



Εθνικό Μετσόβιο Πολυτεχνείο

Σχολή Πολιτικών Μηχανικών

Τομέας Μεταφορών και Συγκοινωνιακής Υποδομής

**Πρότυπα με και χωρίς επίβλεψη για την αυτόματη
αναγνώριση συμβάντων κατά την οδήγηση**

Διπλωματική Εργασία

Γεώργιος Ν. Μπόρας

Επιβλέπουσα Καθηγήτρια : Ελένη Βλαχογιάννη
Επικουρη Καθηγήτρια Σχολής Πολιτικών Μηχανικών ΕΜΠ

Αθήνα, Μάρτιος 2018.

ΕΥΧΑΡΙΣΤΙΕΣ

Κατ' αρχάς, επιθυμώ να ευχαριστήσω θερμά την κυρία Ελένη Βλαχογιάννη, Επίκουρη Καθηγήτρια στον Τομέα Μεταφορών και Συγκοινωνιακής Υποδομής της Σχολής Πολιτικών Μηχανικών, για την ουσιαστική καθοδήγηση της στην εκπόνηση της διπλωματικής εργασίας. Οι γνώσεις και η εμπειρία της με βοήθησαν να διευρύνω τους μαθησιακούς μου ορίζοντες και την ευχαριστώ πολύ για αυτό. Θα ήθελα, επίσης, να ευχαριστήσω το Διδάκτορα Εμμανουήλ Μπαρμπουνάκη, ο οποίος ήταν πάντα διαθέσιμος να μου προσφέρει χρήσιμες συμβουλές, δημιουργώντας μου προβληματισμό για τη διερεύνηση λύσεων με σκοπό τη βαθυστόχαστη κατανόηση.

Με την εκπόνηση της διπλωματικής εργασίας ολοκληρώνεται ένας κύκλος πολύ σημαντικός για μένα. Τα τελευταία χρόνια διεύρυνα τον τρόπο σκέψης μου και έκανα σημαντικούς φίλους.

Τέλος, επιθυμώ να ευχαριστήσω θερμά όλους τους ανθρώπους που είναι κοντά μου και με στηρίζουν σε κάθε μου εγχείρημα. Θέλω να ευχαριστήσω τους φίλους μου για τις συμβουλές τους και τη συμπαράστασή τους. Ευχαριστώ ολόψυχα την οικογένειά μου που με βοηθάει να εξελίσσομαι ως άνθρωπος, τον πατέρα μου και τη μητέρα μου για την εμπιστοσύνη και την πίστη που έχουν σε μένα και τον αδερφό μου που είναι πάντα δίπλα μου και με στηρίζει.

Πρότυπα με και χωρίς επίβλεψη για την αυτόματη αναγνώριση συμβάντων κατά την οδήγηση

Γεώργιος Ν. Μπόρας

Επιβλέπουσα: Ελένη Ι. Βλαχογιάννη, Επίκ. Καθηγήτρια ΕΜΠ

ΣΥΝΟΨΗ

Η σημαντική επιρροή του κλάδου των μεταφορών στην οικονομία και την κοινωνία χρίζει αναγκαία την προσπάθεια για βελτίωση και εκσυγχρονισμό της διαχείρισης των μεταφορών. Η παρούσα διπλωματική εργασία αποσκοπεί στην ανάπτυξη προτύπων μηχανικής μάθησης για την αναγνώριση των ακραίων οδηγικών γεγονότων, όπως η απότομη επιτάχυνση ή επιβράδυνση. Η ανίχνευση των ακραίων συμβάντων βασίζεται σε δεδομένα από αισθητήρες έξυπνων κινητών, που έχουν υποστεί επεξεργασία, λόγω της ύπαρξης θορύβου. Για τη επίλυση του ζητήματος του εντοπισμού αναπτύσσονται δυο μεθοδολογίες. Η πρώτη προσέγγιση αποτελείται από δυο στάδια: το πρώτο στάδιο αφορά στον εντοπισμό της πιθανής επικίνδυνης οδήγησης, μέσω του στατιστικού αλγόριθμου εντοπισμού ακροτάτων, S-H-ESD, και το δεύτερο στάδιο τον καθορισμό των επικίνδυνων οδηγικών χειρισμών και τον τύπο τους, χρησιμοποιώντας νευρωνικά δίκτυα. Η δεύτερη προσέγγιση υπολογίζει την μετρική απόσταση Mahalanobis για τα δεδομένα των επιταχύνσεων. Στη συνέχεια, αναπτύσσεται, βελτιστοποιείται ως προς τη δομή και τις παραμέτρους και εκπαιδεύεται ένα νευρωνικό δίκτυο για τον εντοπισμό των οδηγικών συμβάντων. Και στις δυο προσεγγίσεις το δείγμα είναι μη ισορροπημένο, οπότε εφαρμόζονται στρατηγικές υποδειγματοληψίας. Η πρώτη προσέγγιση αποτελεί ένα ολοκληρωμένο σύστημα εντοπισμού οδηγικών συμβάντων με ακρίβεια της τάξης του 90%. Η δεύτερη προσέγγιση χαρακτηρίζεται ως ένα επεικέες σύστημα αναγνώρισης της οδηγικής συμπεριφοράς, με ακρίβεια εντοπισμού των οδηγικών γεγονότων και της κανονικής οδήγησης 98%. Τέλος, σχολιάζονται οι περιορισμοί της μεθοδολογίας και διατυπώνονται προτάσεις για περαιτέρω έρευνα.

Λέξεις Κλειδιά : Ακραίο Γεγονός, Οδηγική Συμπεριφορά, Πληθοπορισμός, Έξυπνα Κινητά, Εντοπισμός Ακραίων Παρατηρήσεων, Ευφυή Συστήματα Μεταφορών, Μηχανική Μάθηση, Νευρωνικά Δίκτυα, Εκτίμηση Μηχανικού

Supervised and unsupervised learning models for automatically identifying driving events

George N. Boras

Supervising: Eleni Vlahogianni

ABSTRACT

The significant influence of the transport industry on the economy and society calls for an effort to improve and modernize transport management. This diploma thesis aims at developing machine learning models to identify harsh driving events, such as harsh acceleration or deceleration. The detection of harsh events is based on data from smart mobile sensors that have been processed due to the presence of noise. Two methodologies are developed to solve the problem of detection. The first approach consists of two tasks: the first task is to identify the possible dangerous driving through the S-H-ESD statistical algorithm, and the second task is to identify dangerous driving patterns and their type, using neural networks. The second approach calculates the metric distance of Mahalanobis for acceleration data. Then, a neural network is developed, optimized with respect to the structure and parameters, and trained to identify harsh driving events. In both approaches, the sample is unbalanced, so undersampling strategies are implemented. The first approach is an integrated system for detecting driving events, with accuracy of 90%. The second approach is characterized as a gentle recognition system for driving behavior, 98% accurately identifying driving events and normal driving. Finally, the limitations of the methodology and directions for further research are discussed.

Key Words: Harsh Event, Driving Behavior, Crowdsourcing, Smartphones, Outlier Detection, Intelligent Transport Systems, Machine Learning, Neural Networks, Feature Engineering

ΠΕΡΙΛΗΨΗ

Τα σύγχρονα αστικά κέντρα αποτελούν κόμβους ανάπτυξης. Οι μεγάλοι πληθυσμοί και οι ταχείς ρυθμοί ζωής, που τα χαρακτηρίζουν, επιτάσσουν τη συνεχόμενη βελτίωση του επιπέδου διαβίωσης. Οι μεταφορές αποτελούν αντικείμενο μείζονος σημασίας για τη ζωή των ανθρώπων. Η σημαντική επιρροή του κλάδου των μεταφορών στην οικονομία και την κοινωνία χρίζει αναγκαία την προσπάθεια για βελτίωση και εκσυγχρονισμό των υποδομών και της διαχείρισης των μεταφορών. Στην ανάγκη αυτή έρχεται να συμβάλει δυναμικά η Διαχείριση των Οδικών Μεταφορών (Road Traffic Management) με τα Ευφυή Συστήματα Μεταφορών (ITS). Η σωστή διαχείριση της κυκλοφορίας αποσκοπεί σε αποδοτικές μεταφορές που σέβονται το περιβάλλον, στηρίζουν την ανάπτυξη της οικονομίας και παρέχουν ασφάλεια στις μετακινήσεις.

Από την ανασκόπηση της βιβλιογραφίας αναδεικνύεται η σημασία καταγραφής και ανάλυσης της οδηγικής συμπεριφοράς. Η επιθετική συμπεριφορά των οδηγών επιβάλλεται να εντοπισθεί και να αξιολογηθεί αποτελεσματικά. Σημαντικό μέτρο ποσοτικοποίησης της οδηγικής συμπεριφοράς είναι η εμφάνιση ακραίων οδηγικών γεγονότων κατά τη διάρκεια των μετακινήσεων. Σκοπός της διπλωματικής εργασίας αποτελεί η δημιουργία ενός ολοκληρωμένου ευφυούς συστήματος εντοπισμού οδηγικών συμβάντων.

Η υλοποίηση των βημάτων της προτεινόμενης μεθοδολογικής προσέγγισης γίνεται με βάση δεδομένα που συλλέγονται αποκλειστικά από έξυπνα κινητά. Στο πλαίσιο της παρούσας διπλωματικής εργασίας αξιοποιούνται οι μετρήσεις των επιταχύνσεων για τους τρεις άξονες αναφοράς και η ταχύτητα. Λόγω της δομής των δεδομένων και του τρόπου συλλογής, τα δεδομένα απαιτούν κατάλληλη επεξεργασία. Επομένως, για τα δεδομένα των επιταχύνσεων αποφασίστηκε ο υπολογισμός του μήκους του συνισταμένου διανύσματος, αποσκοπώντας στην εξάλειψη του θορύβου από το δείγμα. Η μέτρηση της ταχύτητας από μόνη της δεν μπορεί να προσφέρει ουσιαστικές πληροφορίες, για το σκοπό αυτό αναλύεται και υπολογίζεται η μέγιστη απόλυτη τιμή της διαφοράς ταχύτητας για χρονικά παράθυρα δυο δευτερολέπτων και το πρόσημο της διαφοράς.

Για την εκπόνηση του σκοπού επιλέχθηκε η ανάπτυξη δύο μεθοδολογιών. Η πρώτη μέθοδος βασίζεται στην καινοτόμα μέθοδο διαχωρισμού της οδηγικής συμπεριφοράς σε δυο στάδια. Το πρώτο στάδιο αναλαμβάνει, με τη χρήση του στατιστικού αλγόριθμου εντοπισμού, να ταξινομήσει τις παρατηρήσεις με βάση τα δεδομένα των επιταχύνσεων σε πιθανά οδηγικά συμβάντα και κανονική οδήγηση, με σκοπό την μείωση του όγκου δεδομένων και τη δημιουργία ενός πιο ομοιογενούς δείγματος. Οι εξαγόμενες παρατηρήσεις, δηλαδή τα πιθανά οδηγικά συμβάντα, από το πρώτο στάδιο χαρακτηρίζονται από την απόλυτη τιμή της διαφοράς ταχύτητας και το πρόσημο της διαφοράς. Στο δεύτερο στάδιο εκπαιδεύεται το μοντέλο πρόβλεψης του νευρωνικού δικτύου. Παρά το γεγονός της μείωσης του δείγματος τα δεδομένα εξακολουθούν να αποτελούν ένα μη ισορροπημένο σύνολο, έτσι αποφασίζεται η χρήση μεθόδου

διαχείρισης μη ισορροπημένου δείγματος, και συγκεκριμένα της υποδειγματοληψίας, με σκοπό την ταχύτερη εκπαίδευση του δικτύου. Συνεπώς, αναζητείται ο βέλτιστος συνδυασμός δομής και παραμέτρων του δικτύου, αλλά και επιβαλλόμενου ποσοστού γεγονότων στο δείγμα, για να εντοπισθεί το μοντέλο πρόβλεψης με την μεγαλύτερη αποδοτικότητα. Η βασική λειτουργία του μοντέλου πρόβλεψης με τη χρήση νευρωνικού δικτύου είναι να μπορεί να διαχωρίζει την οδηγική συμπεριφορά σε φυσιολογική οδήγηση και σε επικίνδυνα οδηγικά συμβάντα, και μάλιστα είναι ικανό για τους ακραίους οδηγικούς χειρισμούς να καθορίζει και τον τύπο τους, που μπορεί να είναι απότομη επιτάχυνση ή απότομη επιβράδυνση.

Στη δεύτερη μέθοδο, το σύνολο του δείγματος διαχειρίζεται καθολικά, χωρίς να προηγείται ο διαχωρισμός σε πιθανές επικίνδυνες οδηγικές καταστάσεις. Μια ακόμη ουσιαστική διαφορά είναι ότι υπολογίζεται η μετρική απόσταση του συνισταμένου διανύσματος των επιταχύνσεων των παρατηρήσεων, που συσχετίζει τις παρατηρήσεις και εκφράζει ποσοτικά τη διαφοροποίηση τους από των γενικό χαρακτήρα των δεδομένων. Επομένως, στο νευρωνικό δίκτυο τα εισαγόμενα δεδομένα είναι η μετρική απόσταση, η απόλυτη τιμή της διαφοράς ταχύτητας και το πρόσημό της. Στη δεύτερη προσέγγιση το πρόβλημα της ανομοιογένειας του δείγματος είναι εντονότερο, σκόπιμα λοιπόν, εφαρμόστηκε η μέθοδος της υποδειγματοληψίας. Για την εύρεση του δικτύου με τη μεγαλύτερη αποδοτικότητα, και σε αυτή την περίπτωση, πρέπει να εκτιμηθεί ο συνδυασμός δομής και παραμέτρων του νευρωνικού δικτύου, καθώς και αναλογίας συμβάντων και κανονικής οδήγησης στο δείγμα. Δημιουργείται ένα σύστημα ανίχνευσης οδηγικών συμβάντων, εντοπίζοντας την κανονική οδήγηση και την επικίνδυνη οδήγηση, για την οποία δύναται να αναγνωρίσει και τον τύπο του συμβάντος. Κριτήριο αξιολόγησης των αποτελεσμάτων αποτελεί ο πίνακας ταξινόμησης προβλέψεων/πραγματικότητας και τα στατιστικά μέτρα, που παράγει. Καταλήγοντας με τη διαδικασία της δημιουργίας των αποδοτικότερων μοντέλων πρόβλεψης για τις δύο μεθοδολογικές προσεγγίσεις, ακολουθεί η αξιολόγηση των αποτελεσμάτων τους και η σύγκριση τους. Η σύγκριση των μεθοδολογιών πραγματοποιείται με την ποσοτική αξιολόγηση των στατιστικών μέτρων της ταξινόμησης και την αξιολόγηση των ποιοτικών χαρακτηριστικών τους.

Η πρώτη προσέγγιση καταλήγει στη δημιουργία ενός ολοκληρωμένου συστήματος εντοπισμού με υψηλή ακρίβεια. Το μοντέλο μπορεί να εντοπίζει ευστοχά την φυσιολογική οδήγηση και την επικίνδυνη οδήγηση. Το μοντέλο χαρακτηρίζεται αποδοτικό και στον καθορισμό του τύπου των ακραίων οδηγικών χειρισμών. Για τη δεύτερη προσέγγιση επιτεύχθηκε η δημιουργία ενός μοντέλου πρόβλεψης των οδηγικών γεγονότων με πολύ υψηλή ακρίβεια. Το μειονέκτημα της δεύτερης μεθόδου έγκειται στην χαλαρότητα με την οποία χαρακτηρίζει ένα οδηγικό γεγονός. Συγκεκριμένα, τα οδηγικά συμβάντα εντοπίζονται ευστοχά, όμως ο αριθμός των προβλεπόμενων συμβάντων είναι μεγαλύτερος από των πραγματικών.

Μια σε βάθος ανάλυση των συμπερασμάτων δείχνει ότι η αξιοποίηση των δεδομένων που προέρχονται από έξυπνα κινητά και η εφαρμογή μοντέλων πρόβλεψης νευρωνικών δικτύων εκτιμώνται ικανός συνδυασμός να προσδώσουν αξιόπιστα αποτελέσματα για μεγάλο όγκο πληροφοριών. Επιπλέον, αναγνωρίζεται η αξία της εκτίμησης του μηχανικού (Feature Engineering), η οποία θα καθορίσει αποδοτικές μεθοδολογίες για

την αντιμετώπιση του ζητήματος.

Αν και τα αποτελέσματα δεν είναι γενικεύσιμα, η προτεινόμενη μεθοδολογική προσέγγιση μπορεί να εκπαιδευτεί σε οποιεσδήποτε συνθήκες και να δώσει άμεσα εφαρμόσιμα αποτελέσματα, χρήσιμα σε τομείς όπως οι ασφαλιστικές εταιρίες, οι εταιρίες διαχείρισης στόλων οχημάτων, οι εταιρίες εμπορικών πωλήσεων και οι αρμόδιες αρχές διαχείρισης της κυκλοφορίας.

Προς την κατεύθυνση της βελτίωσης της προτεινόμενης μεθοδολογίας, είναι σαφές ότι ο ευεργετικός συνδυασμός της παροχής δεδομένων από έξυπνα κινητά και της χρήσης μηχανικής μάθησης απαιτεί βαθυστόχαστη διερεύνηση ως προς την αξιοποίηση του για την περαιτέρω βελτίωση των αποτελεσμάτων. Ακόμη, προτείνεται ο εμπλουτισμός των μεταβλητών της οδηγικής συμπεριφοράς, όπως η χρήση των δεδομένων από τους υπόλοιπους αισθητήρες του έξυπνου κινητού, και των χαρακτηριστικών της επιθετικής οδηγικής συμπεριφοράς, όπως ο εντοπισμός των απότομων ελιγμών.

ΠΕΡΙΕΧΟΜΕΝΑ

1. ΕΙΣΑΓΩΓΗ	1
1.1 ΔΙΑΧΕΙΡΙΣΗ ΚΥΚΛΟΦΟΡΙΑΣ.....	1
1.2 ΟΔΗΓΙΚΑ ΣΥΜΒΑΝΤΑ ΚΑΙ Η ΣΗΜΑΣΙΑ ΤΟΥΣ	2
1.3 ΠΛΗΘΟΠΟΡΙΣΤΙΚΑ ΔΕΔΟΜΕΝΑ.....	4
1.4 ΣΚΟΠΟΣ ΤΗΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ	5
1.5 ΔΟΜΗ ΤΗΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ	6
2. ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ.....	8
2.1 ΔΕΔΟΜΕΝΑ ΑΠΟ ΑΙΣΘΗΤΗΡΕΣ.....	8
2.2 ΔΙΑΧΕΙΡΙΣΗ ΔΕΔΟΜΕΝΩΝ	11
2.3 ΣΥΧΝΟΤΗΤΕΣ ΣΤΑ ΔΕΔΟΜΕΝΑ	13
2.4 ΟΔΗΓΙΚΗ ΣΥΜΠΕΡΙΦΟΡΑ	15
2.4.1 ΑΝΑΓΝΩΡΙΣΗ ΟΔΗΓΙΚΟΥ ΣΥΜΒΑΝΤΟΣ.....	16
2.5 ΣΥΓΚΡΙΤΙΚΕΣ ΜΕΘΟΔΟΛΟΓΙΕΣ ΜΟΝΤΕΛΩΝ ΠΡΟΒΛΕΨΗΣ	23
2.6 ΣΥΜΠΕΡΑΣΜΑΤΑ ΑΝΑΣΚΟΠΗΣΗΣ.....	24
3. ΜΕΘΟΔΟΛΟΓΙΚΗ ΠΡΟΣΕΓΓΙΣΗ.....	26
3.1 ΔΙΑΤΥΠΩΣΗ ΠΡΟΒΛΗΜΑΤΟΣ ΚΑΙ ΕΠΙΛΟΓΗ ΜΕΘΟΔΩΝ ΕΠΙΛΥΣΗΣ ..	26
3.2 ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ	29
3.3 ΕΝΤΟΠΙΣΜΟΣ ΑΚΡΑΙΩΝ ΠΑΡΑΤΗΡΗΣΕΩΝ	29
3.3.1 ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗ ΤΕΧΝΙΚΩΝ ΑΝΙΧΝΕΥΣΗΣ ΑΝΩΜΑΛΙΩΝ	30
3.3.2 ΕΦΑΡΜΟΓΕΣ ΑΝΙΧΝΕΥΣΗΣ ΑΝΩΜΑΛΙΩΝ	34
3.4 ΑΛΓΟΡΙΘΜΟΣ Seasonal Hybrid ESD	34
3.5 ΧΡΟΝΟΣΕΙΡΕΣ	38
3.5.1 ΠΕΡΙΟΔΙΚΟΤΗΤΑ	41
3.6 ΜΕΘΟΔΟΙ ΥΠΟΛΟΓΙΣΜΟΥ ΜΕΤΡΙΚΗΣ ΑΠΟΣΤΑΣΗΣ	42
3.7 ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	43
3.7.1 ΔΟΜΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ.....	44
3.7.2 ΕΚΠΑΙΔΕΥΣΗ ΚΑΙ ΕΚΤΙΜΗΣΗ ΥΠΕΡΠΑΡΑΜΕΤΡΩΝ	48
3.8 ΚΡΙΤΗΡΙΑ ΑΞΙΟΛΟΓΗΣΗΣ ΑΠΟΤΕΛΕΣΜΑΤΩΝ	55
3.9 ΕΠΙΛΟΓΗ ΛΟΓΙΣΜΙΚΟΥ	57

4. ΕΝΤΟΠΟΣΜΟΣ ΟΔΗΓΙΚΩΝ ΣΥΜΒΑΝΤΩΝ	59
4.1 ΣΥΛΛΟΓΗ ΔΕΔΟΜΕΝΩΝ	59
4.1.1 ΑΙΣΘΗΤΗΡΕΣ ΚΑΤΑΓΡΑΦΗΣ ΔΕΔΟΜΕΝΩΝ.....	59
4.1.2 ΕΦΑΡΜΟΓΗ ΣΥΛΛΟΓΗΣ ΔΕΔΟΜΕΝΩΝ	62
4.2 ΕΠΕΞΕΡΓΑΣΙΑ ΔΕΔΟΜΕΝΩΝ	63
4.2.1 ΕΠΙΛΟΓΗ ΜΕΤΑΒΗΤΩΝ ΑΝΑΛΥΣΗΣ	63
4.2.2 ΔΗΜΙΟΥΡΓΙΑ ΝΕΩΝ ΜΕΤΑΒΛΗΤΩΝ ΑΠΟ ΔΕΔΟΜΕΝΑ	67
4.3 ΕΦΑΡΜΟΓΗ ΜΕΘΟΔΟΓΙΑΣ ΕΝΤΟΠΙΣΜΟΥ ΟΔΗΓΙΚΩΝ ΓΕΓΟΝΟΤΩΝ...	69
4.3.1 ΜΕΘΟΔΟΣ Α: ΧΡΗΣΗ ΑΛΓΟΡΙΘΜΟΥ ΕΝΤΟΠΙΣΜΟΥ ΑΚΡΟΤΑΤΩΝ.....	69
4.3.1.1 ΕΚΠΑΙΔΕΥΣΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ ΚΑΙ ΑΠΟΤΕΛΕΣΜΑΤΑ	71
4.3.2 ΜΕΘΟΔΟΣ Β: ΧΡΗΣΗ ΜΕΤΡΙΚΗΣ ΑΠΟΣΤΑΣΗΣ	79
4.3.2.1 ΕΚΠΑΙΔΕΥΣΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ ΚΑΙ ΑΠΟΤΕΛΕΣΜΑΤΑ	80
4.4 ΑΞΙΟΛΟΓΗΣΗ ΜΕΘΟΔΩΝ ΕΝΤΟΠΙΣΜΟΥ	88
5. ΣΥΜΠΕΡΑΣΜΑΤΑ	91
5.1 ΓΕΝΙΚΑ	91
5.2 ΒΑΣΙΚΑ ΣΥΜΠΕΡΑΣΜΑΤΑ	92
5.3 ΠΕΡΙΟΡΙΣΜΟΙ ΚΑΙ ΠΡΟΤΑΣΕΙΣ ΓΙΑ ΠΕΡΑΙΤΕΡΩ ΕΡΕΥΝΑ.....	96
6. ΒΙΒΛΙΟΓΡΑΦΙΑ	98

ΕΥΡΕΤΗΡΙΟ ΔΙΑΓΡΑΜΜΑΤΩΝ

Διάγραμμα 1.1: Αριθμός χιλιομέτρων επιβατών για την περίοδο 1995-2015 στην Ε.Ε.. (Πηγή: European Commission Statistical Pocketbook 2017).	2
Διάγραμμα 2.1: Απόκλιση καταγραφής ταχύτητας από GPS (smartphone) και ταχυμέτρου οχήματος (OBD). (Πηγή: Saiprasent et Pattara-Atikom, 2013).	10
Διάγραμμα 2.2: Κατανάλωση ενέργειας smartphone, με και χωρίς τη χρήση εφαρμογής καταγραφής δεδομένων. (Πηγή: Dai et al., 2010).	14
Διάγραμμα 2.3: Συχνότητες καταγραφής για παρατηρούμενα και υπολογιζόμενα δεδομένα. (Πηγή: Fazeen et al., 2012).	15
Διάγραμμα 2.4: Απότομες διακυμάνσεις επιταχύνσεων άξονα Z. (Πηγή: Bhoraskar et al., 2012).	19
Διάγραμμα 2.5: Απότομες διακυμάνσεις επιταχύνσεων άξονα Y. (Πηγή: Bhoraskar et al., 2012).	19
Διάγραμμα 2.6: Σύγκριση απλότητας και ακρίβειας μεθοδολογιών. (Πηγή: Engelbrecht et al., 2014).	23
Διάγραμμα 3.1: Διάγραμμα ροής εργασιών Διπλωματικής Εργασίας.	28
Διάγραμμα 3.2: Διάγραμμα φυσιολογικών και ακραίων παρατηρήσεων. (Πηγή: Chandola et al., 2009).	31
Διάγραμμα 3.3: Διάγραμμα θερμοκρασιακής μεταβολής συνάρτηση του χρόνου. (Πηγή: Chandola et al., 2009).	32
Διάγραμμα 3.4: Τμήμα διαγράμματος καρδιογραφήματος. (Πηγή: Chandola et al., 2009).	32
Διάγραμμα 3.5: Διάγραμμα με την παρουσία τοπικών και γενικών ανωμαλιών. (Πηγή: Vallis et al., 2017).	35
Διάγραμμα 3.6: Ετήσια παραγωγή μπίρας στην Αυστραλία. (Πηγή: AnOmaly.io).	38
Διάγραμμα 3.7: Ετήσια επιβατική κίνηση με αεροσκάφη. (Πηγή: AnOmaly.io).	39
Διάγραμμα 3.8: Ετήσια παραγωγή μπίρας στην Αυστραλία μαζί με την Τάση. (Πηγή: AnOmaly.io).	39
Διάγραμμα 3.9: Ετήσια επιβατική κίνηση με αεροσκάφη μαζί με την Τάση. (Πηγή: AnOmaly.io).	39
Διάγραμμα 3.10: Περιοδικότητα ετήσιας παραγωγής μπίρας στην Αυστραλία. (Πηγή: AnOmaly.io).	40
Διάγραμμα 3.11: Περιοδικότητα ετήσιας επιβατικής κίνησης με αεροσκάφη. (Πηγή: AnOmaly.io).	40
Διάγραμμα 3.12: Περιοδόγραμμα (Πηγή: Eberly College of Science).	41
Διάγραμμα 3.13: Μορφή καμπύλης ROC.	57
Διάγραμμα 4.1: Διάγραμμα επιτάχυνσης άξονα X για φυσιολογική οδήγηση.	64
Διάγραμμα 4.2: Διάγραμμα επιτάχυνσης άξονα Y για φυσιολογική οδήγηση.	64
Διάγραμμα 4.3: Διάγραμμα επιτάχυνσης άξονα Z για φυσιολογική οδήγηση.	64

Διάγραμμα 4.4: Διάγραμμα επιτάχυνσης άξονα X για επικίνδυνη οδήγηση.	65
Διάγραμμα 4.5: Διάγραμμα επιτάχυνσης άξονα Y για επικίνδυνη οδήγηση.	65
Διάγραμμα 4.6: Διάγραμμα επιτάχυνσης άξονα Z για επικίνδυνη οδήγηση.	66
Διάγραμμα 4.7: Διάγραμμα ταχύτητας για φυσιολογική οδήγηση.	66
Διάγραμμα 4.8: Διάγραμμα ταχύτητας για επικίνδυνη οδήγηση.	67
Διάγραμμα 4.9: Διάγραμμα μήκους του διανύσματος της επιτάχυνσης για τους τρεις άξονες.	68
Διάγραμμα 4.10: Σφάλμα Ταξινόμησης για Εποχές Εκπαίδευσης.	74
Διάγραμμα 4.11: Ποσοστιαίο διάγραμμα σημαντικότητας παραμέτρων Μέθοδος A.	75
Διάγραμμα 4.12: Σφάλμα Ταξινόμησης για Εποχές Εκπαίδευσης.	82
Διάγραμμα 4.13: Ποσοστιαίο διάγραμμα σημαντικότητας παραμέτρων Μέθοδος B.	84

ΕΥΡΕΤΗΡΙΟ ΕΚΟΝΩΝ

Εικόνα 2.1: Μορφή συστήματος λειτουργίας GPS. (Πηγή: Saiprasent et Pattara-Atikom, 2013).	9
Εικόνα 2.2: Τοποθέτηση smartphone εντός του οχήματος. (Πηγή: Johnson et Trivedi, 2011).	12
Εικόνα 2.3: Άξονες αναφοράς smartphone. (Πηγή: Bhoraskar et al., 2012).	13
Εικόνα 2.4: Άξονες αναφοράς οχήματος. (Πηγή: Bhoraskar et al., 2012).	13
Εικόνα 2.5: Μορφή βιντεοσκοπικής λήψης των δεδομένων. (Πηγή: Bergasa et al., 2014).	17
Εικόνα 2.6: Δομή ροής εργασιών για τον εντοπισμό συμβάντων. (Πηγή: Bergasa et al., 2014).	18
Εικόνα 2.7: Δομή ροής εργασιών για τον εντοπισμό συμβάντων. (Πηγή: White et al., 2011).	21
Εικόνα 3.1: Τυπική μορφή υπολογισμών αλγόριθμου S-ESD. (Πηγή: Vallis et al., 2017).	37
Εικόνα 3.2: Τυπική μορφή απλού νευρώνα. (Πηγή: Neural Networks and Deep Learning).	45
Εικόνα 3.3: Τυπική μορφή δικτύου με πολλαπλούς νευρώνες. (Πηγή: Neural Networks and Deep Learning).	45
Εικόνα 3.4: Μορφή συνάρτησης Sigmoid. (Πηγή: Online Courses Stanford 231n).	46
Εικόνα 3.5: Μορφή συνάρτησης Tanh. (Πηγή: Online Courses Stanford 231n).	46
Εικόνα 3.6: Μορφή συνάρτησης ReLU. (Πηγή: Online Courses Stanford 231n).	47
Εικόνα 3.7: Τροφοδοτικό Νευρωνικό Δίκτυο. (Πηγή: Towards Data Science).	47
Εικόνα 3.8: Επαναλαμβανόμενο Νευρωνικό Δίκτυο. (Πηγή: Towards Data Science).	47

Εικόνα 3.9: Συνελικτικό Νευρωνικό Δίκτυο.	48
Εικόνα 3.10: Συνάρτηση Κόστους για δυο παραμέτρους. (Πηγή: ml4a.GitHub.io).	49
Εικόνα 3.11: Τρισδιάστατη Συνάρτηση Κόστους για δυο παραμέτρους με «λόφους» και «κοιλιάδες». (Πηγή: ml4a.GitHub.io).	50
Εικόνα 3.12: Συνάρτηση Κόστους για δυο παραμέτρους με διαδρομή ελαχιστοποίησης. (Πηγή: ml4a.GitHub.io).	51
Εικόνα 3.13: Νευρωνικό δίκτυο κανονικό (α) και με απόσυρση νευρώνων (b).	54
Εικόνα 4.1: Άξονες αναφοράς σε smartphone.	60
Εικόνα 4.2: Περιστροφή αξόνων αναφοράς σε smartphone.	61

ΕΥΡΕΤΗΡΙΟ ΠΙΝΑΚΩΝ

Πίνακας 2.1: Σύντομες ερμηνείες χαρακτηριστικών αξιοπιστίας δεδομένων. (Πηγή: Handel et al., 2014).	11
Πίνακας 2.2: Αποδοτικότητα αισθητήρων σε σχέση με τα χαρακτηριστικά αξιοπιστίας των δεδομένων. (Πηγή: Handel et al., 2014).	12
Πίνακας 2.3: Όρια τιμών για τον καθορισμό γεγονότων. (Πηγή: Bergasa et al., 2014).	17
Πίνακας 4.1: Πίνακας ταξινόμησης επικίνδυνης και μη οδήγησης από Αλγόριθμο S-H-ESD.	70
Πίνακας 4.2: Στατιστικά μέτρα Αλγόριθμου S-H-ESD.	71
Πίνακας 4.3: Παράμετροι εκπαίδευσης Νευρωνικού Δικτύου Μέθοδος Α.	74
Πίνακας 4.4: Ποσοστά σημαντικότητας για τις αντίστοιχες παραμέτρους Μέθοδος Α.	75
Πίνακας 4.5: Πίνακας πολλαπλής ταξινόμησης για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος Α.	76
Πίνακας 4.6: Πίνακας ταξινόμησης Συμβάν/Κανονική Οδήγηση για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος Α.	77
Πίνακας 4.7: Στατιστικά Μέτρα για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος Α.	77
Πίνακας 4.8: Πίνακας πολλαπλής ταξινόμησης για Σύνολο Δοκιμής Μέθοδος Α.	78
Πίνακας 4.9: Πίνακας ταξινόμησης Συμβάν/Κανονική Οδήγηση για Σύνολο Δοκιμής Μέθοδος Α.	79
Πίνακας 4.10: Στατιστικά Μέτρα για Σύνολο Δοκιμής Μέθοδος Α.	79
Πίνακας 4.11: Παράμετροι εκπαίδευσης Νευρωνικού Δικτύου Μέθοδος Β.	83
Πίνακας 4.12: Ποσοστά σημαντικότητας για τις αντίστοιχες παραμέτρους Μέθοδος Β.	83
Πίνακας 4.13: Πίνακας πολλαπλής ταξινόμησης για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος Β.	85

Πίνακας 4.14: Πίνακας ταξινόμησης Συμβάν/Κανονική Οδήγηση για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος B.	85
Πίνακας 4.15: Στατιστικά Μέτρα για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος B.	85
Πίνακας 4.16: Πίνακας πολλαπλής ταξινόμησης για Σύνολο Δοκιμής Μέθοδος B.	86
Πίνακας 4.17: Πίνακας ταξινόμησης Συμβάν/Κανονική Οδήγηση για Σύνολο Δοκιμής Μέθοδος B.	87
Πίνακας 4.18: Στατιστικά Μέτρα για Σύνολο Δοκιμής Μέθοδος B.	88
Πίνακας 4.19: Στατιστικά μέτρα για Μέθοδο A και Μέθοδο B.	90


1. ΕΙΣΑΓΩΓΗ

1.1. ΔΙΑΧΕΙΡΙΣΗ ΚΥΚΛΟΦΟΡΙΑΣ

Οι μεταφορές αποτελούν ένα πάρα πολύ σημαντικό κομμάτι της ζωής των ανθρώπων, στη σύγχρονη εποχή. Επηρεάζουν τις καθημερινές τους δραστηριότητες, όσον αφορά στις μετακινήσεις τους προς την εργασία ή την αναψυχή τους, τις εμπορικές δραστηριότητες, για τη διάθεση των προϊόντων, και αποτελούν ένα σημαντικό κλάδο απασχόλησης εργασίας. Σύμφωνα, με στοιχεία της Ευρωπαϊκής Ένωσης, ο τομέας των μεταφορών αντιπροσωπεύει το 4,5% του συνολικού εργατικού δυναμικού στην Ευρωπαϊκή Ένωση και το 4,6% του ακαθάριστου εγχώριου προϊόντος (ΑΕΠ) (Directorate-General for Mobility and Transport (European Commission), 2015). Ο κλάδος των μεταφορών αποτελεί σημαντικό αντικείμενο της ανάπτυξης παγκοσμίως. Η Ευρωπαϊκή Ένωση, τα τελευταία χρόνια, έχει θεσπίσει το πρόγραμμα HORIZON 2020, για την προώθηση της οικονομικής ανάπτυξης και τη δημιουργία θέσεων εργασίας, συνδυάζοντας την έρευνα και την καινοτομία.

Σύμφωνα με έρευνα της Ευρωπαϊκής Ένωσης στον κλάδο των μεταφορών κυρίαρχο μέσο είναι τα επιβατικά οχήματα. Οι επιβάτες κατά συντριπτική πλειονότητα επιλέγουν να μετακινηθούν με επιβατικό όχημα, παράλληλα ο αριθμός των επιβατικών οχημάτων αυξάνεται συνεχώς (European Commission, 2017). Στο Διάγραμμα 1.1 απεικονίζονται οι μέσες αποστάσεις, που διανύονται ανά επιβάτη για το εκάστοτε μέσο μεταφοράς στην Ευρωπαϊκή Ένωση. Καθίσταται αναγκαία η παρακολούθηση και η διαχείριση του συγκεκριμένου κλάδου των μεταφορών.

Συγκεκριμένα, η διαχείριση των οδικών μεταφορών (Road Traffic Management) έχει σκοπό τη βελτίωση της βιωσιμότητας των μεταφορών, δηλαδή αποδοτικές μεταφορές, που σέβονται το περιβάλλον, την άψογη λειτουργία και εφαρμογή των μεταφορικών συστημάτων για καλύτερη κινητικότητα, μικρότερη συμφόρηση και μεγαλύτερη ασφάλεια, και τη διεξαγωγή ερευνών στις μεταφορές, όπως κοινωνικοοικονομικές έρευνες για τη χάραξη πολιτικής στο μέλλον.



Διάγραμμα 1.1: Αριθμός χιλιομέτρων επιβατών για την περίοδο 1995-2015 στην Ε.Ε.. (Πηγή: European Commission Statistical Pocketbook 2017).

Σημαντικό και καινοτόμο ρόλο στον τομέα της διαχείρισης των οδικών μεταφορών έχουν τα Συστήματα Ευφώνων Μεταφορών (ITS). Σύμφωνα με το Σύλλογο Ελλήνων Συγκοινωνιολόγων, τα Συστήματα Ευφώνων Μεταφορών (ITS) συνδυάζουν τις νέες τεχνολογίες με την κυκλοφοριακή τεχνική και το σχεδιασμό των μεταφορών με αποτέλεσμα τον βέλτιστο προγραμματισμό, σχεδιασμό, λειτουργία, συντήρηση και διαχείριση ολοκληρωμένων συστημάτων μεταφορών.

Σκοπός των Ευφώνων Συστημάτων Μεταφορών (ITS) είναι η εξοικονόμηση ενέργειας και η μείωση των ατμοσφαιρικών ρύπων, η βελτίωση του επιπέδου οδικής ασφάλειας, η βελτίωση εξυπηρέτησης των μετακινούμενων, καθώς και η βέλτιστη διαχείριση των υφιστάμενων συγκοινωνιακών υποδομών και πόρων.

Κομμάτι της διαχείρισης των οδικών μεταφορών (Road Traffic Management) είναι ο εντοπισμός οδηγικών γεγονότων, χρήσιμων συγκοινωνιακών εργαλείων για τη γενικότερη διαχείριση των μεταφορών και με σημαντική επιρροή σε αρκετούς κλάδους, όπου εξηγείται αναλυτικότερα παρακάτω.

1.2. ΟΔΗΓΙΚΑ ΣΥΜΒΑΝΤΑ ΚΑΙ Η ΣΗΜΑΣΙΑ ΤΟΥΣ

Οτιδήποτε συμβαίνει, ειδικά κάτι σημαντικό ή ασυνήθιστο, ορίζεται ως γεγονός ή συμβάν (Cambridge Dictionary). Το συμβάν κατά το οποίο ασκείται περισσότερη δύναμη από το κανονικό στο γκάζι ή το φρένο του οχήματος, ονομάζεται σκληρή επιτάχυνση (Harsh Acceleration) ή σκληρή πέδηση (Harsh Braking), αντίστοιχα. Για

παράδειγμα, όταν βρισκόμενοι εντός του οχήματος, ο οδηγός φρενάρει απότομα τότε το σώμα κινείται προς τα μπροστά (Harsh Braking), ενώ σε αντίθεση όταν επιταχύνει τότε το σώμα αισθάνεται να «τραβιέται» προς τα πίσω (Harsh Acceleration), το φαινόμενο αυτό συμβαίνει λόγω της αδράνειας. Η οδήγηση, που χαρακτηρίζεται από συχνά φαινόμενα σκληρής επιτάχυνσης και σκληρής πέδησης μπορεί να αποτελέσει ένδειξη επιθετικής ή μη ασφαλούς οδήγησης.

Η παρακολούθηση της οδηγικής συμπεριφοράς και ο εντοπισμός των ακραίων οδηγικών γεγονότων έχει σημαντική επιρροή στη ποιότητα του περιβάλλοντος. Η επίδραση των μεταφορών στη ρύπανση του περιβάλλοντος είναι έντονη, μάλιστα οι εκπομπές διοξειδίου του άνθρακα από τον τομέα των μεταφορών ευθύνονται για το 20% τουλάχιστον των εκπομπών αερίων του θερμοκηπίου της ΕΕ. Οι οδικές μεταφορές ευθύνονται για το μεγαλύτερο ποσοστό της ρύπανσης, που παράγει ο κλάδος μεταφορών, σχεδόν το 71% των συνολικών εκπομπών CO₂, τα δε επιβατικά αυτοκίνητα ευθύνονται σχεδόν για τα δύο τρίτα των εν λόγω εκπομπών (European Commission, 2014). Το μοτίβο οδήγησης ενός οδηγού παίζει σημαντικό ρόλο στην κατανάλωση καυσίμου. Η επιθετική οδήγηση αυξάνει τα απόβλητα των καυσίμων. Μία σταθερή οδήγηση με σταθερό ρυθμό σημαίνει χαμηλότερη κατανάλωση καυσίμου, ενώ μία επιθετική οδήγηση με συχνές απότομες επιβραδύνσεις και επιταχύνσεις, τα καύσιμα που καταναλώνονται είναι πολύ περισσότερα. Η επιθετική οδήγηση σε σύγκριση με την κανονική οδήγηση μπορεί να οδηγήσει σε αύξηση της κατανάλωσης καυσίμου κατά 40% (De Vlieger et al., 2000). Επομένως, η μη-επιθετική οδήγηση βοηθάει στη μείωση της κατανάλωσης των καυσίμων.

Όταν αυξάνεται η κατανάλωση του καυσίμου ως αποτέλεσμα αυξάνονται και οι ρύποι, που εκπέμπονται στο περιβάλλον. Μια ομαλή οδήγηση, χωρίς απότομους οδηγικούς χειρισμούς, θα συμβάλει στη μείωση της κατανάλωσης του καυσίμου, γεγονός που σημαίνει ότι εκπέμπονται λιγότεροι ρύποι. Η κατανάλωση καυσίμου και οι εκπομπές διοξειδίου του άνθρακα συνδέονται αυστηρά. Στη μη-επιθετική οδήγηση, οι οδηγοί ακολουθούν μία καλύτερη ηθική οδήγησης, που βοηθά στη μείωση της περιβαλλοντικής ρύπανσης. Η μη-επιθετική οδήγηση είναι φιλική προς το περιβάλλον.

Η επιθετική οδήγηση οδηγεί σε αυξανόμενο κίνδυνο ατυχημάτων. Σύμφωνα με την έρευνα των Treat et al. (1979), το «ανθρώπινο σφάλμα» είναι καθοριστική αιτία για το 93% των ατυχημάτων, που εξετάστηκαν. Οι Murray et al. (1996) ισχυρίζονται ότι το 40% των οδηγών θα εμπλακεί σε τροχαία ατυχήματα κάθε χρόνο. Η έλλειψη προσοχής του οδηγού αποτελεί την αιτία για το 25% των οδηγικών ατυχημάτων (NHTSA, 2009). Η επιθετική και απερίσκεπτη οδήγηση θεωρείται συχνά αποτέλεσμα πρόκλησης ή εμπλοκής ατυχημάτων (Oltedal and Ryndmo, 2005). Ο επιθετικός τρόπος οδήγησης θέτει σε άμεσο κίνδυνο, τόσο την ζωή του οδηγού, όσο και την ζωή άλλων. Οδηγοί με προβλήματα θυμού αναφέρουν συχνότερη επικίνδυνη οδήγηση σε σύγκριση με εκείνους με χαμηλότερα, και συχνά εμπλέκονται σε παραβάσεις τόσο στην υπερβολική ταχύτητα όσο και στην αγνόηση των κανόνων κυκλοφορίας (Iversen and Rundmo, 2002).

Η οδήγηση με συχνά ακραία γεγονότα απότομης επιτάχυνσης και επιβράδυνσης αυξάνει σημαντικά τις δαπάνες συντήρησης του οχήματος. Πέραν τις σοβαρές υλικές ζημιές, που μπορεί να οδηγήσει η επιθετική οδήγηση από πρόκληση ενός ατυχήματος, επηρεάζεται σημαντικά και ο μηχανολογικός εξοπλισμός του αυτοκινήτου. Για παράδειγμα, με την παρατεταμένη πέδηση πέφτει πρόωρα η απόδοση της ανάρτησης

του οχήματος και εξαιτίας του σκληρού φρεναρίσματος, τα τακάκια («φρέζες») υπερθερμαίνονται μειώνοντας τη διάρκεια ζωής τους, επιπλέον, λόγω της απότομης επιτάχυνσης μειώνεται η διάρκεια ζωής του συμπλέκτη και της εξάτμισης του οχήματος. Η συντήρηση των οχημάτων αποτελεί σημαντικό παράγοντα οικονομικής βιωσιμότητας για τις εταιρίες διαχείρισης στόλου οχημάτων.

Ο εντοπισμός των ακραίων χειρισμών ενός οδηγού βοηθά στη μείωση της επιθετικής οδήγησης σε μεγάλο βαθμό. Η μειωμένη επιθετική οδήγηση σημαίνει μικρότερο αριθμό επικίνδυνων καταστάσεων για τον οδηγό, γεγονός που οδηγεί άμεσα σε περισσότερη ασφάλεια στις μετακινήσεις. Βέβαια, δε θα ήταν ορθό να θεωρείται ότι κάθε σκληρή/απότομη επιβράδυνση ή επιτάχυνση είναι πάντα ένας δείκτης μη ασφαλούς οδήγησης. Για παράδειγμα ένα σκληρό φρενάρισμα ή επιτάχυνση μπορεί να υποδεικνύει την αποφυγή οδηγικών σφαλμάτων ή ότι ο οδηγός έχει εμπλακεί σε ένα ατύχημα.

