



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΑΙΓΑΙΟΥ  
ΠΟΛΥΤΕΧΝΙΚΗ ΣΧΟΛΗ**

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΑΚΩΝ ΚΑΙ ΕΠΙΚΟΙΝΩΝΙΑΚΩΝ ΣΥΣΤΗΜΑΤΩΝ

ΠΡΟΓΡΑΜΜΑ ΜΕΤΑΠΤΥΧΙΑΚΩΝ ΣΠΟΥΔΩΝ

ΔΙΑΔΙΚΤΥΟ ΤΩΝ ΠΡΑΓΜΑΤΩΝ: ΕΥΦΥΗ ΠΕΡΙΒΑΛΛΟΝΤΑ ΣΕ ΔΙΚΤΥΑ ΝΕΑΣ ΓΕΝΙΑΣ

**Έξυπνο Σύστημα Πρόβλεψης Πυρκαγιάς**

**ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ**

της

**Πολυμένη Σοφίας**

**Επιβλέπων :** Κορμέντζας Γεώργιος

**Μέλη εξεταστικής επιτροπής:**

Σάμος, Οκτώβριος 2020

Η σελίδα αυτή είναι σκόπιμα λευκή.

## Πρόλογος και ευχαριστίες

Η παρούσα διπλωματική εργασία υλοποιήθηκε στα πλαίσια ολοκλήρωσης του Προγράμματος Μεταπτυχιακών Σπουδών με τίτλο «Διαδίκτυο των Πραγμάτων: Ευφυή Περιβάλλοντα σε Δίκτυα Νέας Γενιάς» του τμήματος Μηχανικών Πληροφοριακών και Επικοινωνιακών Συστημάτων του Πανεπιστημίου Αιγαίου, κατά το εαρινό εξάμηνο του ακαδημαϊκού έτους 2019-2020.

Η συμβολή όλων των διδασκόντων του προγράμματος κατέστη ιδιαίτερα χρήσιμη, τόσο στην επιτυχή ολοκλήρωση των σπουδών, όσο και στη συγγραφή της συγκεκριμένης διπλωματικής εργασίας. Ωστόσο, θα ήθελα να ευχαριστήσω συγκεκριμένα τον επιβλέποντα καθηγητή μου κ. Κορμέντζα Γεώργιο, καθηγητή του Πανεπιστημίου Αιγαίου, για την αποδοχή, την άψογη συνεργασία, την υποστήριξη και την εποικοδομητική καθοδήγηση στην περάτωση της συγκεκριμένης εργασίας.

Τέλος, θα ήθελα να ευχαριστήσω ιδιαίτερα την οικογένειά μου για τη συνεχή στήριξη και τη συμπαράσταση μέχρι την ολοκλήρωση των σπουδών μου.

© 2020

της

ΠΟΛΥΜΕΝΗ ΣΟΦΙΑΣ

Τμήμα Μηχανικών Πληροφοριακών και Επικοινωνιακών Συστημάτων

ΠΑΝΕΠΙΣΤΗΜΙΟ ΑΙΓΑΙΟΥ

Η σελίδα αυτή είναι σκόπιμα λευκή.

## Πίνακας περιεχομένων

<b>1</b>	<b>Εισαγωγή .....</b>	<b>1</b>
1.1	Διαδίκτυο των Πραγμάτων .....	1
1.2	Αντικείμενο της Διπλωματικής.....	4
1.3	Μεθοδολογική Προσέγγιση .....	4
1.4	Δομή της Διπλωματικής.....	5
<b>2</b>	<b>Συναφή Συστήματα.....</b>	<b>6</b>
2.1	Παρακολούθηση Πυρκαγιάς.....	6
2.2	Εντοπισμός Πυρκαγιάς .....	6
<b>3</b>	<b>Θεωρητικό Υπόβαθρο.....</b>	<b>8</b>
3.1	Μεταφορά Δεδομένων Συστήματος.....	8
3.1.1	<i>Τεχνολογίες Επικοινωνιών.....</i>	<i>8</i>
3.1.2	<i>Δικτυκά Πρωτόκολλα.....</i>	<i>12</i>
3.2	Τεχνητά Νευρωνικά Δίκτυα.....	14
3.2.1	<i>Εισαγωγικές Έννοιες.....</i>	<i>14</i>
3.2.2	<i>Αρχιτεκτονική Νευρωνικών Δικτύων.....</i>	<i>15</i>
3.2.3	<i>Κατασκευή του Μοντέλου.....</i>	<i>17</i>
3.2.3.1	Τύποι Εκμάθησης .....	17
3.2.3.2	Συναρτήσεις Ενεργοποίησης .....	19
3.2.3.3	Φάση Εκπαίδευσης .....	21
3.2.3.4	Σύνολα Δεδομένων .....	24
3.2.4	<i>Βασικές Κατηγορίες Νευρωνικών Δικτύων .....</i>	<i>25</i>
3.2.4.1	Μοντέλα Αισθητήρων (Perceptrons) .....	25
3.2.4.2	Δίκτυα Πρόσθιας Τροφοδότησης (Feed Forward Neural Networks).....	26
3.2.4.3	Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks).....	27
3.2.4.4	Δίκτυα Long/Short Term Memory.....	28
3.2.4.5	Δίκτυα Gated Recurrent Unit.....	30
3.2.4.6	Δίκτυα Auto-encoder .....	31
3.2.5	<i>Πλεονεκτήματα Νευρωνικών Δικτύων.....</i>	<i>32</i>
<b>4</b>	<b>Εξοπλισμός.....</b>	<b>33</b>
4.1	Πλακέτα ESP32 .....	33
4.2	Αισθητήρας Θερμοκρασίας-Υγρασίας.....	37
4.3	Αισθητήρας Υγρασίας Εδάφους .....	38

4.4	Αισθητήρας Φωτός .....	39
<b>5</b>	<b>Λογισμικό και Πλατφόρμες Δεδομένων .....</b>	<b>40</b>
5.1	Arduino IDE.....	40
5.2	ThingSpeak .....	40
5.3	OpenWeatherMap .....	42
5.4	Keras .....	42
5.5	TensorFlow .....	43
<b>6</b>	<b>Προκλήσεις και Περιορισμοί Συστήματος.....</b>	<b>44</b>
<b>7</b>	<b>Υλοποίηση.....</b>	<b>47</b>
7.1	Περιγραφή Συστήματος .....	47
7.2	Εφαρμογή.....	49
7.3	Προγραμματισμός Πλακέτας .....	51
7.4	Σύνολο Δεδομένων .....	52
7.5	Δημιουργία Μοντέλου Πρόβλεψης.....	55
7.5.1	Προεπεξεργασία Δεδομένων.....	55
7.5.2	Σύνολα Εκπαίδευσης και Επαλήθευσης.....	58
7.5.3	Stacked LSTM Δύο Κατευθύνσεων.....	59
<b>8</b>	<b>Αξιολόγηση Απόδοσης .....</b>	<b>63</b>
8.1	Αποτελέσματα Πρόβλεψης του Μοντέλου .....	63
8.2	Υπολογισμός Βαθμού Επικινδυνότητας .....	65
8.3	Αποστολή Ειδοποιήσεων .....	67
<b>9</b>	<b>Σύνοψη και Συμπεράσματα.....</b>	<b>69</b>
	<b>Βιβλιογραφία.....</b>	<b>70</b>

## Λίστα Σχημάτων

Σχήμα 1. Εφαρμογές του Διαδικτύου των Πραγμάτων.....	3
Σχήμα 2. Τεχνολογία Bluetooth Low Energy.....	9
Σχήμα 3. Διαφορά τεχνολογίας Wi-Fi και Bluetooth.....	10
Σχήμα 4. Σχηματική αναπαράσταση της ροής δεδομένων στο πρωτόκολλο MQTT.....	13
Σχήμα 5. Κόμβος νευρωνικού δικτύου.....	15
Σχήμα 6. Παράδειγμα επιπέδων νευρωνικού δικτύου.....	16
Σχήμα 7. Αλγοριθμική διαφορά μεταξύ επιβλεπόμενης και μη επιβλεπόμενης μάθησης σ' ένα νευρωνικό δίκτυο.....	18
Σχήμα 8. Συναρτήσεις ενεργοποίησης με τους αντίστοιχους τύπους υπολογισμού: (α) Σιγμοειδής συνάρτηση, (b) Συνάρτηση υπερβολικής εφαπτομένης και (c) Ανορθωμένη γραμμική συνάρτηση...20	20
Σχήμα 9. Διαδικασία εκπαίδευσης ενός νευρωνικού δικτύου.....	22
Σχήμα 10. Σχηματική αναπαράσταση μοντέλου αισθητήρα.....	25
Σχήμα 11. Σχηματική αναπαράσταση δικτύου πρόσθιας τροφοδότησης.....	26
Σχήμα 12. Σχηματική αναπαράσταση αναδρομικού νευρωνικού δικτύου.....	27
Σχήμα 13. Σχηματική αναπαράσταση δικτύου Long/Short Term Memory.....	28
Σχήμα 14. Διαφορά μεταξύ Απλού LSTM και LSTM Δύο Κατευθύνσεων.....	29
Σχήμα 15. Σχηματική αναπαράσταση δικτύου Gated Recurrent Unit.....	30
Σχήμα 16. Σχηματική αναπαράσταση δικτύου Auto-encoder.....	31
Σχήμα 17. Πλακέτα ESP32.....	33
Σχήμα 18. Διάγραμμα λειτουργίας ESP32.....	35
Σχήμα 19. Αισθητήρας θερμοκρασίας-υγρασίας DHT22.....	37
Σχήμα 20. Αισθητήρας υγρασίας εδάφους.....	38
Σχήμα 21. Αισθητήρας φωτός.....	39
Σχήμα 22. Μεταφορά δεδομένων στο ThingSpeak.....	41
Σχήμα 23. Γραφική αναπαράσταση λειτουργίας του TensorFlow.....	43
Σχήμα 24. Διάγραμμα λειτουργίας του συστήματος.....	47
Σχήμα 25. Συνδεσμολογία συστήματος.....	50
Σχήμα 26. Το κανάλι που δημιουργήθηκε για την καταγραφή των δεδομένων.....	52
Σχήμα 27. Τιμές θερμοκρασίας και υγρασίας από τον αισθητήρα DHT22.....	53
Σχήμα 28. Τιμές υγρασίας εδάφους από τον αισθητήρα YL-69 και επιπέδου φωτεινότητας από τον BH1750.....	53
Σχήμα 29. Τιμές ατμοσφαιρικής πίεσης από το OpenWeatherMap.....	53
Σχήμα 30. Τιμές ταχύτητας και κατεύθυνσης του ανέμου από το OpenWeatherMap.....	54
Σχήμα 31. Φιλτράρισμα των αρνητικών τιμών της ταχύτητας ανέμου.....	55
Σχήμα 32. Γραφικές απεικονίσεις ταχύτητας ανέμου (a) πριν και (b) μετά το φιλτράρισμα, και μέγιστης ταχύτητας ανέμου (c) πριν και (d) μετά το φιλτράρισμα.....	56
Σχήμα 33. Πίνακας συσχετίσεων δεδομένων.....	56
Σχήμα 34. Προεπεξεργασία δεδομένων.....	57
Σχήμα 35. Σύνολο δεδομένων εκπαίδευσης.....	58
Σχήμα 36. Σύνολο δεδομένων επαλήθευσης.....	58
Σχήμα 37. Διάγραμμα ροής του προτεινόμενου μοντέλου πρόβλεψης.....	59

Σχήμα 38. Stacked LSTM μοντέλο δύο κατευθύνσεων.....	60
Σχήμα 39. Εκπαίδευση του μοντέλου.....	61
Σχήμα 40. Τιμές training και validation loss του μοντέλου.....	61
Σχήμα 41. Σύγκριση training και validation loss για το μοντέλο για 20 εποχές.....	62
Σχήμα 42. Αποτελέσματα πρόβλεψης θερμοκρασίας, υγρασίας και ταχύτητας αέρα.....	63
Σχήμα 43. Αποτελέσματα πρόβλεψης θερμοκρασίας, υγρασίας και ταχύτητας αέρα.....	64
Σχήμα 44. Το κανάλι που δημιουργήθηκε για την καταγραφή του βαθμού επικινδυνότητας και την αποστολή των ειδοποιήσεων.....	67
Σχήμα 45. Μήνυμα ειδοποίησης συστήματος σε περίπτωση (a) κατάστασης συναγερμού, (b) πολύ υψηλού κινδύνου και (c) υψηλού κινδύνου. ....	68



## Λίστα Πινάκων

Πίνακας I. Διαφορές ZigBee, Bluetooth, Wi-Fi.....	11
Πίνακας II. Στοιχεία πλακέτας ESP32. ....	34
Πίνακας III. Καταστάσεις λειτουργίας ESP32. ....	36
Πίνακας IV. Αντιστοίχιση της κατηγορίας κινδύνου εκδήλωσης πυρκαγιάς με τον κάθε βαθμό επικινδυνότητας.....	66

## Ακρωνύμια

<b>ΔτΠ</b>	Διαδίκτυο των Πραγμάτων
<b>BP</b>	Back-Propagation
<b>ΑΔΑ</b>	Ασύρματο Δίκτυο Αισθητήρων
<b>GPS</b>	Global Position System
<b>GSM</b>	Global System for Mobile Communications
<b>BLE</b>	Bluetooth Low Energy
<b>WLAN</b>	Wireless Local Area Network
<b>WPAN</b>	Wireless Personal Area Network
<b>P2P</b>	Peer-to-peer
<b>CRC</b>	Cyclic Redundancy Check
<b>SSL</b>	Secure Sockets Layer
<b>QoS</b>	Quality of Service
<b>TNΔ</b>	Τεχνητό Νευρωνικό Δίκτυο
<b>LSTM</b>	Long/Short Term Memory
<b>BiLSTM</b>	Bidirectional Long/Short Term Memory
<b>GRU</b>	Gated Recurrent Unit
<b>AD</b>	Analog-to-Digital
<b>AES</b>	Advanced Encryption Standard
<b>RAM</b>	Random Access Memory
<b>CPU</b>	Central Processing Unit
<b>RTC</b>	Real-time Clock
<b>ULP</b>	Ultra-Low Power
<b>DTIM</b>	Delivery Traffic Indication Message
<b>I2C</b>	Inter-Integrated Circuit
<b>IDE</b>	Integrated Development Environment
<b>API</b>	Application Programming Interface
<b>GPU</b>	Graphics Processing Unit
<b>TPU</b>	Tensor Processing Unit
<b>WEP</b>	Wired Equivalent Privacy
<b>WPA</b>	Wi-Fi Protected Access

## Περίληψη

Οι δασικές πυρκαγιές είναι ένας από τους πιο κοινούς κινδύνους που μπορεί να εμφανιστούν σε μια δασική έκταση. Ως εκ τούτου, η βελτίωση του επιπέδου εκσυγχρονισμού της παρακολούθησής τους, με χρήση τεχνολογιών και επικοινωνιών, έχει στρατηγική σημασία για πολλές χώρες όπου εμφανίζονται συχνά δασικές πυρκαγιές.

Γενικά, η διαδικασία της παρακολούθησης μιας πυρκαγιάς αποτελείται από τρεις επιμέρους χρονικές φάσεις: (α) προ-πυρκαγιάς, με τη λήψη κατάλληλων μέτρων για τον έλεγχό της, (β) κατά τη διάρκεια της πυρκαγιάς, ανίχνευσή της και προγραμματισμός για τον έλεγχό της, και (γ) μετά-πυρκαγιάς, με την εκτίμηση ζημιών και το σχεδιασμό μετριασμού τους.

Σήμερα, για την ανίχνευση δασικών πυρκαγιών χρησιμοποιείται το δορυφορικό σύστημα, το οποίο όμως λειτουργεί μόνο όταν η πυρκαγιά εξαπλώνεται σε μεγάλη περιοχή, καθιστώντας το ένα μη ιδιαίτερα αποδοτικό σύστημα πρόβλεψης, καθώς περίπου το 80% των απωλειών δασικών εκτάσεων από μια πυρκαγιά προκύπτει λόγω της καθυστερημένης ανίχνευσής της. Σ' αυτό το σημείο, λοιπόν, εισάγονται οι έννοιες του Διαδικτύου των Πραγμάτων και των Τεχνητών Νευρωνικών Δικτύων.

Στόχος της συγκεκριμένης διπλωματικής εργασίας είναι να προτείνει ένα μοντέλο έγκαιρης πρόβλεψης πυρκαγιάς, με τη βοήθεια της πλακέτας ESP32 και άλλων απαιτούμενων αισθητήρων. Η εργασία αυτή παρουσιάζει το σχεδιασμό, την εφαρμογή και την αξιολόγηση της απόδοσης ενός έξυπνου συστήματος πρόβλεψης πυρκαγιάς. Το προτεινόμενο σύστημα, λόγω του χαμηλού κόστους και της φιλικής προς το χρήστη διεπαφής, μπορεί εύκολα να υιοθετηθεί από οποιονδήποτε ενδιαφερόμενο σε εισαγωγικό επίπεδο, χωρίς να είναι απαραίτητη η ανάγκη να επενδύσει σε νέες τεχνολογίες.

Το σύστημα που αναπτύχθηκε βασίζεται αποκλειστικά σε εργαλεία ανοιχτού κώδικα (γλώσσες προγραμματισμού, λογισμικό και υλικό), αποτελώντας ένα χαμηλού κόστους αλλά αποτελεσματικό σύστημα. Το προτεινόμενο σύστημα πρόβλεψης, αξιοποιώντας ένα Ασύρματο Δίκτυο Αισθητήρων, μπορεί να προσφέρει πολλαπλά οφέλη, τόσο από την άποψη των καλλιεργειών, όσο και από την άποψη της καλύτερης διαχείρισης προστασίας των φυσικών πόρων γενικότερα.

**Λέξεις Κλειδιά:** *Διαδίκτυο των Πραγμάτων, Πρόβλεψη Πυρκαγιάς, Νευρωνικά Δίκτυα, Ασύρματο Δίκτυο Αισθητήρων, Τεχνολογίες Επικοινωνιών, Δικτυακά Πρωτόκολλα*

## Abstract

Forest fires are one of the most common hazards that may occur in a forest area; hence, improving the level of modernization of their monitoring, using technologies and communications, is of strategic importance for many countries where forest fires often occur.

In general, the process of fire monitoring consists of three individual time phases: (a) pre-fire, by taking appropriate measures to control it, (b) during the fire, detection and planning for its control, and (c) post-fire, with damage assessment and mitigation planning.

Today, the satellite system is used to detect forest fires, but it only works when the fire spreads over a large area. This renders it a highly inefficient prediction system, as about 80% of forest fire losses occur due to delayed detection. This is the reason why the principles of the Internet of Things and Artificial Neural Networks were introduced.

The goal of this dissertation is to propose a model for early fire prediction, deploying the ESP32 development board as well as other sensors required. This paper presents the design, implementation and evaluation of the performance of a smart system for fire prediction. Thanks to the systems' low-cost and user-friendly interface, the proposed framework can be easily implemented by those interested in the introductory level, without the need to invest in new technologies.

The developed system is based solely on open source resources (programming languages, software and hardware), rendering it a system that is low-cost, yet efficient. The proposed prediction model, which uses a Wireless Sensor Network, can offer multiple benefits, both in terms of crops and in terms of better management of the protection of natural resources in general.

**Keywords:** *Internet of Things, Fire Prediction, Neural Networks, Wireless Sensor Network, Information Technologies, Network Protocols*

# 1

## *Εισαγωγή*

### *1.1 Διαδίκτυο των Πραγμάτων*

Με τη συνεχή αύξηση της ταχύτητας του διαδικτύου προσφέρεται διασύνδεση μεταξύ ολοένα και περισσότερων ατόμων από ολοένα και περισσότερα μέρη του κόσμου. Το Διαδίκτυο των Πραγμάτων (Internet of Things, IoT) προχωράει ένα βήμα παρακάτω, συνδέοντας όχι μόνο άτομα, αλλά και ηλεκτρονικές συσκευές μεταξύ τους [1].

Αναλυτικότερα, το ΔτΠ αποτελεί μια δικτυακή υποδομή όπου εικονικά και φυσικά αντικείμενα συνδέονται μεταξύ τους για την καταγραφή δεδομένων από συσκευές, αλλά και τη μεταφορά των δεδομένων αυτών. Πρόκειται για ένα καινοτόμο πρότυπο σχεδιασμού, το οποίο θα μπορούσε να οριστεί ως ένα δίκτυο δισεκατομμυρίων έως και τρισεκατομμυρίων μικροσκοπικών αισθητήρων που επικοινωνούν μεταξύ τους για να προσφέρουν καινοτόμες λύσεις σε προβλήματα πραγματικού χρόνου [2]. Πιο απλά, το ΔτΠ είναι ένα δίκτυο κόμβων αισθητήρων (sensors) και ενεργοποιητών (actuators) που καλούνται «πράγματα/αντικείμενα (things)», τα οποία αναφέρονται σε κάθε συσκευή ή αισθητήρα που έχει τη δυνατότητα να «αισθάνεται» τα φυσικά σήματα του κόσμου και να τα καταγράφει σε ψηφιακή μορφή [3].

Βασική ιδέα πίσω από το ΔτΠ είναι η σύνδεση ποικίλων ηλεκτρονικών συσκευών μέσω ενός δικτύου και η μετέπειτα ανάκτηση των δεδομένων που έχουν καταγραφεί από τις συσκευές αυτές (αισθητήρες) και βασίζεται σε πέντε αρχές: (i) οποτεδήποτε, (ii) οπουδήποτε, (iii) οτιδήποτε, (iv) όπως και να έχει και (v) με κάθε τρόπο [4]. Στη συνέχεια, και δεδομένου ότι τα καταγεγραμμένα δεδομένα βρίσκονται αποθηκευμένα πλέον σε μια υπηρεσία νέφους (cloud), ακολουθεί συγκέντρωση και κατάλληλη επεξεργασία τους για την υλοποίηση διάφορων εφαρμογών που στόχο έχουν την αντιμετώπιση προκλήσεων και περιορισμών που προκύπτουν.

Βάσει των παραπάνω, συνεπώς, καθορίζονται οι ακόλουθες βασικές δυνατότητες που πρέπει να υποστηρίζει το ΔτΠ σε επίπεδο συστήματος [5]:

- *Ετερογένεια των Συσκευών*: Αφορά τις συσκευές που συμμετέχουν στο σύστημα και οποίες παρουσιάζουν πολύ διαφορετικές δυνατότητες τόσο από υπολογιστική, όσο και από επικοινωνιακή άποψη.
- *Επεκτασιμότητα*: Λόγω της σύνδεσης με μια πολύ μεγάλη υποδομή πληροφοριών, προκύπτουν ζητήματα κλιμάκωσης σε διαφορετικά επίπεδα, όπως (α) ονομασία και θέση, λόγω του μεγάλου μεγέθους του συστήματος, (β) επικοινωνία και δικτύωση δεδομένων, λόγω του υψηλού επιπέδου διασύνδεσης, (γ) διαχείριση πληροφοριών και γνώσεων και (δ) παροχή και διαχείριση υπηρεσιών, λόγω του μεγάλου όγκου διαθέσιμων υπηρεσιών για τη διαχείριση ετερογενών πηγών.
- *Διάχυτη Ανταλλαγή Δεδομένων μέσω Ασύρματων Τεχνολογιών*: Στο ΔτΠ οι ασύρματες επικοινωνίες διαδραματίζουν εξέχοντα ρόλο, καθώς επιτρέπουν τη δικτύωση των αντικειμένων.
- *Βελτιστοποιημένες Ενεργειακές Λύσεις*: Βασικός περιορισμός κάθε «έξυπνου» συστήματος είναι η ελαχιστοποίηση της ενεργειακής κατανάλωσης στις επικοινωνίες και τους υπολογισμούς.
- *Δυνατότητες Εντοπισμού Θέσης και Παρακολούθησης*: Αφορά τον εντοπισμό και την παρακολούθηση των επιμέρους συσκευών του συστήματος που παίζουν ιδιαίτερα σημαντικό ρόλο στην ενεργειακή κατανάλωση του συστήματος, και άρα και στη διάρκεια λειτουργίας του.
- *Δυνατότητες Αυτό-οργάνωσης*: Οι επιμέρους συσκευές/αντικείμενα του συστήματος θα πρέπει να αντιδρούν αυτόνομα σ' ένα ευρύ φάσμα διαφορετικών καταστάσεων, προκειμένου να ελαχιστοποιηθεί η ανθρώπινη παρέμβαση.
- *Διαλειτουργικότητα και Διαχείριση Δεδομένων*: Αφορά την ανταλλαγή και ανάλυση τεράστιων ποσοτήτων δεδομένων, τα οποία πρέπει να περιλαμβάνουν τυποποιημένες μορφές και σημασιολογική περιγραφή του περιεχομένου τους (μετα-δεδομένα).
- *Ασφάλεια και Μηχανισμοί Διατήρησης Ιδιωτικότητας*: Η ασφάλεια πρέπει να θεωρείται βασική ιδιότητα σε επίπεδο συστήματος και να λαμβάνεται υπόψη στο σχεδιασμό αρχιτεκτονικών και μεθόδων για λύσεις ΔτΠ.

Όπως προαναφέρθηκε, το ΔτΠ προσφέρει, πέρα από την επικοινωνία μεταξύ ατόμου με άλλο άτομο, και επικοινωνία μεταξύ ατόμου και συσκευής, ώστε να παρακολουθείται και να ελέγχεται από απόσταση, αλλά και συσκευής με συσκευή επίσης, μέσω του διαδικτύου. Λόγω των νέων προσφερόμενων διασυνδέσεων, πλέον ανοίγουν νέοι δρόμοι στις επικοινωνίες, επηρεάζοντας κάθε κλάδο βιομηχανίας, από τις μεταφορές και τις συγκοινωνίες, μέχρι τους κλάδους ενέργειας και γεωργίας. Για παράδειγμα, στην περίπτωση της ενέργειας, το ΔτΠ εφαρμόζεται για τη δημιουργία Έξυπνων Δικτύων (Smart Grids), τα οποία εντοπίζουν και ανταποκρίνονται σε αλλαγές ενεργειακής κατανάλωσης.

Πέρα από τον ενεργειακό τομέα, ωστόσο, άλλες περιοχές ενδιαφέροντος για το ΔτΠ περιλαμβάνουν τα συστήματα υγειονομικής περιθάλψης, την παρακολούθηση του περιβάλλοντος, τους αυτοματισμούς οικιακού ή εργασιακού περιβάλλοντος, την πρόγνωση καιρικών φαινομένων,

τα συστήματα έγκαιρης προειδοποίησης και, γενικά, τις έξυπνες πόλεις, για την αύξηση του βαθμού αυτοματισμού.



Σχήμα 1. Εφαρμογές του Διαδικτύου των Πραγμάτων.

Συνοψίζοντας, ο όρος «Διαδίκτυο των Πραγμάτων» χρησιμοποιείται για να καλύψει διάφορες πτυχές που σχετίζονται με την επέκταση του διαδικτύου και του Ιστού στο φυσικό επίπεδο, μέσω της ευρείας ανάπτυξης των κατανεμημένων στο χώρο συσκευών, οι οποίες διαθέτουν ενσωματωμένες δυνατότητες ταυτοποίησης, συναίσθησης του χώρου και του περιβάλλοντος (sensing) ή/και ενεργοποίησης (actuation). Το ΔτΠ ως υποδομή προσφέρει ένα μέλλον όπου οι ψηφιακές και οι φυσικές συσκευές μπορούν να συνδεθούν μεταξύ τους, προσφέροντας μια εντελώς νέα κατηγορία εφαρμογών και υπηρεσιών στο χρήστη, με όσο το δυνατόν λιγότερη συμμετοχή του ίδιου στο σύστημα.

Σήμερα, το ΔτΠ θεωρείται ως το μέλλον του Διάχυτου Υπολογισμού (Ubiquitous Computing) και του διαδικτύου γενικότερα, καθώς θεωρείται μια επαναστατική τεχνολογία που μπορεί να καθορίσει τη διασύνδεση φυσικών αντικειμένων με ενσωματωμένο λογισμικό. Ταυτόχρονα, αποτελεί μια νέα επανάσταση στο σημερινό κόσμο του διαδικτύου, παρακολουθώντας τη ροή όλου του κόσμου σε πραγματικό χρόνο, αποκτώντας πληροφορίες σχετικά με τη θερμοκρασία, την υγρασία, τυχόν καταιγίδες ή πυρκαγιές που μπορεί να προκύψουν στην καθημερινότητα.

## **1.2 Αντικείμενο της Διπλωματικής**

Όπως προαναφέρθηκε, οι δασικές πυρκαγιές είναι ένα πολύ συχνό φαινόμενο που παρατηρείται στη χώρα, κυρίως, κατά τους θερινούς μήνες λόγω υψηλής θερμοκρασίας και ισχυρών ανέμων. Συνεπώς, βασική ιδέα πίσω από τη συγκεκριμένη εργασία αποτέλεσε η ανάγκη δημιουργίας ενός μοντέλου κατάλληλου για την πρόβλεψη εκείνων των περιβαλλοντικών συνθηκών που φαίνεται να επηρεάζουν περισσότερο το ποσοστό εκδήλωσης μιας δασικής πυρκαγιάς, φυσικά εξαιρουμένου του ανθρώπινου παράγοντα.

Μέχρι σήμερα, στη βιβλιογραφία υπάρχουν αρκετές συναφείς μελέτες και έρευνες πάνω στο συγκεκριμένο τομέα, ωστόσο, οι περισσότερες επικεντρώνονται στον εντοπισμό της πυρκαγιάς και όχι στην έγκαιρη προειδοποίηση και πρόβλεψή της.

Η παρούσα εργασία, επομένως, στοχεύει στη δημιουργία ενός συστήματος έγκαιρης προειδοποίησης του χρήστη, η οποία επιτεύχθηκε με την ανάπτυξη ενός κατάλληλου μοντέλου τεχνητού νευρωνικού δικτύου για πρόβλεψη περιβαλλοντικών τιμών θερμοκρασίας, υγρασίας του περιβάλλοντος, αλλά και ταχύτητας του ανέμου για τις επερχόμενες 12 ώρες της ημέρας. Στη συνέχεια, και με κατάλληλη μοντελοποίηση, το σύστημα αποστέλλει στο χρήστη αντίστοιχη προειδοποίηση σε περίπτωση πρόβλεψης ακραίων περιβαλλοντικών συνθηκών, όπως είναι, για παράδειγμα, η υψηλή θερμοκρασία, σε συνδυασμό με ισχυρούς ανέμους και χαμηλά ποσοστά υγρασίας στην ατμόσφαιρα.

## **1.3 Μεθοδολογική Προσέγγιση**

Για την επίτευξη του επιθυμητού στόχου, πρώτο στάδιο αποτέλεσε η μελέτη συναφών συστημάτων, η επιλογή των κατάλληλων περιβαλλοντικών τιμών που θα πρέπει να λαμβάνονται κάθε φορά από το σύστημα, καθώς επίσης και ο τρόπος αξιοποίησης της πληροφορίας αυτής.

Στη συνέχεια, ακολούθησε η επιλογή του απαραίτητου υλικού που θα διέθετε τους κατάλληλους αισθητήρες για τη μέτρηση των απαιτούμενων τιμών. Το υλικό που χρησιμοποιήθηκε για τις ανάγκες της εργασίας αποτελείται, λοιπόν, από μια πλακέτα ESP32, καθώς και από άλλους τρεις αισθητήρες, έναν DHT22 για μέτρηση θερμοκρασίας και υγρασίας του περιβάλλοντος, έναν YL-69 για μέτρηση του ποσοστού της υγρασίας του εδάφους και έναν BH1750 για μέτρηση του επιπέδου της φωτεινότητας.

Ωστόσο, τα δεδομένα μόνο από τους συγκεκριμένους αισθητήρες του συστήματος δε θα επαρκούσαν για τη δημιουργία ενός ολοκληρωμένου μοντέλου πρόβλεψης. Για την αντιμετώπιση, επομένως, του συγκεκριμένου προβλήματος, και προκειμένου να διατηρηθεί και το χαμηλό κόστος του συστήματος, χρησιμοποιήθηκαν δεδομένα και από μια ανοιχτή διαδικτυακή υπηρεσία παροχής δεδομένων καιρού, το OpenWeatherMap. Η συγκεκριμένη υπηρεσία παρέχει μια μεγάλη ποικιλία δεδομένων, από τα οποία επιλέχθηκαν μόνο αυτά που θα ήταν χρήσιμα για τη διαδικασία της πρόβλεψης. Τα δεδομένα που επιλέχθηκαν, καθώς και ο τρόπος επιλογής τους παρουσιάζεται εκτενέστερα στην Παρ. 7, που αφορά στην αναλυτική υλοποίηση της εργασίας.

Το επόμενο βήμα, μετά τη συλλογή των κατάλληλων δεδομένων, αποτέλεσε η αποθήκευσή τους σε μια βάση δεδομένων. Για το συγκεκριμένο βήμα επιλέχθηκε η πλατφόρμα του ThingSpeak,



η οποία επιτρέπει και τη γραφική απεικόνιση των δεδομένων στο κανάλι όπου αποθηκεύονται, σε πραγματικό χρόνο. Το γεγονός αυτό συμβάλλει και στην καλύτερη οπτικοποίηση των δεδομένων που αποθηκεύονται κάθε φορά, καθιστώντας ευκολότερη και την κατανόησή τους από τον ίδιο το χρήστη του συστήματος. Η επικοινωνία του συστήματος τόσο με το ThingSpeak, όσο και με το OpenWeatherMap έγινε μέσω HTTP πρωτοκόλλου, χρησιμοποιώντας τις μεθόδους POST και GET, αντίστοιχα.

Το τέταρτο βήμα της εργασίας αφορά στην υλοποίηση του κατάλληλου μοντέλου νευρωνικού δικτύου για την πρόβλεψη των τριών βασικών περιβαλλοντικών τιμών. Πιο συγκεκριμένα, το μοντέλο λαμβάνει τα δεδομένα του συστήματος από τη βάση του ThingSpeak, εκπαιδεύεται πάνω σε αυτά, και βάσει αυτών προβλέπει τιμές θερμοκρασίας, υγρασίας και ταχύτητας ανέμου για τις επόμενες 12 ώρες. Για το συγκεκριμένο στάδιο, η διαδικασία ήταν καθαρά πειραματική και περιλαμβάνει δοκιμές με διάφορα μοντέλα βαθιάς μάθησης. Η τελική επιλογή του κατάλληλου μοντέλου έγινε βάσει της απόδοσης της πρόβλεψής του σε άγνωστα δεδομένα και παρουσιάζεται μαζί με τα αναλυτικά αποτελέσματά του στις Παρ. 7.5 και 8.1.

Τέλος, το τελικό στάδιο αποτέλεσε η εύρεση του κατάλληλου μαθηματικού μοντέλου, το οποίο συνδυάζει τις τιμές που εξάγονται από το μοντέλο πρόβλεψης, επιτελώντας τον επιθυμητό στόχο της έγκαιρης προειδοποίησης του χρήστη για πιθανή πυρκαγιά, μέσω του Twitter, σε περίπτωση ακραίων καιρικών φαινομένων.

## ***1.4 Δομή της Διπλωματικής***

Οι ενότητες που ακολουθούν παρουσιάζουν αναλυτικότερα τη διαδικασία που ακολουθήθηκε μέχρι την ολοκλήρωση της υλοποίησης της εργασίας και την εξαγωγή των αποτελεσμάτων. Πιο συγκεκριμένα, στην Ενότητα 2 παρουσιάζονται συναφείς με το αντικείμενο μελέτες που έχουν υλοποιηθεί και αφορούν στον εντοπισμό και την παρακολούθηση πυρκαγιάς. Η Ενότητα 3 θέτει το θεωρητικό υπόβαθρο της εργασίας, παρουσιάζοντας και περιγράφοντας έννοιες που είναι απαραίτητες για την κατανόηση των παραγράφων της υλοποίησης και αφορούν τόσο στο κομμάτι της μετάδοσης των πληροφοριών, όσο και στο κομμάτι των νευρωνικών δικτύων. Ακολούθως, στις Ενότητες 4 και 5 παρουσιάζεται ο εξοπλισμός και το λογισμικό και οι πλατφόρμες δεδομένων που χρησιμοποιήθηκαν για την εργασία, αντίστοιχα. Η Ενότητα 6 περιλαμβάνει μια συνοπτική παρουσίαση των προκλήσεων που αντιμετωπίστηκαν κατά τη συγγραφή και την υλοποίηση της συγκεκριμένης διπλωματικής. Τέλος, οι Ενότητες 7 και 8 αφορούν στη λεπτομερή παρουσίαση της διαδικασίας που ακολουθήθηκε μέχρι την υλοποίηση του έργου, καθώς επίσης και τα αποτελέσματά του, ενώ η Ενότητα 9 συνοψίζει τη μελέτη παρουσιάζοντας τα βασικά συμπεράσματα που εξήχθησαν.

# 2

## **Συναφή Συστήματα**

### **2.1 Παρακολούθηση Πυρκαγιάς**

Με την ταχεία αύξηση πληθυσμού σε πολλές χώρες ανά τον κόσμο και την επέκταση της πυκνότητας των κτιρίων των πόλεων, τίθενται σοβαρές προκλήσεις στον τομέα της αστικής πυρασφάλειας. Για την προσαρμογή, λοιπόν, στην ανάπτυξη των νέων πόλεων και της δημόσιας ασφάλειας, αναπτύχθηκε από τους Li κ.ά. [6] ένα σύστημα απομακρυσμένης παρακολούθησης σε πραγματικό χρόνο που βασίζεται στην τεχνολογία του ΔτΠ. Το προτεινόμενο σύστημα αποκτά πληροφορίες πυρόσβεσης σε πραγματικό χρόνο και αποθηκεύει τα συλλεγόμενα δεδομένα σ' ένα κέντρο παρακολούθησης. Βάσει των δεδομένων, προτάθηκε ένα μοντέλο έγκαιρης προειδοποίησης πυρκαγιάς που βασίστηκε στο νευρωνικό δίκτυο οπισθοδιάδοσης (BP Neural Network). Επιπλέον, δημιουργήθηκε ένα μοντέλο αξιολόγησης βασισμένο σε οντολογία για διευκόλυνση της online παρακολούθησης και του ελέγχου, διευκόλυνση της πρόβλεψης και βελτίωση της αξιολόγησης του επιπέδου ασφαλείας του εκάστοτε κτιρίου.

