



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΒΙΟΗΜΑΧΙΚΗΣ ΣΧΕΔΙΑΣΗΣ ΚΑΙ ΠΑΡΑΓΩΓΗΣ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Εκτίμηση ικανότητας χειριστή με χρήση μηχανικής μάθησης

Όνομα φοιτητή : Σπυρίδων Αλεξάκος

Επιβλέπων καθηγητής : Γρηγόριος Νικολάου

ΑΘΗΝΑ-ΑΙΓΑΛΕΩ, ΟΚΤΩΒΡΙΟΣ 2021



UNIVERSITY OF WEST ATTICA

FACULTY OF ENGINEERING

DEPARTMENT OF INDUSTRIAL DESIGN AND PRODUCTION ENGINEERS

DIPLOMA THESIS

ASSESSMENT OF OPERATOR COMPETENCE USING MACHINE LEARNING

STUDENT : Spyridon Alexakos

SYPERVISOR : Grigorios Nikolaou

ATHENS-EGALEO, OCTOBER 2021

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Εκτίμηση ικανότητας χειριστή με χρήση μηχανικής μάθησης

Σπυρίδων Αλεξάκος
Α.Μ: 71446294

Επιβλέπων καθηγητής : Γρηγόριος Νικολάου

ΜΕΛΗ ΕΞΕΤΑΣΤΙΚΗΣ ΕΠΙΤΡΟΠΗΣ

Νικολάου Γρηγόριος, Λέκτορας Πανεπιστημίου	
Βασιλειάδου Σουλτάνα, Επίκουρος Καθηγητής	
Δρόσος Χρήστος, ΕΔΠ	

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΠΤΥΧΙΑΚΗΣ/ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑ

Ο κάτωθι υπογεγραμμένος Αλεξάκος Σπυρίδων του Δημητρίου, με αριθμό μητρώου 71446294 φοιτητής του Πανεπιστημίου Δυτικής Αττικής της Σχολής Μηχανικών του Τμήματος Μηχανικών βιομηχανική σχεδίασης και παραγωγής, δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της πτυχιακής/διπλωματικής εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του πτυχίου μου».

Ο Δηλών
Αλεξάκος Σπυρίδων

Σπύρος Αλεξάκος

ΕΥΧΑΡΙΣΤΙΕΣ

Θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή Γρηγόριο Νικολάου , για την καθοδήγηση του ,την χρήσιμη κριτική και τις χρήσιμες προτάσεις καθόλα την διάρκεια ανάπτυξης της διπλωματικής αυτής.

ΠΕΡΙΛΗΨΗ

Στην παρούσα διπλωματική εργασία , αναπτύσσουμε μια αρχιτεκτονική βαθιού νευρωνικού δικτύου με long sort-term memory στρώματα για να προβλέψουμε την κατάσταση που βρίσκεται ο χειριστής. Η είσοδος στο μοντέλο μας είναι μετρήσεις που πάρθηκαν μέσα από βίντεο πολλαπλών χειριστών σε πολλαπλές καταστάσεις. Αναλύουμε τα δεδομένα μας με χρονικές σειρές αφού τα δεδομένα μας παίρνονται από κάθε καρέ από κάθε βίντεο αλλά και για επωφεληθούμε επίσης από τα long short-term memory στρώματα Όσο αφορά την αξιολόγηση του μοντέλου, για μέτρο αξιολόγησης χρησιμοποιούμε την poisson. Σύμφωνα με τα αποτελέσματα παρατηρούμαι ότι το μοντέλο μας κάνει καλή δουλειά στην εκτίμηση της ικανότητας του χειριστή.

ΛΕΞΕΙΣ ΚΛΕΙΔΙΑ: Βαθύ νευρωνικό δίκτυο, χρονικές σειρές , long short-term memory στρώματα , πρόβλεψη κατάστασης χειριστή

ABSTACT

In this bachelor's thesis, we develop a deep neural network architecture with long short-term memory layers so we could predict the state of an operator. Our model's input is measurements taken through videos of multiple operators in multiple states. We analyze our data in time series since our data came from each frame of each video and also to benefit from the long short-term memory layers. As for our model's evaluation, we used poisson for evaluation metric. Based on our results we notice that our model does a good job in assessing the ability of the operator.

KEY WORDS: deep neural network, time series, long short-term memory layer, prediction of operator state

ΠΕΡΙΕΧΟΜΕΝΑ

1 ΕΙΣΑΓΩΓΗ	14
1.1 Τεχνολογίες Ανίχνευσης Υπνηλίας Οδηγού.....	15
1.2 Μηχανική Μάθηση.....	17
1.2.1 Είδη Μηχανικής Μάθησης.....	18
1.2.2 Προσεγγίσεις με Μηχανική μάθηση.....	18
1.3 Σχετικές εργασίες.....	21
2 ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	22
2.1 Artificial Neural Networks.....	22
2.2 Multilayer Perceptron.....	23
2.3 Convolutional Networks.....	23
2.4 Recurrent Networks.....	25
2.4.1 Fully recurrent.....	25
2.4.2 Long short-term memory Networks.....	26
2.5 Το Μοντέλο μας.....	27
2.6 Στοιχεία ενός νευρωνικού δικτύου	27
2.6.1 Νευρώνες	28
2.6.2 Συνδέσεις και βάρη	28
2.6.3 Λειτουργία διάδοσης	28
2.6.4 Συναρτήσεις ενεργοποίησης	28
2.6.4.1 Βηματική	28
2.6.4.2 Γραμμική	29
2.6.4.3 Μη Γραμμική	30
2.6.5 Μαθησιακό ποσοστό	30
2.6.6 Στρώματα	31
3 ΧΡΟΝΙΚΕΣ ΣΕΙΡΕΣ ΚΑΙ ΧΡΟΝΙΚΑ ΒΗΜΑΤΑ	31
3.1 Ανάλυση Χρονικών σειρών	32
3.2 Πρόβλεψη Χρονικών σειρών	32
3.2.1 “Παραδοσιακοί” μέθοδοι	32
3.2.1.1 Μοντέλο κινητού μέσου	33
3.2.1.2 Μοντέλο αυτόματης αντιστροφής κινητού μέσου	33
3.2.2 “Προηγμένοι” μέθοδοι	33
3.2.2.1 Πρόβλεψη με ένα χαρακτηριστικό και ένα χρονικό βήμα	33
3.2.2.2 Πρόβλεψη με πολλαπλά χαρακτηριστικά με ένα χρονικό βήμα	34
3.2.2.3 Πρόβλεψη με πολλαπλά χαρακτηριστικά με πολλαπλά χρονικά βήματα	34
4 ΠΕΙΡΑΜΑΤΑ	36
4.1 Αρχικό Σύνολο δεδομένων	36
4.2 Δημιουργία επεξεργασμένου σύνολο δεδομένων	37
4.3 Μοντέλο μας.....	42
4.3.1 Πειράματα με συναρτήσεις κόστους και μετρικές επίδοσης	42

4.3.2 Πειράματα με την αρχιτεκτονική του μοντέλου μας	52
4.3.3 Βελτιώσεις	57
4.3.4 Πείραμα με καινούργιο, μη εκπαιδευμένο σύνολο δεδομένων στο εκπαιδευμένο μοντέλο μας	59
4.3.5 Πείραμα με εικόνες στο εκπαιδευμένο μας μοντέλο	61
4.3.6 Συμπεράσματα Πειραμάτων	63
4.4 Άλλα Μοντέλα.....	63
4.4.1 Πείραμα με MLP	63
4.4.1 Πείραμα με μονοδιάστατο CNN	64
5 ΣΥΜΠΕΡΑΣΜΑΤΑ – ΠΡΟΤΑΣΕΙΣ	66
ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ – ΑΚΡΩΝΥΜΑ	67
ΒΙΒΛΙΟΓΡΑΦΙΑ	68

ΚΑΤΑΛΟΓΟΣ ΣΧΗΜΑΤΩΝ, ΠΙΝΑΚΩΝ

- 2.1 Συνάρτηση εξόδου νευρωνικού δικτύου. Πηγή: Wikipedia
- 2.2 Αρχιτεκτονική ενός ANN. Πηγή: Wikipedia
- 2.3 Νευρώνες του Convolutional στρώματος(μπλε), συνδεδεμένο στο υποδοχικό πεδίο(κόκκινο). Πηγή: Wikipedia
- 2.4 CNN στρώματα διατεταγμένα σε τρεις διαστάσεις. Πηγή: Wikipedia
- 2.5 Μία τυπική αρχιτεκτονική ενός CNN. Πηγή: Wikipedia
- 2.6 Απλό RNN. Πηγή: Wikipedia
- 2.7 Αρχιτεκτονική LSTM. Πηγή: Wikipedia
- 2.8 Συναρτήσεις ενός LSTM με πύλη που ξεχνάει. Πηγή: Wikipedia
- 2.9 Η Βηματική συνάρτηση και η συνάρτηση της. Πηγή: Wikipedia
- 2.10 Η Γραμμική συνάρτηση και η συνάρτηση της. Πηγή: Wikipedia
- 2.11 Η Λογιστική σιγμοειδής καμπύλη και η συνάρτηση της. Πηγή: Wikipedia
- 2.12 Η Υπερβολική εφαπτόμενη και η συνάρτηση της. Πηγή: Wikipedia
- 3.1: Παράδειγμα ένα χαρακτηριστικό, ένα χρονικό βήμα. Πηγή: Tensorflow
- 3.2: Παράδειγμα πολλαπλά χαρακτηριστικά, ένα χρονικό βήμα. Πηγή: Tensorflow
- 3.3: Παράδειγμα πολλαπλά χαρακτηριστικά, πολλαπλά χρονικό βήμα(False). Πηγή: Tensorflow
- 3.4: Παράδειγμα πολλαπλά χαρακτηριστικά, πολλαπλά χρονικό βήμα(True). Πηγή: Tensorflow
- 3.5: Παράδειγμα πολλαπλά χαρακτηριστικά, πολλαπλά χρονικό βήμα. Πηγή: Tensorflow
- 4.1 : Εικόνες από συμμετέχοντες στις τρεις καταστάσεις[7]
- 4.2 Συντεταγμένες χαρακτηριστικών προσώπου. Πηγή: Wikipedia
- 4.3 : Τιμές που βγήκαν από τις συναρτήσεις
- 4.4 : Επεξεργασμένο σύνολο δεδομένων

- 4.5 : Ετικέτες επεξεργασμένου συνόλου δεδομένων
- 4.6- 4.23 Επιδόσεις μοντέλων και ορισμένες προβλέψεις υπνηλίας από τα πειράματα με συναρτήσεις κόστους και μετρικές επίδοσης.
- 4.24 Πίνακας αποτελεσμάτων ποσοστού επίδοσης πειραμάτων με συναρτήσεις κόστους και μετρικές επίδοσης
- 4.25- 4.33 Επιδόσεις μοντέλων και ορισμένες προβλέψεις υπνηλίας από τα πειράματα με την αρχιτεκτονική του μοντέλου μας.
- 4.34 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας μετά την βελτίωση
- 4.35 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας μετά την βελτίωση
- 4.36 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας μετά την βελτίωση
- 4.37 : Πίνακας αποτελεσμάτων ποσοστού επίδοσης πειραμάτων με την αρχιτεκτονική του μοντέλου μας και την βελτίωση
- 4.38 : Προβλέψεις καινούργιου συνόλου δεδομένων
- 4.39 : Confusion matrix
- 4.40 : Πίνακας εξήγησης των αποτελεσμάτων του confusion matrix
- 4.41 : Πείραμα με την 1η εικόνα
- 4.42 : Κώδικας εμφάνισης πρώτης εικόνας
- 4.43 : Πείραμα με την 2η εικόνα
- 4.44 : Κώδικας εμφάνισης δεύτερης εικόνας
- 4.45 : Επίδοση μοντέλου MLP με σιγμοειδή και ορισμένες προβλέψεις υπνηλίας.
- 4.46 : Επίδοση μοντέλου MLP με softmax
- 4.47 : Επίδοση μοντέλου 1D-CNN με σιγμοειδή και ορισμένες προβλέψεις υπνηλίας.
- 4.48 : Επίδοση μοντέλου 1D-CNN με softmax

ΠΡΟΛΟΓΟΣ

Η διπλωματική εργασία αυτή , με τίτλο Εκτίμηση ικανότητας χειριστή με χρήση μηχανικής μάθησης γράφτηκε ως μέρος του προπτυχιακού προγράμματος σπουδών στο Τμήμα Μηχανικών Βιομηχανικής Σχεδίασης και Παραγωγής του Πανεπιστημίου Δυτικής Αττικής.

1. ΕΙΣΑΓΩΓΗ

Ένα θέμα που απασχολεί όλον το κόσμο και τις κυβερνήσεις εδώ και πολλά χρόνια είναι τα ατυχήματα και ειδικότερα τα τροχαία ατυχήματα που παρόλο όλες τις τεχνολογίες που υπάρχουν συνεχίζουν και γίνονται και αυτό βασίζεται σε καταστάσεις που είναι δύσκολο να ελεγχθούν όπως η υπνηλία των οδηγών. Υπνηλία ή κούραση μπορεί να δημιουργηθεί κατά την οδήγηση μεγάλων ταξιδιών ή όταν οδηγάς αρκετή ώρα χωρίς διάλειμμα, για αυτό χρησιμεύουν συστήματα ανίχνευσης υπνηλίας ή κούρασης τα οποία λειτουργούν για όλη την διάρκεια του ταξιδιού και όχι μόνο όταν ξεκινάει κάποιος την οδήγηση. Σύμφωνα με την Εθνική διοίκηση ασφάλειας κυκλοφορίας εθνικών οδών των Ηνωμένων Πολιτειών Αμερικής [8] περίπου 100.000 καταγεγραμμένα τροχαία ατυχήματα από την αστυνομία είναι λόγο υπνηλίας του οδηγού, όπου 1.550 είναι θανάσιμα ατυχήματα και 71.000 οδήγησαν σε τραυματισμούς. Μια άλλη έρευνα από το AAA Foundation for Traffic Safety[9] έδειξε ότι περίπου 328.000 είναι τα ατυχήματα λόγο υπνηλίας δηλαδή τριπλάσια από αυτά που αναφέρει η Εθνική διοίκηση ασφάλειας κυκλοφορίας εθνικών οδών των Ηνωμένων Πολιτειών Αμερικής και από αυτά 109.000 οδήγησαν σε τραυματισμούς και 6.400 ήταν θανάσιμα ατυχήματα. Για αυτόν τον λόγο πολλές εταιρίες αυτοκινήτων, άρχισαν να εφαρμόζουν τεχνικές που χρησιμοποιούν μηχανική μάθηση για παρατηρούν αν ο οδηγός νιώθει νυσταγμένος ή κουρασμένος και να τον ενημερώνει με ηχητικό μήνυμα ή οπτική εικόνα να ξεκουραστεί. Σε επόμενο κομμάτι της εργασίας, αναφέρουμε ορισμένα τέτοια παραδείγματα συστημάτων ανίχνευσης υπνηλίας από τις εταιρίες αυτοκινήτων. Κάποια σημάδια που μπορούν να βοηθούν κάποιον ώστε να αποφασίσει να ξεκουραστεί είναι:

1. Συχνά χασμουρητά
2. Κουρασμένα μάτια ή αύξηση το πόσο ανοιγοκλείνουμε τα μάτια
3. Αίσθηση ότι αποκοιμάσαι

Υπάρχουν και κάποια πράγματα που μπορεί κάποιος να κάνει για να αποφύγει την υπνηλία ή κούραση, αυτά είναι:

1. Να χωρίσει από την αρχή, τα κομμάτια του ταξιδιού, δηλαδή να χωρίσει το συνολικό ταξίδι σε μικρότερα κομμάτια με κενά ανάμεσα τους ώστε να ξεκουράζεται
2. Να αποφεύγει το αλκοόλ και άλλα ηρεμιστικά
3. Να έχει, αν είναι δυνατόν και κάποιον άλλον μαζί του στο αμάξι για να του κάνει παρέα
4. Να έχει έναν καλό ύπνο πριν το ταξίδι ή ακόμα και τις προηγούμενες νύχτες μέχρι το ταξίδι.
5. Να προσέχει για προειδοποιητικά σήματα, σαν αυτά που αναφέραμε προηγουμένως.

Αυτά είναι κάποια πράγματα τα οποία μπορούν να βοηθήσουν την αποφυγή ατυχημάτων, ωστόσο αρκετοί οδηγοί τα παραμελούν για αυτό είναι χρήσιμα τα συστήματα ανίχνευσης υπνηλίας που ειδοποιούν τον οδηγό εκείνη την στιγμή. Για αυτό σκοπός της διπλωματικής αυτής είναι η αναφορά σε

μια τεχνική που χρησιμοποιεί τα χαρακτηριστικά του προσώπου όπως τα μάτια και το στόμα και προβλέπει την υπνηλία του οδηγού χρησιμοποιώντας μεθόδους μηχανικής μάθησης.

1.1 Τεχνολογίες Ανίχνευσης Υπνηλίας Οδηγού

Με την πάροδο των χρόνων και την ταχεία ανάπτυξη της τεχνολογίας αναπτύχθηκαν ορισμένες τεχνικές για την ανίχνευση υπνηλίας οδηγών. Αυτές είναι:

- **Παρατήρηση κίνησης τιμονιού**, όπου παρατηρείται η κίνηση που κάνει ο οδηγός με το τιμόνι. Έχει παρατηρηθεί ότι αν ο οδηγός νιώθει ή είναι νυσταγμένος κάνει πολύ συχνά μικρές κινήσεις με το τιμόνι ενώ αν είναι ξεκούραστος, το τιμόνι παραμένει σταθερό.
- **Παρατήρηση της θέσης του οχήματος στην οδική λωρίδα**, όπου στην περίπτωση αυτήν παρατηρείται κατά πόσο παραμένει στην λωρίδα του το όχημα. Όταν ο οδηγός του οχήματος νιώθει ή είναι νυσταγμένος έχει παρατηρηθεί ότι το όχημα δεν παραμένει σταθερό στην λωρίδα του αλλά πολλές φορές μπαίνει σε άλλη λωρίδα και ξαναεπαναφέρεται στην δικιά του λωρίδα.
- **Παρατήρηση του προσώπου του οδηγού**, όπου παρατηρούνται τα χαρακτηριστικά του προσώπου όπως τα μάτια και το στόμα και με την χρήση υπολογιστικής όρασης. Η παρατήρηση του προσώπου γίνεται με εγκαταστημένη κάμερα μέσα στο όχημα ή με κινητή συσκευή.
- **Φυσιολογικές μετρήσεις**, όπου μετρούνται παράμετροι όπως η εγκεφαλική δραστηριότητα, μυϊκή δραστηριότητα και οι παλμοί της καρδιάς. Ο τρόπος αυτός είναι πιο δύσκολος στην επίτευξη του γιατί χρειάζεται ο οδηγός να φοράει αισθητήρες στο σώμα του.

Τα τελευταία χρόνια όλο και περισσότερες εταιρίες αυτοκινήτων έχουν αρχίσει και χρησιμοποιούν τις τεχνολογίες αυτές στα δικά τους οχήματα με αποτέλεσμα να έχουν μειωθεί σε ένα μικρό ποσοστό τα τροχαία ατυχήματα που είναι λόγω υπνηλίας του οδηγού. Ορισμένα παραδείγματα εταιριών αυτοκινήτων είναι:

1. **BMW**: Ενεργός βοηθός οδήγησης με βοηθό προσοχής αναλύουν την οδική συμπεριφορά και αν είναι απαραίτητο ενημερώνει τον οδηγό να ξεκουραστεί. Η ενημέρωση για να ξεκουραστεί δίνεται στον οδηγό με την μορφή γραφικών συμβόλων που εμφανίζονται στην οθόνη ελέγχου.[14]
2. **Citroën**: Κάποια μοντέλα χρησιμοποιούν αισθητήρες που βρίσκονται μπροστά από τις μπροστινές ρόδες του αυτοκινήτου και παρακολουθούν τα σημάδια των λωρίδων. Άλλα μοντέλα χρησιμοποιούν κάμερες, οι οποίες βρίσκονται στο κέντρο και πάνω μέρος του παρμπρίζ και κάνει το ίδιο σκοπό. Και τα δύο συστήματα ενημερώνουν τον οδηγό με δονήσεις στην θέση του οδηγού. Τα συστήματα αυτά παρουσιάστηκαν αρχικά το 2005 με το μοντέλο C4 και στην συνέχεια το 2008 με το μοντέλο C5 και το 2013 με το μοντέλο C4 Picasso.
3. **Ford**: Το σύστημα ενημέρωσης οδηγού παρουσιάστηκε το 2011 με το μοντέλο Ford Focus.
4. **Honda**: Η οθόνη προσοχή οδηγού παρουσιάστηκε το 2017 με το μοντέλο CRV.[15]
5. **Hyundai**: Το σύστημα ενημέρωσης προσοχής οδηγού έκανε ντεμπούτο το 2017 με τον μοντέλο i30.