Για τους παραπάνω λόγους θεωρείται σημαντικός ο εντοπισμός των ακραίων αυτών συμβάντων απότομης επιτάχυνσης και επιβράδυνσης. Σε αυτό το σημείο, αξίζει να σημειωθεί, ότι πέραν του απότομου φρεναρίσματος (Harsh Braking) και της απότομης επιτάχυνσης (Harsh Acceleration), υπάρχει και ένα ακόμη ακραίο γεγονός (Harsh Event), το οποίο έχει να κάνει με την αλλαγή κατεύθυνσης του οχήματος και ονομάζεται απότομος ελιγμός (Harsh Cornering). Το Harsh Cornering είναι λίγο πιο δύσκολο να κατανοηθεί διαισθητικά. Το όχημα, σταθευμένο, βρίσκεται σε κατάσταση ηρεμίας και η δύναμη, που του ασκείται είναι η βαρύτητα, λόγω της μάζα του. Το όχημα κινείται και αναπτύσσεται μια ακόμη δύναμη εξαιτίας της πλευρικής επιτάχυνσης. Όταν το όχημα στρίβει, η δύναμη της βαρύτητας εξακολουθεί να ενεργεί στο αυτοκίνητο, αλλά τώρα η δεύτερη δύναμη στρέψης γίνεται σημαντική.

1.3. ΠΛΗΘΟΠΟΡΙΣΤΙΚΑ ΔΕΔΟΜΕΝΑ

Μία εναλλακτική λύση για τη συλλογή πληροφοριών, χρήσιμων για συγκοινωνιολογικά ζητήματα, είναι η χρήση κινητών τηλεφώνων (smartphones). Οι ερευνητές εκμεταλλεόμενοι την εκτεταμένη χρήση των έξυπνων συσκευών μπορούν να προσδώσουν ένα διαφορετικό χαρακτήρα στις έρευνες, αξιοποιώντας τα πλεονεκτήματα των smartphones και συλλέγοντας δεδομένα απευθείας από τους χρήστες κινητών, γνωστά ως πληθοποριστικά δεδομένα (crowdsourced data). Ο όρος «crowdsourcing» αναφέρεται στην περιγραφή του τρόπου με τον οποίο οι επιχειρήσεις χρησιμοποιούν το διαδίκτυο για να αναθέσουν μια εργασία στο πλήθος. Ο Howe (2006) ορίζει τον πληθοπορισμό ως την πράξη μιας επιχείρησης ή ενός ιδρύματος, που αναλαμβάνει μια λειτουργία όταν εκτελείται από υπαλλήλους και την αναθέτει σε ένα απροσδιόριστο (και γενικά μεγάλο) δίκτυο ανθρώπων με τη μορφή μιας ανοιχτής κλήσης. Αυτό μπορεί να πάρει τη μορφή ομότιμης παραγωγής (όταν η εργασία εκτελείται σε συνεργασία), αλλά συχνά αναλαμβάνεται και από μοναδικά άτομα. Η βασική προϋπόθεση είναι η χρήση της ανοιχτής μορφής κλήσεων και του μεγάλου δικτύου δυνητικών εργατών. Μετά από μια έρευνα περισσότερων από 40 ορισμών του πληθοπορισμού, οι Estellés-Arolas and González Ladrón-de-Guevara (2012) κατέληξαν στον πιο επεξηγηματικό ορισμό και ορίζουν «Το Crowdsourcing είναι ένας

τύπος συμμετοχικής ηλεκτρονικής δραστηριότητας, στην οποία ένα άτομο, ένα ίδρυμα, ένας μη κερδοσκοπικός οργανισμός ή μια εταιρεία προτείνει σε μια ομάδα ατόμων διαφορετικής γνώσης, ανομοιογένειας και αριθμού, μέσω μιας ευέλικτης ανοιχτής πρόσκλησης, την εθελοντική ανάληψη μιας αποστολής. Η ανάληψη της αποστολής, στην οποία θα πρέπει να συμμετέχει το πλήθος, φέρνοντας το έργο, τα χρήματά τους, τις γνώσεις και τις εμπειρίες, συνεπάγεται πάντοτε αμοιβαίο όφελος. Ο χρήστης θα λάβει την ικανοποίηση ενός δεδομένου είδους ανάγκης, είτε πρόκειται για οικονομική, κοινωνική αναγνώριση, αυτοεκτίμηση, είτε για την ανάπτυξη ατομικών δεξιοτήτων, ενώ ο παραλήπτης θα αποκτήσει και θα χρησιμοποιήσει προς όφελός του, τα αποτελέσματα, που έφερε ο χρήστης στην επιχείρηση, η μορφή του οποίου θα εξαρτηθεί από το είδος της δραστηριότητας που έχει αναληφθεί.».

Εκμεταλλευόμενοι το φαινόμενο του πληθοπορισμού και την ευρεία χρήση των έξυπνων κινητών, ο όγκος δεδομένων είναι μεγάλος και συνεχής, με αποτέλεσμα να δημιουργούνται νέες προοπτικές στις έρευνες. Η πληθώρα αδρανειακών αισθητήρων, που είναι εξοπλισμένα τα smartphones, τα καθιστά χρήσιμα εργαλεία για να παράγουν αξιόπιστες πληροφορίες στις έρευνες. Τα ευφυή συστήματα των μεταφορών (ITS) και οι μέθοδοι ποσοτικοποίησης στις μεταφορές αποκτούν νέο χαρακτήρα, ικανό να αντιμετωπίζονται τα διάφορα ζητήματα με μεγαλύτερη ευχέρεια και με σημαντικό βαθμό εγκυρότητας. Με τον πληθοπορισμό ανοίγουν νέοι ορίζοντες για τις προσεγγίσεις στα ζητήματα στις μεταφορές. Συνίσταται ιδιαίτερη προσοχή στην αξιοποίηση των πληροφοριών, που παρέχονται από smartphone. Τα προβλήματα, που δημιουργούν τα δεδομένα από έξυπνα κινητά, και οι τρόποι αντιμετώπισης παρουσιάζονται στο Κεφάλαιο 2.

1.4. ΣΚΟΠΟΣ ΤΗΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Η παρούσα διπλωματική εργασία στοχεύει στη δημιουργία αξιόπιστων μοντέλων πρόβλεψης ακραίων οδηγικών γεγονότων. Για το συγκεκριμένο σκοπό τα δεδομένα συλλέχθηκαν αποκλειστικά από έξυπνα κινητά. Η παρακολούθηση της κίνησης του οχήματος πραγματοποιείται μέσω των αισθητήρων, που διαθέτουν τα smartphones, καταγράφοντας τις ενδείξεις, που χαρακτηρίζουν την οδηγική συμπεριφορά. Τα δεδομένα αναλύθηκαν και επεξεργάστηκαν κατάλληλα. Στο πλαίσιο της διπλωματικής εργασίας αναπτύσσονται δυο μεθοδολογίες. Η πρώτη μεθοδολογία προσεγγίζει το ζήτημα καταγράφοντας τα χαρακτηριστικά της μη κανονικής οδήγησης, ή τα πιθανά σημεία οδηγικών συμβάντων με τεχνικές εντοπισμού ακραίων τιμών (outlier detection). Η δεύτερη μεθοδολογία, αντιμετωπίζει το κάθε ταξίδι καθολικά, συσχετίζοντας τα δεδομένα με τη χρήση μεθόδων υπολογισμού των μετρικών αποστάσεων για κάθε στιγμιότυπο της οδήγησης. Στη συνέχεια, με χρήση της μηχανικής μάθησης, συγκεντρώνοντας τα δεδομένα που προέκυψαν από τις δυο μεθοδολογίες και τα χαρακτηριστικά της οδήγησης, εκπαιδεύονται δυο νευρωνικά δίκτυα για καθεμιά από τις μεθόδους, τα οποία βελτιστοποιούνται ως προς τη δομή και τις παραμέτρους τους.

Καταλήγοντας, τα αποτελέσματα των δυο μεθόδων αξιολογούνται ξεχωριστά και συγκρίνονται μεταξύ τους, με κριτήριο την αποδοτικότητα τους να ανιχνεύουν εύστοχα της επικίνδυνες οδηγικές καταστάσεις.

1.5. ΔΟΜΗ ΤΗΣ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Το υποκεφάλαιο θα ασχοληθεί με την παρουσίαση της δομής της διπλωματικής εργασίας, καθώς και θα πραγματοποιηθεί μια συνοπτική περιγραφή των κεφαλαίων, που την απαρτίζουν.

ΚΕΦΑΛΑΙΟ 1

Το πρώτο κεφάλαιο περιλαμβάνει μια εισαγωγή στις μεταφορές την σύγχρονη εποχή παρουσιάζοντας τη σημαντικότητα καταγραφής της οδηγικής συμπεριφοράς. Αναδεικνύει την ανάγκη ποσοτικοποίησης της οδηγικής συμπεριφοράς μέσα από την καταγραφή των ακραίων οδηγικών γεγονότων. Στη συνέχεια, επισημαίνεται η επαναστατική μέθοδος του πληθοπορισμού και η αξιοποίηση της. Τέλος, αναφέρεται ο σκοπός εκπόνησης της παρούσας διπλωματικής.

ΚΕΦΑΛΑΙΟ 2

Στο δεύτερο κεφάλαιο πραγματοποιείται η βιβλιογραφική ανασκόπηση των ερευνών με παραπλήσια θεματολογία. Στην πράξη αναπτύσσονται οι καταγραφείς των δεδομένων και τα ζητήματα, που πρέπει να αντιμετωπισθούν. Γίνεται αναφορά στην επιθετική οδηγική συμπεριφορά και στη σημασία εντοπισμού της. Για την ανίχνευσή της θα αναπτυχθούν και θα αξιολογηθούν οι διάφορες υπάρχουσες προσεγγίσεις, με σκοπό τον εντοπισμό ερευνητικών κενών. Καταλήγοντας, θα γίνει η βιβλιογραφική ανασκόπηση των μεθοδολογιών εντοπισμού και θα αιτιολογηθεί η αποδοτικότητα της επιλογής της χρήσης Νευρωνικών Δικτύων.

ΚΕΦΑΛΑΙΟ 3

Το κεφάλαιο θα ασχοληθεί με την ανάπτυξη του θεωρητικού υπόβαθρου των μεθόδων, που θα χρησιμοποιηθούν, ώστε να παρουσιασθεί μια ολοκληρωμένη μεθοδολογία για τον εντοπισμού ακραίων οδηγικών συμβάντων. Συγκεκριμένα, θα διατυπωθεί το ζήτημα, που θα απασχολήσει, και θα παρατεθεί το διάγραμμα ροής εργασιών της διπλωματικής εργασίας, ακόμη, θα αναδειχθούν οι μεθοδολογικές προσεγγίσεις για τη δημιουργία αξιόπιστων προβλέψεων. Αρχικά, θα αναλυθεί πληρέστερα ο αλγόριθμος εντοπισμού ακραίων παρατηρήσεων, που επιλέχθηκε, Για την εφαρμογή των μεθόδων εντοπισμού χρειάζεται να αναπτυχθούν η περιοδικότητα των δεδομένων, καθώς και η κατηγοριοποίηση των διαφόρων τεχνικών. Έπειτα, θα γίνει αναφορά στις μετρικές μεθόδους. Στη συνέχεια, θα αναλυθεί η δομή, η εκπαίδευση και η βελτιστοποίηση των Νευρωνικών Δικτύων. Στο τέλος, θα αναλυθούν τα κριτήρια αξιολόγησης των αποτελεσμάτων.

ΚΕΦΑΛΑΙΟ 4

Στο τέταρτο κεφάλαιο, θα γίνει αναφορά στον τρόπο συλλογής των δεδομένων και στην αποτελεσματική επεξεργασία τους, ώστε να αποφευχθούν λάθη, που θα οδηγήσουν σε λανθασμένα αποτελέσματα. Θα ακολουθήσει η συλλογιστική πορεία επίλυσης του ζητήματος, δηλαδή γιατί έγιναν ορισμένες επιλογές για την ολοκλήρωση του πειράματος και θα περιγραφεί η διαδικασία εκπόνησης του. Αναπτύσσοντας τις δυο μεθοδολογίες θα παρουσιασθούν τα εξαγόμενα αποτελέσματα, τα οποία θα εισαχθούν στα μοντέλα πρόβλεψης για τον εντοπισμό των ακραίων οδηγικών συμβάντων και την αναγνώριση των επικίνδυνων καταστάσεων οδήγησης. Τα δυο Νευρωνικά Δίκτυα θα εκπαιδευτούν και στη συνέχεια θα βελτιστοποιηθεί η δομή τους, μέσω των παραμέτρων τους. Τέλος, θα εξετασθούν τα αποτελέσματα των προβλέψεων και θα αναλυθούν, καταλήγοντας σε μια σύγκριση των δυο μοντέλων.

ΚΕΦΑΛΑΙΟ 5

Στο πέμπτο κεφάλαιο περιλαμβάνεται από την ανάδειξη των σημαντικότερων σημείων, που προέκυψαν από την εκπόνηση της πειραματικής διαδικασίας. Θα παρατεθούν τα ποιοτικά αποτελέσματα εκφραζόμενα από τα ποσοτικά αποτελέσματα και προτάσεις με σκοπό την ενίσχυση της υπάρχουσας βιβλιογραφίας και την μελλοντική έρευνα.

ΚΕΦΑΛΑΙΟ 6

Στο έκτο κεφάλαιο αναφέρεται η πλήρης βιβλιογραφία, που χρησιμοποιήθηκε για την ολοκλήρωση της παρούσας διπλωματικής εργασίας.

2. ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΑΝΑΣΚΟΠΗΣΗ

Το Κεφάλαιο θα ασχοληθεί με τη βιβλιογραφική ανασκόπηση τους ζητήματος, που αναπτύχθηκε συνοπτικά στο εισαγωγικό κεφάλαιο. Σκοπός είναι η κατανόηση των τρόπων λειτουργίας των συγκοινωνιακών ζητημάτων. Η βιβλιογραφική ανασκόπηση θα βοηθήσει στην κατανόηση του ζητήματος, ώστε να εντοπισθεί ο κατάλληλος τρόπος αντιμετώπισης. Αρχικά, θα γίνει αναφορά στους αισθητήρες καταγραφής και στο τρόπο αξιολόγησης των παραγόμενων δεδομένων. Στη συνέχεια, αναπτύσσοντας τη σημαντικότητα αναγνώρισης της επιθετικής οδήγησης, θα αναλυθεί πως συνίσταται να ανιχνευθεί.

2.1. ΔΕΔΟΜΕΝΑ ΑΠΟ ΑΙΣΘΗΤΗΡΕΣ

Για την παρακολούθηση των δεδομένων, χρήσιμων για την διερεύνηση των οδηγικών χαρακτηριστικών, χρησιμοποιείται μια μεγάλη ποικιλία αισθητήρων. Οι δύο κύριες κατηγορίες είναι οι σταθεροί αισθητήρες και οι αισθητήρες GPS.


Οι σταθεροί αισθητήρες, που παρέχουν πληροφορίες, μπορεί να είναι, είτε ενσύρματοι, είτε ασύρματοι και διακρίνονται σε δύο κατηγορίες ανάλογα με την τοποθέτησή τους εντός του οδοστρώματος, όπως οι πιεζοηλεκτρικοί αισθητήρες και το επαγωγικό μαγνητόμετρο, ή εκτός του οδοστρώματος, όπως το ραντάρ μικροκυμάτων και οι ανιχνευτές υπερήχων.

Η άλλη κατηγορία, η οποία θα απασχολήσει και στην παρούσα διπλωματική, είναι οι αισθητήρες GPS (Γεωγραφικό Σύστημα Προσδιορισμού Θέσης, Global Positioning System), με τη μέθοδο προσδιορισμού θέσης του GNSS (Global Navigation Satellite System). Οι δέκτες GPS των οχημάτων λαμβάνουν σήματα από τους δορυφόρους, οι οποίοι αποστέλλουν στο κέντρο ελέγχου τις συντεταγμένες θέσης του οχήματος, όπου προκύπτουν οι συγκοινωνιακές πληροφορίες.

Η εγκατάσταση σταθερών αισθητήρων είναι μια δαπανηρή διαδικασία, καθώς απαιτείται η τοποθέτηση του εξοπλισμού και η δημιουργία ενός δικτύου για τη μετάδοση των πληροφοριών. Επίσης, οι σταθεροί αισθητήρες συλλέγουν πληροφορίες προσεγγίζοντας ένα συγκεκριμένο σημείο επί της οδού και καταγράφουν τις συνθήκες κυκλοφορίας στο σημείο αυτό. Για να μπορέσει να εκτιμηθεί σωστά η κυκλοφοριακή κατάσταση μιας περιοχής, θα πρέπει να εγκατασταθούν αρκετοί σταθεροί αισθητήρες σε μια ευρύτερη ζώνη. Το πρόβλημα αυτό δύναται να αντιμετωπιστεί με τη χρήση των

αισθητήρων GPS, όμως απαραίτητη προϋπόθεση για καλύτερα αποτελέσματα είναι κάθε δρόμος να έχει ένα σημαντικό ποσοστό οχημάτων με εξοπλισμό GPS.

Οι δέκτες GPS τοποθετούνται εντός του οχήματος (IVDRs), στη θέση της θύρας OBD, και μεταδίδουν πληροφορίες, σχετικά με την τοποθεσία, την ώρα και την ταχύτητα του οχήματος, στο κέντρο συλλογής δεδομένων με κάποια συχνότητα. Η περιοδικότητα στην αποστολή των δεδομένων, λόγω των καθυστερήσεων στις επικοινωνίες, είναι ικανή να δημιουργήσει απώλειες στο σύνολο των δεδομένων. Τα δεδομένα, λοιπόν, απαιτούν προσεκτική και εμπεριστατωμένη επεξεργασία, ώστε να εξαχθούν με τη μεγαλύτερη δυνατή ακρίβεια σε σχέση με τη πραγματικότητα. Λόγω της πολλαπλής διαδρομής του σήματος σε αστικές περιοχές το GPS αντιμετωπίζει δυσκολία στην αποστολή των δεδομένων. Βέβαια με την επιλογή του κατάλληλου αλγόριθμο για την επεξεργασία των δεδομένων στο κεντρικό σύστημα είναι δυνατόν να επιτευχθεί μία εξαιρετική εκτίμηση της κίνησης του οχήματος στην οδό (Calabrese et al., 2011). Σύμφωνα με τους Toledo et al. (2008), η παρακολούθηση όλων των ταξιδιών ενός οχήματος δημιουργεί μία μεγάλη βάση δεδομένων, η οποία είναι πολύτιμη για την παρακολούθηση, τον εντοπισμό και τη αντιμετώπιση των κυκλοφοριακών προβλημάτων. Στην Εικόνα 2.1 απεικονίζεται η τυπική μορφή του συστήματος λειτουργίας GPS.




Εικόνα 2.1: Μορφή συστήματος λειτουργίας GPS. (Πηγή: Saiprasent et Pattara-Atikom, 2013).

Τα τελευταία χρόνια, οι ερευνητικές δραστηριότητες στις μεταφορές, έχουν στραφεί τα δεδομένα να λαμβάνονται από τα έξυπνα κινητά (smartphones). Το φαινόμενο αυτό οφείλεται στη σημαντική μείωση του κόστους αρχικής επένδυσης. Ο όγκος των δεδομένων, που μπορούν να συλλεχθούν από τα έξυπνα κινητά είναι πολύ μεγάλος. Ακόμη, τα smartphones αποτελούν χρήσιμα εργαλεία, καθώς διαθέτουν αρκετούς αισθητήρες, όπως την κάμερα, το μικρόφωνο, τον αδρανειακό αισθητήρα επιτάχυνσης, το γυροσκόπιο, το μαγνητόμετρο και το GPS. Για την αξιοποίηση των δεδομένων με δέκτες τα smartphones θα πρέπει να εξετασθεί πόσο κοντά είναι τα δεδομένα, που λαμβάνονται, με την πραγματικότητα.

Η ευρεία κατοχή και χρήση των έξυπνων κινητών μπορεί να προσφέρει ένα πολύ μεγάλο και σημαντικό όγκο πληροφοριών για τα συγκοινωνιακά ζητήματα. Σύμφωνα

με το Pew Research Center, το 77% του πληθυσμού των Η.Π.Α έχει στην κατοχή του smartphone (Raine and Perrin, 2017). Σημαντικό κομμάτι της αξιοποίησης των πληροφοριών, που προέρχονται από τα έξυπνα κινητά είναι η σωστή διαχείριση και επεξεργασία των δεδομένων αυτών. Αβεβαιότητα προκαλεί ο παράγοντας του «θορύβου», ο οποίος κάνει τα έξυπνα κινητά δυνητικά λιγότερο αξιόπιστα σε σχέση με τους άλλους αισθητήρες. «Θόρυβος» στα δεδομένα ή θορυβώδη δεδομένα ονομάζονται τα δεδομένα με μία μεγάλη ποσότητα πρόσθετων πληροφοριών χωρίς νόημα. Οι Ghose et al. (2016) χρησιμοποιώντας δεδομένα από έξυπνα κινητά για την αξιολόγηση της οδηγικής συμπεριφοράς των οδηγών ανέδειξαν τη χρήση έξυπνων κινητών ως μια βιώσιμη εναλλακτική λύση για την παρακολούθηση των οδηγών.

Τα έξυπνα κινητά έχουν λιγότερη ακρίβεια σε σχέση με τα εγκαταστημένα συστήματα εντός του αυτοκινήτου (IVDR), τα οποία διαθέτουν αισθητήρες GPS και τοποθετούνται στις θύρες OBD του οχήματος, ο Chowdhury et al. (2014) αναφέρει ότι η ταχύτητα του αισθητήρα GPS του smartphone είναι χαμηλότερη από τον αισθητήρα GPS της θύρας OBD, περίπου κατά 2-4 km/h για την επιτάχυνση, ωστόσο, όταν το όχημα επιβραδύνει απότομα, η μέτρηση του smartphone είναι λίγο πιο αισιόδοξη σε σύγκριση με το OBD. Για το smartphone, που βρίσκεται στο κάθισμα του συνοδηγού, οι διακυμάνσεις στην καταμέτρηση των καταχωρισμένων γεγονότων είναι υψηλότερες σε σύγκριση με την ενσωματωμένη μονάδα. Αυτά τα ευρήματα προκαλούν υψηλό ποσοστό σφάλματος για τις μετρήσεις συμβάντων, που βασίζονται σε smartphone, και εξαρτώνται από τις συγκεκριμένες θέσεις του smartphone εντός του οχήματος και τους τύπους συμβάντων. Ένα απλό παράδειγμα είναι ότι τα smartphone δεν είναι σχεδιασμένα για να διαθέτουν αισθητήρες υψηλής ακρίβειας για τον υπολογισμό δεδομένων σε ένα γεγονός απότομης επιβράδυνσης, ένα φαινόμενο με υψηλή δυναμική. Σε μια άλλη έρευνα των Saiprasent and Pattara-Atikom (2013), τα δεδομένα από το smartphone είναι τόσο ακριβές όσο οι τιμές από το ταχύμετρο του αυτοκινήτου, με απόκλιση της ταχύτητας περίπου 4 km/hr, όπως φαίνεται στο Διάγραμμα 2.1.



Διάγραμμα 2.1: Απόκλιση καταγραφής ταχύτητας από GPS (smartphone) και ταχυμέτρου οχήματος (OBD). (Πηγή: Saiprasent et Pattara-Atikom, 2013).

Ακόμη, οι Chakravarty et al. (2014) διαπίστωσαν ότι η εκτίμηση της ταχύτητας από τους αισθητήρες του smartphone είναι πολύ κοντά στην πραγματική ταχύτητα, μετρημένη με σύστημα στη θύρα OBD-II, αρκεί να χρησιμοποιηθεί μια

αποτελεσματική μέθοδος επεξεργασίας από την προοπτική του «θορύβου» στα δεδομένα. Ακόμη, τονίζουν ότι σε ένα μεγάλης διάρκειας ταξίδι ενός οχήματος απαιτείται μεγάλη κατανάλωση ενέργειας από την μπαταρία του κινητού για τη λήψη των δεδομένων.

2.2. ΔΙΑΧΕΙΡΙΣΗ ΔΕΔΟΜΕΝΩΝ

Σημαντική έρευνα για την σωστή αξιολόγηση της ποιότητας των δεδομένων, που παρέχονται από τους αισθητήρες έξυπνων κινητών, των Handel et al. (2014). Αναφέρει ότι η αξιοπιστία των δεδομένων των μετρήσεων, που προέρχονται από smartphone χαρακτηρίζεται από την ακρίβεια, την ακεραιότητα, τη διαθεσιμότητα και τη συνέχεια της υπηρεσίας, οι σύντομες ερμηνείες τους φαίνονται στον Πίνακα 2.1. Στα οχήματα, όπου τα δεδομένα υπολογίζονται μέσω της θύρας OBD, τα αποτελέσματα είναι πολύ ακριβείς, με κάποια μικρά σφάλματα να υπόκεινται στην ολίσθηση των τροχών, στις μεταβολές ακτίνας του τροχού και στην ποσοτικοποίηση των δεδομένων. Με τη χρήση των αισθητήρων GNSS (Global Navigational Satellite System - receiver 3, μια συχνή μέθοδος) των smartphone, τα δεδομένα έχουν πολύ καλή ακρίβεια σε σχέση με αυτά της θύρας OBD, συγκεκριμένα κάτω από 0,1 m/s. Τα προβλήματα των μετρήσεων σε ορισμένες περιπτώσεις υπόκεινται σε μη ανιχνεύσιμες τιμές και σε διαταραχές στο ρυθμό απόκτησης των δεδομένων. Γενικά, η έρευνα αυτή θεωρεί τα smartphone ως καλούς αισθητήρες λήψης δεδομένων για εφαρμογές στον τομέα των Πληροφοριών και των Επικοινωνιών, που επιτρέπουν νέες εφαρμογές για τα Ευφυή Συστήματα Μεταφορών (ITS). Ο Πίνακας 2.2 παρουσιάζει την αποδοτικότητα, που εκτιμήθηκε σε σχέση με τα χαρακτηριστικά αξιοπιστίας των δεδομένων.

Πίνακας 2.1: Σύντομες ερμηνείες χαρακτηριστικών αξιοπιστίας δεδομένων. (Πηγή: Handel et al., 2014).

ΜΕΤΡΗΣΗ	ΠΕΡΙΓΡΑΦΗ
Ακρίβεια (Accuracy)	Η συμμόρφωση μεταξύ πληροφοριών αισθητήρα και πραγματικής αξίας
Ακεραιότητα (Integrity)	Η αξιοπιστία(εμπιστοσύνη), που μπορεί να τεθεί στις πληροφορίες του αισθητήρα και την ποιότητα δεικτών, ακρίβεια, των συστημάτων αισθητήρα
Διαθεσιμότητα (Availability)	Η γεωγραφική κάλυψη, για την οποία ο αισθητήρας παρέχει διαθέσιμες πληροφορίες
Συνέχεια της υπηρεσίας (Continue of Services)	Η διαθεσιμότητα της υπηρεσίας με την πάροδο του χρόνου, χωρίς προγραμματισμένες διακοπές κατά τη διάρκεια της προβλεπόμενης εργασίας.

Πίνακας 2.2: Αποδοτικότητα αισθητήρων σε σχέση με τα χαρακτηριστικά αξιοπιστίας των δεδομένων. (Πηγή: Handel et al., 2014).

ΑΙΣΘΗΤΗΡΑΣ	Ακρίβεια	Ακεραιότητα	Διαθεσιμότητα	Συνέχεια της υπηρεσίας
OBD	Μέτρια	Υψηλή	Υψηλή	Υψηλή
GNSS	Υψηλή	Χαμηλή	Χαμηλή	Υψηλή
GNSS-Ενισχυμένο	Υψηλή	Υψηλή	Χαμηλή	Υψηλή


Για την αποτελεσματική ανίχνευση ακραίων οδηγικών γεγονότων, οι Johnson and Trivedi (2011) χρησιμοποίησαν ένα σύνθετο σύστημα και τους αισθητήρες του smartphone (επιταχυνσιόμετρο, γυροσκόπιο, μαγνητόμετρο, GPS, μικρόφωνο και βίντεο). Η τοποθέτηση του smartphone, ήταν σε συγκεκριμένο σημείο, όπως φαίνεται στην Εικόνα 2.1.




Εικόνα 2.2: Τοποθέτηση smartphone εντός του οχήματος. (Πηγή: Johnson et Trivedi, 2011).

Τα smartphones, ως αισθητήρες, δείχνουν ευαισθησία στη συλλογή δεδομένων ανάλογα με τον προσανατολισμό τους. Ένα smartphone είναι πιθανό να μην τοποθετηθεί οριζόντια, ώστε οι άξονες τους να ταυτίζονται με τους άξονες του οχήματος. Στις Εικόνα 2.3 και Εικόνα 2.4 εμφανίζονται οι άξονες αναφοράς για το smartphone και το όχημα, αντίστοιχα. Οι Alanezi and Mishra (2015) ανέδειξαν το πρόβλημα ότι οι ενδείξεις των αισθητήρων των smartphone επηρεάζονται σημαντικά από τη μεταβολή της θέσης του smartphone, ως αποτέλεσμα να μειώνεται η ακρίβεια των εφαρμογών, που εξαρτώνται από αυτούς τους αισθητήρες. Τα κυριότερα σφάλματα στις μετρήσεις από smartphone, προκαλούνται από την αλλαγή κατεύθυνσης/προσανατολισμού της συσκευής από την κρίσιμη για το συστήματα (Kang et al., 2012). Οι Vlahogianni and Barmounakis (2017), ανέπτυξαν έναν αλγόριθμο, για την αντιμετώπιση του προβλήματος του προσανατολισμού της θέσης του smartphone εντός του αυτοκινήτου, διορθώνοντας τα δεδομένα με χρήση του GPS.

Τα ευρήματα έδειξαν μεγάλη ακρίβεια σε σύγκριση με συσκευές τοποθετημένες στη θύρα OBD. Έναν ακόμη αλγόριθμο για ακριβή εκτίμηση της ταχύτητας, χρησιμοποιώντας την επιτάχυνση και τη θέση, λαμβάνοντας υπόψη τον προσανατολισμό του smartphone, παρουσίασαν οι Ghose et al. (2016).



Εικόνα 2.3: Άξονες αναφοράς smartphone. (Πηγή: Bhoraskar et al., 2012).




Εικόνα 2.4: Άξονες αναφοράς οχήματος. (Πηγή: Bhoraskar et al., 2012).

2.3. ΣΥΧΝΟΤΗΤΕΣ ΣΤΑ ΔΕΔΟΜΕΝΑ

Οι αισθητήρες των smartphone καταγράφουν τα δεδομένα με μια συχνότητα. Η συχνότητα είναι μια σημαντική παράμετρος, για την αξιοποίηση των δεδομένων, καθώς για διαφορετικές συχνότητες οι καταγεγραμμένες παρατηρήσεις θα επηρεαστούν διαφορετικά. Στην έρευνα των Bergasa et al. (2014) τα δεδομένα από επιταχυνσιόμετρο συλλέχθηκαν με συχνότητα 100 Hz, για αυτή τη συχνότητα τα δεδομένα από το smartphone περιέχουν σημαντικές ποσότητες «θορύβου» από τους κραδασμούς του οχήματος. Αντίστοιχα, οι Eriksson et al. (2008) χρησιμοποίησαν δεδομένα από ενσωματωμένο GPS εντός του οχήματος και από τους αισθητήρες του smartphone, οι συχνότητες ήταν 1 Hz και 380 Hz. Αυτό είχε ως αποτέλεσμα για τα δεδομένα, να έχει συλλεχθεί ικανοποιητικός όγκος δεδομένων και χωρίς πολύ


«θόρυβο». Για να μπορέσει, να γίνει η επεξεργασία των δεδομένων, οι πληροφορίες που προήλθαν από το smartphone, χρειάστηκαν επεξεργασία, τα ακατέργαστα δεδομένα επιτάχθηκε να προσαρμοστούν. Οι Engelbrecht et al. (2014) δειγμάτισαν τα δεδομένα από το επιταχυνσιόμετρο και το γυροσκόπιο με 20 Hz. Αν υπήρχε η δυνατότητα για μεγαλύτερο ρυθμό δειγματοληψίας, αυτό θα είχε ως αποτέλεσμα να αυξηθεί η κατανάλωση ενέργειας, οπότε η συχνότητα θεωρήθηκε αρκετή. Προτείνεται, για δεδομένα από GPS η συχνότητα στα 1 Hz κατάλληλη, ενώ για δεδομένα από τους αδρανειακούς αισθητήρες των smartphone μια συχνότητα κοντά στα 20 Hz είναι ικανή να προσφέρει ικανοποιητικό αριθμό και ποιότητα δεδομένων για επεξεργασία, χωρίς υπερβολικές καταναλώσεις ενέργειας (Hemminki et al., 2013). Στην έρευνα των Muscillo et al. (2007), τα σήματα από το επιταχυνσιόμετρο παρέχονταν με συχνότητες μεταξύ 0,2 Hz και 15 Hz, αντίθετα για τους Liu et al. (2009), οι αισθητήρες λειτούργησαν στα 100 Hz. Συγκεκριμένα, σύμφωνα με την έρευνα της Analog Devices, για δεδομένα επιτάχυνσης με εύρος -3g έως 3g, και σε ένα φάσμα συχνοτήτων από 0,5 έως 1600 Hz, για τους άξονες X, Y, και από 0,5 έως 550 Hz, για τον άξονα Z, ο αισθητήρας λειτουργώντας στα 100 Hz, παράγει «θόρυβο» μικρότερο από 3,5mg. Οι υψηλές συχνότητες θα απαιτήσουν και μεγαλύτερη κατανάλωση ενέργειας. Ιδανικά, για μια συχνότητα μικρότερη από 50 Hz, τα ακατέργαστα δεδομένα μπορούν να επεξεργαστούν ικανοποιητικά και η κατανάλωση είναι ανεκτική. Ενδεικτικά, στο Διάγραμμα 2.2, η διαφορά στην κατανάλωση ενέργειας ενός smartphone με τη χρήση συστήματος καταγραφής δεδομένων και χωρίς, σύμφωνα με τους Dai et al. (2010).



Διάγραμμα 2.2: Κατανάλωση ενέργειας smartphone, με και χωρίς τη χρήση εφαρμογής καταγραφής δεδομένων. (Πηγή: Dai et al., 2010).

Για τον Mitrovic (2005), η συχνότητα λήψης των δεδομένων καθορίστηκε στα 60 Hz, όμως τα κοινά συμβάντα οδήγησης διαρκούν μερικά δευτερόλεπτα, για το λόγο αυτό χρησιμοποιήθηκε μια τεχνική κατακερματισμού της κυματομορφής, με αποτέλεσμα όλα σημαντικά χαρακτηριστικά κυματομορφής να διατηρούνται, ενώ ο αριθμός των απαιτούμενων τιμών δεδομένων να μειώνεται. Διάφορες έρευνες επέλεξαν ορισμένες τιμές συχνοτήτων. Για τους Vlahogianni et al. (2013), η απόκτηση δεδομένων ρυθμίστηκε να καταγράφονται με ακρίβεια 100 Hz, εκτός από το τα σήματα βίντεο, στα οποία λαμβάνονται στα 10 Hz και η θέση GPS στα 1 Hz. Οι Baldwin et al. (2004), επέλεξαν 50 Hz. Το σήμα του smartphone, σε μια άλλη έρευνα των Johnson and Trivedi (2011), ήταν 25Hz, με σημαντικές ποσότητες θορύβου να προέρχονται από τις

δονήσεις στο εσωτερικού του οχήματος, αλλά μετά το φιλτράρισμα, τα χαρακτηριστικά αποδεικνύονται σε μεγάλο βαθμό συσχετισμένα. Οι Fazeen et al. (2012) αναζήτησαν την ακρίβεια της συσκευής για συγκεκριμένη συχνότητα, με πειραματική σύγκριση στα υπολογιζόμενα δεδομένα και τα παρατηρούμενα δεδομένα, που καταγράφονται από το smartphone. Τα αποτελέσματα έδειξαν το επιταχυνσιόμετρο, να είναι πολύ ακριβές στα 25 Hz, καθιστώντας την συσκευή αξιόπιστη, όπως φαίνεται στο παρακάτω Διάγραμμα 2.3, όπου στα 4 δευτερόλεπτα τέμνονται τα παρατηρούμενα δεδομένα με τα υπολογιζόμενα.



Διάγραμμα 2.3: Συχνότητες καταγραφής για παρατηρούμενα και υπολογιζόμενα δεδομένα. (Πηγή: Fazeen et al., 2012).

2.4. ΟΔΗΓΙΚΗ ΣΥΜΠΕΡΙΦΟΡΑ

Η αναγνώριση της οδικής συμπεριφοράς είναι πολύ σημαντικό κομμάτι για το τομέα των μεταφορών, όπως εξηγήθηκε και στο εισαγωγικό κεφάλαιο. Υπάρχει πληθώρα ερευνών στον εντοπισμό, την αξιολόγηση και την αξιοποίηση των αποτελεσμάτων για την οδηγική συμπεριφορά.

Μια σημαντική έρευνα για να κατανοήσει κάποιος τις πολιτικές οδήγησης, αλλά και την αξιοποίηση τους είναι αυτή των Tselentis et al. (2017), όπου αναλύει τις πιο δημοφιλείς και συχνά εφαρμοζόμενες μεθοδολογίες στον κλάδο της ασφάλισης των οχημάτων, με σκοπό το ασφάλιστρο, αντί για μια σταθερή τιμή, να υπολογίζεται με βάση τη συμπεριφορά οδήγησης κατά την διάρκεια των ταξιδιών ενός οδηγού (UBI-Usage-based motor insurance). Τέτοια προγράμματα είναι το Pay-As-You-Drive (PAYD) και το Pay-How-You-Drive (PHYD). Οι Handel et al. (2014) ανέπτυξαν ένα αλγόριθμο, με σκοπό τη βαθμολόγηση της συμπεριφοράς των οδηγών, δημιουργώντας τα προφίλ επικίνδυνων συμπεριφορών. Για να το πετύχουν χρησιμοποίησαν παραμέτρους, όπως η ταχύτητα, ο τύπος της οδού, η επικίνδυνη οδήγηση εκφραζόμενη σε γεγονότα απότομης επιτάχυνσης ή επιβράδυνσης, απότομης στροφής και

επικίνδυνων ελιγμών, τη διάρκεια των ταξιδιών και την κατανάλωση ενέργειας. Οι Predic and Stojanovic (2015) ανέπτυξαν ένα σύστημα βασισμένο σε δεδομένα από smartphone, για την ανίχνευση σημαντικών οδηγικών καταστάσεων της κυκλοφορίας. Εντοπίζουν οδηγούς με επιθετική συμπεριφορά, όπως ακραία επιβράδυνση, ξαφνική αλλαγή λωρίδας κατεύθυνσης, απότομες στροφές και υπερβολική ταχύτητα. Αυτά τα συμβάντα κυκλοφορίας μπορούν να κατηγοριοποιηθούν ως επικίνδυνες καταστάσεις οδήγησης. Ακόμη, παρέχονται προληπτικές ενημερώσεις στους οδηγούς, που διέρχονται από τη διαδρομή ή βρίσκονται κοντά στα αναφερόμενα συμβάντα.

Στην έρευνα των Musicant et al. (2014), τονίστηκε η ανάγκη για εξατομικευμένη προσέγγιση της συμπεριφοράς του εκάστοτε οδηγού. Για την ανίχνευση επικίνδυνων οδηγικών γεγονότων χρησιμοποιήθηκαν δεδομένα από IVDRs (πληροφορίες εγγραφής δεδομένων εντός οχήματος). Αναλύοντας τη συχνότητα εμφάνισης επικίνδυνων οδηγικών καταστάσεων, εντοπίστηκε, επίσης ότι το 87% των οδηγών βελτιώσαν την οδηγική τους συμπεριφορά κατά τη διάρκεια της περιόδου μέτρησης. Για να μειωθεί η επικίνδυνη συμπεριφορά των οδηγών, η έρευνα που πραγματοποίησαν οι Lampel and Musicant (2014), δημιούργησε ένα περιβάλλον ανατροφοδότησης, που ενημερώνει τον οδηγό όταν η συμπεριφορά του αλλάζει σε «επιθετική» και τα αποτελέσματα έδειξαν ότι η συχνότητα των συμβάντων μειώθηκε κατά 50%. Αξιοσημείωτη η προσέγγιση των Tran and Trivedi (2010), όπου προσπάθησε να αναλύσει την οδηγική συμπεριφορά, δηλαδή την πρόθεση του οδηγού, την συναισθηματική του κατάσταση και την απόσπαση του κατά τη διάρκεια ενός ταξιδιού, διερευνώντας το ρόλο της στάσης του σώματος σε 3D.


Εμπειρικά στοιχεία, έχουν δείξει ότι η καταγραφή της οδηγικής συμπεριφοράς επηρεάζει σημαντικά τη συμπεριφορά των οδηγών. Συγκεκριμένα, οι Lehman and Cheale (1998) αναφέρουν μείωση της τάξης του 15% έως 30%, στην πρόκληση τροχαίων ατυχημάτων. Οι Wouters and Bos (2000) καθορίζουν ότι η μείωση εξαρτάται και από το είδος παρακολούθησης, όταν η παρακολούθηση ήταν πειραματική η μείωση πρόκλησης ατυχημάτων εντοπίστηκε 20% με επίπεδο σημαντικότητας 95%. Αντίστοιχα, στην περίπτωση εξωτερικής αντιστοίχισης εκτιμήθηκε 12%. Το αποτέλεσμα αυτό δεν ήταν στατιστικά σημαντικό, καθώς η πιθανότητα να μην υπάρχει πραγματική μείωση ήταν 15%.

2.4.1. ΑΝΑΓΝΩΡΙΣΗ ΟΔΗΓΙΚΟΥ ΣΥΜΒΑΝΤΟΣ

Για την εύστοχη αναγνώριση της οδηγικής συμπεριφοράς ενός οδηγού είναι απαραίτητος ο εντοπισμός των ακραίων οδηγικών γεγονότων. Έχουν αναπτυχθεί πολλές μεθοδολογίες για τον εντοπισμό και την πρόβλεψη των ακραίων οδηγικών γεγονότων.

Οι Bergasa et al. (2014) ανέπτυξαν το Drive Safe, μια εφαρμογή που ανιχνεύει τις επικίνδυνες οδηγικές καταστάσεις του οδηγού και δίνει τη δυνατότητα στους οδηγούς να ενημερώνονται για την βαθμολογία τους σε σχέση με το πόσο ασφαλής είναι η οδήγησή τους, μέσω ενός συστήματος ανατροφοδότησης πληροφοριών. Ακόμη, προειδοποιεί προληπτικά τους οδηγούς να διορθώσουν την οδηγική τους πολιτική. Τα

δεδομένα για τον εντοπισμό των επικίνδυνων γεγονότων προέρχονται από την κάμερα, το μικρόφωνο, το GPS και τους αδρανειακούς αισθητήρες του smartphone. Στο πρώτο σκέλος του DriveSafe, αξιοποιήθηκαν τα δεδομένα που προέρχονται από το μικρόφωνο, για να επιβεβαιώσει το σύστημα τον οδηγό, καθώς το ίδιο όχημα μπορεί να χρησιμοποιείται από διαφορετικούς οδηγούς, γεγονός που μπορεί να δημιουργήσει ασάφειες στα αποτελέσματα, ακόμη τα δεδομένα από την κάμερα του smartphone, για να εντοπισθούν τα γεγονότα, όπου το όχημα τείνει να παρασυρθεί εκτός της λωρίδας και την ακούσια αλλαγή λωρίδας κυκλοφορίας, δηλαδή αν μια αλλαγή λωρίδας είναι σκόπιμη ή όχι. Ενδεικτικά, η μορφή της λήψης των δεδομένων φαίνεται στην παρακάτω Εικόνα 2.5.




Εικόνα 2.5: Μορφή βιντεοσκοπικής λήψης των δεδομένων. (Πηγή: Bergasa et al., 2014).

Στο δεύτερο σκέλος, λαμβάνοντας τα δεδομένα της επιτάχυνσης, από τους αδρανειακούς αισθητήρες του smartphone και της ταχύτητας, από το GPS, εντόπισαν τα επιτρεπτά όρια των τιμών, που καθορίζουν αν υπάρχει επικίνδυνο γεγονός ή όχι, τα όρια αυτά φαίνονται, στον παρακάτω Πίνακα 2.3.

Πίνακας 2.3: Όρια τιμών για τον καθορισμό γεγονότων. (Πηγή: Bergasa et al., 2014).

Event Type	Threshold sensitivity		
	Low	Medium	High
Acceleration	$0.1g < a_z < 0.2g$	$0.2g < a_z < 0.4g$	$a_z > 0.4g$
Braking	$-0.1g > a_z > -0.2g$	$-0.2g > a_z > -0.4g$	$a_z < -0.4g$
Turning	$0.1g < a'_y < 0.2g$	$0.2g < a'_y < 0.4g$	$ a'_y > 0.4g$


Τελικά, για το εντοπισμό των συμβάντων συνδύασαν τα αποτελέσματα των δύο μεθόδων με επιτυχία, αφού το σύστημα απέδωσε με συνολική ακρίβεια 82%. Η δομή, που αντιμετώπισαν το πρόβλημα φαίνεται στην παρακάτω Εικόνα 2.6.



Εικόνα 2.6: Δομή ροής εργασιών για τον εντοπισμό συμβάντων. (Πηγή: Bergasa et al., 2014).


Αξίζει να σημειωθεί ότι, για τον εντοπισμό γεγονότων, έθεσαν όρια στις τιμές των επιταχύνσεων. Μια τέτοια τακτική μπορεί να μην είναι πολύ επιτυχημένη στις περιπτώσεις με πολλούς οδηγούς, όπως τονίστηκε και παραπάνω η σημασία της εξατομικευμένης προσέγγισης των ταξιδιών των οδηγών. Για το λόγο αυτό και οι ίδιοι οι συγγραφείς επισημαίνουν την χρήση ενός στατιστικού μοντέλου μηχανικής μάθησης (Machine Learning) για τον εντοπισμό των ακραίων οδηγικών συμβάντων.

