


ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ
ΚΑΙ ΗΛΕΚΤΡΟΝΙΚΩΝ ΣΥΣΤΗΜΑΤΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

«Τεχνικές μηχανικής μάθησης στη σχεδίαση και εφαρμογή διαμορφώσιμων
έξυπνων επιφανειών RIS σε συστήματα ασύρματων επικοινωνιών»



Του φοιτητή
Χαράλαμπος Πασχάλης
Αρ. Μητρώου: 21/2023

Επιβλέπων
Αθανάσιος Ιωσηφίδης
Αναπληρωτής Καθηγητής

Ημερομηνία 25/06/2025

Τίτλος Δ.Ε. Τεχνικές μηχανικής μάθησης στη σχεδίαση και εφαρμογή διαμορφώσιμων
έξυπνων επιφανειών RIS σε συστήματα ασύρματων επικοινωνιών

Κωδικός Δ.Ε. 24216

Όνοματεπώνυμο φοιτητή/των Χαράλαμπος Πασχάλης

Όνοματεπώνυμο εισηγητή Αθανάσιος Ιωσηφίδης

Ημερομηνία ανάληψης Δ.Ε. 28/10/2024

Ημερομηνία περάτωσης Δ.Ε. 01/06/2025

Βεβαιώνω ότι είμαι ο συγγραφέας αυτής της εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, έχω καταγράψει τις όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών, εικόνων και κειμένου, είτε αυτές αναφέρονται ακριβώς είτε παραφρασμένες. Επιπλέον, βεβαιώνω ότι αυτή η εργασία προετοιμάστηκε από εμένα προσωπικά, ειδικά ως διπλωματική εργασία, στο Τμήμα Μηχανικών Πληροφορικής και Ηλεκτρονικών Συστημάτων του ΔΙ.ΠΑ.Ε.

Η παρούσα εργασία αποτελεί πνευματική ιδιοκτησία του φοιτητή Χαράλαμπου Πασχάλη που την εκπόνησε/αν. Στο πλαίσιο της πολιτικής ανοικτής πρόσβασης, ο συγγραφέας/δημιουργός εκχωρεί στο Διεθνές Πανεπιστήμιο της Ελλάδος άδεια χρήσης του δικαιώματος αναπαραγωγής, δανεισμού, παρουσίασης στο κοινό και ψηφιακής διάχυσης της εργασίας διεθνώς, σε ηλεκτρονική μορφή και σε οποιοδήποτε μέσο, για διδακτικούς και ερευνητικούς σκοπούς, άνευ ανταλλάγματος. Η ανοικτή πρόσβαση στο πλήρες κείμενο της εργασίας, δεν σημαίνει καθ' οιονδήποτε τρόπο παραχώρηση δικαιωμάτων διανοητικής ιδιοκτησίας του συγγραφέα/δημιουργού, ούτε επιτρέπει την αναπαραγωγή, αναδημοσίευση, αντιγραφή, πώληση, εμπορική χρήση, διανομή, έκδοση, μεταφόρτωση (downloading), ανάρτηση (uploading), μετάφραση, τροποποίηση με οποιονδήποτε τρόπο, τμηματικά ή περιληπτικά της εργασίας, χωρίς τη ρητή προηγούμενη έγγραφη συναίνεση του συγγραφέα/δημιουργού.

Η έγκριση της διπλωματικής εργασίας από το Τμήμα Μηχανικών Πληροφορικής και Ηλεκτρονικών Συστημάτων του Διεθνούς Πανεπιστημίου της Ελλάδος, δεν υποδηλώνει απαραίτητως και αποδοχή των απόψεων του συγγραφέα, εκ μέρους του Τμήματος.

Πρόλογος

Ο κλάδος των τηλεπικοινωνιών εξελίσσεται ραγδαία, με τεχνολογίες όπως το 5G, το Internet of Things (IoT) και τα δίκτυα οπτικών ινών να αλλάζουν ριζικά τον τρόπο με τον οποίο επικοινωνούμε. Η έρευνα σε μια καινοτομία όπως είναι οι έξυπνες επαναδιαμορφώσιμες επιφάνειες μπορεί να οδηγήσει σε βελτίωση της ταχύτητας, της αξιοπιστίας και της προσβασιμότητας των υπηρεσιών επικοινωνίας.

Επιπλέον, η κατανόηση και η ανάπτυξη νέων τεχνολογιών μπορεί να συμβάλει στην αντιμετώπιση προκλήσεων όπως η κάλυψη απομακρυσμένων περιοχών, η μείωση του ψηφιακού χάσματος και η ενεργειακή αποδοτικότητα των υποδομών. Τέλος, η έρευνα σε αυτό το τομέα προσφέρει τη δυνατότητα επαγγελματικής εξέλιξης και συμβολής στην επιστημονική γνώση, ενώ παράλληλα ενισχύει την καινοτομία σε ένα τομέα που επηρεάζει άμεσα την κοινωνία και την οικονομία.

Η ενασχόληση με μια τεχνολογική καινοτομία στις τηλεπικοινωνίες δεν αφορά μόνο την τεχνική πρόοδο και την προσωπική εξέλιξη, αλλά και τη βελτίωση της καθημερινής ζωής εκατομμυρίων ανθρώπων.

Περίληψη

Μία από τις βασικές τεχνολογίες που αναμένεται να υποστηρίξουν τις μελλοντικές ασύρματες επικοινωνίες και να βελτιώσουν σημαντικά τη φασματική τους απόδοση, είναι τα συστήματα πολλαπλών κεραιών, ή πολλαπλών εισόδων – πολλαπλών εξόδων (MIMO) όπως συνήθως αποκαλούνται. Αν και ιδιαίτερα αποδοτικά, τα συστήματα MIMO που χρησιμοποιούνται για κατευθυνόμενη ακτινοβολία παρουσιάζουν υψηλό ενεργειακό κόστος και απαιτούν σύνθετο υλικό.

Σε αυτό το πλαίσιο, οι Έξυπνες Επαναδιαμορφώσιμες Επιφάνειες (Reconfigurable Intelligent Surfaces – RIS), ή μεταεπιφάνειες, έχουν αναδυθεί ως μια σημαντική οικολογική τεχνολογία για τα μελλοντικά δίκτυα κινητής τηλεφωνίας 6ης γενιάς (6G). Αυτές αποτελούν τεχνητές διδιάστατες δομές με ενσωματωμένα ηλεκτρονικά στοιχεία, που μπορούν να προγραμματιστούν για τον έλεγχο των προσπιπτόντων ηλεκτρομαγνητικών κυμάτων με διάφορους τρόπους. Οι επιφάνειες αυτές μπορούν να τροποποιούν δυναμικά τις χαρακτηριστικές τους ιδιότητες, ώστε να κατευθύνουν την ακτινοβολία σε συγκεκριμένες κατευθύνσεις στο χώρο.

Οι RIS μπορούν να λειτουργήσουν επίσης ως συσκευές του Διαδικτύου των Πραγμάτων (IoT), επιτρέποντας την αλληλεπίδραση με το περιβάλλον και το δίκτυο σε πραγματικό χρόνο. Με αυτόν τον τρόπο, ενισχύουν τη συνδεσιμότητα, μειώνουν την κατανάλωση ενέργειας και υποστηρίζουν την υλοποίηση έξυπνων ασύρματων υποδομών.

Η παρούσα διπλωματική εργασία επικεντρώνεται στη βελτιστοποίηση των ρυθμίσεων των RIS, με στόχο την ενίσχυση του ανακλώμενου σήματος προς τον δέκτη. Αναπτύχθηκε αλγόριθμος υπολογισμού της ισχύος του εισερχόμενου κύματος, τα αποτελέσματα του οποίου μεταφράστηκαν σε γεωμετρικά χαρακτηριστικά μιας ιδανικής επιφάνειας. Με τη χρήση τεχνικών βαθιάς μάθησης και την βιβλιοθήκη Pytorch της γλώσσας προγραμματισμού Python, εντοπίστηκαν βελτιωμένες διαμορφώσεις που προσφέρουν μέγιστη απόδοση σε εύλογο χρόνο.

