



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

Βελτίωση της ενεργειακής απόδοσης κτηρίων
με χρήση τεχνικών διαρκούς μάθησης και
επεξηγήσιμης τεχνητής νοημοσύνης

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΠΑΝΑΓΙΩΤΑ ΡΕΜΠΗ

Επιβλέπων: Δημήτριος Ασκούνης
Καθηγητής Ε.Μ.Π.

ΕΡΓΑΣΤΗΡΙΟ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ ΚΑΙ ΔΙΟΙΚΗΣΗΣ

Αθήνα, Οκτώβριος 2024



Εθνικό Μετσόβιο Πολυτεχνείο

Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών

Τομέας Ηλεκτρικών Βιομηχανικών Διατάξεων και Συστημάτων Αποφάσεων

Εργαστήριο Συστημάτων Αποφάσεων και Διοίκησης

Βελτίωση της ενεργειακής απόδοσης κτηρίων
με χρήση τεχνικών διαρκούς μάθησης και
επεξηγήσιμης τεχνητής νοημοσύνης

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΠΑΝΑΓΙΩΤΑ ΡΕΜΠΗ

Επιβλέπων: Δημήτριος Ασκούνης

Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 15η Οκτωβρίου 2024.

(Υπογραφή)

(Υπογραφή)

(Υπογραφή)

.....
Δημήτριος Ασκούνης
Καθηγητής Ε.Μ.Π.

.....
Ιωάννης Ψαρράς
Καθηγητής Ε.Μ.Π.

.....
Ευάγγελος Μαρινάκης
Επίκουρος Καθηγητής Ε.Μ.Π.

Αθήνα, Οκτώβριος 2024

(Υπογραφή)

.....
ΠΑΝΑΓΙΩΤΑ ΡΕΜΠΗ

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

Copyright ©–All rights reserved Παναγιώτα Ρεμπή, 2024.

Με επιφύλαξη παντός δικαιώματος.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

Περίληψη

Με την αυξανόμενη ενεργειακή ζήτηση και τις επιπτώσεις της κλιματικής αλλαγής να εντείνονται διαρκώς, η ανάγκη εξοικονόμησης ενέργειας βρίσκεται στο επίκεντρο των προκλήσεων που αντιμετωπίζει η σύγχρονη κοινωνία. Ο κτηριακός τομέας, ιδίως τα κτήρια κατοικιών, ευθύνεται για σημαντικό ποσοστό της ενεργειακής κατανάλωσης, καθιστώντας την ενεργειακή αποδοτικότητα έναν από τους πρωταρχικούς στόχους των διεθνών στρατηγικών. Συνεπώς η ενεργειακή αναβάθμιση κτηρίων αποτελεί σημαντικό βήμα προς την επίτευξη ενός πιο βιώσιμου μέλλοντος με πολλαπλά οφέλη. Στο πλαίσιο αυτό, η παρούσα διπλωματική εργασία εστιάζει στην βελτίωση της ενεργειακής απόδοσης κτηρίων κατοικίας και συγκεκριμένα στην πρόβλεψη των απαιτούμενων μέτρων ενεργειακής αναβάθμισης. Ανταπτύσσεται μοντέλο μηχανικής μάθησης, στο οποίο ο/η χρήστης/ρια εισάγει ορισμένα γνωστά σε εκείνον/η χαρακτηριστικά του σπιτιού του και λαμβάνει τις κατάλληλες επιλογές ανακαίνισης προκειμένου να επιτύχει υψηλότερη ενεργειακή κλάση. Η ενδελεχής ανάλυση του αρχικού συνόλου δεδομένων με προέλευση την Λετονία αναδεικνύει την ύπαρξη ανισορροπίας μεταξύ των κλάσεων, στο πλαίσιο αντιμετώπισης της οποίας υιοθετούνται τεχνικές παραγωγής συνθετικών δεδομένων. Επιπλέον, η ενσωμάτωση της επεξηγήσιμης τεχνητής νοημοσύνης ενισχύει την διαφάνεια και την αξιοπιστία του μοντέλου, ενώ παράλληλα συμβάλλει στην πληρέστερη κατανόηση της επίδρασης των χαρακτηριστικών στην ενεργειακή απόδοση. Με σκοπό τη γενίκευση της εφαρμογής, η μελέτη επεκτείνεται σε επιπρόσθετα πραγματικά δεδομένα προερχόμενα από διαφορετικές χώρες με την εφαρμογή στρατηγικών διαρκούς μάθησης. Έτσι, το μοντέλο μπορεί να εκπαιδεύεται διαδοχικά σε διαφορετικά σύνολα δεδομένων, ενισχύοντας την απόκτηση γνώσης από νέα δείγματα και διατηρώντας συγχρόνως την ήδη υπάρχουσα. Προάγεται, λοιπόν, η δημιουργία ενός γενικευμένου μοντέλου με δυνατότητες προσαρμογής ανεξαρτήτως της γεωγραφικής περιοχής και των ιδιαίτερων χαρακτηριστικών των κτηρίων. Καταληκτικά, τα αποτελέσματα υπογραμμίζουν την ανάγκη για επαρκή και ποιοτικά δεδομένα. Η προτεινόμενη μελέτη μπορεί να συνεισφέρει στην επίτευξη των περιβαλλοντικών και οικονομικών στόχων, διευκολύνοντας τους ενδιαφερόμενους να λάβουν τεκμηριωμένες αποφάσεις ενεργειακής αναβάθμισης.

Λέξεις Κλειδιά

Ενεργειακή απόδοση, Ενεργειακή αναβάθμιση κτηρίων, Επεξηγήσιμη τεχνητή νοημοσύνη, Μηχανική μάθηση, Βαθιά μάθηση, Παραγωγή δεδομένων, Διαρκής μάθηση, Διερευνητική ανάλυση δεδομένων

Abstract

With the growing energy demand and the intensifying effects of climate change, the need to save energy is at the forefront of the challenges that modern society is facing. The building sector, particularly residential buildings, accounts for a significant proportion of energy consumption, making energy efficiency of buildings one of the primary goals of European and international strategies. Consequently, energy upgrades of buildings are a critical step towards a more sustainable future, offering multiple benefits at both individual and collective level. This thesis focuses on the optimization of the energy efficiency of residential buildings and specifically on the prediction of the required energy retrofitting measures. A machine learning model is developed, where the user inputs certain known basic characteristics of their home and receives suitable renovation options to achieve a higher energy class. A thorough analysis of the initial dataset, sourced from Latvia, highlights the existence of class imbalances, for which data generation techniques are adopted. Furthermore, the integration of explainable artificial intelligence enhances the transparency and reliability of the model and also contributes to a deeper understanding of how different features impact on energy efficiency. Aiming to expand its worldwide impact, the study is extended to additional real-world data from various countries by applying lifelong learning strategies. In this way, the model can be sequentially trained on different datasets, gaining knowledge from new samples while retaining the previously acquired knowledge. This promotes the creation of a generalized model with adaptive capabilities, regardless of the geographical region and the specific characteristics of each building. Finally, the results underscore the need for adequate and high-quality data. The proposed study can contribute to achieving environmental and economic objectives by enabling stakeholders to make informed decisions regarding building energy retrofitting.

Keywords

Energy efficiency, Building energy retrofitting, Explainable artificial intelligence, Machine learning, Deep learning, Data generation, Lifelong learning, Exploratory data analysis

Ευχαριστίες

Με την ολοκλήρωση αυτής της διπλωματικής εργασίας θα ήθελα να ευχαριστήσω τον καθηγητή κύριο Δημήτριο Ασκούνη για την εμπιστοσύνη και την ευκαιρία που μου έδωσε. Ιδιαίτερα θα ήθελα να ευχαριστήσω τους υποψήφιους διδάκτορες Σωτήρη Πελέκη και Αλέξανδρο Τζώρτζη για την διαρκή και πολύτιμη καθοδήγηση και υποστήριξή τους. Οι ιδέες, οι συμβουλές και η γενικότερη συνεισφορά τους ήταν καθοριστικής σημασίας και αισθάνομαι ευγνώμων και τυχερή για αυτήν την συνεργασία. Τέλος, θα ήθελα να ευχαριστήσω τους κοντινούς μου ανθρώπους για την συνεχή στήριξη και την κατανόησή τους.

Περιεχόμενα

Περίληψη	1
Abstract	3
Ευχαριστίες	5
Περιεχόμενα	8
Κατάλογος Σχημάτων	10
Κατάλογος Πινάκων	11
1 Εισαγωγή	13
1.1 Γενικό πλαίσιο	13
1.2 Αντικείμενο της διπλωματικής	15
1.3 Οργάνωση του τόμου	15
2 Βιβλιογραφική ανασκόπηση και συμβολή	17
2.1 Βιβλιογραφική ανασκόπηση	17
2.1.1 Ενεργειακές προσομοιώσεις	17
2.1.2 Ομαδοποίηση και σύγκριση	18
2.1.3 Πολυκριτήρια ανάλυση	18
2.1.4 Μηχανική μάθηση	18
2.2 Ανασκόπηση συνόλων δεδομένων	20
2.3 Συμβολή της εργασίας σε σχέση με την υπάρχουσα έρευνα	23
3 Διερευνητική ανάλυση δεδομένων	25
3.1 Περιγραφή συνόλου δεδομένων	25
3.2 Προεπεξεργασία δεδομένων	27
3.3 Ανάλυση δεδομένων	29
3.3.1 Γραφική απεικόνιση χαρακτηριστικών	29
3.3.2 Συσχέτιση χαρακτηριστικών	35
3.4 Σύνοψη ιδιαιτεροτήτων του συνόλου δεδομένων	43

4	Ανάλυση επεξηγησιμότητας (explainability)	45
4.1	Επεξηγήσιμη τεχνητή νοημοσύνη	45
4.2	Shapley additive explanations	46
4.3	Εφαρμογή μεθόδου	48
4.4	Καθολικές επεξηγήσεις	49
4.5	Τοπικές επεξηγήσεις	53
4.6	Προσθήκη νέου χαρακτηριστικού	54
5	Μεθοδολογία κύριου πειράματος	57
5.1	Υλοποίηση μοντέλου	57
5.1.1	Επιλογή μοντέλου	57
5.1.2	Εκπαίδευση μοντέλου	59
5.1.3	Βελτιστοποίηση υπερπαραμέτρων	60
5.1.4	Αξιολόγηση μοντέλου	61
5.2	Παραγωγή συνθετικών δεδομένων	63
5.2.1	Τεχνικές παραγωγής δεδομένων	63
5.2.2	Υλοποίηση παραγωγής δεδομένων	67
5.2.3	Αξιολόγηση συνθετικών δεδομένων	68
5.3	Διαρκής μάθηση (Lifelong learning)	69
5.3.1	Γενική περιγραφή	69
5.3.2	Υλοποίηση με επέκταση σε άλλα σύνολα δεδομένων	76
6	Αποτελέσματα	79
6.1	Αποτελέσματα αξιολόγησης συνθετικών δεδομένων	79
6.2	Αποτελέσματα αρχικών και συνθετικών δεδομένων	80
6.3	Αποτελέσματα συνόλων δεδομένων άλλων χωρών	81
6.4	Αποτελέσματα τεχνικών διαρκούς μάθησης	82
7	Συμπεράσματα και μελλοντικές επεκτάσεις	87
7.1	Σύνοψη και συμπεράσματα	87
7.2	Μελλοντικές επεκτάσεις	90
	Βιβλιογραφία	91

Κατάλογος Σχημάτων

1.1	Στατιστικά residential και non-residential κτηρίων	14
3.1	Γράφημα χαρακτηριστικού Region	30
3.2	Γράφημα χαρακτηριστικών Initial energy class, Energy class after	30
3.3	Γραφήματα διακριτών χαρακτηριστικών	31
3.4	Γραφήματα μέτρων ενεργειακής αναβάθμισης	32
3.5	Γραφήματα αριθμητικών χαρακτηριστικών	33
3.6	Κατανομές Energy consumption before, Heat energy consumption before . .	34
3.7	Heatmap συσχέτισης χαρακτηριστικών	36
3.8	Πίνακας συχνοτήτων αρχικών και τελικών ενεργειακών κλάσεων	37
3.9	Πίνακας συχνοτήτων συνδυασμών ενεργειακών κλάσεων και μέτρων αναβάθμισης	38
3.10	Heatmap Cramer's V συσχετίσεων των energy resources χαρακτηριστικών . .	39
3.11	Κατανομές χαρακτηριστικών energy resources συνδυαστικά με energy factors	40
3.12	Heatmap συσχετίσεων των energy resources με τα energy factors	41
3.13	Heatmap συσχετίσεων χαρακτηριστικών της περιοχής	42
3.14	Γράφημα Underground floor υπό συνθήκη County/City	42
4.1	Μέθοδος SHAP	46
4.2	Υπολογισμός SHAP: prediction = base value + sum(SHAP values)	47
4.3	Summary plots ανά κλάση με τα αρχικά χαρακτηριστικά	50
4.4	Summary plots ανά κλάση εξαιρουμένων των χαρακτηριστικών τοποθεσίας . .	51
4.5	Dependence plot του Initial year of exploitation για την κλάση Reconstruc- tion of engineering systems	52
4.6	Waterfall plots τυχαίου δείγματος ανά κλάση	53
5.1	Παράδειγμα δομής MLP	58
5.2	Λειτουργία νευρώνα	58
5.3	Δομή πίνακα σύγχυσης (confusion matrix)	62
5.4	Αρχιτεκτονική GAN και CGAN	66
5.5	Γραφική αναπαράσταση πιθανών εκβάσεων διαρκούς μάθησης	71
5.6	Στρατηγική elastic weight consolidation (EWC)	74
6.1	Γράφημα αποτελεσμάτων αρχικών και συνθετικών δεδομένων	80

6.2	Γράφημα αποτελεσμάτων μεμονωμένης εκπαίδευσης συνόλων δεδομένων	82
6.3	Γράφημα μετρικής precision για κάθε σύνολο δεδομένων για κάθε στρατηγική	85

Κατάλογος Πινάκων

2.1	Ανασκόπηση συνόλων δεδομένων και αντίστοιχων δημοσιεύσεων	23
3.1	Τα χαρακτηριστικά του συνόλου δεδομένων της Λετονίας	27
3.2	Στατιστικά στοιχεία για τα χαρακτηριστικά με ακραίες τιμές	29
4.1	Περιγραφή αρχικά επιλεγμένων χαρακτηριστικών	48
4.2	Πίνακας προσδιορισμού ενεργειακής κλάσης κτηρίου στην Λετονία	55
5.1	Πίνακας υπερπαραμέτρων με εύρος τιμών που χρησιμοποιείται από την Optuna	61
5.2	Κοινά χαρακτηριστικά συνόλων δεδομένων Λετονίας, Ιταλίας, Αγγλίας	77
6.1	Αξιολόγηση συνθετικών δεδομένων	79
6.2	Αποτελέσματα μοντέλου στα αρχικά και τα συνθετικά δεδομένα	80
6.3	Αποτελέσματα μεμονωμένης εκπαίδευσης μοντέλου στα δεδομένα της Αγγλίας και Ιταλίας	81
6.4	Αποτελέσματα εκπαίδευσης μοντέλου στα δεδομένα της Λετονίας για 3 κλάσεις	82
6.5	Αποτελέσματα στρατηγικών διαρκούς μάθησης στα δεδομένα Αγγλίας, Ιταλίας, Λετονίας υπολογισμένα μετά το τέλος όλων των στάδιων εκπαίδευσης	83

Κεφάλαιο 1

Εισαγωγή


1.1 Γενικό πλαίσιο

Μία από τις σημαντικότερες προκλήσεις που καλείται να αντιμετωπίσει η σύγχρονη κοινωνία αφορά την εξοικονόμηση ενέργειας, η οποία συνδέεται άρρηκτα με την προστασία του περιβάλλοντος και την βιώσιμη ανάπτυξη. Αναπόφευκτη είναι σήμερα η συνεχής αύξηση της ζήτησης ενέργειας ως απόρροια της αστικής, βιομηχανικής και τεχνολογικής εξέλιξης. Όμως, καθώς οι ενεργειακοί πόροι ελαττώνονται και οι επιπτώσεις της κλιματικής αλλαγής γίνονται ολοένα και πιο εμφανείς, η ανάγκη για περιορισμό της ενεργειακής κατανάλωσης κρίνεται επιτακτική. Παράλληλα με αυτήν έχει τεθεί ως διεθνής στόχος η ελαχιστοποίηση των εκπομπών αερίων του θερμοκηπίου, με γνώμονα τον οποίο δρουν οργανισμοί και κυβερνήσεις ορίζοντας αντίστοιχους κανονισμούς και στρατηγικές. Για παράδειγμα, η συμφωνία του Παρισιού περιλαμβάνει ένα παγκόσμιο σχέδιο δράσης ώστε να διατηρηθεί η υπερθέρμανση του πλανήτη αρκετά κάτω από τους 2°C άνω των προβιομηχανικών επιπέδων και να συνεχιστούν οι προσπάθειες για τον περιορισμό της στους $1,5^{\circ}\text{C}$ [1].

Σύμφωνα με επίσημα στατιστικά στοιχεία [2], περίπου το 40% της συνολικής κατανάλωσης ενέργειας και περισσότερο από το $1/3$ των εκπομπών αερίων του θερμοκηπίου στην Ευρωπαϊκή Ένωση προέρχονται από τα κτήρια. Μάλιστα το 85% των κτηρίων χτίστηκαν πριν το 2000 και το 75% αυτών παρουσιάζουν χαμηλή ενεργειακή απόδοση. Έτσι, τα κτήρια αποτελούν μία από τις προτεραιότητες της ενεργειακής και κλιματικής πολιτικής τόσο σε ευρωπαϊκό όσο και σε παγκόσμιο επίπεδο. Η ΕΕ έχει θεσπίσει το νομοθετικό πλαίσιο Energy Performance of Buildings Directive, το οποίο μεταξύ άλλων συνεισφέρει στην επίτευξη του στόχου της μείωσης των εκπομπών του κτηριακού τομέα κατά 60% έως το 2030 (συγκριτικά με το 2015) και την μετατροπή όλων των κτηρίων σε κτήρια μηδενικών εκπομπών έως το 2050.

Επιπρόσθετα, όπως φαίνεται στο Σχήμα 1.1 το μεγαλύτερο ποσοστό των κτηρίων όλων των χωρών της ΕΕ είναι κτήρια κατοικιών, τα οποία καταναλώνουν την περισσότερη ενέργεια και εκπέμπουν τα περισσότερα αέρια σε σχέση με εκείνα που εξυπηρετούν διαφορετικούς σκοπούς. Πολλές λειτουργίες εντός των σπιτιών απαιτούν αυξημένα ποσά ενέργειας, με το 80% περίπου αυτής να χρησιμοποιείται για θέρμανση, ψύξη και ζεστό νερό [2]. Συνεπώς ο κτηριακός τομέας χρήζει άμεσης ανάγκης μετασχηματισμού προκειμένου να πραγματοποιηθούν οι ενεργειακοί

και περιβαλλοντικοί στόχοι.



Σχήμα 1.1: Στατιστικά residential και non-residential κτηρίων ¹

Στο πλαίσιο αυτό η έρευνα προσανατολίζεται στην ενεργειακή αποδοτικότητα των κτηρίων κατοικιών, η οποία αφορά την μείωση της χρησιμοποιούμενης ενέργειας για την εκτέλεση των ίδιων λειτουργιών. Αυτό μπορεί να κατορθωθεί μέσω διαφορετικών τεχνολογιών και πρακτικών που ελαττώνουν την κατανάλωση ενέργειας διατηρώντας παράλληλα την άνεση και την λειτουργικότητα των κτηρίων για τους ενοίκους τους. Εκτός από την κατασκευή νέων κτηρίων με βάση τα σύγχρονα περιβαλλοντικά πρότυπα, τα στοιχεία που προαναφέρθηκαν αναδεικνύουν τον καθοριστικό ρόλο που διαδραματίζει και η αναβάθμιση των υφιστάμενων κτηρίων. Η υλοποίηση μέτρων ενεργειακής εξοικονόμησης, όπως η βελτίωση της μόνωσης, η αντικατάσταση παλιών συστημάτων με νέα, η ενσωμάτωση ανανεώσιμων πηγών ενέργειας κ.ά., μπορεί να αποδειχθεί ιδιαίτερα προσοδοφόρα.

Οι επενδύσεις για βελτιστοποίηση της ενεργειακής απόδοσης ελαχιστοποιούν την απαιτούμενη κατανάλωση ενέργειας, άρα και το περιβαλλοντικό αποτύπωμα των κτηρίων μετριάζοντας έτσι την επέκταση της κλιματικής αλλαγής. Αποφέρουν ακόμη και οικονομικά οφέλη μακροπρόθεσμα, καθώς μειώνουν το κόστος διατήρησης όπως και τους λογαριασμούς ενέργειας. Η αξία των ακινήτων, από την άλλη, αυξάνεται αναλόγως. Συμπληρωματικά, δεν πρέπει να παραλειφθεί η βελτίωση της ποιότητας ζωής των κατοίκων και η συμβολή των καλύτερων συνθηκών διαβίωσης στην υγεία και την ευεξία τους.

Ωστόσο, οι αποφάσεις που στοχεύουν στην ενεργειακή αναβάθμιση απαιτούν προσεκτικό σχεδιασμό και μελέτη. Ενέχουν ρίσκο αφού ενδέχεται τα επιλεγμένα μέτρα να μην επιφέρουν πράγματι την εξοικονόμηση ενέργειας και το μελλοντικό κέρδος που αναμένεται. Κατά συ-

¹Πηγή: [3]

νέπεια χρειάζεται συνεκτίμηση πολλαπλών παραγόντων από ειδικούς, το οποίο μπορεί να περιορίσει την διαδικασία και να οδηγήσει σε καθυστερήσεις. Είναι αναγκαία καταληκτικά η δυνατότητα πρόβλεψης των βέλτιστων επιλογών και η εκτίμηση των επικείμενων ωφελειών τους προτού αυτές υλοποιηθούν.

1.2 Αντικείμενο της διπλωματικής

Δεδομένου ότι ένας από τους πρωταρχικούς τομείς για την επίτευξη εξοικονόμησης ενέργειας είναι τα κτήρια κατοικιών, η παρούσα διπλωματική εστιάζει στην βελτιστοποίηση της ενεργειακής απόδοσής τους. Κύριο αντικείμενο μελέτης αποτελεί η πρόβλεψη των απαιτούμενων μέτρων ενεργειακής αναβάθμισης ενός σπιτιού προκειμένου να βελτιωθεί η ενεργειακή του κλάση. Με σημείο εκκίνησης ένα σύνολο δεδομένων για κτήρια κατοικιών της Λετονίας, εκπαιδεύεται ένα μοντέλο μηχανικής μάθησης με δοθέντα χαρακτηριστικά που αφορούν την δομή και την ενεργειακή κατανάλωση του κτηρίου, τα οποία είναι γνωστά στον ιδιοκτήτη του. Προτείνει έπειτα την αναγκαία μορφή ανακαίνισης στην οποία πρέπει να προβεί ώστε η κατοικία να μεταβεί στο επιθυμητό επίπεδο ενεργειακής αποδοτικότητας. Ύστερα από ενδελεχή ανάλυση των δεδομένων οδηγούμαστε στις κατάλληλες επιλογές υλοποίησης αλλά και στους τρόπους αντιμετώπισης των ιδιαιτεροτήτων που παρουσιάζει το συγκεκριμένο σύνολο. Στην διαδικασία αυτή συνεισφέρει και η μελέτη με την βοήθεια της επεξηγήσιμης τεχνητής νοημοσύνης και ειδικότερα της μεθόδου Shapley additive explanations. Συγκεκριμένα, παρέχονται επεξηγήσεις σχετικά με το πως το μοντέλο κατέληξε στην εκάστοτε πρόβλεψη και ποια χαρακτηριστικά των δεδομένων συνέβαλαν στον μεγαλύτερο βαθμό. Για τον εμπλουτισμό του υπάρχοντος συνόλου δεδομένων και την ενίσχυση των δυνατοτήτων του μοντέλου παράγονται νέα δεδομένα με την εφαρμογή κατάλληλης τεχνικής για παραγωγή συνθετικών δεδομένων. Επιπροσθέτως, με σκοπό τη γενίκευση της προσέγγισης μας, επεκτείνουμε το μοντέλο και σε άλλα σύνολα αντίστοιχων δεδομένων, προερχόμενα από την Ιταλία και την Αγγλία, υιοθετώντας ποικίλες στρατηγικές διαρκούς μάθησης και μελετώντας την επίδρασή τους. Ο στόχος αυτών είναι εκπαιδεύοντας το μοντέλο διαδοχικά στα διάφορα σύνολα δεδομένων να συσσωρεύονται πληροφορίες, ώστε να διευκολυνθεί η απόκτηση νέας γνώσης για τα μελλοντικά δεδομένα αλλά ταυτόχρονα να διατηρηθεί η ήδη υπάρχουσα γνώση από τα προηγούμενα. Κατ' αυτόν τον τρόπο μελετάται η δημιουργία ενός ενιαίου μοντέλου με δυνατότητα γενίκευσης που θα αποδίδει καλά σε δεδομένα ανεξαρτήτως της χώρας προέλευσης και θα βελτιώνεται συνεχώς.

1.3 Οργάνωση του τόμου

Η παρούσα διπλωματική εργασία διαρθρώνεται σε 7 κεφάλαια. Το εισαγωγικό Κεφάλαιο 1 ακολουθεί το Κεφάλαιο 2, το οποίο περιλαμβάνει την βιβλιογραφική ανασκόπηση περί του θέματος και εστιάζει στη συμβολή της συγκεκριμένης εργασίας. Στο Κεφάλαιο 3 πραγματοποιείται η διερευνητική ανάλυση του αρχικού συνόλου δεδομένων που χρησιμοποιήθηκε, ενώ ακολουθεί το Κεφάλαιο 4 το οποίο αφορά την ανάλυση της επεξηγησιμότητας των δεδο-

μένων και των προβλέψεων. Στην συνέχεια, στο Κεφάλαιο 5 περιγράφεται η μεθοδολογία των κύριων πειραμάτων, το πρώτο μέρος της οποίας προσδιορίζει την υλοποίηση του μοντέλου. Το δεύτερο μέρος του κεφαλαίου αναφέρεται στην παραγωγή συνθετικών δεδομένων και το τρίτο και τελευταίο στην διαρκή μάθηση. Αναλύονται οι γενικές αρχές και τεχνικές τους θεωρητικά, αλλά και η υλοποίηση που επιλέχτηκε. Καταλήγοντας, το Κεφάλαιο 6 παραθέτει τα αποτελέσματα των πειραμάτων, ενώ το Κεφάλαιο 7 αποτελείται από τα συμπεράσματα και τις μελλοντικές επεκτάσεις της διπλωματικής εργασίας.

Κεφάλαιο 2

Βιβλιογραφική ανασκόπηση και συμβολή

2.1 Βιβλιογραφική ανασκόπηση

2.1.1 Ενεργειακές προσομοιώσεις

Η βελτιστοποίηση της ενεργειακής αποδοτικότητας των κτηρίων και ειδικά των κτηρίων κατοικιών έχει μελετηθεί από διάφορες οπτικές και με ποικίλες μεθόδους. Όσον αφορά στην επιλογή των κατάλληλων μέτρων ενεργειακής αναβάθμισης, μία από τις πρώτες και βασικές προσεγγίσεις που έχουν προταθεί είναι η χρήση ενεργειακών προσομοιώσεων. Συγκεκριμένα, με κατάλληλο λογισμικό μοντελοποίησης κτηρίων ποσοτικοποιείται και υπολογίζεται η ενεργειακή απόδοση του κτηρίου και μέσω πολλαπλών δοκιμών με διαφορετικές παραμέτρους μπορούν να αξιολογηθούν οι αλλαγές με σύγκριση των αποτελεσμάτων. Ένα από τα πιο διαδεδομένα εργαλεία για αυτή την χρήση είναι το EnergyPlus, το οποίο χρησιμοποιούν για παράδειγμα οι συγγραφείς του [4] συνδυαστικά με άλλα μοντέλα, ώστε να αξιολογήσουν πιθανά σενάρια αναβάθμισης ως προς τον ενεργειακό, τον περιβαλλοντικό και τον οικονομικό τομέα. Με παρόμοια λογική αναπτύσσονται υπολογιστικά στατιστικά μοντέλα, τα οποία μέσω συγκεκριμένων φυσικών εξισώσεων και παραμέτρων, υπολογίζουν την εξοικονόμηση ενέργειας που επιφέρουν διαφορετικοί συνδυασμοί μέτρων στα κτήρια με βάση τα χαρακτηριστικά τους. Έτσι οδηγούνται σε συμπεράσματα σχετικά με την αποτελεσματικότητα της κάθε επιλογής και διευκολύνουν την λήψη αποφάσεων [5, 6, 7]. Παρά την αξιοπιστία και την διαφάνεια της εσωτερικής λειτουργίας της μεθόδου, ο υπολογιστικός φόρτος καθίσταται συχνά έως και απαγορευτικός. Το μεγάλο πλήθος των απαιτούμενων παραμέτρων εισόδου αποτελεί έναν ακόμη περιορισμό, καθώς αναλυτικές πληροφορίες, όπως λεπτομέρειες κατασκευής, θερμοκοί συντελεστές κλπ, δεν είναι συχνά γνώστες στον χρήστη ιδίως εάν αφορούν παλαιότερα κτήρια [8].

2.1.2 Ομαδοποίηση και σύγκριση

Στην βιβλιογραφία συναντώνται επίσης αρκετά συχνά οι αλγόριθμοι ομαδοποίησης, οι οποίοι μάλιστα μπορούν να χαρακτηριστούν ως μία από τις αρχικές μορφές ενσωμάτωσης τεχνικών μηχανικής μάθησης στο συγκεκριμένο πρόβλημα. Ιδιαίτερα σε περιπτώσεις που δεν υπάρχουν διαθέσιμα δεδομένα μετά την εφαρμογή των μέτρων, συνηθίζεται η συσταδοποίηση των δειγμάτων με βάση συγκεκριμένα κοινά χαρακτηριστικά τους και έπειτα η σύγκριση ενός κτηρίου με τα παρόμοιά του (benchmarking) [8, 9]. Το [10] προτείνει μια γενικευμένη μέθοδο όπου αναλύει μία βάση δεδομένων ενεργειακών πιστοποιητικών κτηρίων ως προς τα πιο σημαντικά χαρακτηριστικά της, ώστε να καθοριστούν ποια από αυτά μπορούν να αντιμετωπιστούν ως πιθανές προτάσεις ενεργειακών μέτρων αναβάθμισης. Έπειτα, ομαδοποιεί τα κτήρια με βάση την ενεργειακή τους κλάση δημιουργώντας έτσι ένα πρότυπο αναφοράς. Με βάση αυτό μπορούν να καθοριστούν οι απαραίτητες αλλαγές σε ένα κτήριο ώστε να μεταφερθεί σε άλλη ομάδα, δηλαδή να βελτιωθεί η ενεργειακή του κλάση και απόδοση. Ωστόσο, οι αλγόριθμοι ομαδοποίησης μπορούν να συνδυαστούν και με άλλες τεχνικές, όπως οι Monte Carlo προσομοιώσεις σε δημοσιεύσεις όπως η [11]. Ειδικότερα, τα κτήρια ομαδοποιούνται και στην συνέχεια μέσω προσομοιώσεων Monte Carlo εκτιμάται η εξοικονόμηση ενέργειας που επιτυγχάνεται σε αυτά μετά την εφαρμογή διαφορετικών μέτρων. Η επιλογή του κατάλληλου μέτρου πραγματοποιείται μέσω ενός συστήματος αποφάσεων το οποίο λαμβάνει υπόψη ως κριτήρια το κόστος και την μέση εξοικονόμηση ανά κλάση.

2.1.3 Πολυκριτήρια ανάλυση

Σε πολλές μελέτες τα πιθανά σενάρια αναβάθμισης εξετάζονται με βάση πολλαπλά κριτήρια, όπως η ενεργειακή εξοικονόμηση που επιτυγχάνεται, το κόστος που απαιτείται και άλλοι παράγοντες που επηρεάζουν τόσο το περιβάλλον όσο και τον ιδιοκτήτη. Οι περιπτώσεις αυτές αντιμετωπίζονται συνήθως με μοντέλα πολυκριτήριας ανάλυσης και βελτιστοποίησης. Μπορούν να χρησιμοποιηθούν με αποκλειστικότητα, όπως για παράδειγμα στο [12] όπου εξετάζεται η σχέση κόστους-ωφέλειας των μέτρων με στατιστική και οικονομική ανάλυση, αλλά και σε συνδυασμό με άλλες μεθόδους.

2.1.4 Μηχανική μάθηση

Κυρίως τα τελευταία χρόνια παρατηρείται άνοδος στην εφαρμογή μεθόδων μηχανικής μάθησης όσον αφορά τα μοντέλα πρόβλεψης γενικότερα. Οι συγκεκριμένες τεχνικές μπορούν να μειώσουν το υπολογιστικό κόστος χρήσης που αναφέρθηκε σε προηγούμενες έρευνες αλλά και το πλήθος των παραμέτρων που χρειάζεται να εισάγει ο/η χρήστης/ρια. Τα μοντέλα που εκπαιδεύονται σε δεδομένα (data-driven) μπορούν με χρήση μόνο μερικών βασικών χαρακτηριστικών των κτηρίων να εντοπίσουν πολύπλοκες σχέσεις μεταξύ τους και να προσδιορίσουν την ενεργειακή τους συμπεριφορά. Για την αποδοτική υλοποίησή τους όμως είναι αναγκαία η ύπαρξη μεγάλων και ποικιλόμορφων συνόλων δεδομένων για την εκπαίδευση και την ανάπτυξη της δυνατότητας γενίκευσης. Γι' αυτό λοιπόν, όπως επισημαίνει και η έρευνα [8] έως την στιγμή δημοσίευσης της, δεν υπάρχει κάποια μελέτη στην βιβλιογραφία, η οποία να παρέχει

προτάσεις για μέτρα ενεργειακής αναβάθμισης χρησιμοποιώντας αποκλειστικά μοντέλα μηχανικής μάθησης και σύνολα δεδομένων που έχουν παραχθεί από μετρήσεις διαφόρων κτηρίων.