Οι Eriksson et al. (2008), για τη αναγνώριση της κατάστασης του οδοστρώματος με δεδομένα από τους αισθητήρες του smartphone, ανέλυσαν τη σωστή αξιοποίηση των μεγεθών της επιτάχυνσης στους τρεις άξονες και τη σωστή μεταχείριση του καθενός, ανάλογα με το σκοπό της εκάστοτε διερεύνησης. Έτσι, χρησιμοποιώντας τα δεδομένα των επιταχύνσεων από τον κατακόρυφο άξονα (Z-άξονα), με μοντέλα μηχανικής μάθησης (Machine Learning), και συγκεκριμένα τεχνικές συσταδοποίησης (Clustering Methods), εντόπισαν τις έντονες διακυμάνσεις και μπόρεσαν να χαρακτηρίσουν τα τμήματα της οδού. Σε μια άλλη έρευνα, οι Bhoraskar et al. (2012), αναγνωρίζοντας τα προβλήματα, που δημιουργούνται από την ανίχνευση ακραίων οδηγικών γεγονότων θέτοντας όρια στις τιμές (threshold based methods), χρησιμοποίησαν τεχνικές μηχανικής μάθησης, Μοντέλα Συσταδοποίησης (Clustering K-means) και Μηχανή Φορέα Υποστήριξης (SVM-Support Vector Machine), τα οποία είναι πιο ανθεκτικά και ευέλικτα σε σύγκριση με τις μεθόδους, που βασίζονται σε όρια στις τιμές. Λόγω της διακύμανσης στα χαρακτηριστικά, η ακρίβεια του συστήματος με σταθερά κατώτατα όρια θα είναι χαμηλότερη, όταν οι συνθήκες αλλάζουν. Οι συγγραφείς θέλησαν να κατηγοριοποιήσουν τα τμήματα της οδού, που κινείται όχημα, σε ομαλά ή ανώμαλα, καταγράφοντας τις διακυμάνσεις των επιταχύνσεων στον κατακόρυφο άξονα, όπως χαρακτηριστικά φαίνεται στο παρακάτω Διάγραμμα 2.4.



Διάγραμμα 2.4: Απότομες διακυμάνσεις επιταχύνσεων άξονα Z. (Πηγή: Bhoraskar et al., 2012).

Στη συνέχεια, θέλησαν να εντοπίσουν τα συμβάντα απότομης πέδησης. Για να το πετύχουν αξιοποίησαν τις πληροφορίες από το επιταχυνσιόμετρο, και συγκεκριμένα την επιτάχυνση από τον παράλληλο άξονα στην κίνηση του οχήματος (Y-άξονα), καθώς εκεί εντοπιζόνταν οι έντονες διακυμάνσεις, όπως φαίνεται στο Διάγραμμα 2.5, εφαρμόζοντας τις τεχνικές μηχανικής μάθησης εντόπισαν τα γεγονότα απότομης επιβράδυνσης.



Διάγραμμα 2.5: Απότομες διακυμάνσεις επιταχύνσεων άξονα Y. (Πηγή: Bhoraskar et al., 2012).

Στη βιβλιογραφία, για την επιτυχής ανίχνευση ακραίων οδηγικών συμβάντων πολλές έρευνες εφαρμόζουν παρόμοια μεθοδολογική προσέγγιση, τη χρήση των αλγόριθμων DTW. Στην ανάλυση χρονοσειρών, η δυναμική χρονική στρέβλωση (DTW) χρησιμοποιείται για τη μέτρηση της ομοιότητας μεταξύ δύο χρονικών αλληλουχιών, οι οποίες μπορεί να διαφέρουν στην ταχύτητα. Για παράδειγμα, οι ομοιότητες στο περπάτημα θα μπορούσαν να ανιχνευθούν χρησιμοποιώντας το DTW, ακόμα και αν ένα άτομο περπατούσε ταχύτερα από το άλλο ή εάν υπήρχαν επιταχύνσεις και επιβραδύνσεις κατά τη διάρκεια μιας παρατήρησης.

Οι συγγραφείς Engelbrecht et al. (2014) ασχολήθηκαν με τον εντοπισμό των οδηγικών πλευρικών ελιγμών, έτσι για 40 τιμές του δείγματος υπολογίζουν συνεχώς τον κινούμενο μέσο όρο (SMA) και το πλευρικό γεγονός εντοπίζεται τη στιγμή που η τιμή του κινούμενου μέσου όρου περάσει κάποιο κατώτατο όριο. Το διάστημα, που ο κινούμενος μέσος όρος βρίσκεται πάνω από το όριο, που έχει τεθεί, αποτελεί τη διάρκεια εξέλιξης του συμβάντος. Όταν εντοπιστεί ένα γεγονός οδήγησης, τα σήματα που καταγράφονται κατά τη διάρκεια του συμβάντος συγκρίνονται με τα πραγματικά, που έχουν καταγραφεί χρησιμοποιώντας έναν αλγόριθμο δυναμικής χρονικής στρέβλωσης (DTW), υπολογίζοντας την Ευκλείδεια απόσταση μεταξύ των σημείων του σήματος. Στο πείραμα έλαβαν μέρος δυο οδηγοί, ο πρώτος οδήγησε επιθετικά και τα αποτελέσματα ήταν ποσοστό False Negative 80% και ποσοστό False Positive 10,5%, ενώ αντίστοιχα ο οδηγός με τη μη-επιθετική οδήγηση σημείωσε ποσοστό False Negative 0% και ποσοστό False Positive 5,9%. Η προσέγγιση παρουσιάζει αδυναμία στον χαρακτηρισμό της οδηγικής συμπεριφοράς, όταν ο οδηγός ακολουθεί επιθετική οδηγική πολιτική.

Οι έρευνες των Holt et al. (2007) και των Muscillo et al. (2007) χρησιμοποίησαν και τις τρεις διαστάσεις των επιταχύνσεων, ώστε να βρεθεί ο καλύτερος συγχρονισμός. Επιλέχθηκε ένας αλγόριθμος Dynamic Time Warping σε πολυδιάστατες χρονολογικές σειρές (MD-DTW), ο οποίος αποδείχθηκε πολύ πιο αποδοτικός σε σχέση με ένα απλό Dynamic Time Warping αλγόριθμο (DTW). Ένας απλός αλγόριθμος Dynamic Time Warping έδειξε να αδυνατεί να παράγει σωστά συμπεράσματα, όταν αυξανόταν ο «θόρυβος» στα δεδομένα. Τα αποτελέσματα έδειξαν ότι η μέση ποσοστιαία αναγνώριση ακραίων γεγονότων, με MD-DTW ήταν 95%, υψηλότερη από την μέση ποσοστιαία αναγνώριση ακραίων γεγονότων, που λαμβάνονται με DTW (περίπου 85%).


Οι Liu et al. (2009) ανέπτυξαν το uWave, έναν αλγόριθμο για εντοπισμό γεγονότων, που χρησιμοποιεί μόνο επιταχυνσιόμετρο τριών αξόνων. Επεξεργάζοντας τα δεδομένα από το επιταχυνσιόμετρο, υπολογίζοντας το διάνυσμα της επιτάχυνσης στους τρεις άξονες, και την αναγνώριση των κινήσεων του χεριού είναι ικανό να εντοπίσει αποτελεσματικά την ύπαρξη οδηγικού συμβάντος. Το uWave επιτυγχάνει την αναγνώριση των ακραίων οδηγικών γεγονότων με ακρίβεια 98,6%. Το uWave χρησιμοποιώντας δυναμική χρονική στρέβλωση (DTW), μπορεί με μικρά δείγματα εκπαίδευσης να προσφέρει υψηλά ποσοστά επιτυχίας, σε σχέση με άλλες μεθόδους, που απαιτούν μεγαλύτερα δείγματα εκπαίδευσης, όπως τα κρυφά μαρκοβιανά μοντέλα (HMMs).

Η έρευνα του Mitrovic (2005) προσέγγισε το θέμα του εντοπισμού οδηγικών γεγονότων με μια απλή και αξιόπιστη μέθοδο τα κρυφά Μαρκοβιανά μοντέλα (HMMs), δημοφιλή στοχαστικά εργαλεία για τη διερεύνηση δεδομένων χρονοσειρών. Για το μοντέλο πρόβλεψης υπολογίζεται το συνισταμένο διάνυσμα των επιταχύνσεων, για να μεταφράσει την αναλογικότητα του σήματος σε διακριτές τιμές, που θα εισαχθούν στο μοντέλο. Η ευστοχία στον εντοπισμό των συμβάντων ήταν υψηλή, μόνο 4 από 238 (1,7%) των δοκιμαστικών συμβάντων αναγνωρίστηκαν λανθασμένα. Βέβαια, υπήρξε μεγάλη δυσκολία στον διαχωρισμό των συμβάντων, ανάλογα με την κατηγορία τους, για παράδειγμα αν ήταν απότομη επιτάχυνση ή απότομη επιβράδυνση. Το επίπεδο αναγνώρισης της κατάστασης θεωρήθηκε υψηλό, αντίθετα για τον καθορισμό του τύπου του συμβάντος η ακρίβεια ήταν χαμηλή. Μια άλλη έρευνα των Baldwin et al. (2004) επικεντρώθηκε στην εκτίμηση των οδηγικών επιδόσεων των

ηλικιωμένων. Χρησιμοποιήθηκαν οι δύο οριζόντιοι άξονες με την διαφοροποίηση, ότι έγινε και χρήση βίντεο. Ο εντοπισμός των ακραίων οδηγικών γεγονότων έγινε συνδυάζοντας τις απότομες αυξομειώσεις στο διάνυσμα των επιταχύνσεων και της απόστασης από το προπορευόμενο όχημα. Οι Vlahogianni et al. (2013) αντιμετώπισαν το πρόβλημα της αναγνώρισης των επικίνδυνων οδηγικών μοτίβων των δικυκλιστών οχημάτων, με τεχνικές μηχανικής μάθησης, και συγκεκριμένα Bayesian Networks, για τον προσδιορισμό των διαφορετικών μοτίβων οδήγησης.

Οι Engelbrecht et al. (2014), προσπάθησαν να συγκρίνουν ορισμένες μεθοδολογίες στην ανίχνευση ακραίων οδηγικών γεγονότων, όσο αυτό είναι δυνατό. Μια ποσοτική σύγκριση δεν θα είχε νόημα, λόγω της διαφορετικότητάς των χαρακτηριστικών του εκάστοτε πειράματος. Τα πειράματα εφαρμόστηκαν σε διαφορετικά smartphone, που έχουν ποικίλους αισθητήρες, διαφορετική υπολογιστική ισχύ και διαφορετική συχνότητα μετάδοσης των δεδομένων. Ακόμη, οι δοκιμές των ερευνών εκτελέστηκαν σε διάφορες χώρες, με διαφορετικές οδούς και κυκλοφοριακές συνθήκες. Έτσι, ως μέτρο σύγκρισης χρησιμοποίησαν την απλότητα της κάθε μεθοδολογίας. Η απλότητα κάθε μεθοδολογίας βασίζεται σε αυτό που το κάθε ένα σύστημα προσπαθεί να εντοπίσει, ποιους αισθητήρες χρησιμοποιεί και πώς λειτουργούν οι αλγόριθμοι.

Οι White et al. (2011) ανέπτυξαν έναν αλγόριθμο, που αντιλαμβάνεται την ύπαρξη τροχαίων ατυχημάτων και ειδοποιεί αμέσως το προσωπικό έκτακτης ανάγκης. Λαμβάνοντας τις τιμές της επιτάχυνσης από το αδρανειακό επιταχυνσιόμετρο του smartphone, όταν αυτές ξεπεράσουν κάποιο κατώτατο όριο, τότε υπάρχει πιθανό οδηγικό γεγονός, στη συνέχεια για να μειωθούν τα σφάλματα από τη δυσκολία εντοπισμού γεγονότων σε χαμηλές ταχύτητες χρησιμοποιείται το ακουστικό του smartphone, όπου ήχοι άνω των 150 dB επιβεβαιώνουν την ύπαρξη τροχαίου ατυχήματος, όπως μια σύγκρουση οχημάτων ή το άνοιγμα των αερόσακων (180 dB). Βέβαια, μπορεί ομιλίες ή η χρήση ραδιοφώνου να ξεπεράσει αυτό το όριο, γι' αυτό ακολουθεί και δεύτερη επεξεργασία των ακουστικών δεδομένων, καταγράφοντας τις προηγούμενες δραστηριότητες του ήχου, έτσι αν εμφανιστεί μια απότομη αλλαγή καταγράφεται ως συμβάν. Έχει ακρίβεια, εμπειρικά, 100% και είναι το απλούστερο σύστημα, επειδή εντοπίζει μόνο ατυχήματα. Στην Εικόνα 2.7 παρουσιάζεται η τυπική μορφή ειδοποίησης ατυχήματος.



Εικόνα 2.7: Δομή ροής εργασιών για τον εντοπισμό συμβάντων. (Πηγή: White et al., 2011).

Το Nericell, ένα σύστημα που ανέπτυξαν οι Mohan et al. (2008), στοχεύει στον εντοπισμό ακραίων γεγονότων αξιοποιώντας τα δεδομένα από το επιταχυνσιόμετρο, το μικρόφωνο, το ραδιόφωνο GSM και τους αισθητήρες GPS των smartphone. Για τον εντοπισμό της απότομης πέδησης το Nericell, από τα προσανατολισμένα δεδομένα του smartphone, έθεσε ένα κατώτατο όριο, υπολογισμένο συνάρτηση των τιμών των επιταχύνσεων και της ταχύτητας από το GPS, το οποίο όταν ξεπεραστεί υπάρχει ακραίο οδηγικό γεγονός πέδησης. Ως αποτέλεσμα το ποσοστό False Negative ήταν 4-11% για κάθε ταξίδι, δηλαδή ο εντοπισμός των επικίνδυνων οδηγικών συμβάντων απότομης επιβράδυνσης αξιολογείται με ικανοποιητική ακρίβεια. Παρόμοια μεθοδολογική προσέγγιση, όπου αντιμετώπισαν το ζήτημα του εντοπισμού των γεγονότων θέτοντας κατώτατα όρια στις τιμές των επιταχύνσεων, πρόσφεραν και οι Fazeen et al. (2012), οι οποίοι πέραν της οδηγικής συμπεριφοράς ανέπτυξαν και ένα σύστημα χαρτογράφησης των χαρακτηριστικών των οδών, εκμεταλλευόμενοι το GPS και το επιταχυνσιόμετρο ενός smartphone. Η παρακολούθηση της οδηγικής κατάστασης για τους Mohan et al. (2008) κρίθηκε απλούστερη και ακριβέστερη από αυτή των Fazeen et al. (2012), σύμφωνα με τους Engelbrecht et al. (2014).


Οι Johnson and Trivedi, (2011) δημιούργησαν το πρόγραμμα MIROAD, με την καινοτομία ότι όλες οι διεργασίες γίνονται αποκλειστικά από το smartphone. Εκμεταλλευόμενοι του αισθητήρες, που παρέχει ένα έξυπνο κινητό, όπως η κάμερα, το μικρόφωνο, ο αδρανειακός αισθητήρας επιτάχυνσης, το γυροσκόπιο, το μαγνητόμετρο και το GPS. Υπολογίζοντας τον κινούμενο μέσο όρο 15 τιμών, δημιουργούν σταθερά κατώτατα όρια. Χρησιμοποιώντας ένα αλγόριθμο DTW, εντοπίζουν πιθανά σημεία οδηγικών γεγονότων. Καταλήγοντας σε ένα στατιστικό μοντέλο ομαδοποίησης (K-Nearest Neighbors) αναγνωρίζουν τα σημεία αυτά, ως ακραία οδηγικά συμβάντα ή όχι.

Οι Eren et al. (2012) χρησιμοποιώντας τα δεδομένα από το επιταχυνσιόμετρο, το γυροσκόπιο και το μαγνητόμετρο για να εκτιμήσουν τα γεγονότα ανέπτυξαν μια απλή τεχνική. Υπέθεσαν ότι τα επικίνδυνα γεγονότα εμφανίζονται με απότομες διακύμανσης στα δεδομένα, έτσι με το αλγόριθμο ανίχνευσης τελικού σημείου (end-point detection algorithm), μια τεχνική εντοπισμού ακραίων παρατηρήσεων, εντόπισαν τις τιμές αυτές. Στη συνέχεια, χρησιμοποιώντας ένα DTW αλγόριθμο, υπολόγισαν την Ευκλείδεια απόσταση των τιμών αυτών. Για να μπορέσει να γίνει η ταξινόμηση (classification) των γεγονότων αυτών σε επικίνδυνα ή μη, χρησιμοποιήθηκε ένας αλγόριθμος στατιστικής ταξινόμησης Bayesian και τα αποτελέσματα στον εντοπισμό γεγονότων σημείωσαν μεγάλη επιτυχία, εντοπίζοντας σωστά τα γεγονότα για 14 από τους 15 οδηγούς. Οι έρευνες των Johnson and Trivedi (2011) και των Eren et al. (2012) εφάρμοσαν μια πιο περίπλοκη προσέγγιση για την αναγνώριση προτύπων οδηγικής πολιτικής. Τα συστήματά τους έχουν καλή απόδοση, με ποσοστό ακρίβειας 97% και 93%, αντίστοιχα.

Σε μια άλλη έρευνα, οι Dai et al. (2010) ανέπτυξαν ένα σύστημα για την έγκαιρη ανίχνευση των οδηγών υπό την επήρεια αλκοόλ, καταγράφοντας την επικίνδυνη οδική συμπεριφορά, μέσω του εντοπισμού των απότομων οδηγικών ελιγμών, και συγκρίνοντας την οδηγική συμπεριφορά του οδηγού με τυπικά μοτίβα οδήγησης υπό την επήρεια αλκοόλ. Η μεθοδολογική προσέγγιση, που εφάρμοσαν ήταν να θέσουν σταθερά κατώτατά όρια. Αξιοσημείωτο στο συγκεκριμένο πείραμα είναι ότι για την ανίχνευση των απότομων ελιγμών, χρησιμοποιήθηκαν μόνο οι δυο οριζόντιοι άξονες των επιταχύνσεων, ενώ αμελήθηκε ο κατακόρυφος. Τα αποτελέσματα του πειράματος έδειξαν πολύ χαμηλά False Negative και False Positive Rates, 0% και 2,49%, δηλαδή

η μεθοδολογία αποδίδει με υψηλή ακρίβεια για τον εντοπισμό της οδηγικής συμπεριφοράς υπό τη επήρεια αλκοόλ και της φυσιολογικής οδήγησης.

Η ποιοτική αξιολόγηση, σύμφωνα με την έρευνα των Engelbrecht et al. (2014) για τις προσεγγίσεις, που ακολούθησε καθεμιά από τις παραπάνω έρευνες σε σχέση με την απλότητα και την ακρίβεια, φαίνεται στην παρακάτω Διάγραμμα 2.6.



Διάγραμμα 2.6: Σύγκριση απλότητας και ακρίβειας μεθοδολογιών. (Πηγή: Engelbrecht et al., 2014).

2.5. ΣΥΓΚΡΙΤΙΚΕΣ ΜΕΘΟΔΟΛΟΓΙΕΣ ΜΟΝΤΕΛΩΝ ΠΡΟΒΛΕΨΗΣ

Δεδομένου της ύπαρξης πολλών και διαφορετικών αλγόριθμων ανίχνευσης η άμεση σύγκριση μεταξύ τους, για την επιλογή του κατάλληλου για το αντίστοιχο πρόβλημα, δεν είναι πάντοτε δυνατή. Στις περισσότερες περιπτώσεις, η δομή των δεδομένων και ο μηχανισμός ανίχνευσης υπαγορεύουν ποια μέθοδος θα αποδώσει καλύτερα. Κάποιες έρευνες συγκρίνουν διαφορετικές κατηγορίες μεθόδων εντοπισμού. Οι μέθοδοι εντοπισμού, που αποφασίστηκε να χρησιμοποιηθούν για την επίλυση του ζητήματος της παρούσας διπλωματικής, θα αναπτυχθούν αναλυτικότερα στο επόμενο κεφάλαιο της Μεθοδολογικής Προσέγγισης.

Οι Williams et al. (2002) προτείνουν ότι τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN) είναι ικανά να προβλέψουν επαρκώς τα αποτελέσματα σε σύγκριση με άλλες μεθόδους. Σε πολλές περιπτώσεις, η επιτυχία των νευρωνικών δικτύων αυξάνεται για μεγάλο σύνολο δεδομένων. Σύγκριναν, λοιπόν, τα RNN με δυο στατιστικές μεθόδους (Hadi 1994, Knorr et al. 2001) και μια μέθοδο εξόρυξης δεδομένων (Data Mining) (Oliver et al., 1996), και παρόλο που οι στατιστικές μέθοδοι έδιναν πιο ικανοποιητικά αποτελέσματα από τη μέθοδο εξόρυξης, τα αποτελέσματα βελτιώθηκαν, ακόμη περισσότερο με τη χρήση νευρωνικών δικτύων για μεγάλο όγκο παρατηρήσεων. Τα αποτελέσματα δείχνουν, γενικά, ότι τα Νευρωνικά Δίκτυα (Neural Network) παρέχουν πιο ακριβείς προβλέψεις από τις κλασσικές στατιστικές προσεγγίσεις, ιδιαίτερα για τις λεπτομερείς αναλύσεις δεδομένων (Vlahogianni and Karlaftis, 2013). Ακόμη, η

έρευνα των Shekar et al. (2001), χρησιμοποιώντας δεδομένα κυκλοφορίας παρουσιάζουν κάποια πειραματικά αποτελέσματα αξιολόγησης διαφορετικών αλγορίθμων. Η προσέγγιση τους ήταν, για τις διαφορετικές διαδικασίες ανίχνευσης να παρέχονται μοντέλα κόστους. Τελικά, έγινε σύγκριση της απόδοσης κάθε προσέγγισης και κατέληξαν ότι οι τεχνικές μηχανικής μάθησης είναι αρκετά αποδοτικές. Η δυσκολία επιλογής κατάλληλου μοντέλου πρόβλεψης, παρά τις προτάσεις διαφόρων ερευνητών παραμένει, για το λόγο αυτό απαιτείται επαρκής γνώση του ζητήματος, που καλείται κάθε ερευνητής να αντιμετωπίσει, και της λειτουργίας του μοντέλου, που θα χρησιμοποιηθεί. Οι Penny and Jolliffe (2001) σύγκριναν έξι μεθόδους ανίχνευσης πολλών μεταβλητών. Τα αποτελέσματα έδειξαν ότι καμία τεχνική ήταν πολύ ανώτερη από τις υπόλοιπες. Έτσι, ανέφεραν ορισμένους παράγοντες, που επηρεάζουν την αποτελεσματικότητα των διαφόρων μεθόδων. Συγκεκριμένα ορίζουν, ότι η επιλογή του μοντέλου εξαρτάται από τις μεταβλητές, που χαρακτηρίζουν τα αποτελέσματα, από το μέγεθος του συνόλου το δεδομένων, από τη μορφή των αποτελεσμάτων, από το ποσοστό των παρατηρήσεων, που αναζητούνται στο σύνολο του δείγματος, και από το βαθμό συσχέτισης των αποτελεσμάτων με τις υπόλοιπες τιμές, δηλαδή οι αποκλίσεις που προκύπτουν εξαιτίας αλλαγών στη συμπεριφορά του συστήματος, λειτουργούν ως αιτιολογικός μηχανισμός με αποτέλεσμα κάποιες παρατηρήσεις να ξεπερνούν τις υπόλοιπες (King effect). Ακόμη, προσθέτουν την εξάρτηση από τη δομή των δεδομένων (structure), τους χρονικούς περιορισμούς και το τρόπο συλλογής των δεδομένων (συχνότητα καταγραφής, online/offline).

2.6. ΣΥΜΠΕΡΑΣΜΑΤΑ ΑΝΑΣΚΟΠΗΣΗΣ

Από την ανάλυση της βιβλιογραφίας προκύπτει ότι με την κατάλληλη επεξεργασία, τα δεδομένα που συλλέγονται από τους αισθητήρες των κινητών τηλεφώνων μπορούν να θεωρηθούν αρκετά αξιόπιστα για τις έρευνες χαρακτηρισμού της οδηγικής συμπεριφοράς. Η χρήση έξυπνων κινητών ανοίγει νέους ορίζοντες στην αντιμετώπιση των διαφόρων ζητημάτων.

Η αναγνώριση της οδηγικής συμπεριφοράς, κυρίως της επιθετικής οδηγικής συμπεριφοράς μέσω της ανίχνευσης των απότομων οδηγικών χειρισμών απασχολεί έντονα πολλούς κλάδους. Παρέχει σημαντικές πληροφορίες στις ασφαλιστικές εταιρίες, ώστε να διαχειριστούν τον τρόπο προσέγγισης της λειτουργίας τους, ακόμη διευκολύνει της μεταπωλήσεις των οχημάτων και σημαντικότερο ενισχύει την ασφάλεια της μετακίνησης, είτε προειδοποιώντας τον οδηγό για επικίνδυνες καταστάσεις, είτε ενημερώνοντας τους αρμόδιους. Πρέπει, όμως, να αναλυθεί ο τρόπος, με τον οποίο είναι δυνατό να ποσοτικοποιηθεί η επικίνδυνη οδήγηση.

Η επικίνδυνη οδήγηση ποσοτικοποιείται με την εμφάνιση ακραίων φαινομένων σε σχέση με τη φυσιολογική οδήγηση. Η συχνή εμφάνιση απότομων επιταχύνσεων και επιβραδύνσεων μπορούν να χαρακτηρίσουν την οδήγηση επιθετική. Οι επιθετικές αυτές συμπεριφορές μπορούν απλά να καταγραφούν με τη χρήση αισθητήρων. Για παράδειγμα, αν ένα όχημα αυξήσει την ταχύτητα του πολύ γρήγορα αυτό συνεπάγεται με μια υψηλή τιμή της επιτάχυνσης. Αξιοποιώντας, λοιπόν, τα δεδομένα των

αισθητήρων και εκτεταμένη χρήση των έξυπνων κινητών τηλεφώνων, καθίσταται δυνατό να ποσοτικοποιηθεί η επικίνδυνη οδήγηση.

Η υπάρχουσα βιβλιογραφία, παρέχει μια πληθώρα ερευνών σχετικών με την ποσοτικοποίηση της επικίνδυνης οδήγησης. Αρκετές έρευνες στρέφονται στην ανίχνευση αυτών των ακραίων οδηγικών συμβάντων και οι έρευνες αυτές πολλές φορές διαφοροποιούνται. Όπως διαπιστώθηκε από τη βιβλιογραφική ανασκόπηση, οι περισσότερες έρευνες, που ασχολούνται με την ανίχνευση, προσεγγίζουν το ζήτημα από ένα σύνολο δεδομένων να προκύψουν οι ακραίες συμπεριφορές.

Η μηχανική μάθηση έρχεται να βοηθήσει στην αποτελεσματική πρόβλεψη των ακραίων οδηγικών συμβάντων. Οι περισσότερες έρευνες προσέγγισαν το ζήτημα με χρήση απλοϊκών μεθόδων, όπως η χρήση ενός κατώτατου ορίου, τέτοιες μέθοδοι χαρακτηρίζονται από τη δυσκολία προσαρμογής του μοντέλου αν οι συνθήκες αλλάξουν. Έτσι, η μηχανική μάθηση αντιμετωπίζει τα προβλήματα της προσαρμοστικότητας και μάλιστα σύμφωνα με τη βιβλιογραφία καταγράφει σημαντικά ποσοστά επιτυχίας, στις έρευνες που χρησιμοποιείται. Οπότε, η επιλογή του κατάλληλου μοντέλου μηχανικής μάθησης αποτελεί το επόμενο πρόβλημα, που καλείται να αντιμετωπισθεί. Η βιβλιογραφία παρουσιάζει ότι τα Νευρωνικά Δίκτυα αποτελούν αξιόπιστα μοντέλα για προβλέψεις. Για μεγάλα δεδομένα, που χαρακτηρίζονται από αρκετές μεταβλητές και απαιτούν πολύπλοκη ανάλυση, η χρήση νευρωνικών δικτύων μπορεί να προσδώσει ικανοποιητικά αποτελέσματα.

Η δημιουργία αποδοτικών μοντέλων πρόβλεψης με χρήση Νευρωνικών Δικτύων σε συνδυασμό με την μεθοδολογική προσέγγιση του διαχωρισμού της οδηγικής κατάστασης, έρχεται να συμπληρώσει την υπάρχουσα βιβλιογραφία και καλύψει τυχόν ερευνητικά κενά στις μέχρι τώρα μεθοδολογίες. Ακόμη, μπορεί να προσφέρει προβληματισμό, ως προς τους εδραιωμένους τρόπους προσέγγισης, με σκοπό την εξέλιξη της επιστήμης των μεταφορών.

3. ΜΕΘΟΔΟΛΟΓΙΚΗ ΠΡΟΣΕΓΓΙΣΗ

3.1. ΔΙΑΤΥΠΩΣΗ ΠΡΟΒΛΗΜΑΤΟΣ ΚΑΙ ΕΠΙΛΟΓΗ ΜΕΘΟΔΩΝ ΕΠΙΛΥΣΗΣ

Η παρούσα διπλωματική εργασία καλείται να αντιμετωπίσει το πρόβλημα του εντοπισμού των ακραίων οδηγικών συμβάντων, για την αξιοποίηση τους στο χαρακτηρισμό της οδηγικής συμπεριφοράς. Αποσκοπεί στην ανίχνευση των ακραίων γεγονότων και στο χαρακτηρισμό τους ως απότομες επιταχύνσεις και απότομες επιβραδύνσεις. Για τον σκοπό αυτό, δημιουργούνται αξιόπιστα πρότυπα πρόβλεψης για την αναγνώριση επικίνδυνων καταστάσεων αξιοποιώντας τα δεδομένα αποκλειστικά από smartphones, καταγράφοντας τις επιταχύνσεις και την ταχύτητα, θα εκπαιδευθούν μοντέλα πρόβλεψης, τα οποία θα μπορούν να εντοπίσουν τα οδηγικά γεγονότα, αναγνωρίζοντας τα ως απότομες μεταβολές των παρατηρήσεων.


Τα δεδομένα που εισάγονται, ώστε να καθορισθεί η οδηγική συμπεριφορά είναι η επιτάχυνση του άξονα X, του άξονα Y και του Z, και η ταχύτητα, με την οποία κινείται το όχημα. Τα δεδομένα προέρχονται αποκλειστικά από τους αισθητήρες των έξυπνων κινητών. Στη συνέχεια, οι παρατηρήσεις επεξεργάζονται και καταλήγουν στην αξιοποίηση τους από τις δυο μεθοδολογίες πρόβλεψης. Συγκεκριμένα, για τις παρατηρήσεις των επιταχύνσεων, λόγω του θορύβου στα δεδομένα, θα υπολογισθεί το μήκος του διανύσματος τους. Για τα δεδομένα των ταχυτήτων θα υπολογισθούν οι διαφορές ταχυτήτων για χρονικά παράθυρα δυο δευτερολέπτων, και θα καταγραφεί η απόλυτη τιμή της διαφοράς και το πρόσημό της. Μια σημαντική λεπτομέρεια είναι να μην αξιοποιηθούν οι παρατηρήσεις, για τις οποίες έχει καταγραφεί χρήση της συσκευής. Τα δεδομένα αυτά είναι πολύ θορυβώδεις και θα αλλοιώσουν τα αποτελέσματα.

Η πρώτη μέθοδος αναφέρεται στον εντοπισμό των ακραίων οδηγικών συμβάντων με τη χρησιμοποίηση ενός αλγόριθμου εντοπισμού ακραίων παρατηρήσεων και ενός Νευρωνικού Δικτύου. Η μέθοδος διαχωρίζεται σε δυο στάδιο, ένα για το καθορισμό των πιθανών οδηγικών συμβάντων και το άλλο για τον εντοπισμό των επικίνδυνων οδηγικών καταστάσεων. Στο πρώτο στάδιο, εισάγοντας τα επεξεργασμένα δεδομένα των επιταχύνσεων εφαρμόζεται ο αλγόριθμος S-H-ESD, μια στατιστική μέθοδος εντοπισμού ακραίων παρατηρήσεων. Από τον αλγόριθμο εξάγονται οι πιθανές παρατηρήσεις οδηγικών συμβάντων. Στην ουσία, διαχωρίζονται σε πρώτο στάδιο τα δεδομένα σε φυσιολογική οδήγηση και σε πιθανή επικίνδυνη οδήγηση. Το γεγονός αυτό προσδίδει το πλεονέκτημα, το δείγμα που προκύπτει να είναι πολύ μικρότερο και με μεγαλύτερη ομοιογένεια. Στη συνέχεια στο δεύτερο στάδιο, οι παρατηρήσεις, που καταγράφηκαν ως πιθανά οδηγικά γεγονότα, χαρακτηρίζονται από την απόλυτη τιμή της διαφοράς ταχύτητας και το πρόσημό της. Με τα δεδομένα αυτά θα εκπαιδευτεί το νευρωνικό δίκτυο, το οποίο θα καθορίσει τελικά την ύπαρξη οδηγικών συμβάντων ή

φυσιολογικής οδήγησης, και μάλιστα για τις επικίνδυνες καταστάσεις οδήγησης θα προσδιορίσει και τον τύπο τους, απότομες επιταχύνσεις και απότομες επιβραδύνσεις. Η διαδικασία για άρτια εκπαίδευση του νευρωνικού δικτύου απαιτεί προσοχή. Παρά την μείωση του δείγματος εξακολουθεί να υπάρχει η ανάγκη διαχείρισης ενός μη ισορροπημένου συνόλου, καθώς ο αριθμός των γεγονότων στο δείγμα είναι πολύ μικρότερος σε σχέση με τις φυσιολογικές τιμές. Για το λόγο αυτό, χρησιμοποιείται μια μέθοδος διαχείρισης μη ισορροπημένων δειγμάτων, η υποδειγματοληψία. Επομένως, πρέπει να αποφασισθεί ο κατάλληλος συνδυασμός δομής του νευρωνικού δικτύου, παραμέτρων εκπαίδευσης και επιβαλλόμενου ποσοστού συμβάντων στο σύνολο. Για να επιτευχθεί η μέγιστη αποδοτικότητα έγιναν δοκιμές, ώστε να εντοπισθεί το μοντέλο με τη μεγαλύτερη ακρίβεια. Το ζήτημα αποτελεί ένα πρόβλημα ταξινόμησης των παρατηρήσεων σε επικίνδυνες ή μη. Βασικό, κριτήριο για εύρεση του πιο εύστοχου μοντέλου αποτελούν ο πίνακας ταξινόμησης και τα στατιστικά μέτρα, που παράγει.

Για τη δεύτερη μέθοδο ακολουθήθηκε μια διαφορετική μεθοδολογική προσέγγιση. Αντί να πραγματοποιηθεί ο διαχωρισμός της προηγούμενης μεθόδου στο πρώτο στάδιο, επιλέχθηκε η διαχείριση των παρατηρήσεων καθολικά. Για το σκοπό αυτό, υπολογίζεται η μετρική απόσταση Mahalanobis για τα δεδομένα των επιταχύνσεων των στιγμιότυπων. Επομένως, καταγράφοντας τη μετρική απόσταση, που χαρακτηρίζει και συσχετίζει μια παρατήρηση με τις υπόλοιπες, την απόλυτη τιμή της διαφοράς ταχύτητας και το πρόσημό της για όλες της παρατηρήσεις εκπαιδεύτηκε ένα νευρωνικό δίκτυο. Η διαδικασία είναι ίδια με αυτή της προηγούμενης μεθόδου. Απαιτείται, λοιπόν, για την εύρεση του αποδοτικότερου δικτύου ο κατάλληλος συνδυασμός δομής και παραμέτρων εκπαίδευσης, καθώς και της δημιουργίας νέου συνόλου, με τη μέθοδο της υποδειγματοληψίας, ώστε να επιβληθεί η αναλογία συμβάντων και κανονικής οδήγησης στο δείγμα, για ταχύτερους υπολογισμούς. Η διαδικασία αυτή επαναλαμβάνεται πραγματοποιώντας δοκιμές μέχρι τον εντοπισμό του μοντέλου με τη μεγαλύτερη αποδοτικότητα. Το κριτήριο και σε αυτή την περίπτωση αποτελεί ο πίνακας ταξινόμησης και τα στατιστικά παράγωγα του.

Σκοπός είναι να δημιουργηθούν δυο ευφυή και ολοκληρωμένα συστήματα εντοπισμού των επικίνδυνων οδηγικών καταστάσεων. Στο Διάγραμμα 3.1 φαίνεται η ροή εργασιών της παρούσας διπλωματικής εργασίας.



Διάγραμμα 3.1: Διάγραμμα ροής εργασιών Διπλωματικής Εργασίας.

3.2. ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ

Το κεφάλαιο στοχεύει στην περιεκτική ανάλυση του απαιτούμενου θεωρητικού υποβάθρου, που απαιτείται για την κατανόηση των εργασιών, που χρησιμοποιήθηκαν στην παρούσα διπλωματική εργασία. Αρχικά, στο Κεφάλαιο 3.3 αναπτύσσονται οι αλγόριθμοι εντοπισμού ακραίων παρατηρήσεων (Outlier Detection), όπου οι διάφορες τεχνικές κατηγοριοποιούνται με βάση τα χαρακτηριστικά τους. Για το Κεφάλαιο 3.4 ακολουθεί η εμπειριστατωμένη ανάλυση του αλγόριθμο εντοπισμού S-H-ESD, ενός στατιστικού αλγόριθμου με τον πραγματοποιήθηκε ο εντοπισμός των ακραίων παρατηρήσεων. Στη συνέχεια στο Κεφάλαιο 3.5, γίνεται αναφορά στις χρονοσειρές και στην περιοδικότητα των παρατηρήσεων, για την εύρεση των παραμέτρων, που απαιτεί ο αλγόριθμος εντοπισμού. Στο Κεφάλαιο 3.6 θα αναπτυχθεί η διαδικασία υπολογισμών των μετρικών αποστάσεων. Καταλήγοντας, το Κεφάλαιο 3.7 αφορά τα νευρωνικά δίκτυα, όπου θα πραγματοποιηθεί η αναλυτική περιγραφή της δομής και της εκπαίδευσης των δικτύων, καθώς και η εργασίες βελτιστοποίησης, για την εύρεση του αποδοτικότερου μοντέλου πρόβλεψης. Στο τελευταίο Κεφάλαιο 3.8 παρατίθεται η στατιστική αξιολόγηση των μεθόδων, μέσω του πίνακα ταξινόμησης.

3.3. ΕΝΤΟΠΙΣΜΟΣ ΑΚΡΑΙΩΝ ΠΑΡΑΤΗΡΗΣΕΩΝ

Πληθώρα ερευνών, τα τελευταία χρόνια, έχουν ασχοληθεί με τον εντοπισμό ακραίων σημείων (Outlier Detection). Για την κατανόηση της λειτουργίας των μεθόδων εντοπισμού ακραίων σημείων, η διερεύνηση στηρίχθηκε στο κεφάλαιο Outlier Detection, με συγγραφέα τον Irad Ben-Gal (Ben-Gal, 2005) και στην έρευνα Anomaly Detection (Chandola et al., 2009).

Αρχικά, πρέπει να ορισθεί τι σημαίνει ακραία ή αποκλίνουσα τιμή. Ο Hawkins (1980) ορίζει ένα ακραίο σημεία (outlier), την απόκλιση από το γενικό χαρακτήρα του συνόλου, ως την παρατήρηση, η οποία παρεκκλίνει τόσο πολύ από τις υπόλοιπες, ώστε να προκαλέσει υποψίες ότι δημιουργείται από έναν διαφορετικό μηχανισμό. Ο Johnson (1992), ορίζει μια αποκλίνουσα τιμή είναι η παρατήρηση σε ένα σύνολο δεδομένων, που φαίνεται να είναι ασυμβίβαστη με το υπόλοιπο σύνολο δεδομένων. Το outlier detection απασχολεί, κυρίως, τους ερευνητές, που καλούνται να αναλύσουν ένα μεγάλο αριθμό δεδομένων. Ο εντοπισμός αυτών των σημείων καθίσταται αναγκαίος λόγω ότι ακραίες τιμές ενδέχεται να οδηγήσουν σε δυσκολία προσδιορισμού των παραμέτρων και σε προκατειλημμένες παραμέτρους, συνεπώς λανθασμένα αποτελέσματα. Συνιστάται, λοιπόν, ο εντοπισμός τους και, εν συνεχεία, η αφαίρεση τους. Αποφασίσθηκε, λοιπόν, εκμεταλλευόμενοι από τις δυνατότητες του outlier detection, να χρησιμοποιηθεί αντίστροφα, δηλαδή αντί να κανονικοποιηθούν τα αποτελέσματα, αφαιρώντας τις ακραίες τιμές (Novelty Detection, Noise Removal), αντί αυτού θα εντοπίζονται οι τιμές αυτές και θα καταγράφονται ως πιθανά γεγονότα, που είναι και ο σκοπός της παρούσας διπλωματικής.

3.3.1. ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗ ΤΕΧΝΙΚΩΝ ΑΝΙΧΝΕΥΣΗΣ ΑΝΩΜΑΛΙΩΝ


Η τεχνική ανίχνευσης ακραίων σημείων (outlier detection), χωρίζεται σε δυο κύριες κατηγορίες, με μια μεταβλητή (univariate) και με πολλαπλές μεταβλητές (multivariate). Η απλοϊκή τεχνική univariate, στοχεύει στον εντοπισμό ανωμαλιών για την κάθε μέτρηση, ενώ η τεχνική multivariate έχει σκοπό την εκπαίδευση ενός ενιαίου μοντέλου, λαμβάνοντας υπόψη όλες τις μετρήσεις στο δίκτυο.

Η μέθοδος με μια μεταβλητή (univariate), είναι απλούστερη τεχνική και έχει ευκολότερη κλιμάκωση για μεγάλα δείγματα. Ωστόσο, μειονεκτεί στην αναγνώριση της συσχέτισης μεταξύ των «κανονικών» παρατηρήσεων και των ακραίων, στο σύνολο του δείγματος. Αντίθετα, οι προσεγγίσεις με πολλαπλές μεταβλητές (multivariate), ανιχνεύουν ακραία σημεία ως μεμονωμένα γεγονότα, με δυσκολία στην κλιμάκωση σχετικά με τους υπολογισμούς και την ακρίβεια του μοντέλου, δηλαδή εισάγονται οι παρατηρήσεις από τις οποίες πρέπει να εξαχθεί ένας πολύ μικρός αριθμός αποτελεσμάτων. Ακόμη, κάθε μετρική παρατήρηση εισάγει αλληλεπιδράσεις μεταξύ όλων των υπόλοιπων δεδομένων. Για να μπορέσει να λειτουργήσει σωστά και να είναι ακριβές ένα μοντέλο πολλαπλών μεταβλητών, θα πρέπει τα δεδομένα να έχουν παρόμοια στατιστική συμπεριφορά, το συγκεκριμένο ζήτημα αναπτύσσεται στο υποκεφάλαιο 3.5.1, όπου αναλύεται η περιοδικότητα των δεδομένων.

Ακόμη, οι μέθοδοι ανίχνευσης χωρίζονται σε παραμετρικές (parametric) και μη παραμετρικές (non-parametric) στατιστικές τεχνικές ανίχνευσης. Για τις παραμετρικές μέθοδοι είτε να είναι γνωστή η κατανομή των παρατηρήσεων, είτε βασίζονται σε στατιστικές εκτιμήσεις των αγνώστων παραμέτρων. Τέτοια μοντέλα διαχωρίζουν τις ακραίες παρατηρήσεις, που αποκλίνουν από τις υπόλοιπες. Συνήθως, δεν χρησιμοποιούνται για πολύ μεγάλα και αυθαίρετα σύνολα, δηλαδή οι παρατηρήσεις παρέχονται με τυχαίο τρόπο, χωρίς να ακολουθούν κάποιο μοτίβο. Αντίθετα, οι μη παραμετρικές μέθοδοι, μπορούν να διαχειριστούν μεγάλα σύνολα δεδομένων και συνήθως βασίζονται σε μετρικές μεθόδους, όπως οι αποστάσεις, που αναφέρονται στο υποκεφάλαιο 3.6.

Μία ακόμα κατηγοριοποίηση για την εύρεση ακραίων σημείων στα δεδομένα βασίζεται στη διαφοροποίηση των χαρακτηριστικών της ακραίας παρατήρησης, αλλιώς ο τύπος των ανωμαλιών. Οι ανωμαλίες ταξινομούνται στις ακόλουθες τρεις κατηγορίες:

Σημειακή Ανωμαλία ή Μεμονωμένη Ανωμαλία (Point Anomaly). Είναι ο πιο απλός τύπος ανωμαλίας. Σε ένα σύνολο δεδομένων, η τιμή που αποκλίνει αρκετά από τις υπόλοιπες, είναι αυτή που χαρακτηρίζεται ως ανωμαλία και για το συγκεκριμένο στιγμιότυπο ορίζεται το σημείο ανωμαλίας. Στο Διάγραμμα 3.2, τα σημεία o1 και o2, είναι ανωμαλίες σημείου. Για παράδειγμά, αν καταγράφονται οι συναλλαγές μια πιστωτικής κάρτας, εάν έχει δαπανηθεί ένα πολύ μεγάλο ποσό σε σύγκριση με την κίνηση του λογαριασμού, τότε το σημείο αυτό ορίζεται ως ανωμαλία ή ακραία τιμή (outlier).




Διάγραμμα 3.2: Διάγραμμα φυσιολογικών και ακραίων παρατηρήσεων. (Πηγή: Chandola et al., 2009).

Συναφείς ανωμαλίες (Contextual Anomalies). Εάν ένα στιγμιότυπο στα δεδομένα είναι ανωμαλία σε ένα συγκεκριμένο πλαίσιο, δηλαδή σε σχέση με τη δομή των δεδομένων, τότε καλείται συναφής ανωμαλία. Κάθε στιγμιότυπο καθορίζεται από τα παρακάτω χαρακτηριστικά:


- **Συναφή χαρακτηριστικά (Contextual Attributes),** το οποίο χαρακτηρίζει το περιβάλλον του στιγμιότυπου. Για παράδειγμα, για γεωγραφικά δεδομένα, το γεωγραφικό μήκος και το γεωγραφικό πλάτος μιας τοποθεσίας είναι συναφή χαρακτηριστικά. Ακόμη, ο χρόνος σε μια χρονοσειρά είναι συναφή χαρακτηριστικό της θέσης, που βρίσκεται το σημείο.
- **Χαρακτηριστικά συμπεριφοράς (Behavioral Attributes),** τα οποία χαρακτηρίζουν τα μη συναφή χαρακτηριστικά ενός στιγμιότυπου. Για κατανοηθούν καλύτερα, για παράδειγμα σε ένα σύνολο γεωγραφικών δεδομένων, όπου περιγράφεται η μέση βροχόπτωση, τότε η ποσότητα της βροχόπτωσης σε οπουδήποτε σημείο ορίζεται χαρακτηριστικό συμπεριφοράς.

