραιότητα.

Το μέτρο απώλειας χρησιμοποιεί πολυκλασική cross-entropy (`eval_metric = 'mlogloss'`):

$$\ell(y_i, \hat{y}_i) = - \sum_{c=1}^4 1[y_i = c] \cdot \log(p_{i,c}) \quad (31)$$

Η έκφραση $1[y_i = c]$ έχει τιμή 1 όταν η πραγματική κλάση της οντότητας i είναι c , διαφορετικά έχει τιμή 0. Στην πράξη, αυτό συνεπάγεται ότι στο άθροισμα παραμένει μόνο ένας όρος: το $-\log(p_{i, \text{σωστή κλάση}})$. Δηλαδή, λαμβάνεται η πιθανότητα που ανέθεσε το μοντέλο στη σωστή κλάση και την τιμωρείται λογαριθμικά. Αν το μοντέλο έχει αποδώσει υψηλή πιθανότητα (κοντά στο 1) στην ορθή κλάση, το $-\log$ είναι μικρό (καλό). Αντίθετα, αν η πιθανότητα είναι χαμηλή (κοντά στο 0), το $-\log$ αυξάνεται σημαντικά (κακό). Αυτό αποτελεί το `mlogloss` του κώδικα.

3. Προσεγγιστική Βελτιστοποίηση Δεύτερης Τάξης (Newton Boosting)

Σε κάθε γύρο t , η απώλεια προσεγγίζεται με το ανάπτυγμα Taylor 2ης τάξης γύρω από την τρέχουσα πρόβλεψη:

$$\mathcal{L}^{(t)} \approx \sum_i \left[\ell(y_i, \hat{y}_i^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t(x_i)^2 \right] + \Omega(f_t) \quad (32)$$

Το πρόβλημα που χρίζει αντιμετώπισης είναι η αδυναμία άμεσης επίλυσης του θέματος «ποιο είναι το βέλτιστο επόμενο δέντρο» στο πλαίσιο των αλγορίθμων. Για να αντιμετωπιστεί αυτό,

το XGBoost υιοθετεί μια τεχνική προσέγγιση. Γύρω από το τρέχον σημείο, εκτιμά την απώλεια μέσω μιας προσεγγιστικής διαδικασίας χρήσης πολωνύμου 2ου βαθμού, κατά τρόπο ανάλογο με τη μέθοδο του Taylor για την προσεγγιστική αναπαράσταση καμπύλης με παραβολική μορφή.

Ο όρος $g_i f_t(x_i)$ λειτουργεί ως γραμμική προσέγγιση, αντικατοπτρίζοντας τη κλίση, ενώ ο όρος $\frac{1}{2} h_i f_t(x_i)^2$ αφορά τη διορθωτική καμπυλότητα. Με την ταυτόχρονη αξιοποίηση και των δύο αυτών όρων, αντί για την αποκλειστική χρήση της κλίσης όπως στα συμβατικά GBM⁴⁴, το μοντέλο επιτυγχάνει μια πιο ακριβή κατεύθυνση στην προσέγγισή του. Είναι μια διαδικασία που μπορεί να παραλληλιστεί με τη χρήση της μεθόδου Newton αντί της απλής gradient descent.

$$g_i = \partial_{\hat{y}^{(t-1)}} \ell(y_i, \hat{y}_i^{(t-1)}), \quad h_i = \partial_{\hat{y}^{(t-1)}}^2 \ell(y_i, \hat{y}_i^{(t-1)}) \quad (33)$$

όπου, g_i είναι η πρώτη (1η) παράγωγος της απώλειας σε σχέση με την τρέχουσα πρόβλεψη και δείχνει την κατεύθυνση στην οποία πρέπει να αλλάξει η πρόβλεψη για να μειωθεί το σφάλμα. Ενώ το h_i είναι η δεύτερη (2η) παράγωγος και δείχνει πόσο αποφασιστικά ή απότομα ισχύει αυτό, δηλαδή πόσο ευαίσθητη είναι η απώλεια σε μεταβολές. Αυτά τα δύο μεγέθη υπολογίζονται για κάθε οντότητα σε κάθε επανάληψη, πριν δημιουργηθεί το επόμενο δέντρο.

Για δεδομένη δομή δέντρου με σύνολα φύλλων I_j , το βέλτιστο βάρος φύλλου και η ελάχιστη απώλεια σε κλειστή μορφή, δίνεται από την εξίσωση:

$$\omega_j^* = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (34)$$

Αφού καθοριστεί η δομή ενός δέντρου και συγκεκριμένα σε ποιο φύλλο I_j κατατάσσονται οι οντότητες, μπορεί να χρησιμοποιηθεί ένας ειδικός τύπος για να καθορίσει την ακριβή τιμή που πρέπει να πάρει κάθε φύλλο, χωρίς ανάγκη για επαναληπτική βελτιστοποίηση. Αυτή είναι μια αναλυτική λύση. Στον αριθμητή αθροίζονται τα παράγωγα (gradients) των οντοτήτων του φύλλου, ενώ στον παρονομαστή βρίσκονται τα Hessians συν την παράμετρο λ (δηλαδή την L2 ποινή). Όσο αυξάνεται η παράμετρος λ , τόσο πιο περιορισμένο ή μικρό γίνεται το ω_j^* , γεγονός που αντικατοπτρίζει ακριβώς τον τρόπο λειτουργίας του reg_lambda στην πράξη.

$$\mathcal{L}^{*(t)} = - \frac{1}{2} \sum_j \frac{\left(\sum_{i \in I_j} g_i \right)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T \quad (35)$$

⁴⁴ Στον τομέα της μηχανικής μάθησης, η τεχνική της ενίσχυσης κλίσης (gradient boosting) που εφαρμόζεται στα παραδοσιακά Gradient Boosting Machines (GBM) αξιοποιεί την αρνητική κλίση της συνάρτησης απώλειας. Αυτό επιτρέπει την εκπαίδευση νέων, απλών μοντέλων κατά τρόπο διαδοχικό, ώστε να διορθωθούν τα σφάλματα των προηγούμενων μοντέλων.

Αξιολογεί πόσο καλό είναι ολόκληρο το δέντρο βάσει της δομής του, παρέχοντας έτσι ένα μέσο σύγκρισης εναλλακτικών δομών δέντρου κατά τη διαδικασία κατασκευής τους.

Το κριτήριο κέρδους διάσπασης (split gain), με τις υποκλάσεις αριστερό και δεξί σύνολο L , R :

$$Gain = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (36)$$

Αυτός αποτελεί τον πιο θεμελιώδη τύπο και χρησιμοποιείται εκατομμύρια φορές κατά τη διάρκεια της εκπαίδευσης, κάθε φορά που ο αλγόριθμος καλείται να αποφασίσει σχετικά με τη διάσπαση ενός κόμβου. Η βασική ιδέα είναι ότι όταν χωρίζεται ένας κόμβος σε αριστερό (L) και δεξί (R) τμήμα, συγκρίνεται η απώλεια πριν τη διάσπαση, δηλαδή οι όροι που περιλαμβάνουν τους συντελεστές $G_L + G_R$ και $H_L + H_R$, με την απώλεια μετά τη διάσπαση, όπου οι δύο πρώτοι όροι υπολογίζονται ξεχωριστά για τα L και R τμήματα. Εάν η διαφορά, γνωστή ως $Gain$, είναι θετική και μεγαλύτερη από το γ (που αποτελεί την ποινή για τη δημιουργία ενός νέου φύλλου), τότε το χώρισμα θεωρείται ωφέλιμο. Κατά τη διαδικασία αυτή, ο αλγόριθμος εξετάζει πολλαπλά υποψήφια σημεία χωρίσματος και επιλέγει αυτό με το μεγαλύτερο $Gain$.

Η παράμετρος `min_child_weight` καθορίζει το ελάχιστο όριο που πρέπει να ικανοποιήσει ένα φύλλο για να επιτρέπεται η διάσπαση του. Η παράμετρος ορίζει ότι δεν επιτρέπεται η διάσπαση εάν το H_L ή το H_R (το άθροισμα των Hessians σε ένα από τα δύο νέα φύλλα) είναι μικρότερο από την τιμή $X = [1, 3, 5]$. Με τον τρόπο αυτόν αποτρέπεται η δημιουργία φύλλων που βασίζονται σε πολύ λιγότες ή αβέβαιες παρατηρήσεις. Αυτή η διαδικασία λειτουργεί ως μηχανισμός για την αποτροπή της υπερπροσαρμογής.

4. Ο Ρόλος του Learning Rate

Μετά τον υπολογισμό του νέου δέντρου f_t , αυτό δεν προστίθεται άμεσα στη συνολική πρόβλεψη. Αντίθετα, πολλαπλασιάζεται αρχικά με τον παράγοντα η , που αποτελεί το ρυθμό μάθησης (`learning_rate`), σύμφωνα με την εξίσωση

$$\hat{y}^{(t)} = \hat{y}^{(t-1)} + \eta \cdot f_t(x) \quad (37)$$

Αυτή η προσέγγιση υποδηλώνει ότι κάθε δέντρο συμβάλλει με ένα μικρό βήμα προς την επιθυμητή κατεύθυνση. Ένας μικρότερος ρυθμός μάθησης η συνεπάγεται συντηρητικότερα βήματα, απαιτώντας την εκπαίδευση περισσότερων δέντρων ($K/n_estimators$) για να επιτευχθεί το ίδιο επίπεδο ακρίβειας στο μοντέλο. Ωστόσο, αυτή η μέθοδος συχνά οδηγεί σε καλύτερη γενίκευση, καθώς το μοντέλο αποφεύγει την υπερβολική προσαρμογή στα δεδομένα εκπαίδευσης.

3.6.3. Βελτιστοποίηση Υπερπαραμέτρων (Hyperparameter Tuning) - RandomizedSearchCV έναντι Grid Search

Η παραμετρική διαμόρφωση της `xgb_param_dist` προσδιορίζεται από ένα οκταδιάστατο πεδίο αναζήτησης που περιλαμβάνει τις εξής παραμέτρους: `n_estimators` (3 επίπεδα) $\times$ `max_depth` (4 επίπεδα) $\times$ `learning_rate` (4 επίπεδα) $\times$ `subsample` (3 επίπεδα) $\times$ `colsample_bytree` (3 επίπεδα) $\times$ `min_child_weight` (3 επίπεδα) $\times$ `reg_alpha` (3 επίπεδα) $\times$ `reg_lambda` (3 επίπεδα). Συνολικά, αυτοί οι παράγοντες δημιουργούν 34.992 διαφορετικούς συνδυασμούς. Παρόλα αυτά, η τυχαία δειγματοληψία με `n_iter = 10` επιλέγει μόνο 10 σημεία (~0,03% του συνολικού χώρου), στηριζόμενη στη μελέτη των Bergstra & Bengio (2012), η οποία δείχνει ότι αυτή η μέθοδος συχνά φτάνει γρήγορα σε περιοχές με καλή απόδοση, σε σύγκριση με την πλήρη αναζήτηση πλέγματος.

Κάθε επιλεγμένος συνδυασμός αξιολογείται μέσω εσωτερικής διασταυρούμενης επαλήθευσης με τρεις πτυχές 3-fold CV (`cv=3`) στο εκπαιδευτικό σύνολο δεδομένων `X_train`, με το κριτήριο αξιολόγησης να είναι το `scoring = 'f1_macro'`. Ο συνδυασμός με την καλύτερη απόδοση, δηλαδή το `best_estimator_`, υποβάλλεται σε εκ νέου αξιολόγηση με πλήρη διασταυρούμενη επαλήθευση πέντε πτυχών 5-fold StratifiedKFold στο συνολικό σύνολο δεδομένων.

Πίνακας 3.6: Ο ρόλος των υπερπαραμέτρων XGBoost.

Υπερπαραμέτρος	Τιμές στον Κώδικα	Ρόλος
<code>n_estimators</code>	{300, 400, 500}	Πλήθος γύρων ενίσχυσης K
<code>max_depth</code>	{4, 5, 6, 7}	Το μέγιστο βάθος κάθε f_k αναφέρεται στις αλληλεπιδράσεις χαρακτηριστικών.
<code>learning_rate</code> (η)	{0.01, 0.03, 0.05, 0.1}	Η συνάρτηση επαναλαμβανόμενης βελτιστοποίησης μπορεί να περιγραφεί ως εξής: $\hat{y}^{(t)} = \hat{y}^{(t-1)} + \eta \cdot f_t(x)$
<code>subsample</code>	{0.7, 0.85, 1.0}	Τυχαία δειγματοληψία γραμμών ανά δέντρο
<code>colsample_bytree</code>	{0.6, 0.8, 1.0}	Τυχαία δειγματοληψία στηλών ανά δέντρο
<code>min_child_weight</code>	{1, 3, 5}	Ελάχιστο άθροισμα Hessian ανά φύλλο
<code>reg_alpha</code> (α)	{0.0, 0.1, 0.5}	L1 (Lasso) κανονικοποίηση — αραιότητα βαρών
<code>reg_lambda</code> (λ)	{0.5, 1.0, 2.0}	L2 (Ridge) κανονικοποίηση — εμφανίζεται στο ω_j^*

3.7. Μετρικές Αξιολόγησης Μοντέλων Μηχανικής Μάθησης με Δείκτες Απόδοσης και Στατιστικής Επικύρωσης

Η αξιολόγηση της απόδοσης των μοντέλων ταξινόμησης συνιστά θεμελιώδες στάδιο στη μεθοδολογία που εξετάζεται, διότι προσφέρει αντικειμενική βάση για τη σύγκριση διαφορετικών αλγορίθμων, καθώς και την τεκμηρίωση της αξιοπιστίας τους. Στην παρούσα ενότητα γίνεται λεπτομερής παρουσίαση βασικών μετρικών για την πολυκλασική ταξινόμηση, όπως η ακρίβεια (`precision`), η ανάκληση (`recall`), το F1-score και η συνολική απόδοση (`accuracy`), ενώ εξετάζονται και οι συγκεντρωτικοί δείκτες `macro avg` και `weighted`

avg. Ιδιαίτερη έμφαση δίνεται στο macro-F1 score, το οποίο επιλέγεται ως κύριο κριτήριο σύγκρισης λόγω της σχεδόν ισοπληθούς κατανομής των κλάσεων ανθεκτικότητας. Παράλληλα, αναλύεται η μεθοδολογική διάκριση μεταξύ της εκτίμησης απόδοσης σε ένα μεμονωμένο σύνολο ελέγχου (holdout) και της πιο απαιτητικής εκτίμησης που γίνεται μέσω στρωματοποιημένης διασταυρούμενης επικύρωσης (stratified k-fold cross-validation). Αυτή η ανάλυση σκοπό έχει να αξιολογηθεί όχι μόνο το επίπεδο απόδοσης, αλλά και η σταθερότητα και η ικανότητα γενίκευσης κάθε αλγορίθμου. Τέλος, παρουσιάζεται η ανάλυση της τιμής Shapley, που αναδεικνύεται ως ένα ουσιαστικό εργαλείο για την αποτίμηση της επεξηγηματικής δυναμικής στην τεχνητή νοημοσύνη.

1. Ορισμός Πλαισίου του Προβλήματος

Η παρούσα έρευνα επικεντρώνεται σε ένα πρόβλημα πολυκλασικής ταξινόμησης (multiclass classification) με τέσσερις (4) κλάσεις. Οι κλάσεις προκύπτουν από τα τεταρτημόρια του συνεχούς δείκτη CRI_score, μέσα από τη διαδικασία `pd.qcut(..., q=4)`, διασφαλίζοντας ότι είναι πάντα ίσου μεγέθους (25% για κάθε κλάση). Αυτή η ισότητα επηρεάζει σημαντικά την ερμηνεία του δείκτη macro-F1, θέμα που θα αναλυθεί περαιτέρω. Η αξιολόγηση γίνεται μέσω της συνάρτησης `evaluate_model()`, με το `classification_report` να παρέχει λεπτομερή στοιχεία για precision, recall, f1-score και support ανά κλάση, καθώς και συνολικά αποτελέσματα για accuracy, macro average και weighted average.

2. Θεμελιώδη Μεγέθη ανά Κλάση (One-vs-Rest)

Το πρόβλημα το οποίο εξετάζουμε περιλαμβάνει τέσσερις κλάσεις ταυτόχρονα: Μη Κρίσιμο, Χαμηλής Ανθεκτικότητας, Κρίσιμο και Πολύ Κρίσιμο. Ωστόσο, οι μετρικές τύπου Precision, Recall και F1-score είναι εκ φύσεως σχεδιασμένες για δυαδικά προβλήματα, δηλαδή για καταστάσεις όπου υπάρχουν μόνο δύο πιθανές εκβάσεις. Κατά συνέπεια, για κάθε κλάση K (όπου $k = 1, 2, 3, 4$), οι μετρικές αυτές προσδιορίζονται με την αντιμετώπιση της κλάσης K ως θετικής και όλων των υπόλοιπων κατηγοριών ως αρνητικές, σε μια προσέγγιση one-vs-rest. Η τεχνική μία-εναντίον-όλων (one-vs-rest) λειτουργεί μετατρέποντας ένα πολυκλασικό πρόβλημα σε πολλά μικρότερα δυαδικά προβλήματα, το καθένα εκ των οποίων αντιστοιχεί σε μία κλάση.

Πίνακας 3.7: Η τεχνική One-vs-Rest στην περίπτωση πολυκλασικής ταξινόμησης.

Πραγματική Κλάση	Πως αντιμετωπίζεται για τον υπολογισμό Πολύ Κρίσιμο
Πολύ Κρίσιμο	Θετική (Positive)
Κρίσιμο	Αρνητική (Negative)
Χαμηλής Ανθεκτικότητας	Αρνητική (Negative)
Μη Κρίσιμο	Αρνητική (Negative)

Με άλλα λόγια, το ερώτημα γίνεται σαφώς δυαδικό, καθώς αφορά στη διάκριση της οντότητας ως Πολύ Κρίσιμο ή όχι (δηλαδή, οποιαδήποτε άλλη κατάσταση).

Σε αυτό το αναδιαμορφωμένο δυαδικό πλαίσιο, μπορεί πλέον να διατυπωθεί με ακρίβεια το εξής:

- **TP_k (True Positive):** Πλήθος οντοτήτων που πράγματι ανήκουν στην κλάση (k) και προβλέφθηκαν σωστά ως (k). Παραδείγματος χάριν, πραγματικά Πολύ Κρίσιμο και προβλέφθηκε Πολύ Κρίσιμο.
- **FP_k (False Positive):** Πλήθος οντοτήτων άλλης πραγματικής κλάσης που προβλέφθηκαν λανθασμένα ως (k). Παραδείγματος χάριν, πραγματικά κάποια άλλη κλάση (Μη Κρίσιμο, Χαμηλής Ανθεκτικότητας ή Κρίσιμο) και προβλέφθηκε λανθασμένα Πολύ Κρίσιμο.
- **FN_k (False Negative):** Πλήθος οντοτήτων που πράγματι ανήκουν στην (k) αλλά προβλέφθηκαν σε άλλη κλάση. Παραδείγματος χάριν, πραγματικά Πολύ Κρίσιμο και προβλέφθηκε λανθασμένα κάποια άλλη κλάση.
- **$Support_k = TP_k + FN_k$:** Το πραγματικό πλήθος δειγμάτων της κλάσης (k) στο test set (y_{test}).

Στον κώδικα, το σύνολο δεδομένων y_{test} δημιουργήθηκε μέσω της συνάρτησης `train_test_split(..., stratify=y_encoded, test_size=0.25)`. Ως εκ τούτου, η κατανομή των υποδεικνυομένων Support ανά κλάση στο test set αντιπροσωπεύει τη στρωματοποιημένη κατανομή του συνολικού dataset.

Η προαναφερόμενη διαδικασία επαναλαμβάνεται τέσσερις φορές, εστιάζοντας διαδοχικά σε κάθε κλάση ως θετική (μία φορά για την κλάση Πολύ Κρίσιμο έναντι όλων των υπολοίπων, μία φορά για την κλάση Κρίσιμο έναντι όλων, κ.λπ.). Αυτή η προσέγγιση παράγει τέσσερα διακριτά σύνολα δεικτών Precision, Recall και F1, το καθένα αντιστοιχίζοντας σε μία γραμμή του `classification_report`. Στη συνέχεια, τα αποτελέσματα υπολογίζονται αθροιστικά για τη δημιουργία του macro-F1 μέσω του απλού μέσου όρου των τεσσάρων επιμέρους δεικτών.

3. Precision, Recall και F1-score ανά Κλάση

Ακρίβεια Πρόβλεψης (Precision)

$$Precision_k = \frac{TP_k}{TP_k + FP_k} \quad (38)$$

Δηλαδή, από τις οντότητες που το μοντέλο προέβλεψε ότι ανήκουν στην κλάση (k), τι ποσοστό ανήκε πραγματικά εκεί. Αυτό μετρά το «κόστος των ψευδών συναγερμών».

Ανάκληση / Ευαισθησία (Recall)

$$Recall_k = \frac{TP_k}{TP_k + FN_k} \quad (39)$$

Δηλαδή, από όσες οντότητες που πραγματικά ανήκουν στην κλάση (k), ποιο ποσοστό εντοπίστηκε σωστά. Στο πλαίσιο CRI, το Recall για την κλάση Πολύ Κρίσιμο έχει σημαντική

πρακτική και κανονιστική σημασία, καθώς ένα False Negative σε αυτήν τη περίπτωση σημαίνει ότι μια πραγματικά πολύ ευάλωτη οντότητα κατατάσσεται λανθασμένα ως λιγότερο κρίσιμη.

Αρμονικός Μέσος Precision-Recall (F1-score)

$$F1_k = 2 \cdot \frac{Precision_k \cdot Recall_k}{Precision_k + Recall_k} \quad (40)$$

Ο αρμονικός μέσος (όχι αριθμητικός) χρησιμοποιείται επειδή τιμωρεί περισσότερο τις περιπτώσεις όπου ένα από τα δύο μεγέθη είναι ιδιαίτερα χαμηλό. Με άλλα λόγια, ένα μοντέλο δεν μπορεί να επιτύχει υψηλό F1 καλύπτοντας χαμηλό Recall με υψηλό Precision ή το αντίθετο.

Το $zero_division = 0$ στον κώδικα, σημαίνει ότι σε περίπτωση διαίρεσης με το μηδέν για κάποια κλάση (π.χ. καμία πρόβλεψη σε αυτή την κλάση, με αποτέλεσμα $Precision_k = \frac{0}{0}$), η τιμή ορίζεται στο 0 αντί να προκαλέσει σφάλμα ή NaN.

4. Συνολική Ακρίβεια (Accuracy)

$$Accuracy = \frac{\sum_{k=1}^4 TP_k}{N_{test}} \quad (41)$$

Όπου, N_{test} είναι το συνολικό πλήθος δειγμάτων $hold - out\ test\ set = 0.25 \cdot n_{samples}$. Πρόκειται για το συνολικό ποσοστό σωστών προβλέψεων, ανεξαρτήτως κλάσης. Δεν εμφανίζεται στον τελικό πίνακα σύγκρισης του σεναρίου, αλλά μόνο στο λεπτομερές `classification_report` κάθε μοντέλου. Ο πίνακας συγκρίσεων βασίζεται αποκλειστικά στο macro-F1.

5. Macro Average vs Weighted Average

Αυτές οι δύο γραμμές από το `classification_report` συνοψίζουν τις τιμές ανά κλάση (Precision, Recall, F1) σε μια ενιαία τιμή, αλλά με διαφορετική προσέγγιση στη στάθμιση:

Macro Average

$$Macro - X = \frac{1}{K} \sum_{k=1}^K X_k \quad \mu\epsilon \ K = 4 \quad (42)$$

όπου, το X αντιπροσωπεύει το Precision, το Recall ή το F1. Κάθε κλάση διατηρεί ίσες βαρύτητες ($1/4$), ανεξάρτητα από τον αριθμό δειγμάτων (support) που διαθέτει. Αυτό είναι ιδιαίτερα σημαντικό όταν μας ενδιαφέρει εξίσου η επίδοση σε σπάνιες αλλά σημαντικές κλάσεις, όπως για παράδειγμα η κλάση Πολύ Κρίσιμο. Με αυτή την προσέγγιση,

αποφεύγουμε την κατάσταση όπου η κλάση με τα περισσότερα δείγματα θα καλύψει την αδύναμη επίδοση μιας μικρότερης κλάσης.

Weighted Average

$$Weighted - X = \sum_{k=1}^K \frac{n_k}{N_{test}} \cdot X_k \quad \mu\epsilon \quad n_k = Support_k \quad (43)$$

Κάθε κλάση σταθμίζεται ανάλογα με το μέγεθος της στο test set. Στη περίπτωση μας οι κλάσεις να είναι σχεδόν ίσου μεγέθους (τεταρτημόρια), ο σταθμισμένος μέσος όρος (weighted avg) είναι σχεδόν ίσως με τον μακρο-μέσο όρο (macro avg). Μια σημαντική διαφορά θα προέκυπτε μόνο αν υπήρχε μεγάλη ανισορροπία στις κλάσεις, κάτι που αποφεύγεται από την αρχή μέσω της χρήσης του `pd.qcut`.

6. Μετρική Αξιολόγησης Macro-F1 Score ως Κεντρική Μετρική

Το *macro - F1* αποτελεί τον μη σταθμισμένο μέσο όρο των μετρικών $F1_k$ για τις $K = 4$ κλάσεις. Δεδομένου ότι δεν γίνεται στάθμιση αναλόγως του αριθμού παρατηρήσεων σε κάθε κλάση, μια μειοψηφούσα κλάση, όπως αυτή με λιγότερες οντότητες στην κλάση Πολύ Κρίσιμο, έχει την ίδια βαρύτητα με μια πλειοψηφούσα. Αυτή η προσέγγιση αποτρέπει το μοντέλο από το να αποκρύψει υποδεέστερη απόδοση σε σπάνιες αλλά κρίσιμης σημασίας κλάσεις.

$$macro - F1 = \frac{1}{K} \sum_{k=1}^K F1_k \quad \rightarrow$$
$$macro - F1 = \frac{1}{4} (F1_{Μη \ Κρίσιμο} + F1_{Χαμηλής \ Ανθεκτικότητας} + F1_{Κρίσιμο} + F1_{Πολύ \ Κρίσιμο}) \quad (44)$$

Η επιλογή της ως ενιαίας μετρικής αξιολόγησης `scoring = 'f1_macro'`, η οποία χρησιμοποιείται τόσο στο `RandomizedSearchCV` όσο και στο `cross_val_score`, πραγματοποιήθηκε για τους εξής λόγους:

1. Πρόκειται για πρόβλημα πολλών κλάσεων, και
2. Το πρόβλημα που μας απασχολεί είναι πολυσύνθετο και απαιτεί την εξασφάλιση ισότιμης σημασίας για όλες τις κλάσεις ανθεκτικότητας. Αυτό περιλαμβάνει ιδιαίτερα τις πιο ακραίες κλάσεις, όπως Πολύ Κρίσιμο, οι οποίες έχουν μεγαλύτερη κανονιστική και πρακτική βαρύτητα στο πλαίσιο των οδηγιών CER/NIS2.

7. Holdout vs Mean – Δύο Διαιφορετικοί Εκτιμητές της Ίδιας Μετρικής

Στην παρούσα περίπτωση υπολογίζονται δύο ανεξάρτητες εκτιμήσεις του *macro – F1* για κάθε μοντέλο, οι οποίες στη συνέχεια αποθηκεύονται στο λεξικό `results`⁴⁵:

1. Holdout Macro-F1

Σε αυτή την περίπτωση το μοντέλο που έχει εκπαιδευτεί στο `train set`, κάνει προβλέψεις στο `test set` και υπολογίζει την ακρίβεια των προβλέψεων σε σχέση με την πραγματικότητα. Αυτό αναφέρεται ως το `hold-out macro-F1` και πρόκειται για έναν και μοναδικό διαχωρισμό δεδομένων.

$$X, y \xrightarrow{\text{train_test_split}(75\% / 25\%, \text{stratify})} (X_{\text{train}}, y_{\text{train}}), (X_{\text{test}}, y_{\text{test}})$$

Αρχικά λαμβάνεται όλο το `dataset`, με τα χαρακτηριστικά X και τις ετικέτες y με όλες τις `n_samples` οντότητες. Στο `train_test_split` το μοντέλο εκπαιδεύεται στο 75% ($\approx \frac{3 \cdot n_{\text{samples}}}{4}$ οντότητες) και αξιολογείται μία μόνο φορά στο μη ορατό 25% ($\approx \frac{n_{\text{samples}}}{4}$ οντότητες). Το `stratify` διασφαλίζει ότι η αναλογία των 4 κλάσεων διατηρείται σταθερή και στα δύο τμήματα. Δηλαδή εάν η κλάση Πολύ Κρίσιμο είναι 25% στο συνολικό `dataset`, θα παραμείνει ~25% και στο `train` και ~25% στο `test`.

Ο όρος μη ορατό χρησιμοποιείται γιατί το μοντέλο δεν έχει δει τα συγκεκριμένα δεδομένα κατά τη φάση της εκπαίδευσης και δεν έχει προηγούμενη γνώση αυτών. Αυτή η προσέγγιση είναι κρίσιμη για να διασφαλιστεί η αμεροληψία στην αξιολόγηση, καθώς εάν το μοντέλο αξιολογηθεί πάνω σε δεδομένα που έχει ήδη συναντήσει κατά την εκπαίδευσή του, το αποτέλεσμα της αξιολόγησης θα ήταν τεχνητά διογκωμένο (υπερβολικά καλό `score`), απλώς επειδή το μοντέλο έχει αποστηθίσει τις πληροφορίες.

$$\text{holdout macro} - F1 = \text{macro} - F1(f(X_{\text{train}}, y_{\text{train}}), X_{\text{test}}, y_{\text{test}})$$

Στο $f(X_{\text{train}}, y_{\text{train}})$, το f αντιπροσωπεύει το εκπαιδευμένο μοντέλο, το οποίο προκύπτει από τη διαδικασία κατά την οποία ένας αλγόριθμος, όπως η Logistic Regression, το Random Forest ή το XGBoost, εκτίθεται σε δεδομένα εκπαίδευσης. Στον κώδικα, αυτή η διαδικασία συνίσταται στα βήματα: α) `baseline_pipeline.fit(X_train, y_train)` για τη Logistic Regression, β) `rf_search.fit(X_train, y_train)` για το Random Forest, και γ) `xgb_search.fit(X_train, y_train)` για το XGBoost.

Μετά την εκπαίδευση, το ήδη εκπαιδευμένο μοντέλο f δεν ξαναβλέπει ποτέ το X_{train} . Αντιθέτως, χρησιμοποιείται αποκλειστικά για την παραγωγή προβλέψεων στο X_{test} , δηλαδή εφαρμόζει `y_pred = model.predict(X_test)`, που αποτελεί σύνολο δεδομένων τα οποία το μοντέλο δεν έχει συναντήσει προηγουμένως. Οι προβλέψεις συγκρίνονται με τις πραγματικές ετικέτες y_{test} , και υπολογίζεται το *macro – F1*, που είναι ο μέσος όρος των F1 για κάθε κλάση.

⁴⁵ `results["..."] = {'Holdout': macro_f1, 'CV_mean': cv_scores.mean(), 'CV_std': cv_scores.std()}`

2. Μέσος Όρο και Τυπική Απόκλιση 5-Fold CV

Η ανάλυση βασίζεται σε πλήρη 5-fold⁴⁶ στρωματοποιημένη διασταυρούμενη επικύρωση η οποία εφαρμόστηκε στο συνολικό σύνολο δεδομένων και όχι αποκλειστικά στο τμήμα εκπαίδευσης. Το σύνολο δεδομένων χωρίζεται σε 5 στρωματοποιημένα υποσύνολα (folds) $F_1, F_2, \dots, F_5$, ίσου μεγέθους χρησιμοποιώντας τη μέθοδο StratifiedKFold($n_splits = 5$). Η χρήση της τεχνικής Stratified εξασφαλίζει ότι η αναλογία των 4 κατηγοριών παραμένει ίδια σε κάθε τμήμα.

CV Mean

$$\overline{F1}_{CV} = \frac{1}{5} \sum_{f=1}^5 F1_{macro}^{(f)} \quad (45)$$

Για κάθε fold f , το βέλτιστο μοντέλο `best_rf` εκπαιδεύεται στα υπόλοιπα 4 folds και αξιολογείται στο fold f , αποδίδοντας την τιμή $F1_{macro}^{(f)}$.

Η μέση τιμή του $\overline{F1}_{CV}$ (`cv_scores_rf.mean()`) αντιπροσωπεύει τον μέσο όρο αυτών των 5 τιμών, παρέχοντας έτσι μια πιο συνεπή εκτίμηση της τυπικής απόδοσης του μοντέλου. Αυτή η προσέγγιση μειώνει την εξάρτηση από ένα μόνο, τυχαίο διαχωρισμό δεδομένων και προσφέρει μια πιο αξιόπιστη μέτρηση των ικανοτήτων του μοντέλου.

Η τυπική απόκλιση των βαθμολογιών διασταυρούμενης επικύρωσης s_{CV} (`cv_scores_rf.std()`) υποδεικνύει τη διακύμανση μεταξύ των πέντε τιμών $F1_{macro}^{(f)}$. Μια χαμηλή τιμή της s_{CV} φανερώνει μια συνεπή και αξιόπιστη απόδοση του μοντέλου, ανεξαρτήτως του set δεδομένων που χρησιμοποιείται για την αξιολόγηση. Αντιθέτως, μια υψηλή τιμή s_{CV} υποδεικνύει αστάθεια και μπορεί να υποδηλώνει υπερεκπαίδευση σε συγκεκριμένες υπο-ομάδες δεδομένων.