### **2.2 Εντοπισμός Πυρκαγιάς**

Σε σύγκριση με τις παραδοσιακές τεχνικές ανίχνευσης δασικών πυρκαγιών, η τεχνολογία των Ασύρματων Δικτύων Αισθητήρων (Wireless Sensor Networks, WSNs) είναι μια πολλά υποσχόμενη πράσινη τεχνολογία ανίχνευσης δασικών πυρκαγιών για το μέλλον. Η μελέτη των Cantuna κ.ά. [7] παρουσιάζει την ανάπτυξη ενός ΑΔΑ με στόχο τον εντοπισμό και την παρακολούθηση σε πραγματικό χρόνο δασικών πυρκαγιών σε μια συγκεκριμένη δασική έκταση του Ισημερινού. Το προτεινόμενο σύστημα βασίστηκε στη συνεχή μέτρηση τριών τύπων αερίων που υπάρχουν σε κάθε διαδικασία καύσης, ενώ επιπλέον παρέχει δεδομένα θερμοκρασίας και υγρασίας του περιβάλλοντος, καθώς και δεδομένα θέσης (GPS). Η μετάδοση των δεδομένων αυτών, στη συνέχεια, έγινε μέσω ασύρματων επικοινωνιών προς μια κατάλληλη διεπαφή για γραφική αναπαράστασή τους, ώστε να εξαχθούν στατιστικές πληροφορίες. Τέλος, μέσω διαδικασίας επικύρωσης, αποδείχτηκε πως το σύστημά τους παρείχε μια αποτελεσματική και αξιόπιστη μέθοδο εντοπισμού και παρακολούθησης δασικών πυρκαγιών για ένα σύντομο χρονικό διάστημα.

Αντίστοιχα, οι Sharma κ.ά. [8] προχώρησαν στην κατασκευή ενός ανιχνευτή πυρκαγιάς, χρησιμοποιώντας ένα Arduino Uno διασυνδεδεμένο με αισθητήρες θερμοκρασίας και καπνού, αλλά και με ένα βομβητή (buzzer). Ο αισθητήρας θερμοκρασίας χρησιμοποιήθηκε για την ανίχνευση της θερμότητας, ο αισθητήρας καπνού για την ανίχνευση τυχόν καπνού λόγω πυρκαγιάς ή καύσης και ο βομβητής για την παροχή ένδειξης συναγερμού. Σε κάθε περίπτωση εμφάνισης πυρκαγιάς, το σύστημα αυτόματα την εντοπίζει και ειδοποιεί το χρήστη μέσω μιας κινητής εφαρμογής ή ιστοσελίδας του διαδικτύου.

Πέρα από τις δασικές πυρκαγιές, ωστόσο, δεν είναι λίγες και οι περιπτώσεις οικιακών πυρκαγιών, οι οποίες συνήθως συμβαίνουν στα σπίτια λόγω απροσεξίας και αλλαγών στις περιβαλλοντικές συνθήκες. Φέρουν μεγάλο βαθμό επικινδυνότητας, καθώς μπορεί να οδηγήσουν σε υλικές ζημιές ή ακόμα και να θέσουν σε κίνδυνο την ανθρώπινη ζωή· συνεπώς, η άμεση ειδοποίηση είναι το κρισιμότερο ζήτημα. Η μελέτη των Shinde κ.ά. [9], λοιπόν, επικεντρώθηκε στον εντοπισμό πυρκαγιών σε πολυώροφα κτίρια, προτείνοντας ένα σύστημα παρακολούθησης σε πραγματικό χρόνο, με αυτόματη ειδοποίηση συναγερμού. Καθώς η κατάσταση του συστήματος πυρασφάλειας ενός κτιρίου μπορεί να ελέγχεται σε πραγματικό χρόνο και εκτός του κτιρίου, χάρη στο διαδίκτυο ή στα ΑΔΑ, το προτεινόμενο σύστημα παρακολούθησης μειώνει το κόστος για τις εργασίες διαχείρισης των κτιρίων, κάνοντας αποτελεσματικότερη τη διάκριση μεταξύ απειλών πυρκαγιάς και μη πυρκαγιάς, αυξάνοντας, κατ' επέκταση, το διαθέσιμο χρόνο για την προστασία της ανθρώπινης ζωής. Ωστόσο, η παρακολούθηση και ο έλεγχος των συστημάτων υπηρεσιών ενός κτιρίου απαιτεί προστασία ασφαλείας για την αποτροπή παροχής ψευδών πληροφοριών εμφάνισης πυρκαγιάς σε ιδιοκτήτες κτιρίων και πυροσβεστικές υπηρεσίες.

Μια ανάλογη προσέγγιση ακολουθήθηκε από τους Saeed κ.ά. [10], οι οποίοι σχεδίασαν και αξιολόγησαν ένα ΑΔΑ για έγκαιρη ανίχνευση πυρκαγιάς στο σπίτι. Σε αντίθεση, όμως, με την προηγούμενη μελέτη, εδώ προστίθεται και η χρήση του Παγκόσμιου Συστήματος Κινητών Επικοινωνιών (GSM) για την αποφυγή ψευδών συναγερμών. Τέλος, πραγματοποιήθηκε δοκιμή της απόδοσης του συστήματος προσομοιώνοντας μια πυρκαγιά σ' ένα «έξυπνο» σπίτι. Τα αποτελέσματα της προσομοίωσης έδειξαν πως το σύστημα πρόβλεψης μπορεί να ανιχνεύσει πρόωρη πυρκαγιά, ακόμα και όταν ένας αισθητήρας δε λειτουργεί, διατηρώντας παράλληλα την κατανάλωση ενέργειας των αισθητήρων σε αποδεκτό επίπεδο.

Ολοκληρώνοντας, ένας επιπλέον τομέας της καθημερινότητας όπου μπορεί εύκολα να προκληθεί πυρκαγιά είναι και οι οδικές μεταφορές. Πιο συγκεκριμένα, έρευνες έδειξαν πως περισσότερα από δύο χιλιάδες αυτοκίνητα καταστρέφονται καθημερινά από ανεπιθύμητες πυρκαγιές. Ένας από τους βασικότερους παράγοντες πρόκλησής τους είναι η έλλειψη ενός εξελιγμένου συστήματος πυρασφάλειας στο αυτοκίνητο. Το πρόβλημα αυτό κλήθηκαν να αντιμετωπίσουν οι Sowah κ.ά. [11], σχεδιάζοντας και εφαρμόζοντας ένα σύστημα ανίχνευσης πυρκαγιάς για αυτοκίνητα χρησιμοποιώντας fuzzy λογική. Το σύστημα αποτελείται από αισθητήρες φλόγας, θερμοκρασίας και καπνού για την ανίχνευση πυρκαγιάς, η οποία ανιχνεύεται εντός 20 δευτερολέπτων και, για να σβηστεί, χρησιμοποιείται το σύστημα κλιματισμού του αυτοκινήτου.

# 3

## **Θεωρητικό Υπόβαθρο**

### **3.1 Μεταφορά Δεδομένων Συστήματος**

Για την εφαρμογή και την επικοινωνία των επιμέρους στοιχείων κάθε «έξυπνου» συστήματος του ΔτΠ, και πιο συγκεκριμένα για τη μετάδοση των δεδομένων και τη διασύνδεση του εξοπλισμού, είναι απαραίτητη η ύπαρξη των κατάλληλων επικοινωνιών και δικτυακών πρωτοκόλλων.

Στη συγκεκριμένη υπο-ενότητα περιγράφονται τεχνολογίες επικοινωνιών που μπορούν να χρησιμοποιηθούν στη συγκεκριμένη, αλλά και σε αντίστοιχες υλοποιήσεις. Πιο αναλυτική αναφορά στις επικοινωνίες και τα πρωτόκολλα που χρησιμοποιήθηκαν για την υλοποίηση παρουσιάζονται στην Παρ. 7.1.

#### **3.1.1 Τεχνολογίες Επικοινωνιών**

Γενικά, με τον όρο «τεχνολογίες επικοινωνιών» ορίζονται οι τεχνολογίες εκείνες που σχετίζονται με τη μελέτη, σχεδίαση, ανάπτυξη, υλοποίηση, συντήρηση και διαχείριση υπολογιστικών πληροφοριακών συστημάτων, κυρίως όσον αφορά εφαρμογές λογισμικού και υλικού υπολογιστών. Κάθε εργασία, με λίγα λόγια, που προσπαθεί να συνδυάσει υλικό και λογισμικό διακατέχεται από τις τεχνολογίες αυτές, γεγονός που υφίσταται και στη συγκεκριμένη εργασία με την κατασκευή του προτεινόμενου έξυπνου συστήματος για πρόβλεψη πυρκαγιάς.

Για την καταγραφή των δεδομένων από τις μετρήσεις των αισθητήρων, λοιπόν, απαραίτητη είναι η ύπαρξη ασύρματης επικοινωνίας της πλακέτας με το Cloud, για την καταχώρηση των μετρήσεων. Η επικοινωνία αυτή σ' ένα σύστημα ΔτΠ μπορεί να πραγματοποιηθεί είτε μέσω Bluetooth (Bluetooth Classic ή BLE), είτε μέσω Wi-Fi, είτε μέσω ZigBee.

Αρχικά, το κλασικό Bluetooth είναι ένα τυπικό πρωτόκολλο επικοινωνίας που ανήκει στις μικρού εύρους (short-range) επικοινωνίες των ασύρματων δικτύων προσωπικού χώρου (WPAN) και αποτελεί μια τεχνολογία που συμβάλλει στη δημιουργία ενός δικτύου χαμηλής ενέργειας και δεδομένων. Πρόκειται για ένα πρωτόκολλο που μπορεί να διαχειριστεί αρκετό όγκο δεδομένων, αλλά καταναλώνει υψηλές ποσότητες ενέργειας, με αποτέλεσμα να είναι ιδανικό για προϊόντα που απαιτούν συνεχή μεταφορά δεδομένων.

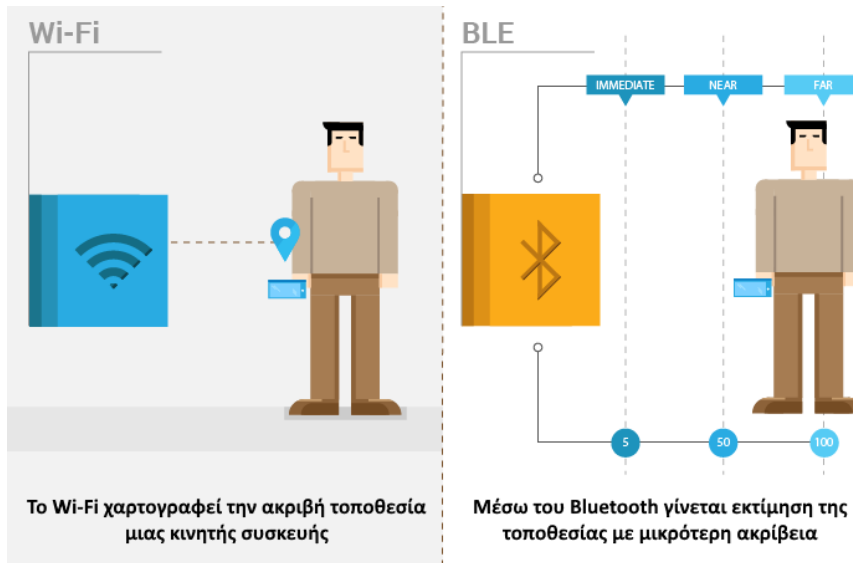
Παρομοίως, το BLE ανήκει στην ίδια κατηγορία επικοινωνιών με το κλασικό Bluetooth, αλλά διαφέρει αρκετά από αυτό. Σε αντίθεση με το κλασικό Bluetooth, το BLE είναι σχεδιασμένο για εφαρμογές μετάδοσης και λήψης μικρού όγκου δεδομένων, καταναλώνοντας εξαιρετικά χαμηλές ποσότητες ενέργειας και μειώνοντας το κόστος. Προκειμένου να επιτευχθεί αυτό, η συσκευή παραμένει σε κατάσταση αναστολής (sleep mode) για το μεγαλύτερο διάστημα της λειτουργίας της και κάθε φορά που εμφανίζεται ένα συμβάν, η συσκευή «ξυπνάει», ενεργοποιείται, και ένα μικρό μήνυμα αποστέλλεται στη θύρα ή στον υπολογιστή. Ένα ενδεικτικό διάγραμμα ροής της λειτουργίας του BLE παρουσιάζεται στο ακόλουθο Σχήμα 2. Συνεπώς, πρόκειται για ένα πρωτόκολλο ιδανικό για συνδεσιμότητα προϊόντων που απαιτούν μόνο περιοδική και όχι συνεχή μεταφορά δεδομένων.



Σχήμα 2. Τεχνολογία Bluetooth Low Energy.

Από την άλλη πλευρά, το Wi-Fi αποτελεί μια μορφή επικοινωνίας που χρησιμοποιείται ευρέως σε ασύρματα τοπικά δίκτυα (WLAN) και είναι μια τεχνολογία που χρησιμοποιεί ραδιοκύματα για την παροχή σύνδεσης στο δίκτυο. Μια σύνδεση Wi-Fi δημιουργείται χρησιμοποιώντας έναν ασύρματο μετασχηματιστή (adapter) για τη δημιουργία hotspots, περιοχών δηλαδή κοντά σ' έναν ασύρματο δρομολογητή που είναι συνδεδεμένες στο δίκτυο και επιτρέπουν στον εκάστοτε χρήστη ή χρήστες να έχουν πρόσβαση σε υπηρεσίες του διαδικτύου. Πιο συγκεκριμένα, η λειτουργία του προσομοιάζει σε αυτή ενός κινητού τηλεφώνου, επειδή, όπως προαναφέρθηκε, χρησιμοποιεί ραδιοκύματα για τη μετάδοση των πληροφοριών σ' ένα δίκτυο. Ο υπολογιστής θα πρέπει να διαθέτει έναν ασύρματο μετασχηματιστή, ο οποίος θα μεταφράζει τα δεδομένα που αποστέλλονται μέσα σ' ένα ραδιοφωνικό σήμα. Το ίδιο σήμα θα μεταδοθεί, μέσω κεραίας, σ' έναν αποκωδικοποιητή, γνωστό και ως δρομολογητή (router). Μόλις επιτευχθεί η αποκωδικοποίησή τους, τα δεδομένα αυτά αποστέλλονται στο διαδίκτυο μέσω ενσύρματης Ethernet σύνδεσης. Καθώς, όμως, το ασύρματο δίκτυο λειτουργεί ως μια αμφίδρομη κίνηση, τα δεδομένα που λαμβάνονται από το διαδίκτυο θα περνούν, επίσης, μέσω του προς κωδικοποίηση πλέον δρομολογητή σ' ένα ραδιοφωνικό σήμα, το οποίο λαμβάνεται από τον ασύρματο μετασχηματιστή του υπολογιστή. Το βασικό πλεονέκτημα, παρόλα αυτά, που προσφέρει το Wi-Fi ως μορφή ασύρματης επικοινωνίας είναι το γεγονός ότι είναι συμβατό με σχεδόν οποιοδήποτε λειτουργικό σύστημα και συσκευή.

Παρά το γεγονός, όμως, ότι και οι δύο μορφές επικοινωνίας είναι ιδιαίτερα χρήσιμες σε παρόμοιες υλοποιήσεις, διαφέρουν μεταξύ τους αρκετά. Αναλυτικότερα, το BLE [12], [13] είναι καταλληλότερο για τη μετάδοση μικρών ποσοτήτων δεδομένων, όπως είναι οι μετρήσεις των αισθητήρων, αλλά δεν είναι κατάλληλο για την αποστολή δεδομένων σε πραγματικό χρόνο σ' ένα διακομιστή. Επειδή, όμως, στη συγκεκριμένη περίπτωση απαιτούνται δεδομένα σε πραγματικό χρόνο, θα πρέπει να χρησιμοποιηθεί μια ειδική πύλη για την αποστολή των δεδομένων. Αντίθετα, το Wi-Fi μπορεί να μεταδώσει δεδομένα με πολύ μεγαλύτερη ταχύτητα, χωρίς επιπλέον απαιτήσεις ή προεπεξεργασία, επομένως είναι ιδανικότερο.



Σχήμα 3. Διαφορά τεχνολογίας Wi-Fi και Bluetooth.

Διαφορές παρατηρούνται, επίσης, και στην εμβέλεια αυτών των δύο τεχνικών. Από τη μία πλευρά, η τεχνολογία του Bluetooth σχετίζεται περισσότερο με την εγγύτητα παρά με την ακριβή τοποθεσία. Στον αντίποδα, το Wi-Fi είναι σχεδιασμένο ώστε να μπορεί να δείχνει σωστά την ακριβή τοποθεσία, μετρώντας σημεία πρόσβασης σε μια συσκευή, χρησιμοποιώντας παραμέτρους όπως το SSID και τη διεύθυνση MAC. Ενδεικτικά, το μέγιστο εύρος που μπορεί να προσφέρει μια ασύρματη BLE σύνδεση είναι 30m, ενώ το εύρος του Wi-Fi μπορεί να φτάσει σε πολύ μεγαλύτερες αποστάσεις.

Τέλος, το ZigBee [14] είναι ένα πρότυπο επικοινωνίας ραδιοσυχνότητας που βασίζεται στο IEEE 802.15.4, μιας σειράς πρωτοκόλλων επικοινωνίας υψηλού επιπέδου που χρησιμοποιούνται για τη δημιουργία χαμηλού ρυθμού WPAN δικτύων. Συνήθως, χρησιμοποιείται για οικιακό αυτοματισμό, συλλογή δεδομένων από ιατρικές συσκευές, αλλά και για άλλες ανάγκες χαμηλής ισχύος και χαμηλού εύρους ζώνης. Ως εκ τούτου, το ZigBee είναι ένα ασύρματο Ad-hoc δίκτυο χαμηλής ισχύος, χαμηλής ταχύτητας δεδομένων που καλύπτει μικρές περιοχές. Έχει καθορισμένο ρυθμό μετάδοσης στα 250kbps, καθιστώντας το κατάλληλο για διαλείπουσες μεταδόσεις δεδομένων από έναν αισθητήρα ή μια συσκευή εισόδου.

Πίνακας I. Διαφορές ZigBee, Bluetooth, Wi-Fi.

	ZigBee	Bluetooth	Wi-Fi
<b>Πρότυπο IEEE</b>	802.15.4	802.15.1	802.11b
<b>Εφαρμογές</b>	Παρακολούθηση & Έλεγχος	Αντικατάσταση Καλωδίου	Ιστός, Βίντεο, e-mail
<b>Πηγή Συστήματος</b>	28kbytes	250kbytes	1Mbytes+
<b>Κύκλος Ζωής Μπαταρίας (Ημέρες)</b>	100 έως 1000+	1 έως 7	1 έως 5
<b>Εύρος Ζώνης (kbps)</b>	250	1000	11000+
<b>Φάσμα (m)</b>	~30	~10	1 έως 100
<b>Τοπολογία Δικτύου</b>	P2P, Αστέρα, Κυψέλης, Ad-hoc	Ad-hoc, Μικρό Δίκτυο	Διασημειακή (Point to hub)
<b>Διαμόρφωση</b>	BPSK (+ASK), O-QPSK	GFSK	BPSK, QPSK, COFDM, CCK, M-QAM
<b>Προστασία Δεδομένων</b>	16-bit CRC	16-bit CRC	32-bit CRC
<b>Μετρικές Επιτυχίας</b>	Αξιοπιστία, Χαμηλή Κατανάλωση, Χαμηλό Κόστος	Κόστος, Ευκολία	Ταχύτητα, Ευελιξία

Συνοψίζοντας, η τεχνολογία που ορίζεται από το συγκεκριμένο πρότυπο επικοινωνίας προορίζεται να είναι απλούστερη και φθηνότερη από άλλα WPAN δίκτυα, όπως το Bluetooth, ή και από τα ασύρματα τοπικά δίκτυα γενικότερα, όπως το Wi-Fi. Ο Πίνακας I παρουσιάζει συγκεντρωτικά τα χαρακτηριστικά και τις διαφορές μεταξύ των τριών αυτών προτύπων επικοινωνίας. Παρατηρώντας τον πίνακα, τόσο το ZigBee, όσο και το Wi-Fi προσφέρουν πολλά θετικά, αλλά και κάποια αρνητικά. Αναλυτικότερα, το εύρος ζώνης που κερδίζεται με τη χρήση του Wi-Fi, χάνεται σε ισχύ, ενώ αντίθετα το κέρδος που προσφέρει το ZigBee σε ό,τι αφορά την κατανάλωση ενέργειας του συστήματος, χάνεται σε εύρος ζώνης και περιοχή κάλυψης. Τέλος, αξίζει να σημειωθεί ότι το ZigBee δεν είναι συμβατό με συσκευές όπως υπολογιστές και κινητά. Επομένως, θα πρέπει κάθε φορά οι αισθητήρες να επικοινωνούν μ' ένα κεντρικό κόμβο (hub) που θα είναι είτε συνδεδεμένος με το κεντρικό οικιακό δίκτυο μέσω Wi-Fi, είτε μέσω καλωδίου ethernet, το οποίο θα είναι συνδεδεμένο στο δρομολογητή.

### 3.1.2 Δικτυακά Πρωτόκολλα

Επί του παρόντος, η πρόσβαση στο διαδίκτυο απαιτεί πρωτόκολλα εφαρμογών μέσω TCP/IP ή UDP/IP. Το HTTP (Hyper Text Transfer Protocol) είναι ένα δημοφιλές και ευρέως χρησιμοποιούμενο πρωτόκολλο. Ωστόσο, τα τελευταία χρόνια το MQTT (Message Queuing Telemetry Transport) φαίνεται να προτιμάται ολοένα και περισσότερο [15].

Αρχικά, το HTTP είναι ένα πρωτόκολλο πελάτη-διακομιστή, που σημαίνει πως τα μηνύματα αποστέλλονται από μια οντότητα, το χρήστη [16]. Στις περισσότερες περιπτώσεις, ο χρήστης είναι ένα πρόγραμμα περιήγησης, αλλά δεν είναι και περιοριστικό. Κάθε μεμονωμένο αίτημα αποστέλλεται σ' ένα διακομιστή, ο οποίος το διαχειρίζεται και παρέχει μια απάντηση (response). Μεταξύ του πελάτη και του διακομιστή υπάρχουν διάφορες άλλες οντότητες, που ονομάζονται διακομιστές μεσολάβησης (proxies), οι οποίοι εκτελούν διαφορετικές λειτουργίες.

Όπως και άλλα πρωτόκολλα, έτσι και το HTTP διαθέτει μεθόδους που ορίζουν την εκάστοτε διαδικασία που θέλει να επιτελέσει ο χρήστης. Πιο συγκεκριμένα, η μέθοδος HTTP POST χρησιμοποιείται για την αποστολή των δεδομένων από την πλακέτα του συστήματος στο Cloud, μέσω του κατάλληλου API key. Αιτείται από ένα διακομιστή την αποδοχή των δεδομένων που εμπεριέχονται στο μήνυμα αίτησης, πιθανότατα για την αποθήκευσή του. Συχνά, χρησιμοποιείται κατά το «ανέβασμα» ενός αρχείου ή κατά την υποβολή μιας ολοκληρωμένης φόρμας. Αντίθετα, η μέθοδος HTTP GET χρησιμοποιείται για την ανάκτηση πληροφοριών από το διακομιστή.

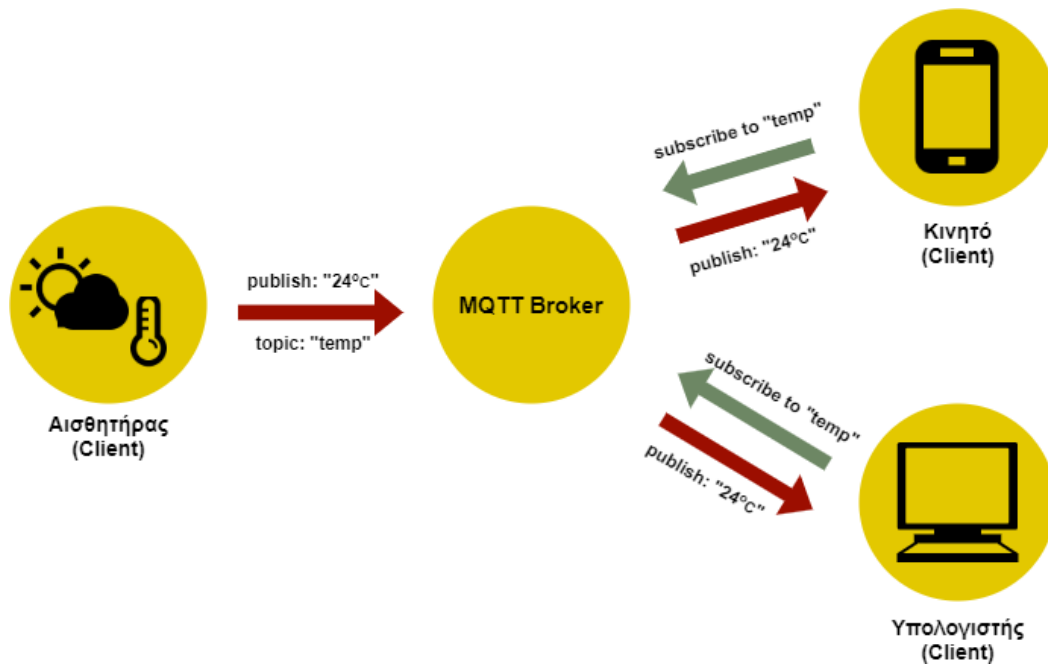
Όσον αφορά το MQTT [17], όπως κάθε άλλο πρωτόκολλο, έτσι και αυτό είναι βασισμένο σε πελάτες και διακομιστή. Με τον ίδιο τρόπο, ο διακομιστής είναι υπεύθυνος για τη διαχείριση των αιτημάτων των πελατών του δικτύου να δέχονται ή να αποστέλλουν δεδομένα μεταξύ τους. Πιο συγκεκριμένα, ο διακομιστής του MQTT καλείται «MQTT Broker» και οι πελάτες είναι οι συνδεδεμένες στο δίκτυο συσκευές. Καθώς είναι ένα πρωτόκολλο publish/subscribe (pub/sub), επιτρέπει στις συσκευές του δικτύου να δημοσιεύουν στον MQTT Broker. Οι πελάτες (clients) συνδέονται μ' αυτόν τον broker, ο οποίος στη συνέχεια μεσολαβεί στην επικοινωνία μεταξύ των δύο συσκευών. Κάθε συσκευή μπορεί να εγγραφεί (subscribe) σε συγκεκριμένα topics και όταν ένας άλλος πελάτης δημοσιεύει (publish) ένα μήνυμα σ' ένα εγγεγραμμένο topic, ο broker προωθεί το μήνυμα σε όποιον πελάτη έχει εγγραφεί.

Στο Σχήμα 4 που ακολουθεί παρουσιάζεται μια σχηματική αναπαράσταση της ροής δεδομένων από ένα σύστημα σε μια συσκευή. Όταν μια συσκευή/πελάτης θέλει να αποστείλει δεδομένα στον broker, η διαδικασία αυτή καλείται «publish». Αντίθετα, όταν μια συσκευή/πελάτης θέλει να λάβει δεδομένα από τον broker, η διαδικασία αυτή καλείται «subscribe». Επιπρόσθετα, οι πελάτες αυτοί μπορούν να δημοσιεύσουν και να εγγραφούν σε topics. Έτσι, ο broker είναι αυτός που διαχειρίζεται τις pub/sub διαδικασίες στα topics-στόχους.

Στο Σχήμα 4 παρατηρείται η αποστολή δεδομένων θερμοκρασίας σ' ένα απλό ΑΔΑ. Αρχικά, υπάρχει μια συσκευή που διαθέτει έναν αισθητήρα θερμοκρασίας (αριστερά), η οποία θέλει να αποστείλει τις μετρήσεις που λαμβάνει στον broker. Από την άλλη πλευρά, δεξιά του σχήματος, υπάρχουν οι εφαρμογές που θέλουν να λάβουν την τιμή της θερμοκρασίας. Επομένως, δύο είναι οι διαδικασίες που πρόκειται να συμβούν. Αρχικά, η συσκευή ορίζει το topic όπου θέλει να δημοσιεύσει, π.χ. «temp», και στη συνέχεια, δημοσιεύει το μήνυμα «τιμή θερμοκρασίας». Αντίστοιχα, η κάθε εφαρμογή εγγράφεται στο topic «temp» και, στη συνέχεια, λαμβάνει το μήνυμα που έχει δημοσιεύσει η συσκευή, που είναι μια τιμή θερμοκρασίας. Στο συγκεκριμένο παράδειγμα,



ο ρόλος του broker είναι να λάβει το μήνυμα «τιμή θερμοκρασίας» και να το μεταδώσει στην κάθε εφαρμογή.



Σχήμα 4. Σχηματική αναπαράσταση της ροής δεδομένων στο πρωτόκολλο MQTT.

Ολοκληρώνοντας, καθένα από τα πρωτόκολλα που αναφέρθηκαν μπορούν να προσφέρουν πολλά πλεονεκτήματα ανάλογα με την εφαρμογή και τον τρόπο χρήσης τους. Ενδεικτικά, μερικά από τα πλεονεκτήματα χρήσης του HTTP είναι ότι πρόκειται για ένα πρωτόκολλο που υποστηρίζεται σχεδόν παντού, εξασφαλίζοντας ευκολότερη συμβατότητα με το εκάστοτε τείχος προστασίας. Ιδιαίτερα σημαντικό πλεονέκτημα σε περιπτώσεις όπου η ανάπτυξη του συστήματος γίνεται σε άγνωστο δίκτυο. Επιπλέον, καθώς είναι ένα κοινό πρωτόκολλο, προσφέρει μια αίσθηση άνεσης και στον τελικό χρήστη του συστήματος.

Από την άλλη πλευρά, το MQTT είναι ένα πρωτόκολλο που βασίζεται στα δεδομένα (data centric). Επιτρέπει συνεχείς συνδέσεις που μπορούν να εξοικονομήσουν σημαντικούς πόρους, σε αντίθεση με το HTTP, όπου χρησιμοποιείται το πρωτόκολλο SSL. Είναι ένα ιδιαίτερα αποδοτικό πρωτόκολλο σε περίπτωση που αποστέλλονται μόνο λίγες μετρήσεις. Καθώς το MQTT έχει σχεδιαστεί για την παράδοση δεδομένων, το μοντέλο pub/sub προσφέρει πολλά χρήσιμα ενσωματωμένα χαρακτηριστικά. Επίσης, προσφέρει έναν απλό τρόπο εφαρμογής κρυπτογράφησης, ελέγχου ταυτότητας και ελέγχου πρόσβασης. Πρόκειται για ένα πρωτόκολλο που προορίζεται για καταστάσεις όπου η σύνδεση ενδέχεται να έχει διαλείψει ή να είναι αναξιόπιστη, καθώς τα διάφορα επίπεδα QoS παρέχουν αρκετούς τρόπους διασφάλισης της αξιόπιστης αποστολής των δεδομένων. Σε μεγαλύτερες εφαρμογές, ο MQTT Broker φαίνεται να παρέχει ευκολότερη διαχείριση, καθώς υπάρχει ένα τυποποιημένο σύνολο μετρικών για τη μέτρηση της απόδοσης. Τέλος, η δομή topic/subtopic του MQTT βοηθά στην οργάνωση των δεδομένων και διευκολύνει την κλιμάκωση των πραγμάτων και την κοινή χρήση πόρων μεταξύ πολλών έργων.

## 3.2 Τεχνητά Νευρωνικά Δίκτυα

Επί του παρόντος, τα Νευρωνικά Δίκτυα (Neural Networks) και η Βαθιά Μάθηση (Deep Learning) αποτελούν μεγάλους ερευνητικούς τομείς στην Επιστήμη των Υπολογιστών, καθώς παρέχουν τις καλύτερες λύσεις σε πολλά προβλήματα, όπως στην αναγνώριση εικόνας, την αναγνώριση ομιλίας, την επεξεργασία φυσικής γλώσσας κ.ά. Πολλά άρθρα και έρευνες έχουν δημοσιευτεί που περιλαμβάνουν Τεχνητή Νοημοσύνη (Artificial Intelligence, AI) για εκμάθηση ζωγραφικής, δημιουργία 3D μοντέλων, διεπαφών χρήστη και πολλά άλλα, χρησιμοποιώντας νευρωνικά δίκτυα.

Επιπλέον, η πρόβλεψη για το τί θα μπορούσε να συμβεί στο μέλλον θεωρούνταν πάντα μια μυστήρια δραστηριότητα την οποία οι επιστήμονες προσπαθούν να μετατρέψουν σε επιστημονική δραστηριότητα βασισμένη σε καθιερωμένες θεωρίες και μαθηματικά μοντέλα [18]. Στη σύγχρονη κοινωνία, τέτοιου είδους προβλέψεις μπορούν να χρησιμοποιηθούν για την κατανόηση της συμπεριφοράς σύνθετων συστημάτων ή φαινομένων που σχετίζονται με πραγματικά προβλήματα, ή ακόμα και ως βάση για τη λήψη αποφάσεων, ιδίως σε περιπτώσεις πρόληψης καταστροφών ή/και των ανεπιθύμητων συνεπειών τους.

### 3.2.1 Εισαγωγικές Έννοιες


Γενικά, ένα ΤΝΔ είναι ένα μαθηματικό μοντέλο που μπορεί εύκολα να εφαρμοστεί ως προσομοίωση ενός λογισμικού που προσπαθεί να προσομοιώσει δύο βασικές ιδιότητες του ανθρώπινου εγκεφάλου, σε σχέση με τις υψηλές δυνατότητες παράλληλης επεξεργασίας πληροφοριών [19]. Πιο συγκεκριμένα, η πρώτη ιδιότητα αφορά στην ικανότητα του ανθρώπου να μαθαίνει μέσα από παραδείγματα, ενώ αντίστοιχα η δεύτερη σχετίζεται με την ικανότητα γενίκευσης των γνώσεων, που αποκτήθηκαν μέσω της διαδικασίας μάθησης, σε νέα παραδείγματα.

Όπως στον ανθρώπινο εγκέφαλο, έτσι και σε κάθε ΤΝΔ, η βασική υπολογιστική μονάδα είναι ο νευρώνας, ο οποίος στην περίπτωση των νευρωνικών δικτύων καλείται «κόμβος (node)» ή «μονάδα (unit)». Η λειτουργία του αφορά αφενός στη λήψη τιμών εισόδου, τόσο από άλλους κόμβους του δικτύου, όσο και από κάποια εξωτερική πηγή, και αφετέρου στον υπολογισμό της τιμής εξόδου. Κάθε είσοδος έχει ένα σχετικό βάρος ( $w$ ), το οποίο εκχωρείται βάσει της σχετικής σημασίας του για άλλες εισόδους και ο κόμβος εφαρμόζει μια συνάρτηση στο σταθμισμένο άθροισμα (weighted sum) των εισόδων του.

Πρακτικά, τα ΤΝΔ είναι ένα σύνολο αλγορίθμων, μοντελοποιημένα σύμφωνα με τον ανθρώπινο εγκέφαλο, όπως προαναφέρθηκε, που έχουν σχεδιαστεί για την αναγνώριση μοτίβων. Ερμηνεύουν δεδομένα που παρέχονται από αισθητήρες, τα κατηγοριοποιούν (labelling) και τα ομαδοποιούν (clustering). Θα μπορούσαν και να θεωρηθούν ως ένα clustering και classification επίπεδο πάνω από τα δεδομένα που αποθηκεύονται. Συμβάλλουν στην ομαδοποίηση unlabeled δεδομένων, βάσει ομοιοτήτων μεταξύ των τιμών εισόδων, και ταξινομούν τα δεδομένα όταν αυτά έχουν ένα labeled σύνολο δεδομένων με βάση το οποίο μπορούν να εκπαιδευτούν. Αντίστοιχα, τα μοτίβα που αναγνωρίζουν είναι αριθμητικά, περιέχονται σε διανύσματα, στα οποία και πρέπει να μεταφραστούν όλα τα πραγματικά δεδομένα, όπως εικόνες, ήχος, κείμενο κ.λπ.

### 3.2.2 Αρχιτεκτονική Νευρωνικών Δικτύων

Κάθε ΤΝΔ αποτελείται από επιμέρους επίπεδα, τα οποία είναι κατασκευασμένα από κόμβους. Όπως αναφέρθηκε ήδη, ο κόμβος είναι απλώς ένα μέρος όπου συμβαίνει ο υπολογισμός και πυροδοτείται όταν συναντά επαρκή ερεθίσματα. Ένας κόμβος συνδυάζει την είσοδο από τα δεδομένα με ένα σύνολο βαρών, που είτε ενισχύουν είτε μειώνουν αυτήν την είσοδο, αποδίδοντας έτσι σημασία στις εισόδους σε σχέση με αυτό το οποίο προσπαθεί να μάθει ο αλγόριθμος. Τα δεδομένα αυτά αθροίζονται και, στη συνέχεια, το άθροισμά τους περνά από τη λεγόμενη «συνάρτηση ενεργοποίησης (activation function)» ενός κόμβου, προκειμένου να προσδιοριστεί εάν και σε ποιο βαθμό το συγκεκριμένο σήμα πρέπει να προχωρήσει περαιτέρω μέσω του δικτύου για να επηρεάσει το τελικό αποτέλεσμα, π.χ. μια ταξινόμηση. Εάν τα σήματα περάσουν, τότε θεωρείται ότι ο νευρώνας έχει ενεργοποιηθεί. Η διαδικασία αυτή παρουσιάζεται σχηματικά στο Σχήμα 5.