6. **Jaguar Land Rover:** Τα συστήματα παρακολούθησης κατάστασης οδηγού και προειδοποίηση κόπωσης οδηγού, αξιολογούν την τεχνική οδήγησης για σημάδια κόπωσης του οδηγού. Όταν το χαρακτηριστικό καθορίζει εάν ο οδηγός είναι κουρασμένος, το κέντρο μηνυμάτων εμφανίζει την προειδοποίηση “Κάνε διάλειμμα” για ένα λεπτό, συνοδευόμενη από ένα ήχο. Όταν ο οδηγός συνεχίζει για περισσότερο από 15 λεπτά μετά την πρώτη προειδοποίηση, χωρίς να κάνει ένα διάλειμμα, δίνεται μια επιπλέον προειδοποίηση. Η προειδοποίηση συνεχίζεται έως ότου πατηθεί το κουμπί OK στο χειριστήριο του τιμονιού.
7. **Kia:** Το σύστημα προειδοποίησης προσοχής οδηγού έκανε ντεμπούτο το 2018 με το μοντέλο Stinger.
8. **Mazda:** Το σύστημα ειδοποίησης προσοχής οδηγού, ενεργοποιείται σε ταχύτητες άνω των 65 χιλιομέτρων ανά ώρα (ή 40 μίλια ανά ώρα). Μαθαίνει την οδηγική συμπεριφορά μέσω της εισόδου που παίρνει από το τιμόνι και της θέσης του δρόμου κατά την έναρξη της διαδρομής και συγκρίνει τα δεδομένα που έχουν μάθει κατά τα στάδια της διαδρομής. Μια διαφορά πάνω από ένα συγκεκριμένο όριο ενεργοποιεί ένα ακουστικό και οπτικό στοιχείο. Το σύστημα αυτό σξεκίνησε με το μοντέλο CX-5.[16]
9. **Mercedes-Benz:** Το σύστημα βοήθεια προσοχής παρουσιάστηκε το 2009, το οποίο παρακολουθεί το επίπεδο κόπωσης και την υπνηλία του οδηγού με βάση τις εισόδους οδήγησης. Εκδίδει οπτικό και ηχητικό συναγερμό για να ειδοποιεί τον οδηγό εάν είναι νυσταγμένος ή όχι για να συνεχίσει την οδήγηση. Ένα πλεονέκτημα που έχει με σχέσει κάποια άλλα συστήματα είναι ότι συνδέεται με το σύστημα πλοήγησης του αυτοκινήτου και χρησιμοποιώντας αυτά τα δεδομένα, μπορεί να πει στον οδηγό πού διατίθενται καφές.[17]
10. **Cadillac:** Το σύστημα σούπερ πορείας Cadillac χρησιμοποιεί την τεχνολογία όρασης FOVIO, για να ενεργοποιήσει υπέρυθρη κάμερα στο τιμόνι, η οποία προσδιορίζει την κατάσταση προσοχής του οδηγού. Αυτό επιτυγχάνεται μέσω ενός ακριβούς μέτρου του προσανατολισμού της κεφαλής και των κινήσεων των βλεφάρων κάτω από ένα πλήρες φάσμα ημερήσιων και νυχτερινών συνθηκών οδήγησης, συμπεριλαμβανομένης της χρήσης γυαλιών ηλίου.
11. **Nissan:** Το σύστημα ειδοποίησης προσοχής οδηγού έκανε ντεμπούτο το 2014 με το μοντέλο Qashqai και στην συνέχεια το 2016 με το μοντέλο Maxima. [18]
12. **Volvo Cars:** Το σύστημα ελέγχου ενημέρωσης οδηγού ήταν το πρώτο σύστημα ανίχνευσης υπνηλίας οδηγού και ξεκίνησε το 2007. Το σύστημα παρακολουθεί τις κινήσεις του αυτοκινήτου και αξιολογεί εάν το όχημα κινείται με ελεγχόμενο ή ανεξέλεγκτο τρόπο. Αν το σύστημα εντοπίσει υψηλό κίνδυνο ότι ο οδηγός είναι νυσταγμένος, το ειδοποιεί μέσω ενός ηχητικού σήματος. Επίσης, εμφανίζεται ένα μήνυμα κειμένου στην οθόνη πληροφοριών του αυτοκινήτου, το οποίο προειδοποιεί με ένα σύμβολο φλιτζανιού καφέ για ένα διάλειμμα. Επιπλέον, ο οδηγός μπορεί να ανακτά συνεχώς πληροφορίες οδήγησης από τον υπολογιστή ταξιδιού του αυτοκινήτου. Το σημείο εκκίνησης είναι πέντε μπάρες. Όσο λιγότερο συνεπής είναι η οδήγηση, τόσο λιγότερες μπάρες παραμένουν.[19]

Όπως βλέπουμε σχεδόν όλες οι εταιρίες αυτοκινήτων έχουν εφαρμόσει συστήματα ελέγχουν νηφαλιότητας ή κούρασης και άλλα παρόμοια συστήματα, με σκοπό την αύξηση της ασφάλειας των οδηγών τους. Στην Ευρωπαϊκή Ένωση, ο κανονισμός (ΕΕ) 2019/2144 ρυθμίζει το σύστημα παρακολούθησης οδηγού. Κανονισμός (ΕΕ) 2019/2144[20]:

- “Υπνηλία οδηγού και υπενθύμιση προσοχής σημαίνει ένα σύστημα που αξιολογεί την εγρήγορση του οδηγού μέσω ανάλυσης συστημάτων οχημάτων και προειδοποιεί τον οδηγό εάν χρειάζεται “.
- “Τα προειδοποιητικά συστήματα υπνηλίας και προσοχής του οδηγού και τα προηγμένα συστήματα προειδοποίησης απόσπασης της προσοχής του οδηγού πρέπει να σχεδιάζονται κατά τέτοιο τρόπο ώστε τα συστήματα αυτά να μην καταγράφουν συνεχώς ούτε να διατηρούν δεδομένα άλλα εκτός από αυτά που είναι απαραίτητα σε σχέση με τους σκοπούς για τους οποίους συλλέχθηκαν ή επεξεργάστηκαν με άλλο τρόπο στο κλειστό. - σύστημα βρόχου. Επιπλέον, αυτά τα δεδομένα δεν είναι προσβάσιμα ή διαθέσιμα σε τρίτους ανά πάσα στιγμή και διαγράφονται αμέσως μετά την επεξεργασία. Αυτά τα συστήματα πρέπει επίσης να είναι σχεδιασμένα ώστε να αποφεύγουν την αλληλεπικάλυψη και να μην προτρέπουν τον οδηγό ξεχωριστά και ταυτόχρονα ή με σύγχυση, όταν μία ενέργεια ενεργοποιεί και τα δύο συστήματα”.

1.2 Μηχανική Μάθηση

Η Μηχανική Μάθηση είναι η δημιουργία μοντέλων ή προτύπων από ένα σύνολο δεδομένων, από ένα υπολογιστικό σύστημα. Είναι μια μορφή Τεχνητής Νοημοσύνης που δίνει την δυνατότητα σε υπολογιστές να μαθαίνουν από δεδομένα χωρίς να έχουν ρητά προγραμματιστεί με αυτή τη γνώση. Η Μηχανική μάθηση εφαρμόζεται σε μια σειρά από υπολογιστικές εργασίες, όπου τόσο ο σχεδιασμός όσο και ο ρητός προγραμματισμός των αλγορίθμων είναι ανέφικτος. Με την πάροδο του χρόνου έχουν δοθεί διάφοροι ορισμοί για το τι είναι η Μηχανική Μάθηση. Κάποιοι από αυτούς είναι:

- Το 1959 ο Arthur Samuel[21] ορίζει τη μηχανική μάθηση ως "Πεδίο μελέτης που δίνει στους υπολογιστές την ικανότητα να μαθαίνουν, χωρίς να έχουν ρητά προγραμματιστεί".
- Το 1987 ο Carbonell[11] δίνει έναν ορισμό για την Μηχανική Μάθηση, “η μελέτη υπολογιστικών μεθόδων για την απόκτηση νέας γνώσης , νέων δεξιοτήτων και νέων τρόπων οργάνωσης της υπάρχουσας γνώσης”.
- Το 1997 ο Mitchell[10] δίνει έναν άλλον ορισμό, “ Ένα πρόγραμμα υπολογιστή θεωρείται ότι μαθαίνει από την εμπειρία E σε σχέση με μία κατηγορία εργασιών T και μια μετρική απόδοσης P , αν η απόδοση του σε εργασίες της T , όπως μετριούνται από την P , βελτιώνονται με την εμπειρία E ”.
- Το 2000 έχουμε έναν νέο ορισμό από τον Witten και τον Frank[12], “Κάτι μαθαίνει όταν αλλάζει τη συμπεριφορά του κατά τέτοιο τρόπο ώστε να αποδίδει καλύτερα στο μέλλον”.

Πολλοί επιστημονικοί κλάδοι έχουν επωφεληθεί από την χρήση της Μηχανικής μάθησης όπως τα Μαθηματικά, η Πληροφορικοί, η Μηχανική κτλ. Διάφορες εφαρμογές που χρησιμοποιούν Μηχανική

μάθηση είναι στην αναγνώριση ομιλίας και ου γραφικού χαρακτήρα, στην επεξεργασία της φυσικής γλώσσας, στα ηλεκτρονικά παιχνίδια, στην ιατρική διάγνωση, στην οικονομία και σε πολλά άλλα. Γενικά, η Μηχανική μάθηση έχει βοηθήσει πολλούς κλάδους και προβλήματα.

1.2.1 Είδη εκπαίδευσης με Μηχανική μάθηση

Με την πάροδο των χρόνων αναπτύχθηκαν τρεις ειδών τεχνικές εκπαίδευσης με Μηχανική Μάθηση και χρησιμοποιούνται ανάλογα με την φύση του προβλήματος που έχουμε. Αυτές οι τεχνικές είναι:

- **Μάθηση με επίβλεψη:** Το υπολογιστικό πρόγραμμα δέχεται τις παραδειγματικές εισόδους καθώς και τα επιθυμητά αποτελέσματα και κατασκευάζει μια συνάρτηση και έχει ως σκοπό να γενικεύσει την συνάρτηση αυτή ώστε με γνώστη είσοδο να βγάξει μια έξοδο. Η μάθηση με επίβλεψη χωρίζεται σε δύο κατηγορίες, την δομική επίβλεψη και την προσωρινή εκμάθηση. Η μάθηση με επίβλεψη χρησιμοποιείται σε προβλήματα Ταξινόμησης, Πρόγνωσης και Διερμηνείας.
- **Μάθηση χωρίς επίβλεψη:** Ο αλγόριθμος κατασκευάζει ένα μοντέλο για κάποιο σύνολο εισόδων υπό μορφή παρατηρήσεων χωρίς να γνωρίζει τις επιθυμητές εξόδους. Κάποιοι αλγόριθμοι εκπαίδευσης είναι ο αλγόριθμος Hebbian, ο διαφορικός αλγόριθμος Hebbian και ο Min-Max αλγόριθμος. Η μάθηση χωρίς επίβλεψη χρησιμοποιείται σε προβλήματα Ανάλυσης Συσχετισμών και Ομαδοποίησης.
- **Ενισχυτική Μάθηση:** Ο αλγόριθμος μαθαίνει μια στρατηγική ενεργειών μέσα από άμεση αλληλεπίδραση με το περιβάλλον χωρίς να καθοδηγείται, οπότε πρέπει να ανακαλύψει μόνος του ποιες ενέργειες του προσφέρουν μεγαλύτερο κέρδος. Χρησιμοποιείται κυρίως σε προβλήματα Σχεδιασμού.

1.2.2 Προσεγγίσεις με Μηχανική μάθηση

Εδώ θα αναφέρουμε κάποιες προσεγγίσεις σε προβλήματα χρησιμοποιώντας Μηχανική μάθησης. Κάποιες από αυτές είναι:

- **Εκμάθησης με δέντρα απόφασης.** Η εκμάθηση με δέντρα απόφασης χρησιμοποιεί δέντρο απόφασης, όπου το δέντρο απόφασης είναι μια απλοποιημένη μορφή ενός πραγματικού προβλήματος και περιλαμβάνουν τις κυριότερες ενέργειες και γεγονότα.
- **Δίκτυα Bayes.** Ένα δίκτυο Bayes απεικονίζει ένα σύνολο τυχαίων μεταβλητών και την μεταξύ τους υποθετική ανεξαρτησία διαμέσου ενός κατευθυνόμενου άκυκλου γράφου.
- **Τεχνικά νευρωνικά δίκτυα.** Ένα νευρωνικό δίκτυο είναι ένας αλγόριθμος μάθησης που εμπνέεται από τη δομή και τις λειτουργικές πτυχές των βιολογικών νευρωνικών δικτύων. Περισσότερα πράγματα για τα νευρωνικά δίκτυα θα μιλήσουμε στο επόμενο κεφάλαιο της διπλωματικής μας.
- **Βαθιά μάθηση.** Με την βαθιά μάθηση προσπαθούμε να μοντελοποιήσουμε τον τρόπο που ο ανθρώπινος εγκέφαλος επεξεργάζεται το φως και τον ήχο και τα μετατρέπει σε όραση και ακοή.

- **Ομαδοποίηση.** Η ομαδοποίηση είναι η διαδικασία κατά την οποία ένα σύνολο παρατηρήσεων χωρίζεται σε υποσύνολα έτσι ώστε οι παρατηρήσεις που ανήκουν στην ίδια ομάδα είναι όμοιες, σύμφωνα με κάποιο ή κάποια κριτήρια.
- **Γενικοί αλγόριθμοι.** Οι γενικοί αλγόριθμοι είναι τεχνικές βελτιστοποίησης που χρησιμοποιούν διαδικασίες επεξεργασίας όπως ο γενετικός συνδυασμός. Γενετικοί αλγόριθμοι χρησιμοποιήθηκαν στην μηχανική μάθηση την δεκαετία του 1980 και του 1990.[22][23]

1.3 Σχετικές Εργασίες

MLP: [1] Το σύνολο δεδομένων που χρησιμοποιήθηκε είναι το NTHU(National Tsing Hua University) Driver Drowsiness Detection Dataset. Το σύνολο δεδομένων αυτό αποτελείται από test και training σύνολο δεδομένων 22 συμμετεχόντων διαφορετικών εθνικοτήτων, οι οποίοι καταγράφονται σε διάφορα σενάρια προσομοιωμένης οδήγησης υπό νύχτα και υπό μέρα όπως είναι όταν χασμουριούνται, αργό ρυθμό ανοιγόκλεισμα ματιών, σε ζάλη και σε άλλα. Το μοντέλο παίρνει σαν είσοδο τις ετικέτες(Labels) και τις συντεταγμένες των χαρακτηριστικών προσώπου που εξήχθη από τις εικόνες, οι οποίες εξήχθη από τα καρτέ των βίντεο και έξοδο είναι η πρόβλεψη αν ο οδηγός είναι νυσταγμένος ή όχι. Μέσω των πειραμάτων, επιτεύχθηκε μέσο όρο ακρίβεια 81%. Ο μέσος όρος ακρίβειας πάρθηκε με βάση τις ακρίβειες που επιτεύχθηκαν από τις διάφορες καταστάσεις όπως με γυαλιά, χωρίς γυαλιά, νύχτα χωρίς γυαλιά, νύχτα με γυαλιά και με γυαλιά ηλίου όπου παρατηρήθηκαν αλλαγές και πτώση του ποσοστού ακρίβειας όταν συμμετέχοντας φοράει γυαλιά με σχέση όταν δεν φοράει γυαλιά λόγω ότι με γυαλιά είναι πιο δύσκολη η ανίχνευση των ματιών. Επίσης παρατηρείτε διαφορά στο ποσοστού ακρίβειας μεταξύ στις καταστάσεις που πάρθηκαν κατά την νύχτα και κατά την μέρα αφού η φωτεινότητα είναι ένα επίσης σημαντικός παράγοντας με αποτέλεσμα την μέρα ή με καλό φωτισμό τα ποσοστά επιτυχίας να είναι πιο υψηλά. Η αρχιτεκτονική του MLP που χρησιμοποιήθηκε είναι 5 στρώματα με αριθμό νευρώνων 100,10,10,10,1.

SVM,HMM,CNN:[2] Το έγγραφο αυτό αναφέρει τρεις μεθόδους για την ανίχνευση υπνηλίας αλλά για την αναφορά αυτήν θα βασιστούμε στην τρίτη μέθοδο που είναι τα μέτρα συμπεριφοράς που βασίζονται στις πληροφορίες που παίρνονται από το πρόσωπο του οδηγού και μέσω τεχνικών μηχανικής μάθησης να βρίσκει το επιθυμητό αποτέλεσμα το οποίο είναι αν ο οδηγός είναι νυσταγμένος ή όχι. Οι διαδικασίες που έγιναν για την ανίχνευση υπνηλίας αναφέρονται σε μία σειρά βημάτων. Το πρώτο βήμα είναι Λήψη βίντεο στο οποίο τα καρτέ του βίντεο τα μετατρέπουμε σε μια σειρά εικόνων. Το δεύτερο βήμα είναι Ανίχνευση προσώπου στο οποίο ανιχνεύουμε το πρόσωπο του οδηγού στις εικόνες. Το τρίτο βήμα είναι Εξαγωγή χαρακτηριστικών όπου εξάγουμε τα χαρακτηριστικά του προσώπου. Το τέταρτο βήμα είναι Ανάλυση χαρακτηριστικών όπου επεξεργαζόμαστε τα χαρακτηριστικά που εξάγαμε με βάση τις πληροφορίες που αναφέραμε παραπάνω και το τελευταίο βήμα είναι Ταξινόμηση όπου εκεί βρίσκονται οι ταξινομητές που χρησιμοποιήθηκαν για την έκβαση του αποτελέσματος για την ανίχνευση υπνηλίας. Χρησιμοποιήθηκαν τρεις τεχνικές, πρώτη τεχνική είναι με Support Vector Machines (SVM) οι οποίες είναι εποπτευόμενες μέθοδοι μάθησης ταξινόμησης και οπισθοδρόμησης. Η δεύτερη τεχνική είναι με Hidden Markov Model (HMM) το οποίο είναι ένα στατιστικό μοντέλο που χρησιμοποιείτε για να κάνει προβλέψεις σχετικά με κρυφές καταστάσεις βασισμένες σε παρατηρούμενες καταστάσεις ορισμένες από πιθανότητες και τη τρίτη τεχνική είναι με CNN το οποίο είναι παρόμοιο με ένα απλό δίκτυο νευρώνων το οποίο είναι επίσης αποτελούμενο από νευρώνες που αποτελούνται από βάρη που μαθαίνουν. Τα σύνολα δεδομένων που χρησιμοποιήθηκαν στις μελέτες αυτές είναι το Multimodality Drowsiness Database(DROZY), το ZJU Eye blink Database, το Yawn Detection Dataset(YawnDD), το Eye-Chimera και το NTHU-drowsy driver detection video dataset. Όσο για την επιτυχία που είχαν οι

τεχνικές αυτές, διέφεραν ανάλογα με το σύνολο δεδομένων χρησιμοποιούταν αλλά παρατηρήθηκε ότι με CNN τα ποσοστά επιτυχίας ήταν 92-98%, με SVM ήταν 75-98% και με HMM ήταν 79-96% με καλύτερα αποτελέσματα να βγάζουν όλα με το σύνολο δεδομένων ZJU Eye blink Database που σημαίνει ότι σημαντικό ρόλο έχει και το σύνολο δεδομένων και όχι μόνο το μοντέλο.