CV Std (τυπική απόκλιση, $\pm$)

$$s_{CV} = \sqrt{\frac{1}{5} \sum_{f=1}^5 \left(F1_{macro}^{(f)} - \overline{F1}_{CV} \right)^2} \quad (46)$$

8. Τιμή Shapley⁴⁷ (Θεμελιώδης Τύπος SHAP - SHapley Additive exPlanations)

Στην περίπτωση μας, αναφορικά με το πλαίσιο του SHAP, οι «παίκτες» είναι τα χαρακτηριστικά εισόδου του μοντέλου, όπως για παράδειγμα οι 7 δείκτες KPIs και οι 12 sector μεταβλητές, και η ανταμοιβή είναι η πρόβλεψη του μοντέλου. Συνεπώς, το ουσιαστικό ερώτημα μετατρέπεται: **Πόσο συνέβαλε κάθε χαρακτηριστικό στο να καταλήξει το Random**

⁴⁶ skf = StratifiedKFold($n_splits=5$, $shuffle=True$, $random_state=RANDOM_STATE$) και έπειτα `cv_scores = cross_val_score(model, X, y_encoded, cv=skf, scoring='f1_macro', n_jobs=-1)`

⁴⁷ Η τιμή Shapley αποτελεί έναν θεμελιώδη όρο της θεωρίας παιγνίων, εισαγόμενος από τον Shapley το 1953, ο οποίος επιχειρεί να απαντήσει σε ένα ουσιαστικό ερώτημα: Πώς κατανέμεται δικαίως η συνολική ανταμοιβή σε μια ομάδα συνεργαζόμενων παικτών, λαμβάνοντας υπόψη την ατομική συμβολή του καθενός στο παραχθέν αποτέλεσμα;

Forest ή το XGBoost σε αυτή τη συγκεκριμένη πρόβλεψη, για αυτή τη συγκεκριμένη οντότητα;

$$\varphi_i(f) = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|! (p - |S| - 1)!}{p!} [f_x(S \cup \{i\}) - f_x(S)] \quad (47)$$

όπου, $F = \{1, \dots, p\}$ είναι το σύνολο όλων των χαρακτηριστικών εισόδου ($p = 7$ δείκτες + 12 one-hot sector μεταβλητές, δηλαδή συνολικά 19 χαρακτηριστικά στο X). Το $S \subseteq F \setminus \{i\}$ είναι ένα υποσύνολο χαρακτηριστικών που δεν περιλαμβάνει το χαρακτηριστικό i που εξετάζεται. Το $f_x(S)$ είναι η αναμενόμενη πρόβλεψη του μοντέλου όταν είναι γνωστές μόνο οι τιμές του χαρακτηριστικού S . Οι υπόλοιπες θεωρούνται άγνωστες και υπολογίζεται ο αναμενόμενος μέσος όρος πάνω σε αυτές. Ο όρος $[f_x(S \cup \{i\}) - f_x(S)]$ είναι η οριακή συνεισφορά του χαρακτηριστικού i , δηλαδή πόσο αλλάζει η πρόβλεψη όταν προστεθεί η γνώση του i σε ένα σύνολο που ήδη γνωρίζει το S . Ο συντελεστής $\frac{|S|!(p-|S|-1)!}{p!}$ αποτελεί μια σταθμισμένη πιθανότητα, καθώς αντιπροσωπεύει την πιθανότητα επιλογής τυχαίας σειράς με την οποία τα p χαρακτηριστικά εισάγονται σταδιακά στο μοντέλο, καταλήγοντας ακριβώς στο υποσύνολο S πριν εισαχθεί το i . Τέλος, το εξωτερικό άθροισμα $\sum_{S \subseteq F \setminus \{i\}} (\cdot)$ σημαίνει ότι εφαρμόζουμε την εν λόγω διαδικασία σε κάθε δυνατό υποσύνολο S . Υπάρχουν 2^{p-1} τέτοια υποσύνολα και αθροίζουμε τις σταθμισμένες οριακές συνεισφορές από αυτά.

9. Global Feature Importance (Bar Plot)

Το γράφημα Global Feature Importance (Bar Plot) αποκαλύπτει ποια χαρακτηριστικά έχουν τη μεγαλύτερη επίδραση στο μοντέλο συνολικά, λαμβάνοντας υπόψη το μέσο όρο σε όλο το δείγμα δεδομένων, παρά για μια συγκεκριμένη οντότητα. Απαντά στην ερώτηση: *Αν έπρεπε να επιλέξω τα πέντε πιο σημαντικά χαρακτηριστικά που καθορίζουν την κλάση ανθεκτικότητας μιας οντότητας, ποια θα ήταν αυτά;*

$$I_i = \frac{1}{n_{sample}} \sum_{j=1}^{n_{sample}} |\varphi_i(x_j)| \quad (48)$$

όπου, το $n_{sample} = 600$ είναι το πλήθος των παρατηρήσεων του δείγματος ελέγχου ($X_{sample} = X_{test}[:600]$). Το $\varphi_i(x_j)$ είναι η τιμή Shapley για το χαρακτηριστικό i στην παρατήρηση x_j μπορεί να είναι είτε θετική, υποδεικνύοντας αύξηση στην πρόβλεψη, είτε αρνητική, δείχνοντας μείωση. Το $|\varphi_i(x_j)|$ ως απόλυτη τιμή λαμβάνεται υπόψη, διότι για την εκτίμηση της συνολικής σημασίας, το ενδιαφέρον μας επικεντρώνεται στο μέγεθος της επιρροής ανεξαρτήτως κατεύθυνσης (είτε θετικής, είτε αρνητικής). Ένα χαρακτηριστικό που οδηγεί σε δραστικές μεταβολές στην πρόβλεψη, είτε αυτές είναι αυξήσεις είτε μειώσεις, θεωρείται εξίσου σημαντικό με εκείνο που συμβάλλει μόνο στην αύξηση της πρόβλεψης. Τέλος, το άθροισμα $\sum_{j=1}^{600} (\cdot)$ και η διαίρεση αυτού με το n_{sample} δίνει τον μέσο όρο της

απόλυτης επιρροής σε όλες τις 600 παρατηρήσεις. Το αποτέλεσμα αυτό αποτελεί το μήκος κάθε μπάρας στο `shap.summary_plot(..., plot_type = "bar")`.

10. Εξειδικευμένη Τιμή SHAP ανά Δείκτη και Τομέα (Beeswarm Plot)

Το Beeswarm Plot είναι το λεπτομερέστερο από τα δύο γραφήματα SHAP που παράγει ο κώδικας. Ενώ το bar plot παρουσιάζει έναν μοναδικό αριθμό για κάθε χαρακτηριστικό, το Beeswarm Plot εμφανίζει όλες τις 600 μεμονωμένες παρατηρήσεις με τη μορφή ενός «σμήνους μελισσών» γύρω από κάθε χαρακτηριστικό. Αυτό το γράφημα απαντά σε πιο σύνθετες ερωτήσεις από αυτές του bar plot, όπως όχι μόνο ποια χαρακτηριστικά είναι σημαντικά αλλά και με ποιο τρόπο και προς ποια κατεύθυνση επηρεάζουν την πρόβλεψη. Εξετάζει επίσης αν αυτό ισχύει ομοιόμορφα για όλες τις οντότητες ή αν υπάρχουν διαφορές.

$$\varphi_i^{(k^*)}(x_j), \quad k^* = \text{index}(\text{Πολύ Κρίσιμο}) \quad (49)$$

Καθώς το πρόβλημα περιλαμβάνει τέσσερις κλάσεις $K = 4$, κάθε χαρακτηριστικό αποκτά διαφορετική τιμή SHAP ανά κλάση. Έτσι, η επίδραση, για παράδειγμα, του `C1_mttr` στην πρόβλεψη Κρίσιμο διαφέρει από την επίδραση του στην πρόβλεψη Πολύ Κρίσιμο. Ο κώδικας επομένως επικεντρώνεται σε μία συγκεκριμένη κλάση-στόχο (`target_class = "Πολύ Κρίσιμο"`) και εντοπίζει δυναμικά τη θέση της k^* εντός της λίστας `le.classes_`. Αυτό είναι αναγκαίο, δεδομένου ότι ο `LabelEncoder` ταξινομεί τις ετικέτες αλφαβητικά και όχι κατά βαθμό σοβαρότητας, καθιστώντας τη σωστή θέση απρόβλεπτη εκ των προτέρων.

ΚΕΦΑΛΑΙΟ 4

Παρουσίαση Αποτελεσμάτων & Συζήτηση

4.1. Εισαγωγικό Πλαίσιο Παρουσίασης Αποτελεσμάτων

Σε αυτή την ενότητα παρουσιάζονται τα αποτελέσματα από τη διαδικασία εκπαίδευσης, βελτιστοποίησης υπερπαραμέτρων και αξιολόγησης των τριών μοντέλων Μηχανικής Μάθησης (ML), που χρησιμοποιήθηκαν για την πρόβλεψη των κλάσεων ανθεκτικότητας των κρίσιμων οντοτήτων. Αυτή η διαδικασία βασίζεται στον Σύνθετο Δείκτη Ανθεκτικότητας (CRI), όπως καθορίζεται στο Παράρτημα ΣΤ' της Εθνικής Στρατηγικής για την Ανθεκτικότητα Κρίσιμων Οντοτήτων 2026-2030. Η ανάλυση έγινε με συνθετικά δεδομένα κρίσιμων οντοτήτων, τα οποία ταξινομήθηκαν σε τέσσερις ισάριθμες κλάσεις (quartiles): Μη Κρίσιμο, Χαμηλής Ανθεκτικότητας, Κρίσιμο και Πολύ Κρίσιμο. Τα συνθετικά δεδομένα δημιουργήθηκαν προγραμματιστικά με στόχο την ακριβή προσομοίωση της δομής, της διασποράς και των τομεακών αποκλίσεων των 22 δεικτών KPIs και KRIs, όπως ορίζονται από το θεσμικό πλαίσιο. Με τη συγκεκριμένη μεθοδολογία, καθίσταται εφικτή η διεξαγωγή της έρευνας, δεδομένου ότι επιτρέπει την αναπαραγωγή χαρακτηριστικών όπως των πραγματικών δεδομένων. Αυτό εξασφαλίζει την προστασία της ιδιωτικότητας, καθώς αποφεύγεται η συμπερίληψη ευαίσθητων ή διαβαθμισμένων πληροφοριών των κρίσιμων οντοτήτων.

Τα συνθετικά σύνολα δεδομένων δημιουργήθηκαν από κρίσιμες οντότητες, οι οποίες κατανέμονται τυχαία σε 12 τομείς κρίσιμων υποδομών, όπως περιγράφεται στο παράρτημα της Οδηγίας CER (ΕΕ) 2022/2557 και ενσωματώνονται στην Εθνική Στρατηγική για την Ανθεκτικότητα Κρίσιμων Οντοτήτων 2026-2030. Οι τομείς αυτοί περιλαμβάνουν: την Ενέργεια, τις Μεταφορές, τον Τραπεζικός κλάδος, τις Υποδομές χρηματοπιστωτικών αγορών, την Υγεία, το Πόσιμο νερό, τα Λύματα, τα Αστικά απόβλητα, τις Ψηφιακές υποδομές, τη Δημόσια διοίκηση, το Διάστημα και την Παραγωγή & διανομή τροφίμων. Σε κάθε οντότητα, υπολογίζονται τιμές για 22 δείκτες απόδοσης (KPIs/KRIs), οι οποίοι κατηγοριοποιούνται σε τέσσερις διαστάσεις:

- **Διάσταση Α' – Διακυβέρνηση και Θεσμική Ωριμότητα με συντελεστή στάθμισης $w_A = 0.25$:** Περιλαμβάνει έξι δείκτες, όπως "A1_char_pct", (%) το ποσοστό κρίσιμων οντοτήτων που έχουν χαρακτηριστεί, "A2_plan_appr_pct", (%) το ποσοστό οντοτήτων με εγκεκριμένο Σχέδιο Ανθεκτικότητας, "A3_appr_time", ο μέσος χρόνος αξιολόγησης/έγκρισης Σχεδίου Ανθεκτικότητας, "A4_authority_pct", (%) το ποσοστό Τομέων με λειτουργική Τομεακή Αρμόδια Αρχή, "A5_contact_point", η λειτουργία Εθνικού Ενιαίου Σημείου Επαφής, "A6_tisn_net", η λειτουργία δικτύων TISN.
- **Διάσταση Β' – Αποδοτικότητα Οντοτήτων με συντελεστή στάθμισης $w_B = 0.30$:** Αποτελείται από έξι δείκτες, όπως "B1_iso_pct", (%) το ποσοστό οντοτήτων με πιστοποίηση ISO 22301 (Business Continuity), "B2_training_pct", (%) το ποσοστό Υπευθύνων Ανθεκτικότητας και στελεχών κρίσιμων λειτουργιών με εξειδικευμένη

κατάρτιση, "B3_exercises_num", ο μέσος αριθμός διεξαχθέντων ασκήσεων ετοιμότητας ετησίως ανά οντότητα, "B4_inspection_pct", (%) το ποσοστό υλοποίησης του ετήσιου προγράμματος επιθεωρήσεων, "B5_incident_rep_pct", (%) το ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών, "B6_digital_twin", οι κρίσιμες υποδομές με χρήση Ψηφιακού Διδύμου (Digital Twin).

- **Διάσταση Γ' – Αποτελέσματα και Επιπτώσεις με συντελεστή στάθμισης $w_c = 0.25$** : Συμπεριλαμβάνει πέντε δείκτες, όπως "C1_mttr", ο μέσος χρόνος αποκατάστασης βλάβης/υπηρεσίας (MTTR) ανά τομέα, "C2_major_incidents", ο αριθμός σημαντικών συμβάντων με σοβαρές επιπτώσεις, "C3_financial_loss", οι συνολικές οικονομικές επιπτώσεις από διαταραχές (σε €), "C4_user_satisfaction", ο δείκτης ικανοποίησης χρηστών/πολιτών ουσιωδών υπηρεσιών, "C5_insurance_claims", ο αριθμός ασφαλιστικών απαιτήσεων από διαταραχές.
- **Διάσταση Δ' – Συμφωνία με το Πλαίσιο Sendai, Στόχος 4 με συντελεστή στάθμισης $w_c = 0.20$** : Περιλαμβάνει πέντε δείκτες, όπως "D1_infra_damage", οι ζημιές σε κρίσιμες υποδομές από καταστροφές, "D2_health_interruption", οι ημέρες διακοπής υπηρεσιών υγείας, "D3_edu_interruption", οι ημέρες διακοπής υπηρεσιών εκπαίδευσης, "D4_power_outage_prop", ο πληθυσμός εκτεθειμένος σε διακοπή ηλεκτρισμού άνω των 24 ωρών, "D5_water_outage_prop", ο πληθυσμός εκτεθειμένος σε διακοπή πόσιμου νερού άνω των 24 ωρών.

Ορισμένα προσβάσιμα χαρακτηριστικά σε επίπεδο μεμονωμένης οντότητας θεωρούνται εύκολα διαθέσιμα, χωρίς να απαιτείται πλήρης επιτόπια επιθεώρηση της Εποπτεύουσας Αρχής. Γι' αυτό επιλέχθηκαν 7 από τους ανωτέρω 22 δείκτες KPIs/KRIs, οι οποίοι είναι τα μοναδικά στοιχεία που αντιλαμβάνονται τα μοντέλα τεχνητής νοημοσύνης.

1. (%) Ποσοστό οντοτήτων με εγκεκριμένο Σχέδιο Ανθεκτικότητας, "A2_plan_appr_pct".
2. (%) Ποσοστό οντοτήτων με πιστοποίηση ISO 22301 (Business Continuity), "B1_iso_pct".
3. (%) Ποσοστό Υπευθύνων Ανθεκτικότητας και στελεχών κρίσιμων λειτουργιών με εξειδικευμένη κατάρτιση, "B2_training_pct".
4. Μέσος αριθμός διεξαχθέντων ασκήσεων ετοιμότητας ετησίως ανά οντότητα, "B3_exercises_num".
5. (%) Ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών, "B5_incident_rep_pct".
6. Μέσος χρόνος αποκατάστασης βλάβης/υπηρεσίας (MTTR) ανά τομέα, "C1_mttr".
7. Δείκτης ικανοποίησης χρηστών/πολιτών ουσιωδών υπηρεσιών, "C4_user_satisfaction".

Οι τιμές των δεικτών προκύπτουν μέσω μιας κατανομής $Beta(2.2, 2.0)$ στο εύρος $[0, 100]$. Σε αυτήν την κατανομή προστίθεται μια σταθερή μετατόπιση ανά κλάδο, με τον τραπεζικό κλάδο να έχει +10 μονάδες επιπλέον, την ενέργεια και τις χρηματοπιστωτικές υποδομές να λαμβάνουν +8 μονάδες, τις ψηφιακές υποδομές +5, το διάστημα +3, τις μεταφορές 0, την υγεία -3, το πόσιμο νερό και η δημόσια διοίκηση -5, η παραγωγή & διανομή τροφίμων -6, τα αστικά απόβλητα -7, ενώ για τα λύματα υπάρχει μείωση κατά -8 μονάδες. Επιπλέον, προστίθεται και τυχαίος θόρυβος σύμφωνα με μία κανονική κατανομή με τυπική απόκλιση

$\sigma = 4$. Αυτές οι τροποποιήσεις αποσκοπούν στη ρεαλιστική προσομοίωση της ποικιλίας θεσμικής και τεχνολογικής ωριμότητας που χαρακτηρίζει κάθε κλάδο.

Το τελικό CRI score υπολογίζεται ως ο σταθμισμένος μέσος όρος των τεσσάρων διαστάσεων, με προσθήκη μη γραμμικής ποιινής αλληλεπίδρασης (-8 μονάδες) όταν μια οντότητα εμφανίζει ταυτόχρονα βαθμολογία κάτω από 40 στη Διακυβέρνηση και στην Αποδοτικότητα. Αυτό αντιπροσωπεύει την δυσανάλογη επιδείνωση κινδύνου λόγω της συνύπαρξης πολλαπλών θεσμικών αδυναμιών. Επίσης, προστίθεται στοχαστικός θόρυβος μέτρησης με $\sigma = 3,5$. Το συνεχές CRI score στη συνέχεια μετατρέπεται σε τέσσερις ισοδύναμες κατηγορίες (τεταρτημόρια) μέσω της `pandas.qcut`: Μη Κρίσιμο, Χαμηλής Ανθεκτικότητας, Κρίσιμο και Πολύ Κρίσιμο. Εν συνεχεία, εκπαιδεύτηκαν τρία μοντέλα μηχανικής μάθησης για την ταξινόμηση πολλαπλών κλάσεων και συγκρίθηκαν μεταξύ τους. Έγινε διαχωρισμός σε σύνολο εκπαίδευσης (75% με $n = 3.750, n = 7.500, n = 15.000$ και $n = 30.000$) και ανεξάρτητο σύνολο ελέγχου hold-out (25% με $n = 1.250, n = 2.500, n = 5.000$ και $n = 10.000$). Τέλος, πραγματοποιείται Stratified 5-Fold Cross Validation επί του συνόλου των δεδομένων για πιο αξιόπιστη εκτίμηση γενίκευσης πέραν του ενός διαχωρισμού.


1. Η **Logistic Regression** ως Baseline μοντέλο: Χρησιμοποιήθηκε εντός pipeline με προηγούμενη κανονικοποίηση (StandardScaler) και μέγιστο αριθμό επαναλήψεων (`max_iter = 2000`), χωρίς ρύθμιση παραμέτρων (hyperparameter tuning) και λειτουργεί ως μοντέλο αναφοράς.
2. Ο **Random Forest Classifier**: Ρυθμίστηκε με `class_weight = 'balanced'` για να αντιμετωπιστεί πιθανή ανισορροπία στις κλάσεις. Η βελτιστοποίηση των παραμέτρων πραγματοποιήθηκε μέσω του `RandomizedSearchCV`, με 10 επαναλήψεις και τριπλή διασταυρούμενη επικύρωση (`n_iter = 10, cv = 3`), χρησιμοποιώντας ως μέτρο ακρίβειας το `macro - F1` (`scoring = f1_macro`). Η βελτιστοποίηση πραγματοποιήθηκε σε ένα πλέγμα υπερπαραμέτρων, το οποίο περιλάμβανε τα: `n_estimators`, `max_depth`, `min_samples_split`, `min_samples_leaf` και `max_features`.
3. Ο **XGBoost Classifier**: Έγινε ρύθμιση με αντικειμενική συνάρτηση `multi:softprob`, ενώ για τη βελτιστοποίηση εφαρμόστηκε η μέθοδος `RandomizedSearchCV`. Αυτή η διαδικασία περιελάμβανε 10 επαναλήψεις και 3 πτυχές διασταύρωσης (`n_iter = 10, cv = 3`), με τη μέτρηση της απόδοσης να γίνεται μέσω του `macro - F1` (`scoring = f1_macro`). Η βελτιστοποίηση πραγματοποιήθηκε σε ένα διευρυμένο πλέγμα υπερπαραμέτρων, το οποίο περιλάμβανε τα: `n_estimators`, `max_depth`, `learning_rate`, `subsample`, `colsample_bytree`, `min_child_weight`, `reg_alpha` (L1 Lasso) και `reg_lambda` (L2 Ridge).

Για τη διασφάλιση της πλήρους αναπαραγωγιμότητας των αποτελεσμάτων, καθορίστηκε σταθερή τιμή `random_state = 42` σε όλες τις περιπτώσεις.

Από τα ευρήματα της παρούσας έρευνας αναμένεται να προκύψουν συμπεράσματα που θα συμβάλλουν στην επίτευξη δύο κύριων στόχων: α) την εκτίμηση της προγνωστικής ικανότητας των αλγορίθμων ταξινόμησης Logistic Regression ως Baseline μοντέλο, Random Forest και XGBoost όταν αυτοί έχουν πρόσβαση μόνο σε ένα υποσύνολο 7 από τους 22 δείκτες KPIs και KRIs, τα δεδομένα των οποίων είναι εύκολα προσβάσιμα, και β) την αναγνώριση των χαρακτηριστικών που επηρεάζουν σε μεγαλύτερο βαθμό μια κρίσιμη

οντότητα ώστε να χαρακτηριστεί ως Πολύ Κρίσιμη, αξιοποιώντας τη μέθοδο SHAP (SHapley Additive exPlanations).

Η αξιολόγηση των μοντέλων πραγματοποιήθηκε τόσο μέσω της μεθόδου ανεξάρτητου συνόλου δοκιμής (Hold-out evaluation) όσο και με την τεχνική της διασταυρούμενης επικύρωσης 5 πτυχών (5-Fold Cross-Valuation). Ως κύριος δείκτης αξιολόγησης επιλέχθηκε το *Macro – F1 Score*, ο οποίος παρέχει μια ισορροπημένη μέτρηση της απόδοσης για όλες τις κλάσεις. Επιπροσθέτως, για τα περίπλοκα μοντέλα όπως το Random Forest και το XGBoost, εφαρμόστηκε η ανάλυση ερμηνευσιμότητας SHAP προκειμένου να αναλυθεί ο αντίκτυπος των χαρακτηριστικών στις προβλέψεις.



Εικόνα 4.2: Η απεικόνιση του Pipeline μηχανικής μάθησης για την πρόβλεψη του δείκτη CRI για συνθετικό dataset 5.000 οντοτήτων σε 12 τομείς, μέσω feature engineering (7 KPIs, one-hot encoding, split 75/25), εκπαιδεύονται και συγκρίνονται τρία μοντέλα (LogReg, Random Forest, XGBoost) με αξιολόγηση βάσει F1-score, CV, ερμηνευσιμότητα SHAP και δείκτη αξιολόγησης macro-F1.

Για να εξασφαλιστεί η αξιοπιστία και να διερευνηθεί η συμπεριφορά των αλγορίθμων υπό διαφορετικές συνθήκες αύξησης του όγκου δεδομένων, η πειραματική διαδικασία πραγματοποιήθηκε σε τέσσερα διαφορετικά μεγέθη δείγματος (n):

- Για $n = 5.000$ Κρίσιμες Οντότητες (1.250 ανά κλάση και 1.250 στο hold-out test set)
- Για $n = 10.000$ Κρίσιμες Οντότητες (2.500 ανά κλάση και 2.500 στο hold-out test set)
- Για $n = 20.000$ Κρίσιμες Οντότητες (5.000 ανά κλάση και 5.000 στο hold-out test set)
- Για $n = 40.000$ Κρίσιμες Οντότητες (10.000 ανά κλάση και 10.000 στο hold-out test set)

Η επανάληψη της διαδικασίας με διαφορετικά μεγέθη δείγματος ($n = 5.000, 10.000, 20.000, 40.000$) είναι μια σημαντική μεθοδολογική στρατηγική που συχνά αναφέρεται ως ανάλυση κλιμάκωσης (scalability analysis). Η συγκεκριμένη προσέγγιση επιτυγχάνει αρκετούς βασικούς στόχους και συνεισφέρει στην ανάλυση πολύτιμων συμπερασμάτων:

1. Έλεγχος Ανθεκτικότητας και Γενίκευσης (Robustness & Generalization)

Όταν ένα μοντέλο αξιολογείται με βάση ένα μοναδικό μέγεθος δείγματος, υπάρχει ο κίνδυνος τα αποτελέσματα να εμφανιστούν τυχαία ή να επηρεαστούν από τις ιδιαίτερα χαρακτηριστικά του συγκεκριμένου συνόλου δεδομένων. Με την προοδευτική αύξηση του n , επιδιώκεται να διαπιστωθεί αν η επίδοση των μοντέλων παραμένει σταθερή. Σε αυτή την περίπτωση, εάν το *macro* – *F1* των 3 μοντέλων δεν μεταβάλλονται δραματικά με την αύξηση του μεγέθους του συνόλου δεδομένων, τότε επικρατεί η άποψη ότι τα μοντέλα είναι σταθερά ανεξάρτητα από το μέγεθος του δείγματος. Με άλλα λόγια, η αύξηση του μεγέθους του συνόλου δεδομένων, αντιστοιχεί σε έναν έλεγχο ανθεκτικότητας (robustness) στην εμπειρική έρευνα, γεγονός που ενισχύει την εσωτερική εγκυρότητα των ευρημάτων.

Επιπροσθέτα, υπάρχει και ουσιώδες πρακτικό και υπολογιστικό ενδιαφέρον, καθώς η ανάλυση του χρόνου εκτέλεσης και της συμπεριφοράς του RandomizedSearchCV με αύξηση του μεγέθους του συνόλου δεδομένων παρουσιάζει ιδιαίτερη σημασία, ειδικά αν το μοντέλο προορίζεται να εφαρμοστεί σε πραγματικά δεδομένα Εθνικής κλίμακας δείχνει εάν η προσέγγιση μπορεί να κλιμακωθεί υπολογιστικά χωρίς προβλήματα.

2. Μελέτη Καμπύλης Μάθησης (Learning Curves)

Στη Μηχανική Μάθηση, οι πιο εξελιγμένοι αλγόριθμοι, όπως το Random Forest και το XGBoost, συνήθως απαιτούν μεγάλες ποσότητες δεδομένων. Με την αύξηση του πλήθους δεδομένων n , μπορούμε να παρατηρήσουμε αν η προσθήκη νέων δεδομένων ενισχύει την ακρίβεια των προβλέψεων. Στην περίπτωση που η αποτελεσματικότητα βελτιώνεται, σημαίνει ότι το μοντέλο χρειάζεται μεγάλο όγκο δεδομένων για να εντοπίσει τα μοτίβα. Στην περίπτωση που δεν βελτιώνεται η αποτελεσματικότητα, δηλαδή με την αύξηση των δεδομένων από $n = 5.000$ σε $n = 40.000$ δεν παρατηρείται βελτίωση του *macro* – *F1*, γίνεται αντιληπτό ότι το πρόβλημα έχει φτάσει σε ένα σημείο κορεσμού από πλευράς πληροφορίας (performance plateau) με τα συγκεκριμένα χαρακτηριστικά, και η απλή προσθήκη περισσότερων δεδομένων δεν παρέχει περαιτέρω βελτίωση στα μοντέλα.

3. Αξιολόγηση Υπερπροσαρμογής (Overfitting)

Σε μικρά σύνολα δεδομένων (π.χ. $n = 5.000$), τα περίπλοκα μοντέλα συχνά τείνουν να υπερπροσαρμόζονται, δηλαδή να απομνημονεύουν τον θόρυβο. Καθώς το μέγεθος του δείγματος αυξάνεται, η πιθανότητα υπερπροσαρμογής μειώνεται.

4. Σύγκριση Αλγορίθμων υπό Διαφορετικές Συνθήκες

Ορισμένοι αλγόριθμοι επιδεικνύουν καλύτερη απόδοση με μικρότερα σύνολα δεδομένων, ενώ άλλοι αναδεικνύουν την αξία τους σε συνθήκες με μεγάλο όγκο δεδομένων. Για παράδειγμα, η Logistic Regression καταφέρνει να έχει απροσδόκητα καλή και σταθερή απόδοση συγκριτικά με τα μη γραμμικά μοντέλα, ανεξαρτήτως του αριθμού δεδομένων. Αυτό οδηγεί στο συμπέρασμα ότι για το συγκεκριμένο πρόβλημα ταξινόμησης, ένα απλό μοντέλο, λογαριθμικής παλινδρόμησης, μπορεί να είναι εξίσου αποτελεσματικό όσο και τα δέντρα αποφάσεων, ανεξάρτητα από τον όγκο των δεδομένων.

5. Σταθερότητα στις Ερμηνευσιμότητας SHAP

Ίσως το πιο σημαντικό στοιχείο για τη παρούσα έρευνα είναι η χρήση των SHAP plots, βασισμένων σε ένα δείγμα 600 παρατηρήσεων από το test set. Με $n = 5.000$, το test set περιλαμβάνει περίπου 1.250 παρατηρήσεις, πράγμα που σημαίνει ότι υπάρχουν μόνο περίπου 50 παρατηρήσεις ανά τομέα (12 τομείς), γεγονός που είναι οριακά ανεπαρκές για σταθερές εκτιμήσεις, ειδικά για υποεκπροσωπούμενους τομείς, όπως το Διάστημα και οι Μεταφορές. Όταν το δείγμα ανέβει στο $n = 40.000$, τότε το test set διευρύνεται στις ~ 10.000 παρατηρήσεις, οδηγώντας σε πιο αξιόπιστη κατανομή των τιμών SHAP ανά τομέα, με λιγότερο θόρυβο στο beeswarm. Έτσι, παρέχεται η δυνατότητα να επιβεβαιωθεί εάν η ιεράρχηση της σπουδαιότητας (π.χ. Τομέας 1 > Τομέας 2 > Τομέας 3) διατηρείται, ή αν ήταν εν μέρει τυχαία λόγω του μικρότερου δείγματος.

Συνοψίζοντας, η διεύρυνση του δείγματος είναι κρίσιμη για να αποδειχθεί εάν τα συμπεράσματα από τα αποτελέσματα των μοντέλων δεν αποτελούν απλά θέμα τύχης. Παράλληλα, επιτρέπεται η εξέταση της συμπεριφοράς των αλγορίθμων κάτω από συνθήκες Big Data, ώστε να εξακριβωθεί αν η επένδυση σε μεγαλύτερο όγκο δεδομένων πραγματικά βελτιώνει την ακρίβεια του Δείκτη Ανθεκτικότητας (CRI).

4.2. Αποτελέσματα Συνθετικού Συνόλου Δεδομένων $n = 5.000$ Κρίσιμων Οντοτήτων

4.2.1. Κατανομή Οντοτήτων ανά Κλάση Ανθεκτικότητας

Η διαδικασία qcut, χρησιμοποιώντας 4 τεταρτημόρια, δημιούργησε, όπως ήταν αναμενόμενο, τέσσερις κλάσεις με ίσο αριθμό οντοτήτων από ένα σύνολο 5.000 οντοτήτων. Δηλαδή, Μη Κρίσιμο, Χαμηλής Ανθεκτικότητας, Κρίσιμο και Πολύ Κρίσιμο από 1.250 οντότητες.

4.2.2. Logistic Regression ως Baseline Μοντέλο

Το μοντέλο βάσης, χωρίς οποιαδήποτε ρύθμιση υπερπαραμέτρων, πέτυχε συνολική ακρίβεια ($accuracy = 0.55$) και ένα $macro - F1 = 0.540$ στο hold-out σύνολο ελέγχου. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον πίνακα 4.1, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη Κρίσιμο



επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.72 και 0.66, αντίστοιχα. Αντίθετα, οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ και στις δύο περιπτώσεις 0.39.

Πίνακας 4.1: Αποτελέσματα Ταξινόμησης Logistic Regression (hold-out, $n = 1.250$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.43	0.35	0.39	313
Μη Κρίσιμο	0.63	0.70	0.66	312
Πολύ Κρίσιμο	0.69	0.75	0.72	313
Χαμηλής Ανθεκτικότητας	0.40	0.39	0.39	312
Accuracy			0.55	1250
Macro avg	0.54	0.55	0.54	1250
Weighted avg	0.54	0.55	0.54	1250

4.2.3. Random Forest με Hyperparameter Tuning

Η τυχαία αναζήτηση υπερπαραμέτρων (RandomizedSearchCV) οδήγησε στον παρακάτω συνδυασμό ως τον καλύτερο: `{'n_estimators': 200, 'min_samples_split': 2, 'min_samples_leaf': 4, 'max_features': 'sqrt', 'max_depth': 15}`.

Με αυτές τις παραμέτρους, το βέλτιστο Random Forest πέτυχε συνολική ακρίβεια ($accuracy = 0.54$) και ένα $macro - F1 = 0.535$ στο hold-out σύνολο ελέγχου, το οποίο είναι ελαφρώς χαμηλότερο από το Baseline. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον πίνακα 4.2, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη Κρίσιμο επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.71 και 0.63, αντίστοιχα. Αντίθετα, οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ και στις δύο περιπτώσεις 0.40.

Πίνακας 4.2.: Αποτελέσματα Ταξινόμησης Random Forest (hold-out, $n = 1.250$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.45	0.37	0.40	313
Μη Κρίσιμο	0.59	0.68	0.63	312
Πολύ Κρίσιμο	0.69	0.74	0.71	313
Χαμηλής Ανθεκτικότητας	0.41	0.39	0.40	312
Accuracy			0.54	1250
Macro avg	0.53	0.54	0.54	1250
Weighted avg	0.53	0.54	0.54	1250

4.2.4. XGBoost με Hyperparameter Tuning

Αντίστοιχα, η βελτιστοποίηση του XGBoost ανέδειξε τον εξής συνδυασμό παραμέτρων: `{'subsample': 0.85, 'reg_lambda': 2.0, 'reg_alpha': 0.0, 'n_estimators': 500, 'min_child_weight': 5, 'max_depth': 5, 'learning_rate': 0.01, 'colsample_bytree': 0.6}`.