Από τα αποτελέσματα της ανάλυσης διαπιστώθηκε ότι οι τεχνικές βαθιάς μάθησης όπως η Feedforward Neural Network φαίνεται να είναι οι πλέον αποδοτικές για μικρά και μεσαία προβλήματα λόγω ταχύτητας και καλής ακρίβειας. Το Convolutional Neural Network αποδείχθηκε ότι υπερέρχει σε προβλήματα μικρής πολυπλοκότητας με χωρικά χαρακτηριστικά, αλλά με υψηλότερο υπολογιστικό κόστος, ενώ το Recurrent Neural Network διαπιστώθηκε ότι είναι κατάλληλο για διαδοχικά δεδομένα, με καλή γενίκευση και απόδοση, αλλά αυξημένο χρόνο εκπαίδευσης.

Η αξιοποίηση των RIS δεν περιορίζεται μόνο σε θεωρητικά μοντέλα, αλλά επεκτείνεται και σε πρακτικά σενάρια, όπως η ενίσχυση σήματος σε αστικές περιοχές με πολλά εμπόδια, η βελτίωση της κάλυψης σε εσωτερικούς χώρους ή η υποστήριξη συνδεσιμότητας σε περιβάλλοντα με χαμηλή ενεργειακή διαθεσιμότητα. Ως εκ τούτου, αποτελούν κρίσιμο κρίκο στην εξέλιξη των έξυπνων, ευέλικτων και βιώσιμων ασύρματων δικτύων του μέλλοντος.

« Machine learning techniques in the design and implementation of
configurable RIS smart surfaces in wireless communication systems»
(στην αγγλική γλώσσα)

«Charalampos Paschalis»

(στην αγγλική γλώσσα)

Abstract

One of the key technologies expected to support future wireless communications and significantly improve their spectral efficiency is the use of multiple antennas, or Multiple Input – Multiple Output (MIMO) systems, as they are often called. Although highly efficient, MIMO systems used for directional beamforming involve high energy consumption and require complex hardware.

In this context, Reconfigurable Intelligent Surfaces (RIS), also known as metasurfaces, have emerged as a promising green technology for next-generation (6G) mobile communication networks. These are artificial, two-dimensional structures with embedded electronic components, which can be programmed to control incoming electromagnetic waves in various ways. These surfaces are capable of dynamically altering their properties to steer radiation toward specific directions.

RIS can also function as Internet of Things (IoT) devices, enabling real-time interaction with the surrounding environment and the network. In doing so, they enhance connectivity, reduce energy consumption, and contribute to the development of intelligent wireless infrastructures.

This thesis focuses on the optimization of RIS configuration settings with the goal of maximizing the reflected signal power toward the receiver. A power estimation algorithm was developed to evaluate the strength of the incoming electromagnetic wave, the results of which were translated into geometric parameters of an ideal RIS surface. Subsequently, deep learning techniques were employed to identify improved configurations that achieve optimal performance within efficient timeframes.

The analysis results showed that deep learning techniques such as the Feedforward Neural Network appear to be the most efficient for small and medium-sized problems due to their speed and good accuracy. The Convolutional Neural Network was found to excel in problems of low complexity with spatial features, albeit with higher computational cost, while the Recurrent Neural Network proved suitable for sequential data, offering good generalization and performance, though with increased training time.

The utilization of RIS extends beyond theoretical models and finds applications in real-world scenarios, such as signal enhancement in urban environments with significant obstructions, coverage improvement in indoor spaces, or connectivity support in low-energy settings. As such, RIS represent a crucial element in the evolution of intelligent, flexible, and sustainable wireless communication networks of the future.

Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον κ. Αθανάσιο Ιωσηφίδη, Αναπληρωτή καθηγητή του Τμήματος Μηχανικών Πληροφορικής και Ηλεκτρονικών Συστημάτων του ΔΙ.ΠΑ.Ε για τη στήριξη και τη βοήθεια που επέδειξε στην εκπόνηση αυτής της Διπλωματικής Εργασίας, καθώς και τον κ. Τραϊανό Γιούλτση καθηγητή του τμήματος Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Α.Π.Θ. για την επιστημονική υποστήριξη.

Ολοκληρώνοντας, θα ήθελα να εκφράσω την ειλικρινή μου ευγνωμοσύνη προς τη σύζυγό μου και τα παιδιά μου, για τη συνεχή στήριξη και ενθάρρυνσή τους καθ' όλη τη διάρκεια των σπουδών μου.

Περιεχόμενα

Πρόλογος.....	v
Περίληψη.....	vi
Abstract	vii
Ευχαριστίες	viii
Περιεχόμενα	ix
Κατάλογος Εικόνων / Σχημάτων.....	xi
Κατάλογος Πινάκων.....	xii
Συντομογραφίες.....	xiii
Κεφάλαιο 1ο: Εισαγωγή.....	1
1.1 Εισαγωγή.....	1
1.2 Τι είναι RIS	3
1.3 Δισδιάστατη δομή	4
1.4 Έξυπνες επιφάνειες	4
Μεγάλες έξυπνες επιφάνειες	5
Έξυπνες ανακλαστικές επιφάνειες	5
Ψηφιακά ελεγχόμενοι σκεδαστές.....	5
Επιφάνειες ελεγχόμενες από λογισμικό	5
1.5 Μεταεπιφάνειες.....	6
1.6 Τα πρωτότυπα του MIT και της DOCOMO NTT.....	6
1.7 Σχετικές εργασίες	7
1.8 Επιμέρους Στόχοι / Μεθοδολογία	9
Οργάνωση	10
1.9 Επίλογος.....	10
Κεφάλαιο 2ο: Ανάπτυξη αλγορίθμου υπολογισμού της ισχύος λήψης σε μία έξυπνη επαναδιαμορφώσιμη επιφάνεια (RIS).....	11
2.1 Εισαγωγή.....	11
2.2 Ισοζύγιο ισχύος ζεύξης (Link Budget)	11
Παράδειγμα Ασύρματης Επικοινωνίας με RIS	12
Διατομή σκέδασης ραντάρ (Radar Cross Section, RCS)	13
2.3 Θεωρητικός υπολογισμός φάσης.....	15
Αλγόριθμος υπολογισμού της ισχύος λήψης.....	16
2.4 Υλοποίηση του αλγορίθμου	17

2.5	Αποτελέσματα	22
2.6	Επίλογος	23
Κεφάλαιο 3ο:	Τεχνικές μηχανικής μάθησης και σχεδίαση επιφάνειας RIS	25
3.1	Εισαγωγή	25
3.2	Μηχανική Μάθηση και Νευρωνικά Δίκτυα	26
	Τεχνικές Μηχανικής Μάθησης	26
	Βαθιά Μάθηση και Αντίστροφος Σχεδιασμός RIS	27
3.3	Αρχιτεκτονικές Νευρωνικών Δικτύων	27
	Feedforward Neural Network (FFNN)	27
	Convolutional Neural Network (CNN)	28
	Recurrent Neural Networks (RNN)	29
3.4	Αλγόριθμος δημιουργίας του dataset	30
	Αλγόριθμος δημιουργίας του dataset	30
	Υλοποίηση αλγορίθμου 2 και δημιουργία του dataset	31
3.5	Σχεδίαση RIS	33
3.5.1	Σχεδίαση RIS με FFNN	34
3.5.2	Σχεδίαση RIS με CNN	37
3.5.3	Σχεδίαση RIS με RNN	38
3.6	Επίλογος	39
Κεφάλαιο 4ο:	Αποτελέσματα τεχνικών μηχανικής μάθησης για την σχεδίαση RIS	41
4.1	Εισαγωγή	41
	Αποτελέσματα αρχιτεκτονικής FFNN για συνδυασμούς χωρητικότητας 4 στοιχείων	41
	Αποτελέσματα αρχιτεκτονικής FFNN για συνδυασμούς χωρητικότητας 8 στοιχείων	45
	Συγκριτικά συμπεράσματα για αποτελέσματα τύπου FFNN	48
	Αποτελέσματα αρχιτεκτονικής CNN για συνδυασμούς χωρητικότητας 4 και 8 στοιχείων	50
	Αρχιτεκτονική RNN για συνδυασμούς χωρητικότητας 4 στοιχείων	54
	Αρχιτεκτονική RNN για συνδυασμούς χωρητικότητας 8 στοιχείων	57
4.2	Συγκριτικά συμπεράσματα αποτελεσμάτων αρχιτεκτονικών FFNN, CNN, RNN	61
4.3	Επίλογος	63
Κεφάλαιο 5ο:	Συμπεράσματα ή/και προτάσεις βελτίωσης	65
	BIBΛΙΟΓΡΑΦΙΑ	67
	ΠΑΡΑΡΤΗΜΑ: ΑΠΟΤΕΛΕΣΜΑΤΑ	71