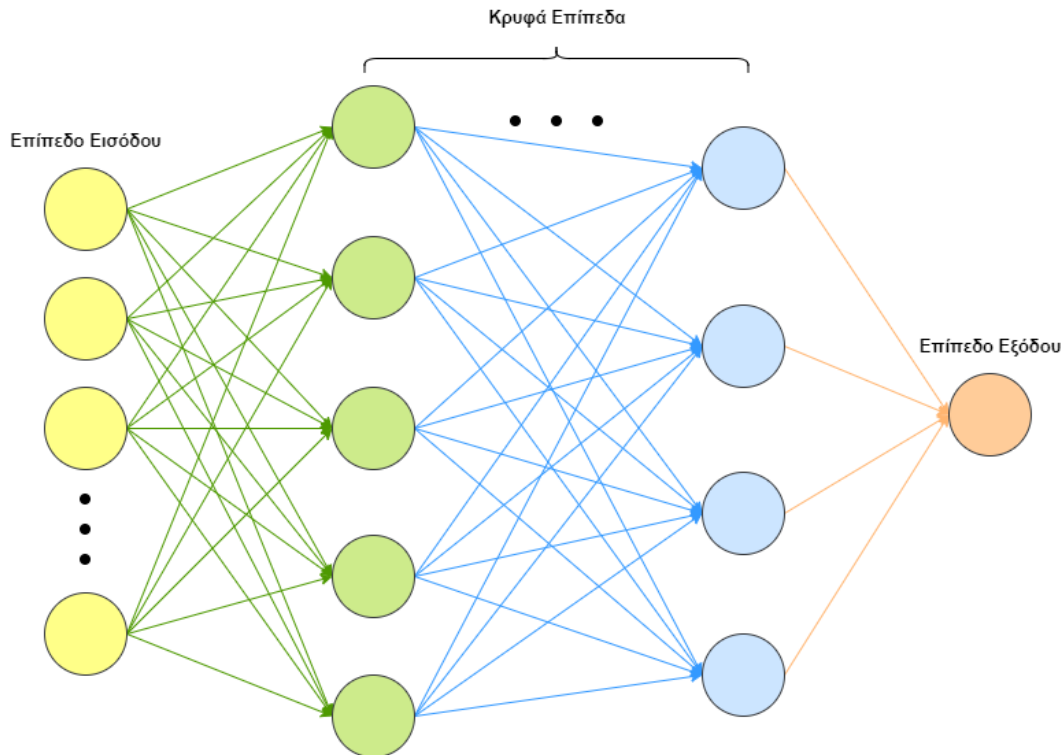
Σχήμα 5. Κόμβος νευρωνικού δικτύου.

Ωστόσο, στις περισσότερες περιπτώσεις, ένα ΤΝΔ αποτελείται από τρία επιμέρους επίπεδα μονάδων επεξεργασίας, όπως φαίνεται και στο Σχήμα 6 που ακολουθεί:

- *Επίπεδο Εισόδου:* Ή αλλιώς κόμβοι εισόδου. Στο επίπεδο αυτό δεν γίνονται υπολογισμοί, αλλά μόνο μεταβίβαση πληροφοριών στο επόμενο επίπεδο, που στις περισσότερες περιπτώσεις είναι το κρυφό επίπεδο.
- *Κρυφά Επίπεδα:* Ή αλλιώς κρυφοί κόμβοι. Στα συγκεκριμένα επίπεδα γίνεται η ενδιάμεση επεξεργασία ή ο υπολογισμός και, στη συνέχεια, γίνεται μεταφορά του βάρους από το επίπεδο εισόδου στο επόμενο επίπεδο που ακολουθεί. Στο Σχήμα 6 το χρώμα κάθε ακμής υποδηλώνει και την αντίστοιχη μεταφορά του βάρους από επίπεδο σε επίπεδο. Συμβάλλουν στην επίτευξη βέλτιστης γενίκευσης από τη συνάρτηση.
- *Επίπεδο Εξόδου:* Ή αλλιώς κόμβοι εξόδου. Πρόκειται για το επίπεδο όπου χρησιμοποιείται η συνάρτηση ενεργοποίησης που αντιστοιχεί στην επιθυμητή μορφή εξόδου.

Όπως φαίνεται και στο Σχήμα 6, οι νευρώνες ενός επιπέδου μπορούν να συνδεθούν μόνο με νευρώνες του αμέσως προηγούμενου και του αμέσως επόμενου επιπέδου. Το επίπεδο που λαμβάνει τα εξωτερικά δεδομένα είναι το επίπεδο εισόδου, ενώ το επίπεδο που παράγει το τελικό αποτέλεσμα είναι το επίπεδο εξόδου. Ωστόσο, ο αριθμός των ενδιάμεσων κρυφών επιπέδων ποικίλλει από δίκτυο σε δίκτυο.

Στην απλούστερη μορφή του, ένα ΤΝΔ μπορεί να έχει τρία επίπεδα νευρώνων συνολικά, ένα επίπεδο εισόδου, ένα επίπεδο εξόδου και ένα ενδιάμεσο κρυφό επίπεδο. Παρόλα αυτά, υπάρχουν και ΤΝΔ που δε διαθέτουν κρυφό επίπεδο. Επίσης, μεταξύ δύο επιπέδων υπάρχουν πολλά διαφορετικά μοτίβα σύνδεσης. Υπάρχουν ΤΝΔ όπου παρατηρείται πλήρης σύνδεση νευρώνων από επίπεδο σε επίπεδο, όπως στο παράδειγμα του σχήματος, αλλά υπάρχουν και ΤΝΔ στα οποία μια ομάδα νευρώνων συνδέεται μόνο με έναν νευρώνα του επόμενου επιπέδου, μειώνοντας έτσι τον αριθμό των νευρώνων στο συγκεκριμένο επίπεδο.



Σχήμα 6. Παράδειγμα επιπέδων νευρωνικού δικτύου.

Αξίζει να σημειωθεί πως ο αριθμός των ενδιάμεσων κρυφών επιπέδων, δηλαδή το βάθος, παίζει ρόλο στο διαχωρισμό των απλών ΤΝΔ ενός κρυφού επιπέδου από τα δίκτυα βαθιάς μάθησης. Πιο συγκεκριμένα, το βάθος του δικτύου ορίζει τον αριθμό των επιπέδων των κόμβων μέσω των οποίων πρέπει να περάσουν τα δεδομένα σε μια διαδικασία αναγνώρισης προτύπων. Παλαιότερες εκδόσεις ΤΝΔ, όπως τα πρώτα perceptrons που θα παρουσιαστούν στη συνέχεια, ήταν ρηχές και αποτελούνταν από ένα επίπεδο εισόδου, ένα επίπεδο εξόδου και το πολύ ένα κρυφό επίπεδο ενδιάμεσα. ΤΝΔ, επομένως, που αποτελούνται από περισσότερα από τρία επίπεδα, για παράδειγμα, ένα επίπεδο εισόδου, ένα επίπεδο εξόδου και πολλαπλά κρυφά επίπεδα, εντάσσονται στα πλαίσια της βαθιάς μάθησης. Ένα σύστημα βαθιάς μάθησης είναι αυτοδίδακτο και μαθαίνει καθώς φιλτράρει πληροφορίες μέσω πολλαπλών κρυφών επιπέδων, με παρόμοιο τρόπο με αυτόν που μαθαίνει και ο άνθρωπος. Φαίνεται, λοιπόν, πως οι δύο έννοιες είναι άρρηκτα συνδεδεμένες, καθώς η μία βασίζεται στην άλλη. Χωρίς ΤΝΔ, δε θα υπήρχε βαθιά μάθηση.

### 3.2.3 Κατασκευή του Μοντέλου

Τα ΤΝΔ έχουν την ικανότητα να μαθαίνουν μαθηματικές σχέσεις μεταξύ μιας σειράς μεταβλητών εισόδου και των αντίστοιχων μεταβλητών εξόδου. Η μάθηση αυτή επιτυγχάνεται μέσω της εκπαίδευσης του δικτύου σ' ένα σύνολο δεδομένων εκπαίδευσης (training set), το οποίο αποτελείται από μεταβλητές πρόβλεψης και τα γνωστά ή σχετιζόμενα αποτελέσματά τους. Τα ΤΝΔ προγραμματίζονται για να προσαρμόζουν τα εσωτερικά τους βάρη στις μαθηματικές σχέσεις που προσδιορίζονται μεταξύ των εισόδων και των εξόδων σ' ένα σύνολο δεδομένων. Μόλις ένα ΤΝΔ έχει εκπαιδευτεί, μπορεί να χρησιμοποιηθεί για αναγνώριση προτύπων ή ταξινόμηση σ' ένα ξεχωριστό σύνολο δεδομένων ελέγχου (validation ή test set), όπως αυτά αναφέρονται στην Παρ. 3.2.3.4.

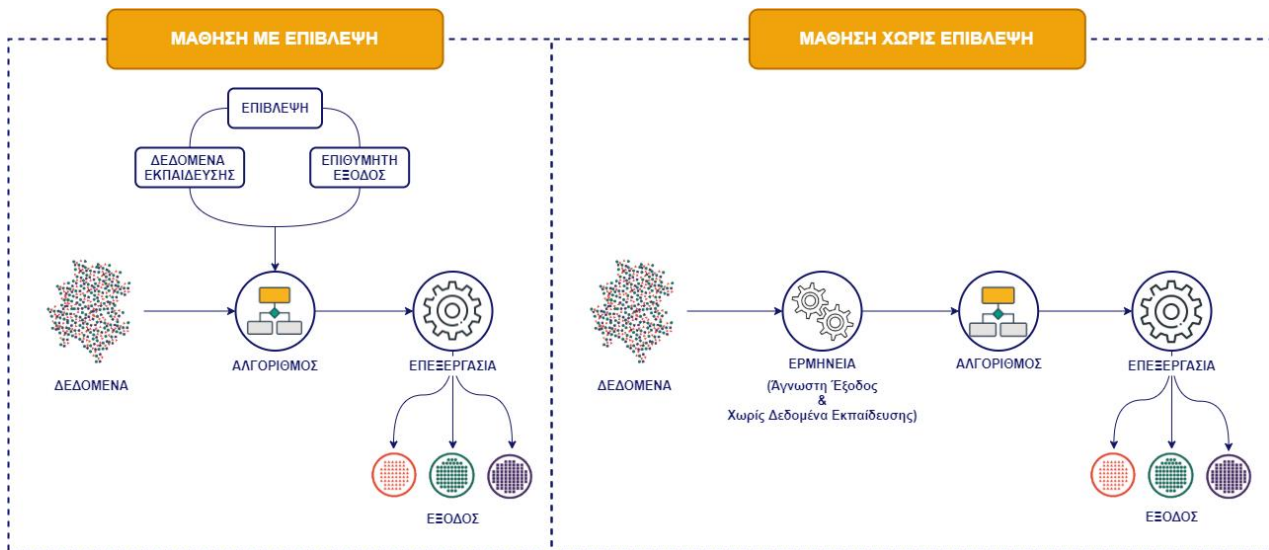
#### 3.2.3.1 Τύποι Εκμάθησης

Στο πεδίο της Μηχανικής Μάθησης διακρίνονται δύο βασικοί τύποι εκπαίδευσης ενός ΤΝΔ: (α) μάθηση με επίβλεψη (supervised learning) και (β) μάθηση χωρίς επίβλεψη (unsupervised learning). Η βασική διαφορά μεταξύ αυτών των δύο τύπων είναι ότι η μάθηση με επίβλεψη πραγματοποιείται χρησιμοποιώντας μια πραγματική τιμή αποτελέσματος (ground truth), ή πιο απλά, προϋποθέτει πρότερη γνώση των τιμών εξόδου. Επομένως, ο στόχος της μάθησης με επίβλεψη είναι να μάθει μια συνάρτηση που, δεδομένου ενός δείγματος δεδομένων και επιθυμητών εξόδων, προσεγγίζει καλύτερα τη σχέση μεταξύ εισόδου και εξόδου που παρατηρείται στα δεδομένα [20]. Αντίθετα, η μάθηση χωρίς επίβλεψη δε διαθέτει γνώση του αποτελέσματος, οπότε η εκπαίδευση του ΤΝΔ γίνεται βάσει των δεδομένων που εισάγονται στο δίκτυο.

Πιο συγκεκριμένα, όπως υποδηλώνει και το όνομα, η μάθηση με επίβλεψη πραγματοποιείται υπό την επίβλεψη ενός φυσικού προσώπου/διαχειριστή και είναι μια εξαρτημένη διαδικασία. Κατά τη διάρκεια της εκπαίδευσης του ΤΝΔ, το διάνυσμα εισόδου παρουσιάζεται στο δίκτυο, το οποίο στο τέλος παράγει ένα διάνυσμα εξόδου. Στη συνέχεια, το διάνυσμα εξόδου συγκρίνεται με το επιθυμητό διάνυσμα εξόδου/στόχο (ground truth). Σε περίπτωση ύπαρξης διαφοράς μεταξύ των τιμών πρόβλεψης με την τιμή-στόχο, δημιουργείται ένα σήμα σφάλματος, βάσει του οποίου ρυθμίζονται τα βάρη των συνδέσεων μεταξύ κάθε νευρώνα, έως ότου η τιμή της πρόβλεψης να ταιριάζει όσο το δυνατόν περισσότερο με την τιμή του ground truth.

Από την άλλη πλευρά, η μάθηση χωρίς επίβλεψη αναφέρεται σε εκπαίδευση χωρίς ground truth, όπως είναι οι ετικέτες που χρησιμοποιούνται για τη διόρθωση του σφάλματος κατά την πρόβλεψη του μοντέλου. Συνεπώς, στη συγκεκριμένη περίπτωση το ΤΝΔ μπορεί να εκπαιδευτεί εικάζοντας την κατανομή των δεδομένων βάσει ενός δείγματος δεδομένων και, έπειτα, ελέγχοντας την εικασία αυτή έναντι της πραγματικής κατανομής. Σε αντίθεση με την εποπτευόμενη μάθηση, η συγκεκριμένη διαδικασία είναι ανεξάρτητη. Κατά τη διάρκεια της εκπαίδευσης του ΤΝΔ, τα διανύσματα εισόδου που έχουν παρόμοιο τύπο δεδομένων συνδυάζονται, σχηματίζοντας συστάδες (clusters). Όταν εφαρμόζεται ένα νέο μοτίβο εισόδου, τότε το ΤΝΔ δίνει μια απόκριση εξόδου, η οποία υποδηλώνει την κλάση όπου ανήκει το συγκεκριμένο μοτίβο εισόδου. Στο συγκεκριμένο τύπο μάθησης δεν παρέχεται δυνατότητα βελτιστοποίησης από το περιβάλλον αναφορικά με το ποια θα πρέπει να είναι η επιθυμητή τιμή της εξόδου και αν αυτή είναι σωστή ή λανθασμένη. Ως εκ τούτου, στην περίπτωση αυτή θα πρέπει το ίδιο το δίκτυο να ανακαλύψει τα μοτίβα, τα

χαρακτηριστικά των δεδομένων εισόδου, αλλά και τη σχέση αυτών με τις προβλεπόμενες τιμές της εξόδου.



Σχήμα 7. Αλγοριθμική διαφορά μεταξύ επιβλεπόμενης και μη επιβλεπόμενης μάθησης σ' ένα νευρωνικό δίκτυο.

Μάθηση με επίβλεψη υλοποιείται, συνήθως, σε περιπτώσεις ταξινόμησης (classification), όταν απαιτείται η χαρτογράφηση της εισόδου στις ετικέτες εξόδου, ή παλινδρόμησης (regression), για τη χαρτογράφηση της εισόδου σε μια συνεχή έξοδο. Στόχος και στις δύο περιπτώσεις είναι η εύρεση συγκεκριμένων σχέσεων ή δομών στα δεδομένα εισόδου, οι οποίες θα επιτρέπουν την αποτελεσματική δημιουργία «σωστών» δεδομένων εξόδου. Η «σωστή» έξοδος καθορίζεται εξ ολοκλήρου από τα δεδομένα εκπαίδευσης, οπότε ενώ υπάρχει ground truth την οποία το μοντέλο θεωρεί ότι είναι αλήθεια, αυτό δε σημαίνει ότι οι ετικέτες των δεδομένων είναι πάντα σωστές σε πραγματικές καταστάσεις. Ετικέτες δεδομένων με θόρυβο ή σφάλματα θα οδηγήσουν σε μείωση της αποτελεσματικότητας του μοντέλου.

Παράλληλα, υπάρχουν δύο βασικές αποφάσεις που πρέπει να ληφθούν κατά την κατασκευή του μοντέλου και αφορούν αφενός στην πολυπλοκότητα του μοντέλου και, αφετέρου, στο ισοζύγιο μεταξύ πόλωσης (bias) και διακύμανσης (variance), τα οποία είναι αλληλένδετα. Πιο συγκεκριμένα, η πολυπλοκότητα του μοντέλου αναφέρεται στην πολυπλοκότητα της συνάρτησης εκπαίδευσης. Το κατάλληλο επίπεδο πολυπλοκότητας του μοντέλου καθορίζεται, γενικά, από τη φύση των διαθέσιμων δεδομένων εκπαίδευσης. Αν τα δεδομένα εκπαίδευσης είναι λίγα ή ανομοιόμορφα καταναμημένα σε διαφορετικά σενάρια, τότε θα πρέπει να επιλεγεί ένα μοντέλο χαμηλής πολυπλοκότητας, καθώς σε αντίθετη περίπτωση θα υπάρξει «υπερ-προσαρμογή (overfitting)» του μοντέλου. Ο όρος της υπερ-προσαρμογής αναφέρεται στην εκμάθηση μιας λειτουργίας που ταιριάζει πολύ καλά με τα δεδομένα εκπαίδευσης, αλλά δε γενικεύεται σε άλλα δεδομένα.

Το ισοζύγιο (trade-off) μεταξύ πόλωσης και διακύμανσης σχετίζεται, επίσης, με τη γενίκευση του μοντέλου. Σε οποιοδήποτε μοντέλο υπάρχει μια ισορροπία μεταξύ πόλωσης, που είναι το σφάλμα, και διακύμανσης, που είναι το ποσό κατά το οποίο το σφάλμα μπορεί να ποικίλει μεταξύ διαφορετικών δεδομένων εκπαίδευσης. Ωστόσο, πρόκειται για δύο έννοιες αντίθετες, καθώς η

αύξηση της πόλωσης, συνήθως, οδηγεί σε χαμηλότερη διακύμανση και αντίστροφα. Γενικά, η αύξηση της πόλωσης, και άρα η μείωση της διακύμανσης, οδηγεί σε μοντέλα με σχετικά εγγυημένα επίπεδα απόδοσης. Επιπλέον, για την κατασκευή καλών μοντέλων γενίκευσης, η διακύμανση πρέπει να κλιμακώνεται ανάλογα με το μέγεθος του συνόλου δεδομένων εκπαίδευσης. Ενδεικτικά, σε μικρά, απλά σύνολα δεδομένων πρέπει να μαθαίνονται μοντέλα χαμηλής διακύμανσης, ενώ σε αντίθετη περίπτωση απαιτούνται μοντέλα υψηλότερης διακύμανσης για πλήρη εκμάθηση της δομής των δεδομένων.

Τέλος, οι συνηθέστερες περιπτώσεις όπου συναντάται μάθηση χωρίς επίβλεψη είναι εκείνες όπου απαιτείται η εκμάθηση των δομών των δεδομένων, χωρίς όμως να απαιτείται η χρήση ετικετών, όπως συμβαίνει στη διερευνητική ανάλυση και τη μείωση της διάστασης των δεδομένων. Σχετικά με τη διερευνητική ανάλυση, η μάθηση χωρίς επίβλεψη είναι μια ιδιαίτερα χρήσιμη προσέγγιση, καθώς μπορεί να αναγνωρίσει αυτόματα τη δομή των δεδομένων. Σε καταστάσεις όπου είναι αδύνατο ή μη πρακτικό να προταθούν τάσεις στα δεδομένα, η μη επιβλεπόμενη μάθηση παρέχει αρχικές πληροφορίες που μπορούν, στη συνέχεια, να χρησιμοποιηθούν για τη δοκιμή μεμονωμένων υποθέσεων. Αντίστοιχα, στην αναπαράσταση των δεδομένων είναι απαραίτητη η εκμάθηση της σχέσης μεταξύ μεμονωμένων χαρακτηριστικών, με αποτέλεσμα να επιτρέπεται η αναπαράσταση των δεδομένων.

### 3.2.3.2 Συναρτήσεις Ενεργοποίησης

Ως συνάρτηση ενεργοποίησης ενός ΤΝΔ ορίζεται η μαθηματική εξίσωση που καθορίζει την έξοδο του δικτύου [21]. Όπως προαναφέρθηκε και φαίνεται στο Σχήμα 5, η συνάρτηση αυτή συνδέεται με κάθε νευρώνα στο δίκτυο και, με βάση τη σχετικότητα του κάθε νευρώνα με την πρόβλεψη του μοντέλου, καθορίζει αν αυτός θα πρέπει ή όχι να ενεργοποιηθεί. Παράλληλα, οι συναρτήσεις ενεργοποίησης βοηθούν και στην κανονικοποίηση της εξόδου του κάθε νευρώνα του δικτύου με χαρτογράφηση των τιμών της σε εύρος που κυμαίνεται μεταξύ 0 και 1 ή -1 και 1, βάσει της εκάστοτε συνάρτησης.

Επιπρόσθετα, μια συνάρτηση ενεργοποίησης θα πρέπει να διακατέχεται από υπολογιστική αποτελεσματικότητα, καθώς υπολογίζεται σε χιλιάδες ή ακόμα και εκατομμύρια νευρώνες για κάθε δείγμα δεδομένων. Καθώς τα σύγχρονα ΤΝΔ χρησιμοποιούν μια τεχνική που καλείται «οπισθοδιάδοση» για την εκπαίδευση του μοντέλου, τίθεται αυξημένη υπολογιστική πίεση στη συνάρτηση ενεργοποίησης και στη λειτουργία της.

Έστω, ενδεικτικά, ένας νευρώνας:

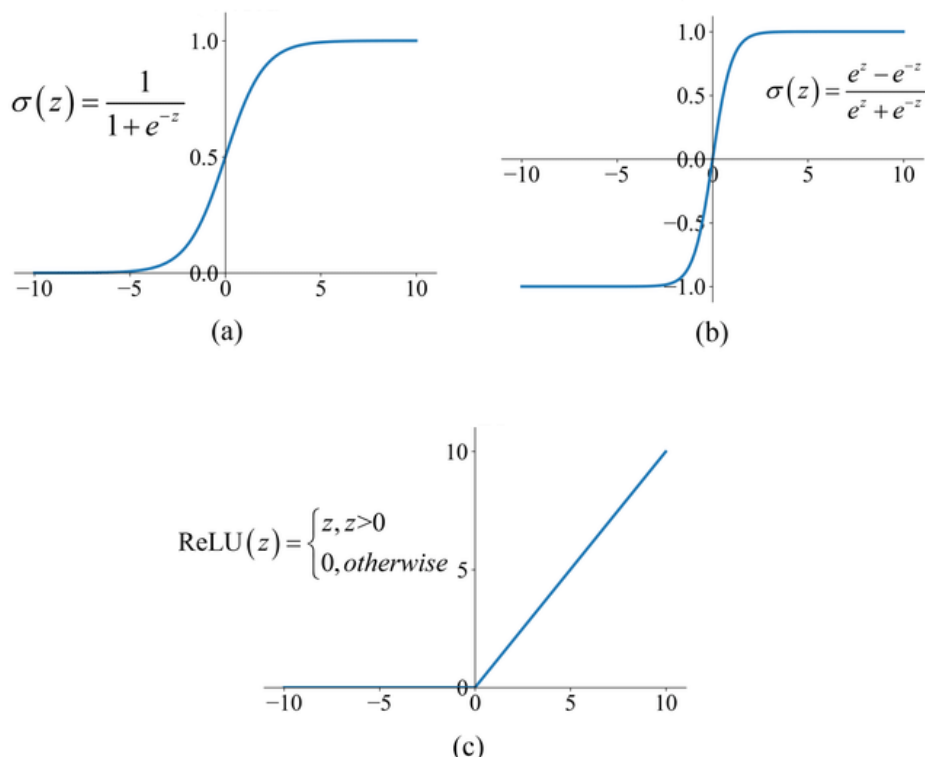
$$Y = \sum(\text{βάρος} \times \text{τιμή εισόδου}) + \text{πόλωση} \quad (3.1)$$

Σε ένα ΤΝΔ, κάθε νευρώνας τροφοδοτείται με τιμές εισόδου στο αντίστοιχο επίπεδο εισόδου. Όπως φαίνεται από τη συνάρτηση (3.1), κάθε νευρώνας έχει ένα συγκεκριμένο βάρος και ο πολλαπλασιασμός του με την τιμή εισόδου δίνει κάθε φορά την έξοδο του νευρώνα, η οποία με τη σειρά της μεταφέρεται στο επόμενο επίπεδο.

Με λίγα λόγια, μια συνάρτηση ενεργοποίησης αποτελεί μια μαθηματική πύλη ανάμεσα στην είσοδο που τροφοδοτεί τον τρέχοντα νευρώνα και την έξοδο αυτού, η οποία μεταφέρεται στο επόμενο επίπεδο. Η λειτουργία της μπορεί να είναι τόσο απλή όσο μια βηματική συνάρτηση που ενεργοποιεί ή απενεργοποιεί την έξοδο του νευρώνα, βάσει ενός κανόνα ή κατωφλίου (threshold),

ή μπορεί ακόμα να είναι ένας μετασχηματισμός που χαρτογραφεί τα σήματα εισόδου σε απαραίτητα για τη λειτουργία του ΤΝΔ σήματα εξόδου. Οι βασικές κατηγορίες των συναρτήσεων ενεργοποίησης είναι τρεις και διακρίνονται σε βηματικές, γραμμικές και μη γραμμικές. Ωστόσο, τα σύγχρονα ΤΝΔ χρησιμοποιούν μη γραμμικές συναρτήσεις, οι οποίες επιτρέπουν στο δίκτυο να μαθαίνει πολύπλοκα δεδομένα, να υπολογίζει και να μαθαίνει σχεδόν οποιαδήποτε λειτουργία αντιπροσωπεύει μια ερώτηση, αλλά και να παρέχει ως αποτέλεσμα μια ακριβή πρόβλεψη.

Ο διαχωρισμός των μη γραμμικών συναρτήσεων ενεργοποίησης βασίζεται στην καμπύλη της κάθε μιας. Από αυτές, οι συναρτήσεις που συναντώνται συχνότερα είναι η «σιγμοειδής» συνάρτηση, η «υπερβολική εφαπτομένη» και η «ανορθωμένη γραμμική». Πιο συγκεκριμένα, η «σιγμοειδής (sigmoid) ή λογιστική (logistic)» συνάρτηση καλείται έτσι από την καμπύλη της που προσομοιάζει στο αγγλικό γράμμα «S», όπως φαίνεται στο Σχήμα 8(a). Η συγκεκριμένη συνάρτηση διαθέτει ένα εύρος τιμών που περιορίζεται σε τιμές από 0 έως 1 και χρησιμοποιείται σε μοντέλα για πρόβλεψη πιθανότητας, καθώς το αντίστοιχο εύρος τιμών για οποιαδήποτε πιθανότητα κυμαίνεται μόνο μεταξύ αυτών των δύο τιμών [22]. Παράλληλα, αποτελεί παραγωγίσιμη (differentiable) συνάρτηση, γεγονός που σημαίνει πως η κλίση της μπορεί να υπολογιστεί σε οποιοδήποτε σημείο της καμπύλης. Ωστόσο, για πολύ υψηλές ή χαμηλές τιμές του  $z$ , δεν παρατηρείται σχεδόν καμία αλλαγή στην πρόβλεψη, οδηγώντας στο πρόβλημα της εξαφάνισης της κλίσης (vanishing gradient), με αποτέλεσμα το ΤΝΔ να μην εκπαιδεύεται περαιτέρω ή να φτάνει πολύ αργά σε μια ακριβή πρόβλεψη.



Σχήμα 8. Συναρτήσεις ενεργοποίησης με τους αντίστοιχους τύπους υπολογισμού: (α) Σιγμοειδής συνάρτηση, (β) Συνάρτηση υπερβολικής εφαπτομένης και (γ) Ανορθωμένη γραμμική συνάρτηση.



Από την άλλη πλευρά, η συνάρτηση της «υπερβολικής εφαπτομένης (hyperbolic tangent ή tanh)» μοιάζει με τη σιγμοειδή συνάρτηση, αλλά αποφέρει καλύτερα αποτελέσματα. Η καμπύλη της είναι αρκετά όμοια με αυτή της σιγμοειδούς, όπως φαίνεται στο Σχήμα 8(b), αλλά το εύρος τιμών της κυμαίνεται μεταξύ του -1 και του 1. Βασικό της πλεονέκτημα έναντι της σιγμοειδούς συνάρτησης είναι το γεγονός ότι η συνάρτηση της υπερβολικής εφαπτομένης επιτρέπει τη μοντελοποίηση εισόδων που έχουν έντονα αρνητικές, ουδέτερες, αλλά και θετικές τιμές.

Τέλος, η «ανορθωμένη γραμμική συνάρτηση ή συνάρτηση ράμπας (Rectified Linear Unit ή ReLu)» αποτελεί την πιο συχνά χρησιμοποιούμενη συνάρτηση ενεργοποίησης, δεδομένου ότι χρησιμοποιείται σε σχεδόν όλα τα συνελκτικά ΤΝΔ (Convolutional NNs) ή τη βαθιά μάθηση. Όπως φαίνεται από το Σχήμα 8(c), το εύρος τιμών της κυμαίνεται από το 0 έως το  $+\infty$ , με αποτέλεσμα όλες οι αρνητικές τιμές να μετατρέπονται κατευθείαν σε μηδενικές. Γενικά, αποτελεί μια υπολογιστικά αποδοτική συνάρτηση, επιτρέποντας τη γρηγορότερη σύγκλιση (convergence) του εκάστοτε ΤΝΔ όπου εφαρμόζεται. Το βασικό της μειονέκτημα, ωστόσο, εμφανίζεται σε περιπτώσεις όπου οι τιμές εισόδου πλησιάζουν στο μηδέν ή είναι αρνητικές. Στην περίπτωση αυτή προκαλείται το πρόβλημα «dying ReLu», κατά το οποίο το δίκτυο δεν μπορεί πλέον να εφαρμόσει οπισθοδιάδοση και κατ' επέκταση δεν μπορεί πλέον να μάθει.

Είναι φανερό, συνεπώς, πως για τη δημιουργία ενός μοντέλου και την εκπαίδευση ενός ΤΝΔ, η επιλογή της κατάλληλης συνάρτησης ενεργοποίησης είναι ιδιαίτερα σημαντική. Για παράδειγμα, σε προβλήματα ταξινόμησης έχει παρατηρηθεί πως μια σιγμοειδής συνάρτηση λειτουργεί αρκετά καλύτερα και προτιμάται σε αντίθεση με τη ReLu που είναι η συνηθέστερη επιλογή. Ωστόσο, πρόκειται για μια διαδικασία που είναι καθαρά πειραματική και εξαρτάται από το εκάστοτε πρόβλημα.

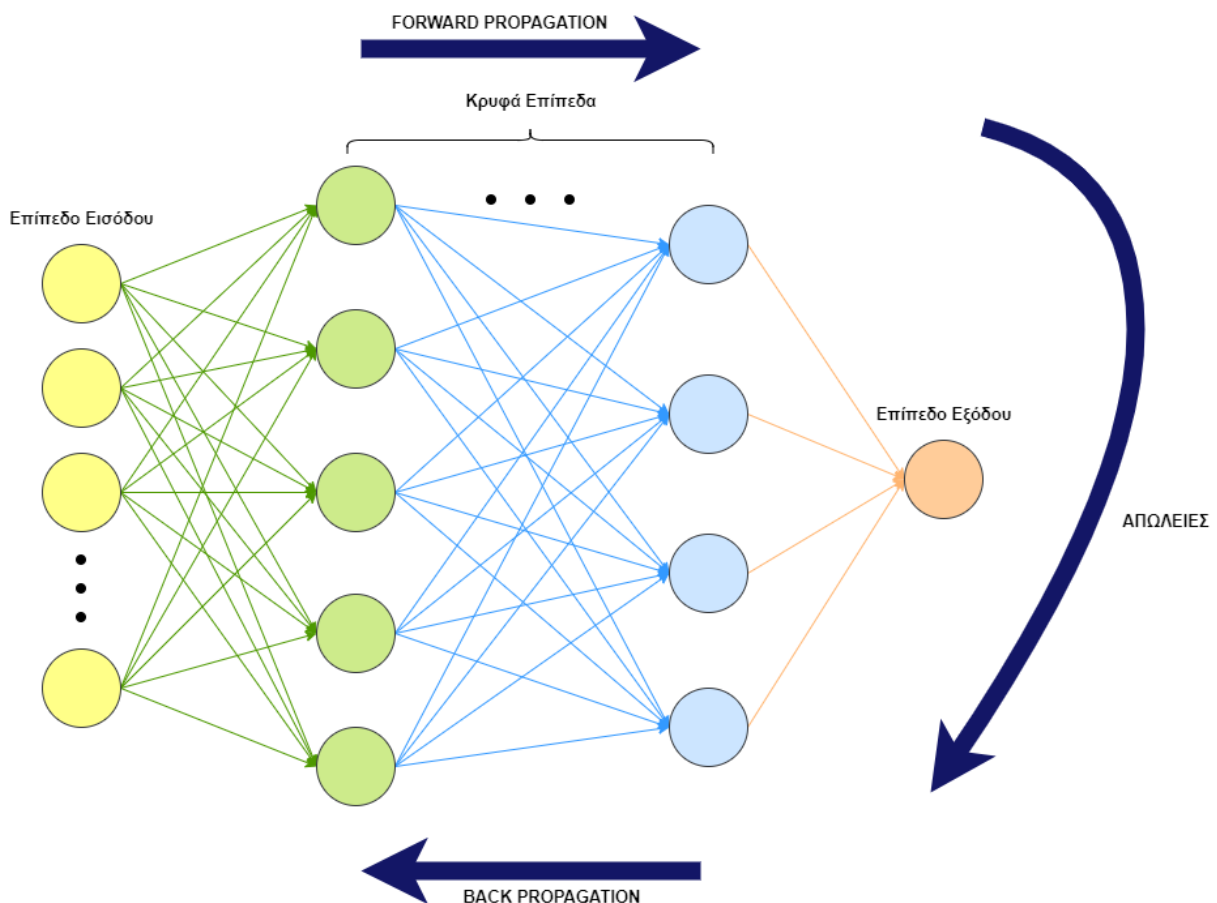
### 3.2.3.3 Φάση Εκπαίδευσης

Όπως αναλύθηκε παραπάνω, κάθε ΤΝΔ αποτελείται από νευρώνες που συνδέονται μεταξύ τους και κάθε σύνδεση σχετίζεται μ' ένα βάρος, το οποίο, όταν πολλαπλασιάζεται με την τιμή εισόδου, υπαγορεύει στο νευρώνα τη σημασία αυτής της σχέσης. Επιπλέον, κάθε νευρώνας διαθέτει μια συνάρτηση ενεργοποίησης που καθορίζει την έξοδό του.

Η εκπαίδευση του ΤΝΔ, δηλαδή η εκμάθηση των τιμών αυτών των παραμέτρων, αποτελεί μια επαναληπτική διαδικασία «μετάβασης» και «επιστροφής» των στρωμάτων των νευρώνων [23]. Η «μετάβαση», πρακτικά, είναι μια προς τα εμπρός τροφοδότηση (forward-propagation) των πληροφοριών, ενώ η «επιστροφή» είναι μια οπισθοδιάδοσή τους (back-propagation). Πιο συγκεκριμένα, η πρώτη φάση του forward-propagation εμφανίζεται όταν στο δίκτυο εισέρχονται τα δεδομένα εκπαίδευσης και διασχίζουν ολόκληρο το ΤΝΔ μέχρι να υπολογιστούν οι ετικέτες τους (labels). Πρόκειται, δηλαδή, για τη διάδοση των δεδομένων εισόδου με τέτοιο τρόπο στο δίκτυο, ώστε όλοι οι νευρώνες να εφαρμόζουν το μετασχηματισμό τους στις λαμβανόμενες από τους νευρώνες του προηγούμενου επιπέδου πληροφορίες και, στη συνέχεια, να τις αποστέλλουν στους νευρώνες του επόμενου επιπέδου. Όταν τα δεδομένα εισόδου θα έχουν περάσει από όλα τα επίπεδα του ΝΔ και όλοι οι νευρώνες έχουν ολοκληρώσει τους υπολογισμούς τους, τότε στο τελευταίο επίπεδο (επίπεδο εξόδου) θα φτάσει ένα αποτέλεσμα με ετικέτα πρόβλεψης για τα δεδομένα αυτά.

Το επόμενο στάδιο περιλαμβάνει τη χρήση μιας συνάρτησης απωλειών (loss function) για την εκτίμηση του σφάλματος, αλλά και τη σύγκριση του αποτελέσματος που λήφθηκε στην προηγούμενη φάση σε σχέση με το πραγματικό αποτέλεσμα (ground truth), πάντα στην περίπτωση μάθησης με επίβλεψη όπου υπάρχει ετικέτα με την αναμενόμενη τιμή. Στην ιδανική περίπτωση, το σφάλμα είναι μηδενικό, δηλαδή η απόκλιση μεταξύ προβλεπόμενης και επιθυμητής τιμής είναι μηδενική. Επομένως, καθώς το μοντέλο εκπαιδεύεται, τα βάρη των συνδέσεων των νευρώνων προσαρμόζονται σταδιακά, έως ότου ληφθεί η βέλτιστη πρόβλεψη.