Πρόβλεψη ενεργειακής κατανάλωσης

Πολλές δημοσιεύσεις αναλογίζονται το πρόβλημα ως την πρόβλεψη της ενεργειακής κατανάλωσης μετά την εφαρμογή ενός μέτρου (και συνεπώς της ενεργειακής εξοικονόμησης) και την χρήση αυτής ως κριτήριο για την βέλτιστη επιλογή τρόπου αναβάθμισης. Σε αυτήν την περίπτωση μπορούν να υιοθετηθούν οι πολλαπλές μέθοδοι, συμπεριλαμβανομένων και διάφορων μεθόδων μηχανικής μάθησης, που έχουν εκτενώς ερευνηθεί για τον τομέα πρόβλεψης της κατανάλωσης ενέργειας. Στήνεται, λοιπόν, και επιλύεται ένα πρόβλημα παλινδρόμησης με χρήση μοντέλων όπως νευρωνικά δίκτυα, τα οποία με είσοδο ένα υποσύνολο παραμέτρων του κτηρίου και των πιθανών μέτρων δίνουν ως έξοδο την ενέργεια που εξοικονομείται με την εφαρμογή τους [13]. Η έξοδος αυτή πιθανώς συνδυάζεται και με άλλες τιμές όπως το κόστος και η μείωση των εκπομπών CO₂ [14]. Αντίστοιχη παραλλαγή αποτελεί και η πρόβλεψη της ενεργειακής κλάσης, στην οποία αναμένεται να ανήκει το κτήριο μετά την αναβάθμισή του, όπως στο [15] όπου μάλιστα δοκιμάζεται η διεύρυνση των διαθέσιμων χαρακτηριστικών με την ενσωμάτωση εικόνων των κτηρίων. Στο [16] εκπαιδεύονται πολλαπλά μοντέλα μηχανικής μάθησης για την πρόβλεψη της ετήσιας κατανάλωσης ενέργειας. Ακόμη, υλοποιείται μία εφαρμογή στην οποία ο/η χρήστης/ρια μπορεί να εισάγει τα χαρακτηριστικά του σπιτιού του διαφοροποιημένα ως προς τα μέτρα αναβάθμισης που θέλει να εξετάσει και με βάση τα αποτελέσματα να αξιολογήσει την επίδραση τους. Μία διαφορετική προσέγγιση εισάγεται στο [17] για την πρόβλεψη της ενεργειακής απόδοσης με βάση τις απώλειες θερμότητας των επιμέρους τμημάτων του κάθε κτηρίου. Συγκεκριμένα, εκπαιδεύεται ένα physics-informed νευρωνικό δίκτυο με έξοδο χαρακτηριστικά των δομικών στοιχείων του κτηρίου. Με την ενσωμάτωση φυσικών σχέσεων στην συνάρτηση απωλειών υπολογίζεται η κατανάλωση ενέργειας με βάση τις απώλειες θερμότητας. Επομένως, αναδεικνύονται και τα συγκεκριμένα σημεία του κτηρίου που χρειάζονται ενεργειακή αναβάθμιση συμβάλλοντας στην πληρέστερη αξιολόγηση αντίστοιχων μέτρων.

Συνδυασμός με άλλες μεθόδους

Η μηχανική μάθηση συχνά συνδυάζεται και με άλλες ποικίλες μεθόδους με παράδειγμα το [18]. Οι συγγραφείς του χρησιμοποιούν ένα νευρωνικό δίκτυο για πρόβλεψη της ενεργειακής εξοικονόμησης μετά από σενάρια αναβάθμισης, αλλά και Monte Carlo προσομοιώσεις για την πρόβλεψη του κόστους των αλλαγών, με στόχο να αναζητήσουν τις βέλτιστες οικονομικές και αποδοτικές επιλογές. Στο [19] μοντέλα μηχανικής μάθησης χρησιμοποιούνται μαζί με μεθόδους πολυκριτήριας βελτιστοποίησης χρησιμοποιώντας δεδομένα μίας βάσης ενεργειακών πιστοποιητικών κατοικιών. Συγκεκριμένα, εκπαιδεύουν μοντέλα παλινδρόμησης για την πρόβλεψη των ενεργειακών αναγκών και της ενεργειακής κλάσης των κτηρίων και έπειτα ενσωματώνουν διαδικασία πολυκριτήριας βελτιστοποίησης για την πρόταση μέτρων αναβάθμισης. Η υλοποίηση παρέχεται σε διαδικτυακή εφαρμογή όπου ο/η χρήστης/ρια μετά την εισαγωγή των ζητούμενων στοιχείων έχει τη δυνατότητα είτε πειραματισμού χειροκίνητα με πολλαπλές

αλλαγές είτε λήψης πληροφοριών για τα βέλτιστα μέτρα με βάση ενεργειακά και οικονομικά κριτήρια που έχει καθορίσει. Ένα συνδυαστικό μοντέλο αναπτύσσεται στο [20], το οποίο ενσωματώνει ένα μοντέλο προσομοίωσης, ένα μοντέλο μηχανικής μάθησης για πρόβλεψη της κατανάλωσης και ένα μοντέλο βελτιστοποίησης και βοηθά στην αξιολόγηση των ενεργειακών επιλογών ακόμη και στο αρχικό στάδιο σχεδιασμού ενός κτηρίου. Τέλος, μία άλλη εφαρμογή μηχανικής μάθησης υλοποιείται στο [21] όπου οι συγγραφείς προτείνουν μια μεθοδολογία για την κατηγοριοποίηση επενδύσεων σχετικών με την ενεργειακή αποδοτικότητα κτηρίων ως προς το κόστος αλλά και την εξοικονόμηση ενέργειας που προσφέρουν. Συνδυάζοντας πολλά μοντέλα δείχνουν ότι τα αποτελέσματα του meta-learning μοντέλου υπερέχουν με υψηλή ακρίβεια στην αξιολόγηση μελλοντικών επενδύσεων.

Έλεγχος λειτουργίας μεμονωμένων συστημάτων

Εκτός από την γενικότερη μελέτη και πρόβλεψη των προτεινόμενων μέτρων ενεργειακής αναβάθμισης κτηρίων, έχουν προταθεί και διάφορες μέθοδοι οι οποίες αφορούν τον έλεγχο και την χρήση επιμέρους συστημάτων με στόχο την ενεργειακή βελτιστοποίηση. Παράδειγμα αποτελεί το [22] όπου μέσω ενισχυτικής μάθησης γίνεται πρόβλεψη της συμπεριφοράς των καταναλωτών στα δωμάτια του κτηρίου, τα αποτελέσματα της οποίας χρησιμοποιούνται για τον σχεδιασμό της λειτουργίας διαφόρων συστημάτων (θέρμανσης, εξαερισμού κλπ). Συνεπώς με γνώμονα την άνεση των ενοίκων βελτιστοποιείται η χρήση ενέργειας στον χώρο. Αντίστοιχα στο [23] αναπτύσσεται μία μέθοδος ενισχυτικής μάθησης βασισμένη σε τεχνικές ομαδοποίησης (deep clustering multi-agent cooperative reinforcement learning), η οποία διαχειρίζεται την λειτουργία των ψυκτικών συστημάτων σε κτήρια με αποτέλεσμα την ενεργειακή εξοικονόμηση.

2.2 Ανασκόπηση συνόλων δεδομένων

Η πλειοψηφία των δεδομένων που χρησιμοποιούνται στην βιβλιογραφία προέρχεται από ενεργειακά πιστοποιητικά κτηρίων (Energy Performance Certificates (EPCs)). Τα πιστοποιητικά έχουν εκδοθεί για ένα ποσοστό των κτηρίων με βάση τον ευρωπαϊκό κανονισμό Energy Performance of Buildings Directive (EPBD) και περιλαμβάνουν πληροφορίες για την ενεργειακή αποδοτικότητά τους. Συγκεκριμένα περιγράφουν βασικά χαρακτηριστικά της κατασκευής και του ενεργειακού επιπέδου κάθε κτηρίου προσδίδοντάς τους παράλληλα την αντίστοιχη ενεργειακή κλάση. Επιπρόσθετα δύνανται να περιλαμβάνουν μέτρα ενεργειακής αναβάθμισης και την τελική κλάση που μπορεί να επιφέρει η εφαρμογή τους. Κάθε χώρα προσαρμόζει την μορφή με τις δικές της προδιαγραφές με ορισμένες να διατηρούν ολοκληρωμένες βάσεις ενεργειακών πιστοποιητικών. Ακολούθως περιγράφονται ορισμένα από τα πιο διαδεδομένα τέτοια σύνολα δεδομένων.

CENED DB

Η βάση δεδομένων Certificazione Energetica degli Edifici DataBase (Energy Performance Certification of Buildings), ή αλλιώς CENED +2 DB, περιλαμβάνει δεδομένα από τα

ενεργειακά πιστοποιητικά κτηρίων της Ιταλίας και συγκεκριμένα της περιοχής της Λομβαρδίας. Η διαχείρισή της πραγματοποιείται από την Περιφέρεια Λομβαρδίας και την υπηρεσία ARIA (Azienda Regionale per l'Innovazione e gli Acquisti). Παρέχεται δωρεάν πρόσβαση στο σύνολο των δεδομένων (στην ιταλική γλώσσα) μέσω του Regione Lombardia Open Data [24]. Στην έκδοση που δημοσιεύτηκε στις 25/04/2024 το πλήθος των καταγραφόμενων κτηρίων είναι 1.828.705 εκ των οποίων τα 1.558.873 αναφέρονται σε κτήρια κατοικίας. Συγκεκριμένα, 152.498 πιστοποιητικά αναφέρονται σε ολόκληρο το κτήριο περιλαμβάνοντας το σύνολο των διαμερισμάτων που το αποτελούν, ενώ τα υπόλοιπα σε ένα ή περισσότερα μεμονωμένα διαμερίσματα. Περιλαμβάνουν 196 χαρακτηριστικά λεπτομερούς περιγραφής των κτηρίων (δομικά και ενεργειακά) πριν και μετά την εφαρμογή μέτρων ενεργειακής αναβάθμισης. Τα μέτρα αυτά αναπαρίστανται από 7 στήλες, οι οποίες αφορούν αλλαγές σε στοιχεία του κτηρίου όπως τοίχοι, πατώματα, παράθυρα, πόρτες κλπ, το σύστημα θέρμανσης και ψύξης, άλλα συστήματα όπως εξαερισμός, φωτισμός, θέρμανσης νερού, καθώς και χρήση ανανεώσιμων πηγών ενέργειας. Ενδεικτικές δημοσιεύσεις στις οποίες χρησιμοποιούνται τα συγκεκριμένα δεδομένα είναι οι [11, 18].

Scottish Energy Performance Certificate Register (SEPCR)

Τα δεδομένα του Scottish Energy Performance Certificate Register (SEPCR) προέρχονται από τα ενεργειακά πιστοποιητικά οικιακών κτηρίων στην Σκωτία και διατίθενται δημόσια από την κυβέρνηση της χώρας [25]. Η έκδοση του Απριλίου 2024 (Dataset - Q2 2014 to Q1 2024) αποτελείται από 1.557.456 δείγματα τα οποία είναι χωρισμένα σε χρονιές και συγκεκριμένα τρίμηνα αυτών, με το κάθε τρίμηνο να έχει περίπου 30 με 40 χιλιάδες δείγματα. Τα δεδομένα παρέχονται σε αρχεία της μορφής YearQi όπου Year η αντίστοιχη χρονιά και Qi με $i=1,2,3,4$ το αντίστοιχο τρίμηνο ξεκινώντας από το δεύτερο τρίμηνο του 2014 (2014Q2) έως το πρώτο τρίμηνο του 2024 (2024Q1). Εντός των 105 χαρακτηριστικών που περιλαμβάνει βρίσκονται και ορισμένα μέτρα για την βελτίωση της ενεργειακής αποδοτικότητας των κτηρίων. Αυτά σχετίζονται με διαφόρων μορφών μονώσεις (π.χ. εξωτερικού τοίχου, πατώματος κλπ), αλλαγή σε φώτα χαμηλής ενέργειας, ποικίλες αλλαγές στο σύστημα θέρμανσης και στο σύστημα θέρμανσης νερού, χρήση ανανεώσιμων μορφών ενέργειας (ηλιακή) και γενικότερες αλλαγές στην μορφή του κτηρίου. Η συγκεκριμένη βάση δεδομένων χρησιμοποιείται για παράδειγμα στην δημοσίευση [15].

Energy Performance of Buildings Data England and Wales

Το σύνολο δεδομένων Energy Performance of Buildings Data England and Wales αποτελεί την βάση δεδομένων των ενεργειακών πιστοποιητικών (EPCs) της Αγγλίας και της Ουαλίας, η οποία διαχωρίζεται σε οικιακά και μη οικιακά κτήρια. Διατίθεται δημόσια από το Department for Levelling Up, Housing and Communities το οποίο υπόκειται στην δικαιοδοσία της κυβέρνησης του Ηνωμένου Βασιλείου [26]. Το πλήθος των δεδομένων που αφορούν οικιακά κτήρια είναι 25.991.274 έως και τον Μάρτιο του 2024 (έκδοση 25/04/2024) και περιλαμβάνει όλα τα διαφορετικά είδη κατοικιών. Τα χαρακτηριστικά του συνόλου είναι αρκετά

παρόμοια με την αντίστοιχη βάση δεδομένων για την Σκωτία με την οποία και μοιράζονται ίδια πρότυπα. Τα μέτρα ενεργειακής αναβάθμισης παρατίθενται σε ξεχωριστό αρχείο με την επεξήγηση του κάθε μέτρου και το κόστος εφαρμογής του. Μία έρευνα η οποία εκμεταλλεύεται τα δεδομένα αυτά είναι η [16].

Building Energy Rating (BER), Irish EPC database

Η βάση δεδομένων για τα ενεργειακά πιστοποιητικά της Ιρλανδίας (Building Energy Rating certificates - BER) διατηρείται και παρέχεται από την Sustainable Energy Authority of Ireland (SEAI) [27]. Περιέχει δεδομένα για 1.048.576 οικιακά κτήρια και 211 χαρακτηριστικά που αφορούν την κατασκευή και την ενεργειακή κατάσταση τους. Οι πληροφορίες για τα μέτρα ενεργειακής αναβάθμισης στα σπίτια της Ιρλανδίας υπάρχουν στο σύνολο δεδομένων Post-Works Building Energy Rating (PWBER) το οποίο ωστόσο δεν είναι δημόσια διαθέσιμο από το SEAI. Με βάση τις δημοσιεύσεις [28, 5], το συγκεκριμένο σύνολο περιέχει δεδομένα από ένα δείγμα 112.007 κτηρίων τα οποία ανακαινίστηκαν την περίοδο 2010-2015. Στο Παράρτημα Α του [28], παρατίθεται η μέση τιμή βελτίωσης του Building energy rating (BER) ($\text{kWh/m}^2 \text{ year}$) για πλήθος συνδυασμών μέτρων ανάλογα την ενεργειακή κλάση και τον τύπο του κτηρίου. Η αντιστοίχιση του τελικού BER στην τελική ενεργειακή κλάση πραγματοποιείται με βάση τον επίσημο πίνακα που βρίσκεται στον οδηγό της βάσης δεδομένων. Μάλιστα στην ίδια δημοσίευση επισημαίνεται ότι οι συνδυασμοί μέτρων που εφαρμόζονται πιο συχνά είναι οι Attic and Cavity insulation, Boiler with heating controls, External Wall insulation, Solar thermal, Attic and Cavity insulation and Boiler with heating controls και αποτελούν το 84% του συνόλου δεδομένων. Επιπλέον τα δεδομένα ενσωματώνονται και στην δημοσίευση [10].

Άλλες βάσεις δεδομένων ενεργειακών πιστοποιητικών κτηρίων

Αντίστοιχα δεδομένα υπάρχουν στις βάσεις των ενεργειακών πιστοποιητικών κτηρίων των περισσότερων ευρωπαϊκών χωρών, η πλειοψηφία των οποίων όμως δεν παρέχει ελεύθερη πρόσβαση στο κοινό. Οι αντίστοιχοι οργανισμοί που τα διατηρούν τα διαθέτουν μόνο σε συγκεκριμένες περιπτώσεις, όπως πιστοποιημένους ειδικούς ενέργειας. Ορισμένες χώρες εκδίδουν είτε γενικά στατιστικά είτε ορισμένα μεμονωμένα στοιχεία έπειτα από αναζήτηση μέσω της διεύθυνσης του σπιτιού ή του αναγνωριστικού αριθμού του πιστοποιητικού. Μερικές από τις πιο γνωστές εθνικές βάσεις δεδομένων προέρχονται από τις εξής χώρες:

- Πορτογαλία (διατηρείται από τον Πορτογαλικό Οργανισμό Ενέργειας ADENE) ([6, 19])
- Σουηδία (διατηρείται από το Boverket, Swedish National Board of Housing, Building and Planning) ([4, 7, 14, 9])
- Ελβετία (CECB ή αλλιώς GEAK)
- Γαλλία (CEREN)

Στον Πίνακα 2.1 καταγράφονται τα παραπάνω σύνολα δεδομένων συνδυαστικά με ορισμένες από τις βασικές δημοσιεύσεις στις οποίες έχουν χρησιμοποιηθεί. Αυτές αναφέρονται στο αντίστοιχο πρόβλημα πρόβλεψης μέτρων με στόχο την βελτίωση της ενεργειακής απόδοσης των κτηρίων και παρατίθενται παράλληλα με την μέθοδο που χρησιμοποιούν οι εκάστοτε συγγραφείς.

Dataset	Related papers
CENED DB [24]	[11] clustering and Monte Carlo simulations [18] ML and Monte Carlo simulations
Scottish Energy Performance Certificate Register [25]	[15] ML (predicts energy savings of retrofits)
Energy Performance of Buildings Data England and Wales [26]	[16] ML (predicts energy consumption)
Building Energy Rating (BER) [27]	[10] clustering and benchmarking [28, 5] energy simulations/modelling
Portugal's EPC database	[6] statistical computational model [19] ML and multi-objective optimization
Sweden's EPC database	[4, 7] energy simulations/modelling [14] ML (predicts energy performance of retrofits) [9] clustering and benchmarking

Πίνακας 2.1: Ανασκόπηση συνόλων δεδομένων και αντίστοιχων δημοσιεύσεων

2.3 Συμβολή της εργασίας σε σχέση με την υπάρχουσα έρευνα

Λαμβάνοντας υπόψη την έρευνα που έχει προηγηθεί όπως καταγράφεται στην βιβλιογραφία, μπορούμε να συνοψίσουμε την συνεισφορά της παρούσας διπλωματικής εργασίας στην βελτιστοποίηση της ενεργειακής απόδοσης κτηρίων κατοικίας στους ακόλουθους άξονες. Πρωτίστως, το σύστημα πρόβλεψης των μέτρων ενεργειακής αναβάθμισης που υλοποιούμε βασίζεται εξ ολοκλήρου σε τεχνικές τεχνητής νοημοσύνης και μηχανικής μάθησης αξιοποιώντας τα

πλεονεκτήματά τους. Τα χαρακτηριστικά που απαιτούνται ως είσοδος είναι λίγα και εύκολα προσβάσιμα από τον χρήστη και δεν απαιτούν εξειδικευμένη γνώση και εμπειρία. Επιπλέον, η πλειονότητα των υπάρχουσων ερευνών αφορά την πρόβλεψη της ενεργειακής κατανάλωσης και εξοικονόμησης μέσω της εφαρμογής συγκεκριμένων μέτρων. Ο/η χρήστης-ρια, λοιπόν, καλείται να δοκιμάσει πολλαπλές πιθανές εναλλακτικές αλλαγές και να τις αξιολογήσει με βάση την κρίση του/της. Η προτεινόμενη μέθοδος, από την άλλη, ελαχιστοποιεί την πολυπλοκότητα της διαδικασίας για τον χρήστη καθώς αποτελεί ξεκάθαρη ταξινόμηση και του προσφέρει ακριβείς προτάσεις για να αναβαθμίσει ενεργειακά την κατοικία του. Ο στόχος από εκείνον-η παρέχεται ως η τελική ενεργειακή κλάση που επιθυμεί, έννοια η οποία είναι πιο κατανοητή και άμεση για τον μέσο ενδιαφερόμενο πολίτη.

Συγχρόνως, η ενσωμάτωση της επεξηγήσιμης τεχνητής νοημοσύνης με την μέθοδο SHAP ενισχύει την διαφάνεια, την αξιοπιστία και την κατανόηση της λειτουργίας του μοντέλου. Αναδεικνύει τον βαθμό σημαντικότητας κάθε χαρακτηριστικού για τις προβλέψεις, συμβάλλοντας έτσι στην περαιτέρω ανάλυση αφού τα αποτελέσματά μας καθοδηγούν ώστε να αναπροσαρμόσουμε τις επιλογές της υλοποίησης. Παρέχονται επεξηγήσεις σχετικά με τους λόγους επιλογής της εκάστοτε σύστασης, οι οποίες δύνανται ακόμα να αυξήσουν την εμπιστοσύνη των χρηστών μειώνοντας την αβεβαιότητα και οδηγώντας τελικά στην υιοθέτηση περισσότερων ενεργειακών αναβαθμίσεων.

Επιπροσθέτως, εισάγουμε την χρήση στρατηγικών διαρκούς μάθησης, οι οποίες επιτρέπουν στο μοντέλο να εκπαιδεύεται διαδοχικά σε πολλαπλά σύνολα δεδομένων από διαφορετικές πηγές προέλευσης (χώρες), και αναδεικνύουμε τις προοπτικές και τα πλεονεκτήματα που μπορούν να επιφέρουν. Ειδικότερα, έτσι το μοντέλο διατηρεί τις πληροφορίες που αποκτά από προηγούμενα δεδομένα, ενώ παράλληλα η προσαρμογή του στα νέα διευκολύνεται μοιράζοντας την υπάρχουσα κοινή γνώση. Η προσέγγιση αυτή μπορεί να οδηγήσει σε ένα ενιαίο μοντέλο που γενικεύει μεταξύ διαφορετικών χωρών και αποδίδει στο σύνολό τους. Ακόμη, μπορεί να ενσωματώνει νέες ροές δεδομένων με την πάροδο του χρόνου, είτε από νέες περιοχές είτε από επιπλέον δεδομένα των ίδιων πηγών, διασφαλίζοντας την προσαρμοστικότητα και την μεταφορά γνώσης ακόμα και από μεγαλύτερα σε μικρότερα σύνολα δεδομένων χωρίς την ανάγκη συνεχούς επανεκπαίδευσης.

Αναφορικά με τα δεδομένα που χρησιμοποιούνται, ενσωματώνουμε στην μελέτη μας ένα νέο σύνολο δεδομένων με προέλευση την Λετονία. Επιπλέον με βάση αυτό παράγουμε νέα συνθετικά δεδομένα εμπλουτίζοντας το περαιτέρω και τέλος το συνδυάζουμε με δύο ήδη εδραιωμένα σύνολα δεδομένων από την Ιταλία και την Αγγλία.

Κεφάλαιο 3

Διερευνητική ανάλυση δεδομένων

3.1 Περιγραφή συνόλου δεδομένων

Το αρχικό σύνολο δεδομένων που χρησιμοποιείται αφορά κτήρια ιδιωτικών κατοικιών τα οποία αναβαθμίστηκαν ενεργειακά με δημόσια χρηματοδότηση στην Λετονία. Τα δεδομένα αυτά συλλέχθηκαν από το LEIF (Latvian Environmental Investment Fund). Ειδικότερα, περιλαμβάνουν πληροφορίες σχετικές με το εκάστοτε κτήριο, τα μέτρα ενεργειακής εξοικονόμησης που υλοποιήθηκαν σε αυτό, καθώς και την αρχική αλλά και τελική κατάσταση που επιτεύχθηκε, με παράδειγμα την ενεργειακή κλάση και κατανάλωση.

Τα δεδομένα αποτελούνται από 198 δείγματα (κτήρια) και διαθέτουν 83 χαρακτηριστικά, τα οποία παρουσιάζονται στον Πίνακα 3.1.

Features of Latvian dataset

Project number
The date
Region
The town/village
Home address
County/City
Initial year of exploitation
Building Total Area
Room volume
Average floor height
Reference area
Above-ground floors
Underground floor
Mansard
Roof floor
Initial energy class
Energy consumption before

Heat energy consumption before
Carbon dioxide emissions before
Carrying out construction works
Reconstruction of engineering systems
Water heating system
Heat installation
Energy audit number
Energy class after
Heat energy consumption after
Consumption for hot water after
Consumption for mechanical ventilation after
Consumption for lighting after
Consumption for cooling after
Energy consumption after
Heat saving for heating
Total energy consumption saving
Saving of heat energy
Primary non-renewable energy
Primary total energy consumption
Almost zero energy building
Carbon dioxide emission tons after
Carbon dioxide emission after
Area of the external surface
Average heat transfer coefficient
Average heat transfer coefficient_1
Building calculated heat loss coefficient
Building allowable heat loss coefficient
Indoor temperature heating
Indoor temperature for cooling
Air exchange rate
Ventilation heat loss coefficient
Energy resource for heating 1
Energy resource for heating 2
Energy resource for hot water 1
Energy resource for hot water 2
Energy resource for ventilation
Energy resource for cooling 1
Energy resource for cooling 2
CO₂ emission factor for heating 1
CO₂ emission factor for heating 2
CO₂ emission factor for hot water 1

CO₂ emission factor for hot water 2
 CO₂ emission factor for ventilation
 CO₂ emission factor for cooling 1
 CO₂ emission factor for cooling 2
 Non-renewable factor for heating 1
 Non-renewable factor for heating 2
 Non-renewable factor for hot water 1
 Non-renewable factor for hot water 2
 Non-renewable factor for ventilation
 Non-renewable factor for cooling 1
 Non-renewable factor for cooling 2
 Renewable factor for heating 1
 Renewable factor for heating 2
 Renewable factor for hot water 1
 Renewable factor for hot water 2
 Renewable factor for ventilation
 Renewable factor for cooling 1
 Renewable factor for cooling 2
 Total factor for heating 1
 Total factor for heating 2
 Total factor for hot water 1
 Total factor for hot water 2
 Total factor for ventilation
 Total factor for cooling 1
 Total factor for cooling 2

Πίνακας 3.1: Τα χαρακτηριστικά του συνόλου δεδομένων της Λετονίας

Τα χαρακτηριστικά Energy resource for heating 1/2, hot water 1/2, ventilation, cooling 1/2 αφορούν τις πηγές ενέργειας που χρησιμοποιούνται για το κάθε σύστημα του κτηρίου και στο εξής θα αναφερόμαστε σε αυτά ως χαρακτηριστικά Energy resources. Όλες οι επόμενες γραμμές των χαρακτηριστικών, δηλαδή τα CO₂ emission/Non-renewable, Renewable/Total factor for heating 1/2, hot water 1/2, ventilation, cooling 1/2 αποτελούν τις τιμές των αντίστοιχων συντελεστών ενέργειας για κάθε σύστημα και θα τα χαρακτηρίζουμε ως Energy factors στην συνέχεια. Οι δείκτες 1, 2 σχετίζονται με την ύπαρξη και δεύτερου ξεχωριστού συστήματος για την ίδια λειτουργία.

3.2 Προεπεξεργασία δεδομένων

Ως πρώτο βήμα απαιτείται η προεπεξεργασία των δεδομένων, ώστε να εντοπιστούν ασυνέπειες και να μετατραπούν σε κατάλληλη μορφή για περαιτέρω ανάλυση και χρήση.

Αρχικά παρατηρήθηκε ότι ορισμένα από τα χαρακτηριστικά του συνόλου παρουσιάζουν αποκλίσεις ως προς τον αναμενόμενο τύπο δεδομένων. Συγκεκριμένα εντοπίστηκαν και διορθώθηκαν κάποιες ασυνέπειες στην μορφή των τιμών, όπως στο χαρακτηριστικό Almost zero energy building το οποίο ενώ λαμβάνει τιμές 0 και 1 υπήρχε και η τιμή 'Jā' που σημαίνει 'ναι'. Ακόμη, ο αναμενόμενος αριθμητικός τύπος των στηλών Indoor temperature for cooling και των Energy factors αντικαθίσταται από τον τύπο object λόγω της ύπαρξης τιμών '-', οι οποίες αναπαριστούν κενές τιμές καθώς είτε δεν υπάρχει το αντίστοιχο ξεχωριστό σύστημα είτε είναι άγνωστο. Αντίστοιχες '-' συναντώνται και στα Energy resources χαρακτηριστικά. Συμπεριλαμβάνοντας τις τιμές '-' στο σύνολο, τα τελικά πλήθη των κενών τιμών είναι τα εξής:

- The town/village: 7
- Carbon dioxide emissions before: 1
- Primary non-renewable energy: 1
- Area of the external surface - Air exchange rate: 19 (με βάση την σειρά που εμφανίζονται στον Πίνακα 3.1)
- Ventilation heat loss coefficient: 21
- Energy resources, Energy factors for heating 1: 19
- Energy resources, Energy factors for heating 2: 153
- Energy resources, Energy factors for hot water 1: 23
- Energy resources, Energy factors for hot water 2: 147
- Energy resources, Energy factors for ventilation: 142
- Energy resources, Energy factors for cooling 1: 131
- Energy resources, Energy factors for cooling 2: 191

Είναι συνεπώς εμφανές ότι το πλήθος των κενών τιμών σε ορισμένες στήλες είναι ιδιαίτερα υψηλό, με χαρακτηριστικό παράδειγμα τις σχετικές με το δεύτερο σύστημα ψύξης (cooling 2), οι οποίες έχουν 191 κενές τιμές από τις 198 συνολικές.

Οι απουσιάζουσες τιμές μπορούν να συμπληρωθούν με κάποια από τις γνωστές τεχνικές imputation. Ωστόσο, δεν προχωράμε στην ανάλυση της διαδικασίας αυτής καθώς τα συγκεκριμένα χαρακτηριστικά τελικά δεν χρησιμοποιούνται από τα μοντέλα μας όπως θα φανεί στην συνέχεια.

Όσον αφορά τις ακραίες τιμές (outliers), τις υπολογίζουμε με βάση το z-score το οποίο δείχνει πόσο μακριά από την μέση τιμή βρίσκεται η εξεταζόμενη, μετρώντας την διαφορά σε πλήθος τυπικών αποκλίσεων. Μελετώντας τα αποτελέσματα συνδυαστικά με τα στατιστικά στοιχεία των δεδομένων γίνεται εμφανές ότι τα περισσότερα outliers είναι αποδεκτά, καθώς παρά την διαφορά τους από την συνήθη περίπτωση περιέχουν χρήσιμη και αντιπροσωπευτική

πληροφορία. Εφόσον, όμως, αναφερόμαστε σε ιδιωτικά σπίτια η ακραία τιμή 76 μέτρα, για παράδειγμα, που λαμβάνει το Average floor height δεν μπορεί να είναι λογική. Όπως γνωρίζουμε και αναδεικνύεται και από τα δεδομένα στον Πίνακα 3.2, το 75% των κτηρίων έχουν μέσο ύψος μικρότερο από 2,66 μέτρα (75-percentile). Επίσης η τιμή που λαμβάνουν κυμαίνεται γύρω στα 3 μέτρα (εάν εξαιρέσουμε το outlier). Όσον αφορά το χαρακτηριστικό Carbon dioxide emission tons after παρουσιάζει τιμή ίση με 386.15, ενώ το 75% των δεδομένων είναι κάτω από 2.14 και η μέση τιμή τους 3.276 (Πίνακας 3.2). Η απόκλιση είναι εξαιρετικά μεγάλη και στο συγκεκριμένο δείγμα δεν παρατηρούνται αντίστοιχες διαφορές σε άλλα χαρακτηριστικά σχετικά με το χώρο για παράδειγμα του κτηρίου που ίσως να μπορούσαν να αιτιολογήσουν μια τέτοια μεταβολή. Συνεπώς, οι δύο αυτές τιμές είναι πράγματι ακραίες και χρειάζεται η αφαίρεση τους ώστε να μην προκαλέσουν την εξαγωγή λανθασμένων συμπερασμάτων κατά την υλοποίηση.

	Average floor height	Carbon dioxide emission tons after
count	198	198
mean	2.931	3.276
std	5.224	27.385
min	2.08	0
25%	2.4	0.423
50%	2.5	0.665
75%	2.658	2.14
max	76	386.15

Πίνακας 3.2: Στατιστικά στοιχεία για τα χαρακτηριστικά με ακραίες τιμές

3.3 Ανάλυση δεδομένων


Συνεχίζοντας με την ανάλυση των δεδομένων κρίνεται σπουδαίας σημασίας η γραφική αναπαράσταση των δεδομένων, διότι η οπτικοποίηση μέσω διαγραμμάτων συνεισφέρει στην πιο άμεση κατανόηση. Ειδικότερα, η ανάλυση πραγματοποιείται τόσο για κάθε μεταβλητή ξεχωριστά (univariate analysis) όσο και για συνδυασμό αυτών (multivariate analysis).

3.3.1 Γραφική απεικόνιση χαρακτηριστικών

Αρχικά κρίνεται σκόπιμο να μελετηθούν οι επιμέρους κατανομές κάθε στήλης. Για τις κατηγορικές χρησιμοποιούνται barplots ενώ για τις αριθμητικές ιστογράμματα.


Τα χαρακτηριστικά Project number και Energy audit number περιλαμβάνουν διαφορετική μοναδική τιμή για κάθε κτήριο αφού αποτελούν μοναδικά αναγνωριστικά. Παρόμοια και το Home address παρουσιάζει κοινές τιμές μόνο για δύο ζευγάρια κτηρίων, τα οποία μάλιστα βρίσκονται σε διαφορετικές περιοχές οι οποίες φαίνεται να διαθέτουν μία κοινή διεύθυνση.