CNN: [3] Για σύνολο δεδομένων εξέτασαν 3 ειδών και κατέληξαν στην χρήση του τρίτου σύνολο δεδομένων, το οποίο είναι και το σύνολο δεδομένων που δημιούργησαν μόνοι τους. Το σύνολο δεδομένων αυτό δημιουργήθηκε με 33 συμμετέχοντες, στους οποίους ζητήθηκε να παρουσιάσουν τρεις καταστάσεις, κανονική δηλαδή όχι νυσταγμένος, να χασμουριέται και να είναι νυσταγμένος. Τα άλλα 2 ειδών σύνολο δεδομένων ήταν το DROZY σύνολο δεδομένων, το οποίο όμως αποτελείται από 11 συμμετέχοντες μόνος και θεωρήθηκε μικρό ποσοστό για να εκπαιδευτεί ένα CNN αλλά και οι αισθητήρες που ήταν τοποθετημένοι στα πρόσωπα των συμμετεχόντων δυσκόλευαν την προσέγγιση της εργασίας αυτής, η οποία βασίζεται σε Υπολογιστική όραση. Το τελευταίο σύνολο δεδομένων ήταν το NTHU Driver Drowsiness Detection dataset για το οποίο θεωρήθηκε ότι οι γωνίες των καμερών και η ετικέτα(label) της κλάσης ήταν διαφορετικές από το πειραματικό περιβάλλον τους. Το σκεπτικό που ακολουθήθηκε αποτελείται από επεξεργασία δύο βημάτων όπου το πρώτο βήμα είναι η ανίχνευση και η ευθυγράμμιση του προσώπου και το δεύτερο βήμα είναι το μοντέλο ανίχνευσης υπνηλίας. Για το πρώτο βήμα χρησιμοποιήθηκε Multi-Task Cascaded Convolutional Networks (MTCNN) αφού θεωρείται από τους πιο γρήγορους και ακριβείς ανιχνευτές προσώπου, όσο για το δεύτερο βήμα χρησιμοποιήθηκαν διάφορα μοντέλα με το καθένα να έχει και διαφορετικό αποτέλεσμα. Το πρώτο μοντέλο το ονόμασαν baseline-4 model, το μοντέλο αυτό παίρνει 4 εισόδους το αριστερό μάτι, το δεξί μάτι, το πρόσωπο και το στόμα. Αποτελείται από 5 convolutional στρώματα για κάθε είσοδο ροή, όπου τα στρώματα των ματιών μοιράζονται το ίδιο συνοπτικό βάρος αφού τα χαρακτηριστικά που παίρνουν από τα μάτια είναι σχεδόν ίδια. Μετά κάθε ροή από τα convolutional στρώματα καταλήγει σε full connected(FC) στρώματα και μετά αυτά καταλήγουν σε 2 FC στρώματα. Στο τέλος προβλέπουν για εξόδους 3 κλάσης, κανονική ή όχι νυσταγμένος, χασμουριέται και νυσταγμένος. Επειδή το baseline-4 model είναι σχετικά αργό και θέλανε σε πραγματικό χρόνο, δημιούργησαν το δεύτερο μοντέλο το baseline-2 model όπου σαν είσοδο παίρνει μόνο το αριστερό μάτι και το στόμα, οπότε αποτελείται από 2 ροές 5 convolutional στρωμάτων τα οποία με την σειρά τους καταλήγουν σε 2 FC στρώματα και αυτά σε άλλα 2, με τις εξόδους να παραμένουν οι ίδιες. Το τρίτο μοντέλο είναι το compressed-2 model το οποίο δημιουργήθηκε για να μειωθεί η ταχύτητα επιπλέον. Σε αυτό το μοντέλο παρουσιάζουν 2 έννοιες, το teacher network και το student network όπου το student network είναι μικρότερα σε μέγεθος και κάνουν γρηγορότερα τους υπολογισμούς με σχέση το teacher network. Το teacher network είναι το αρχικό μεγάλο δίκτυο το οποίο εκπαιδεύεται κατευθείαν από το σύνολο δεδομένων και το student network είναι ένα μικρό δίκτυο το οποίο μαθαίνει τα χαρακτηριστικά από τα απλά αποτέλεσμα που παράγονται από το teacher network. Στην έρευνα αυτή το teacher network είναι το baseline-2 model και το student network είναι το compressed-2 model. Τα ποσοστά επιτυχίας που πέτυχαν τα μοντέλα αυτά είναι το baseline-4 model 91.3%, το baseline-2 model 93.8% και το compressed-2 model 89.5% ωστόσο παρατηρήθηκε ότι το baseline-2 model έχει μεγαλύτερο ποσοστό αλλά το compressed-2 model είναι πιο γρήγορο και μερικές φορές η ταχύτητα είναι πολύ σημαντική σε τέτοια προβλήματα.

[5] Για να καθορίσουν το επίπεδο υπνηλίας του οδηγού χρησιμοποιούνται διάφορα μέτρα, όπως είναι τα σωματικά μέτρα, τα μέτρα του οχήματος και τα μέτρα συμπεριφοράς στα οποία αναφέρονται στην έρευνα αυτήν για την ανίχνευση υπνηλίας. Τα μέτρα συμπεριφοράς βασίζονται στην συμπεριφορά του οδηγού και κυρίως στο πρόσωπο του, όπου βρίσκονται τα μάτια και το στόμα, η συμπεριφορά των

οποίων έχει μεγάλο βάρος στην ανίχνευση υπνηλίας. Η μέθοδος που χρησιμοποιήθηκε στην έρευνα αυτή αποτελείται από τέσσερα βήματα. Το πρώτο βήμα είναι η εξαγωγή των καρτέ από το βίντεο ή την κάμερα. Το δεύτερο είναι ο εντοπισμός και η εξαγωγή της περιοχής των ματιών από τις εικόνες που εξάγαμε. Το τρίτο βήμα είναι η εξαγωγή χαρακτηριστικών από την περιοχή που εξήχθη στο προηγούμενο βήμα και το τέταρτο και τελευταίο βήμα είναι η χρησιμοποίηση ενός ταξινομητή για την ταξινόμηση των εικόνων για να βρούμε αν ο οδηγός είναι νυσταγμένος ή όχι. Το σύνολο δεδομένων που χρησιμοποιήθηκε για το πείραμα αυτό αποτελείται από 2850 εικόνες όπου οι μισές είναι όχι νυσταγμένος ο οδηγός και στις άλλες μισές είναι. Το μοντέλο που χρησιμοποιήθηκε για την εξαγωγή αυτή του πειράματος είναι ένα βαθύ δισδιάστατο CNN το οποίο αποτελείται από 4 convolutional στρώματα και από 1 FC(Fully connected) στρώμα. Τα αποτελέσματα τους είχαν μια επιτυχία 96%.

ANN: [4]Για σύνολο δεδομένων δεν γίνεται αναφορά ονομαστικά ποιο σύνολο δεδομένων χρησιμοποιήθηκε αλλά γίνεται γνωστό ότι το σύνολο δεδομένων περιέχει 200 εικόνες από έναν οδηγό την στιγμή που οδηγούσε, με 100 να είναι με ανοιχτά μάτια ή μισάνοιχτα και οι άλλες 100 με κλειστά μάτια. Οι εικόνες αυτές επίσης έχουν περικοπεί και έχουν γίνει down-sampled για την αποφυγή μεγάλου χρόνου επεξεργασίας και υπερφόρτωση μνήμης. Χρησιμοποίησαν 2 μεθόδους, η πρώτη μέθοδος είναι με την χρήση του Matlab Neural Network Toolbox και ένα στρώμα ANN ενώ στην δεύτερη μέθοδο χρησιμοποιήθηκε ο αυτόματος κωδικοποιητής του Deep Learning Toolbox. Για την πρώτη μέθοδο οι 200 εικόνες, χωρίστηκαν σε 140 για το train και validation και 60 για το test. Η δομή του νευρώνα που χρησιμοποιήθηκε είναι 2601 νευρώνες στο στρώμα εισόδου, 10 νευρώνες στο κρυφό στρώμα και 2 νευρώνες στο στρώμα εξόδου. Ο αριθμός των νευρώνων στο στρώμα εισόδου αντιστοιχεί στον αριθμό των στοιχείων του διανύσματος εισόδου που είναι η έκδοση της αναδιαμορφωμένη στήλης της down-sampled εικόνα του οδηγού και ο αριθμός των νευρώνων στο στρώμα εξόδου είναι ο αριθμός των πιθανών αποτελεσμάτων, που είναι αν είναι νυσταγμένος ή όχι ο οδηγός. Για την δεύτερη μέθοδο χρησιμοποιήθηκαν οι ίδιοι είσοδοι και εξοδοί με την πρώτη μέθοδο. Οι αυτόματοι κωδικοποιητές χρησιμοποιούν μεθόδους που εκπαιδεύουν κάθε στρώμα ξεχωριστά και μετά τα ενώνουν μαζί σε ένα μονό δίκτυο με πολλαπλά στρώματα και στο τέλος εκπαιδεύουν το τελικό δίκτυο όλο μαζί. Και στα δύο δίκτυα παρατηρήθηκαν πολύ καλά αποτελέσματα, με τα δύο δίκτυα να έχουν 100% επιτυχία.

LSTM,CNN:[6]Η μέθοδος που χρησιμοποιήθηκε ουσιαστικά αποτελείται από 3 βήματα. Το πρώτο βήμα είναι η εξαγωγή εικόνων σε κάθε καρτέ. Το δεύτερο βήμα είναι η εξαγωγή εικόνων με τα χαρακτηριστικά του προσώπου δηλαδή τα μάτια, το στόμα και το κεφάλι από τις εικόνες που εξήχθη προηγουμένως και το τελευταίο βήμα είναι η χρήση των εικόνων αυτών που είναι για κάθε καρτέ για να παρατηρηθεί αν είναι νυσταγμένος ή όχι ο οδηγός. Παραπάνω είναι τα 3 βήματα που χρησιμοποιήθηκαν στην έρευνα αυτήν αλλά τώρα θα μιλήσουμε λίγο πιο συγκεκριμένα για 2 βήματα, το δεύτερο και το τρίτο. Στο δεύτερο βήμα είναι η εξαγωγή των χαρακτηριστικών αλλά πιο συγκεκριμένα ότι αυτό γίνεται με ένα CNN το οποίο με την σειρά του διαδέχεται το τρίτο βήμα που είναι η ανίχνευση υπνηλίας του οδηγού μέσω των εικόνων που εξήχθη με την βοήθεια του CNN, το οποίο γίνεται με ένα LSTM. Το σύνολο δεδομένων που χρησιμοποιήθηκε για την έρευνα αυτήν είναι το National TsingHua University Drowsy Driver Detection (NTHU-DDD) το ποίο αποτελείται από 18 συμμετέχοντες που ενεργούν ως οδηγοί σε διάφορες καταστάσεις και σενάρια. Τα αποτελέσματα που επιτεύχθηκαν κυμαίνονται από 80-90%.

2. ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

2.1 Artificial Neural Networks


Artificial neural networks ή όπως συνήθως ονομάζονται νευρωνικά δίκτυα(neural networks) είναι υπολογιστικά συστήματα βασισμένα στα βιολογικά νευρωνικά δίκτυα που αποτελούν τον εγκέφαλο ενός ζώου. Τα ANN είναι δίκτυα που αποτελούνται από κόμβους(νευρώνες) οι οποίοι είναι διασυνδεδεμένοι μεταξύ τους και μέσω της σύνδεσης αυτής μπορούν και στέλνουν σήματα, ο ένας νευρώνας σε άλλον νευρώνα. Κάθε νευρώνας δέχεται ένα σύνολο αριθμητικών εισόδων από διαφορετικές πηγές όπως άλλοι νευρώνες ή το περιβάλλον, στην συνέχεια κάνει έναν υπολογισμό με βάση τις εισόδους και παράγει μια έξοδο, όπου με την σειρά της η έξοδος αυτή πηγαίνει στο περιβάλλον ή γίνεται είσοδος σε έναν άλλον νευρώνα. Οι νευρώνες χωρίζονται σε τρεις κατηγορίες:

- Νευρώνες εισόδου
- Κρυφοί νευρώνες
- Νευρώνες εξόδου.

$$y_k = \phi \left(\sum_{i=0}^N x_{ki} w_{ki} \right)$$

Σχήμα 2.1 : Συνάρτηση εξόδου νευρωνικού δικτύου

Όπου το y_k είναι η έξοδος του k νευρώνα , το Φ είναι η συνάρτηση ενεργοποίησης , το x_{ki} είναι η είσοδος του k νευρώνα και το w_{ki} είναι το συνοπτικό βάρος του k νευρώνα.



Σχήμα 2.2 :

Αρχιτεκτονική ενός ANN


2.2 Multilayer Perceptron

Το MLP είναι μια κλάση του ANN πρόσθιας τροφοδότησης. Το MLP σαν νευρωνικό δίκτυο μπορεί να πεί κανείς ότι είναι ένα ANN, ωστόσο με διαφορά ότι στην αρχιτεκτονική του MLP έχουμε τουλάχιστον ένα κρυφό στρώμα, δηλαδή το MLP αποτελείται από τουλάχιστον ένα νευρώνα εισόδου, ένα κρυφό νευρώνα και από ένα νευρώνα εξόδου. Εκτός από τους νευρώνες εισόδου κάθε νευρώνα χρησιμοποιεί μη γραμμική συνάρτηση ενεργοποίησης για αυτό το MLP μπορεί να επιλύσει προβλήματα ταξινόμησης που είναι μη γραμμικά διαχωρίσιμα. Για την αρχιτεκτονική του MLP μπορούμε να αναφερθούμε στο Σχήμα 2.2 μιας και η αρχιτεκτονική είναι ίδια με ένα ANN. Την εποχή των 1980s τα MLP ήταν μια δημοφιλής λύση μηχανικής μάθησης, βρίσκοντας εφαρμογή σε διάφορα πεδία όπως σε αναγνώριση ομιλίας, αναγνώριση εικόνας και σε λογισμικά μηχανική μετάφρασης[13].


2.3 Convolutional Neural Networks

Το CNN είναι μια κλάση του βαθύ νευρωνικού δικτύου, του οποίου η πιο συχνή χρήση είναι στην ανάλυση οπτική εικόνας. Τα CNN είναι μια κανονικοποιημένη έκδοση των MLP και με σχέση άλλους αλγόριθμους ταξινόμησης εικόνων τα CNN χρειάζονται λιγότερη προεπεξεργασία, το οποίο σημαίνει ότι το δίκτυο αυτό μπορεί και μαθαίνει να βελτιστοποιεί τα φίλτρα μέσω αυτόματης μάθησης που στην περίπτωση παραδοσιακών αλγόριθμων τα φίλτρα αυτά είναι χειροποίητα. Η ανεξαρτησία των CNN από προηγούμενη γνώση και την ανθρώπινη παρέμβαση στην εξαγωγή χαρακτηριστικών τους δίνει μεγάλο πλεονέκτημα από άλλους αλγόριθμους. Η αρχιτεκτονική ενός CNN είναι ανάλογη με το μοτίβο συνδεσιμότητας των νευρώνων στον ανθρώπινο εγκέφαλο. Οι μεμονωμένοι νευρώνες ανταποκρίνονται σε ερεθίσματα μόνο στην περιορισμένη περιοχή του οπτικού πεδίου που είναι γνωστό ως Υποδοχικό πεδίο(Receptive Field). Η συλλογή τέτοιων πεδίων αλληλεπικαλύπτεται για να καλύψει ολόκληρη την οπτική περιοχή.

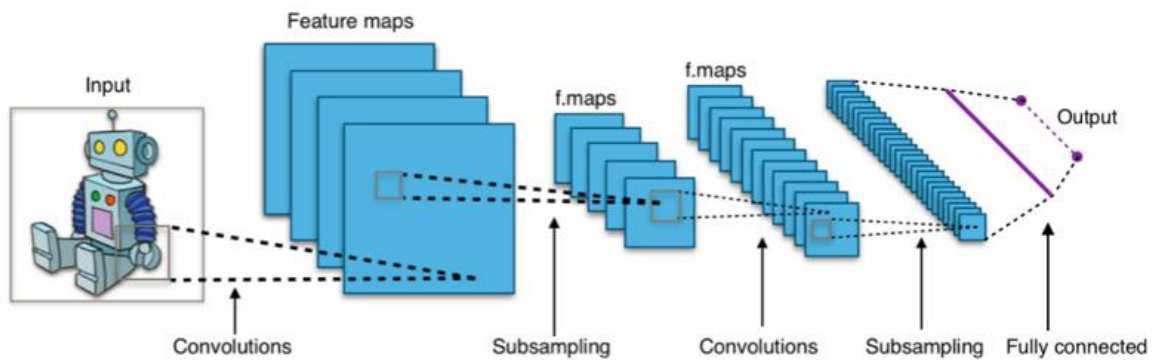
Το Convolutional στρώμα είναι το βασικό στοιχείο για ένα CNN. Οι παράμετροι του στρώματος αποτελούνται από μαθησιακά φίλτρα, τα οποία έχουν μικρό υποδοχικό πεδίο αλλά επεκτείνονται σε όλο το βάθος του όγκου της εισόδου. Κατά την διάρκεια προώθησης, κάθε φίλτρο περιστρέφεται κατά το πλάτος και το ύψος του όγκου εισόδου, υπολογίζοντας το προϊόν κουκκίδων μεταξύ των εισόδων των φίλτρων και της εισόδου, παράγοντας έναν δισδιάστατο χάρτη ενεργοποίησης αυτού του φίλτρου.



Σχήμα 2.3 : Νευρώνες του Convolutional στρώματος(μπλε) , συνδεδεμένο στο υποδοχικό πεδίο(κόκκινο)



Σχήμα 2.4 : CNN στρώματα διατεταγμένα σε τρεις διαστάσεις



Σχήμα 2.5 : Μία τυπική αρχιτεκτονική ενός CNN

Τα CNN χρησιμοποιούν περισσότερους υπερπαραμέτρους με σχέση ένα MLP, με τους συνήθεις κανόνες για την μαθησιακό ποσοστό και την κανονικοποίηση σταθερών να ισχύουν κανονικά, ωστόσο τα CNN έχουν και δικούς τους, σημαντικούς υπερπαραμέτρους όπως είναι:

- ο αριθμός των φίλτρων
- το μέγεθος των φίλτρων
- ο τύπος και το μέγεθος της ομαδοποίησης

Τα CNN εφαρμόζονται σε πολλά πράγματα, με μερικά από αυτά να είναι σε αναγνώριση εικόνων και βίντεο, σε ταξινόμηση εικόνων, σε τμηματοποίηση εικόνων, σε ανάλυση ιατρικών εικόνων, σε επεξεργασία φυσικής γλώσσας, σε διεπαφές εγκεφάλου και υπολογιστή και φυσικά σε χρηματοοικονομικές χρονικές σειρές.


2.4 Recurrent Neural Networks

Το RNN είναι κλάση του ANN όπου η σύνδεση μεταξύ των νευρώνων σχηματίζουν ένα κατευθυνόμενο γράφημα κατά μια χρονική ακολουθία, το οποίο τους επιτρέπει να εμφανίζουν χρονική δυναμική συμπεριφορά. Τα RNN μπορούν να χρησιμοποιήσουν την μνήμη τους για για επεξεργαστούν ακολουθίες μεταβλητού μήκους εισόδων. Αυτό τα καθιστά εφαρμόσιμα σε εργασίες όπως η μη καταχωρισμένη, συνδεδεμένη αναγνώριση γραφικού χαρακτήρα ή αναγνώριση ομιλίας. Θα αναφέρουμε δύο ειδών RNN:

1. FRNN
2. LSTM.

2.4.1 Fully Recurrent Neural Networks

Τα FRNN συνδέουν τις εξόδους όλων των νευρώνων με τις εισόδους όλων των νευρώνων. Αυτή είναι η πιο γενική τοπολογία νευρικού δικτύου, επειδή όλες οι άλλες τοπολογίες μπορούν να αναπαρασταθούν θέτοντας κάποια βάρη στο μηδέν για προσομοίωση της έλλειψης συνδέσεων μεταξύ αυτών των νευρώνων.




Σχήμα 2.6 : Απλό RNN

Όπως παρατηρείται από το Σχήμα 2.6 στην ουσία δηλαδή η έξοδος ενός νευρώνα γίνεται είσοδος στον επόμενο νευρώνα για κάθε χρονικό βήμα και αυτό συνεχίζεται για όσα χρονικά βήματα έχουμε.

2.4.2 Long short-term memory Networks

Το LSTM είναι μία τεχνητή αρχιτεκτονική RNN και σε αντίθεση με νευρωνικά δίκτυα πρόσθιας τροφοδοσίας το LSTM έχει συνδέσεις ανατροφοδότησης. Επίσης το LSTM μπορεί να επεξεργαστεί εκτός από απλά δεδομένα όπως οι εικόνες, μπορεί να επεξεργαστεί και ολόκληρες ακολουθίες δεδομένων όπως ο λόγος και βίντεο. Ένα απλό LSTM αποτελείται από ένα κελί, μια πύλη εισόδου, μια πύλη εξόδου και μία πύλη που ξεχνάει. Το κελί θυμάται τιμές από αυθαίρετα χρονικά διαστήματα, ενώ οι πύλες ρυθμίζουν την ροή των πληροφοριών μέσα και έξω από το κελί. Η πύλη που ξεχνάει έχει την

δυνατότητα να ξεχνάει πληροφορίες που δεν είναι σημαντικές. Τα LSTM μπορούν να μάθουν εργασίες που απαιτούν αναμνήσεις γεγονότων που συνέβησαν χιλιάδες ή ακόμα και εκατομμύρια διακριτών χρονικών βημάτων νωρίτερα για αυτό τα LSTM είναι ιδανικά για ταξινόμηση, επεξεργασία και πρόβλεψη πάνω σε βάση δεδομένων χρονικών σειρών, αφού μπορεί να υπάρχουν καθυστερήσεις άγνωστης διάρκειας μεταξύ σημαντικών δεδομένων σε μια χρονική σειρά. Τα LSTM εφευρέθηκαν από τον Hochreiter και τον Schmidhuber το 1997 και έθεσαν ρεκόρ ακρίβειας σε πολλούς τομείς εφαρμογών.