Χρησιμοποιώντας τις τιμές των χαρακτηριστικών συμπεριφοράς, και θέτοντας ως στιγμιότυπα τα συναφή χαρακτηριστικά, εντοπίζονται οι ανωμαλίες. Οι συναφείς ανωμαλίες, είναι η συνηθέστερη μέθοδος, για δεδομένα χρονοσειρών. Ο καθορισμός του πλαισίου είναι μια δύσκολη διαδικασία για ορισμένες περιπτώσεις που είναι πολύπλοκο να προσδιοριστούν τα χαρακτηριστικά του πλαισίου συνάφειας. Για παράδειγμα, στο παρακάτω Διάγραμμα 3.3 φαίνεται, η θερμοκρασιακή μεταβολή μιας περιοχής για ένα χρονικό διάστημα. Μια χαμηλή τιμή της θερμοκρασίας είναι λογικό να εμφανιστεί τους χειμερινούς μήνες, αντίθετα η εμφάνιση χαμηλής θερμοκρασίας τους εαρινούς μήνες, αποτελεί ανωμαλία.



Διάγραμμα 3.3: Διάγραμμα θερμοκρασιακής μεταβολής συνάρτηση του χρόνου. (Πηγή: Chandola et al., 2009).

Συλλογικές ανωμαλίες (Collective Anomalies), όπου ένα σύνολο ή διάστημα συνεχών στιγμιότυπων, θεωρούνται ανωμαλίες. Ένα μεμονωμένο σημείο μπορεί από μόνο του να μην θεωρηθεί ανωμαλία, αλλά συλλογικά με τις γειτονικές τιμές να χαρακτηριστεί το διάστημα αυτό ανωμαλία. Στο παρακάτω Διάγραμμα 3.4, όπου απεικονίζεται ένα καρδιογράφημα, με κόκκινο χρώμα εμφανίζεται το διάστημα της ανωμαλίας σε σχέση με την περιοδικότητα των δεδομένων.



Διάγραμμα 3.4: Τμήμα διαγράμματος καρδιογραφήματος. (Πηγή: Chandola et al., 2009).

Είναι σημαντικό να επισημανθεί και ο τρόπος με τον οποίο εξάγονται οι ανωμαλίες, ως αποτελέσματα ενός μοντέλου πρόβλεψης. Οι ανωμαλίες μπορούν να εξαχθούν από τα μοντέλα, ως Αποδόσεις (Scores). Εξάγονται, συνήθως, μόνο οι ανωμαλίες, οι οποίες εκφράζονται από το σημείο, που εντοπίστηκαν, και από μια βαθμολογία (score), που χαρακτηρίζει την τιμή αυτή ως ακραία τιμή ανάλογα με την μέθοδο, που χρησιμοποιήθηκε, για παράδειγμα θα μπορούσε να ο κινούμενος μέσος όρος της τιμής, όταν η μέθοδος εντοπισμού είναι η Μέθοδος Κινούμενου Μέσου Όρου. Ο ερευνητής μπορεί να διερευνήσει τις ανωμαλίες, είτε να χρησιμοποιήσει κάποιο όριο με σκοπό

την αυστηροποίηση των αποτελεσμάτων. Ακόμη, κάποιες τεχνικές αποδίδουν για αποτέλεσμα μόνο την πληροφορία για το συγκεκριμένο στιγμιότυπο και όχι για όλα τα δεδομένα, δηλαδή αν είναι φυσιολογική τιμή ή ανωμαλία. Τα αποτελέσματα αυτά, δίνουν την τάξη του στιγμιότυπου για αυτό και ονομάζονται Ετικέτες (Labels). Οι ετικέτες δεν επιτρέπουν στους ερευνητές να αναλύσουν εύκολα τα αποτελέσματα, παραμόνο μέσω των παραμέτρων του μοντέλου, που χρησιμοποιήθηκε.

Οι μεθοδολογικές προσεγγίσεις, που χρησιμοποιούνται για την ανίχνευση και εξαρτώνται από το αντικείμενο της έρευνας του εκάστοτε ερευνητή, διακρίνονται στις παρακάτω κατηγορίες:

Μέθοδοι με επίβλεψη (Supervised Anomaly Detection). Τέτοιες μέθοδοι στηρίζονται στην εποπτεία του ερευνητή, όπου ο εποπτεύων χαρακτηρίζει τι θεωρείται ανωμαλία και τι όχι. Έτσι, κατασκευάζεται ένα μοντέλο πρόβλεψης, το οποίο καθορίζει σε ποια τάξη ανήκει το στιγμιότυπο, σε φυσιολογική τιμή ή ανωμαλία. Η ανίχνευση ανωμαλιών υπό επίβλεψη καλείται να αντιμετωπίσει δυο σημαντικά ζητήματα. Οι ανωμαλίες στα δεδομένα είναι πολύ λιγότερες από τις φυσιολογικές τιμές στο σύνολο των δεδομένων. Το πρόβλημα των μη ισορροπημένων κατανομών κλάσης, συνήθως, αντιμετωπίζεται με χρήση μεθόδων εξόρυξης δεδομένων (Data mining) για την ανίχνευση ανωμαλιών υπό επίβλεψη και με μηχανική μάθηση (Machine learning). Το δεύτερο ζήτημα, που προκύπτει, είναι η απόκτηση και η επιλογή των αντιπροσωπευτικών χαρακτηριστικών, που χρειάζονται για να δημιουργηθεί ένα εύστοχο μοντέλο. Ακόμη, σημαντική δυσκολία υπάρχει στην επιλογή και κατασκευή κατάλληλου μοντέλου πρόβλεψης για τις πληροφορίες του εκάστοτε προβλήματος.

Ημι-εποπτευόμενη τεχνική ανίχνευσης δεδομένων (Semi-Supervised Anomaly Detection). Τα μοντέλα πρόβλεψης συνήθως εκπαιδεύονται για να ανιχνεύουν μόνο τις φυσιολογικές τιμές. Για τις τεχνικές Ημι-εποπτευόμενης ανίχνευσης δεδομένων, η κατασκευή ενός μοντέλου πρόβλεψης, αντιστοιχεί στην εύρεση των φυσιολογικών τιμών μέσα από το δείγμα εκπαίδευσης (Training Data) και από τα δεδομένα δοκιμής (Test Data) ανιχνεύονται οι ανωμαλίες. Τέτοιες τεχνικές δεν χρησιμοποιούνται συχνά, κυρίως επειδή είναι δύσκολο να αποκτηθεί ένα σύνολο δεδομένων εκπαίδευσης, που να καλύπτει κάθε πιθανή ανώμαλη συμπεριφορά.

Ανίχνευση ανωμαλιών χωρίς επίβλεψη (Unsupervised Anomaly Detection). Οι τεχνικές δεν απαιτούν δεδομένα εκπαίδευσης, συνεπώς είναι εύκολα εφαρμόσιμες. Η ανίχνευση ανωμαλιών χωρίς επίβλεψη, υποθέτει ότι οι φυσιολογικές τιμές θα εμφανιστούν πολύ συχνότερα από τις ανωμαλίες στα δεδομένα. Αν η υπόθεση αυτή δεν επιβεβαιωθεί ενδέχεται ένα μοντέλο πρόβλεψης χωρίς επίβλεψη να οδηγήσει σε λανθασμένα αποτελέσματα. Πολλές τεχνικές ημι-εποπτευόμενης ανίχνευσης μπορούν να προσαρμοστούν, ώστε να λειτουργήσουν ως τεχνικές χωρίς επιτήρηση. Η προσαρμογή απαιτεί στα δεδομένα δοκιμής να υπάρχουν ελάχιστες ανωμαλίες και το μοντέλο πρόβλεψης να είναι αρκετά εύστοχο, για τον εντοπισμό αυτών των λίγων ανωμαλιών.

3.3.2. ΕΦΑΡΜΟΓΕΣ ΑΝΙΧΝΕΥΣΗΣ ΑΝΩΜΑΛΙΩΝ

Ο εντοπισμός των ανωμαλιών αποτελεί σημαντική μέθοδο για πολλές εφαρμογές. Η ανίχνευση εισχωρήσεων (Intrusion detection), αναφέρεται στην ανίχνευση κακόβουλων δραστηριοτήτων. Οι κακόβουλες δραστηριότητες είναι ενδιαφέρουσες, συνήθως για την ασφάλεια των υπολογιστών. Μια διαφορετική από την κανονική συμπεριφορά του συστήματος εντοπίζεται και χαρακτηρίζεται ως ανωμαλία, καλώντας κάποιο συναγερμό (Alert). Οι προκλήσεις σε τέτοια ζητήματα είναι ο μεγάλος όγκος δεδομένων και το γεγονός, ότι οι πληροφορίες παρέχονται σε πραγματικό χρόνο (Streaming Data). Συνήθως, προτιμάται η χρήση ημι-εποπτευόμενων τεχνικών ανίχνευσης και τεχνικών χωρίς επίβλεψη, τα αποτελέσματα ενδείκνυται να εξάγονται σε μορφή ετικέτας (Label).


Άλλες εφαρμογές αφορούν την ανίχνευση απάτης (Fraud detection). Η ανίχνευση παράνομων δραστηριοτήτων, που διαπράττονται στο εμπόριο, σε οργανισμούς όπως τράπεζες, εταιρείες πιστωτικών καρτών, ασφαλιστικές εταιρείες, κινητά τηλέφωνα κτλ.. Η τυπική προσέγγιση των τεχνικών ανίχνευσης απάτης είναι η διατήρηση ενός προφίλ χρήσης για κάθε πελάτη και ο εντοπισμός τυχόν αποκλίσεων. Ακόμη, οι βιομηχανικές μονάδες υφίστανται ζημιές λόγω της συνεχούς χρήσης και της κανονικής φθοράς. Οι ζημιές αυτές πρέπει να εντοπιστούν νωρίς για να αποφευχθούν η περαιτέρω απώλειες. Τα δεδομένα σε αυτόν τον τομέα συνήθως καταγράφονται με τη χρήση διαφορετικών αισθητήρων και συλλέγονται για ανάλυση. Επιπλέον, οι τεχνικές εντοπισμού ανωμαλιών ασχολούνται με την επεξεργασία εικόνας, όπως η ανίχνευση κίνησης ή ο εντοπισμός θέσης παρκαρίσματος, και επεξεργασίας κειμένων, για τον εντοπισμό κυρίως νέων θεμάτων ή ειδήσεων σε μια συλλογή εγγράφων ή άρθρων.

Για να επιτευχθούν εφαρμογές εντοπισμού, χρησιμοποιείται μια πληθώρα μεθόδων. Οι μέθοδοι που χρησιμοποιούνται συχνά είναι τα Νευρωνικά Δίκτυα (Neural Networks), Bayesian Networks, Support Vector Machine Methods, τεχνικές βασισμένες στο Nearest Neighbor ή στη Συσταδοποίηση (Clustering).

Η παρούσα διπλωματική στηρίχθηκε στη χρήση Νευρωνικών Δικτύων και στον αλγόριθμο εντοπισμού Seasonal Hybrid Extreme Studentized Deviate (S-H-ESD). Στο επόμενο υποκεφάλαιο 3.4 αναπτύσσεται η μεθοδολογία του αλγόριθμου για την κατανόηση του.

3.4. ΑΛΓΟΡΙΘΜΟΣ Seasonal Hybrid ESD

Η μέθοδος ανιχνεύει αυτόματα ανωμαλίες σε δεδομένα χρονολογικών σειρών. Ο αλγόριθμος Seasonal Hybrid ESD (S-H-ESD), βασίζεται στον γενικευμένο αλγόριθμο ESD (S-ESD), για την ανίχνευση ανωμαλιών. Αξίζει να σημειωθεί, ότι το S-H-ESD μπορεί να χρησιμοποιηθεί για την ανίχνευση τόσο γενικών (Global), όσο και τοπικών (Topic) ανωμαλιών (Vallis et al., 2017). Στο παρακάτω Διάγραμμα 3.11, φαίνεται μπλε κουκίδες οι ανωμαλίες, τοπικές και γενικές ανωμαλίες.



Διάγραμμα 3.5: Διάγραμμα με την παρουσία τοπικών και γενικών ανωμαλιών. (Πηγή: Vallis et al., 2017).

Ο Αλγόριθμος ESD (Extreme Studentized Deviate) μπορεί να χρησιμοποιηθεί για την ανίχνευση πολλαπλών ανωμαλιών σε χρονοσειρές. Στην πράξη, ο αριθμός των ανωμαλιών είναι συνήθως μικρότερος από 1% στο πλαίσιο της εφαρμογής, και λιγότερο από 5% στο πλαίσιο του συνόλου των δεδομένων. Το ESD υπολογίζει τα ακόλουθα στατιστικά στοιχεία (1) δοκιμών για τον αριθμό των ακραίων τιμών στο σύνολο δεδομένων. Και στη συνέχεια, συγκρίνει τα στατιστικά στοιχεία με μια κρίσιμη τιμή λ , η οποία υπολογίζεται χρησιμοποιώντας τη σχέση (2), με αποτέλεσμα να προσδιοριστεί αν μια τιμή είναι ανωμαλία. Το ESD επαναλαμβάνει αυτή τη διαδικασία k φορές, με k τον αριθμό των ανωμαλιών, για να θεωρηθεί μια τιμή ανωμαλία θα πρέπει $C_k > \lambda_k$.

$$C_k = \frac{\max x_k |x_k - \bar{x}|}{s} \quad (1)$$

$$\lambda_k = \frac{(n-k)t_{p,n-k-1}}{\sqrt{(n-k-1+t_{p,n-k-1}^2)(n-k+1)}} \quad (2)$$

Ο Γενικευμένος Αλγόριθμος Seasonal ESD (S-ESD) χρησιμοποιεί ένα τροποποιημένο μοντέλο STL αποσύνθεσης (STL Decomposition) για να εξάγει το υπολειπόμενο στοιχείο (residual) της χρονοσειράς και στη συνέχεια εφαρμόζει τον Αλγόριθμο ESD για την ανίχνευση ανωμαλιών. Αυτή η διαδικασία δύο βημάτων επιτρέπει στον S-ESD να ανιχνεύσει, γενικές ανωμαλίες (Global anomalies), που υπερβαίνουν το αναμενόμενες εποχιακές ελάχιστες και μέγιστες τιμές, και τοπικές ανωμαλίες (Topic anomalies), που διαφορετικά θα είχαν καλυφθεί από την εποχικότητα (Seasonality), μια έννοια που περιγράφεται στο υποκεφάλαιο 3.5.

Μια δεδομένη χρονολογική σειρά (X) αποσυντίθεται σε τρεις, την εποχικότητα (Seasonality) (S_X), τάση (Trend) (T_X) και υπολειμματικά στοιχεία (Residuals) (R_X). Ο αλγόριθμος πρώτα αποδίδει την τάση T_X χρησιμοποιώντας τη μέθοδο κινούμενου

μέσου όρου (4) και στη συνέχεια την αφαιρεί από το X , τη χρονοσειρά. Μόλις αφαιρεθεί η τάση, η εποχικότητα S_X υπολογίζεται ως ο μέσος όρος των σημείων εντός των υποκυκλίων. Μια σειρά υποκυκλίων περιλαμβάνει τιμές σε κάθε θέση εποχιακού κύκλου. Για παράδειγμα, αν η σειρά είναι μηνιαία με ετήσια περιοδικότητα, τότε ο πρώτος υπο-κύκλος σειρά είναι οι τιμές του Ιανουαρίου, η δεύτερη είναι οι τιμές του Φεβρουαρίου, και ούτω καθεξής (Cleveland et al., 1990). Τα υπολειμματικά στοιχεία R_X υπολογίζονται ως εξής : $R_X = X - T_X - S_X$ (5). Τα υπολειμματικά στοιχεία ενδέχεται να είναι δυνητικά αλλοιωμένα από ακραίες ανωμαλίες στα δεδομένα εισόδου. Το ζήτημα αυτό αντιμετωπίζεται από τον Αλγόριθμο LOESS. Ο αλγόριθμος αυτός αποτελείται από έναν εσωτερικό βρόχο, που παράγει την τάση, την εποχικότητα και τα υπολειμματικά στοιχεία και έναν εξωτερικό βρόχο, που αυξάνει την ευρωστία του αλγορίθμου σε σχέση με τις ανωμαλίες. Το STL χρησιμοποιεί το LOESS για να εξαχθεί η εποχικότητα, έτσι η αποσύνθεση της χρονοσειράς μπορεί να αντιμετωπίσει πιο περίπλοκες λειτουργίες από τις προσθετικές ή τις πολλαπλασιαστικές προσεγγίσεις. Επιπλέον, το STL επαναλαμβάνει τη διαδικασία αρκετές φορές, μέχρι η διαφορά στις επαναλήψεις είναι μικρότερη από κάποιο όριο. Το STL μπορεί να γίνει πιο ισχυρό έναντι της επίδρασης των ανωμαλιών, θέτοντας βάρη (3).

$$Weight = B \left(\frac{|R_X|}{6 \times median|R_X|} \right) \quad (4) \quad ,$$

$$\text{όπου} \quad B(u) = \begin{cases} (1 - u^2)^2, & \text{για } 0 \leq u \leq 1 \\ 0, & \text{για } u > 1 \end{cases} .$$

Η μέθοδος κινούμενου μέσου όρου, υπολογίζει το μέσο όρο για ένα διάστημα τιμών, με κέντρο την μια συγκεκριμένη τιμή και υπολογίζεται ο κινούμενος μέσος όρος της τιμής αυτής. Τα διαστήματα πρέπει να είναι σταθερά.

$$SMA = \frac{x_1 + x_{t-1} + \dots + x_{t-(n-1)}}{n} \quad (3)$$

Η εφαρμογή της STL αποσύνθεσης σε χρονολογικές σειρές, σε ορισμένες περιπτώσεις, κατέληγε σε ψευδείς ανωμαλίες, λόγω της τάσης (trend) των δεδομένων, για το λόγο αυτό η εξίσωση αποσύνθεσης (5) μετατρέπεται σε $R_X = X - S_X - \tilde{X}$, όπου το X η δεδομένη χρονολογική σειρά, το S_X η εποχικότητα και το $\tilde{X}$, η διάμεσος των τιμών της χρονοσειράς. Αντικαταστάθηκε η τάση με τη διάμεσο, για να εξαλειφθούν οι ψευδείς ανωμαλίες. Το S-ESD δεν μπορεί να εφαρμοστεί με επιτυχία, σε σύνολα δεδομένων που έχουν υψηλό ποσοστό ανωμαλιών. Στη συνέχεια, αναλύεται η βελτίωση του S-ESD. Η τυπική μορφή του αλγόριθμου Seasonal ESD (S-ESD) δίνεται, παρακάτω Εικόνα 3.1.

S-ESD Algorithm

Input:

X = A time series
 n = number of observations in X
 k = max anomalies (iterations in ESD)

Output:

X_A = An anomaly vector wherein each element is a tuple (*timestamp, observed value*)

Require:

$k \leq (n \times .49)$

1. Extract seasonal component S_X using STL Variant
2. Compute median $\tilde{X}$
/* Compute residual */
3. $R_X = X - S_X - \tilde{X}$
/* Detect anomalies vector X_A using ESD */
4. $X_A = \text{ESD}(R, k)$

return X_A

Εικόνα 3.1: Τυπική μορφή υπολογισμών αλγόριθμου S-ESD. (Πηγή: Vallis et al., 2017).

Το Seasonal Hybrid ESD (S-H-ESD) βασίζεται στον Γενικευμένο Αλγόριθμο S-ESD, για να αντιμετωπίσει το ζήτημα του αριθμού των ανωμαλιών. Το S-H-ESD χρησιμοποιεί τις στατιστικές τεχνικές Διαμέσου και Απόλυτης Απόκλισης Διαμέσου (Median and Median Absolute Deviation), για να καταστεί δυνατή μια πιο συνεκτική μέτρηση της κεντρικής τάσης μιας χρονοσειράς για υψηλό ποσοστό ανωμαλιών. Αντικαθιστώντας το μέσο όρο και τη τυπική απόκλιση που χρησιμοποιείται στην σχέση (1), δημιουργήθηκε μια πιο ισχυρή στατιστική μέθοδος με καλύτερη ακρίβεια για μεγάλο ποσοστό ανωμαλιών. Συγκεκριμένα, χρησιμοποιείται η διάμεσος και η απόλυτη απόκλιση της διαμέσου.

Διάμεσος (Median) και Απόλυτη Απόκλιση Διαμέσου (Median Absolute Deviation) (MAD).

Για ένα σύνολο δεδομένων $X_1, X_2, \dots, X_n$, η Απόλυτη Απόκλιση Διαμέσου (MAD) ορίζεται, ως η διάμεσος των απόλυτων τυπικών αποκλίσεων από το δείγμα των διαμέσων.

$$MAD = \text{median}_i(|X_i - \text{median}_j(X_j)|)$$

Σε αντίθεση με την τυπική απόκλιση, το MAD είναι ανθεκτικό στις ανωμαλίες στα δεδομένα εισόδου. Επιπλέον, το MAD μπορεί να χρησιμοποιηθεί για να υπολογιστεί η τυπική απόκλιση, κλιμακώνοντας το MAD κατά μια σταθερά b .

$\hat{\sigma} = b (MAD)$, όπου $b = 1,4826$, για κανονικά κατανομημένα δεδομένα (normal distribution) , ενώ για υποκείμενη κατανομή δεδομένων (underlying distribution)


$$b = \frac{1}{Q(0.75)} , \text{ με } Q(0.75) , \text{ η ποσότητα } 0,75 \text{ της υποκείμενης κατανομής.}$$

3.5. ΧΡΟΝΟΣΕΙΡΕΣ


Με τον όρο Χρονοσειρές εννοείται μια σειρά από παρατηρήσεις, που καταγράφονται σε ορισμένες χρονικές στιγμές ή περιόδους που ισαπέχουν μεταξύ τους. Συμβολίζοντας με X_i τις n χρονικές στιγμές (έτη, μήνες, μέρες κλπ.) και με Y_i τις τιμές των αντίστοιχων παρατηρήσεων, δημιουργούνται η ζεύγη της μορφής $M(X_i, Y_i)$, τα οποία μπορούν να παρατεθούν στο σύστημα αξόνων, ενώνοντας τα σημεία αυτά δημιουργείται το χρονοδιάγραμμα, η ανάλυση του οποίου δίνει μια γενική εικόνα της διαχρονικής εξέλιξης του υπό έρευνα φαινομένου ή χαρακτηριστικού.

Μια χρονοσειρά μπορεί να αναλυθεί σε τρεις συνιστώσες. Η πρώτη συνιστώσα είναι η τάση, ως συνάρτηση του χρόνου, η δεύτερη είναι η περιοδικότητα ή εποχικότητα, συνάρτηση της περιόδου των παρατηρήσεων, για παράδειγμα οι παρατηρήσεις επαναλαμβάνονται για K ίσα χρονικά διαστήματα. Τελευταία συνιστώσα, είναι χρονοσειρά των υπολοίπων σημείων, αυτά ενδέχεται να συσχετίζονται μεταξύ του ή όχι. Οι υπόλοιπες τιμές μπορεί να είναι «θόρυβος» στα δεδομένα ή ανωμαλίες. Για να υπάρχει μια επιτυχής αποσύνθεση, είναι σημαντικό να γίνει επιλογή μεταξύ του προσθετικού ή του πολλαπλασιαστικού μοντέλου. Στο προσθετικό μοντέλο, η χρονοσειρά αποδίδεται ως το άθροισμα της τάσης, της εποχικότητας και των υπολοίπων σημείων, ενώ στο πολλαπλασιαστικό μοντέλο, η χρονοσειρά αποδίδεται ως το γινόμενο των συνιστωσών της χρονοσειράς. Όταν η εποχική διακύμανση, εποχικότητα παρατηρείται σταθερή, δηλαδή δεν αλλάζει όταν αυξάνεται η χρονολογική σειρά, συνίσταται το προσθετικό μοντέλο. Για παράδειγμα, η ετήσια παραγωγή ενός προϊόντος, με ζήτηση όλο το χρόνο, πιθανό να παρουσιάσει σταθερή εποχικότητα. Αντίθετα, όταν οι χρονολογικές σειρές αυξάνουν όλο και περισσότερο τις εποχιακές διακυμάνσεις, τότε πρέπει να χρησιμοποιείται το πολλαπλασιαστικό μοντέλο. Οι διακυμάνσεις του αριθμού των επιβατών των αεροσκαφών ενδέχεται να απαιτήσουν την πολλαπλασιαστική προσέγγιση.

Για να γίνει κατανοητή η αποσύνθεση μιας χρονοσειράς θα χρησιμοποιηθεί το παρακάτω παράδειγμα. Στα χρονοδιαγράμματα, το Διάγραμμα 3.6 εκφράζει την ετήσια παραγωγή μπίρας στην Αυστραλία, και το Διάγραμμα 3.7 τις επιβατικές κινήσεις με αεροσκάφη.




Διάγραμμα: 3.6: Ετήσια παραγωγή μπίρας στην Αυστραλία. (Πηγή: AnOmalio.io).




Διάγραμμα 3.7: Ετήσια επιβατική κίνηση με αεροσκάφη. (Πηγή: AnOmalY.io).

Είναι προφανές από όσα προαναφέρθηκαν ότι η παραγωγή μπίρας απαιτεί το προσθετικό μοντέλο, ενώ η κίνηση των επιβατών το πολλαπλασιαστικό μοντέλο.

Μια καλή τακτική για να εντοπισθεί η τάση της χρονοσειράς (Trend), είναι ο κινούμενος μέσος όρος, όπου για σταθερά διαστήματα υπολογίζεται ο μέσος όρος των τιμών εντός του διαστήματος. Στο παράδειγμα, για την ετήσια παραγωγή μπίρας το Διάγραμμα 3.8, όπου φαίνεται η τάση με συνεχή γραμμή, και, αντίστοιχα, το Διάγραμμα 3.9 για την επιβατική κίνηση.



Διάγραμμα 3.8: Ετήσια παραγωγή μπίρας στην Αυστραλία μαζί με την Τάση. (Πηγή: AnOmalY.io).




Διάγραμμα 3.9: Ετήσια επιβατική κίνηση με αεροσκάφη μαζί με την Τάση. (Πηγή: AnOmalY.io).


Στη συνέχεια, σκοπός είναι να εντοπισθεί η εποχικότητα ή περιοδικότητα (Seasonality). Για να επιτευχθεί αυτό θα πρέπει να αφαιρεθεί η τάση από τα δεδομένα, και για την περίοδο των δεδομένων, δηλαδή για πόσα διαστήματα επαναλαμβάνονται οι τιμές, να εντοπισθεί η εποχικότητα.

Ο εντοπισμός της περιόδου απαιτεί μια ιδιαίτερη προσοχή. Πολλές φορές είναι γνωστή η τιμή από τα δεδομένα. Η περίοδος (T) είναι ο αριθμός των χρονικών περιόδων που απαιτούνται για την ολοκλήρωση ενός μόνο κύκλου της συνάφειας και η συχνότητα είναι $\omega = 1 / T$, δηλαδή το κλάσμα του πλήρους κύκλου που ολοκληρώνεται σε μια μόνο χρονική περίοδο. Για παράδειγμα, εάν τα δεδομένα είναι μηνιαία σε ετήσια βάση, τότε η συχνότητα είναι 12 .

Στο παράδειγμά, η εποχιακή περιοδικότητα της ετήσιας παραγωγής είναι για εποχιακά δεδομένα και η συχνότητα είναι 4, ενώ για τις επιβατικές κινήσεις, τα δεδομένα είναι μηνιαία άρα η συχνότητα 12. Στο διάγραμμα 3.10 παρουσιάζεται η περιοδικότητα της παραγωγής, ενώ στο Διάγραμμα 3.11 της επιβατικής κίνησης.



Διάγραμμα 3.10: Περιοδικότητα ετήσιας παραγωγής μπίρας στην Αυστραλία. (Πηγή: AnOmalY.io).



Διάγραμμα 3.11: Περιοδικότητα ετήσιας επιβατικής κίνησης με αεροσκάφη. (Πηγή: AnOmalY.io).

Καταλήγοντας στο παράδειγμα, για να εντοπιστούν οι υπόλοιπες τιμές στην περίπτωση της παραγωγής, όπου εφαρμόζεται η προσθετική μέθοδος,

$$\text{ΧΡΟΝΟΣΕΙΡΑ} = \text{ΤΑΣΗ} + \text{ΕΠΟΧΗΚΟΤΗΤΑ} + \text{ΥΠΟΛΟΙΠΕΣ ΤΙΜΕΣ} .$$

Αντίθετα, για την πολλαπλασιαστική προσέγγιση, ετήσιες επιβατικές κινήσεις με αεροσκάφη, ισχύει

$$\text{ΧΡΟΝΟΣΕΙΡΑ} = \text{ΤΑΣΗ} * \text{ΕΠΟΧΗΚΟΤΗΤΑ} * \text{ΥΠΟΛΟΙΠΕΣ ΤΙΜΕΣ} .$$

3.5.1. ΠΕΡΙΟΔΙΚΟΤΗΤΑ

Ένα ζήτημα, που χρειάστηκε να αντιμετωπισθεί στην παρούσα εργασία, είναι λόγω ότι τα δεδομένα, προέρχονται από το smartphone σε πραγματικό χρόνο είτε online, είτε offline, και σε μη καθορισμένα χρονικά διαστήματα, έχουν πολύ «θόρυβο» (Noisy Data). Γεγονός, που καθιστά δύσκολο τον εντοπισμό της περιοδικότητας. Για το λόγο αυτό, θα γίνει μια αναφορά στο περιοδόγραμμα, που βοήθησε στην αντιμετώπιση του προβλήματος για την καλύτερη δυνατή εκτίμηση της συχνότητας. Για την κατανόηση, χρησιμοποιήθηκε τα ηλεκτρονικά μαθήματα του Eberly College of Science.

Οι χρονοσειρές αντιμετωπίζονται σαν ένα σύνολο κυμάτων συνημίτονου με μεταβαλλόμενα πλάτη και συχνότητες. Ένας στόχος μιας ανάλυσης με περιοδόγραμμα είναι να προσδιοριστούν οι σημαντικές συχνότητες (ή περίοδοι) στις παρατηρήσεις. Ένα περιοδόγραμμα χρησιμοποιείται για τον προσδιορισμό των κυρίαρχων περιόδων (ή συχνοτήτων) μιας χρονοσειράς. Αυτό μπορεί να είναι ένα χρήσιμο εργαλείο για τον εντοπισμό κυρίαρχης κυκλικής συμπεριφοράς σε μια χρονοσειρά, ιδιαίτερα όταν οι κύκλοι δεν σχετίζονται με τη συχνότητα για παράδειγμα η μηνιαία ή εβδομαδιαία εποχικότητα. Η εκτίμηση του περιοδογράμματος αποτελεί μία διαδικασία εύρεσης του Μετασχηματισμού Fourier (Fourier Transform) (1) για τις παρατηρήσεις.


Θεωρείται το σύνολο των πιθανών συχνοτήτων $\omega_j = j / n$ για $j = 1, 2, \dots, n / 2$. Αυτές ονομάζονται αρμονικές συχνότητες. Στη συνέχεια, θα εκπροσωπηθούν οι παρατηρήσεις της χρονοσειράς ως ,

$$x_t = \sum_{j=1}^{n/2} \left[\beta_1 \left(\frac{j}{n} \right) \cos(2\pi\omega_j t) + \beta_2 \left(\frac{j}{n} \right) \sin(2\pi\omega_j t) \right] \quad (1)$$

Ας υποθεθούν οι $\beta_1(j/n)$ και $\beta_2(j/n)$, ως παράμετροι παλινδρόμησης. Το πρώτο βήμα στη δημιουργία του περιοδογράμματος, είναι η εκτίμηση των παραμέτρων $\beta_1(j/n)$ και $\beta_2(j/n)$. Στην πραγματικότητα δεν είναι απαραίτητο να πραγματοποιηθεί αυτή η παλινδρόμηση για να εκτιμηθούν οι παράμετροι $\beta_1(j/n)$ και $\beta_2(j/n)$, επομένως χρησιμοποιείται μια μαθηματική σχέση (2), για τις παραμέτρους του Μετασχηματισμού Fourier (FFT) (1).

$$\text{Ορίζεται, λοιπόν } P \left(\frac{j}{n} \right) = \hat{\beta}_1^2 \left(\frac{j}{n} \right) + \hat{\beta}_2^2 \left(\frac{j}{n} \right) \quad (2)$$

Αυτή είναι η τιμή του αθροίσματος των τετραγωνικών συντελεστών «παλινδρόμησης» στη συχνότητα j/n . Συνεπώς, το περιοδόγραμμα είναι ένα γράφημα του $P(j/n)$, για j/n από $j = 1, 2, \dots, n/2$.



Διάγραμμα 3.12: Περιοδόγραμμα (Πηγή: Eberly College of Science).

3.6. ΜΕΘΟΔΟΙ ΥΠΟΛΟΓΙΣΜΟΥ ΜΕΤΡΙΚΗΣ ΑΠΟΣΤΑΣΗΣ

Η χρήση της απόστασης είναι μια ευρέως χρησιμοποιούμενη μεθοδολογία, για τον εντοπισμό σημείων, που δεν ταιριάζουν με τον γενικό χαρακτήρα του συνόλου δεδομένων. Τα σημεία αυτά ονομάζονται ακραίες παρατηρήσεις (outliers), δηλαδή τιμές που βρίσκονται εκτός του «κανονικού» εύρους. Η εύρεση των outliers είναι πολύ σημαντική στην διαχείριση των δεδομένων, συχνά αποτελούν στόχο αναζήτησης, για να χαρακτηρίσουν ένα γεγονός, άλλες φορές εντοπίζονται για να αφαιρεθούν στο πλαίσιο της κανονικοποίησης και της πρόβλεψης των δεδομένων (forecast).

Τα δεδομένα αποτελούνται από παρατηρήσεις. Οι παρατηρήσεις θεωρούνται ως σημεία σε έναν πολυδιάστατο χώρο. Συνήθως, σε μια βάση δεδομένων, εκτός από τα αριθμητικά πεδία, υπάρχουν και δυαδικά, ονομαστικά και διατακτικά πεδία. Ακόμη, ο υπολογισμός της απόστασης ορίζεται για περιπτώσεις, όπου οι παρατηρήσεις περιλαμβάνουν διαφορετικά γνωρίσματα, δηλαδή αριθμητικά, ονομαστικά κτλ.. Στην παρούσα εργασία θα απασχολήσουν τα αριθμητικά δεδομένα.

Υπάρχουν αρκετές μέθοδοι υπολογισμού της απόστασης, οι επικρατέστερες είναι η Ευκλείδεια απόσταση, Μέση Ευκλείδεια απόσταση, η Τετραγωνική Ευκλείδεια απόσταση, η Απόσταση Manhattan, η Απόσταση των Bray-Curtis, η Συντελεστής Canberra, η Απόσταση του Chebyshev, η Απόσταση του Minkowski, η Απόσταση του Pearson, η Εκθετική απόσταση, η απόσταση Hellinger και η απόσταση Mahalanobis.

Ενδεικτικά θα παρουσιαστούν κάποιες από τις μεθόδους υπολογισμού απόστασης. Στην απλή περίπτωση, όπου οι παρατηρήσεις αποτελούνται από δύο μόνο γνωρίσματα X και Y . Κάθε παρατήρηση μπορεί να αναπαρασταθεί στον διδιάστατο χώρο X, Y ως ένα σημείο. Έστω δύο σημεία X_a και X_b , στο διδιάστατο χώρο και η μεταξύ τους απόσταση $d(X_a, X_b)$, τότε η Ευκλείδεια απόσταση δίνεται από την παρακάτω σχέση (1):

$$d(X_a, X_b) = \sqrt{\sum_{j=1}^n (X_{aj} - X_{bj})^2} \quad (1)$$

Η απόσταση Manhattan (City-block) ορίζεται από τη σχέση (2).

$$d(X_a, X_b) = \sum_{j=1}^n |X_{aj} - X_{bj}| \quad (2)$$

Αξίζει να επισημανθεί ότι, η απόσταση του Minkowski (3), αποτελεί γενίκευση της Ευκλείδειας απόστασης και της απόστασης Manhattan, όπου για $q=1$ η απόσταση του Minkowski ταυτίζεται με την απόσταση Manhattan, ενώ για $q=2$ με την Ευκλείδεια απόσταση.

$$d(X_a, X_b) = \sqrt[q]{\sum_{j=1}^n |X_{aj} - X_{bj}|^q} \quad (3)$$

Στην παρούσα εργασία θα χρησιμοποιηθεί η απόσταση Mahalanobis, που δίνεται από την σχέση (4). Η απόσταση Mahalanobis μετρά την απόσταση σε σχέση με το κεντροειδές. Το κεντροειδές είναι ένα σημείο στον πολυπαραγοντικό χώρο, όπου όλες οι μέσες τιμές από όλες τις μεταβλητές τέμνονται. Όσο μεγαλύτερη είναι η απόσταση, τόσο πιο μακριά από το κέντρο είναι το σημείο. Το πρόβλημα της ύπαρξης γραμμικής συσχέτισης μεταξύ των γνωρισμάτων, η οποία μπορεί να προκαλέσει στρεβλώσεις στον υπολογισμό της απόστασης, μπορεί να μετριάσει με την απόσταση Mahalanobis, αφού λαμβάνει υπόψη τις συσχετίσεις μεταξύ των γνωρισμάτων και δεν επηρεάζεται από την κλίμακα μέτρησης των μεταβλητών.

$$d(X_a, X_b) = (X_a - X_b)^T S^{-1} (X_a - X_b) \quad (4) ,$$

όπου S , ο πίνακας συνδιασποράς.

3.7. ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Ένας τυπικός εγκέφαλος περιέχει περίπου 100 δισεκατομμύρια μικροσκοπικά κύτταρα, που ονομάζονται νευρώνες. Ο νευρώνας είναι ένα ηλεκτρικά διεγερτικό κύτταρο που λαμβάνει, επεξεργάζεται και μεταδίδει πληροφορίες μέσω ηλεκτρικών και χημικών σημάτων (Wikipedia). Η βασική ιδέα για την δημιουργία νευρωνικών δικτύων, είναι να προσομοιώνουν πολλά πυκνά διασυνδεδεμένα εγκεφαλικά κύτταρα μέσα σε έναν υπολογιστή, ώστε να υπάρχει η δυνατότητα να εκπαιδεύονται, να μαθαίνουν, να αναγνωρίζουν πρότυπα και να λαμβάνουν αποφάσεις, όπως ο ανθρώπινος εγκέφαλος.

3.7.1. ΔΟΜΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Τα νευρωνικά δίκτυα (Neural Network) αποτελούνται κυρίως από τρία επίπεδα, το επίπεδο εισόδου, το επίπεδο εξόδου και τα ενδιάμεσα επίπεδα, όπου διαφορετικά ονομάζονται και κορμός νευρωνικού δικτύου ή κρυμμένα επίπεδα. Το πρώτο επίπεδο είναι το επίπεδο εισόδου (input layer). Το επίπεδο εισόδου επικοινωνεί με το εξωτερικό περιβάλλον και δέχεται τα δεδομένα που θα εισαχθούν και θα εκπαιδευτεί το νευρωνικό δίκτυο. Ασχολείται μόνο με τα εισηγμένα δεδομένα, τα οποία και μεταφέρει στα κρυμμένα στρώματα. Κάθε νευρώνας εισόδου πρέπει να αντιπροσωπεύει κάποια ανεξάρτητη μεταβλητή, που επηρεάζει τα εξαγόμενα δεδομένα του νευρικού δικτύου, δηλαδή σε κάθε επίπεδο ενός νευρωνικού δικτύου, οι νευρώνες δεν συνδέονται μεταξύ τους παραμόνο με τους νευρώνες των γειτονικών επιπέδων. Το δεύτερο στάδιο των νευρικών δικτύων αποτελούν, τα κρυμμένα επίπεδα (hidden layer). Είναι ενδιάμεσα επίπεδα, που βρίσκονται ανάμεσα στο επίπεδο εισόδου και το επίπεδο εξόδου, και επεξεργάζονται τα δεδομένα από το επίπεδο εισόδου. Τα κρυμμένα/κρυφά επίπεδα είναι υπεύθυνα την εξαγωγή των απαιτούμενων χαρακτηριστικών στα δεδομένα εξόδου, αποτελέσματα. Σε ένα νευρωνικό δίκτυο μπορεί να υπάρχουν πολλά κρυμμένα επίπεδα, σε αντίθεση με τα επίπεδα εισόδου και εξόδου, που είναι ένα επίπεδο, αντίστοιχα. Τελευταίο επίπεδο είναι το επίπεδο εξόδου, το οποίο συλλέγει τις πληροφορίες, που έχουν προκύψει από τα κρυμμένα επίπεδα και τις μεταδίδει στο εξωτερικό περιβάλλον για να αξιολογηθούν ως αποτελέσματα.


Το νευρωνικό δίκτυο αποτελείται από συνδέσεις, μεταξύ των επιπέδων του. Κάθε σύνδεση μεταφέρει την πληροφορία από την έξοδο ενός νευρώνα στην είσοδο των νευρώνων του επόμενου επιπέδου και σε κάθε σύνδεση έχει εκχωρηθεί ένα βάρος. Ακόμη, κάθε νευρώνας αποτελεί ένα κόμβο συλλογής πληροφοριών. Η λειτουργία ενεργοποίησης ενός κόμβου καθορίζει την έξοδο του κόμβου για δεδομένη είσοδο ή σύνολο εισόδων, δηλαδή από περισσότερους νευρώνες. Η λειτουργία ονομάζεται και λειτουργία μεταφοράς. Κάθε λειτουργία ενεργοποίησης παίρνει έναν μόνο αριθμό και εκτελεί μια συγκεκριμένη σταθερή μαθηματική. Η διαδικασία λειτουργίας ενός μοντέλου νευρωνικού δικτύου θα επεξηγηθεί αναλυτικότερα με τη χρήση παραδείγματος παρακάτω.

Είναι συνετό να εκτιμηθεί ο αριθμός για τα κρυμμένα επίπεδα που χρειάζονται να χρησιμοποιηθούν, για το εκάστοτε πρόβλημα. Η πιο απλή και παλιά μορφή μοντέλου νευρωνικού δικτύου είναι το Perceptron, όπου τα δεδομένα εισόδου μπορούν να χωριστούν γραμμικά, επομένως δεν χρειάζεται να χρησιμοποιηθούν κρυφά επίπεδα. Η λειτουργία ενεργοποίησης μπορεί να εφαρμοστεί στο στρώμα εισόδου και να λύσει το πρόβλημα.


Σε άλλες περιπτώσεις προβλημάτων, τα οποία αφορούν πιο σύνθετες αποφάσεις, είναι δυνατό να χρησιμοποιηθούν περισσότερα κρυμμένα επίπεδα, ανάλογα με το βαθμό πολυπλοκότητας του προβλήματος ή τον βαθμό ακρίβειας, που απαιτείται. Βέβαια, δεν σημαίνει ότι αν αυξάνεται συνεχώς ο αριθμός των κρυφών επιπέδων, το νευρωνικό δίκτυο θα αποδίδει με μεγαλύτερη ακρίβεια. Όσο αυξάνεται ο αριθμός των κρυφών επιπέδων, η ακρίβεια, μετά από ένα σημείο γίνεται σταθερή ή πέφτει, αν προστεθεί ένα επιπλέον. Ιδιαίτερη σημασία έχει και ο αριθμός των νευρώνων, ο οποίος πρέπει να είναι μεγαλύτερος σε σύγκριση με την πολυπλοκότητα του προβλήματος, επειδή ενδέχεται

εάν υπάρχουν πολύ λίγοι νευρώνες στα κρυμμένα επίπεδα, να μην μπορούν να ανιχνεύσουν επαρκώς οι πληροφορίες, σε ένα περίπλοκο σύνολο δεδομένων.

Είναι ανάγκη να γίνει αντιληπτή λειτουργία ενός Νευρωνικού Δικτύου, για το λόγο αυτό θα περιγραφεί πιο αναλυτικά. Αρχικά, η λειτουργία του απλού νευρωνικού δικτύου Perceptron θα βοηθήσει να γίνουν αντιληπτά ευκολότερα, τα συστήματα με μεγαλύτερη πολυπλοκότητα, όπως πολλά κρυφά επίπεδα με πολλούς νευρώνες. Εισάγοντας, ως πληροφορίες, αρκετές εισόδους, $x_1, x_2, \dots, x_n$, παράγεται μία μόνο έξοδος. Για παράδειγμα, εισάγοντας τρεις πληροφορίες εισόδου (input) x_1, x_2, x_3 και τα βάρη (weights), πραγματικούς αριθμούς που εκφράζουν τη σημασία των συνθηκών των αντίστοιχων εισροών, $w_1, w_2, \dots$. Το αποτέλεσμα εξόδου προκύπτει από το άθροισμα $\sum_j w_j x_j$, αν είναι μικρότερο ή μεγαλύτερο από κάποια σταθερή κατώτατη τιμή (threshold), σε 0 ή 1. Σε αυτή την απλή δομή (Εικόνα 3.2) βασίζονται και τα πιο πολύπλοκα μοντέλα νευρωνικών δικτύων, όπως στο σχήμα (Εικόνα 3.3).



Εικόνα 3.2: Τυπική μορφή απλού νευρώνα. (Πηγή: Neural Networks and Deep Learning).




Εικόνα 3.3: Τυπική μορφή δικτύου με πολλαπλούς νευρώνες. (Πηγή: Neural Networks and Deep Learning).