Επομένως, μπορούμε με ασφάλεια να αγνοήσουμε τις στήλες αυτές καθώς δεν προσφέρουν ουσιαστική πληροφορία στα δεδομένα. Αντίστοιχα μπορούμε να πράξουμε για την στήλη The date η οποία αφορά την ημερομηνία που το πρόγραμμα ανακαίνισης καταχωρήθηκε. Έτσι, εφόσον οι τιμές της αφορούν συγκεκριμένες μόνο χρονολογίες (2021, 2022) και δεν είναι ιδιαίτερα σημαντική στο συγκεκριμένο πλαίσιο έρευνας δεν θα προχωρήσουμε σε περαιτέρω μελέτη της.



Σχήμα 3.1: Γράφημα χαρακτηριστικού Region


Από την γραφική παράσταση του χαρακτηριστικού Region στο Σχήμα 3.1 παρατηρούμε ότι τα περισσότερα σπίτια του συνόλου δεδομένων βρίσκονται στην Ρίγα. Δέκα σπίτια βρίσκονται στην περιοχή Latgales και τα υπόλοιπα είναι ισοκατανεμημένα στις υπόλοιπες 3 περιοχές. Οι άλλες δύο στήλες που υποδεικνύουν την περιοχή, δηλαδή οι The town/village και County/City, έχουν πολλαπλές διακριτές τιμές, 122 και 68 αντίστοιχα στα 198 συνολικά δείγματα.



Σχήμα 3.2: Γράφημα χαρακτηριστικών Initial energy class, Energy class after

Δύο ακόμη κατηγορικές στήλες είναι οι Initial energy class και Energy class after, οι οποίες αναφέρονται στην ενεργειακή κλάση του κτηρίου πριν και μετά την εφαρμογή του προ-

γράμματος ανακαίνισης. Έχουν υψηλή αξία στα πλαίσια της εφαρμογής των διαφόρων μέτρων ενεργειακής αναβάθμισης καθώς αναδεικνύουν την βελτίωση που αυτά επιφέρουν ως προς την ενεργειακή αποδοτικότητα. Οι κατανομές τους αναπαρίστανται στο Σχήμα 3.2. Συμπεραίνουμε ότι τα περισσότερα κτήρια αρχικά ανήκαν στην κλάση D. Οι υπόλοιπες αρχικές κλάσεις σε φθίνουσα σειρά ως προς το πλήθος είναι οι F, E, C και τέλος η B η οποία εμφανίζεται σε ένα μόνο κτήριο. Με άλλα λόγια οι περισσότερες περιπτώσεις περιγράφουν σπίτια χαμηλής ενεργειακής αποδοτικότητας. Τελικά 10% περίπου των κτηρίων απέκτησαν την βέλτιστη ενεργειακή κλάση A, περίπου 20% την κλάση B και η πλειοψηφία αυτών δηλαδή περίπου το 68% βρέθηκαν στην κλάση C. Όλα τα κτήρια, λοιπόν, αποκτούν κλάσεις A, B, C που σημαίνει ότι τα μέτρα που εφαρμόστηκαν πέτυχαν σαφώς κάποια αναβάθμιση.




Σχήμα 3.3: Γραφήματα διακριτών χαρακτηριστικών

Στο Σχήμα 3.3 παρουσιάζονται τα διαγράμματα ορισμένων ακόμη βασικών διακριτών στηλών του συνόλου δεδομένων. Όσον αφορά τα Underground floor, Mansard, Roof floor παρατηρούμε ότι τα ποσοστά των κτηρίων που έχουν τα αντίστοιχα χαρακτηριστικά είναι 42%, 24% και 14% για το καθένα. Επίσης, 66% των κτηρίων διαθέτουν 2 ορόφους, ενώ 7 μόνο από τα σπίτια έχουν 3. Το πλήθος ορόφων των υπόλοιπων κατοικιών είναι 1. Ένα πολύ μικρό ποσοστό κτηρίων, συγκεκριμένα μόνο 5, μπορεί να χαρακτηριστεί ως almost zero energy με βάση τις καθορισμένες απαιτούμενες προδιαγραφές¹.

Το Σχήμα 3.4 σχετίζεται με τα χαρακτηριστικά που αναπαριστούν τα μέτρα ενεργειακής αναβάθμισης τα οποία υλοποιούνται στα πλαίσια των προγραμμάτων του συνόλου δεδομένων. Αυτά, λοιπόν, λαμβάνουν τιμή 1 εάν έχουν εφαρμοστεί στο εκάστοτε κτήριο και 0 διαφορετικά.

¹Ενότητα III του <https://likumi.lv/ta/id/322436>



Σχήμα 3.4: Γραφήματα μέτρων ενεργειακής αναβάθμισης


Από την κατανομή τους μπορούμε να καταλήξουμε στα εξής:

- ‘Carrying out construction works’ εφαρμόστηκε περίπου στο 85% των σπιτιών
- ‘Reconstruction of engineering systems’ εφαρμόστηκε περίπου στο 55% των σπιτιών
- ‘Water heating system’ εφαρμόστηκε περίπου στο 5% των σπιτιών
- ‘Heat installation’ εφαρμόστηκε περίπου στο 6% των σπιτιών

Με άλλα λόγια στα περισσότερα κτήρια υλοποιήθηκαν κατασκευές στην εξωτερική δομή τους και μόνο σε πολύ λίγα εγκαταστάθηκαν νέα συστήματα για ζεστό νερό και για θέρμανση από ανανεώσιμες πηγές ενέργειας. Περίπου στα μισά πραγματοποιήθηκαν εργασίες στα υπόλοιπα συστήματα όπως αυτό του εξαερισμού.

Στα πλαίσια της παρούσας διπλωματικής εργασίας σκοπός μας είναι η υλοποίηση ενός μοντέλου που θα προβλέπει ποια μέτρα ενεργειακής αναβάθμισης θα πρέπει να εφαρμοστούν στο ζητούμενο κτήριο ώστε να βελτιωθεί η ενεργειακή του απόδοση. Άρα τα παραπάνω χαρακτηριστικά θα είναι οι κλάσεις-στόχοι για το πρόβλημα της ταξινόμησης. Επομένως η έλλειψη ισορροπίας μεταξύ των ετικετών κάθε μίας από τις τέσσερις αυτές στήλες πρέπει να αντιμετωπιστεί. Ιδιαίτερα πρέπει να διορθωθούν οι δύο τελευταίες στις οποίες τα θετικά δείγματα είναι ελάχιστα, αλλά και η πρώτη στην οποία εμφανίζεται επίσης μεγάλη διαφορά μεταξύ θετικών και αρνητικών δειγμάτων.

Οι στήλες Energy resources αφορούν τις τελικές πηγές ενέργειας τις οποίες κατέληξαν να χρησιμοποιούν τα κτήρια για κάθε ένα από τα επιμέρους συστήματά τους. Ένα συμπέρασμα που




Σχήμα 3.5: Γραφήματα αριθμητικών χαρακτηριστικών

αντλούμε από τις κατανομές είναι ότι όσον αφορά την θέρμανση οι συχνότερα εμφανιζόμενες πηγές είναι οι ακόλουθες: στερεά βιοκαύσιμα, φυσικό αέριο, ξύλο, ηλεκτρική ενέργεια από το δίκτυο διανομής. Επίσης, 45 από τα σπίτια διαθέτουν και δεύτερη πηγή ενέργειας για θέρμανση. Για ζεστό νερό οι κορυφαίες επιλογές παραμένουν ίδιες με διαφορετική σειρά συχνότητας και σε αυτήν την περίπτωση 51 σπίτια έχουν δεύτερη ενεργειακή πηγή για την συγκεκριμένη λειτουργία. Ξεχωριστή πηγή για τον εξαερισμό διατίθεται στο 30% των σπιτιών και συνήθως αυτή είναι η ηλεκτρική ενέργεια. Τέλος, σχετικά με την ψύξη οι παρατηρήσεις είναι παρόμοιες, με 7 σπίτια να έχουν δύο διαφορετικές πηγές για τον σκοπό αυτό.

Περισσότερα γενικά συμπεράσματα για τα δεδομένα μπορούν να εξαχθούν και από τα διαγράμματα των αριθμητικών χαρακτηριστικών στο Σχήμα 3.5. Πιο συγκεκριμένα, η συχνότητα του χαρακτηριστικού Initial year of exploitation είναι μέγιστη εντός του εύρους 1970 και 2022, όπου η τελευταία μάλιστα είναι και η μέγιστη τιμή που συναντάται στα δεδομένα. Υπάρχουν ορισμένα σπίτια των οποίων η εκμετάλλευση ξεκίνησε γύρω στο 1900 και σε γενικές γραμμές το πλήθος κτηρίων ανά έτος ακολουθεί μία σχεδόν αύξουσα τάση ανά τα χρόνια.

Το Building total area για τα περισσότερα κτήρια είναι μεταξύ 100 και 200 m², μάλιστα το 75% των κτηρίων έχει τιμή κάτω από 212 m². Το Reference area ακολουθεί παρόμοια σχεδόν κατανομή με μικρότερες όμως τιμές, το οποίο είναι αναμενόμενο αφού αφορά την θερμαινόμενη περιοχή κάθε κτηρίου που προφανώς είναι μικρότερη από την συνολική. Από την άλλη, το Room volume δεν διαφέρει στην μορφή της κατανομής, με διαφορετικές προφανώς τιμές και μέγιστη συχνότητα εμφάνισης στο διάστημα 250 με 500 m³. Το Average height floor παρουσιάζει τιμές μεταξύ 2 και 3 m με ελάχιστα δείγματα να ξεπερνούν κατά έως 1 περίπου μέτρο (εξαιρουμένου του outlier που προαναφέρθηκε).

Αναφορικά με την ενεργειακή κατανάλωση τόσο η συνολική (Energy consumption before) όσο και η σχετική με την θέρμανση (Heat energy consumption before) μοιράζονται σχεδόν ίδια κατανομή, το οποίο γίνεται εμφανές τόσο από τα ιστογράμματα όσο και από το Σχήμα 3.6 με την ακριβή συνάρτηση κατανομής των δύο στηλών. Συνεπώς, η συνύπαρξη και των δύο χαρακτηριστικών δεν προσδίδει σπουδαία επιπρόσθετη πληροφορία. Το παραπάνω μπορεί να αποτελέσει και ένδειξη ότι το μεγαλύτερο μέρος της κατανάλωσης προέρχεται από τις διαδικασίες θέρμανσης.



Σχήμα 3.6: Κατανομές Energy consumption before, Heat energy consumption before

Παρατηρούμε ακόμα ότι οι τιμές του Heat energy consumption before βρίσκονται πε-

ρίπου μεταξύ 60 και 200 kWh/m² κατά πλειοψηφία, με λιγότερες τιμές να ξεπερνούν τα 400 kWh/m². Το Heat energy consumption after αντίθετα έχει σχεδόν όλες του τις τιμές κάτω από 100 kWh/m² με ελάχιστες εξαιρέσεις, κάτι το οποίο καταδεικνύει ότι τα εφαρμοσμένα μέτρα πέτυχαν μείωση της συγκεκριμένης κατανάλωσης στο σύνολο των κτηρίων. Παρατηρούμε επιπλέον ότι μετά την θέρμανση η κατανάλωση που ακολουθεί αφορά το ζεστό νερό (Consumption for hot water after) και έπειτα την ψύξη (Consumption for cooling after) με χαμηλές ωστόσο τιμές. Ακόμη χαμηλότερη κατανάλωση απαιτείται για τον μηχανικό εξαερισμό (Consumption for mechanical ventilation after) και τέλος σχεδόν μηδενική κατανάλωση στο μεγαλύτερο μέρος των κτηρίων για τον φωτισμό (Consumption for lighting after). Όσον αφορά την συνολική ενέργεια που καταναλώνεται μετά τα μέτρα Energy consumption after παρουσιάζεται και αυτή ιδιαίτερα ελαττωμένη με μέγιστη τιμή πλέον τα 165 kWh/m². Παρόμοια μείωση υποδεικνύεται και για τις εκπομπές διοξειδίου του άνθρακα μέσω των αποτελεσμάτων των Carbon dioxide emissions after και Carbon dioxide emissions before.


3.3.2 Συσχέτιση χαρακτηριστικών

Εξίσου σημαντικές για μελέτη προβάλλονται και οι σχέσεις που προκύπτουν μεταξύ των χαρακτηριστικών, οι οποίες πέρα των αρχικών παρατηρήσεων που προηγήθηκαν δύνανται να αποτυπωθούν μέσω της συσχέτισής τους. Υπολογίζεται λοιπόν η συσχέτιση (correlation) και αναπαρίσταται στο heatmap του Σχήματος 3.7. Αυτό αφορά συγκεκριμένα όλες τις αριθμητικές στήλες (εκτός των Energy factors, οι οποίοι εξετάζονται στην συνέχεια) αλλά και τις Initial energy class, Energy class after καθώς μπορούν να κωδικοποιηθούν αριθμητικά λόγω της κατάταξης που συμβολίζουν οι τιμές τους (A:1, B:2 κ.ο.κ.). Συνεπώς, θετική/αρνητική τιμή σημαίνει θετική/αρνητική συσχέτιση με την τέλεια συσχέτιση να λαμβάνει τιμές 1/-1, ενώ μηδενική τιμή σημαίνει καμία συσχέτιση. Ο χρωματικός κώδικας διευκολύνει την κατανόηση του διαγράμματος, αφού τα θερμά χρώματα συμβολίζουν υψηλότερη συσχέτιση ενώ τα ψυχρά χαμηλότερη.

Καθίσταται εμφανές ότι το Reference area έχει υψηλή συσχέτιση με τα Room volume και Building Total Area, τα οποία σαφώς είναι και μεταξύ τους συσχετιζόμενα. Τα τρία αυτά χαρακτηριστικά συσχετίζονται επίσης με το Area of external surface. Όλα τα παραπάνω αναφέρονται στον χώρο του κτηρίου με διαφορετικό τρόπο και πιθανώς είναι περιττή η ταυτόχρονη χρήση τους. Από την άλλη, η συσχέτιση της αρχικής συνολικής κατανάλωσης με την αρχική θερμική είναι σχεδόν ίση με 1. Τα παραπάνω επιβεβαιώνουν τα συμπεράσματα στα οποία καταλήξαμε και οπτικά μέσω των επιμέρους διαγραμμάτων στο προηγούμενο στάδιο.

Μεγάλη συσχέτιση υπάρχει ακόμη μεταξύ των Energy consumption before, Heat energy consumption before με τα Heat saving for heating, Total energy consumption saving και Saving of heat energy. Αυτό είναι αναμενόμενο καθώς οι τελευταίες στήλες υπολογίζονται από τις στήλες που αφορούν την κατανάλωση (πριν και μετά). Έτσι, δεν προσδίδουν σημαντικά στοιχεία που δεν είναι ήδη γνωστά από τα αρχικά χαρακτηριστικά και αποτελούν απλώς δείκτες της βελτίωσης που επήλθε.

Μία επιπλέον δικαιολογημένη συσχέτιση είναι αυτή μεταξύ των Carbon dioxide emission



Σχήμα 3.7: Heatmap συσχέτισης χαρακτηριστικών


tons after και Carbon dioxide emission after, καθώς αναφέρονται στο ίδιο ποσό μετρημένο διαφορετικά, δηλαδή συνολικά σε τόνους CO₂ ανά έτος και σε κιλά ανά τετραγωνικό μέτρο της συνολικής επιφάνειας του κτηρίου δηλαδή kg CO₂/m² ανά έτος. Συσχέτιση παρατηρείται και μεταξύ των Carbon dioxide emission after (και Carbon dioxide emission tons after) με το Carbon dioxide emission before. Οι κατανομές των εκπομπών πριν και μετά την εφαρμογή των μέτρων είναι παρόμοιες με τελικές τιμές προφανώς μειωμένες σε σχέση με τις αρχικές.

Επιπλέον, η συσχέτιση μεταξύ των Primary total energy consumption (after) και Energy consumption after δικαιολογείται από το γεγονός ότι η πρώτη περιλαμβάνει στην μέτρησή της, τις απώλειες ενέργειας κατά την μετατροπή και διανομή και υπολογίζεται αριθμητικά από την δεύτερη με χρήση των κατάλληλων συντελεστών.

Μικρότερες αλλά υπαρκτές συσχετίσεις παρατηρούνται επίσης μεταξύ των χαρακτηριστικών που αφορούν τους συντελεστές θερμότητας του κτηρίου (Building calculated heat loss coefficient κλπ.) με τα χαρακτηριστικά που αφορούν τον χώρο του κτηρίου (Building total area κλπ.). Τα τελευταία μάλιστα σχετίζονται σε ένα βαθμό και με τις καταναλώσεις ενέργειας πριν και κυρίως μετά. Τέλος, υπάρχει συσχέτιση και μεταξύ των ίδιων αυτών συντελεστών

(απώλειας και μεταφοράς θερμότητας).

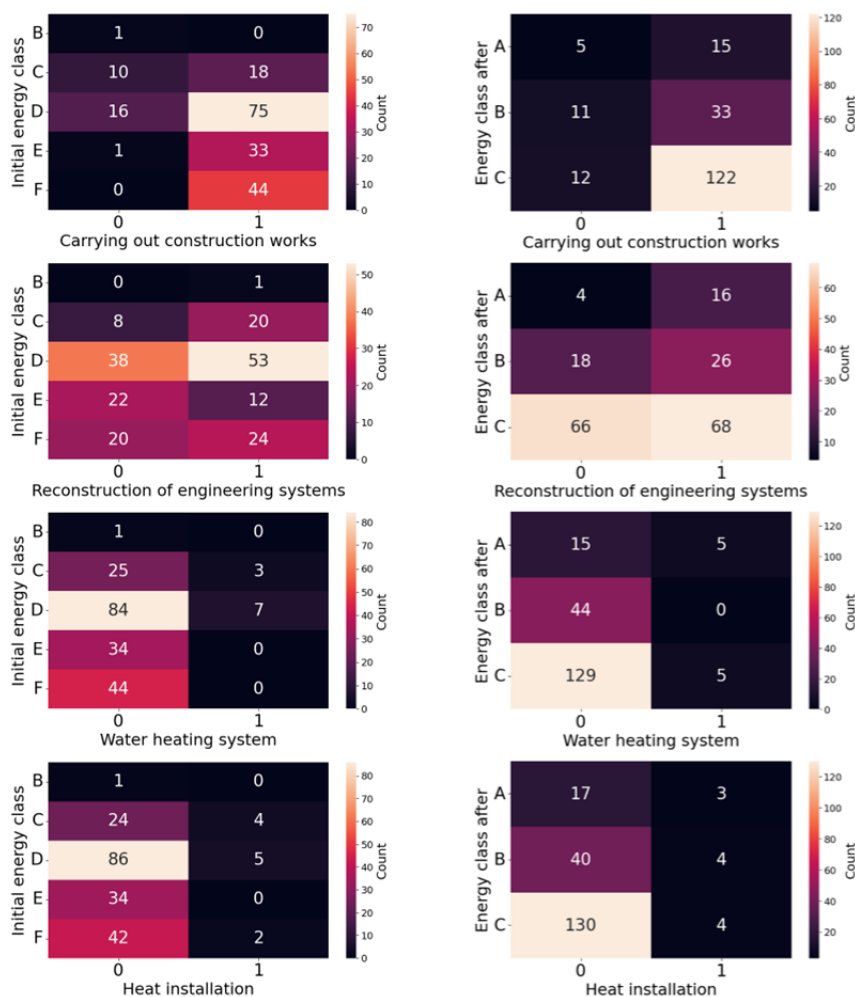
Η αρχική ενεργειακή κλάση του κτηρίου έχει υψηλή συσχέτιση με την ενεργειακή κατανάλωση (τόσο την συνολική όσο και την θερμική) πριν τα μέτρα, το οποίο είναι αναμενόμενο αφού η κλάση ενός σπιτιού βασίζεται εν μέρει στην ενεργειακή κατανάλωση. Παρόμοια συμπεράσματα ισχύουν και για τα τελικά αντίστοιχα χαρακτηριστικά. Οι ενεργειακές κλάσεις επιδρούν με πλήθος άλλων χαρακτηριστικών επίσης, τόσο ενεργειακών όσο και σχετικών με στοιχεία της μορφής του κτηρίου. Θα ήταν άρα μια εύλογη υπόθεση να πούμε ότι τα Initial energy class και Energy class after αποτελούν δύο σημαντικές μεταβλητές που περιέχουν χρήσιμες πληροφορίες και σαφώς βοηθούν στην αναγνώριση της ενεργειακής ταυτότητας των κτηρίων.



Σχήμα 3.8: Πίνακας συχνοτήτων αρχικών και τελικών ενεργειακών κλάσεων

Το Σχήμα 3.8 δείχνει το πλήθος των κτηρίων του συνόλου δεδομένων με βάση την κλάση στην οποία βρίσκονταν αρχικά και την κλάση που οδηγήθηκαν ύστερα από την ανακαίνιση. Γίνεται αντιληπτό ότι τα περισσότερα σπίτια κλάσης E ή F έλαβαν την κλάση C, ενώ ελάχιστα από αυτά κατέληξαν στις κλάσεις A και B. Η πλειοψηφία της κλάσης D εξελίχθηκε σε C, ένα μικρότερο ποσοστό σε B και μόνο 3 από αυτά σε A. Η κλάση C μετατράπηκε σχεδόν ισόποσα σε A και B και τέλος το μοναδικό κτήριο που βρισκόταν εξ αρχής στην κλάση B έλαβε την ετικέτα της κλάσης A. Παρατηρούμε ότι δεν υπάρχουν δείγματα αντιπροσωπευτικά για όλες τις εφικτές μεταβάσεις, ενώ για ορισμένες το πλήθος είναι ιδιαίτερα μικρό (μέχρι και 1-2 δείγματα). Έτσι, όποιο μοντέλο αναπτυχθεί με αυτά τα δεδομένα δεν θα έχει συναντήσει επαρκώς όλους τους πιθανούς συνδυασμούς τους οποίους ενδέχεται να αντιμετωπίσει κατά την λειτουργία του.

Χρήσιμες πληροφορίες προσφέρει και μια πιο ενδελεχής ανάλυση για την επίδραση των διαφόρων χαρακτηριστικών στις τελικές κλάσεις, δηλαδή στα Carrying out construction works, Reconstruction of engineering systems, Heat installation και Water heating system. Στο Σχήμα 3.9 φαίνεται πώς τα κτήρια της κάθε ενεργειακής κλάσης ταξινομούνται σχετικά με το αν λαμβάνουν ή όχι το κάθε μέτρο αναβάθμισης. Τα αποτελέσματα αυτά αντικατοπτρίζουν τις




Σχήμα 3.9: Πίνακας συχνότητων συνδυασμών ενεργειακών κλάσεων και μέτρων αναβάθμισης

επιμέρους κατανομές των τεσσάρων στηλών όπως παρουσιάστηκαν προηγουμένως. Δηλαδή το Carrying out construction works υλοποιήθηκε από τα περισσότερα σπίτια, μάλιστα για τις χαμηλότερες κλάσεις εφαρμόζεται σχεδόν σε όλα. Το Reconstruction of engineering systems μοιράζεται τόσο στην εφαρμογή όσο και στην μη εφαρμογή του, ενώ για τα τελευταία δύο τα αποτελέσματα δεν μπορούν να είναι ξεκάθαρα καθώς τα σπίτια στα οποία εφαρμόστηκαν είναι πολύ λίγα.

Για την αντίστοιχη εξέταση των κατηγορικών χαρακτηριστικών γίνεται χρήση της μεθόδου Cramer's V η οποία βασίζεται στον Chi-square στατιστικό έλεγχο, ο οποίος αξιολογεί την ύπαρξη σχέσης μεταξύ των μεταβλητών λαμβάνοντας υπόψη την συχνότητα εμφάνισης των αντίστοιχων τιμών. Οι τιμές που προκύπτουν είναι κανονικοποιημένες στο εύρος 0-1 όπου το 0 υποδηλώνει πως δεν υπάρχει καμία συσχέτιση ενώ το 1 υψηλά συσχετιζόμενες μεταβλητές.

Στο Σχήμα 3.10 φαίνονται οι Cramer's V συσχετίσεις των χαρακτηριστικών των ενεργειακών πηγών που χρησιμοποιούνται για τα επιμέρους συστήματα. Τιμές μεγαλύτερες του 0.7 προκύπτουν για τα ζεύγη των πρώτων πηγών για θέρμανση και ζεστό νερό, των δεύτερων αντίστοιχων πηγών και του εξαερισμού με την πρώτη πηγή ψύξης. Για 7 ακόμα ζεύγη παρα-

τηρείται τιμή μεγαλύτερη του 0.5, ενώ γενικά η ελάχιστη τιμή είναι 0.23 και η μέγιστη 0.86. Συνεπώς φαίνεται να υπάρχει κάποια σχέση μεταξύ των διαφόρων πηγών ενέργειας των κτηρίων. Παρ' όλα αυτά πρέπει να σημειωθεί ότι οι συγκεκριμένες στήλες παρουσιάζουν μεγάλο πλήθος τιμών '-' και άρα άγνωστων τιμών. Επομένως, οι σχέσεις που προκύπτουν βασίζονται σε λίγα δεδομένα και δεν είναι απαραίτητα αντιπροσωπευτικές της πραγματικότητας.




Σχήμα 3.10: Heatmap Cramer's V συσχετίσεων των energy resources χαρακτηριστικών

Ένα μεγάλο μέρος των χαρακτηριστικών του συνόλου δεδομένων αποτελούν οι συντελεστές πρωταρχικής ενέργειας και οι συντελεστές εκπομπών (energy factors) και συγκεκριμένα οι ανανεώσιμοι, μη ανανεώσιμοι, εκπομπών διοξειδίου του άνθρακα και συνολικοί συντελεστές για θέρμανση, ζεστό νερό, εξαερισμό και ψύξη. Σχετίζονται με την εκάστοτε πηγή ενέργειας που χρησιμοποιείται στο αντίστοιχο σύστημα (αντίστοιχα χαρακτηριστικά Energy resources) και ορίζονται με βάση τον κανονισμό για υπολογισμό της ενεργειακής αποδοτικότητας κτηρίων στην Λετονία ². Συνεπώς για κάθε πηγή ενέργειας αναμένεται συγκεκριμένη τιμή των αντίστοιχων συντελεστών, η οποία σε ορισμένες περιπτώσεις των δεδομένων είναι ωστόσο διαφορετική.

Πιο αναλυτικά, για παράδειγμα για το CO₂ emission factor ως προς κάθε πηγή ενέργειας λαμβάνουμε το Σχήμα 3.11. Είναι φανερό πως παρά το γεγονός ότι στις περισσότερες περιπτώσεις η αντιστοίχιση σέβεται τα πρότυπα και παρατηρούμε ομοιομορφία, υπάρχουν λίγες εξαιρέσεις. Για παράδειγμα, το gas στην πλειοψηφία των δειγμάτων έχει συντελεστή 202 ο


²<https://likumi.lv/ta/id/322436#piel6>



Σχήμα 3.11: Κατανομές χαρακτηριστικών energy resources συνδυαστικά με energy factors

οποίος ορίζεται από τον κανονισμό. Ωστόσο υπάρχουν μερικά δείγματα με τιμές 1.1 και 56.1. Καταληκτικά, και πάλι βλέπουμε ότι οι συντελεστές συνδέονται ως επί το πλείστον με τις ενεργειακές πηγές.

Ένα άλλο συμπέρασμα που συνάδει με την γενική γνώση είναι ότι πηγές όπως γεωθερμική ενέργεια, ηλιακή κλπ έχουν μηδενικούς συντελεστές. Αυτό σημαίνει πως οι ανανεώσιμες πηγές ενέργειας σίγουρα βελτιώνουν την ενεργειακή αποδοτικότητα των κτηρίων και θα έπρεπε να αποτελούν μία από τις επικρατέστερες επιλογές. Από την άλλη ορυκτά καύσιμα όπως το φυσικό αέριο και ο άνθρακας έχουν μεγάλες τιμές συντελεστή εκπομπής CO₂ (με τις προηγούμενες εξαιρέσεις). Για αυτό άλλωστε στα μέτρα αναβάθμισης εμπεριέχεται η αντικατάσταση των πηγών με άλλες ανανεώσιμες για το σύστημα θέρμανσης το οποίο πραγματοποιεί την μέγιστη κατανάλωση με βάση τα δεδομένα.




Σχήμα 3.12: Heatmap συσχετίσεων των energy resources με τα energy factors

Υπολογίζοντας στο Σχήμα 3.12 τις τιμές μεταξύ των χαρακτηριστικών energy resources με τα energy factors επιβεβαιώνεται η αναμενόμενη λόγω του τρόπου ορισμού τους μεγάλη συσχέτιση (έως και σχεδόν 1). Αντίστοιχα είναι δυνατόν να προκύψει ότι η συσχέτιση μεταξύ των διαφορετικών συντελεστών για το ίδιο σύστημα είναι υπαρκτή, καθώς η εκπομπή CO₂ (CO₂ emission factors) σχετίζεται με το αν η πηγή είναι ανανεώσιμη ή όχι (Renewable, Non-renewable factors). Κατ' αντιστοιχία ο συνολικός συντελεστής (Total factors) προκύπτει ως άθροισμα των τελευταίων δύο.


Όπως διαπιστώθηκε κατά την προεπεξεργασία, τα χαρακτηριστικά αυτά παρουσιάζουν μεγάλο πλήθος κενών τιμών το οποίο αγγίζει και ποσοστά μεταξύ 65% και 95% εξαιρουμένων των περιπτώσεων των πρώτων ενεργειακών πηγών για θέρμανση και ζεστό νερό. Έτσι για παράδειγμα η περίπτωση εξαίρεσης από το Σχήμα 3.12 της δεύτερης πηγής για ψύξη, όπου οι τιμές δεν είναι υψηλές πιθανώς οφείλεται στον ελάχιστο αριθμό μη κενών τιμών στις συγκεκριμένες στήλες. Επομένως μπορούμε να οδηγηθούμε στο συμπέρασμα ότι δεν διαθέτουμε αρκετές πληροφορίες ώστε να εξαγάγουμε εύρωστα μεμονωμένα χρήσιμα συμπεράσματα για τα παραπάνω.

Τέλος, επιπλέον αποτελέσματα παρουσιάζονται στο Σχήμα 3.13 όπου εξετάζονται οι σχέσεις των χαρακτηριστικών Region, The town/village και County/City τόσο μεταξύ τους όσο και με κάποια από τα χαρακτηριστικά που περιγράφουν την μορφή των κτηρίων. Γίνεται αντιλη-



Σχήμα 3.13: Heatmap συσχετίσεων χαρακτηριστικών της περιοχής

πτή η ύπαρξη κάποιας σχέσης μεταξύ των στηλών που αναφέρονται στην τοποθεσία, όπως και θα περιμέναμε. Επιπλέον, μικρότερες αλλά όχι αμελητέες σχέσεις υπάρχουν και σε ορισμένους από τους υπόλοιπους συνδυασμούς. Για την περαιτέρω κατανόησή τους παρατίθενται τα επόμενα ενδεικτικά διαγράμματα στο Σχήμα 3.14 τα οποία απεικονίζουν την κατανομή του Underground floor υπό συνθήκη ως προς το County/City.



Σχήμα 3.14: Γράφημα Underground floor υπό συνθήκη County/City

Αναλυτικότερα, το πρώτο περιλαμβάνει τις τιμές County οι οποίες έχουν πάνω από 1 δείγμα στο σύνολο δεδομένων, ενώ το δεύτερο τις τιμές για τις οποίες υπάρχει ένα ακριβώς δείγμα. Στις τελευταίες βλέπουμε ότι τα περισσότερα κτήρια διαθέτουν υπόγειο. Επίσης παρατηρούμε

ότι για αρκετές περιοχές υπάρχουν κτήρια και των δύο ειδών με την πλειοψηφία να διαθέτει περισσότερα κτήρια χωρίς υπόγειο. Στις περιοχές με αποκλειστικά ύπαρξη ή μη υπογείου σε όλα τα σπίτια υπερτερεί η μη ύπαρξη. Με βάση τα παραπάνω, ανά County/City υπάρχει ένα είδος σχέσης της ύπαρξης ή μη Underground floor. Αντίστοιχα συμπεράσματα μπορούν να εξαχθούν και για τα υπόλοιπα χαρακτηριστικά που διαθέτουν αντίστοιχες κατανομές και παρουσίασαν μη αμελητέα συσχέτιση.

3.4 Σύνοψη ιδιαιτεροτήτων του συνόλου δεδομένων

Έπειτα από την διερευνητική ανάλυση των δεδομένων που προηγήθηκε καθίσταται σαφές ότι το σύνολο δεδομένων παρουσιάζει ορισμένες ιδιαιτερότητες, τις οποίες οφείλουμε να αντιμετωπίσουμε προκειμένου να εξασφαλίσουμε τα επιθυμητά αποτελέσματα στην μετέπειτα πορεία.

Αρχικά το πλήθος των δειγμάτων που περιλαμβάνονται στο σύνολο δεδομένων είναι αρκετά μικρό (λιγότερα από 200 δείγματα). Ως αποτέλεσμα δεν επαρκεί ώστε ένα μοντέλο να εκπαιδευτεί κατάλληλα σε αυτό και να αναπτύξει ικανοποιητική δυνατότητα γενίκευσης.