Σχήμα 2.7 : Αρχιτεκτονική LSTM

$$\begin{aligned}
 f_t &= \sigma_g(W_f x_t + U_f h_{t-1} + b_f) \\
 i_t &= \sigma_g(W_i x_t + U_i h_{t-1} + b_i) \\
 o_t &= \sigma_g(W_o x_t + U_o h_{t-1} + b_o) \\
 \tilde{c}_t &= \sigma_c(W_c x_t + U_c h_{t-1} + b_c) \\
 c_t &= f_t \circ c_{t-1} + i_t \circ \tilde{c}_t \\
 h_t &= o_t \circ \sigma_h(c_t)
 \end{aligned}$$

Σχήμα 2.8 : Συναρτήσεις ενός LSTM με πύλη που ξεχνάει

Όπου x_t είναι το διάνυσμα εισόδου στην μονάδα, f_t είναι το διάνυσμα ενεργοποίησης της πύλης που ξεχνάει, το i_t είναι το διάνυσμα ενεργοποίησης της πύλης εισόδου/ενημέρωσης, το o_t είναι το διάνυσμα ενεργοποίησης της πύλης εξόδου, το h_t είναι το διάνυσμα εξόδου της μονάδας, το c_t είναι το διάνυσμα ενεργοποίησης εισόδου κελιού, το c_t είναι το διάνυσμα κατάστασης κελιού, το W, U, b είναι πίνακες βάρους και παράμετροι διανυσμάτων πόλωσης. Το σ_g είναι σιγμοειδή συνάρτησης και τα σ_c, σ_h είναι υπερβολικές εφαπτόμενες συναρτήσεις.

Τα LSTM έχουν εφαρμογή σε πολλές εργασίες, μερικές από αυτές είναι η πρόβλεψη χρονικών σειρών, αναγνώριση ομιλίας, σύνθεση μουσικής, αναγνώριση γραφικού χαρακτήρα, αναγνώριση ανθρώπινης κίνησης, μετάφραση νοηματικής γλώσσας και η πρόβλεψη αγοράς.

2.5 Το Μοντέλο μας

Για το μοντέλο μας αποφασίσαμε να χρησιμοποιήσουμε το νευρωνικό δίκτυο LSTM. Ο λόγος που αποφασίσαμε το LSTM είναι ότι τα δεδομένα μας είναι με βάση τον χρόνο, μιας και επεξεργαστήκαμε βίντεο και είναι γνωστό ότι τα RNN και ειδικότερα τα LSTM δουλεύουν πολύ καλά με δεδομένα που είναι βασισμένα στον χρόνο. Για εμάς τα δεδομένα μας ήταν για τα πρώτα 240 καρέ από κάθε βίντεο που έχουμε. Για είσοδο στο μοντέλο μας έχουμε τιμές που βγήκαν με την βοήθεια από συναρτήσεις και των συντεταγμένων των χαρακτηριστικών του προσώπου, τις οποίες αναλύσαμε με χρονικές σειρές. Το μοντέλο μας αποτελείται από 6 στρώματα, με τα 5 στρώματα να είναι πυκνά στρώματα και το ένα να είναι LSTM στρώμα. Έχουμε συνάρτηση ενεργοποίησης σε κάθε στρώμα εκτός του στρώματος LSTM, με 3 στρώματα να έχουν συνάρτηση ενεργοποίησης την σιγμοειδή, με ένα στρώμα να έχει την συνάρτηση εφαπτομένη και ένα άλλο να έχει την γραμμική συνάρτηση. Εκτός από τα 6 στρώματα αυτά έχουμε και ένα στρώμα επιπεδοποίησης και 2 στρώματα εγκατάλειψης με ποσοστό 50%. Από νευρώνες έχουμε 100 νευρώνες στα 3 πρώτα στρώματα, 50 στον 4ο στρώμα, 25 στο 5ο και 1 νευρώνα στο τελευταίο στρώμα. Για την εκπαίδευση του μοντέλου μας χρησιμοποιούμε τον βελτιστοποιητή Adam, για συνάρτηση κόστους χρησιμοποιούμε την δυαδική εγκάρσια εντροπία και μετρική επίδοση έχουμε την poisson. Από την πλευρά των αποτελεσμάτων το μοντέλο βγάζει τις τιμές 0 ή 1 ανάλογα με την κατάσταση που βρίσκεται ο χειριστής/οδηγός, οι οποίες είναι 0 αν ο οδηγός δεν είναι νυσταγμένος και η τιμή 1 είναι όταν ο οδηγός είναι νυσταγμένος. Για τα αποτελέσματα μπορεί να τα δει κανείς στο κεφάλαιο πειράματα, όπου δείχνουμε και τα πειράματα και τις αλλαγές που κάναμε πριν φτάσουμε στο τελικό αποτέλεσμα.

2.6 Στοιχεία ενός νευρωνικού δικτύου

Ένα νευρωνικό δίκτυο αποτελείται από πολλά πράγματα, όπως είναι οι νευρώνες, τα στρώματα, οι συναρτήσεις ενεργοποίησης και πολλά άλλα. Εδώ θα αναφέρουμε κάποια από αυτά και θα πούμε και λίγα λόγια για το καθένα. Ο λόγος είναι ότι, όταν αναφερόμαστε σε ένα νευρωνικό δίκτυο κυρίως αναφερόμαστε στο τι είδους δίκτυο είναι, πχ LSTM ή CNN και δεν αναφερόμαστε στα στοιχεία που υπάρχουν στο δίκτυο αυτό, τα οποία είναι πολύ σημαντικά στο πως θα λειτουργήσει ένα μοντέλο.

2.6.1 Νευρώνες

Όπως αναφέρθηκε προηγουμένως οι νευρώνες χωρίζονται σε τρεις κατηγορίες:

- Νευρώνες εισόδου
- Κρυφοί νευρώνες
- Νευρώνες εξόδου.

Όπου οι νευρώνες εισόδου δίνουν μία είσοδο στο δίκτυο μας, με την σειρά του οι κρυφοί νευρώνες αν έχουμε δέχονται αυτή την είσοδο αλλιώς την είσοδο αυτήν την δέχονται κατευθείαν οι νευρώνες εξόδου, όπου και στις δύο περιπτώσεις είτε οι κρυφοί νευρώνες είτε οι νευρώνες εξόδου κάνουν υπολογισμούς με βάση την είσοδο αυτήν και παράγουν μία έξοδο η οποία με την σειρά της θα είναι η έξοδο του δικτύου ή θα είναι είσοδος σε ένα άλλον νευρώνα.

2.6.2 Συνδέσεις και βάρη

Το δίκτυο αποτελείται από συνδέσεις, όπου κάθε σύνδεση παρέχει την έξοδο ενός νευρώνα ως είσοδο σε έναν άλλο νευρώνα. Σε κάθε σύνδεση αντιστοιχεί ένα βάρος που αντιπροσωπεύει τη σχετική σημασία της. Ένας δεδομένος νευρώνας μπορεί να έχει πολλαπλές συνδέσεις εισόδου και εξόδου.

2.6.3 Λειτουργία διάδοσης

Οι νευρώνες που κάνουν τους υπολογισμούς πολλαπλασιάζουν κάθε είσοδο τους με το αντίστοιχο συνοπτικό βάρος και υπολογίζουν το ολικό άθροισμα των γινομένων και με την σειρά του, το άθροισμα αυτό τροφοδοτείται ως όρισμα στην συνάρτηση ενεργοποίησης και μετά το τελικό αποτέλεσμα βγαίνει από τους νευρώνες εξόδου ή γίνεται είσοδος σε έναν άλλον νευρώνα.

2.6.4 Συναρτήσεις ενεργοποίησης


Στις συναρτήσεις ενεργοποίησης έχουμε τρεις κατηγορίες:

1. Βηματική συνάρτηση ενεργοποίησης
2. Γραμμική συνάρτηση ενεργοποίησης
3. Μη γραμμική συνάρτηση ενεργοποίησης
4. Στοχαστική συνάρτηση ενεργοποίησης

2.6.4.1 Βηματική

Η Βηματική συνάρτηση δεν θεωρείται χρήσιμη ως συνάρτηση ενεργοποίησης στα νευρωνικά δίκτυα γιατί έχει το μειονέκτημα ότι η παράγωγος της απειρίζεται, για αυτό προέκυψε η ανάγκη συναρτήσεων ενεργοποίησης που η γραφική τους είναι συνεχείς και παραγωγίσιμες σε όλο το πεδίο ορισμού τους. Οι τιμές που μπορεί να πάρει η συνάρτηση είναι 0 ή 1.

Βηματική συνάρτηση




$$\phi(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

Σχήμα 2.9: Η Βηματική συνάρτηση και η συνάρτησή της

2.6.4.2 Γραμμική

Γραμμική συνάρτηση ενεργοποίησης




$$\phi(x) = x$$

Σχήμα 2.10: Η Γραμμική συνάρτηση και η συνάρτησή της

2.6.4.3 Μη Γραμμική

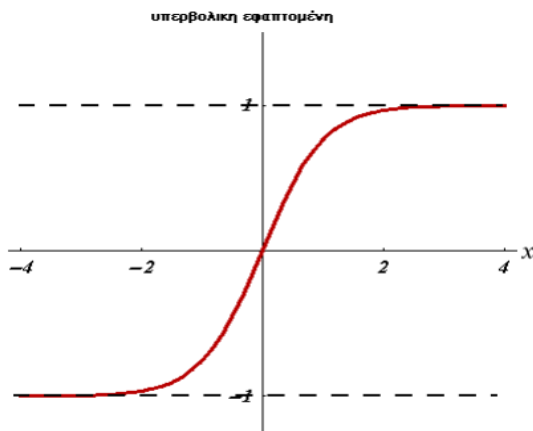
Η μη γραμμική συνάρτηση ενεργοποίησης που χρησιμοποιείται συνήθως στα νευρωνικά δίκτυα καλείται σιγμοειδής συνάρτηση. Η σιγμοειδής συνάρτηση είναι παντού παραγωγίσιμη και παίρνει σαν τιμή όλους τους πραγματικούς αριθμούς από το 0 έως το 1. Έχουμε δύο τύπους σιγμοειδής συνάρτησης, την Λογιστική σιγμοειδή και την Υπερβολική εφαπτόμενη.

Σχήμα
η



$$f(x) = \frac{1}{1 + e^{-x}}$$

2.11: Η Λογιστική σιγμοειδής καμπύλη και συνάρτησή της



$$\phi(x) = \tanh x$$

Σχήμα 2.12: Η Υπερβολική εφαπτόμενη και η συνάρτησή της

2.6.5 Μαθησιακό ποσοστό

Το μαθησιακό ποσοστό καθορίζει το μέγεθος των διορθωτικών βημάτων που λαμβάνει το μοντέλο για να προσαρμόσει τα λάθη σε κάθε παρατήρηση. Μεγάλο μαθησιακό ποσοστό, μειώνει το χρόνο της εκπαίδευσης αλλά μικραίνει και η τελική ακρίβεια, ενώ μικρό μαθησιακό ποσοστό αυξάνει το χρόνο της εκπαίδευσης αλλά υπάρχει η πιθανότητα αύξησης της ακρίβειας.

2.6.6 Στρώματα

Το στρώμα σε ένα βαθύ μαθησιακό μοντέλο είναι μία τοπολογία δικτύου στην αρχιτεκτονική του μοντέλου, η οποία παίρνει πληροφορίες από τα προηγούμενα στρώματα και μετά δίνει την πληροφορία στα επόμενα στρώματα. Στην βαθιά μάθηση έχουμε πολλά “διάσημα” μοντέλα, κάποια από αυτά είναι:

1. Convolutional στρώμα

Το convolutional στρώμα και το στρώμα μέγιστη ομαδοποίηση χρησιμοποιούνται σε CNN. Το convolutional στρώμα συνήθως έχουν τα ακόλουθα χαρακτηριστικά:

- Convolutional φίλτρα ορισμένα από πλάτος και ύψος
- Το αριθμό των καναλιών εισόδου και των καναλιών εξόδου
- Πρόσθετους υπερπαραμέτρους

2. Στρώμα μέγιστης ομαδοποίησης

Το στρώμα μέγιστης ομαδοποίησης χρησιμοποιεί τη μέγιστη τιμή κάθε τοπικού συμπλέγματος νευρώνων στο χάρτη χαρακτηριστικών.

3. Πλήρως συνδεδεμένο ή πυκνό στρώμα

Τα πλήρως συνδεδεμένα ή πυκνά στρώματα συνδέουν κάθε νευρώνα σε ένα στρώμα με κάθε νευρώνα σε ένα άλλο στρώμα.

4. RNN και LSTM στρώματα

Τα RNN και LSTM στρώματα χρησιμοποιούνται σε RNN και LSTM αντίστοιχα. Και τα δύο στρώματα αυτά έχουν την δυνατότητα να μεταφέρουν ή να ξεχάσουν πληροφορίες από στρώμα σε στρώμα ανάλογα αν θέλουμε εμείς να μεταφέρεται η πληροφορία αυτή ή όχι.

5. Στρώμα εγκατάλειψης

Με το στρώμα εγκατάλειψης, κατά την εκπαίδευση κάποιος αριθμός στρωμάτων εξόδου αγνοούνται ή “εγκαταλείπονται” τυχαία ανάλογα πάντα με το ποσοστό που δίνουμε στο στρώμα. Για παράδειγμα αν το ποσοστό που του δώσαμε είναι 50% τότε το 1 στα 2 στρώματα εξόδου θα αγνοηθούν.

3. ΧΡΟΝΙΚΕΣ ΣΕΙΡΕΣ ΚΑΙ ΧΡΟΝΙΚΑ ΒΗΜΑΤΑ

Η χρονική σειρά μπορεί να θεωρηθεί σαν ένα σύνολο τιμών, οι οποίες τιμές παίρνονται σε διαδοχικά ισαπέχουσες χρονικές σειρές ή περιόδους ανάλογα με το κάθε πρόβλημα που θέλουμε να αντιμετωπίσουμε. Οι χρονικές σειρές χρησιμοποιούνται στην Στατιστική, στην Επεξεργασία σήματος, στην Αναγνώριση μοτίβου, στην Πρόβλεψη σεισμού, κτλ. και γενικά σε μεγάλο βαθμό σε οποιονδήποτε τομέα εφαρμοσμένης επιστήμης και μηχανικής που περιλαμβάνει χρονικές μετρήσεις. Οι χρονικές σειρές μπορούν να χωριστούν σε δύο τομείς, στην ανάλυση χρονικών σειρών και στην πρόβλεψη χρονικών σειρών.

3.1 Ανάλυση Χρονικών σειρών

Η ανάλυση χρονικών σειρών είναι η χρήση μεθόδων για την ανάλυση δεδομένων χρονικών σειρών για μπορέσουμε να εξάγουμε σημαντικά στοιχεία, πληροφορίες και χαρακτηριστικά από τα δεδομένα. Οι μέθοδοι για την ανάλυση χρονικών σειρών μπορούν να χωριστούν σε δύο κατηγορίες:

- μέθοδοι τομέα συχνότητων
- μέθοδοι χρονικού τομέα

Όπου μέθοδοι τομέα συχνοτήτων περιλαμβάνουν τη φασματική ανάλυση και την ανάλυση κύματος και οι μέθοδοι χρονικού τομέα περιλαμβάνουν ανάλυση αυτοσυσχέτισης και διασταυρούμενης συσχέτισης. Οι μέθοδοι ανάλυσης μπορούν να χωριστούν σε γραμμικές και μη γραμμικές. Ανάλογα με τον σκοπό μας, δηλαδή ανάλογα τι είδος αποτέλεσμα ψάχνουμε, υπάρχουν και διάφοροι τρόποι ανάλυσης χρονικών σειρών.

3.2 Πρόβλεψη Χρονικών σειρών

Η πρόβλεψη χρονικών σειρών είναι η χρήση μοντέλων για την πρόβλεψη μελλοντικών τιμών, με την χρήση προηγούμενων τιμών. Δηλαδή με την χρήση κατάλληλων μοντέλων και των τιμών που έχουν παρθεί μπορούμε να προβλέψουμε τις μελλοντικές τιμές, ανάλογα πάντα με το τι θέλουμε να προβλέψουμε. Οι τεχνικές με τις οποίες επιτύχετε αυτό ονομάζονται μέθοδοι πρόβλεψης. Τους μεθόδους αυτούς θα μπορούσε να τους χωρίσει θεωρητικά σε:

- “Παραδοσιακοί” μέθοδοι
- “Προηγμένοι” μέθοδοι

Η πρόβλεψη χρονικών σειρών είναι ένα σημαντικός τομέας της μηχανικής μάθησης αφού πολλά προβλήματα πρόβλεψης περιέχουμε σαν μεταβλητή των χρόνων, ωστόσο συχνά τα προβλήματα αυτά τα παραμελούν γιατί ή μεταβλητή χρόνος κάνει τα προβλήματα αυτά πιο δύσκολα να τα χειριστούν. Στην πρόβλεψη, υπάρχουν πολλοί παράγοντες που παίζουν ρόλο, οι οποίοι δυσκολεύουν την ακρίβεια της πρόβλεψης, παρόλα αυτά με την ανάπτυξη της τεχνολογίας, οι τεχνικές μηχανικής μάθησης έχουν περάσει κάθε προσδοκία και πλέον μπορούν να προβλέψουν με μεγαλύτερη ακρίβεια.

3.2.1 “Παραδοσιακοί” μέθοδοι

Στους “Παραδοσιακούς” μεθόδους περιλαμβάνονται τα μοντέλα αυτόματης αντιστροφής(AR), τα ολοκληρωμένα μοντέλα(I), τα μοντέλα κινητού μέσου(MA), τα μοντέλα αυτορυθμιζόμενου κινούμενου μέσου (ARMA), τα μοντέλα αυτόματης αντιστροφής κινητού μέσου (ARIMA) και το μοντέλο αυτόματης αντιστροφής, κλασματικά ολοκληρωμένου κινούμενου μέσου (ARFIMA).

3.2.1.1 Μοντέλο κινητού μέσου

Για το μοντέλο κινητού μέσου έχουμε ότι, η προβλεπόμενη τιμή μας για κάθε χρονική περίοδος μας είναι ο μέσος όρος ενός συνόλου τιμών από παρατηρήθηκαν προηγουμένως. Η διαφορά του κινητού μέσου με το απλό μέσο είναι ότι το κινητό μέσο χρησιμοποιεί το τελευταίο σύνολο τιμών για κάθε πρόβλεψη. Αυτό σημαίνει ότι η τιμή που προβλέψαμε χρησιμοποιείται ενώ ταυτόχρονα αφαιρούμε την παλαιότερη τιμή που παρατηρήθηκε από το σύνολο για να προβλέψουμε την επόμενη νέα τιμή.

3.2.1.2 Μοντέλο αυτόματης αντιστροφής κινητού μέσου

Το μοντέλο αυτόματης αντιστροφής κινητού μέσου είναι μια πολύ δημοφιλής μέθοδο για την πρόβλεψη χρονικών σειρών. Στο μοντέλο αυτόματης αντιστροφής κινητού μέσου υπάρχουν τρεις πολύ σημαντική παράμετροι. Αυτοί είναι:

- p (παλαιότερες τιμές για την πρόβλεψη της επόμενης τιμής)
- q (παλαιότερα λάθη πρόβλεψης που χρησιμοποιούνται για την πρόβλεψη των μελλοντικών τιμών)
- d (σειρά διαφοροποίησης)

Οι αλλαγές στις παραμέτρους του μοντέλου αυτόματης αντίστροφης κινητού μέσου καταναλώνει πολύ χρόνο για αυτό συχνά χρησιμοποιείται το αυτόματο μοντέλο αυτόματης αντίστροφης κινητού μέσου το οποίο διαλέγει αυτόματα τον καλύτερο συνδυασμό των τριών παραμέτρων.


3.2.2 “Προηγμένοι” μέθοδοι

Οι “προηγμένοι” μέθοδοι χρησιμοποιούν μοντέλα όπως το CNN, RNN και το LSTM, ωστόσο εδώ θα μιλήσουμε για τις χρήσεις με το LSTM μιας και αυτό το μοντέλο χρησιμοποιούμε στα πειράματά μας. Πριν ξεκινήσουμε, πρέπει να θυμίσουμε ότι τα LSTM χρησιμοποιούνται συχνά σε προβλήματα πρόβλεψης συχνοτήτων αφού τα LSTM έχουν την δυνατότητα να αποθηκεύουν πληροφορίες που είναι χρήσιμες αλλά και να ξεχνούν πληροφορίες αν δεν είναι χρήσιμες επίσης. Οι χρήσεις χρησιμοποιώντας LSTM είναι:

- Πρόβλεψη με ένα χαρακτηριστικό και ένα χρονικό βήμα
- Πρόβλεψη με πολλαπλά χαρακτηριστικά με ένα χρονικό βήμα
- Πρόβλεψη με πολλαπλά χαρακτηριστικά με πολλαπλά χρονικά βήματα

3.2.2.1 Πρόβλεψη με ένα χαρακτηριστικό και ένα χρονικό βήμα

Με την πρόβλεψη αυτήν, έχουμε μια είσοδο και προβλέπουμε με σχέση την είσοδο αυτήν την έξοδο.