Με αυτές τις παραμέτρους, το βέλτιστο XGBoost πέτυχε συνολική ακρίβεια ($accuracy = 0.54$) και ένα $macro - F1 = 0.528$ στο hold-out σύνολο ελέγχου, το οποίο είναι χαμηλότερο από το Baseline. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον πίνακα 4.3, επίσης, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη Κρίσιμο επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.70 και 0.64, αντίστοιχα. Αντίθετα, οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ 0.39 και 0.37, αντίστοιχα.

Πίνακας 4.3: Αποτελέσματα Ταξινόμησης XGBoost (hold-out, $n = 1.250$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.43	0.36	0.39	313
Μη Κρίσιμο	0.59	0.71	0.64	312
Πολύ Κρίσιμο	0.69	0.73	0.70	313
Χαμηλής Ανθεκτικότητας	0.39	0.36	0.37	312
Accuracy			0.54	1250
Macro avg	0.52	0.54	0.53	1250
Weighted avg	0.52	0.54	0.53	1250

4.2.5. Συγκριτική Αξιολόγηση Μοντέλων για $n = 5.000$

Ο πίνακας 4.4 συνοψίζει την απόδοση των τριών μοντέλων, τόσο στο hold-out σύνολο όσο και στη 5-Fold Cross-Validation πάνω στο συνολικό dataset.

Πίνακας 4.4: Συγκριτική Απόδοση Μοντέλων (macro-F1 score, $n = 1.250$).

Μοντέλο	Hold-out macro-F1	5-Fold CV Mean	CV Std ($\pm$)
Logistic Regression (Baseline)	0.540	0.550	0.010
Random Forest	0.535	0.537	0.004
XGBoost	0.528	0.530	0.014


Το βασικό συμπέρασμα, για το σύνολο δεδομένων $n = 5.000$ οντότητες, συνίσταται στο ότι το πιο απλό μοντέλο, δηλαδή η Logistic Regression (Baseline), παρουσίασε την καλύτερη απόδοση ($macro-F1 = 0.540$ στο hold-out και 0.550 στο 5-Fold Cross-Validation). Αυτή η απόδοση υπερβαίνει ελαφρώς το βελτιστοποιημένο μοντέλο Random Forest (0.535 / 0.537) και το βελτιστοποιημένο μοντέλο XGBoost (0.528 / 0.530). Οι διαφορές ανάμεσα στα τρία μοντέλα είναι σχετικώς ασήμαντες (εντός 0.2 – 1.0 ποσοστιαίων μονάδων) και εμπίπτουν στην τυπική απόκλιση του Cross-Validation (± 0.004 έως ± 0.014), γεγονός που υποδηλώνει την απουσία στατιστικά σημαντικής υπεροχής κάποιου εκ των μοντέλων.

Η έλλειψη αξιοσημείωτης ανωτερότητας των πολυπλοκότερων μη γραμμικών μοντέλων, Random Forest και το XGBoost, σε σύγκριση με την Logistic Regression υποδηλώνει πιθανώς ότι η σχέση μεταξύ των χαρακτηριστικών εισόδου και της κλάσης ανθεκτικότητας είναι κατά κύριο λόγο γραμμική. Ενδέχεται, επίσης, να καταδεικνύει ότι η διαθέσιμη πληροφορία από τους 7 δείκτες, σε σύγκριση με τους συνολικά 22 δείκτες που απαρτίζουν το πραγματικό CRI score, δεν αρκεί ώστε η ανώτερη εκφραστική δυναμική των μητρικών μοντέλων να παρέχει πρόσθετο προγνωστικό πλεονέκτημα.

4.2.6. Ερμηνευσιμότητα Μοντέλων (SHAP Analysis)

Η ανάλυση SHAP (Shapley Additive exPlanations) αποσκοπεί στην κατανόηση των δεικτών που επηρεάζουν τις προβλέψεις των μοντέλων, εστιάζοντας κυρίως στους παράγοντες που καθορίζουν την κατάταξη μιας οντότητας σε μια συγκεκριμένη κλάση ανθεκτικότητας. Για τα δύο μοντέλα δέντρων (Random Forest και XGBoost) υπολογίστηκαν οι τιμές SHAP μέσω TreeExplainer σε δείγμα 600 πρώτων παρατηρήσεων του συνόλου ελέγχου. Η εκτέλεση παρήγαγε επιτυχώς τέσσερα διαγράμματα SHAP (δύο ανά μοντέλο δέντρων). Δύο συγκεντρωτικά bar plots σπουδαιότητας χαρακτηριστικών σε όλες τις κλάσεις για το Random Forest και το XBoost, και δύο αναλυτικά beeswarm summary plots εστιασμένα στην κλάση Πολύ Κρίσιμο για το Random Forest και το XBoost. Σημειώνεται ότι, λόγω της αλφαβητικής κωδικοποίησης του LabelEncoder, στα bar plots η ετικέτα Class 2 αντιστοιχεί στην κλάση Πολύ Κρίσιμο, η Class 0 στην κλάση Κρίσιμο, η Class 1 στην κλάση Μη Κρίσιμο και η Class 3 στην κλάση Χαμηλής Ανθεκτικότητας.

1. Random Forest & XGBoost – Συνολική Σπουδαιότητα Χαρακτηριστικών




Εικόνα 4.2: SHAP Feature Importance CRI (Bar plots για όλες οι κλάσεις): α. Random Forest, και β. XGBoost.

Στο μοντέλο Random Forest, η σημαντικότερη μεταβλητή είναι οι τομέας (sector) «Τραπεζικός κλάδος», ακολουθεί ένας λειτουργικός δείκτης, ο B1_iso_pct (ποσοστό πιστοποίησης ISO 22301) και έπειτα οι τομείς «Υποδομές χρηματοπιστωτικών αγορών» και «Ενέργεια». Στη συνέχεια, παρατηρούνται 5 λειτουργικοί και ποσοτικοί δείκτες, με σειρά σημαντικότητας B3_exercises_num, B2_training_pct, A2_plan_appr_pct, B5_incident_rep_pct και C4_user_satisfaction. Εν συνεχεία, ο τομέας «Ψηφιακές υποδομές» και ο έβδομος λειτουργικός δείκτης C1_mttr, ενώ στο τέλος οι τομείς με την μικρότερη επιρροή είναι «Δημόσια διοίκηση», «Πόσιμο νερό» και «Υγεία».

Στο μοντέλο XGBoost, η κατάσταση διαφοροποιείται, καθώς αποδίδει μεγαλύτερη συνολική βαρύτητα στους 4 λειτουργικούς δείκτες B1_iso_pct, B3_exercises_num, B5_incident_rep_pct και C4_user_satisfaction. Ακολουθούν, ο τομέας «Τραπεζικός κλάδος», οι λειτουργικοί και ποσοτικοί δείκτες A2_plan_appr_pct και B2_training_pct, οι τομείς «Υποδομές χρηματοπιστωτικών αγορών» και «Ενέργεια» και ο δείκτης C1_mttr. Τέλος, οι τομείς με την μικρότερη επιρροή είναι «Πόσιμο νερό», «Μεταφορές» και «Υγεία». Αυτή η διαφοροποίηση καταδεικνύει τον διαφορετικό χειρισμό των δύο μοντέλων στον χώρο των χαρακτηριστικών. Το XGBoost, αξιοποιώντας τον διαδοχικό μηχανισμό εκπαίδευσής του, φαίνεται να επιμερίζει τη βαρύτητα πιο ομοιόμορφα μεταξύ τομεακών και λειτουργικών παραμέτρων, ενώ το Random Forest τείνει να αποδίδει μεγαλύτερη βαρύτητα στα τομεακά σήματα.

2. Random Forest & XGBoost – Κατεύθυνση Επίδρασης για Κλάση «Πολύ Κρίσιμο»



Εικόνα 4.3: SHAP Summary CRI (Beeswarm plots για την κλάση «Πολύ Κρίσιμο»): α. Random Forest, και β. XGBoost.

Η ανάλυση beeswarm του Random Forest για την κλάση Πολύ Κρίσιμο αποδεικνύει ξεκάθαρα ότι η συμμετοχή στους τομείς «Τραπεζικός κλάδος», «Ενέργεια» και «Υποδομές χρηματοπιστωτικών αγορών» (κόκκινες κουκκίδες, τιμή χαρακτηριστικού = 1) ενισχύει σταθερά και έντονα την πρόβλεψη για την κλάση Πολύ Κρίσιμο με θετικές τιμές SHAP έως και 0.4 στην λογαριθμική κλίμακα log-odds. Αντίθετα, η απουσία από αυτούς τους τομείς (μπλε κουκκίδες, τιμή χαρακτηριστικού = 0) έχει μια ελαφρώς αρνητική επίδραση. Για τους λειτουργικούς δείκτες (B1_iso_pct, A2_plan_appr_pct, B2_training_pct, C4_user_satisfaction, B3_exercises_num, B5_incident_rep_pct), παρατηρείται ένα αναμενόμενο μοτίβο, καθώς οι υψηλές τιμές (κόκκινες κουκκίδες) συνδέονται με θετική συνεισφορά στην πρόβλεψη της Πολύ Κρίσιμης κλάσης, ενώ οι χαμηλές τιμές (μπλε κουκκίδες) δείχνουν αρνητική τάση, υποδηλώνοντας ότι οι οντότητες με χαμηλότερη επιχειρησιακή ωριμότητα τείνουν να χαρακτηρίζονται ως λιγότερο ανθεκτικές.

Στο beeswarm του μοντέλου XGBoost για την κλάση Πολύ Κρίσιμο, οι τομείς «Τραπεζικός κλάδος», «Ενέργεια» και «Υποδομές χρηματοπιστωτικών αγορών» αναδεικνύονται ως οι πλέον ισχυροί θετικοί παράγοντες, με τιμές SHAP να φτάνουν περίπου από 1.0 έως 1.3 στη λογαριθμική κλίμακα log-odds. Το χαρακτηριστικό B1_iso_pct παρουσιάζει την πιο έντονη διασπορά μεταξύ όλων των λειτουργικών δεικτών, γεγονός που υποδηλώνει μια μη γραμμική και πιθανόν αλληλεπιδραστική σχέση με την πιθανότητα ταξινόμησης στην κλάση Πολύ Κρίσιμο. Αντιθέτως, οι τομείς όπως «Παραγωγή/διανομή τροφίμων», «Λύματα», «Δημόσια διοίκηση» και «Πόσιμο νερό» λειτουργούν ως σταθεροί αρνητικοί παράγοντες. Αυτοί μειώνουν την πιθανότητα μιας οντότητας να ταξινομηθεί ως Πολύ Κρίσιμη, κάτι που προκύπτει από τα αρνητικά δεδομένα αντιστάθμισης της βάσης τομέα που τους αποδόθηκαν αρχικά κατά την ανάλυση δεδομένων.

3. Σύγκριση Ερμηνευσιμότητας μεταξύ των Μοντέλων

Τα ευρήματα της ανάλυσης, για την περίπτωση του συνόλου δεδομένων με $n = 5.000$ οντότητες, συνοψίζονται σε τέσσερα κύρια σημεία, τα οποία προσφέρουν σημαντική αξία τόσο από μεθοδολογική όσο και από ερμηνευτική άποψη.

Αρχικά, παρατηρείται μία οροφή στην απόδοση, καθώς κανένα από τα τρία μοντέλα δεν κατάφερε να ξεπεράσει ουσιαστικά το $macro - F1 \approx 0,55$, παρά την αξιοποίηση ισχυρών, μη γραμμικών αλγορίθμων, όπως το Random Forest και το XGBoost, και τη συστηματική βελτιστοποίηση των υπερπαραμέτρων. Αυτό το αποτέλεσμα δεν υποδηλώνει απαραίτητα προβλήματα στη μοντελοποίηση, αλλά είναι περισσότερο αναμενόμενο λόγω της δομής των δεδομένων. Πρώτον, το τελικό CRI score ενσωματώνει αισθητό στοχαστικό θόρυβο, τόσο σε επίπεδο επιμέρους δεικτών όσο και στο συνολικό σκορ, προκαλώντας ένα φυσικό όριο στην ακρίβεια (irreducible error⁴⁸). Δεύτερον, τα μοντέλα διαθέτουν πρόσβαση μόνο σε 7 από τους 22 δείκτες που επηρεάζουν το CRI score, με αποτέλεσμα να μην έχουν πλήρη πληροφόρηση για κρίσιμες Διαστάσεις (Α, Γ, Δ στον μεγαλύτερο βαθμό). Τρίτον, η μετατροπή σε ισοπληθή τεταρτημόρια εισάγει εκ των πραγμάτων «σκληρά» όρια μεταξύ γειτονικών κλάσεων σε μια συνεχή κατανομή, με συνέπεια οντότητες με παρόμοια CRI scores να κατατάσσονται σε διαφορετικές κλάσεις.

Η δεύτερη παρατήρηση είναι ότι η Logistic Regression, που χρησιμοποιήθηκε ως Baseline μοντέλο, πέτυχε την υψηλότερη μέση απόδοση ($CV\ mean = 0.550$), ελαφρώς καλύτερη από το Random Forest ($CV\ mean = 0.537$) και το XGBoost ($CV\ mean = 0.530$). Αυτό υποδηλώνει ότι η σχέση μεταξύ των εισερχόμενων χαρακτηριστικών και της κλάσης ανθεκτικότητας είναι σε μεγάλο βαθμό γραμμική ή μονότονη. Βασικά, αυτό ήταν αναμενόμενο εφόσον το CRI score δημιουργείται ως σταθμισμένος γραμμικός συνδυασμός δεικτών με μόνο μία περιορισμένη μορφή μη γραμμικής αλληλεπίδρασης. Σε ένα τέτοιο πλαίσιο, η παραπάνω πολυπλοκότητα που προσφέρουν τα μοντέλα δέντρων δεν παρέχει κάποιο εμφανές πλεονέκτημα.

⁴⁸ Το μη μειώσιμο σφάλμα (irreducible error) αποτελεί το τμήμα του σφάλματος σε ένα μοντέλο μηχανικής μάθησης που παραμένει ανεξάλειπτο, ανεξαρτήτως της βελτίωσης του μοντέλου. Αυτό το σφάλμα αποδίδεται στον εγγενή θόρυβο των δεδομένων, σε αστάθμητους παράγοντες ή σε τυχαίες διακυμάνσεις που υπάρχουν στα δεδομένα.

Το τρίτο είναι ότι για τις ενδιαμέσες κλάσεις παρατηρείται χαμηλότερη απόδοση. Και τα τρία μοντέλα παρουσιάζουν το ίδιο μοτίβο σφάλματος, καθώς τα $F1 - scores$ για τις κλάσεις Κρίσιμο και Χαμηλής Ανθεκτικότητας ($\approx 0.37 - 0.40$) είναι σχεδόν κατά το ήμισυ χαμηλότερες από αυτές των δύο ακραίων κλάσεων Μη Κρίσιμο και Πολύ Κρίσιμο ($\approx 0.63 - 0.72$). Αυτό το εύρημα είναι ιδιαίτερα σημαντικό από πρακτικής άποψης για μια μελλοντική εφαρμογή εποπτείας, καθώς δείχνει ότι τα μοντέλα είναι αξιόπιστα στην αναγνώριση οντοτήτων με σαφώς υψηλό ή χαμηλό κίνδυνο, αλλά είναι λιγότερο αποτελεσματικά στη λεπτομερή διαβάθμιση των μεσαίων περιπτώσεων. Συνεπώς, σε αυτές τις περιπτώσεις θα απαιτείται πιο συχνά η μεγαλύτερη εποπτική παρέμβαση.

Η τελευταία παρατήρηση αφορά την ερμηνευσιμότητα των μοντέλων ταξινόμησης σχετικά με τις 12 τομεακές (sector) μεταβλητές και τους 7 λειτουργικούς δείκτες που χρησιμοποιήθηκαν. Η ανάλυση SHAP αναδεικνύει ότι τα δύο μοντέλα δέντρων κατάφεραν με συνέπεια να εντοπίσουν το υποκείμενο μοτίβο των τομεακών μετατοπίσεων που είχαν εισαχθεί κατά τη δημιουργία των δεδομένων. Ειδικότερα, οι τομείς του «Τραπεζικού κλάδου», της «Ενέργειας» και των «Υποδομών χρηματοπιστωτικών αγορών» προσδιορίστηκαν ως αυτοί με την υψηλότερη πιθανότητα κατάταξης στην κλάση Πολύ Κρίσιμη. Αντιθέτως, οι τομείς των «Λυμάτων», της «Δημόσιας διοίκησης», του «Πόσιμου νερού» και των «Μεταφορών» αξιολογήθηκαν ως τομείς με σημαντικά χαμηλότερο κίνδυνο. Επιπλέον, από τους 7 διαθέσιμους λειτουργικούς δείκτες, ο βαθμός πιστοποίησης ISO 22301 (B1_iso_pct) αναδείχθηκε ως ο πιο ισχυρός ατομικός προβλεπτικός παράγοντας και στα δύο χρησιμοποιούμενα μοντέλα. Ακολουθεί ο αριθμός ασκήσεων ετοιμότητας (B3_exercises_num) και το ποσοστό έγκαιρης υποβολής αναφοράς περιστατικών (B5_incident_rep_pct). Αυτά τα αποτελέσματα ευθυγραμμίζονται με τη διεθνή βιβλιογραφία στον τομέα της οργανωσιακής ανθεκτικότητας, όπου η πιστοποιημένη επιχειρησιακή συνέχεια και η τακτική δοκιμή σχεδίων θεωρούνται από τους πλέον αξιόπιστους προγνωστικούς δείκτες.

4.3. Αποτελέσματα Συνθετικού Συνόλου Δεδομένων $n = 10.000$ Κρίσιμων Οντοτήτων

4.3.1. Κατανομή Οντοτήτων ανά Κλάση Ανθεκτικότητας

Η διαδικασία qcut, χρησιμοποιώντας 4 τεταρτημόρια, δημιούργησε, όπως ήταν αναμενόμενο, τέσσερις κλάσεις με ίσο αριθμό οντοτήτων από ένα σύνολο 10.000 οντοτήτων. Δηλαδή, Μη Κρίσιμο, Χαμηλής Ανθεκτικότητας, Κρίσιμο και Πολύ Κρίσιμο από 2.500 οντότητες.

4.3.2. Logistic Regression ως Baseline Μοντέλο

Το μοντέλο βάσης, χωρίς οποιαδήποτε ρύθμιση υπερπαραμέτρων, πέτυχε συνολική ακρίβεια ($accuracy = 0.56$) και ένα $macro - F1 = 0.551$ στο hold-out σύνολο ελέγχου. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον πίνακα 4.5, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη Κρίσιμο επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.72 και 0.66, αντίστοιχα. Αντίθετα,

οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ και στις δύο περιπτώσεις 0.41.

Πίνακας 4.5: Αποτελέσματα Ταξινόμησης Logistic Regression (hold-out, $n = 2.500$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.47	0.36	0.41	625
Μη Κρίσιμο	0.61	0.71	0.66	625
Πολύ Κρίσιμο	0.68	0.77	0.72	625
Χαμηλής Ανθεκτικότητας	0.43	0.40	0.41	625
Accuracy			0.56	2500
Macro avg	0.55	0.56	0.55	2500
Weighted avg	0.55	0.56	0.55	2500

4.3.3. Random Forest με Hyperparameter Tuning

Η τυχαία αναζήτηση υπερπαραμέτρων (RandomizedSearchCV) οδήγησε στον παρακάτω συνδυασμό ως τον καλύτερο: `{'n_estimators': 200, 'min_samples_split': 2, 'min_samples_leaf': 4, 'max_features': 'sqrt', 'max_depth': 15}`. Με αυτές τις παραμέτρους, το βέλτιστο Random Forest πέτυχε συνολική ακρίβεια ($accuracy = 0.55$) και ένα $macro - F1 = 0.535$ στο hold-out σύνολο ελέγχου, το οποίο είναι ελαφρώς χαμηλότερο από το Baseline. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον πίνακα 4.6, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη Κρίσιμο επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.71 και 0.64, αντίστοιχα. Αντίθετα, οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ 0.38 και 0.41, αντίστοιχα.

Πίνακας 4.6: Αποτελέσματα Ταξινόμησης Random Forest (hold-out, $n = 2.500$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.46	0.33	0.38	625
Μη Κρίσιμο	0.59	0.69	0.64	625
Πολύ Κρίσιμο	0.67	0.75	0.71	625
Χαμηλής Ανθεκτικότητας	0.42	0.41	0.41	625
Accuracy			0.55	2500
Macro avg	0.53	0.55	0.53	2500
Weighted avg	0.53	0.55	0.53	2500

4.3.4. XGBoost με Hyperparameter Tuning

Αντίστοιχα, η βελτιστοποίηση του XGBoost ανέδειξε τον εξής συνδυασμό παραμέτρων: `{'subsample': 0.85, 'reg_lambda': 2.0, 'reg_alpha': 0.0, 'n_estimators': 300, 'min_child_weight': 3, 'max_depth': 5, 'learning_rate': 0.03, 'colsample_bytree': 0.8}`.

Με αυτές τις παραμέτρους, το βέλτιστο XGBoost πέτυχε συνολική ακρίβεια ($accuracy = 0.54$) και ένα $macro - F1 = 0.526$ στο hold-out σύνολο ελέγχου, το οποίο είναι χαμηλότερο από το Baseline. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον

πίνακα 4.7, επίσης, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη Κρίσιμο επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.71 και 0.64, αντίστοιχα. Αντίθετα, οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ 0.38 και 0.41, αντίστοιχα.

Πίνακας 4.7: Αποτελέσματα Ταξινόμησης XGBoost (hold-out, $n = 2.500$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.44	0.34	0.38	625
Μη Κρίσιμο	0.59	0.68	0.63	625
Πολύ Κρίσιμο	0.66	0.74	0.70	625
Χαμηλής Ανθεκτικότητας	0.41	0.38	0.39	625
Accuracy			0.54	2500
Macro avg	0.52	0.54	0.53	2500
Weighted avg	0.52	0.54	0.53	2500

4.3.5. Συγκριτική Αξιολόγηση Μοντέλων για $n = 10.000$

Ο πίνακας 4.8 συνοψίζει την απόδοση των τριών μοντέλων, τόσο στο hold-out σύνολο όσο και στη 5-Fold Cross-Validation πάνω στο συνολικό dataset.

Πίνακας 4.8: Συγκριτική Απόδοση Μοντέλων (macro-F1 score, $n = 2.500$).

Μοντέλο	Hold-out macro-F1	5-Fold CV Mean	CV Std ($\pm$)
Logistic Regression (Baseline)	0.551	0.545	0.008
Random Forest	0.535	0.532	0.010
XGBoost	0.526	0.533	0.011

Το βασικό συμπέρασμα, για το σύνολο δεδομένων $n = 10.000$ οντότητες, συνίσταται στο ότι το πιο απλό μοντέλο, δηλαδή η Logistic Regression (Baseline), την καλύτερη απόδοση (macro-F1 = 0.551 στο hold-out και 0.545 στο 5-Fold Cross-Validation). Αυτή η απόδοση υπερβαίνει ελαφρώς το βελτιστοποιημένο μοντέλο Random Forest (0.535 / 0.532) και το βελτιστοποιημένο μοντέλο XGBoost (0.526 / 0.533). Οι διαφορές ανάμεσα στα τρία μοντέλα είναι σχετικώς ασήμαντες (εντός 0.3 – 0.7 ποσοστιαίων μονάδων) και εμπίπτουν στην τυπική απόκλιση του Cross-Validation ($\pm 0,008$ έως $\pm 0,011$), γεγονός που υποδηλώνει την απουσία στατιστικά σημαντικής υπεροχής κάποιου εκ των μοντέλων.


Η έλλειψη αξιοσημείωτης ανωτερότητας των πολυπλοκότερων μη γραμμικών μοντέλων, Random Forest και το XGBoost, σε σύγκριση με την Logistic Regression υποδηλώνει πιθανώς ότι η σχέση μεταξύ των χαρακτηριστικών εισόδου και της κλάσης ανθεκτικότητας είναι κατά κύριο λόγο γραμμική. Ενδέχεται, επίσης, να καταδεικνύει ότι η διαθέσιμη πληροφορία από τους 7 δείκτες, σε σύγκριση με τους συνολικά 22 δείκτες που απαρτίζουν το πραγματικό CRI score, δεν αρκεί ώστε η ανώτερη εκφραστική δυναμική των μοντέλων να παρέχει πρόσθετο προγνωστικό πλεονέκτημα.

4.3.6. Ερμηνευσιμότητα Μοντέλων (SHAP Analysis)

Η ανάλυση SHAP (Shapley Additive exPlanations) αποσκοπεί στην κατανόηση των δεικτών που επηρεάζουν τις προβλέψεις των μοντέλων, εστιάζοντας κυρίως στους παράγοντες που καθορίζουν την κατάταξη μιας οντότητας σε μια συγκεκριμένη κλάση ανθεκτικότητας. Για τα δύο μοντέλα δέντρων (Random Forest και XGBoost) υπολογίστηκαν οι τιμές SHAP μέσω TreeExplainer σε δείγμα 600 πρώτων παρατηρήσεων του συνόλου δεδομένων. Η εκτέλεση παρήγαγε επιτυχώς τέσσερα διαγράμματα SHAP (δύο ανά μοντέλο δέντρων). Δύο συγκεντρωτικά bar plots σπουδαιότητας χαρακτηριστικών σε όλες τις κλάσεις για το Random Forest και το XBoost, και δύο αναλυτικά beeswarm summary plots εστιασμένα στην κλάση Πολύ Κρίσιμο για το Random Forest και το XBoost. Σημειώνεται ότι, λόγω της αλφαβητικής κωδικοποίησης του LabelEncoder, στα bar plots η ετικέτα Class 2 αντιστοιχεί στην κλάση Πολύ Κρίσιμο, η Class 0 στην κλάση Κρίσιμο, η Class 1 στην κλάση Μη Κρίσιμο και η Class 3 στην κλάση Χαμηλής Ανθεκτικότητας.

1. Random Forest & XGBoost – Συνολική Σπουδαιότητα Χαρακτηριστικών

Στο μοντέλο Random Forest, οι τρεις σημαντικότερες μεταβλητές είναι οι τομείς (sector) «Τραπεζικός κλάδος», «Υποδομές χρηματοπιστωτικών αγορών» και «Ενέργεια», Ακολουθούν, οι έξι πιο σημαντικοί λειτουργικοί και ποσοτικοί δείκτες, με σειρά προτεραιότητας B3_exercises_num, B2_training_pct, B5_incident_rep_pct, B1_iso_pct, C4_user_satisfaction και C1_mttr. Εν συνεχεία, παρουσιάζονται οι τομείς «Ψηφιακές υποδομές» και «Λύματα», ενώ στο τέλος με την μικρότερη επιρροή είναι οι τομείς «Μεταφορές», «Δημόσια διοίκηση» και «Υγεία».




Εικόνα 4.4: SHAP Feature Importance CRI (Bar plots για όλες οι κλάσεις): α. Random Forest, και β. XGBoost.

Το μοντέλο XGBoost αποδίδει μεγαλύτερη συνολική βαρύτητα σε λειτουργικούς δείκτες. Αρχικά, οι λειτουργικοί και ποσοτικοί δείκτες που καταλαμβάνουν τις πρώτες έξι

υψηλότερες θέσεις, με σειρά σημαντικότητας, είναι B3_exercises_num, B5_incident_rep_pct, B2_training_pct, C4_user_satisfaction, C1_mttr και B1_iso_pct. Ακολουθούν, οι τομεακές μεταβλητές «Υποδομές χρηματοπιστωτικών αγορών», «Τραπεζικός κλάδος» και «Ενέργεια». Εν συνεχεία, παρουσιάζεται ο λειτουργικός δείκτης A2_plan_appr_pct και οι τομείς «Ψηφιακές υποδομές», «Λύματα» και «Αστικά απόβλητα». Τέλος, οι τομείς με την μικρότερη επιρροή είναι «Δημόσια διοίκηση», «Μεταφορές» και «Υγεία». Αυτή η διαφοροποίηση καταδεικνύει τον διαφορετικό χειρισμό των δύο μοντέλων στον χώρο των χαρακτηριστικών. Το XGBoost, αξιοποιώντας τον διαδοχικό μηχανισμό εκπαίδευσής του, φαίνεται να επιμερίζει τη βαρύτητα πιο ομοιόμορφα μεταξύ τομεακών και λειτουργικών παραμέτρων, ενώ το Random Forest τείνει να αποδίδει μεγαλύτερη βαρύτητα στα τομεακά σήματα.

2. Random Forest & XGBoost – Κατεύθυνση Επίδρασης για Κλάση «Πολύ Κρίσιμο»

Η ανάλυση beeswarm του Random Forest για την κλάση Πολύ Κρίσιμο αποδεικνύει ξεκάθαρα ότι η συμμετοχή στους τομείς «Τραπεζικός κλάδος», «Υποδομές χρηματοπιστωτικών αγορών» και «Ενέργεια» (κόκκινες κουκκίδες, τιμή χαρακτηριστικού = 1) ενισχύει σταθερά και έντονα την πρόβλεψη για την κλάση Πολύ Κρίσιμο με θετικές τιμές SHAP έως και 0,4 στην λογαριθμική κλίμακα log-odds. Αντίθετα, η απουσία από αυτούς τους τομείς (μπλε κουκκίδες, τιμή χαρακτηριστικού = 0) έχει μια ελαφρώς αρνητική επίδραση. Για τους τομείς «Λύματα», «Αστικά απόβλητα» και «Παραγωγή/διανομή τροφίμων» παρουσιάζουν αντίθετη κατεύθυνση, καθώς η συμμετοχής σ' αυτούς τους τομείς (κόκκινες κουκκίδες) σχετίζεται με αρνητικές τιμές SHAP και λειτουργεί προστατευτικά έναντι του χαρακτηρισμού Πολύ Κρίσιμο.



Εικόνα 4.5: SHAP Summary CRI (Beeswarm plots για την κλάση «Πολύ Κρίσιμο»): α. Random Forest, και β. XGBoost.

Για τους λειτουργικούς δείκτες (B2_training_pct, B3_exercises_num, C1_mttr, B5_incident_rep_pct, C4_user_satisfaction και B1_iso_pct), παρατηρείται ένα αναμενόμενο

μοτίβο, καθώς οι υψηλές τιμές (κόκκινες κουκκίδες) συνδέονται με θετική συνεισφορά στην πρόβλεψη της Πολύ Κρίσιμης κλάσης, ενώ οι χαμηλές τιμές (μπλε κουκκίδες) δείχνουν αρνητική τάση, υποδηλώνοντας ότι οι οντότητες με χαμηλότερη επιχειρησιακή ωριμότητα τείνουν να χαρακτηρίζονται ως λιγότερο ανθεκτικές.

Στο *beeswarm* του XGBoost για την κλάση Πολύ Κρίσιμο αποκαλύπτει με μεγαλύτερη σαφήνεια την ίδια τάση που διαπιστώθηκε στο Random Forest, αν και με εντονότερη διασπορά στις τιμές SHAP. Το εύρος κυμαίνεται από περίπου -1.3 έως $+1.4$, σε σύγκριση με το Random Forest που ήταν από -0.05 έως $+0.40$, κάτι αναμενόμενο λόγω των διαφορετικών κλιμάκων στο XGBoost για προβλήματα πολλαπλών κλάσεων. Για άλλη μια φορά, οι υψηλές τιμές στους δείκτες C1_mttr, B2_training_pct, C4_user_satisfaction, B5_incident_rep_pct και B3_exercises_num είναι συνδεδεμένες με θετική προώθηση προς την κλάση Πολύ Κρίσιμο. Επιπλέον, η συμμετοχή στον «Τραπεζικό κλάδο», τις «Υποδομές χρηματοπιστωτικών αγορών» και τον τομέα «Ενέργεια» συνεχίζει να λειτουργεί ως ισχυρός θετικός παράγοντας, όπως παρατηρήθηκε και στο Random Forest.

3. Σύγκριση Ερμηνευσιμότητας μεταξύ των Μοντέλων

Τα ευρήματα της ανάλυσης, για την περίπτωση του συνόλου δεδομένων με $n = 10.000$ οντότητες, συνοψίζονται σε τέσσερα κύρια σημεία, τα οποία προσφέρουν σημαντική αξία τόσο από μεθοδολογική όσο και από ερμηνευτική άποψη. Αρχικά, σε επίπεδο προγνωστικής ακρίβειας, τα επιτευχθέντα επίπεδα *macro* – *F1*, κυμαινόμενα από 0.54 έως 0.56 , υποδηλώνουν μέτρια, αντί για υψηλή, προγνωστική ικανότητα. Συγκεκριμένα, σε ένα πρόβλημα ταξινόμησης με τέσσερις ισοδύναμες κατηγορίες, ένας τυχαίος ταξινομητής θα αναμενόταν να επιτύχει ένα *macro* – *F1* περίπου ίσο με 0.25 . Τα χρησιμοποιούμενα μοντέλα υπερβαίνουν αυτό το όριο κατά περίπου $116 - 124\%$, γεγονός που μαρτυρά ότι οι 7 δείκτες που επιλέχθηκαν, λόγω ευκολίας προσβασιμότητας, περιέχουν πραγματικό, αλλά περιορισμένο προγνωστικό περιεχόμενο. Το γεγονός ότι η ακρίβεια είναι μέτρια, και όχι υψηλή, είναι αναμενόμενο και συνιστάται από τον σχεδιασμό του πειράματος.