Δεύτερο και κύριο πρόβλημα είναι ότι οι κλάσεις στις οποίες γίνεται η ταξινόμηση είναι ιδιαίτερα ανισόρροπες (class imbalance). Με άλλα λόγια, το πλήθος των δειγμάτων που λαμβάνουν την τιμή 1 για μία κλάση είναι σημαντικά μικρότερο από αυτών που λαμβάνουν την τιμή 0. Μάλιστα σε δύο από τις τέσσερις κλάσεις (Water heating system, Heat installation) η αναλογία των ετικετών 0 και 1 είναι σχεδόν 95% - 5%. Η τιμή 1, η οποία υποαντιπροσωπεύεται, αποτελεί και την ετικέτα μεγαλύτερου ενδιαφέροντος καθώς ορίζει την εφαρμογή του συγκεκριμένου μέτρου. Η κλάση Carrying out construction works) με την σειρά της αγγίζει το ποσοστό 85% υπέρ της τιμή 1 παρέχοντας λιγότερα δείγματα στα οποία δεν προτείνεται η εφαρμογή του μέτρου αυτού. Αυτές οι αποκλίσεις αποτελούν ιδιαίτερο ζήτημα, καθώς το μοντέλο μηχανικής μάθησης που θα εκπαιδευτεί σε αυτά θα πάσχει από μεροληψία υπέρ της ετικέτας με το μεγαλύτερο ποσοστό δειγμάτων. Απαιτείται συνεπώς εξισορρόπηση των δεδομένων ώστε το μοντέλο να μπορεί να αποκτήσει την δυνατότητα να γενικεύει και να προβλέπει ορθά και τις δύο περιπτώσεις όλων των κλάσεων.

Τα παραπάνω μπορούν να αντιμετωπιστούν με την κατάλληλη αύξηση και εμπλουτισμό των δεδομένων. Για τον σκοπό αυτό οδηγούμαστε στην μελέτη και εφαρμογή της παραγωγής συνθετικών δεδομένων. Επιπλέον αξίζει η μελέτη της προσθήκης νέων πραγματικών δεδομένων αντίστοιχης λογικής με διαφορετική ωστόσο προέλευση και κατανομή, το οποίο επίσης μελετάμε στην πορεία της διπλωματικής εργασίας.

Επιπρόσθετα, ορισμένα από τα χαρακτηριστικά του συνόλου παρουσιάζουν έλλειψη ορισμένων καταστάσεων τους, όπως ο συνδυασμός της αρχικής και τελικής ενεργειακής κλάσης που επεξηγήθηκε αναλυτικά. Τα δεδομένα εκπαίδευσης δεν αποτελούν λοιπόν αντιπροσωπευτικό δείγμα για τις περιπτώσεις πιθανώς να κληθεί να αντιμετωπίσει το τελικό σύστημα. Έτσι, κρίνεται σκόπιμο να εξεταστεί η εισαγωγή για παράδειγμα νέων χαρακτηριστικών συνδυάζοντας τα υφιστάμενα, που θα προσδίδουν μια διαφορετική οπτική στο πρόβλημα ωθώντας το μοντέλο να «κατανοήσει» καλύτερα τα υπάρχοντα μοτίβα.

Τέλος, εγείρεται η ανάγκη περαιτέρω μελέτης των χαρακτηριστικών ως προς την σημαντικότητά τους και την συμβολή που μπορούν να επιτύχουν στις προβλέψεις. Στόχο αποτελεί η επιλογή μόνο των απαραίτητων και ουσιωδών για την περίπτωση χαρακτηριστικών από το αρκετά μεγάλο πλήθος τους. Σε αυτό (και όχι μόνο) συμβάλλει η ανάλυση που πραγματοποιείται ακολούθως με εργαλεία επεξηγήσιμης τεχνητής νοημοσύνης η οποία αναδεικνύει την σημαντικότητά τους.

Κεφάλαιο 4

Ανάλυση επεξηγησιμότητας (explainability)

4.1 Επεξηγήσιμη τεχνητή νοημοσύνη

Ο όρος Επεξηγήσιμη τεχνητή νοημοσύνη ή αλλιώς Explainable artificial intelligence (XAI) αφορά στις μεθόδους που αποσκοπούν στην επεξήγηση των αποφάσεων που λαμβάνονται από μοντέλα τεχνητής νοημοσύνης και μηχανικής μάθησης. Τα μοντέλα αυτά λειτουργούν ως «μαύρα κουτιά» (black boxes) εξάγοντας τα αποτελέσματά τους χωρίς να διευκρινίζουν τον τρόπο με τον οποίο αυτά προέκυψαν. Προκειμένου να εξασφαλιστεί η διαφάνεια και η αξιοπιστία των προβλέψεων, κρίνεται σημαντική η εφαρμογή των κατάλληλων εργαλείων επεξήγησης, ώστε ο/η χρήστης/ρια να μπορέσει να κατανοήσει την απόφαση του αλγορίθμου και να την ελέγξει. Έτσι μπορούν να αποτραπούν πιθανοί κίνδυνοι από λανθασμένες αυθαίρετες επιλογές και να αναπτυχθούν ηθικά συστήματα τεχνητής νοημοσύνης σεβόμενα το σχετικό νομικό πλαίσιο που έχει οριστεί.

Παράλληλα, οι μέθοδοι επεξηγησιμότητας διαδραματίζουν σπουδαίο ρόλο και στην δημιουργία των συστημάτων αυτών, καθώς είναι δυνατόν να εντοπιστούν λάθη και μεροληπτικές συμπεριφορές των μοντέλων όπως και οι πηγές αυτών. Η ανάλυση των δεδομένων επίσης διευκολύνεται, αφού αναδεικνύεται η επίδραση κάθε χαρακτηριστικού στο αποτέλεσμα και οι μεταξύ τους σχέσεις. Καθίσταται, άρα, εύκολη η αναγνώριση πιθανών ιδιαιτεροτήτων των δεδομένων, όπως περιττά χαρακτηριστικά, μη εμφανείς αλληλεπιδράσεις τους και επαναπροσδιορίζεται η σημαντικότητά τους.

Οι μέθοδοι επεξήγησης μπορούν να ταξινομηθούν όπως παρουσιάζεται στην συνέχεια [29]:


- **Intrinsic/Post hoc:** Η εγγενής (intrinsic) επεξηγησιμότητα αναφέρεται σε μοντέλα που μπορούν να θεωρηθούν ερμηνεύσιμα λόγω της απλής δομής τους, όπως τα μικρά δέντρα απόφασης. Αντίθετα, η εκ των υστέρων (post hoc) αφορά μεθόδους που εφαρμόζονται έπειτα από την εκπαίδευση του εκάστοτε μοντέλου.
- **Model-specific/Model-agnostic:** Στην πρώτη κατηγορία εμπίπτουν οι μέθοδοι που αφορούν κάποιο συγκεκριμένο μοντέλο, για παράδειγμα η ερμηνεία των βαρών ενός γραμ-

μικού μοντέλου. Από την άλλη, τα model-agnostic εργαλεία χρησιμοποιούνται ανεξαρτήτως μοντέλου και αναλύουν ζεύγη εισόδου-εξόδου δηλαδή δεδομένων και προβλέψεων.

- Local/Global: Η τοπική (local) επεξήγηση σχετίζεται με μεμονωμένες προβλέψεις, ενώ η καθολική (global) με το μοντέλο ως σύνολο και αφορά όλες τις προβλέψεις που αυτό παρέχει.

4.2 Shapley additive explanations

Η μέθοδος SHAP (SHapley Additive exPlanations) [31] αποτελεί μία από τις πιο εδραιωμένες μεθόδους επεξηγησιμότητας. Συγκεκριμένα πρόκειται για ένα model-agnostic εργαλείο (με προσεγγιστικές model-specific παραλλαγές), το οποίο αναλύει ζευγάρια εισόδου-εξόδου μοντέλων και υπολογίζει την συνεισφορά κάθε χαρακτηριστικού στην τελική πρόβλεψη, όπως φαίνεται στο Σχήμα 4.1.



Σχήμα 4.1: Μέθοδος SHAP ¹

Βασίζεται στις shapley τιμές της θεωρίας παιγνίων, όπου παίκτες συνεργάζονται και λαμβάνουν μία ανταμοιβή από αυτή την συνεργασία, η οποία αποτελεί δίκαιη κατανομή του συνολικού κέρδους αναλόγως την συνεισφορά κάθε παίκτη σε αυτό. Αντιστοιχίζονται, δηλαδή, οι παίκτες με τα χαρακτηριστικά και η ανταμοιβή με την πρόβλεψη [29]. Ειδικότερα η τιμή shapley αφορά την συμβολή κάθε χαρακτηριστικού στην διαφορά μεταξύ της πραγματικής τιμής πρόβλεψης και της μέσης τιμής πρόβλεψης. Η τιμή shapley για το χαρακτηριστικό i υπολογίζεται ως το σταθμισμένο άθροισμα της συνεισφοράς του i ως προς όλους τους πιθανούς συνδυασμούς των χαρακτηριστικών με βάση την σχέση 4.1:

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|!(|F| - |S| - 1)!}{|F|!} [f_{S \cup \{i\}}(x_{S \cup \{i\}}) - f_S(x_S)] \quad (4.1)$$

¹Πηγή: [30]


όπου το S συμβολίζει κάθε πιθανό υποσύνολο των χαρακτηριστικών που δεν περιλαμβάνει το i με μέγεθος $|S|, |F|$ είναι το συνολικό πλήθος όλων των χαρακτηριστικών, $f_{S \cup \{i\}}(x_{S \cup \{i\}})$ είναι η πρόβλεψη του μοντέλου όταν χρησιμοποιούνται τα χαρακτηριστικά του συνόλου S και το i είναι παρόν, ενώ $f_S(x_S)$ είναι η πρόβλεψη όταν το i απουσιάζει.

Η μέθοδος SHAP αναπαριστά τις επεξηγήσεις μέσω των shapley τιμών ως ένα απλούστερο γραμμικό μοντέλο επεξήγησης, προσέγγιση του αρχικού (additive feature attribution), που ορίζεται από την σχέση 4.2:

$$g(z') = \phi_0 + \sum_{j=1}^M \phi_j z'_j \quad (4.2)$$

όπου g το μοντέλο επεξήγησης, M το πλήθος των χαρακτηριστικών, $z' \in \{0, 1\}^M$ τα απλοποιημένα χαρακτηριστικά εισόδου με τιμή 1 να υποδηλώνει ότι το αντίστοιχο χαρακτηριστικό είναι παρόν και τιμή 0 ότι απουσιάζει (με βάση την ερμηνεία των shapley values) και ϕ_j η shapley τιμή του χαρακτηριστικού j (feature attribution) (η ϕ_0 αφορά την περίπτωση που δεν είναι παρόν κανένα χαρακτηριστικό).

Καταληκτικά, οι τιμές shap δείχνουν την μεταβολή της πρόβλεψης του μοντέλου υπό συνθήκη της τιμής του αντίστοιχου χαρακτηριστικού. Επεξηγούν πώς οδηγείται το μοντέλο στην τρέχουσα έξοδο από την αναμενόμενη (base value), την οποία θα προέβλεπε αν δεν ήταν γνωστό κανένα χαρακτηριστικό, αθροίζοντας σε αυτήν όλες τις τιμές shap. Ένα παράδειγμα αυτής της διαδικασίας παρουσιάζεται στο Σχήμα 4.2 [31]. Αν το μοντέλο δεν είναι γραμμικό, ή τα χαρακτηριστικά δεν είναι ανεξάρτητα, τότε η σειρά με την οποία αθροίζονται έχει σημασία και οι τιμές shap προκύπτουν από τον μέσο όρο των ϕ_i για όλες τις πιθανές διατάξεις των χαρακτηριστικών.



Σχήμα 4.2: Υπολογισμός SHAP: prediction = base value + sum(SHAP values) ²

Όσο μεγαλύτερη είναι η απόλυτη τιμή της shap τιμής για κάποιο χαρακτηριστικό, τόσο μεγαλύτερη επιρροή ασκεί το συγκεκριμένο στην πρόβλεψη της εξόδου. Πιο αναλυτικά, θετικές shap τιμές επιδρούν θετικά στην πρόβλεψη οδηγώντας σε υψηλότερες τιμές εξόδου και αρνητικές shap τιμές επιδρούν αρνητικά και οδηγούν σε χαμηλότερες τιμές εξόδου. Στην περίπτωση της ταξινόμησης, αναφερόμαστε στις ετικέτες 1 και 0 αντίστοιχα. Καθίσταται τελικά προφανές ότι εάν ένα χαρακτηριστικό παρουσιάζει μεγαλύτερες shap τιμές είναι πιο σημαντικό από τα υπόλοιπα.

²Πηγή: [31]

4.3 Εφαρμογή μεθόδου

Ακολουθώντας, εφαρμόζουμε την μέθοδο SHAP στο σύνολο δεδομένων ενεργειακής αναβάθμισης κτηρίων της Λετονίας. Μέσω των επεξηγήσεων είμαστε σε θέση να κατανοήσουμε σε βάθος τις σχέσεις και την σημασία των χαρακτηριστικών που συμβάλλουν στην επιλογή των μέτρων βελτιστοποίησης. Για την υλοποίηση χρησιμοποιήθηκε η βιβλιοθήκη shap της python και το μοντέλο με το οποίο πραγματοποιήθηκε η μελέτη είναι ένα νευρωνικό δίκτυο πολλαπλών επιπέδων και αναλύεται περαιτέρω στο Κεφάλαιο 5.1.

Feature	Description	Unit	Type
Region	Region of the building	-	Categorical
The town/village	Town/Village of the building	-	Categorical
County/City	County/city of the building	-	Categorical
Initial year of exploitation	Year the building was first used	-	Numerical
Building Total Area	Total area of the building	m ²	Numerical
Room volume	Volume of rooms	m ³	Numerical
Average floor height	Average height of floors	m	Numerical
Reference area	Heated area	m ²	Numerical
Above-ground floors	Number of floors above ground	-	Numerical
Underground floor	Existence of underground floor	-	Boolean
Mansard	Existence of mansard (roof with 4 sloping sides)	-	Boolean
Roof floor	Existence of roof floor	-	Boolean
Initial energy class	Energy class before retrofit	-	Categorical
Energy consumption before	Energy consumption before retrofit	kWh/m ²	Numerical
Energy class after	Energy class after retrofit	-	Categorical

Πίνακας 4.1: Περιγραφή αρχικά επιλεγμένων χαρακτηριστικών

Ένα ακόμη βήμα αποτελεί η επιλογή των χαρακτηριστικών που θα συμπεριληφθούν στο μοντέλο και συνεπώς στην ανάλυση. Όπως έγινε εμφανές στο προηγούμενο κεφάλαιο, τα χαρακτηριστικά του συνόλου δεδομένων περιλαμβάνουν πλήθος διαφορετικών στοιχείων που περιγράφουν διάφορες πτυχές των κτηρίων και της ενεργειακής συμπεριφοράς αυτών. Ωστόσο, σκοπός μας είναι η ανάπτυξη ενός μοντέλου στο οποίο ο/η χρήστης/ρια θα εισάγει τα στοιχεία του δικού του σπιτιού και θα λαμβάνει τις κατάλληλες προτάσεις ενεργειακής αναβάθμισης. Γι'αυτό πρέπει να επιλεχθούν μόνο τα χαρακτηριστικά που είναι εύκολα προσβάσιμα και γνωστά στον ιδιοκτήτη. Με άλλα λόγια, ο/η χρήστης/ρια δεν γνωρίζει πάντα τις πλήρεις λεπτομέρειες κατασκευής του κτηρίου όπως για παράδειγμα ειδικούς συντελεστές θερμότητας. Επιπρόσθετα, ένας μεγάλος αριθμός των στηλών του συνόλου αναφέρεται στο κτήριο ύστερα από την υλοποίηση των επιλεγμένων κάθε φορά μέτρων. Ο/η χρήστης/ρια, λοιπόν, δεν μπορεί (και δεν χρειάζεται συνήθως) να προσδιορίσει αναλυτικά την κάθε πτυχή της τελικής


κατανάλωσης και κατασκευής. Ο στόχος μπορεί να καθοριστεί από πιο γενικά στοιχεία όπως η επιθυμητή ενεργειακή κλάση που θα αποκτήσει τελικά το κτήριο. Λόγω των παραπάνω και έπειτα από την ανάλυση της ερμηνείας των στηλών η επιλογή των αρχικών χαρακτηριστικών φαίνεται στον Πίνακα 4.1.

4.4 Καθολικές επεξηγήσεις

Ξεκινώντας εξετάζουμε τις καθολικές επεξηγήσεις των προβλέψεων αποτυπώνοντας την επίδραση κάθε χαρακτηριστικού ως προς το σύνολο των δειγμάτων του συνόλου δεδομένων. Στο Σχήμα 4.3 παρατίθενται τα summary plots για κάθε μία από τις κλάσεις Carrying out construction works, Reconstruction of engineering systems, Heat installation και Water heating system, τα οποία οπτικοποιούν τις κατανομές των τιμών shap όλων των χαρακτηριστικών. Στα συγκεκριμένα διαγράμματα βλέπουμε στον κάθετο άξονα τα χαρακτηριστικά ταξινομημένα με βάση την μέση απόλυτη τιμή των shap τιμών τους, δηλαδή την μέση επίδρασή τους στο σύνολο των δειγμάτων. Έτσι, πιο ψηλά στο διάγραμμα συναντάται το χαρακτηριστικό με την μεγαλύτερη τιμή shap, το οποίο αποτελεί το σημαντικότερο χαρακτηριστικό για την πρόβλεψη. Στον οριζόντιο άξονα οι κουκίδες αναπαριστούν τις shap τιμές κάθε δείγματος των δεδομένων. Τέλος, το χρώμα κάθε σημείου αντιπροσωπεύει την τιμή του εκάστοτε χαρακτηριστικού στο δείγμα αυτό, όπου αποχρώσεις προς το μπλε υποδεικνύουν χαμηλή τιμή συγκριτικά με τα υπόλοιπα δείγματα ενώ προς το κόκκινο υψηλή τιμή.

Από το Σχήμα 4.3 λοιπόν παρατηρούμε ότι ως σημαντικότερα χαρακτηριστικά προκύπτουν τα The town/village, County/City, Region, ενώ λίγα από τα υπόλοιπα έχουν μικρή επίδραση. Αυτό αποκλίνει από τα αναμενόμενα αποτελέσματα, καθώς δεν θα περιμέναμε οι αποφάσεις για την εφαρμογή μέτρων ενεργειακής αναβάθμισης στα κτήρια να εξαρτώνται σε τόσο μεγάλο βαθμό από την περιοχή στην οποία βρίσκεται το κτήριο συγκριτικά με τα υπόλοιπα στοιχεία του. Πρέπει άρα να εξετάσουμε τον λόγο που το μοντέλο προτιμά αυτές τις στήλες ως κριτήρια. Μία πιθανή αιτία έγκειται στο γεγονός ότι τα χαρακτηριστικά αυτά εμφανίζουν πολλές διακριτές τιμές. Ιδιαίτερα τα δύο πρώτα παρουσιάζουν στα δεδομένα 122 και 68 διαφορετικές τιμές αντίστοιχα, τα οποία αποτελούν μεγάλο ποσοστό αν αναλογιστούμε ότι το συνολικό πλήθος ανέρχεται στα 198 δείγματα. Συνεπώς, αυτό σημαίνει πως δεν υπάρχουν αρκετά δεδομένα για να μάθει το μοντέλο ουσιαστικές σχέσεις από τα συγκεκριμένα χαρακτηριστικά και υπάρχει κίνδυνος υπερπροσαρμογής στα δεδομένα εκπαίδευσης, σε μοτίβα τα οποία δεν είναι δυνατόν να γενικευτούν. Είναι πιθανό επίσης να χρησιμοποιεί αυτά τα χαρακτηριστικά για να διαχωρίσει τις προβλέψεις με βάση τις διαφορετικές πολλαπλές τιμές. Συμπληρωματικά, η shap τιμή ενός χαρακτηριστικού αυξάνεται όταν αυτό αλληλεπιδρά με άλλα χαρακτηριστικά ή όταν βασίζεται στις τιμές τους και επηρεάζει τις προβλέψεις σε συνδυασμό με αυτά παρά μεμονωμένα. Όπως αναφέρθηκε κατά την ανάλυση των δεδομένων, υπάρχουν πράγματι σχέσεις των χαρακτηριστικών αυτών με άλλα και έτσι η πληροφορία που παρέχουν μπορεί να αποτυπωθεί από εκείνα. Οι τρεις στήλες που καθορίζουν την τοποθεσία έχουν ασφαλώς υψηλή συσχέτιση μεταξύ τους και γι' αυτόν τον λόγο η συνδυαστική τους επίδραση εντείνεται.

Δοκιμάζοντας λοιπόν να αφαιρέσουμε τις στήλες The town/village, County/City, Re-



Σχήμα 4.3: Summary plots ανά κλάση με τα αρχικά χαρακτηριστικά

gion παρατηρούμε ότι οι μετρικές του μοντέλου δεν παρουσιάζουν πολύ μεγάλες αποκλίσεις. Είτε αφαιρέσουμε μεμονωμένα κάποιο από τα χαρακτηριστικά τοποθεσίας είτε και τα τρία μαζί, η απόδοση μεταβάλλεται σε μικρό βαθμό είτε προς τα πάνω είτε προς τα κάτω ανάλογα την μετρική. Η εξαίρεσή τους από την διαδικασία ωφελεί και την δυνατότητα γενίκευσης του μοντέλου σε σύνολα δεδομένων που αφορούν άλλες χώρες, καθώς αναφέρονται σε συγκεκριμένες πόλεις και περιοχές της Λετονίας και περιορίζουν τις γνώσεις του μοντέλου στα όρια της χώρας. Αντίθετα, τα εναπομείναντα χαρακτηριστικά σχετίζονται με γενικές πληροφορίες που διαθέτει κάθε κτήριο και κάθε ιδιοκτήτης ανεξάρτητα από την γεωγραφική περιοχή.

Με εκ νέου εκπαίδευση του μοντέλου και υπολογισμό των τιμών shap στις υπόλοιπες επιλεγμένες στήλες των δεδομένων, τα ανανεωμένα summary plots που προκύπτουν απεικονίζονται στο Σχήμα 4.4. Αντιλαμβανόμαστε ότι τώρα οι τιμές shap έχουν αυξηθεί στην



Σχήμα 4.4: Summary plots ανά κλάση εξαιρουμένων των χαρακτηριστικών τοποθεσίας


πλειοψηφία των χαρακτηριστικών κι έτσι αυτά λαμβάνονται περισσότερο υπόψη στην πρόβλεψη της εξόδου.

Όσον αφορά τα σημαντικότερα χαρακτηριστικά, ένα από αυτά φαίνεται να είναι η αρχική ενεργειακή κλάση (Initial energy class), που μάλιστα βρίσκεται σε δύο περιπτώσεις κλάσεων στην κορυφή και σε μία στην δεύτερη θέση. Για παράδειγμα για το μέτρο Carrying out construction works του πρώτου διαγράμματος, οι πιο υψηλές τιμές του χαρακτηριστικού Initial energy class έχουν θετικές shap τιμές (δηλαδή τείνουν να δώσουν την τιμή 1) και οι πιο χαμηλές έχουν αρνητικές shap τιμές (δηλαδή τείνουν να δώσουν την τιμή 0). Η κωδικοποίηση του συγκεκριμένου κατηγορικού χαρακτηριστικού πραγματοποιήθηκε με label encoder, δηλαδή η κατάταξη των κλάσεων διατηρήθηκε αφού η αντιστοιχία ήταν A:1, B:2, C:3, D:4, E:5, F:6. Άρα εξάγουμε το συμπέρασμα ότι το μέτρο Carrying out construction works τείνει να εφαρμοστεί στα κτήρια με τις «χειρότερες» κλάσεις. Ένα από τα επίσης σημαντικά χαρακτηριστικά φαίνεται να είναι το Underground floor, το οποίο λαμβάνει τιμές 1 και 0 ανάλογα την ύπαρξη ή μη υπογείου. Έτσι από το πρώτο διάγραμμα μπορούμε να συμπεράνουμε ότι στα κτήρια με υπόγειο (υψηλές τιμές, δηλαδή 1) είναι πιο πιθανό να προβλεφθεί η εφαρμογή του μέτρου, ενώ

στα κτήρια που δεν διαθέτουν (χαμηλές τιμές, δηλαδή 0) ισχύει το αντίθετο. Αντίστοιχα το Above-ground floors παρατηρούμε ότι αποτελεί κυρίως ένα από τα πρώτα χαρακτηριστικά και έχει ξεκάθαρο διαχωρισμό των τιμών του. Στην εφαρμογή του πρώτου μέτρου οδηγούνται περισσότερο τα κτήρια με περισσότερους ορόφους, ενώ στην εφαρμογή των υπολοίπων τα κτήρια με λιγότερους. Παρόμοια πορίσματα είναι δυνατόν να προκύψουν και για άλλους συνδυασμούς χαρακτηριστικών και κλάσεων.

Σε γενικές γραμμές, είναι εμφανές πως η αρχική και η τελική ενεργειακή κλάση διαδραματίζουν σημαντικό ρόλο στην επιλογή των μέτρων όπως άλλωστε αναμέναμε. Επίσης σημαντικά παρουσιάζονται τα χαρακτηριστικά που αφορούν τους ορόφους, το έτος έναρξης εκμετάλλευσης των κτηρίων και τις δύο ειδών στέγες. Οι υπόλοιπες στήλες προσφέρουν και αυτές στην πρόβλεψη με μικρότερες ωστόσο συνήθως τιμές.

Ως επιπρόσθετη παρατήρηση, το γεγονός ότι τα Heat installation και Water heating system εμφανίζουν συνολικά μικρότερες τιμές shap από τα άλλα δύο μπορεί να αποδοθεί στο μικρό πλήθος θετικών δειγμάτων που έχουν στο σύνολο δεδομένων. Αξίζει να σημειωθεί ότι τα αποτελέσματα είναι επηρεασμένα από την έλλειψη ισορροπίας των κλάσεων και τις υπόλοιπες ιδιαιτερότητες των δεδομένων, οι οποίες επηρεάζουν την δυνατότητα πρόβλεψης.



Σχήμα 4.5: Dependence plot του Initial year of exploitation για την κλάση Reconstruction of engineering systems


Μία διαφορετική μορφή αναπαράστασης καθολικών επεξηγήσεων αποτελούν τα dependence plots. Στην περίπτωση αυτή, κάθε διάγραμμα αναφέρεται σε ένα μεμονωμένο χαρακτηριστικό και περιλαμβάνει ένα σημείο για κάθε δείγμα του συνόλου δεδομένων. Οι τιμές του χαρακτηριστικού βρίσκονται στον άξονα x και οι αντίστοιχες τιμές shap στον άξονα y. Στα διαγράμματα αυτά ενσωματώνεται και η αναπαράσταση της αλληλεπίδρασης των χαρακτηριστικών με χρήση χρωματικού κώδικα. Το κάθε σημείο χρωματίζεται με βάση την τιμή ενός άλλου χαρακτηριστικού (το πιο στενά συσχετιζόμενο ή κατόπιν επιλογής) και σύμφωνα με το υπόμνημα.

Ενδεικτικά παρατίθεται ένα παράδειγμα τέτοιων διαγραμμάτων. Στο Σχήμα 4.5 παρουσιάζεται το dependence plot του χαρακτηριστικού Initial year of exploitation για την κλάση Reconstruction of engineering systems. Είναι εμφανές ότι ακολουθεί μία γραμμική αύξου-

σα τάση και οι μεγαλύτερες τιμές του χαρακτηριστικού (κανονικοποιημένες) αντιστοιχούν σε μεγαλύτερες τιμές shap. Εμπλουτίζεται με την συσχέτιση του έτους με το Room volume με βάση τον χρωματικό κώδικα. Οι μεγαλύτερες τιμές του δεύτερου αντιστοιχούν κατά βάση με μεγαλύτερες τιμές του πρώτου, ενώ για οι μικρότερες τιμές Room volume κατανέμονται σε όλο το εύρος τιμών Initial year of exploitation.

4.5 Τοπικές επεξηγήσεις

Εξίσου χρήσιμο είναι να οπτικοποιήσουμε τις τοπικές επεξηγήσεις, οι οποίες αφορούν μεμονωμένες προβλέψεις. Ένα είδος τέτοιων γραφημάτων αποτελούν τα waterfall plots που σχεδιάζονται για ένα συγκεκριμένο δείγμα και μία συγκεκριμένη κλάση. Η αναπαράσταση ξεκινά στο κάτω μέρος του διαγράμματος με την αναμενόμενη τιμή της πρόβλεψης με βάση το σύνολο δεδομένων εάν δεν γνωρίζουμε τις τιμές των επιμέρους χαρακτηριστικών (baseline: $E(f(x))$). Έπειτα κάθε γραμμή αντιστοιχεί σε ένα χαρακτηριστικό (και την τιμή που λαμβάνει) και δείχνει πώς η θετική ή αρνητική συνεισφορά (τιμή shap) του μεταβάλλει την αναμενόμενη έξοδο καταλήγοντας στην τελική πρόβλεψη του στιγμιότυπου ($f(x)$) στην κορυφή του διαγράμματος. Εφόσον πρόκειται για πρόβλημα ταξινόμησης οι αναμενόμενες και οι τελικές τιμές αφορούν την πιθανότητα να λάβει το στιγμιότυπο την ετικέτα 1 για την συγκεκριμένη κλάση. Με αυτόν τον τρόπο αποτυπώνεται και αξιολογείται η αθροιστική ιδιότητα των shap τιμών.



Σχήμα 4.6: Waterfall plots τυχαίου δείγματος ανά κλάση

Για παράδειγμα, το Σχήμα 4.6α' ταυτίζεται με το waterfall plot ενός δείγματος για την κλάση Carrying out construction works. Η αρχική (baseline) τιμή είναι η $E[f(x)] = 0.865$ που προέκυψε από το ποσοστό των δειγμάτων του συνόλου που λαμβάνουν 1 στην κλάση αυτή. Εκκινώντας από την αναμενόμενη αυτή τιμή τα περισσότερα χαρακτηριστικά αυξάνουν την τιμή κατά 0.01, ενώ το Energy consumption before κατά 0.02. Από την άλλη, το Underground floor μειώνει κατά 0.02, το οποίο συνάδει με το summary plot της κλάσης όπου μικρές τιμές του (δηλαδή 0) όπως εδώ έχουν αρνητικές shap τιμές. Τέλος, το Initial energy class φαίνεται να είναι το χαρακτηριστικό που επηρεάζει περισσότερο την πρόβλεψη ωθώντας την τιμή πιο κοντά στο 1 κατά 0.07. Για κάθε χαρακτηριστικό αναγράφεται η τιμή που λαμβάνει στο συγκεκριμένο στιγμιότυπο η οποία βρίσκεται σε κανονικοποιημένη μορφή. Όπως το Underground floor έτσι και τα περισσότερα χαρακτηριστικά ακολουθούν την συμπεριφορά του summary plot αν και δεν είναι σε όλες τις περιπτώσεις τόσο ξεκάθαρο λόγω της κατανομής τους. Σε ορισμένα δείγματα τα χαρακτηριστικά που παρουσιάζονται ως πιο σημαντικά στην καθολική περίπτωση δεν επηρεάζουν καθόλου την πρόβλεψη.

Κατ' αντιστοιχία το Σχήμα 4.6β' αφορά την κλάση Reconstruction of engineering systems. Σε αυτή την περίπτωση την μεγαλύτερη συνεισφορά έχουν τα Initial energy class, Energy class after, Underground floor, Mansard, το θετικό άθροισμα των οποίων υπερτερεί έναντι της αρνητικής μικρότερης συμβολής των υπόλοιπων χαρακτηριστικών. Τα 4 χαρακτηριστικά αυτά βρίσκονται στα κορυφαία 6 του summary plot της ίδιας κλάσης.

Τα Σχήματα 4.6γ' και 4.6δ' αφορούν τις άλλες δύο κλάσεις, οι οποίες από σχεδόν μηδενική αναμενόμενη τιμή (πολύ μικρό πλήθος θετικών δειγμάτων στο σύνολο δεδομένων) με την συνεισφορά 3 μόνο χαρακτηριστικών μειώνουν περαιτέρω την προβλεπόμενη τιμή.

Τα waterfall plots παρέχουν μια πιο στοχευμένη περιγραφή του τρόπου εξαγωγής της πρόβλεψης με τις ακριβείς τιμές. Προφανώς οι αναμενόμενες τιμές διαδραματίζουν καθοριστικό ρόλο στην πρόβλεψη, διότι αποτελούν την βάση την οποία επηρεάζουν οι επιμέρους τιμές των χαρακτηριστικών. Για παράδειγμα στην πρώτη περίπτωση η $E[f(x)]$ ήταν ήδη πολύ κοντά στο 1, ενώ στην τρίτη και τέταρτη ήταν σχεδόν μηδενική. Η άνιση κατανομή των δεδομένων στις κλάσεις, επομένως, είναι καίριας σημασίας και προσδίδει ένα βαθμό μεροληψίας στο μοντέλο.

4.6 Προσθήκη νέου χαρακτηριστικού

Αναμφίβολα σε όλη την έκταση του κεφαλαίου τονίστηκε η σπουδαιότητα των χαρακτηριστικών Initial energy class, Energy class after, τα οποία κατείχαν πρωτεύουσα θέση στην κατάταξη των σημαντικών στηλών του συνόλου. Αυτό το συμπέρασμα ήταν εν μέρει προβλέψιμο από την αρχή, λόγω του ότι ο στόχος της τελικής ενεργειακής κλάσης δίνεται από τον χρήστη μέσω του Energy class after. Άρα το μοντέλο καλείται να επιλέξει ποια από τα τέσσερα πιθανά μέτρα αναβάθμισης χρειάζεται να εφαρμοστούν ώστε η κλάση του κτηρίου να μεταβληθεί από την Initial energy class στην Energy class after. Κατά την διερευνητική ανάλυση των δεδομένων φάνηκε ότι δεν υπάρχουν αρκετά παραδείγματα για κάθε πιθανή μετάβαση κλάσεων ώστε το μοντέλο να εκπαιδευτεί επαρκώς και να γνωρίζει κατά πόσο και με ποιον τρόπο μπορεί να βελτιωθεί αποδοτικά το εκάστοτε σπίτι. Αυτό είναι σημαντικό διότι

υπάρχει διαφορά στην ευκολία μεταβολής της ενεργειακής κλάσης από ένα συγκεκριμένο επίπεδο σε κάθε άλλο. Ένας τρόπος για να ενισχυθεί αυτή η δυνατότητα θα ήταν η προσθήκη ενός νέου χαρακτηριστικού στα δεδομένα, το οποίο ποσοτικοποιεί την ενεργειακή αυτή μετάβαση ως έναν συνεχή αριθμό. Στην Λετονία οι κλάσεις ενέργειας των κτηρίων καθορίζονται με βάση την ενεργειακή θερμική κατανάλωση (Heat energy consumption before) και την θερμαινόμενη επιφάνεια (Reference area) με βάση τον Πίνακα 4.2.