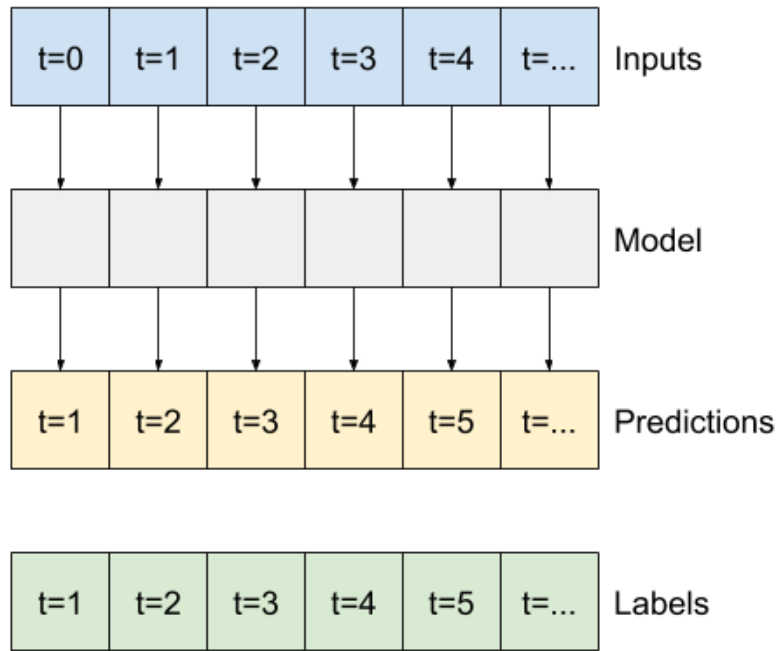
Σχήμα
ένα χρονικό βήμα

3.1:

Παράδειγμα ένα χαρακτηριστικό,

3.2.2.2 Πρόβλεψη με πολλαπλά χαρακτηριστικά με ένα χρονικό βήμα

Στην πρόβλεψη αυτήν έχουμε πολλαπλές εισόδους και για κάθε είσοδο προβλέπουμε μια έξοδο.

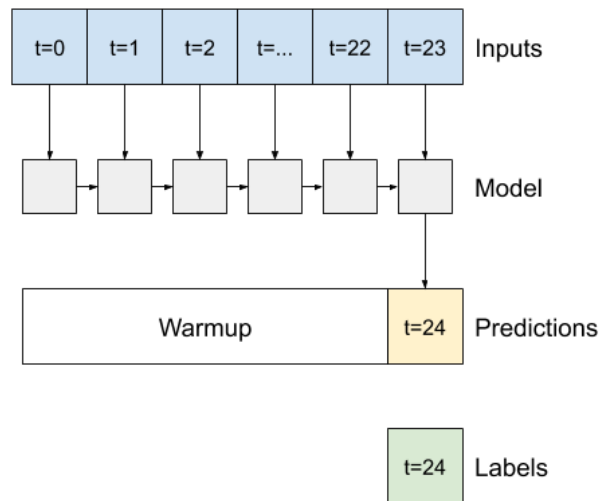


Σχήμα 3.2: Παράδειγμα πολλαπλά χαρακτηριστικά, ένα χρονικό βήμα

3.2.2.3 Πρόβλεψη με πολλαπλά χαρακτηριστικά με πολλαπλά χρονικά βήματα

Στην πρόβλεψη αυτή έχουμε πολλαπλές εισόδους και προβλέπουμε έξοδο ανάλογα με το τι θέλουμε. Εδώ χρησιμοποιείται το πλεονέκτημα που έχουν τα μοντέλα RNN και ειδικότερα το LSTM λόγο του επιχειρήματος `return_sequences`.

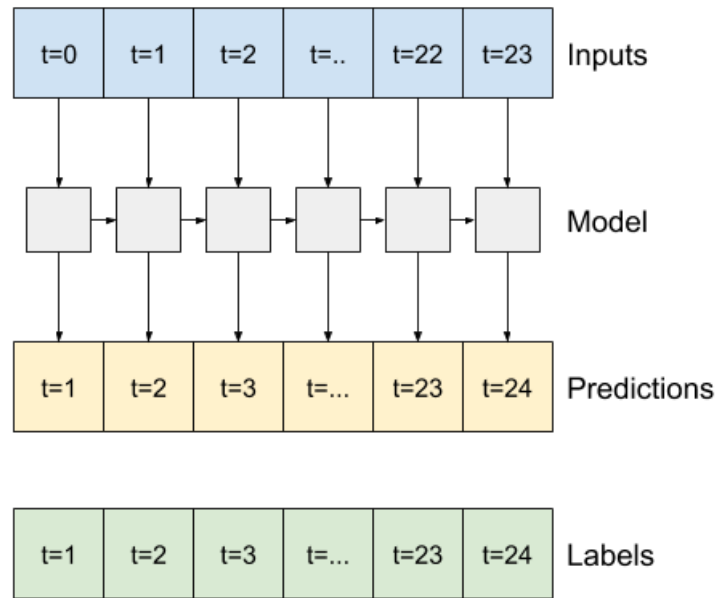
Όταν το επιχειρήμα αυτό είναι **False** τότε επιστρέφεται μόνο η έξοδος του τελευταίου χρονικού βήματος.



Σχήμα 3.3: πολλαπλά χαρακτηριστικά, βήμα(False)

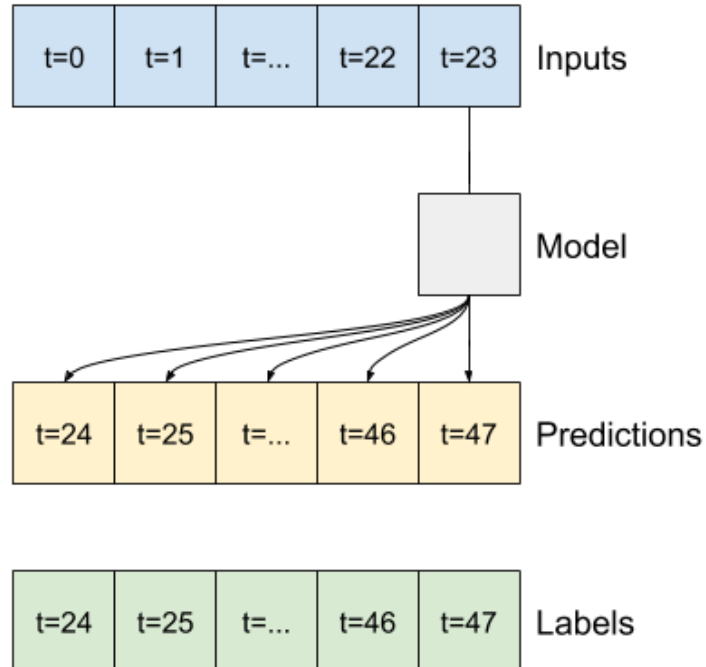
Παράδειγμα πολλαπλά πολλαπλά χρονικό

Ενώ, αν το επιχείρημα είναι **True** τότε για κάθε είσοδο έχουμε μία έξοδο.



Σχήμα 3.4: Παράδειγμα πολλαπλά χαρακτηριστικά, πολλαπλά χρονικό βήμα(True)

Επίσης έχουμε και την περίπτωση όπου παίρνουμε ένα σύνολο τιμών σαν είσοδο και προβλέπουμε το επόμενο σύνολο τιμών.



Σχήμα 3.5: Παράδειγμα πολλαπλά χαρακτηριστικά, πολλαπλά χρονικό βήμα

Όπως βλέπουμε από το Σχήμα 3.5, παίρνουμε τις πρώτες 23 τιμές σαν είσοδο και προβλέπουμε τις επόμενες 23 τιμές.

Τα πιο σημαντικά χαρακτηριστικά για τις προβλέψεις αυτές είναι πόσα χρονικά βήματα έχουμε, την αντιστάθμιση χρόνου που έχουν μεταξύ τους(πχ. Αν θες να προβλέψεις τον καιρό ανά μία ώρα τότε η διαφορά που θα έχουν τα χρονικά βήματα θα είναι μία ώρα) και ποια χαρακτηριστικά χρησιμοποιούνται σαν είσοδο, έξοδο και ετικέτα.

4. ΠΕΙΡΑΜΑΤΑ

Στο κεφάλαιο αυτό θα αναφερθούμε στα πειράματα που κάναμε χρησιμοποιώντας το δικό μας μοντέλο αλλά και μοντέλα που πήραμε από εργασίες άλλων ανθρώπων. Κάποια μοντέλα που χρησιμοποιήσαμε είναι μοντέλα από τα άρθρα που αναφέραμε στο κομμάτι σχετικές εργασίες. Για όλα τα πειράματα χρησιμοποιήσαμε το ίδιο σύνολο δεδομένων γιατί θέλαμε να παρατηρήσουμε τις αλλαγές στα ποσοστά επιτυχίας που υπάρχουν σε κάθε μοντέλο.

4.1 Αρχικό Σύνολο δεδομένων

Το αρχικό σύνολο δεδομένων μας είναι το UTA-RLDD[7] σύνολο δεδομένων. Το σύνολο δεδομένων αυτό αποτελείται από περίπου 30 ώρες RGB βίντεο από 60 υγιής συμμετέχοντες και κάθε συμμετέχοντα έχει ένα βίντεο για κάθε μία από τις τρεις καταστάσεις που βρισκόταν, νυσταγμένος, όχι νυσταγμένος και λίγο νυσταγμένος, οπότε έχουμε ένα πλήθος 180 RGB βίντεο. Κάθε βίντεο είναι περίπου 10 λεπτά και έχει σαν ετικέτα ανάλογα σε ποια κατάσταση ανήκει: 0 αν ανήκει στην κατάσταση όχι νυσταγμένος, 5 λίγο νυσταγμένος και 10 αν είναι νυσταγμένος. Το σύνολο δεδομένων αυτό αποτελεί ένα από τα πιο μεγάλα σύνολα δεδομένων ρεαλιστικής υπνηλίας.




Σχήμα 4.1 : Εικόνες από συμμετέχοντες στις τρεις καταστάσεις[7]

Στο Σχήμα 4.1 παρατηρούμαι εικόνες από ορισμένους συμμετέχοντες που πάρθηκαν μέσα από τα βίντεο στις αντίστοιχες καταστάσεις που βρίσκονταν. Βλέπουμε στην πρώτη γραμμή να είναι εικόνες των συμμετεχόντων στην κατάσταση 0 δηλαδή όχι νυσταγμένοι, στην δεύτερη γραμμή οι συμμετέχοντες βρίσκονται στην κατάσταση 5, λίγο νυσταγμένοι ενώ στην τρίτη γραμμή οι συμμετέχοντες βρίσκονται στην κατάσταση 10, δηλαδή νυσταγμένοι. Αυτές οι εικόνες πάρθηκαν μέσα από τα βίντεο που έχουμε, οπότε μπορούμε να θεωρήσουμε και ότι κάθε εικόνα αποτελεί ένα καρέ από τα βίντεο.

Το σύνολο δεδομένων αυτό είναι χωρισμένο σε 10 κομμάτια/φακέλους όπου ο κάθε φάκελος έχει 18 βίντεο. Τρία βίντεο, ένα βίντεο για κάθε κατάσταση για 6 συμμετέχοντες. Επειδή κάθε φάκελος είχε μέγεθος πάνω από 10G, δεν θα ήταν δυνατόν να έχουμε στην κατοχή μας όλους τους φακέλους, οπότε αποφασίσαμε να κατεβάσουμε ένα φάκελο, τον φάκελο 6, ο οποίος αποτελείται από τους συμμετέχοντες 31 έως 36. Γνωρίζουμε ότι με την επιλογή μας να μην πάρουμε όλους τους φακέλους, τα ποσοστά μας θα διαφέρουν από αν τους παίρναμε όλους, το οποίο αναφέρουμε στα συμπεράσματα μας, ωστόσο δεν θα απέχουμε πάρα πολύ και τα αποτελέσματα μας θα βγαίνουν και πιο γρήγορα. Αφού κατεβάσαμε τον φάκελο αυτόν στον υπολογιστή μας, στην συνέχεια έπρεπε να κάνουμε το περιβάλλον μας που στην περίπτωση μας το Jupiter notebook να διαβάζει όλα τα βίντεο. Στην αρχή μας πήρε αρκετό καιρό η προσπάθεια να το κάνουμε να διαβάζει όλα τα βίντεο μαζί σε σειρά και όχι ένα-ένα όταν αλλάζουμε τις διευθύνσεις που βρίσκονται τα βίντεο χειροκίνητα. Δεν μπορέσαμε να το καταφέρουμε και αποφασίσαμε να το κάνουμε χειροκίνητα για όλα τα βίντεο, δηλαδή σε κάθε μετρήσεις αλλάζαμε την διεύθυνση του βίντεο. Αφού αποφασίσαμε να το κάνουμε έτσι, αυτό που έπρεπε να κάνουμε μετά είναι να πάμε στο επόμενο βήμα το οποίο είναι η δημιουργία του επεξεργασμένου συνόλου δεδομένων για να μπορέσουμε να το έχουμε σαν είσοδο στο μοντέλο μας.

4.2 Δημιουργία επεξεργασμένου σύνολο δεδομένων

Το επεξεργασμένο σύνολο δεδομένων είναι το σύνολο δεδομένων που χρησιμοποιήσαμε σε όλα τα πειράματα που κάναμε τόσο με το δικό μας μοντέλο όσο και με τα άλλα μοντέλα. Αρχικά διαβάζουμε ένα βίντεο, μετά κεντρίζουμε το πρόσωπο του κάθε συμμετέχοντα για να είναι πιο εύκολο να εξάγουμε τις συντεταγμένες που θέλουμε και με την βοήθεια της βιβλιοθήκης γνωστή ως Dlib, εξάγουμε τις συντεταγμένες των χαρακτηριστικών του προσώπου του συμμετέχοντα. Αυτό το κάνουμε για όλα τα βίντεο και για όλους του συμμετέχοντες για 240 καρέ ανά βίντεο, που στην περίπτωση μας 1 καρέ ισοδυναμεί με 1 δεύτερο.



Σχήμα 4.2 : Συντεταγμένες χαρακτηριστικών προσώπου

Το κομμάτι που κεντρίζουμε το πρόσωπο του συμμετέχοντα και την εξαγωγή των συντεταγμένων του προσώπου μας πήρε κάποιο καιρό, μέχρι να φτιάξουμε τον σωστό κώδικα ώστε να εξάγει και να δείχνει συντεταγμένες των χαρακτηριστικών του προσώπου για όσο θέλουμε από το βίντεο. Έπειτα την στιγμή που εξάγουμε τις συντεταγμένες των χαρακτηριστικών του προσώπου βρίσκουμε ταυτόχρονα τις τιμές ορισμένων συναρτήσεων για κάθε καρέ για κάθε βίντεο και τις καταγράφουμε σε ένα αρχείο comma-separated values(csv), το οποίο στην συνέχεια θα το επεξεργαστούμε και θα το χρησιμοποιήσουμε ως το σύνολο δεδομένων μας, στα πειράματά μας.

Οι συναρτήσεις αυτές είναι :

- **eye_aspect_ratio(eye)** η οποία βρίσκει το πόσο ανοιχτό είναι το μάτι. Όσο πιο μεγάλος ο αριθμός είναι τότε δείχνει ότι το μάτι είναι ανοιχτό και αντίθετα αν ο αριθμός μικραίνει τότε το μάτι αρχίζει και κλείνει.(δες συνάρτηση (4.1))

$$EAR = \frac{\|p38-p42\|+\|p39-p41\|}{2\|p37-p40\|} \quad (4.1)$$

- **mouth_aspect_ratio(mouth)** η οποία βρίσκει το πόσο ανοιχτό είναι το στόμα. Όσο μεγαλώνει ο αριθμός σημαίνει ότι το στόμα ανοίγει δηλαδή έχουμε χασμουρητό. (δες συνάρτηση (4.2))

$$MAR = \frac{\|p62-p68\|+\|p63-67\|+\|p64-p66\|}{3\|p61-p65\|} \quad (4.2)$$

- **circularity(eye)** η οποία βρίσκει την διαστολή της κόρης του ματιού. Αν είναι μικρός ο αριθμός σημαίνει ότι το μάτι κλείνει , ενώ αν ο αριθμός είναι μεγάλος τότε το μάτι είναι ανοιχτό. (δες συναρτήσεις (4.3)-(4.5))

$$Area = \frac{\|p38-p41\|^2}{2} * \pi \quad (4.3)$$

$$Perimeter = \|p37 - p38\| + \|p38 - p39\| + \|p39 - p40\| + \|p40 - p41\| + \|p41 - p42\| + \|p42 - p37\| \quad (4.4)$$

$$circularity = \frac{4*\pi*Area}{Perimeter^2} \quad (4.5)$$

- **mouth_over_eye(eye)** η οποία είναι συνάρτηση που βρίσκει την αναλογία του eye_aspect_ratio(eye) και του mouth_aspect_ratio(mouth). Όσο ο αριθμός μεγαλώνει τότε ο συμμετέχοντας νιώθει πιο νυσταγμένος.(δες συνάρτηση (4.4))

$$MOE = MAR/EAR \quad (4.6)$$

Όταν καταγράφουμε τις τιμές αυτές στο αρχείο csv, ταυτόχρονα καταγράφουμε και τις ετικέτες στις οποίες ανήκει κάθε τιμή. Δηλαδή, οι τιμές που παίρνουμε από το βίντεο στο οποίο ο συμμετέχοντας είναι νυσταγμένος θα έχουμε δίπλα την ετικέτα 10.

```
1 PARTICIPANT,EAR,MAR,Circularity,MOE,LABEL
2 31.0,0.3342538911019798,0.8803579708365457,0.4565969498482214,2.6338002167578396,0.0
3 31.0,0.3342538911019798,0.889252062561134,0.4565969498482214,2.660409007145488,0.0
4 31.0,0.3339791012515797,0.9019636697442207,0.5014894719640659,2.7006590123876935,0.0
5 31.0,0.3219113899898252,0.8809086218218096,0.4794712789962464,2.736494107430162,0.0
6 31.0,0.3339791012515797,0.8678886848154947,0.4597385787287795,2.598631715466926,0.0
7 31.0,0.2919573346211484,0.8678886848154947,0.4035243473582091,2.972655870905557,0.0
8 31.0,0.33873707089402166,0.8467131018964316,0.4634867890798009,2.4996174751754197,0.0
9 31.0,0.2919573346211484,0.8553901494010249,0.4035243473582091,2.929846412356798,0.0
10 31.0,0.2998334720937463,0.8612576303768535,0.4288505879408143,2.872453246672779,0.0
11 31.0,0.2998334720937463,0.8787717266924724,0.4761393424782915,2.93086599223223,0.0
12 31.0,0.29121588932479703,0.8678886848154947,0.3664269404634326,2.980224351177235,0.0
13 31.0,0.26651864186110785,0.8553901494010249,0.45079417443870035,3.2094946283224663,0.0
14 31.0,0.2523772325625344,0.85490868642545578,0.3697046435898034,3.3874167474386883,0.0
15 31.0,0.27784375041325915,0.8018104140530244,0.37614279254279903,2.885832101173512,0.0
16 31.0,0.300348166137385,0.8152949664709951,0.42125069271628246,2.714499565474502,0.0
17 31.0,0.32670267161630046,0.7852473613647813,0.4799450850792666,2.4035535353289785,0.0
18 31.0,0.34385253013055134,0.7794978187231278,0.47751599118709226,2.2669538549772312,0.0
19 31.0,0.3498424165232827,0.7860930501940355,0.4934950190184002,2.246991825651649,0.0
20 31.0,0.36199121419580643,0.8049844718999244,0.5184165864581762,2.2237679820165366,0.0
21 31.0,0.344707889976085,0.7860930501940355,0.4739024997234629,2.280461437214486,0.0
22 31.0,0.37997197031472213,0.8049844718999244,0.5119627326681786,2.1185364573949337,0.0
23 31.0,0.37574334481908095,0.7852473613647813,0.5451800447684925,2.0898503518216005,0.0
24 31.0,0.37455690881382736,0.7826880197071049,0.5349741176171109,2.089637118657817,0.0
25 31.0,0.3559959797327521,0.7827865396140383,0.5011057568400147,2.1988634259344164,0.0
26 31.0,0.35712362265734277,0.7651817867565556,0.558077730650087,2.142624397296567,0.0
```

Σχήμα 4.3 : Τιμές που βγήκαν από τις συναρτήσεις

Στο Σχήμα 4.3 βλέπουμε τις πρώτες 25 τιμές από τις συναρτήσεις EAR, MAR, Circularity, MOE που βγήκαν από το βίντεο με κατάσταση 0(όχι νυσταγμένος) του συμμετέχοντα με αριθμό 31.