Η περιορισμένη ικανότητα των μοντέλων να επιτύχουν ποσοστά *macro* – *F1* άνω του $\sim 55\%$ οφείλεται σε τέσσερις παράγοντες που είναι αλληλένδετα συνδεδεμένοι. Πρώτον, υπάρχει ένα ενδογενές πληροφοριακό κενό, καθώς η κλάση-στόχος προσδιορίζεται από ένα σύνολο 22 λειτουργικών δεικτών του Παραρτήματος ΣΤ' στις τέσσερις Διαστάσεις. Ωστόσο, τα μοντέλα έχουν πρόσβαση μόνο σε 7 από αυτούς (κυρίως στη Διάσταση Β). Επιπρόσθετα, έχουν πρόσβαση σε ένα στοιχείο από τη Διάσταση Α, δύο από τη Διάσταση Γ, ενώ δεν υπάρχει καμία πληροφορία από τη Διάσταση Δ (Sendai). Αυτό δημιουργεί έναν ανώτατο περιορισμό ως προς την ακρίβεια, ανεξάρτητο από τον χρησιμοποιούμενο αλγόριθμο. Δεύτερον, η διαδικασία παραγωγής δεδομένων περιέχει στοχαστικό θόρυβο τόσο στους επιμέρους δείκτες (με τυπική απόκλιση $\sigma = 4.0$) όσο και στο συνολικό CRI Score (με τυπική απόκλιση $\sigma = 3.5$), γεγονός που εισάγει αβεβαιότητα που κανένα μοντέλο δεν μπορεί να εξαλείψει πλήρως. Τρίτον, η μετατροπή της συνεχούς βαθμολογίας σε τεταρτημόρια δημιουργεί εκ φύσεως δυσδιάκριτες οριακές καταστάσεις, κυρίως στις δύο μεσαίες κατηγορίες. Τέταρτον, η μη γραμμική ποινή των -8 μονάδων που επιβάλλεται όταν οι Διαστάσεις Α και Β είναι συγχρόνως χαμηλές, δεν είναι πλήρως ανιχνεύσιμη από τα

μοντέλα, δεδομένου ότι η Διάσταση A παραμένει σχεδόν αόρατη στο διαθέσιμο σύνολο χαρακτηριστικών.

Για την παρατήρηση ότι οι αυξημένες τιμές στους δείκτες `B2_training_pct`, `B3_exercises_num`, `B5_incident_rep_pct` και `B1_iso_pct` συσχετίζονται με μεγαλύτερη πιθανότητα χαρακτηρισμού ως Πολύ Κρίσιμο αντί για Μη Κρίσιμο, απαιτεί λεπτομερή ανάλυση. Βάσει της μεθοδολογίας δημιουργίας του συνθετικού συνόλου δεδομένων, διαπιστώνεται μια σύγχυση ανάμεσα στη συσχέτιση λόγω κοινού αιτίου και της αιτιώδους σχέσης. Οι οντότητες υψηλού κινδύνου, όπως στους τομείς των τραπεζών και της ενέργειας, τείνουν να επενδύουν περισσότερο στην κατάρτιση, στις ασκήσεις ετοιμότητας και στις πιστοποιήσεις, καθώς αναγνωρίζουν τον αυξημένο κίνδυνο που αντιμετωπίζουν εξαιτίας της κρισιμότητας των υποδομών τους. Η μεταβλητή του τομέα ενεργεί ως κοινός παράγοντας, ο οποίος επηρεάζει τόσο το επίπεδο επένδυσης στην ετοιμότητα όσο και το τελικό επίπεδο κρισιμότητας, δημιουργώντας έτσι μια θετική συσχέτιση μεταξύ καλής προετοιμασίας και υψηλής κρισιμότητας που δεν υποδηλώνει απαραίτητα αιτιώδη σχέση. Αυτό το εύρημα αποτελεί μια κρίσιμη προειδοποίηση για την ορθή ερμηνεία των τιμών SHAP. Η μέθοδος SHAP καταδεικνύει τη λογική του μοντέλου σε ό,τι αφορά την κατανόηση και την εκμάθηση από τα δεδομένα, χωρίς απαραίτητα να αντικατοπτρίζει αιτιώδεις συνδέσεις στον πραγματικό κόσμο.

Τέλος, η κυριαρχία των μεταβλητών τομέα, ιδιαίτερα στο Random Forest, αντικατοπτρίζει με ακρίβεια τον τρόπο δημιουργίας του συνθετικού συνόλου δεδομένων, όπου εφαρμόστηκε ξεκάθαρη τομεακή μετατόπιση βασικής γραμμής στους δείκτες. Στο πραγματικό επιχειρηματικό πλαίσιο, αυτό μπορεί να ερμηνευθεί ως ένδειξη ότι ορισμένοι τομείς, όπως ο «Τραπεζικός κλάδος», οι «Υποδομές χρηματοπιστωτικών αγορών» και η «Ενέργεια», από τη φύση τους λειτουργούν σε συνθήκες αυξημένης πολυπλοκότητας, αλληλεξάρτησης και έκθεσης σε κινδύνους. Αυτό πιθανόν να αιτιολογεί μια διαφοροποιημένη εποπτική προσέγγιση ή την κατανομή πόρων εποπτείας με στόχο κάθε τομέα από τις αρμόδιες αρχές.

4.4. Αποτελέσματα Συνθετικού Συνόλου Δεδομένων $n = 20.000$ Κρίσιμων Οντοτήτων

4.4.1. Κατανομή Οντοτήτων ανά Κλάση Ανθεκτικότητας

Η διαδικασία `qcut`, χρησιμοποιώντας 4 τεταρτημόρια, δημιούργησε, όπως ήταν αναμενόμενο, τέσσερις κλάσεις με ίσο αριθμό οντοτήτων από ένα σύνολο 20.000 οντοτήτων. Δηλαδή, Μη Κρίσιμο, Χαμηλής Ανθεκτικότητας, Κρίσιμο και Πολύ Κρίσιμο από 5.000 οντότητες.

4.4.2. Logistic Regression ως Baseline Μοντέλο

Το μοντέλο βάσης, χωρίς οποιαδήποτε ρύθμιση υπερπαραμέτρων, πέτυχε συνολική ακρίβεια ($accuracy = 0.54$) και ένα $macro - F1 = 0.531$ στο hold-out σύνολο ελέγχου. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον πίνακα 4.9, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη Κρίσιμο επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.71 και 0.64, αντίστοιχα. Αντίθετα,

οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ 0.35 και 0.41, αντίστοιχα.

Πίνακας 4.9: Αποτελέσματα Ταξινόμησης Logistic Regression (hold-out, $n = 5.000$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.42	0.31	0.35	1250
Μη Κρίσιμο	0.59	0.70	0.64	1250
Πολύ Κρίσιμο	0.67	0.76	0.71	1250
Χαμηλής Ανθεκτικότητας	0.43	0.40	0.41	1250
Accuracy			0.54	5000
Macro avg	0.53	0.54	0.53	5000
Weighted avg	0.53	0.54	0.53	5000

4.4.3. Random Forest με Hyperparameter Tuning

Η τυχαία αναζήτηση υπερπαραμέτρων (RandomizedSearchCV) οδήγησε στον παρακάτω συνδυασμό ως τον καλύτερο: `{'n_estimators': 500, 'min_samples_split': 4, 'min_samples_leaf': 4, 'max_features': 'sqrt', 'max_depth': 20}`. Με αυτές τις παραμέτρους, το βέλτιστο Random Forest πέτυχε συνολική ακρίβεια ($accuracy = 0.53$) και ένα $macro - F1 = 0.520$ στο hold-out σύνολο ελέγχου, το οποίο είναι ελαφρώς χαμηλότερο από το Baseline. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον πίνακα 4.10, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη Κρίσιμο επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.70 και 0.64, αντίστοιχα. Αντίθετα, οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ 0.33 και 0.41, αντίστοιχα.

Πίνακας 4.10: Αποτελέσματα Ταξινόμησης Random Forest (hold-out, $n = 5.000$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.40	0.28	0.33	1250
Μη Κρίσιμο	0.58	0.70	0.64	1250
Πολύ Κρίσιμο	0.66	0.74	0.70	1250
Χαμηλής Ανθεκτικότητας	0.42	0.41	0.41	1250
Accuracy			0.53	5000
Macro avg	0.52	0.53	0.52	5000
Weighted avg	0.52	0.53	0.52	5000

4.4.4. XGBoost με Hyperparameter Tuning

Αντίστοιχα, η βελτιστοποίηση του XGBoost ανέδειξε τον εξής συνδυασμό παραμέτρων: `{'subsample': 0.85, 'reg_lambda': 2.0, 'reg_alpha': 0.0, 'n_estimators': 300, 'min_child_weight': 3, 'max_depth': 5, 'learning_rate': 0.03, 'colsample_bytree': 0.8}`. Με αυτές τις παραμέτρους, το βέλτιστο XGBoost πέτυχε συνολική ακρίβεια ($accuracy = 0.53$) και ένα $macro - F1 = 0.521$ στο hold-out σύνολο ελέγχου, το οποίο είναι χαμηλότερο από το Baseline. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον πίνακα 4.11, επίσης, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη

Κρίσιμο επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.70 και 0.65, αντίστοιχα. Αντίθετα, οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ 0.33 και 0.40, αντίστοιχα.

Πίνακας 4.11: Αποτελέσματα Ταξινόμησης XGBoost (hold-out, $n = 5.000$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.40	0.28	0.33	1250
Μη Κρίσιμο	0.59	0.72	0.65	1250
Πολύ Κρίσιμο	0.67	0.75	0.70	1250
Χαμηλής Ανθεκτικότητας	0.41	0.39	0.40	1250
Accuracy			0.53	5000
Macro avg	0.52	0.53	0.52	5000
Weighted avg	0.52	0.53	0.52	5000

4.4.5. Συγκριτική Αξιολόγηση Μοντέλων για $n = 20.000$

Ο πίνακας 4.12 συνοψίζει την απόδοση των τριών μοντέλων, τόσο στο hold-out σύνολο όσο και στη 5-Fold Cross-Validation πάνω στο συνολικό dataset.

Πίνακας 4.12: Συγκριτική Απόδοση Μοντέλων (macro-F1 score, $n = 5.000$).

Μοντέλο	Hold-out macro-F1	5-Fold CV Mean	CV Std ($\pm$)
Logistic Regression (Baseline)	0.531	0.538	0.007
Random Forest	0.520	0.525	0.007
XGBoost	0.521	0.529	0.008

Το βασικό συμπέρασμα, για το σύνολο δεδομένων $n = 10.000$ οντότητες, συνίσταται στο ότι το πιο απλό μοντέλο, δηλαδή η Logistic Regression (Baseline), την καλύτερη απόδοση (macro-F1 = 0.531 στο hold-out και 0.538 στο 5-Fold Cross-Validation). Αυτή η απόδοση υπερβαίνει ελαφρώς το βελτιστοποιημένο μοντέλο Random Forest (0.520 / 0.525) και το βελτιστοποιημένο μοντέλο XGBoost (0.521 / 0.529). Οι διαφορές ανάμεσα στα τρία μοντέλα είναι σχετικώς ασήμαντες (εντός 0.5 – 0.8 ποσοστιαίων μονάδων) και εμπίπτουν στην τυπική απόκλιση του Cross-Validation ($\pm 0,005$ έως $\pm 0,008$), γεγονός που υποδηλώνει την απουσία στατιστικά σημαντικής υπεροχής κάποιου εκ των μοντέλων.


Η έλλειψη αξιοσημείωτης ανωτερότητας των πολυπλοκότερων μη γραμμικών μοντέλων, Random Forest και το XGBoost, σε σύγκριση με την Logistic Regression υποδηλώνει πιθανώς ότι η σχέση μεταξύ των χαρακτηριστικών εισόδου και της κλάσης ανθεκτικότητας είναι κατά κύριο λόγο γραμμική. Ενδέχεται, επίσης, να καταδεικνύει ότι η διαθέσιμη πληροφορία από τους 7 δείκτες, σε σύγκριση με τους συνολικά 22 δείκτες που απαρτίζουν το πραγματικό CRI score, δεν αρκεί ώστε η ανώτερη εκφραστική δυναμική των μοντέλων να παρέχει πρόσθετο προγνωστικό πλεονέκτημα.

4.4.6. Ερμηνευσιμότητα Μοντέλων (SHAP Analysis)

Η ανάλυση SHAP (Shapley Additive exPlanations) αποσκοπεί στην κατανόηση των δεικτών που επηρεάζουν τις προβλέψεις των μοντέλων, εστιάζοντας κυρίως στους παράγοντες που καθορίζουν την κατάταξη μιας οντότητας σε μια συγκεκριμένη κλάση ανθεκτικότητας. Για τα δύο μοντέλα δέντρων (Random Forest και XGBoost) υπολογίστηκαν οι τιμές SHAP μέσω TreeExplainer σε δείγμα 600 πρώτων παρατηρήσεων του συνόλου δεδομένων. Η εκτέλεση παρήγαγε επιτυχώς τέσσερα διαγράμματα SHAP (δύο ανά μοντέλο δέντρων). Δύο συγκεντρωτικά bar plots σπουδαιότητας χαρακτηριστικών σε όλες τις κλάσεις για το Random Forest και το XBoost, και δύο αναλυτικά beeswarm summary plots εστιασμένα στην κλάση Πολύ Κρίσιμο για το Random Forest και το XBoost. Σημειώνεται ότι, λόγω της αλφαβητικής κωδικοποίησης του LabelEncoder, στα bar plots η ετικέτα Class 2 αντιστοιχεί στην κλάση Πολύ Κρίσιμο, η Class 0 στην κλάση Κρίσιμο, η Class 1 στην κλάση Μη Κρίσιμο και η Class 3 στην κλάση Χαμηλής Ανθεκτικότητας.

1. Random Forest & XGBoost – Συνολική Σπουδαιότητα Χαρακτηριστικών

Στο μοντέλο Random Forest, οι τρεις σημαντικότερες μεταβλητές είναι οι τομείς (sector) «Τραπεζικός κλάδος», «Υποδομές χρηματοπιστωτικών αγορών» και «Ενέργεια» και ακολουθούν οι 7 λειτουργικοί και ποσοτικοί δείκτες, με σειρά σημαντικότητας C4_user_satisfaction, B1_iso_pct, A2_plan_appr_pct, B5_incident_rep_pct, B3_exercises_num, C1_mttr και B2_training_pct. Έπειτα ακολουθούν οι τομείς «Ψηφιακές υποδομές» και «Αστικά απόβλητα», ενώ οι τομείς με την μικρότερη επιρροή είναι «Μεταφορές», «Πόσιμο νερό» και «Υγεία».



Εικόνα 4.6: SHAP Feature Importance CRI (Bar plots για όλες οι κλάσεις): α. Random Forest, και β. XGBoost.

Στο μοντέλο XGBoost, η κατάσταση διαφοροποιείται, καθώς αποδίδει μεγαλύτερη συνολική βαρύτητα στους τομείς «Υποδομές χρηματοπιστωτικών αγορών» και «Τραπεζικός κλάδος»,

αλλά μετά ακολουθούν και οι 7 λειτουργικοί και ποσοτικοί δείκτες, με σειρά σημαντικότητας B1_iso_pct, C4_user_satisfaction, B5_incident_rep_pct, C1_mttr, B3_exercises_num, A2_plan_appr_pct και B2_training_pct. Έπειτα ακολουθούν οι τομείς «Ενέργεια» και «Λύματα», ενώ οι τομείς με την μικρότερη επιρροή είναι «Πόσιμο νερό», «Υγεία» και «Μεταφορές». Αυτή η διαφοροποίηση καταδεικνύει τον διαφορετικό χειρισμό των δύο μοντέλων στον χώρο των χαρακτηριστικών. Το XGBoost, αξιοποιώντας τον διαδοχικό μηχανισμό εκπαίδευσής του, φαίνεται να επιμερίζει τη βαρύτητα πιο ομοιόμορφα μεταξύ τομεακών και λειτουργικών παραμέτρων, ενώ το Random Forest τείνει να αποδίδει μεγαλύτερη βαρύτητα στα τομεακά σήματα.


2. Random Forest & XGBoost – Κατεύθυνση Επίδρασης για Κλάση «Πολύ Κρίσιμο»

Το beeswarm του Random Forest για την κλάση Πολύ Κρίσιμο παρέχει σαφή εικόνα της επίδρασης διαφορετικών τομέων στις προβλέψεις. Η ένταξη μιας οντότητας στους τομείς του «Τραπεζικού κλάδου», «Υποδομών χρηματοπιστωτικών αγορών», «Ενέργειας», «Ψηφιακών υποδομών» ή «Διαστήματος» επιδεικνύει μια σταθερή και σημαντική θετική ώθηση προς την κατηγοριοποίηση ως κλάση Πολύ Κρίσιμο. Αυτό απεικονίζεται με τις τιμές SHAP να φθάνουν από 0.3 έως 0.4 και πιο πάνω (κόκκινες κουκκίδες, τιμή χαρακτηριστικού = 1), ενώ η απουσία από αυτούς τους τομείς (κουκκίδες μπλε χρώματος) έχει μια περιορισμένη αρνητική επίδραση. Αντιθέτως, η συμμετοχή σε τομείς όπως «Λύματα», «Αστικά απόβλητα», «Δημόσια διοίκηση», «Πόσιμο νερό», «Υγεία» και «Παραγωγή/διανομή τροφίμων» λειτουργεί προστατευτικά έναντι της κατάταξης ως κλάση Πολύ Κρίσιμο, που υποδηλώνεται από αρνητικές τιμές SHAP. Όσον αφορά στους λειτουργικούς δείκτες B1_iso_pct, C4_user_satisfaction, B5_incident_rep_pct, A2_plan_appr_pct, C1_mttr, B2_training_pct και B3_exercises_num, παρατηρείται μια αναμενόμενη μονότονη σχέση με τις υψηλότερες τιμές των δεικτών (κόκκινες κουκκίδες) να συνδέονται με θετική ώθηση προς την κλάση Πολύ Κρίσιμο.

Αυτό είναι σε ένα βαθμό αντιφατικό, καθώς θα αναμενόταν οι υψηλότερες επιδόσεις σε δείκτες ετοιμότητας, όπως η πιστοποίηση ISO 22301 ή η εκπαίδευση προσωπικού, να αντιστοιχούν σε μειωμένη κρισιμότητα. Η αντίφαση αυτή εξηγείται μέσω της διαδικασίας παραγωγής του συνθετικού δείγματος όπως εξηγήθηκε και στα συμπεράσματα του προηγούμενου πειράματος. Οι τομείς που χαρακτηρίζονται από υψηλή τομεακή μετατόπιση βάσης, όπως ο «Τραπεζικός κλάδος» και η «Ενέργεια», έχουν συστηματικά αυξημένες τιμές σε όλους τους δείκτες, περιλαμβανομένων αυτών που συμβάλλουν στο CRI. Το μοντέλο, χωρίς πρόσβαση στους δείκτες της Δ' Διάστασης (Sendai) που επηρεάζουν έντονα αυτούς τους τομείς, ερμηνεύει τις υψηλές τιμές των ορατών δεικτών ως χαρακτηριστικό τομεακής ταυτότητας υψηλού κινδύνου και όχι ως ένδειξη πραγματικής επιχειρησιακής ετοιμότητας.

Στο beeswarm του XGBoost η κλάση Πολύ Κρίσιμο καταδεικνύει παρόμοια ποιοτικά χαρακτηριστικά με το Random Forest, αλλά με μεγαλύτερη ποικιλία τιμών SHAP, ακόμη και πάνω από 1.0 για τον «Τραπεζικό κλάδο» και την «Ενέργεια». Οι τομείς που θεωρούνται υψηλού κινδύνου, όπως ο «Τραπεζικός κλάδος», οι «Υποδομές χρηματοπιστωτικών αγορών», η «Ενέργεια», οι «Ψηφιακές υποδομές» και το «Διάστημα», τείνουν να κατευθύνουν έντονα προς την κλάση Πολύ Κρίσιμο όταν μια οντότητα ανήκει σε αυτούς. Αντίθετα, οι τομείς όπως

τα «Λύματα», τα «Αστικά απόβλητα», η «Δημόσια διοίκηση», η «Παραγωγή/διανομή τροφίμων», το «Πόσιμο νερό» και η «Υγεία» παρέχουν έναν προστατευτικό ρόλο.



Εικόνα 4.7: SHAP Summary CRI (Beeswarm plots για την κλάση «Πολύ Κρίσιμο»): α. Random Forest, και β. XGBoost.

Σε ό,τι αφορά τους λειτουργικούς δείκτες, το XGBoost αναδεικνύει πιο καθαρά τη θετική συσχέτιση μεταξύ υψηλών τιμών και της πρόβλεψης Πολύ Κρίσιμο, ιδιαίτερα για τους δείκτες `B1_iso_pct` και `B5_incident_rep_pct`. Αυτή η διαπίστωση ενισχύει την προηγούμενη ερμηνεία, η οποία εξετάζει τη σύγκριση μεταξύ τομεακής ταυτότητας και πραγματικής επιχειρησιακής ετοιμότητας.

3. Σύγκριση Ερμηνευσιμότητας μεταξύ των Μοντέλων

Η ανάλυση που πραγματοποιήθηκε σε δείγμα μεγέθους $n = 20.000$ αποκαλύπτει τρία σημαντικά ευρήματα με ιδιαίτερη σημασία. Πρώτον, η πρόβλεψη της κλάσης ανθεκτικότητας με τη χρήση ενός περιορισμένου εύρους εύκολα παρατηρήσιμων δεικτών είναι δυνατή με ακρίβεια ανώτερη της τυχαίας πρόγνωσης ($macro - F1 \approx 0.52 - 0.531$, $accuracy \approx 0.53 - 0.54$), αν και παραμένει σημαντικό περιθώριο βελτίωσης προτού αυτές οι προβλέψεις μπορέσουν να ενισχύσουν πλήρως αυτοματοποιημένες διαδικασίες λήψης αποφάσεων. Δεύτερον, η αύξηση της πολυπλοκότητας του μοντέλου, από τη χρήση λογιστικής παλινδρόμησης έως τα σύνολα δέντρων με βελτιστοποιημένες υπερπαραμέτρους, δεν παρέχει κάποιο αξιόλογο πλεονέκτημα ως προς την απόδοση στο συγκεκριμένο πλαίσιο και σύνολο χαρακτηριστικών. Τρίτον, η ταυτότητα του τομέα δραστηριότητας αναδεικνύεται ως κεντρικός παράγοντας στην πρόγνωση της κρισιμότητας εντός του συνθετικού δείγματος. Ωστόσο, αυτό το εύρημα απαιτεί προσεκτική ερμηνεία, καθώς ενδέχεται να αντικατοπτρίζει τις υποθέσεις του σχεδιασμού της γεννήτριας δεδομένων και όχι φυσική τομεακή αιτιότητα.

4.5. Αποτελέσματα Συνθετικού Συνόλου Δεδομένων $n = 40.000$ Κρίσιμων Οντοτήτων

4.5.1. Κατανομή Οντοτήτων ανά Κλάση Ανθεκτικότητας

Η διαδικασία `qsut`, χρησιμοποιώντας 4 τεταρτημόρια, δημιούργησε, όπως ήταν αναμενόμενο, τέσσερις κλάσεις με ίσο αριθμό οντοτήτων από ένα σύνολο 40.000 οντοτήτων. Δηλαδή, Μη Κρίσιμο, Χαμηλής Ανθεκτικότητας, Κρίσιμο και Πολύ Κρίσιμο από 10.000 οντότητες.

4.5.2. Logistic Regression ως Baseline Μοντέλο

Το μοντέλο βάσης, χωρίς οποιαδήποτε ρύθμιση υπερπαραμέτρων, πέτυχε συνολική ακρίβεια ($accuracy = 0.56$) και ένα $macro - F1 = 0.544$ στο hold-out σύνολο ελέγχου. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον πίνακα 4.13, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη Κρίσιμο επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.73 και 0.66, αντίστοιχα. Αντίθετα, οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ 0.39 και 0.40, αντίστοιχα.

Πίνακας 4.13: Αποτελέσματα Ταξινόμησης Logistic Regression (hold-out, $n = 10.000$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.44	0.35	0.39	2500
Μη Κρίσιμο	0.61	0.73	0.66	2500
Πολύ Κρίσιμο	0.69	0.77	0.73	2500
Χαμηλής Ανθεκτικότητας	0.43	0.37	0.40	2500
Accuracy			0.56	10000
Macro avg	0.54	0.56	0.54	10000
Weighted avg	0.54	0.56	0.54	10000

4.5.3. Random Forest με Hyperparameter Tuning

Η τυχαία αναζήτηση υπερπαραμέτρων (`RandomizedSearchCV`) οδήγησε στον παρακάτω συνδυασμό ως τον καλύτερο: `{'n_estimators': 500, 'min_samples_split': 4, 'min_samples_leaf': 4, 'max_features': 'sqrt', 'max_depth': 20}`.

Με αυτές τις παραμέτρους, το βέλτιστο Random Forest πέτυχε συνολική ακρίβεια ($accuracy = 0.55$) και ένα $macro - F1 = 0.534$ στο hold-out σύνολο ελέγχου, το οποίο είναι ελαφρώς χαμηλότερο από το Baseline. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον πίνακα 4.14, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη Κρίσιμο επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.72 και 0.65, αντίστοιχα. Αντίθετα, οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ 0.38 και 0.39, αντίστοιχα.

Πίνακας 4.14: Αποτελέσματα Ταξινόμησης Random Forest (hold-out, $n = 10.000$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.43	0.34	0.38	2500
Μη Κρίσιμο	0.60	0.71	0.65	2500
Πολύ Κρίσιμο	0.68	0.76	0.72	2500
Χαμηλής Ανθεκτικότητας	0.41	0.37	0.39	2500
Accuracy			0.55	10000
Macro avg	0.53	0.55	0.53	10000
Weighted avg	0.53	0.55	0.53	10000

4.5.4. XGBoost με Hyperparameter Tuning

Αντίστοιχα, η βελτιστοποίηση του XGBoost ανέδειξε τον εξής συνδυασμό παραμέτρων: {'subsample': 0.85, 'reg_lambda': 2.0, 'reg_alpha': 0.0, 'n_estimators': 300, 'min_child_weight': 3, 'max_depth': 5, 'learning_rate': 0.03, 'colsample_bytree': 0.8}. Με αυτές τις παραμέτρους, το βέλτιστο XGBoost πέτυχε συνολική ακρίβεια ($accuracy = 0.538$) και ένα $macro - F1 = 0.538$ στο hold-out σύνολο ελέγχου, το οποίο είναι χαμηλότερο από το Baseline. Η πλήρης αναφορά της ταξινόμησης, που παρουσιάζεται στον πίνακα 4.15, επίσης, δείχνει μια σαφή ετερογένεια απόδοσης μεταξύ των κλάσεων. Οι ακραίες κλάσεις Πολύ Κρίσιμο και Μη Κρίσιμο επιτυγχάνουν σχετικά καλή αναγνώριση με $F1 - score$ 0.71 και 0.66, αντίστοιχα. Αντίθετα, οι ενδιάμεσες κλάσεις, Κρίσιμο και Χαμηλής Ανθεκτικότητας, εμφανίζουν αισθητά χαμηλότερη απόδοση, με $F1 - score$ 0.38 και 0.40, αντίστοιχα.

Πίνακας 4.15: Αποτελέσματα Ταξινόμησης XGBoost (hold-out, $n = 10.000$).

Κλάση	Precision	Recall	F1-score	Support
Κρίσιμο	0.44	0.34	0.38	2500
Μη Κρίσιμο	0.60	0.73	0.66	2500
Πολύ Κρίσιμο	0.67	0.76	0.71	2500
Χαμηλής Ανθεκτικότητας	0.42	0.38	0.40	2500
Accuracy			0.55	10000
Macro avg	0.53	0.55	0.54	10000
Weighted avg	0.53	0.55	0.55	10000

4.5.5. Συγκριτική Αξιολόγηση Μοντέλων για $n = 40.000$

Ο πίνακας 4.16 συνοψίζει την απόδοση των τριών μοντέλων, τόσο στο hold-out σύνολο όσο και στη 5-Fold Cross-Validation πάνω στο συνολικό dataset.

Πίνακας 4.16: Συγκριτική Απόδοση Μοντέλων (macro-F1 score, $n = 10.000$).

Μοντέλο	Hold-out macro-F1	5-Fold CV Mean	CV Std ($\pm$)
Logistic Regression (Baseline)	0.544	0.545	0.001
Random Forest	0.534	0.532	0.003
XGBoost	0.538	0.537	0.004

Για το σύνολο δεδομένων $n = 40.000$ οντότητες, προκύπτει ότι το πιο απλό μοντέλο, δηλαδή η Logistic Regression (Baseline), την καλύτερη απόδοση ($\text{macro-F1} = 0.544$ στο hold-out και 0.545 στο 5-Fold Cross-Validation). Αυτή η απόδοση υπερβαίνει ελαφρώς το βελτιστοποιημένο μοντέλο Random Forest ($0.534 / 0.532$) και το βελτιστοποιημένο μοντέλο XGBoost ($0.538 / 0.537$). Οι διαφορές ανάμεσα στα τρία μοντέλα είναι σχετικώς ασήμαντες (εντός $0.1 - 0.2$ ποσοστιαίων μονάδων) και εμπίπτουν στην τυπική απόκλιση του Cross-Validation ($\pm 0,001$ έως $\pm 0,004$), γεγονός που υποδηλώνει την απουσία στατιστικά σημαντικής υπεροχής κάποιου εκ των μοντέλων. Η πολύ μικρή τυπική απόκλιση ($CV Std \leq 0.004$) σε όλα τα μοντέλα υποδηλώνει εξαιρετική σταθερότητα εκτιμήσεων, κάτι που άλλωστε φαινόταν αναμενόμενο δεδομένου του μεγάλου μεγέθους του συνόλου δεδομένων.

Το κύριο εύρημα, σε αυτό το σύνολο δεδομένων, είναι ότι παρά την αυξημένη πολυπλοκότητα και τις εντατικές προσπάθειες βελτιστοποίησης των υπερπαραμέτρων, οι δύο αλγόριθμοι βασισμένοι σε δομές δέντρου (Random Forest και XGBoost) δεν κατάφεραν να ξεπεράσουν το απλό μοντέλο αναφοράς (Logistic Regression). Πιο συγκεκριμένα, το Random Forest είχε ελαφρώς χειρότερη απόδοση (-0.010 στην τιμή macro-F1), ενώ το XGBoost παρουσίασε μια οριακή υστέρηση (-0.006). Αυτές οι διαφορές, που κυμαίνονται μεταξύ $1 - 2\%$, βρίσκονται εντός του πλαισίου στατιστικού θορύβου σύμφωνα με τα $CV Std$, γεγονός που τις καθιστά πρακτικά ασήμαντες. Αυτό το εύρημα δεν αντικατοπτρίζει κάποια αδυναμία στην υλοποίηση, καθώς η αναζήτηση υπερπαραμέτρων ήταν λεπτομερής και οι επιλογές τιμών λογικές. Αντίθετα, πρόκειται για μια ισχυρή ένδειξη ότι το ανώτατο όριο απόδοσης ($\sim 0.534 - 0.544 \text{ macro-F1}$) επιβάλλεται από τη φύση του προβλήματος παρά από την εκφραστική ικανότητα του αλγορίθμου.


4.5.6. Ερμηνευσιμότητα Μοντέλων (SHAP Analysis)

Η ανάλυση SHAP (Shapley Additive exPlanations) αποσκοπεί στην κατανόηση των δεικτών που επηρεάζουν τις προβλέψεις των μοντέλων, εστιάζοντας κυρίως στους παράγοντες που καθορίζουν την κατάταξη μιας οντότητας σε μια συγκεκριμένη κλάση ανθεκτικότητας. Για τα δύο μοντέλα δέντρων (Random Forest και XGBoost) υπολογίστηκαν οι τιμές SHAP μέσω TreeExplainer σε δείγμα 600 πρώτων παρατηρήσεων του συνόλου δεδομένων. Η εκτέλεση παρήγαγε επιτυχώς τέσσερα διαγράμματα SHAP (δύο ανά μοντέλο δέντρων). Δύο συγκεντρωτικά bar plots σπουδαιότητας χαρακτηριστικών σε όλες τις κλάσεις για το Random Forest και το XBoost, και δύο αναλυτικά beeswarm summary plots εστιασμένα στην κλάση Πολύ Κρίσιμο για το Random Forest και το XBoost. Σημειώνεται ότι, λόγω της αλφαβητικής κωδικοποίησης του LabelEncoder, στα bar plots η ετικέτα Class 2 αντιστοιχεί στην κλάση Πολύ Κρίσιμο, η Class 0 στην κλάση Κρίσιμο, η Class 1 στην κλάση Μη Κρίσιμο και η Class 3 στην κλάση Χαμηλής Ανθεκτικότητας.

1. Random Forest & XGBoost – Συνολική Σπουδαιότητα Χαρακτηριστικών

Στο μοντέλο Random Forest, οι τρεις σημαντικότερες μεταβλητές είναι οι τομείς (sector) «Τραπεζικός κλάδος», «Υποδομές χρηματοπιστωτικών αγορών» και «Ενέργεια» και ακολουθούν οι 5 λειτουργικοί και ποσοτικοί δείκτες, με σειρά σημαντικότητας

C4_user_satisfaction, B1_iso_pct, A2_plan_appr_pct, B5_incident_rep_pct και C1_mttr. Έπειτα ακολουθούν ο τομέας «Ψηφιακές υποδομές», οι λειτουργικοί και ποσοτικοί δείκτες B2_training_pct, B3_exercises_num, και ο τομέας «Αστικά απόβλητα», ενώ οι τομείς με την μικρότερη επιρροή είναι «Δημόσια διοίκηση», «Πόσιμο νερό» και «Υγεία».




Εικόνα 4.8: SHAP Feature Importance CRI (Bar plots για όλες οι κλάσεις): α. Random Forest, και β. XGBoost.