Energy efficiency class of building	Energy consumption for heating (kWh/m ²) of residential buildings		
	Heated area, m ²		
	from 50 to 120	from 120 to 250	over 250 m ²
A+	≤ 35	≤ 35	≤ 30
A	≤ 60	≤ 50	≤ 40
B	≤ 75	≤ 65	≤ 60
C	≤ 95	≤ 90	≤ 80
D	≤ 150	≤ 130	≤ 100
E	≤ 180	≤ 150	≤ 125
F	over 180	over 150	over 125

Πίνακας 4.2: Πίνακας προσδιορισμού ενεργειακής κλάσης κτηρίου στην Λετονία

Χρησιμοποιώντας τα όρια αυτά δημιουργούμε το νέο χαρακτηριστικό ως την διαφορά των άνω ορίων της αρχικής κλάσης από την τελική, η οποία υποδηλώνει την μέγιστη απαιτούμενη για την μετάβαση αύξηση της ενεργειακής απόδοσης ή αλλιώς την μείωση της ενεργειακής κατανάλωσης. Έτσι η μεταβολή ξεφεύγει από τα όρια των συγκεκριμένων κλάσεων και λαμβάνει μια πιο γενικευμένη μορφή (κατά πόσο χρειάζεται να μειωθεί η κατανάλωση για να μεταβληθεί η κλάση) που βοηθά το μοντέλο να προσδιορίσει συγκριτικά ακόμα και μεταβολές τις οποίες δεν έχει συναντήσει αυτούσιες.

Εκπαιδεύουμε το μοντέλο μαζί με αυτό το χαρακτηριστικό και υπολογίζουμε και πάλι τις τιμές shap. Στα παραγόμενα summary plots βρίσκεται περίπου στην μέση της κατάταξης των χαρακτηριστικών ως προς την σημαντικότητά τους για την πρόβλεψη. Για τις δύο τελευταίες κλάσεις βρίσκεται αρκετά πιο χαμηλά. Στα waterfall plots σε ορισμένα δείγματα η συνεισφορά του βρίσκεται στα κορυφαία πιο σημαντικά χαρακτηριστικά δηλαδή αναλογίζεται σημαντικά από το μοντέλο. Σε άλλα, όμως, δείγματα η συνεισφορά αυτή είναι ιδιαίτερα μικρή έως και μηδενική. Συμπερασματικά, με αυτή την προσθήκη παρατηρείται μια μικρή βελτίωση στις μετρικές που μελετάμε, ωστόσο τα προβλήματα που προκύπτουν από τα δεδομένα δεν μπορούν να εξαλειφθούν. Σημειώνεται επιπροσθέτως ότι το νέο αυτό χαρακτηριστικό βασίζεται στις ενεργειακές προδιαγραφές της Λετονίας και χρειάζεται τροποποίηση στον τρόπο υπολογισμού του ώστε να είναι γενικεύσιμο και για δεδομένα άλλων χωρών.

Κεφάλαιο 5

Μεθοδολογία κύριου πειράματος

Στο κάτωθι κεφάλαιο περιγράφεται η βασική μεθοδολογία στα στάδια της οποίας οδηγήσαμε από τις αναλύσεις των προηγούμενων κεφαλαίων. Συνοπτικά αφορά το μοντέλο που χρησιμοποιείται, την διαδικασία παραγωγής συνθετικών δεδομένων και την επέκταση σε άλλα σύνολα δεδομένων μέσω τεχνικών διαρκούς μάθησης.

5.1 Υλοποίηση μοντέλου

Η συγκεκριμένη ενότητα περιγράφει την υλοποίηση του αρχικού μοντέλου που χρησιμοποιήθηκε για τα πειράματα. Το μοντέλο αυτό καλείται να προβλέπει για κάθε δείγμα κτηρίου τέσσερις κλάσεις, οι οποίες ταυτίζονται με τα μέτρα ενεργειακής αναβάθμισης, δηλαδή τα Carrying out construction works, Reconstruction of engineering systems, Water heating system, Heat installation. Η έξοδος του λοιπόν θα είναι δυαδική για κάθε μία από αυτές, με την τιμή 1 εάν προτείνεται η εφαρμογή του μέτρου αυτού και τιμή 0 αλλιώς. Πρόκειται άρα για ένα πρόβλημα ταξινόμησης πολλαπλών ετικετών (multilabel classification) κατά την οποία κάθε δείγμα μπορεί να ανατεθεί σε περισσότερες από μία κλάσεις χωρίς να υπάρχουν περιορισμοί αμοιβαίου αποκλεισμού μεταξύ τους.


5.1.1 Επιλογή μοντέλου

Το μοντέλο που επιλέγουμε να χρησιμοποιήσουμε είναι το Multi-Layer Perceptron (MLP), το οποίο αποτελεί μία πολύ συχνή και βασική επιλογή για ένα εύρος διαφορετικών προβλημάτων βαθιάς μάθησης. Λόγω της απλότητας και της ευελιξίας του επιτρέπει την εκτενέστερη και ευκολότερη διερεύνηση διαφόρων μεθόδων και πειραματικών συνθηκών. Για την υλοποίησή του βασιζόμαστε στην χρήση των PyTorch και Lightning πακέτων python, τα οποία απλοποιούν ορισμένες από τις απαιτούμενες διαδικασίες για την κατασκευή και εκπαίδευσή του.


Το MLP είναι ένα βαθύ feedforward νευρωνικό δίκτυο, το οποίο αποτελείται από νευρώνες οργανωμένους σε πολλαπλά επίπεδα [32]. Ένα παράδειγμα της γενικής δομής του παρουσιάζεται στο Σχήμα 5.1. Κάθε νευρώνας είναι πλήρως συνδεδεμένος με τις εξόδους (x_i) των νευρώνων του προηγούμενου επιπέδου (είσοδοι του τρέχοντος νευρώνα) και παράγει έξοδο

(y) η οποία τροφοδοτείται στους νευρώνες του επόμενου επιπέδου. Κάθε σύνδεση χαρακτηρίζεται από ένα βάρος (w_i) και κάθε νευρώνας έχει μία σταθερή τιμή προκατάληψης (bias, b). Επίσης στην έξοδο κάθε νευρώνα εφαρμόζεται μία συνάρτηση ενεργοποίησης (f), η οποία εισάγει την μη γραμμικότητα στο μοντέλο επιτρέποντάς του να μάθει πιο πολύπλοκα μοτίβα. Η κατάλληλη επιλογή της μπορεί να πραγματοποιηθεί από μία πληθώρα διαφορετικών συναρτήσεων ενεργοποίησης μέσω της διαδικασίας βελτιστοποίησης των υπερπαραμέτρων. Έτσι, η έξοδος κάθε νευρώνα προκύπτει μέσω της σχέσης 5.1 και η λειτουργία του περιγράφεται στο Σχήμα 5.2.

$$y = f \left(\sum_{i=1}^n (w_i x_i) + b \right) \quad (5.1)$$



Σχήμα 5.1: Παράδειγμα δομής MLP ¹



Σχήμα 5.2: Λειτουργία νευρώνα ²

¹Πηγή: <https://www.shiksha.com/online-courses/articles/understanding-multilayer-perceptron-mlp-neural-networks/>

²Πηγή: <https://shivammehta25.github.io/posts/introduction-to-neural-networks/>

Όσον αφορά τα διάφορα επίπεδα, το επίπεδο εισόδου (input layer) έχει μέγεθος ίσο με την διάσταση της εισόδου δεδομένων που δέχεται το μοντέλο. Συνεπώς είναι ίση με το πλήθος των στηλών του συνόλου δεδομένων που τελικά χρησιμοποιούμε, αφού κάθε νευρώνας του αντιστοιχεί σε ένα χαρακτηριστικό. Τα κρυφά εσωτερικά επίπεδα (hidden layers) επιλέγονται ως προς το πλήθος και το μέγεθος μέσω της διαδικασίας βελτιστοποίησης των υπερπαραμέτρων όπως περιγράφεται στην ενότητα 5.1.3. Η συνάρτηση ενεργοποίησης που εφαρμόζεται στους νευρώνες αυτών των επιπέδων είναι η ReLU, η οποία ορίζεται από την σχέση 5.2 και μπορεί επίσης να επιλεγεί μέσω της ίδιας διαδικασίας. Είναι η πιο συχνά χρησιμοποιούμενη συνάρτηση ενεργοποίησης για τα ενδιάμεσα κρυφά επίπεδα λόγω της υπολογιστικής της απόδοσης και διότι αποτρέπει προβλήματα που μπορούν να προκύψουν κατά την εκπαίδευση (π.χ. vanishing gradient problem).

$$ReLU(x) = \max(0, x) \quad (5.2)$$

Το επίπεδο εξόδου (output layer) παράγει την τελική έξοδο του μοντέλου και γι' αυτό το μέγεθός του εξαρτάται γενικά από τον τύπο του προβλήματος. Αποτελείται επομένως από πλήθος νευρώνων ίσο με το πλήθος των κλάσεων που θέλουμε να μπορεί να προβλέψει, δηλαδή τα 4 μέτρα ενεργειακής αναβάθμισης. Η συνάρτηση ενεργοποίησης που εφαρμόζεται σε αυτό το επίπεδο είναι η σιγμοειδής συνάρτηση (sigmoid), η οποία ορίζεται στην σχέση 5.3 και είναι κατάλληλη για την περίπτωση της multilabel ταξινόμησης, όπου σε ένα δείγμα μπορούν να αποδοθούν περισσότερες από μία κλάσεις. Μετατρέπει κάθε έξοδο σε τιμές μεταξύ 0 και 1 που αναπαριστούν την πιθανότητα η ετικέτα της αντίστοιχης κλάσης να είναι 1.

$$Sigmoid(x) = \frac{1}{1 + e^{-x}} \quad (5.3)$$

5.1.2 Εκπαίδευση μοντέλου

Κατά την εκπαίδευση του μοντέλου, χρησιμοποιείται ο αλγόριθμος backpropagation, αναθεωρώντας επαναληπτικά τα βάρη και τα biases του δικτύου ώστε να υπολογιστούν οι βέλτιστες τιμές τους που ελαχιστοποιούν την συνάρτηση απωλειών (loss function). Η συνάρτηση αυτή ποσοτικοποιεί την διαφορά μεταξύ των προβλέψεων και των πραγματικών τιμών αποτελώντας μέτρο αξιολόγησης της επίδοσης του μοντέλου. Χρησιμοποιούμε την binary cross-entropy loss, η οποία ορίζεται από την εξίσωση 5.4, όπου y_i η πραγματική ετικέτα του δείγματος i , $\hat{y}_i$ η προβλεπόμενη πιθανότητα για το δείγμα i (που έχει προκύψει από την εφαρμογή της σιγμοειδούς συνάρτησης) και N το πλήθος των δειγμάτων.

$$BCELoss = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (5.4)$$

Με βάση αυτές τις τιμές λοιπόν προσαρμόζονται τα βάρη με την βοήθεια ενός αλγορίθμου βελτιστοποίησης, ο οποίος μπορεί να επιλεγεί μέσω διαδικασίας *hyperparameter tuning*. Μία από τις συνηθέστερες επιλογές την οποία και χρησιμοποιούμε αποτελεί ο βελτιστοποιητής Adam (Adaptive Moment Estimation optimizer). Αντίστοιχα αποφασίζεται η τιμή του ρυθμού εκμάθησης (learning rate) που ελέγχει κατά πόσο θα μεταβληθούν τα βάρη από τους υπολογισμούς κάθε επανάληψης.

Στο μοντέλο εφαρμόζεται επίσης η τεχνική κανονικοποίησης Early stopping, σύμφωνα με την οποία η εκπαίδευση ενός μοντέλου σταματά προτού ολοκληρωθεί το προκαθορισμένο πλήθος εποχών, εάν η απόδοση στο σύνολο επικύρωσης (validation set) πάψει να βελτιώνεται. Συγκεκριμένα κριτήριο αποτελεί η συνάρτηση απώλειας στα δεδομένα αυτά (validation loss) που έχει ήδη οριστεί και υπολογίζεται στο τέλος κάθε εποχής εκπαίδευσης. Με την μέθοδο αυτή αυξάνεται η ικανότητα γενίκευσης αφού αποφεύγεται η υπερπροσαρμογή (overfitting), η οποία συμβαίνει όταν το μοντέλο εκπαιδεύεται σε βαθμό που μαθαίνει θόρυβο και λεπτομέρειες από τα δεδομένα εκπαίδευσης. Συγχρόνως μειώνεται το υπολογιστικό κόστος, καθώς η εκπαίδευση σταματά όταν πλέον δεν είναι πιθανή η περαιτέρω βελτίωση χωρίς περιττή αύξηση του απαιτούμενου χρόνου και κατάληψη πόρων.

Επιπλέον απαιτούμενο για την ορθή εκπαίδευση και λειτουργία του μοντέλου είναι ο διαχωρισμός του συνόλου δεδομένων σε τρία επιμέρους σύνολα: το σύνολο εκπαίδευσης (train set), το σύνολο επικύρωσης (validation set) και το σύνολο ελέγχου (test set). Από το πρώτο σύνολο το μοντέλο μαθαίνει και ανανεώνει τα βάρη του με βάση τον αλγόριθμο εκπαίδευσης, ενώ το δεύτερο χρησιμοποιείται για έλεγχο της επίδοσης του μοντέλου ώστε να επιτευχθούν διαδικασίες όπως η εύρεση των βέλτιστων υπερπαραμέτρων του. Τέλος, το τρίτο σύνολο χρησιμοποιείται αποκλειστικά μετά το πέρας της εκπαίδευσης και με βάση αυτό αξιολογείται συνολικά το μοντέλο. Διευκρινίζεται ότι τα δεδομένα μοιράζονται σε δεδομένα εκπαίδευσης και ελέγχου με ποσοστά 75% και 25% αντίστοιχα. Έπειτα ακολουθεί περαιτέρω αντίστοιχη διάσπαση του συνόλου εκπαίδευσης για να προκύψουν από αυτό τα δεδομένα επικύρωσης. Επιπροσθέτως, πρέπει να ικανοποιήσουμε την ανάγκη κατάλληλης κανονικοποίησης τόσο των αριθμητικών όσο και των κατηγορικών χαρακτηριστικών των δεδομένων ώστε να είναι συμβατά με την λειτουργία του μοντέλου.

5.1.3 Βελτιστοποίηση υπερπαραμέτρων

Όπως είναι γνωστό στον τομέα της μηχανικής μάθησης, ένα από τα σπουδαιότερα βήματα κατά την υλοποίηση μοντέλων αποτελεί το *hyperparameter tuning*, δηλαδή η διαδικασία εύρεσης των βέλτιστων υπερπαραμέτρων του μοντέλου ώστε να ενισχυθεί η απόδοσή του. Ο καθορισμός συγκεκριμένων υπερπαραμέτρων είναι αναγκαίος για την κατασκευή του μοντέλου και μη βέλτιστες επιλογές τιμών μπορούν να περιορίσουν σημαντικά τις δυνατότητες του. Μία αποδοτική λύση για τον σκοπό αυτόν αποτελεί η χρήση της Optuna [33], η οποία είναι βιβλιοθήκη για αυτοματοποιημένη βελτιστοποίηση υπερπαραμέτρων. Αναλυτικότερα, χρησιμοποιείται στρατηγική δειγματοληψίας (sampling) TPE (Tree-structured Parzen Estimator), ώστε να επιλέγονται οι πιο υποσχόμενοι συνδυασμοί υπερπαραμέτρων εστιάζοντας

στις περιοχές τιμών που έχουν δώσει έως τότε τα καλύτερα αποτελέσματα και αγνοώντας τις υπόλοιπες. Ακόμα χρησιμοποιείται η στρατηγική κλαδέματος (pruning) Median Pruner, η οποία ελέγχει και τερματίζει νωρίτερα την εκπαίδευση για συνδυασμούς που δεν δίνουν εξαρχής καλά αποτελέσματα. Έτσι εξοικονομεί χρόνο και πόρους και προχωρά στην αξιολόγηση επόμενων δυνητικά καλύτερων επιλογών. Η αξιολόγηση των μη αποδοτικών περιπτώσεων πραγματοποιείται με βάση τον υπολογισμό του validation loss.

Η Optuna αναφέρεται στην διαδικασία βελτιστοποίησης των υπερπαραμέτρων μέσω δοκιμής διαφορετικών συνδυασμών ως study και σε κάθε έναν συνδυασμό από αυτούς ως trial. Κάθε study αποτελείται από πολλαπλά trials, το πλήθος των οποίων ορίζεται από τον χρήστη. Ο/η χρήστης/ρια επίσης καθορίζει το επιλεγμένο εύρος αναζήτησης των υπερπαραμέτρων, όπως απεικονίζουμε στον Πίνακα 5.1 για την περίπτωση μας.

Hyperparameter	Search space
n_layers	[2,6]
layer_sizes	32,64,128,256,512
l_rate	0.0001,0.001,0.01
activation	ReLU
optimizer	Adam
batch_size	16,32,64,128
num_workers	4
n_trials	50
max_epochs	100

Πίνακας 5.1: Πίνακας υπερπαραμέτρων με εύρος τιμών που χρησιμοποιείται από την Optuna

5.1.4 Αξιολόγηση μοντέλου

Για την αξιολόγηση κάθε μοντέλου δίνεται η δυνατότητα επιλογής από ένα πλήθος διαφορετικών μετρικών. Υπάρχουν πολλά διαφορετικά είδη που διευκολύνουν την κατανόηση της απόδοσης των εξεταζόμενων μοντέλων. Η κατάλληλη απόφαση εξαρτάται από το εκάστοτε πρόβλημα και την υπό μελέτη περίπτωση και οδηγεί στην αντίστοιχη ερμηνεία των μετρικών. Όσον αφορά την ταξινόμηση οι πιο συχνές είναι οι accuracy, precision, recall, F1 score, για τον ορισμό των οποίων θα προηγηθεί ο ορισμός του πίνακα σύγχυσης (confusion matrix). Συγκεκριμένα, όπως φαίνεται στο Σχήμα 5.3, αποτελεί έναν πίνακα που συνδυάζει τις πραγματικές τιμές των δεδομένων με τις προβλέψεις του μοντέλου. Οι τιμές Positive/Negative (τιμές 1 και 0 αντίστοιχα) αναφέρονται στις προβλέψεις, ενώ οι τιμές True/False στις πραγματικές τιμές. Ορίζονται οι ακόλουθες περιπτώσεις:

- True Positives (TP): Το πλήθος των δειγμάτων για τα οποία το μοντέλο προέβλεψε 1 (Positive) και ήταν πράγματι 1 (True) (αφορά σωστές προβλέψεις).

- **True Negatives (TN):** Το πλήθος των δειγμάτων για τα οποία το μοντέλο προέβλεψε 0 (Negative) και ήταν πράγματι 0 (True) (αφορά σωστές προβλέψεις).
- **False Positives (FP):** Το πλήθος των δειγμάτων για τα οποία το μοντέλο προέβλεψε 1 (Positive) ενώ ήταν 0 (False) (αφορά λανθασμένες προβλέψεις).
- **False Negatives (FN):** Το πλήθος των δειγμάτων για τα οποία το μοντέλο προέβλεψε 0 (Negative) ενώ ήταν 1 (False) (αφορά λανθασμένες προβλέψεις).

		Actual value	
		Positive	Negative
Predicted value	Positive	True Positive TP	False Positive FP
	Negative	False Negative FN	True Negative TN

Σχήμα 5.3: Δομή πίνακα σύγχυσης (confusion matrix)

Με βάση τα παραπάνω λοιπόν μπορούν να οριστούν και οι μετρικές ταξινόμησης ως εξής:

- **Accuracy:** Η μετρική accuracy δείχνει τον λόγο των σωστών προβλέψεων ως προς όλες τις προβλέψεις, δηλαδή πόσο συχνά το μοντέλο προβλέπει ορθά, και ορίζεται από την εξίσωση 5.5.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} = \frac{\text{correct predictions}}{\text{total predictions}} \quad (5.5)$$

- **Precision:** Η μετρική αυτή δείχνει τον λόγο των σωστών positive προβλέψεων ως προς όλες τις positive προβλέψεις, δηλαδή το ποσοστό των positive προβλέψεων που ήταν πράγματι positive και ορίζεται από την εξίσωση 5.6.

$$\text{Precision} = \frac{TP}{TP + FP} = \frac{\text{correct positive predictions}}{\text{total predicted positives}} \quad (5.6)$$

- **Recall:** Η μετρική αυτή δείχνει τον λόγο των σωστών positive προβλέψεων ως προς όλες τις πραγματικά positive τιμές, δηλαδή το ποσοστό των πραγματικά positive τιμών που κατάφερε να βρει το μοντέλο και ορίζεται από την εξίσωση 5.7.

$$\text{Recall} = \frac{TP}{TP + FN} = \frac{\text{correct positive predictions}}{\text{total actual positives}} \quad (5.7)$$

- **F1 score:** Η μετρική αυτή αποτελεί τον αρμονικό μέσο των Precision και Recall και άρα ορίζεται από την εξίσωση 5.8.

$$\text{F1 score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5.8)$$

- **Hamming distance:** Μία ακόμη μετρική που μπορεί να χρησιμοποιηθεί είναι η απόσταση Hamming, η οποία δείχνει την απόσταση μεταξύ των προβλέψεων και των αληθινών τιμών, δηλαδή το ποσοστό των λανθασμένων προβλέψεων. Κατά βάση αποτελεί μία συμπληρωματική ένδειξη της μετρικής accuracy.

Στην αξιολόγηση του μοντέλου μας χρησιμοποιούμε τις παραπάνω μετρικές προσαρμοσμένες στην multilabel ταξινόμηση, δηλαδή τις εκδοχές Multilabel Accuracy κ.ο.κ. Υπολογίζονται ανεξάρτητα για κάθε ετικέτα και έπειτα εξάγεται ο μέσος όρος των αποτελεσμάτων για το σύνολο των τεσσάρων περιπτώσεων. Ο τρόπος που επιλέγουμε για τον συνδυασμό των αποτελεσμάτων όλων των κλάσεων προκύπτει θέτοντας την αντίστοιχη παράμετρο ως 'macro'. Ο μέσος όρος αυτός είναι μη σταθμισμένος και δίνει την ίδια βαρύτητα σε κάθε κλάση. Χωρίς να επηρεάζεται από το πλήθος των δειγμάτων που ανήκουν σε αυτήν διαιρεί το άθροισμα των επιμέρους τιμών της μετρικής για κάθε κλάση με το πλήθος των κλάσεων.

Όσον αφορά το πρόβλημά μας, στόχος του οποίου είναι η πρόβλεψη των κατάλληλων μέτρων ενεργειακής αναβάθμισης για ένα συγκεκριμένο κτήριο, η μετρική precision αναδεικνύεται ιδιαίτερα σημαντική. Ειδικότερα, υψηλή τιμή precision σημαίνει πως ό,τι προβλέπει το μοντέλο ως θετικό είναι πράγματι σωστό. Με αυτόν τον τρόπο οι ιδιοκτήτες των κατοικιών δεν υποβάλλονται σε περιττές διαδικασίες και έξοδα. Στα πλαίσια αυτά, λοιπόν, αξίζει να εστιάσουμε στην ανάλυση της συγκεκριμένης μετρικής, καθώς επιθυμούμε τα μέτρα που προτείνονται να είναι πράγματι κατάλληλα αποφεύγοντας αναίτιες χρηματικές δαπάνες.

5.2 Παραγωγή συνθετικών δεδομένων

Προκειμένου να αντιμετωπιστούν τα προβλήματα του μικρού σε μέγεθος και μη ισορροπημένου ως προς τις κλάσεις συνόλου δεδομένων, εγείρεται η ανάγκη παραγωγής νέων συνθετικών δεδομένων (data generation). Έτσι, το σύνολο θα εμπλουτιστεί με νέα δείγματα συνολικά αλλά θα ενισχυθούν και οι κλάσεις οι οποίες συναντώνται λιγότερο εξαλείφοντας την ανισορροπία κλάσεων των δεδομένων. Κρίνεται, λοιπόν, σκόπιμο να παρουσιαστεί η ανασκόπηση των διάφορων μεθόδων που πραγματοποιήθηκε προσανατολισμένη στις ανάγκες του συγκεκριμένου προβλήματος προκειμένου να οδηγηθούμε στην κατάλληλη επιλογή.

5.2.1 Τεχνικές παραγωγής δεδομένων

Δειγματοληψία

Έχουν αναπτυχθεί πολλαπλές μέθοδοι και εργαλεία που εξυπηρετούν τον σκοπό της παραγωγής συνθετικών δεδομένων για τον ζητούμενο σκοπό. Κυρίως βασίζονται στην υπερδειγματοληψία (oversampling), η οποία δύναται να αυξήσει το πλήθος των δεδομένων με διαφορετικούς τρόπους προσθήκης νέων στιγμιοτύπων. Οι αρχικές προσεγγίσεις του oversampling είναι η αντιγραφή τυχαία επιλεγμένων δειγμάτων από την κλάση με τα λιγότερα δείγματα και η τυχαία δημιουργία νέων δεδομένων από τις ήδη υπάρχουσες τιμές τους. Παρά το γεγονός ότι και οι δύο είναι αρκετά εύκολες και γρήγορες υπολογιστικά, δεν είναι ιδιαίτερα αποτελεσματικές. Με την πρώτη δεν επέρχεται ουσιαστική αύξηση της πληροφορίας, αφού απλώς δημιουργεί

διπλότυπα και άρα κορυφώνει την πιθανότητα υπερπροσαρμογής στα δεδομένα εκπαίδευσης. Από την άλλη, η δεύτερη δεν παρέχει πάντοτε δεδομένα που συνάδουν με την λογική και δεν αναπαριστά τις πιθανές σχέσεις μεταξύ των χαρακτηριστικών των δεδομένων. Σημειώνεται ότι στον αντίποδα της υπερδειγματοληψίας βρίσκεται η υποδειγματοληψία (undersampling), η οποία μπορεί να επιφέρει την ισορροπία μεταξύ των κλάσεων διαγράφοντας τυχαία δείγματα της κλάσης που υπερτερεί. Ωστόσο, συνήθως αφαιρεί πολύτιμη πληροφορία και ειδικά για την περίπτωση που τα δεδομένα είναι λίγα προφανώς δεν είναι κατάλληλη. Στο εξής η κλάση που υπερτερεί ως προς τα δείγματα θα αναφέρεται ως κλάσης πλειοψηφίας (majority) και η άλλη ως κλάση μειοψηφίας (minority).

SMOTE

Η τεχνική SMOTE (Synthetic Minority Over-sampling Technique) αποτελεί μία από τις πιο γνωστές μεθόδους σύνθεσης νέων δεδομένων [34]. Συνοπτικά, επιλέγεται ένα δείγμα από την minority κλάση, βρίσκονται οι k κοντινότεροι γείτονές του από την ίδια κλάση, επιλέγεται ένας τυχαίος από αυτούς και με παρεμβολή μεταξύ αυτού και του αρχικού δείγματος δημιουργείται το συνθετικό. Για την ακρίβεια, στο αρχικό δείγμα προστίθεται η απόσταση του από τον γείτονα πολλαπλασιασμένη με ένα τυχαίο αριθμό από το 0 ως το 1 και με αυτόν τον τρόπο το νέο στιγμιότυπο βρίσκεται μεταξύ των δύο αρχικών. Η μέθοδος, όμως, εμφανίζει ορισμένα μειονεκτήματα όπως η έλλειψη μεγάλης ποικιλίας στα συνθετικά δεδομένα και το γεγονός ότι δεν λαμβάνεται υπόψη η κατανομή πιθανότητας των δειγμάτων της κλάσης μειοψηφίας. Ειδικά στις περιπτώσεις με μικρό πλήθος δειγμάτων δεν υπάρχει η δυνατότητα συνδυασμού και δημιουργίας πολλαπλών διαφορετικών δεδομένων και έτσι οδηγούμαστε σε επικάλυψη των ίδιων δειγμάτων και έλλειψη ποικιλομορφίας. Όσον αφορά τα κατηγορικά δεδομένα εάν αυτά κωδικοποιηθούν θα μπορέσουν να παραχθούν νέα τα οποία όμως πιθανώς δεν θα είναι έγκυρα καθώς θα έχουν αντιμετωπιστεί ως αριθμητικές τιμές. Το πρόβλημα αυτό επιλύεται με την τεχνική SMOTE-NC (Synthetic Minority Over-sampling Technique for Nominal and Continuous features), η οποία επιλέγει ως τιμή για το νέο δείγμα την πιο συχνά εμφανιζόμενη κατηγορία μεταξύ των k κοντινότερων γειτόνων [34]. Γενικότερα, μετά την δημοσίευσή του SMOTE, έχουν υλοποιηθεί περισσότερες από 85 παραλλαγές του [35]. Κάποιες από τις πιο γνωστές είναι η ADASYN (Adaptive Synthetic Sampling) και η Borderline-SMOTE. Η πρώτη δημιουργεί περισσότερα δείγματα της minority κλάσης για τα δεδομένα τα οποία μαθαίνονται πιο δύσκολα από έναν ταξινομητή (minority δείγματα με λίγους minority γείτονες), ενώ η δεύτερη εστιάζει στην παραγωγή δεδομένων κοντά στο σύνορο των περιοχών απόφασης, καθώς αυτά τα δείγματα διαδραματίζουν σημαντικότερο ρόλο στην ταξινόμηση. Κάθε μία αποτελεί βελτίωση και προσφέρει συγκεκριμένα πλεονεκτήματα, αλλά δεν επιλύει όλες τις αδυναμίες που εμφανίζει το SMOTE ειδικά σε σύνολα με ορισμένες ιδιαιτερότητες οι οποίες παραμένουν ακόμη τρέχοντα ζητήματα προς επίλυση.

GANs

Τα τελευταία χρόνια ευρέως διαδεδομένα είναι τα Γεννητικά Ανταγωνιστικά Δίκτυα (γνωστά ως Generative Adversarial Networks - GANs) [36], τα οποία αντίθετα με τις τεχνικές SMOTE δεν χρησιμοποιούν μόνο τοπικές πληροφορίες αλλά εκπαιδεύονται ώστε να μάθουν την συνολική κατανομή των κλάσεων στα πραγματικά δεδομένα. Η λειτουργία των GANs βασίζεται σε μία ανταγωνιστική διαδικασία όπου εκπαιδεύονται ταυτόχρονα δύο μοντέλα: ο generator G και ο discriminator D . Ο G με είσοδο τυχαίο θόρυβο συνθέτει νέα δείγματα ώστε αυτά να ακολουθούν την κατανομή των αρχικών δεδομένων. Ο D λαμβάνει τόσο αληθινά όσο και ψεύτικα δείγματα και έχει ως στόχο να μεγιστοποιήσει την πιθανότητα να ταξινομηθούν σωστά και οι δύο κατηγορίες δειγμάτων. Ο G από την πλευρά του εκπαιδεύεται ώστε να βελτιώσει την ποιότητα των παραγόμενων δεδομένων στοχεύοντας στην ελαχιστοποίηση της πιθανότητας ο D να διακρίνει ορθά την ψεύτικη φύση των δειγμάτων αυτών. Με άλλα λόγια, θέλει να «ξεγελάσει» τον D και για αυτό ανανεώνεται με βάση την συνάρτηση απωλειών του. Η εξίσωση 5.9 αποτελεί την συνολική minimax συνάρτηση απωλειών του GAN, όπου οι κατανομές $p_{data}(x)$ και $p_z(x)$ αναφέρονται στα αληθινά και συνθετικά δεδομένα αντίστοιχα, $D(x)$ είναι η πιθανότητα που αποδίδει ο D ώστε ένα αληθινό δείγμα x να είναι αληθινό, $D(G(x))$ η πιθανότητα που αποδίδει ο D ώστε ένα συνθετικό δείγμα να είναι αληθινό:

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (5.9)$$


Μία από τις τροποποιήσεις της γενικής αρχιτεκτονικής του GAN είναι το Conditional GAN (CGAN) [37], το οποίο δίνει την δυνατότητα να τεθούν υπό συνθήκη κάποιας συγκεκριμένης κλάσης τόσο ο generator όσο και ο discriminator. Έτσι η παραγωγή δεδομένων μπορεί να κατευθυνθεί υπέρ της κλάσης που υποαντιπροσωπεύεται σε ένα σύνολο δεδομένων συμβάλλοντας στην καταπολέμηση άνισων κατανομών των ετικετών σε αυτό. Η συνθήκη εισάγεται ως ένα επιπρόσθετο επίπεδο εισόδου και διαφοροποιεί την συνάρτηση απωλειών σύμφωνα με την εξίσωση 5.10.

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{data}(x)} [\log D(x|y)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z|y)))] \quad (5.10)$$

Η σχηματική αναπαράσταση της γενικής μορφής των GANs αλλά και των conditional GANs (CGANs) παρουσιάζεται στο Σχήμα 5.4.

Η αρχική και πιο εκτεταμένη έρευνα για την χρήση των GANs είναι προσανατολισμένη κυρίως στις εικόνες. Παρά την ιδιαίτερη αποτελεσματικότητά τους στην παραγωγή ρεαλιστικών εικόνων όμως, παρουσιάζουν προβλήματα όταν πρόκειται να εφαρμοστούν σε δεδομένα μορφής πίνακα (tabular data). Μερικές από τις αιτίες που τα εμποδίζουν είναι η συνύπαρξη συνεχών και διακριτών/κατηγορικών τύπων χαρακτηριστικών, η διαφοροποίηση των κατανομών τους

³Πηγή: <https://learnopencv.com/conditional-gan-cgan-in-pytorch-and-tensorflow/>

Σχήμα 5.4: Αρχιτεκτονική GAN και CGAN ³

από γκαουσιανές και η αυξημένη πιθανότητα ύπαρξης ανισορροπίας τιμών στις κατηγορικές στήλες [38].