Αφού βρίσκουμε τις τιμές για τα πρώτα 240 καρέ για κάθε βίντεο, για κάθε κατάσταση, μετά ενώνουμε όλα τα αρχεία csv σε ένα ολοκληρωμένο csv. Εκεί ολοκληρώνεται το κομμάτι στο οποίο χρειαζόμαστε τις συντεταγμένες των χαρακτηριστικών του προσώπου, αφού έχουμε βγάλει τις τιμές που θέλουμε. Μετά από εκεί αρχίζουμε και επεξεργαζόμαστε το αρχείο αυτό για να μπορέσουμε να το βάλουμε σαν είσοδο στο μοντέλο μας. Αρχικά, επειδή θεωρήσαμε ότι στην κατάσταση λίγο νυσταγμένος κάθε άνθρωπος λειτουργεί διαφορετικά, για παράδειγμα κάποιιοι όταν νιώθουν λίγο νυσταγμένοι δεν μπορούν να κάνουν δουλειές ενώ κάποιιοι άλλοι μπορούν αποφασίσαμε να κάνουμε τις τιμές με ετικέτα 5 να χωρίζονται τυχαία στις τιμές με ετικέτα 0 και ετικέτα 10, αυτό όμως γίνεται μόνο στο τέλος στα αποτελέσματα μας για αυτό μπορούμε να δούμε στο αρχείο μέσα ακόμα την ετικέτα 5. Αφού το κάνουμε αυτό, στην συνέχεια, χωρίζουμε το καινούργιο μας σύνολο δεδομένων σε σετ εκπαίδευσης και σε σετ δοκιμής και θεωρήσαμε ως καλό ποσοστό το 50% δοκιμή και 50% εκπαίδευση. Έπειτα μεταμορφώνουμε το σύνολο δεδομένων μας ώστε οι τιμές μας από τις παραπάνω συναρτήσεις μέσα στο αρχείο να είναι από το -1 έως 1 και αυτό το κάνουμε γιατί κάθε άνθρωπος έχει διαφορετική φυσιολογία οπότε για κάποιους οι συναρτήσεις μπορεί να δείχνουν για παράδειγμα, ότι νιώθουν νυσταγμένοι χωρίς

να είναι για αυτό με το τρόπο αυτό ομαλοποιούμε τις τιμές. Τέλος, μετά από αυτό το κομμάτι, φτιάχνουμε το σύνολο δεδομένων με βάση τα χρονικά βήματα που θέλουμε και μεταμορφώνουμε το σύνολο δεδομένων μας σε τρισδιάστατη διανυσματική είσοδο για το LSTM μοντέλο μας. Η διανυσματική είσοδος για το LSTM είναι ένας τρισδιάστατος πίνακας που αποτελείται από τον αριθμό των μετρήσεων μας, τον αριθμό των χρονικών βημάτων και τον αριθμό των χαρακτηριστικών μας. Για παράδειγμα, στο πείραμα μας έχουμε 1440 τιμές στην εκπαίδευση και 1440 τιμές στη δοκιμή, για να τις βάλω στον πίνακα τότε θα κάνουμε τιμές / χρονικά βήματα και ότι βγει τότε μπαίνει στον αριθμό μετρήσεων, στην περίπτωση μας για 5 χρονικά βήματα η διανυσματική είσοδος θα είναι (288,5,4) για την εκπαίδευση όπου 288 είναι ο αριθμός μετρήσεων, το 5 είναι τα χρονικά βήματα και το 4 είναι ο αριθμός των χαρακτηριστικών μας (EAR, MAR, Circularity, MOE) και για την δοκιμή θα είναι (288,5,4).

```
[[[0.71985102 0.25405991 0.57665407 0.06085436]
 [0.71985102 0.26738395 0.57665407 0.06276729]
 [0.71909433 0.28642693 0.70671449 0.06566091]
 [0.68586328 0.25488482 0.64292446 0.06823713]
 [0.71909433 0.23537994 0.58575584 0.05832605]]

 [[0.60337831 0.23537994 0.42289471 0.08521507]
 [0.73219643 0.20365726 0.59661497 0.05120781]
 [0.60337831 0.21665616 0.42289471 0.08213745]
 [0.62506696 0.2254461 0.49626866 0.07801139]
 [0.62506696 0.25168359 0.63327133 0.08221074]]

 [[0.60133658 0.23537994 0.31541792 0.08575917]
 [0.53332737 0.21665616 0.55984255 0.10224167]
 [0.49438594 0.21593216 0.32491392 0.11503269]
 [0.56451351 0.13638953 0.34356621 0.07897321]
 [0.62648428 0.15659044 0.47425062 0.06665592]]

 ...

 [[0.38577183 0.50130193 0.43223626 0.22445544]
 [0.39543549 0.5085216 0.41496714 0.22033363]
 [0.46622939 0.5085216 0.4216435 0.18329993]
 [0.50719331 0.49097187 0.46318419 0.16197785]
 [0.45882144 0.49669663 0.33665039 0.18443291]]
```



```

[[0.32471581 0.48522419 0.3203436 0.26143387]
 [0.3612213 0.49955394 0.46329218 0.23946773]
 [0.32861178 0.60458148 0.50208156 0.28836817]
 [0.35573895 0.55243098 0.40299942 0.25565399]
 [0.38907546 0.60534117 0.43964627 0.24579392]]

[[0.55760334 0.52718351 0.60266453 0.14897677]
 [0.57001148 0.51934172 0.57866091 0.14316422]
 [0.58071184 0.56233798 0.52328135 0.14671603]
 [0.59775218 0.51049026 0.5005066 0.13225956]
 [0.61320833 0.48339732 0.50608551 0.12290773]]]

```

Σχήμα 4.4 : Επεξεργασμένο σύνολο δεδομένων

Στο Σχήμα 4.4 βλέπουμε τις πρώτες 15 και τις τελευταίες 15 τιμές του επεξεργασμένου συνόλου δεδομένων μας, όπου οι τιμές είναι οι τιμές από τις συναρτήσεις EAR, MAR, Circularity, MOE αντίστοιχα τις οποίες έχουμε κάνει να είναι από το -1 έως το 1 και τις έχουμε μεταμορφώσει με 5 χρονικά βήματα για αυτό τις βλέπουμε να είναι σε ομάδες των πέντε.

```

[1. ]
[1. ]
[1. ]
[1. ]
[1. ]
[0. ]
[0. ]
[0. ]
[0. ]
[0. ]
[0. ]
[0. ]
[0. ]
[0. ]
[0. ]
[0.5]
[0.5]
[0.5]
[0.5]
[0.5]
[0.5]

```

Σχήμα 4.5 : Ετικέτες επεξεργασμένου σύνολο δεδομένων

Στο Σχήμα 4.5 βλέπουμε ορισμένες τιμές των ετικετών του επεξεργασμένου συνόλου δεδομένων, όπου η τιμή 1. αντιστοιχεί στην κατάσταση 10(νυσταγμένος), η τιμή 0 στην κατάσταση 0.(όχι νυσταγμένος) και η τιμή 0.5 στην κατάσταση 5(λίγο νυσταγμένος). Ωστόσο με αυτόν τον τρόπο οι τιμές 0.5 βγαίνουν τυχαία στα αποτελέσματα σαν την τιμή 0 ή την τιμή 1 και ο λόγος που το κάναμε αυτό, το εξηγήσαμε παραπάνω και είναι ότι στην κατάσταση 5(λίγο νυσταγμένος) κάθε άνθρωπος λειτουργεί διαφορετικά,

δηλαδή κάποιιοι όταν νιώθουν λίγο νυσταγμένοι δεν έχουν πρόβλημα να κάνουν δουλειές ενώ κάποιιοι άλλοι δεν μπορούν.

4.3 Μοντέλο μας

Για το δικό μας μοντέλο πειραματιστήκαμε με διάφορα χρονικά βήματα αλλά και με διάφορες αρχιτεκτονικές. Όσο αφορά τα χρονικά βήματα τα πειράματα που κάναμε ήταν με 30 χρονικά βήματα , με 5 χρονικά βήματα και με 1 χρονικό βήμα, ενώ όσο αφορά την αρχιτεκτονική πειραματιστήκαμε στην αρχή με διάφορες συναρτήσεις κόστους αλλά και με διάφορες μετρικές επίδοσης και αφού βρήκαμε ποιος συνδυασμός των δύο αυτών είχε μεγαλύτερο ποσοστό επιτυχίας τότε αρχίσαμε να πειραματιζόμαστε με πόσα στρώματα έχουμε ή με πόσους νευρώνες σε κάθε στρώμα ή ποια συνάρτηση ενεργοποίησης υπάρχει σε κάθε στρώμα. Για να μπορέσει το μοντέλο να επιδώσει καλύτερα χρειαζόμαστε έναν βελτιστοποιητή, στην περίπτωση μας σε όλα τα πειράματα μας σαν **βελτιστοποιητή είχαμε τον Adam**. Ο Adam είναι μια στοχαστική μέθοδος που βασίζεται σε προσαρμοστική εκτίμηση στιγμών πρώτης τάξης και δεύτερης τάξης. Στο τέλος το μοντέλο μας προβλέπει την υπνηλία του χειριστή/οδηγού με αποτέλεσμα 0 ο οδηγός δεν είναι νυσταγμένος και με αποτέλεσμα 1 ο οδηγός είναι νυσταγμένος. Τα πειράματα μας έγιναν στο Jupiter notebook.

4.3.1 Πειράματα με συναρτήσεις κόστους και μετρικές επίδοσης

Στα πειράματα αυτά οι μόνες αλλαγές που κάναμε στο μοντέλο μας ήταν στην συνάρτηση κόστους και στις μετρικές επίδοσης. Επειδή θέλουμε να προβλέψουμε την υπνηλία του χειριστή/οδηγού χρησιμοποιήσαμε συναρτήσεις κόστους πρόβλεψης. Οι συναρτήσεις που μπόρεσαν να λειτουργήσουν κανονικά στο μοντέλο μας είναι η δυαδική εγκάρσια εντροπία(binary_crossentropy) και η poisson. Όσο για τις μετρικές επίδοσης για το ίδιο λόγο με τις συναρτήσεις κόστους, πήραμε μετρικές πρόβλεψης όσες μπόρεσαν να δουλέψουν σωστά την μετρική poisson και την μετρική δυαδική εγκάρσια εντροπία(binary_crossentropy) αλλά πήραμε και από τις μετρικές ακρίβειας την μετρική ακρίβεια(accuracy) και την δυαδική ακρίβεια(binary_accuracy).

Αρχικά κρατήσαμε την συνάρτηση κόστους δυαδική εγκάρσια εντροπία και αλλάξαμε μόνο τις μετρικές επίδοσης και στην συνέχεια κρατήσαμε την συνάρτηση κόστους poisson και αλλάξαμε τις μετρικές επίδοσης.

1ο Πείραμα, Συνάρτηση κόστους: δυαδική εγκάρσια εντροπία, Μετρική επίδοση: ακρίβεια

Με 1 χρονικό βήμα:

```
loss: 0.4900 - accuracy: 0.6200
loss: 0.4861 - accuracy: 0.6099 [0]
loss: 0.4745 - accuracy: 0.6175 [0]
... [0]
loss: 0.4904 - accuracy: 0.6078 [0]
loss: 0.4934 - accuracy: 0.6061 [0]
loss: 0.4836 - accuracy: 0.6256
```

Σχήμα 4.6 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 63% και έχουμε μια πρόβλεψη ότι κάποιοι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος)

Με 5 χρονικά βήματα:

```
loss: 0.5426 - accuracy: 0.5657
loss: 0.4748 - accuracy: 0.6327 [0]
loss: 0.5232 - accuracy: 0.5902 [0]
loss: 0.5492 - accuracy: 0.5846 [0]
loss: 0.5236 - accuracy: 0.6059 [0]
loss: 0.4815 - accuracy: 0.6435 [0]
```

Σχήμα 4.7 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 64% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι.

Με 30 χρονικά βήματα:

```
loss: 0.4789 - accuracy: 0.6096
loss: 0.4795 - accuracy: 0.6165 [0]
loss: 0.4792 - accuracy: 0.6382 [1]
loss: 0.4616 - accuracy: 0.6609 [0]
loss: 0.4605 - accuracy: 0.6250 [0]
loss: 0.4223 - accuracy: 0.7180 [0]
```

Σχήμα 4.8 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 72% και έχουμε μια πρόβλεψη ότι κάποιοι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος) αλλά και κάποιοι άλλοι είναι στην κατάσταση 1(νυσταγμένος).

2ο Πείραμα, Συνάρτηση κόστους: δυαδική εγκάρσια εντροπία, Μετρική επίδοση: δυαδική ακρίβεια

Με 1 χρονικό βήμα:

```
loss: 0.4809 - binary_accuracy: 0.6137

loss: 0.4862 - binary_accuracy: 0.6073
[0]

loss: 0.4978 - binary_accuracy: 0.5907
[0]

...
loss: 0.4971 - binary_accuracy: 0.5999
[0]

loss: 0.4995 - binary_accuracy: 0.5985
[0]

loss: 0.4707 - binary_accuracy: 0.6213
```

Σχήμα 4.9 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 62% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι.

Με 5 χρονικά βήματα:

```
loss: 0.5134 - binary_accuracy: 0.6044

loss: 0.5368 - binary_accuracy: 0.5737
[0]

loss: 0.4983 - binary_accuracy: 0.6102
[0]

loss: 0.4839 - binary_accuracy: 0.6142
[0]

loss: 0.5230 - binary_accuracy: 0.5796
[0]

loss: 0.4961 - binary_accuracy: 0.6374
[1]
```

Σχήμα 4.10 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 64% και έχουμε μια πρόβλεψη ότι κάποιοι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος) αλλά και ένας συμμετέχοντας είναι στην κατάσταση 1(νυσταγμένος).

Με 30 χρονικά βήματα:

```
loss: 0.4438 - binary_accuracy: 0.6444

loss: 0.3956 - binary_accuracy: 0.7005           [0]
                                                  [1]

loss: 0.4128 - binary_accuracy: 0.6963           [1]
                                                  [0]
                                                  [0]

loss: 0.5136 - binary_accuracy: 0.5913           [0]
                                                  [1]
                                                  [0]

loss: 0.4801 - binary_accuracy: 0.6186           [0]
                                                  [0]

loss: 0.4243 - binary_accuracy: 0.7290
```

Σχήμα 4.11 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 73% και έχουμε μια πρόβλεψη ότι κάποιοι συμμετέχοντες δεν είναι νυσταγμένοι ενώ κάποιοι είναι.

3ο Πείραμα, Συνάρτηση κόστους: δυαδική εγκάρσια εντροπία, Μετρική επίδοση: poisson

Με 1 χρονικό βήμα:

```
- loss: 0.6724 - poisson: 0.8032

loss: 0.5749 - poisson: 0.7531           [0]
                                                  [0]

loss: 0.5917 - poisson: 0.7585           [0]
                                                  ...

loss: 0.5842 - poisson: 0.7625           [0]
                                                  [0]
                                                  [0]

loss: 0.5827 - poisson: 0.7745

loss: 0.5757 - poisson: 0.7499 -
```

Σχήμα 4.12 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 80% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος).

Με 5 χρονικά βήματα:

```
· loss: 0.6925 - poisson: 0.8241

loss: 0.6473 - poisson: 0.7931      [0]
                                     [0]
loss: 0.5842 - poisson: 0.7646      [0]
                                     [0]
                                     [0]
loss: 0.6075 - poisson: 0.7704      [0]
                                     [1]
                                     [1]
loss: 0.6000 - poisson: 0.7559      [0]
                                     [1]

loss: 0.6031 - poisson: 0.7653
```

Σχήμα 4.13 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 82% και έχουμε μια πρόβλεψη ότι κάποιοι συμμετέχοντες δεν είναι νυσταγμένοι ενώ κάποιοι είναι.

Με 30 χρονικά βήματα:

```
loss: 0.6808 - poisson: 0.7920

loss: 0.6697 - poisson: 0.8042      [0]
                                     [1]
                                     [1]
loss: 0.6043 - poisson: 0.7300      [0]
                                     [0]
                                     [0]
loss: 0.5986 - poisson: 0.7544      [1]
                                     [0]
                                     [0]
                                     ---
loss: 0.5646 - poisson: 0.7639

loss: 0.6649 - poisson: 0.8306
```

Σχήμα 4.14 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 83% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος) ενώ άλλοι συμμετέχοντες είναι στην κατάσταση 1(νυσταγμένος).

4ο Πείραμα, Συνάρτηση κόστους: poisson, Μετρική επίδοση: ακρίβεια

Με 1 χρονικό βήμα:

```
loss: 0.7195 - accuracy: 0.6170
loss: 0.7268 - accuracy: 0.6039
loss: 0.7245 - accuracy: 0.5944      [0]
loss: 0.7148 - accuracy: 0.6129      [0]
loss: 0.7105 - accuracy: 0.6088      [0]
loss: 0.7155 - accuracy: 0.6177      [0]
```

Σχήμα 4.15 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 62% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι.

Με 5 χρονικά βήματα:

```
loss: 0.7539 - accuracy: 0.6114
loss: 0.7193 - accuracy: 0.6075      [0]
loss: 0.7197 - accuracy: 0.6037      [0]
loss: 0.7122 - accuracy: 0.6139      [0]
loss: 0.7073 - accuracy: 0.6071      [1]
loss: 0.7416 - accuracy: 0.6377      [1]
```

Σχήμα 4.16 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 64% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος) ενώ άλλοι συμμετέχοντες είναι στην κατάσταση 1(νυσταγμένος).

Με 30 χρονικά βήματα:

```
loss: 0.7474 - accuracy: 0.5659
loss: 0.7651 - accuracy: 0.5548      [0]
                                     [1]
loss: 0.7043 - accuracy: 0.7019      [0]
                                     [0]
                                     [0]
loss: 0.6780 - accuracy: 0.6852      [0]
                                     [1]
                                     [0]
loss: 0.6987 - accuracy: 0.6215      [0]
                                     [0]
loss: 0.6633 - accuracy: 0.7438
```

Σχήμα 4.17 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 75% και έχουμε μια πρόβλεψη ότι κάποιοι συμμετέχοντες δεν είναι νυσταγμένοι και άλλοι είναι.

5ο Πείραμα, Συνάρτηση κόστους: poisson, Μετρική επίδοση: δυαδική ακρίβεια

Με 1 χρονικό βήμα:


```

loss: 0.7181 - binary_accuracy: 0.6088

- loss: 0.7297 - binary_accuracy: 0.6084

loss: 0.7129 - binary_accuracy: 0.5965 [0]
[0]
[0]

- loss: 0.7195 - binary_accuracy: 0.6120 ...
[0]
[0]
[0]

loss: 0.7188 - binary_accuracy: 0.6051

```

Σχήμα 4.18 : Επίδοση

ορισμένες προβλέψεις υπνηλίας

μοντέλο αυτό να πιάνει μια

επίδοση του ύψους 62% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση

0(όχι νυσταγμένος).

μοντέλου και
 Βλέπουμε το
 επίδοση του ύψους 62% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος).

Με 5 χρονικά βήματα:

```

loss: 0.7117 - binary_accuracy: 0.6324

loss: 0.7087 - binary_accuracy: 0.6338 [0]
[0]
[0]

loss: 0.7359 - binary_accuracy: 0.6258 [0]
[0]
[0]

loss: 0.7131 - binary_accuracy: 0.6274 [1]
[1]
[0]

loss: 0.7478 - binary_accuracy: 0.5755 [1]
[1]

loss: 0.6732 - binary_accuracy: 0.6432

```

Σχήμα 4.19 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 64% και έχουμε μια πρόβλεψη ότι κάποιοι συμμετέχοντες δεν είναι νυσταγμένοι και άλλοι είναι.

Με 30 χρονικά βήματα:

```

loss: 0.6882 - binary_accuracy: 0.6325 .
loss: 0.7374 - binary_accuracy: 0.5789 . [0]
[1]
[0]
· loss: 0.7539 - binary_accuracy: 0.5486 [0]
[0]
[0]
· loss: 0.7037 - binary_accuracy: 0.6301 [1]
[0]
[0]
loss: 0.7009 - binary_accuracy: 0.5638 . ---
· loss: 0.6995 - binary_accuracy: 0.6997

```

Σχήμα 4.20 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 70% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος) ενώ άλλοι συμμετέχοντες βρίσκονται στην κατάσταση 1(νυσταγμένος).