Στο μοντέλο XGBoost, η κατάσταση διαφοροποιείται, καθώς αποδίδει μεγαλύτερη βαρύτητα στον λειτουργικό δείκτη C4_user_satisfaction. Ακολουθούν οι τομείς «Υποδομές χρηματοπιστωτικών αγορών» και «Τραπεζικός κλάδος», οι λειτουργικοί και ποσοτικοί δείκτες B1_iso_pct, B2_training_pct, C1_mttr, ο τομέας «Ενέργεια», ο λειτουργικός δείκτης B3_exercises_num και ο τομέας «Ψηφιακές υποδομές». Τέλος, οι τομείς με την μικρότερη επιρροή είναι «Πόσιμο νερό», «Μεταφορές» και «Υγεία». Αυτή η διαφοροποίηση καταδεικνύει τον διαφορετικό χειρισμό των δύο μοντέλων στον χώρο των χαρακτηριστικών. Το XGBoost, αξιοποιώντας τον διαδοχικό μηχανισμό εκπαίδευσής του, φαίνεται να επιμερίζει τη βαρύτητα πιο ομοιόμορφα μεταξύ τομεακών και λειτουργικών παραμέτρων, ενώ το Random Forest τείνει να αποδίδει μεγαλύτερη βαρύτητα στα τομεακά σήματα.

2. Random Forest & XGBoost – Κατεύθυνση Επίδρασης για Κλάση «Πολύ Κρίσιμο»

Το beeswarm του Random Forest για την κλάση Πολύ Κρίσιμο παρέχει σαφή εικόνα της επίδρασης διαφορετικών τομέων στις προβλέψεις. Η ένταξη μιας οντότητας στους τομείς του «Τραπεζικού κλάδου», «Υποδομών χρηματοπιστωτικών αγορών», «Ενέργειας», «Ψηφιακών υποδομών» ή «Διαστήματος» επιδεικνύει μια σταθερή και σημαντική θετική ώθηση προς την κατηγοριοποίηση ως κλάση Πολύ Κρίσιμο. Αυτό απεικονίζεται με τις τιμές SHAP να φθάνουν από 0.3 έως 0.4 και πιο πάνω (κόκκινες κουκκίδες, τιμή χαρακτηριστικού = 1), ενώ η απουσία από αυτούς τους τομείς (κουκκίδες μπλε χρώματος) έχει μια περιορισμένη αρνητική επίδραση.



Εικόνα 4.9: SHAP Summary CRI (Beeswarm plots για την κλάση «Πολύ Κρίσιμο»): α. Random Forest, και β. XGBoost

Αντιθέτως, η συμμετοχή σε τομείς όπως «Λύματα», «Αστικά απόβλητα», «Παραγωγή/διανομή τροφίμων», «Δημόσια διοίκηση», «Πόσιμο νερό», «Υγεία» και «Μεταφορές» λειτουργεί προστατευτικά έναντι της κατάταξης ως κλάση Πολύ Κρίσιμο, που υποδηλώνεται από αρνητικές τιμές SHAP. Όσον αφορά στους λειτουργικούς δείκτες C4_user_satisfaction, B1_iso_pct, B5_incident_rep_pct, B2_training_pct, C1_mttr, B3_exercises_num, και A2_plan_appr_pct παρατηρείται μια αναμενόμενη μονότονη σχέση με τις υψηλότερες τιμές των δεικτών (κόκκινες κουκκίδες) να συνδέονται με θετική ώθηση προς την κλάση Πολύ Κρίσιμο. Αυτό είναι σε ένα βαθμό αντιφατικό, καθώς θα αναμενόταν οι υψηλότερες επιδόσεις σε δείκτες ετοιμότητας, όπως η ικανοποίηση των χριστών/πολιτών για τις παρεχόμενες υπηρεσίες ή η πιστοποίηση ISO 22301, να αντιστοιχούν σε μειωμένη κρισιμότητα. Η αντίφαση αυτή εξηγείται μέσω της διαδικασίας παραγωγής του συνθετικού δείγματος όπως εξηγήθηκε και στα συμπεράσματα του προηγούμενου πειράματος. Οι τομείς που χαρακτηρίζονται από υψηλή τομεακή μετατόπιση βάσης, όπως ο «Τραπεζικός κλάδος» και η «Ενέργεια», έχουν συστηματικά αυξημένες τιμές σε όλους τους δείκτες, περιλαμβανομένων αυτών που συμβάλλουν στο CRI. Το μοντέλο, χωρίς πρόσβαση στους δείκτες της Δ' Διάστασης (Sendai) που επηρεάζουν έντονα αυτούς τους τομείς, ερμηνεύει τις υψηλές τιμές των ορατών δεικτών ως χαρακτηριστικό τομεακής ταυτότητας υψηλού κινδύνου και όχι ως ένδειξη πραγματικής επιχειρησιακής ετοιμότητας.

Στο beeswarm του XGBoost η κλάση Πολύ Κρίσιμο καταδεικνύει παρόμοια ποιοτικά χαρακτηριστικά με το Random Forest, αλλά με μεγαλύτερη ποικιλία τιμών SHAP, ακόμη και πάνω από 1.0 για τον «Τραπεζικό κλάδο» και την «Ενέργεια». Οι τομείς που θεωρούνται υψηλού κινδύνου, όπως ο «Τραπεζικός κλάδος», οι «Υποδομές χρηματοπιστωτικών αγορών», η «Ενέργεια», οι «Ψηφιακές υποδομές» και το «Διάστημα», τείνουν να κατευθύνουν έντονα προς την κλάση Πολύ Κρίσιμο όταν μια οντότητα ανήκει σε αυτούς. Αντίθετα, οι τομείς όπως



τα «Λύματα», η «Παραγωγή/διανομή τροφίμων», τα «Αστικά απόβλητα», η «Δημόσια διοίκηση», το «Πόσιμο νερό» και η «Υγεία» παρέχουν έναν προστατευτικό ρόλο. Σε ό,τι αφορά τους λειτουργικούς δείκτες, το XGBoost αναδεικνύει πιο καθαρά τη θετική συσχέτιση μεταξύ υψηλών τιμών και της πρόβλεψης Πολύ Κρίσιμο, ιδιαίτερα για τους δείκτες C4_user_satisfaction, B5_incident_rep_pct και B2_training_pct. Αυτή η διαπίστωση ενισχύει την προηγούμενη ερμηνεία, η οποία εξετάζει τη σύγχυση μεταξύ τομεακής ταυτότητας και πραγματικής επιχειρησιακής ετοιμότητας.

3. Σύγκριση Ερμηνευσιμότητας μεταξύ των Μοντέλων

Η ανάλυση που πραγματοποιήθηκε σε δείγμα μεγέθους $n = 40.000$ αποκαλύπτει τρία σημαντικά ευρήματα με ιδιαίτερη σημασία. Πρώτον, η πρόβλεψη της κλάσης ανθεκτικότητας με τη χρήση ενός περιορισμένου εύρους εύκολα προσβάσιμων δεικτών είναι δυνατή με ακρίβεια ανώτερη της τυχαίας πρόγνωσης ($macro - F1 \approx 0.534 - 0.544$, $accuracy \approx 0.55 - 0.56$), αν και παραμένει σημαντικό περιθώριο βελτίωσης προτού αυτές οι προβλέψεις μπορέσουν να ενισχύσουν πλήρως αυτοματοποιημένες διαδικασίες λήψης αποφάσεων. Δεύτερον, η αύξηση της πολυπλοκότητας του μοντέλου, από τη χρήση λογιστικής παλινδρόμησης έως τα σύνολα δέντρων με βελτιστοποιημένες υπερπαραμέτρους, δεν παρέχει κάποιο αξιολογικό πλεονέκτημα ως προς την απόδοση στο συγκεκριμένο πλαίσιο και σύνολο χαρακτηριστικών. Τρίτον, η ταυτότητα του τομέα δραστηριότητας αναδεικνύεται ως κεντρικός παράγοντας στην πρόγνωση της κρισιμότητας εντός του συνθετικού δείγματος. Ωστόσο, αυτό το εύρημα απαιτεί προσεκτική ερμηνεία, καθώς ενδέχεται να αντικατοπτρίζει τις υποθέσεις του σχεδιασμού της γεννήτριας δεδομένων και όχι φυσική τομεακή αιτιότητα.

4.6. Συγκριτική Ανάλυση Αποτελεσμάτων Συνθετικών Συνόλων Δεδομένων $n = 5.000, 10.000, 20.000$ και 40.000 Κρίσιμων Οντοτήτων

4.6.1. Εισαγωγή και Σκοπός της Συγκριτικής Ανάλυσης

Στην παρούσα έρευνα πραγματοποιήθηκε η ίδια πειραματική προσέγγιση για σύνολα δεδομένων, με μεγέθη $n = 5.000, 10.000, 20.000$ και 40.000 οντότητες αντιστοίχως. Η διαδικασία επικεντρώνεται στη δημιουργία ενός συνθετικού συνόλου δεδομένων, κάθε φορά, με βάση το Παράρτημα ΣΤ' της Εθνικής Στρατηγικής Ανθεκτικότητας για Κρίσιμες Οντότητες κατά την περίοδο 2026-2030. Η μεθοδολογία περιλαμβάνει την εκπαίδευση τριών μοντέλων ταξινόμησης, της Logistic Regression ως μοντέλο αναφοράς (Baseline), του Random Forest και του XGBoost, χρησιμοποιώντας την τεχνική RandomizedSearchCV για βέλτιστη παραμετροποίηση. Η αξιολόγηση των μοντέλων πραγματοποιήθηκε μέσα από τη μέτρηση $macro - F1$ σε διαχωρισμένο hold-out σύνολο ελέγχου (25% του συνόλου των δεδομένων) και 5-fold Stratified CV. Επιπλέον, εφαρμόστηκε ανάλυση ερμηνεύσιμότητας μέσω SHAP για τα διάφορα σύνολα δεδομένων δειγμάτων.

Ο σκοπός της παρούσας συγκριτικής ανάλυσης είναι να διερευνηθεί η σταθερότητα των ευρημάτων που προκύπτουν από επιμέρους τέσσερις διαδικασίες ταξινόμησης, καθώς αυξάνεται το μέγεθος του δείγματος. Επιπλέον, επιδιώκει να εντοπίσει πιθανές αποκλίσεις ή

ασυνέπειες μεταξύ αυτών των ευρημάτων. Τελικός στόχος είναι η διαμόρφωση μιας ενοποιημένης και κριτικά στοχαστικής αποτίμησης, τόσο για τη στατιστική απόδοση των ερευνητικών μοντέλων όσο και την ερμηνευτική τους δυνατότητα μέσω της εφαρμογής SHAP.

Θα πρέπει να σημειωθεί ότι τα τέσσερα σύνολα δεδομένων που εξετάζονται δεν είναι ένθετα υποσύνολα ενός κοινού κύριου συνόλου δεδομένων, αλλά ανεξάρτητες προσομοιώσεις της ίδιας γεννήτριας συνθετικών δεδομένων, διατηρώντας το σταθερό `random_state` ίσο με 42. Αυτό σημαίνει ότι οι παρατηρούμενες διαφορές μεταξύ των δειγμάτων n δεν αντικατοπτρίζουν αποκλειστικά την καθαρή επίδραση του μεγέθους δείγματος. Αντίθετα, περιλαμβάνουν και τη στοχαστική διακύμανση που συνδέεται με την ίδια τη διαδικασία δημιουργίας των δεδομένων, όπως η τυχαία κατανομή των οντοτήτων σε τομείς και ο τυχαίος θόρυβος. Κατά συνέπεια, αυτό το στοιχείο πρέπει να λαμβάνεται υπόψη σε κάθε ερμηνεία των τάσεων που παρουσιάζονται στη συνέχεια.

4.6.2. Συγκριτική Απόδοση Ταξινόμησης (macro-F1)

Ο πίνακας 4.17 παρουσιάζει τη συνολική απόδοση (*macro* – *F1*) των τριών διαφορετικών μοντέλων (Logistic Regression, Random Forest και XGBoost) σε τέσσερα διακριτά μεγέθη δείγματος. Οι μετρήσεις αποδοτικότητας αφορούν τόσο το ανεξάρτητο σύνολο ελέγχου (hold-out) όσο και τον μέσο όρο των αποτελεσμάτων από τη διαδικασία της 5-fold διασταυρούμενης επικύρωσης (Cross Validation), συμπεριλαμβανομένης της τυπικής απόκλισης αυτής της διαδικασίας.

Από την ανάλυση των αποτελεσμάτων που προέκυψαν από την εφαρμογή των τριών μοντέλων σε τέσσερα διαφορετικά σύνολα δεδομένων, το πιο αξιόπιστο συμπέρασμα συνίσταται στο ότι η απλή λογαριθμική παλινδρόμηση (Logistic Regression) εμφανίζεται ελαφρώς ανώτερη σε σύγκριση με τα δύο μη γραμμικά, βελτιστοποιημένα μοντέλα σε όλες τις περιπτώσεις.

Στο σύνολο δεδομένων $n = 40.000$ το XGBoost παρουσίασε *macro* – *F1* = 0.538 πλησιάζοντας το Baseline με *macro* – *F1* = 0.544 και υπερτερεί καθαρά του Random Forest με *macro* – *F1* = 0.534, ενώ στο $n = 20.000$ το XGBoost παρουσίασε *macro* – *F1* = 0.521 επικρατώντας οριακά του Random Forest με *macro* – *F1* = 0.520. Αυτό υποδηλώνει μια διακριτική αλλά σταθερή τάση. Καθώς, όσο αυξάνεται το n , το XGBoost φαίνεται να αξιοποιεί καλύτερα τον επιπλέον όγκο δεδομένων συγκριτικά με το Random Forest, χωρίς βέβαια να ανατρέπει την επικράτηση του Baseline.

Πρόκειται για ένα σημαντικό εύρημα, διότι η αύξηση της αλγοριθμικής πολυπλοκότητας δεν προσφέρει το προσδοκώμενο πλεονέκτημα όταν το όριο της απόδοσης καθορίζεται εγγενώς, όπως στην περίπτωση μας, από την τεχνητή απόκρυψη 15 από τους 22 δείκτες και τον ενσωματωμένο στοχαστικό θόρυβο της γεννήτριας δεδομένων.

Πίνακας 4.17: Συγκριτική Απόδοση (macro-F1) των τριών μοντέλων στα τέσσερα σύνολα δεδομένων.

n	Μοντέλο	Hold-out macro-F1	5-Fold CV Mean	CV Std ($\pm$)
5.000	Logistic Regression	0.540	0.550	0.010
	Random Forest	0.535	0.537	0.004
	XGBoost	0.528	0.530	0.014
10.000	Logistic Regression	0.551	0.545	0.008
	Random Forest	0.535	0.532	0.010
	XGBoost	0.526	0.533	0.011
20.000	Logistic Regression	0.531	0.538	0.007
	Random Forest	0.520	0.525	0.007
	XGBoost	0.521	0.529	0.008
40.000	Logistic Regression	0.544	0.545	0.001
	Random Forest	0.534	0.532	0.003
	XGBoost	0.538	0.537	0.004

Επίσης, σημαντικό εύρημα της ανάλυσης είναι η συνεχής μείωση της τυπικής απόκλισης του συντελεστή μεταβλητότητας (CV) καθώς αυξάνει το μέγεθος του δείγματος n , από περίπου ± 0.010 έως ± 0.014 όταν $n = 5.000$, σε περίπου ± 0.001 έως ± 0.004 όταν $n = 40.000$. Αυτή η τάση είναι απολύτως αναμενόμενη από στατιστικής σκοπιάς και θεωρείται ως αποδεικτικό στοιχείο ότι η διαδικασία αξιολόγησης εφαρμόστηκε σωστά και με συνέπεια σε όλες τις περιπτώσεις. Αποτελεί ουσιαστικά το πιο ξεκάθαρο συμπέρασμα που σχετίζεται με το μέγεθος του δείγματος (sample-size effect) στο σύνολο της ανάλυσης, δεδομένου ότι δεν επηρεάζεται στον ίδιο βαθμό από την στοχαστικότητα της παραγωγής δεδομένων, όπως συμβαίνει με τα απόλυτα επίπεδα του macro-F1.

Τέλος, τα απόλυτα επίπεδα του macro-F1 δεν δείχνουν συνεχή αύξηση με την αύξηση του n , κάτι που θα αναμενόταν εάν επρόκειτο για υποσύνολα των ίδιων δεδομένων. Παρατηρείται ότι το $n = 20.000$ παρουσιάζει τη χαμηλότερη συνολική επίδοση για όλα τα μοντέλα, από $macro - F1 = 0.520$ (Random Forest) έως $macro - F1 = 0.531$ (Logistic Regression), ακόμη πιο χαμηλή κι από το $n = 5.000$. Αυτό ενισχύει την επιφύλαξη που διατυπώθηκε αρχικά, ότι τα τέσσερα σύνολα είναι ανεξάρτητα, δημιουργούνται τυχαία και η παρατηρούμενη διακύμανση πρέπει να αποδοθεί στη στοχαστικότητα της δημιουργίας δεδομένων και όχι σε πραγματική μείωση της απόδοσης των μοντέλων στο $n = 20.000$. Σε μια μελλοντική εκδοχή αυτής της έρευνας ή την εφαρμογή της από την Εποπτεύουσα Αρχή, θα ήταν ιδιαίτερα χρήσιμη η χρήση ενός κοινού συνόλου πραγματικών δεδομένων, έτσι ώστε να απομονωθεί καθαρά η επίδραση της αύξησης του n από τη στοχαστική διακύμανση κατά τη γέννηση των δεδομένων.

4.6.3. Απόδοση ανά Κλάση Ανθεκτικότητας

Οι πίνακες 4.18 έως 4.20 παρουσιάζουν το F1-score ανά κλάση (σύνολο ελέγχου hold-out) για κάθε μοντέλο, στα τέσσερα μεγέθη των παραγόμενων συνόλων συνθετικών δεδομένων.



Πίνακας 4.18: F1-score ανά κλάση για την Logistic Regression (Baseline).

Κλάση	n = 5.000	n = 10.000	n = 20.000	n = 40.000
Μη Κρίσιμο	0.66	0.66	0.64	0.66
Χαμηλής Ανθεκτικότητας	0.39	0.41	0.41	0.40
Κρίσιμο	0.39	0.41	0.35	0.39
Πολύ Κρίσιμο	0.72	0.72	0.71	0.73

Πίνακας 4.19: F1-score ανά κλάση για την Random Forest.

Κλάση	n = 5.000	n = 10.000	n = 20.000	n = 40.000
Μη Κρίσιμο	0.63	0.64	0.64	0.65
Χαμηλής Ανθεκτικότητας	0.40	0.41	0.41	0.39
Κρίσιμο	0.40	0.38	0.33	0.38
Πολύ Κρίσιμο	0.71	0.71	0.70	0.72

Πίνακας 4.20: F1-score ανά κλάση για την XGBoost.

Κλάση	n = 5.000	n = 10.000	n = 20.000	n = 40.000
Μη Κρίσιμο	0.64	0.63	0.65	0.66
Χαμηλής Ανθεκτικότητας	0.37	0.39	0.40	0.40
Κρίσιμο	0.39	0.38	0.33	0.38
Πολύ Κρίσιμο	0.70	0.70	0.70	0.71

Ίσως, το πλέον σημαντικό εύρημα όλης της συγκριτικής ανάλυσης είναι ότι σε όλους τους 12 συνδυασμούς, των τριών μοντέλων και των τεσσάρων συνόλων δεδομένων, οι ακραίες κλάσεις Μη Κρίσιμο και Πολύ Κρίσιμο επιτυγχάνουν τιμές F1-score στην περιοχή 0.63 έως 0.73. Αντίθετα, οι ενδιάμεσες κλάσεις Χαμηλής Ανθεκτικότητας και Κρίσιμο παραμένουν σταθερά σε επίπεδα που κυμαίνονται από 0.33 έως 0.41, δηλαδή σχεδόν στο μισό. Αυτό το μοτίβο δεν εξασθενεί με την αύξηση του n , γεγονός που ενισχύει σημαντικά τις τέσσερις αναφορές ότι πρόκειται για βασικό χαρακτηριστικό της μεθόδου `qsut` όταν εφαρμόζεται σε συνεχείς, θορυβώδεις κατανομές. Τα όρια μεταξύ γειτονικών τεταρτημορίων είναι χαρακτηριστικά ασαφή, και το ζήτημα δε φαίνεται να σχετίζεται με περιορισμούς δεδομένων που θα μπορούσαν να επιλυθούν με μεγαλύτερο δείγμα.

Είναι σημαντικό να σημειωθεί η εμφανώς χαμηλότερη τιμή της κατηγορίας Κρίσιμο για $n = 20.000$ (F1-score, 0.33 – 0.35), συγκριτικά με τα άλλα τρία σύνολα δεδομένων (F1-score, 0.38 – 0.41). Αυτή η διακύμανση, καθώς εμφανίζεται ταυτόχρονα σε όλα τα μοντέλα του ίδιου συνόλου δεδομένων, είναι πιο πιθανό να οφείλεται σε μια τυχαία διαμόρφωση που δημιουργήθηκε κατά τη διαμόρφωση του συγκεκριμένου συνόλου δεδομένων, όπως η μεγαλύτερη επικάλυψη στην περιοχή των ορίων μεταξύ του δεύτερου και τρίτου τεταρτημορίου, παρά σε κάποια ουσιαστική μεθοδολογική αδυναμία. Σε μελλοντική έρευνα, θα ήταν σκόπιμο να χρησιμοποιηθούν 2 – 3 διαφορετικά seeds για να επιβεβαιωθεί εάν η παρατηρούμενη διαφοροποίηση οφείλεται σε θόρυβο δειγματοληψίας.

4.6.4. Βέλτιστες Υπερπαραμέτροι μη Γραμμικών Μοντέλων (RandomizedSearchCV)

Οι πίνακες 4.21 και 4.22 παρουσιάζουν τις βέλτιστες υπερπαραμέτρους των μη γραμμικών μοντέλων Random Forst και XGBoost, στα τέσσερα μεγέθη των παραγόμενων συνόλων συνθετικών δεδομένων.

Πίνακας 4.21: Βέλτιστες Υπερπαραμέτροι του Random Forest για $n = 5.000, 10.000, 20.000$ και 40.000 .

n	n_estimators	min_samples_split	min_samples_leaf	max_features	max_depth
5.000	200	2	4	sqrt	15
10.000	200	2	4	sqrt	15
20.000	500	4	4	sqrt	20
40.000	500	4	4	sqrt	20

Πίνακας 4.22: Βέλτιστες Υπερπαραμέτροι του XGBoost για $n = 5.000, 10.000, 20.000$ και 40.000 .

n	subsample	reg lambda (L2 Ridge)	reg alpha (L1 Lasso)	n estimators	min child weight	max depth	learning rate	colsample bytree
5.000	0.85	2.0	0.0	500	5	5	0.01	0.6
10.000	0.85	2.0	0.0	300	3	5	0.03	0.8
20.000	0.85	2.0	0.0	300	3	5	0.03	0.8
40.000	0.85	2.0	0.0	300	3	5	0.03	0.8

Από την παρατήρηση των ανωτέρω πινάκων με τις βέλτιστες υπερπαραμέτρους του μοντέλου Random Forest με όλα τα παραγόμενα σύνολα δεδομένων, προκύπτει ένα ενδιαφέρον μοτίβο. Η αναζήτηση συγκλίνει σε δύο διακριτά επίπεδα ($n_estimators = 200, max_depth = 15$) για $n = 5.000 / 10.000$ και ($n_estimators = 500, max_depth = 20$) για $n = 20.000 / 40.000$. Αυτό καταδεικνύει ότι μεγαλύτερα σύνολα δεδομένων μπορούν να χειριστούν και να επωφεληθούν από βαθύτερα και περισσότερα δέντρα χωρίς να οδηγηθούν σε υπερεκπαίδευση (overfitting), κάτι που είναι πλήρως ευθυγραμμισμένο με τη θεωρία μάθησης σχετικά με την ισορροπία μεταξύ μεταβλητότητας και μεροληψίας (bias-variance trade-off).

Για το XGBoost, το αποτέλεσμα είναι ακόμη πιο εντυπωσιακό. Για τιμές n από 10.000 και πάνω, η RandomizedSearchCV καταλήγει στον ίδιο ακριβώς συνδυασμό υπερπαραμέτρων. Δηλαδή, $n_estimators = 300, max_depth = 5, learning_rate = 0,03, subsample = 0,85, colsample_bytree = 0,80$ και $min_child_weight = 3$. Αυτό είναι αξιοσημείωτο, δεδομένου ότι αφορά τρία διαφορετικά σύνολα δεδομένων και τρεις ανεξάρτητες, τυχαιοποιημένες αναζητήσεις παραμέτρων. Η πρακτική αυτή σύγκλιση παρέχει μια έμμεση, αλλά ισχυρή, ένδειξη πως η σταθεροποίηση του σήματος του προβλήματος επιτυγχάνεται με σχετική ταχύτητα καθώς αυξάνει το μέγεθος του δείγματος.

Αντίθετα, με $n = 5.000$, η αναζήτηση κατέληξε σε πιο συντηρητική παραμετροποίηση: $learning_rate = 0,01, n_estimators = 500$ και $colsample_bytree = 0,60$. Αυτό ήταν αναμενόμενο, καθώς σε μικρότερο δείγμα το εσωτερικό 3-fold CV της RandomizedSearchCV γίνεται πιο ευάλωτο σε θόρυβο και τείνει να τιμωρεί τις πιο επιθετικές παραμετροποιήσεις.

4.6.5. Συγκριτική Ανάλυση SHAP – Bar Plots (Συνολική Σπουδαιότητα)

Το Random Forest παρουσιάζει αξιοσημείωτα σταθερή συμπεριφορά και στα τέσσερα σύνολα δεδομένων. Οι τρεις μεταβλητές τομέα με θετική αρχική μετατόπιση (όπως ο Τραπεζικός κλάδος, οι Υποδομές χρηματοπιστωτικών αγορών και η Ενέργεια) συστηματικά κατατάσσονται στις πρώτες θέσεις σπουδαιότητας, ανεξάρτητα από το μέγεθος του δείγματος. Αυτό το εύρημα αντανακλά μια γνωστή ιδιότητα του αλγορίθμου Random Forest να κλειδώνει νωρίς σε ισχυρά δυαδικά, χαμηλής εντροπίας χαρακτηριστικά.

Το XGBoost, αντίθετα, αναδεικνύει μια σημαντική μεταβλητότητα στην κατάταξη των σημαντικών χαρακτηριστικών μεταξύ των τεσσάρων πειραματικών συνθηκών. Συγκεκριμένα, για μεγέθη δείγματος $n = 5.000$ και $n = 10.000$, κυριαρχούν οι λειτουργικοί και ποσοτικοί δείκτες. Αντίθετα, για $n = 20.000$, αποκτούν προτεραιότητα οι τομείς Υποδομές χρηματοπιστωτικών αγορών και Τραπεζικός κλάδος, ενώ στο $n = 40.000$, αναδεικνύεται κυρίαρχη η παράμετρος C4_user_satisfaction σε συνδυασμό με την παρουσία των τομέων Υποδομές χρηματοπιστωτικών αγορών και Τραπεζικός κλάδος. Αξιοσημείωτο είναι το γεγονός ότι ένας πυρήνας περίπου 6 – 7 κρίσιμων χαρακτηριστικών, που περιλαμβάνει τρεις τομείς υψηλού κινδύνου (Τραπεζικός κλάδος, Υποδομές χρηματοπιστωτικών αγορών και Ενέργεια), καθώς και τους δείκτες B1_iso_pct, B2_training_pct, B3_exercises_num, B5_incident_rep_pct, C1_mttr και C4_user_satisfaction, παραμένει σταθερός ανεξαρτήτως μεγέθους δείγματος. Μόνο η εσωτερική τους κατάταξη διαφοροποιείται. Αυτό το στοιχείο είναι θεμελιώδες για την ανάλυσή μας, δεδομένου ότι η αριθμητική ταξινόμηση που προκύπτει από τη μέθοδο XGBoost δεν πρέπει να θεωρείται πάντα σταθερή. Ωστόσο, η αναγνώριση και διατήρηση της ταυτότητας των σημαντικών μεταβλητών παραμένει αναλλοίωτη και απαιτεί ιδιαίτερη προσοχή.

Στον πίνακα 4.23 παρουσιάζεται μια ποιοτική σύνοψη της κατάταξης της σημασίας των χαρακτηριστικών (bar plots, mean |SHAP value|) για τα μη γραμμικά μοντέλα Random Forest και XGBoost και στα τέσσερα μεγέθη των παραγόμενων συνόλων συνθετικών δεδομένων.

Πίνακας 4.23: Ποιοτική σύνοψη της κατάταξης SHAP bar plots ανά μοντέλο και $n = 5.000, 10.000, 20.000, 40.000$.

n	Random Forest	XGBoost
5.000	Κυριαρχεί ο τομέας Τραπεζικός κλάδος και ακολουθούν ο λειτουργικός δείκτης B1_iso_pct (ποσοστό οντοτήτων με πιστοποίηση ISO 22301), οι τομείς Υποδομές των χρηματοπιστωτικών αγορών και Ενέργεια. Εν συνεχεία παρουσιάζονται οι λειτουργικοί και ποσοτικοί δείκτες B3_exercises_num (μέσος αριθμός διεξαχθέντων ασκήσεων ετοιμότητας ετησίως ανά οντότητα) και B2_training_pct (ποσοστό Υπευθύνων Ανθεκτικότητας και στελεχών κρίσιμων λειτουργιών με εξειδικευμένη κατάρτιση),	Κυριαρχούν οι λειτουργικοί και ποσοτικοί δείκτες B1_iso_pct (ποσοστό οντοτήτων με πιστοποίηση ISO 22301), B3_exercises_num (μέσος αριθμός διεξαχθέντων ασκήσεων ετοιμότητας ετησίως ανά οντότητα), B5_incident_rep_pct (ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών) και C4_user_satisfaction (δείκτης ικανοποίησης χρηστών/πολιτών ουσιαστικών υπηρεσιών).

10.000	Κυριαρχούν οι τομείς είναι ο Τραπεζικός κλάδος, οι Υποδομές των χρηματοπιστωτικών αγορών και η Ενέργεια. Ακολουθούν οι λειτουργικοί και ποσοτικοί τομείς B3_exercises_num (μέσος αριθμός διεξαχθέντων ασκήσεων ετοιμότητας ετησίως ανά οντότητα), B2_training_pct (ποσοστό Υπευθύνων Ανθεκτικότητας και στελεχών κρίσιμων λειτουργιών με εξειδικευμένη κατάρτιση), B5_incident_rep_pct (ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών), B1_iso_pct (ποσοστό οντοτήτων με πιστοποίηση ISO 22301) και C4_user_satisfaction (δείκτης ικανοποίησης χρηστών/πολιτών ουσιαδών υπηρεσιών).	Κυριαρχούν οι λειτουργικοί και ποσοτικοί δείκτες B3_exercises_num (μέσος αριθμός διεξαχθέντων ασκήσεων ετοιμότητας ετησίως ανά οντότητα), B5_incident_rep_pct (ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών), B2_training_pct (ποσοστό Υπευθύνων Ανθεκτικότητας και στελεχών κρίσιμων λειτουργιών με εξειδικευμένη κατάρτιση), C4_user_satisfaction (δείκτης ικανοποίησης χρηστών/πολιτών ουσιαδών υπηρεσιών), C1_mttr (μέσος χρόνος αποκατάστασης βλάβης/υπηρεσίας ανά τομέα) και B1_iso_pct (ποσοστό οντοτήτων με πιστοποίηση ISO 22301).
20.000	Κυριαρχούν οι τομείς είναι ο Τραπεζικός κλάδος, οι Υποδομές των χρηματοπιστωτικών αγορών και η Ενέργεια. Ακολουθούν οι λειτουργικοί και ποσοτικοί τομείς C4_user_satisfaction (δείκτης ικανοποίησης χρηστών/πολιτών ουσιαδών υπηρεσιών), B1_iso_pct (ποσοστό οντοτήτων με πιστοποίηση ISO 22301), A2_plan_appr_pct (ποσοστό οντοτήτων με εγκεκριμένο Σχέδιο Ανθεκτικότητας), B5_incident_rep_pct (ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών) και B3_exercises_num (μέσος αριθμός διεξαχθέντων ασκήσεων ετοιμότητας ετησίως ανά οντότητα).	Κυριαρχούν οι τομείς Υποδομές των χρηματοπιστωτικών αγορών και Τραπεζικός κλάδος. Ακολουθούν οι λειτουργικοί και ποσοτικοί δείκτες B1_iso_pct (ποσοστό οντοτήτων με πιστοποίηση ISO 22301), B5_incident_rep_pct (ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών), C4_user_satisfaction (δείκτης ικανοποίησης χρηστών/πολιτών ουσιαδών υπηρεσιών), C1_mttr (μέσος χρόνος αποκατάστασης βλάβης/υπηρεσίας ανά τομέα) και B3_exercises_num (μέσος αριθμός διεξαχθέντων ασκήσεων ετοιμότητας ετησίως ανά οντότητα).
40.000	Κυριαρχούν οι τομείς είναι ο Τραπεζικός κλάδος, οι Υποδομές των χρηματοπιστωτικών αγορών και η Ενέργεια. Ακολουθούν οι λειτουργικοί και ποσοτικοί τομείς C4_user_satisfaction (δείκτης ικανοποίησης χρηστών/πολιτών ουσιαδών υπηρεσιών), B1_iso_pct (ποσοστό οντοτήτων με πιστοποίηση ISO 22301), B5_incident_rep_pct (ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών) και C1_mttr (μέσος χρόνος αποκατάστασης βλάβης/υπηρεσίας ανά τομέα).	Κυριαρχούν ο λειτουργικός δείκτης C4_user_satisfaction (δείκτης ικανοποίησης χρηστών/πολιτών ουσιαδών υπηρεσιών) και οι τομείς Υποδομές των χρηματοπιστωτικών αγορών και Τραπεζικός κλάδος. Ακολουθούν οι λειτουργικοί και ποσοτικοί δείκτες B5_incident_rep_pct (ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών), B1_iso_pct (ποσοστό οντοτήτων με πιστοποίηση ISO 22301) και B2_training_pct (ποσοστό Υπευθύνων Ανθεκτικότητας και στελεχών κρίσιμων λειτουργιών με εξειδικευμένη κατάρτιση).