Μετά τον υπολογισμό των απωλειών, το επόμενο στάδιο της διαδικασίας εκπαίδευσης του ΤΝΔ περιλαμβάνει την οπισθοδιάδοση των πληροφοριών. Ξεκινώντας από το επίπεδο εξόδου, οι πληροφορίες απωλειών διαδίδονται σε όλους τους νευρώνες του κρυφού επιπέδου που συμβάλλουν άμεσα στην τιμή πρόβλεψης. Ωστόσο, κάθε νευρώνας των κρυφών επιπέδων λαμβάνει κάθε φορά μόνο ένα μέρος του συνολικού σήματος απωλειών, βάσει της σχετικής συνεισφοράς του στην τιμή της εξόδου. Η συγκεκριμένη διαδικασία επαναλαμβάνεται σε κάθε στρώμα ώσπου όλοι οι νευρώνες του δικτύου να λάβουν ένα σήμα απωλειών που περιγράφει τη σχετική συμβολή τους στη συνολική απώλεια πρόβλεψης. Στο Σχήμα 9 που ακολουθεί παρουσιάζεται η διαδικασία εκπαίδευσης που αναφέρθηκε στο ΤΝΔ του προηγούμενου σχήματος.



Σχήμα 9. Διαδικασία εκπαίδευσης ενός νευρωνικού δικτύου.

Τελικό στάδιο της διαδικασίας εκπαίδευσης αποτελεί η αναπροσαρμογή του βάρους κάθε σύνδεσης νευρώνα, έτσι ώστε οι απώλειες να τείνουν να μηδενιστούν στην επόμενη χρήση του ΤΝΔ. Για το σκοπό αυτό, λοιπόν, χρησιμοποιείται η τεχνική της βασισμένης στην κλίση καθόδου (gradient descent), η οποία αλλάζει τα βάρη με μικρές προσαυξήσεις υπολογίζοντας την παράγωγο (derivative) της συνάρτησης απωλειών.

Η τεχνική της βασισμένης στην κλίση καθόδου αποτελεί έναν επαναληπτικό αλγόριθμο βελτιστοποίησης που χρησιμοποιείται στον τομέα της μηχανικής μάθησης για την εύρεση καλύτερων αποτελεσμάτων, τα οποία είναι τα ελάχιστα μιας καμπύλης. Πιο συγκεκριμένα, ο όρος «κλίση (gradient)» αφορά το ποσοστό κλίσης ή απόκλισης μιας καμπύλης, ενώ ο όρος «κάθοδος (descent)» έχει την ομώνυμη σημασία. Παράλληλα, το γεγονός ότι πρόκειται για έναν επαναληπτικό αλγόριθμο σημαίνει πως θα πρέπει τα αποτελέσματα να εξαχθούν πολλές φορές, μέχρι να εξαχθεί το βέλτιστο από αυτά. Η επαναληπτική αυτή ιδιότητα του αλγορίθμου βοηθά την εκάστοτε καμπύλη να ταιριάζει βέλτιστα στα δεδομένα. Τέλος, η συγκεκριμένη διαδικασία επιτελείται, γενικά, σε ομάδες δεδομένων κατά τη διάρκεια των κύκλων εκπαίδευσης ή απλά εποχών (epochs) όλων των συνόλων δεδομένων που περνούν μέσα στο δίκτυο σε κάθε επανάληψη.

Ορολογίες όπως εποχές, μέγεθος παρτίδας και επαναλήψεις χρησιμοποιούνται μόνο σε περιπτώσεις όπου ο όγκος των δεδομένων εκπαίδευσης είναι πολύ μεγάλος και δεν μπορεί να μεταφερθεί ταυτόχρονα. Έτσι, για την αντιμετώπιση του προβλήματος αυτού, αρκεί να χωριστούν τα δεδομένα σε μικρότερα σύνολα που θα περαστούν ένα-προς-ένα και να ενημερωθούν τα βάρη των ΤΝΔ στο τέλος του κάθε βήματος, ώστε να ταιριάζουν στα δεδομένα.

Αναλυτικότερα, με τον όρο «εποχή» εννοείται τόσο η διάδοση, όσο και η οπισθοδιάδοση ενός συνόλου δεδομένων μέσω ενός ΤΝΔ. Για μία εποχή, η διαδικασία αυτή πραγματοποιείται μόνο μία φορά. Ωστόσο, δεδομένου ότι μια εποχή είναι πολύς όγκος δεδομένων για ταυτόχρονη τροφοδοσία, στις περισσότερες περιπτώσεις χωρίζεται σε πολλές μικρότερες παρτίδες. Πέρα από τον όγκο όμως, η μεταφορά ολόκληρου του συνόλου δεδομένων σε ένα πέρασμα δεν είναι αρκετή, αλλά πρέπει να περαστεί αρκετές φορές στο ίδιο ΤΝΔ. Καθώς ο αριθμός των εποχών αυξάνεται, τόσες περισσότερες φορές αλλάζει το βάρος στο ΤΝΔ, με αποτέλεσμα η καμπύλη να μεταβαίνει από καμπύλη ατελούς μάθησης (underfitting), σε βέλτιστη καμπύλη, σε καμπύλη υπερ-προσαρμογής (overfitting).

Από την άλλη πλευρά, με τον όρο «μέγεθος παρτίδας (batch size)» εννοείται ο συνολικός αριθμός παραδειγμάτων εκπαίδευσης που υπάρχουν σε μία μεμονωμένη παρτίδα, καθώς, όπως προαναφέρθηκε, δεν μπορεί να μεταφερθεί ολόκληρο το σύνολο δεδομένων στο ΤΝΔ μόνο με μία φορά. Έτσι, το σύνολο των δεδομένων θα πρέπει να διαιρεθεί σε μικρότερες παρτίδες ή δεσμίδες δεδομένων.

Τέλος, οι επαναλήψεις (iterations) αποτελούν τον αριθμό των παρτίδων που απαιτούνται για την ολοκλήρωση μιας εποχής. Αξίζει να σημειωθεί πως ο αριθμός των παρτίδων ισούται με τον αριθμό των επαναλήψεων για μια εποχή. Για παράδειγμα, έστω ότι τα δείγματα εκπαίδευσης που πρόκειται να χρησιμοποιηθούν είναι 2000. Τότε, το σύνολο δεδομένων αυτών των 2000 χαρακτηριστικών μπορεί να χωριστεί σε παρτίδες των, έστω, 500 χαρακτηριστικών και, στη συνέχεια, θα χρειαστούν 4 επαναλήψεις για να ολοκληρωθεί μία εποχή.

Συνεπώς, οι προαναφερθέντες όροι συμβάλλουν ιδιαίτερα στον καλύτερο διαχωρισμό της διαδικασίας, με αποτέλεσμα αυτή να γίνεται ευκολότερα κατανοητή και ευανάγνωστη από κάποιον τρίτο.

Συνοψίζοντας, συγκεντρωτικά η φάση της εκπαίδευσης ενός μοντέλου ΤΝΔ αποτελείται από επτά επιμέρους στάδια. Το πρώτο στάδιο αφορά στις τυχαίες, συνήθως, τιμές των παραμέτρων του δικτύου, ενώ το δεύτερο στην επιλογή ενός συνόλου δεδομένων ως δεδομένα εισόδου για το δίκτυο, τα οποία θα περάσουν μέσα από το δίκτυο και τελικά θα υπολογιστεί η προβλεπόμενη τιμή (forward-propagation). Η σύγκριση των τιμών της πρόβλεψης με τις αναμενόμενες ετικέτες με χρήση της συνάρτησης απωλειών αποτελεί το τρίτο στάδιο, το οποίο διαδέχεται η βελτιστοποίηση (optimization) των τιμών των παραμέτρων, η τεχνική της οπισθοδιάδοσης και η ενημέρωση των παραμέτρων στα στάδια 4, 5 και 6, αντίστοιχα. Το τελικό έβδομο στάδιο είναι η επανάληψη της διαδικασίας μέχρι να βρεθεί το βέλτιστο μοντέλο.

#### 3.2.3.4 Σύνολα Δεδομένων

Όσον αφορά τα δεδομένα που χρησιμοποιούνται για τη δημιουργία του τελικού μοντέλου, συνήθως, αυτά χωρίζονται σε περισσότερα επιμέρους σύνολα δεδομένων. Πιο συγκεκριμένα, τρία είναι τα πιο συνηθισμένα σύνολα δεδομένων και κάθε ένα χρησιμοποιείται σε διαφορετικό στάδιο της διαδικασίας δημιουργίας: (α) δεδομένα εκπαίδευσης (training set), (β) δεδομένα επικύρωσης (validation set) και (γ) δεδομένα ελέγχου (test set), και κάθε ένα ορίζεται ακολούθως [24].

Ως δεδομένα εκπαίδευσης ορίζεται το δείγμα εκείνο των δεδομένων που χρησιμοποιείται για να ταιριάζει στο εκάστοτε μοντέλο. Πρόκειται, δηλαδή, για το σύνολο των δεδομένων που χρησιμοποιείται για την εκπαίδευση του μοντέλου ενός ΤΝΔ, συμπεριλαμβανομένων των βαρών και της πόλωσης.

Αντίστοιχα, τα δεδομένα επικύρωσης αναφέρονται στο δείγμα που χρησιμοποιείται για την παροχή αμερόληπτης (unbiased) αξιολόγησης ενός μοντέλου που ταιριάζει στα δεδομένα εκπαίδευσης, συντονίζοντας παράλληλα τις υπερ-παραμέτρους του. Η αξιολόγηση γίνεται πιο μεροληπτική (biased) καθώς η δεξιότητα στα δεδομένα επικύρωσης ενσωματώνεται στη διαμόρφωση του μοντέλου. Το συγκεκριμένο σύνολο δεδομένων χρησιμοποιείται για την αξιολόγηση ενός δεδομένου μοντέλου, με στόχο τη βελτίωση των υπερ-παραμέτρων του μοντέλου. Ως εκ τούτου, το ΤΝΔ «βλέπει» περιστασιακά τα δεδομένα αυτά, αλλά δεν μαθαίνει ποτέ από αυτά. Συνεπώς, τα δεδομένα επικύρωσης επηρεάζουν μεν το μοντέλο, αλλά όχι άμεσα.

Τέλος, ως δεδομένα ελέγχου ορίζονται εκείνα που χρησιμοποιούνται για την παροχή αμερόληπτης αξιολόγησης ενός τελικού μοντέλου που ταιριάζει στο σύνολο δεδομένων εκπαίδευσης. Πρόκειται για το σύνολο των δεδομένων που παρέχει το πρότυπο για την αξιολόγηση του μοντέλου και χρησιμοποιείται μόνο όταν αυτό είναι πλήρως εκπαιδευμένο, έχοντας ήδη χρησιμοποιήσει τα δεδομένα εκπαίδευσης και επικύρωσης. Γενικά, τα δεδομένα ελέγχου επιλέγονται με ιδιαίτερη προσοχή, περιλαμβάνοντας δεδομένα από διάφορες κλάσεις.

Αξίζει να σημειωθεί πως ο διαχωρισμός των δεδομένων στα προαναφερθέντα σύνολα είναι ιδιαίτερα σημαντικός και βασίζεται, κυρίως, αφενός στο συνολικό αριθμό των δειγμάτων και, αφετέρου στο ίδιο το μοντέλο που πρόκειται να εκπαιδευτεί. Ενδεικτικά, υπάρχουν μοντέλα που χρειάζονται σημαντικό αριθμό δεδομένων για την εκπαίδευσή τους, επομένως απαιτείται


μεγαλύτερο σύνολο δεδομένων εκπαίδευσης. Επιπλέον, μοντέλα με μικρό αριθμό υπερ-παραμέτρων είναι ευκολότερα στην επικύρωση και στο συντονισμό, οπότε το μέγεθος του αντίστοιχου συνόλου δεδομένων θα μπορούσε να μειωθεί. Αντίθετα, αν το μοντέλο έχει πολλές υπερ-παραμέτρους, απαιτείται μεγαλύτερο σύνολο δεδομένων επικύρωσης, ενώ αν δεν έχει καθόλου, ή έχει αλλά αυτές δεν μπορούν να συντονιστούν εύκολα, μπορεί και να μη χρειάζεται καθόλου σύνολο επικύρωσης.

### 3.2.4 Βασικές Κατηγορίες Νευρωνικών Δικτύων

Διαφορετικοί τύποι ΤΝΔ χρησιμοποιούν διαφορετικές αρχές για τον καθορισμό των δικών τους κανόνων. Υπάρχουν πολλοί τύποι ΤΝΔ, καθένας από τους οποίους έχει και τα δικά του μοναδικά πλεονεκτήματα. Στις υπο-ενότητες που ακολουθούν παρουσιάζονται ενδεικτικά τα βασικότερα μοντέλα και αυτά που μελετήθηκαν στα πλαίσια της παρούσας διπλωματικής εργασίας για το μετέπειτα κομμάτι της υλοποίησης.

#### 3.2.4.1 Μοντέλα Αισθητήρων (Perceptrons)

Το μοντέλο του αισθητήρα αποτελεί μια μονάδα ΤΝΔ, έναν τεχνητό νευρώνα δηλαδή, η οποία πραγματοποιεί συγκεκριμένους υπολογισμούς για την ανίχνευση χαρακτηριστικών ή νοημοσύνης στα δεδομένα εισόδου. Πρόκειται για έναν απλό, δυαδικό αλγόριθμο ταξινόμησης που βοηθά στη διαίρεση ενός συνόλου σημάτων σε δύο μέρη, «ναι» και «όχι» [25]. Σε αντίθεση, όμως, με πολλούς άλλους αλγορίθμους ταξινόμησης, το μοντέλο του αισθητήρα διαμορφώθηκε βάσει του νευρώνα του ανθρώπινου εγκεφάλου και διαθέτει την ικανότητα να μαθαίνει και να λύνει πολύπλοκα προβλήματα.



Σχήμα 10. Σχηματική αναπαράσταση μοντέλου αισθητήρα.

Όπως φαίνεται και από το Σχήμα 10, είναι ένας πολύ απλός αλγόριθμος μηχανικής μάθησης. Μπορεί να πάρει μερικές εισόδους, καθεμία από τις οποίες διαθέτει ένα συγκεκριμένο βάρος που υποδηλώνει τη σημαντικότητά της, και να δημιουργήσει μια απόφαση εξόδου με τιμές «0» ή «1». Ωστόσο, όταν συνδυάζεται και με άλλα αντίστοιχα μοντέλα αισθητήρων (Πολυεπίπεδα Δίκτυα Αισθητήρων ή Δίκτυα Πρόσθιας Τροφοδότησης), μπορεί θεωρητικά να απαντήσει σε οποιαδήποτε ερώτηση, δεδομένου ότι υπάρχουν αρκετά δεδομένα εκπαίδευσης και υπολογιστική ισχύς.


Όσον αφορά τη διαδικασία εκπαίδευσής του, αυτή περιλαμβάνει μια σειρά από συγκεκριμένα βήματα. Στο πρώτο βήμα, λαμβάνονται από το μοντέλο οι τιμές των εισόδων, πολλαπλασιάζονται με τα βάρη τους και υπολογίζεται το άθροισμά τους. Το βάρος κάθε εισόδου βοηθά το μοντέλο του αισθητήρα να αξιολογήσει τη σχετική σημασία κάθε εξόδου. Στο δεύτερο βήμα της διαδικασίας εκπαίδευσης, το μοντέλο προσθέτει έναν παράγοντα πόλωσης, καθιστώντας δυνατή τη μετακίνηση της συνάρτησης ενεργοποίησης πάνω και κάτω, ή δεξιά και αριστερά στο γράφημα. Πρόκειται για ένα βήμα που επιτρέπει τη λεπτή ρύθμιση της αριθμητικής εξόδου του μοντέλου. Συνεχίζοντας, το τρίτο βήμα περιλαμβάνει το πέρασμα του τελικού αθροίσματος από το δεύτερο βήμα μέσω της συνάρτησης ενεργοποίησης, η οποία αντιστοιχίζει τις τιμές εισόδου στις απαιτούμενες τιμές εξόδου. Για παράδειγμα, οι τιμές εισόδου μπορεί να είναι μεταξύ 1 και 100, ενώ οι εξοδοί μόνο 0 ή 1, αφού το μοντέλο είναι δυαδικό. Τέλος, το τέταρτο και τελευταίο βήμα είναι και το αποτέλεσμα ως τιμή εξόδου του μοντέλου.

### 3.2.4.2 Δίκτυα Πρόσθιας Τροφοδότησης (Feed Forward Neural Networks)

Τα δίκτυα πρόσθιας τροφοδότησης [26], ή επίσης γνωστά και ως πολυεπίπεδα δίκτυα αισθητήρων, αποτελούν θεμέλιο των περισσότερων μοντέλων βαθιάς μάθησης. Δίκτυα όπως τα Συνελκτικά ΤΝΔ (Convolutional NNs) και τα Αναδρομικά ΤΝΔ (Recurrent NNs), τα οποία αναλύονται στην Παρ. 3.2.4.3, αποτελούν ειδικές περιπτώσεις δικτύων πρόσθιας τροφοδότησης.

Πρόκειται για έναν από τους απλούστερους τύπους ΤΝΔ, που χρησιμοποιείται συνήθως σε περιπτώσεις μάθησης με επίβλεψη όπου είναι ήδη γνωστό το αποτέλεσμα που πρέπει να πετύχει το δίκτυο. Τα δεδομένα περνούν από διαφορετικούς κόμβους εισόδου μέχρι να φτάσουν στον κόμβο εξόδου. Με άλλα λόγια, τα δεδομένα μετακινούνται προς μια μόνο κατεύθυνση από το πρώτο επίπεδο του δικτύου και μετά, μέχρι να φτάσουν στον κόμβο εξόδου.

Σε αντίθεση με τους πιο σύνθετους τύπους ΤΝΔ, εδώ δεν υπάρχει η τεχνική της οπισθοδιάδοσης μέχρι τα δεδομένα να φτάσουν στο επίπεδο της εξόδου όπως συμβαίνει, για παράδειγμα, στα αναδρομικά ΤΝΔ, καθώς, όπως προαναφέρθηκε, τα δεδομένα μετακινούνται μόνο προς μια κατεύθυνση. Στη συγκεκριμένη κατηγορία δικτύων, υπολογίζεται το άθροισμα των αποτελεσμάτων των εισόδων και των αντίστοιχων βαρών τους, το οποίο στη συνέχεια μεταφέρεται στην έξοδο. Στο Σχήμα 11 παρουσιάζεται ένα παράδειγμα δικτύου πρόσθιας τροφοδότησης.




Σχήμα 11. Σχηματική αναπαράσταση δικτύου πρόσθιας τροφοδότησης.

Γενικά, τα δίκτυα πρόσθιας τροφοδότησης χρησιμοποιούνται σε τεχνολογίες όπως η αναγνώριση προσώπου και η υπολογιστική όραση, καθώς στις συγκεκριμένες εφαρμογές οι κλάσεις-στόχοι είναι πολύ δύσκολο να ταξινομηθούν. Ένα ΤΝΔ αυτής της κατηγορίας είναι εξοπλισμένο για την αντιμετώπιση δεδομένων που περιέχουν πολύ θόρυβο, ενώ, επιπλέον, είναι σχετικά απλό στη συντήρηση.

### 3.2.4.3 Αναδρομικά Νευρωνικά Δίκτυα (Recurrent Neural Networks)

Τα αναδρομικά ΤΝΔ αποτελούν έναν τύπο δικτύου που εισάγει ένα νέο τύπο κόμβων, τους αναδρομικούς κόμβους, όπως φαίνεται στο Σχήμα 12. Με την προσθήκη της νέας λειτουργίας των αναδρομικών κόμβων, η έξοδος ενός συγκεκριμένου στρώματος αποθηκεύεται και περνάει πίσω στην είσοδο, βοηθώντας στην πρόβλεψη του αποτελέσματος του επιπέδου.

Η διαδικασία της εκπαίδευσης είναι παρόμοια με αυτή των προηγούμενων δικτύων, με τη διαφορά ότι τα αναδρομικά δίκτυα, επιπλέον, έχουν την ικανότητα να θυμούνται πράγματα που έμαθαν από προηγούμενες εισόδους κατά την παραγωγή των αντίστοιχων εξόδων [27]. Τα αναδρομικά δίκτυα μπορούν να πάρουν ένα ή περισσότερα διανύσματα εισόδου και να παράξουν ένα ή περισσότερα διανύσματα εξόδου, οι τιμές των οποίων επηρεάζονται όχι μόνο από τα βάρη, όπως στα κλασικά ΤΝΔ, αλλά και από ένα «κρυφό» διάνυσμα κατάστασης που αντιπροσωπεύει το πλαίσιο βάσει προηγούμενων εισόδων και εξόδων.




Σχήμα 12. Σχηματική αναπαράσταση αναδρομικού νευρωνικού δικτύου.

Με λίγα λόγια, η διαδικασία της εκπαίδευσης σ' ένα κλασικό ΤΝΔ περιλαμβάνει τη μετατροπή μιας σταθερής τιμής εισόδου σε μια σταθερή τιμή εξόδου. Ένα κλασικό ΤΝΔ θεωρείται αναδρομικό όταν εφαρμόζει επανειλημμένα τους μετασχηματισμούς σε μια σειρά από δεδομένα εισόδου, παράγοντας μια σειρά από διανύσματα εξόδου. Επιπρόσθετα, το μέγεθος του διανύσματος δεν περιορίζεται και, εκτός από την παραγωγή της εξόδου ως συνάρτησης της εισόδου και των κρυφών επιπέδων, περιλαμβάνεται και ενημέρωση του ίδιου του κρυφού επιπέδου βάσει της εισόδου, ώστε τα αποτελέσματα να χρησιμοποιηθούν για επεξεργασία της επόμενης εισόδου.

### 3.2.4.4 Δίκτυα Long/Short Term Memory

Τα δίκτυα Long/Short Term Memory, ή εν συντομία LSTMs, αποτελούν υποκατηγορία των αναδρομικών δικτύων που προαναφέρθηκαν και εισάγουν αλλαγές στον τρόπο υπολογισμού των εξόδων και των κρυφών επιπέδων [28]. Βελτιώνουν τον απλό μετασχηματισμό των αναδρομικών ΤΝΔ και εισάγουν πρόσθετες πύλες και καταστάσεις κόμβων, έτσι ώστε να αντιμετωπίζεται θεμελιωδώς το πρόβλημα της διατήρησης ή της επαναφοράς του περιεχομένου. Υπάρχουν παραλλαγές των LSTM, όπως τα GRU που παρουσιάζονται παρακάτω στην Παρ. 3.2.4.5, που χρησιμοποιούν τις πύλες με διαφορετικούς τρόπους για την αντιμετώπιση του προβλήματος της συγκράτησης πληροφοριών στη μνήμη για μεγάλα χρονικά διαστήματα.

Πιο αναλυτικά, η αρχιτεκτονική των LSTM μοιάζει αρκετά με αυτή των υπολοίπων αναδρομικών ΤΝΔ, με την έννοια ότι απαρτίζονται και αυτά από έναν αριθμό μονάδων συνδεδεμένων αλυσιδωτά μεταξύ τους σε κάθε επίπεδο. Η διαφορά έγκειται στο γεγονός ότι οι μονάδες που βρίσκονται στα κρυφά επίπεδα του δικτύου περιέχουν κάποια επιπλέον στοιχεία και ονομάζονται «μονάδες μνήμης (memory blocks)». Πιο συγκεκριμένα, κάθε μονάδα του δικτύου αποτελείται από έναν ή περισσότερους «κόμβους μνήμης» που συνδέονται μεταξύ τους, αλλά και από πύλες εισόδου, εξόδου και επιλεκτικής συγκράτησης (forget gate), υπεύθυνες για λειτουργίες εγγραφής, ανάγνωσης και επαναφοράς των κόμβων, αντίστοιχα. Η χρήση των πυλών αυτών διασφαλίζει την αποθήκευση και την πρόσβαση στις πληροφορίες, ακόμα και με την πάροδο μεγάλων χρονικών περιόδων ή πολλών βημάτων.



Σχήμα 13. Σχηματική αναπαράσταση δικτύου Long/Short Term Memory.

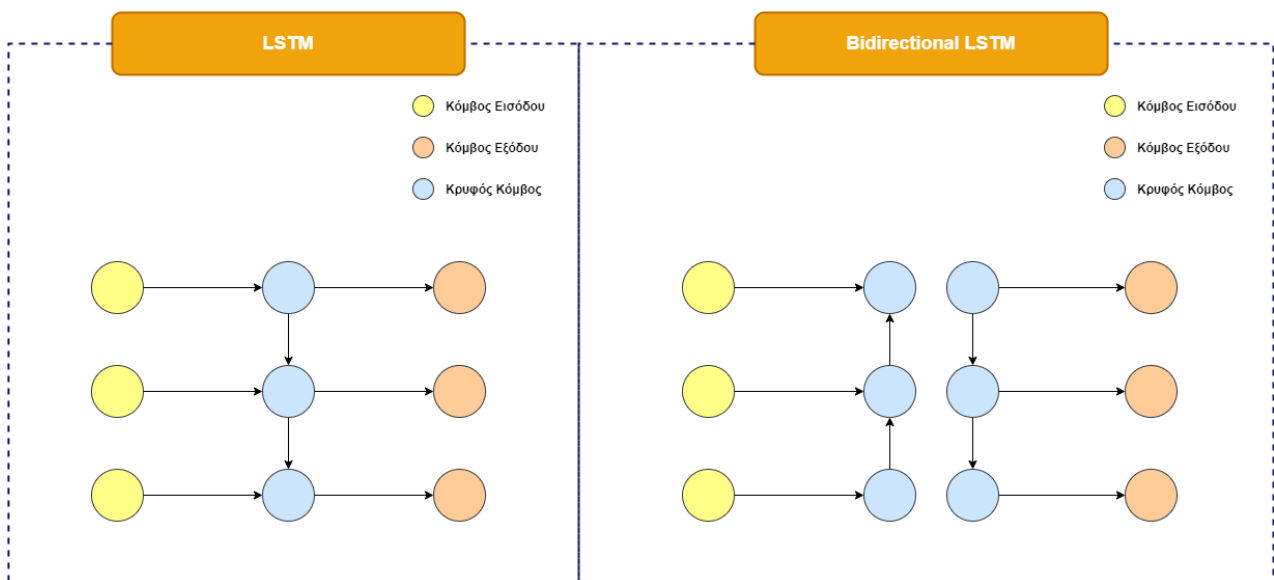
Όπως προαναφέρθηκε, ένα από τα βασικά πλεονεκτήματα των αναδρομικών δικτύων είναι η ικανότητά τους για συνδυασμό πληροφοριών από προηγούμενα δεδομένα εκπαίδευσης και η εφαρμογή τους σε νέα δεδομένα. Ωστόσο, όσο τα κενά μεταξύ των αλληλοεξαρτήσεων μεγαλώνουν, τα κλασικά αναδρομικά ΤΝΔ δε δύνανται να συνδυάσουν αυτές τις πληροφορίες, λόγω του πεπερασμένου αριθμού των προηγούμενων βημάτων και για το σκοπό αυτό προτιμώνται τα δίκτυα LSTM, που υπερνικούν τη συγκεκριμένη δυσκολία.



Όπως περιγράφηκε παραπάνω, ένα απλό LSTM δίκτυο αποτελείται από ένα μόνο κρυφό επίπεδο LSTM, ακολουθούμενο από ένα τυπικό επίπεδο εξόδου πρόσθιας τροφοδότησης. Μια επέκταση αυτού του μοντέλου TND αποτελεί το Stacked LSTM, το οποίο διαθέτει πολλά κρυφά επίπεδα LSTM και κάθε τέτοιο επίπεδο διαθέτει πολλούς κόμβους μνήμης.

Η προσθήκη επιπλέον κρυφών επιπέδων (stacking) LSTM δημιουργεί ένα βαθύτερο μοντέλο TND. Δεδομένου ότι τα δίκτυα LSTM χρησιμοποιούνται σε δεδομένα ακολουθίας, αυτό σημαίνει πως η προσθήκη επιπέδων προσθέτει με τη σειρά της επίπεδα που, με την πάροδο του χρόνου, αφαιρούν παρατηρήσεις εισόδου, ή πρακτικά αντιπροσωπεύουν το πρόβλημα σε διαφορετικές χρονικές κλίμακες. Παράλληλα, οι παράμετροι του μοντέλου μπορούν να καταναμηθούν κατά μήκος ολόκληρου του μοντέλου, χωρίς να απαιτούν περισσότερη μνήμη. Το γεγονός αυτό επιτρέπει στο μοντέλο να επιταχύνει τη σύγκλιση (convergence), αλλά και να βελτιώνει τις μη γραμμικές λειτουργίες των πρωτογενών δεδομένων. Τέλος, ένα βαθύ δίκτυο LSTM μπορεί να βοηθήσει στην ενίσχυση ολόκληρης της διαδικασίας απομνημόνευσης μιας γραμμής σήματος, εντοπίζοντας αυτόματα σημαντικά σημεία του ακατέργαστου σήματος.

Μια άλλη παραλλαγή του συγκεκριμένου τύπου δικτύων είναι το LSTM Δύο Κατευθύνσεων (Bidirectional LSTM), το οποίο σε αντίθεση με το απλό LSTM χρησιμοποιεί τόσο παρελθοντικές, όσο και μελλοντικές ακολουθίες δεδομένων εισόδου [29]. Όπως φαίνεται στο Σχήμα 14, χρησιμοποιούνται δύο συνδεδεμένα επίπεδα για την επεξεργασία των δεδομένων εισόδου, έτσι ώστε το ένα επίπεδο να εκτελεί τις λειτουργίες ακολουθώντας ίδια κατεύθυνση με αυτή της ακολουθίας των δεδομένων, ενώ το άλλο επίπεδο να εφαρμόζεται σε αντίστροφη κατεύθυνση.



Σχήμα 14. Διαφορά μεταξύ Απλού LSTM και LSTM Δύο Κατευθύνσεων.


Η χρήση των δύο αυτών επιπέδων στο BiLSTM, συνεπώς, μπορεί να παρέχει επιπλέον πληροφορίες για το ίδιο το δίκτυο, με αποτέλεσμα να προσφέρει καλύτερη ακρίβεια πρόβλεψης, καθιστώντας το αποτελεσματικότερο του απλού μονοκατευθυντικού LSTM δικτύου σε ορισμένες εφαρμογές, όπως είναι προβλήματα ταξινόμησης ακολουθιών και πρόβλεψης χρονοσειρών.

### 3.2.4.5 Δίκτυα Gated Recurrent Unit

Η τεχνική του Gated Recurrent Unit, ή εν συντομία GRU, στοχεύει στην επίλυση του προβλήματος της εξαφάνισης της κλίσης, το οποίο παρατηρείται στα αναδρομικά ΤΝΔ και έχει ως αποτέλεσμα η διαδικασία εκπαίδευσης να μην εντοπίζει ικανοποιητικά καλές τιμές για τα βάρη του μοντέλου [30]. Τα συγκεκριμένα δίκτυα μπορούν να θεωρηθούν ως μια παραλλαγή των δικτύων LSTM, καθώς και τα δύο έχουν σχεδιαστεί με παρόμοιο τρόπο και, σε ορισμένες περιπτώσεις, παράγουν εξίσου καλά αποτελέσματα.

Η διαφοροποίηση ανάμεσα στους δύο τύπους ΤΝΔ παρατηρείται στην ύπαρξη δύο νέων πυλών στα δίκτυα GRU, της «πύλης ενημέρωσης (update gate)» και της «πύλης επαναφοράς (reset gate)», για την αντιμετώπιση του προβλήματος της εξαφάνισης κλίσης. Πιο συγκεκριμένα, η πύλη ενημέρωσης συνδυάζει τις πύλες εισόδου και επιλεκτικής συγκράτησης που υπάρχουν στα κλασικά δίκτυα LSTM, ενώ αντίστοιχα, η πύλη επαναφοράς κατευθύνει μόνο τις αναδρομικές συνδέσεις του δικτύου στο διάνυσμα της κατάστασης του κόμβου, και από εκεί στην είσοδο της κατάστασης του επόμενου block. Με λίγα λόγια, η πύλη επαναφοράς παίρνει τη θέση της πύλης εξόδου που υπάρχει στα κλασικά LSTM δίκτυα.

Βασικά, οι δύο νέες πύλες αποτελούν τα δύο διανύσματα που αποφασίζουν ποιες πληροφορίες θα πρέπει να διαβιβάζονται στην έξοδο του δικτύου. Το ιδιαίτερο χαρακτηριστικό αυτού του τύπου δικτύων είναι η ικανότητά τους να εκπαιδεύονται για να κρατούν πληροφορίες στη μνήμη και ύστερα από μεγάλο χρονικό διάστημα, χωρίς να αφαιρούν πληροφορίες που δε σχετίζονται με την πρόβλεψη.

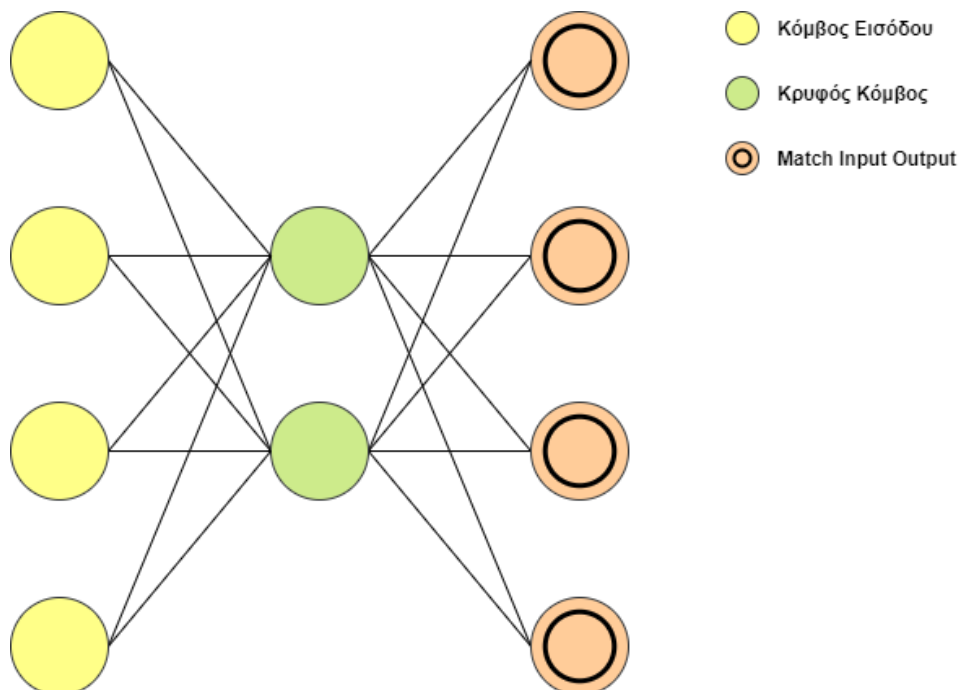


Σχήμα 15. Σχηματική αναπαράσταση δικτύου Gated Recurrent Unit.

Συνοψίζοντας, η βασική διαφορά μεταξύ ενός LSTM και ενός GRU δικτύου έγκειται στον τρόπο που το καθένα συνδυάζει τα διανύσματα των κρυφών επιπέδων. Στα δίκτυα GRU, αντί για την ύπαρξη της πύλης επιλεκτικής συγκράτησης, μπορεί να αποφασιστεί η ποσότητα των προηγούμενων πληροφοριών που θα διατηρηθεί ή θα απορριφθεί βάσει του συμπληρώματος της πύλης εισόδου.

### 3.2.4.6 Δίκτυα Auto-encoder

Τα δίκτυα Auto-encoder αποτελούν ΤΝΔ που ακολουθούν μάθηση χωρίς επίβλεψη. Μαθαίνουν πώς να συμπιέζουν και να κωδικοποιούν αποτελεσματικά τα δεδομένα, αλλά και πώς να ανακατασκευάσουν τα πλέον συμπιεσμένα δεδομένα σε μια αναπαράσταση που είναι όσο το δυνατόν πιο κοντά στην αρχική είσοδο [31]. Ο συγκεκριμένος τύπος δικτύου, βάσει σχεδιασμού, μειώνει τις διαστάσεις των δεδομένων μαθαίνοντας πώς να αγνοεί το θόρυβο στα δεδομένα. Στην πιο απλή του μορφή, αποτελείται από ένα επίπεδο εισόδου, ένα κρυφό επίπεδο και ένα επίπεδο εξόδου που έχει το ίδιο πλήθος κόμβων με το αντίστοιχο επίπεδο εισόδου, όπως φαίνεται στο Σχήμα 16.



Σχήμα 16. Σχηματική αναπαράσταση δικτύου Auto-encoder.

Πιο αναλυτικά, τα βασικά δομικά στοιχεία ενός τέτοιου δικτύου είναι ο «encoder», ο οποίος μειώνει τις διαστάσεις των δεδομένων εισόδου συμπιέζοντάς τα σε μια κωδικοποιημένη αναπαράσταση, και ο «decoder», ο οποίος ανακατασκευάζει τα δεδομένα από την κωδικοποιημένη αναπαράσταση, ώστε να προσομοιάζουν όσο το δυνατόν περισσότερο στην αρχική είσοδο. Επιπλέον, το επίπεδο που περιέχει τη συμπιεσμένη αναπαράσταση των δεδομένων καλείται «bottleneck» και αποτελεί τη χαμηλότερη δυνατή διάσταση των δεδομένων εισαγωγής. Τέλος, η έξοδος του auto-encoder ονομάζεται «ανακατασκευή (reconstruction)», λόγω του στόχου του μοντέλου, και η συνάρτηση απωλειών καλείται «απώλεια ανακατασκευής (reconstruction loss)» και έχει ως ρόλο να μετρά πόσο καλά αποδίδει ο decoder και πόσο κοντά είναι η έξοδος στην αρχική είσοδο. Στη συνέχεια, η εκπαίδευση του μοντέλου περιλαμβάνει τη χρήση της τεχνικής της οπισθοδιάδοσης, ώστε να ελαχιστοποιηθούν οι απώλειες ανακατασκευής του δικτύου.