Ένα μοντέλο νευρωνικού δικτύου με αυξημένη πολυπλοκότητα, έχει σκοπό να εξάγει ακριβέστερα αποτελέσματα, αν είναι δυνατό μέσω της διαδικασίας αυτής. Όπως φαίνεται στην Εικόνα 3.3, το δίκτυο χωρίζεται σε τρεις αποφάσεις, σύμφωνα με τα δεδομένα εισόδου, και αυτοί οι νευρώνες αποτελούν το πρώτο επίπεδο. Στη συνέχεια, σταθμίζοντας τα αποτελέσματα από το πρώτο επίπεδο, το δίκτυο καλείται να πάρει τέσσερις αποφάσεις, από τους νευρώνες του δεύτερου επιπέδου. Και καταλήγοντας, τα δεδομένα από το δεύτερο επίπεδο θα οδηγηθούν στο επίπεδο εξόδου, όπου θα εξαχθούν τα αποτελέσματα. Απλοποιώντας το τρόπο λειτουργίας του απλού νευρώνα Perceptron, θέτοντας το άθροισμα $\sum_j w_j x_j$ ίσο με το εσωτερικό γινόμενο των διανυσμάτων w^*x και, ακόμη, ως b (bias) προκατάληψη, τη σταθερή κατώτατη τιμή (threshold), τότε το αποτέλεσμα εξαρτάται από το γινόμενο w^*x και την προκατάληψη b , και αν η τιμή


αυτή είναι μεγαλύτερη ή μικρότερη του 0 ($w \cdot x + b$). Η αλλαγή αυτή θα διευκολύνει στη συνέχεια να κατανοηθούν οι διάφοροι τρόποι επιλογής αποφάσεων ή λειτουργία ενεργοποίησης (μεταφοράς). Στο πλαίσιο της εκπαίδευσης νευρωνικών δικτύων, που θα αναλυθεί στο επόμενο υποκεφάλαιο 3.7.2, είναι επιθυμητό το δίκτυο να εκπαιδευτεί να μαθαίνει τα βάρη και τις προκαταλήψεις, ώστε να εντοπίζει με ακρίβεια τα αποτελέσματα. Για παράδειγμα, αν το δίκτυο εντοπίσει λάθος ένα αποτέλεσμα, θα μπορούσε επιστρέφοντας και κάνοντας μικρές αλλαγές στα βάρη και τις προκαταλήψεις, να το διορθώσει. Αντίθετα, αλλαγές στις τιμές των βαρών ή των προκαταλήψεων, οποιουδήποτε νευρώνα στο δίκτυο, ενδέχεται διορθώνοντας ένα αποτέλεσμα να αλλάζει τα υπόλοιπα και αυτή η διαδικασία να συνεχίζεται. Καθίσταται, λοιπόν, δύσκολος ο εντοπισμός των σωστών τιμών για τις προκαταλήψεις και τα βάρη. Για την αντιμετώπιση αυτού του προβλήματος, χρησιμοποιείται η λειτουργία ενεργοποίησης ή μεταφοράς, όπου οι μικρές αλλαγές προκαλούν μόνο μικρή αλλαγή στις πληροφορίες εξόδου από τον εκάστοτε νευρώνα. Συνήθεις συναρτήσεις, για τη λειτουργία ενεργοποίησης είναι Sigmoid, Tanh, ReLU και Maxout.

- Η σιγμοειδής συνάρτηση(Sigmoid) , έχει τη μαθηματική σχέση $\sigma(z) = 1 / (1 + e^{-z})$, όπου $z = w \cdot x + b$. Δέχεται πραγματικές τιμές και τις μοιράζει σε 0 και 1.




Εικόνα 3.4: Μορφή συνάρτησης Sigmoid. (Πηγή: Online Courses Stanford 231n).

- Η Tanh, μοιράζει τα αποτελέσματα σε εύρος από -1 έως 1 και η χρήση της προτιμάται σε σχέση με τη σιγμοειδής. Ο μαθηματικός της τύπος είναι $\tanh(z) = 2\sigma(2z) - 1$, όπου $z = w \cdot x + b$ και $\sigma(z) = 1 / (1 + e^{-z})$.



Εικόνα 3.5: Μορφή συνάρτησης Tanh. (Πηγή: Online Courses Stanford 231n).


- Η ReLU(The Rectified Linear Unit) , το αποτέλεσμα υπολογίζεται από τη συνάρτηση $f(z) = \max(0, z)$, $z = w * x + b$, δηλαδή η ενεργοποίηση της εξαρτάται από το 0.



Εικόνα 3.6: Μορφή συνάρτησης ReLU. (Πηγή: Online Courses Stanford 231n).


- Τέλος η Maxout , μια μέθοδος , που γενικεύει την ReLU και ο τύπος της συνάρτησης είναι $f(z) = \max(w_1^T * x + b_1, w_2^T * x + b_2)$.

Υπάρχουν πολλές κατηγορίες Νευρωνικών Δικτύων, οι δύο πιο βασικές είναι τα τροφοδοτικά νευρωνικά δίκτυα (Feedforward Neural Network) (Εικόνα 3.7), και οι υποκατηγορίες τους, και τα επαναλαμβανόμενα νευρωνικά δίκτυα (Recurrent Neural Network –RNN) (Εικόνα 3.8), και η δομή τους φαίνεται στο σχήμα αντίστοιχα.



Εικόνα 3.7: Τροφοδοτικό Νευρωνικό Δίκτυο. / Εικόνα 3.8: Επαναλαμβανόμενο Νευρωνικό Δίκτυο. (Πηγή: Towards Data Science).

Τα τροφοδοτικά νευρωνικά δίκτυα είναι τεχνητά νευρωνικά δίκτυα, όπου οι πληροφορίες, κινούνται προς μια κατεύθυνση, από τους νευρώνες εισόδου, στο επίπεδο εισόδου, μέσω των νευρώνων στα κρυφά επίπεδα, στους νευρώνες στο επίπεδο εξόδου, δηλαδή δεν σχηματίζουν βρόγχους στο δίκτυο. Το Perceptron είναι το πιο από μοντέλο τροφοδοτικού νευρωνικού δικτύου. Ένα νευρωνικό δίκτυο μπορεί να διαθέτει και με περισσότερα κρυφά επίπεδα, αυτά ονομάζονται πολυεπίπεδα Perceptron (Multilayer Perceptron–MLP). Ακόμη, υπάρχουν και τα συνελκτικά νευρωνικά δίκτυα (Convolutional Neural Network–CNN), τα οποία είναι παρόμοια με τα συνηθισμένα νευρωνικά δίκτυα. Κυρίως χρησιμοποιούνται σε εφαρμογές για αναγνώριση εικόνων ή βίντεο και σε συστήματα γλωσσικής επεξεργασίας, ενδεικτικά η μορφή λειτουργίας τους στην Εικόνα 3.9.



Εικόνα 3.9: Συνελικτικό Νευρωνικό Δίκτυο.

Στα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN), οι συνδέσεις μεταξύ των νευρώνων σχηματίζουν βρόγχους, δηλαδή οι πληροφορίες δε μεταδίδονται μόνο από τα προηγούμενα επίπεδα στα επόμενα, αλλά έχουν τη δυνατότητα οι πληροφορίες να μεταφέρονται και από τα μεταγενέστερα στα προηγούμενα. Τα επαναλαμβανόμενα νευρωνικά δίκτυα έχουν συχνές εφαρμογές στην αναγνώριση μη κατεργασμένου χειρόγραφου και στην αναγνώριση ομιλίας.

3.7.2. ΕΚΠΑΙΔΕΥΣΗ ΚΑΙ ΕΚΤΙΜΗΣΗ ΥΠΕΡΠΑΡΑΜΕΤΡΩΝ


Η εκπαίδευση των νευρωνικών δικτύων είναι πολύ σημαντικό και ιδιαίτερο κομμάτι για την εφαρμογή τους, χαρακτηριστικά στη βιβλιογραφία αναφέρεται ότι εκπαίδευση των δικτύων είναι μια δύσκολη διαδικασία, λόγω της αλληλεξαρτήσεως των νευρώνων, και ακόμη δεν είναι γνωστό ότι θα έχει σίγουρα αποτελέσματα. Για το λόγο αυτό ακολουθείται συχνά η παρακάτω τακτική. Αρχικά πρέπει να ορισθεί ένα κόστος, ως σημείο αναφοράς για τον εντοπισμό του βέλτιστου μοντέλου. Μια Συνάρτηση Κόστους (Cost Function) είναι η Μέθοδος των ελαχίστων τετραγώνων, με μαθηματικό τύπο (1), η οποία είναι γνωστή ως Συνάρτηση Απώλειας (Loss Function). Αξίζει να σημειωθεί ότι σύμφωνα με το CS231n, σημειώσεις μαθήματος από το πανεπιστήμιο του Sandford, στη πράξη πιο αποδοτική συνάρτηση κόστους, η (2α). Στη συνάρτηση κόστους (2α) , το w (βάρη) και b (προκαταλήψεις), υποδηλώνουν το συνολικό αριθμό των w , b και το $f(w,b)$ το αποτέλεσμα που εξάγεται, συναρτήσει των w , b . Μια ακόμα, συνάρτηση κόστους θεωρείται και η Cross Entropy, με μαθηματική σχέση (2β).

$$C(w, b) = \frac{1}{n} \sum (y_i - f(w, b))^2 \quad (1)$$

$$C(w, b) = \frac{1}{2n} \sum || y_i - f(w, b) ||^2 \quad (2\alpha)$$

$$C(w, b) = \frac{1}{n} \sum [y_i * \ln[f(w, b)] + (1 - y_i) * \ln[1 - f(w, b)]] \quad (2\beta)$$

Για εντοπιστούν, οι τιμές που αναζητούνται, ώστε να ελαχιστοποιείται η Συνάρτηση Κόστους χρησιμοποιείται ο αλγόριθμος Απότομης Καθόδου, γνωστός και ως αλγόριθμος σύγκλισης με ελάττωση της παραγώγου (The gradient descent method). Η διαδικασία περιγράφεται, ως εξής, θέτοντας αρχικές παραμέτρους, συγκεκριμένα για τα βάρη και τις προκαταλήψεις, στη συνέχεια εντοπίζεται με μικρά βήματα προς ποια κατεύθυνση μειώνεται το κόστος, για την κατανόηση αυτής της λειτουργίας βοηθάει η παρακάτω Εικόνα 3.10, με το κόστος και τις δύο παραμέτρους. Η διαδικασία αυτή συνεχίζεται, μέχρις ότου τα αποτελέσματα να θεωρηθούν ικανοποιητικά.



Εικόνα 3.10: Συνάρτηση Κόστους για δυο παραμέτρους. (Πηγή: ml4a.GitHub.io).

Για βρεθεί η κατεύθυνση, που η συνάρτηση κόστους μειώνεται, υπολογίζεται η κλίση. Η κλίση υπολογίζεται μέσω της παραγώγου, σχέση (3).

$$\Delta C(w, b) = \frac{\partial C}{\partial f(w, b)} = \frac{\partial C(w, b)}{\partial w} \Delta w + \frac{\partial C(w, b)}{\partial b} \Delta b \quad (3)$$

Στην περίπτωση, που υπάρχουν περισσότερες διαστάσεις, τότε το σύνολο των $f(w, b)$, που προκύπτει συναρτήσεων των w και b , τότε η (3) παίρνει τη μορφή (4).

$$\Delta C = \nabla C \cdot \Delta f(w, b) \quad (4) ,$$

$$\text{όπου } \nabla C(w, b) = \left(\frac{\partial C}{\partial f_1(w, b)}, \frac{\partial C}{\partial f_2(w, b)}, \dots, \frac{\partial C}{\partial f_k(w, b)} \right) \quad (5)$$

$$\text{και } \Delta f(w, b) = -a \nabla C \quad (6)$$

Στη σχέση (5) ορίστηκε, το a , ο ρυθμός εκμάθησης. Ο ρυθμός εκμάθησης (learning rate) είναι μια παράμετρος, που προστέθηκε για να καθορίσει πόσο θα είναι τα «βήματα», για να εντοπισθούν τα b, w , που ελαχιστοποιούν τη συνάρτηση κόστους. Οι παράμετροι ενός νευρωνικού δικτύου, συχνά καλούνται υπερπαραμέτροι (hyperparameters). Ο ρυθμός μάθησης a , είναι μια ευαίσθητη υπερπαραμέτρος, που πρέπει να αποφασισθεί από τον ερευνητή. Για μια πολύ χαμηλή τιμή του a , ο χρόνος

για να φθάσει η συνάρτηση κόστους στο κατώτατο σημείο είναι απαράδεκτα μεγάλος, αντίθετα μια υπερβολικά υψηλή τιμή του a , τα βήματα είναι μεγάλα με κίνδυνο να υπερβεί η σωστή διαδρομή, που ελαχιστοποιεί το κόστος.

Άρα, από (5) και (6) προκύπτει η σχέση (7).

$$\Delta C = -a \nabla C \cdot \nabla C \quad (7) ,$$


$$\text{όπου } f(w, b) := f'(w, b) = f(w, b) - a \nabla C$$

Ακόμη, για τη διόρθωση, προκύπτουν και οι σχέσεις (6) και (7), για τις παραμέτρους τα βάρη και οι προκαταλήψεις, αντίστοιχα.

$$w := w' = w - a \nabla C \quad (8)$$

$$b := b' = b - a \nabla C \quad (9)$$


Η παραπάνω προσέγγιση, είναι αποτελεσματική στην περίπτωση, που η συνάρτηση κόστους είναι σχεδόν γραμμική. Λόγω της πολυπλοκότητας των νευρωνικών δικτύων πρέπει να αντιμετωπιστεί ακόμα, το πρόβλημα της κυρτότητας (The problem of convexity). Λόγω της μη γραμμικότητας που εισάγουν οι λειτουργίες ενεργοποίησης, η μορφή της συνάρτησης κόστους του νευρωνικού δικτύου αποτελείται από πολλούς «λόφους» και «κοιλιάδες» (Εικόνα 3.11), δηλαδή, υπάρχουν πολλά τοπικά ελάχιστα και μέγιστα. Αυτό σημαίνει ότι η διαδικασία εκπαίδευσης ενδέχεται να «κολλήσει» σε κάποιο τοπικό ελάχιστο.



Εικόνα 3.11: Τρισδιάστατη Συνάρτηση Κόστους για δυο παραμέτρους με «λόφους» και «κοιλιάδες». (Πηγή: ml4a.GitHub.io).

Ένα ακόμη πρόβλημα είναι ότι η μέθοδος εντοπισμού της διαδρομής, που ελαχιστοποιείται το κόστος (gradient descent), είναι πολύ αργή. Ένα νευρωνικό δίκτυο μπορεί να έχει πάρα πολλούς παραμέτρους αυτό σημαίνει ότι απαιτούνται πάρα πολλές

εργασίες για την εκτίμησή τους. Για να αντιμετωπιστούν αυτά τα προβλήματα, χρησιμοποιείται ο Στοχαστικός Αλγόριθμος Απότομης Καθόδου (Stochastic Gradient Descent). Το σύνολο του δείγματος υποδιαιρείται σε N , τυχαία αντιπροσωπευτικά υποσύνολα του δείγματος, στα οποία γίνονται οι παραπάνω υπολογισμοί. Μολίς ολοκληρωθεί η διαδικασία για όλα τα σύνολα, τότε αναφέρεται ότι συμπληρώθηκε μια Εποχή (Epoch), μια ακόμη υπερπαράμετρος των νευρωνικών δικτύων. Ενδεικτικά, στο παρακάτω σχήμα (Εικόνα 3.12) φαίνεται ο υπολογισμός της κατεύθυνσης, που ελαχιστοποιείται το κόστος με χρήση υποσυνόλων.



Εικόνα 3.12: Συνάρτηση Κόστους για δυο παραμέτρους με διαδρομή ελαχιστοποίησης. (Πηγή: ml4a.GitHub.io).

Μια άλλη υπερπαράμετρος που προστίθεται είναι η ορμή β , όπου η διόρθωση της παραμέτρου, βάρη ή προκαταλήψεις, δεν είναι πλέον συνάρτηση μόνο του «βήματος» της κλίσης, ρυθμός εκπαίδευσης, αλλά η διόρθωση προσαρμόζεται σταδιακά από τον ρυθμό της προηγούμενης ενημέρωσης. Όσο μεγαλύτερη είναι η ορμή β , τόσο πιο δυναμική είναι η διόρθωση των παραμέτρων. Συγκεκριμένα, ο τύπος διόρθωσης των παραμέτρων γίνεται (10).

$$f_t(w, b) := f_{t-1}(w, b) - a z_t \quad (10) \quad ,$$

$$\text{όπου } z_t := \beta z_{t-1} + \nabla C[f_{t-1}(w, b)]$$

Λαμβάνεται, δηλαδή υπόψη η προηγούμενη κλίση, με συνέπεια για τον εντοπισμό της βέλτιστης διαδρομής, ακόμη και αν στη διαδρομή η κλίση αλλάξει σημαντικά και ενδέχεται να οδηγηθεί σε μη βέλτιστες διαδρομές, η ορμή θα επαναπροσδιορίσει τη κατεύθυνση προς τη διαδρομή, που ελαχιστοποιεί τη συνάρτηση κόστους. Για να γίνει αντιληπτή, η έννοια της ορμής, ας υποθεθεί μια μπάλα που κυλάει προς τα κάτω σε ένα ανάγλυφο μέχρι να σταματήσει στο χαμηλότερο σημείο. Η μπάλα ξεπερνά τα τοπικά ελάχιστα και τα σημεία, που δημιουργείται «σέλα» στο ανάγλυφο λόγω της ταχύτητας, που έχει ήδη αναπτύξει από τη διαδρομή, έτσι λοιπόν ας υποθεθεί η ορμή σαν την ταχύτητα της μπάλας. Η ορμή, προδίδοντας κάποια εξάρτηση από τις τοπικές τιμές, βοηθά να εντοπιστούν γρήγορα και αποτελεσματικά οι διορθώσεις για το βέλτιστο νευρωνικό δίκτυο.

Ένα, ακόμη, σημαντικό πρόβλημα στην εκπαίδευση των νευρωνικών δικτύων είναι ο καθορισμός του ρυθμού εκπαίδευσης. Συνήθως, δίνεται μια αυθαίρετη τιμή και στην συνέχεια μειώνεται βαθμιαία, μέχρις ότου το μοντέλο να συγκλίνει στη μεγαλύτερη ακρίβεια. Επιπλέον, είναι ίδιος για όλες τις παραμέτρους του νευρωνικού δικτύου. Αυτή η λειτουργία δεν είναι ικανοποιητική, καθώς η τιμή είναι η ίδια για κάθε μεμονωμένη παράμετρο, ανεξάρτητα από τα χαρακτηριστικά της συνάρτησης κόστους. Ως συμπέρασμα, είναι δύσκολο να ορισθεί η κατάλληλη τιμή ρυθμού εκμάθησης και μεταβολής της. Για το λόγο αυτό θα γίνει μια αναφορά στις Προσαρμοστικές Μεθόδους (Adaptive Methods), που αντιμετωπίζουν το συγκεκριμένο πρόβλημα. Η απλούστερη μέθοδος ενημέρωσης ανά παράμετρο είναι η AdaGrad, με την οποία κάθε παράμετρος διορθώνεται ξεχωριστά, σύμφωνα με την τοπική κλίση. Η μαθηματική σχέση είναι η (11) και αντιπροσωπεύει τη διόρθωση, ως το πηλίκο του ρυθμού εκπαίδευσης προς το άθροισμα των τετραγώνων της κλίσης για αυτή την παράμετρο, για κάθε βήμα από την έναρξη της εκπαίδευσης. Άλλες, προσαρμοστικές μέθοδοι είναι η AdaDelta, παρόμοια με την AdaGrad, και η RMSprop.

$$w := w - \frac{a}{\sqrt{G+\varepsilon}} \frac{dC}{dw} \quad (11), \text{ η διόρθωση είναι (12) } \delta w = - \frac{a}{\sqrt{G+\varepsilon}} * g_t$$

Το ε είναι ένας πολύ μικρός αριθμός για μην μηδενίζεται ο παρονομαστής και το G , ο μέσος όρος των τετραγώνων των κλίσεων, όπου (13) $RMS(\delta w) = \sqrt{G + \varepsilon}$.

Το AdaGrad αποτελεί, γενικά, μια αξιόπιστη προσαρμοστική μέθοδο, με τα εξής μειονεκτήματα, την επιλογή αρχικού ρυθμού εκμάθησης και την συνεχή μείωση του. Έτσι, η AdaDelta έρχεται για να βελτιώσει την AdaGrad για την επίλυση των παραπάνω ανησυχιών. Το AdaDelta επιλύει τη συνεχώς φθίνουσα ταχύτητα εκμάθησης χρησιμοποιώντας την εξής διαδικασία.

Έχοντας το μέσο όρο των τετραγώνων κλίσεων στο χρόνο t ως $E(g^2)_t = \gamma * E(g^2)_{t-1} + (1 - \gamma) * g^2_t$ (14), όπου γ , η ορμή και συνήθως 0,9.

$$\text{Από (13) και (14) προκύπτει η διόρθωση, } RMS(\delta w) = \sqrt{E(\delta w^2)_t + \varepsilon} \quad (15).$$

Οπότε προκύπτει για τη χρονική στιγμή t , όπου δεν έχει υπολογισθεί το $RMS(\delta w)_t$, αντικαθιστώντας τον ρυθμό εκμάθησης με $RMS(\delta w)_{t-1}$.

Το AdaDelta, υπολογίζει τη διόρθωση, λοιπόν αντικαθιστώντας τον ρυθμό εκμάθησης α , με $RMS(\delta w)_{t-1}$ και προκύπτει από (12), (13), η σχέση (16)

$$\delta w = - \frac{RMS(\delta w)_{t-1}}{RMS(g)_t} * g_t \quad (16).$$

Αφού, εκπαιδευτεί ένα μοντέλο νευρωνικού δικτύου, τότε μια τακτική για την αξιολόγηση του, θα ήταν να ελεγχθούν τα αποτελέσματα του με τα πραγματικά. Το φαινόμενο της υπερπροσαρμογής (overfitting) θα βοηθήσει να γίνει αντιληπτό γιατί αυτό δεν είναι η βέλτιστη τακτική. Το πρόβλημα της υπερπροσαρμογής εμφανίζεται όταν το μοντέλο εκπαιδεύτηκε για να είναι υπερβολικά ακριβές στα δεδομένα εκπαίδευσης, παράλληλα παρουσιάζει αδυναμία να είναι αντίστοιχα εύστοχο σε άγνωστα δεδομένα. Για παράδειγμα, επιθυμώντας να εκπαιδευτεί ένα μοντέλο να εντοπίζει τις διατροφικές συνήθειες και τα δεδομένα εκπαίδευσης, που του παρέχονται είναι από τη δεκαετία 2000s, τότε τα αποτελέσματα, που θα εξάγονται θα είναι burger,


pizza κτλ.. Το μοντέλο θα έχει ακρίβεια να εντοπίζει τις διατροφικές συνήθειες αλλά για την σύγχρονη εποχή, τα αποτελέσματα του μοντέλου για παλαιότερες δεκαετίες, πχ 1920s, θα είναι λανθασμένα. Η απλούστερη λύση για αποφευχθεί το πρόβλημα της υπερπροσαρμογής και της εξαπάτησης, λόγω της υπερβολικής εκπαίδευσης σε βάρος της γενίκευσης, είναι να χωρισθούν τα δεδομένα. Τα δεδομένα χωρίζονται σε Δεδομένα Εκπαίδευσης (Train Data), όπου είναι τα δεδομένα, με τα οποία θα εκπαιδευτεί το νευρωνικό δίκτυο, συνήθως επιλέγεται περίπου 70% του συνολικού δείγματος. Επόμενο υποσύνολο είναι τα Δεδομένα Επικύρωσης (Valid Data), τα οποία θα χρησιμοποιηθούν από το μοντέλο για αποφευχθεί το πρόβλημα της υπερπροσαρμογής, όσο η ακρίβεια του μοντέλου στα Δεδομένα Επικύρωσης αυξάνεται, τόσο το μοντέλο μπορεί να αντιμετωπίσει καλύτερα άγνωστα δεδομένα. Συνήθως, επιλέγεται το 15%-25% του συνολικού δείγματος. Τα δεδομένα επικύρωσης επιτυγχάνουν την αξιολόγηση του μοντέλου, ώστε να βρεθούν οι βέλτιστοι υπερπαράμετροι. Συχνά, για να αυξηθεί η ακρίβεια επιλέγεται να χωριστούν τα δεδομένα επικύρωσης και εκπαίδευσης σε ίσα K υποσύνολα, ώστε να αξιολογηθεί το μοντέλο αρκετές φορές, συγκεκριμένα K . Η διαδικασία αυτή ονομάζεται Cross-Validation. Τέλος, υπάρχουν και τα Δεδομένα Δοκιμής (Test Data), όπου αξιολογείται αμερόληπτα η ακρίβεια του μοντέλου σε άγνωστα δεδομένα, συνήθεις τιμές είναι το 10% έως 20% του δείγματος.

Για την αντιμετώπιση της υπερπροσαρμογής, η οποία εμφανίζεται όταν οι τιμές στα βάρη αυξάνονται αρκετά, λόγω των απότομων αλλαγών στη Συνάρτηση Κόστους, είναι η Συστηματοποίηση (Regularization). Προσθέτοντας ένα όρο L στη συνάρτηση κόστους, που υπονομεύει τα μεγάλα βάρη, αυτό επιτυγχάνεται με το όρο L_2 -regularization, και οι μαθηματικές σχέσεις είναι οι (12) και (13). Ένας, ακόμη τρόπος είναι μέσω της απόστασης L_1 , Manhattan Distance.

$$R(f) = \frac{1}{2} L \sum w^2 \quad (12)$$

$$C(w, b) = C_0 + R(f) \quad (13)$$

Η απόρριψη νευρώνων (Dropout) είναι μια ευφυής τακτική συστηματοποίησης. Κατά τη διάρκεια της εκπαίδευσης, ένα ποσοστό των νευρώνων, απενεργοποιούνται μαζί με τις συνδέσεις τους, το ποσοστό αυτό προκύπτει από μια υπερπαράμετρο και είναι συνήθως από 20% έως 50%. Οι νευρώνες αποσύρονται συνεχώς και τυχαία. Το αποτέλεσμα είναι να μειωθεί η υπερβολική εξάρτηση από ορισμένους νευρώνες, έτσι το δίκτυο αναγκάζεται να εκπαιδευτεί με μια πιο ισορροπημένη αντιπροσώπευση. Ενδεικτικά το παρακάτω σχήμα (Εικόνα 3.13).



Εικόνα 3.13: Νευρωνικό δίκτυο κανονικό (a) και με απόσυρση νευρώνων (b).

Αφού, αναπτύχθηκαν οι υπερπαράμετροι, που θα οδηγήσουν το μοντέλο του νευρωνικού δικτύου στην ελαχιστοποίηση της συνάρτησης κόστους και, κατά συνέπεια στον εντοπισμό των κατάλληλων παραμέτρων, βάρη και προκαταλήψεις, θα αντιμετωπισθεί το γεγονός ότι σε μεγάλα δεδομένα θα πρέπει να υπολογίζεται ένας μεγάλος αριθμός κλίσεων και παραμέτρων. Για το πρόβλημα αυτό χρησιμοποιείται η Οπισθόδρομη Διάδοση Σφάλματος (Backpropagation). Η βασική ιδέα είναι ότι η Οπισθόδρομη Διάδοση Σφάλματος καθιστά δυνατό τον υπολογισμό όλων των παραμέτρων των κλίσεων, μέσω μιας «εμπρός» και «πίσω» διέλευσης στο νευρωνικό δίκτυο. Αυτό επιτυγχάνεται με τη χρήση του κανόνα της αλυσίδας (Calculus). Παρακολουθώντας τις διαφορές των τιμών σε ένα πέρασμα προς τα «εμπρός», είναι δυνατό να υπολογισθεί η κλίση, ως τον όρο απώλειας, που βρίσκεται στο τέλος του περάσματος πολλαπλασιασμένο με το σφάλμα του περάσματος προς τα «πίσω», μέσα από κάθε επίπεδο. Ανακαλώντας τις μαθηματικές σχέσεις (5) και (8), προκύπτει η (14).

$$w := w' = w - a \nabla C \quad (8)$$

$$\nabla C(w, b) = \left(\frac{\partial C}{\partial f_1(w, b)}, \frac{\partial C}{\partial f_2(w, b)}, \dots, \frac{\partial C}{\partial f_k(w, b)} \right) \quad (5)$$

$$\frac{\partial C}{\partial w_i} \approx \frac{C(f + e e_i) - C(f)}{e} \quad (14) \quad , \text{ όπου το } e_i, \text{ είναι ένα διάνυσμα με } 0 \text{ εκτός από τη θέση } i, \text{ όπου } 1, \text{ και το } e \text{ ένας πολύ μικρός αριθμός. Για να αποκτηθεί η κλίση σε ένα στοιχείο, είναι απαραίτητο να υπολογιστεί η συνάρτηση κόστους και στις δύο διελεύσεις.}$$

3.8. ΚΡΙΤΗΡΙΑ ΑΞΙΟΛΟΓΗΣΗΣ ΑΠΟΤΕΛΕΣΜΑΤΩΝ

Το μοντέλο πρόβλεψης, αφού εκπαιδευτεί με τα δεδομένα εκπαίδευσης (Training Data), στη συνέχεια, θα αξιολογηθούν τα αποτελέσματα, που θα προκύψουν χρησιμοποιώντας τα δεδομένα δοκιμής (Test Data), όπως προαναφέρθηκε. Σκοπός της αξιολόγησης των αποτελεσμάτων είναι η ακρίβεια των προβλέψεων, η οποία θα χαρακτηρίσει και την αποδοτικότητα του μοντέλου. Η επιτυχία του μοντέλου στις προβλέψεις, θα προκύψει από τη σύγκριση των πραγματικών δεδομένων με τα αποτελέσματα του μοντέλου πρόβλεψης. Αυτό θα επιτευχθεί υπολογίζοντας στατιστικά μέτρα, τα οποία θα αναλυθούν για την μεγιστοποίηση της ακρίβειας και τον περιορισμό των σφαλμάτων.

Σε ένα πρόβλημα πολλαπλής ταξινόμησης (Multiclassification) με 3 τάξεις, Συμβάν 1 (1), Συμβάν 2 (2), Κανένα συμβάν (0), για τα πραγματικά και τα δεδομένα της πρόβλεψης, θα προκύψει ο παρακάτω πίνακας.

		ΠΡΑΓΜΑΤΙΚΟΤΗΤΑ		
		0	1	2
ΠΡΟΒΛΕΨΗ	0	K_{11}	K_{12}	K_{13}
	1	K_{21}	K_{22}	K_{23}
	2	K_{31}	K_{32}	K_{33}

Οι τιμές K_{ij} , υποδεικνύουν τον αριθμό των παρατηρήσεων, που προέκυψαν από το μοντέλο σε σχέση με τα αποτελέσματα, που έπρεπε να προκύψουν από την πραγματικότητα. Το πρόβλημα πολλαπλής ταξινόμησης θα αναχθεί σε πρόβλημα απλής ταξινόμησης (Classification), δηλαδή με δυο τάξεις. Η τάξη 1 θα περιγράφει την ύπαρξη συμβάντος (Συμβάν 1 και Συμβάν 2) και η τάξη 0 τη μη ύπαρξη συμβάντος (Κανένα συμβάν), οπότε προκύπτει ο παρακάτω πίνακας και τα στατιστικά μέτρα.

	0	1
0	A	B
1	Γ	Δ

Το A είναι η περίπτωση, όπου το μοντέλο προέβλεψε σωστά τη μη ύπαρξη συμβάντος, αλλιώς ονομάζεται True Negative, καθώς και το Δ, όπου προβλέφθηκε σωστά την ύπαρξη συμβάντος, True Positive. Στο B, το μοντέλο πρόβλεψε τη μη ύπαρξη συμβάντος, ενώ στην πραγματικότητα υπάρχει, καλείται False Negative, αναφέρεται

και ως Λάθος Τύπου II. Για το Γ, το μοντέλο πρόβλεψε την ύπαρξη συμβάντος, ενώ στην πραγματικότητα δεν υπάρχει, ονομάζεται True Positive, αναφέρεται και ως Λάθος Τύπου I.

Τα στατιστικά μέτρα ορίζονται :

$$\text{Sensitivity (True Positive Rate) (TPR)} = \frac{TP}{TP+FN}$$

$$\text{Specificity (True Negative Rate) (TNR)} = \frac{TN}{TN+FP}$$

$$\text{Precision (Positive Predictive Value) (PPV)} = \frac{TP}{TP+FP}$$

$$\text{Negative Predictive Value (NPV)} = \frac{TN}{TN+FN}$$

$$\text{False Negative Rate / Error Type II (FNR)} = \frac{FN}{TP+FN} = 1 - TPR$$

$$\text{False Positive Rate / Error Type I (FPR)} = \frac{FP}{FP+TN} = 1 - TNR$$

$$\text{False Discovery Rate (FDR)} = \frac{FP}{FP+TP} = 1 - PPV$$

$$\text{False Omission Rate (FOR)} = \frac{FN}{TN+FN} = 1 - NPV$$

$$\text{Accuracy (ACC)} = \frac{TP+TN}{TP+TN+FP+FN}$$


$$F_1 = \frac{2*TP}{2*TP+FP+FN}$$

$$\text{Classification Error} = 1 - ACC$$

Γενικά, είναι επιθυμητό οι πραγματικές παρατηρήσεις να συμπίπτουν με τις εξαγόμενες από το μοντέλο πρόβλεψης, δηλαδή τα Α και Δ να είναι όσο το δυνατό περισσότερα, ενώ σε αντίθεση τα Β και Γ όσο το δυνατό λιγότερα, στη βέλτιστη περίπτωση 0. Τα στατιστικά μέτρα Sensitivity, Specificity, Precision, Negative Predictive Value και Accuracy να πλησιάζουν τη μονάδα. Αντίθετα, τα FOR, FDR, το Σφάλμα Τύπου I, το Σφάλμα Τύπου II και το Classification Error να ελαχιστοποιούνται και να πλησιάζουν το 0. Για τα δεδομένα, στην παρούσα εργασία, απαιτήθηκε μια ιδιαίτερη προσοχή, καθώς ο αριθμός των γεγονότων ήταν πολύ μικρότερος από τις φυσιολογικές τιμές. Για τον καθορισμό του βέλτιστου μοντέλου, με τη μεγαλύτερη ακρίβεια, σημαντικό ρόλο έχουν τα στατιστικά μέτρα Sensitivity, Specificity, Precision και Accuracy.

Για την εύρεση ενός αποτελεσματικού μοντέλου, ενδέχεται να απαιτηθούν πολλές δοκιμές, ένας γρήγορος τρόπος για να αποφευχθεί η άσκοπη ανάλυση όλων των

στατιστικών μέτρων είναι η καμπύλη ROC (Receiver Operating Characteristic) και ο δείκτης AUC (Area Under Curve), το εμβαδόν του χωρίου εντός της καμπύλης. Οι δύο άξονες είναι, στον κάθετο άξονα το True Positive Rate (Sensitivity), για τον οποίο είναι επιθυμητό να πλησιάζει την τιμή 1 και στον οριζόντιο άξονα, το False Negative Rate (1-Specificity), επιθυμητά να προσεγγίζει το 0. Αφού, στόχος είναι η δημιουργία ενός μοντέλου με υψηλό Sensitivity και χαμηλό 1-Specificity, ιδανικά ο δείκτης AUC, πρέπει να πλησιάζει το 1. Ενδεικτικά το Διάγραμμα 3.13.



Διάγραμμα 3.13: Μορφή καμπύλης ROC.

Συνοψίζοντας, πρέπει να επισημανθεί, ότι τα αποτελέσματα μεταχειρίστηκαν ως πρόβλημα απλής ταξινόμησης. Για το λόγο αυτό, θα πρέπει να γίνει και η ανάλυση των στατιστικών παραμέτρων της πολλαπλής ταξινόμησης, για να εντοπιστεί η ικανότητα του μοντέλου να εντοπίζει, όχι μόνο το γεγονός, αλλά και τον τύπο του γεγονότος. Η μέθοδος αξιολόγησης είναι η ίδια και ισχύουν, οι ίδιοι τύποι για τα στατιστικά μέτρα.

3.9. ΕΠΙΛΟΓΗ ΛΟΓΙΣΜΙΚΟΥ

Ένα σημαντικό ζήτημα αποτελεί η επιλογή του κατάλληλου λογισμικού, που θα πραγματοποιηθούν οι υπολογισμοί. Επιλέχθηκε, λοιπόν, η γλώσσα προγραμματισμού R, χρησιμοποιώντας το περιβάλλον λογισμικού, που είναι πιο φιλικό στη λειτουργία της γλώσσας, RStudio. Η γλώσσα προγραμματισμού R πλεονεκτεί, αφού παρέχει ανοιχτό κώδικα προς όλους τους χρήστες. Χρησιμοποιείται κυρίως για στατιστικούς σκοπούς και για ανάπτυξη ευφυών συστημάτων υπολογισμών. Ακόμη, παρέχει μια πληθώρα πακέτων εργασίας. Στη συγκεκριμένη εργασία επιλέχθηκαν τα εξής πακέτα, το AnomalyDetection, για τους γρήγορους υπολογισμούς του αλγόριθμου εντοπισμού ακραίων παρατηρήσεων, το ROSE, για την διαχείριση μη ισορροπημένων δεδομένων,

το distances, για τον υπολογισμό της μετρικής απόστασης Mahalanobis και το h2o, στο οποίο αναπτύχθηκαν τα Νευρωνικά Δίκτυα.

Η R αντιμετωπίζει ένα πολύ σημαντικό πρόβλημα για τους υπολογισμούς και αυτό είναι ο χρόνος ολοκλήρωσης τους και ο διαθέσιμος αποθηκευτικός χώρος. Για το σκοπό αυτό, η R αποθηκεύει τα αρχεία στη μνήμη RAM του υπολογιστή, για το χρονικό διάστημα χρησιμοποίησης του λογισμικού, με αποτέλεσμα να υπάρχει εύκολη και γρήγορη πρόσβαση στα δεδομένα και τα αποτελέσματα, μειώνοντας παράλληλα τον χρόνο και τη χωρητικότητα των υπολογισμών.

4. ΕΝΤΟΠΙΣΜΟΣ ΟΔΗΓΙΚΩΝ ΣΥΜΒΑΝΤΩΝ

Στο παρόν κεφάλαιο, θα αναπτυχθεί η ολοκληρωμένη διαδικασία κατηγοριοποίησης της οδηγικής συμπεριφοράς. Περιγράφοντας το τρόπο συλλογής των δεδομένων, στη συνέχεια θα αναλυθεί η απαραίτητη επεξεργασία τους για την παραγωγή των αποτελεσμάτων. Το ζήτημα του εντοπισμού, που καλείται να αντιμετωπίσει η παρούσα εργασία, θα προσεγγιστεί με δυο μεθόδους, οι οποίες θα αναλυθούν και θα γίνει πλήρης περιγραφή της διαδικασίας ολοκλήρωσης των εργασιών τους. Στο τέλος, θα παρατεθούν τα αποτελέσματα από τις δυο μεθόδους και θα ακολουθήσει η σύγκριση τους.


4.1. ΣΥΛΛΟΓΗ ΔΕΔΟΜΕΝΩΝ

Αρχικά, για να επιτευχθεί δημιουργία ενός εύστοχου και αποτελεσματικού μοντέλου πρόβλεψης των ακραίων οδηγικών γεγονότων, θα πρέπει να καθοριστούν τα δεδομένα που θα εισαχθούν στο μοντέλο. Θα αναλυθεί, λοιπόν, ο τρόπος συλλογής τους και η διαδικασία επεξεργασίας τους, για την εκπαίδευση των μοντέλων. Η βασική ιδέα ήταν η εκμετάλλευση του συνδυασμού της εκτεταμένης χρήσης των smartphones με την ποικιλία αισθητήρων, που διαθέτουν. Έτσι, κρίνεται αναγκαία η κατανόηση της λειτουργίας των αισθητήρων. Θα γίνει αναφορά μόνο στους αισθητήρες, που χρησιμοποιήθηκαν, για την εκπόνηση της παρούσας διπλωματικής.

4.1.1. ΑΙΣΘΗΤΗΡΕΣ ΚΑΤΑΓΡΑΦΗΣ ΔΕΔΟΜΕΝΩΝ

Το επιταχυνσιόμετρο είναι μια ηλεκτρομηχανική συσκευή, που χρησιμοποιείται για τη μέτρηση των δυνάμεων επιτάχυνσης. Τέτοιες δυνάμεις μπορεί να είναι στατικές, όπως η συνεχής δύναμη της βαρύτητας, ή δυναμικές για την ανίχνευση της κίνησης ή των κραδασμών, που προκαλούνται από την κίνηση ενός οχήματος. Η επιτάχυνση είναι η μέτρηση της μεταβολής της ταχύτητας. Για παράδειγμα, ένα αυτοκίνητο που είναι σταματημένο σε κατάσταση ηρεμίας, ξεκινά να επιταχύνεται στα 50 χιλιόμετρα ανά ώρα σε 5 δευτερόλεπτα, έτσι η επιτάχυνση του θα είναι 10 km/h ανά δευτερόλεπτο.

Ένα επιταχυνσιόμετρο είναι σε θέση να εντοπίσει την επιτάχυνση μέσω ενός μικρό-ηλεκτρομηχανικού συστήματος (MEMS), το οποίο αλλάζει τις ηλεκτρικές ιδιότητες όπως η τάση. Αυτές οι αλλαγές μεταφράζονται σε σήματα, τα οποία αποστέλλονται στο κατάλληλο λογισμικό για επεξεργασία. Υπάρχουν διάφοροι τύποι επιταχυνσιόμετρων που χρησιμοποιούνται στα smartphones το πιεζοηλεκτρικό επιταχυνσιόμετρο, το μικρό-ηλεκτρομηχανικό σύστημα (MEMS) και το χωρητικό επιταχυνσιόμετρο. Το πιεζοηλεκτρικό επιταχυνσιόμετρο βασίζεται στις φυσικές δομές των πιεζοηλεκτρικών κρυστάλλων, οι οποίες αντιδρούν στις δυνάμεις που ασκούνται στο τηλέφωνο δημιουργώντας ένα ηλεκτρικό φορτίο, το οποίο στη συνέχεια δημιουργεί τάση. Το MEMS πρόκειται για μικροσκοπικές μηχανικές δομές, που αλλάζουν όταν εφαρμόζονται σε αυτές οι επιταχυνσιακές δυνάμεις, μεταβάλλοντας στη συνέχεια μια ηλεκτρική ιδιότητα. Τέλος, το χωρητικό επιταχυνσιόμετρο είναι ένα είδος MEMS. Μια καθαρή δύναμη, που εφαρμόζεται στο μηχανικό σύστημα έχει ως αποτέλεσμα μια μεταβολή της χωρητικότητας του συστήματος. Τα επιταχυνσιόμετρα καταναλώνουν πολλή ενέργεια, επομένως συνίσταται να απενεργοποιούνται όταν δεν χρησιμοποιούνται για να αποφευχθεί η αποστράγγιση της μπαταρίας μιας συσκευής. Μια τυπική συσκευή smartphone διαθέτει ένα επιταχυνσιόμετρο, που μπορεί να ανιχνεύσει την επιτάχυνση σε τρεις άξονες, επιτρέποντας του να αισθανθεί την κίνηση και τον προσανατολισμό. Οι άξονες, συνήθως, περιγράφονται ως κάθετος στην επιφάνεια της συσκευής, άξονας Z, παράλληλος με τη μεγάλη διάσταση της συσκευής, άξονας Y, και παράλληλος στη μικρή διάσταση, άξονας X. Οι άξονες αναφοράς φαίνονται στην Εικόνα 4.1.




Εικόνα 4.1: Άξονες αναφοράς σε smartphone.

Ο αισθητήρας, εφόσον είναι ενεργοποιημένος, καταγράφει για χρονική στιγμή την επιτάχυνση, που δέχεται η συσκευή, για καθέναν από τους τρεις άξονες. Η τιμή, συνήθως, καταγράφεται συναρτήσει της επιτάχυνσης της βαρύτητας g , 9.81 m/s^2 , πχ $0.15g$. Σημείωση, ότι τα δεδομένα του άξονα Y θέλουν μια κανονικοποίηση λόγω της ύπαρξης της βαρύτητας σε ένα αποπροσανατολισμένο σύστημα αναφοράς, δηλαδή ένα

σύστημα που έχει εκτραπεί από το αρχικό, στη συνέχεια θα αναλυθεί πως αντιμετωπίζεται αυτό.

Ένα ζήτημα, που προκύπτει είναι ο προσανατολισμός της συσκευής. Οι επιταχύνσεις από το επιταχυνσιόμετρο καταγράφονται στο σύστημα αναφοράς τριών αξόνων, με το επίπεδο, που ορίζεται να είναι παράλληλο με την επιφάνεια της γης. Η συσκευή δεν είναι πάντα προσανατολισμένη σε αυτό το σύστημα αναφοράς. Θα πρέπει, λοιπόν, να πραγματοποιηθεί ο προσανατολισμός της συσκευής ανάγοντας τις επιταχύνσεις, στο αρχικό σύστημα αναφοράς X, Y, Z . Τα smartphones είναι εξοπλισμένα με το γυροσκόπιο, το οποίο υπολογίζει την γωνία περιστροφής της συσκευής με άξονες αναφοράς, X, Y, Z , όπως φαίνεται στο παρακάτω σχήμα. Η περιστροφή γύρω από τον άξονα X ονομάζεται Pitch, γύρω από τον Y , Roll, και γύρω από τον Z , Azimuth (Yaw). Έτσι το γυροσκόπιο χρησιμοποιείται για τον ορισμό του φορέα βαρύτητας. Το γυροσκόπιο φαίνεται να είναι ο ιδανικός αισθητήρας για τον υπολογισμό της εκτροπής της συσκευής από το αρχικό σύστημα αναφοράς. Αν η συσκευή κινείται αυτό δυσκολεύει τα πράγματα, καθώς η επιτάχυνση της κίνησης, κατά X , επηρεάζει τα αποτελέσματα λόγω της αδράνειας, για παράδειγμα ένα λεωφορείο ξεκινάει την κίνηση του απότομα προς τα μπροστά τότε το σώμα του επιβάτη τραβιέται προς τα πίσω. Έτσι, η επιτάχυνση X χρησιμοποιείται για να διορθώσει την επιτάχυνση Y , αφαιρώντας την από τα δεδομένα γυροσκοπίου και η επιτάχυνση Y χρησιμοποιείται για να διορθώσει την επιτάχυνση X , αφαιρώντας την από τα δεδομένα επιταχυνσιόμετρου. Αποτέλεσμα του συνδυασμού των δύο αισθητήρων είναι ότι μαζί μπορούν να καθορίσουν την περιστροφή και την επιτάχυνση του τηλεφώνου, δηλαδή τη θέση του σε σχέση με τη βαρύτητα. Η περιστροφή του κάθε άξονα στην Εικόνα 4.2.



Εικόνα 4.2: Περιστροφή αξόνων αναφοράς σε smartphone.