4.6.6. Συγκριτική Ανάλυση SHAP – Beeswarm Plots (Κλάση «Πολύ Κρίσιμο»)

Σε ότι αφορά με την κατεύθυνση της επίδρασης που παρουσιάζουν τα Beeswarm Plots με SHAP Summary (CRI), εστιασμένα στην κλάση «Πολύ Κρίσιμο», τα ευρήματα αποδεικνύουν εξαιρετικά συνεπή μοτίβα και για τα τέσσερα παραγόμενα σύνολα συνθετικών δεδομένων, στα δύο μη γραμμικά μοντέλα, Random Forest και XGBoost.

Στην ανάλυση SHAP με τη χρήση Beeswarm Plots, διαπιστώνονται σημαντικά ευρήματα για την κλάση Πολύ Κρίσιμο. Οι τρεις τομείς που ξεχωρίζουν για τη σταθερότητα και τη σημασία τους είναι ο Τραπεζικός κλάδος, οι Υποδομές χρηματοπιστωτικών αγορών και η



Ενέργεια. Αυτοί οι τομείς παραμένουν σταθεροί και ισχυροί ανεξάρτητα από το μέγεθος του δείγματος και το χρησιμοποιούμενο μοντέλο.

Ο Τραπεζικός κλάδος κατατάσσεται πρώτος σε προτεραιότητα στις έξι από τις οκτώ περιπτώσεις που εξετάστηκαν και στα δύο μοντέλα (Random Forest και XGBoost), με εξαίρεση στο XGBoost για $n = 5.000$ και $n = 10.000$, όπου τις πρώτες θέσεις καταλαμβάνουν οι δείκτες B1_iso_pct και C1_mttr, αντίστοιχα.

Πίνακας 4.24: Σύγκριση κατάταξης SHAP Beeswarm Plots για Random Forest και $n = 5.000, 10.000, 20.000, 40.000$

Θέση	$n = 5.000$	$n = 10.000$	$n = 20.000$	$n = 40.000$
1	Τραπεζικός κλάδος	Τραπεζικός κλάδος	Τραπεζικός κλάδος	Τραπεζικός κλάδος
2	Ενέργεια	Υποδομές χρηματοπιστ. αγορών	Υποδομές χρηματοπιστ. αγορών	Υποδομές χρηματοπιστ. αγορών
3	Υποδομές χρηματοπιστ. αγορών	Ενέργεια	Ενέργεια	Ενέργεια
4	B1_iso_pct	B2_training_pct	B1_iso_pct	C4_user_satisfaction
5	A2_plan_appr_pct	B3_exercises_num	C4_user_satisfaction	B1_iso_pct
6	B2_training_pct	C1_mttr	B5_incident_rep_pct	B5_incident_rep_pct
7	C4_user_satisfaction	B5_incident_rep_pct	A2_plan_appr_pct	B2_training_pct
8	B3_exercises_num	C4_user_satisfaction	C1_mttr	C1_mttr
9	B5_incident_rep_pct	B1_iso_pct	B2_training_pct	Ψηφιακές υποδομές
10	C1_mttr	Ψηφιακές υποδομές	Ψηφιακές υποδομές	B3_exercises_num
11	Ψηφιακές υποδομές	A2_plan_appr_pct	B3_exercises_num	A2_plan_appr_pct
12	Λύματα	Λύματα	Λύματα	Λύματα
13	Διάστημα	Αστικά απόβλητα	Αστικά απόβλητα	Αστικά απόβλητα
14	Παραγωγή/διανομή τροφίμων	Παραγωγή/διανομή τροφίμων	Διάστημα	Διάστημα
15	Αστικά απόβλητα	Διάστημα	Παραγωγή/διανομή τροφίμων	Παραγωγή/διανομή τροφίμων
16	Δημόσια διοίκηση	Πόσιμο νερό	Δημόσια διοίκηση	Δημόσια διοίκηση
17	Πόσιμο νερό	Δημόσια διοίκηση	Πόσιμο νερό	Πόσιμο νερό
18	Υγεία	Υγεία	Υγεία	Υγεία
19	Μεταφορές	Μεταφορές	Μεταφορές	Μεταφορές

Πέρα από αυτή τη μοναδική αλλαγή, οι τρεις τομείς, Τραπεζικός κλάδος, Υποδομές χρηματοπιστωτικών αγορών και Ενέργεια, διατηρούν συστηματικά τις πέντε κορυφαίες θέσεις σε κάθε ανάλυση, με εξαίρεση την περίπτωση $n = 10.000$ του XGBoost, και

εμφανίζουν σημαντικά υψηλότερο απόλυτο δείκτη τιμών SHAP σε σχέση με οποιοδήποτε άλλο χαρακτηριστικό, φτάνοντας τις τιμές 0.4 – 0.45 στο Random Forest και 1.3 – 1.4 στο XGBoost. Αυτό κάνει αυτούς τους τομείς τους πιο ακραίους και σημαντικούς προβλεπτικούς παράγοντες για κάθε δείγμα, ανεξάρτητα από μικρές αλλαγές στην εσωτερική τους κατάταξη.

Αντίθετα, οι επτά τομείς με μικρότερη σημασία, όπως τα Λύματα, η Παραγωγή/διανομή τροφίμων, τα Αστικά απόβλητα, η Δημόσια διοίκηση, το Πόσιμο νερό, η Υγεία και οι Μεταφορές, σχετίζονται με μια ελαφρά μείωση του κινδύνου όταν είναι ενεργοποιημένοι. Από την άλλη πλευρά, το Διάστημα και οι Ψηφιακές υποδομές παρατηρούν μια αντίθετη τάση, με μια μικρή αύξηση στον κίνδυνο. Επιπλέον, αυτοί οι επτά μικρότεροι τομείς καταλαμβάνουν συνεχώς τις τελευταίες θέσεις στην κατάταξη σπουδαιότητας σε κάθε ανάλυση, εμφανίζοντας σχεδόν ταυτόσημη και συγκρίσιμη επίδραση μεταξύ τους. Αυτό υποδηλώνει ότι η σχετική τους βαρύτητα στο μοντέλο παραμένει σταθερή ακόμη και με μικρότερα μεγέθη δειγμάτων και δεν επηρεάζεται ουσιαστικά από την αύξηση του συνόλου δεδομένων.

Κατά τη σύγκριση των δύο μοντέλων όσον αφορά τη σταθερότητα της κατάταξης σπουδαιότητας σε διάφορα μεγέθη δείγματος, το Random Forest ξεχωρίζει ως πιο αξιόπιστο. Η ικανότητά του να διατηρεί αμετάβλητη την εσωτερική σειρά της κρίσιμης τριάδας τομέων σε τρία από τα τέσσερα μεγέθη δείγματος είναι αξιοσημείωτη, με εξαίρεση το $n = 5.000$, όπου η σειρά μεταξύ των Υποδομών χρηματοπιστωτικών αγορών και της Ενέργειας αναστρέφεται. Επιπλέον, το εύρος των τιμών SHAP παραμένει σχεδόν σταθερό, κυμαινόμενο από -0,05 έως 0,40-0,45, υποδεικνύοντας ότι το μοντέλο παρέχει μια συνεπή αναπαράσταση της σχέσης χαρακτηριστικών και κινδύνου, ακόμα και στα μικρότερα δείγματα.

Από την άλλη πλευρά, το XGBoost παρουσιάζει μεγαλύτερη διακύμανση στην κατάταξη των χαρακτηριστικών ανάλογα με το μέγεθος του δείγματος. Ο δείκτης `B1_iso_pct` κυμαίνεται από την 1η έως την 7η θέση, ενώ ο Τραπεζικός κλάδος φτάνει από την 1η έως την 6η θέση. Ιδιαίτερα αξιοσημείωτη είναι η περίπτωση της Ενέργειας, που υποχωρεί από την 3η θέση όταν $n = 5.000$, έως την 9η θέση για $n = 20.000$ και $n = 40.000$, αν και οι τιμές SHAP παραμένουν σταθερά υψηλές. Αυτή η συμπεριφορά δείχνει ότι το XGBoost αξιοποιεί σε μεγαλύτερο βαθμό τις αλληλεπιδράσεις μεταξύ μεταβλητών και τα τοπικά όρια απόφασης. Αυτό κάνει τη μέση σπουδαιότητα των χαρακτηριστικών πιο ευαίσθητη στη σύνθεση του δεδομένου δείγματος, σε αντίθεση με τη σταθερότερη προσέγγιση του Random Forest.

Στα δύο μοντέλα παρατηρείται ότι με την αύξηση του n , ιδιαίτερα μετά το $n = 20.000$, η κατάταξη των χαρακτηριστικών τείνει να συγκλίνει και να σταθεροποιείται. Οι μεταβολές στις κατατάξεις μεταξύ $n = 20.000$ και $n = 40.000$ είναι λιγότερο εμφανείς απ' ό,τι οι αλλαγές που σημειώνονται μεταξύ $n = 5.000$ και $n = 10.000$. Στο μοντέλο XGBoost ξεχωρίζει μια έντονη ταλάντωση, καθώς οι λειτουργικοί δείκτες κερδίζουν έδαφος στο $n = 10.000$, υποχωρούν στο $n = 20.000$ καθώς οι τομείς επιστρέφουν στην κορυφή της λίστας, και επανακάμπτουν στο $n = 40.000$. Αυτό μπορεί να υποδηλώνει είτε μια έλλειψη σταθερότητας του μοντέλου είτε μια λεπτή ισορροπία σπουδαιότητας ανάμεσα στους κλάδους και τους λειτουργικούς και ποσοτικούς δείκτες.



Πίνακας 4.24: Σύγκριση κατάταξης SHAP Beeswarm Plots για XGBoost και $n = 5.000, 10.000, 20.000, 40.000$

Θέση	$n = 5.000$	$n = 10.000$	$n = 20.000$	$n = 40.000$
1	B1_iso_pct	C1_mttr	Τραπεζικός κλάδος	Τραπεζικός κλάδος
2	Τραπεζικός κλάδος	B2_training_pct	B1_iso_pct	C4_user_satisfaction
3	Ενέργεια	C4_user_satisfaction	B5_incident_rep_pct	B5_incident_rep_pct
4	Υποδομές χρηματοπιστ. αγορών	B5_incident_rep_pct	Υποδομές χρηματοπιστ. αγορών	B2_training_pct
5	A2_plan_appr_pct	B3_exercises_num	C4_user_satisfaction	Υποδομές χρηματοπιστ. αγορών
6	B2_training_pct	Τραπεζικός κλάδος	C1_mttr	B1_iso_pct
7	C1_mttr	B1_iso_pct	B2_training_pct	C1_mttr
8	B3_exercises_num	Υποδομές χρηματοπιστ. αγορών	B3_exercises_num	B3_exercises_num
9	C4_user_satisfaction	A2_plan_appr_pct	Ενέργεια	Ενέργεια
10	B5_incident_rep_pct	Ενέργεια	Λύματα	A2_plan_appr_pct
11	Ψηφιακές υποδομές	Ψηφιακές υποδομές	A2_plan_appr_pct	Ψηφιακές υποδομές
12	Παραγωγή/διανομή τροφίμων	Λύματα	Αστικά απόβλητα	Λύματα
13	Λύματα	Αστικά απόβλητα	Ψηφιακές υποδομές	Παραγωγή/διανομή τροφίμων
14	Δημόσια διοίκηση	Παραγωγή/διανομή τροφίμων	Παραγωγή/διανομή τροφίμων	Αστικά απόβλητα
15	Διάστημα	Δημόσια διοίκηση	Δημόσια διοίκηση	Δημόσια διοίκηση
16	Πόσιμο νερό	Πόσιμο νερό	Διάστημα	Πόσιμο νερό
17	Αστικά απόβλητα	Διάστημα	Πόσιμο νερό	Διάστημα
18	Υγεία	Υγεία	Υγεία	Υγεία
19	Μεταφορές	Μεταφορές	Μεταφορές	Μεταφορές

Επιπλέον, οι μέγιστες απόλυτες τιμές των SHAP επεκτείνονται ελαφρώς με την αύξηση του n . Συγκεκριμένα, στο Τραπεζικό κλάδο, το εύρος αυτό κυμαίνεται από περίπου 0.42 για το Random Forest όταν $n = 5.000$ έως περίπου 0.45 όταν $n = 40.000$. Στην περίπτωση του XGBoost, το εύρος παραμένει περίπου στο 1.3 για όλα τα επίπεδα n , ενώ παρουσιάζει μια ήπια ανοδική τάση στο $n = 40.000$. Αυτή η παρατήρηση καταδεικνύει ότι καθώς αυξάνεται ο όγκος των δεδομένων, τα μοντέλα επιδεικνύουν μεγαλύτερη εμπιστοσύνη στην αποτύπωση σαφών σημάτων στους τομείς υψηλού κινδύνου.

Συνεπώς, από τα παραπάνω προκύπτει ότι η εσωτερική δομή της εκτίμησης κινδύνου παραμένει ουσιαστικά αμετάβλητη στα δύο εξεταζόμενα μοντέλα. Τομείς όπως οι τράπεζες,

οι χρηματοπιστωτικές υποδομές και η ενεργειακή βιομηχανία διατηρούν σταθερή την ισχύ τους ως ανεξάρτητοι παράγοντες επιρροής. Ταυτόχρονα, η ωριμότητα και η ετοιμότητα, που εκφράζονται μέσω διεθνών προτύπων όπως τα ISO, εκπαιδευτικών προγραμμάτων, ασκήσεων ετοιμότητας, αναφοράς συμβάντων, του Μέσου Χρόνου Αποκατάστασης (MTTR), της ικανοποίησης χρηστών και των εγκρίσεων σχεδίων, λειτουργούν συνεχώς με έναν προστατευτικό ρόλο. Η παρατηρούμενη «αστάθεια» αφορά κυρίως τη σχετική κατάταξη παραγόντων με παρόμοια επίδραση, η οποία φαίνεται πιο έντονη στο μοντέλο XGBoost, αλλά τείνει να μειώνεται με την αύξηση του μεγέθους του δείγματος. Αυτή η τάση δείχνει μια σύγκλιση προς πιο αξιόπιστη και ακριβή ιεράρχηση της σημασίας των παραγόντων.

4.6.7. Συμπέρασμα Συγκριτικής Ανάλυσης

Η σύγκριση των τεσσάρων αναλύσεων καταδεικνύει ότι τα ουσιαστικά ευρήματα της μελέτης εξακολουθούν να ισχύουν. Αυτά περιλαμβάνουν την μέτρια αλλά σημαντική προγνωστική ακρίβεια (macro-F1 περίπου 0.52–0.55), την ελαφρώς βελτιωμένη απόδοση της logistic Regression (Baseline) σε σχέση με τα μοντέλα δέντρων Random Forest και XGBoost, την έντονη διαφοροποίηση απόδοσης μεταξύ των ακραίων και των ενδιάμεσων κλάσεων, καθώς και την εξέχουσα σημασία του τομέα ως μεταβλητής στην ερμηνευσιμότητα SHAP. Αυτά τα ευρήματα μένουν αμετάβλητα ακόμη κι όταν το μέγεθος του δείγματος επεκτείνεται από $n = 5.000$ σε $n = 40.000$ οντότητες. Η αύξηση του μεγέθους δείγματος συμβάλλει κυρίως στη σταθεροποίηση των εκτιμήσεων, παρατηρώντας ελάττωση στην τυπική απόκλιση κατά τη διασταυρούμενη επικύρωση και πιο συνεπείς υπερπαραμέτρους, παρά στην αύξηση της συνολικής ακρίβειας. Αυτό ενισχύει την αντίληψη ότι υπάρχει ταβάνι στην απόδοσης που φαίνεται να είναι ενσωματωμένο στα συγκεκριμένα σύνολα δεδομένων.

Επίλογος

Η παρούσα εργασία ξεκίνησε από τη θεσμική και θεωρητική διαπίστωση, ότι η ανθεκτικότητα των κρίσιμων οντοτήτων, όπως αυτές καθορίζονται από τις Οδηγίες CER και NIS2 και ενσωματώνονται στο Ελληνικό νομικό πλαίσιο μέσω των Νόμων 5236/2025 και 5160/2024, δεν μπορεί πλέον να θεωρείται στατική, περιγραφική ή καθαρά ποιοτική ιδιότητα. Η πολυπλοκότητα, οι αλληλεξαρτήσεις και ο όγκος των δεδομένων που χαρακτηρίζουν τις σύγχρονες κρίσιμες υποδομές επέβαλαν τη μετάβαση σε ένα ποσοτικό, δεδομενοκεντρικό πλαίσιο αξιολόγησης, αξιοποιώντας εργαλεία μηχανικής μάθησης. Στο πειραματικό μέρος της εργασίας, που αναπτύχθηκε σε τέσσερα ανεξάρτητα πειράματα με διαφορετικά μεγέθη δείγματος ($n = 5.000, 10.000, 20.000$ και 40.000 συνθετικών οντοτήτων), δοθήκαν εμπειρικές απαντήσεις στα πέντε ερευνητικά ερωτήματα που διατυπώθηκαν στο Κεφάλαιο 1.

Σε σχέση με το πρώτο ερώτημα για τους παράγοντες που επηρεάζουν περισσότερο την ανθεκτικότητα μιας οντότητας, η ανάλυση SHAP, η οποία εφαρμόστηκε επανειλημμένα και με συνέπεια σε τέσσερα πειράματα, ανέδειξε δύο κύριες κατηγορίες σημαντικών παραγόντων. Πρώτα, ο τομέας δραστηριότητας, όπως ο τραπεζικός κλάδος, η ενέργεια και οι υποδομές χρηματοπιστωτικών αγορών, λειτουργεί ως ισχυρός δομικός προσδιοριστικός παράγοντας. Επιπλέον, η πιστοποίηση επιχειρησιακής συνέχειας (ISO 22301), οι ασκήσεις ετοιμότητας και η έγκαιρη αναφορά περιστατικών αντιπροσωπεύουν δείκτες που συνδέονται με συγκεκριμένες, ελεγχόμενες πρακτικές διακυβέρνησης αντί για παθητικά χαρακτηριστικά μιας οντότητας.

Όσον αφορά το δεύτερο ερώτημα, δηλαδή αν είναι δυνατή η αξιόπιστη πρόβλεψη της κλάσης ανθεκτικότητας χρησιμοποιώντας μόνο 7 από τους 22 επίσημους δείκτες, η απάντηση είναι μετρημένα θετική. Η προγνωστική ικανότητα μετριέται σε macro-F1 περίπου 0.52 έως 0.55, τιμή που υπερβαίνει το τυχαίο όριο του 0.25, υποδεικνύοντας μια στατιστικά σημαντική αλλά όχι απολύτως επαρκή ακρίβεια για πλήρως αυτοματοποιημένες εποπτικές αποφάσεις. Αυτό το εύρημα επιβεβαιώνεται με συνέπεια μέσα σε τέσσερα ανεξάρτητα σύνολα δεδομένων, καθιστώντας το ένα από τα πιο αξιόπιστα αποτελέσματα της μελέτης. Συγκεκριμένα, τα μοντέλα μπορούν να αναγνωρίσουν με συνέπεια οντότητες πολύ υψηλού ή χαμηλού κινδύνου, αλλά παρουσιάζουν δυσκολία στις ενδιάμεσες «γκρίζες» περιπτώσεις, όπου η εποπτική κρίση παραμένει απαραίτητη.

Όσον αφορά το τρίτο ερώτημα για την ποσοτικοποίηση της ανθεκτικότητας μέσω πολυδιάστατων δεικτών, η αρχιτεκτονική του CRI score ως σταθμισμένος συνδυασμός τεσσάρων Διαστάσεων (Α, Β, Γ και Δ) με μη γραμμική ποινή αλληλεπίδρασης αποδείχθηκε αποτελεσματική. Το γεγονός ότι η κατεύθυνση επίδρασης κάθε χαρακτηριστικού στο SHAP παραμένει πλήρως ευθυγραμμισμένη με τον μηχανισμό παραγωγής των δεδομένων αποτελεί ισχυρή ένδειξη εγκυρότητας. Αυτό σημαίνει ότι τα μοντέλα δεν απορρόφησαν θόρυβο, αλλά προσδιόρισαν επιτυχώς την πραγματική δομή της διαδικασίας παραγωγής δεδομένων.

Αναφορικά με το τέταρτο ερώτημα, που αφορά το επίπεδο υπεροχής της τεχνητής νοημοσύνης συγκριτικά με τις παραδοσιακές στατιστικές προσεγγίσεις, το πιο παράδοξο αλλά επαναλαμβανόμενο εύρημα της μελέτης είναι ότι η απλή Logistic Regression (Baseline)

υπερβαίνει ή εξισώνει τις βελτιστοποιημένες τεχνικές Random Forest και XGBoost σε κάθε ένα από τα τέσσερα πειράματα. Αυτό το εύρημα δεν μειώνει την αξία της τεχνητής νοημοσύνης. Αντιθέτως, αποδεικνύει ότι η υπεροχή της τεχνητής νοημοσύνης απέναντι στις παραδοσιακές μεθόδους δεν είναι αυτομάτως εξασφαλισμένη, αλλά εξαρτάται από τη συγκεκριμένη μη γραμμικότητα του φαινομένου που εξετάζεται, το οποίο στην προκειμένη περίπτωση είναι σχεδόν γραμμικό εξαιτίας της ίδιας της δομής του CRI score. Στη συγκεκριμένη μελέτη, η αξία της τεχνητής νοημοσύνης αναδείχθηκε κυρίως μέσω της ερμηνευσιμότητας του SHAP και όχι μέσω καθαρής προγνωστικής υπεροχής.

Τέλος, το πέμπτο ερώτημα, που αφορά την υποστήριξη μιας ενοποιημένης μεθοδολογίας CER/NIS2 με επιχειρησιακά μετρήσιμα αποτελέσματα, η συγκεκριμένη προσέγγιση της εργασίας παρέχει μια αρχική και αναπαραγωγίμη σύνδεση μεταξύ των κανονιστικών απαιτήσεων και των ποσοτικών εργαλείων. Προτείνεται ένα πλαίσιο ταξινόμησης κινδύνου, το οποίο βασίζεται σε εύκολα προσβάσιμου δείκτες και συνοδεύεται από ερμηνεύσιμες αιτιολογήσεις ανά οντότητα. Αυτό το πλαίσιο θα μπορούσε να διευκολύνει τη στοχευμένη κατανομή των πόρων εποπτείας από τις αρμόδιες Τομεακές Αρχές, όπως ορίζεται στο Παράρτημα ΣΤ' της Εθνικής Στρατηγικής για την περίοδο 2026–2030.

Καθώς ολοκληρώνεται αυτή η εργασία, είναι χρήσιμο να επιχειρηθεί η περιγραφή ορισμένων κατευθύνσεων για μελλοντική επιστημονική έρευνα και περαιτέρω ανάλυση πάνω στο θέμα που εξετάστηκε. Μια βασική κατεύθυνση για περαιτέρω έρευνα είναι η επικύρωση της προτεινόμενης μεθοδολογίας χρησιμοποιώντας πραγματικά ή ημι-πραγματικά δεδομένα εποπτείας. Συνεργασία με τις Τομεακές Αρμόδιες Αρχές μπορεί να βοηθήσει στον έλεγχο της μεταφερσιμότητας των ευρημάτων πέρα από το συνθετικό περιβάλλον, που αναπτύχθηκε στην περίπτωση μας, ενισχύοντας έτσι την εξωτερική εγκυρότητα των αποτελεσμάτων. Επιπλέον, συνιστάται η χρήση ενός κοινού master dataset με ένθετη υποδειγματοληψία για διάφορα μεγέθη δείγματος, ώστε να μπορεί να διαχωριστεί μεθοδολογικά η καθαρή επίδραση του μεγέθους του δείγματος από τη στοχαστικότητα που εγγενώς εισάγει η διαδικασία γέννησης των δεδομένων.

Η ενσωμάτωση, ακόμη και σε μικρό βαθμό, δεικτών από τις Διαστάσεις Α' (Διακυβέρνηση) και Δ' (Sendai), που λείπουν σχεδόν εντελώς από το υπάρχον σύνολο χαρακτηριστικών, αναμένεται να αυξήσει το ανώτατο δυνατό επίπεδο του δείκτη macro-F1, βελτιώνοντας την επεξηγηματική ικανότητα του μοντέλου. Επιπλέον, θα μπορούσε να δοθεί έμφαση στα μοντέλα επιβίωσης, όπως το μοντέλο αναλογικών κινδύνων του Cox, το οποίο έχει ήδη αναλυθεί στο θεωρητικό πλαίσιο. Με αυτόν τον τρόπο, θα υπήρχε η δυνατότητα εκτίμησης όχι μόνο της κατηγορίας κινδύνου αλλά και του αναμενόμενου χρόνου μέχρι την επόμενη κρίσιμη διαταραχή.

Η ενσωμάτωση πραγματικών ροών δεδομένων από συστήματα SCADA/IoT και τηλεμετρία σε πραγματικό χρόνο επιτρέπει τη μετάβαση από στατική ταξινόμηση σε μια δυναμική και συνεχή παρακολούθηση της ανθεκτικότητας, αξιοποιώντας ψηφιακά δίδυμα. Παράλληλα, προτείνεται η διεύρυνση του μοντέλου ώστε να περιλαμβάνει ρητά δείκτες κυβερνοασφάλειας σύμφωνα με την Οδηγία NIS2, σε συνδυασμό με τους φυσικούς και οργανωσιακούς δείκτες της Οδηγίας CER. Με αυτόν τον τρόπο, επιτυγχάνεται μια ολιστική



σύγκλιση μεταξύ φυσικής και ψηφιακής ασφάλειας, όπως περιγράφεται στο πρώτο κεφάλαιο της μελέτης.

Τέλος, συνιστάται μια πιο οργανωμένη προσέγγιση στην αναζήτηση υπερπαραμέτρων μέσω της Bayesian Optimization ή της εξαντλητικής GridSearchCV. Επιπλέον, προτείνεται η δοκιμή επιπρόσθετων αλγορίθμων, όπως οι LightGBM, CatBoost και διάφορες τεχνικές νευρωνικών δικτύων, για να διαπιστωθεί αν το παρατηρούμενο ταβάνι στην απόδοση είναι πραγματικά δομικό ή εν μέρει οφείλεται σε αλγοριθμικούς περιορισμούς.



Βιβλιογραφία

- Adobor, H., & McMullen, R. S. (2018). Supply chain resilience: a dynamic and multidimensional approach. *The International Journal of Logistics Management*. <https://doi.org/10.1108/ijlm-04-2017-0093>.
- Agresti, A. (2003). Logit Models for Multinomial Responses. 267-313. <https://doi.org/10.1002/0471249688.ch7>.
- Alazab, M., Khurma, R. A., García-Arenas, M., Jatana, V., Baydoun, A., & Damaševičius, R. (2024). Enhanced threat intelligence framework for advanced cybersecurity resilience. *Egyptian Informatics Journal*. <https://doi.org/10.1016/j.eij.2024.100521>.
- Alhadidi, T., & Hasoon, S. (2024). Software Defect Prediction Using Extreme Gradient Boosting (XGBoost) with Tune Hyperparameter. *AL-Rafidain Journal of Computer Sciences and Mathematics*. <https://doi.org/10.33899/csmj.2023.142739.1081>.
- Amer, L., Erkoc, M., Andiroglu, E., & Çelik, N. (2022). A Novel Composite Resilience Indicator for Decentralized Infrastructure Systems (CRI-DS). *ArXiv, abs/2207.08303*. <https://doi.org/10.48550/arxiv.2207.08303>.
- Arif, M., Rabby, H. R., Nadia, N. Y., Hassan, M. Z., & Babu, H. (2026). Machine Learning Models for Cybersecurity Risk Analysis in U.S. Critical Infrastructure Systems. *Journal of Information Systems Engineering and Management*. <https://doi.org/10.52783/jisem.v11i1s.14284>.
- Bentéjac, C., Csörgo, A., & Martínez-Muñoz, G. (2019). A comparative analysis of gradient boosting algorithms. *Artificial Intelligence Review*, 54, 1937 - 1967. <https://doi.org/10.1007/s10462-020-09896-5>.
- Bergstra, J., & Bengio, Y. (2012). Random Search for Hyper-Parameter Optimization. *J. Mach. Learn. Res.*, 13, 281-305. <https://jmlr.org/papers/volume13/bergstra12a/bergstra12a.pdf>.
- Bernal, L., Rastelli, G., & Pinzi, L. (2025). Improving Machine Learning Classification Predictions through SHAP and Features Analysis Interpretation. *Journal of Chemical Information and Modeling*, 65, 11716 - 11732. <https://doi.org/10.1021/acs.jcim.5c02015>.
- Berry, H. S., Dasri, Y., Mitra, S., & Palaskar, B. (2026). AI-Enhanced Cybersecurity Risk Assessment for Smart Grid Infrastructures Using NIST Framework. *2026 14th International Symposium on Digital Forensics and Security (ISDFS)*, 1-9. <https://doi.org/10.1109/isdfs69419.2026.11459070>.
- Biau, G., & Scornet, E. (2015). A random forest guided tour. *TEST*, 25, 197 - 227. <https://doi.org/10.1007/s11749-016-0481-7>.



- Boldini, D., Grisoni, F., Kuhn, D., Friedrich, L., & Sieber, S. (2023). Practical guidelines for the use of gradient boosting for molecular property prediction. *Journal of Cheminformatics*, 15. <https://doi.org/10.1186/s13321-023-00743-7>.
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5-32. <https://doi.org/10.1023/a:1010933404324>.
- Camacho, C., Bower, P., Webb, R. T., & Munford, L. (2025). Assessing the relationship between community resilience and health outcomes: an observational local-authority level study in England. *Journal of Epidemiology and Community Health*, 80. <https://doi.org/10.1136/jech-2025-224513>.
- Carlson, J., Haffenden, R., Bassett, G., Buehring, W., Collins, M., Folga, S., Petit, F., Phillips, J., Verner, D., & Whitfield, R. (2012). Resilience: Theory and Application. <https://doi.org/10.2172/1044521>.
- Chen, T., & Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. <https://doi.org/10.1145/2939672.2939785>.
- Choi, T., & Lambert, J. (2017). Advances in Risk Analysis with Big Data. *Risk Analysis*, 37. <https://doi.org/10.1111/risa.12859>.
- Darkow, P. (2018). Beyond “bouncing back”: Towards an integral, capability-based understanding of organizational resilience. *Journal of Contingencies and Crisis Management*. <https://doi.org/10.1111/1468-5973.12246>.
- De Soto, B. G., Georgescu, A. V., Mantha, B. R. K., Turk, Ž., Maciel, A., & Sonkor, M. S. (2022). Construction cybersecurity and critical infrastructure protection: new horizons for Construction 4.0. *J. Inf. Technol. Constr.*, 27, 571-594. <https://doi.org/10.36680/j.itcon.2022.028>.
- Dick, K., Russell, L., Dosso, Y. S., Kwamena, F., & Green, J. (2019). Deep Learning for Critical Infrastructure Resilience. *Journal of Infrastructure Systems*. [https://doi.org/10.1061/\(asce\)is.1943-555x.0000477](https://doi.org/10.1061/(asce)is.1943-555x.0000477).
- Duchek, S. (2019). Organizational resilience: a capability-based conceptualization. *Business Research*, 13, 215-246. <https://doi.org/10.1007/s40685-019-0085-7>.
- El-Habil, A. (2012). An Application on Multinomial Logistic Regression Model. *Pakistan Journal of Statistics and Operation Research*, 8, 271-291. <https://doi.org/10.18187/pjsor.v8i2.234>.
- Fitzgerald, J., & Morisset, C. (2024). Can we develop holistic approaches to delivering cyber-physical systems security? *Res. Dir. Cyber Phys. Syst.*, 2. <https://doi.org/10.1017/cbp.2024.1>.
- Florek, P., & Zagdanski, A. (2023). Benchmarking state-of-the-art gradient boosting algorithms for classification. *ArXiv*, abs/2305.17094. <https://doi.org/10.48550/arxiv.2305.17094>.



- Fonseca, J., & Bação, F. (2023). Tabular and latent space synthetic data generation: a literature review. *Journal of Big Data*, 10, 1-37. <https://doi.org/10.1186/s40537-023-00792-7>.
- Förster, A., Hollick, M., Katzenbeisser, S., & Krauß, C. (2026). Resilience Meets Security in Cyber-Physical Systems and Critical Infrastructures. *Communications of the ACM*, 69, 35 - 38. <https://doi.org/10.1145/3768169>.
- Gandomi, A. H., Chen, F., & Abualigah, L. (2023). Big Data Analytics Using Artificial Intelligence. *Electronics*. <https://doi.org/10.3390/electronics12040957>.
- Grebovic, M., Filipović, L., Katnic, I., Vukotić, M., & Popović, T. (2022). Overcoming Limitations of Statistical Methods with Artificial Neural Networks. *2022 International Arab Conference on Information Technology (ACIT)*, 1-6. <https://doi.org/10.1109/acit57182.2022.9994218>.
- Guikema, S. D. (2009). Natural disaster risk analysis for critical infrastructure systems: An approach based on statistical learning theory. *Reliability Engineering & System Safety*, 94(4), 855–860. <https://doi.org/10.1016/j.res.2008.09.003>.
- Halabaku, E., & Bytyçi, E. (2024). Overfitting in Machine Learning: A Comparative Analysis of Decision Trees and Random Forests. *Intell. Autom. Soft Comput.*, 39, 987-1006. <https://doi.org/10.32604/iasc.2024.059429>.
- Hromada, M., Řehák, D., & Lukás, L. (2021). Resilience Assessment in Electricity Critical Infrastructure from the Point of View of Converged Security. *Energies*. <https://doi.org/10.3390/en14061624>.
- Hromada, M., Řehák, D., Skobiej, B., & Bajer, M. (2023). Converged Security and Information Management System as a Tool for Smart City Infrastructure Resilience Assessment. *Smart Cities*. <https://doi.org/10.3390/smartcities6050102>.
- Hussain, I., Ching, K. B., Utraphan, C., Tay, K. G., Memon, I., & Memon, S. (2025). Predicting Monthly Wind Speeds Using XGBoost: A Case Study for Renewable Energy Optimization. *Processes*. <https://doi.org/10.3390/pr13061763>.
- Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*, 31, 685 - 695. <https://doi.org/10.1007/s12525-021-00475-2>.
- Kabir, M. H., Razib, M., Arafat, Y., Rashed, R. A. M., & Jesan, Z. (2025). Strengthening U.S. Critical Infrastructure Resilience Through NIST-Aligned Cybersecurity Governance and AI-Driven Threat Detection. *Journal of Computer Science and Technology Studies*. <https://doi.org/10.32996/jcsts.2025.7.6.134>.
- Kaufman, S., Rosset, S., & Perlich, C. (2011). Leakage in data mining: formulation, detection, and avoidance. 556-563. <https://doi.org/10.1145/2020408.2020496>.
- Kayan, H., Nunes, M., Rana, O., Burnap, P., & Perera, C. (2021). Cybersecurity of Industrial Cyber-Physical Systems: A Review. *ACM Computing Surveys (CSUR)*, 54, 1 - 35. <https://doi.org/10.1145/3510410>.