Τέλος, και όσον αφορά την αρχιτεκτονική του δικτύου, αυτή μπορεί να διαφέρει μεταξύ ενός απλού δικτύου πρόσθιας τροφοδότησης, ενός δικτύου LSTM ή ενός συνελκτικού ΤΝΔ, ανάλογα με την περίπτωση χρήσης. Ενδεικτικά, η απλούστερη μορφή ενός auto-encoder, όπως φαίνεται και στο Σχήμα 16, προσομοιάζει στη δομή ενός μικρού δικτύου πρόσθιας τροφοδότησης, με τους encoder και decoder να αποτελούνται ο καθένας από ένα πλήρως συνδεδεμένο επίπεδο, με βασικό περιορισμό ότι ο αριθμός των κόμβων εισόδου πρέπει να είναι ίδιος με αυτόν των κόμβων εξόδου. Σε αντίθετη περίπτωση, ο auto-encoder χαρακτηρίζεται μη ολοκληρωμένος (undercomplete) και δεν είναι πλέον ικανός να αντιγράψει τυφλά τις τιμές των εισόδων στις κωδικοποιήσεις του. Σε περιπτώσεις όπου συμβαίνει αυτό, η εκπαίδευση περιλαμβάνει τη μάθηση μόνο των σημαντικότερων χαρακτηριστικών των δεδομένων, αγνοώντας τα υπόλοιπα.

### 3.2.5 Πλεονεκτήματα Νευρωνικών Δικτύων

Ολοκληρώνοντας, η χρήση των ΤΝΔ για την επίλυση συγκεκριμένων προβλημάτων και καταστάσεων προσφέρει ποικίλα πλεονεκτήματα [32]. Αρχικά, τα μοντέλα των ΤΝΔ απαιτούν λιγότερη στατιστική εκπαίδευση για την ανάπτυξή τους. Μπορούν να αναπτυχθούν χωρίς ιδιαίτερη προϋπηρεσία και προαπαιτούμενες γνώσεις, υπό την προϋπόθεση ότι υπάρχει κατάλληλο σύνολο δεδομένων και λογισμικό. Γενικά, ένα ΤΝΔ μπορεί να εκπαιδευτεί χρησιμοποιώντας τόσο συνεχείς, όσο και κατηγορικές μεταβλητές εισόδου και εξόδου, αν και ενδέχεται να είναι απαραίτητοι ορισμένοι μετασχηματισμοί δεδομένων ανάλογα με το λογισμικό που χρησιμοποιείται.

Επιπλέον, τα ΤΝΔ μπορούν να εντοπίσουν έμμεσα και να μοντελοποιήσουν σύνθετες μη γραμμικές σχέσεις μεταξύ ανεξάρτητων και εξαρτημένων μεταβλητών, χαρακτηριστικό ιδιαίτερα χρήσιμο για την επίλυση των προβλημάτων της καθημερινότητας. Σε περίπτωση που υπάρχουν σημαντικά ποσά μη γραμμικότητας μεταξύ των μεταβλητών πρόβλεψης και των αντίστοιχων αποτελεσμάτων τους σ' ένα σύνολο δεδομένων εκπαίδευσης, τότε το δίκτυο θα προσαρμόσει αυτόματα τα βάρη των συνδέσεων.

Όπως έχει αναφερθεί ήδη αρκετές φορές, τα ΤΝΔ διαθέτουν ικανότητα γενίκευσης. Αυτό σημαίνει πως με την ολοκλήρωση της εκπαίδευσής τους βάσει των αρχικών τιμών εισόδου, αλλά και των σχέσεων αυτών, μπορούν να συμπεράνουν και μη ορατές σχέσεις μεταξύ μη ορατών δεδομένων. Το γεγονός αυτό καθιστά το ΤΝΔ ως ένα μοντέλο γενίκευσης που μπορεί να προβλέπει άγνωστες τιμές δεδομένων.

Τέλος, και σε αντίθεση με άλλες τεχνικές πρόβλεψης, ένα ΤΝΔ δεν επιβάλλει περιορισμούς στις μεταβλητές εισόδου. Παράλληλα, πλήθος μελετών έχουν δείξει πως τα ΤΝΔ μπορούν να μοντελοποιήσουν καλύτερα δεδομένα με υψηλή μεταβλητότητα και μη σταθερή διακύμανση, δεδομένης της ικανότητάς τους να μαθαίνουν κρυφές σχέσεις μεταξύ των δεδομένων, όπως αναφέρθηκε προηγουμένως.


# 4

## Εξοπλισμός

### 4.1 Πλακέτα ESP32

Πρόκειται για μια μικρού μεγέθους πλακέτα που παράγεται από την Espressif και επιτρέπει ασύρματη σύνδεση, είτε μέσω Wi-Fi, που προτιμήθηκε για τα πλαίσια της συγκεκριμένης εργασίας, είτε μέσω Bluetooth (BLE/Bluetooth Smart και Bluetooth Classic) [33]. Η συγκεκριμένη πλακέτα περιλαμβάνει τη μονάδα ESP-WROOM-32 που περιέχει τον μικροεπεξεργαστή Tensilica Xtensa Dual-Core 32-bit LX6. Ο μικροεπεξεργαστής αυτός διαθέτει δύο πυρήνες CPU και μπορεί να λειτουργεί στα 80 έως 240MHz με ρυθμιζόμενη συχνότητα ρολογιού. Ταυτόχρονα, η λειτουργία χαμηλής ισχύος που διαθέτει επιτρέπει τη χρήση AD μετατροπών, ακόμα και σε περιπτώσεις «deep sleep», ενώ υλοποιεί τον AES και το πρωτόκολλο SSL στο υλικό, για επιτάχυνση.

Όσον αφορά την τροφοδοσία της πλακέτας, αυτή παρέχεται μέσω της ενσωματωμένης micro USB υποδοχής. Επιπλέον, για τη ρύθμιση των ενεργειακών του απαιτήσεων, το ESP32 διαθέτει ρυθμιστή τάσης, ώστε να διατηρείται η τάση σταθερή στα 3.3V. Η έξοδος του ρυθμιστή διασπάται, επίσης, σε μία από τις πλευρές της πλακέτας, φέροντας την ένδειξη 3V3, όπως φαίνεται στο ακόλουθο σχήμα. Το συγκεκριμένο pin της πλακέτας χρησιμοποιείται για να τροφοδοτούνται εξωτερικά εξαρτήματα.



Σχήμα 17. Πλακέτα ESP32.

Όπως φαίνεται και στο σχήμα, η συγκεκριμένη πλακέτα διαθέτει δύο κουμπιά. Το κουμπί που αναγράφεται ως «EN» και βρίσκεται στην κάτω δεξιά γωνία είναι το κουμπί «reset», που χρησιμοποιείται για την επαναφορά του ESP32. Αντίστοιχα, το κουμπί στην πάνω δεξιά γωνία, με τη σήμανση «BOOT», είναι το κουμπί λήψης και χρησιμοποιείται για το «κατέβασμα» του νέου κώδικα στην πλακέτα. Τέλος, το ESP32 περιλαμβάνει και μια γέφυρα USB-to-UART, η οποία μετατρέπει το USB σήμα σε σειριακό και επιτρέπει την επικοινωνία της πλακέτας με τον υπολογιστή. Ο Πίνακας II συγκεντρώνει όλα τα στοιχεία, με κάποιες επιπρόσθετες πληροφορίες, που προαναφέρθηκαν στο Σχήμα 17.

**Πίνακας II. Στοιχεία πλακέτας ESP32.**

Στοιχείο Πλακέτας	Περιγραφή
ESP-WROOM-32 Chip	Πυρήνας ESP32.
EN/Reset Button	Κουμπί επαναφοράς (reset).
Boot Button	Κουμπί λήψης. Πατώντας το κουμπί του boot και στη συνέχεια το EN, ενεργοποιείται η διαδικασία λήψης του firmware μέσω μιας σειριακής θύρας.
USB-to-UART Bridge	Απαραίτητο για την επικοινωνία της πλακέτας με τον υπολογιστή κατά τον προγραμματισμό της.
Micro USB Connector	Διεπαφή USB. Τροφοδοσία ρεύματος για την πλακέτα, αλλά και διασύνδεση επικοινωνίας μεταξύ υπολογιστή και ESP32.
3V3 Output of Regulator	Pin της πλακέτας. Χρησιμοποιείται για παροχή τάσης 3.3V σε περιφερειακά.
External Power Supply	Εναλλακτική παροχή τάσης 5V σε πλακέτα και περιφερειακά.

Συνοψίζοντας το τεχνικό κομμάτι, ο βασικός λόγος επιλογής της συγκεκριμένης πλακέτας είναι η υψηλή απόδοσή της σε συνδυασμό με τη χαμηλή της κατανάλωση. Ωστόσο, η κατανάλωση ενέργειας της συγκεκριμένης πλακέτας εξαρτάται σε πολύ μεγάλο βαθμό από την κατάσταση στην οποία βρίσκεται. Πιο συγκεκριμένα, σε περιπτώσεις όπου ένα ανάλογο σύστημα τροφοδοτείται από ρεύμα απευθείας, η κατανάλωση ενέργειας του συστήματος δεν είναι ιδιαίτερα σημαντική. Αντίθετα, η χρήση μπαταρίας για την τροφοδοσία της πλακέτας αλλάζει τις ενεργειακές απαιτήσεις του συστήματος. Η λύση στο συγκεκριμένο πρόβλημα, επομένως, έγκειται στη μείωση της κατανάλωσης ενέργειας της πλακέτας ESP32, αξιοποιώντας μια από τις καταστάσεις ύπνου που διαθέτει, καθώς το σύστημα δε χρειάζεται να είναι ενεργό συνέχεια.

Για την ύπαρξη ξεκάθαρης εικόνας του εσωτερικού της πλακέτας, παρέχεται ένα διάγραμμα στο Σχήμα 18, ώστε να γίνει ευκολότερη και η κατανόηση του τρόπου με τον οποίο επιτελείται η εξοικονόμηση ενέργειας. Όπως φαίνεται στο σχήμα, λοιπόν, στο κέντρο της πλακέτας ESP32 υπάρχει ο μικροεπεξεργαστής, όπως αναφέρθηκε και παραπάνω, και γύρω από αυτόν υπάρχουν οι

μονάδες Wi-Fi και Bluetooth, ένας επιταχυντής σχεδιασμένος ειδικά για την εκτέλεση κρυπτογράφησης, η RTC μονάδα και τα περιφερειακά.



Σχήμα 18. Διάγραμμα λειτουργίας ESP32.

Όσον αφορά τις καταστάσεις λειτουργίας που παρέχονται από την πλακέτα, αυτές είναι πέντε: (α) «Active», (β) «Modem Sleep», (γ) «Light Sleep», (δ) «Deep Sleep» και (ε) «Hibernation», και κάθε μία έχει τα δικά της διακριτά χαρακτηριστικά και τις δικές της δυνατότητες εξοικονόμησης [34]. Ο Πίνακας III περιλαμβάνει συνοπτικά την ταξινόμηση των ενεργών και ανενεργών μονάδων της πλακέτας ESP32 ανάλογα με την κατάσταση λειτουργίας στην οποία βρίσκεται.

Αρχικά, η κλασική κατάσταση όπου όλα τα επιμέρους τμήματα της πλακέτας είναι ενεργοποιημένα, είναι η «active». Καθώς στη συγκεκριμένη κατάσταση όλα τα τμήματα, και ειδικότερα το Wi-Fi, το Bluetooth και οι επεξεργαστές, είναι ενεργά, η πλακέτα απαιτεί περισσότερα από 240mA ισχύος για να λειτουργήσει. Επιπλέον, διάφορα πειράματα από μελέτες έδειξαν πως σε περιπτώσεις χρήσης και του Wi-Fi και του Bluetooth, παρατηρούνται ακραίες τιμές ενέργειας. Συνεπώς, η συγκεκριμένη κατάσταση είναι η λιγότερο αποδοτική σε ό,τι αφορά την κατανάλωση ενέργειας, η οποία κυμαίνεται από 160mA έως 260mA.

Στην κατάσταση «modem sleep» όλες οι μονάδες είναι ενεργές εκτός από το Wi-Fi, το Bluetooth και το ράδιο και η κατανάλωση κυμαίνεται μεταξύ 3mA σε χαμηλή ταχύτητα και 20mA σε υψηλή ταχύτητα. Ωστόσο, προκειμένου να μπορέσουν να διατηρηθούν ενεργές οι συνδέσεις με το Wi-Fi ή το Bluetooth, ο επεξεργαστής και οι αντίστοιχες μονάδες ασύρματης διασύνδεσης «ξυπνούν» σε προκαθορισμένα χρονικά διαστήματα. Κατά τη διαδικασία αυτή, η κατάσταση λειτουργίας αλλάζει από «active» σε «modem sleep». Τέλος, να σημειωθεί ότι η πλακέτα μπορεί να εισέλθει σε κατάσταση «modem sleep» μόνο όταν είναι συνδεδεμένη με το δρομολογητή, με τον οποίο παραμένει συνδεδεμένη μέσω ενός μηχανισμού που καλείται «φάρος DTIM (DTIM beacon)». Στο μηχανισμό αυτό, ο δρομολογητής μεταδίδει περιοδικά μηνύματα (beacon frames), καθένα από τα οποία περιλαμβάνει όλες τις πληροφορίες του δικτύου και, συνήθως,

χρησιμοποιείται αφενός για την ανακοίνωση της παρουσίας ενός ασύρματου δικτύου και αφετέρου για το συγχρονισμό όλων των συνδεδεμένων μελών στο δίκτυο. Προκειμένου, λοιπόν, το ESP32 να μπορέσει να εξοικονομήσει ενέργεια, απενεργοποιεί τη μονάδα του Wi-Fi μεταξύ δύο διαστημάτων DTIM και ενεργοποιείται ξανά αυτόματα πριν από την άφιξη του επόμενου μηνύματος. Ο χρόνος αναστολής εξαρτάται από μηχανισμό DTIM του δρομολογητή και είναι συνήθως από 100ms έως 1000ms.

**Πίνακας III. Καταστάσεις λειτουργίας ESP32.**

Κατάσταση	Ενεργή Μονάδα	Ανενεργή Μονάδα	Σε Παύση
Active	Όλες	Καμία	Καμία
Modem Sleep	Πυρήνας ESP32 & Μνήμη, Επεξεργαστής ULP, RTC Μνήμες και Περιφερειακά	Wi-Fi, Bluetooth, Ράδιο, Περιφερειακά	Καμία
Light Sleep	Επεξεργαστής ULP, RTC Μνήμες και Περιφερειακά	Wi-Fi, Bluetooth, Ράδιο, Περιφερειακά	Πυρήνας ESP32
Deep Sleep	Επεξεργαστής ULP, RTC Μνήμες και Περιφερειακά	Πυρήνας ESP32, Wi-Fi, Bluetooth, Ράδιο, Περιφερειακά	Καμία
Hibernation	RTC Μνήμες και Περιφερειακά	Πυρήνας ESP32, Επεξεργαστής ULP, Wi-Fi, Bluetooth, Ράδιο, Περιφερειακά	Καμία

Όσον αφορά την κατάσταση «light sleep», έχει παρόμοια λειτουργία με αυτή της «modem sleep» που παρουσιάστηκε παραπάνω, με τη διαφορά ότι σ' αυτή την περίπτωση τα περιφερειακά, το μεγαλύτερο μέρος της μνήμης RAM και της CPU είναι clock-gated. Με τη διαδικασία αυτή απενεργοποιούνται τμήματα του κυκλώματος, έτσι ώστε τα εσωτερικά flip-flops να μη χρειάζεται να αλλάζουν καταστάσεις, και άρα επιτυγχάνεται εξοικονόμηση ενέργειας. Στη συγκεκριμένη κατάσταση, η CPU βρίσκεται σε παύση, ενώ οι RTC μνήμες και τα περιφερειακά και ο ULP επεξεργαστής είναι ακόμα ενεργά, με αποτέλεσμα την ακόμα χαμηλότερη κατανάλωση ενέργειας, η οποία είναι περίπου στα 0.8mA. Τέλος, κατά την έξοδο από την κατάσταση «light sleep», τα περιφερειακά και οι επεξεργαστές συνεχίζουν τη λειτουργία τους και η εσωτερική κατάστασή τους διατηρείται.

Αντίθετα, στην κατάσταση «deep sleep», η CPU, το μεγαλύτερο μέρος της μνήμης RAM, καθώς και όλα τα ψηφιακά περιφερειακά, απενεργοποιούνται. Τα μόνα τμήματα της πλακέτας που μπορούν ακόμα να λειτουργήσουν είναι ο RTC controller, τα RTC περιφερειακά, συμπεριλαμβανομένου και του ULP επεξεργαστή, και οι RTC μνήμες. Στη συγκεκριμένη κατάσταση λειτουργίας, η πλακέτα καταναλώνει περίπου στα 0.15mA με 10μΑ, καθώς οι




εφαρμογές, πριν την είσοδο σε κατάσταση «deep sleep», θα πρέπει να απενεργοποιούν το Wi-Fi ή το Bluetooth χρησιμοποιώντας τις κλήσεις κατάλληλων συναρτήσεων. Επειδή, όμως, οι συγκεκριμένες συνδέσεις δε διατηρούνται σε καταστάσεις αναστολής, σε περίπτωση που η διατήρηση της σύνδεσης με το Wi-Fi είναι απαραίτητη, θα πρέπει να πραγματοποιηθούν οι κατάλληλες ρυθμίσεις στο μόντεμ για την ενεργοποίηση, πλέον, της «light sleep» κατάστασης.

Τέλος, και σε αντίθεση με την «deep sleep» κατάσταση, κατά τη διάρκεια του «hibernation», η πλακέτα απενεργοποιεί επιπλέον και τον ULP επεξεργαστή, αφήνοντας ενεργές μόνο τις RTC μνήμες και τα περιφερειακά που είναι υπεύθυνα για την επαγρύπνηση της πλακέτας. Η συγκεκριμένη λειτουργία μειώνει την κατανάλωση ενέργειας περισσότερο από κάθε άλλη κατάσταση που έχει αναφερθεί, με την πλακέτα να καταναλώνει μόνο περίπου 2.5μΑ.

## 4.2 Αισθητήρας Θερμοκρασίας-Υγρασίας

Αναφορικά με τον αισθητήρα θερμοκρασίας και υγρασίας του περιβάλλοντος επιλέχθηκε ο DHT22 [35], του οποίου το εύρος για τη θερμοκρασία κυμαίνεται από  $-40^{\circ}\text{C}$  έως  $+80^{\circ}\text{C}$ , ενώ το εύρος του ποσοστού υγρασίας κυμαίνεται από 0 έως και 100%. Η ανάλυση που προσφέρει όσον αφορά τις τιμές θερμοκρασίας είναι  $0.1^{\circ}\text{C}$  και όσον αφορά το ποσοστό υγρασίας 0.1%. Τέλος, λειτουργεί σε τάση επιπέδου 3V έως 6V συνεχούς ρεύματος, η κατανάλωση ρεύματος είναι στα 1mA με 1.5mA και η περίοδος δειγματοληψίας του στα 2 δευτερόλεπτα. Μια εικόνα του συγκεκριμένου αισθητήρα παρουσιάζεται στο Σχήμα 19 που ακολουθεί.


Πρόκειται για έναν αισθητήρα που προσφέρει πολλά οφέλη λόγω της αξιόπιστης ακρίβειας που παρέχει και του χαμηλού του κόστους. Έχει τη δυνατότητα να αποστέλλει πληροφορίες σε ψηφιακή μορφή μέσω μιας ασύγχρονης επικοινωνίας ενός καλωδίου που χρησιμοποιεί μόνο ένα σύρμα. Ο συγκεκριμένος αισθητήρας αποστέλλει 40bits δεδομένων οργανωμένα σε πέντε οκτάδες ( $5 \times 8 = 40\text{bits}$ ) [36]. Πιο συγκεκριμένα, τα πρώτα bits είναι οργανωμένα σε τέσσερις οκτάδες, για την αποστολή του ακεραίου και των δεκαδικών μερών των τιμών θερμοκρασίας και υγρασίας, και η πέμπτη οκτάδα αποτελεί ένα απλό άθροισμα ελέγχου, απαραίτητο για την ανίχνευση σφαλμάτων. Τέλος, η ενδεδειγμένη χρήση του αισθητήρα αυτού είναι για εσωτερικό περιβάλλον, επομένως είναι ιδιαίτερα σημαντικό να τοποθετηθεί σε σημείο προστατευμένο από άμεση έκθεση στον ήλιο ή τη βροχή.



Σχήμα 19. Αισθητήρας θερμοκρασίας-υγρασίας DHT22.

### 4.3 Αισθητήρας Υγρασίας Εδάφους

Ο αισθητήρας υγρασίας εδάφους αποτελείται από δύο ανιχνευτές (probes), όπως φαίνεται και στο Σχήμα 20, που μετρούν τον όγκο του νερού στο έδαφος. Οι δύο αυτοί ανιχνευτές επιτρέπουν στο ηλεκτρικό ρεύμα να διέρχεται μέσα στο έδαφος και, σύμφωνα με την αντίσταση του πρώτου, μετριέται το επίπεδο υγρασίας του εδάφους όπου τοποθετείται. Σε περίπτωση που υπάρχει περισσότερο νερό στο έδαφος, αυτό αποδίδει περισσότερη ηλεκτρική ενέργεια, με αποτέλεσμα η αντίσταση να είναι μικρότερη και, κατ' επέκταση, το επίπεδο υγρασίας να είναι υψηλότερο. Αντίθετα, το ξηρό έδαφος μειώνει την αγωγιμότητα. Επομένως, όταν υπάρχει λιγότερο νερό, το έδαφος αποδίδει λιγότερη ηλεκτρική ενέργεια, με αποτέλεσμα να έχει περισσότερη αντίσταση. Συνεπώς, το επίπεδο υγρασίας θα είναι χαμηλότερο.




Σχήμα 20. Αισθητήρας υγρασίας εδάφους.

Γενικά, η βασική αρχή λειτουργίας αυτού του τύπου των αισθητήρων είναι κοινή. Κάθε αισθητήρας αυτού του τύπου περιλαμβάνει τουλάχιστον 3 βασικά pins, GND, AO και VCC, όμως ο αισθητήρας που χρησιμοποιήθηκε για την υλοποίηση του προτεινόμενου συστήματος περιλαμβάνει και ένα τέταρτο, το DO, όπως αναγράφονται στο παραπάνω σχήμα. Πρακτικά, το pin AO αλλάζει ανάλογα με την ποσότητα υγρασίας στο έδαφος, δηλαδή όσο περισσότερο νερό υπάρχει σ' αυτό, τόσο αυξάνεται. Από την άλλη πλευρά, σε περίπτωση που η ποσότητα υγρασίας στο έδαφος είναι μικρότερη από την επιτρεπόμενη, η οποία μπορεί να αλλάξει από το ποτενσιόμετρο, το pin DO παίρνει την τιμή 1, διαφορετικά παραμένει στην τιμή 0.

Συνοψίζοντας, είναι ένας ιδιαίτερα αποδοτικός αισθητήρας, καθώς μπορεί να μετρήσει αλλαγές της τάξης του 0.1% και μικρότερες, χωρίς να επηρεάζεται από την ύπαρξη αλάτων ή λιπασμάτων στο έδαφος όπου τοποθετείται [37].

## 4.4 Αισθητήρας Φωτός

Ολοκληρώνοντας το κομμάτι της εργασίας που αφορά στον εξοπλισμό που χρησιμοποιήθηκε, ως αισθητήρας φωτός επιλέχθηκε ο GY-30 (BH1750FVI). Ο συγκεκριμένος αισθητήρας αποτελεί ένα ολοκληρωμένο κύκλωμα με δυνατότητα εντοπισμού ενός ευρέος φάσματος αλλαγών της έντασης του φωτός στο περιβάλλον με υψηλή ανάλυση, η οποία μπορεί να κυμαίνεται από 1lx έως και 65535lx. Όπως φαίνεται και στο Σχήμα 21, αποτελείται από 5 pins και συνδέεται με την πλακέτα ESP32 μέσω I2C διεπαφής. Πρόκειται για έναν αισθητήρα που μπορεί να εξάγει αποτελέσματα απευθείας από ένα ψηφιακό σήμα, χωρίς περίπλοκους υπολογισμούς, και να μετρήσει αντικείμενα απευθείας με φωτόμετρο [38].



Σχήμα 21. Αισθητήρας φωτός.

Αναλυτικότερα, πρόκειται για έναν αισθητήρα με ενσωματωμένο AD μετατροπέα των 16 bits, ο οποίος όπως προαναφέρθηκε συμβάλλει στην απευθείας εξαγωγή ψηφιακού σήματος, παρακάμπτοντας τη βαθμονόμηση. Πρόκειται για μια πιο ακριβή, αλλά ευκολότερη στη χρήση εναλλακτική της απλής φωτοαντίστασης, η οποία εξάγει μόνο μια τάση που πρέπει να υπολογιστεί για τη λήψη σημαντικών δεδομένων. Γενικά, η βασική αρχή λειτουργίας του συγκεκριμένου αισθητήρα έχει ως εξής: όταν αντικείμενα που φωτίζονται με ομοιογενή τρόπο λαμβάνουν μια φωτεινή ροή της τάξης του 1lx σε ένα τετραγωνικό μέτρο, τότε η ένταση της φωτεινότητάς του είναι 1lx.

Τέλος, αξίζει να σημειωθεί ότι ο συγκεκριμένος αισθητήρας διαθέτει έξι διαφορετικές καταστάσεις μέτρησης χωρισμένες βάσει δύο βασικών λειτουργιών: (α) συνεχής λειτουργία, όπου μετριέται συνεχώς η τιμή της φωτεινότητας, και (β) εφάπαξ λειτουργία, όπου ο αισθητήρας πραγματοποιεί μόνο μία μέτρηση και στη συνέχεια μεταβαίνει σε λειτουργία απενεργοποίησης. Όσον αφορά την τροφοδοσία του, μπορεί να συνδεθεί είτε στο 3.3V pin είτε στο 5V pin της πλακέτας ESP32.

# 5

## Λογισμικό και Πλατφόρμες Δεδομένων

### 5.1 Arduino IDE

Το λογισμικό που χρησιμοποιήθηκε για τον προγραμματισμό της πλακέτας ESP32, ώστε να εξάγονται οι μετρήσεις από το σύστημα σε πραγματικό χρόνο, είναι το Arduino IDE. Αναλυτικότερα, το ακρωνύμιο «IDE» σημαίνει «Ολοκληρωμένο Περιβάλλον Ανάπτυξης» και είναι το επίσημο λογισμικό που εισήγαγε το Arduino.cc, κυρίως για επεξεργασία, μεταγλώττιση και «κατέβασμα/αποστολή» του κώδικα στην πλακέτα ανάπτυξης και είναι διαθέσιμο σε μια αρκετά μεγάλη γκάμα λειτουργικών συστημάτων, όπως τα Windows, το macOS και τα Linux.

Πρόκειται για ένα ανοιχτό λογισμικό που χρησιμοποιείται για τον προγραμματισμό των μικροεπεξεργαστών αντίστοιχων πλακετών, όπως το Arduino Uno, το ESP32 κ.ά., έτσι ώστε αυτές να συνδέονται με τους αισθητήρες και να εκτελούν τις επιθυμητές κάθε φορά λειτουργίες που τους αναθέτονται με τη βοήθεια ανάλογων βιβλιοθηκών. Ο προγραμματισμός της εκάστοτε πλακέτας γίνεται σε γλώσσα προγραμματισμού C ή C++.

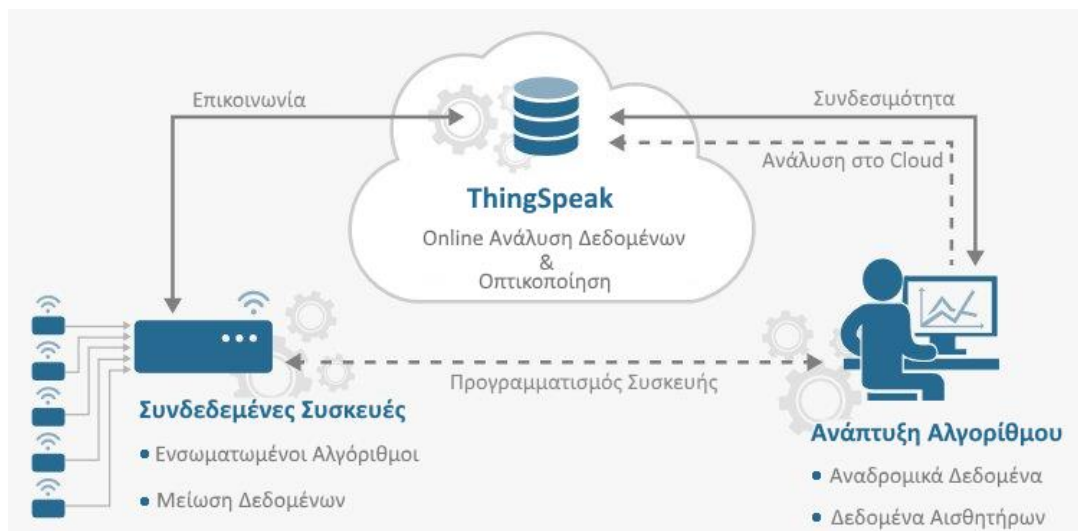
Πρακτικά, ο κώδικας που δημιουργείται στο λογισμικό δημιουργεί ένα δεκαεξαδικό αρχείο, το οποίο τελικά μεταφέρεται και μεταδίδεται στον επεξεργαστή της πλακέτας. Το συγκεκριμένο προγραμματιστικό περιβάλλον περιλαμβάνει δύο βασικά μέρη: (α) τον editor, που χρησιμοποιείται για τη δημιουργία του κώδικα, και (β) το μεταγλωττιστή (compiler), ο οποίος έχει ως ρόλο τη μεταγλώττιση και το «κατέβασμα» του κώδικα στην πλακέτα.

### 5.2 ThingSpeak

Πέρα από το λογισμικό του Arduino IDE, χρησιμοποιήθηκε και η πλατφόρμα ThingSpeak για τη γραφική απεικόνιση των μετρήσεων από το σύστημα, σε πραγματικό χρόνο [39], [40]. Αποτελεί μια πλατφόρμα του ΔτΠ που επιτρέπει στον εκάστοτε χρήστη να συλλέξει και να αποθηκεύσει δεδομένα από τους αισθητήρες για την ανάπτυξη εφαρμογών ΔτΠ, είτε μέσω του διαδικτύου χάρη στα πρωτόκολλα HTTP και MQTT, όπως αυτά αναλύθηκαν στην Παρ. 3.1.2, είτε μέσω ενός δικτύου ευρείας περιοχής. Ουσιαστικά, το ThingSpeak είναι μια πλατφόρμα ανοιχτού κώδικα και API για το ΔτΠ, το οποίο επιτρέπει τη δημιουργία καταγραφών των μετρήσεων από τον εκάστοτε

αισθητήρα ή αισθητήρες, καθώς επίσης και εφαρμογές εντοπισμού θέσης, αλλά και ένα κοινωνικό Δίκτυο των Πραγμάτων (Social Network of Things), με διαρκείς ενημερώσεις κατάστασης. Επιπλέον, διαθέτει ενσωματωμένη υποστήριξη του λογισμικού MATLAB, επιτρέποντας έτσι την ανάλυση και την οπτικοποίηση των δεδομένων.

Ενδεικτικά, το Σχήμα 22 παρουσιάζει τη ροή της μεταφοράς των δεδομένων ενός συστήματος ΔτΠ στο ThingSpeak. Ξεκινώντας από τα αριστερά του σχήματος, υπάρχουν οι «έξυπνες» συσκευές που ζουν στην άκρη του δικτύου και συλλέγουν δεδομένα. Στη μέση του σχήματος υπάρχει το Cloud, στη συγκεκριμένη περίπτωση το ThingSpeak, όπου συγκεντρώνονται δεδομένα από πολλές πηγές και, στη συνέχεια, αναλύονται σε πραγματικό χρόνο. Τέλος, η δεξιά πλευρά απεικονίζει την ανάπτυξη του αλγορίθμου που σχετίζεται με την εκάστοτε εφαρμογή του ΔτΠ. Η διαδικασία που ακολουθείται στη συγκεκριμένη φάση περιλαμβάνει την απόκτηση μιας γενικής εικόνας των συλλεγόμενων από τους αισθητήρες δεδομένων, πραγματοποιώντας ανάλυση αναδρομικών δεδομένων.



Σχήμα 22. Μεταφορά δεδομένων στο ThingSpeak.

Κάθε σύστημα ΔτΠ περιλαμβάνει αυτά τα επιμέρους στοιχεία. Όπως προαναφέρθηκε, το ThingSpeak αποτελεί το Cloud όπου συλλέγονται και αναλύονται τα δεδομένα από αισθητήρες συνδεδεμένους στο Διαδίκτυο. Πιο συγκεκριμένα, για τη συλλογή των δεδομένων ο εκάστοτε χρήστης θα πρέπει να δημιουργήσει ένα δικό του δημόσιο ή ιδιωτικό κανάλι, το οποίο θα έχει το δικό του αναγνωριστικό (channel ID), όνομα (channel name), API key και περιγραφή και θα περιλαμβάνει τα γραφήματα με τις επιθυμητές μετρήσεις. Παράλληλα, η πλατφόρμα αυτή επιτρέπει τη συλλογή, την αποθήκευση, αλλά και το σχεδιασμό γραφημάτων στα κανάλια της. Οι γραφικές απεικονίσεις αυτών των αποτελεσμάτων, στη συνέχεια, θα αρχίσουν να δημιουργούνται σε πραγματικό χρόνο, από τη στιγμή που ο χρήστης θα έχει θέσει σε λειτουργία το σύστημά του. Σε ακόλουθη παράγραφο θα παρουσιαστεί το κανάλι που δημιουργήθηκε για την αναπαράσταση των μετρήσεων στα πλαίσια της παρούσας διπλωματικής εργασίας.

### 5.3 *OpenWeatherMap*

Το OpenWeatherMap είναι μια διαδικτυακή υπηρεσία που παρέχει δεδομένα καιρού, συμπεριλαμβανομένων τρεχόντων δεδομένων, προβλέψεων, καθώς επίσης και δεδομένων από το ιστορικό [41]. Ως πηγή δεδομένων χρησιμοποιεί μετεωρολογικές υπηρεσίες μετάδοσης, ανεπεξέργαστα δεδομένα από μετεωρολογικούς σταθμούς αεροδρομίων, πρωτογενή δεδομένα από ραντάρ καιρού, αλλά και δεδομένα από άλλους επίσημους μετεωρολογικούς σταθμούς. Η επεξεργασία των δεδομένων γίνεται με τέτοιο τρόπο, ώστε να παρέχονται ακριβή δεδομένα πρόγνωσης και χαρτών καιρού, όπως για παράδειγμα σε περιπτώσεις συννεφιάς ή υετού.

Πέρα από την παροχή των δεδομένων, ωστόσο, η συγκεκριμένη διαδικτυακή υπηρεσία περιλαμβάνει, επίσης, και τη συμμετοχή των ιδιοκτητών των μετεωρολογικών σταθμών κατά τη διαδικασία της σύνδεσης με την υπηρεσία, με αποτέλεσμα να αυξάνεται και η ακρίβεια των παρεχόμενων δεδομένων καιρού. Η ιδεολογία της υπηρεσίας εμπνέεται από το OpenStreetMap, το οποίο και χρησιμοποιεί για την εμφάνιση των χαρτών καιρού.

Τα δεδομένα που παρέχονται από το API του OpenWeatherMap είναι σε μορφή JSON, XML και HTML. Οι χρήστες της υπηρεσίας μπορούν να αιτηθούν πληροφορίες σχετικά με τα τρέχοντα καιρικά δεδομένα, εκτεταμένες προβλέψεις, αλλά και γραφικούς χάρτες, που παρουσιάζουν την κάλυψη από σύννεφα, την ταχύτητα του ανέμου και τη βροχόπτωση. Παρόλα αυτά, με εξαίρεση τα δεδομένα πραγματικού χρόνου, οι λοιπές προσφερόμενες υπηρεσίες έχουν περιορισμένο επίπεδο δωρεάν χρήσης. Αναλυτικότερα, τόσο η πραγματοποίηση περισσότερων των 60 κλήσεων ανά λεπτό, όσο και η πρόσβαση σε δεδομένα που έχουν κρατηθεί στο ιστορικό, απαιτούν συνδρομή επί πληρωμή ανά μήνα.

### 5.4 *Keras*

Το Keras είναι μια βιβλιοθήκη ΤΝΔ ανοιχτού κώδικα, γραμμένη σε γλώσσα προγραμματισμού Python, και αποτελεί ένα από τα κορυφαία API νευρωνικών δικτύων υψηλού επιπέδου [38]. Υποστηρίζει πολλαπλές back-end υπολογιστικές μηχανές ΤΝΔ, όπως TensorFlow, Microsoft Cognitive Toolkit, R, Theano ή PlaidML και είναι ειδικά σχεδιασμένο ώστε να παρέχει ευκολία στη μάθηση και το σχεδιασμό μοντέλων ΤΝΔ, όντας παράλληλα ιδιαίτερα φιλικό προς το χρήστη.