Για τους παραπάνω λόγους προτάθηκε η ανάπτυξη του Conditional Tabular GAN (CT-GAN) [38], το οποίο είναι κατάλληλο για δομημένα δεδομένα σε μορφή πίνακα. Αρχικά εισάγει μία μέθοδο κανονικοποίησης για την επεξεργασία των δεδομένων πριν την εκπαίδευση, την mode-specific normalization, η οποία χρησιμοποιείται για τις αριθμητικές στήλες ενώ οι κατηγορικές αναπαρίστανται με one-hot κωδικοποιημένα διανύσματα. Συγκεκριμένα, κάθε συνεχής αριθμητική στήλη μοντελοποιείται με χρήση Variational Gaussian Mixture (VGM) μοντέλου, αναγνωρίζοντας τις καταστάσεις (modes) της κατανομής. Για κάθε τιμή της στήλης υπολογίζεται η πιθανότητα αυτή να προέρχεται από το κάθε mode. Επιλέγεται το πιο πιθανό mode και με βάση αυτό κανονικοποιείται η τιμή. Ως αποτέλεσμα προκύπτει ένα one-hot διάνυσμα, με το συγκεκριμένο mode να υποδεικνύεται από τον αριθμό 1, και μία τιμή κανονικοποιημένη με βάση τα χαρακτηριστικά του mode αυτού. Έτσι, οι μη γκαουσιανές multimodal κατανομές μετατρέπονται σε κανονικοποιημένη διανυσματική μορφή κατάλληλη για τα μοντέλα. Όσον αφορά το πρόβλημα του class-imbalance στις διακριτές στήλες αυτό αντιμετωπίζεται με την επινόηση των conditional generator και training-by-sampling. Ο πρώτος βοηθά στην παραγωγή δεδομένων υπό συνθήκη κάποιας συγκεκριμένης κλάσης, ενώ η στρατηγική training-by-sampling εξασφαλίζει ότι τα δείγματα που θα συμμετάσχουν στην εκπαίδευση του μοντέλου θα λαμβάνονται με ισάξιο τρόπο από τις διάφορες κατηγορίες ώστε να εξερευνηθούν εξίσου και αυτές που υποαντιπροσωπεύονται. Επίσης, χρησιμοποιούνται πλήρως συνδεδεμένα νευρω-

νικά δίκτυα για τους generator και discriminator για να καταγραφούν οι πιθανές συσχετίσεις μεταξύ των στηλών οι οποίες δεν παρουσιάζουν κάποια τοπική σχέση με βάση τον τρόπο ορισμού τους.

Επιλογή μεθόδου

Έχει αποδειχθεί μέσω πολλών μελετών ότι τα GANs υπερτερούν έναντι των άλλων μεθόδων τόσο γενικά όσο και ειδικά στην περίπτωση των tabular δεδομένων και της ύπαρξης class-imbalance [39]. Έχει υποστηριχθεί μάλιστα ότι η απόδοσή τους βελτιστοποιείται όταν συνδυάζονται με MLP και CNN μοντέλα για την χρήση των συνθετικών δεδομένων [39]. Ένα από τα πιο διαδεδομένα μοντέλα του είδους είναι το CTGAN. Η υπεροχή του έχει αναδειχθεί τόσο από την αρχική δημοσίευση που το εισήγαγε όσο και από πολλές που ακολούθησαν, έπειτα από συγκρίσεις σε ποικίλα σύνολα δεδομένων και ποικίλες μετρικές.

Στην βιβλιογραφία συναντώνται πολλαπλές παραλλαγές των GANs οι οποίες προσαρμόζουν τις λειτουργίες τους με βάση τις ιδιαιτερότητες κάθε προβλήματος και των δεδομένων που αναλύουν. Υπάρχουν ακόμη και άλλα εξειδικευμένα μοντέλα που αποτελούν πιθανώς και βελτιώσεις σε συγκεκριμένα περιβάλλοντα για συνθετικά tabular δεδομένα. Όμως η πρόσφατη δημοσίευσή τους έχει ως αποτέλεσμα είτε να μην συνοδεύονται από την αντίστοιχη πλήρη υλοποίηση είτε να μην έχουν εφαρμοστεί και συγκριθεί επαρκώς σε πλήθος διαφορετικών περιπτώσεων όπως αυτή του class-imbalance.

Είναι γενικώς εμφανές ότι ακόμη και μεταξύ των επικρατέστερων μοντέλων για το πρόβλημα της δημιουργίας συνθετικών δεδομένων η επιλογή εξαρτάται από ποικίλους παράγοντες. Για παράδειγμα, ορισμένα μοντέλα υπερτερούν στα αριθμητικά χαρακτηριστικά, κάποια στα κατηγορικά και κάποια δεν μπορούν να ανταπεξέλθουν επαρκώς όταν οι τιμές δεν είναι κατανεμημένες ομαλά στις διαφορετικές κατηγορίες. Ορισμένες μέθοδοι λειτουργούν για μικρά σύνολα δεδομένων ενώ άλλες απαιτούν ικανοποιητικό πλήθος δεδομένων. Σημαντικός είναι σαφώς και ο ρόλος των υπερπαραμέτρων του κάθε μοντέλου, η επιλογή των οποίων συχνά εξαρτάται από το εκάστοτε σύνολο δεδομένων.

Καταληκτικά, λόγω όλων των παραπάνω θα χρησιμοποιήσουμε το μοντέλο CTGAN το οποίο είναι υλοποιημένο στοχευμένα για δεδομένα μορφής πίνακα και αποτελεί μία από τις πιο ευρέως διαδεδομένες και δοκιμασμένες αντίστοιχες μεθόδους. Η υλοποίησή του διατίθεται έτοιμη με βέλτιστο τρόπο και έτσι η εφαρμογή του καθίσταται ιδιαίτερα εύκολη και γρήγορη.

5.2.2 Υλοποίηση παραγωγής δεδομένων

Αφού καταλήξαμε στην χρήση του CTGAN ως κατάλληλη επιλογή προχωράμε στην συνέχεια στην περιγραφή της υλοποίησής του. Σύμφωνα με τους δημιουργούς του το CTGAN μπορεί να υλοποιηθεί είτε απευθείας ως βιβλιοθήκη (ctgan) είτε μέσω της βιβλιοθήκης SDV. Η SDV (Synthetic Data Vault) [40] αποτελεί ένα σύνολο Python βιβλιοθηκών που περιλαμβάνει ένα σύνολο μοντέλων για παραγωγή συνθετικών δεδομένων διαφορετικών ειδών αλλά και εργαλεία αξιολόγησής τους. Επιλέγεται η εφαρμογή του CTGAN μέσω της βιβλιοθήκης SDV έναντι της χρήσης του ως βιβλιοθήκη ctgan, καθώς αποτελεί ευκολότερη υλοποίηση.

Περιλαμβάνει τα βήματα της κατάλληλης προεπεξεργασίας, όπως η κανονικοποίηση και η κωδικοποίηση, αλλά και εύκολη εφαρμογή περιορισμών και συνθηκών παραγωγής δεδομένων (constraints, conditions).

Χρησιμοποιώντας το αρχικό σύνολο δεδομένων για μέτρα ενεργειακής αναβάθμισης σε κτήρια της Λετονίας με τα επιλεγμένα αρχικά χαρακτηριστικά, εκπαιδεύουμε ένα μοντέλο CTGAN και παράγουμε νέα συνθετικά δείγματα. Εκτός από την συνολική αύξηση των δεδομένων, στόχος είναι και η εξισορρόπηση ως προς τις τελικές κλάσεις των μέτρων (Carrying out construction works, Reconstruction of engineering systems, Water heating system, Heat installation) που προβλέπει το μοντέλο. Γι' αυτό κατά την εφαρμογή του εκπαιδευμένου CTGAN για δημιουργία δειγμάτων γίνεται χρήση των κατάλληλων συνθηκών παραγωγής (conditions) που διαθέτει η sdv ως παράμετρο. Ορίζεται δηλαδή το πλήθος δειγμάτων που επιθυμούμε να παραχθούν και να έχουν μία συγκεκριμένη τιμή σε κάποιο χαρακτηριστικό. Στην περίπτωση μας που ασχολούμαστε με multilabel ταξινόμηση, οι ετικέτες των κλάσεων παρουσιάζουν εξαρτήσεις μεταξύ τους. Για αυτό εφαρμόζουμε επαναληπτικά την παραγωγή υπό συνθήκη για όλες τις κλάσεις και διαφορετικές τιμές καταλήγοντας σε ένα μεγαλύτερο σύνολο όπου οι αποκλίσεις μεταξύ των ποσοστών 1 και 0 στις ετικέτες έχουν μειωθεί όσο είναι δυνατόν. Τέλος, δίνουμε τα συνολικά δεδομένα ως είσοδο στο ίδιο MLP μοντέλο της ενότητας 5.1, το οποίο πραγματοποιεί εκ νέου εύρεση των βέλτιστων υπερπαραμέτρων και εξάγει τα αποτελέσματα των αντίστοιχων μετρικών.

5.2.3 Αξιολόγηση συνθετικών δεδομένων

Ιδιαίτερη σημασία μετά την δημιουργία των συνθετικών δεδομένων έχει ο έλεγχος τους, ώστε να εξασφαλιστεί πως αυτά μοιράζονται παρόμοιες ιδιότητες με τα αρχικά δεδομένα. Για την διαδικασία αυτήν μπορούν να χρησιμοποιούν διάφορες μετρικές που έχουν προταθεί για τον σκοπό αυτό και αφορούν τόσο στατιστικές ιδιότητες των χαρακτηριστικών όσο και μεταξύ τους συσχετίσεις.

Ένας εύκολος και ασφαλής τρόπος είναι η χρήση της python βιβλιοθήκης SDMetrics (Synthetic Data Metrics) η οποία είναι κατάλληλη να αξιολογήσει συνθετικά tabular δεδομένα συγκριτικά με τα πραγματικά, χρησιμοποιώντας πλήθος μετρικών και οπτικών αναπαραστάσεων [41]. Αξίζει να σημειωθεί πως για την χρήση της τα συνθετικά δεδομένα μπορούν να έχουν παραχθεί από οποιοδήποτε μοντέλο.

Αρχικά πραγματοποιείται έλεγχος της εγκυρότητας (DiagnosticReport) των δεδομένων, δηλαδή ελέγχεται κατά πόσο η δομή των συνθετικών δεδομένων είναι η αναμενόμενη και συνάδει με αυτή των αρχικών. Έπειτα πραγματοποιείται ο έλεγχος ποιότητας (QualityReport) για την αξιολόγηση των ιδιοτήτων των δεδομένων, ο οποίος διαχωρίζεται σε δύο μέρη ως εξής:

- Column shapes score: Η πρώτη μετρική που υπολογίζεται είναι η Column shapes score, η οποία περιγράφει την συνολική κατανομή κάθε στήλης και λαμβάνει μεγαλύτερη τιμή όταν η ομοιότητα μεταξύ συνθετικών και πραγματικών δεδομένων είναι μεγαλύτερη. Η τελική τιμή του αποτελέσματος αποτελεί τον μέσο όρο για όλες τις στήλες του συνόλου, αλλά μπορεί να αναλυθεί και στις επιμέρους τιμές τους.

- Για τις αριθμητικές στήλες υπολογίζεται η μετρική $KSComplement$, η οποία χρησιμοποιεί τον Kolmogorov-Smirnov στατιστικό έλεγχο και μετρά την απόσταση μεταξύ των κατανομών.
- Για τις κατηγορικές υπολογίζεται η μετρική $TVComplement$ που προκύπτει από την Total Variation Distance μεταξύ των συνθετικών και πραγματικών στηλών, εκφράζοντας ως πιθανότητες τις συχνότητες εμφάνισης των διαφόρων τιμών.
- Column Pair Trends: Ο συγκεκριμένος έλεγχος μετρά ακόμα την μετρική Column Pair Trends, η οποία δηλώνει εάν τα συνθετικά δεδομένα αναδεικνύουν τις σχέσεις μεταξύ των στηλών, π.χ. την συσχέτισή τους. Όσο μεγαλύτερη είναι η τιμή, τόσο μεγαλύτερη είναι και η ομοιότητα. Αντίστοιχα με τη προηγούμενη μετρική το αποτέλεσμα της αποτελεί τον μέσο όρο για όλες τις στήλες.
 - Μεταξύ αριθμητικών χαρακτηριστικών υπολογίζεται η μετρική correlation.
 - Μεταξύ κατηγορικών ή κατηγορικού με αριθμητικό υπολογίζεται η μετρική ομοιότητας contingency για την κατανομή συχνότητας των συνδυασμών τιμών.

5.3 Διαρκής μάθηση (Lifelong learning)

Επόμενο βήμα αποτελεί η επέκταση της παρούσας μελέτης σε άλλα σύνολα δεδομένων που προέρχονται από διαφορετικές χώρες. Επιλέγουμε να τα συνδυάσουμε με τα ήδη χρησιμοποιούμενα δεδομένα μέσω τεχνικών διαρκούς μάθησης. Εκτός από τις λεπτομέρειες υλοποίησης παρουσιάζεται η μέθοδος και οι συγκεκριμένες στρατηγικές που χρησιμοποιούνται προκειμένου να καταστούν σαφείς οι λόγοι υπεροχής της απόφασης αυτής.

5.3.1 Γενική περιγραφή

Η τρέχουσα τάση που κυριαρχεί στον τομέα της μηχανικής μάθησης περιλαμβάνει αλγόριθμους απομονωμένης μάθησης (isolated learning), όπου ένα μοντέλο εκπαιδεύεται σε ένα συγκεκριμένο σύνολο δεδομένων και εφαρμόζεται στην επίλυση συγκεκριμένων προβλημάτων. Δεν λαμβάνει υπόψη σχετικές πληροφορίες από άλλες πηγές και δεν διατηρεί την γνώση που έχει αποκτήσει στο παρελθόν. Αντίθετα, ο άνθρωπος μαθαίνει ανθρωπιστικά, δηλαδή συσσωρεύει προηγούμενες γνώσεις και τις αξιοποιεί προσαρμόζοντας τις σε νέες πληροφορίες στις οποίες εκτίθεται. Έτσι, αναβαθμίζει σταδιακά και αποδοτικά τις ικανότητες του, εκμεταλλευόμενος την συσχέτιση μεταξύ διαφορετικών προβλημάτων που καλείται να αντιμετωπίσει. Αυτή η διαδικασία της ανθρώπινης εκμάθησης ενέπνευσε ένα άλλο είδος μάθησης, τη διαρκή μάθηση ή ευρέως γνωστή ως lifelong learning. Στον τομέα της βαθιάς μάθησης συναντάται επίσης και ο όρος continual learning [42].

Η διαρκής μάθηση, λοιπόν, αφορά την περίπτωση που ένα μοντέλο μαθαίνει συνεχώς, διατηρεί την γνώση από το παρελθόν και την αξιοποιεί για να βοηθήσει την μελλοντική μάθηση. Ωστόσο αυτός ο τύπος μάθησης επιφέρει ένα βασικό πρόβλημα που ονομάζεται catastrophic


forgetting. Το φαινόμενο αυτό προκύπτει όταν η εκπαίδευση ενός μοντέλου σε νέα προβλήματα και κατηγορίες οδηγεί στην μείωση της επίδοσής του στα προηγούμενα καθώς ξεχνά την ήδη υπάρχουσα γνώση που έχει αποκομίσει. Το catastrophic forgetting συναντάται κυρίως στα MLPs και στα βαθιά νευρωνικά δίκτυα, όταν κατά την διαδοχική εκπαίδευση τα βάρη αντικαθίστανται για να εξυπηρετήσουν τους νέους σκοπούς χωρίς να δίνεται πλέον έμφαση στους παλιούς. Για την αντιμετώπισή του εφαρμόζονται ποικίλες στρατηγικές που έχουν προταθεί και ανάλογα τις ανάγκες της κάθε περίπτωσης βελτιώνουν τα αποτελέσματα. Ανακύπτει επομένως το δίλημμα σταθερότητας-πλαστικότητας (stability-plasticity dilemma), το οποίο αφορά την ισορροπία μεταξύ της προσαρμοστικότητας του μοντέλου, όσον αφορά την ενσωμάτωση νέων γνώσεων, και της σταθερότητάς, του όσον αφορά τη διατήρηση των γνώσεων που έχουν αποκτηθεί προηγουμένως.

Συνεπώς, η διαρκής μάθηση αποτελεί μία διαδικασία συνεχούς μάθησης κατά την οποία έστω ότι το μοντέλο έχει εκπαιδευτεί σε N tasks, τα $T_1, T_2, \dots, T_N$ με αντίστοιχα σύνολα δεδομένων $D_1, D_2, \dots, D_N$. (Χρησιμοποιούμε τον όρο tasks για τα διαφορετικά προβλήματα, τον οποίο όμως θα συγκεκριμενοποιήσουμε στην συνέχεια για την κατηγοριοποίηση των διαφόρων ειδών.) Όταν έρθει αντιμέτωπο με το $(N+1)$ -ό task, δηλαδή το T_{N+1} με δεδομένα D_{N+1} , θα αξιοποιήσει την σχετική γνώση που έχει αποκτήσει και διατηρήσει στην βάση γνώσεών του (knowledge base) κατά την εκπαίδευσή του στα προηγούμενα tasks, προκειμένου να μάθει καλύτερα και πιο εύκολα το τρέχον task. Η συνέχεια της εκμάθησης δεν πρέπει να επηρεάσει την απόδοσή του σε ό,τι έχει προηγηθεί και η νέα γνώση που θα εκμαιεύσει θα αποθηκευτεί ώστε να συμβάλει στην περαιτέρω βελτίωση των μελλοντικών αλλά και όλων συνολικά των tasks.

Καταληκτικά οι στόχοι του αυξητικού και συνεχούς είδους μάθησης είναι να αποφευχθεί το catastrophic forgetting και να ενισχυθεί η μεταφορά γνώσης τόσο προς τα εμπρός (forward transfer) όσο και προς τα πίσω (backward transfer). Η πρώτη αναφέρεται στην βοήθεια που προσφέρει η γνώση από τα παλιά tasks στα μελλοντικά, ενώ η δεύτερη στην βελτίωση των παλιών tasks που επιφέρει η περαιτέρω εκπαίδευση σε νέα tasks. Γενικότερα στοχεύει στην συνολική και ενιαία βελτιστοποίηση και το μοντέλο μαθαίνει διαρκώς ακόμα και αφού τελειώσει η άμεση εκμάθηση του T_i στα D_i . Γίνεται επιπλέον συχνά η υπόθεση ότι μετά την ολοκλήρωση αυτή τα δεδομένα D_i δεν είναι πλέον προσβάσιμα με πιθανή εξαίρεση ένα ποσοστό αυτών. Επίσης πολλές φορές τα δεδομένα ανανεώνονται με την πάροδο του χρόνου και δεν είναι γνωστά εξαρχής. Ακόμη και για την περίπτωση που είναι όλα διαθέσιμα η παράλληλη χρήση τους αυξάνει τους απαιτούμενους πόρους μνήμης αλλά και τον υπολογιστικό φόρτο για ταυτόχρονη επανεκπαίδευση σε όλα τα δεδομένα.

Στο Σχήμα 5.5 απεικονίζονται γραφικά τα πιθανά σενάρια έκβασης της διαρκούς μάθησης όπως ήδη αναλύθηκαν. Στο Σχήμα 5.5α' οπτικοποιείται η επίδραση του catastrophic forgetting κατά το οποίο η επίδοση που επιτυγχάνεται με την εκπαίδευση στο Task 1 δεν διατηρείται στα επόμενα βήματα. Ομοίως συμβαίνει για το Task 2. Αντίθετα, το Σχήμα 5.5β' δείχνει την περίπτωση πλήρους εξάλειψης του φαινομένου όπου το μοντέλο δεν ξεχνά ό,τι έχει ήδη μάθει και όλα τα tasks καταλήγουν στην ίδια επίδοση. Τέλος, το Σχήμα 5.5γ' αναπαριστά την

⁴Πηγή: <https://www.cs.uic.edu/liub/Part-1-continual-learning-slides.pdf>



Σχήμα 5.5: Γραφική αναπαράσταση πιθανών εκβάσεων διαρκούς μάθησης ⁴

περίπτωση forward μεταφοράς και βλέπουμε ότι το τελευταίο εκπαιδευόμενο Task 3 λαμβάνει την μέγιστη απόδοση, ακολουθεί το Task 2 και έπειτα το Task 1. Αντίστοιχα, στο Σχήμα 5.5δ' προστίθεται και η backward μεταφορά και έτσι με την πάροδο των tasks παρατηρείται βελτίωση και αυτών που έχουν ήδη εκπαιδευτεί καταλήγωντας σε υψηλότερες, με μικρότερες διαφορές, αποδόσεις μεταξύ των τριών tasks. Σαφώς τα παραπάνω αποτελούν εξιδανικευμένα σενάρια και στοχεύουν στην θεωρητική ανάδειξη των αποτελεσμάτων.

Διαφορές με σχετικά είδη μάθησης

Η διαρκής μάθηση παρουσιάζει πολλές ομοιότητες με άλλα είδη μάθησης, όπως transfer learning και multitask learning. Ωστόσο, οι υπόλοιπες τεχνικές δεν διαθέτουν ένα ή περισσότερα από τα χαρακτηριστικά της [42].

- **Transfer learning:** Αφορά την μεταφορά γνώσης κατά την οποία η γνώση που έχει αποκτήσει ένα μοντέλο σε ένα συγκεκριμένο πρόβλημα (source domain) αξιοποιείται για να διευκολυνθεί η μάθηση ενός δεύτερου προβλήματος (target domain). Το source domain περιλαμβάνει μεγάλο πλήθος επισημασμένων (labeled) δεδομένων εκπαίδευσης και ενώ είναι δυνατόν να υπάρξουν περισσότερα τέτοια domains η πλειοψηφία των ερευνών αφορά μόνο ένα. Από την άλλη το target domain περιλαμβάνει συνήθως λίγα δεδομένα και συναντώνται διάφορες τεχνικές για την εκπαίδευσή του. Το transfer learning δεν αφορά την συνεχή μάθηση και την συσσώρευση γνώσεων σε αντίθεση με την διαρκή μάθηση, καθώς η μεταφορά γνώσης πραγματοποιείται μία μόνο φορά και δεν διατηρείται

για μελλοντική χρήση. Επίσης ωφελείται μόνο το target από το source και όχι αντίστροφα και συνεπώς δεν διαθέτει την ιδιότητα της αμφίδρομης διαδικασίας όπως η διαρκής μάθηση κατά την οποία η γνώση από τα νέα προβλήματα μπορεί να χρησιμοποιηθεί ώστε να βελτιώσει την επίδοση των προηγούμενων.

- **Multitask learning:** Αφορά την διαδικασία μάθησης πολλαπλών tasks ταυτόχρονα με στόχο την επίτευξη καλύτερων αποτελεσμάτων χρησιμοποιώντας τις κοινές σχετικές πληροφορίες που μοιράζονται μεταξύ τους. Τα tasks αυτά θεωρούνται στενά συσχετιζόμενα, έχουν όλα επαρκή επισημασμένα δεδομένα και αντιμετωπίζονται ισάξια. Δεν διατηρεί γνώση παρά μόνο δεδομένα με τα οποία έρχεται σε επαφή στο σύνολό τους. Στην περίπτωση μεγάλου πλήθους tasks και δεδομένων δεν είναι αποδοτική και εύκολη η επανεκπαίδευση σε όλα μαζί κάθε φορά που προστίθεται ένα νέο task.

Είδη

Η διαρκής μάθηση μπορεί να διακριθεί σε τρία διαφορετικά είδη ή αλλιώς σενάρια με τον ακόλουθο τρόπο [43]:

- **Task-incremental learning:** Το μοντέλο μαθαίνει διαδοχικά ένα σύνολο διακριτών προβλημάτων (tasks) προσδιορίζοντας ξεκάθαρα για ποιο από αυτά πρόκειται κάθε φορά μέσω κάποιου αναγνωριστικού (task identity). (Ο όρος task χρησιμοποιείται στην βιβλιογραφία με διαφορετικές ερμηνείες, αλλά στα πλαίσια της συνεχούς μάθησης θα αναφέρεται πλέον σε ένα συγκεκριμένο πλαίσιο προβλήματος όπου κάθε δείγμα θα ανήκει ξεκάθαρα σε αυτό.) Ένα παράδειγμα task-incremental learning είναι να μάθει να παίζει διαφορετικά αθλήματα ή μουσικά όργανα, καθώς είναι ξεκάθαρος ο κάθε τύπος αθλήματος ή οργάνου στον οποίο εκπαιδεύεται κάθε φορά. Στο συγκεκριμένο είδος μπορούμε να αναπτύξουμε διαφοροποιήσεις σε ξεχωριστά τμήματα των δικτύων για κάθε task, όπως τα επίπεδα κλπ.
- **Class-incremental learning:** Το μοντέλο μαθαίνει διαδοχικά να πραγματοποιεί την διάκριση μεταξύ ενός αυξανόμενου αριθμού αντικειμένων ή κλάσεων. Έρχεται σε επαφή με μία ακολουθία προβλημάτων ταξινόμησης καθένα εκ των οποίων περιλαμβάνει διαφορετικές κλάσεις και εκπαιδεύεται ώστε να κατηγοριοποιεί ορθά τα δείγματα μεταξύ όλων των κλάσεων. Για παράδειγμα, μπορεί αρχικά να μάθει να διακρίνει γάτες και σκύλους και αργότερα αγελάδες και άλογα. Στο τέλος πρέπει να έχει την ικανότητα ταξινόμησης μεταξύ του συνόλου όλων των ζώων, δηλαδή ακόμα και αυτών για τα οποία δεν έχει εκπαιδευτεί ταυτόχρονα, π.χ. γάτες και άλογα.
- **Domain-incremental learning:** Το μοντέλο πρέπει να μάθει το ίδιο είδος προβλήματος αλλά σε διαφορετικές συνθήκες. Με άλλα λόγια η δομή του προβλήματος παραμένει ίδια (ίδιες πιθανές έξοδοι/κλάσεις), ενώ μπορεί να διαφοροποιηθεί το περιεχόμενο και η κατανομή των δεδομένων εισόδου. Στις διαφορετικές αυτές περιπτώσεις αναφερόμαστε ως domains (domain shifts). Τα διαφορετικά domains δεν ορίζονται ρητά στον αλγόριθμο και ο τελικός στόχος είναι η δυνατότητα γενίκευσης μεταξύ των domains χωρίς τα

δείγματα να χαρακτηρίζονται από συγκεκριμένα αναγνωριστικά. Παράδειγμα αποτελεί η ταξινόμηση θετικών και αρνητικών κριτικών ταινιών (πρώτο domain) και αυτοκινήτων (δεύτερο domain), όπως επίσης και η αναγνώριση αντικειμένων υπό μεταβαλλόμενες συνθήκες φωτισμού.

Στρατηγικές


Οι στρατηγικές διαρκούς μάθησης που έχουν αναπτυχθεί μπορούν να κατηγοριοποιηθούν ως εξής:

- Βασισμένες στην κανονικοποίηση (regularization-based): Επιβάλλουν κάποιο είδος ποινής στις αλλαγές των βαρών που είναι σημαντικά για την επίλυση των προηγούμενων προβλημάτων. Προσθέτουν έναν όρο κανονικοποίησης στην συνάρτηση απωλειών της ταξινόμησης για τον υπολογισμό της συνολικής απώλειας προκειμένου να αποτρέψουν μεγάλες μεταβολές που οδηγούν στο catastrophic forgetting.
- Βασισμένες στην επανάληψη (replay-based): Ενισχύουν το τρέχον σύνολο δεδομένων εκπαίδευσης επαναλαμβάνοντας ένα υποσύνολο των προηγούμενων δεδομένων. Αυτό αποτελείται είτε από αποθηκευμένα σε δεδομένη μνήμη δείγματα είτε από συνθετικά ψευδο-δείγματα που παράγονται από κατάλληλα εκπαιδευμένο data generator. Η βελτίωση της απόδοσης των μοντέλων αυξάνεται ανάλογα με την αύξηση του μεγέθους του διαθέσιμου αποθηκευτικού χώρου, αλλά οι τεχνικές αυτές παρουσιάζουν περιορισμούς μνήμης και υπολογιστικού φόρτου.
- Βασισμένες στην αρχιτεκτονική (architecture-based): Δημιουργούν διαφορετικά υποδίκτυα και επίπεδα του μοντέλου για κάθε task και παρά την σημαντική επίδοση που μπορούν να επιτύχουν παρουσιάζουν σημαντικές δυσκολίες στην υλοποίηση.
- Υβριδικές: Συνδυάζουν τις παραπάνω και είναι πιο περίπλοκες αλλά μπορούν με τις κατάλληλες τροποποιήσεις να επιτύχουν ισορροπία μεταξύ της δυσκολίας και της αποδοτικότητάς τους.

Στην συνέχεια αναλύονται ορισμένες από τις πιο γνωστές στρατηγικές διαρκούς μάθησης, τις οποίες και εφαρμόζουμε στο σύνολο τους στην παρούσα μελέτη.

Elastic Weight Consolidation (EWC) [44]: Η στρατηγική αυτή περιορίζει την ανανέωση σε ορισμένα βάρη ποσοτικοποιώντας την επίδραση που έχουν στην απόδοση των προηγούμενων tasks, ώστε οι πιο σημαντικές παράμετροι να μην διαφοροποιηθούν πολύ. Αντλεί έμπνευση από τον ανθρώπινο εγκέφαλο, ο οποίος αντιμετωπίζει με αντίστοιχο τρόπο τις συνάψεις για να εξασφαλίσει συνεχή μάθηση (synaptic consolidation). Για περαιτέρω επεξήγηση θεωρούμε ότι ένα μοντέλο έχει ήδη εκπαιδευτεί στο πρόβλημα A και επιθυμούμε εκπαιδευτεί στο πρόβλημα B. Με την EWC επιβάλλουμε ποινές στην αλλαγή των παραμέτρων, ώστε επιλεκτικά να μειωθούν οι μεταβολές (plasticity) αυτών που διαδραματίζουν τον μεγαλύτερο ρόλο στην διατήρηση των γνώσεων του A και έτσι να επιτύχουμε αποδεκτά

αποτελέσματα στο B χωρίς catastrophic forgetting. Αντίθετα, εάν επιτρέψουμε στα βάρη να μεταβληθούν χωρίς περιορισμούς θα πετύχουμε βέλτιστη απόδοση για το B αλλά θα ξεχαστούν οι σχετικές με το A γνώσεις που έχουν αποκτηθεί. Εάν από την άλλη επιβάλλουμε ίδιο συντελεστή ποινής σε κάθε παράμετρο, τότε δεν θα καταφέρει το μοντέλο να μάθει επαρκώς το B. Οι παραπάνω αναμενόμενες συμπεριφορές οπτικοποιούνται στο Σχήμα 5.6.



Σχήμα 5.6: Στρατηγική elastic weight consolidation (EWC)

Καταλήγοντας, η στρατηγική EWC χρησιμοποιεί την συνάρτηση απωλειών 5.11, όπου $\mathcal{L}_B(\theta)$ είναι η απώλεια μόνο του προβλήματος B, θ οι παράμετροι του δικτύου και i ο δείκτης κάθε παραμέτρου, λ η υπερπαραμέτρος που δείχνει την σημαντικότητα του B συγκρινόμενο με το A, θ_A^* οι παράμετροι που εκπαιδεύτηκαν στο A και F ο Fisher πίνακας ο οποίος αναπαριστά την σημαντικότητα των παραμέτρων i . Καθώς το μοντέλο προχωρά σε επόμενα προβλήματα (Γ κ.ο.κ.), γίνεται προσπάθεια διατήρησης όλων των προηγούμενων (A,B) είτε με διαφορετικούς είτε με ενιαίο όρο ποινής.

$$\mathcal{L}(\theta) = \mathcal{L}_B(\theta) + \sum_i \frac{\lambda}{2} F_i(\theta_i - \theta_{A,i}^*)^2 \quad (5.11)$$

Learning without Forgetting (LwF) [45]: Η στρατηγική αυτή συμβάλλει στην αποφυγή του catastrophic forgetting εντάσσοντας στην εκπαίδευση τις προηγούμενες γνώσεις χωρίς την απαίτηση αποθήκευσης δεδομένων. Ειδικότερα, το μοντέλο εκπαιδεύεται με χρήση τόσο των hard labels (πραγματικές ετικέτες για το τρέχον νέο πρόβλημα) για να προσαρμοστεί στην κατανομή των νέων δεδομένων, όσο και των soft labels για να διατηρήσει την προηγούμενη γνώση. Τα soft labels προκύπτουν μέσω της διαδικασίας knowledge distillation, κατά την οποία τα δεδομένα του νέου task εισάγονται στο μοντέλο των προηγούμενων tasks. Από την έξοδο αυτή παράγονται οι ψευδο-ετικέτες, οι οποίες προσομοιώνουν την λειτουργία του μοντέλου που έχει εκπαιδευτεί έως τότε.

Οι παράμετροι του μοντέλου αποτελούνται από τις κοινές παραμέτρους θ_s , τις παραμέτρους των προηγούμενων tasks θ_o και του νέου θ_n . Στόχος είναι η βελτιστοποίηση αυτών των παραμέτρων ώστε το μοντέλο να αποδίδει στο σύνολο των προβλημάτων. Για αυτό η συνάρτηση βελτιστοποίησης προκύπτει από την σχέση 5.12.

$$\theta_s^*, \theta_o^*, \theta_n^* \leftarrow \arg \min_{\hat{\theta}_s, \hat{\theta}_o, \hat{\theta}_n} \left(\lambda_o \mathcal{L}_{old}(Y_o, \hat{Y}_o) + \mathcal{L}_{new}(Y_n, \hat{Y}_n) + \mathcal{R}(\hat{\theta}_s, \hat{\theta}_o, \hat{\theta}_n) \right) \quad (5.12)$$

Η συνάρτηση απωλειών αποτελείται από την συνάρτηση απωλειών των προηγούμενων tasks $\mathcal{L}_{old}$ και αυτής του νέου $\mathcal{L}_{new}$. Η ισορροπία μεταξύ της διατήρησης της παλιάς γνώσης και της απόκτησης νέας ρυθμίζεται μέσω της παραμέτρου λ_o , μεγάλες τιμές της οποίας δίνουν βαρύτητα στο πρώτο ενώ μικρές στο δεύτερο. Ο όρος κανονικοποίησης R αποτρέπει την περίπτωση υπερπροσαρμογής.