- Khatib, M. E., Shehhi, H. A., & Nuaimi, M. A. (2023). How Big Data and Big Data Analytics Mediate Organizational Risk Management. *Journal of Financial Risk Management*. <https://doi.org/10.4236/jfrm.2023.121001>.
- Koh, S., Suresh, K., Ralph, P., & Saccone, M. (2023). Quantifying organisational resilience: an integrated resource efficiency view. *International Journal of Production Research*, 62, 5737 - 5756. <https://doi.org/10.1080/00207543.2023.2296018>.
- Kutlu, M., Donmez, T. B., & Freeman, C. (2024). Machine Learning Interpretability in Diabetes RiskAssessment: A SHAP Analysis. *ADBA Information Technology and Publishing Limited Company*. <https://doi.org/10.69882/adba.cem.2024075>.
- Kyriazos, T., & Poga, M. (2024). Application of Machine Learning Models in Social Sciences: Managing Nonlinear Relationships. *Encyclopedia*. <https://doi.org/10.3390/encyclopedia4040118>.
- Li, L., Rysavy, M., Bobashev, G., & Das, A. (2024). Comparing methods for risk prediction of multicategory outcomes: dichotomized logistic regression vs. multinomial logit regression. *BMC Medical Research Methodology*, 24. <https://doi.org/10.1186/s12874-024-02389-x>
- Li, Z. (2022). Extracting spatial effects from machine learning model using local interpretation method: An example of SHAP and XGBoost. *Comput. Environ. Urban Syst.*, 96, 101845. <https://doi.org/10.1016/j.compenvurbsys.2022.101845>.
- Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R News*, 2(3), 18–22. <https://journal.r-project.org/articles/RN-2002-022/>.
- Liu, B., & Mazumder, R. (2024). Randomization Can Reduce Both Bias and Variance: A Case Study in Random Forests. *J. Mach. Learn. Res.*, 26, 150:1-150:49. <https://doi.org/10.48550/arxiv.2402.12668>.
- Longo, A., Ardebili, A. A., Lazari, A., & Ficarella, A. (2025). Cyber-Physical Resilience: Evolution of Concept, Indicators, and Legal Frameworks. *Electronics*. <https://doi.org/10.3390/electronics14081684>.
- Lu, Y.-C., Wang, H., Fu, T., & Wei, W. (2023). Machine Learning for Synthetic Data Generation: a Review. *ArXiv, abs/2302.04062*. <https://doi.org/10.48550/arxiv.2302.04062>.
- Lundberg, S. M., & Lee, S.-I. (2017). A Unified Approach to Interpreting Model Predictions. 4765-4774. <https://doi.org/10.4230/oasics.dx.2024.27>.
- Lundberg, S. M., Erion-Barner, G., & Lee, S.-I. (2018). Consistent Individualized Feature Attribution for Tree Ensembles. *ArXiv, abs/1802.03888*. <https://doi.org/10.48550/arxiv.1802.03888>.
- Manuilov, Y. (2026). Countering Physical Cyber Threats and Critical Infrastructure Protection: International Experience and Strategic Priorities. *INFORMATION AND LAW*. [https://doi.org/10.37750/2616-6798.2026.2\(57\).364481](https://doi.org/10.37750/2616-6798.2026.2(57).364481).



- Marzi, S., Mysiak, J., Essenfelder, A., Amadio, M., Giove, S., & Fekete, A. (2019). Constructing a comprehensive disaster resilience index: The case of Italy. *PLoS ONE*, 14. <https://doi.org/10.1371/journal.pone.0221585>.
- Mikac, R. (2023). Protection of the EU's Critical Infrastructures: Results and Challenges. *Applied Cybersecurity & Internet Governance*. <https://doi.org/10.60097/acig/162868>.
- Min, O. (2013). Review on modeling and simulation of interdependent critical infrastructure systems. *Reliab. Eng. Syst. Saf.*, 121, 43-60. <https://doi.org/10.1016/j.res.2013.06.040>.
- Mohamad, N., Ali, Z., Noor, N. M., & Baharum, A. (2016). Multinomial logistic regression modelling of stress level among secondary school teachers in Kubang Pasu District, Kedah. 060018. <https://doi.org/10.1063/1.4954623>.
- Mottahedi, A., Sereshki, F., Ataei, M., Qarahasanlou, A. N., & Barabadi, A. (2021). The Resilience of Critical Infrastructure Systems: A Systematic Literature Review. *Energies*. <https://doi.org/10.3390/en14061571>.
- Ojo, B., Ogborigbo, J. C., & Okafor, M. O. (2024). Innovative solutions for critical infrastructure resilience against cyber-physical attacks. *World Journal of Advanced Research and Reviews*. <https://doi.org/10.30574/wjarr.2024.22.3.1921>.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Louppe, G., Prettenhofer, P., Weiss, R., Weiss, R. J., VanderPlas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. (2011). Scikit-learn: Machine Learning in Python. *J. Mach. Learn. Res.*, 12, 2825-2830. <https://doi.org/10.5555/1953048.2078195>.
- Pellegrino, E., Camilla, C., Abbou, N., Beaufils, N., Pissier, C., Gabert, J., Nanni-Metellus, I., & Ouafik, L. (2023). Extreme Gradient Boosting Tuned with Metaheuristic Algorithms for Predicting Myeloid NGS Onco-Somatic Variant Pathogenicity. *Bioengineering*, 10. <https://doi.org/10.3390/bioengineering10070753>.
- Pezoulas, V., Zaridis, D. I., Mylona, E., Androutsos, C., Apostolidis, K., Tachos, N., & Fotiadis, D. I. (2024). Synthetic data generation methods in healthcare: A review on open-source tools and methods. *Computational and Structural Biotechnology Journal*, 23, 2892 - 2910. <https://doi.org/10.1016/j.csbj.2024.07.005>.
- Potcovaru, S.-D., & Mustata, M.-A. (2026). Critical Infrastructure through a Securitization Theory Lens. *BULLETIN OF "CAROL I" NATIONAL DEFENCE UNIVERSITY*. <https://doi.org/10.53477/2284-9378-25-65>.
- Probst, P., Wright, M. N., & Boulesteix, A. (2018). Hyperparameters and tuning strategies for random forest. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9. <https://doi.org/10.1002/widm.1301>.



Probst, P., Wright, M. N., & Boulesteix, A. (2018). Hyperparameters and tuning strategies for random forest. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9. <https://doi.org/10.1002/widm.1301>.

Pursiainen, C., & Kytömaa, E. (2022). From European critical infrastructure protection to the resilience of European critical entities: what does it mean?. *Sustainable and Resilient Infrastructure*, 8, 85 - 101. <https://doi.org/10.1080/23789689.2022.2128562>.

Qudus, L. (2025). Resilient Systems: Building Secure Cyber-Physical Infrastructure for Critical Industries Against Emerging Threats. *International Journal of Research Publication and Reviews*. <https://doi.org/10.55248/gengpi.6.0125.0514>.

Rahmani, A., Azhir, E., Ali, S., Mohammadi, M., Ahmed, O. H., Ghafour, M. Y., Ahmed, S. H., & Hosseinzadeh, M. (2021). Artificial intelligence approaches and mechanisms for big data analytics: a systematic study. *PeerJ Computer Science*, 7. <https://doi.org/10.7717/peerj-cs.488>.

Raich, R., Raich, A., & Kinhekar, N. (2025). Securing the Convergence of IT and OT Networks in Cyber Physical System: Policy, Architecture and Implementation Challenges. *ITM Web of Conferences*. <https://doi.org/10.1051/itmconf/20257901005>.

Rostek, K., Wisniewski, M. J., & Skomra, W. (2022). Analysis and Evaluation of Business Continuity Measures Employed in Critical Infrastructure during the COVID-19 Pandemic. *Sustainability*. <https://doi.org/10.3390/su142215388>.

Scholten, K., Scott, P., & Fynes, B. (2019). Building routines for non-routine events: supply chain resilience learning mechanisms and their antecedents. *Supply Chain Management: An International Journal*. <https://doi.org/10.1108/scm-05-2018-0186>

Scholz, C., Schauer, S., & Latzenhofer, M. (2022). The emergence of new critical infrastructures. Is the COVID-19 pandemic shifting our perspective on what critical infrastructures are?. *International Journal of Disaster Risk Reduction*, 83, 103419 - 103419. <https://doi.org/10.1016/j.ijdrr.2022.103419>.

Scornet, E., Biau, G., & Vert, J.-P. (2014). Consistency of Random Forests. *Annals of Statistics*, 43, 1716-1741. <https://doi.org/10.1214/15-aos1321>.

Shkuropadska, D., Lebedeva, L., & Gonçalves, J. (2025). Institutional framework for the resilience of critical infrastructure of EU, NATO countries and Ukraine. *Scientia fructuosa*. [https://doi.org/10.31617/1.2025\(159\)03](https://doi.org/10.31617/1.2025(159)03).

Sono, D., Wei, Y., & Jin, Y. (2021). Assessing the Climate Resilience of Sub-Saharan Africa (SSA): A Metric-Based Approach. *Land*. <https://doi.org/10.3390/land10111205>.

Srivastava, P. K. (2025). Cyber-Physical Resilience in Mission-Critical Facilities: Integrating Security, Reliability, and Safety Engineering. *International Journal of Emerging Research in Engineering and Technology*. <https://doi.org/10.63282/3050-922x.ijeret-v6i4p122>.



Ulya, D. M., Juhari, J., Yuliana, R. E., & Jamhuri, M. (2025). Reliable and Efficient Sentiment Analysis on IMDb with Logistic Regression. *CAUCHY: Jurnal Matematika Murni dan Aplikasi*. <https://doi.org/10.18860/cauchy.v10i2.33809>.

Wells, E. M., Boden, M., Tseytlin, I., & Linkov, I. (2022). Modeling critical infrastructure resilience under compounding threats: A systematic literature review. *Progress in Disaster Science*. <https://doi.org/10.1016/j.pdisas.2022.100244>.

Wisniewski, M. J., Szwarc, K., & Skomra, W. (2023). Continuity of Essential Services as an Emerging Challenge for Societal Resilience. *IEEE Access*, 11, 44614-44635. <https://doi.org/10.1109/access.2023.3271751>.

Zabor, E., Reddy, C., Tendulkar, R., & Patil, S. (2021). Logistic Regression in Clinical Studies. *International journal of radiation oncology, biology, physics*. <https://doi.org/10.1016/j.ijrobp.2021.08.007>.

Zaripova, R., Kosulin, V. V., Shkinderov, M., & Rakhmatullin, I. (2023). Unlocking the potential of artificial intelligence for big data analytics. *E3S Web of Conferences*. <https://doi.org/10.1051/e3sconf/202346004011>.

Zou, X., Hu, Y., Tian, Z., & Shen, K.-Y. (2019). Logistic Regression Model Optimization and Case Analysis. *2019 IEEE 7th International Conference on Computer Science and Network Technology (ICCSNT)*, 135-139. <https://doi.org/10.1109/iccsnt47585.2019.8962457>.

ΠΑΡΑΡΤΗΜΑ Ι

Κώδικας Python

RandomizedSearchCV_5000_commented.py

Generated on August 18, 2026

```
1  """
2  =====
3  ΜΟΝΤΕΛΟΠΟΙΗΣΗ ΣΥΝΘΕΤΟΥ ΔΕΙΚΤΗ ΑΝΘΕΚΤΙΚΟΤΗΤΑΣ (COMPOSITE RESILIENCE INDEX - CRI)
4  =====
5  Θεσμικό Πλαίσιο: Εθνική Στρατηγική Ανθεκτικότητας Κρίσιμων Οντοτήτων 2026–2030 (Παράρτημα ΣΤ')
6  Νομοθεσία: Ν. 5236/2025 (Οδηγία CER) & Ν. 5160/2024 (Οδηγία NIS2)
7
8  Περιγραφή:
9  1. Δημιουργία συνθετικού δείγματος n=5.000 κρίσιμων οντοτήτων κατανεμημένων σε 12 Τομείς.
10  2. Υπολογισμός του Composite Resilience Index (CRI, κλίμακα 0-100) βάσει 4 Διαστάσεων (A-D)
11     και 22 KPIs/KRIs.
12  3. Ταξινόμηση οντοτήτων σε 4 Κλάσεις Ανθεκτικότητας (Quartiles).
13  4. Εκπαίδευση & Hyperparameter Tuning (RandomizedSearchCV) μοντέλων ML:
14     - Logistic Regression (Baseline)
15     - Random Forest Classifier
16     - XGBoost Classifier
17  5. Εξαγωγή Διαγραμμάτων Ερμηνευσιμότητας SHAP (Bar Plot & Summary Beeswarm Plot).
18  =====
19  """
20  # =====
21  # Εισαγωγή απαραίτητων βιβλιοθηκών
22  # =====
23  import numpy as np          # αριθμητικοί υπολογισμοί, τυχαίοι αριθμοί, πράξεις σε πίνακες
24  import pandas as pd         # δομές δεδομένων (DataFrame) για τη διαχείριση του dataset
25  import matplotlib.pyplot as plt # δημιουργία και αποθήκευση γραφημάτων (π.χ. SHAP plots)
26  from sklearn.model_selection import (
27      train_test_split,        # διαχωρισμός δεδομένων σε εκπαίδευση/έλεγχο
28      StratifiedKFold,         # διασταυρούμενη επικύρωση με διατήρηση αναλογίας κλάσεων
29      cross_val_score,         # υπολογισμός σκορ απόδοσης σε πολλαπλά folds
30      RandomizedSearchCV,      # τυχαία αναζήτηση βέλτιστων υπερπαραμέτρων μοντέλου
31  )
32  from sklearn.ensemble import RandomForestClassifier # ο ταξινομητής Random Forest
33  from sklearn.linear_model import LogisticRegression # ο ταξινομητής λογιστικής παλινδρόμησης
34  # (baseline)
35  from sklearn.metrics import classification_report, f1_score # μετρικές αξιολόγησης απόδοσης
36  from sklearn.preprocessing import LabelEncoder, StandardScaler # κωδικοποίηση ετικετών &
37  # κανονικοποίηση χαρακτηριστικών
38  from sklearn.pipeline import make_pipeline # δημιουργία αλυσίδας επεξεργασίας (scaler + μοντέλο)
39  import xgboost as xgb        # η βιβλιοθήκη XGBoost (gradient boosting)
40  import warnings              # έλεγχος εμφάνισης προειδοποιητικών μηνυμάτων
41
42  # Απενεργοποίηση μη κρίσιμων προειδοποιήσεων (π.χ. από sklearn/xgboost) για καθαρό output στο console
```

```

42 warnings.filterwarnings("ignore")
43 # =====
44 # 1. ΓΕΝΙΚΕΣ ΡΥΘΜΙΣΕΙΣ & ΣΤΑΘΕΡΕΣ (CONFIGURATION)
45 # =====
46
47 # Σταθερός "σπόρος" τυχειότητας (Seed) για απόλυτη αναπαραγωγιμότητα αποτελεσμάτων
48 # Εξασφαλίζει ότι κάθε φορά που τρέχει ο κώδικας παράγονται τα ΙΔΙΑ "τυχαία" αποτελέσματα
  (αναπαραγωγιμότητα πειράματος)
49 RANDOM_STATE = 42
50 np.random.seed(RANDOM_STATE)
51
52 # ===== CONFIGURATION =====
53 # Λίστα με τους 12 τομείς κρίσιμων υποδομών, όπως ορίζονται στο Παράρτημα της Οδηγίας CER (ΕΕ)
  2022/2557 / Ν.5236/2025
54 # Προσαρμογή στις απαιτήσεις της Εθνικής Στρατηγικής για την Ανθεκτικότητα των Κρίσιμων Οντοτήτων
  2026-2030
55 SECTORS = [
56     "Ενέργεια",
57     "Μεταφορές",
58     "Τραπεζικός κλάδος",
59     "Υποδομές χρηματοπιστωτικών αγορών",
60     "Υγεία",
61     "Πόσιμο νερό",
62     "Λύματα",
63     "Αστικά απόβλητα",
64     "Ψηφιακές υποδομές",
65     "Δημόσια διοίκηση",
66     "Διάστημα",
67     "Παραγωγή/διανομή τροφίμων",
68 ]
69
70 # Οι 4 κλάσεις ανθεκτικότητας, που προκύπτουν από τα τεταρτημόρια (Quartiles) του CRI, στις οποίες θα
  ταξινομείται
71 # κάθε οντότητα (η σειρά εδώ είναι λογική/σοβαρότητας, ΟΧΙ απαραίτητα η σειρά που θα δώσει αργότερα
  ο LabelEncoder,
72 # ο οποίος ταξινομεί αλφαβητικά)
73 CLASS_LABELS = ["Μη κρίσιμο", "Χαμηλή ανθεκτικότητα", "Κρίσιμο", "Πολύ κρίσιμο"]
74
75
76 # =====
77 # 2. ΑΡΧΙΤΕΚΤΟΝΙΚΗ CRI - ΠΑΡΑΡΤΗΜΑ ΣΤ' (4 ΔΙΑΣΤΑΣΕΙΣ & ΔΕΙΚΤΕΣ)
78 # =====
79 # Η δομή CRI_LEVELS περιλαμβάνει το βάρος κάθε Διάστασης (sum = 1.0)
80 # και τη λίστα των επιμέρους κανονικοποιημένων δεικτών της (0-100).
81

```

```

82 CRI_LEVELS = {
83     # Διάσταση Α': Διακυβέρνηση & Θεσμική Ωριμότητα (Συντελεστής Στάθμισης w_A = 0.25)
84     "dim_A_governance": (
85         0.25,
86         [
87             "A1_char_pct",    # (%) Ποσοστό κρίσιμων οντοτήτων που έχουν χαρακτηριστεί
88             "A2_plan_appr_pct", # (%) Ποσοστό οντοτήτων με εγκεκριμένο Σχέδιο Ανθεκτικότητας
89             "A3_appr_time",    # Μέσος χρόνος αξιολόγησης/έγκρισης Σχεδίου Ανθεκτικότητας
90             "A4_authority_pct", # (%) Ποσοστό Τομέων με λειτουργική Τομεακή Αρμόδια Αρχή
91             "A5_contact_point", # Λειτουργία Εθνικού Ενιαίου Σημείου Επαφής
92             "A6_tisn_net"      # Λειτουργία Δικτύων TISN
93         ]
94     ),
95     # Διάσταση Β': Αποδοτικότητα Οντοτήτων (Συντελεστής Στάθμισης w_B = 0.30)
96     "dim_B_efficiency": (
97         0.30,
98         [
99             "B1_iso_pct",      # (%) Ποσοστό οντοτήτων με πιστοποίηση ISO 22301 (Business Continuity)
100             "B2_training_pct", # (%) Ποσοστό Υπευθύνων Ανθεκτικότητας και στελεχών κρίσιμων λειτουργιών
101             "B3_exercises_num", # Μέσος αριθμός διεξαχθέντων ασκήσεων ετοιμότητας ετησίως ανά
102             "B4_inspection_pct", # (%) Ποσοστό υλοποίησης του ετήσιου προγράμματος επιθεωρήσεων
103             "B5_incident_rep_pct", # (%) Ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών
104             "B6_digital_twin"    # Κρίσιμες υποδομές με χρήση Ψηφιακού Διδύμου (Digital Twin)
105         ]
106     ),
107     # Διάσταση Γ': Αποτελέσματα & Επιπτώσεις (Συντελεστής Στάθμισης w_C = 0.25)
108     "dim_C_results": (
109         0.25,
110         [
111             "C1_mttr",          # Μέσος χρόνος αποκατάστασης βλάβης/υπηρεσίας (MTTR) ανά τομέα
112             "C2_major_incidents", # Αριθμός σημαντικών συμβάντων με σοβαρές επιπτώσεις
113             "C3_financial_loss",  # Συνολικές οικονομικές επιπτώσεις από διαταραχές (σε €)
114             "C4_user_satisfaction", # Δείκτης ικανοποίησης χρηστών/πολιτών ουσιωδών υπηρεσιών
115             "C5_insurance_claims" # Αριθμός ασφαλιστικών απαιτήσεων από διαταραχές
116         ]
117     ),
118     # Διάσταση Δ': Ευθυγράμμιση με Πλαίσιο Sendai - Στόχος 4 (Συντελεστής Στάθμισης w_D = 0.20)
119     "dim_D_sendai": (
120         0.20,
121         [
122             "D1_infra_damage",    # Ζημίες σε κρίσιμες υποδομές από καταστροφές
123             "D2_health_interruption", # Ημέρες διακοπής υπηρεσιών υγείας
124             "D3_edu_interruption",  # Ημέρες διακοπής υπηρεσιών εκπαίδευσης
125             "D4_power_outage_pop",  # Πληθυσμός εκτεθειμένος σε διακοπή ηλεκτρισμού άνω των 24 ωρών

```

```

126         "D5_water_outage_pop"    # Πληθυσμός εκτεθειμένος σε διακοπή πόσιμου νερού άνω των 24 ωρών
127     ]
128 )
129 }
130
131 #
=====
132 # Σημείωση: Οι δείκτες της Διάστασης Δ' ακολουθούν τους δείκτες του τέταρτου στόχου του πλαισίου
SENDAI του Ο.Η.Ε.
133 # Η εκπαίδευση (δείκτης Δ3) δεν αποτελεί τομέα του ν. 5236/2025, αλλά παρακολουθείται ως δείκτης
κοινωνικής
134 # ανθεκτικότητας, σε συνεργασία με τις αρμόδιες αρχές, χωρίς να δημιουργεί υποχρεώσεις στο πλαίσιο
της στρατηγικής.
135 #
=====
136
137 # Επίπεδη λίστα με το σύνολο των 22 δεικτών του Παραρτήματος ΣΤ'
138 ALL_CRI_INDICATORS = [sub for _, subs in CRI_LEVELS.values() for sub in subs]
139
140 # Υποσύνολο παρατηρήσιμων δεικτών σε επίπεδο μεμονωμένης οντότητας που θεωρούμε "εύκολα
διαθέσιμους" χωρίς πλήρη επιτόπια επιθεώρηση
141 # (αυτό είναι το μόνο που θα "βλέπουν" τα μοντέλα TN)
142 # Αυτοί οι δείκτες αποτελούν τα αριθμητικά χαρακτηριστικά (features) του μηχανικού πίνακα X
143 AVAILABLE_SUBSET = [
144     "A2_plan_appr_pct", # 1. (%) Ποσοστό οντοτήτων με εγκεκριμένο Σχέδιο Ανθεκτικότητας
145     "B1_iso_pct",      # 2. (%) Ποσοστό οντοτήτων με πιστοποίηση ISO 22301 (Business Continuity)
146     "B2_training_pct", # 3. (%) Ποσοστό Υπευθύνων Ανθεκτικότητας και στελεχών κρίσιμων λειτουργιών
με εξειδικευμένη κατάρτιση
147     "B3_exercises_num", # 4. Μέσος αριθμός διεξαχθέντων ασκήσεων ετοιμότητας ετησίως ανά οντότητα
148     "B5_incident_rep_pct", # 5. (%) Ποσοστό οντοτήτων που υποβάλλουν περιστατικά εντός 24 ωρών
149     "C1_mttr",         # 6. Μέσος χρόνος αποκατάστασης βλάβης/υπηρεσίας (MTTR) ανά τομέα
150     "C4_user_satisfaction" # 7. Δείκτης ικανοποίησης χρηστών/πολιτών ουσιαδών υπηρεσιών
151 ]
152
153 # =====
154 # 3. ΣΥΝΑΡΤΗΣΕΙΣ ΔΗΜΙΟΥΡΓΙΑΣ ΔΕΔΟΜΕΝΩΝ & ΠΡΟΕΠΕΞΕΡΓΑΣΙΑΣ
155 # =====
156
157 def generate_synthetic_dataset_cri(n_samples: int = 5000, random_state: int = RANDOM_STATE) ->
pd.DataFrame:
158     """
159     Δημιουργεί συνθετικό dataset n_samples οντοτήτων με βάση τη μεθοδολογία 3 βημάτων του
Παραρτήματος ΣΤ'.
160
161     Βήμα 1: Παραγωγή κανονικοποιημένων δεικτών (0-100) με τομεακές αποκλίσεις (beta distribution).
162     Βήμα 2: Υπολογισμός βαθμολογίας κάθε Διάστασης (A, B, C, D) ως μέσος όρος δεικτών.

```

```

163 Βήμα 3: Υπολογισμός CRI Score ως σταθμισμένος μέσος όρος + μη γραμμική συνδυαστική ποινή.
164 ""
165 # Δημιουργία ανεξάρτητης γεννήτριας τυχαίων αριθμών με συγκεκριμένο σπόρο,
166 # ώστε η παραγωγή δεδομένων να είναι πλήρως αναπαραγώγιμη
167 rng = np.random.default_rng(random_state)
168
169 # Ανάθεση τυχαίου τομέα (από τους 12) σε κάθε μία από τις n_samples οντότητες
170 data = {"sector": rng.choice(SECTORS, size=n_samples)}
171
172 # Τομεακές αποκλίσεις βάσης (Sector Baseline Offsets). Αντικατοπτρίζουν τη διαφορετική θεσμική/
τεχνολογική
173 # ωριμότητα κάθε κλάδου. Σταθερή μετατόπιση βαθμολογίας ανά τομέα: κάποιοι τομείς θεωρούνται
174 # συστηματικά πιο ή λιγότερο ανθεκτικοί (π.χ. τράπεζες +10, λύματα -8)
175 sector_baseline = {
176     "Ενέργεια": 8, "Τραπεζικός κλάδος": 10, "Υποδομές χρηματοπιστωτικών αγορών": 8,
177     "Ψηφιακές υποδομές": 5, "Μεταφορές": 0, "Υγεία": -3,
178     "Πόσιμο νερό": -5, "Λύματα": -8, "Αστικά απόβλητα": -7, "Δημόσια διοίκηση": -5,
179     "Διάστημα": 3, "Παραγωγή/διανομή τροφίμων": -6,
180 }
181
182 # Δημιουργία τιμών για καθένα από τους 22 δείκτες
183 for sub in ALL_CRI_INDICATORS:
184     # Χρήση κατανομής Beta(2.2, 2.0) για φυσιολογική διασπορά τιμών κλιμακωμένη στο [0-100]
185     # (η Beta δίνει ρεαλιστική ασυμμετρία: οι περισσότερες τιμές μέτριες)
186     base = rng.beta(2.2, 2.0, size=n_samples) * 100
187     # μετατόπιση ανάλογα με τον τομέα κάθε οντότητας (0 αν ο τομέας δεν
188     # υπάρχει ρητά στο sector_baseline)
189     shift = np.array([sector_baseline.get(s, 0) for s in data["sector"]])
190     # τυχαίος θόρυβος (κανονική κατανομή, μέση τιμή 0, τυπική απόκλιση 4)
191     noise = rng.normal(0, 4, size=n_samples)
192     # τελική τιμή δείκτη: άθροισμα βάσης + μετατόπισης + θορύβου,
193     # περιορισμένη ώστε να παραμένει μέσα στο εύρος [0, 100] (Κανονικοποίηση)
194     data[sub] = np.clip(base + shift + noise, 0, 100)
195
196 # Μετατροπή του dictionary δεδομένων σε pandas DataFrame
197 df = pd.DataFrame(data)
198
199 # Βήμα 1 & 2: Βαθμολογία κάθε Διάστασης (μη σταθμισμένος μέσος όρος των δεικτών της)
200 # Υπολογισμός βαθμολογίας κάθε επιπέδου CRI ως μέσος όρος των επιμέρους δεικτών που το
απαρτίζουν
201 dim_scores = {dim: df[subs].mean(axis=1) for dim, (_, subs) in CRI_LEVELS.items()}
202
203 # Βήμα 3: Υπολογισμός γραμμικού μέρους του CRI Score (Σταθμισμένος μέσος όρος)
204 # Γραμμικό μέρος του τελικού δείκτη RMI: σταθμισμένο άθροισμα των 22 επιπέδων,
205 # με τα βάρη που ορίστηκαν στο CRI_LEVELS
206 linear_part = sum(w * dim_scores[dim] for dim, (w, _) in CRI_LEVELS.items())

```

```

207
208 # Μη γραμμική συνδυαστική ποινή:
209 # Αν μια οντότητα υστερεί ταυτόχρονα στη Διακυβέρνηση (<40) και στην Αποδοτικότητα (<40),
210 # επιβάλλεται επιπλέον ποινή -8 μονάδων λόγω συνδυαστικού κινδύνου.
211 # (αναπαριστά τη δυσανάλογη επιδείνωση όταν συνυπάρχουν πολλαπλές αδυναμίες)
212 interaction_penalty = np.where(
213     (dim_scores["dim_A_governance"] < 40) & (dim_scores["dim_B_efficiency"] < 40), -8.0, 0.0
214 )
215 # Επιπλέον στοχαστικός θόρυβος μέτρησης πάνω στο τελικό σκορ
216 noise = rng.normal(0, 3.5, size=len(df))
217
218 # Τελικός υπολογισμός CRI Score: γραμμικό μέρος + ποινή αλληλεπίδρασης + θόρυβος,
219 # περιορισμένος στο εύρος [0, 100]
220 df["CRI_score"] = np.clip(linear_part + interaction_penalty + noise, 0, 100)
221
222 # Μετατροπή του συνεχούς δείκτη CRI_score σε 4 διακριτές 4 ισοπληθείς κλάσεις
223 # (Quartiles: 0-25%, 25-50%, 50-75%, 75-100%), χρησιμοποιώντας τεταρτημόρια (κάθε κλάση ≈ 25% του
224 πληθυσμού).
225 # duplicates='drop': αν δύο όρια τεταρτημορίων συμπίσουν, αγνοείται το διπλότυπο όριο αντί να
226 προκύψει σφάλμα
227 df["resilience_class"] = pd.qcut(df["CRI_score"], q=4, labels=CLASS_LABELS, duplicates='drop')
228
229 # Ασφαλιστικός έλεγχος: το duplicates='drop' μπορεί σιωπηλά να παράξει λιγότερες από 4 κλάσεις αν
230 συμπίσουν
231 # όρια τεταρτημορίων. Το qcut θα έχει ήδη ρίξει labels σε αυτή την περίπτωση, οπότε ελέγχουμε πόσες
232 # μοναδικές κλάσεις προέκυψαν στην πράξη.
233 n_classes_found = df["resilience_class"].nunique() # μετράει πόσες διαφορετικές κλάσεις υπάρχουν
234 στην πράξη
235 assert n_classes_found == len(CLASS_LABELS), ( # σταματάει το πρόγραμμα αν δεν βρέθηκαν
236 ακριβώς 4 κλάσεις
237
238     f"Αναμενόμενες {len(CLASS_LABELS)} κλάσεις, βρέθηκαν {n_classes_found}. "
239     "Πιθανή σύμπτωση ορίων τεταρτημορίων (duplicates='drop') — έλεγξε την κατανομή του CRI_score."
240 )
241 return df # επιστροφή του πλήρους DataFrame με όλους τους δείκτες, το CRI_score και την κλάση
242
243
244 def build_feature_sets(df: pd.DataFrame):
245     """
246     Κατασκευάζει τον πίνακα χαρακτηριστικών X και τη μεταβλητή στόχο y.
247     Εφαρμόζει One-Hot Encoding στη μεταβλητή του Τομέα (sector).
248     """
249     # Επιλογή MONO των "διαθέσιμων" δεικτών ως χαρακτηριστικά εισόδου (X)
250     X = df[AVAILABLE_SUBSET].copy()
251     # Μετατροπή της κατηγορικής μεταβλητής sector σε dummy μεταβλητές
252     # Προσθήκη one-hot κωδικοποιημένων μεταβλητών τομέα (μία δυαδική στήλη
253     # ανά τομέα: 1 αν η οντότητα ανήκει σε αυτόν τον τομέα, αλλιώς 0)