6ο Πείραμα, Συνάρτηση κόστους: poisson, Μετρική επίδοση: δυαδική εγκάρσια εντροπία

Με 1 χρονικό βήμα:

```

loss: 0.7696 - binary_crossentropy: 0.6027
loss: 0.7733 - binary_crossentropy: 0.5931 [0]
[0]
loss: 0.7649 - binary_crossentropy: 0.5887 [0]
...
loss: 0.7601 - binary_crossentropy: 0.5779 [0]
[0]
[0]
loss: 0.7702 - binary_crossentropy: 0.5815
loss: 0.7590 - binary_crossentropy: 0.5852

```

Σχήμα 4.21 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 60% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι.

Με 5 χρονικά βήματα:

```

loss: 0.8048 - binary_crossentropy: 0.6548

loss: 0.7819 - binary_crossentropy: 0.5939      [0]
                                                  [0]
loss: 0.7715 - binary_crossentropy: 0.6158      [0]
                                                  [0]
                                                  [0]
loss: 0.7624 - binary_crossentropy: 0.6195      [0]
                                                  [1]
                                                  [1]
loss: 0.7486 - binary_crossentropy: 0.5975      [0]
                                                  [1]

```

```
loss: 0.7478 - binary_crossentropy: 0.5521
```

Σχήμα 4.22 : Επίδοση

μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 65% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος) ενώ άλλοι συμμετέχοντες βρίσκονται στην κατάσταση 1(νυσταγμένος).

Με 30 χρονικά βήματα:

```

loss: 0.8077 - binary_crossentropy: 0.6862      [1]
                                                  [1]
loss: 0.8138 - binary_crossentropy: 0.6575      [0]
                                                  [0]
loss: 0.8206 - binary_crossentropy: 0.6746      [0]
                                                  [0]
loss: 0.7785 - binary_crossentropy: 0.6634      [1]
                                                  [0]
                                                  [1]
loss: 0.8075 - binary_crossentropy: 0.6468      [0]

```

Σχήμα 4.23 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 69% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι ενώ κάποιοι άλλοι είναι νυσταγμένοι.

	Χρονικά βήματα	Μετρικές επίδοσης
--	----------------	-------------------

Συναρτήσεις κόστους		Ακρίβεια	Δυαδική ακρίβεια	Δυαδική εγκάρσια εντροπία	Poisson
Δυαδική εγκάρσια εντροπία	1	63%	62%		80%
	5	65%	64%		82%
	30	72%	74%		83%
Poisson	1	62%	62%	60%	
	5	64%	64%	65%	
	30	74%	70%	69%	

Σχήμα 4.24 : Πίνακας αποτελεσμάτων ποσοστού επίδοσης πειραμάτων με συναρτήσεις κόστους και μετρικές επίδοσης

Επειδή το μεγαλύτερο ποσοστό έχουμε όταν για συνάρτηση κόστους έχουμε την δυαδική εγκάρσια εντροπία και για μετρική επίδοση έχουμε την poisson, κρατήσαμε αυτές τις αλλαγές για τα επόμενα πειράματα που αλλάζουμε την αρχιτεκτονική του μοντέλου.

4.3.2 Πειράματα με την αρχιτεκτονική του μοντέλου μας

Η αρχιτεκτονική που είχε το μοντέλο μας όταν έγιναν όλα τα αρχικά πειράματα, στα οποία αλλάζαμε μόνο την συνάρτηση κόστους και την μετρική επίδοση αποτελούταν από 7 στρώματα από τα οποία τα 6 ήταν LSTM στρώματα και το τελευταίο στρώμα είναι 1 πυκνό στρώμα. Οι νευρώνες που περιείχε κάθε στρώμα είναι 100, 100, 50, 40, 30, 10, 1 αντίστοιχα, με τα πρώτα 6 στρώματα να μην έχουν καμία συνάρτηση ενεργοποίησης και με το τελευταίο στρώμα να έχει συνάρτηση ενεργοποίησης της συνάρτηση σιγμοειδή (sigmoid). Επίσης, ανάμεσα σε κάθε στρώμα έχουμε και στρώματα εγκατάλειψης (dropout) με ποσοστό 20% για να αποφύγουμε την υπερμοντελοποίηση και να έχουμε πιο ακριβή αποτελέσματα.

1ο Πείραμα

Στο πρώτο πείραμα, αλλάξαμε μόνο τους νευρώνες που υπάρχουν στα στρώματα, οπότε το μοντέλο μας έχει 7 στρώματα, τα πρώτα 6 είναι LSTM στρώματα και το τελευταίο είναι ένα πυκνό στρώμα. Έχουμε μετά από κάθε στρώμα, στρώματα εγκατάλειψης με ποσοστό 20% και συνάρτηση ενεργοποίησης έχουμε μόνο στο τελευταίο στρώμα και είναι συνάρτηση σιγμοειδής. Τα πρώτα 5 στρώματα έχουν 100 νευρώνες, το 6ο στρώμα έχει 10 νευρώνες και το τελευταίο στρώμα είναι το ίδιο με 1 νευρώνα. Τα πειράματα που κάναμε είναι με 1 χρονικό βήμα, με 5 χρονικά βήματα και με 30 χρονικά βήματα.

Με 1 χρονικό βήμα:

```

· loss: 0.6663 - poisson: 0.7982

loss: 0.5857 - poisson: 0.7567      [0]
                                     [0]
                                     [0]
                                     ...
loss: 0.5952 - poisson: 0.7600      [0]
                                     [0]
                                     [0]

loss: 0.5884 - poisson: 0.7792

loss: 0.6086 - poisson: 0.7877

```

Σχήμα 4.25 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 80% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος).

Με 5 χρονικά βήματα:

```

- loss: 0.6883 - poisson: 0.8027

loss: 0.5917 - poisson: 0.7629 -      [0]
                                     [0]
                                     [0]
                                     [0]
loss: 0.5971 - poisson: 0.7556 -      [1]
                                     [1]
                                     [1]
loss: 0.5927 - poisson: 0.7753 -      [1]
                                     [1]
                                     [1]

loss: 0.5955 - poisson: 0.7533 -

```

Σχήμα 4.26 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 80% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι ενώ κάποιοι άλλοι είναι νυσταγμένοι.

Με 30 χρονικά βήματα:

```

- loss: 0.7001 - poisson: 0.8620

· loss: 0.6925 - poisson: 0.8116 · [0]
· loss: 0.6925 - poisson: 0.8116 · [1]
· loss: 0.6925 - poisson: 0.8116 · [1]
· loss: 0.6925 - poisson: 0.8116 · [0]
· loss: 0.6925 - poisson: 0.8116 · [0]
· loss: 0.6925 - poisson: 0.8116 · [1]
· loss: 0.6925 - poisson: 0.8116 · [0]
· loss: 0.6925 - poisson: 0.8116 · [0]

· loss: 0.6312 - poisson: 0.7477 ·

```

Σχήμα 4.27 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πάνει μια επίδοση του ύψους 86% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος) ενώ άλλοι συμμετέχοντες βρίσκονται στην κατάσταση 1(νυσταγμένος).

2ο Πείραμα

Στο δεύτερο πείραμα, αλλάξαμε επίσης μόνο τους νευρώνες που υπάρχουν στα στρώματα αλλά προσθέσαμε συνάρτηση ενεργοποίησης οπότε το μοντέλο μας παρέμεινε ίδιο σε σχέση πόσα στρώματα έχουμε. Άρα το μοντέλο μας έχει 7 στρώματα, τα πρώτα 6 είναι LSTM στρώματα και το τελευταίο είναι ένα πυκνό στρώμα. Έχουμε μετά από κάθε στρώμα, στρώματα εγκατάλειψης με ποσοστό 20% και συνάρτηση ενεργοποίησης έχουμε μόνο στο 6ο στρώμα και στο τελευταίο στρώμα και είναι συνάρτηση σιγμοειδής. Τα πρώτα 5 στρώματα να έχουν 50 νευρώνες, το 6ο στρώμα να έχει 10 νευρώνες και το τελευταίο στρώμα είναι το ίδιο με 1 νευρώνα. Τα πειράματα που κάναμε είναι με 1 χρονικό βήμα, με 5 χρονικά βήματα και με 30 χρονικά βήματα.

Με 1 χρονικό βήμα:

```

loss: 0.6825 - poisson: 0.8004

loss: 0.5913 - poisson: 0.7710      [0]
                                   [0]
                                   [0]

loss: 0.5948 - poisson: 0.7639      ...
                                   [0]
                                   [0]
                                   [0]

loss: 0.6077 - poisson: 0.7814

loss: 0.5815 - poisson: 0.7587

```

Σχήμα 4.28 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπηγίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 80% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι.

Με 5 χρονικά βήματα:

```

. loss: 0.6894 - poisson: 0.7979

                                   [0]
loss: 0.6684 - poisson: 0.7980      [0]
                                   [0]
                                   [0]
loss: 0.6224 - poisson: 0.7970      [0]
                                   [1]
                                   [1]
loss: 0.5989 - poisson: 0.7738      [1]
                                   [1]
                                   [1]
loss: 0.5793 - poisson: 0.7438      [1]
                                   - -

```

Σχήμα 4.29 : ορισμένες προβλέψεις υπηγίας

Επίδοση μοντέλου και

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 80% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος) ενώ άλλοι συμμετέχοντες βρίσκονται στην κατάσταση 1(νυσταγμένος).

Με 30 χρονικά βήματα:

```

- loss: 0.7987 - poisson: 0.8071
[0]
[1]
loss: 0.6855 - poisson: 0.7873 -
[1]
[0]
loss: 0.6997 - poisson: 0.8348 -
[0]
[1]
[0]
loss: 0.7005 - poisson: 0.8146 -
[0]
[0]

loss: 0.6900 - poisson: 0.8254 -

```

Σχήμα 4.30 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 83% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι ενώ κάποιοι άλλοι είναι νυσταγμένοι.

3ο Πείραμα

Στο τρίτο πείραμα, αλλάξαμε και σε αυτό μόνο τους νευρώνες που υπάρχουν στα στρώματα οπότε το μοντέλο παρέμεινε ίδιο σε σχέση πόσα στρώματα έχουμε. Άρα το μοντέλο μας έχει 7 στρώματα, τα πρώτα 6 είναι LSTM στρώματα και το τελευταίο είναι ένα πυκνό στρώμα. Έχουμε μετά από κάθε στρώμα, στρώματα εγκατάλειψης με ποσοστό 20% και συνάρτηση ενεργοποίησης έχουμε μόνο στο τελευταίο στρώμα και είναι συνάρτηση σιγμοειδής. Τα στρώματα μας έχουν νευρώνες 50, 40, 30, 20, 10, 10 αντίστοιχα και το τελευταίο στρώμα είναι με 1 νευρώνα. Τα πειράματα που κάναμε είναι με 1 χρονικό βήμα, με 5 χρονικά βήματα και με 30 χρονικά βήματα.

Με 1 χρονικό βήμα:

```

- loss: 0.6847 - poisson: 0.8094
[0]
loss: 0.6009 - poisson: 0.7694 .
[0]
...
loss: 0.5893 - poisson: 0.7726 .
[0]
[0]
loss: 0.5962 - poisson: 0.7699 .

```

Σχήμα 4.31 : loss: 0.5935 - poisson: 0.7710 · Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 81% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος).

Με 5 χρονικά βήματα:


```

- loss: 0.6915 - poisson: 0.8102

loss: 0.6529 - poisson: 0.7747 - [0]
[0]
[0]
loss: 0.5854 - poisson: 0.7550 - [0]
[0]
[1]
loss: 0.6073 - poisson: 0.7616 - [1]
[0]
[1]
loss: 0.5896 - poisson: 0.7739 -

```

Σχήμα 4.32 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 81% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι ενώ κάποιοι άλλοι είναι νυσταγμένοι.

Με 30 χρονικά βήματα:

```

- loss: 0.6968 - poisson: 0.8244

loss: 0.6637 - poisson: 0.7932 - [0]
[1]
[1]
loss: 0.6451 - poisson: 0.7827 - [0]
[0]
[1]
loss: 0.6135 - poisson: 0.8001 - [0]
[0]

loss: 0.6581 - poisson: 0.8170 -

```

Σχήμα 4.33 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 82% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος) ενώ άλλοι συμμετέχοντες βρίσκονται στην κατάσταση 1(νυσταγμένος).

4.3.3 Βελτιώσεις

Μετά τα πειράματα που κάναμε προσπάθειες να βελτιώσουμε και άλλο το μοντέλο μας και το επιτύχαμε. Το τελικό και βελτιωμένο μας μοντέλο αποτελείται από 6 στρώματα με μόνο στρώμα LSTM

να είναι το 2ο στρώμα και τα υπόλοιπα είναι πυκνά στρώματα. Σε κάθε στρώμα έχουμε συνάρτηση ενεργοποίησης εκτός από το στρώμα LSTM. Στο 1ο, στο 5ο και στο τελευταίο στρώμα έχουμε συνάρτηση ενεργοποίησης, την σιγμοειδή, στο 3ο στρώμα έχουμε την εφαπτόμενη(tanh) και στο 4ο στρώμα έχουμε την συνάρτηση γραμμική(relu). Επίσης έχουμε ένα στρώμα επιπεδοποίησης(flatten) το οποίο βρίσκεται μετά το στρώμα LSTM και έχουμε και 2 στρώματα εγκατάλειψης τα οποία βρίσκονται μετά το 4ο και 5ο στρώμα με ποσοστό 50%. Από νευρώνες έχουμε στα πρώτα 3 στρώματα 100 νευρώνες, στο 4ο έχουμε 50, στο 5ο έχουμε 25 και στο τελευταίο στρώμα έχουμε 1 νευρώνα. Από την πλευρά της συνάρτησης κόστους έχουμε την συνάρτηση δυαδική εγκάρσια εντροπία, στην μετρική επίδοση έχουμε την poisson και βελτιστοποιητή έχουμε τον Adam.

Με 1 χρονικό βήμα:

```
- loss: 0.7462 - poisson: 0.8349

loss: 0.6989 - poisson: 0.8119      [0]
                                   [0]
loss: 0.6890 - poisson: 0.8059      [0]
                                   ...
                                   [0]
loss: 0.6895 - poisson: 0.8073      [0]
                                   [0]

loss: 0.6894 - poisson: 0.8155
```

Σχήμα 4.34 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας μετά την βελτίωση

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 83% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι.

Με 5 χρονικά βήματα:

```
- loss: 0.7214 - poisson: 0.8371 [0]
                                   [0]
loss: 0.7210 - poisson: 0.8335 [0]
                                   [1]
loss: 0.6954 - poisson: 0.8103 [1]
                                   [1]
loss: 0.6944 - poisson: 0.8350 [1]
                                   [1]
loss: 0.6950 - poisson: 0.8108 [1]
```

Σχήμα 4.35 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας μετά την βελτίωση

Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 84% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος) ενώ άλλοι συμμετέχοντες βρίσκονται στην κατάσταση 1(νυσταγμένος).

Με 30 χρονικά βήματα:

```

- loss: 0.9016 - poisson: 0.9093 [0]
loss: 0.8298 - poisson: 0.9103 [1]
loss: 0.6951 - poisson: 0.8167 [0]
loss: 0.7758 - poisson: 0.8322 [0]
loss: 0.6955 - poisson: 0.8099 [0]

```

Σχήμα 4.36 : Επίδοση μοντέλου και ορισμένες προβλέψεις υπνηλίας μετά την βελτίωση
 Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 91% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι ενώ κάποιοι άλλοι είναι νυσταγμένοι.


Αρχιτεκτονικές	Χρονικά βήματα	Επιδόσεις
1ο Πείραμα 7 στρωματά/ πρώτα 6 LSTM, τελευταίο πυκνό στρωματά εγκατάλειψης μετά από κάθε στρώμα με ποσοστό 20% συνάρτηση ενεργοποίησης στο τελευταίο στρώμα και είναι σιγμοειδής πρώτα 5 στρωματά 100 νευρώνες, 6ο στρώμα 10νευρώνες, τελευταίο 1 νευρώνα	1	80%
	5	80%
	30	86%
2ο Πείραμα 7 στρωματά/ πρώτα 6 LSTM, τελευταίο πυκνό στρωματά εγκατάλειψης μετά από κάθε στρώμα με ποσοστό 20% συνάρτηση ενεργοποίησης στο 6ο και 7ο στρώμα και είναι σιγμοειδής πρώτα 5 στρωματά 50 νευρώνες, 6ο στρώμα 10νευρώνες, τελευταίο 1 νευρώνα	1	80%
	5	80%
	30	83%
3ο Πείραμα 7 στρωματά/ πρώτα 6 LSTM, τελευταίο πυκνό στρωματά εγκατάλειψης μετά από κάθε στρώμα με ποσοστό 20% συνάρτηση ενεργοποίησης στο τελευταίο στρώμα και είναι σιγμοειδής 1ο στρώμα 50 νευρώνες, 2ο 40 νευρώνες, 3ο 30 νευρώνες, 4ο 20 νευρώνες, 5ο 10 νευρώνες, 6ο 10 νευρώνες και το 7ο 1 νευρώνα	1	81%
	5	81%
	30	82%

Βελτίωση 6 στρώματα/ όλα πυκνά εκτός του 2ου στρώματος που είναι LSTM στρώματα εγκατάλειψης μετά το 4ο και 5ο στρώμα με ποσοστό 50% στρώμα επιπεδοποίησης μετά το στρώμα LSTM συνάρτηση ενεργοποίησης στο 1ο, 5ο, 6ο στρώμα και είναι σιγμοειδής συνάρτηση ενεργοποίησης στο 3ο στρώμα και είναι εφραπτομένη συνάρτηση ενεργοποίησης στο 4ο στρώμα και είναι γραμμική στο 1ο, 2ο και 3ο στρώμα έχουμε 100 νευρώνες, στο 4ο 50 νευρώνες, στο 5ο 25 νευρώνες και στο 6ο στρώμα έχουμε 1 νευρώνα	1	83%
	5	84%
	30	91%

Σχήμα 4.37 : Πίνακας αποτελεσμάτων ποσοστού επίδοσης πειραμάτων με την αρχιτεκτονική του μοντέλου μας και την βελτίωση

4.3.4 Πείραμα με καινούργιο, μη εκπαιδευμένο σύνολο δεδομένων στο εκπαιδευμένο μοντέλο μας

Αφού τελειώσαμε με τα πειράματα μας και βελτιώσαμε το μοντέλο μας αποφασίσαμε να δούμε πώς δουλεύει το εκπαιδευμένο μοντέλο μας, πάνω σε ένα σύνολο δεδομένων το οποίο δεν το έχει “δει” ξανά σε 30 χρονικά βήματα.



Σχήμα 4.38 : Προβλέψεις καινούργιου συνόλου δεδομένων

Στο Σχήμα 4.38 βλέπουμε τα αποτελέσματα από την πρόβλεψη του μοντέλου μας, πάνω στο καινούργιο σύνολο δεδομένων που του τροφοδοτήσαμε.

Εκτός από τις προβλέψεις του μοντέλου μας αποφασίσαμε να τρέξουμε ένα confusion matrix και τα βρούμε το precision, το recall και το accuracy. Το confusion matrix, επίσης γνωστός ως μήτρα σφάλματος, είναι ένας συνοπτικός πίνακας που χρησιμοποιείται για την αξιολόγηση της απόδοσης ενός μοντέλου ταξινόμησης. Ο αριθμός των σωστών και λανθασμένων προβλέψεων συνοψίζεται με τις τιμές μέτρησης και αναλύεται ανά τάξη. Το precision είναι η ικανότητα του ταξινομητή να μην χαρακτηρίζει ως θετικό ένα αρνητικό δείγμα, ενώ το recall είναι η ικανότητα του ταξινομητή να βρει όλα τα θετικά δείγματα. Το accuracy είναι ο λόγος των σωστών προβλέψεων προς το συνολικό αριθμό προβλέψεων.

```
array([[219, 21],
       [116, 4]], dtype=int64)
```

Σχήμα 4.39 : Confusion matrix

Στο Σχήμα 4.39 βλέπουμε τα αποτελέσματα που έβγαλε το confusion matrix.

		Πραγματικές τιμές	
		0	1
Τιμές πρόβλεψης	0	True Positive (TP) 219	False Positive (FP) 21
	1	False Negative (FN) 116	True Negative (TN) 4

Σχήμα 4.40 : Πίνακας εξήγησης των αποτελεσμάτων του confusion matrix

Στο Σχήμα 4.40 παρατηρούμε τα αποτελέσματα του confusion matrix και εξηγούμε ότι 219 προβλέψεις ανήκουν στο True Positive, 21 στο False Positive, 116 στο False Negative και στο True Negative ανήκουν 4 προβλέψεις.