Κατάλογος Εικόνων / Σχημάτων

Εικόνα 1.1: Συγκλίνουσες ισοφασικές επιφάνειες	4
Εικόνα 1.2: Εννοιολογική δομή μιας έξυπνης επιφάνειας αναδιαμόρφωσης	5
Εικόνα 1.3: Το πρωτότυπο RFocus το MIT	6
Εικόνα 1.4: Το πρωτότυπο NTT της DOCOMO	7
Εικόνα 2.1: Ασύρματη ζεύξη επικοινωνίας με υποβοήθηση RIS	11
Εικόνα 2.2: Διάγραμμα ροής αλγορίθμου	17
Εικόνα 2.3: Μονάδα κελιού μορφής Jerusalem Cross	18
Εικόνα 2.4: Πλάτος και φάση του συντελεστή ανάκλασης	18
Εικόνα 2.5: Σενάριο ανώμαλης ανάκλασης ενός transverse electric πολωμένου επιπέδου κύματος	19
Εικόνα 2.6: Σχηματική απεικόνιση της περιοχής πλήρους κυματικής προσομοίωσης RIS.....	21
Εικόνα 2.7: Σενάριο ανώμαλης ανάκλασης. Πόλωση εγκάρσιου ηλεκτρικού πεδίου (TE) και πόλωση εγκάρσιου μαγνητικού πεδίου (TM).....	21
Εικόνα 2.8: Κατανομή της ισχύος λήψης για διαφορετικές γωνίες ανάκλασης και αριθμού μονάδων κυψελών ανά supercell	22
Εικόνα 2.9: Διαγράμματα της κατευθυντικότητας για διαφορετικές γωνίες ανάκλασης και αριθμού μονάδων κυψελών ανά supercell	22
Εικόνα 3.1: Δομή Feedforward Neural Network	28
Εικόνα 3.2: Δομή Feedforward Neural Network της εφαρμογής	33
Εικόνα 3.3: Flow Chart εφαρμογής του Convolutional Neural Network	36
Εικόνα 3.4: Flow Chart εφαρμογής του Recurrent Neural Network	38
Εικόνα 4.1: Γράφημα απεικόνισης του Training Loss και Validation Loss με 32 νευρώνες	44
Εικόνα 4.2: Διαγράμματα σύγκλισης και κατευθυντικότητας της ισχύος λήψης για FFNN 56°	49
Εικόνα 4.3: Διαγράμματα σύγκλισης και κατευθυντικότητας της ισχύος λήψης για FFNN 65°	49
Εικόνα 4.4: Διαγράμματα σύγκλισης και κατευθυντικότητας της ισχύος λήψης για CNN 65°	53
Εικόνα 4.5: Διαγράμματα σύγκλισης και κατευθυντικότητας της ισχύος λήψης για CNN 56°	53
Εικόνα 4.6: Διαγράμματα σύγκλισης και κατευθυντικότητας της ισχύος λήψης για RNN 65°	57
Εικόνα 4.7: Διαγράμματα σύγκλισης και κατευθυντικότητας της ισχύος λήψης για RNN 65°	61

Κατάλογος Πινάκων

Πίνακας 2.1: Πλήθος μονάδων κελιών ανά supercell για διαφορετικές γωνίες ανάκλασης	20
Πίνακες 4.1a - 4.1e Αποτελέσματα που αφορούν 400000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικοτήτων στις 56° για FFNN.....	41 - 42
Πίνακες 4.2a - 4.2e Αποτελέσματα που αφορούν 400000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικοτήτων στις 65° για FFNN	42 - 43
Πίνακας 4.3: Καλύτερα αποτελεσμάτα ανά μέγεθος κρυφού επιπέδου για συνδυασμούς χωρητικοτήτων 4 στοιχείων για FFNN	45
Πίνακες 4.4a - 4.4c Αποτελέσματα που αφορούν 200000 στοιχεία στην είσοδο του NN από συνδυασμό 8 χωρητικοτήτων στις 56° για FFNN	45 - 46
Πίνακες 4.5a - 4.5c Αποτελέσματα που αφορούν 200000 στοιχεία στην είσοδο του NN από συνδυασμό 8 χωρητικοτήτων στις 65° για FFNN	46
Πίνακας 4.6: Καλύτερα αποτελεσμάτα ανά μέγεθος κρυφού επιπέδου για συνδυασμούς χωρητικοτήτων 8 στοιχείων για FFNN	47
Πίνακες 4.7a - 4.7c Αποτελέσματα που αφορούν 200000 και 400000 στοιχεία στην είσοδο του NN από συνδυασμό 8 και 4 χωρητικοτήτων στις 65° και 56° για CNN.....	50 - 51
Πίνακας 4.8: Καλύτερα αποτελεσμάτα ανά μέγεθος κρυφού επιπέδου για συνδυασμούς χωρητικοτήτων 4 στοιχείων για CNN	52
Πίνακες 4.9a - 4.9c Αποτελέσματα που αφορούν 400000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικοτήτων στις 56° για RNN	54
Πίνακες 4.10a - 4.10c Αποτελέσματα που αφορούν 400000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικοτήτων στις 65° για RNN	55
Πίνακας 4.11: Καλύτερα αποτελεσμάτα ανά μέγεθος κρυφού επιπέδου για συνδυασμούς χωρητικοτήτων 4 στοιχείων για RNN.....	57
Πίνακες 4.12a - 4.12c Αποτελέσματα που αφορούν 200000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικοτήτων στις 56° για RNN	58
Πίνακες 4.13a - 4.13c Αποτελέσματα που αφορούν 200000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικοτήτων στις 65° για RNN	58 - 59
Πίνακας 4.14: Καλύτερα αποτελεσμάτα ανά μέγεθος κρυφού επιπέδου για συνδυασμούς χωρητικοτήτων 8 στοιχείων για RNN	60

Συντομογραφίες

MIMO	Multiple-Input and Multiple-Output
RIS	Reconfigurable Intelligent Surfaces
IoT	Internet of Things
RF	Radio Frequency
CSI	Channel State Information
ML	Machine Learning
AI	Artificial Intelligence
DL	Deep Learning
WMMSE	Weighted Minimum Mean Squared Error
CNN	Convolutional Neural Network
DNN	Deep Neural Network
RSSI	Received Signal Strength Indicator
TDS	Training Data Set
RCS	Radar Cross Section
ANN	Artificial Neural Network
PNN	Prediction Neural Networks
FFNN	Feedforward Neural Network
RNN	Recurrent neural network
NN	Neural Network
LSTM	Long Short-Term Memory
ABF	Analogue Beamforming
MSE	Mean Squared Error
RMSE	Root Mean Square Error
CV Loss	Cross Validation Loss