Ακόμα, ως Y_n συμβολίζονται οι πραγματικές ετικέτες των νέων δεδομένων τις οποίες γνωρίζουμε από την αρχή και Y_o είναι οι προβλέψεις για τα νέα δείγματα χρησιμοποιώντας τις θ_s και θ_o , δηλαδή η αρχικοποίηση που πραγματοποιούμε με το μοντέλο προτού εκπαιδευτεί στα νέα δείγματα. Κατά την εκπαίδευση, $\hat{Y}_n$ είναι οι προβλέψεις για τα νέα δείγματα χρησιμοποιώντας τις τρέχουσες $\hat{\theta}_s$ και $\hat{\theta}_n$ και $\hat{Y}_o$ οι προβλέψεις για τα νέα δείγματα χρησιμοποιώντας τις τρέχουσες $\hat{\theta}_s$ και $\hat{\theta}_o$.

Experience replay: Η στρατηγική αυτή αφορά την αποθήκευση ορισμένων δειγμάτων από τα προηγούμενα σύνολα δεδομένων σε εξωτερική μνήμη προκαθορισμένου μεγέθους. Κατά την εκπαίδευση συνδυάζονται αυτά τα δείγματα με τα δεδομένα του τρέχοντος προβλήματος και έτσι το μοντέλο διατηρεί ταυτόχρονα την προηγούμενη γνώση.

Synaptic Intelligence (SI) [46]: Η στρατηγική αυτή αποτρέπει μεγάλες αλλαγές των παραμέτρων που κρίνονται σημαντικές στην επίλυση προβλημάτων στα οποία έχει εκπαιδευτεί προηγουμένως το μοντέλο. Έτσι οι νέες γνώσεις επηρεάζουν κυρίως τις μη σημαντικές παραμέτρους στην προσπάθεια αποφυγής του catastrophic forgetting. Λειτουργεί παρόμοια με την EWC, ωστόσο πραγματοποιεί τους υπολογισμούς με online τρόπο κατά την διάρκεια της εκπαίδευσης. Το μέτρο της σημαντικότητας είναι ανάλογο της συνεισφοράς της παραμέτρου στην μείωση της απώλειας με την πάροδο του χρόνου. Οι παράμετροι περιγράφονται ως συνάψεις λόγω της συσχέτισής τους με τις βιολογικές λειτουργίες του εγκεφάλου.

Η τροποποιημένη με τον όρο κανονικοποίησης συνάρτηση απωλειών που χρησιμοποιείται παρουσιάζεται στην εξίσωση 5.13:

$$\tilde{L}_\mu = L_\mu + c \sum_k \Omega_k^\mu \left(\tilde{\theta}_k - \theta_k \right)^2 \quad (5.13)$$

όπου L_μ είναι η συνάρτηση απώλειας του τρέχοντος task, $\tilde{\theta}_k = \theta_k(t^{\mu-1})$ οι παράμετροι στο τέλος του προηγούμενου task (παράμετροι αναφοράς), θ_k οι τρέχουσες παράμετροι.

Επίσης χρησιμοποιείται η ανά-παράμετρο δύναμη της κανονικοποίησης που ορίζεται από την εξίσωση 5.14:

$$\Omega_k^\mu = \sum_{\nu < \mu} \frac{\omega_k^\nu}{(\Delta_k^\nu)^2 + \xi} \quad (5.14)$$

όπου ο όρος $(\Delta_k^\nu)^2$ εξασφαλίζει τις ίδιες μονάδες με την συνολική απώλεια και η παράμετρος ξ (damping parameter) την αποφυγή διαίρεσης με το 0. Το ω_k^μ (importance measure) δείχνει πόσο σημαντικές είναι οι παράμετροι θ_k για το task μ και υπολογίζεται κατά την διάρκεια της εκπαίδευσης ως το τρέχον άθροισμα του γινομένου της παραγώγου του loss $g_k(t) = \frac{\partial L}{\partial \theta_k}$ με την ανανέωση της παραμέτρου $\theta'_k(t) = \frac{\partial \theta_k}{\partial t}$. Τέλος, η παράμετρος c αντισταθμίζει την

ισορροπία μεταξύ προηγούμενων και νέων προβλημάτων με την τιμή 1 τυπικά να προσδίδει ίσα βάρη στις δύο περιπτώσεις και την τιμή 0 να αγνοεί την ήδη υπάρχουσα γνώση.

Baselines

Η αξιολόγηση των στρατηγικών διαρκούς μάθησης διευκολύνεται εάν συγκριθούν με κάποιες στρατηγικές αναφοράς. Αυτές είναι απλοϊκές ή συνολικές τεχνικές οι οποίες θα μπορούσαν να δώσουν τα θεωρητικά κάτω και άνω όρια.

Individual learning: Εκπαίδευση ενός ξεχωριστού μοντέλου για κάθε task (/domain) με τα δικά του μόνο δεδομένα. Δεν υπάρχουν λοιπόν οι έννοιες forgetting και transfer.

Naive: Εκπαιδεύει διαδοχικά το μοντέλο στα διαφορετικά σύνολα δεδομένων με απλό finetuning χωρίς να εφαρμόζει κάποια μέθοδο για αποφυγή του catastrophic forgetting. Επεξηγηματικά, λαμβάνει υπόψη μόνο το τρέχον σύνολο δεδομένων για την εκπαίδευση, ενώ αρχικοποιεί τα βάρη με βάση την τελευταία προηγούμενη εκπαίδευση. Η επίδρασή του catastrophic forgetting είναι άρα εμφανής στα αποτελέσματα και έτσι η στρατηγική αυτή είναι η πιο απλή και λιγότερο αποδοτική.

Cumulative: Εκπαίδευση του μοντέλου στα τρέχουσα δεδομένα αθροιστικά με όλα τα προηγούμενα δεδομένα. Επανεκτιμά τις παραμέτρους του μοντέλου χρησιμοποιώντας όλη τη διαθέσιμη ως εκείνη τη στιγμή πληροφορία, το οποίο απαιτεί υψηλό υπολογιστικό φόρτο και προϋποθέτει τα δεδομένα να παραμένουν προσβάσιμα στο σύνολο τους.

Joint training: Εκπαίδευση ενός μοντέλου στο οποίο δίνονται ταυτόχρονα όλα τα δεδομένα όλων των διαφορετικών συνόλων τα οποία είναι διαθέσιμα από την αρχή. Προϋποθέτει πρόσβαση σε όλα τα δεδομένα και έχει μεγάλες απαιτήσεις μνήμης και χρόνου. Εάν υπάρχει αρκετά μεγάλο πλήθος δεδομένων ξεπερνά προβλήματα όπως το catastrophic forgetting. Εάν από την άλλη οι διαφορές των κατανομών είναι μεγάλες και τα μεγέθη είναι άνισα οδηγεί σε υποβέλτιστη δυνατότητα γενίκευσης.

5.3.2 Υλοποίηση με επέκταση σε άλλα σύνολα δεδομένων

Συνεπώς, η προσέγγιση της διαρκούς μάθησης μπορεί να αποδειχθεί χρήσιμη για την επέκταση του προβλήματος της βελτιστοποίησης της ενεργειακής απόδοσης των κτηρίων σε άλλα σύνολα πραγματικών δεδομένων. Έτσι έπειτα από εκτενή αναζήτηση σχετικών δεδομένων από άλλες χώρες εκτός της Λετονίας, βρέθηκε ένα πλήθος τέτοιων συνόλων τα οποία παρουσιάζονται αναλυτικά στο Κεφάλαιο 2.2. Η επιλογή πραγματοποιήθηκε πρωτίστως με βάση τον περιορισμό της ελεύθερης πρόσβασης και διαθεσιμότητας των δεδομένων. Ως κριτήρια τέθηκαν, επίσης, το κτήριο να λειτουργεί ως κατοικία (residential), να περιλαμβάνονται προτάσεις μέτρων αναβάθμισης και η ενεργειακή αξιολόγηση να γίνεται μέσω της ενεργειακής κλάσης η οποία να ορίζεται σαφώς τόσο πριν όσο και μετά την υλοποίηση. Συνεπώς, στοχεύοντας ακόμα στην μεγαλύτερη ομοιότητα με τα αρχικά Λετονικά δεδομένα καταλήγουμε στην χρήση των συνόλων δεδομένων ενεργειακών πιστοποιητικών της Ιταλίας (CENED DB)

και της Αγγλίας (Energy Performance of Buildings Data England and Wales).

Τα δεδομένα αυτά έχουν μεγάλο πλήθος χαρακτηριστικών (196 και 99 αντίστοιχα), αλλά καθώς γενικά εξυπηρετούν διαφορετικούς σκοπούς δεν είναι όλα χρήσιμα για την μελέτη μας. Επομένως επιλέγονται χαρακτηριστικά που είναι κοινά με το αρχικό μας σύνολο δεδομένων, τα οποία παρουσιάζονται στον Πίνακα 5.2. Κρατάμε λοιπόν τις στήλες που είναι κοινές στα τρία σύνολα. Σημειώνεται ότι μερικά από τα χαρακτηριστικά αυτά δεν υπάρχουν αυτούσια αλλά μπορούν να εξαχθούν μέσω υπολογισμών ή συνδυασμών των υπολοίπων.

Latvian	Italian	English
Initial year of exploitation	✓	✓
Building total area	✓	✓
Reference area	✓	X
Room volume	X	X
Average floor height	X	✓
Above-ground floors	✓	✓
Underground floor	✓	X
Roof floor	X	✓
Mansard	X	✓
Initial energy class	✓	✓
Energy consumption before	✓	✓
Energy class after	✓	✓

Πίνακας 5.2: Κοινά χαρακτηριστικά συνόλων δεδομένων Λετονίας, Ιταλίας, Αγγλίας

Σχετικά με τα μέτρα ενεργειακής αναβάθμισης που αποτελούν τις κλάσεις του προβλήματος οι επιλογές σε κάθε σύνολο δεδομένων διαφοροποιούνται. Συνεπώς ομαδοποιούμε τις τιμές στις κατηγορίες μέτρων που συναντώνται στην Λετονία ως εξής:

- Carrying out construction works: αφορά αναβαθμίσεις στην περιβάλλουσα δομή του κτηρίου, όπως αλλαγές στην μόνωση.
- Reconstruction of engineering systems: αφορά βελτίωση ή αντικατάσταση διαφόρων συστημάτων των κτηρίων, όπως εξαερισμού, φωτισμού κλπ. Ακόμη περιλαμβάνει μέτρα που αφορούν τον έλεγχο (και όχι την παραγωγή) της ενεργειακής χρήσης για θέρμανση.
- Water heating system: αφορά το σύστημα θέρμανσης νερού και τις αλλαγές που εμπίπτουν αποκλειστικά σε αυτό.
- Heat installation: αφορά την αναβάθμιση ή αντικατάσταση των συστημάτων θέρμανσης χρησιμοποιώντας είτε ανανεώσιμες πηγές ενέργειας είτε πιο αποδοτικά συστήματα που διαχειρίζονται καλύτερα τα ίδια καύσιμα.

Το ιταλικό σύνολο δεδομένων δεν παρέχει πληροφορίες για μέτρα που εμπίπτουν στην τρίτη

κατηγορία, οπότε για λόγους λειτουργικότητας στα πειράματα που ακολουθούν διατηρούμε τις υπόλοιπες τρεις κλάσεις.

Επιπρόσθετα πριν την χρήση των δεδομένων απαιτείται η προεπεξεργασία τους ώστε να εξαλειφθούν τυχόν ασυνέπειες και να εξασφαλιστεί η αξιοπιστία και η ομαλή αναπαράστασή τους. Αυτό το βήμα είναι αναγκαίο καθώς οι πληροφορίες του εκάστοτε πιστοποιητικού συλλέγονται και καταγράφονται από διαφορετικούς ανθρώπους (τους ειδικούς που αξιολογούν το κάθε κτήριο) και δεν έχει υπάρξει μέριμνα ομοιόμορφων καταχωρήσεων. Έτσι διατηρούμε πραγματοποιούμε μία σειρά διαδοχικών τροποποιήσεων και προσαρμογών στα δεδομένα έπειτα από μελέτη των τιμών που λαμβάνουν τα χαρακτηριστικά τους.

Προκειμένου να εξασφαλίσουμε δύο σύνολα δεδομένων όσο το δυνατόν πιο ισορροπημένα ως προς τις κλάσεις των μέτρων αναβάθμισης, τα οποία δεν θα περιλαμβάνουν κενές ή λανθασμένης μορφής τιμές, επιλέγονται κατάλληλα υποσύνολα των παραπάνω συνόλων.

Έτσι το πρόβλημά μας ανάγεται σε domain-incremental learning όπου κάθε σύνολο δεδομένων αντιμετωπίζεται ως ένα ξεχωριστό domain. Ο στόχος είναι κοινός, δηλαδή ίδιες κλάσεις εξόδου, και η διαφοροποίηση των δεδομένων έγκειται στην διαφορετική κατανομή λόγω της προέλευσής τους από άλλες χώρες.

Για την υλοποίηση χρησιμοποιείται η βιβλιοθήκη Avalanche [47], η οποία είναι σχεδιασμένη για διαρκή μάθηση και βασίζεται στο PyTorch. Τα δεδομένα μοντελοποιούνται ως μία ακολουθία (αλλιώς ροή ή stream) από εμπειρίες μάθησης (experiences), τις οποίες το μοντέλο επεξεργάζεται διαδοχικά. Όπως σε κάθε περίπτωση μάθησης υπάρχει το train stream για την εκπαίδευση του μοντέλου και το test stream για την αξιολόγησή του, τα οποία με βάση τους όρους και τις διαδικασίες της Avalanche συνθέτουν ένα benchmark. Στην περίπτωση των περιγραφόμενων πειραμάτων αντιστοιχούμε κάθε experience σε ένα σύνολο δεδομένων, δηλαδή ένα domain, και συνεπώς έχουμε 3 εμπειρίες σε κάθε stream (1 για τα δεδομένα της Λετονίας, 1 για της Ιταλίας και 1 για της Αγγλίας).

Για την εκπαίδευση εφαρμόζονται οι στρατηγικές που επεξηγήθηκαν στην προηγούμενη ενότητα, οι οποίες διατίθενται υλοποιημένες από την Avalanche [48]. Όσον αφορά την αξιολόγηση εκτός από τις έτοιμες μετρικές που παρέχει δίνει την δυνατότητα στον χρήστη να ορίσει νέες μέσω ειδικών plugins. Προκειμένου, λοιπόν, να αξιολογήσουμε την multilabel ταξινόμηση που εξετάζουμε με αποτελέσματα συγκρίσιμα με της έως τώρα μελέτης, ενσωματώνουμε τις μετρικές accuracy, precision, recall, F1 score, hamming distance στην multilabel μορφή τους. Ο υπολογισμός των μετρικών πραγματοποιείται στο τέλος της εκπαίδευσης κάθε experience. Δηλαδή εφόσον το μοντέλο εκπαιδευτεί στα δεδομένα της Αγγλίας αξιολογείται τόσο σε αυτά (προφανώς στο αντίστοιχο σύνολο ελέγχου), όσο και στα δεδομένα της Ιταλίας και της Λετονίας. Έπειτα το μοντέλο εκπαιδεύεται στο ιταλικό σύνολο και αξιολογείται στα δεδομένα ελέγχου και των τριών χωρών κ.ο.κ. Με αυτόν τον τρόπο γίνονται εμφανείς πιθανές επιπτώσεις των catastrophic forgetting, forward/backward transfer και αξιολογείται η απόδοση κάθε στρατηγικής.

Κεφάλαιο 6

Αποτελέσματα

Στο κεφάλαιο αυτό παρατίθενται όλα τα αποτελέσματα των πειραμάτων που αναλύθηκαν στο Κεφάλαιο 5 συνοδευόμενα από τον αντίστοιχο σχολιασμό τους.

6.1 Αποτελέσματα αξιολόγησης συνθετικών δεδομένων

Πρωτίστως αξίζει να αναφερθούμε στην αξιολόγηση των συνθετικών δεδομένων που παράχθηκαν συγκριτικά με τα αρχικά σύμφωνα με την ενότητα 5.2.3. Τα σχετικά αποτελέσματα παρατίθενται στον Πίνακα 6.1.

Diagnostic Report	100%
Quality Report	Column shapes score: 80% Column pair trends: 60% Average similarity score: 70%

Πίνακας 6.1: Αξιολόγηση συνθετικών δεδομένων


Αρχικά ο έλεγχος εγκυρότητας (Diagnostic Report) δίνει αποτέλεσμα 100%. Επομένως αντιλαμβανόμαστε ότι η βασική μορφή και δομή των συνθετικών δεδομένων δείχνει ίδια με των πραγματικών. Από τον έλεγχο ποιότητας (Quality Report) λαμβάνουμε τιμές περίπου 80% και 60% για τα Column shapes score και Column pair trends αντίστοιχα. Συμπερασματικά το συνολικό ποσοστό ομοιότητας κατά μέσο όρο είναι 70%. Δηλαδή τα νέα δεδομένα προσομοιάζουν σε έναν σημαντικό βαθμό τα αρχικά όσον αφορά την κάθε στήλη μεμονωμένα, ενώ παρουσιάζουν λίγο μεγαλύτερη δυσκολία στην αποτύπωση της μεταξύ τους συσχέτισης. Αναλογιζόμενα, όμως, την αρχική ποσότητα και κατανομή τους καθώς και την έλλειψη ισορροπημένων κλάσεων, το αποτέλεσμα είναι δικαιολογημένο και θεωρείται ικανοποιητικό για τους σκοπούς της εργασίας μας. Για παράδειγμα, υπενθυμίζεται πως οι στήλες Heat installation και Water heating system στο αρχικό σύνολο διαθέτουν από 10 μόνο περίπου δείγματα με την τιμή 1. Έτσι, προφανώς καθίσταται πιο δύσκολο για το CTGAN μοντέλο να μάθει πιθανά πρότυπα και σχέσεις που συμπεριλαμβάνουν τα χαρακτηριστικά αυτά.

6.2 Αποτελέσματα αρχικών και συνθετικών δεδομένων

Ακολούθως, παρατίθενται τα αποτελέσματα που προέκυψαν μετά την εκπαίδευση και τον έλεγχο του μοντέλου στο αρχικό σύνολο δεδομένων της Λετονίας αλλά και στα συνθετικά δεδομένα. Αυτά παρουσιάζονται στον Πίνακα 6.2 και επίσης οπτικοποιούνται στο διάγραμμα του Σχήματος 6.1.

	Accuracy	Precision	Recall	F1 score	Hamming
Initial data	0.83	0.36	0.45	0.40	0.17
Synthetic data	0.65	0.61	0.53	0.52	0.35

Πίνακας 6.2: Αποτελέσματα μοντέλου στα αρχικά και τα συνθετικά δεδομένα



Σχήμα 6.1: Γράφημα αποτελεσμάτων αρχικών και συνθετικών δεδομένων

Όσον αφορά τα αρχικά δεδομένα, παρατηρούμε ότι οι περισσότερες μετρικές δεν δίνουν ιδιαίτερα καλά αποτελέσματα (precision, recall, F1 score). Αυτό ήταν αναμενόμενο λόγω των ιδιοτήτων που αναλύσαμε ήδη σε όλη την έκταση της διπλωματικής εργασίας, οι οποίες περιορίζουν τις δυνατότητες του μοντέλου. Η μετρική accuracy, από την άλλη, λαμβάνει τιμή της τάξης του 0.8 ή αλλιώς 80%. Ωστόσο αυτή η τιμή είναι πλασματική και δεν αντιπροσωπεύει την πραγματικότητα. Η συγκεκριμένη μετρική δεν λειτουργεί ορθά στις περιπτώσεις μη ισορροπημένων ως προς τις κλάσεις συνόλων δεδομένων, όπως είναι το εξεταζόμενο. Αυτό συμβαίνει καθώς παρά το γεγονός ότι το μοντέλο μπορεί να μην προσδίδει την απαιτούμενη βαρύτητα στην ετικέτα μειοψηφίας και να προβλέπει κατά κύριο λόγο την ετικέτα πλειοψηφίας, τα δείγματα που πράγματι ανήκουν στην πρώτη είναι λίγα και δεν επηρεάζουν σε μεγάλο βαθμό το ποσοστό των σωστών προβλέψεων. Έστω, για παράδειγμα, ότι έχουμε 100 συνολικά δείγματα εκ των οποίων τα 99 ανήκουν στην κλάση A και το 1 στην κλάση B. Τότε εάν το

μοντέλο προβλέπει συνεχώς την κλάση A θα επιτύχει accuracy ίση με 99%. Συνεπώς, το γεγονός ότι η τιμή της μετρικής αυτής είναι υψηλή δεν σημαίνει ότι το μοντέλο έχει ορθή συμπεριφορά. Για τον λόγο αυτό, προκειμένου να αξιολογήσουμε σφαιρικά την πραγματική επίδοση του μοντέλου χρειάζεται να λάβουμε υπόψη κι άλλες μετρικές πιο αντικειμενικές για την περίπτωση, όπως οι υπόλοιπες που υπολογίζουμε.

Χρησιμοποιώντας λοιπόν το εμπλουτισμένο από τα συνθετικά δεδομένα σύνολο, τα δείγματα του οποίου είναι πιο ισορροπημένα στις κλάσεις, παρατηρούμε ότι οι τιμές των μετρικών μεταβάλλονται. Αρχικά η μετρική accuracy μειώνεται περίπου κατά 0.15. Η αλλαγή αυτή θα μπορούσε να αποτελεί βελτίωση επειδή όπως προαναφέρθηκε η αρχικά υψηλή τιμή δεν ήταν αντιπροσωπευτική της επίδοσης του μοντέλου. Τώρα το μοντέλο εκτίθεται σε μεγαλύτερο ποσοστό δειγμάτων από όλες τις κλάσεις και έτσι εκπαιδεύεται εξίσου σε αυτές. Αυτή η μετρική, λοιπόν, αντικατοπτρίζει πλέον περισσότερο τις πραγματικές δυνατότητες του μοντέλου, αλλά σαφώς δεν λαμβάνει μια αρκετά καλή τιμή για την ταξινόμηση. Αντίστοιχη συμπεριφορά εμφανίζει και η μετρική hamming, η οποία αξιολογεί με βάση την οπτική των λανθασμένων προβλέψεων των ετικετών. Οι μετρικές recall και precision αυξάνονται, καθώς λόγω των περισσότερων και πιο αντιπροσωπευτικών δεδομένων το μοντέλο γίνεται πιο ικανό στην αναγνώριση των θετικών στιγμιότυπων όλων των κλάσεων και ταυτόχρονα αυτά που αναγνωρίζει ως θετικά είναι ορθώς ταξινομημένα. Παράλληλα αυξάνεται και το F1 score αφού προκύπτει συνδυάζοντας τα δύο προηγούμενα. Συνολικά δηλαδή είναι εμφανής η γενικότερη βελτίωση του μοντέλου μας μέσω της παραγωγής νέων δεδομένων και αυτό είναι αντιληπτό από τη βελτίωση όλων των μετρικών εκτός αυτής του accuracy, η οποία είναι μη αντιπροσωπευτική όπως και εξηγήθηκε. Σημειώνεται ωστόσο πως η βελτίωση αυτή δεν είναι αρκετή για να εξασφαλίσει αρκετά καλές και αποδεκτές μετρικές για το μοντέλο και το πρόβλημα σε απόλυτο επίπεδο.

6.3 Αποτελέσματα συνόλων δεδομένων άλλων χωρών


Στον Πίνακα 6.3 παρατίθενται τα αποτελέσματα της μεμονωμένης εκπαίδευσης (individual training) του μοντέλου σε κάθε ένα από τα σύνολα δεδομένων των χωρών της Αγγλίας και της Ιταλίας ξεχωριστά.

	Accuracy	Precision	Recall	F1 score	Hamming
English dataset	0.78	0.79	0.8	0.8	0.23
Italian dataset	0.8	0.78	0.79	0.78	0.2

Πίνακας 6.3: Αποτελέσματα μεμονωμένης εκπαίδευσης μοντέλου στα δεδομένα της Αγγλίας και Ιταλίας

Καθίσταται εμφανές ότι οι μετρικές στα αγγλικά και ιταλικά δεδομένα είναι βελτιωμένες σε μεγάλο βαθμό συγκριτικά με τα αντίστοιχα λετονικά. Μάλιστα η απόδοση των δύο είναι παρόμοια. Αυτό αναδεικνύει ότι το μοντέλο έχει την δυνατότητα να λειτουργήσει ορθά σε μεγάλα και ισορροπημένα σύνολα δεδομένων και τα χαμηλά αποτελέσματα για την Λετονία

οφείλονται στους περιορισμούς που επιφέρει το σύνολό της.



Σχήμα 6.2: Γράφημα αποτελεσμάτων μεμονωμένης εκπαίδευσης συνόλων δεδομένων

6.4 Αποτελέσματα τεχνικών διαρκούς μάθησης

Όπως αναφέρθηκε και στην μεθοδολογία, η ακόλουθη μελέτη αφορά τις τρεις μόνο κλάσεις ώστε να υπάρχει συνοχή μεταξύ όλων των συνόλων δεδομένων. Στον Πίνακα 6.4 παρουσιάζονται τα αποτελέσματα των λετονικών δεδομένων στην περίπτωση αυτή.

	Accuracy	Precision	Recall	F1 score	Hamming
Latvian dataset	0.81	0.43	0.52	0.51	0.19

Πίνακας 6.4: Αποτελέσματα εκπαίδευσης μοντέλου στα δεδομένα της Λετονίας για 3 κλάσεις

Παρατηρούμε ότι προκύπτουν λίγο διαφοροποιημένα ως προς τις μετρικές precision, recall, F1 score, οι τιμές των οποίων έχουν αυξηθεί κατά περίπου 0.07. Αυτό θα μπορούσε να δικαιολογηθεί καθώς η κλάση που αφαιρέθηκε είναι μία από αυτές που εμφανίζουν εξαιρετικά μεγάλη ανισορροπία των ετικετών με ελάχιστα θετικά δείγματα και δυσχεραίνουν την λειτουργία του μοντέλου. Τα υπόλοιπα δεδομένα δεν εμφανίζουν διαφοροποιήσεις στις τιμές των μετρικών τους. Μάλιστα το Σχήμα 6.2 οπτικοποιεί την σύγκριση των τριών συνόλων δεδομένων κατά την μεμονωμένη εκπαίδευση του μοντέλου με κάθε ένα από αυτά.

Ακολουθώντας στον Πίνακα 6.5 αναγράφονται τα αποτελέσματα των μετρικών για κάθε στρατηγική διαρκούς μάθησης που εφαρμόστηκε. Συγκεκριμένα αναφέρονται στο τέλος της συνολικής εκπαίδευσης αφού αυτή πραγματοποιηθεί και για το τελευταίο σύνολο δεδομένων (experience) δηλαδή τα δεδομένα της Λετονίας. Οι μετρικές παρατίθενται για την αξιολόγηση κάθε συνόλου δεδομένων (ελέγχου) ξεχωριστά εκείνη την χρονική στιγμή.

Strategy	Evaluate in	Accuracy	Precision	Recall	F1	Hamming
Naive	English	0.549	0.730	0.442	0.464	0.451
	Italian	0.585	0.556	0.542	0.465	0.415
	Latvian	0.707	0.556	0.403	0.460	0.293
Cumulative	English	0.767	0.785	0.807	0.795	0.233
	Italian	0.764	0.733	0.771	0.751	0.236
	Latvian	0.813	0.485	0.560	0.518	0.187
Joint training	English	0.761	0.786	0.790	0.787	0.239
	Italian	0.758	0.719	0.787	0.751	0.242
	Latvian	0.807	0.503	0.547	0.524	0.193
EWC	English	0.533	0.670	0.510	0.556	0.467
	Italian	0.688	0.692	0.630	0.618	0.312
	Latvian	0.673	0.510	0.409	0.453	0.327
LwF	English	0.526	0.675	0.519	0.533	0.474
	Italian	0.630	0.626	0.647	0.584	0.370
	Latvian	0.687	0.581	0.401	0.461	0.313
Replay	English	0.621	0.661	0.684	0.672	0.379
	Italian	0.726	0.681	0.766	0.720	0.274
	Latvian	0.800	0.548	0.498	0.512	0.200
Synaptic intelligence	English	0.526	0.651	0.558	0.572	0.474
	Italian	0.698	0.696	0.690	0.712	0.307
	Latvian	0.700	0.586	0.415	0.482	0.300

Πίνακας 6.5: Αποτελέσματα στρατηγικών διαρκούς μάθησης στα δεδομένα Αγγλίας, Ιταλίας, Λετονίας υπολογισμένα μετά το τέλος όλων των στάδιων εκπαίδευσης

Στα αποτελέσματα της Naive στρατηγικής αποτυπώνεται η αναμενόμενη συμπεριφορά του διαδοχικού finetuning το οποίο πάσχει από catastrophic forgetting. Η ύπαρξή του γίνεται ξεκάθαρη καθώς οι τιμές των μετρικών των αγγλικών και ιταλικών δεδομένων είναι αρκετά μειωμένες συγκριτικά με την περίπτωση της μεμονωμένης εκπαίδευσης σε αυτά (Πίνακας 6.3). Κατά συνέπεια το μοντέλο δε διατηρεί την προηγούμενη γνώση που έχει αποκτήσει κατά την πάροδο της διαδοχικής διαδικασίας εκπαίδευσης. Μάλιστα η μέγιστη απόδοση αυτών επιτυγχάνεται στο βήμα όπου τα δεδομένα εκπαίδευσης είναι του εκάστοτε ίδιου συνόλου δεδομένων. Οι τιμές αυτές στο επόμενο βήμα πέφτουν. Όσον αφορά στο σύνολο της Λετονίας εκεί παρατηρούνται μικτές μεταβολές των τιμών των μετρικών με κάποιες να αυξάνονται (π.χ. precision) και κάποιες να μειώνονται (π.χ. recall). Η μετρική accuracy και σε αυτήν την περίπτωση πιθανώς δεν είναι αντιπροσωπευτική για τους λόγους που προαναφέρθηκαν.

Από την άλλη, η Cumulative στρατηγική δίνει αποτελέσματα για τα δεδομένα της Αγγλίας και της Ιταλίας όμοια σχεδόν με αυτά της μεμονωμένης εκπαίδευσης (της Ιταλίας με μικρή μείωση). Άρα αντίθετα από την Naive η βελτίωση που επιφέρει κάθε εκπαίδευση στο αντίστοιχο σύνολο δεδομένων διατηρείται μέχρι τέλους και δεν εμφανίζεται το πρόβλημα του catastrophic

forgetting. Αυτό μπορούσε εύκολα να προβλεφθεί καθώς σε κάθε στάδιο εκπαίδευσης (experience) επαναλαμβάνονται όλα τα δεδομένα τα οποία έχουν χρησιμοποιηθεί έως τότε. Σχετικά με τα αποτελέσματα της Λετονίας, αυτά εμφανίζουν βελτίωση σε όλες τις βασικές μετρικές. Ωστόσο αυτή η τεχνική είναι υπολογιστικά πολύ πιο ακριβή ειδικά όσο αυξάνεται ο όγκος δεδομένων. Επίσης έρχεται σε αντίθεση με τις υπόλοιπες τεχνικές, οι οποίες μπορούν να συνεχίσουν την εκπαίδευση του μοντέλου σε μεταγενέστερο χρόνο με νέα δεδομένα χωρίς την προϋπόθεση να έχουν διατηρηθεί τα προηγούμενα (με εξαίρεση την Replay που όμως απαιτεί ένα πολύ μικρό ποσοστό δειγμάτων).


Αντίστοιχα αποτελέσματα δίνει το Joint training το οποίο όμως στην πραγματικότητα δεν αποτελεί μία περίπτωση διαρκούς μάθησης αφού τα δεδομένα δίνονται όλα εξ αρχής. Το υπολογιστικό του κόστος είναι αδιαμφισβήτητο και σε κάθε νέα προσθήκη δεδομένων απαιτεί επανεκπαίδευση του μοντέλου από τη αρχή.

Συγκρίνουμε τώρα αποκλειστικά τα αποτελέσματα των λετονικών δεδομένων μεταξύ της Naive στρατηγικής και των αθροιστικών τεχνικών (Cumulative, Joint training). Η πρώτη επιτυγχάνει μεγαλύτερη τιμή precision, αντίθετα με την τιμή recall που μειώνεται. Το γεγονός αυτό μπορεί να αναδείξει τα πιθανά προβλήματα που έχουν διαδικασίες όπως το Joint training για σύνολα δεδομένων διαφορετικών μεγεθών με διαφορετικές κατανομές (domain shifts). Οι διακριτές ιδιότητες, ειδικά των λιγότερων δεδομένων, μπορούν να «θολώσουν» μειώνοντας την δυνατότητα γενίκευσης. Η εξαιρετικά μεγάλη αύξηση των συνολικών δεδομένων από την άλλη, μπορεί να αντισταθμίσει το γεγονός αυτό συνεισφέροντας θετικά στο μοντέλο ιδιαίτερα σε περιπτώσεις μικρότερων αποκλίσεων. Σημαντικός παράγοντας ακόμη παραμένει ότι οι τεχνικές αυτές είναι πολύ πιο ακριβές και με περιορισμούς διαθεσιμότητας.