Ο βασικός σκοπός για τον οποίο σχεδιάστηκε είναι ώστε να αποτελεί μια διεπαφή και όχι ένα αυτόνομο πλαίσιο μηχανικής μάθησης. Αναλυτικότερα, ο ρόλος του είναι να προσφέρει ένα υψηλότερου επιπέδου, αλλά και πιο διαισθητικό σύνολο αφαιρέσεων (set of abstractions), το οποίο διευκολύνει την ανάπτυξη μοντέλων βαθιάς μάθησης, ανεξάρτητα από το υπολογιστικό back-end που χρησιμοποιείται.

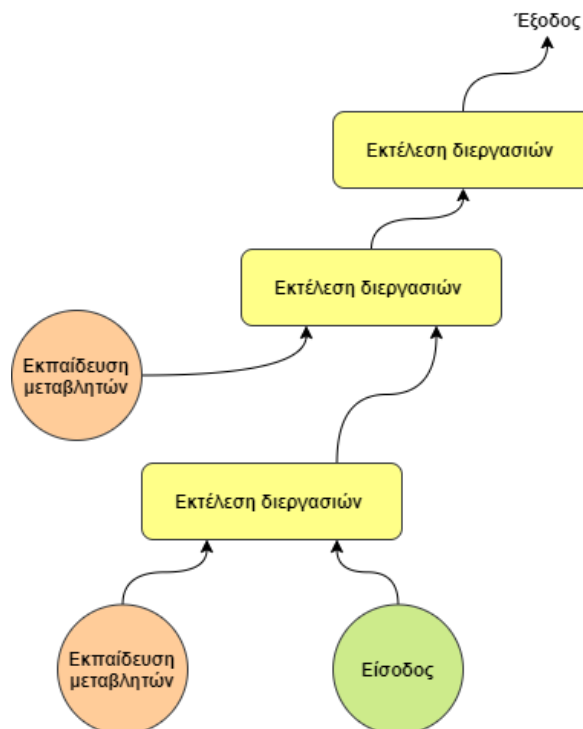
Όσον αφορά τα χαρακτηριστικά του, αρχικά, το Keras περιλαμβάνει ποικίλες εφαρμογές από συχνά χρησιμοποιούμενες δομικές μονάδες ΤΝΔ, όπως είναι τα επίπεδα του ΤΝΔ, οι συναρτήσεις ενεργοποίησης, οι optimizers, καθώς και πολλά άλλα εργαλεία που διευκολύνουν εργασίες επεξεργασίας εικόνας και κειμένου, με στόχο την απλοποίηση της απαραίτητης κωδικοποίησης για τη σύνταξη κώδικα ενός ΤΝΔ. Επιπλέον, διαθέτει υποστήριξη και συνελκτικών και αναδρομικών ΤΝΔ, πέρα των τυπικών δικτύων, με υποστήριξη επιπρόσθετων επιπέδων χρησιμότητας, όπως ο περιορισμός ενεργοποίησης (dropout), οι τεχνικές κανονικοποίησης (batch normalization) και η

συγκέντρωση (pooling). Τέλος, το Keras επιτρέπει στους χρήστες την παραγωγή μοντέλων βαθιάς μάθησης είτε σε smartphones, είτε στον Ιστό, είτε σε Java Virtual Machine, καθώς και τη χρήση κατακευμασμένης εκπαίδευσης (distributed learning) μοντέλων βαθιάς μάθησης σε συστάδες Μονάδων Επεξεργασίας Γραφικών (GPU) και Μονάδων Επεξεργασίας Τανυστών (TPU), κυρίως σε συνδυασμό με το CUDA.

## 5.5 TensorFlow

Τέλος, το TensorFlow [42] είναι μια βιβλιοθήκη μηχανικής μάθησης ανοιχτού κώδικα, γραμμένη σε γλώσσα προγραμματισμού Python, που χρησιμοποιεί συμβολικά μαθηματικά και διαφορικό προγραμματισμό (differentiable programming), για τη βελτιστοποίηση των παραμέτρων. Τα βασικά πλεονεκτήματα που μπορεί να αποφέρει η επιλογή του είναι δύο: (α) αύξηση της λειτουργικότητας, καθώς το TensorFlow είναι πιο προηγμένο από το Keras σε λειτουργίες υψηλού επιπέδου (high-level operations), και (β) αύξηση του ελέγχου, ανάλογα με τις απαιτήσεις του εκάστοτε ΤΝΔ.

Τα τελευταία χρόνια, η TensorFlow ανακοίνωσε ότι το Keras ενσωματώνεται πλέον στη συγκεκριμένη βιβλιοθήκη, επιτρέποντας έτσι την εναπόθεση του ακατέργαστου TensorFlow κώδικα απευθείας στο Keras μοντέλο [43]. Η ενσωμάτωση αυτή, επομένως, προσφέρει μεγαλύτερη ευκολία στη δημιουργία και την εκπαίδευση ενός μοντέλου ΤΝΔ, καθώς γίνεται χρήση του API που παρέχεται από το Keras, το οποίο είναι εξαιρετικά εύκολο στη χρήση, για τη δημιουργία του μοντέλου. Επιπλέον, σε περίπτωση που απαιτείται για παράδειγμα εφαρμογή ενός προσαρμοσμένου επιπέδου στο μοντέλο ή μια πιο περίπλοκη συνάρτηση απωλειών, πραγματοποιείται αυτόματη ενσωμάτωση στο TensorFlow του κώδικα με το μοντέλο Keras.



Σχήμα 23. Γραφική αναπαράσταση λειτουργίας του TensorFlow.

# 6

## *Προκλήσεις και Περιορισμοί Συστήματος*

Η δημιουργία και η κατασκευή ενός συστήματος πρόβλεψης είναι μια ιδιαίτερα απαιτητική διαδικασία που περιλαμβάνει αρκετές προκλήσεις κατά το σχεδιασμό. Ενδεικτικά, κάποια από τα βασικά ζητήματα που μπορεί να προκύψουν κατά το σχεδιασμό αντίστοιχων συστημάτων με αισθητήρες παρακολούθησης αφορούν αφενός στη σχέση μεταξύ των παραμέτρων του περιβάλλοντος και των δεδομένων των αισθητήρων, και αφετέρου σε ακόμα πρακτικότερα ζητήματα, όπως η ενεργειακή κατανάλωση του ίδιου του συστήματος, αλλά και τυχόν θέματα ασφαλείας. Ανάλογες προκλήσεις προκύπτουν και κατά την επιλογή του κατάλληλου ΤΝΔ που θα χρησιμοποιηθεί.

Πιο συγκεκριμένα, η κατανόηση της σχέσης μεταξύ περιβαλλοντικών παραμέτρων και δεδομένων αισθητήρων έρχεται αντιμέτωπη με τρεις βασικές προκλήσεις [44]. Πρώτον, είναι η έλλειψη παρακολούθησης σε πραγματικό χρόνο των περιβαλλοντικών δεδομένων και μετρήσεων. Η παρατήρηση των συνθηκών του περιβάλλοντος σε πραγματικό χρόνο, υπό διαφορετικές συνθήκες και σε υψηλότερες χωρικές και χρονικές αναλύσεις [45], αποτελεί απαραίτητη προϋπόθεση για λεπτομερή ανάλυση. Σε πολλές εφαρμογές ΔτΠ αναπτύσσεται είτε ένας μικρός αριθμός αισθητήρων υψηλής ακρίβειας σε χαμηλή χωρική ανάλυση (spatial resolution), είτε ένας μεγάλος αριθμός μη δαπανηρών αισθητήρων χαμηλής ακρίβειας σε υψηλή χωρική ανάλυση, για τη μείωση του συνολικού κόστους ανάπτυξης. Λόγω μη διαθεσιμότητας των δεδομένων σε τοποθεσίες όπου δεν αναπτύσσονται αισθητήρες, ή λόγω σφαλμάτων και αβεβαιότητας που μπορεί να προκύψουν σε αισθητήρες χαμηλής ακρίβειας, η λήψη αξιόπιστων και λεπτομερών μετρήσεων από την εκάστοτε περιοχή παρακολούθησης σε πραγματικό χρόνο είναι δύσκολη. Η δεύτερη πρόκληση περιλαμβάνει τον εντοπισμό των ασυνήθιστων γεγονότων ως πρότυπα από περιβαλλοντικά δεδομένα. Μια ευρεία ποικιλία επιπτώσεων και αλληλεπιδράσεων είναι εφικτή σε χωροχρονικό τομέα μέσα σ' ένα αστικό περιβάλλον. Τέλος, η τρίτη πρόκληση είναι ο συνδυασμός πολλαπλών αισθητήρων και πολυπαραγοντικής απεικόνισης για τη μετάδοση των δεδομένων σε πραγματικό χρόνο, συμπεριλαμβανομένης της γεωγραφικής τοποθεσίας και των δεδομένων των αισθητήρων που μεταβάλλονται με την πάροδο του χρόνου. Δεδομένου ότι συλλέγονται όλο και περισσότερα δεδομένα, η ανάλυση μπορεί να γίνει πολύπλοκη και επίπονη, όπως τα ευρήματα των προτύπων και η λήψη αποφάσεων βάσει των εκάστοτε δεδομένων.



Παράλληλα, η επιλογή του κατάλληλου προτύπου (standard) για την ασύρματη επικοινωνία των αισθητήρων παίζει πολύ σημαντικό ρόλο στην υλοποίηση του προτεινόμενου συστήματος, αλλά και γενικότερα κάθε συστήματος, λόγω της άμεσης συσχέτισής του με ζητήματα ενεργειακής κατανάλωσης.

Αναλυτικότερα, μελέτες πάνω στο συγκεκριμένο θέμα παρατήρησαν πως σε σύγκριση με το IEEE 802.15.4, με μέγιστη ταχύτητα δεδομένων στα 250kbps, το IEEE 802.11b/g λειτουργεί σε πολύ υψηλότερες ταχύτητες δεδομένων, οι οποίες κυμαίνονται από 1Mbps έως 54Mbps [46]. Το γεγονός αυτό επιτρέπει στους ασύρματους αισθητήρες να ξοδεύουν πολύ λιγότερο χρόνο κατά τη μετάδοση ή τη λήψη των δεδομένων. Λειτουργώντας με υψηλότερους ρυθμούς δεδομένων, περιορίζεται επίσης και η κατανάλωση ενέργειας, καθώς όσο υψηλότερος είναι ο ρυθμός μετάδοσης των δεδομένων, τόσο μειώνεται η απαιτούμενη ενέργεια για τη λήψη και την εκπομπή ενός bit. Ως εκ τούτου, ο αντίκτυπος της ενέργειας εκπομπής και λήψης στη διάρκεια ζωής της μπαταρίας καθίσταται δευτερεύων παράγοντας, εκτός εάν ο εκάστοτε ασύρματος αισθητήρας αποστέλλει ή λαμβάνει μεγάλο όγκο δεδομένων.

Τέλος, το γεγονός ότι οι ασύρματοι αισθητήρες χειρίζονται ευαίσθητα δεδομένα και πληροφορίες σε διάφορους τομείς μιας εφαρμογής καθιστά ιδιαίτερα σημαντική την απαίτηση για αποτελεσματικούς μηχανισμούς ασφαλείας. Λόγω των περιορισμών μνήμης και υπολογισμών ενός δικτύου αισθητήρων, η ασφάλεια μπορεί να δημιουργήσει διάφορες προκλήσεις. Το πρότυπο 802.11 παρέχει αρκετά τυπικά συστήματα ασφαλείας που διευκολύνουν την εμπιστευτικότητα, την επαλήθευση και τη διαθεσιμότητα των δεδομένων.

Μελέτες που επικεντρώθηκαν στην επίδραση των συνηθισμένων συστημάτων ασφαλείας Wi-Fi στην κατανάλωση ενέργειας [46], όπως τα WEP, WPA/TKIPPSK και WPA2/AES-PSK, συμπέραναν την ύπαρξη συρρίκνωσης μεταξύ της ισχύος του μηχανισμού ασφαλείας και της κατανάλωσης ενέργειας. Το ευπαθές WEP εισάγει μια αμελητέα επαλήθευση ταυτότητας και κρυπτογράφηση. Από την άλλη πλευρά, τόσο το WPA, όσο και το WPA2, απαιτούν σημαντικό χρόνο για την επαλήθευση, καθώς και ενεργειακή κατανάλωση, λόγω αρκετών ανταλλαγών μηνυμάτων κατά τη διαδικασία της «χειραγίας (handshake)». Συνεπώς, μετά από κάθε αφύπνιση θα πρέπει να αποφεύγεται η επανασύνδεση και η επανειλημμένη επαλήθευση, ώστε να επιτυγχάνεται καλύτερη καθυστέρηση μεταφοράς (latency), αλλά και βέλτιστη απόδοση της ζωής της μπαταρίας που χρησιμοποιείται. Αντίθετα, η κρυπτογράφηση έχει μικρή επίδραση στην κατανάλωση ενέργειας, η οποία θα μπορούσε να αποδοθεί στη μηχανή κρυπτογράφησης του υλικού, στην ίδια τη μονάδα του Wi-Fi. Αντίστοιχες μετρήσεις έδειξαν ότι το WPA2/AES-PSK προσφέρει το καλύτερο ισοζύγιο μεταξύ ασφάλειας και απόδοσης για τους ασύρματους αισθητήρες που χρησιμοποιούν Wi-Fi [47].

Ολοκληρώνοντας, τελική πρόκληση της συγκεκριμένης εργασίας αποτελεί η επιλογή του κατάλληλου μοντέλου πρόβλεψης, η οποία είναι αρκετά δύσκολη λόγω του μεγάλου αριθμού των παραγόντων που σχετίζονται με την επιλογή του μοντέλου. Παρόλο που στη βιβλιογραφία προτείνονται αρκετοί κανόνες επιλογής, κανένας από αυτούς δεν μπορεί να εφαρμοστεί καθολικά καθώς κάθε περίπτωση εφαρμογής ποικίλλει.

Ένα από τα σημαντικότερα προβλήματα αποτελεί ο τρόπος ανάπτυξης ενός δικτύου με κατάλληλο μέγεθος για την καταγραφή υποκείμενων προτύπων στα δεδομένα εκπαίδευσης. Το σημαντικότερο χαρακτηριστικό ενός μοντέλου ΤΝΔ, ώστε αυτό να μπορεί να καταστεί χρήσιμο,

είναι η δυνατότητα γενίκευσης ή πρόβλεψης που διαθέτει. Κατά κανόνα, το μέγεθος ενός ΤΝΔ εξαρτάται σε μεγάλο βαθμό από τον αριθμό των κόμβων εισόδου και τον αριθμό των κρυφών κόμβων. Μελέτες [48] έδειξαν πως ο αριθμός των κόμβων εισόδου αποτελεί τη σημαντικότερη παράμετρο σε σχέση με τον καθορισμό των κρυφών κόμβων, καθώς κάθε κόμβος εισόδου αντιστοιχεί στον αριθμό των παρατηρήσεων που χρησιμοποιήθηκαν για την ανακάλυψη των υποκείμενων μοτίβων σε μια χρονοσειρά. Προφανώς, τόσο ο πολύ μεγάλος, όσο και ο πολύ μικρός αριθμός κόμβων εισόδου μπορεί να έχει σημαντικό αντίκτυπο στην εκπαίδευση και την πρόβλεψη του δικτύου.

Από την άλλη πλευρά, οι κρυφοί κόμβοι του δικτύου χρησιμοποιούνται για την καταγραφή των μη γραμμικών δομών σε μια χρονοσειρά, με αποτέλεσμα ο προσδιορισμός τους να αποτελεί ένα επιπλέον ζήτημα στη διαδικασία κατασκευής του σωστού μοντέλου ΤΝΔ. Γενικά, η θεωρία των ΤΝΔ υποδηλώνει πως μεγαλύτερος αριθμός κρυφών κόμβων οδηγεί, συνήθως, σε καλύτερη ακρίβεια. Ωστόσο, πολύ μεγάλος αριθμός μπορεί να οδηγήσει στο πρόβλημα της υπερ-προσαρμογής (overfitting), με αποτέλεσμα το δίκτυο να μαθαίνει πολύ καλά τα δεδομένα εκπαίδευσης, αλλά να αδυνατεί να γενικεύσει ή να προβλέψει τιμές εκτός του δείγματος. Για το λόγο αυτό, στην πράξη η επιλογή του αριθμού των κρυφών κόμβων του δικτύου πραγματοποιείται μέσω πειραματισμού.

Τέλος, ένα άλλο επίσης άρρηκτα συνδεδεμένο ζήτημα με την κατασκευή ενός ορθού μοντέλου ΤΝΔ είναι η επιλογή του κατάλληλου όγκου των δεδομένων εκπαίδευσης και ελέγχου, αλλά και ο σωστός διαχωρισμός τους. Από την ήδη υπάρχουσα βιβλιογραφία, συνηθίζεται η επιλογή ενός μεγάλου δείγματος για την εκπαίδευση του μοντέλου και ενός μικρότερου δείγματος για τον έλεγχο της απόδοσής του. Γενικά, όμως, η λαθεμένη επιλογή των δεδομένων εκπαίδευσης και ελέγχου μπορεί να επηρεάσει σε μεγάλο βαθμό την απόδοση του μοντέλου πρόβλεψης τόσο εντός όσο και εκτός του συνόλου των δειγμάτων.

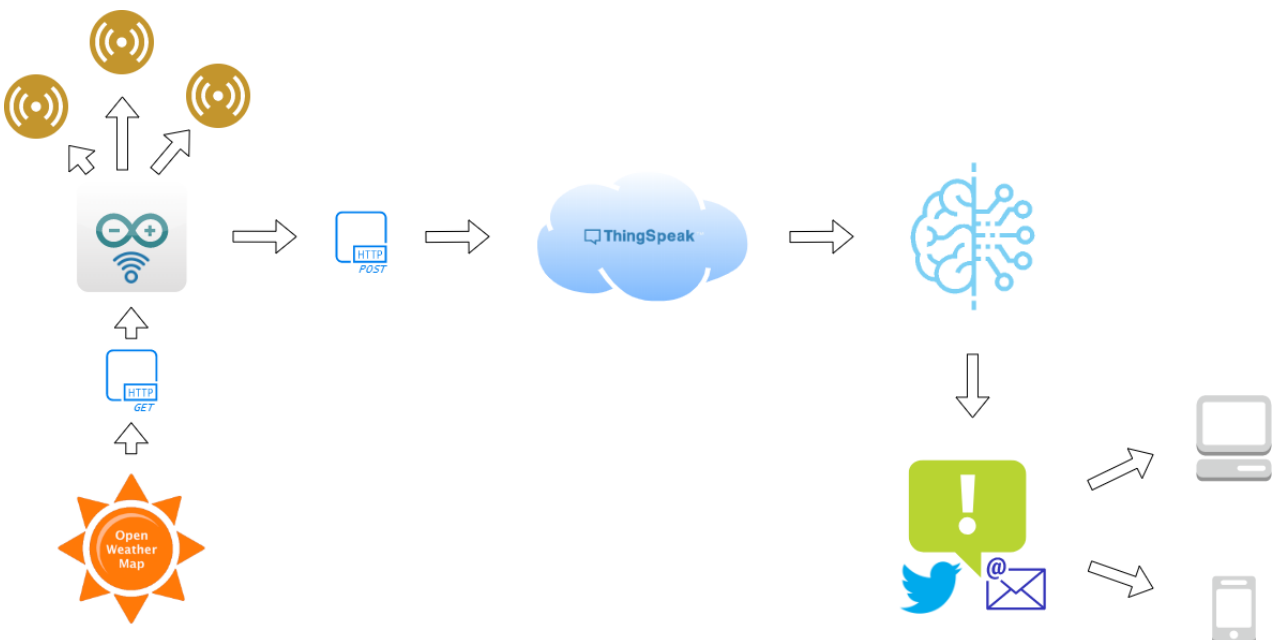
Συνοψίζοντας λοιπόν, προκειμένου να επιτευχθεί καλή γενίκευση του μοντέλου, ένα ΤΝΔ πρέπει αφενός να έχει αρκετά δεδομένα εκπαίδευσης για να μάθει, αλλά αφετέρου να είναι και σε θέση να μαθαίνει αρκετά γρήγορα, ώστε να προσαρμόζεται στις μεταβαλλόμενες συνθήκες. Συνεπώς, είναι απαραίτητη η επιλογή αντιπροσωπευτικών δεδομένων εκπαίδευσης σε σχέση με τις συνθήκες όπου πρόκειται να εφαρμοστεί το μοντέλο πρόβλεψης, ενώ παράλληλα, το ίδιο το μοντέλο δε θα πρέπει να είναι υπερ-προσαρμοσμένο (overfit) ώστε να μη μεροληπτεί (unbiased) υπέρ ενός συγκεκριμένου αποτελέσματος.

# 7

## Υλοποίηση

### 7.1 Περιγραφή Συστήματος

Η προτεινόμενη υλοποίηση αφορά στην κατασκευή ενός έξυπνου συστήματος πρόβλεψης πυρκαγιάς, το οποίο λαμβάνει πληροφορίες από το περιβάλλον, όπως θερμοκρασία, υγρασία, ατμοσφαιρική πίεση κ.λπ., σε πραγματικό χρόνο και βάσει αυτών προβλέπει τις τιμές της θερμοκρασίας, της υγρασίας του περιβάλλοντος και της ταχύτητας του ανέμου για τις επόμενες 12 ώρες. Τέλος, και με βάση την πρόβλεψη, ακολουθεί μαθηματική μοντελοποίηση των αποτελεσμάτων για την εξαγωγή του βαθμού επικινδυνότητας εμφάνισης πυρκαγιάς στη συγκεκριμένη περιοχή ενδιαφέροντος.



Σχήμα 24. Διάγραμμα λειτουργίας του συστήματος.

Μια περιγραφική εικόνα της λειτουργίας του έργου παρουσιάζεται στο Σχήμα 24. Ξεκινώντας από το υλικό, χρησιμοποιείται η πλακέτα ESP32, η οποία με κατάλληλη συνδεσμολογία με τους απαιτούμενους αισθητήρες (Παρ. 4) και την υπηρεσία του OpenWeatherMap λαμβάνει δεδομένα καιρού. Καθώς η συγκεκριμένη πλακέτα υποστηρίζει την ασύρματη σύνδεση με το δρομολογητή και το διαδίκτυο, οι λαμβανόμενες μετρήσεις αποστέλλονται μέσω Wi-Fi στο Cloud και συγκεκριμένα, στην πλατφόρμα ανάλυσης των δεδομένων ThingSpeak.

Με την ενεργοποίηση της πλακέτας ESP32, γίνεται μια αρχική ρύθμιση (setup) των διαφόρων παραμέτρων του συστήματος, όπως η αρχικοποίηση των αισθητήρων και η ασύρματη σύνδεση στο δρομολογητή. Στη συνέχεια, λαμβάνονται από το σύστημα τα απαραίτητα δεδομένα που θα χρησιμοποιηθούν από το μοντέλο για την πρόβλεψη, τα οποία προέρχονται αφενός από μετρήσεις των αισθητήρων του συστήματος, και αφετέρου από την υπηρεσία OpenWeatherMap. Στη συνέχεια, τα δεδομένα αυτά καταγράφονται στο Cloud και, τέλος, το μοντέλο λαμβάνει τα δεδομένα από τη βάση του ThingSpeak ως δεδομένα εκπαίδευσης.

Αναλυτικότερα, αρχικά, το σύστημα λαμβάνει συνεχώς δεδομένα από τους αισθητήρες και την υπηρεσία του OpenWeatherMap κάθε τρεις ώρες. Το συγκεκριμένο χρονικό όριο τέθηκε λόγω του OpenWeatherMap, το οποίο ενημερώνει τα δεδομένα καιρού ανά χρονικά διαστήματα των τριών ωρών. Λόγω της λήψης μετρήσεων σε σχετικά μεγάλα χρονικά διαστήματα, μπορεί να επιτευχθεί εξοικονόμηση ενέργειας από το σύστημα, το οποίο θα ενεργοποιείται μόνο όταν είναι να λάβει τις μετρήσεις και, ακολούθως, θα μεταβαίνει σε λειτουργία «deep sleep».

Η προσθήκη της συγκεκριμένης υπηρεσίας στη διαδικασία λήψης των δεδομένων καιρού έγινε για τη δημιουργία ενός πιο ολοκληρωμένου συνόλου δεδομένων εκπαίδευσης για το μοντέλο ΤΝΔ. Όπως προαναφέρθηκε, οι αισθητήρες του συστήματος είναι περιορισμένοι, οπότε επιπλέον απαραίτητες πληροφορίες για την πρόβλεψη, όπως ατμοσφαιρική πίεση, περιγραφή του καιρού, ταχύτητα ανέμου κ.λπ., λαμβάνονται μέσω της υπηρεσίας OpenWeatherMap με το πρωτόκολλο HTTP και το αίτημα GET. Πιο συγκεκριμένα, το ανοιχτό API του OpenWeatherMap προσφέρει αρκετά χρήσιμα πεδία σε μορφή JSON, ενδεικτικά τα «weather\_description», «pressure», «wind\_speed», «wind\_direction» κ.λπ. Ωστόσο, επειδή θα λαμβάνονται από το σύστημα διπλές τιμές, όπως η θερμοκρασία και η υγρασία, οι οποίες παρέχονται τόσο από τις μετρήσεις των αισθητήρων όσο και από το OpenWeatherMap, γίνεται διαχωρισμός (parsing) των JSON δεδομένων, ώστε κάθε φορά να κρατούνται μόνο οι απαραίτητες τιμές.

Τέλος, τα δεδομένα αυτά αποστέλλονται στο Cloud μέσω του API που παρέχεται από το ThingSpeak. Συγκεκριμένα, γίνεται χρήση του πρωτοκόλλου HTTP με το αίτημα POST και διαχωρίζονται οι μετρήσεις που λαμβάνονται σε διαφορετικά πεδία (fields). Η καταγραφή των δεδομένων πραγματοποιείται στην πλατφόρμα ThingSpeak, η οποία προσφέρει και διαρκείς ενημερώσεις κατάστασης. Οι μετρήσεις είναι ορατές σαν γραφήματα, στο χρήστη με το συγκεκριμένο κλειδί API, αλλά μπορούν να μετατραπούν σε δημόσιες (Public), ώστε να είναι ορατές από όλους τους χρήστες.

Μετά τη συλλογή των δεδομένων, λοιπόν, ακολουθεί η πρόβλεψη από το μοντέλο τριών τιμών που επηρεάζουν περισσότερο την εμφάνιση πυρκαγιάς σε μια περιοχή: (i) θερμοκρασία περιβάλλοντος, (ii) υγρασία περιβάλλοντος και (iii) ταχύτητα ανέμου για τις επόμενες 12 ώρες. Αναλυτικότερες πληροφορίες αναφορικά με την εκπαίδευση του ΤΝΔ παρουσιάζονται παρακάτω, στην Παρ. 7.5. Τελικό στάδιο της εργασίας αποτελεί η μαθηματική μοντελοποίηση των δεδομένων

πρόβλεψης του TNΔ, για την εξαγωγή του βαθμού επικινδυνότητας εμφάνισης πυρκαγιάς, και η αποστολή αντίστοιχης ειδοποίησης στο χρήστη μέσω της εφαρμογής του Twitter. Για παράδειγμα, σε περίπτωση που προβλεφθεί από το μοντέλο υψηλή τιμή θερμοκρασίας, σε συνδυασμό με χαμηλά ποσοστά υγρασίας και ισχυρούς ανέμους, το σύστημα θα ειδοποιεί το χρήστη, με κατάλληλο κάθε φορά μήνυμα, ότι υπάρχει υψηλή πιθανότητα πρόκλησης πυρκαγιάς στη συγκεκριμένη περιοχή/χώρο τις επόμενες ώρες.

## 7.2 Εφαρμογή

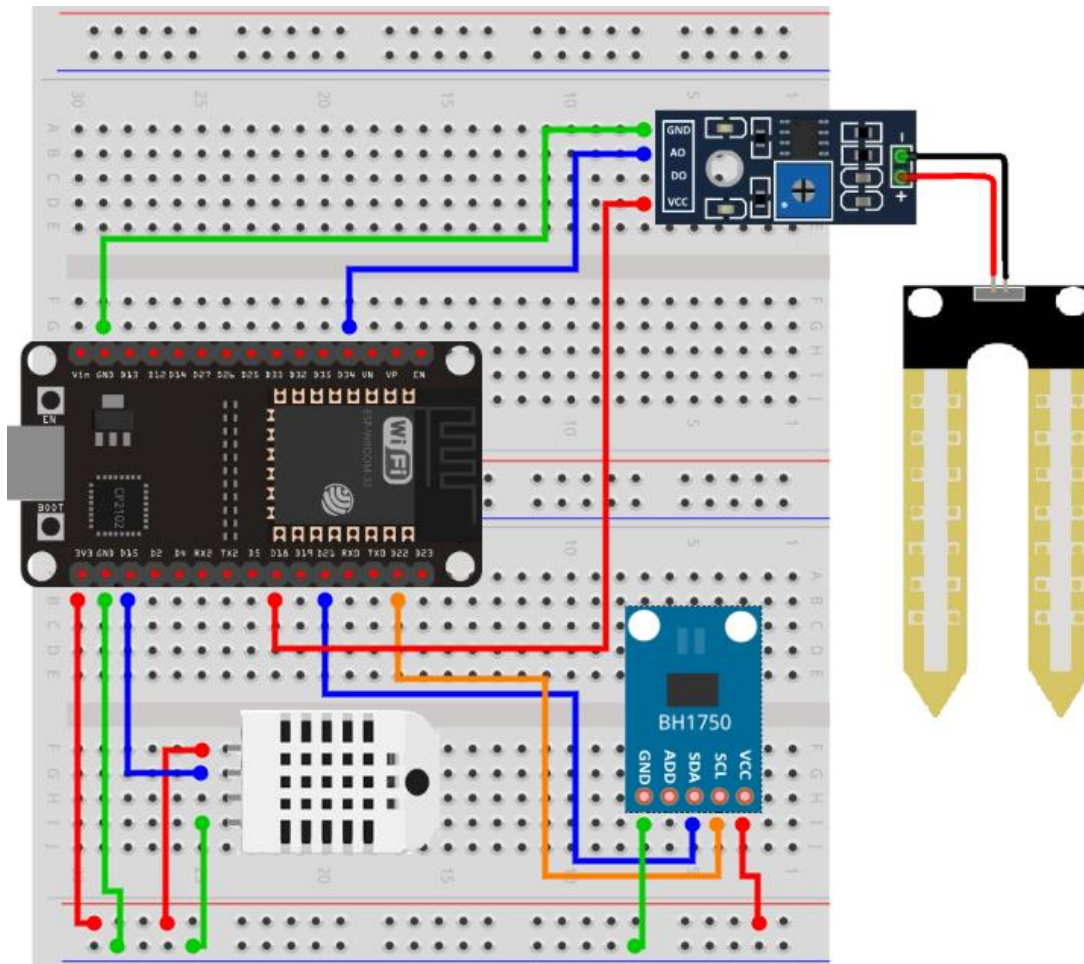
Όπως έχει αναφερθεί ήδη από την Παρ. 4, το υλικό που χρησιμοποιήθηκε για τη λήψη των μετρήσεων αποτελείται από την πλακέτα ESP32, έναν αισθητήρα θερμοκρασίας-υγρασίας του περιβάλλοντος (DHT22), έναν αισθητήρα υγρασίας εδάφους (YL-69) και έναν αισθητήρα μέτρησης της φωτεινότητας του περιβάλλοντος (BH1750). Στο ακόλουθο Σχήμα 25 παρουσιάζεται η συνδεσμολογία της πλακέτας με τους αισθητήρες, όπως αυτή πραγματοποιήθηκε για τη δημιουργία του συστήματος πρόβλεψης. Με κόκκινο υποδεικνύονται οι συνδέσεις που σχετίζονται με την τροφοδοσία του κάθε στοιχείου, ενώ με πράσινο οι γειώσεις τους. Τέλος, η σύνδεση των στοιχείων με την πλακέτα έγινε μέσω breadboard, οπότε χρησιμοποιήθηκαν αρσενικά jumper wires, ενώ για την παροχή ενέργειας και τον προγραμματισμό της πλακέτας χρησιμοποιήθηκε ένα micro USB καλώδιο.

Πιο συγκεκριμένα, ο αισθητήρας DHT22 έχει τέσσερα pins, όπως φαίνεται αναλυτικά στο Σχήμα 19, εκ των οποίων για το σύστημα χρειάζεται να συνδεθούν μόνο τα τρία. Το pin της τροφοδοσίας συνδέεται με το pin 3V3 της πλακέτας, ενώ το pin που σχετίζεται με τη μετάδοση των δεδομένων συνδέεται στο pin D15 της πλακέτας.

Αντίστοιχα, το pin της τροφοδοσίας του ποτενσιόμετρου για τον αισθητήρα μέτρησης της υγρασίας του εδάφους συνδέεται με το pin D18 της πλακέτας, έτσι ώστε ο συγκεκριμένος αισθητήρας να μην παραμένει ενεργός συνέχεια, καθώς είναι αρκετά ευαίσθητος. Επειδή, λοιπόν, οι μετρήσεις που θα καταγράφονται κάθε φορά στη βάση του ThingSpeak θα είναι ανά διαστήματα των τριών ωρών, ο αισθητήρας χρειάζεται να ενεργοποιείται μόνο λίγα δευτερόλεπτα πριν ληφθούν οι μετρήσεις και μετά θα απενεργοποιείται πάλι. Όσον αφορά τη μετάδοση των δεδομένων στην πλακέτα, για το σκοπό αυτό χρησιμοποιήθηκε το pin A0 που συνδέθηκε με το pin D34 της πλακέτας. Ο λόγος που επιλέγεται το συγκεκριμένο pin του αισθητήρα και όχι το DO είναι διότι βασικός στόχος είναι η παρακολούθηση των τιμών της υγρασίας του εδάφους.

Προκειμένου, ωστόσο, να ληφθούν σωστά δεδομένα από τον αισθητήρα, είναι απαραίτητη η βαθμονόμησή του στο έδαφος που πρόκειται να τοποθετηθεί. Αρχικό στάδιο αποτελεί η παρατήρηση των πραγματικών τιμών που λαμβάνονται από τον αισθητήρα, σε περίπτωση που αυτός είναι εντελώς στεγνός και όταν, αντίθετα, βυθίζεται πλήρως σε νερό. Για το λόγο αυτό, η πρώτη βαθμονόμησή του πραγματοποιήθηκε σε ένα ποτήρι με νερό, ρυθμίζοντας την ευαισθησία του ποτενσιόμετρου μέχρι να παρατηρηθεί η ελάχιστη και η μέγιστη τιμή του. Να σημειωθεί ότι, ανάλογα με την τάση λειτουργίας και το ποτενσιόμετρο, οι τιμές μπορεί να διαφέρουν. Το επόμενο στάδιο αποτελεί η βαθμονόμηση του αισθητήρα στο έδαφος που θα παρακολουθείται για τις ανάγκες της συγκεκριμένης εργασίας. Ακολουθείται πάλι η ίδια διαδικασία με πριν, μέχρι να παρατηρηθεί η μέγιστη και η ελάχιστη τιμή που δίνει ο αισθητήρας, όταν το έδαφος είναι τελείως

στεγνό και όταν είναι πλήρως υγρό. Εφόσον καταγραφούν η μέγιστη και η ελάχιστη τιμή, η διαδικασία της βαθμονόμησης ολοκληρώνεται με τη χρήση της λειτουργίας *map()* στον κώδικα, ώστε να προσαρμοστούν αυτές οι τιμές στο εύρος από 0 έως 100% και να είναι κατανοητές στο γράφημα.



Σχήμα 25. Συνδεσμολογία συστήματος.

Ολοκληρώνοντας, από τον αισθητήρα μέτρησης της φωτεινότητας του περιβάλλοντος χρησιμοποιήθηκαν μόνο τα τέσσερα από τα πέντε pins που διαθέτει. Αναλυτικότερα, το pin της τροφοδοσίας του αισθητήρα συνδέεται με το 3V3 pin της πλακέτας. Το pin SCL του αισθητήρα, που είναι υπεύθυνο για την παροχή του παλμού του ρολογιού για την I2C επικοινωνία, συνδέεται με το pin D22 της πλακέτας και, αντίστοιχα, το pin SDA, που χρησιμοποιείται για τη μεταφορά των δεδομένων μέσω της I2C επικοινωνίας, με το pin D21 της πλακέτας. Το pin ADDR δε χρησιμοποιείται στη συγκεκριμένη υλοποίηση, καθώς ένας αισθητήρας φωτός αρκεί.