Κεφάλαιο 1ο: Εισαγωγή

1.1 Εισαγωγή

Οι πρώτες γενιές ασύρματων δικτύων βασίστηκαν στην παραδοχή ότι το περιβάλλον λειτουργίας των ασύρματων συσκευών είναι σταθερό, καθοριζόμενο από τη γεωμετρία και τις συνθήκες του χώρου, χωρίς δυνατότητα τροποποίησης. Για να αντιμετωπιστούν οι προκλήσεις που προέκυπταν, αναπτύχθηκαν προηγμένα συστήματα μετάδοσης και λήψης. Ωστόσο, η βελτίωση της απόδοσης αποκλειστικά μέσω της προσαρμογής των τερματικών συσκευών μπορεί να μην είναι πλέον αρκετή για να καλύψει τις απαιτήσεις των μελλοντικών δικτύων. Η έκτη γενιά δικτύων αναμένεται να εισαγάγει μια νέα αρχιτεκτονική, η οποία θα συνδυάζει επικοινωνία, ανίχνευση και εντοπισμό, προσφέροντας ταυτόχρονα εξαιρετική απόδοση, ελάχιστη καθυστέρηση και υψηλή αξιοπιστία, με δυνατότητα δυναμικής προσαρμογής σε πραγματικό χρόνο [1].

Οι εταιρείες κινητής τηλεφωνίας ξεκίνησαν να υλοποιούν παγκοσμίως από το 2019 την τεχνολογία 5ης γενιάς (5G) για ευρυζωνικά κυψελωτά δίκτυα. Οι ταχύτητές της κυμαίνονται από περίπου 50 Mbps έως 1 Gbps ή και υψηλότερα στις ανώτερες ζώνες συχνοτήτων. Οι μέγιστες ταχύτητες 5G επιτυγχάνονται στις ζώνες χιλιοστομετρικών κυμάτων (mmWave), όπου τα μήκη κύματος κυμαίνονται μεταξύ 1 και 10 χιλιοστών, φτάνοντας έως και 4 Gbps, ανάλογα με τον τύπο του καναλιού ραδιοσυχνοτήτων (Radio Frequency - RF) και το φορτίο του σταθμού βάσης [2].

Η ζώνη των χιλιοστομετρικών κυμάτων αναφέρεται στο φάσμα ραδιοσυχνοτήτων που εκτείνεται από 30 έως 300 GHz στο ηλεκτρομαγνητικό πεδίο. Βρίσκεται ανάμεσα στη ζώνη υπερυψηλών συχνοτήτων (SHF) και στη μακρινή περιοχή του υπέρυθρου φάσματος, με το κατώτερο τμήμα της τελευταίας να ανήκει στη ζώνη των TeraHertz. Τα κύματα αυτής της κατηγορίας μεταδίδονται κυρίως μέσω διαδρομών οπτικής επαφής, χωρίς να ανακλώνται από την ιονόσφαιρα ή να κινούνται παράλληλα με την επιφάνεια της Γης, όπως συμβαίνει με τα κύματα εδάφους και τις χαμηλότερες ραδιοσυχνότητες. Σε συνήθεις εντάσεις ισχύος, εμποδίζονται από τοίχους κτηρίων και εξασθενούν σημαντικά όταν διέρχονται μέσα από πολύ λεπτές επιφάνειες [3].

Η συνεχώς αυξανόμενη ζήτηση για δεδομένα από εφαρμογές όπως η εικονική και η επαυξημένη πραγματικότητα, η ολογραφική προβολή, τα αυτόνομα οχήματα, το διαδίκτυο των πραγμάτων (IoT) και άλλες τεχνολογίες αναμένεται, σύμφωνα με την πρόβλεψη της Διεθνούς Ένωσης Τηλεπικοινωνιών (ITU), να οδηγήσει την κίνηση δεδομένων στα δίκτυα 5G σε επίπεδα που θα αγγίξουν τα 5 Zettabytes μηνιαίως έως το 2030. Επιπλέον, μια άλλη ανάλυση εκτιμά ότι μεταξύ 2020 και 2030 η παγκόσμια διαδικτυακή μεταφορά δεδομένων θα αυξάνεται κατά 55% ετησίως, φτάνοντας συνολικά τα 5,016 Exabytes (σύμφωνα με τις προβλέψεις IMT Traffic Estimates). Ως αποτέλεσμα, η ακαδημαϊκή κοινότητα έχει εντείνει το ερευνητικό της ενδιαφέρον για το δίκτυο επόμενης γενιάς, το 6G, το οποίο θα κληθεί να ανταποκριθεί σε αυτές τις απαιτήσεις [4]. Οι υψηλές απαιτήσεις που θέτει η μελλοντική έκτη γενιά (6G) έχουν κατευθύνει την έρευνα προς την ανάπτυξη νέων υλικών και καινοτόμων αρχιτεκτονικών front-end ραδιοσυχνοτήτων. Μία από τις πρωτοποριακές τεχνολογίες που ξεχωρίζουν ως υποψήφιες λύσεις είναι και οι αναδιαμορφώσιμες έξυπνες επιφάνειες (RIS) [5].

Τα δίκτυα επικοινωνίας του IoT έχουν επιτρέψει τη σύνδεση συσκευών με δυνατότητες ανίχνευσης, επεξεργασίας και επικοινωνίας, παρέχοντας υπηρεσίες όπως έξυπνη παραγωγική διαδικασία, ανίχνευση εκτάκτων αναγκών και εξ αποστάσεως ιατρική παρακολούθηση με ελάχιστη ανθρώπινη παρέμβαση. Ωστόσο, υπάρχουν δύο βασικά προβλήματα: η τεράστια συνδεσιμότητα που προκαλεί παρεμβολές και η ανάγκη για ενεργειακά αποδοτικές λύσεις λόγω της περιορισμένης διάρκειας ζωής των μπαταριών των συσκευών IoT. Οι λύσεις που προσφέρονται είναι η κατανομή ξεχωριστού φάσματος σε κάθε

συσκευή, η οποία όμως δεν είναι βιώσιμη λόγω περιορισμένων πόρων και η μαζική χρήση συστημάτων MIMO για εστιασμένη δέσμη σήματος, η οποία όμως είναι ενεργοβόρα. Το παραπάνω πρόβλημα μπορεί να επιλυθεί μέσω της τεχνολογίας RIS [6]. Οι επιφάνειες RIS χρησιμοποιούνται για τη μετάδοση των κυμάτων που προσπίπτουν σε αυτές, συμβάλλοντας έτσι σε μια ενεργειακά αποδοτική και βιώσιμη επικοινωνία [7]. Αυτή η τεχνολογία διακρίνεται για την υψηλή ενεργειακή της απόδοση, καθώς επιτρέπει την παθητική εκπομπή δέσμης χωρίς να απαιτείται ενίσχυση ισχύος, σε αντίθεση με τους συμβατικούς σταθμούς βάσης MIMO [8].

Οι RIS έχουν πρόσφατα καθιερωθεί ως μια πρωτοποριακή τεχνολογία στο φυσικό επίπεδο των ασύρματων επικοινωνιών, στοχεύοντας στη βελτίωση των ραδιοκαναλιών και στη δημιουργία ενός πιο ευφυούς ασύρματου περιβάλλοντος. Αυτές οι επιφάνειες χρησιμοποιούν ανακλαστικά στοιχεία για να προσαρμόζουν δυναμικά τη φάση και το πλάτος των σημάτων που λαμβάνουν, αντιμετωπίζοντας προβλήματα όπως τα φυσικά εμπόδια, η εξασθένηση του σήματος και η ύπαρξη σκίασης, χωρίς να απαιτείται σύνθετη επεξεργασία σήματος ή πολύπλοκη κωδικοποίηση και αποκωδικοποίηση. Μέσω της διαχείρισης της σκέδασης και της ανάκλασης των ηλεκτρομαγνητικών κυμάτων, οι RIS μειώνουν σημαντικά τις αλλοιώσεις και τις παρεμβολές στα ραδιοσήματα, εξαλείφοντας την ανάγκη για επιπλέον σταθμούς βάσης ή κόμβους αναμετάδοσης. Αυτό έχει ως αποτέλεσμα τη βελτιωμένη κάλυψη και συνδεσιμότητα των ασύρματων δικτύων. Στην ουσία, οι RIS μετατρέπουν το ραδιοπεριβάλλον από έναν παθητικό παράγοντα σε έναν ενεργό ρυθμιστή των συνθηκών μετάδοσης [9].