Για να βρούμε το precision πρέπει να ακολουθήσουμε την συνάρτηση 4.7.

$$precision = \frac{TruePositive(TP)}{TruePositive(TP)+FalsePositive(FP)} \quad (4.7)$$

το αποτέλεσμα που μας βγήκε είναι 0.913.

Για να βρούμε το recall θα πρέπει να ακολουθήσουμε την συνάρτηση 4.8.

$$recall = \frac{TruePositive(TP)}{TruePositive(TP)+FalseNegative(FN)} \quad (4.8)$$

με την σειρά του, το αποτέλεσμα που βρήκαμε είναι 0.65.

Για να βρούμε την accuracy θα πρέπει να δούμε την συνάρτηση 4.9


$$accuracy = \frac{TruePositive(TP)+TrueNegative(TN)}{TruePositive(TP)+TrueNegative(TN)+FalsePositive(FP)+FalseNegative(FN)} \quad (4.9)$$

και το αποτέλεσμα που βρήκαμε ήταν 0.62.

4.3.5 Πείραμα με εικόνες στο εκπαιδευμένο μας μοντέλο

Προηγουμένως πειραματιστήκαμε με ένα καινούργιο σύνολο δεδομένων και είδαμε πόσο καλά λειτουργεί το μοντέλο μας με αυτό, τώρα αποφασίσαμε να πειραματιστούμε με εικόνες στις οποίες δεν έχει εκπαιδευτεί το μοντέλο μας και στο τέλος να εμφανίζει την εικόνα με την πρόβλεψη του. Δοκιμάσαμε με 2 εικόνες, η πρώτη εικόνα είναι από το σύνολο δεδομένων UTA-RLDD[7] και η δεύτερη εικόνα είναι δικιά μας.

1η Εικόνα



Σχήμα 4.41 : Πείραμα με την 1η εικόνα

Στο Σχήμα 4.41 βλέπουμε την εικόνα που δώσαμε σαν είσοδο στο μοντέλο μας και βλέπουμε την έξοδο του μοντέλου, η οποία είναι η ίδια η εικόνα μαζί με την πρόβλεψη του μοντέλου μας. Όσο για το ποσοστό επιτυχίας είχαμε περίπου 85%. Ανά 20 φορές, τις 17 φορές είχε σωστή πρόβλεψη, η οποία είναι η κατάσταση 0 δηλαδή όχι νυσταγμένος και τις άλλες 3 φορές πρόβλεπε λάθος την κατάσταση 1 δηλαδή νυσταγμένος.


```
y=(model.predict(datasetX_test_scaled) > 0.5).astype("int32")
```

```
image = plt.imread('frame110.jpg')  
plt.imshow(image)  
plt.axis('off')  
predicted_class_name = y  
_ = plt.title("Prediction: " + str(y))
```

Σχήμα 4.42 : Κώδικας εμφάνισης πρώτης εικόνας

Στο Σχήμα 4.42 βλέπουμε τον κώδικα με τον οποίο εμφανίζουμε στο τέλος την εικόνα που είχαμε σαν είσοδο μαζί με την πρόβλεψη του μοντέλου μας.

2η Εικόνα



Σχήμα 4.43 : Πείραμα με την 2η εικόνα

Στο Σχήμα 4.43 παρατηρούμαι την εικόνα που δώσαμε σαν είσοδο στο μοντέλο μας και βλέπουμε την έξοδο του μοντέλου, η οποία είναι η ίδια η εικόνα μαζί με την πρόβλεψη του μοντέλου μας. Όσο για το ποσοστό επιτυχίας είχαμε περίπου 65%. Ανά 20 φορές, τις 13 φορές είχε σωστή πρόβλεψη, η οποία είναι η κατάσταση 0 δηλαδή όχι νυσταγμένος και τις άλλες 7 φορές πρόβλεπε λάθος την κατάσταση 1 δηλαδή νυσταγμένος. Ένας λόγος που είχαμε μια διαφορά του ύψους 20% με την 1η εικόνα είναι λόγο ότι η 2η εικόνα, η δικιά μας εικόνα δεν πάρθηκε κάτω από καλό φωτισμό με αποτέλεσμα μερικές φορές το μοντέλο να μην μπορεί να διαχωρίσει αν τα μάτια μας είναι κλειστά ή λίγο κλειστά ή ακόμα και ανοιχτά.

```
y=(model.predict(datasetX_test_scaled) > 0.5).astype("int32")
```

```
image = plt.imread('1234.jpg')  
plt.imshow(image)  
plt.axis('off')  
predicted_class_name = y  
_ = plt.title("Prediction: " + str(y))
```

Σχήμα 4.44 : Κώδικας εμφάνισης δεύτερης εικόνας

Στο Σχήμα 4.44 παρατηρούμε τον κώδικα με τον οποίο εμφανίζουμε στο τέλος την εικόνα που είχαμε σαν είσοδο μαζί με την πρόβλεψη του μοντέλου μας.

4.3.6 Συμπεράσματα Πειραμάτων

Τα συμπεράσματα που μπορεί κανείς να βγάλει από τα πειράματα, φυσικά είναι ότι με την πρόσθεση περισσότερων στρωμάτων ή την πρόσθεση και άλλων νευρώνων, η επίδοση του μοντέλου μπορεί να αυξηθεί αλλά και με το να έχεις μια συνάρτηση ενεργοποίησης στα στρώματα μπορεί να οδηγήσεις σε αύξηση της επίδοσης. Ωστόσο, αυτό που γίνεται πολύ σαφές είναι ότι με 30 χρονικά βήματα είχαμε καλύτερα ποσοστά επίδοσης με σχέση τα 5 χρονικά βήματα και το 1 χρονικό βήμα, που σημαίνει ότι όταν τον μοντέλο μας παρακολουθεί περισσότερες παλαιότερες τιμές, τότε έχει μεγαλύτερο ποσοστό να προβλέψει την επόμενη ή τις επόμενες καινούργιες τιμές.

4.4 Άλλα μοντέλα

Εκτός από τα πειράματα που κάναμε με το δικό μας μοντέλο, πειραματιστήκαμε με έτοιμα μοντέλα από άλλες έρευνες, με τις έρευνες αυτές να τις έχουμε αναφέρει στο κομμάτι σχετικές εργασίες για να δούμε τις διαφορές στα αποτελέσματα που θα έχουμε. Τα μοντέλα που μπορέσαμε να δουλέψουν από τις εργασίες αυτές, είναι το MLP[1] και το μονοδιάστατο CNN[2] όπου καταφέραμε να βγάλουν αποτελέσματα αλλά δεν μπορέσαμε να αποκτήσουμε παρόμοια αποτελέσματα με αυτά που αναφέρουν μέσα στις έρευνες. Αυτό πολύ πιθανόν να οφείλεται στην χρήση διαφορετικών σύνολο δεδομένων αφού στην περίπτωση του μονοδιάστατου CNN έγινε χρήση συνόλου δεδομένων με εικόνες ενώ τώρα είχε τιμές, ενώ στην περίπτωση του MLP έγινε χρήση συνόλου δεδομένων με τιμές και τις δύο φορές αλλά με διαφορετικά στοιχεία. Στην περίπτωση του MLP το σύνολο δεδομένων είχε τιμές από τα μάτια, το στόμα και το κεφάλι ενώ το δικό μας είχε τιμές καθαρά μόνο από τα μάτια και το στόμα, το οποίο στην ουσία σημαίνει ότι το μοντέλο δουλεύει με διαφορετικές μεταβλητές για αυτό και τα διαφορετικά αποτελέσματα. Όσο για τα αποτελέσματα είχαμε μια επιτυχία 61-65% που σημαίνει ότι το μοντέλο δουλεύει καλά αλλά θα μπορούσε να δουλεύει και πολύ καλύτερα αφού στις έρευνες βλέπουμε αποτελέσματα 75-90%.

4.4.1 Πείραμα με MLP

Το μοντέλο MLP αποτελείται από 5 πυκνά στρώματα, με τα πρώτα 4 στρώματα να έχουν συνάρτηση ενεργοποίησης την συνάρτηση γραμμική ενώ το τελευταίο στρώμα έχει την συνάρτηση softmax. Επίσης έχουμε μετά από κάθε στρώμα και στρώματα εγκατάλειψης με ποσοστό 20%. Όσο για τους νευρώνες έχουμε 100, 10, 10, 10, 1 αντίστοιχα. Για βελτιστοποιητή έχουμε τον Adam, για συνάρτηση κόστους έχουμε την δυαδική εγκάρσια εντροπία και για μετρική επίδοση έχουμε την ακρίβεια. Επειδή η πρόβλεψη που κάνουν στην έρευνα είναι ανάμεσα σε 3 αποτελέσματα, ενώ σε εμάς είναι ανάμεσα σε 2 χρησιμοποιήσαμε σαν συνάρτηση ενεργοποίησης στο τελευταίο στρώμα, την συνάρτηση σιγμοειδής. Τέλος σαν είσοδο είχε σύνολο δεδομένων είναι το δικό μας σύνολο δεδομένων με 5 χρονικά βήματα.


```

loss: 0.5369 - accuracy: 0.5947
[0]
loss: 0.5744 - accuracy: 0.5344
[0]
[0]
[0]
[0]
loss: 0.5241 - accuracy: 0.6049
[0]
[0]
[0]
loss: 0.5359 - accuracy: 0.5860
[0]
[0]
[0]
[0]
loss: 0.5049 - accuracy: 0.6518

```

Σχήμα 4.45 : Επίδοση μοντέλου MLP με σιγμοειδή και ορισμένες προβλέψεις υπνηλίας

Παρατηρούμε ότι το μοντέλο πιάνει μια επίδοση 65% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες δεν είναι νυσταγμένοι. Ωστόσο δοκιμάσαμε και με την συνάρτηση ενεργοποίησης softmax για να έχουμε ακριβώς το ίδιο μοντέλο με την έρευνα αλλά τα αποτελέσματα ήταν πολύ χαμηλότερα από ότι με την συνάρτηση ενεργοποίησης σιγμοειδή που φτάσανε στο 35%.

```
loss: 8.4147 - accuracy: 0.2580
```

```
loss: 8.0580 - accuracy: 0.3320
```

```
loss: 8.5946 - accuracy: 0.2689
```

```
loss: 8.1402 - accuracy: 0.3054
```

```
loss: 7.9455 - accuracy: 0.3042
```

```
loss: 7.5152 - accuracy: 0.3517
```

Σχήμα 4.46 : Επίδοση μοντέλου MLP με softmax

4.4.2 Πείραμα με μονοδιάστατο CNN

Το μονοδιάστατο μοντέλο CNN αποτελείται από 2 στρώματα, με το 1ο στρώμα να είναι ένα μονοδιάστατο στρώμα CNN με 20 νευρώνες και το μέγεθος του φίλτρου(kernal) είναι 2 και με το 2ο στρώμα να είναι ένα απλό στρώμα με 1 νευρώνα και συνάρτηση ενεργοποίησης την softmax. Για βελτιστοποιητή έχουμε τον Adam, για συνάρτηση κόστους έχουμε την δυαδική εγκάρσια εντροπία και για μετρική επίδοση έχουμε την ακρίβεια. Επειδή η πρόβλεψη που κάνουν στην έρευνα είναι ανάμεσα σε 3 αποτελέσματα, ενώ σε εμάς είναι ανάμεσα σε 2 χρησιμοποιήσαμε σαν συνάρτηση ενεργοποίησης στο τελευταίο στρώμα, την συνάρτηση σιγμοειδής. Τέλος σαν είσοδο είχε σύνολο δεδομένων είναι το δικό μας σύνολο δεδομένων με 5 χρονικά βήματα.

```

loss: 0.5577 - accuracy: 0.5966

loss: 0.5890 - accuracy: 0.5734 [0]
[0]
[0]
loss: 0.5761 - accuracy: 0.5533 [1]

loss: 0.5683 - accuracy: 0.6011 [0]
[0]
[0]
loss: 0.5508 - accuracy: 0.6091 [0]

```

Σχήμα 4.47 : Επίδοση μοντέλου 1D-CNN με σιγμοειδή και ορισμένες προβλέψεις υπνηλίας
 Βλέπουμε το μοντέλο αυτό να πιάνει μια επίδοση του ύψους 61% και έχουμε μια πρόβλεψη ότι οι συμμετέχοντες βρίσκονται στην κατάσταση 0(όχι νυσταγμένος) ενώ άλλοι συμμετέχοντες βρίσκονται στην κατάσταση 1(νυσταγμένος). Παρόλα αυτά, δοκιμάσαμε και με την συνάρτηση ενεργοποίησης softmax για να έχουμε ακριβώς το ίδιο μοντέλο με την έρευνα αλλά τα αποτελέσματα ήταν πολύ χαμηλότερα από ότι με την συνάρτηση ενεργοποίησης σιγμοειδή που φτάσανε στο 34%.

```

loss: 8.5765 - accuracy: 0.2785

loss: 8.3586 - accuracy: 0.2688

loss: 9.0463 - accuracy: 0.2352

loss: 8.6287 - accuracy: 0.2824

loss: 7.6593 - accuracy: 0.3383

```

Σχήμα 4.48 : Επίδοση μοντέλου 1D-CNN με softmax

5. ΣΥΜΠΕΡΑΣΜΑΤΑ - ΠΡΟΤΑΣΕΙΣ

Στην διπλωματική εργασία αυτή προτείνουμε βαθύ νευρωνικό δίκτυο για την πρόβλεψη της κατάστασης του χειριστή και ποιο ιδικά την υπνηλία οδηγού αυτοκινήτου. Τα αποτελέσματα που βγάλαμε είναι αρκετά υψηλά, που σημαίνει ότι ένα τέτοιο σύστημα μπορεί να προβλέψει την υπνηλία οδηγού, οπότε μπορεί να χρησιμοποιηθεί σε συστήματα μέσα στο αμάξι για την αποφυγή ατυχημάτων. Σαν είσοδο στο δίκτυο χρησιμοποιούμε το σύνολο δεδομένων, με τις μετρήσεις που πήραμε με την βοήθεια των χαρακτηριστικών των προσώπων των οδηγών, το οποίο το αναλύσαμε με χρονικές σειρές και μεταμορφώσαμε με την βοήθεια των χρονικών βημάτων. Όσο για προτάσεις, για μελλοντικές εργασίες, αλλαγή στην αρχιτεκτονική του μοντέλου με την πρόσθεση και άλλων LSTM στρωμάτων ή αλλαγή στα πόσα χρονικά βήματα έχουμε μπορεί να κάνει το μοντέλο να έχει καλύτερα αποτελέσματα. Φυσικά, η ύπαρξη μεγαλύτερου συνόλου δεδομένων για εκπαίδευση και δοκιμή είναι ένα τρόπος για να αυξηθεί η ακρίβεια και επιτυχία του μοντέλου μας, Επίσης, όπως είδαμε στα πειράματα με εικόνες, στην εικόνα με όχι τόσο καλό φωτισμό τα αποτελέσματα μας δεν ήταν τόσο καλά όσο με την εικόνα που πάρθηκε με καλό φωτισμό, οπότε μία πρόταση είναι τα σύνολα δεδομένων μας να παίρνονται μέσα από διάφορες καταστάσεις όπως την νύκτα, την μέρα, με γυαλιά και χωρίς γυαλιά. Όσο για τον φωτισμό, μία λύση είναι όταν παίρνονται οι μετρήσεις από το σύστημα μέσα στο αυτοκίνητο να ανοίγει αυτόματα και ένα φως, για παράδειγμα το φως από τον μπροστινό καθρέφτη ή από την οροφή.

ΣΥΝΤΟΜΟΓΡΑΦΙΕΣ - ΑΚΡΩΝΥΜΑ

ANN	Artificial neural networks
RNN	Recurrent neural networks
CNN	Convolutional neural networks
MLP	Multilayer perceptron
LSTM	Long short-term memory
FRNN	Fully recurrent neural networks

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] Rateb Jabbara , Khalifa Al-Khalifa, Mohamed Kharbeche, Wael Alhajyaseen, Mohsen Jafari, Shan Jiang . Real-time Driver Drowsiness Detection for Android Application Using Deep Neural Networks Techniques. The 9th International Conference on Ambient Systems, Networks, and Technologies (ANT 2018). Procedia Computer Science 130 (2018) 400–407
- [2] Mkhuseleli Ngxande , Jules-Raymond Tapamo , Michael Burke . Driver drowsiness detection using Behavioral measures and machine learning techniques: A review of state-of-art techniques . Η κριτική αυτή είναι διαθέσιμη στο https://researchspace.csir.co.za/dspace/bitstream/handle/10204/10018/Ngxande_20148_2017.pdf?sequence=1&isAllowed=y
- [3] Bhargava Reddy, Ye-Hoon Kim, Sojung Yun, Chanwon Seo, Junik Jang . Real-time Driver Drowsiness Detection for Embedded System Using Model Compression of Deep Neural Networks . Η κριτική αυτή είναι διαθέσιμη στο https://openaccess.thecvf.com/content_cvpr_2017_workshops/w4/papers/Reddy_Real-Time_Driver_Drowsiness_CVPR_2017_paper.pdf
- [4] T. Vesselenyi et al 2017 IOP Conf. Ser.: Mater. Sci. Eng. 252 012097 . Driver drowsiness detection using ANN image processing
- [5] Venkata Rami Reddy Chirra , Srinivasulu Reddy Uyyala , Venkata Krishna Kishore Kolli. Deep CNN: A Machine Learning Approach for Driver Drowsiness Detection Based on Eye State . Vol. 33, No. 6, December, 2019, pp. 461-466
- [6] Jie Lyu , Zejian Yuan , Dapeng Chen . Long-term Multi-granularity Deep Framework for Driver Drowsiness Detection .arXiv:1801.02325v1 [cs.CV] 8 Jan 2018.
- [7] Το σύνολο δεδομένων που χρησιμοποιήσαμε μπορεί να βρεθεί στο <https://sites.google.com/view/utarlidd/home> . Οι άνθρωποι που έφτιαξαν το σύνολο δεδομένων αυτό έκαναν και την δική τους ερευνητική έρευνα και μπορεί κανείς να την βρει στο <https://arxiv.org/abs/1904.07312> .
- [8] National Center for Statistics and Analysis. (2017, October). Drowsy Driving 2015 (Crash•Stats Brief Statistical Summary. Report No. DOT HS 812 446). Washington, DC: National Highway Traffic Safety Administration.
- [9] Owens, J.M., Dingus, T.A., Guo, F., Fang, Y., Perez, M., McClafferty, J. & Tefft, B.C. (2018). *Prevalence of Drowsy Driving Crashes: Estimates from a Large-Scale Naturalistic Driving Study*(Research Brief). Washington, D.C.: AAA Foundation for Traffic Safety.
- [10] Mitchell, T. (1997). *Machine Learning*, McGraw Hill, *Machine Learning*, McGraw Hill, p.2.
- [11] Langley, P., & Carbonell, J. G. (1987). Machine learning: techniques and foundations. *UC Irvine: Donald Bren School of Information and Computer Sciences*. Retrieved from <https://escholarship.org/uc/item/8160p39f>.

- [12] Ian H. Witten, Eibe Frank, and Mark A. Hall. 2011. *Data Mining: Practical Machine Learning Tools and Techniques (3rd. ed.)*. Morgan Kaufmann Publishers Inc., San Francisco, CA, USA.
- [13] Neural networks. II. What are they and why is everybody so interested in them now?; Wasserman, P.D.; Schwartz, T.; Page(s): 10-15; IEEE Expert, 1988, Volume 3, Issue 1
- [14] "BMW model upgrade measures taking effect from the summer of 2013". BMW. 2013-06-05. Retrieved 2015-11-05.
- [15] "Driver Attention Monitor | 2017 Honda CR-V | Honda Owners Site". *owners.honda.com*. Retrieved 2018-03-23.
- [16] "Driver Attention Alert - Mazda i-ACTIVSENSE".
- [17] "ATTENTION ASSIST: Drowsiness-detection system warns drivers to prevent them falling asleep momentarily". Retrieved 18 February 2010
- [18] "2016 Nissan Maxima "4-Door Sports Car" makes global debut at New York International Auto Show". Nissan Online Newsroom. Retrieved 4 April 2015.
- [19] "Volvo Cars introduces new systems for alerting tired and distracted drivers". Retrieved 28 August 2007.
- [20] Κανονισμός (ΕΕ) 2019/2144 μπορεί κανείς να το βρει στην ιστοσελίδα: <https://eur-lex.europa.eu/eli/reg/2019/2144/oj> .
- [21] Phil Simon (18 Μαρτίου 2013). Too Big to Ignore: The Business Case for Big Data. Wiley. Σελ.89. ISBN 978-1-118-63817-0.
- [22] Goldberg, David E.; Holland, John H. (1988). «Genetic algorithms and machine learning». *Machine Learning* 3 (2): 95–99.doi:10.1007/bf00113892.
- [23] Michie, D.· Spiegelhalter, D. J.· Taylor, C. C. (1994). *Machine Learning, Neural and Statistical Classification*. Ellis Horwood.