```

```

248     X = pd.concat([X, pd.get_dummies(df["sector"], prefix="sector")], axis=1)
249     return X, df["resilience_class"]
250
251     # =====
252     # 4. ΣΥΝΑΡΤΗΣΕΙΣ ΑΞΙΟΛΟΓΗΣΗΣ & SHAP EXPLAINABILITY
253     # =====
254     # ===== EVALUATION =====
255     def evaluate_model(model, X_test, y_test, name: str, target_names):
256         """
257         Υπολογίζει και τυπώνει τα μέτρα αξιολόγησης (Precision, Recall, F1-Score)
258         στο ανεξάρτητο σύνολο δοκιμής (Hold-out Test Set).
259         """
260         # Πρόβλεψη κλάσεων στο σύνολο ελέγχου με το ήδη εκπαιδευμένο μοντέλο
261         y_pred = model.predict(X_test)
262         # Υπολογισμός macro-F1 (μέσος όρος F1 ανά κλάση, ίση βαρύτητα σε κάθε κλάση)
263         macro_f1 = f1_score(y_test, y_pred, average="macro")
264         # Εκτύπωση επικεφαλίδας με το όνομα του μοντέλου
265         print(f"\n{'='*70}\n{name} - Hold-out Evaluation\n{'='*70}")
266         # Αναλυτική αναφορά precision/recall/F1 ανά κλάση
267         print(classification_report(y_test, y_pred, target_names=target_names, zero_division=0))
268         # Εκτύπωση του συνολικού macro-F1 με 3 δεκαδικά ψηφία
269         print(f"Macro-F1 Score: {macro_f1:.3f}")
270         return macro_f1    # επιστροφή του macro-F1 για περαιτέρω χρήση/αποθήκευση
271
272     # ===== SHAP ΑΝΑΛΥΣΗ =====
273     def compute_shap(model, X_test, model_name: str, class_names, target_class: str = "Πολύ κρίσιμο"):
274         """
275         Υπολογίζει τις τιμές SHAP (SHapley Additive exPlanations) και παράγει:
276         1. Bar plot: Συνολική σπουδαιότητα χαρακτηριστικών για όλες τις κλάσεις.
277         2. Summary Beeswarm plot: Επίδραση των χαρακτηριστικών στην κλάση 'Πολύ κρίσιμο'.
278         """
279         # Ενημερωτικό μήνυμα έναρξης
280         print(f"\nΥπολογισμός ερμηνευσιμότητας SHAP για το μοντέλο {model_name}...")
281         try:
282             import shap    # εισαγωγή της βιβλιοθήκης SHAP (εντός try, μπορεί να μην είναι εγκατεστημένη)
283             X_sample = X_test[:600] # χρήση μόνο 600 πρώτων γραμμών του test set (ταχύτερος υπολογισμός
SHAP)
284
285             # Βρίσκουμε δυναμικά τη θέση της κλάσης-στόχου μέσα στη λίστα class_names (π.χ. le.classes_),
286             # αντί να υποθέτουμε σταθερό index. Η σειρά του LabelEncoder είναι ΑΛΦΑΒΗΤΙΚΗ, όχι σειρά
σοβαρότητας:
287             # για τις 4 ετικέτες εδώ προκύπτει (0=Κρίσιμο, 1=Μη κρίσιμο, 2=Πολύ κρίσιμο, 3=Χαμηλή
ανθεκτικότητα).
288             class_names_list = list(class_names)    # μετατροπή σε απλή λίστα Python για εύκολη αναζήτηση
289             if target_class not in class_names_list: # έλεγχος ότι η ζητούμενη κλάση υπάρχει πράγματι
290                 raise ValueError(f"Η κλάση-στόχος '{target_class}' δεν βρέθηκε στις class_names:

```

```
{class_names_list}")
```

```
291
292     target_idx = class_names_list.index(target_class) # η πραγματική θέση (index) της κλάσης-στόχου
293
294     # Δημιουργία επεξηγητή SHAP (TreeExplainer) κατάλληλου για Tree-based μοντέλα (RF, XGBoost)
295     explainer = shap.TreeExplainer(model)
296     # Υπολογισμός τιμών SHAP για το δείγμα ελέγχου
297     shap_values = explainer.shap_values(X_sample)
298
299     # --- 1. Bar Plot (Overall Importance) ---
300     # 1. Bar Plot: γράφημα μπάρας με τη μέση σημαντικότητα κάθε χαρακτηριστικού, αθροιστικά σε όλες
    τις κλάσεις
301     plt.figure(figsize=(11, 7))
302     shap.summary_plot(shap_values, X_sample, plot_type="bar", show=False)
303     plt.title(f"SHAP Feature Importance (CRI) - {model_name}")
304     plt.tight_layout()
305     filename_bar = f"shap_cri_{model_name.lower().replace(' ', '_')}_bar.png"
306     plt.savefig(filename_bar, dpi=250, bbox_inches='tight')
307     plt.close()
308     print(f"Αποθηκεύτηκε το διάγραμμα: {filename_bar}")
309
310     # --- 2. Summary Beeswarm Plot για την κλάση 'Πολύ κρίσιμο' ---
311     # 2. Detailed Plot (beeswarm/dot) για την κλάση-στόχο (π.χ. 'Πολύ κρίσιμο')
312     plt.figure(figsize=(11, 7))
313     if isinstance(shap_values, list):
314         shap_target = shap_values[target_idx]
315     elif isinstance(shap_values, np.ndarray) and len(shap_values.shape) == 3: # νεότερη έκδοση: 3D
    πίνακας
316         shap_target = shap_values[:, :, target_idx]
317     else:
318         shap_target = shap_values
319
320     shap.summary_plot(shap_target, X_sample, show=False) # σχεδίαση detailed summary plot για την
    κλάση-στόχο
321     plt.title(f"SHAP Summary (CRI) - {model_name} (Κλάση '{target_class}')")
322     plt.tight_layout()
323     filename_crit = f"shap_cri_{model_name.lower().replace(' ', '_')}_critical.png"
324     plt.savefig(filename_crit, dpi=250, bbox_inches='tight')
325     plt.close()
326     print(f"Αποθηκεύτηκε το διάγραμμα: {filename_crit}")
327
328     except Exception as e:
329         # Αν κάτι αποτύχει (π.χ. δεν είναι εγκατεστημένο το shap), τυπώνεται
330         # προειδοποίηση αντί να "σκάσει" ολόκληρο το πρόγραμμα
331         print(f" ⚠ Σφάλμα SHAP για {model_name}: {e}")
332
```

```

333
334 # =====
335 # 5. ΚΥΡΙΑ ΔΙΑΔΙΚΑΣΙΑ ΕΚΤΕΛΕΣΗΣ (MAIN EXECUTION PIPELINE)
336 # =====
337 # ===== MAIN =====
338 def main(n_samples: int = 5000):
339     # -- Α. Δημιουργία & Προετοιμασία Δεδομένων --
340     print(f"Δημιουργία συνθετικού dataset βάσει CRI Παραρτήματος ΣΤ' (n={n_samples} οντότητες)...")
341     # παραγωγή του πλήρους συνθετικού dataset
342     df = generate_synthetic_dataset_cri(n_samples)
343     print("\nΚατανομή Κλάσεων Ανθεκτικότητας (CRI Quartiles):\n",
df["resilience_class"].value_counts().sort_index())
344
345     # εξαγωγή χαρακτηριστικών (X) και ετικέτας-στόχου (y)
346     X, y = build_feature_sets(df)
347     # Κωδικοποίηση ετικετών (Labels). Μετατρέπει κείμενο σε ακέραιος αριθμούς 0, 1, 2, 3
348     le = LabelEncoder()
349     # εκπαίδευση του encoder και μετατροπή των ετικετών σε ακέραιους αριθμούς
350     y_encoded = le.fit_transform(y)
351
352     # Διαχωρισμός σε Train Set (75%) και Hold-out Test Set (25%), με διαστρωμάτωση (stratification)
353     # στρωματοποίηση (stratify) ώστε να διατηρείται η αναλογία κλάσεων και στα δύο υποσύνολα
354     X_train, X_test, y_train, y_test = train_test_split(
355         X, y_encoded, test_size=0.25, stratify=y_encoded, random_state=RANDOM_STATE
356     )
357
358     results = {} # dictionary όπου θα αποθηκευτούν τα αποτελέσματα κάθε μοντέλου
359
360     # Ορισμός σχήματος Stratified 5-Fold Cross Validation στρωματοποιημένης διασταυρούμενης
επικύρωσης,
361     # για αξιόπιστη εκτίμηση γενίκευσης με ανακάτεμα (shuffle) πριν τον διαχωρισμό σε folds
362     skf = StratifiedKFold(n_splits=5, shuffle=True, random_state=RANDOM_STATE)
363
364     # Εκτύπωση επικεφαλίδας πειράματος
365     print("\n" + "="*80)
366     print(f"HYPERPARAMETER TUNING & ΜΟΝΤΕΛΟΠΟΙΗΣΗ CRI (n={n_samples})")
367     print("="*80)
368
369     # -- Β. Μοντέλο 1: Logistic Regression Baseline --
370     print("\n[1/3] Εκπαίδευση Baseline (Logistic Regression)...")
371     # Δημιουργία Pipeline για κανονικοποίηση χαρακτηριστικών (StandardScaler): Πρώτα κανονικοποίηση
χαρακτηριστικών
372     # μετά λογιστική παλινδρόμηση — απαραίτητο γιατί η λογιστική παλινδρόμηση είναι ευαίσθητη στην
κλίμακα των μεταβλητών
373     baseline_pipeline = make_pipeline(StandardScaler(), LogisticRegression(max_iter=2000,
random_state=RANDOM_STATE))

```

```

374 baseline_pipeline.fit(X_train, y_train) # εκπαίδευση του baseline μοντέλου στα δεδομένα εκπαίδευσης
375
376 # Υπολογισμός macro-F1 στο σύνολο ελέγχου (hold-out)
377 macro_f1_bl = evaluate_model(baseline_pipeline, X_test, y_test, "Logistic Regression Baseline",
le.classes_)
378 print(f"-> Εκτέλεση τελικού 5-Fold CV για Baseline...")
379 # Πλήρης 5-fold διασταυρούμενη επικύρωση πάνω σε ΟΛΟ το dataset (X, y_encoded),
380 # για πιο αξιόπιστη εκτίμηση απόδοσης πέρα από ένα μόνο διαχωρισμό
381 cv_scores_bl = cross_val_score(baseline_pipeline, X, y_encoded, cv=skf, scoring='f1_macro', n_jobs=-1)
382 # Αποθήκευση των αποτελεσμάτων (hold-out F1, μέσος όρος CV, τυπική απόκλιση CV)
383 results["Baseline (LogReg)"] = {'Holdout': macro_f1_bl, 'CV_mean': cv_scores_bl.mean(), 'CV_std':
cv_scores_bl.std()}
384
385 # -- C. Μοντέλο 2: Random Forest με Hyperparameter Tuning --
386 print("\n[2/3] Hyperparameter Tuning για Random Forest...")
387 # Βασικό μοντέλο Random Forest πριν το tuning:
388 # class_weight='balanced' αντισταθμίζει τυχόν ανισορροπία κλάσεων,
389 # n_jobs=-1 χρησιμοποιεί όλους τους διαθέσιμους πυρήνες επεξεργαστή
390 rf_base = RandomForestClassifier(class_weight='balanced', random_state=RANDOM_STATE, n_jobs=-1)
391
392 # Πλέγμα πιθανών τιμών υπερπαραμέτρων προς δοκιμή στο RandomizedSearchCV
393 rf_param_dist = {
394     'n_estimators': [200, 400, 500], # αριθμός δέντρων
395     'max_depth': [None, 10, 15, 20], # μέγιστο βάθος κάθε δέντρου (None = απεριόριστο)
396     'min_samples_split': [2, 4, 6], # ελάχιστος αριθμός δειγμάτων για διαχωρισμό κόμβου
397     'min_samples_leaf': [1, 2, 4], # ελάχιστος αριθμός δειγμάτων σε κάθε τελικό φύλλο
398     'max_features': ['sqrt', 0.4, 0.6] # πλήθος χαρακτηριστικών που εξετάζονται σε κάθε διαχωρισμό
399 }
400
401 # Δημιουργία αντικειμένου τυχαίας αναζήτησης: δοκιμάζει n_iter=10
402 # τυχαίους συνδυασμούς παραμέτρων, αξιολογώντας τον καθέναν με 3-fold CV
403 rf_search = RandomizedSearchCV(
404     estimator=rf_base, param_distributions=rf_param_dist, n_iter=10,
405     scoring='f1_macro', cv=3, random_state=RANDOM_STATE, n_jobs=-1, verbose=0
406 )
407 rf_search.fit(X_train, y_train) # εκτέλεση της αναζήτησης πάνω στα δεδομένα εκπαίδευσης
408 best_rf = rf_search.best_estimator_ # εξαγωγή του μοντέλου με τις καλύτερες παραμέτρους
409 print(f"🏆 Βέλτιστες Παράμετροι RF: {rf_search.best_params_}")
410
411 # Αξιολόγηση του βέλτιστου Random Forest στο σύνολο ελέγχου
412 macro_f1_rf = evaluate_model(best_rf, X_test, y_test, "Random Forest", le.classes_)
413 # Πλήρης 5-fold CV του βέλτιστου μοντέλου πάνω σε όλο το dataset
414 cv_scores_rf = cross_val_score(best_rf, X, y_encoded, cv=skf, scoring='f1_macro', n_jobs=-1)
415 results["Random Forest"] = {'Holdout': macro_f1_rf, 'CV_mean': cv_scores_rf.mean(), 'CV_std':
cv_scores_rf.std()}
416

```

```

417 # Υπολογισμός και αποθήκευση γραφημάτων SHAP για το βέλτιστο Random Forest
418 compute_shap(best_rf, X_test, "Random Forest", le.classes_)
419
420 # -- D. Μοντέλο 3: XGBoost Classifier με Hyperparameter Tuning --
421 print("\n[3/3] Hyperparameter Tuning για XGBoost...")
422 # Βασικό μοντέλο XGBoost πριν το tuning:
423 # objective='multi:softprob' για ταξινόμηση πολλαπλών κλάσεων με πιθανότητες,
424 # num_class = πλήθος κλάσεων, eval_metric='mlogloss' ως εσωτερική μετρική εκπαίδευσης
425 xgb_base = xgb.XGBClassifier(
426     objective='multi:softprob', num_class=len(CLASS_LABELS),
427     eval_metric='mlogloss', random_state=RANDOM_STATE, n_jobs=-1
428 )
429
430 # Πλέγμα πιθανών τιμών υπερπαραμέτρων για το XGBoost
431 xgb_param_dist = {
432     'n_estimators': [300, 400, 500],      # πλήθος διαδοχικών δέντρων (boosting rounds)
433     'max_depth': [4, 5, 6, 7],           # μέγιστο βάθος κάθε δέντρου
434     'learning_rate': [0.01, 0.03, 0.05, 0.1], # ρυθμός μάθησης (πόσο βάρος παίρνει κάθε νέο δέντρο) /
    ρυθμός μάθησης (Eta)
435     'subsample': [0.7, 0.85, 1.0],       # ποσοστό δειγμάτων που χρησιμοποιείται σε κάθε δέντρο
436     'colsample_bytree': [0.6, 0.8, 1.0],  # ποσοστό χαρακτηριστικών που χρησιμοποιείται σε κάθε δέντρο
437     'min_child_weight': [1, 3, 5],       # ελάχιστο άθροισμα βαρών δειγμάτων ανά φύλλο (έλεγχος
    overfitting)
438     'reg_alpha': [0.0, 0.1, 0.5],       # συντελεστής κανονικοποίησης L1 (Lasso)
439     'reg_lambda': [0.5, 1.0, 2.0]       # συντελεστής κανονικοποίησης L2 (Ridge)
440 }
441
442 # Τυχαία αναζήτηση βέλτιστων υπερπαραμέτρων για το XGBoost, ίδια λογική με το Random Forest
    παραπάνω
443 xgb_search = RandomizedSearchCV(
444     estimator=xgb_base, param_distributions=xgb_param_dist, n_iter=10,
445     scoring='f1_macro', cv=3, random_state=RANDOM_STATE, n_jobs=-1, verbose=0
446 )
447 xgb_search.fit(X_train, y_train)      # εκτέλεση αναζήτησης στα δεδομένα εκπαίδευσης
448 best_xgb = xgb_search.best_estimator_ # εξαγωγή του καλύτερου μοντέλου XGBoost
449 print(f"🏆 Βέλτιστες Παράμετροι XGBoost: {xgb_search.best_params_}")
450
451 # Αξιολόγηση του βέλτιστου XGBoost στο σύνολο ελέγχου
452 macro_f1_xgb = evaluate_model(best_xgb, X_test, y_test, "XGBoost", le.classes_)
453 print(f"-> Εκτέλεση τελικού 5-Fold CV για το βέλτιστο XGBoost...")
454 # Πλήρες 5-fold CV του βέλτιστου XGBoost πάνω σε όλο το dataset
455 cv_scores_xgb = cross_val_score(best_xgb, X, y_encoded, cv=skf, scoring='f1_macro', n_jobs=-1)
456 results["XGBoost"] = {'Holdout': macro_f1_xgb, 'CV_mean': cv_scores_xgb.mean(), 'CV_std':
    cv_scores_xgb.std()}
457
458 # Υπολογισμός και αποθήκευση γραφημάτων SHAP για το βέλτιστο XGBoost

```

```

459     compute_shap(best_xgb, X_test, "XGBoost", le.classes_)
460
461     # -- Ε. Συγκεντρωτική Παρουσίαση Αποτελεσμάτων --
462     # ===== SUMMARY =====
463     print("\n" + "="*90)
464     print(f"ΣΥΓΚΡΙΤΙΚΟΣ ΠΙΝΑΚΑΣ ΑΠΟΔΟΣΗΣ ΜΟΝΤΕΛΩΝ CRI (Macro-F1 Score, n={n_samples})")
465     print("="*90)
466     # Εκτύπωση συνοπτικού πίνακα με τα αποτελέσματα όλων των μοντέλων
467     for name, scores in results.items():
468         print(f"{name:22} | Holdout: {scores['Holdout']:.3f} | CV Mean: {scores['CV_mean']:.3f}
469         (±{scores['CV_std']:.3f})")
470
471     print("\n Η διαδικασία ολοκληρώθηκε! Τα μοντέλα βελτιστοποιήθηκαν για n=5000 και τα SHAP
472     γραφήματα αποθηκεύτηκαν.")
473     return df # επιστροφή του τελικού DataFrame (χρήσιμο αν καλείται η main() από άλλο script)
474
475     # Εκτέλεση της κύριας συνάρτησης όταν το αρχείο τρέχει ως script απευθείας (όχι όταν εισάγεται ως
476     module)
477     if __name__ == "__main__":
478         main(n_samples=5000)

```

ΠΑΡΑΡΤΗΜΑ ΙΙ

Αποτελέσματα Μοντέλων Ταξινόμησης

Δημιουργία συνθετικού dataset βάσει CRI Παραρτήματος ΣΤ' (n=5000 οντότητες)...

Κατανομή Κλάσεων Ανθεκτικότητας (CRI Quartiles):

```
resilience_class
Μη κρίσιμο          1250
Χαμηλή ανθεκτικότητα 1250
Κρίσιμο             1250
Πολύ κρίσιμο        1250
Name: count, dtype: int64
```

=====

HYPERPARAMETER TUNING & ΜΟΝΤΕΛΟΠΟΙΗΣΗ CRI (n=5000)

=====

[1/3] Εκπαίδευση Baseline (Logistic Regression)...

=====

Logistic Regression Baseline - Hold-out Evaluation

=====

	precision	recall	f1-score	support
Κρίσιμο	0.43	0.35	0.39	313
Μη κρίσιμο	0.63	0.70	0.66	312
Πολύ κρίσιμο	0.69	0.75	0.72	313
Χαμηλή ανθεκτικότητα	0.40	0.39	0.39	312
accuracy			0.55	1250
macro avg	0.54	0.55	0.54	1250
weighted avg	0.54	0.55	0.54	1250

Macro-F1 Score: 0.540

-> Εκτέλεση τελικού 5-Fold CV για Baseline...

[2/3] Hyperparameter Tuning για Random Forest...

✱ Βέλτιστες Παράμετροι RF: {'n_estimators': 200, 'min_samples_split': 2, 'min_samples_leaf': 4, 'max_features': 'sqrt', 'max_depth': 15}

=====

Random Forest - Hold-out Evaluation

=====

	precision	recall	f1-score	support
Κρίσιμο	0.45	0.37	0.40	313
Μη κρίσιμο	0.59	0.68	0.63	312
Πολύ κρίσιμο	0.69	0.74	0.71	313
Χαμηλή ανθεκτικότητα	0.41	0.39	0.40	312
accuracy			0.54	1250
macro avg	0.53	0.54	0.54	1250
weighted avg	0.53	0.54	0.54	1250

Macro-F1 Score: 0.535

Υπολογισμός ερμηνευσιμότητας SHAP για το μοντέλο Random Forest...

✓ Αποθηκεύτηκε το διάγραμμα: shap_cri_random_forest_bar.png

✓ Αποθηκεύτηκε το διάγραμμα: shap_cri_random_forest_critical.png

[3/3] Hyperparameter Tuning για XGBoost...

✱ Βέλτιστες Παράμετροι XGBoost: {'subsample': 0.85, 'reg_lambda': 2.0, 'reg_alpha': 0.0, 'n_estimators': 500, 'min_child_weight': 5, 'max_depth': 5, 'learning_rate': 0.01, 'colsample_bytree': 0.6}

=====

XGBoost - Hold-out Evaluation

	precision	recall	f1-score	support
Κρίσιμο	0.43	0.36	0.39	313
Μη κρίσιμο	0.59	0.71	0.64	312
Πολύ κρίσιμο	0.69	0.73	0.70	313
Χαμηλή ανθεκτικότητα	0.39	0.36	0.37	312
accuracy			0.54	1250
macro avg	0.52	0.54	0.53	1250
weighted avg	0.52	0.54	0.53	1250

Macro-F1 Score: 0.528

-> Εκτέλεση τελικού 5-Fold CV για το βέλτιστο XGBoost...

Υπολογισμός ερμηνευσιμότητας SHAP για το μοντέλο XGBoost...



Αποθηκεύτηκε το διάγραμμα: shap_cri_xgboost_bar.png



Αποθηκεύτηκε το διάγραμμα: shap_cri_xgboost_critical.png

ΣΥΓΚΡΙΤΙΚΟΣ ΠΙΝΑΚΑΣ ΑΠΟΔΟΣΗΣ ΜΟΝΤΕΛΩΝ CRI (Macro-F1 Score, n=5000)

Baseline (LogReg)	Holdout: 0.540	CV Mean: 0.550 (±0.010)
Random Forest	Holdout: 0.535	CV Mean: 0.537 (±0.004)
XGBoost	Holdout: 0.528	CV Mean: 0.530 (±0.014)

🎉 Η διαδικασία ολοκληρώθηκε! Τα μοντέλα βελτιστοποιήθηκαν για n=5000 και τα SHAP γραφήματα αποθηκεύτηκαν.

Δημιουργία συνθετικού dataset βάσει CRI Παραρτήματος ΣΤ' (n=10000 οντότητες)...

Κατανομή Κλάσεων Ανθεκτικότητας (CRI Quartiles):

```
resilience_class
Μη κρίσιμο          2500
Χαμηλή ανθεκτικότητα 2500
Κρίσιμο             2500
Πολύ κρίσιμο        2500
Name: count, dtype: int64
```

=====

HYPERPARAMETER TUNING & ΜΟΝΤΕΛΟΠΟΙΗΣΗ CRI (n=10000)

=====

[1/3] Εκπαίδευση Baseline (Logistic Regression)...

=====

Logistic Regression Baseline - Hold-out Evaluation

=====

	precision	recall	f1-score	support
Κρίσιμο	0.47	0.36	0.41	625
Μη κρίσιμο	0.61	0.71	0.66	625
Πολύ κρίσιμο	0.68	0.77	0.72	625
Χαμηλή ανθεκτικότητα	0.43	0.40	0.41	625
accuracy			0.56	2500
macro avg	0.55	0.56	0.55	2500
weighted avg	0.55	0.56	0.55	2500

Macro-F1 Score: 0.551

-> Εκτέλεση τελικού 5-Fold CV για Baseline...

[2/3] Hyperparameter Tuning για Random Forest...

✱ Βέλτιστες Παράμετροι RF: {'n_estimators': 200, 'min_samples_split': 2, 'min_samples_leaf': 4, 'max_features': 'sqrt', 'max_depth': 15}

=====

Random Forest - Hold-out Evaluation

=====

	precision	recall	f1-score	support
Κρίσιμο	0.46	0.33	0.38	625
Μη κρίσιμο	0.59	0.69	0.64	625
Πολύ κρίσιμο	0.67	0.75	0.71	625
Χαμηλή ανθεκτικότητα	0.42	0.41	0.41	625
accuracy			0.55	2500
macro avg	0.53	0.55	0.53	2500
weighted avg	0.53	0.55	0.53	2500

Macro-F1 Score: 0.535

Υπολογισμός ερμηνευσιμότητας SHAP για το μοντέλο Random Forest...

✓ Αποθηκεύτηκε το διάγραμμα: shap_cri_random_forest_bar.png

✓ Αποθηκεύτηκε το διάγραμμα: shap_cri_random_forest_critical.png

[3/3] Hyperparameter Tuning για XGBoost...

✱ Βέλτιστες Παράμετροι XGBoost: {'subsample': 0.85, 'reg_lambda': 2.0, 'reg_alpha': 0.0, 'n_estimators': 300, 'min_child_weight': 3, 'max_depth': 5, 'learning_rate': 0.03, 'colsample_bytree': 0.8}

=====

XGBoost - Hold-out Evaluation

	precision	recall	f1-score	support
Κρίσιμο	0.44	0.34	0.38	625
Μη κρίσιμο	0.59	0.68	0.63	625
Πολύ κρίσιμο	0.66	0.74	0.70	625
Χαμηλή ανθεκτικότητα	0.41	0.38	0.39	625
accuracy			0.54	2500
macro avg	0.52	0.54	0.53	2500
weighted avg	0.52	0.54	0.53	2500

Macro-F1 Score: 0.526

-> Εκτέλεση τελικού 5-Fold CV για το βέλτιστο XGBoost...

Υπολογισμός ερμηνευσιμότητας SHAP για το μοντέλο XGBoost...



Αποθηκεύτηκε το διάγραμμα: shap_cri_xgboost_bar.png



Αποθηκεύτηκε το διάγραμμα: shap_cri_xgboost_critical.png

ΣΥΓΚΡΙΤΙΚΟΣ ΠΙΝΑΚΑΣ ΑΠΟΔΟΣΗΣ ΜΟΝΤΕΛΩΝ CRI (Macro-F1 Score, n=10000)

Baseline (LogReg)	Holdout: 0.551 CV Mean: 0.545 (±0.008)
Random Forest	Holdout: 0.535 CV Mean: 0.532 (±0.010)
XGBoost	Holdout: 0.526 CV Mean: 0.533 (±0.011)

🎉 Η διαδικασία ολοκληρώθηκε! Τα μοντέλα βελτιστοποιήθηκαν για n=10000 και τα SHAP γραφήματα αποθηκεύτηκαν.

Δημιουργία συνθετικού dataset βάσει CRI Παραρτήματος ΣΤ' (n=20000 οντότητες)...

Κατανομή Κλάσεων Ανθεκτικότητας (CRI Quartiles):

```
resilience_class
Μη κρίσιμο          5000
Χαμηλή ανθεκτικότητα 5000
Κρίσιμο             5000
Πολύ κρίσιμο        5000
Name: count, dtype: int64
```

=====

HYPERPARAMETER TUNING & ΜΟΝΤΕΛΟΠΟΙΗΣΗ CRI (n=20000)

=====

[1/3] Εκπαίδευση Baseline (Logistic Regression)...

=====

Logistic Regression Baseline - Hold-out Evaluation

=====

	precision	recall	f1-score	support
Κρίσιμο	0.42	0.31	0.35	1250
Μη κρίσιμο	0.59	0.70	0.64	1250
Πολύ κρίσιμο	0.67	0.76	0.71	1250
Χαμηλή ανθεκτικότητα	0.43	0.40	0.41	1250
accuracy			0.54	5000
macro avg	0.53	0.54	0.53	5000
weighted avg	0.53	0.54	0.53	5000

Macro-F1 Score: 0.531

-> Εκτέλεση τελικού 5-Fold CV για Baseline...

[2/3] Hyperparameter Tuning για Random Forest...

✨ Βέλτιστες Παράμετροι RF: {'n_estimators': 500, 'min_samples_split': 4, 'min_samples_leaf': 4, 'max_features': 'sqrt', 'max_depth': 20}

=====

Random Forest - Hold-out Evaluation

=====

	precision	recall	f1-score	support
Κρίσιμο	0.40	0.28	0.33	1250
Μη κρίσιμο	0.58	0.70	0.64	1250
Πολύ κρίσιμο	0.66	0.74	0.70	1250
Χαμηλή ανθεκτικότητα	0.42	0.41	0.41	1250
accuracy			0.53	5000
macro avg	0.52	0.53	0.52	5000
weighted avg	0.52	0.53	0.52	5000

Macro-F1 Score: 0.520

Υπολογισμός ερμηνευσιμότητας SHAP για το μοντέλο Random Forest...

✓ Αποθηκεύτηκε το διάγραμμα: shap_cri_random_forest_bar.png

✓ Αποθηκεύτηκε το διάγραμμα: shap_cri_random_forest_critical.png

[3/3] Hyperparameter Tuning για XGBoost...

✨ Βέλτιστες Παράμετροι XGBoost: {'subsample': 0.85, 'reg_lambda': 2.0, 'reg_alpha': 0.0, 'n_estimators': 300, 'min_child_weight': 3, 'max_depth': 5, 'learning_rate': 0.03, 'colsample_bytree': 0.8}

=====

XGBoost - Hold-out Evaluation

	precision	recall	f1-score	support
Κρίσιμο	0.40	0.28	0.33	1250
Μη κρίσιμο	0.59	0.72	0.65	1250
Πολύ κρίσιμο	0.67	0.75	0.70	1250
Χαμηλή ανθεκτικότητα	0.41	0.39	0.40	1250
accuracy			0.53	5000
macro avg	0.52	0.53	0.52	5000
weighted avg	0.52	0.53	0.52	5000

Macro-F1 Score: 0.521

-> Εκτέλεση τελικού 5-Fold CV για το βέλτιστο XGBoost...

Υπολογισμός ερμηνευσιμότητας SHAP για το μοντέλο XGBoost...



Αποθηκεύτηκε το διάγραμμα: shap_cri_xgboost_bar.png



Αποθηκεύτηκε το διάγραμμα: shap_cri_xgboost_critical.png

ΣΥΓΚΡΙΤΙΚΟΣ ΠΙΝΑΚΑΣ ΑΠΟΔΟΣΗΣ ΜΟΝΤΕΛΩΝ CRI (Macro-F1 Score, n=20000)

Baseline (LogReg)	Holdout: 0.531 CV Mean: 0.538 (±0.007)
Random Forest	Holdout: 0.520 CV Mean: 0.525 (±0.007)
XGBoost	Holdout: 0.521 CV Mean: 0.529 (±0.008)

🎉 Η διαδικασία ολοκληρώθηκε! Τα μοντέλα βελτιστοποιήθηκαν για n=20000 και τα SHAP γραφήματα αποθηκεύτηκαν.

Δημιουργία συνθετικού dataset βάσει CRI Παραρτήματος ΣΤ' (n=40000 οντότητες)...

Κατανομή Κλάσεων Ανθεκτικότητας (CRI Quartiles):

```
resilience_class
Μη κρίσιμο          10000
Χαμηλή ανθεκτικότητα 10000
Κρίσιμο             10000
Πολύ κρίσιμο        10000
Name: count, dtype: int64
```

=====

HYPERPARAMETER TUNING & ΜΟΝΤΕΛΟΠΟΙΗΣΗ CRI (n=40000)

=====

[1/3] Εκπαίδευση Baseline (Logistic Regression)...

=====

Logistic Regression Baseline - Hold-out Evaluation

=====

	precision	recall	f1-score	support
Κρίσιμο	0.44	0.35	0.39	2500
Μη κρίσιμο	0.61	0.73	0.66	2500
Πολύ κρίσιμο	0.69	0.77	0.73	2500
Χαμηλή ανθεκτικότητα	0.43	0.37	0.40	2500
accuracy			0.56	10000
macro avg	0.54	0.56	0.54	10000
weighted avg	0.54	0.56	0.54	10000

Macro-F1 Score: 0.544

-> Εκτέλεση τελικού 5-Fold CV για Baseline...

[2/3] Hyperparameter Tuning για Random Forest...

✱ Βέλτιστες Παράμετροι RF: {'n_estimators': 500, 'min_samples_split': 4, 'min_samples_leaf': 4, 'max_features': 'sqrt', 'max_depth': 20}

=====

Random Forest - Hold-out Evaluation

=====

	precision	recall	f1-score	support
Κρίσιμο	0.43	0.34	0.38	2500
Μη κρίσιμο	0.60	0.71	0.65	2500
Πολύ κρίσιμο	0.68	0.76	0.72	2500
Χαμηλή ανθεκτικότητα	0.41	0.37	0.39	2500
accuracy			0.55	10000
macro avg	0.53	0.55	0.53	10000
weighted avg	0.53	0.55	0.53	10000

Macro-F1 Score: 0.534

Υπολογισμός ερμηνευσιμότητας SHAP για το μοντέλο Random Forest...

✓ Αποθηκεύτηκε το διάγραμμα: shap_cri_random_forest_bar.png

✓ Αποθηκεύτηκε το διάγραμμα: shap_cri_random_forest_critical.png

[3/3] Hyperparameter Tuning για XGBoost...

✱ Βέλτιστες Παράμετροι XGBoost: {'subsample': 0.85, 'reg_lambda': 2.0, 'reg_alpha': 0.0, 'n_estimators': 300, 'min_child_weight': 3, 'max_depth': 5, 'learning_rate': 0.03, 'colsample_bytree': 0.8}

=====

XGBoost - Hold-out Evaluation

	precision	recall	f1-score	support
Κρίσιμο	0.44	0.34	0.38	2500
Μη κρίσιμο	0.60	0.73	0.66	2500
Πολύ κρίσιμο	0.67	0.76	0.71	2500
Χαμηλή ανθεκτικότητα	0.42	0.38	0.40	2500
accuracy			0.55	10000
macro avg	0.53	0.55	0.54	10000
weighted avg	0.53	0.55	0.54	10000

Macro-F1 Score: 0.538

-> Εκτέλεση τελικού 5-Fold CV για το βέλτιστο XGBoost...

Υπολογισμός ερμηνευσιμότητας SHAP για το μοντέλο XGBoost...



Αποθηκεύτηκε το διάγραμμα: shap_cri_xgboost_bar.png



Αποθηκεύτηκε το διάγραμμα: shap_cri_xgboost_critical.png

ΣΥΓΚΡΙΤΙΚΟΣ ΠΙΝΑΚΑΣ ΑΠΟΔΟΣΗΣ ΜΟΝΤΕΛΩΝ CRI (Macro-F1 Score, n=40000)

Baseline (LogReg)	Holdout: 0.544	CV Mean: 0.545 (±0.001)
Random Forest	Holdout: 0.534	CV Mean: 0.532 (±0.003)
XGBoost	Holdout: 0.538	CV Mean: 0.537 (±0.004)

🎉 Η διαδικασία ολοκληρώθηκε! Τα μοντέλα βελτιστοποιήθηκαν για n=40000 και τα SHAP γραφήματα αποθηκεύτηκαν.