Προτού αξιοποιηθούν πλήρως τα οφέλη των RIS, πρέπει να ξεπεραστούν ορισμένες προκλήσεις. Η επίτευξη της βέλτιστης ανάκλασης μέσω ενός RIS απαιτεί άριστη γνώση της κατάστασης του καναλιού (Channel State Information - CSI). Ωστόσο, σε ένα πραγματικό ασύρματο δίκτυο που χρησιμοποιεί RIS, η διαρκής και ακριβής εκτίμηση του CSI είναι δύσκολη, καθώς η κινητικότητα των χρηστών και τα εμπόδια μπορούν να επηρεάσουν το σήμα. Επομένως, η αξιόπιστη εκτίμηση του CSI και η βελτιστοποίηση της απόδοσης του δικτύου σε συνθήκες μη ιδανικού CSI είναι κρίσιμες για την αποτελεσματική και σε πραγματικό χρόνο μετάδοση μέσω RIS. Η διαδικασία εκτίμησης του καναλιού είναι ιδιαίτερα απαιτητική στα ασύρματα δίκτυα με RIS, καθώς αυτά διαθέτουν μεγάλο αριθμό στοιχείων, γεγονός που αποτελεί πρόκληση στην όλη διαδικασία. Επιπλέον, η συλλογή δεδομένων για το κανάλι μπορεί να απαιτεί σημαντικό υπολογιστικό φόρτο. Παράλληλα, η διαχείριση της μετατόπισης φάσης των ανακλαστικών στοιχείων δυσχεραίνει τη δημιουργία ενός ιδανικού συστήματος παθητικής διαμόρφωσης δέσμης. Οι παραδοσιακές μέθοδοι διαμόρφωσης των RIS είναι περίπλοκες, απαιτώντας διαδικασίες που καταναλώνουν τόσο χρόνο όσο και ενέργεια [10]. Η αξιολόγηση του καναλιού και η διαχείριση της κίνησης του δικτύου υπό αβεβαιότητα είναι κρίσιμες για την αποδοτική επικοινωνία μέσω RIS, αλλά η πολυπλοκότητα αυτής της διαδικασίας καθιστά τη συλλογή δεδομένων χρονοβόρα.

Η μηχανική μάθηση (ML) έχει αναδειχθεί ως μια πολλά υποσχόμενη λύση, καθώς επιτρέπει στα συστήματα να μαθαίνουν και να προσαρμόζονται αυτόνομα. Πολλοί ερευνητές έχουν αναπτύξει τεχνικές ML για την επίλυση αυτών των προκλήσεων, εστιάζοντας στην εκπαίδευση παραμέτρων και τη βελτιστοποίηση της λήψης αποφάσεων. Η ακρίβεια των μαθηματικών μεθόδων βελτιστοποίησης επηρεάζει σημαντικά την αποτελεσματικότητα αυτών των μοντέλων, ιδίως στη σύγχρονη εποχή των μεγάλων δεδομένων [11]. Χάρη στην ταχεία ανάπτυξή της, χρησιμοποιείται στον σχεδιασμό ηλεκτρομαγνητικών δομών, επιτρέποντας ταχύτερους υπολογισμούς. Οι μέθοδοι που βασίζονται σε μηχανική μάθηση περιλαμβάνουν τον αντίστροφο σχεδιασμό, που προβλέπει τις διαστάσεις μιας δομής μέσω S-παραμέτρων, τον προωθητικό σχεδιασμό, που έχει κοινά στοιχεία με τις παραδοσιακές μεθόδους με καλύτερα και καινοτόμα αποτελέσματα, τον γενετικό σχεδιασμό με τη χρήση μοντέλων παραγωγής και την ενισχυτική μάθηση (Reinforcement Learning - RL), που αυτοματοποιεί τη δημιουργία ηλεκτρομαγνητικών δομών σύμφωνα με τις επιθυμητές προδιαγραφές [12].

1.2 Τι είναι RIS

Το RIS είναι μια ηλεκτρομαγνητική διάταξη που ενσωματώνει ηλεκτρονικά κυκλώματα και διαθέτει προηγμένες δυνατότητες ασύρματης επικοινωνίας [13]. Αποτελείται από πολλαπλά παθητικά ανακλαστικά στοιχεία, τα οποία μπορούν να τροποποιήσουν το περιβάλλον μετάδοσης, κατευθύνοντας τα εισερχόμενα σήματα με προγραμματιζόμενο τρόπο, χωρίς να προσθέτουν επιπλέον θερμικό θόρυβο κατά την ανάκλαση [14]. Αυτά τα οικονομικά αποδοτικά ανακλαστικά στοιχεία ρυθμίζουν μεμονωμένα τη μετατόπιση φάσης του λαμβανόμενου σήματος και, μέσω της συντονισμένης λειτουργίας τους, διαμορφώνουν ένα ευνοϊκό κανάλι ασύρματης επικοινωνίας, αξιοποιώντας το ανακλώμενο σήμα με καινοτόμο τρόπο [15]. Η ηλεκτρομαγνητική απόκριση των παθητικών ανακλαστικών στοιχείων (unit cells) όπως οι μετατοπίσεις φάσης, μπορεί να ρυθμιστεί μέσω απλών προγραμματιζόμενων διόδων PIN. Λόγω της λειτουργίας ON/OFF των διόδων που διαθέτει, το RIS μπορεί να επιτύχει μόνο έναν συγκεκριμένο αριθμό διακριτών μετατοπίσεων φάσης. Σε αντίθεση με τις παραδοσιακές κεραίες που εκπέμπουν διασκορπισμένα κύματα, η μικρή απόσταση μεταξύ των στοιχείων του RIS επιτρέπει τη δημιουργία ανακλώμενων και διαθλώμενων κυμάτων μέσω της υπέρθεσης των εισερχόμενων κυμάτων στην επιφάνειά του.

Διαθέτοντας αυτήν την προγραμματιζόμενη ικανότητα διαμόρφωσης των μετώπων κύματος σε επιθυμητά σχήματα, το RIS δρα ως στοιχείο ενός δυναμικά διαμορφώσιμου περιβάλλοντος διάδοσης, επιτρέποντας την κατευθυνόμενη ανάκλαση των σημάτων προς τους δέκτες, χωρίς να απαιτείται επιπλέον κατανάλωση ενέργειας ή πρόσθετος υλικός εξοπλισμός. Έτσι, συμβάλλει στη βελτίωση της ποιότητας του συνδέσμου και της κάλυψης [16].