Συνεχίζοντας στις αμιγώς διαρκούς μάθησης τεχνικές (Replay, EWC, Lwf, Synaptic intelligence), θα μπορούσε κανείς να συμπεράνει πως είναι δυνητικά εφικτό να επιτευχθούν ικανοποιητικά αποτελέσματα χωρίς την ανάγκη χρήσης όλων των δεδομένων επαναληπτικά αλλά με ένα μικρό ποσοστό αυτών. Η τεχνική Replay κρατά και επαναχρησιμοποιεί ένα συγκεκριμένο πλήθος δεδομένων, 40 δείγματα ανά σύνολο δεδομένων στην περίπτωση μας, το οποίο είναι αρκετά μικρό συγκριτικά με την τάξη των χιλιάδων δειγμάτων που περιλαμβάνονται αρχικά. Τα αποτελέσματα της Λετονίας είναι πράγματι βελτιωμένα στο σύνολό τους, ενώ των δύο άλλων χωρών έχουν ξεπεράσει σε μεγάλο βαθμό το catastrophic forgetting. Της Ιταλίας μάλιστα σχεδόν αγγίζουν την επίδοση που θα είχαν αν επαναλαμβανόταν ολόκληρο το σύνολο δεδομένων της. Είναι προφανές ότι η περαιτέρω αύξηση της μνήμης μπορεί να επιφέρει και περαιτέρω αύξηση των τιμών των μετρικών.

Τα αποτελέσματα των τεχνικών που βασίζονται στην κανονικοποίηση (EWC, LwF, Synaptic intelligence) και δεν απαιτούν καθόλου προηγούμενα δείγματα δεδομένων φαίνεται ότι επίσης διαθέτουν προοπτικές βελτίωσης, παρέχοντας μία ισορροπία μεταξύ της διατήρησης παλιάς γνώσης και της απόκτησης νέας. Στην ισορροπία αυτή σημαντικό ρόλο διαδραματίζουν οι παράμετροι της κάθε στρατηγικής και συμπεραίνουμε πως η σύγκριση μεταξύ τους μπορεί να πραγματοποιηθεί ανάλογα την μετρική που επιθυμούμε καθώς παρουσιάζουν διακυμάνσεις ως προς τις μεταβολές τους. Τα αποτελέσματα των δύο πρώτων συνόλων δεδομένων είναι κατά βάση αυξημένα σε σχέση με την αρχική Naive τεχνική. Δίνουν λοιπόν βαρύτητα στην

διατήρηση της προηγούμενης γνώσης, η οποία παραμένει στο μοντέλο σε πιο ικανοποιητικό βαθμό έως και το τέλος του πειράματος εκπαίδευσης που υλοποιούμε. Επιπλέον διακρίνουμε μία διαφορά στις επιδόσεις μεταξύ των δεδομένων της Αγγλίας και της Ιταλίας με την δεύτερη να παρουσιάζει υψηλότερες τιμές μετρικών. Μία τέτοια απόκλιση δεν δικαιολογείται από την μορφή των δεδομένων, όπως είδαμε και στην επιμέρους μελέτη τους, αλλά από την σειρά τους. Πιο αναλυτικά, εφόσον η εκπαίδευση στο αγγλικό σύνολο εκτελείται πρώτη μεσολαβεί περισσότερος χρόνος έως την στιγμή των απεικονιζόμενων αποτελεσμάτων. Έτσι, η διατήρηση της αντίστοιχης γνώσης εξασθενεί περισσότερο συγκρινόμενη με τα ιταλικά δεδομένα τα οποία το μοντέλο συνάντησε πιο πρόσφατα.



Σχήμα 6.3: Γράφημα μετρικής precision για κάθε σύνολο δεδομένων για κάθε στρατηγική

Στο σημείο αυτό, έπειτα από την γενική ανασκόπηση της απόδοσης κάθε στρατηγικής σε όλες τις μετρικές, έχει νόημα να εστιάσουμε στην μετρική precision. Όπως επεξηγήθηκε στην ενότητα 5.1, η συγκεκριμένη μετρική αποδεικνύεται ιδιαίτερα σημαντική στα πλαίσια του προβλήματος που μελετάμε. Γι' αυτό στο Σχήμα 6.3 παρουσιάζεται το γράφημα των τιμών precision για κάθε στρατηγική σε κάθε σύνολο δεδομένων.

Είναι εμφανές ότι τα αποτελέσματα για τα δεδομένα της Λετονίας βελτιώνονται με την χρήση όλων των στρατηγικών διαρκούς μάθησης που χρησιμοποιήσαμε. Μάλιστα, στην περίπτωση αυτή η στρατηγική Synaptic intelligence επιφέρει την μέγιστη βελτίωση αυξάνοντας το precision κατά 0.156. Αμέσως μετά ακολουθεί η τεχνική LwF με σχεδόν αντίστοιχη επίδοση. Επομένως καθίσταται σαφές πως στα πλαίσια του προβλήματός μας το αρχικό σύνολο της Λετονίας επωφελείται από την χρήση της διαρκούς μάθησης.

Αναφορικά με τα σύνολα δεδομένων της Αγγλίας και της Ιταλίας παρατηρούμε την επίδραση του catastrophic forgetting και στην μετρική precision. Εξαιρουμένων των στρατηγικών Naive, Cumulative που εμφανίζουν την συμπεριφορά που επεξηγήσαμε προηγουμένως, γίνεται αντιληπτό ότι οι υπόλοιπες τεχνικές κατορθώνουν να το εξαλείψουν σε βαθμό που κρίνεται ικανοποιητικός για τα πλαίσια της μελέτης μας. Οι στρατηγικές αυτές σε αύξουσα σειρά απο-

τελεσματικότητας για το ιταλικό σύνολο δεδομένων είναι SI, EWC, Replay, LwF ενώ για το αγγλικό LwF, EWC, Replay, SI.

Αν μελετήσουμε, από την άλλη, την μετρική F1 score διαπιστώνουμε πως στην περίπτωση της Λετονίας, όταν η τιμή της δεν επιδέχεται αύξηση, η μείωση που παρατηρείται δεν είναι δραματικά μεγάλη. Έτσι, παρά την ελάττωση του recall που προκύπτει σε ορισμένες στρατηγικές, η ισορροπία μεταξύ των μετρικών διατηρείται. Επομένως, η υπεροχή της precision έναντι της recall βρίσκεται εντός ορίων και είναι αποδεκτή στα πλαίσια της πρόβλεψης μέτρων ενεργειακής αναβάθμισης κτηρίων. Επισημαίνουμε ότι αυτό ισχύει καθώς επιθυμούμε οι προτάσεις να είναι πράγματι κατάλληλες (υψηλό precision) χωρίς να ζημιώνουν οικονομικά τους ιδιοκτήτες/ριες, ενώ εάν κάποιες απαιτούμενες υλοποιήσεις παραλειφθούν (χαμηλό recall) μπορούν να επιλεγθούν σε δεύτερη μελέτη στην συνέχεια.

Συνοψίζοντας το γενικό συμπέρασμα που μπορεί να εξαχθεί είναι πως η διαρκής μάθηση μπορεί να συμβάλει στο πρόβλημα βελτιστοποίησης της ενεργειακής απόδοσης των κτηρίων που μελετάμε. Τα αποτελέσματα είναι ενθαρρυντικά για το αρχικό σύνολο δεδομένων το οποίο μπορεί να ενισχυθεί κατ' αυτόν τον τρόπο. Περαιτέρω βελτίωση πιθανώς μπορεί να επιτευχθεί με μεγαλύτερη ρύθμιση των υπερπαραμέτρων των στρατηγικών που χρησιμοποιούνται αλλά και του μοντέλου. Ωστόσο πρέπει να σημειωθεί ότι η αύξηση αυτή στο συγκεκριμένο σύνολο δεδομένων θα είναι πάντοτε περιορισμένη, καθώς οι ιδιαιτερότητές του δεν είναι εφικτό να εξαλειφθούν πλήρως. Τα αγγλικά και ιταλικά σύνολα δεδομένων από την μεριά τους δεν λαμβάνουν θετική επίδραση από την διαδικασία αυτή, αλλά οδηγούν στην τελική υλοποίηση ενός ενιαίου μοντέλου με δυνατότητες πρόβλεψης ανεξαρτήτως της χώρας προέλευσης. Το μοντέλο αυτό θα μπορεί μέσω των τεχνικών διαρκούς μάθησης να βελτιώνεται συνεχώς αποδοτικά με νέα δεδομένα που προέρχονται είτε από διαφορετικές χώρες είτε από επιπρόσθετα κτήρια στις ήδη εξεταζόμενες περιοχές.

Κεφάλαιο 7

Συμπεράσματα και μελλοντικές επεκτάσεις

7.1 Σύνοψη και συμπεράσματα

Στην παρούσα διπλωματική εργασία μελετήθηκε το πρόβλημα της βελτιστοποίησης της ενεργειακής απόδοσης κτηρίων μέσω διαφορετικών τεχνικών και δεδομένων. Κύριο άξονα αποτέλεσε η πρόβλεψη των απαιτούμενων μέτρων ενεργειακής αναβάθμισης, τα οποία με την εφαρμογή τους δύνανται να βελτιώσουν την ενεργειακή κλάση στον κτηριακό τομέα.

Ξεκινώντας πραγματοποιήθηκε εκτενής διερευνητική ανάλυση του συνόλου δεδομένων που είχαμε στην διάθεσή μας, το οποίο αφορά κτήρια κατοικιών της Λετονίας. Με τα δεδομένα αυτά, λοιπόν, εκπαιδεύτηκε ένα νευρωνικό δίκτυο πολλαπλών επιπέδων προκειμένου να προτείνει επιλογές αναβάθμισης για κάποιο κτήριο, δεδομένης της τελικής ενεργειακής κλάσης στην οποία επιθυμούμε να μεταβεί. Ωστόσο, όπως φάνηκε, το μοντέλο αυτό δεν απέφερε ικανοποιητικά αποτελέσματα. Μέσω της μελέτης των χαρακτηριστικών των δεδομένων και των σχέσεών τους εντοπίσαμε ορισμένες ιδιαιτερότητές τους, στις οποίες αποδίδεται η αιτία της συγκεκριμένης επίδοσης. Με βάση αυτές, επομένως, προσαρμόστηκε η μετέπειτα πορεία που ακολουθήσαμε.

Η ανάλυση επεκτάθηκε μέσω της χρήσης της μεθόδου επεξηγήσιμης τεχνητής νοημοσύνης shap, η οποία ανέδειξε την σημαντικότητα κάθε χαρακτηριστικού για την τελική πρόβλεψη του μοντέλου. Αρχικά η συνεισφορά της έγκειται στην διαφάνεια και την πληρέστερη κατανόηση της λειτουργίας του μοντέλου μηχανικής μάθησης. Οι επεξηγήσεις των προβλέψεων είναι καθοριστικής σημασίας προκειμένου να δημιουργηθεί ένα αξιόπιστο σύστημα πρόβλεψης, το οποίο οι χρήστες-ριες μπορούν να εμπιστεύονται και να υλοποιούν πράγματι τις προτάσεις του. Επιπροσθέτως, διαδραμάτισε βασικό ρόλο και στην διαδικασία ανάπτυξης του μοντέλου αυτού, καθώς συνέβαλε στην τελική επιλογή των χαρακτηριστικών που χρησιμοποιήθηκαν. Μελετώντας την επίδρασή τους ενισχύθηκε η ανάλυσή μας και με βάση αυτήν οδηγηθήκαμε στην απόρριψη περιττών για τον σκοπό μας στοιχείων. Τελικά καταλήξαμε σε ένα σύνολο χαρακτηριστικών, τα οποία είναι εύκολα προσβάσιμα από τον χρήστη και γενικευμένης φύσεως, χωρίς να εξαρτώνται από τον τύπο και την περιοχή του εκάστοτε κτηρίου. Μάλιστα εξετάστη-

κε και η δημιουργία νέων χαρακτηριστικών ως συνδυασμός των υφιστάμενων με στόχο την ενίσχυση των δυνατοτήτων γενίκευσης του μοντέλου, η οποία επίσης αξιολογήθηκε μέσω της μεθόδου shap.

Ένα από τα κύρια θέματα που κληθήκαμε να αντιμετωπίσουμε ήταν η μεγάλη ανισορροπία μεταξύ των θετικών και αρνητικών δειγμάτων των κλάσεων που παρουσίασε το σύνολο δεδομένων. Συνδυαστικά με το μικρό μέγεθός του, οδηγηθήκαμε στην ενσωμάτωση τεχνικών παραγωγής συνθετικών δεδομένων προκειμένου να το εμπλουτίσουμε και να το εξισορροπήσουμε. Ειδικότερα, ύστερα από ανασκόπηση των διαθέσιμων μεθόδων αποφασίστηκε η χρήση του μοντέλου Conditional Generative Adversarial Network για δεδομένα σε μορφή πίνακα (CTGAN). Συγκρίνοντας τα αποτελέσματα των νέων δεδομένων με αυτά των αρχικών ως προς τις ίδιες μετρικές, παρατηρήσαμε εμφανή βελτίωση. Μάλιστα η μέγιστη μεταβολή συναντάται στην μετρική precision, η οποία και μας αφορά ιδιαίτερα, και φτάνει την αύξηση κατά περίπου 0.25 άνω της αρχικής τιμής. Συνεπώς, ο εμπλουτισμός των δεδομένων με νέα συνθετικά συνδράμει ουσιαστικά στην ενίσχυση της απόδοσης του μοντέλου. Ωστόσο επισημαίνεται πως τα αποτελέσματα δεν είναι και πάλι απόλυτα ικανοποιητικά για το πρόβλημα, καθώς όπως κατέστη σαφές η δημιουργία των συνθετικών δεδομένων βασίζεται στην ποιότητα των αρχικών θέτοντας περιορισμούς στο ποσοστό βελτίωσης που μπορεί να επιτευχθεί. Αν, λοιπόν, αναλογιστούμε το παραπάνω συνδυαστικά με το γεγονός ότι το stagni κατόρθωσε βαθμό ομοιότητας των δεδομένων 70% κατά μέσο όρο, η τελική αξιολόγηση ήταν ικανοποιητική.

Με γνώμονα τα παραπάνω διευρύνουμε την έρευνα σε άλλα αντίστοιχα σύνολα πραγματικών δεδομένων προερχόμενα από διαφορετικές χώρες. Η αναλυτική αναζήτηση με κριτήριο την συμβατότητα με το πρόβλημά μας και την ομοιότητα με τα λετονικά δεδομένα μας οδήγησε στην υιοθέτηση δύο άλλων συνόλων. Αυτά προήλθαν από τα ενεργειακά πιστοποιητικά των κτηρίων με χώρες προέλευσης την Αγγλία και την Ιταλία. Η εφαρμογή του μοντέλου στα συγκεκριμένα σύνολα μεμονωμένα προσέφερε πολύ καλύτερα αποτελέσματα (της τάξης του 0.8) συγκριτικά με την Λετονία (της τάξης του 0.5 κατά μέσο όρο), αναδεικνύοντας την ανάγκη του μοντέλου για ένα επαρκές και ποιοτικό σύνολο δεδομένων.

Ο τρόπος που επιλέχτηκε για τον συνδυασμό των διαφορετικών συνόλων εκπαίδευσης είναι η διαρκής μάθηση (lifelong/continual learning). Ειδικότερα, ακολουθήσαμε το σενάριο domain-incremental learning, κατά το οποίο κάθε σύνολο δεδομένων αφορά ένα domain λόγω και της διαφορετικής κατανομής που προσδίδει η χώρα προέλευσης. Έτσι, το μοντέλο εκπαιδεύτηκε διαδοχικά στα σύνολα δεδομένων της Αγγλίας, της Ιταλίας και της Λετονίας ενσωματώνοντας στρατηγικές προς αποφυγή του catastrophic forgetting. Πέρα της απλοϊκής Naive στρατηγικής (benchmark), εξετάστηκαν στρατηγικές βασισμένες στην κανονικοποίηση (EWC, LwF, Synaptic intelligence), στην επανάληψη (Replay) και τέλος αθροιστικές (Cumulative). Συνολικά η γενικότερη τάση των αποτελεσμάτων είναι ενθαρρυντική με τις διάφορες μετρικές να κυμαίνονται σε διαφορετικές τιμές και κάθε μία υπερτερεί ανάλογα τις συνθήκες.

Για την αξιολόγηση των μεθόδων εστιάζουμε στην μετρική precision η οποία έχει επιλεγεί για το πρόβλημα, καθώς πρωταρχικός στόχος είναι να αποφευχθούν οποιεσδήποτε περιττές δαπάνες χρημάτων σε αναίτιες τελικά ενέργειες. Έτσι, λοιπόν, παρατηρήσαμε πως όλες οι

στρατηγικές διαρκούς μάθησης που εφαρμόσαμε επέφεραν αύξηση της συγκεκριμένης μετρικής για το σύνολο δεδομένων της Λετονίας. Ειδικότερα, από την τιμή 0.43 που πέτυχε η μεμονωμένη εκπαίδευση του μοντέλου στα αρχικά λετονικά δεδομένα καταλήξαμε στην τιμή 0.586 μέσω της στρατηγικής Synaptic intelligence. Δηλαδή η μέγιστη βελτίωση ανέρχεται σε 0.16, με την στρατηγική LwF να ακολουθεί αμέσως μετά με αύξηση κατά 0.15.

Όσον αφορά την επίδοση των προηγούμενων συνόλων δεδομένων, δηλαδή της Αγγλίας και της Ιταλίας, είναι εμφανής η επίδραση του φαινομένου catastrophic forgetting από το οποίο αναμέναμε να πλήττεται η διαρκής μάθηση. Συνεπώς οι τιμές της μετρικής precision εμφανίζονται μειωμένες συγκριτικά με αυτές που παρατηρήθηκαν κατά την εκπαίδευση σε κάθε ένα από αυτά τα σύνολα ξεχωριστά. Η χειρότερη περίπτωση συναντάται στην baseline Naive στρατηγική της οποίας η μέγιστη μείωση ανέρχεται στο 0.22, ενώ η καλύτερη στην Cumulative στρατηγική η οποία σχεδόν εξαλείφει την μείωση στο έως και 0.05 κατά μέσο όρο αυξάνοντας όμως παράλληλα το κόστος. Οι υπόλοιπες αποδοτικές στρατηγικές διαρκούς μάθησης κατορθώνουν να διατηρήσουν την μείωση σε επίπεδα που κυμαίνονται από 0.08 έως 0.15. Πιο αναλυτικά, για την Ιταλία προκύπτει τελική τιμή 0.696 (από 0.78) με την στρατηγική SI και για την Αγγλία 0.675 (από 0.79) με την στρατηγική LwF. Στην περίπτωση της Αγγλίας δεν παρατηρείται μεγάλη διαφορά μεταξύ των αποτελεσμάτων των διαφορετικών τεχνικών. Μπορούμε, συνεπώς, να αποφανθούμε πως η στρατηγική Synaptic intelligence αποτελεί μία από τις ταυτόχρονα αποδοτικές και αποτελεσματικές στρατηγικές διαρκούς μάθησης.

Συμπεραίνουμε, άρα, ότι οι τεχνικές διαρκούς μάθησης μπορούν να αποδειχθούν ωφέλιμες στο πρόβλημα που εξετάζουμε, επιφέροντας βελτίωση μέχρι και κατά 0.16 στα δεδομένα της Λετονίας. Συγχρόνως διατηρούν την επίδοση των άλλων συνόλων δεδομένων εντός αποδεκτών ορίων για τους σκοπούς της συγκεκριμένης μελέτης, δηλαδή με μείωση ίση περίπου με 0.1 κατά μέσο όρο. Μέσω των υπερπαραμέτρων των στρατηγικών μπορούμε να καθορίσουμε την ισορροπία που επιθυμούμε μεταξύ της απόδοσης των προηγούμενων και των τρεχόντων δεδομένων. Με βάση τα παραπάνω αναπτύσσεται επομένως ένα ενιαίο μοντέλο, το οποίο αποδίδει ανεξαρτήτως της χώρας στην οποία βρίσκεται το κτήριο. Ακόμα, δίνεται η δυνατότητα συνέχισης της εκπαίδευσης μελλοντικά με δεδομένα επιπρόσθετων χωρών ή με νέα δείγματα κτηρίων συσσωρεύοντας την γνώση και μειώνοντας τις απαιτήσεις.

Καταληκτικά, οι σύγχρονες συνθήκες έχουν φέρει στο προσκήνιο περισσότερο από ποτέ άλλοτε την ανάγκη εξοικονόμησης ενέργειας και μείωσης των εκπομπών επιβλαβών αερίων. Ένας από τους πρωταρχικούς τομείς που συμβάλλουν σε αυτό είναι τα κτήρια και κυρίως οι κατοικίες. Η έρευνα λοιπόν και η ανάπτυξη του μοντέλου για την πρόβλεψη των απαραίτητων για κάθε κτήριο μέτρων αναβάθμισης κρίνεται ιδιαίτερα ωφέλιμη στα πλαίσια αυτά. Ο τρόπος λειτουργίας και η διαφάνεια του προτεινόμενου συστήματος μπορούν να αποβούν πολύ χρήσιμα για τους ιδιοκτήτες κατά την διαδικασία εκπλήρωσης των ενεργειακών στόχων στις προσωπικές τους κατοικίες. Ένα επιπρόσθετο συμπέρασμα που είναι δυνατόν να εξαχθεί από την παρούσα μελέτη αφορά την πολύτιμη σημασία των δεδομένων που χρησιμοποιούνται. Τα ελλιπή δεδομένα ασκούν πολύ μεγάλη επίδραση στα αποτελέσματα και έτσι ανακύπτει η ανάγκη για ολοκληρωμένα σύνολα δεδομένων με αντιπροσωπευτικά δείγματα.

7.2 Μελλοντικές επεκτάσεις

Με την ολοκλήρωση της παρούσας διπλωματικής εργασίας αναφέρονται οι πιθανές μελλοντικές επεκτάσεις της που αξίζουν να ερευνηθούν. Σε όλη την έκτασή της έγινε σαφές ότι η ποσότητα και ποιότητα των δεδομένων διαδραματίζει πρωταρχικό ρόλο για την έκβαση της έρευνας. Συνεπώς ως κύρια ανάγκη τίθεται η συγκέντρωση περισσότερων δεδομένων από εφαρμογές ενεργειακής αναβάθμισης κατοικιών άλλων χωρών. Ιδιαίτερα ωφέλιμο θα ήταν να υπάρξει μέριμνα για την διατήρηση και ενιαία προσαρμογή των πληροφοριών αυτών, ώστε να εξαλειφθούν οι περιορισμοί διαθεσιμότητας και να ενισχυθούν η αποδοτικότητα και αξιοπιστία των μοντέλων που αναπτύχθηκαν. Επίσης καίριας σημασίας είναι και η συνεχής ανανέωσή των δεδομένων αυτών ώστε να συμβαδίζουν με τα νέα πρότυπα και προδιαγραφές του ενεργειακού κτηριακού τομέα. Παράλληλα με την συλλογή των πραγματικών δεδομένων θα είχε νόημα η μελέτη και δοκιμή εναλλακτικών τεχνικών παραγωγής συνθετικών δεδομένων με στόχο τον περαιτέρω ποιοτικό εμπλουτισμό της διαθέσιμης πληροφορίας.

Επιπρόσθετα, σπουδαία μπορεί να αναδειχθεί η διαδικασία της ρύθμισης των υπερπαραμέτρων (hyperparameter tuning) της διαρκούς μάθησης αλλά και συνολικά του μοντέλου. Στα πλαίσια της διπλωματικής μελετήθηκε η συνεισφορά που δύναται να έχει η διαρκής μάθηση στο πρόβλημα βελτιστοποίησης της ενεργειακής αποδοτικότητας των κτηρίων εφαρμόζοντας βασικές τεχνικές για μελέτη της γενικής συμπεριφοράς τους. Χρειάζεται, λοιπόν, η πιο λεπτομερής μελέτη των διαφορετικών τιμών των υπερπαραμέτρων ώστε να επιτευχθούν βέλτιστα αποτελέσματα και συμπεράσματα. Συγχρόνως μπορεί να δοκιμαστεί η ενσωμάτωση περισσότερων στρατηγικών διαρκούς μάθησης αλλά και επιπλέον μετρικών για την πιο αναλυτική αξιολόγησή τους (π.χ. forgetting). Ο συνδυασμός των μεθόδων αυτών με πραγματικά αλλά και συνθετικά δεδομένα θα μπορούσε επίσης να εξεταστεί στην συνέχεια.

Βιβλιογραφία

- [1] The Paris Agreement. Available online: <https://unfccc.int/process-and-meetings/the-paris-agreement> (accessed on 28 September 2024)
- [2] Energy Performance of Buildings Directive. Available online: https://energy.ec.europa.eu/topics/energy-efficiency/energy-efficient-buildings/energy-performance-buildings-directive_en (accessed on 28 September 2024)
- [3] EU Building Stock Observatory. Available online: https://energy.ec.europa.eu/topics/energy-efficiency/energy-efficient-buildings/eu-building-stock-observatory_en (accessed on 28 September 2024)
- [4] O. Pasichnyi, F. Levihn, H. Shahrokni, J. Wallin, and O. Kordas. Data-driven strategic planning of building energy retrofitting: The case of stockholm. *Journal of Cleaner Production*, 233:546–560, 10 2019.
- [5] T. M. Uidhir, F. Rogan, M. Collins, J. Curtis, and B. P. Gallachóir. Improving energy savings from a residential retrofit policy: A new model to inform better retrofit decisions. *Energy and Buildings*, 209, 2 2020..
- [6] J. P. Gouveia and P. Palma. Harvesting big data from residential building energy performance certificates: Retrofitting and climate change mitigation insights at a regional scale. *Environmental Research Letters*, 14, 9 2019.
- [7] G. Mutani, M. Alehasin, Y. Usta, F. Fiermonte, and A. Mariano. Statistical building energy model from data collection, place-based assessment to sustainable scenarios for the city of milan. *Sustainability* 2023, Vol. 15, Page 14921, 15:14921, 10 2023.
- [8] C. Deb and A. Schlueter. Review of data-driven energy modelling techniques for building retrofit. *Renewable and Sustainable Energy Reviews*, 144:110990, 7 2021.
- [9] S. R. Penaka, K. Feng, A. Rebbling, S. Azizi, W. Lu, and T. Olofsson. A data-driven framework for building energy benchmarking and renovation decision-making support in sweden. *IOP Conference Series: Earth and Environmental Science*, 1196:012005, 6 2023.

- [10] U. Ali, M. H. Shamsi, M. Bohacek, C. Hoare, K. Purcell, E. Mangina, and J. O'Donnell. A data-driven approach to optimize urban scale energy retrofit decisions for residential buildings. *Applied Energy*, 267, 6 2020.
- [11] F. R. Cecconi, A. Khodabakhshian, and L. Rampini. Data-driven decision support system for building stocks energy retrofit policy. *Journal of Building Engineering*, 54:104633, 8 2022.
- [12] F. Belaïd, Z. Ranjbar, and C. Massié. Exploring the cost-effectiveness of energy efficiency implementation measures in the residential sector. *Energy Policy*, 150:112122,3 2021.
- [13] T. Walter and M. D. Sohn. A regression-based approach to estimating retrofit savings using the building performance database. *Applied Energy*, 179:996–1005, 10 2016..
- [14] K. Feng, W. Lu, Y. Wang, and Q. Man. Energy-efficient retrofitting under incomplete information: A data-driven approach and empirical study of sweden. *Buildings* 2022, Vol. 12, Page 1244, 12:1244, 8 2022.
- [15] M. Sun, C. Han, Q. Nie, J. Xu, F. Zhang, and Q. Zhao. Understanding building energy efficiency with administrative and emerging urban big data by deep learning in glasgow. *Energy and Buildings*, 273:112331, 10 2022.
- [16] H. Seraj, A. Bahadori-Jahromi, and S. Amirkhani. Developing a data-driven ai model to enhance energy efficiency in uk residential buildings. *Sustainability* 2024, Vol. 16, Page 3151, 16:3151, 4 2024.
- [17] V. Michalakopoulos, S. Pelekis, G. Kormpakis, V. Karakolis, S. Mouzakis, and D. Askounis. Data-driven building energy efficiency prediction using physics-informed neural networks. *ArXiv*, 11 2023.
- [18] F. R. Cecconi and L. Rampini. Data driven economic scenarios for retrofitting residential buildings in a northern italian region. *IOP Conference Series: Earth and Environmental Science*, 1196:012113, 6 2023.
- [19] G. R. Araújo, R. Gomes, P. Ferrão, and M. G. Gomes. Optimizing building retrofit through data analytics: A study of multi-objective optimization and surrogate models derived from energy performance certificates. *Energy and Built Environment*, 5:889–899, 12 2024.
- [20] L. D. Long. An ai-driven model for predicting and optimizing energy-efficient building envelopes. *Alexandria Engineering Journal*, 79:480–501, 9 2023.
- [21] E. Sarmas, E. Spiliotis, V. Marinakis, T. Koutselis, and H. Doukas. A meta-learning classification model for supporting decisions on energy efficiency investments. *Energy and Buildings*, 258:111836, 3 2022.

- [22] N. Haidar, N. Tamani, Y. Ghamri-Doudane, and A. Boujou. Selective reinforcement graph mining approach for smart building energy and occupant comfort optimization. *Building and Environment*, 228:109806, 1 2023.
- [23] R. Z. Homod, Z. M. Yaseen, A. K. Hussein, A. Almusaed, O. A. Alawi, M. W. Falah, A. H. Abdelrazek, W. Ahmed, and M. Eltaweel. Deep clustering of cooperative multi-agent reinforcement learning to optimize multi chiller hvac systems for smart buildings energy management. *Journal of Building Engineering*, 65:105689, 4 2023.
- [24] CENED Database. Available online: https://www.dati.lombardia.it/Energia/Datatabase-CENED-2-Certificazione-ENergetica-degli-E/bbky-sde5/about_data (accessed on 26 April 2024)
- [25] Scottish EPCs Database. Available online: <https://statistics.gov.scot/data/domestic-energy-performance-certificates> (accessed on 26 April 2024)
- [26] English EPCs Database: Energy Performance of Buildings Data England and Wales. Available online: <https://epc.opendatacommunities.org/domestic/search> (accessed on 26 April 2024)
- [27] Irish EPCs Database: Building Energy Rating (BER). Available online: <https://ndber.seai.ie/BERResearchTool/ber/search.aspx> (accessed on 26 April 2024)
- [28] T. Mac Uidhir, F. Rogan, M. Collins, J. Curtis, and B. Gallachóir. Residential stock data and dataset on energy efficiency characteristics of residential building fabrics in ireland. *Data in Brief*, 29:105247, 02 2020
- [29] Molnar, C. (2022). *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable* (2nd ed.). <https://christophm.github.io/interpretable-ml-book/>
- [30] SHAP Documentation. Available online: <https://shap.readthedocs.io/en/latest/index.html> (accessed on 12 September 2024)
- [31] S. M. Lundberg and S. I. Lee. A unified approach to interpreting model predictions. In *Advances in Neural Information Processing Systems*, volume 2017-December, 2017.
- [32] I. Goodfellow, Y. Bengio, and A. Courville. *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org>.
- [33] T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama. Optuna: A next-generation hyperparameter optimization framework. In *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2019.
- [34] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer. Smote: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16:321–357, June 2002

- [35] A. Fernández, S. Garcia, F. Herrera, and N. Chawla. Smote for learning from imbalanced data: Progress and challenges, marking the 15-year anniversary. *Journal of Artificial Intelligence Research*, 61:863–905, 04 2018.
- [36] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio. Generative adversarial networks. *Advances in Neural Information Processing Systems*, 3, 06 2014.
- [37] M. Mirza and S. Osindero. Conditional generative adversarial nets. *ArXiv*, abs/1411.1784, 2014.
- [38] L. Xu, M. Skoularidou, A. Cuesta-Infante, and K. Veeramachaneni. Modeling tabular data using conditional gan. In *Advances in Neural Information Processing Systems*, 2019.
- [39] R. Sauber-Cole and T. Khoshgoftaar. The use of generative adversarial networks to alleviate class imbalance in tabular data: a survey. *Journal of Big Data*, 9, 08 2022.
- [40] N. Patki, R. Wedge, and K. Veeramachaneni. The synthetic data vault. In *IEEE International Conference on Data Science and Advanced Analytics (DSAA)*, pages 399–410, Oct 2016.
- [41] Synthetic Data Metrics. Version 0.14.0. DataCebo, Inc. 4 2024.
- [42] Z. Chen and B. Liu. *Lifelong machine learning*. Springer Nature, 2022.
- [43] G. van de Ven, T. Tuytelaars, and A. Tolias. Three types of incremental learning. *Nature Machine Intelligence*, 4:1–13, 12 2022.
- [44] J. Kirkpatrick, R. Pascanu, N. Rabinowitz, J. Veness, G. Desjardins, A. Rusu, K. Milan, J. Quan, T. Ramalho, A. Grabska-Barwinska, D. Hassabis, C. Clopath, D. Kumaran, and R. Hadsell. Overcoming catastrophic forgetting in neural networks. *Proceedings of the National Academy of Sciences*, 114, 12 2016.
- [45] Z. Li and D. Hoiem. Learning without forgetting. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 40:2935–2947, 2016
- [46] F. Zenke, B. Poole, and S. Ganguli. Continual learning through synaptic intelligence. In *Proceedings of the 34th International Conference on Machine Learning - Volume 70, ICML’17*, page 3987–3995. JMLR.org, 2017.
- [47] V. Lomonaco, L. Pellegrini, A. Cossu, A. Carta, G. Graffieti, T. L. Hayes, M. D. Lange, M. Masana, J. Pomponi, G. van de Ven, M. Mundt, Q. She, K. Cooper, J. Forest, E. Belouadah, S. Calderara, G. I. Parisi, F. Cuzzolin, A. Tolias, S. Scardapane, L. Antiga, S. Amhad, A. Popescu, C. Kanan, J. van de Weijer, T. Tuytelaars, D. Bacciu, and D. Maltoni. Avalanche: an end-to-end library for continual learning. In

Proceedings of IEEE Conference on Computer Vision and Pattern Recognition, 2nd Continual Learning in Computer Vision Workshop, 2021.

- [48] Avalanche documentation. Available online: <https://avalanche-api.continualai.org/en/v0.5.0/training.html> (accessed on 24 September 2024)