### 7.3 Προγραμματισμός Πλακέτας

Ο προγραμματισμός της πλακέτας έγινε στη γλώσσα C μέσω του Arduino IDE. Αναλυτικότερα, η ρύθμιση του σταθμού για τη λήψη μετρήσεων περιβαλλοντικών τιμών, σε πραγματικό χρόνο, περιλαμβάνει την ακόλουθη ροή:

- Setup()  
Αρχικοποίηση όλων των αισθητήρων, καθώς επίσης και της I2C διεπαφής που είναι απαραίτητη για τον αισθητήρα φωτεινότητας. Ορισμός του pin D18 της πλακέτας ως pin τροφοδοσίας για τον αισθητήρα YL-69. Απενεργοποίηση της κατάστασης «deep sleep» της πλακέτας, ώστε αυτή να ξεκινήσει να λειτουργεί, και εκκίνηση της μονάδας του Wi-Fi για την επίτευξη ασύρματης επικοινωνίας με το ThingSpeak. Κάθε φορά που απενεργοποιείται η κατάσταση ύπνου της πλακέτας, είναι απαραίτητη και η επανεκκίνηση του Wi-Fi, καθώς όπως προαναφέρθηκε, στην περίπτωση του «deep sleep» οι συγκεκριμένες συνδέσεις δε διατηρούνται.
- Connect to Wifi()  
Δημιουργία σύνδεσης της πλακέτας ESP32 με το SSID του τοπικού δικτύου όπου τοποθετείται.
- Http Request()  
Δημιουργία σύνδεσης με το διακομιστή του OpenWeatherMap για την απόκτηση των επιπρόσθετων δεδομένων. Σε περίπτωση επιτυχούς σύνδεσης, λαμβάνονται ως απάντηση από το διακομιστή τα δεδομένα του συστήματος σε μορφή JSON.
- Loop()  
Ατέρμονη διαδικασία λήψης, επεξεργασίας και αποστολής των δεδομένων ανά χρονικά διαστήματα τριών ωρών. Επιπρόσθετη ενεργοποίηση και απενεργοποίηση του αισθητήρα YL-69 ακριβώς 5 δευτερόλεπτα πριν από την κάθε λήψη και άλλα 5 δευτερόλεπτα, αντίστοιχα, μετά τη λήξη της. Πρώτο στάδιο στη συγκεκριμένη συνάρτηση αποτελεί η λήψη των μετρήσεων από τους αισθητήρες του συστήματος, καθώς επίσης και ο διαχωρισμός των JSON δεδομένων που λαμβάνονται από το OpenWeatherMap. Ο διαχωρισμός των δεδομένων γίνεται, ώστε κάθε φορά να κρατούνται στο Cloud μόνο επιπρόσθετα δεδομένα (περιγραφή καιρού, ατμοσφαιρική πίεση, ταχύτητα και κατεύθυνση ανέμου), που είναι απαραίτητα για τη δημιουργία ενός ολοκληρωμένου συνόλου εκπαίδευσης για το μοντέλο του TNΔ. Ακολουθεί η αποστολή των δεδομένων στη βάση του ThingSpeak και η γραφική τους απεικόνιση. Τέλος, πραγματοποιείται απενεργοποίηση της μονάδας του Wi-Fi και ενεργοποίηση της κατάστασης «deep sleep» μέχρι την επόμενη μέτρηση, ώστε το σύστημα να καταναλώνει όσο το δυνατόν λιγότερη ενέργεια.

Με την ολοκλήρωση του κώδικα και το κατέβασμά του στην πλακέτα, μπορεί να πραγματοποιηθεί η επιτυχής λήψη, μετάδοση και γραφική απεικόνιση των μετρούμενων τιμών από τους αισθητήρες και το OpenWeatherMap, σε πραγματικό χρόνο. Ενδεικτικές εικόνες από την επιτυχή καταγραφή των δεδομένων στο ThingSpeak περιλαμβάνονται στην επόμενη παράγραφο.

## 7.4 Σύνολο Δεδομένων

Η συγκεκριμένη παράγραφος της εργασίας επικεντρώνεται στην παρουσίαση και την ανάλυση του συνόλου δεδομένων που χρησιμοποιήθηκε για την εκπαίδευση του μοντέλου πρόβλεψης στα πλαίσια αυτής της εργασίας.

Στο ακόλουθο σχήμα παρουσιάζεται το κανάλι που δημιουργήθηκε στην πλατφόρμα του ThingSpeak για την καταγραφή των δεδομένων από το σύστημα. Ο σύνδεσμος του καναλιού, όπου φαίνεται η καταγραφή των δεδομένων σε πραγματικό χρόνο είναι ο εξής: <https://thingspeak.com/channels/1087740>.

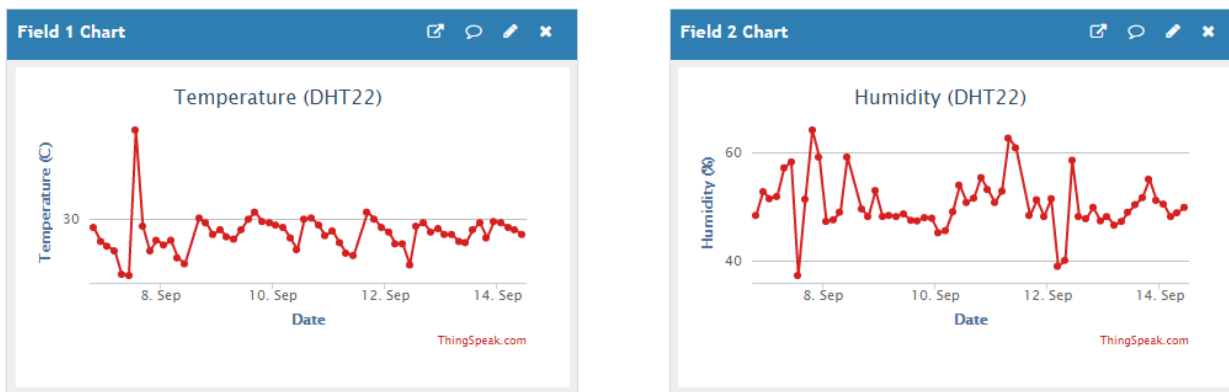
The screenshot shows the ThingSpeak interface for a channel named 'ESP32 - Fire Prediction (Pt. 1)'. The channel ID is 1087740, created by 'sofiapl' and set to private access. The description states it monitors the environment in Thessaloniki (GR) using DHT22, YL-69, and BH1750 sensors, with data from OpenWeatherMap every 3 hours. Navigation options include Private View, Public View, Channel Settings, Sharing, API Keys, and Data Import / Export. Action buttons include 'Add Visualizations', 'Add Widgets', 'Export recent data', 'MATLAB Analysis', and 'MATLAB Visualization'. Channel statistics show it was created 2 months ago, has a last entry 22 minutes ago, and contains 149 entries.

Σχήμα 26. Το κανάλι που δημιουργήθηκε για την καταγραφή των δεδομένων.

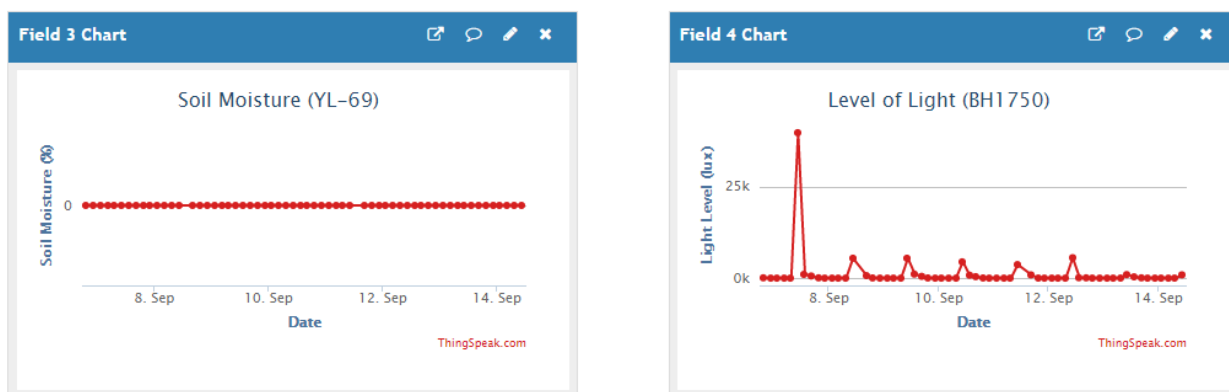
Όπως έχει ήδη αναφερθεί, το μοντέλο ΤΝΔ θα χρησιμοποιεί τα δεδομένα που καταγράφονται στο ThingSpeak τόσο από το ίδιο σύστημα, όσο και από το OpenWeatherMap. Έτσι, λοιπόν, στο κανάλι που δημιουργήθηκε, για κάθε τιμή που μετρείται από τους αισθητήρες του συστήματος ή λαμβάνεται από το OpenWeatherMap, έχει δημιουργηθεί το αντίστοιχο πεδίο που περιλαμβάνει τις καταγραφές των τιμών αυτών. Πέρα από τις τιμές, ωστόσο, το ThingSpeak επιτρέπει την παρουσίασή τους ως γραφήματα, με αποτέλεσμα να είναι πιο ευανάγνωστα και ο ενδιαφερόμενος να μπορεί να εξάγει πληροφορίες σχετικά και με τη διακύμανση των τιμών.

Στα σχήματα που ακολουθούν παρουσιάζονται οι γραφικές απεικονίσεις των τιμών θερμοκρασίας και υγρασίας του περιβάλλοντος που λαμβάνονται από τον αισθητήρα DHT22, του ποσοστού υγρασίας του εδάφους που λαμβάνεται από τον YL-69, του επιπέδου φωτεινότητας που λαμβάνεται από τον αισθητήρα BH1750, καθώς επίσης και της ατμοσφαιρικής πίεσης, και της ταχύτητας και της κατεύθυνσης του ανέμου, όπως αυτά παρέχονται από το εργαλείο του OpenWeatherMap. Οι μετρούμενες τιμές των γραφημάτων που ακολουθούν καταγράφονται κάθε φορά ανά διαστήματα των 3 ωρών, ώστε να συμβαδίζουν με τις νέες τιμές που παρέχονται από το σύστημα του OpenWeatherMap.







Σχήμα 27. Τιμές θερμοκρασίας και υγρασίας από τον αισθητήρα DHT22.



Σχήμα 28. Τιμές υγρασίας εδάφους από τον αισθητήρα YL-69 και επιπέδου φωτεινότητας από τον BH1750.



Σχήμα 29. Τιμές ατμοσφαιρικής πίεσης από το OpenWeatherMap.



Σχήμα 30. Τιμές ταχύτητας και κατεύθυνσης του ανέμου από το OpenWeatherMap.

Στο σημείο αυτό αξίζει να σημειωθεί πως, τελικά, τα δεδομένα του συστήματος που παρουσιάστηκαν και καταγράφηκαν στο ThingSpeak δεν επαρκούν για την εκπαίδευση του μοντέλου, γεγονός που οφείλεται, κυρίως, στη φύση του αλγορίθμου μηχανικής μάθησης που θα χρησιμοποιηθεί.

Πιο συγκεκριμένα, ο αλγόριθμος που θα χρησιμοποιηθεί για την πρόβλεψη θα πρέπει να είναι μη γραμμικός, έτσι ώστε να είναι σε θέση να μάθει περίπλοκες μη γραμμικές σχέσεις μεταξύ των χαρακτηριστικών εισόδου και εξόδου. Σε αντίθετη περίπτωση χρήσης γραμμικού αλγορίθμου, αναμένεται πως, ανεξάρτητα από τον αριθμό των κρυφών επιπέδων που θα χρησιμοποιηθούν στο μοντέλο, αυτό θα συμπεριφέρεται κατά τον ίδιο τρόπο, με αποτέλεσμα να μην επιτελείται σωστή εκπαίδευσή του.

Η ευελιξία, συνεπώς, που παρέχεται από τους μη γραμμικούς αλγορίθμους είναι ιδιαίτερα χρήσιμη σε παρόμοια προβλήματα πρόβλεψης, όπου βασικός στόχος είναι η εύρεση της αλληλοεξάρτησης μεταξύ κάποιων τιμών. Ωστόσο, αυτή η ευελιξία δημιουργεί, από την άλλη πλευρά, την ανάγκη για πολύ μεγαλύτερο όγκο δεδομένων εκπαίδευσης, συνήθως της τάξης των ~10000 τιμών και άνω.

Για τις ανάγκες, λοιπόν, της υλοποίησης της συγκεκριμένης εργασίας χρησιμοποιήθηκαν δεδομένα από έτοιμο dataset, το οποίο προσομοίαζε όσο το δυνατόν περισσότερο στα δεδομένα που συλλέγονται από το σύστημα. Συγκεκριμένα, χρησιμοποιήθηκε το Jena Climate dataset, που παρέχεται από το Ινστιτούτο Βιοχημείας Max Planck και διαθέτει περίπου 300000 δείγματα που καταγράφηκαν κατά τη χρονική περίοδο από το 2009 έως και το 2016. Πρόκειται στην ουσία για ένα μετεωρολογικό σταθμό στην περιοχή Jena της Γερμανίας, ο οποίος μετρά 14 περιβαλλοντικές τιμές, όπως η θερμοκρασία, η ατμοσφαιρική πίεση, η υγρασία κ.λπ., κάθε 10 λεπτά της ώρας. Τα δεδομένα αυτά είναι αποθηκευμένα σε ένα .csv αρχείο, το οποίο εισάγεται στο μοντέλο TNΔ, με τη μορφή ενός πίνακα που διαθέτει 15 στήλες/χαρακτηριστικά (attributes). Αναλυτικότερα, η πρώτη στήλη αποτελεί την ημερομηνία καταγραφής της κάθε περιβαλλοντικής τιμής και είναι χωρισμένη σε διαστήματα των 10 λεπτών της ώρας. Αντίστοιχα, οι ακόλουθες 14 στήλες αφορούν η κάθε μία σε μία συγκεκριμένη περιβαλλοντική μεταβλητή.

## 7.5 Δημιουργία Μοντέλου Πρόβλεψης

Στην παράγραφο αυτή παρουσιάζεται αναλυτικά η διαδικασία που ακολουθήθηκε μέχρι την υλοποίηση του προτεινόμενου ΤΝΔ μοντέλου πρόβλεψης. Κάθε μία από τις ακόλουθες υπο-παραγράφους αναλύει και κάθε διαφορετική φάση της εκπαίδευσης του αλγορίθμου, από την κατάλληλη επεξεργασία των δεδομένων, μέχρι την εξαγωγή του επιθυμητού αποτελέσματος.

### 7.5.1 Προεπεξεργασία Δεδομένων

Όπως προαναφέρθηκε, το Jena dataset περιλαμβάνει περίπου 300000 δεδομένα με 14 διαφορετικές περιβαλλοντικές τιμές για την εκπαίδευση του μοντέλου. Για την απόκτηση μιας γενικής εικόνας των δεδομένων, πραγματοποιήθηκε γραφική απεικόνιση της κάθε μεταβλητής για τη χρονική περίοδο από το 2009 έως και το 2016.

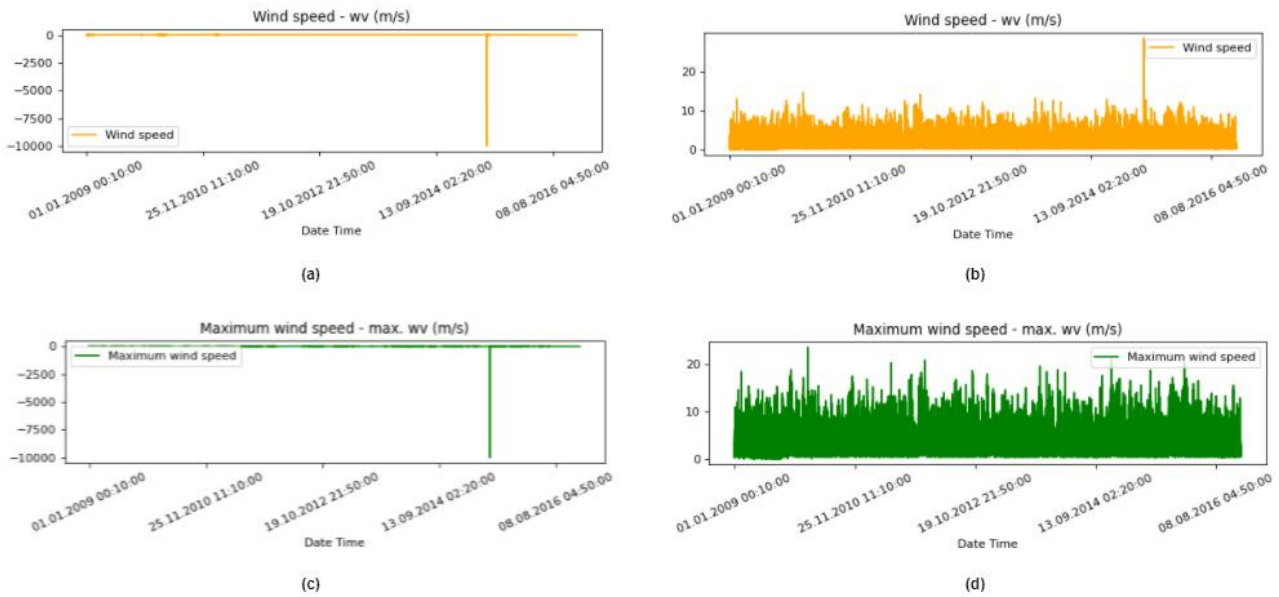
Από το σύνολο των μεταβλητών, ωστόσο, παρατηρήθηκε πως οι τιμές για τις μεταβλητές της ταχύτητας, καθώς και της μέγιστης ταχύτητας του ανέμου παρουσίαζαν αρκετές ανωμαλίες, καθώς ως ελάχιστη τιμή καταγράφηκε το -9999, η οποία φαίνεται αδύνατη για μεταβλητές ταχύτητας. Συνεπώς, θεωρώντας ως υπάρχουν λανθασμένες μετρήσεις για τις συγκεκριμένες μεταβλητές, το επόμενο βήμα αποτέλεσε το φιλτράρισμα (filtering) των δεδομένων αυτών των δύο στηλών, όπως φαίνεται στον κώδικα στο Σχήμα 31.

```

1 def replace_outliers(col):
2     median = df[col].median()
3     outliers = (df[col] < 0)
4     df.loc[outliers, col] = np.nan
5     df[col].fillna(median, inplace=True)
6
7 replace_outliers('wv (m/s)')
8 replace_outliers('max. wv (m/s)')
```

Σχήμα 31. Φιλτράρισμα των αρνητικών τιμών της ταχύτητας ανέμου.

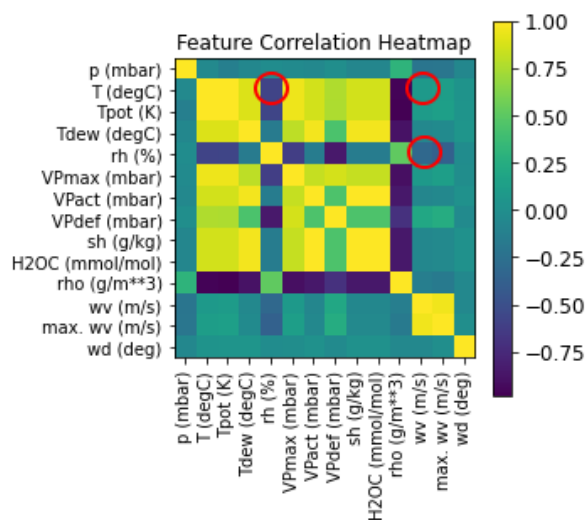
Πιο συγκεκριμένα, στη συνάρτηση που υλοποιήθηκε, υπολογίζεται κάθε φορά η μέση τιμή της κάθε στήλης, μία για τη στήλη της ταχύτητας του ανέμου ( $wv$  (m/s)) και άλλη μία για τη στήλη της μέγιστης ταχύτητας ( $max. wv$  (m/s)). Στη συνέχεια, για κάθε αρνητική τιμή της κάθε μεταβλητής, γίνεται αντικατάστασή της με τη μέση τιμή που υπολογίστηκε, με αποτέλεσμα τα τελικά δεδομένα των στηλών να μην περιλαμβάνουν καμία αρνητική τιμή. Τέλος, να σημειωθεί πως παρόλο που οι αρνητικές τιμές κάθε στήλης θα μπορούσαν να αντικατασταθούν με την τιμή μηδέν, δε θεωρήθηκε πολύ καλή πρακτική, καθώς η μέση τιμή κάθε στήλης είναι πιο ουδέτερη και βοηθάει στην καλύτερη εκπαίδευση του ΤΝΔ. Στο σχήμα που ακολουθεί, οι γραφικές απεικονίσεις παρουσιάζουν τα γραφήματα για τις στήλες « $wv$  (m/s)» και « $max. wv$  (m/s)» πριν και μετά το φιλτράρισμα.



Σχήμα 32. Γραφικές απεικονίσεις ταχύτητας ανέμου (a) πριν και (b) μετά το φιλτράρισμα, και μέγιστης ταχύτητας ανέμου (c) πριν και (d) μετά το φιλτράρισμα.

Για την εύρεση κάποιας συσχέτισης μεταξύ των δεδομένων του συνόλου, δημιουργήθηκε ένας πίνακας συσχετίσεων (correlation matrix). Πιο αναλυτικά, ένας πίνακας συσχετίσεων είναι απλά ένας  $n \times n$  τετραγωνικός και συμμετρικός πίνακας, του οποίου η  $(i, j)$  είσοδος αποτελεί τη συσχέτιση μεταξύ των στηλών  $i$  και  $j$  [49]. Όσο υψηλότερη είναι μια τιμή στο συγκεκριμένο πίνακα, τόσο μεγαλύτερος είναι και ο βαθμός συσχέτισης μεταξύ των δύο αυτών χαρακτηριστικών.

Στο Σχήμα 33 που ακολουθεί, παρουσιάζεται ο πίνακας συσχετίσεων όλων των 14 διαφορετικών τιμών του συνόλου δεδομένων Jena. Στα δεξιά του σχήματος, υπάρχει μια μπάρα που περιλαμβάνει τιμές από -1 έως 1, μαζί με το αντίστοιχο χρώμα, προκειμένου να υποδείξει αν η συσχέτιση μεταξύ δύο τιμών είναι υψηλή ή όχι. Φυσικά, όσο υψηλότερη είναι η συσχέτιση μεταξύ των χαρακτηριστικών που θα επιλεγούν για την εκπαίδευση του μοντέλου, τόσο καλύτερα θα είναι και τα τελικά αποτελέσματα πρόβλεψης που θα εξαχθούν.



Σχήμα 33. Πίνακας συσχετίσεων δεδομένων.

Γενικά, υψηλή συσχέτιση δύο μεταβλητών παρατηρείται για τιμές μεγαλύτερες του 0.7. Τιμές που κυμαίνονται από 0.5 έως 0.7, φανερώουν μέτρια συσχέτιση, ενώ για οποιαδήποτε τιμή κάτω από 0.4, θεωρείται ότι δεν υπάρχει καμία συσχέτιση μεταξύ των μεταβλητών.

Επόμενο βήμα στην προεπεξεργασία των δεδομένων είναι η δημιουργία των χρονοσειρών εκπαίδευσης και ελέγχου του μοντέλου. Ορίστηκε αυθαίρετα ένα διάστημα 120 ωρών (*past*) με στόχο την εκμάθηση του ΤΝΔ για πρόβλεψη μετά από 12 ώρες (*future*). Πιο συγκεκριμένα, αναφέρθηκε παραπάνω πως οι 14 τιμές του συνόλου δεδομένων καταγράφονται κάθε 10 λεπτά, δηλαδή 6 φορές κάθε ώρα (*step*). Άρα, το διάστημα *past* αναλογεί σε  $6 \text{ steps} \times 120 \text{ ώρες} = 720$  μετρήσεις. Αυτά τα δεδομένα θα χρησιμοποιηθούν, έπειτα, για την πρόβλεψη των τριών σημαντικότερων τιμών, της θερμοκρασίας, της υγρασίας και της ταχύτητας του ανέμου, μετά από 12 ώρες, δηλαδή  $12 \text{ ώρες} \times 6 \text{ steps} = 72$  μετρήσεις (*future = 72*).

Παράλληλα, και δεδομένου ότι κάθε μεταβλητή του συνόλου δεδομένων έχει τιμές διαφορετικού εύρους, το επόμενο βήμα αποτελεί η κανονικοποίηση αυτών, ώστε να περιοριστεί το εύρος τους σε τιμές που κυμαίνονται από 0 έως 1 πριν από την εκπαίδευση του μοντέλου. Η συγκεκριμένη διαδικασία υλοποιείται με αφαίρεση του μέσου όρου και διαιρώντας με την τυπική απόκλιση (*standard deviation*) κάθε χαρακτηριστικού. Τέλος, για την εκπαίδευση του μοντέλου ΤΝΔ, από το σύνολο των δεδομένων, θα χρησιμοποιηθεί το 85% αυτών (*split\_fraction = 0.85*), ενώ το υπόλοιπο 15% θα αποτελέσει τα δεδομένα επαλήθευσης. Η διαδικασία αυτή της κανονικοποίησης, μαζί με τον ορισμό του συνόλου δεδομένων εκπαίδευσης (*train\_split*), παρουσιάζεται στο ακόλουθο σχήμα.

```

1 split_fraction = 0.85
2 train_split = int(split_fraction * int(df.shape[0]))
3 step = 6
4
5 past = 720
6 future = 72
7 learning_rate = 0.001
8 batch_size = 2048
9 epochs = 20
10
11
12 def normalize(data, train_split):
13     data_mean = data.mean(axis=0)
14     data_std = data.std(axis=0)
15     print(data_mean)
16     print(data_std)
17
18     return data_mean, data_std, (data - data_mean) / data_std

```

Σχήμα 34. Προεπεξεργασία δεδομένων.

Τέλος, το μοντέλο λαμβάνει ως δεδομένα εκπαίδευσης τιμές και από τις 14 μεταβλητές του συνόλου δεδομένων. Παρόλα αυτά, από τον πίνακα συσχετίσεων στο Σχήμα 33 παρατηρείται πως κάποιες μεταβλητές, όπως είναι η μεταβλητή της κατεύθυνσης του ανέμου (*wd (deg)*), που είναι η τελευταία τιμή του πίνακα, δε σχετίζεται με καμία άλλη μεταβλητή. Συνεπώς, δεν είναι απαραίτητο να βρίσκεται στα δεδομένα εκπαίδευσης του μοντέλου και μπορεί να αφαιρεθεί πριν ξεκινήσει η εκπαίδευσή του.

### 7.5.2 Σύνολα Εκπαίδευσης και Επαλήθευσης

Το σύνολο των δεδομένων εκπαίδευσης ξεκινάει (*start*) από την 792η μέτρηση, η οποία υπολογίζεται ως το άθροισμα των προηγούμενων 720 σειρών με τις επόμενες 72, δηλαδή των δεδομένων από 120 ώρες πριν με τις 12 ώρες, μετά τις οποίες γίνεται η πρόβλεψη. Παρατηρείται, επίσης, πως ως δεδομένα εκπαίδευσης του μοντέλου ΤΝΔ (*x\_train*) λαμβάνονται οι 13 από τις 14 μεταβλητές του συνόλου δεδομένων, όπως φαίνεται και στον κώδικα, ενώ το *ground truth* (*y\_train*) αφορά στις τρεις σημαντικότερες για τις ανάγκες της εργασίας μεταβλητές: (i) θερμοκρασία περιβάλλοντος, (ii) υγρασία περιβάλλοντος και (iii) ταχύτητα ανέμου.

```

1 start = past + future
2 end = start + train_split
3
4 x_train = train_data[[i for i in range(13)]].values
5 y_train = features.iloc[start:end][[1,4,11]]
6 print(x_train)
7 sequence_length = int(past / step)

```

Σχήμα 35. Σύνολο δεδομένων εκπαίδευσης.

Το σύνολο των δεδομένων επαλήθευσης, αντίθετα, αντιστοιχεί στο υπόλοιπο 15% του συνόλου των δεδομένων, το οποίο θα πρέπει να ξεκινάει 792 σειρές μετά τα δεδομένα εκπαίδευσης (*label\_start*).

```

1 x_end = len(val_data) - past - future
2
3 label_start = train_split + past + future
4
5 x_val = val_data.iloc[:x_end][[i for i in range(13)]].values
6 y_val = features.iloc[label_start:][[1,4,11]]
7
8
9
10 dataset_val = keras.preprocessing.timeseries_dataset_from_array(
11     x_val,
12     y_val,
13     sequence_length=sequence_length,
14     sampling_rate=step,
15     batch_size=batch_size,
16 )
17
18
19 for batch in dataset_train.take(1):
20     inputs, targets = batch
21
22 print("Input shape:", inputs.numpy().shape)
23 print("Target shape:", targets.numpy().shape)

```

```

Input shape: (2048, 120, 13)
Target shape: (2048, 3)

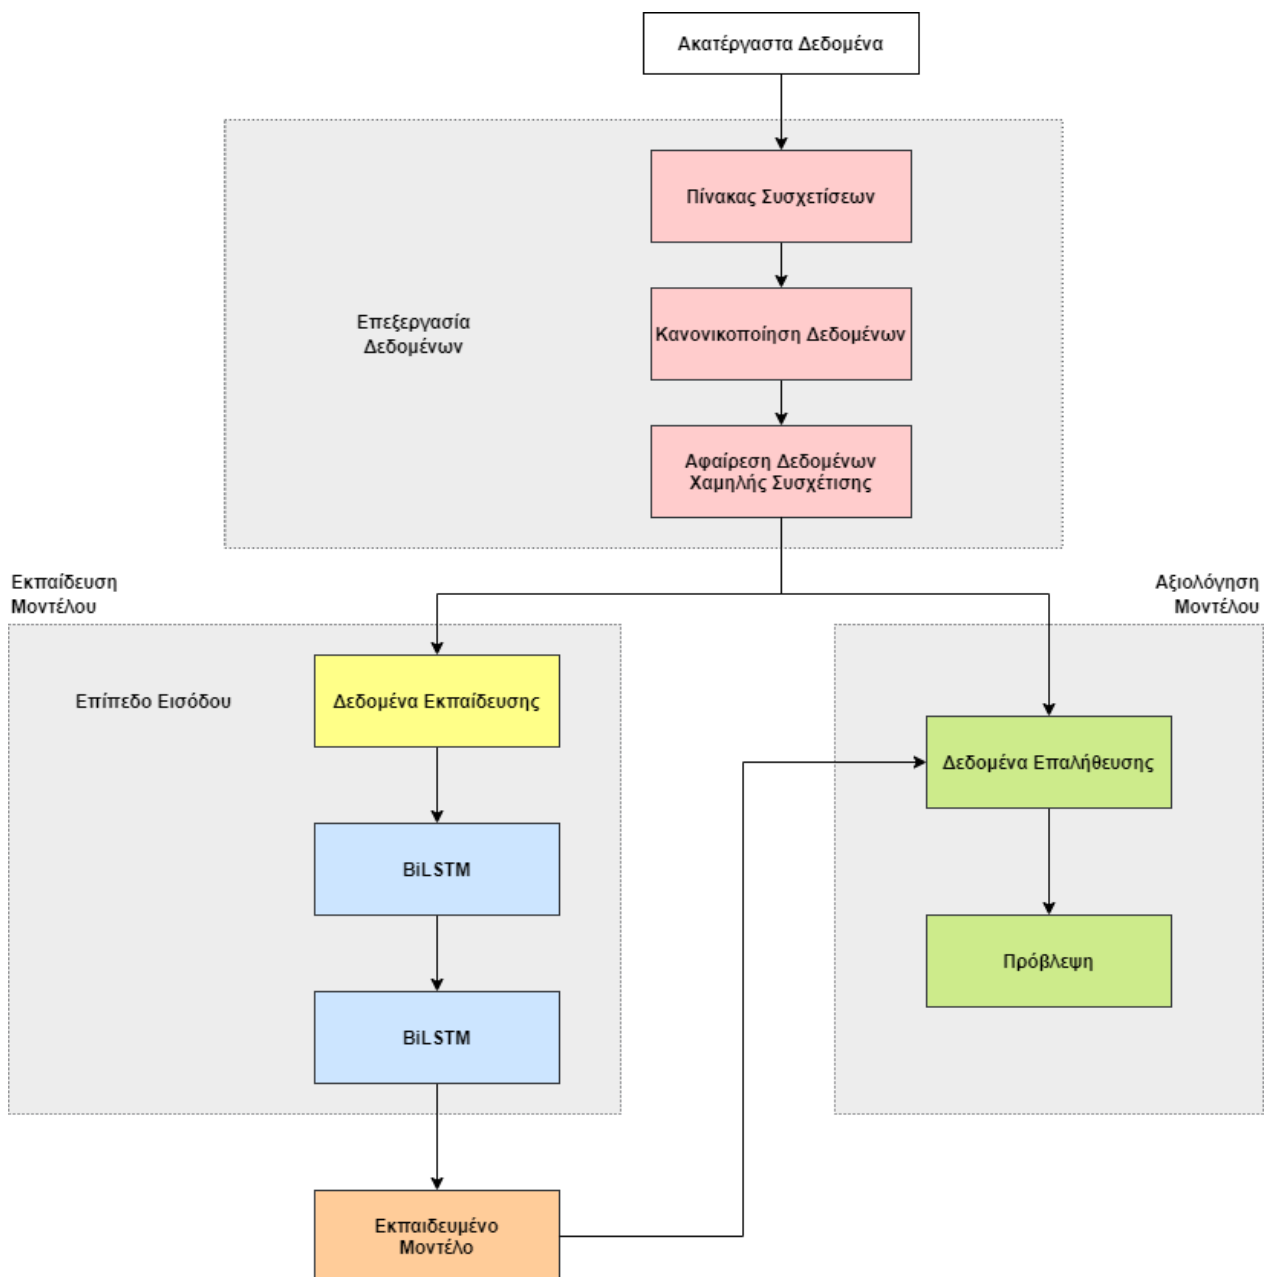
```

Σχήμα 36. Σύνολο δεδομένων επαλήθευσης.

### 7.5.3 Stacked LSTM Δύο Κατευθύνσεων

Η συγκεκριμένη παράγραφος της εργασίας παρουσιάζει και αναλύει το προτεινόμενο μοντέλο πρόβλεψης που υλοποιήθηκε, καθώς επίσης εξετάζει την απόδοσή του, συγκρίνοντας τις τιμές του training loss με το validation loss.

Στο Σχήμα 37 που ακολουθεί, φαίνεται το διάγραμμα ροής του μοντέλου, από την εισαγωγή των ακατέργαστων δεδομένων, μέχρι και την εξαγωγή των τιμών πρόβλεψης. Η διαδικασία φαίνεται πως αποτελείται από τρεις επιμέρους φάσεις, την επεξεργασία των δεδομένων, όπως αυτή αναλύθηκε στην Παρ. 7.5.1, την εκπαίδευση του μοντέλου και, τέλος, την αξιολόγηση του εκπαιδευμένου μοντέλου βάσει της τιμής του validation loss.



Σχήμα 37. Διάγραμμα ροής του προτεινόμενου μοντέλου πρόβλεψης.

Αρχικό στάδιο της διαδικασίας εκπαίδευσης, όπως φαίνεται και στο διάγραμμα, αποτελεί η σωστή επιλογή του συνόλου των δεδομένων εκπαίδευσης. Όπως προαναφέρθηκε στην προηγούμενη παράγραφο, ο διαχωρισμός των δεδομένων έγινε σε δύο επιμέρους σύνολα, ώστε το 85% να αποτελεί τα δεδομένα εκπαίδευσης ( $x_{train}$ ) και το υπόλοιπο 15% να αποτελεί τα δεδομένα επαλήθευσης ( $x_{val}$ ). Σκοπός της διαδικασίας αυτής είναι το μοντέλο να προσπαθήσει να μάθει τα δεδομένα που του δίνονται κατά τη διαδικασία εκπαίδευσης, ώστε να μπορέσει να φτάσει στην πρόβλεψη των τιμών που έχουν οριστεί ως *ground truth* για τις τρεις σημαντικότερες μεταβλητές ( $y_{train}$ ).

Επόμενο και σημαντικότερο βήμα της διαδικασίας εκπαίδευσης είναι η εύρεση και η υλοποίηση του κατάλληλου μοντέλου. Η διαδικασία αυτού του βήματος ήταν καθαρά πειραματική, λαμβάνοντας υπόψη και κάποιες βασικές αρχές της βιβλιογραφίας. Μέχρι την τελική επιλογή, πραγματοποιήθηκαν πολλές δοκιμές με διάφορα μοντέλα. Ενδεικτικά, μερικά από αυτά που χρησιμοποιήθηκαν είναι ένα απλό LSTM μοντέλο, ένα απλό LSTM μοντέλο δύο κατευθύνσεων, ένα Stacked LSTM μοντέλο δύο επιπέδων, καθώς επίσης και ένα απλό δίκτυο GRU. Ωστόσο, τα αποτελέσματα αυτών των δοκιμών δεν ήταν ενθαρρυντικά, καθώς είτε δεν επέφεραν καλά αποτελέσματα, είτε οδηγούσαν σε *overfitting*.

Το μοντέλο, τελικά, που επέφερε τα βέλτιστα αποτελέσματα πρόβλεψης είναι ένα Stacked LSTM μοντέλο δύο κατευθύνσεων (Bidirectional Stacked LSTM), με δύο επίπεδα και συνάρτηση ενεργοποίησης αυτή της υπερβολικής εφαπτομένης (*tanh*), όπως φαίνεται στο διάγραμμα ροής αλλά και στον κώδικα στο Σχήμα 38.

```

1 import keras.backend as K
2 from keras.models import Sequential
3 from keras.layers import *
4
5 model = Sequential()
6
7 model.add(Bidirectional(LSTM(16, activation='tanh', dropout=0.2, return_sequences=True), input_shape=(inputs.shape[1], input
8 model.add(Bidirectional(LSTM(8, activation='tanh', dropout=0.2, return_sequences=False)))
9
10 model.add(Dense(3))
11
12 model.compile(optimizer=keras.optimizers.RMSprop(lr=learning_rate), loss='mse')
13 model.summary()

```

Σχήμα 38. Stacked LSTM μοντέλο δύο κατευθύνσεων.

Στη συνέχεια, το μοντέλο ορίζεται ως διαδοχικό (*sequential*), καθώς πρόκειται να αποτελείται από στοιβαγμένα διαδοχικά επίπεδα και, πιο συγκεκριμένα, τα επίπεδα αυτά είναι δύο BiLSTM μεγέθους 16 και 8 κρυφών επιπέδων, αντίστοιχα. Επειδή πρόκειται για μια διαδοχική διαδικασία μεταφοράς των δεδομένων από το ένα επίπεδο BiLSTM στο άλλο, θα πρέπει το ένα να παίρνει ως είσοδο κάθε φορά το αποτέλεσμα της εξόδου του προηγούμενου. Για το σκοπό αυτό, έγινε χρήση της παραμέτρου «*return\_sequences*» που στο πρώτο επίπεδο ορίστηκε ως «*true*», ενώ αντίθετα στο δεύτερο ως «*false*», με αποτέλεσμα το δεύτερο επίπεδο να λαμβάνει ως είσοδο την έξοδο του πρώτου και να συνεχίζει η διαδικασία εκπαίδευσης.