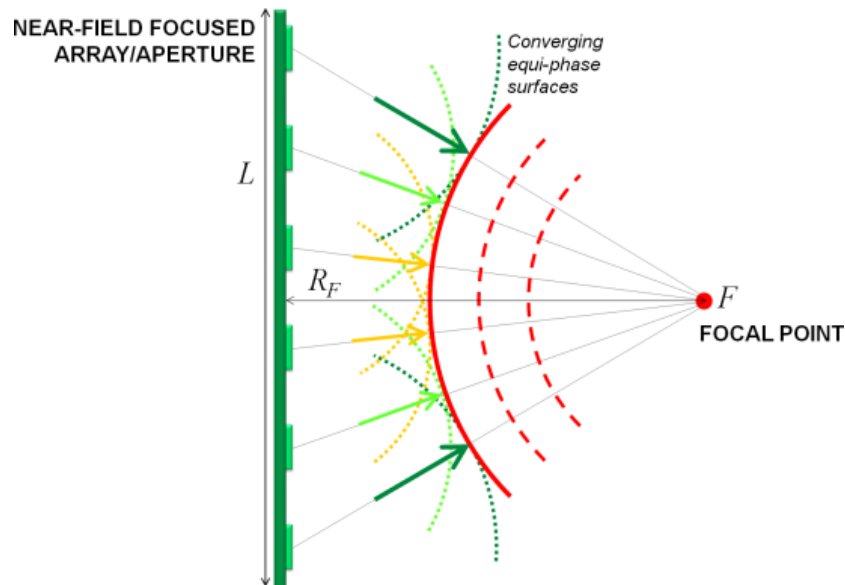
Στο παρελθόν, παρουσιάστηκαν πρωτοποριακά συστήματα, όπως οι έξυπνοι τοίχοι που διευκολύνουν τη μετάδοση, ενώ ο έλεγχος της κάλυψης του σήματος πραγματοποιείται μέσω επιφανειών που είναι επιλεκτικές ως προς τη συχνότητα. Αντί της παραδοσιακής εκπομπής δέσμης προς μια συγκεκριμένη κατεύθυνση, χρησιμοποιούνται πίνακες ανακλαστικών διατάξεων, όπου η έξυπνη ανάκλαση επιτυγχάνεται μέσω ρύθμισης της μετατόπισης φάσης κάθε στοιχείου τους, ενισχύοντας έτσι το λαμβανόμενο σήμα στον δέκτη [7]. Παράλληλα, αποτρέπεται η εκπομπή σήματος σε μη εξουσιοδοτημένους αποδέκτες, συμβάλλοντας στη μείωση της τηλεπικοινωνιακής συμφόρησης στο ίδιο κανάλι και στη βελτιωμένη εξυπηρέτηση των χρηστών που βρίσκονται στα όρια των κυψελών [15].

Το RIS μιμείται τη συμβατική λειτουργία ενός αναμεταδότη, παρέχοντας ενίσχυση και προώθηση του σήματος, με το πλεονέκτημα της χαμηλής κατανάλωσης ενέργειας. Αυτό επιτυγχάνεται μέσω παθητικής ανάκλασης του σήματος, χωρίς την ανάγκη ενεργών αλυσίδων ραδιοσυχνοτήτων. Τα RF εξαρτήματα που αξιοποιεί το RIS για τη μετάδοση είναι κατά βάση παθητικά, γεγονός που αποτρέπει την προσθήκη θερμικού θορύβου στο ανακλώμενο σήμα [15].

Οι Rehman, Bellili, Mezghani και Hossain (2022) πρότειναν ένα γενικότερο πλαίσιο όπου το RIS αξιοποιείται για την ενσωμάτωση δεδομένων σε ανακλώμενα ή αναμεταδιδόμενα σήματα. Σε αυτό το πλαίσιο, η λειτουργία μπορεί να επιτευχθεί είτε μέσω παθητικής εκπομπής δέσμης για δέκτες που εξυπηρετούνται από σταθμούς βάσης, είτε ενσωματώνοντας πληροφορίες μέσω επικοινωνίας οπισθοσκέδασης (backscatter communication), είτε συνδυάζοντας και τις δύο μεθόδους ταυτόχρονα. Ένα βασικό πλεονέκτημα αυτής της προσέγγισης είναι ότι επιτρέπει στους σταθμούς βάσης να κατευθύνουν όλη την ισχύ μετάδοσης προς το ισχυρότερο μονοπάτι επικοινωνίας, το οποίο σχηματίζεται μεταξύ του σταθμού και των ανακλώμενων επιφανειών. Οι επιφάνειες αυτές διαμορφώνουν παθητικά τα σήματα, ρυθμίζοντας κατάλληλα τις μετατοπίσεις φάσης [8].

Η συγκέντρωση του ηλεκτρομαγνητικού πεδίου συμβάλλει στην ενίσχυση της πυκνότητας της ηλεκτρομαγνητικής ισχύος μέσα σε μια καθορισμένη περιοχή και εντός της ζώνης εκπομπής του RIS.

Αυτό επιτυγχάνεται μέσω του ελέγχου της φάσης των στοιχείων ακτινοβολίας του RIS, ώστε η συνολική τους συνεισφορά να ενισχύεται εποικοδομητικά προς το προκαθορισμένο εστιακό σημείο (Εικόνα 1.1). Ένα επιπλέον πλεονέκτημα είναι ότι ο αριθμός των χρηστών που μπορούν να εξυπηρετηθούν δεν εξαρτάται από τις διαθέσιμες διαδρομές των καναλιών μεταξύ των σταθμών βάσης και των ανακλώμενων επιφανειών. Αντίθετα, καθορίζεται από τον αριθμό των ανακλώμενων στοιχείων της.



Εικόνα 1.1: Συγκλίνουσες ισοφασικές επιφάνειες του πεδίου. Πρόκειται για επιφάνειες που, ακτινοβολούνται από ηλεκτρομαγνητικές πηγές που βρίσκονται σε ένα επίπεδο άνοιγμα και εστιάζονται σε ένα εστιακό σημείο, σε κεραία ακτινοβολίας κοντινού πεδίου. Το L και το R_F υποδηλώνουν το μέγεθος του διαφράγματος της κεραίας και την εστιακή τους απόσταση, αντίστοιχα [17]


1.3 Δισδιάστατη δομή

Το RIS αναπαριστά μια δισδιάστατη κατασκευή τεχνητού υλικού (Εικόνα 1.2), της οποίας η εγκάρσια διάσταση είναι σημαντικά μεγαλύτερη από το πάχος της. Συνήθως, οι εγκάρσιες διαστάσεις ενός RIS υπερβαίνει κατά πολύ το μήκος κύματος των ραδιοκυμάτων. Ανάλογα με τις απαιτούμενες λειτουργίες, η διάστασή του μπορεί να κυμαίνεται από μερικές δεκάδες έως και μερικές εκατοντάδες φορές το μήκος κύματος, ενώ το πάχος του παραμένει ιδιαίτερα μικρό. Για τον λόγο αυτό, συχνά περιγράφεται ως ένα ηλεκτρομαγνητικό υλικό με σχεδόν μηδενικό πάχος [1].

Όπως αναφέρουν οι ίδιοι, η δισδιάστατη διαμόρφωση του RIS επιτρέπει έναν απλούστερο σχεδιασμό, μειώνοντας τις απώλειες και το κόστος υλοποίησης σε σχέση με τα τρισδιάστατα μοντέλα, των οποίων το πάχος δεν μπορεί να θεωρηθεί αμελητέο.

1.4 Έξυπνες επιφάνειες

Στη βιβλιογραφία συναντώνται διάφοροι όροι και ακρωνύμια που σχετίζονται με τις έξυπνες επιφάνειες. Οι πιο συχνά χρησιμοποιούμενοι περιλαμβάνουν τις μεγάλες έξυπνες επιφάνειες (Large Intelligent Surfaces – LIS), τις έξυπνες ανακλαστικές επιφάνειες (Intelligent Reflecting Surfaces – IRS), τους ψηφιακά ελεγχόμενους διασκορπιστές (Digitally Controlled Scatters – DCS) και τις επιφάνειες ελεγχόμενες από λογισμικό (Software Controllable Surfaces – SCS).



Εικόνα 1.2: Εννοιολογική δομή μιας έξυπνης επιφάνειας αναδιαμόρφωσης [1]

Μεγάλες έξυπνες επιφάνειες

Ο όρος LIS αναφέρεται σε επιφάνειες που αντιπροσωπεύουν το επόμενο εξελικτικό βήμα μετά την τεχνολογία MIMO. Οι LIS θεωρούνται ενεργές επιφάνειες, καθώς τα επιμέρους στοιχεία τους είναι εξοπλισμένα με ξεχωριστά κυκλώματα ραδιοσυχνότητας (RF chains) και ενισχυτές ισχύος, επιτρέποντας την επεξεργασία του σήματος [18].