Ακόμη, για να οριστεί ο προσανατολισμός, δηλαδή προς ποια κατεύθυνση κινείται η συσκευή σε σχέση με το έδαφος, θα χρειαστεί ένας άλλος αισθητήρας, το μαγνητόμετρο. Το μαγνητόμετρο χρησιμοποιείται για τον καθορισμό της περιστροφής στο μαγνητικό πεδίο, σαν μια πυξίδα. Έτσι, συνδυάζοντας τους τρεις αισθητήρες, οι οποίοι διορθώνονται συνεχώς μεταξύ τους, παρέχονται οι προσανατολισμένες

πληροφορίες, που χρειάζονται, σε κοινό διορθωμένο σύστημα αναφοράς. Η υπολογιστική διαδικασία διόρθωσης του προσανατολισμού εκτελείται από το smartphone. Για τα προσανατολισμένα δεδομένα, όπως αναλύθηκε στο υποκεφάλαιο 2.2 επιτάσσεται να επαναπροσανατολιστούν, ώστε το σύστημα αναφοράς του έξυπνου κινητού να ταυτίζεται με του οχήματος. Σημειώνεται ότι τα δεδομένα που αξιοποιήθηκαν ήταν πλήρως προσανατολισμένα ως προς τον άξονα του οχήματος.

Χρησιμοποιώντας το GPS, που βρίσκεται στα smartphones, παρέχονται οι χρονικές πληροφορίες και τα δεδομένα της ταχύτητας. Καταγράφοντας το στίγμα της θέσης του οχήματος συνάρτηση του χρόνου, υπολογίζεται η τιμή της ταχύτητας. Τα δεδομένα της ταχύτητας από GPS χαρακτηρίζονται θορυβώδη δεδομένα, το γεγονός αυτό οφείλεται στη μετάδοση των δεδομένων. Συγκεκριμένα, η σύνδεση του GPS του έξυπνου κινητού με το δορυφόρο, συνήθως διακόπτεται λόγω της πολλαπλής διαδρομής του σήματος ή χαμηλής εμβέλειας του σήματος ή κακών καιρικών συνθηκών, με αποτέλεσμα η συχνότητα αποστολής των δεδομένων να μην είναι σταθερή. Λόγω της κακής μετάδοσης του σήματος οι πληροφορίες αλλοιώνονται και κατά συνέπεια υπάρχει θόρυβος στα δεδομένα από το GPS. Επιπλέον, το GPS αποτελεί σημαντική πηγή κατανάλωσης ενέργειας της μπαταρίας της συσκευής, συνίσταται, λοιπόν, να ενεργοποιείται μόνο κατά τη χρήση του. Η ταχύτητα, που καταγράφεται από το GPS του έξυπνου κινητού, είναι μια πολύ σημαντική μεταβλητή για το πείραμα, καθώς αποτελεί βασικό χαρακτηριστικό της οδηγικής συμπεριφοράς, με την οποία θα κατηγοριοποιηθούν οι παρατηρήσεις, σε φυσιολογική οδηγική συμπεριφορά και σε επικίνδυνες οδηγικές καταστάσεις.

4.1.2. ΕΦΑΡΜΟΓΗ ΣΥΛΛΟΓΗΣ ΔΕΔΟΜΕΝΩΝ

Η εφαρμογή καταγραφής των δεδομένων, που χρησιμοποιήθηκαν για επίλυση του ζητήματος, είναι η Oseven Telematics. Η εφαρμογή είναι διαθέσιμη για όλους τους τύπους έξυπνων κινητών τηλεφώνων (smartphones), και αξιοποιώντας τους αδρανειακούς αισθητήρες του κινητού και το GPS, παρέχει τις απαραίτητες πληροφορίες. Οι πληροφορίες προσφέρθηκαν σύμφωνα με την τήρηση του προσωπικού απορρήτου του χρήστη. Τα δεδομένα καταγράφονται συνεχώς κατά τη διάρκεια ενός ταξιδιού και είτε αποστέλλονται, μετά το πέρας του ταξιδιού στον κεντρικό διαχειριστή (offline data), είτε μεταδίδονται άμεσα στον κεντρικό διακομιστή (online streaming data), με σκοπό της μείωσης της κατανάλωσης ενέργειας και τη μη επιβάρυνση της μνήμης της συσκευής, ώστε να δημιουργείται ένα φιλικό περιβάλλον προς τον πάροχο της συσκευής για την ευρεία χρησιμοποίηση της εφαρμογής.

Οι συνθήκες καταγραφής είναι νατουραλιστικές. Αυτό σημαίνει ότι στο πείραμα δεν τέθηκε κανένας περιορισμός για την παρακολούθηση των οδηγικών χαρακτηριστικών. Ακόμη, οι χρήστες δεν είναι ενημερωμένοι για την έναρξη της συνεχής καταγραφής, η μόνη γνώση προκύπτει από την αρχική εγκατάσταση της εφαρμογής καταγραφής, που επέλεξαν να συμμετέχουν. Ο κάτοχος της συσκευής smartphone, κινείται όπως στη

καθημερινότητα του, χωρίς να προσέχει εσκεμμένα την οδηγική του συμπεριφορά. Για παράδειγμα στην περίπτωση πραγματοποίησης ενός πειράματος οδηγικής συμπεριφοράς με παρακολούθηση από άτομο εντός του οχήματος, ο οδηγός ενδέχεται να είναι πιο προσεκτικός από ότι συνήθως, αφού η παρουσία του ατόμου του υπενθυμίζει ότι παρακολουθείται.

Η συχνότητα, που επιλέχθηκε είναι 1Hz. Με τη συχνότητα αυτή ο όγκος των πληροφοριών θεωρήθηκε αποδεκτός και, επίσης, είναι μια συχνότητα που μπορούν να ανταπεξέλθουν όλες οι συσκευές, ακόμα και τα smartphones παλαιότερης γενιάς. Ακόμη, η επιλογή μιας υψηλής συχνότητας θα οδηγήσει σε επιβάρυνση της συσκευής, λόγω της αυξημένης υπολογιστικής ισχύς και της γρήγορης αποστράγγισης της μπαταρίας της συσκευής. Η λογική είναι οι εφαρμογές καταγραφής δεδομένων να είναι φιλικές, προς τους χρήστες για να επεκτείνεται η χρήση τους.

4.2. ΕΠΕΞΕΡΓΑΣΙΑ ΔΕΔΟΜΕΝΩΝ

Τα δεδομένα, που αξιοποιήθηκαν για την δημιουργία του μοντέλου πρόβλεψης προέρχονται από την εφαρμογή Oseven Telematics. Συγκεκριμένα, για ένα συνολικό αριθμό 408 ταξιδιών από ένα όχημα σε νατουραλιστικές συνθήκες. Τα δεδομένα είναι προσανατολισμένα ως προς τους τυπικούς άξονες αναφοράς του οχήματος και αποτελούνται από ταξίδια συνολικής διάρκειας 796.755 δευτερολέπτων. Στο σύνολο το δεδομένων εμπεριέχεται μια πληθώρα μετρήσεων διαφορετικών οδηγικών χαρακτηριστικών. Για τη επιλογή των κατάλληλων παραμέτρων, χρησιμοποιήθηκε η μέθοδος που περιγράφεται στο επόμενο υποκεφάλαιο.


4.2.1. ΕΠΙΛΟΓΗ ΜΕΤΑΒΛΗΤΩΝ ΑΝΑΛΥΣΗΣ

Κάθε αρχείο αντιπροσωπεύει και ένα ταξίδι. Τα αρχεία αποτελούνται από πολλές παραμέτρους, συνεπώς είναι απαραίτητη η κατανόηση της δομής των δεδομένων, ώστε να χρησιμοποιηθούν οι σχετικές πληροφορίες με το ζήτημα. Όπως, έχει αναφερθεί στο Κεφάλαιο 3, η αποτελεσματική λειτουργία ενός μοντέλου εντοπισμού εξαρτάται από τις μεταβλητές και αυτές είναι, που θα καθορίσουν το αποτέλεσμα. Ένα σημαντικό βήμα για την έρευνα, ήταν η επιλογή των κατάλληλων μεταβλητών. Για την επιλογής τους, βοήθησε αρκετά η οπτικοποίηση (visualization) των δεδομένων, ώστε να αποκτηθεί μεγαλύτερη ευχέρεια στην κατανόηση του τρόπου λειτουργίας του «περιβάλλοντος» εργασίας. Για να υλοποιηθεί ο σκοπός, έγιναν αρκετές δοκιμές, οπότε θα παρουσιασθούν μόνο τα διαγράμματα, που περιγράφουν το «περιβάλλον» εργασίας.


Αρχικά, παρατίθεται, η οπτικοποίηση των δεδομένων των επιταχύνσεων για κάθε άξονα ξεχωριστά με τη ύπαρξη ή όχι οδηγικών γεγονότων. Οπότε, προκύπτουν τα

παρακάτω διαγράμματα για τις επιταχύνσεις και τις ταχύτητες, αναλύοντας την συμπεριφορά των παρατηρήσεων. Έγιναν πολλές δοκιμές και τα διαγράμματα επιλέχτηκαν ως αντιπροσωπευτικά της κατάστασης των παρατηρήσεων.

Αρχικά, εξετάστηκε η περίπτωση μη ύπαρξης συμβάντος, ώστε να γίνει αντιληπτή η κανονικότητα των παρατηρήσεων (Διάγραμμα 4.1, 4.2, 4.3). Οι διακυμάνσεις στις τιμές, δεν είναι μεγάλες, καθώς και δεν εντοπίζονται μεγάλες αριθμητικές τιμές στις παρατηρήσεις. Το γεγονός αυτό είναι απόλυτα λογικό, καθώς δεν υπήρξε κάποιος παράγοντας να επηρεάσει τα δεδομένα.



Διάγραμμα 4.1: Διάγραμμα επιτάχυνσης άξονα X για φυσιολογική οδήγηση.




Διάγραμμα 4.2: Διάγραμμα επιτάχυνσης άξονα Y για φυσιολογική οδήγηση.




Διάγραμμα 4.3: Διάγραμμα επιτάχυνσης άξονα Z για φυσιολογική οδήγηση.


Ερευνώντας την περίπτωση της ύπαρξης συμβάντος και, συγκεκριμένα, ένα οδηγικό γεγονός απότομης επιτάχυνσης, παρατηρείται ότι σε αυτή την περίπτωση οι διακυμάνσεις των τιμών είναι πιο έντονες και οι τιμές των παρατηρήσεων πολύ μεγαλύτερες. Τα δεδομένα περιγράφουν ορθά την κατάσταση, καθώς το γεγονός ότι ο οδηγός ανέπτυξε απότομα την ταχύτητα κίνησης του οχήματος επηρεάζει την κανονικότητα της κίνησης. Στα παρακάτω διαγράμματα (Διάγραμμα 4.4, 4.5, 4.6) είναι φανερό ότι στην επιτάχυνση του άξονα Y επιδρά πιο έντονα το φαινόμενο, αλλά και οι τιμές των επιταχύνσεων στους άξονες X, Z δείχνουν να επηρεάζονται από το φαινόμενο. Σημείωση ότι το γεγονός καταγράφεται για την παρατήρηση 15 στα διαγράμματα. Για το λόγο αυτό επιλέχθηκε η χρησιμοποίηση και των τριών επιταχύνσεων για την ανίχνευση οδηγικών γεγονότων.



Διάγραμμα 4.4: Διάγραμμα επιτάχυνσης άξονα X για επικίνδυνη οδήγηση.




Διάγραμμα 4.5: Διάγραμμα επιτάχυνσης άξονα Y για επικίνδυνη οδήγηση.




Διάγραμμα 4.6: Διάγραμμα επιτάχυνσης άξονα Z για επικίνδυνη οδήγηση.

Ένα επιπλέον χαρακτηριστικό της κίνησης του οχήματος, που εμφανίζει έντονη επίδραση στο φαινόμενο των απότομων επιταχύνσεων και επιβραδύνσεων είναι η ταχύτητα. Στην περίπτωση οδηγικού συμβάντος, η ταχύτητα σε σύντομο χρονικό διάστημα μεταβάλλεται απότομα. Αντίθετα, στην περίπτωση της κανονικής οδήγησης η μεταβολή είναι ομαλή και χρειάζεται περισσότερος χρόνος. Ενδεικτικά, τα παρακάτω διαγράμματα (Διάγραμμα 4.7, 4.8) σε αντιστοιχία με τα προηγούμενα των επιταχύνσεων παρουσιάζουν την διακύμανση της ταχύτητας. Επομένως, χαρακτηριστικό της κίνησης για τους υπολογισμούς είναι και η ταχύτητα.



Διάγραμμα 4.7: Διάγραμμα ταχύτητας για φυσιολογική οδήγηση.




Διάγραμμα 4.8: Διάγραμμα ταχύτητας για επικίνδυνη οδήγηση.

4.2.2. ΔΗΜΙΟΥΡΓΙΑ ΝΕΩΝ ΜΕΤΑΒΛΗΤΩΝ ΑΠΟ ΔΕΔΟΜΕΝΑ

Τα δεδομένα, που προέρχονται από smartphone, είναι πολύ ευαίσθητα. Η μετακίνηση της συσκευής εντός του οχήματος, η τοποθέτηση της και η χρήση της κατά την διάρκεια ενός ταξιδιού επηρεάζουν σημαντικά τις παρατηρήσεις. Το γεγονός αυτό απαιτεί την επεξεργασία των δεδομένων πριν χρησιμοποιηθούν για τους υπολογισμούς. Δεν δύναται να είναι γνωστή τοποθέτηση της συσκευής εντός του οχήματος, επομένως η θέση της συσκευής είναι τελείως αυθαίρετη. Ενδεχομένως, η συσκευή να βρίσκεται στην τσέπη του οδηγού ή να έχει τοποθετηθεί σε κάποιο σταθερό σημείο ή, ακόμη, να βρίσκεται μέσα σε τσάντα, έτσι οι πληροφορίες των επιταχύνσεων αλλοιώνονται, με αποτέλεσμα να δημιουργείται «θόρυβος» στα δεδομένα. Λόγω του «θορύβου» δε συνίσταται να χρησιμοποιηθούν οι τιμές των επιταχύνσεων για τον κάθε άξονα ξεχωριστά. Με σκοπό τη μείωση του «θορύβου» θα πρέπει να υπολογιστεί μια συνισταμένη των επιταχύνσεων, που θα καθορίσει τα αποτελέσματα. Σύμφωνα με τη βιβλιογραφία, πολλές έρευνες για την αντιμετώπιση αυτού του φαινομένου χρησιμοποίησαν το μέτρο του διανύσματος $|a| = \sqrt{a_x^2 + a_y^2 + a_z^2}$, (Liu et al., 2009), (Mitrovic, 2005) και (Baldwin et al., 2004). Αντί αυτής της προσέγγισης, επιλέχθηκε η χρήση της νόρμας του διανύσματος. Η χρησιμοποίηση του μήκος του διανύσματος της επιτάχυνσης δεν λαμβάνει υπόψη τον κατευθυντικό προσανατολισμό του διανύσματος και αναφέρεται κυρίως στην αριθμητική τιμή του μήκους, η οποία και απασχολεί. Επομένως, χρησιμοποιήθηκε η μαθηματική σχέση (1), για την εισαγωγή των δεδομένων της επιτάχυνσης στους υπολογισμούς. Το παρακάτω Διάγραμμα 4.9 παρουσιάζει την επιτάχυνση σε σχέση με το χρόνο για ένα ταξίδι.

$$\alpha = \|\alpha\| = \alpha_x^2 + \alpha_y^2 + \alpha_z^2 \quad (1)$$



Διάγραμμα 4.9: Διάγραμμα μήκους του διανύσματος της επιτάχυνσης για τους τρεις άξονες.

Όπως, αναφέρθηκε προηγουμένως η χρήση του κινητού επηρεάζει την καταγραφή των παρατηρήσεων. Κατά τη διάρκεια της οδήγησης, ο οδηγός ενδέχεται να χρησιμοποιεί το smartphone είτε για να συνομιλεί, είτε στέλνοντας μηνύματα, είτε ακούγοντας μουσική, έτσι κρίθηκε απαραίτητο τα δεδομένα, που καταγράφηκαν κατά τη χρήση της συσκευής για οποιαδήποτε δραστηριότητα να αφαιρεθούν από το σύνολο των δεδομένων. Συγκεκριμένα, αφαιρέθηκαν τα δεδομένα, όπου έχει καταγραφεί Mobile Usage.

Τέλος, η ένδειξη της ταχύτητας από μόνη της δεν μπορεί να προσφέρει αρκετές πληροφορίες. Για παράδειγμα, εάν η ταχύτητα ήταν 100 km/h, δεν μπορεί να επιβεβαιώσει την ύπαρξη οδηγικού γεγονότος. Συνεπώς, ενδιαφέρει η διακύμανση σε σχέση με το χρόνο. Γι' αυτό εκτιμήθηκε κατάλληλο, κάνοντας δοκιμές, ότι για ένα χρονικό παράθυρο 2 δευτερολέπτων είναι δυνατό να επιτευχθεί μια αντιπροσωπευτική τιμή της διαφοράς της ταχύτητας. Δηλαδή, υποθέτοντας μια χρονική στιγμή t , τότε υπολογίζοντας τις διαφορές των ταχυτήτων ανά δύο δευτερόλεπτα, σημειώνεται η μέγιστη διαφορά ταχυτήτων, ως αυτή που χαρακτηρίζει το συγκεκριμένο στιγμιότυπο. Συγκεκριμένα, υπολογίστηκε η διαφορά ταχυτήτων για τα χρονικά διαστήματα $(-3,-1)$, $(-2,0)$, $(-1,+1)$, $(0,+2)$, $(+1,+3)$, $(+2,+4)$, όπου το 0 αναφέρεται στη χρονική στιγμή t , και καταγράφηκε η μέγιστη απόλυτη τιμή από αυτές τις διαφορές ταχυτήτων και το πρόσημο, για να χαρακτηρίσει το στιγμιότυπο.

4.3. ΕΦΑΡΜΟΓΗ ΜΕΘΟΔΟΓΙΑΣ ΕΝΤΟΠΙΣΜΟΥ ΟΔΗΓΙΚΩΝ ΓΕΓΟΝΟΤΩΝ

4.3.1. ΜΕΘΟΔΟΣ Α: ΧΡΗΣΗ ΑΛΓΟΡΙΘΜΟΥ ΕΝΤΟΠΙΣΜΟΥ ΑΚΡΟΤΑΤΩΝ

Η πρώτη μέθοδος αναφέρεται στον αλγόριθμο SHED. Τα δεδομένα αποτελούνται από 408 ταξίδια ενός οδηγού, συνολικής διάρκειας 796.755 δευτερόλεπτων. Έπειτα από δοκιμές, αποφασίστηκε ότι για χρονικά διαστήματα 30 δευτερολέπτων, η εξάρτηση του φαινομένου από τις παρατηρήσεις είναι ικανοποιητική. Με κριτήριο ότι ένα οδηγικό γεγονός διαρκεί μόνο μερικά δευτερόλεπτα, το χρονικό διάστημα που επιλέχθηκε εκτιμάται ικανό να εντοπίσει την πλήρη εξέλιξη ενός οδηγικού γεγονότος, δηλαδή την κανονικότητα στην οδήγηση, την αρχή του συμβάντος, το χρόνο που εκτυλίσσεται, το τέλος του συμβάντος και την επιστροφή στην κανονική οδήγηση. Για το λόγο αυτό, για χρονικά διαστήματα 30 δευτερολέπτων εντοπίστηκαν οι ακραίες τιμές (outliers), οι οποίες χαρακτηρίζονται και τιμές μη κανονικής οδήγησης, χωρίς να σημαίνει απαραίτητα ότι είναι οδηγικά γεγονότα. Η φυσική σημασία είναι ότι ακραίες τιμές, μπορεί να προέρχονται από επιτάχυνση ή επιβράδυνση του οχήματος για να προσαρμοστεί στις συνθήκες κυκλοφορίας, από απαραίτητους ελιγμούς, ώστε να αποφευχθεί η πρόκληση ατυχήματος, τέτοιες καταστάσεις όμως δεν πρέπει να χαρακτηρισθούν ως αποτελέσματα επιθετικής οδήγησης. Τα δεδομένα, που εισάχθηκαν στον αλγόριθμο είναι οι τιμές των επιταχύνσεων. Για την ανίχνευση των πιθανών οδηγικών συμβάντων ή των παρατηρήσεων μη κανονικής οδήγησης, υπολογίστηκε το μήκος του διανύσματος των επιταχύνσεων $\|a\|$.

Για τον καθορισμό των παραμέτρων του αλγόριθμου εντοπισμού χρειάζεται ένα ακόμα στάδιο, ο εντοπισμός της περιοδικότητας. Όπως αναφέρθηκε και στο Κεφάλαιο 3, η εύρεση της περιόδου έγινε με τη χρήση του περιοδογράμματος στα διαθέσιμα δεδομένα, για τα χρονικά διαστήματα των 30 δευτερολέπτων. Η προσέγγιση είναι να εντοπιστούν οι 5 μεγαλύτερες συχνότητες με βάση τις τιμές των ισχυρότερων Μετασχηματισμών Fourier (FFT) και να επιλεγεί η συχνότητα με το μεγαλύτερη συσχέτιση, που παράλληλα είναι μικρότερη από το 50% του δείγματος, καθώς επιβάλλεται το κάθε δείγμα να αποτελείται τουλάχιστον από δυο διαστήματα, για να υπάρχει περιοδικότητα. Η συχνότητα αυτή αντιπροσωπεύει το δείγμα και μετατρέπεται σε περίοδο, ως ανάστροφος της συχνότητας, όπως απαιτεί ο αλγόριθμος. Ακόμη, ο βαθμός σημαντικότητας επιλέχθηκε 0,1, καθώς από δοκιμές διαπιστώθηκε κατάλληλος, και οι ανωμαλίες αναζητήθηκαν και για τις δυο κατευθύνσεις, αφού σκοπός είναι να ανιχνευθούν απότομες πτώσεις και απότομες άνοδοι για τις παρατηρήσεις.

Τέλος, ένα σημαντικό ζήτημα είναι και ο αριθμός των τοπικών και των γενικών ανωμαλιών, που απαιτείται από τον αλγόριθμο να εξάγει. Το σημείο αυτό αποτέλεσε σημαντικό σημείο για την εκπόνηση της διπλωματικής, αφού οι περισσότεροι αλγόριθμοι απαιτούν να καθορισθεί ο αριθμός των ανωμαλιών. Η επιλογή του

ποσοστού των ανωμαλιών στο δείγμα για τα δεδομένα είναι μια δύσκολη διαδικασία γιατί στην πραγματικότητα δεν είναι γνωστός ο αριθμός των ακραίων τιμών, που θα προκύψουν και, ακόμη, δεν είναι γνωστό και ότι θα υπάρξει ακραία τιμή. Για το λόγο αυτό, αποφασίσθηκε, η καινοτόμα διαδικασία να εξάγονται από τον αλγόριθμο, οι πιθανές παρατηρήσεις ακραίων οδηγικών συμβάντων, δηλαδή τα δεδομένα που χαρακτηρίζονται από μη κανονική οδήγηση, χωρίς να σημαίνει απαραίτητα ότι είναι οδηγικά γεγονότα. Στη συνέχεια οι παρατηρήσεις αυτές θα εισαχθούν στο μοντέλο πρόβλεψης και θα καθορισθεί αν είναι οδηγικά γεγονότα και ο τύπος τους. Επειδή, από τα δεδομένα προέκυψε ότι ο αριθμός των οδηγικών γεγονότων στην πραγματικότητα είναι πολύ μικρός, οι τιμές κυμαίνονται από 0,03% έως 1,3%, εκτιμήθηκε ότι για 10% του δείγματος, να χαρακτηρίζεται ως μη κανονική οδήγηση, επιτυγχάνεται η μεγαλύτερη ευστοχία να βρίσκεται ένα οδηγικό γεγονός στα εξαγόμενα δεδομένα του αλγόριθμου ως ανωμαλίες και παράλληλα ο αριθμός των συνολικών ανωμαλιών να είναι ο μικρότερος. Για την επιλογή του μέγιστου ποσοστού ανωμαλιών στα δεδομένα, 10%, χρησιμοποιήθηκε η μέθοδος αξιολόγησης για προβλήματα ταξινόμησης, όπως αναλύθηκε στο Κεφάλαιο 3. Συγκεκριμένα, υπολογίσθηκε ο πίνακας πραγματικών αποτελεσμάτων και προβλέψεων για καθένα ταξίδι, και η ταξινόμηση διερεύνησε την ύπαρξη πραγματικών γεγονότων στο σύνολο των ανωμαλιών, που υπολογίσθηκαν από τον αλγόριθμο για το σύνολο του δείγματος.

Παρακάτω παρουσιάζεται ο συνοπτικός πίνακας ταξινόμησης (Πίνακας 4.1) και τα αποτελέσματα των στατιστικών μέτρων (Πίνακας 4.2). Έγιναν δοκιμές για διαφορετικά ποσοστά ανωμαλιών, ώστε να επιλεγεί το 0,1 του δείγματος, για λόγους οικονομίας δεν κρίθηκε αναγκαίο να παρουσιασθούν. Συγκεκριμένα, ο αλγόριθμος για το σύνολο του δείγματος, 796.755 παρατηρήσεις, εκτίμησε ότι 62.366 παρατηρήσεις, είναι πιθανά οδηγικά συμβάντα, δηλαδή το 7,8% του δείγματος. Από τα πιθανά οδηγικά συμβάντα, στην πραγματικότητα οι 1.653 παρατηρήσεις ήταν ακραία οδηγικά γεγονότα. Οπότε, εκτιμήθηκε η ικανότητα του αλγόριθμου να εντοπίζει ανωμαλίες, στις οποίες να περιέχονται τα πραγματικά οδηγικά συμβάντα. Ο αλγόριθμος έχει τη δυνατότητα να εντοπίζει με μεγάλη επιτυχία την ύπαρξη συμβάντων, καθώς στα εξαγόμενα δεδομένα υπολογίζεται Sensitivity 94,9% και Specificity 92,4%, η συνολική ευστοχία εκτιμήθηκε Accuracy 92,4%, καθώς και Error Type I 7,6%, Error Type II 5,1%. Το πρόβλημα έγκειται στο μεγάλο αριθμό ανωμαλιών στο δείγμα, από τα οποία τα περισσότερα δεν είναι γεγονότα, και εκφράζεται από την πολύ χαμηλή τιμή Precision 2,5%. Η τιμή του Precision δεν απασχολεί, καθώς πρέπει να επισημανθεί ότι ο σκοπός είναι ο εντοπισμός των γεγονότων στο σύνολο των ανωμαλιών, ο οποίος επιτεύχθηκε με υψηλή ευστοχία.

Πίνακας 4.1: Πίνακας ταξινόμησης επικίνδυνης και μη οδήγησης από Αλγόριθμο S-H-ESD.

Sensitivity (TPR)	0,949	Neg.Pred.Value (NPV)	0,999
Specificity (TNR)	0,924	Precision (PPV)	0,025
Error Type II (FNR)	0,051	FalseDisc.Rate (FDR)	0,975
Error Type I (FPR)	0,076	FalseOm.Rate (FOR)	0,001
Accuracy (ACC)	0,924	F1	0,959
Classification Error	0,076	AUC	0,937

Πίνακας 4.2: Στατιστικά μέτρα Αλγόριθμου S-H-ESD.

		ΠΡΑΓΜΑΤΗΚΟΤΗΤΑ		ΑΘΡΟΙΣΜΑ
ΠΡΟΒΛΕΨΗ	Επικίνδυνη Οδήγηση	Επικίνδυνη Οδήγηση	Μη Επικίνδυνη Οδήγηση	
	Επικίνδυνη Οδήγηση	1569	60797	62366
	Μη Επικίνδυνη Οδήγηση	84	734305	734389
ΑΘΡΟΙΣΜΑ		1653	795102	796755

Γενικά, ο αλγόριθμος εντοπίζει με μεγάλη επιτυχία τα οδηγικά συμβάντα. Οπότε το σύνολο των δεδομένων, που προκύπτουν από τον αλγόριθμο, ως πιθανά οδηγικά συμβάντα θα καθορίσει αν είναι οδηγικά συμβάντα και τον τύπο τους. Καταλήγοντας, με τα χαρακτηριστικά της οδηγικής συμπεριφοράς, τη διαφορά ταχύτητας και το χρόνο καταγραφής για τα πιθανά οδηγικά συμβάντα, που προέκυψαν, εκπαιδεύεται το μοντέλο πρόβλεψης με τη χρήση Νευρωνικού Δικτύου.

4.3.1.1. ΕΚΠΑΙΔΕΥΣΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ ΚΑΙ ΑΠΟΤΕΛΕΣΜΑΤΑ

ΑΕΔΟΜΕΝΑ.

Από τον αλγόριθμο SHED, κατηγοριοποιήθηκαν οι παρατηρήσεις σε φυσιολογική οδήγηση και σε πιθανή επικίνδυνη οδήγηση. Ως αποτέλεσμα, από τις 796.755 αρχικές παρατηρήσεις προέκυψαν 62.366 παρατηρήσεις πιθανής επικίνδυνης οδήγησης, με τις οποίες εκπαιδεύτηκε το Νευρωνικό Δίκτυο. Τα χαρακτηριστικά, που εκφράζουν αυτές τις παρατηρήσεις είναι η απόλυτη τιμή της διαφοράς ταχύτητας και το πρόσημό της, όπως έχει περιγραφεί ανωτέρω. Σύμφωνα, με τη βιβλιογραφία από το Κεφάλαιο 3 επιλέχθηκε για Σύνολο Εκπαίδευσης και Επικύρωσης το 90% του δείγματος, 55.923 παρατηρήσεις, και για Σύνολο Δοκιμής το 10% του δείγματος, 6.443 παρατηρήσεις. Το Σύνολο Εκπαίδευσης και Επικύρωσης χωρίστηκε σε 70% και σε 30%, αντίστοιχα. Δηλαδή, το Σύνολο Εκπαίδευσης (63% του δείγματος) αποτελείται από 39.146 παρατηρήσεις, ενώ το Σύνολο Επικύρωσης (27% του δείγματος) από 16.777 παρατηρήσεις. Ακόμη, για κάθε παρατήρηση χρησιμοποιώντας τα πραγματικά δεδομένα σημειώθηκε και ο τύπος του γεγονότος, για τις απότομες επιταχύνσεις δόθηκε η ονομασία “HA” (Harsh Acceleration), για τις απότομες επιβραδύνσεις “HB” (Harsh Braking) και οι παρατηρήσεις για τη μη ύπαρξη κανενός γεγονότος ονομάστηκαν “NOTHING”.

ΥΠΟΔΕΙΓΜΑΤΟΛΗΨΙΑ.

Ένα πολύ σημαντικό ζήτημα είναι η διαχείριση του μικρού αριθμού γεγονότων στο δείγμα. Συγκεκριμένα, έχοντας καταλήξει σε 55.923 παρατηρήσεις να αποτελούν το Σύνολο Εκπαίδευσης/Επικύρωσης, στο δείγμα, που θα εκπαιδευτεί το δίκτυο, υπάρχουν 1.533 παρατηρήσεις, καταγεγραμμένες ως οδηγικό συμβάν, δηλαδή το 2,7% του δείγματος. Είναι σαφές, λοιπόν, ότι το σύνολο δεδομένων αποτελεί ένα μη ισορροπημένο δείγμα. Το γεγονός αυτό καθιστά δύσκολη την εκπαίδευση του Νευρωνικού Δικτύου, λόγω της ανομοιογένειας του δείγματος. Η βασική ιδέα είναι να δημιουργηθεί ένα ισορροπημένο δείγμα, με το οποίο θα εκπαιδευτεί το Νευρωνικό Δίκτυο και, στη συνέχεια, θα αξιολογηθεί το Δίκτυο στα αρχικά δεδομένα. Καταλήγοντας, για το Σύνολο Εκπαίδευσης και Επικύρωσης θα εφαρμοστεί μια απλή μέθοδος υποδειγματοληψίας. Η μέθοδος αυτή, από το αρχικό δείγμα που τα δεδομένα είναι μη ισορροπημένα, θα δημιουργήσει ένα νέο δείγμα, με ισορροπημένα δεδομένα για διάφορα ποσοστά, με το οποίο θα εκπαιδευτεί το Νευρωνικό Δίκτυο. Στην πράξη επιλέγεται το ποσοστό των οδηγικών γεγονότων που θα υπάρχει μέσα στο νέο δείγμα. Πρέπει να ληφθεί υπόψη ότι όσο μεγαλύτερο είναι το ποσοστό των γεγονότων στο δείγμα, μπορεί να εκπαιδευτεί καλύτερα το δίκτυο, όμως σε βάρος της γενίκευσης. Η μέθοδος υποδειγματοληψίας αποσκοπεί στην ταχύτερη εκπαίδευση του δικτύου να ανιχνεύει τόσο τις ακραίες επιταχύνσεις και επιβραδύνσεις, όσο και την φυσιολογική οδήγηση. Σκοπός της χρήσης της μεθόδου υποδειγματοληψίας είναι να εντοπισθούν ταχύτερα οι παράμετροι εκπαίδευσης του Νευρωνικού Δικτύου. Γενικά, για μικρές τιμές επιβαλλόμενου ποσοστού συμβάντων στο δείγμα, μικρότερες από 10%, η υποδειγματοληψία, στην πράξη δεν εφαρμόζεται καθώς για το μικρό αυτό ποσοστό το δείγμα θεωρείται ακόμα μη ισορροπημένο. Στα δεδομένα, με τα οποία θα εκπαιδευτεί το δίκτυο, κυριαρχεί η φυσιολογική οδήγηση, με αποτέλεσμα μοντέλο πρόβλεψης να εκπαιδευτεί ικανοποιητικά να εντοπίζει την κανονική οδήγηση, αλλά να δυσκολεύεται να εντοπίσει τα οδηγικά συμβάντα, τα οποία είναι πολύ λιγότερα. Αντίθετα, για μεγάλες τιμές του ποσοστού υποδειγματοληψίας, μεγαλύτερες από 50%, η ύπαρξη οδηγικών συμβάντων και κανονικής οδήγησης είναι απόλυτα ισορροπημένα. Το πρόβλημα, που δημιουργείται για μεγάλα ποσοστά, είναι ότι το μοντέλο μπορεί να εντοπίσει με ικανοποιητική ακρίβεια τους ακραίους χειρισμούς και την κανονική οδήγηση, όμως σε βάρος της γενίκευσης. Συγκεκριμένα, η εφαρμογή του μοντέλου σε άγνωστα δεδομένα, τα δεδομένα δοκιμής, το δίκτυο σημειώνει υψηλή ευστοχία στην αναγνώριση των συμβάντων και παράλληλα αρκετά χαμηλή στον εντοπισμό της φυσιολογικής οδήγησης.


Καταλήγοντας, η επιλογή του κατάλληλου ποσοστού υποδειγματοληψίας πρέπει να κυμαίνεται στα όρια, που προαναφέρθηκαν. Ακόμη, πρέπει να επισημανθεί ότι για διαφορετικά ποσοστά γεγονότων στο δείγμα, με τους κατάλληλους συνδυασμούς παραμέτρων και δομής του νευρωνικού δικτύου, ενδέχεται τα αποτελέσματα να είναι αποτελεσματικά. Εφαρμόζοντας δοκιμές για διαφορετικά επιβαλλόμενα ποσοστά συμβάντων στο δείγμα, αποφασίσθηκε ότι ο κατάλληλος συνδυασμός ταχύτητας εκπαίδευσης και αποδοτικότητας επιτυγχάνεται για το 30% του δείγματος. Το στάδιο αυτό αφορά μόνο την εκπαίδευση του νευρωνικού δικτύου. Για δεδομένα στην πραγματικότητα το ποσοστό επικίνδυνων γεγονότων στο δείγμα είναι πολύ μικρότερο.

Συνεπώς, στα δεδομένα δοκιμής δεν εφαρμόζεται υποδειγματοληψία, ώστε το Σύνολο Δοκιμής να αντιπροσωπεύει τις πραγματικές συνθήκες οδήγησης.

ΔΟΜΗ ΚΑΙ ΠΑΡΑΜΕΤΡΟΙ ΕΚΠΑΙΔΕΥΣΗΣ.

Σκοπός είναι να εκπαιδευτεί ένα Νευρωνικό Δίκτυο, με υψηλή ακρίβεια (Accuracy). Αφού, πραγματοποιήθηκαν αρχικά δοκιμές για την επιλογή της σωστής δομής εκτιμήθηκε, ότι ο αριθμός των κρυφών επιπέδων και των νευρώνων, που τους αποτελούν, δεν απαιτείται να είναι μεγάλος, καθώς δεν βελτιώνεται η αποδοτικότητα του δικτύου, απλά μεγαλώνει ο χρόνος εκπαίδευσης. Ύστερα από δοκιμές, για τη δομή του νευρωνικού δικτύου αποφασίσθηκε, 2 κρυφά επίπεδα, όπου το καθένα αποτελείται από 5 νευρώνες. Στη συνέχεια, επιλέχθηκε η συνάρτηση ενεργοποίησης για τους νευρώνες. Από τη σιγμοειδή συνάρτηση, τη Tanh, τη ReLU και τη Maxout, η συνάρτηση ReLU, για τη λειτουργία ενεργοποίησης, ανταποκρίθηκε στα πιο εύστοχα αποτελέσματα.

Βασικό κριτήριο επιλογής του κατάλληλου Νευρωνικού Δικτύου είναι η ταχύτητα εκμάθησης. Γενικά, είναι επιθυμητό τα Νευρωνικά Δίκτυα να έχουν υψηλή απόδοση και να εκπαιδεύονται γρήγορα. Επιλέχθηκε, οπότε, ένα δίκτυο, που χρησιμοποιεί τη Προσαρμοστική Μέθοδο AdaDelta. Ο τρόπος λειτουργίας των Νευρωνικών Δικτύων με Προσαρμοστικές Μεθόδους αναλύθηκε στο Κεφάλαιο 3. Βασικό, κριτήριο είναι η επιλογή της συνάρτησης κόστους, η οποία αποφασίσθηκε η Cross Entropy. Οπότε, αφού έγιναν αρκετές δοκιμές, εκτιμήθηκε ο αρχικός ρυθμός εκμάθησης 0,005, για τον οποίο ο προσαρμοστικός ρυθμός μείωσης του ρυθμού εκμάθησης 0,9, και το e , ώστε να μην μηδενίζεται ο παρονομαστής 10^{-8} . Λόγω της χρήσης της προσαρμοστικής μεθόδου η ορμή τέθηκε 0. Όσον αφορά τις παραμέτρους Συστηματοποίησης επιλέγεται για L1, 10^{-6} και L2-regularization, 0, οι τιμές προέκυψαν ύστερα από δοκιμές. Το δείγμα από το Σύνολο Εκπαίδευσης και Επικύρωσης χωρίστηκε σε 10 υποσύνολα. Ακόμη, σημαντικό ζήτημα είναι και ο καθορισμός των Εποχών του νευρωνικού δικτύου. Αρχικά, η εκπαίδευση ξεκίνησε με 30 εποχές, όμως όσο μειώνεται ο αριθμός των εποχών η αποδοτικότητα αυξάνεται. Η μεγαλύτερη ευστοχία του μοντέλου εντοπίστηκε για 10 έως 15 εποχές. Για τους παραπάνω παραμέτρους εκπαίδευσης προέκυψε ότι μετά τις 12 εποχές, το δίκτυο έχει εκπαιδευτεί ικανοποιητικά. Παρουσιάζεται, λοιπόν το παρακάτω Διάγραμμα 4.10 Classification Error (1-Accuracy) για τις Εποχές, με τις παραμέτρους, που έχουν τεθεί. Είναι εμφανές ότι για 12 Εποχές εντοπίζεται το μικρότερο σφάλμα. Επομένως, καταγράφονται συνοπτικά στον παρακάτω Πίνακα 4.3 οι παράμετροι εκπαίδευσης του νευρωνικού δικτύου.



Διάγραμμα 4.10: Σφάλμα Ταξινόμησης για Εποχές Εκπαίδευσης.

Πίνακας 4.3: Παράμετροι εκπαίδευσης Νευρωνικού Δικτύου Μέθοδος A.

Παράμετροι	Τιμές
Υποσύνολα Εκπαίδευσης/Επικύρωσης	10
Λειτουργία Ενεργοποίησης	ReLU
Κρυμμένα Επίπεδα	[5,5]
Εποχές	12
Ορμή	0
Αρχικός ρυθμός εκμάθησης	0,005
Προσαρμοστικός ρυθμός εκμάθησης	0,9
e (Σφάλμα)	10^{-8}
L1	10^{-6}
L2	0
Συνάρτηση Κόστους	Cross Entropy


ΔΙΑΔΙΚΑΣΙΑ ΕΚΠΑΙΔΕΥΣΗΣ.

Από την εκπαίδευση του Νευρωνικού Δικτύου θα προκύψουν οι «προκαταλήψεις» (Bias) και τα βάρη (Weights) για κάθε νευρώνα, όπως αναλύθηκαν στο Κεφάλαιο 3. Στο αρχικό επίπεδο εισόδου, για την κάθε παρατήρηση υπάρχουν τρεις νευρώνες εισόδου, στους δύο νευρώνες εισάγονται κατηγοριοποιημένα δεδομένα, ενώ στον τρίτο αριθμητικές τιμές. Ο πρώτος νευρώνας εισόδου καταγράφει το αρνητικό πρόσημο της απόλυτης τιμής της ταχύτητας, για παράδειγμα εάν η απόλυτη τιμή είναι αρνητική (“NEGATIVE”), τότε εισάγεται 1, αντίθετα αν είναι θετική (“POSITIVE”), τότε εισάγεται 0, στο συγκεκριμένο νευρώνα. Με την αντίστοιχη διαδικασία, ο δεύτερος νευρώνας εισόδου καταγράφει τα θετικά πρόσημα των διαφορών της ταχύτητας. Ο

τρίτος νευρώνας εισόδου δέχεται τα αριθμητικά δεδομένα της απόλυτης τιμής της διαφοράς ταχύτητας. Παρουσιάζεται, λοιπόν, η σημαντικότητα των μεταβλητών για το δίκτυο, που εκπαιδεύτηκε (Πίνακας 4.4, Διάγραμμα 4.11).

Πίνακας 4.4: Ποσοστά σημαντικότητας για τις αντίστοιχες παραμέτρους Μέθοδος A.

	Σχετική Σημαντικότητα	Ποσοστιαία Σημαντικότητα
Πρόσημο Αρνητικό	0,798	37,49%
Πρόσημο Θετικό	0,386	18,15%
Διαφορά Ταχύτητας	0,945	44,37%



Διάγραμμα 4.11: Ποσοστιαίο διάγραμμα σημαντικότητας παραμέτρων Μέθοδος A.

Το επόμενο στάδιο του Νευρωνικού Δικτύου είναι το πρώτο κρυφό επίπεδο, το οποίο αποτελείται από πέντε νευρώνες. Ο κάθε νευρώνας χαρακτηρίζεται από μια προκατάληψη (bias) και ένα βάρος (weight). Τα δεδομένα εισόδου του επιπέδου εισόδου εισάγονται στο πρώτο κρυφό επίπεδο, συγκεκριμένα από τέσσερις αρχικούς νευρώνες εισόδου (input layer) θα εισαχθούν στους πέντε νευρώνες του κρυφού επιπέδου. Για το κάθε νευρώνα, μέσω της διαδικασίας βελτιστοποίησης τη συνάρτησης κόστους (Cross Entropy), θα καταγραφούν οι βέλτιστες παράμετροι για τα βάρη και τις προκαταλήψεις. Τα εξαγόμενα αποτελέσματα από τον κάθε νευρώνα οδηγούνται στο επόμενο στάδιο. Για το τρίτο στάδιο της δομής, και συγκεκριμένα το δεύτερο κρυφό επίπεδο. Τα δεδομένα, που εξάγονται από το πρώτο κρυφό επίπεδο των πέντε νευρώνων, θα εισαχθούν στους πέντε νευρώνες του δεύτερου κρυφού επιπέδου. Τελευταίο στάδιο, είναι η κατηγοριοποίηση των παρατηρήσεων, το επίπεδο εξόδου (output layer). Οι παρατηρήσεις θα ταξινομηθούν σε ΗΑ, απότομη επιτάχυνση, ΗΒ,

απότομη επιβράδυνση, και σε NOTHING, κανένα οδηγικό συμβάν. Οπότε, το τελικό επίπεδο νευρώνων αναλαμβάνει αυτή την εργασία

Αφού, περιεγράφηκαν όλα τα στάδια εργασιών του Νευρωνικού Δικτύου, αρκεί να αξιολογηθούν τα αποτελέσματα εκπαίδευσης και επικύρωσης. Καθώς, πρέπει να αντιμετωπισθεί ένα ζήτημα πολλαπλής ταξινόμησης, με ταξινομητές HA, HB και NOTHING, η τυπική προσέγγιση αξιολόγησης, που ακολουθήθηκε για τα αποτελέσματα της πολλαπλής ταξινόμησης είναι η εξής. Για το πίνακα πολλαπλής ταξινόμησης ελέγχθηκε η ακρίβεια των αποτελεσμάτων, και αφού κρίθηκε ικανοποιητική, στη συνέχεια δημιουργήθηκε ο πίνακας απλής ταξινόμησης, με δυο ταξινομητές, τα συμβάντα συνολικά, HA και HB, και την μη ύπαρξη συμβάντων, NOTHING, για τον οποίο πραγματοποιήθηκε η στατιστική ανάλυση.

Ο πίνακας πολλαπλής ταξινόμησης στο Σύνολο Εκπαίδευσης και Επικύρωσης, παρουσιάζει ένα δίκτυο για τα χαρακτηριστικά, που προαναφέρθηκαν, καλά εκπαιδευμένο. Ο Πίνακας 4.5 αντιστοιχεί στο Σύνολο Εκπαίδευσης και στο Σύνολο Επικύρωσης. Για το σύνολο δεδομένων σημειώθηκε συνολική μέση ακρίβεια 97,1%, και οι αντίστοιχες ακρίβειες, για καθένα ταξινομητή είναι, για τις απότομες επιταχύνσεις HA 99,6%, για τις απότομες επιβραδύνσεις HB 98,9%, και για τη μη ύπαρξη συμβάντος NOTHING 96,3%. Τα παραπάνω στατιστικά μέτρα δείχνουν ότι το Νευρωνικό Δίκτυο είναι ικανό να εντοπίσει την πραγματικότητα και, μάλιστα, με υψηλή απόδοση.

Πίνακας 4.5: Πίνακας πολλαπλής ταξινόμησης για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος A.