Επιπρόσθετα, κατά την εκπαίδευση, χρησιμοποιήθηκαν οι callback λειτουργίες «*ModelCheckpoint*», για την τακτική αποθήκευση των βαρών αλλά και του καλύτερου μοντέλου με το χαμηλότερο validation loss, και «*EarlyStopping*», για τη διακοπή της διαδικασίας εκπαίδευσης σε περίπτωση που το validation loss πάψει να βελτιώνεται. Στη συγκεκριμένη περίπτωση σημαίνει ότι έχει παρατηρηθεί overfitting.

```

1 path_checkpoint = "model_checkpoint.h5"
2 es_callback = keras.callbacks.EarlyStopping(monitor="val_loss", min_delta=0, patience=3)
3
4 modelckpt_callback = keras.callbacks.ModelCheckpoint(
5     monitor="val_loss",
6     filepath=path_checkpoint,
7     verbose=1,
8     save_weights_only=True,
9     save_best_only=True,
10 )
11
12 history = model.fit(
13     dataset_train,
14     epochs=epochs,
15     validation_data=dataset_val,
16     callbacks=[es_callback, modelckpt_callback],
17 )

```

Σχήμα 39. Εκπαίδευση του μοντέλου.

Κατά τη διαδικασία επαλήθευσης, δίνονται στο μοντέλο άγνωστα δεδομένα ( $x_{val}$ ) και, στη συνέχεια, γίνεται προσπάθεια ελέγχου της απόδοσής του, παρατηρώντας πόσο κοντά έπεσε στα νέα labels ( $y_{val}$ ).

Στο σχήμα που ακολουθεί περιλαμβάνονται τα αποτελέσματα επαλήθευσης από το προτεινόμενο μοντέλο για τις δύο τελευταίες εποχές. Παρατηρείται πως οι δύο τιμές μεταξύ training loss και validation loss είναι αρκετά κοντά, ενώ αντίστοιχα, η βέλτιστη τιμή για το validation loss του μοντέλου, μετά από 20 εποχές, είναι ίση με 0.45904.

```


Epoch 19/20
175/175 [=====] - ETA: 0s - loss: 0.4414
Epoch 00019: val_loss improved from 0.46084 to 0.46015, saving model to model_checkpoint.h5
175/175 [=====] - 215s 1s/step - loss: 0.4414 - val_loss: 0.4601
Epoch 20/20
175/175 [=====] - ETA: 0s - loss: 0.4399
Epoch 00020: val_loss improved from 0.46015 to 0.45904, saving model to model_checkpoint.h5
175/175 [=====] - 216s 1s/step - loss: 0.4399 - val_loss: 0.4590

```

Σχήμα 40. Τιμές training και validation loss του μοντέλου.

Τέλος, στο Σχήμα 41 παρουσιάζεται η διαφορά μεταξύ training loss και validation loss του μοντέλου για 20 εποχές. Όπως φαίνεται από το γράφημα, οι δύο καμπύλες είναι αρκετά κοντά,

γεγονός που σημαίνει πως το αποτέλεσμα της πρόβλεψης του μοντέλου είναι πολύ κοντά στις πραγματικές τιμές, με αποτέλεσμα να παρατηρείται ελάχιστο overfitting.



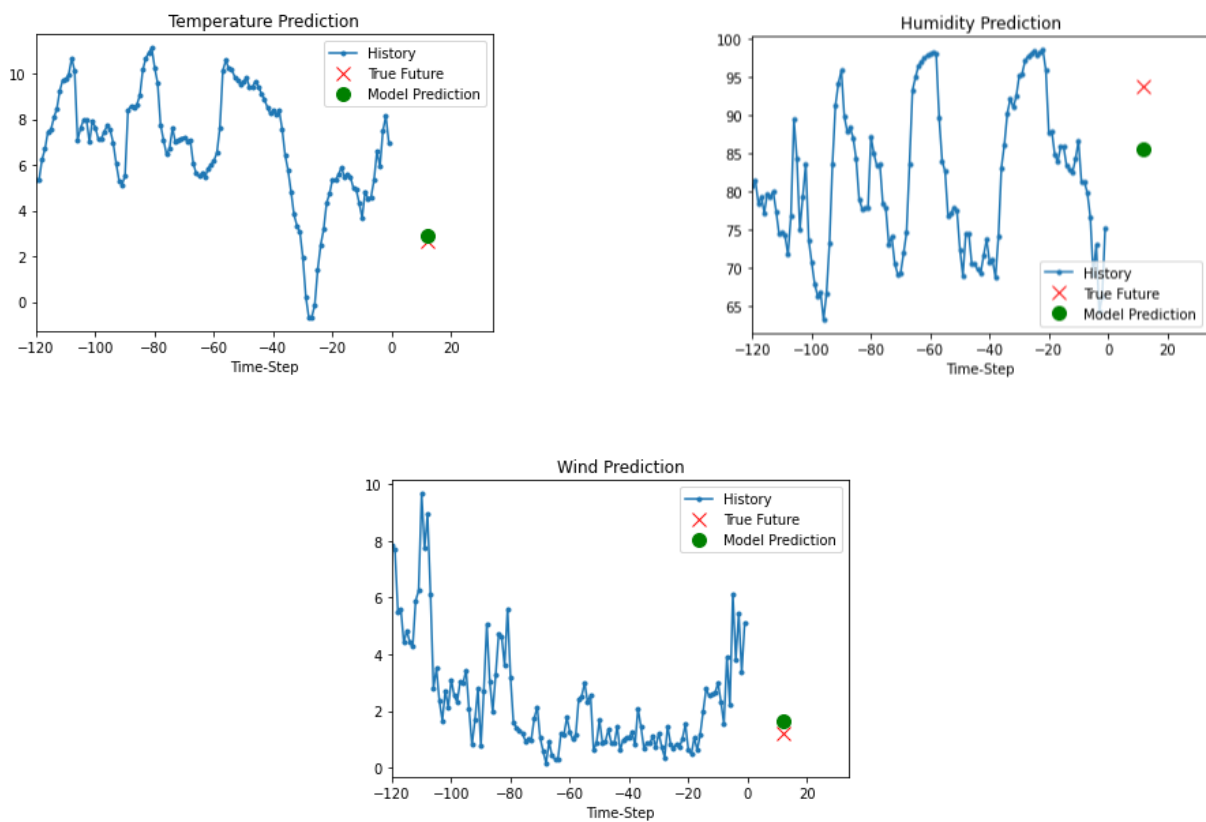
Σχήμα 41. Σύγκριση training και validation loss για το μοντέλο για 20 εποχές.

# 8

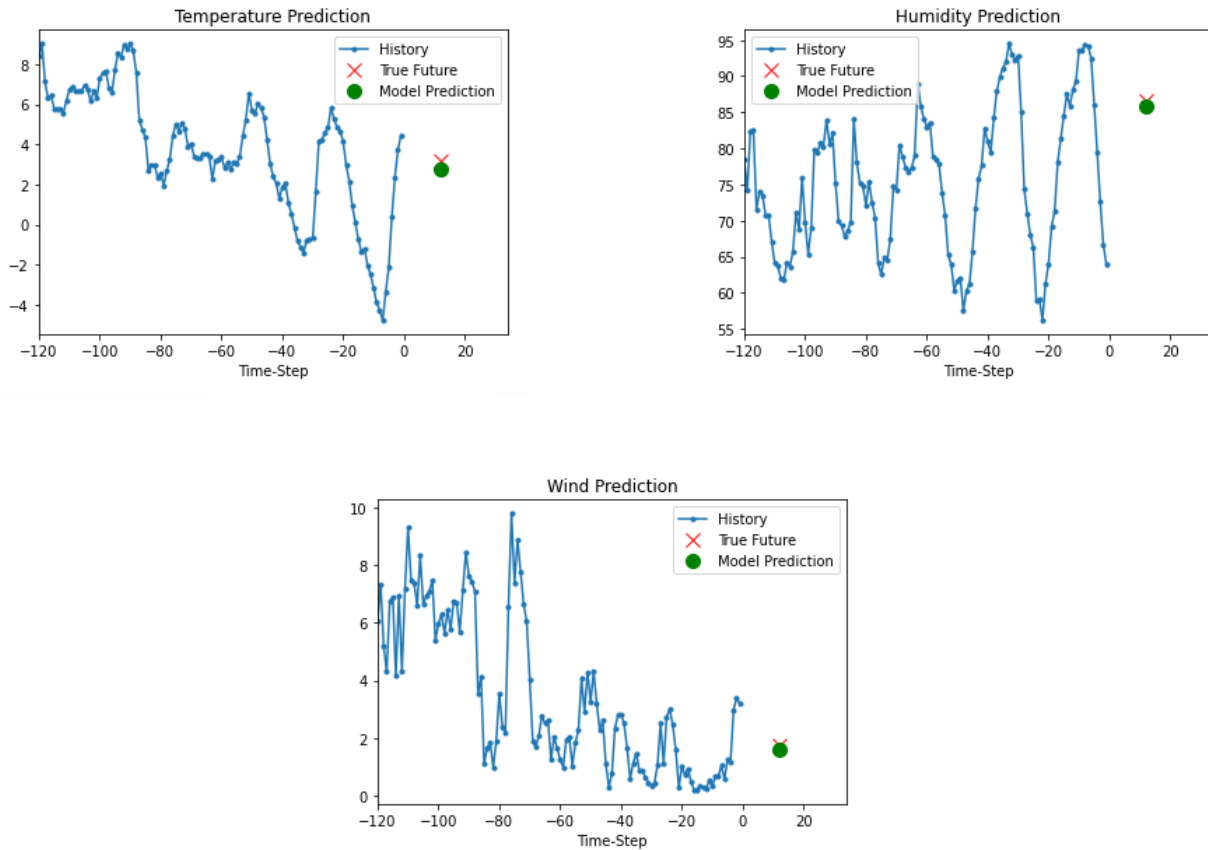
## Αξιολόγηση Απόδοσης

### 8.1 Αποτελέσματα Πρόβλεψης του Μοντέλου

Στη συγκεκριμένη παράγραφο της εργασίας παρουσιάζονται τα αποτελέσματα της πρόβλεψης μετά την εφαρμογή του μοντέλου που αναλύθηκε στην προηγούμενη ενότητα. Στα σχήματα που ακολουθούν παρουσιάζονται οι γραφικές απεικονίσεις που αφορούν την πρόβλεψη των τιμών της θερμοκρασίας, της υγρασίας και της ταχύτητας του αέρα, για τις επόμενες 12 ώρες.



Σχήμα 42. Αποτελέσματα πρόβλεψης θερμοκρασίας, υγρασίας και ταχύτητας αέρα.



Σχήμα 43. Αποτελέσματα πρόβλεψης θερμοκρασίας, υγρασίας και ταχύτητας αέρα.

Παρατηρώντας τα γραφήματα, η μπλε καμπύλη παρουσιάζει τη διακύμανση των τιμών της κάθε μεταβλητής από το σύνολο των δεδομένων για τις προηγούμενες 120 ώρες, το κόκκινο σημάδι δείχνει την πραγματική τιμή (ground truth), ενώ το πράσινο σημάδι δείχνει την τιμή που προέβλεψε το μοντέλο.

Τα αποτελέσματα της πρόβλεψης είναι αρκετά κοντά στις πραγματικές τιμές, στις περισσότερες περιπτώσεις. Εξάιρεση αποτελεί το γράφημα του ποσοστού υγρασίας από το Σχήμα 42, όπου παρατηρείται μια ελάχιστη απόκλιση μεταξύ των δύο τιμών, η οποία δεν είναι μεγαλύτερη από 10%. Ωστόσο, λόγω της πολυ-παραμετρικής φύσης του προβλήματος, αποκλίσεις αυτής της τάξης θεωρούνται αναμενόμενες.

Η επιλογή του συγκεκριμένου αριθμού εποχών, καθώς επίσης και ο ορισμός της τιμής του learning rate σε 0.001, σε συνδυασμό με την κατάλληλη προεπεξεργασία και διαχωρισμό των δεδομένων, έπαιξαν σημαντικό ρόλο στην επιτυχημένη εκπαίδευσή του, καθώς το μοντέλο έχει αποκτήσει ικανότητες γενίκευσης, εφαρμόζοντας αυτά που έχει μάθει από τα δεδομένα εκπαίδευσης σε νέα, άγνωστα δεδομένα. Συμπεραίνεται, επομένως, πως πρόκειται για ένα αρκετά καλό μοντέλο που προσφέρει ικανοποιητικά αποτελέσματα πρόβλεψης μελλοντικών περιβαλλοντικών τιμών.

## 8.2 Υπολογισμός Βαθμού Επικινδυνότητας

Για την αξιολόγηση του κινδύνου της εκδήλωσης μιας πυρκαγιάς, απαραίτητη προϋπόθεση είναι η δημιουργία ενός συστήματος διαχείρισης που θα ενσωματώνει τις πτυχές των επιλεγμένων χαρακτηριστικών κινδύνου σε αριθμητικούς ή ποιοτικούς δείκτες [50]. Μέχρι στιγμής, στη βιβλιογραφία περιλαμβάνονται αρκετά δημοφιλή συστήματα διαχείρισης πυρκαγιάς [51]. Για τις ανάγκες της παρούσας διπλωματικής εργασίας, ωστόσο, και τον υπολογισμό του βαθμού επικινδυνότητας, επιλέχθηκαν το «Simple Fire Danger Index» [52] και το «McArthur Forest Fire Danger Index» [53], καθώς συσχετίζουν τις τρεις τιμές θερμοκρασίας, υγρασίας και ταχύτητας του ανέμου που εξάγονται από την πρόβλεψη του μοντέλου.

Αναλυτικότερα, το σύστημα αξιολόγησης κινδύνου «Simple Fire Danger Index» συνδυάζει τις μετεωρολογικές πληροφορίες με την εκτίμηση της περιεκτικότητας σε υγρασία για την υλοποίηση του βαθμού επικινδυνότητας, ο οποίος υπολογίζεται από τον τύπο:

$$SFDI = \frac{\max(U_0, U)}{FMI} \quad (8.2.1)$$

όπου  $U$  είναι η ταχύτητα του ανέμου σε kph και  $U_0$  η τιμή-κατώφλι που έχει εισαχθεί ώστε να διασφαλιστεί ότι ο βαθμός επικινδυνότητας θα είναι μεγαλύτερος του μηδενός, ακόμα και στην περίπτωση μηδενικής ταχύτητας ανέμου. Η τιμή αυτή είναι ορισμένη στο 1kph, καθώς τότε το σύστημα έδινε τα βέλτιστα αποτελέσματα. Τέλος, η παράμετρος  $FMI$  αποτελεί το δείκτη υγρασίας και υπολογίζεται ως:

$$FMI = 10 - 0.25(T - H) \quad (8.2.2)$$

όπου  $T$  είναι η τιμή της θερμοκρασίας σε βαθμούς Κελσίου και  $H$  το ποσοστό της υγρασίας.

Από την άλλη πλευρά, το «McArthur Forest Fire Danger Index» αποτελεί ένα σύστημα αξιολόγησης κινδύνου που παράγει το δείκτη  $FFDI$ , ο οποίος υπολογίζεται κατά προσέγγιση από τον τύπο:

$$FFDI \approx 12.5 \exp\left(0.0234U + \frac{1}{30}(T - H)\right) \quad (8.2.3)$$

όπου  $U$  είναι η ταχύτητα του ανέμου σε kph,  $T$  η τιμή της θερμοκρασίας σε βαθμούς Κελσίου και  $H$  το ποσοστό της υγρασίας. Ο δείκτης αυτός αποτελεί τη βάση του συστήματος αξιολόγησης, όπου οι κατηγορίες κινδύνου πυρκαγιάς κυμαίνονται από «Χαμηλή» έως και «Ακραία».

Καθώς τα συγκεκριμένα συστήματα αξιολόγησης διακρίνονται σε πέντε επιμέρους επίπεδα, κατασκευάστηκαν αντίστοιχες πέντε κατηγορίες κινδύνου βάσει της πιθανότητας εκδήλωσης πυρκαγιάς και της αναμενόμενης δυσκολίας αντιμετώπισής της. Οι κατηγορίες αυτές, σύμφωνα και με τη Γενική Γραμματεία Πολιτικής Προστασίας [55], κυμαίνονται από «Χαμηλή» σε «Κατάσταση Συναγερμού» ως εξής:

- I. *Χαμηλή Κατηγορία Κινδύνου (Μπλε):* Ο κίνδυνος είναι χαμηλός και η πιθανότητα για πρόκληση πυρκαγιάς σχεδόν απίθανη. Αν εκδηλωθεί πυρκαγιά, οι περιβαλλοντικές συνθήκες δε θα ευνοήσουν τη γρήγορη εξέλιξή της. Επιτρέπονται οι ελεγχόμενες καύσεις.

- II. *Μέτρια Κατηγορία Κινδύνου (Πράσινη)*: Συνήθης κίνδυνος καθ' όλη τη θερινή περίοδο στη χώρα. Υπάρχει πιθανότητα πρόκλησης πυρκαγιάς, αλλά αναμένεται να είναι μέσης δυσκολίας στην αντιμετώπισή της. Επιτρέπονται οι ελεγχόμενες καύσεις, αλλά με μεγάλη προσοχή.
- III. *Υψηλή Κατηγορία Κινδύνου (Κίτρινη)*: Υψηλός κίνδυνος. Υπάρχει πιθανότητα εκδήλωσης πυρκαγιάς που ενδέχεται να λάβει μεγάλες διαστάσεις λόγω έντονων περιβαλλοντικών συνθηκών. Οι ελεγχόμενες καύσεις, αν είναι απαραίτητες, θα πρέπει να περιοριστούν στις πρώτες πρωινές ώρες ή αργά το βράδυ.
- IV. *Πολύ Υψηλή Κατηγορία Κινδύνου (Πορτοκαλί)*: Ιδιαίτερα υψηλός κίνδυνος. Σε περίπτωση πρόκλησης πυρκαγιάς, αυτή θα λάβει μεγάλες διαστάσεις λόγω ακραίων περιβαλλοντικών συνθηκών. Δεν προτείνονται οι καύσεις για οποιοδήποτε λόγο.
- V. *Κατάσταση Συναγερμού (Κόκκινη)*: Ο κίνδυνος είναι ακραίος. Οι περιβαλλοντικές συνθήκες (ισχυρός άνεμος, χαμηλή υγρασία, υψηλή θερμοκρασία) είναι πιθανό να οδηγήσουν σε ανεξέλεγκτη κατάσταση με μεγάλο αριθμό πυρκαγιών ακραίας συμπεριφοράς. Η δυσκολία ελέγχου αναμένεται να είναι πολύ μεγάλη μέχρι να μεταβληθούν οι συνθήκες.

Στον πίνακα που ακολουθεί παρουσιάζεται η αντιστοίχιση των τιμών των βαθμών επικινδυνότητας *SFDI* και *FFDI* με την αντίστοιχη κατηγορία κινδύνου στην οποία εντάσσονται.

Πίνακας IV. Αντιστοίχιση της κατηγορίας κινδύνου εκδήλωσης πυρκαγιάς με τον κάθε βαθμό επικινδυνότητας.


Κατηγορία Κινδύνου	Βαθμός Επικινδυνότητας <i>SFDI</i>	Βαθμός Επικινδυνότητας <i>FFDI</i>
Χαμηλή	[0, 0.7]	[0, 5]
Μέτρια	[0.7, 1.5]	[5, 12]
Υψηλή	[1.5, 2.7]	[12, 24]
Πολύ Υψηλή	[2.7, 6.1]	[24, 50]
Κατάσταση Συναγερμού	> 6.1	[50, 100]

Για την επιλογή του καλύτερου συστήματος αξιολόγησης, πραγματοποιήθηκαν δοκιμές και με τους δύο δείκτες. Παρατηρήθηκε πως σε περιπτώσεις όπου οι τιμές της θερμοκρασίας ήταν υψηλές ( $\geq 30^{\circ}\text{C}$ ) και το ποσοστό της υγρασίας ιδιαίτερα χαμηλό ( $< 30\%$ ), τα αποτελέσματα και από τα δύο συστήματα ήταν πολύ κοντά μεταξύ τους. Από την άλλη πλευρά, σε περιπτώσεις όπου οι τιμές της θερμοκρασίας και της υγρασίας ήταν υψηλές ( $T \geq 30^{\circ}\text{C}$  και  $H > 60\%$ ) ή, αντίθετα, ήταν και οι δύο τιμές χαμηλές ( $T \leq 10^{\circ}\text{C}$  και  $H < 20\%$ ), τα αποτελέσματα των δύο συστημάτων ήταν εντελώς διαφορετικά. Το πρόβλημα παρατηρήθηκε στο δείκτη *SFDI* που ταξινομούσε τα αποτελέσματα σε υψηλές ή πολύ υψηλές κατηγορίες κινδύνου, ενώ στην πραγματικότητα οι πιθανότητες για πρόκληση πυρκαγιάς με τις δεδομένες συνθήκες κυμαίνονταν από ελάχιστες έως μέτριες. Συνεπώς, για τον υπολογισμό του βαθμού επικινδυνότητας επιλέχθηκε ο δείκτης *FFDI*.

### 8.3 Αποστολή Ειδοποιήσεων

Το τελικό στάδιο της υλοποίησης της παρούσας διπλωματικής εργασίας αφορά την αποστολή μηνύματος ειδοποίησης στο χρήστη, σε περίπτωση που ο βαθμός επικινδυνότητας υπολογιστεί ως υψηλός. Για την αποστολή των ειδοποιήσεων χρησιμοποιήθηκε ξανά η πλατφόρμα του ThingSpeak, με τη δημιουργία ενός νέου, δεύτερου καναλιού και την αποστολή τριών επιμέρους reactions μέσω της εφαρμογής του ThingTweet.

Αρχικά, το δεύτερο κανάλι που δημιουργήθηκε παρουσιάζεται στο ακόλουθο σχήμα και το κανάλι περιλαμβάνει μόνο ένα πεδίο, όπου καταγράφεται κάθε φορά ο βαθμός επικινδυνότητας «McArthur Forest Fire Danger Index», όπως αυτός υπολογίζεται από το σύστημα. Ο σύνδεσμος του καναλιού είναι ο εξής: <https://thingspeak.com/channels/1146853>.



Σχήμα 44. Το κανάλι που δημιουργήθηκε για την καταγραφή του βαθμού επικινδυνότητας και την αποστολή των ειδοποιήσεων.

Τέλος, στο Σχήμα 45 παρουσιάζονται ενδεικτικά τρεις ειδοποιήσεις, μία για κάθε κατηγορία κινδύνου, όπως αυτές αποστέλλονται στο χρήστη μέσω της εφαρμογής του Twitter. Τα μηνύματα ειδοποίησης αποστέλλονται μόνο σε περιπτώσεις όταν ο βαθμός επικινδυνότητας  $FFDI \geq 12$ . Επειδή, όμως, δημιουργήθηκαν τρεις διαφορετικές κατηγορίες κινδύνου για τις συγκεκριμένες τιμές του βαθμού επικινδυνότητας, ορίστηκαν σε κάθε περίπτωση και τα αντίστοιχα εύρη τιμών.

Επομένως, όταν η τιμή του *FFDI* είναι εντός του εύρους τιμών [12, 24], τότε αποστέλλεται ειδοποίηση που αντιστοιχεί σε σήμα υψηλού κινδύνου, όπως φαίνεται και στο Σχήμα 45(c). Αντίστοιχα, για τιμές εντός του εύρους [24, 50] αποστέλλεται ειδοποίηση πολύ υψηλού κινδύνου (Σχήμα 45(b)), ενώ ειδοποίηση για την ακραία περίπτωση της κατάστασης συναγερμού (Σχήμα 45(a)) αποστέλλεται όταν η τιμή του *FFDI* ανήκει εντός του συνόλου [50, 100].



Σχήμα 45. Μήνυμα ειδοποίησης συστήματος σε περίπτωση (a) κατάστασης συναγερμού, (b) πολύ υψηλού κινδύνου και (c) υψηλού κινδύνου.



# 9

## Σύνοψη και Συμπεράσματα

Στην παρούσα διπλωματική εργασία έγινε ανάπτυξη ενός «έξυπνου» συστήματος πρόβλεψης πυρκαγιάς, η υλοποίηση της οποίας βασίστηκε τόσο στο υλικό, όσο και στην εύρεση του κατάλληλου μοντέλου τεχνητού νευρωνικού δικτύου για την πρόβλεψη. Το προτεινόμενο ενσωματωμένο σύστημα συλλογής δεδομένων αποτελείται από μια πλακέτα ESP32, έναν αισθητήρα θερμοκρασίας-υγρασίας του περιβάλλοντος (DHT22), έναν αισθητήρα υγρασίας εδάφους (YL-69), καθώς επίσης και έναν αισθητήρα επιπέδου φωτεινότητας (BH1750). Οι μετρήσεις που λήφθηκαν από το σύστημα συνδυάστηκαν με επιπλέον περιβαλλοντικές τιμές ατμοσφαιρικής πίεσης, ταχύτητας και κατεύθυνσης του ανέμου, από το εργαλείο του OpenWeatherMap, και, τέλος, καταγράφηκαν στο ThingSpeak. Συμπληρωματικά, για την εκπαίδευση του μοντέλου χρησιμοποιήθηκε και το Jena Climate dataset.

Το προτεινόμενο Stacked LSTM μοντέλο δύο κατευθύνσεων (Bidirectional Stacked LSTM) αναπτύχθηκε χρησιμοποιώντας τη μέθοδο της επιβλεπόμενης μάθησης, με στόχο την πρόβλεψη των τριών σημαντικότερων μεταβλητών που επηρεάζουν την εκδήλωση πυρκαγιάς, βάσει ενός συνόλου δεδομένων. Διαθέτει την ικανότητα να εντοπίζει συσχετίσεις μεταξύ των δεδομένων εκπαίδευσής του, ώστε να οδηγείται στο τελικό αποτέλεσμα πρόβλεψης. Τα αποτελέσματα χρήσης του δείχνουν ότι μπορεί να προβλέψει τιμές για τις επόμενες 12 ώρες της ημέρας με μεγάλη ακρίβεια βασιζόμενο σε προηγούμενες τιμές, οι οποίες περιλαμβάνονται στο σύνολο δεδομένων.

Παράλληλα, η επιλογή και η χρήση του δείκτη «McArthur Forest Fire Danger Index» ως βαθμού επικινδυνότητας συνδυάζει τις τιμές που προβλέπονται από το μοντέλο, με τρόπο κατάλληλο ώστε το αποτέλεσμα να είναι έγκυρο. Ως εκ τούτου, και σε συνδυασμό με την αποστολή ειδοποιήσεων ενημέρωσης, το τελικό προτεινόμενο σύστημα καθίσταται ιδιαίτερα χρήσιμο και αποτελεσματικό για την έγκαιρη πρόβλεψη και προειδοποίηση δασικών πυρκαγιών.

## Βιβλιογραφία

- [1] M. H. Asghar, A. Negi, and N. Mohammadzadeh, “Principle application and vision in Internet of Things (IoT),” in *International Conference on Computing, Communication & Automation*, 2015, pp. 427–431.
- [2] R. C. Shit, S. Sharma, D. Puthal, and A. Y. Zomaya, “Location of Things (LoT): A review and taxonomy of sensors localization in IoT infrastructure,” *IEEE Commun. Surv. Tutorials*, vol. 20, no. 3, pp. 2028–2061, 2018.
- [3] I. F. Akyildiz, W. Su, Y. Sankarasubramaniam, and E. Cayirci, “Wireless sensor networks: a survey,” *Comput. networks*, vol. 38, no. 4, pp. 393–422, 2002.
- [4] D. Grace, Asplund, Ely, Intorf, “The Osborne fire finder and basic lookout tools: Fireman guide California Region,” 2013.
- [5] D. Miorandi, S. Sicari, F. De Pellegrini, and I. Chlamtac, “Internet of things: Vision, applications and research challenges,” *Ad hoc networks*, vol. 10, no. 7, pp. 1497–1516, 2012.
- [6] Y. Li, J. Yi, X. Zhu, Z. Wang, and F. Xu, “Developing a fire monitoring and control system based on IoT,” in *2016 2nd International Conference on Artificial Intelligence and Industrial Engineering (AIIE 2016)*, 2016.
- [7] J. G. Cantuna, D. Bastidas, S. Solórzano, and J.-M. Clairand, “Design and implementation of a Wireless Sensor Network to detect forest fires,” in *2017 Fourth international conference on eDemocracy & eGovernment (ICEDEG)*, 2017, pp. 15–21.
- [8] A. K. Sharma, M. F. R. Ansari, M. F. Siddiqui, and M. A. Baig, “IOT enabled forest fire detection and online monitoring system,” *Int. J. Curr. Trends Eng. Res.(IJCTER)*, vol. 3, pp. 50–54, 2017.
- [9] R. Shinde, R. Pardeshi, A. Vishwakarma, and N. Barhate, “Need for wireless fire detection systems using IOT,” *Int Res J Eng Technol*, vol. 4, no. 1, 2017.
- [10] F. Saeed, A. Paul, A. Rehman, W. H. Hong, and H. Seo, “IoT-based intelligent modeling of smart home environment for fire prevention and safety,” *J. Sens. Actuator Networks*, vol. 7, no. 1, p. 11, 2018.
- [11] R. Sowah, K. O. Ampadu, A. Ofoli, K. Koumadi, G. A. Mills, and J. Nortey, “Design and implementation of a fire detection and control system for automobiles using fuzzy logic,” in *2016 IEEE industry applications society annual meeting*, 2016, pp. 1–8.
- [12] E. Mackensen, M. Lai, and T. M. Wendt, “Bluetooth Low Energy (BLE) based wireless sensors,” in *SENSORS, 2012 IEEE*, 2012, pp. 1–4.
- [13] C. Gomez, J. Oller, and J. Paradells, “Overview and evaluation of bluetooth low energy: An emerging low-power wireless technology,” *Sensors*, vol. 12, no. 9, pp. 11734–11753, 2012.
- [14] D. Gislason, *Zigbee wireless networking*. Newnes, 2008.
- [15] T. Yokotani and Y. Sasaki, “Comparison with HTTP and MQTT on required network resources for IoT,” in *2016 international conference on control, electronics, renewable energy and*

- communications (ICCEREC)*, 2016, pp. 1–6.
- [16] R. Fielding *et al.*, “Hypertext transfer protocol–HTTP/1.1,” 1999.
- [17] U. Hunkeler, H. L. Truong, and A. Stanford-Clark, “MQTT-S—A publish/subscribe protocol for Wireless Sensor Networks,” in *2008 3rd International Conference on Communication Systems Software and Middleware and Workshops (COMSWARE’08)*, 2008, pp. 791–798.
- [18] K. Gurney, *An introduction to neural networks*. CRC press, 1997.
- [19] Y. Safi and A. Bouroumi, “Prediction of forest fires using artificial neural networks,” *Appl. Math. Sci.*, vol. 7, no. 6, pp. 271–286, 2013.
- [20] D. K. Chaturvedi, “Artificial neural network and supervised learning,” *Soft Comput. Tech. its Appl. Electr. Eng.*, pp. 23–50, 2008.
- [21] “7 Types of Neural Network Activation Functions: How to Choose?,” *missinglink.ai*. [Online]. Available: <https://missinglink.ai/guides/neural-network-concepts/7-types-neural-network-activation-functions-right/>.
- [22] J. Pawan, “Complete Guide of Activation Functions,” *Towar. Data Sci.*, 2019.
- [23] S. S. Haykin, “Neural networks and learning machines/Simon Haykin.” New York: Prentice Hall, 2009.
- [24] J. Brownlee, “What is the Difference Between Test and Validation Datasets?,” 2017.
- [25] “Perceptrons and Multi-Layer Perceptrons: The Artificial Neuron at the Core of Deep Learning.”
- [26] Y. Upadhyay, “Introduction to FeedForward Neural Networks,” *Towar. Data Sci.*, 2019.
- [27] M. Venkatachalam, “Recurrent Neural Networks,” *Towar. Data Sci.*, 2019.
- [28] Colah, “Understanding LSTM Networks,” 2015. [Online]. Available: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/>.
- [29] K. A. Althelaya, E.-S. M. El-Alfy, and S. Mohammed, “Evaluation of bidirectional lstm for short-and long-term stock market prediction,” in *2018 9th international conference on information and communication systems (ICICS)*, 2018, pp. 151–156.
- [30] S. Kostadinov, “Understanding GRU Networks,” *Towar. Data Sci.*, 2017.
- [31] W. Badr, “Auto-Encoder: What Is It? And What Is It Used For? (Part 1),” *Towar. Data Sci.*, 2019.
- [32] J. V Tu, “Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes,” *J. Clin. Epidemiol.*, vol. 49, no. 11, pp. 1225–1231, 1996.
- [33] Espressif, “ESP32 Overview.” [Online]. Available: <https://www.espressif.com/en/products/hardware/esp32/overview>.
- [34] Espressif Systems, “ESP32 Datasheet.” [Online]. Available: <https://lastminuteengineers.com/datasheets/esp32-datasheet-en.pdf>.
- [35] “DHT22 Temperature and Humidity Sensor.” [Online]. Available: <https://makeradvisor.com/tools/dht22-temperature-humidity-sensor/>.

- [36] R. C. Brito, F. Favarim, G. Calin, and E. Todt, “Development of a low cost weather station using free hardware and software,” in *2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR)*, 2017, pp. 1–6.
- [37] baseline, “Soil Moisture Sensors - Technical Specifications.” [Online]. Available: <https://www.baselinesystems.com/mediafiles/pdf/SensorSpec.pdf>.
- [38] Sunfounder, “GY-30 Digital Light Intensity Measuring Module.” [Online]. Available: [http://wiki.sunfounder.cc/index.php?title=GY-30\\_Digital\\_Light\\_Intensity\\_Measuring\\_Module](http://wiki.sunfounder.cc/index.php?title=GY-30_Digital_Light_Intensity_Measuring_Module).
- [39] M. A. G. Maureira, D. Oldenhof, and L. Teernstra, “ThingSpeak—an API and Web Service for the Internet of Things,” *World Wide Web*, 2011.
- [40] S. Pasha, “ThingSpeak based sensing and monitoring system for IoT with Matlab Analysis,” *Int. J. New Technol. Res.*, vol. 2, no. 6, 2016.
- [41] C. Dewi and R.-C. Chen, “Integrating Real-Time Weather Forecasts Data Using OpenWeatherMap and Twitter,” *Int. J. Inf. Technol. Bus.*, vol. 1, no. 2, pp. 48–52, 2019.
- [42] Wikipedia, “TensorFlow.” [Online]. Available: <https://en.wikipedia.org/wiki/TensorFlow>.
- [43] A. Rosebrock, “Keras vs. TensorFlow,” 2018. [Online]. Available: <https://www.pyimagesearch.com/2018/10/08/keras-vs-tensorflow-which-one-is-better-and-which-one-should-i-learn/>.
- [44] P. Rathore, A. S. Rao, S. Rajasegarar, E. Vanz, J. Gubbi, and M. Palaniswami, “Real-time urban microclimate analysis using internet of things,” *IEEE Internet Things J.*, vol. 5, no. 2, pp. 500–511, 2017.
- [45] A. Buyantuyev and J. Wu, “Urban heat islands and landscape heterogeneity: linking spatiotemporal variations in surface temperatures to land-cover and socioeconomic patterns,” *Landsc. Ecol.*, vol. 25, no. 1, pp. 17–33, 2010.
- [46] S. Tozlu, M. Senel, W. Mao, and A. Keshavarzian, “Wi-Fi enabled sensors for internet of things: A practical approach,” *IEEE Commun. Mag.*, vol. 50, no. 6, pp. 134–143, 2012.
- [47] S. Tozlu, “Experimental Study of Security Impact on Battery Lifetime for Low-Power Wi-Fi Systems,” in *Wireless Congress*, 2010.
- [48] G. P. Zhang, B. E. Patuwo, and M. Y. Hu, “A simulation study of artificial neural networks for nonlinear time-series forecasting,” *Comput. Oper. Res.*, vol. 28, no. 4, pp. 381–396, 2001.
- [49] S. Brown, R. Tauler, and B. Walczak, *Comprehensive chemometrics: chemical and biochemical data analysis*. Elsevier, 2020.
- [50] C. Chandler, P. Cheney, P. Thomas, L. Trabaud, and D. Williams, *Fire in forestry. Volume 1. Forest fire behavior and effects. Volume 2. Forest fire management and organization*. John Wiley & Sons, Inc., 1983.
- [51] N. Hamadeh, A. Karouni, B. Daya, and P. Chauvet, “Using correlative data analysis to develop weather index that estimates the risk of forest fires in Lebanon & Mediterranean: Assessment versus prevalent meteorological indices,” *Case Stud. Fire Saf.*, vol. 7, pp. 8–22, 2017.
- [52] J. J. Sharples, R. H. D. McRae, R. O. Weber, and A. M. Gill, “A simple index for assessing fire danger rating,” *Environ. Model. Softw.*, vol. 24, no. 6, pp. 764–774, 2009.

- [53] I. R. Noble, A. M. Gill, and G. A. V Bary, “McArthur’s fire-danger meters expressed as equations,” *Aust. J. Ecol.*, vol. 5, no. 2, pp. 201–203, 1980.
- [54] N. W. Service, “Spring Burning - Learn Before You Burn.” [Online]. Available: <https://www.weather.gov/riw/agburning>.
- [55] Γενική Γραμματεία Πολιτικής Προστασίας, “Ημερήσιος Χάρτης Πρόβλεψης Κινδύνου Πυρκαγιάς.” [Online]. Available: [http://www.patt.gov.gr/site/index.php?option=com\\_content&view=article&id=31635:imerisios-xartis-provlepsi-kindynou-pyrkagias-2&catid=337&Itemid=375](http://www.patt.gov.gr/site/index.php?option=com_content&view=article&id=31635:imerisios-xartis-provlepsi-kindynou-pyrkagias-2&catid=337&Itemid=375).