Έξυπνες ανακλαστικές επιφάνειες

Οι έξυπνες ανακλαστικές επιφάνειες λειτουργούν ως ρυθμιζόμενοι ανακλαστήρες, αποτελούμενοι από στοιχεία των οποίων η απόκριση φάσης μπορεί να προσαρμοστεί ξεχωριστά. Αυτό επιτρέπει τη βελτιστοποίηση της κατεύθυνσης της ανακλώμενης δέσμης. Συνήθως, αυτά τα στοιχεία δεν έχουν τη δυνατότητα ενίσχυσης των προσπιπτόντων σε αυτές σημάτων, αλλά μπορούν να μεταβάλλουν την απόκριση φάσης τους. Οι επιφάνειες αυτού του τύπου αναφέρονται ως Intelligent Reflecting Surfaces (IRS) [7].

Ψηφιακά ελεγχόμενοι σκεδαστές

Ο όρος ψηφιακά ελεγχόμενοι σκεδαστές (Digitally Controlled Scatterers - DCS), είναι παρόμοιος με το RIS και χρησιμοποιείται για να υπογραμμίσει την ικανότητα ψηφιακού ελέγχου της συμπεριφοράς των επιφανειών ή συσκευών που ενσωματώνουν έξυπνα υλικά. Στην περίπτωση αυτή, έμφαση δίνεται στα επιμέρους στοιχεία, τα οποία αντιμετωπίζονται ως τοπικοί διασκορπιστές. Οι DCS κατασκευάζονται συνήθως από παθητικά στοιχεία που δεν μπορούν να ενισχύσουν τα λαμβανόμενα σήματα, αλλά βασίζονται στη μεταξύ τους σύζευξη, με αποτέλεσμα η θέση τους στην επιφάνεια να παίζει σημαντικό ρόλο στη λειτουργία τους [19].

Επιφάνειες ελεγχόμενες από λογισμικό

Οι έξυπνες επιφάνειες που μπορούν να ελέγχονται και να βελτιστοποιούνται μέσω τεχνολογιών δικτύωσης που καθορίζονται από λογισμικό αναφέρονται ως Software Controllable Surfaces (SCS). Αυτές διαθέτουν ένα δίκτυο νανοεπικοινωνίας που διευκολύνει την επικοινωνία μεταξύ των κελιών τους. Σε ορισμένες περιπτώσεις, είναι εξοπλισμένες με αισθητήρες χαμηλής ισχύος για την παρακολούθηση του περιβάλλοντος. Ο συνδυασμός αισθητήρων και επικοινωνίας επιτρέπει στις επιφάνειες αυτές να εκτελούν βασικές τοπικές λειτουργίες, καθιστώντας τις πιο αυτόνομες. Ωστόσο, αυτή η δυνατότητα μπορεί να αυξήσει την πολυπλοκότητα της λειτουργίας τους και την κατανάλωση ενέργειας [20].

1.5 Μεταεπιφάνειες

Το μεταυλικό είναι ένα τεχνητό υλικό που έχει σχεδιαστεί ώστε να διαθέτει μοναδικές ηλεκτρομαγνητικές ή άλλες φυσικές ιδιότητες που δεν απαντώνται στη φύση. Μια ειδική κατηγορία ηλεκτρομαγνητικών υλικών, η οποία αποτελείται από ένα ή λίγα στρώματα δομών διατεταγμένων είτε περιοδικά είτε απεριοδικά κατά μήκος της κατεύθυνσης διάδοσης των ηλεκτρομαγνητικών κυμάτων, ονομάζεται μεταεπιφάνεια (metasurface) [21].

Μια μεταεπιφάνεια, σύμφωνα με τον ορισμό της, χαρακτηρίζεται ως ηλεκτρικά λεπτή, δηλαδή το πάχος της είναι σημαντικά μικρότερο από το μήκος κύματος. Ταυτόχρονα, θεωρείται ηλεκτρικά μεγάλη, καθώς οι εγκάρσιες διαστάσεις της είναι σχετικά μεγάλες σε σύγκριση με το μήκος κύματος. Επιπλέον, είναι ομογενοποιήσιμη, καθώς η απόσταση μεταξύ των γειτονικών κελιών που την απαρτίζουν είναι πολύ μικρότερη από το μήκος κύματος, ενώ η δομή της είναι πολύ μικρότερη του μήκους κύματος (subwavelength), γεγονός που σημαίνει ότι κάθε κυψέλη έχει μέγεθος πολύ μικρότερο από το μήκος κύματος [22].



Εικόνα 1.3: Το Πρωτότυπο RFocus του MIT [23]

Στον τομέα των ασύρματων επικοινωνιών και δικτύων, οι ερευνητές θεωρούν ότι ο όρος RIS είναι ο πιο κατάλληλος για να περιγράψει την εννοιολογική αρχιτεκτονική της έξυπνης επιφάνειας, γεγονός που δικαιολογεί την υιοθέτησή του στο πλαίσιο της παρούσας μελέτης.

1.6 Τα πρωτότυπα του MIT και της DOCOMO NTT

Πολλοί επιστήμονες ασχολούνται με την ανάπτυξη έξυπνων επιφανειών που έχουν τη μορφή προγραμματιζόμενης λεπτής ταπετσαρίας ή γυαλιού. Αυτές οι επιφάνειες μπορούν να ρυθμίζουν τα ραδιοκύματα σύμφωνα με τις ανάγκες που πρέπει να καλύψουν. Παρακάτω παρουσιάζονται δύο παραδείγματα.


Το πρωτότυπο RFocus, που αναπτύχθηκε από το MIT, αποτελείται από 3.720 κεραίες χαμηλού κόστους, διατεταγμένες σε επιφάνεια έξι τετραγωνικών μέτρων (Εικόνα 1.3). Η κατασκευή αυτή λειτουργεί σχεδόν παθητικά, καθώς δεν εκπέμπει νέα ραδιοκύματα. Ωστόσο, μέσω ηλεκτρονικών κυκλωμάτων χαμηλής ισχύος, μπορεί να διαμορφώνει τη δέσμη των εισερχόμενων ραδιοκυμάτων και να τα κατευθύνει προς μια συγκεκριμένη θέση και κατεύθυνση [23].

Η DOCOMO NTT (Nippon Telegraph and Telephone Corporation), ανέπτυξε μια έξυπνη λεπτή γυάλινη επιφάνεια, γνωστή ως μεταεπιφάνεια (Εικόνα 1.4), η οποία αποτελείται από πλήθος στοιχείων

μικρότερων από το μήκος κύματος (subwavelength). Αυτά είναι διατεταγμένα περιοδικά σε μια δισδιάστατη επιφάνεια με γυάλινο υπόστρωμα. Μέσω μικρής μετακίνησης του γυάλινου υποστρώματος, καθίσταται δυνατός ο δυναμικός έλεγχος της απόκρισης στα προσπίπτοντα ραδιοκύματα με τρεις τρόπους:

- i. πλήρης διείσδυση των ραδιοκυμάτων,
- ii. μερική ανάκλαση των ραδιοκυμάτων και
- iii. πλήρης ανάκλαση όλων των ραδιοκυμάτων.

Η γυάλινη έξυπνη επιφάνεια είναι διάφανη και κατάλληλη για διακριτική χρήση [24]



Εικόνα 1.4: Το πρωτότυπο NTT της DOCOMO [24]

1.7 Σχετικές εργασίες

Σε μια προσπάθεια ενσωμάτωσης της τεχνητής νοημοσύνης (AI) με τις RIS, οι Ahmed και άλλοι εξέτασαν διάφορους αλγόριθμους AI, όπως η επιβλεπόμενη και μη επιβλεπόμενη μάθηση, η βαθιά μάθηση (DL), η ενισχυτική μάθηση (RL), η ομοσπονδιακή μάθηση (Federated Learning - FL) και άλλες τεχνικές. Ιδιαίτερη έμφαση δόθηκε στη συμβολή της AI στη βελτιστοποίηση των RIS, βελτιώνοντας πτυχές όπως η εκτίμηση καναλιού, η ενεργειακή απόδοση και η ασφάλεια των δικτύων [25].