		ΠΡΑΓΜΑΤΗΚΟΤΗΤΑ			ΑΘΡΟΙΣΜΑ
		HA	HB	NOTHING	
ΠΡΟΒΛΕΨΗ	HA	491	3	42	536
	HB	2	1028	91	1121
	NOTHING	0	9	3444	3453
	ΑΘΡΟΙΣΜΑ	493	1040	3577	5110

Για πιο εμπεριστατωμένη στατιστική ανάλυση το πρόβλημα πολλαπλής ταξινόμησης θα πραγματοποιηθεί η αναγωγή σε απλή ταξινόμηση (Πίνακας 4.6) και προκύπτουν οι παρακάτω πίνακες με τα στατιστικά μετρά (Πίνακας 4.7). Αρχικά, παρουσιάζονται τα αποτελέσματα για το Σύνολο Εκπαίδευσης και το Σύνολο Επικύρωσης. Η εκπαίδευση του μοντέλου πρόβλεψης είναι αποδοτική. Το γεγονός συμπεραίνεται από τα υψηλά ποσοστά Sensitivity, 99,1%, Specificity, 96,3%, και Precision, 91,9%. Η μέση ακρίβεια υπολογίστηκε 97,1. Για τιμές του εμβαδού της καμπύλης ROC, AUC μεγαλύτερες από 0,9, το δίκτυο εκτιμάται καλά εκπαιδευμένο. Ακόμη, τα Error Type I και II, από τη μη σωστή ταξινόμηση είναι πολύ χαμηλά, οι τιμές τους 3,7% και 0,9%, αντίστοιχα. Η στατιστική ανάλυση έδειξε ότι έχει δημιουργηθεί ένα αποδοτικό εκπαιδευμένο δίκτυο.

Καθοριστικό βήμα πλέον, είναι η αξιολόγηση του μοντέλου στα Δεδομένα Δοκιμής, όπου θα εκτιμηθεί και η πραγματική αποδοτικότητα του.

Πίνακας 4.6: Πίνακας ταξινόμησης Συμβάν/Κανονική Οδήγηση για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος Α.

ΠΡΟΒΛΕΨΗ	Οδηγικό Συμβάν Κανονική Οδήγηση	ΠΡΑΓΜΑΤΗΚΟΤΗΤΑ		ΑΘΡΟΙΣΜΑ
		Οδηγικό Συμβάν	Κανονική Οδήγηση	
		1519	133	1652
		14	3444	3458
	ΑΘΡΟΙΣΜΑ	1533	3577	5110

Πίνακας 4.7: Στατιστικά Μέτρα για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος Α.

Sensitivity (TPR)	0,991	Neg.Pred.Value (NPV)	0,996
Specificity (TNR)	0,963	Precision (PPV)	0,919
Error Type II (FNR)	0,009	FalseDisc.Rate (FDR)	0,081
Error Type I (FPR)	0,037	FalseOm.Rate (FOR)	0,004
Accuracy (ACC)	0,971	F1	0,954
Classification Error	0,029	AUC	0,977

ΔΟΚΙΜΗ.

Υπενθυμίζοντας ότι στα δεδομένα, με τα οποία εκπαιδεύτηκε το Νευρωνικό Δίκτυο, εφαρμόστηκε υποδειγματοληψία, το δείγμα, που δημιουργήθηκε δεν ανταποκρίνεται στην πραγματικότητα, καθώς σκόπιμα επιλέχθηκε οι παρατηρήσεις οδηγικών συμβάντων να αποτελούν το 30% του δείγματος, ενώ στην πραγματικότητα κυμαίνονται σε πολύ μικρότερα ποσοστά. Στη συγκεκριμένη φάση, θα αξιολογηθεί το μοντέλο, που εκπαιδεύτηκε, για πραγματικές συνθήκες χρησιμοποιώντας το Σύνολο Δοκιμής. Το Σύνολο Δοκιμής αποτελείται από 6.443 παρατηρήσεις, στις οποίες εμπεριέχονται 281 παρατηρήσεις οδηγικών συμβάντων, δηλαδή περίπου το 4% του δείγματος. Το ποσοστό αυτό αντικατοπτρίζει την πραγματικότητα και στο δείγμα δοκιμής εφαρμόστηκε το μοντέλο πρόβλεψης, για το οποίο προέκυψε ο παρακάτω Πίνακας 4.8 πολλαπλής ταξινόμησης.

Πίνακας 4.8: Πίνακας πολλαπλής ταξινόμησης για Σύνολο Δοκιμής Μέθοδος Α.

		ΠΡΑΓΜΑΤΗΚΟΤΗΤΑ			ΑΘΡΟΙΣΜΑ
		HA	HB	NOTHING	
ΠΡΟΒΛΕΨΗ	HA	101	0	71	172
	HB	1	177	138	316
	NOTHING	0	2	5953	5955
	ΑΘΡΟΙΣΜΑ	102	179	6162	6443

Από τον Πίνακα 4.8 παρατηρείται υψηλή ευστοχία στη πρόβλεψη της οδηγικής κατάστασης. Για τα οδηγικά συμβάντα απότομης επιτάχυνσης καταγράφεται ακρίβεια (Accuracy) 97,5% και το σφάλμα ταξινόμησης (Classification Error) 2,5%. Αντίστοιχα, για την απότομη επιβράδυνση η ακρίβεια είναι 97,94% και το σφάλμα 2,06%. Επομένως, το Νευρωνικό Δίκτυο είναι ικανό να εντοπίζει με μεγάλη ακρίβεια την ύπαρξη οδηγικών συμβάντων και τον σωστό τύπο. Όσον αφορά τη μη ύπαρξη οδηγικών συμβάντων, την κανονική οδήγηση, η ακρίβεια εντοπισμού είναι 97,61% , με το σφάλμα 2,39%.

ΑΠΟΤΕΛΕΣΜΑΤΑ.

Ανάγοντας, λοιπόν, το πρόβλημα πολλαπλής ταξινόμησης σε απλή προκύπτει ο παρακάτω πίνακας ταξινόμησης (Πίνακας 4.9) με τα στατιστικά μέτρα (Πίνακας 4.10). Αναλύοντας τον πίνακα προβλέψεων και πραγματικότητας, και τα στατιστικά μέτρα συνεπάγεται ότι το νευρωνικό δίκτυο έχει υψηλή αποδοτικότητα στον καθορισμό της οδηγικής κατάστασης. Η συνολική ακρίβεια είναι 96,7% και το σφάλμα της ταξινόμησης 3,3%. Το Sensitivity και το Specificity, 98,9% και 96,6%, υποδεικνύουν ότι το μοντέλο πρόβλεψης είναι εύστοχο τόσο στον εντοπισμό των ακραίων οδηγικών συμβάντων, όσο και στην ανίχνευση της κανονικής οδήγησης. Επιπλέον, το γεγονός ότι το Precision είναι 57,1%, υποδεικνύει τη δημιουργία ενός πιο επεικούς μοντέλου πρόβλεψης. Αρκεί να γίνει υπενθύμιση στη φύση του προβλήματος. Ο σκοπός είναι ο εντοπισμός των καταστάσεων οδήγησης, οπότε αφού προβλέφθηκαν περισσότερα οδηγικά συμβάντα, κατά συνέπεια η οδηγική συμπεριφορά χαρακτηρίζεται με μικρότερη αυστηρότητα πρόβλεψης σε σχέση με την πραγματικότητα. Στην ουσία δεν επηρεάζει σημαντικά η τιμή του Precision, γιατί εξαρτάται από την αυστηρότητα της ταξινόμησης των συμβάντων στην πραγματικότητα. Βασικό, κριτήριο στην επιλογή μοντέλου αποτελεί η ακρίβεια του.

Όσον αφορά τα λάθη του ταξινομητή Error Type I και II, οι τιμές είναι αποδεκτές, 3,4% και 1,1%, αντίστοιχα. Τα Error Type I υποδηλώνουν ότι το δίκτυο αναγνωρίζει ως οδηγικό συμβάν, μια παρατήρηση που στην πραγματικότητα δεν είναι. Η τιμή του είναι πολύ χαμηλή και κοντά στο 0, οπότε η αστοχία του μοντέλου στον λάθος χαρακτηρισμό των κανονικών οδηγικών καταστάσεων κυμαίνεται σε αποδεκτά όρια. Όμοια συμπεράσματα προκύπτουν και για το Error Type II, το οποίο πλησιάζει το 0. Σχετικά με την καμπύλη ROC, όπου αφορά το Sensitivity και το 1-Specificity. Το εμβαδόν της

υπολογίσθηκε 0,978, μια τιμή πολύ κοντά στη μονάδα, που υποδηλώνει ένα πολύ αποδοτικό μοντέλο πρόβλεψης.

Πίνακας 4.9: Πίνακας ταξινόμησης Συμβάν/Κανονική Οδήγηση για Σύνολο Δοκιμής Μέθοδος Α.

ΠΡΟΒΛΕΨΗ	Οδηγικό Συμβάν Κανονική Οδήγηση ΑΘΡΟΙΣΜΑ	ΠΡΑΓΜΑΤΗΚΟΤΗΤΑ		ΑΘΡΟΙΣΜΑ
		Οδηγικό Συμβάν	Κανονική Οδήγηση	
		278	209	487
		3	5953	5956
		281	6162	6443

Πίνακας 4.10: Στατιστικά Μέτρα για Σύνολο Δοκιμής Μέθοδος Α.

Sensitivity (TPR)	0,989	Neg.Pred.Value (NPV)	0,999
Specificity (TNR)	0,966	Precision (PPV)	0,571
Error Type II (FNR)	0,011	FalseDisc.Rate (FDR)	0,429
Error Type I (FPR)	0,034	FalseOm.Rate (FOR)	0,001
Accuracy (ACC)	0,967	F1	0,724
Classification Error	0,033	AUC	0,978

Καταλήγοντας, με την ολοκλήρωση της διαδικασίας δημιουργήθηκε ένα αποδοτικό Νευρωνικό Δίκτυο για την ανίχνευση των επικίνδυνων και κανονικών οδηγικών καταστάσεων. Η ακρίβεια εντοπισμού των πιθανών οδηγικών συμβάντων είναι 93% και η ακρίβεια καθορισμού της οδηγικής κατάστασης 97%, κατά συνέπεια η συνολική ακρίβεια εκτιμάται 90%. Το μοντέλο είναι ικανό να δέχεται δεδομένα από διάφορα ταξίδια, και ύστερα από την κατάλληλη επεξεργασία να εντοπίζει την οδηγική συμπεριφορά, διακρίνοντας τη σε κανονική και επικίνδυνη. Στη συνέχεια έχει τη δυνατότητα, στην περίπτωση της επικίνδυνης οδήγησης να καθορίζει τον τύπο, χωρίζοντας τη σε απότομες επιταχύνσεις και απότομες επιβραδύνσεις.

4.3.2. ΜΕΘΟΔΟΣ Β: ΧΡΗΣΗ ΜΕΤΡΙΚΗΣ ΑΠΟΣΤΑΣΗΣ

Τα δεδομένα, που αξιοποιήθηκαν για τους υπολογισμούς ήταν, όπως και στην προηγούμενη μέθοδο, 408 ταξίδια, συνολικής διάρκειας 796.755 δευτερολέπτων. Στη δεύτερη μέθοδο, το ζητούμενο προσεγγίστηκε διαφορετικά. Για να αντιμετωπιστεί το φαινόμενο του πολύ μικρού αριθμού οδηγικών γεγονότων, αλλά και παράλληλα να μην

χαθεί κανένα οδηγικό γεγονός, επιλέχθηκε ο υπολογισμός των μετρικών αποστάσεων των παρατηρήσεων. Συγκεκριμένα, η τυπική προσέγγιση ήταν να υπολογιστεί για κάθε παρατήρηση, η αντιπροσωπευτική μετρική απόσταση, και στη συνέχεια μαζί με τα υπόλοιπα χαρακτηριστικά της οδήγησης να καθορίσουν τα αποτελέσματα του μοντέλου πρόβλεψης.

Για το σκοπό αυτό, υπολογίστηκε η μετρική απόσταση της εξεταζόμενης παρατήρησης σε σχέση με τις υπόλοιπες και καταγράφηκε. Τα δεδομένα, με τα οποία έγιναν η υπολογισμοί των μετρικών αποστάσεων των παρατηρήσεων είναι τα μήκη των διανυσμάτων των επιταχύνσεων $\|a\|$. Συγκεκριμένα, εντοπίστηκε ότι για χρονικά διαστήματα 20 δευτερολέπτων, η μετρική απόσταση της τιμής είναι αντιπροσωπευτική. Για παράδειγμα, υποθέτοντας μια παρατήρηση σε συγκεκριμένη χρονική στιγμή t . Για την παρατήρηση t , απομονώθηκαν οι παρατηρήσεις σε χρονικό εύρος $(t - 10s)$ έως $(t + 10s)$ και υπολογίστηκε η μετρική απόσταση Mahalanobis (Κεφάλαιο 3). Τέλος, η μετρική απόσταση της παρατήρησης t , είναι η απόσταση Mahalanobis, για το χρονικό διάστημα $[-10s, +10s]$. Αξίζει να σημειωθεί ότι η απόσταση Mahalanobis εκτιμήθηκε πιο ικανοποιητική σε σχέση με της υπόλοιπες μετρικές αποστάσεις Ευκλείδεια Απόσταση, Απόσταση Manhattan, όπως και από μεθόδους Κινούμενου Μέσου Όρου. Η επιλογή έγινε λόγω της καλύτερης συσχέτισης των μεταβλητών, λαμβάνοντας υπόψη τη συνδιακύμανση, αλλά και της απλότητας της.

Συνοψίζοντας, για κάθε παρατήρηση καταγράφηκε η απόσταση Mahalanobis, η χρονική στιγμή καταγραφής και τα χαρακτηριστικά της διαφοράς ταχυτήτων, πρόσημο και απόλυτη τιμή. Από τα χαρακτηριστικά του κάθε στιγμιότυπου των ταξιδιών εκπαιδεύτηκε το Νευρωνικό Δίκτυο.

4.3.2.1. ΕΚΠΑΙΔΕΥΣΗ ΝΕΥΡΩΝΙΚΟΥ ΔΙΚΤΥΟΥ ΚΑΙ ΑΠΟΤΕΛΕΣΜΑΤΑ

ΔΕΔΟΜΕΝΑ.

Η δεύτερη μέθοδος θα διαχειριστεί το σύνολο των δεδομένων. Έχοντας καταγράψει τη μετρική απόσταση Mahalanobis για κάθε παρατήρηση, παραγόμενη από τα δεδομένα των επιταχύνσεων, καθώς και τα υπόλοιπα χαρακτηριστικά της διαφοράς ταχύτητας, θα πρέπει να καθορισθούν τα σύνολα, με τα οποία θα δημιουργηθεί το Νευρωνικό Δίκτυο. Το δείγμα αποτελείται από 796.755 παρατηρήσεις, οι οποίες χαρακτηρίζονται από την μετρική απόσταση Mahalanobis, την απόλυτη τιμή της διαφοράς ταχύτητας και το πρόσημο της διαφοράς. Όπως και στην προηγούμενη μέθοδο, σύμφωνα με τη βιβλιογραφία επιλέχθηκε το 90% του δείγματος να εκπροσωπεί το Σύνολο Εκπαίδευσης και Επικύρωσης και το 10% του δείγματος το Σύνολο Δοκιμής. Το Σύνολο Εκπαίδευσης και Επικύρωσης χωρίστηκε σε 80% και 20%. Συγκεκριμένα προκύπτουν 573.663 παρατηρήσεις για το Σύνολο Εκπαίδευσης (72% του δείγματος),

143.416 παρατηρήσεις, για Σύνολο Επικύρωσης (18% του δείγματος) και 79.676 παρατηρήσεις για το Σύνολο Δοκιμής (10% του δείγματος). Πέραν από τα χαρακτηριστικά της κάθε παρατήρησης, τα δεδομένα συνοδεύονται και από τον καθορισμό της πραγματικής κατάστασης, όμοια με την προηγούμενη μέθοδο, οι απότομες επιβραδύνσεις καλούνται “HB”, οι απότομες επιταχύνσεις “HA” και η μη ύπαρξη οδηγικού συμβάντος “NOTHING”.


ΥΠΟΔΕΙΓΜΑΤΟΛΗΨΙΑ.

Όπως και με την προηγούμενη, ένα μη ισορροπημένο σύνολο δεδομένων πρέπει να διαχειριστεί. Για την ακρίβεια από τον συνολικό αριθμό των 796.755 παρατηρήσεων, προκύπτει το Σύνολο Εκπαίδευσης και Επικύρωσης για 717.079 παρατηρήσεις. Ο αριθμός των οδηγικών συμβάντων, που καταγράφηκαν στην πραγματικότητα στο δείγμα εκπαίδευσης είναι 1.461, δηλαδή το 0,2% του δείγματος. Το ποσοστό είναι πάρα πολύ μικρό και καθιστά αδύνατη την εκπαίδευση του νευρωνικού δικτύου. Για να αντιμετωπιστεί η ανομοιογένεια στις παρατηρήσεις χρησιμοποιήθηκε η μέθοδος της υποδειγματοληψίας. Θα δημιουργηθεί ένα νέο σύνολο παρατηρήσεων, στο οποίο επιβάλλεται το ποσοστό των οδηγικών γεγονότων, που υπάρχουν στο δείγμα. Με το νέο σύνολο το δίκτυο καθίσταται δυνατό να εκπαιδευτεί ταχύτερα, βέβαια η αξιολόγηση της αποδοτικότητας του δικτύου θα εξετασθεί στο Σύνολο Δοκιμής, στο οποίο δε εφαρμόζεται η μέθοδος διαχείρισης μη ισορροπημένου δείγματος. Όπως προαναφέρθηκε η επιλογή του ποσοστού υποδειγματοληψίας για τη μείωση του χρόνου εκπαίδευσης και την εύρεση του αποδοτικότερου μοντέλου, συνίσταται να κυμαίνεται από 20% έως 40%. Επισημαίνοντας ότι για διαφορετικά ποσοστά γεγονότων στο δείγμα, με τους κατάλληλους συνδυασμούς παραμέτρων και δομής, ενδέχεται τα αποτελέσματα να είναι αποδοτικά. Αποφασίστηκε ο εντοπισμός του βέλτιστου μοντέλου πρόβλεψης να προκύψει από το ποσοστό υποδειγματοληψίας 30%. Επομένως, δημιουργήθηκε ένα νέο σύνολο με το οποίο θα εκπαιδευτεί το νευρωνικό δίκτυο, αποτελούμενο από 4.842 παρατηρήσεις.

ΔΟΜΗ ΚΑΙ ΠΑΡΑΜΕΤΡΟΙ ΕΚΠΑΙΔΕΥΣΗΣ.

Στη συνέχεια θα αναπτυχθεί η δομή του Νευρωνικού Δικτύου και οι υπερπαραμέτροι εκπαίδευσης, που έδωσαν την μεγαλύτερη αποδοτικότητα του μοντέλου πρόβλεψης. Επιλέχθηκαν, λοιπόν, 2 κρυφά επίπεδα, λόγω του γεγονότος ότι τέσσερις μεταβλητές χαρακτηρίζουν τις παρατηρήσεις, δεν κρίθηκε ωφέλιμο να χρησιμοποιηθούν παραπάνω κρυφά επίπεδα, αφού δεν βελτιώνεται η ευστοχία του μοντέλου και αυξάνεται κατά πολύ ο χρόνος εκπαίδευσης. Για κάθε κρυφό επίπεδο ο αριθμός των νευρώνων, που τα αποτελούν, είναι 6. Γενικά, οι συναρτήσεις ενεργοποίησης για την μεγαλύτερη αποδοτικότητα του δικτύου είναι η ReLU και Tanh, με την ReLU να σημειώνει λίγο μεγαλύτερη ευστοχία. Επομένως, η συνάρτηση για τη λειτουργία της ενεργοποίησης αποφασίστηκε να είναι η ReLU. Για την επιλογή της δομής, πραγματοποιήθηκαν δοκιμές, ώστε να εντοπισθεί αυτή, που προσδίδει τα πιο ευστοχά αποτελέσματα.

Όπως και προηγουμένως, για λόγους γρήγορου εντοπισμού της ελαχιστοποίησης της Συνάρτησης Κόστος αποφασίσθηκε η επιλογή του Νευρωνικού Δικτύου με την Προσαρμοστική Μέθοδο AdaDelta. Στο συγκεκριμένο δίκτυο η συνάρτηση κόστους είναι η Cross Entropy. Η προσαρμοστική μέθοδος, που χρησιμοποιήθηκε, απαίτησε την ορμή να είναι 0, και για αρχικό ρυθμό εκμάθησης 0,005, να μειώνεται με προσαρμοστικό ρυθμό εκμάθησης 0,9, με μια πολύ μικρή τιμή ϵ για μην μηδενίζεται ποτέ ο παρονομαστής ίση με 10^{-8} . Ακόμη, οι παράμετροι Συστηματοποίησης τέθηκαν για L1, 10^{-6} και L2-regularization, 10^{-8} . Στη συνέχεια πρέπει να καθορισθεί για το Σύνολο Εκπαίδευσης και Επικύρωσης, ο αριθμός των υποσυνόλων, για τον οποίο θα εκπαιδευτεί το Νευρωνικό Δίκτυο, οπότε επιλέχθηκαν 10 υποσύνολα. Ένα στάδιο, που χρειάστηκε ιδιαίτερη μεταχείριση είναι ο καθορισμός των Εποχών. Συγκεκριμένα, το δίκτυο έδειξε να αποδίδει περισσότερο για 7 Εποχές. Το μοντέλο πέραν τις 7 εποχές, έχει εκπαιδευτεί αρκετά για να μπορέσει να εντοπίσει με ακρίβεια την οδηγική κατάσταση. Όπως φαίνεται από το παρακάτω Διάγραμμα 4.12 Classification Error (1-Accuracy) για τις Εποχές, η επιλογή των 7 Εποχών είναι ικανοποιητική. Επομένως, θα παρατεθούν σε ένα συνοπτικό Πίνακα 4.11, η δομή και οι παράμετροι εκπαίδευσης του Νευρωνικού Δικτύου.



Διάγραμμα 4.12: Σφάλμα Ταξινόμησης για Εποχές Εκπαίδευσης.

Πίνακας 4.11: Παράμετροι εκπαίδευσης Νευρωνικού Δικτύου Μέθοδος B.


Παράμετροι	Τιμές
Υποσύνολα Εκπαίδευσης/Επικύρωσης	10
Λειτουργία Ενεργοποίησης	ReLU
Κρυμμένα Επίπεδα	[6,6]
Εποχές	7
Ορμή	0
Αρχικός ρυθμός εκμάθησης	0,005
Προσαρμοστικός ρυθμός εκμάθησης	0,9
e (Σφάλμα)	10^{-8}
L1	10^{-6}
L2	10^{-8}
Συνάρτηση Κόστους	Cross Entropy

ΔΙΑΔΙΚΑΣΙΑ ΕΚΠΑΙΔΕΥΣΗΣ.

Αφού, αποφασίσθηκε η δομή και οι παράμετροι του νευρωνικού δικτύου θα περιγραφούν τα στάδια υπολογισμών. Το πρώτο βήμα είναι η εισαγωγή των χαρακτηριστικών των παρατηρήσεων στον επίπεδο εισόδου. Το επίπεδο εισόδου αποτελείται από τέσσερις νευρώνες, δύο κατηγοριοποιητικούς και δύο αριθμητικούς. Ο πρώτος νευρώνας αναφέρεται στο αρνητικό πρόσημο της απόλυτης τιμής της διαφοράς ταχύτητας, ενώ ο δεύτερος νευρώνας στο θετικό πρόσημο. Για παράδειγμα, αν το πρόσημο είναι αρνητικό, τότε στο πρώτο νευρώνα θα εισαχθεί η τιμή 1, ενώ στο δεύτερο νευρώνα η τιμή 0, παρόμοια και αν η ένδειξη είναι για θετικό πρόσημο. Ο τρίτος νευρώνας εισόδου δέχεται τις αριθμητικές τιμές της μετρικής απόστασης Mahalanobis, όπου εισάγεται η αριθμητική τιμή. Στον τελευταίο νευρώνα, εισάγονται οι αριθμητικές τιμές των απόλυτων τιμών των διαφορών ταχυτήτων. Η σημαντικότητα των μεταβλητών φαίνεται παρακάτω, Πίνακας 4.12 και Διάγραμμα 4.13.

Πίνακας 4.12: Ποσοστά σημαντικότητας για τις αντίστοιχες παραμέτρους Μέθοδος B.

	Σχετική Σημαντικότητα	Ποσοστιαία Σημαντικότητα
Πρόσημο Αρνητικό	0,950	35,83%
Πρόσημο Θετικό	0,279	10,51%
Διαφορά Ταχύτητας	1,000	37,72%
Απόσταση Mahalanobis	0,422	15,93%



Διάγραμμα 4.13: Ποσοστιαίο διάγραμμα σημαντικότητας παραμέτρων Μέθοδος B.

Το δεύτερο στάδιο υπολογισμών του Νευρωνικού Δικτύου είναι το πρώτο κρυφό επίπεδο, το οποίο αποτελείται από έξι νευρώνες. Ο κάθε νευρώνας χαρακτηρίζεται από μια προκατάληψη (bias) και ένα βάρος (weight). Τα εισαγόμενα δεδομένα στο επίπεδο εισόδου οδηγούνται στους έξι νευρώνες. Το επόμενο στάδιο της δομής είναι το δεύτερο κρυφό επίπεδο. Τα δεδομένα, που εξάγονται από το πρώτο κρυφό επίπεδο των έξι νευρώνων και εισάγονται στους έξι νέους νευρώνες του δεύτερου κρυφού επιπέδου. Το τελικό στάδιο, είναι το επίπεδο εξόδου, όπου γίνεται η κατηγοριοποίηση των παρατηρήσεων. Οι παρατηρήσεις ταξινομούνται σε HA, απότομη επιτάχυνση, HB, απότομη επιβράδυνση, και σε NOTHING, κανένα οδηγικό συμβάν. Στο στάδιο αυτό θα καθορισθεί η ύπαρξη ή όχι οδηγικού συμβάντος, και αν ναι ο τύπος του.

Ακολούθως, θα παρουσιασθούν τα αποτελέσματα της ταξινόμησης, που προέκυψαν από τη διαδικασία εκπαίδευσης του Νευρωνικού Δικτύου. Συγκεκριμένα, θα παρουσιασθεί ο πίνακας πολλαπλής ταξινόμησης, με ταξινομητές, τις ακραίες επιταχύνσεις HA, τις ακραίες επιβραδύνσεις HB και τη μη ύπαρξη συμβάντων NOTHING. Υπενθυμίζεται ότι η μέθοδος καλείται να διαχειριστεί το σύνολο των δεδομένων σε αυτή την περίπτωση. Στη συνέχεια θα γίνει αναγωγή σε απλή ταξινόμηση, όπου θα υπάρχουν τα επικίνδυνα οδηγικά συμβάντα και η κανονική οδήγηση. Αρχικά, παρουσιάζονται τα αποτελέσματα για το Σύνολο Εκπαίδευσης και Επικύρωσης, όπου ο Πίνακας 4.13 για την πολλαπλή ταξινόμηση, ο Πίνακας 4.14 για την αναγωγή σε απλή ταξινόμηση ο Πίνακας 4.15 με τα στατιστικά μέτρα.

Πίνακας 4.13: Πίνακας πολλαπλής ταξινόμησης για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος B.

		ΠΡΑΓΜΑΤΗΚΟΤΗΤΑ			ΑΘΡΟΙΣΜΑ
		HA	HB	NOTHING	
ΠΡΟΒΛΕΨΗ	HA	459	5	29	493
	HB	2	988	45	1035
	NOTHING	0	9	3307	3314
	ΑΘΡΟΙΣΜΑ	461	1000	3381	4842

Πίνακας 4.14: Πίνακας ταξινόμησης Συμβάν/Κανονική Οδήγηση για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος B.

		ΠΡΑΓΜΑΤΗΚΟΤΗΤΑ		ΑΘΡΟΙΣΜΑ
		Οδηγικό Συμβάν	Κανονική Οδήγηση	
ΠΡΟΒΛΕΨΗ	Οδηγικό Συμβάν	1447	74	1521
	Κανονική Οδήγηση	14	3307	3321
	ΑΘΡΟΙΣΜΑ	1461	3381	4842

Πίνακας 4.15: Στατιστικά Μέτρα για Σύνολο Εκπαίδευσης/Επικύρωσης Μέθοδος B.

Sensitivity (TPR)	0,991	Neg.Pred.Value (NPV)	0,996
Specificity (TNR)	0,978	Precision (PPV)	0,951
Error Type II (FNR)	0,009	FalseDisc.Rate (FDR)	0,049
Error Type I (FPR)	0,022	FalseOm.Rate (FOR)	0,004
Accuracy (ACC)	0,982	F1	0,971
Classification Error	0,018	AUC	0,984

Από τα αποτελέσματα προκύπτει, κατά το στάδιο εκπαίδευσης, η ακρίβεια του μοντέλου είναι αρκετά υψηλή μεγαλύτερη, 98,2%. Το μοντέλο εκπαιδεύτηκε να εντοπίζει με ικανοποιητική ακρίβεια τις απότομες επιταχύνσεις, οι οποίες εντοπίζονται με ακρίβεια 99,6% και τις ακραίες επιβραδύνσεις με ακρίβεια 98,8%. Ακόμη, η μη ύπαρξη συμβάντων προβλέπεται με ακρίβεια κοντά στο 97,8%. Τα σφάλματα τύπου I και II, κυμαίνονται στις αποδεκτές τιμές, όπως, 2,2% και 0,09%, αντίστοιχα. Το Positive Predicted Value 95,1% και το Negative Predicted Value 99,6%. Επιπλέον, από την καμπύλη ROC, το εμβαδό είναι 0,984, όπου γενικά, τιμές μεγαλύτερες του 0,9 υποδεικνύουν πολύ αποδοτικά μοντέλα. Από τα παραπάνω στατιστικά μέτρα συμπεραίνεται ότι έχει δημιουργηθεί ένα μοντέλο με υψηλή ακρίβεια, ικανό να εντοπίζει την οδηγική κατάσταση και τον τύπο της. Επιβάλλεται, όμως, να δοκιμαστεί το μοντέλο πρόβλεψης του Νευρωνικού Δικτύου σε πραγματικές οδηγικές

καταστάσεις χρησιμοποιώντας τα δεδομένα Δοκιμής, ώστε να καθοριστεί η ικανότητα πρόβλεψης σε βάρος της γενίκευσης.

ΔΟΚΙΜΗ.

Στα δεδομένα εκπαίδευσης και επικύρωσης του νευρωνικού δικτύου έχει εφαρμοστεί υποδειγματοληψία, και συγκεκριμένα επιλέχθηκε το δείγμα να αποτελείται από 30% παρατηρήσεων οδηγικών συμβάντων και το υπόλοιπο από παρατηρήσεις κανονικής οδήγησης. Το Σύνολο Δοκιμής αντιπροσωπεύει τη γενίκευση, δηλαδή τα δεδομένα εισάγονται, όπως έχουν παραχθεί στην πραγματικότητα, χωρίς να έχει εφαρμοστεί η μέθοδος διαχείρισης μη ισορροπημένων δεδομένων. Αποτελείται από 79.676 παρατηρήσεις, στις οποίες εμπεριέχονται 169 οδηγικά συμβάντα ακραίων επιταχύνσεων και επιβραδύνσεων, δηλαδή το 0,2% του δείγματος. Το ποσοστό αυτό αντικαθρεπτίζει τις πραγματικές συνθήκες, αφού γενικά ο αριθμός το συμβάντων στη διάρκεια ενός ταξιδιού είναι πολύ μικρός. Από τα Νευρωνικό Δίκτυο, προβλέφθηκαν οι οδηγικές καταστάσεις και συγκρίνοντας τις προβλέψεις με την πραγματικότητα προκύπτει ο παρακάτω Πίνακας 4.16 πολλαπλής ταξινόμησης.

Πίνακας 4.16: Πίνακας πολλαπλής ταξινόμησης για Σύνολο Δοκιμής Μέθοδος B.

		ΠΡΑΓΜΑΤΗΚΟΤΗΤΑ			ΑΘΡΟΙΣΜΑ
		HA	HB	NOTHING	
ΠΡΟΒΛΕΨΗ	HA	59	1	677	737
	HB	1	105	791	897
	NOTHING	0	3	78039	78042
	ΑΘΡΟΙΣΜΑ	60	109	79507	79676

Αξιολογώντας την ακρίβεια εντοπισμού, για τα οδηγικά συμβάντα απότομης επιτάχυνσης, HA εντοπίζονται με απόλυτη ακρίβεια (Accuracy) 98,3%, το μοντέλο σημειώνει μεγάλη ευστοχία στην ανίχνευση των συγκεκριμένων συμβάντων. Για την απότομη επιβράδυνση η ακρίβεια είναι 96,3%. Καταλήγοντας στο συμπέρασμα ότι το Νευρωνικό Δίκτυο μπορεί να εντοπίζει την ύπαρξη οδηγικών συμβάντων και τον σωστό τύπο, με αρκετά υψηλή ακρίβεια. Σχετικά με την κανονική οδήγηση, τη μη ύπαρξη επικίνδυνων οδηγικών γεγονότων, η ακρίβεια εντοπισμού των φυσιολογικών καταστάσεων είναι 98,2%. Είναι εμφανές ότι τα δεδομένα φυσιολογικής οδήγησης κυριαρχούν στο δείγμα, αφού μόλις το 0,2% αποτελούν οδηγικά συμβάντα. Το γεγονός ότι το μοντέλο είναι ικανό να προβλέπει εύστοχα τόσο την ύπαρξη οδηγικών συμβάντων και τον τύπο, όσο και τη μη ύπαρξη, το καθιστά αποδοτικό.

ΑΠΟΤΕΛΕΣΜΑΤΑ.

Ανάγοντας το πρόβλημα πολλαπλής ταξινόμησης σε απλή για καλύτερη στατιστική ανάλυση των αποτελεσμάτων θα προκύψει ο παρακάτω Πίνακας 4.17 με τα στατιστικά μέτρα (Πίνακας 4.18).

Από τον πίνακα προβλέψεων και πραγματικότητας και τα στατιστικά μέτρα συμπεραίνεται ότι το νευρωνικό δίκτυο είναι αποδοτικό για την ανίχνευση της οδηγικής κατάστασης. Το Sensitivity 97,1% και το Specificity 98,2%, το συμπέρασμα είναι ότι το μοντέλο πρόβλεψης είναι ικανοποιητικά εύστοχο στον εντοπισμό και των δυο καταστάσεων οδήγησης. Η ακρίβεια του μοντέλου εκτιμήθηκε 98,2%. Ακόμη, από το Error Type I και Error Type II, 1,8% και 2,7% αντίστοιχα, συμπεραίνεται η λάθος ταξινόμηση σε σύγκριση με την πραγματικότητα είναι πολύ μικρή. Οι τιμές είναι πολύ χαμηλές και πλησιάζουν να μηδενιστούν. Το εμβαδόν της καμπύλης ROC, Sensitivity και 1-Specificity, είναι 0,976 μια πολύ υψηλή τιμή, που περιγράφει είναι πολύ εύστοχο μοντέλο. Το Negative Predicted Value είναι πολύ υψηλό 99,9%, ενώ η τιμή του Precision είναι πολύ χαμηλή, 10,1%. Στην πραγματικότητα στα δεδομένα η φυσιολογική οδήγηση κυριαρχεί σε σχέση με τα οδηγικά συμβάντα, συγκεκριμένα τα γεγονότα αποτελούν περίπου το 0,2% του δείγματος. Το μοντέλο είναι ικανό να εντοπίζει με μεγάλη ακρίβεια τις καταστάσεις οδήγησης, όμως σημειώνει πολύ χαμηλό Precision. Το φαινόμενο αυτό ονομάζεται Παράδοξο Ακρίβειας (Accuracy Paradox) και οφείλεται στο γεγονός ότι τα True Positive, η σωστή πρόβλεψη επικίνδυνης οδήγησης, και τα True Negative, η σωστή πρόβλεψη κανονικής οδήγησης, αποτελούν ένα μεγάλο ποσοστό των παρατηρήσεων, για το πείραμα το ποσοστό αυτό είναι 98%, λόγω των True Negative κυρίως. Συνεπώς, η αυστηρότητα ανίχνευσης επικίνδυνων οδηγικών χειρισμών είναι πολύ χαμηλή.

Πίνακας 4.17: Πίνακας ταξινόμησης Συμβάν/Κανονική Οδήγηση για Σύνολο Δοκιμής Μέθοδος Β.

		ΠΡΑΓΜΑΤΗΚΟΤΗΤΑ		ΑΘΡΟΙΣΜΑ
ΠΡΟΒΛΕΨΗ	Οδηγικό Συμβάν Κανονική Οδήγηση	Οδηγικό Συμβάν	Κανονική Οδήγηση	
		164	1468	1632
		5	78039	78044
	ΑΘΡΟΙΣΜΑ	169	79507	79676

Πίνακας 4.18: Στατιστικά Μέτρα για Σύνολο Δοκιμής Μέθοδος Β.

Sensitivity (TPR)	0,971	Neg.Pred.Value (NPV)	0,999
Specificity (TNR)	0,982	Precision (PPV)	0,101
Error Type II (FNR)	0,027	FalseDisc.Rate (FDR)	0,899
Error Type I (FPR)	0,018	FalseOm.Rate (FOR)	0,001
Accuracy (ACC)	0,982	F1	0,182
Classification Error	0,018	AUC	0,976

Καταλήγοντας στη δημιουργία ενός Νευρωνικού Δικτύου για τον εντοπισμό της φυσιολογικής οδηγικής συμπεριφοράς και των επικίνδυνων οδηγικών καταστάσεων, καθώς και τον καθορισμό του τύπου τους. Το μοντέλο πρόβλεψης διαχειρίζεται το σύνολο των παρατηρήσεων των ταξιδιών των οδηγών και να παράγει ακριβείς αποτελέσματα για τον εντοπισμό της οδηγικής συμπεριφοράς, όμως είναι πολύ επιεικής στον καθορισμό μιας παρατήρησης σε οδηγικό συμβάν.

4.4. ΑΞΙΟΛΟΓΗΣΗ ΜΕΘΟΔΩΝ ΕΝΤΟΠΙΣΜΟΥ

Στο παρόν υποκεφάλαιο θα συγκριθούν οι δυο μεθοδολογικές προσεγγίσεις που αναπτύχθηκαν στο πλαίσιο της παρούσας διπλωματικής εργασίας. Η σύγκριση βασίζεται σε δυο κριτήρια. Το πρώτο κριτήριο θα είναι τα στατιστικά μέτρα, που προέκυψαν από την αξιολόγηση των προβλέψεων και της πραγματικότητας για τα Σύνολα Δοκιμής, και στο δεύτερο θα χαρακτηρίζονται οι δυο μέθοδοι με βάση τα ποιοτικά χαρακτηριστικά τους. Η ποιοτική αξιολόγηση των μεθόδων είναι μια αυθαίρετη διαδικασία, καθώς είναι δύσκολο να ποσοτικοποιηθεί. Για το σκοπό αυτό θα γίνει η προσπάθεια το δεύτερο κριτήριο να είναι όσο το δυνατό αμερόληπτο.

Η Μέθοδος Α, χρησιμοποιώντας τον αλγόριθμο εντοπισμού ακραίων παρατηρήσεων εντοπίζει τις πιθανές επικίνδυνες οδηγικές καταστάσεις, και στη συνέχεια με τη χρήση του νευρωνικού δικτύου καθορίζει αν είναι οι πιθανές παρατηρήσεις είναι οδηγικά γεγονότα και τον τύπο τους. Η Μέθοδος Β καλείται να αντιμετωπίσει το σύνολο του δείγματος, καταγράφοντας τη μετρική απόσταση Mahalanobis, και επόμενα το νευρωνικό δίκτυο θα καθορίσει τις οδηγικές συμπεριφορές και τον τύπο τους. Και η δυο μέθοδοι σημείωσαν υψηλή μέση ακρίβεια, συγκεκριμένα για την Μέθοδο Α το Accuracy είναι 96,7% με το σφάλμα ταξινόμησης Classification Error 3,3%. Με την πρώτη προσέγγιση λόγω του διαχωρισμού των παρατηρήσεων σε πιθανούς επικίνδυνους οδηγικούς χειρισμούς, όπου ο αλγόριθμος σημείωσε ακρίβεια 92,4%, η συνολική μέση ακρίβεια για τη Μέθοδο Α εκτιμάται 90%. Οι αντίστοιχες τιμές ακρίβειας και σφάλματος για τη Μέθοδο Β είναι 98,2% και 1,8%. Και για τις δυο

μεθόδους οι ακρίβειες βρίσκονται σε αποδεκτά όρια και κρίνονται σχεδόν ισάξιος. Από τις τιμές για τα Sensitivity, όπου η Μέθοδος Α σημείωσε 98,9% και η Μέθοδος Β 97,1%, παρατηρείται, ότι η προσέγγιση με τη Μέθοδο Α έχει λίγο υψηλότερο Sensitivity, το γεγονός αυτό εξηγείται ως η Μέθοδος Α καταγράφει μεγαλύτερη ευστοχία στον εντοπισμό των ακραίων οδηγικών συμβάντων από τη Μέθοδο Β. Το ποσοστό των συμβάντων στο δείγμα είναι πολύ μικρότερο για τη Μέθοδο Β, 0,2%, σε σχέση με τη Μέθοδο Α, 4%. Αντίθετα, με παρόμοια λογική εξηγείται ότι η Μέθοδος Β σημειώνει υψηλότερο Specificity, 98,2%, από τη Μέθοδο Α, 96,6%, όπου η κυριαρχία της φυσιολογικής οδήγησης για τη Μέθοδο Β είναι υψηλότερη από τη Μέθοδο Α. Συνεπώς, εξαιτίας του ποσοστού οδηγικών συμβάντων καταλήγει το συμπέρασμα ότι Μέθοδος Α πλεονεκτεί στον εντοπισμό της επικίνδυνης οδηγικής συμπεριφοράς, ενώ η Μέθοδος Β μπορεί να αναγνωρίσει ευκολότερα την φυσιολογική οδήγηση. Εξετάζοντας τα σφάλματα Error Type I, δηλαδή τη λανθασμένη ταξινόμηση των οδηγικών συμβάντων στην πραγματικότητα σε φυσιολογική οδήγηση, και Error Type II, τη λάθος ταξινόμηση πραγματικής κανονικής οδήγησης σε οδηγικό γεγονός, και τα δύο μοντέλα έχουν χαμηλές αποδεκτές τιμές. Για τη Μέθοδο Α καταγράφηκε Error Type I, 3,4%, και Error Type II, 1,1%. Αντίστοιχα, η Μέθοδος Β σημείωσε για Error Type I, 1,8% και για Error Type II, 2,7%. Σχολιάζοντας τις τιμές του Negative Predictive Value για τις δύο προσεγγίσεις, το ποσοστό των παρατηρήσεων κανονικής οδήγησης, που προβλέφθηκαν σωστά, σε σχέση με το σύνολο των προβλεπόμενων παρατηρήσεων φυσιολογικής οδήγησης, και τα δύο μοντέλα, οι τιμές πλησιάζουν τη βέλτιστη περίπτωση 1, επισημαίνοντας την κυριαρχία της κανονικής οδήγησης.

Όσον αφορά στο Precision, δηλαδή το ποσοστό της σωστής πρόβλεψης των οδηγικών συμβάντων σε σχέση με το σύνολο των προβλεπόμενων οδηγικών συμβάντων, η Μέθοδος Α κατέγραψε 57,1% και η Μέθοδος Β 10,1%. Το γεγονός των χαμηλών τιμών του Precision έγκειται στο μικρό αριθμό συμβάντων σε σχέση με τη φυσιολογική οδήγηση. Η Μέθοδος Α επικρατεί καθώς σημειώνει πολύ υψηλότερο ποσοστό σε σχέση με τη μέθοδο Β. Η γενική αξιολόγηση των μοντέλων μέσω της καμπύλης ROC, Sensitivity και 1-Specificity, παρουσιάζει μέσω του υπολογισμού του εμβαδού του χωρίου εντός της καμπύλης AUC, ότι και οι δύο μέθοδοι είναι αρκετά αποδοτικοί, σημείωσαν, λοιπόν, 0,978 και 0,976, η Μέθοδος Α και Β, αντίστοιχα.

Καταλήγοντας από την αξιολόγηση των στατιστικών μέτρων για τις δύο μεθόδους, η Μέθοδος Β είναι ικανοποιητικά ακριβής στον εντοπισμό των οδηγικών συμβάντων και της κανονικής οδήγησης, όμως η πολύ χαμηλή τιμή του Precision υποδηλώνει ότι η προσέγγιση είναι πολύ επεικής στον χαρακτηρισμό μιας παρατήρησης σε οδηγικό γεγονός. Οι προβλεπόμενες παρατηρήσεις επικίνδυνων οδηγικών χειρισμών είναι πολύ περισσότερες σε σχέση με τις πραγματικές. Επομένως, η Μέθοδος Β χαρακτηρίζεται με πολύ χαμηλή αυστηρότητα στον καθορισμό γεγονότων. Στο επόμενο κεφάλαιο θα προταθούν τρόποι βελτίωσης της μεθόδου, ώστε να αντιμετωπίσει τα μειονεκτήματά της. Η Μέθοδος Α σημείωσε χαμηλότερη ευστοχία σε σχέση με Μέθοδο Β, βέβαια αρκετά υψηλή, 90%. Το πρόβλημα των περισσότερων προβλεπόμενων παρατηρήσεων είναι πολύ μικρότερο, επομένως η προσέγγιση χαρακτηρίζεται πιο κοντά στην πραγματικότητα και στον εντοπισμό των οδηγικών καταστάσεων. Αποτελεί μια ολοκληρωμένη μέθοδο αναγνώρισης της οδηγικής συμπεριφοράς.

Η σύνοψη των μέτρων σύγκρισης των δύο μεθοδολογιών παρουσιάζεται στον Πίνακα 4.19.

Πίνακας 4.19: Στατιστικά μέτρα για Μέθοδο Α και Μέθοδο Β.

	Μέθοδος Α	Μέθοδος Β
Sensitivity (TPR)	0,989	0,971
Specificity (TNR)	0,966	0,982
Error Type II (FNR)	0,011	0,027
Error Type I (FPR)	0,034	0,018
Accuracy (ACC)	0,967	0,982
Classification Error	0,033	0,018
Neg.Pred.Value (NPV)	0,999	0,999
Precision (PPV)	0,571	0,101
FalseDisc.Rate (FDR)	0,429	0,899
FalseOm.Rate (FOR)	0,001	0,001
F1	0,724	0,182
AUC	0,978	0,976

Το δεύτερο κριτήριο, αποτελεί την ποιοτική αξιολόγηση των μεθόδων. Αρχικά, θα εξετασθεί η απλότητα των μεθόδων. Η Μέθοδος Α προσεγγίζει το ζήτημα με αυξημένη πολυπλοκότητα σε σχέση με τη μέθοδο Β. Η Μέθοδος Α, στο αρχικό στάδιο με τη χρήση του αλγόριθμου SHED, ξεχωρίζει τις παρατηρήσεις και τις κατηγοριοποιεί σε φυσιολογικές συνθήκες και σε πιθανές επικίνδυνες καταστάσεις. Οι πιθανές επικίνδυνες καταστάσεις εισάγονται στο μοντέλο πρόβλεψης του νευρωνικού δικτύου και ταξινομούνται σε απότομες επιταχύνσεις, απότομες επιβραδύνσεις και σε κανονική οδήγηση. Η Μέθοδος Β κρίνεται πιο απλή, αφού διαχειρίζεται το σύνολο των παρατηρήσεων, χωρίς να τις διαχωρίζει σε πρώτο στάδιο, και καταγράφει τη μετρική απόσταση Mahalanobis των επιταχύνσεων των παρατηρήσεων. Στη συνέχεια, τα δεδομένα εισάγονται στο νευρωνικό δίκτυο για να γίνει η ταξινόμηση. Επόμενα, θα εξετασθεί ο χρόνος ολοκλήρωσης των μεθόδων. Γενικά, η εκπαίδευση των νευρωνικών δικτύων είναι μια χρονοβόρα διαδικασία. Με τη Μέθοδο Α τα δεδομένα, που εισάγονται είναι πολύ λιγότερα, αφού έχει πραγματοποιηθεί ο διαχωρισμός σε πιθανά οδηγικά γεγονότα, σε σχέση με τη Μέθοδο Β, που εισάγεται το σύνολο των δεδομένων. Με τη Μέθοδο Α οι υπολογισμοί πραγματοποιούνται ταχύτερα από τη Μέθοδο Β, από το οποίο συνεπάγεται, επιπλέον, χαμηλότερη υπολογιστική ισχύ και κατανάλωση ενέργειας ενός ηλεκτρονικού υπολογιστή.

5. ΣΥΜΠΕΡΑΣΜΑΤΑ

5.1. ΓΕΝΙΚΑ

Σκοπός της παρούσας διπλωματικής ήταν η δημιουργία ενός αξιόπιστου μοντέλου αναγνώρισης των επικίνδυνων οδηγικών συμβάντων με χρήση μηχανικής μάθησης. Το πρόβλημα, που διαχειρίστηκε η παρούσα διπλωματική εργασία, είναι ο εντοπισμός των απότομων επιταχύνσεων και επιβραδύνσεων στη διάρκεια των ταξιδιών ενός οδηγού. Βασικό στάδιο, είναι η αναγνώριση της σημαντικότητας του εντοπισμού των ακραίων οδηγικών συμβάντων, καθώς επιδρούν έντονα στην ασφάλεια των μετακινήσεων, στη δημιουργία φιλικού κλίματος προς το περιβάλλον, σε οικονομικούς παράγοντες, όπως το κόστος ατυχημάτων. Η αναγνώριση των επικίνδυνων γεγονότων, αποτελεί βασικό κριτήριο καθορισμού της οδηγικής συμπεριφοράς. Τα ταξίδια των οδηγών με έντονα φαινόμενα απότομων επιταχύνσεων και επιβραδύνσεων υποδηλώνουν επιθετική οδήγηση.

Το αρχικό στάδιο εργασιών αποτελείτο από τη συλλογή και την απαραίτητη επεξεργασία των δεδομένων. Εκμεταλλευόμενοι το αναπτυσσόμενο φαινόμενο του πληθοπορισμού και της εκτεταμένης χρησιμοποίησης των έξυπνων κινητών, σε συνδυασμό διευρύνονται οι υπάρχοντες περιορισμοί στην συλλογή δεδομένων. Επομένως, συλλέχθηκαν δεδομένα αποκλειστικά από έξυπνα κινητά, τα οποία επεξεργάστηκαν κατάλληλα, για να εισαχθούν στις μεθόδους εντοπισμού. Η επεξεργασία είναι μια απαραίτητη διαδικασία, διότι τα αποτελέσματα εξαρτώνται από τα δεδομένα εισόδου, συνεπώς από αλλοιωμένα δεδομένα προκύπτουν λανθασμένα αποτελέσματα.

Για να επιτευχθεί η δημιουργία ενός αξιόπιστου μοντέλου για την ανίχνευση των επικίνδυνων οδηγικών καταστάσεων, αναπτύχθηκαν δύο προσεγγίσεις, οι οποίες αξιολογήθηκαν και συγκρίθηκαν μεταξύ τους. Η βασική ιδέα της πρώτης προσέγγισης είναι η ανάλυση των δεδομένων σε δύο στάδια, ένα για τον προσδιορισμό των πιθανών επικίνδυνων οδηγικών συμβάντων και το άλλο για το καθορισμό των γεγονότων, αλλά και του τύπου τους. Αρχικά, με βάση τη βιβλιογραφική ανασκόπηση επιλέχθηκε ένας στατιστικός αλγόριθμος εντοπισμού ακραίων παρατηρήσεων. Τα δεδομένα απαίτησαν μια περαιτέρω επεξεργασία για την εφαρμογή του αλγορίθμου, τον καθορισμό της περιοδικότητας των παρατηρήσεων. Τα αποτελέσματα του κρίθηκαν ως πιθανές ακραίες οδηγικές καταστάσεις και συγκεκριμένα η μέθοδος κατέγραψε ακρίβεια 93%. Το δεύτερο στάδιο αναλαμβάνει τον καθορισμό των πιθανών επικίνδυνων οδηγικών συμπεριφορών σε συμβάντα οδήγησης, απότομη επιτάχυνση και επιβράδυνση. Για το

σκοπό αυτό αναπτύχθηκε ένα νευρωνικό δίκτυο ως μοντέλο πρόβλεψης των οδηγικών καταστάσεων. Το δίκτυο για δεδομένα εισόδου έλαβε τα χαρακτηριστικά των διαφορών ταχύτητας, για το αισθητά μειωμένο συνολικό δείγμα. Το δείγμα, με το οποίο εκπαιδεύτηκε το νευρωνικό δίκτυο, είναι ένα μη ισορροπημένο δείγμα, καθώς το σύνολο της φυσιολογικής οδήγησης κυριαρχεί σε σχέση με τον αριθμό των πραγματικών γεγονότων, για το λόγο αυτό εφαρμόζεται η μέθοδος της υποδειγματοληψίας. Αφού, καθοριστεί η δομή και οι παράμετροι εκπαίδευσης του δικτύου, αναζητείται το αποδοτικότερο μοντέλο πρόβλεψης, που θα προκύψει από την αξιοποίηση των στατιστικών μέτρων της ταξινόμησης. Για την πρώτη μέθοδο η ακρίβεια σημειώθηκε 96,7 %. Συνεπώς η συνολική ακρίβεια εκτιμάται μεγαλύτερη του 90%. Συνεπάγεται η δημιουργία μιας ολοκληρωμένης μεθόδου εντοπισμού των οδηγικών γεγονότων, που έρχεται να συμπληρώσει της υπάρχουσες μεθόδους, σύμφωνα με τη βιβλιογραφία.

Η δεύτερη μέθοδος προσέγγισε το ζήτημα με πιο καθολικό τρόπο. Ελέγχθηκε η ικανότητα εντοπισμού για το σύνολο των δεδομένων, χωρίς να προηγείται ο διαχωρισμός της πιθανής επικίνδυνης οδήγησης. Για το σκοπό αυτό, αποφασίστηκε να υπολογίζεται η μετρική απόσταση Mahalanobis των επιταχύνσεων, που συσχετίζει την παρατήρηση με τις υπόλοιπες. Στη συνέχεια, χρησιμοποιώντας τα χαρακτηριστικά της διαφοράς ταχύτητας και τη μετρική απόσταση, εκπαιδεύτηκε το νευρωνικό δίκτυο. Η δεύτερη μέθοδος κατέγραψε ακρίβεια 98%.

5.2. ΒΑΣΙΚΑ ΣΥΜΠΕΡΑΣΜΑΤΑ

Τα δύο μοντέλα αξιολογούνται αποδοτικά για τον χαρακτηρισμό της οδηγικής συμπεριφοράς. Και τα δυο μοντέλα καταγράφουν ευαισθησία στον αριθμό των προβλεπόμενων οδηγικών συμβάντων, όπου είναι μεγαλύτερος από τα πραγματικά. Το πρόβλημα είναι εντονότερο για τη δεύτερη προσέγγιση, όπου η μεθοδολογία πρόβλεψης οδηγικών γεγονότων χαρακτηρίζεται λιγότερο αυστηρή σε σχέση με την πραγματικότητα. Στην πρώτη προσέγγιση το ζήτημα αντιμετωπίζεται σε ικανοποιητικό βαθμό, με συνέπεια τη δημιουργία ενός ολοκληρωμένου ευφυούς συστήματος εντοπισμού επικίνδυνων οδηγικών γεγονότων. Για τον καθορισμό του αποδοτικότερου μοντέλου, τα δυο μοντέλα αξιολογούνται και ως προς τα ποιοτικά χαρακτηριστικά τους.

Τα συμπεράσματα, στα οποία καταλήγει η παρούσα διπλωματική, είναι αποτέλεσμα της εκτίμησης των αποφάσεων του Μηχανικού και της ανάλυσης των μοντέλων πρόβλεψης.

Η παροχή των δεδομένων συνίσταται να πραγματοποιείται από έξυπνα κινητά. Η χρήση των έξυπνων συσκευών είναι ευρέως διαδεδομένη. Στις ανεπτυγμένες χώρες, η πλειονότητα του πληθυσμού είναι κάτοχοι smartphone. Παράλληλα με τη ραγδαία ανάπτυξη του πληθοπορισμού, οι ακαδημαϊκές έρευνες και οι εμπορικοί σκοποί πρέπει να εκσυγχρονισθούν με τις νέες τεχνολογικές τάσεις, εκμεταλλευόμενοι τα

πλεονεκτήματα τους. Ο όγκος των διαθέσιμων πληροφοριών και η ευκολία απόκτησης τους αυξάνεται έντονα. Βέβαια, απαιτείται η εμπεριστατωμένη ανάλυση και επεξεργασία των δεδομένων, πριν αξιοποιηθούν, η οποία εξαρτάται άμεσα από τη φύση του ζητήματος της εκάστοτε διερεύνησης.

Η αντιμετώπιση των ζητημάτων εξαρτάται σε μεγάλο βαθμό από τη εκτίμηση του Μηχανικού (Feature Engineering). Στο ζήτημα του εντοπισμού των ακραίων οδηγικών γεγονότων, επιλέχθηκε μια μέθοδος να διαχωρίζει σε πρώτο στάδιο τις πιθανές επικίνδυνες οδηγικές συμπεριφορές και στην συνέχεια να οριστικοποιεί την ύπαρξη συμβάντων, αποτέλεσμα να μειώνεται ο όγκος του δείγματος, χωρίς να αλλοιώνονται τα χαρακτηριστικά του, που απασχολούν. Αξιόπιστες τεχνικές για τον εντοπισμό των πιθανών συμβάντων είναι οι μέθοδοι εντοπισμού ακραίων τιμών (Outlier Detection). Μια άλλη μέθοδος είναι η καταγραφή της μετρικής απόστασης, που χαρακτηρίζει και συσχετίζει τα δεδομένα. Στην παρούσα διερεύνηση, αποφασίσθηκε η καταγραφή της απόστασης Mahalanobis, μια απλοϊκή μετρική απόσταση, που λαμβάνει υπόψη την συνδιακύμανση, είναι ικανή να αντιπροσωπεύσει τη συσχέτιση μεταξύ των παρατηρήσεων. Βασική προϋπόθεση για την επίλυση ζητημάτων είναι η κατανόηση της φύσης του ζητήματος. Ο ερευνητής ανασκοπώντας την υπάρχουσα βιβλιογραφία, πρέπει να εκτιμήσει με ακρίβεια το ζήτημα, και με βάση την εμπειρία και τις γνώσεις, για να προσδώσει μια αποδοτική και εφαρμόσιμη λύση.

Η επιλογή των κατάλληλων παραμέτρων αποτελεί πολύ σημαντικό κομμάτι της εκτίμησης του Μηχανικού. Για την επιλογή τους μπορούν να χρησιμοποιηθούν στατιστικές μέθοδοι, που εκφράζουν τη σημαντικότητα των μεταβλητών στα αποτελέσματα. Μια απλή μέθοδος είναι η οπτικοποίηση των δεδομένων. Με την οπτικοποίηση των δεδομένων ο ερευνητής αντιλαμβάνεται καλύτερα το περιβάλλον εργασίας, στο οποίο συμβαίνουν τα φαινόμενα, που αναζητά. Ακόμη, η οπτικοποίηση των δεδομένων βοηθάει σημαντικά και στην κατανόηση των ενδιαφερόμενων για την φύση του προβλήματος. Στο ζήτημα εντοπισμού των απότομων επιταχύνσεων και επιβραδύνσεων εκτιμάται ότι την οδηγική συμπεριφορά εκφράζουν τα δεδομένα των επιταχύνσεων, και για τους τρεις άξονες, και της ταχύτητας. Τα δεδομένα της ταχύτητας καταγράφονται από τον αισθητήρα GPS του έξυπνου κινητού και περιέχουν θόρυβο, κυρίως λόγω της πολλαπλής διαδρομής του σήματος στα σύγχρονα αστικά κέντρα ή από το γεγονός ότι επικρατούν κακές καιρικές συνθήκες στην περιοχή, επομένως συνίσταται επεξεργασία στα δεδομένα της ταχύτητας.

Αξιοπιστία και συνέπεια σε ακριβή αποτελέσματα δίνουν τα Νευρωνικά Δίκτυα. Για τη δημιουργία αποδοτικών μοντέλων πρόβλεψης χρησιμοποιώντας νευρωνικά δίκτυα θα πρέπει να καθορισθεί ο κατάλληλος συνδυασμός δομής και παραμέτρων εκπαίδευσης. Η διαδικασία βελτιστοποίησης των μοντέλων καθορίζεται από το πιο μοντέλο προσδίδει την μεγαλύτερη ακρίβεια. Γενικά, η διαδικασία εκπαίδευσης και εκτίμησης του αποτελεσματικότερου μοντέλου είναι μια δύσκολη διαδικασία. Συγκεκριμένα, εκτιμήθηκε για τη δομή των μοντέλων εντοπισμού επικίνδυνων οδηγικών συμπεριφορών, ότι δεν απαιτείται μεγάλος αριθμός κρυφών επιπέδων και νευρώνων, που τα αποτελούν. Για δυο κρυφά επίπεδα και οι νευρώνες να κυμαίνονται από τέσσερις έως οχτώ, το δίκτυο αποδίδει ικανοποιητικά, για μεγαλύτερες δομές το δίκτυο δεν βελτιώνεται και αυξάνεται αισθητά ο χρόνος εκπαίδευσης. Ακόμη, για

συνάρτηση της λειτουργίας ενεργοποίησης συνίσταται αρχικά η επιλογή της ReLU και στη συνέχεια της Tanh. Η αξιολόγηση της εκπαίδευσης των δικτύων, στο συγκεκριμένο πείραμα, έδειξε ότι μέχρι 10 εποχές το νευρωνικό δίκτυο έχει εκπαιδευτεί αρκετά. Ακόμη, συνίσταται η εφαρμογή των προσαρμοστικών μεθόδων στα νευρωνικά δίκτυα, αφού μειώνουν σημαντικά το χρόνο εκπαίδευσης και διευκολύνουν τους υπολογισμούς του πειράματος. Όσο μειώνεται ο προσαρμοστικός μειωτικός ρυθμός εκπαίδευσης, το δίκτυο μαθαίνει καλύτερα σε βάρος του χρόνου υπολογισμών, για το πείραμα οι τιμές από 0,85 έως 0,9, έχουν ικανοποιητικά αποτελέσματα και σύντομα. Οι υπόλοιποι παράμετροι συστηματοποίησης συνίσταται να επιλέγονται αρκετά χαμηλά για να εκπαιδευτεί ένα εύστοχο δίκτυο, οι τιμές κυμαίνονται από 0 έως 10^{-6} . Τέλος, πρέπει να καθορισθεί η συνάρτηση κόστους του δικτύου, η οποία επιλέγεται να είναι η Cross Entropy.

Στα δεδομένα, που περιγράφουν την οδηγική συμπεριφορά, κυριαρχεί η φυσιολογική οδήγηση. Οι παρατηρήσεις οδηγικών συμβάντων είναι πολύ λιγότερες στο σύνολο του δείγματος, συγκεκριμένα περίπου 0,2%. Το γεγονός αυτό χαρακτηρίζει το δείγμα ανομοιογενές και πρέπει τα μη ισορροπημένα δεδομένα να προσαρμοστούν. Έτσι συνίσταται σε μη ισορροπημένα δείγματα να εφαρμόζεται η μέθοδος της υποδειγματοληψίας. Θα πρέπει να δημιουργηθεί ένα ισορροπημένο σύνολο, για το οποίο επιβάλλεται το ποσοστό των οδηγικών συμβάντων στο σύνολο του δείγματος. Συγκεκριμένα, για το πείραμα το ποσοστό αυτό εκτιμήθηκε 30%. Πρέπει να επισημανθεί ότι το δίκτυο εξαρτάται από τη δομή, τις παραμέτρους εκπαίδευσης, τα ποσοστά συνόλων εκπαίδευσης, επικυρώσεις, δοκιμής, και από το ποσοστό υποδειγματοληψίας, επομένως πρέπει να αναζητείται ο κατάλληλος συνδυασμός τους, που κάνει το δίκτυο αποδοτικότερο, με τη χρήση δοκίμων. Με το νέο σύνολο είναι δυνατό να εκπαιδευτεί το μοντέλο πρόβλεψης. Βέβαια, χρειάζεται προσοχή για την δοκιμή του μοντέλου πρόβλεψης, τα δεδομένα δοκιμής πρέπει να ανταποκρίνονται στη γενίκευση της πραγματικότητας, επομένως στα δεδομένα δοκιμής δεν εφαρμόζεται υποδειγματοληψία.

Για την επιλογή της μεθόδου υλοποίησης θα πρέπει να λαμβάνονται υπόψη και τα ποιοτικά χαρακτηριστικά της μεθόδου. Τα ποιοτικά χαρακτηριστικά είναι αποτέλεσμα της εκτίμησης του ερευνητή. Ο καθορισμός αμερόληπτων χαρακτηριστικών είναι μια δύσκολη διαδικασία, και απαιτεί προσοχή. Στη συγκεκριμένη έρευνα για την αξιολόγηση των μεθόδων εντοπισμού ως ποιοτικά χαρακτηριστικά χρησιμοποιούνται η απλότητα των μεθόδων, γενικά προτιμώνται απλές μέθοδοι, καθώς απαιτείται μειωμένη υπολογιστική ισχύ, και κατά συνέπεια κατανάλωση ενέργειας. Βασική προϋπόθεση για την αξιολόγηση των ποιοτικών χαρακτηριστικών είναι τα μοντέλα πρόβλεψης από άποψη στατιστικής αξιολόγησης να κρίνονται αποδοτικά, αλλιώς δεν έχει νόημα να αξιολογηθεί ένα μοντέλο μη αποδοτικό, για τα ποιοτικά χαρακτηριστικά του. Η επιλογή των ποιοτικών χαρακτηριστικών εξαρτάται από την εκτίμηση του ερευνητή, και είναι μια διαδικασία, που απαιτεί ιδιαίτερη προσοχή, καθώς τα χαρακτηριστικά πρέπει να είναι αμερόληπτα και να εκφράζουν το εκάστοτε πρόβλημα.

Από τα συμπεράσματα, που προέκυψαν από την ανάλυση του πειράματος, μπορούν να προκύψουν οφέλη σε διάφορους τομείς. Είναι προφανές ότι οι ασφαλιστικές εταιρίες και ασφαλιστικοί οργανισμοί μπορούν να αξιοποιήσουν τη γνώση της ύπαρξης

οδηγικών συμβάντων. Συμπληρώνοντας τα προγράμματα UBI και το PAYD. Τα αποτελέσματα μπορούν να εξυπηρετήσουν αρκετούς σκοπούς, όπως η βαθμολόγηση των οδηγών, με σκοπό την επιβράβευση των καλών οδηγών, στην ουσία μπορούν να προσαρμόσουν την τιμολόγηση των ασφαλιστρών με κριτήριο την επιθετική οδήγηση, επιβραβεύοντας τους συνεπείς οδηγούς στην φυσιολογική οδήγηση.

Ακόμα, οι εταιρίες, που διαθέτουν στόλους οχημάτων προς ενοικίαση, μπορούν να επωφεληθούν παρακολουθώντας την οδηγική συμπεριφορά των πελατών τους. Τα δεδομένα είναι πολύ χρήσιμα, καθώς οι εταιρίες δύναται να γνωρίζουν την μηχανολογική καταπόνηση, που υφίσταται ο στόλος οχημάτων τους. Για παράδειγμα, με την επιβράβευση της σωστής οδηγικής συμπεριφοράς στην τιμολόγηση, έχει συνέπεια ο στόλος οχημάτων να απαιτεί μικρότερη συντήρηση και τα οικονομικά οφέλη της εταιρίας αυξάνονται.

Οι περισσότερες εταιρίες εμπορίου, στο πλαίσιο του ανταγωνισμού, διαθέτουν στους πωλητές εταιρικά οχήματα. Η καταγραφή της οδηγικής συμπεριφοράς προσφέρει χρήσιμα στοιχεία στις εταιρίες, για την οικονομική διαχείριση και τη διαχείριση του προσωπικού. Στις εταιρίες παρέχεται η γνώση της συνέπειας των συναντήσεων και ακόμη της ψυχολογικής κατάστασης του πωλητή. Για παράδειγμα, εάν ο πωλητής κατά τη διάρκεια ενός ταξιδιού για μια επαγγελματική συνάντηση σημειώσει αρκετά συμβάντα επιταχύνσεων και επιβραδύνσεων, συνεπάγεται μια επιθετική συμπεριφορά, πριν το επαγγελματικό ραντεβού.

Τα συστήματα αναγνώρισης οδηγικής συμπεριφοράς μπορούν να προσφέρουν ενίσχυση στο κλάδο του εμπορίου των μεταχειρισμένων οχημάτων. Αυτό συνεπάγεται από ένα επιπλέον χαρακτηριστικό της κατάστασης του οχήματος. Ένα όχημα, το οποίο κατά τη διάρκεια χρησιμοποίησης του έχει αρκετά οδηγικά συμβάντα ενδέχεται να βρίσκεται σε χειρότερη μηχανολογική κατάσταση από ένα με πολύ λιγότερα οδηγικά συμβάντα.

Η καταγραφή της οδηγικής συμπεριφοράς, και κατά συνέπεια των οδηγικών συμβάντων, παρέχει χρήσιμες πληροφορίες για την πρόκληση ατυχημάτων στις αρμόδιες αρχές. Αποτελέσματα της αξιοποίησης των πληροφοριών είναι η έγκαιρη επέμβαση του ασθενοφόρου σε περίπτωση ατυχήματος, όπως και η προειδοποίηση των οδηγών για την επερχόμενη οδηγική κατάσταση, ώστε να μην αιφνιδιασθούν.

Ο εντοπισμός των επικίνδυνων οδηγικών καταστάσεων συνεπάγεται άμεσα στον καθορισμό της επιθετικής οδηγικής συμπεριφοράς. Η αναγνώριση της επιθετικής οδήγησης συμβάλει για ακαδημαϊκούς σκοπούς, διευρύνοντας τις έρευνες. Τα αποτελέσματα χρησιμοποιούνται από διάφορες έρευνες και αξιοποιούνται, με σκοπό την εξαγωγή των απαραίτητων συμπερασμάτων.

Τέλος, σημαντική είναι η έννοια του εντοπισμού των οδηγικών συμβάντων στη διαχείριση της κυκλοφορίας. Οι αρχές γνωρίζοντας τις οδηγικές συμπεριφορές μπορούν να επιβάλλουν αποδοτικότερα την τάξη στις συγκοινωνίες, αποσκοπώντας στη εύρυθμη λειτουργία και την αύξηση της ασφάλειας των μεταφορών.

5.3. ΠΕΡΙΟΡΙΣΜΟΙ ΚΑΙ ΠΡΟΤΑΣΕΙΣ ΓΙΑ ΠΕΡΑΙΤΕΡΩ ΕΡΕΥΝΑ

Σχετικά, με τη μεθοδολογία, η εκτίμηση του μηχανικού είναι αυτή, που καθορίζει τη ροή των εργασιών και την επιλογή των κατάλληλων μεθοδολογιών. Στη παρούσα εργασία εκτιμήθηκε και αποδείχθηκε η αποδοτικότητα των συγκεκριμένων επιλογών, χωρίς αυτό να σημαίνει ότι οι υπόλοιπες μέθοδοι μειονεκτούν. Με αυτή τη λογική, θα μπορούσε να ακολουθηθεί μια διαφορετική ροή εργασιών, όπως και να επιλεγούν διαφορετικές μεθοδολογικές προσεγγίσεις για τον εντοπισμό των επικίνδυνων οδηγικών καταστάσεων. Η βιβλιογραφία παρέχει μια πληθώρα μεθοδολογικών προσεγγίσεων όσο για το κομμάτι του εντοπισμού των ακραίων παρατηρήσεων, όσο και στην επιλογή των μοντέλων πρόβλεψης με χρήση μηχανικής μάθησης. Επίσης, ο εμπλουτισμός των χαρακτηριστικών, που καθορίζουν την οδηγική συμπεριφορά ενδέχεται να βελτιώσει τα αποτελέσματα. Τα έξυπνα κινητά διαθέτουν μια πληθώρα αισθητήρων προς αξιοποίηση, όπως οι πληροφορίες από το γυροσκόπιο και το μικρόφωνο. Επιπλέον, η χρήση κάμερας μπορεί να προσφέρει χρήσιμες πληροφορίες για την αναγνώριση των οδηγικών συμβάντων. Στη συνέχεια θα προταθούν έρευνες, σχετικές με τη θεματολογία για περαιτέρω έρευνα.

Αναφερόμενοι στον εντοπισμό συμβάντων, η έννοια μπορεί να διευρυνθεί. Στην εργασία ορίστηκε ως οδηγικό συμβάν η απότομη επιτάχυνση και επιβράδυνση. Ακόμη, συμπληρώνοντας την έννοια του συμβάντος προτείνεται να διερευνηθεί η επικίνδυνη οδηγική κατάσταση των απότομων ελιγμών. Οι ελιγμοί, όταν αυτοί καταγράφονται μπορούν να αποτελέσουν ένα επιπλέον κριτήριο χαρακτηρισμού της επιθετικής οδηγικής συμπεριφοράς. Σύμφωνα με τη βιβλιογραφία εντοπίστηκε αδυναμία καταγραφής του φαινομένου. Για το σκοπό αυτό προτείνεται, επίσης, η διεξαγωγή πειράματος, ώστε να καταγραφεί το φαινόμενο πιο αντιπροσωπευτικά. Για παράδειγμα, η απότομη αλλαγή ταχύτητας πρέπει να εκφραστεί συνάρτηση της ταχύτητας. Σκεπτόμενοι το παράδειγμα της στάθμευσης του οχήματος, όπου μια απότομη αλλαγή για πολύ μικρή ταχύτητα, δεν πρέπει να θεωρείται απότομος ελιγμός.

Η συγκεκριμένη έρευνα τονίζει τα εξατομικευμένα χαρακτηριστικά της οδηγικής συμπεριφοράς. Το γεγονός, που ξεχωρίζει μια κατάσταση από την κανονικότητα είναι σχετικό. Το ζήτημα μπορεί να αντιμετωπίζεται εξατομικευμένα με σκοπό τη δημιουργία του κατάλληλου μοντέλου εντοπισμού ακραίων συμπεριφορών για τον εκάστοτε οδηγό. Προτείνεται λοιπόν η διεύρυνση της. Αυτό πραγματοποιείται είτε αντιμετωπίζοντας περισσότερους οδηγούς εξατομικευμένα, είτε δημιουργώντας μια ομαδοποίηση των οδηγών, ανάλογα με τα κοινά χαρακτηριστικά τους, για τον εντοπισμό των επικίνδυνων καταστάσεων.

Ένα σημαντικό ζήτημα, που δημιουργήσε έντονο προβληματισμό στην παρούσα εργασία είναι η αξιοπιστία των αποτελεσμάτων της πραγματικότητας. Στις συνήθειες περιπτώσεις, για λόγους οικονομίας και χρόνου, η καταγραφή της πραγματικότητας γίνεται με αποδεδειγμένες επικρατούσες μεθόδους. Για την καταγραφή της πραγματικότητας χρησιμοποιούνται συστήματα εντοπισμού, με δεδομένα από αξιόπιστους αισθητήρες εντός του οχήματος. Προτείνεται, λοιπόν, ο συνδυασμός των

μεθόδων καταγραφής της πραγματικότητας. Για τη δημιουργία του μοντέλου η επιτόπου καταγραφή θεωρείται η πιο αξιόπιστη, στη συνέχεια το μοντέλο, που δημιουργείται, με τη χρήση της μηχανικής μάθησης, να βελτιώνεται συνεχώς με τα δεδομένα από τους αισθητήρες.

Αξιοποιώντας τα δεδομένα των επιταχύνσεων δύναται να γίνει η καταγραφή της αξιολόγησης των οδοστρωμάτων. Εντοπίζοντας, λοιπόν, με παρόμοια μεθοδολογία, με αυτή που ακολουθήθηκε, τις ακραίες παρατηρήσεις στον κατάκορφο άξονα, μπορούν να εντοπισθούν οι έντονες διαταράξεις του οδοστρώματος. Αποτέλεσμα, εντοπίζοντας τα σημεία στο οδόστρωμα, όπου οι διακυμάνσεις είναι έντονες, εκτιμάται η πιθανή κακή κατάσταση του οδοστρώματος, με την εμφάνιση λακκουβών.

Διευρύνοντας το πεδίο έρευνας, θα μπορούσε να υπάρξει μια ενιαία ερευνά, που να αξιολογεί τη γενική οδηγική συμπεριφορά διαφόρων κοινωνικών ομάδων, ακόμα και κρατών. Ο εντοπισμός διαφορετικών οδηγικών συμπεριφορών συνάρτηση της διαφορετικότητας των χαρακτηριστικών και του περιβάλλοντος, για παράδειγμα για διαφορετικές ηλικίες ή διαφορετικές αστικές περιοχές κτλ., εκτιμάται ότι θα προσδώσει πολύ χρήσιμα συμπεράσματα για την αξιολόγηση των προβλημάτων και την αντιμετώπιση τους.

Παραπάνω έγινε αναφορά σε ερευνητικές προτάσεις με θεματολογία σχετική με το κλάδο των μεταφορών. Αρκετές άλλες επιστήμες μπορούν να αντλήσουν χρήσιμες πληροφορίες από τη αναγνώριση της οδηγικής πολιτικής. Η οδηγική συμπεριφορά συνδέεται άμεσα με την ψυχολογική κατάσταση του οδηγού. Ένας αγχωμένος οδηγός θα δημιουργήσει περισσότερες ανωμαλίες κατά την οδηγική του συμπεριφορά.

6. ΒΙΒΛΙΟΓΡΑΦΙΑ

- Alanezi, K., & Mishra, S. (2015). Design, implementation and evaluation of a smartphone position discovery service for accurate context sensing. *Computers & Electrical Engineering*, 44, 307-323. <https://doi.org/10.1016/j.compeleceng.2015.01.015>
- Almazán, J., Bergasa, L., Yebes, J., Barea, R., & Arroyo, R. (2013). Full auto-calibration of a smartphone on board a vehicle using IMU and GPS embedded sensors. *2013 IEEE Intelligent Vehicles Symposium (IV)*. <https://doi.org/10.1109/IVS.2013.6629658>
- Analog Devices. Small, Low Power, 3-Axis $\pm 3g$ MEMS® reference. Retrieved 2/2018 from: <http://www.analog.com/media/en/technical-documentation/data-sheets/ADXL330.pdf>
- Baldwin, K., Duncan, D., & West, S. (2004). The Driver Monitor System: A Means of Assessing Driver Performance. In *Johns Hopkins APL technical digest*. 1-10. Retrieved 2/2018 from: <http://techdigest.jhuapl.edu/TD/td2503/Baldwin.pdf>
- Ben-Gal, I. (2005). Outlier Detection. In O. Mainon & L. Rockach (Eds). *Data Mining and Knowledge Discovery Handbook: A Complete Guide for Practitioners and Researchers*. Kluwer Academic Publishers.
- Bergasa, L., Almeria, D., Almazán, J., Yebes, J., & Arroyo, R. (2014). DriveSafe: An App for Alerting Inattentive Drivers and Scoring Driving Behaviors. *2014 IEEE, Intelligent Vehicles Symposium Proceedings*. <https://doi.org/10.1109/IVS.2014.6856461>
- Bhoraskar, R., Vankadhara, N., Raman, B., & Kulkarni, P. (2012). Wolverine: Traffic and Road Condition Estimation using Smartphone Sensors. *2012 Fourth International Conference on Communication Systems and Networks*. <https://doi.org/10.1109/COMSNETS.2012.6151382>
- Calabrese, F., Colonna, M., Lovisolo, P., Parata, D., & Ratti, C. (2011). Real-Time Monitoring Using Cell Phones: A Case Study in Rome. *IEEE Transactions on Intelligent Transportation Systems*, 12, 141-151. <https://doi.org/10.1109/TITS.2010.2074196>
- Chakravarty, T., Chowdhury, A., & Balamuralidhar, P. (2014). A Novel Approach To Improve Vehicle Speed Estimation Using Smartphone's INS/GPS Sensors. *Proceedings of the 8th International Conference on Sensing Technology*. Accessed 2/2018: <https://pdfs.semanticscholar.org/81b4/c64f9f795f18db436c10ed9350b1cd6e7bb2.pdf>
- Chandola, V., Banerjee, A., & Kumar, V. (2009). Anomaly Detection: A Survey. *Journal ACM Computing Surveys*, 44, Article 15. <https://doi.org/10.1145/1541880.1541882>

- Chowdhury, A., Chakravarty, & T., Balamuralidhar, & P. (2014). Estimating true speed of moving vehicle using smartphone-based GPS measurement. *2014 IEEE International Conference on Systems, Man, and Cybernetics*.
<https://doi.org/10.1109/SMC.2014.6974444>
- Cleveland, R., Cleveland, W., McRae, J., & Terpenning, I. (1990). STL: a seasonal-trend decomposition procedure based on loess). *Journal of official statistics*, 6, 3-33.
- Dai, J., Teng, J., Bai, X., Shen, Z., & Xuan, D. (2010). Mobile Phone Based Drunk Driving Detection). *2010 4th International Conference on-NO PERMISSIONS Pervasive Computing Technologies for Healthcare (Pervasive Health)*.
<https://doi.org/10.4108/ICST.PERVASIVEHEALTH2010.8901>
- De Vlieger, I., De Keukeleere, D., & Kretzschmar, G.G. (2000). Environmental effects of driving behaviour and congestion related to passenger cars. *Atmospheric Environment*, 4, 4649-4655. [https://doi.org/10.1016/S1352-2310\(00\)00217-X](https://doi.org/10.1016/S1352-2310(00)00217-X)
- Directorate-General for Mobility and Transport (European Commission). (2015). Employment in the EU transport sector. *EU publications*.
<https://dx.doi.org/10.2832/49571>
- Engelbrecht, J., Booysen, M., & Van Rooyen, G. (2014). Recognition of driving manoeuvres using smartphone-based inertial and GPS measurement, *Proceedings of the First International Conference on the use of Mobile Informations and Communication Technology (ICT) in Africa UMICTA 2014*
<https://dx.doi.org/10.13140/RG.2.1.4741.480>
- Eren, H., Makinist, S., Akin, E., & Yilmaz, A. (2012). Estimating Driving Behavior by a Smartphone. *2012 Intelligent Vehicles Symposium*.
<https://dx.doi.org/10.1109/IVS.2012.6232298>
- Eriksson, J., Girod, L., Hull, B., Newton, R., Madden, S., & Balakrishnan, H. (2008). The Pothole Patrol: Using a Mobile Sensor Network for Road Surface Monitoring. *MobiSys '08 Proceedings of the 6th international conference on Mobile systems, applications, and services*. 29-39. <https://dx.doi.org/10.1145/1378600.1378605>
- Estellés-Arolas, E., & González Ladrón-de-Guevara, F. (2012). Towards an integrated crowdsourcing definition. *Journal of Information Science*, 38, 189-200.
<https://doi.org/10.1177/0165551512437638>
- European Commission. (2017). EU transport in figures, Statistical Pocketbook 2017. *Mobility and Transport (European Commission)*. <https://ec.europa.eu/transport/facts-fundings/statistics/pocketbook-2017>
- European Commission. (2017). Συνδέοντας τους ευρωπαίους πολίτες και τις ευρωπαϊκές επιχειρήσεις. *EU publications*. <https://dx.doi.org/10.2775/13022>
- Fazeen, M., Gozick, B., Dantu, R., Bhukhiya, M., & Gonzalez, M., (2012). Safe Driving Using Mobile Phones. *IEEE Transactions on Intelligent Transportation Systems*, 13, 1462-1468. <https://doi.org/10.1109/TITS.2012.2187640>

- Ghose, A., Chowdhury, A., Chandel, V., Banerjee, T., & Chakravarty, T. (2016). An Enchanted Automated System for Evaluating Harsh Driving Using Smartphone Sensors. *Proceedings of the 17th International Conference on Distributed Computing and Networking*. <https://doi.org/10.1145/2833312.2849555>
- Hadi, A. (1994). A modification of a method for the detection of outliers in multivariate samples. *Journal of the Royal Statistical Society*, 56. <https://doi.org/10.2307/2345910>
- Handel, P., Skog, I., Wahlstorm, J., & Bonawiede, F. (2014). Insurance Telematics: Opportunities and Challenges with the Smartphone Solution. *IEEE Intelligent Transportation Systems Magazine*, 6, 57-70. <https://dx.doi.org/10.1109/MITS.2014.2343262>
- Hawkins, D. (1980). Identification of Outliers. *Chapman and Hall*.
- Hemminki, S., Nurmi, P., & Torkoma, S. (2013). Accelerometer-Based Transportation Mode Detection on Smartphones. *SenSys '13 Proceedings of the 11th ACM Conference on Embedded Networked Sensor Systems Article No. 13*. <https://doi.org/10.1145/2517351.2517367>
- Holt, G., Reinders, M., & Hendriks, E. (2007). Multi-dimensional dynamic time warping for gesture recognition. Retrieved 2/2018 from: https://www.researchgate.net/publication/228740947_Multi-dimensional_dynamic_time_warping_for_gesture_recognition
- Iversen, H., & Rundmo, T. (2002). Personality, risky driving and accident involvement among Norwegian drivers. *Personality and Individual Differences*, 33, 1251-1263. [https://doi.org/10.1016/S0191-8869\(02\)00010-7](https://doi.org/10.1016/S0191-8869(02)00010-7)
- Jeff Howe (2006). The Rise of Crowdsourcing. *Wired*. Accessed 2/2018: <https://www.wired.com/2006/06/crowds>
- Johnson, D., & Trivedi, M. (2011). Driving style recognition using a smartphone as a sensor platform. *2011 14th International IEEE Conference on Intelligent Transportation Systems*. <https://doi.org/10.1109/ITSC.2011.6083078>
- Johnson, R. (1992). Applied Multivariate Statistical Analysis. *Prentice Hall*.
- Kang, W., Nam, S., Han Y., & Lee, S. (2012). Improved Heading Estimation for Smartphone-Based Indoor Positioning Systems. *2012 IEEE 23rd International Symposium on Personal, Indoor and Mobile Radio Communications*. <https://doi.org/10.1109/PIMRC.2012.6362768>
- Knorr, E., Ng, R., & Zamar, R. (2001). Robust space transformations for distance-based operations. *Proceedings of 7th ACM SIGKDD international conference on Knowledge discovery and data mining*, 126-135. <https://doi.org/10.1145/502512.502532>
- Lampel, L., & Musicant, O. (2014). When Technology Tells Novice Drivers How to Drive. *Transportation Research record: Journal of the Transportation Research Board*, 2182. <https://doi.org/10.3141/2182-02>

- Lehman, G., & Cheale, A. (1998). The contribution of onboard recording systems to road safety and accident analysis. *16th Technical Conference on the Enhanced Safety of vehicles*.
- Liu, J., Zhong, L., Wickramasuriya, J., & Vasudevan, V. (2009). uWave: Accelerometer-based personalized gesture recognition and its applications. *Pervasive and Mobile Computing*, 5, 657-675. <https://doi.org/10.1016/j.pmcj.2009.07.007>
- Mitrovic, D. (2005). Reliable Method for Driving Events Recognition. *IEEE Transactions on Intelligent Transportation Systems*, 6, 198-205. <https://doi.org/10.1109/TITS.2005.848367>
- Mohan, P., Padmanabhan, V., & Ramjee, R. (2008). Recognition of driving manoeuvres using smartphone-based inertial and GPS measurement. *Proceedings pf the 6th ACM conference on Embedded Network Sensor Systems*, 328-303. Retrieved 2/2018 from: <https://www.microsoft.com/en-us/research/wp-content/uploads/2016/02/Nericell-Sensys2008.pdf>
- Murray, W., Durkin, D., & Williams, M. (1996). Benchmarking commercial vehicle accidents. Research report, Department of Transport and Logistics, University of Huddersfield, UK
- Muscillo, R., Schmid, M., Conforto, S., Caselli, P., & D'Alessio, T. (2007). Classification of Motor Activities through Derivative Dynamic Time Warping applied on Accelerometer Data. *Conf Proc IEEE Engineering in Medicine and Biology Society*. 2007. <https://doi.org/10.1109/IEMBS.2007.4353446>
- Musicant, O., Bar-Gera, H., & Schechtman, E. (2014). Temporal perspective on individual driver behavior using electronic records of undesirable events. *Accident Analysis & Prevention*, 70, 55-64. <https://doi.org/10.1016/j.aap.2014.03.008>
- NHTSA. (2009). An examination of driver distraction as recorded in NHTSA Databases. *Traffic Safety Facts*. Accessed 2/2018: <https://crashstats.nhtsa.dot.gov/Api/Public/ViewPublication/811216>
- Oliver, J., Baxter, R., & Wallace, C. (1996). Unsupervised Learning Using MML. *Proceedings of the 13th international conference in machine learning*.
- Oltedal, S., & Rundmo, T. (2005). The effects of personality and gender on risky driving behaviour and accident involvement. *Safety Science*, 44, 621-628. <https://doi.org/10.1016/j.ssci.2005.12.003>
- Online Courses_Eberly College of Science. Retrieved 2/2018 from: onlinecourses.science.psu.edu/stat510/?q=book/export/html/52
- Penny, K., & Jolliffe, I. (2001). A comparison of multivariate outlier detection methods for clinical laboratory safety data. *Journal of the Royal Statistical Society. Series D (The Statistician)*, 50, 295-308.

- Predic, B., & Stojanovic, D. (2015). Enhancing driver situational awareness through crowd intelligence. *Expert System with Applications*, 42, 4892-4909. <https://doi.org/10.1016/j.eswa.2015.02.013>
- Rainie, L., & Perrin, A., (2017). 10 facts about smartphone as the iPhone turns 10. *Pew Research Center*. Accessed 2/2018: <http://www.pewresearch.org/fact-tank/2017/06/28/10-facts-about-smartphones/>
- Saiprasent, C., & Pattara-Atikom, W. (2013). Smartphone Enabled Dangerous Driving Report System. *2013 46th Hawaii International Conference on System Sciences*. <https://doi.org/10.1109/HICSS.2013.484>
- Shekhar, S., Lu, C., Zhang, P. (2001). Detecting Graph-Based Spatial Outlier: Algorithms and Applications. *KDD*. <https://doi.org/10.1145/502512.502567>
- Tselentis, D., Yannis, G., & Vlahogianni, E. (2017). Innovative motor insurance schemes: A review of current practices and emerging challenges. *Accident Analysis & Prevention*, 98, 139-148. <https://doi.org/10.1016/j.aap.2016.10.006>
- Toledo, T., Musicant, O., & Lotan, T. (2008). In-vehicle data recorders for monitoring and feedback on drivers' behaviour. *Transportation Research Part C: Emerging Technologies*, 16, 320-331. <https://doi.org/10.1016/j.trc.2008.01.001>
- Tran, C., & Trivedi, M. (2010). Towards a Vision-based System Exploring 3D Driver Posture Dynamics for Driver Assistance: Issues and Possibilities. *Intelligent Vehicles Symposium (IV), 2010 IEEE*. <https://doi.org/10.1109/IVS.2010.5547957>
- Treat, J. R., Tumbas, N. S., McDonald, S. T., Shinar, D., Hume, R. D., Mayer, R. E., Stansifer, R. L., & Castellan, N. J. (1979). Tri-level study of the causes of traffic accidents. Report No. *DOT-HS-034-3-535-77*.
- Vlahogianni, E., & Barmpounakis, E. (2017). Driving analytics using smartphones: Algorithms, comparisons and challenges. *Transportation Research Part C: Emerging Technologies*, 79, 196-206. <https://doi.org/10.1016/j.trc.2017.03.014>
- Vlahogianni, E., Yannis, G., & Golias, J. (2013). Critical power two wheeler driving patterns at the emergence of an incident. *Accident Analysis & Prevention*, 58, 340-345. <https://doi.org/10.1016/j.aap.2012.12.026>
- Vlahogianni, E., & Karlaftis M. (2013). Testing and Comparing Neural Network and Statistical Approaches for Predicting Transportation Time Series. *Transportation Research record*, 2399. <https://doi.org/10.3141/2399-02>
- White, J., Turner, H., Thompson, C., & Schmidt, D. (2011). WreckWatch: Automatic Traffic Accident Detection and Notification with Smartphones. *Mobile Networks and Applications*, 16, 285-303. <https://doi.org/10.1007/s11036-011-0304-8>
- Williams, G., Baxter, R., He, H., Hawkins, S., & Gu, L. (2002). A Comparative Study of RNN for Outlier Detection in Data Mining. *Proceedings in 2002 IEEE International Conference on Data Mining*. <https://doi.org/10.1109/ICDM.2002.1184035>

- Wouters, P., & Bos, J. (2000). Traffic accident reduction by monitoring driver behaviour with in-car data recorders. *Accident Analysis and Prevention*, 32, 643-650.
[https://doi.org/10.1016/S0001-4575\(99\)00095-0](https://doi.org/10.1016/S0001-4575(99)00095-0)
- Vallis, O., Hochenbaum, J., & Kejariwal, A. (2017). Automatic Anomaly Detection in the Cloud Via Statistical Learning. *Twitter Inc.* Retrieved 2/2018 from:
<https://www.usenix.org/system/files/conference/hotcloud14/hotcloud14-vallis.pdf>