Οι Peng και άλλοι έχοντας μελετώντας τη μεγιστοποίηση του αθροιστικού ρυθμού μετάδοσης σε ένα κανάλι καθόδου πολλαπλών χρηστών (Multiple-input and single-output - MISO) μέσω πολλαπλής πρόσβασης διαίρεσης χώρου (Spatial Division Multiple Access – SDMA), αντιμετώπισαν προκλήσεις όπως η υψηλή διαστατικότητα και η έλλειψη πλήρους πληροφορίας κατάστασης καναλιού (CSI). Για την διαχείριση αυτών των προκλήσεων προτείνουν μια υβριδική προσέγγιση μηχανικής μάθησης που συνδυάζει τον προκωδικοποιητή σταθμισμένου ελάχιστου μέσου τετραγωνικού σφάλματος (Weighted Minimum Mean Squared Error - WMMSE) στο σταθμό βάσης με ένα νευρωνικό δίκτυο, το RISnet, για τη διαμόρφωση του RIS. Το RISnet μπορεί να βελτιστοποιήσει 1296 στοιχεία χρησιμοποιώντας μόνο μερική CSI από 16 στοιχεία και μαθαίνει αυτόνομα τη βέλτιστη διαμόρφωση μέσω μη επιβλεπόμενης μάθησης. Τα αριθμητικά αποτελέσματα δείχνουν ότι το προτεινόμενο μοντέλο επιτυγχάνει υψηλή απόδοση με χαμηλό υπολογιστικό κόστος και λειτουργεί με διακριτές μετατοπίσεις φάσης, ξεπερνώντας σημαντικά τις υπάρχουσες μεθόδους [26].

Μια νέα προσέγγιση στον αντίστροφο σχεδιασμό ελεύθερης διαμόρφωσης αναδιαμορφώσιμων μεταεπιφανειών προτείνεται από τους Liu, Yang και Xu. Πρόκειται για μια μέθοδο που διαχωρίζει τα μετα-άτομα (μοναδιαία κελιά) της μεταεπιφάνειας σε στατικές δομές και συγκεντρωτικούς διακόπτες,

μειώνοντας σημαντικά το μέγεθος του απαιτούμενου συνόλου δεδομένων. Η προσέγγιση αυτή επιτρέπει την απόκτηση των αποκρίσεων ενός 1-bit αναδιαμορφώσιμου μετα-ατόμου με μία μόνο προσομοίωση, ενώ η διαδικασία αντίστροφου σχεδιασμού απλοποιείται μέσω της εστίασης στη στατική δομή. Για τη βελτίωση της απόδοσης, χρησιμοποιείται ένα μοντέλο συνελκτικού νευρωνικού δικτύου (Convolutional Neural Network - CNN) για πρόβλεψη της απόκρισης των δομών, ενώ ένας γενετικός αλγόριθμος εφαρμόζεται στον αντίστροφο σχεδιασμό. Έτσι, η δημιουργία μετα-ατόμων ελεύθερης διαμόρφωσης για ευρυζωνικές, μονοζωνικές και πολυζωνικές εφαρμογές καθίσταται άμεση μετά την εκπαίδευση του δικτύου. Η προτεινόμενη στρατηγική επιτρέπει ταχύ σχεδιασμό και ανάπτυξη υψηλής απόδοσης αναδιαμορφώσιμων μεταεπιφανειών, συμβάλλοντας στην πρόοδο της τεχνολογίας στην εποχή της τεχνητής νοημοσύνης [27].

Οι προσεγγίσεις που βασίζονται στη μάθηση με επίβλεψη, όπου ένα βαθύ νευρωνικό δίκτυο (Deep Neural Network - DNN) εκπαιδεύεται εκτός σύνδεσης για να αποτυπώσει τη σχέση μεταξύ των μετρούμενων συντεταγμένων και της διαμόρφωσης φάσης του RIS, αντιμετωπίζουν ένα κρίσιμο ζήτημα: την απόκτηση ετικετών. Η εύρεση των βέλτιστων ετικετών πραγματοποιείται μέσω εξαντλητικής αναζήτησης, μια διαδικασία ιδιαίτερα απαιτητική από πλευράς υπολογιστικών πόρων, ειδικά όταν απαιτείται μεγάλος όγκος δεδομένων εκπαίδευσης.

Για να μειωθεί το κόστος που συνεπάγεται η διαδικασία επισήμανσης στη μάθηση με επίβλεψη, οι Gao και άλλοι, προτείνουν την εφαρμογή ενός μηχανισμού μη επιβλεπόμενης μάθησης για τον σχεδιασμό παθητικής διαμόρφωσης δέσμης, όπου δεν απαιτούνται ετικέτες. Συγκεκριμένα, αναπτύσσεται μια προσαρμοσμένη αρχιτεκτονική DNN, ειδικά σχεδιασμένη για το συγκεκριμένο πρόβλημα, ενώ επιλέγεται ένα σύνολο κατάλληλων χαρακτηριστικών για τη διαδικασία εκπαίδευσης. Τα αποτελέσματα των προσομοιώσεων καταδεικνύουν ότι η προτεινόμενη προσέγγιση, βασισμένη στη μη επιβλεπόμενη μάθηση, μειώνει σημαντικά τον υπολογιστικό χρόνο, διατηρώντας παράλληλα αποδεκτό επίπεδο απόδοσης σε σύγκριση με την κλασική μέθοδο που βασίζεται στην τεχνική ημι-ορισμένης χαλάρωσης (Semi-Definite Relaxation - SDR) [28].

Εκτός από την εξέλιξη των μοντέλων μάθησης, ένα κρίσιμο στοιχείο είναι η ποιότητα του συνόλου δεδομένων εκπαίδευσης (Training Data Set - TDS), η οποία επηρεάζει άμεσα την αποδοτικότητα του σχεδιασμού. Ωστόσο, η δημιουργία ενός υψηλής ποιότητας TDS αποτελεί μια σύνθετη πρόκληση. Για την αντιμετώπιση αυτού του ζητήματος, ο Wei και άλλοι προτείνουν μια μέθοδο σχεδιασμού μεταεπιφανειών που συνδυάζει γνώση ηλεκτρομαγνητικών κυμάτων με γενετική μηχανική μάθηση. Αντί να επιλέγει δείγματα εκπαίδευσης, η μέθοδος βασίζεται στη θεωρία του ισοδύναμου κυκλώματος φίλτρου για την επιλογή των πιο συναφών δειγμάτων, ενισχύοντας έτσι την ποιότητα του συνόλου δεδομένων. Η χρήση του μεταβολικού αυτοκωδικοποιητή (Variational Autoencoder - VAE) επιτρέπει τη μείωση των διαστάσεων των δεδομένων και τη βελτιστοποίηση της αναζήτησης βέλτιστων λύσεων, αυξάνοντας την αποδοτικότητα του σχεδιασμού. Η προτεινόμενη τεχνική είναι ιδιαίτερα χρήσιμη για εφαρμογές που απαιτούν ταχεία ανάπτυξη και υψηλή απόδοση μεταεπιφανειών. Σε αντίθεση με τις παραδοσιακές μεθόδους, δεν απαιτεί εξειδικευμένη γνώση, καθιστώντας τον σχεδιασμό πιο προσιτό. Μόλις ολοκληρωθεί η εκπαίδευση, η διαδικασία γίνεται πλήρως αυτοματοποιημένη, προσφέροντας έναν αποδοτικό και εύχρηστο τρόπο σχεδιασμού. Επιπλέον, η μεθοδολογία δημιουργίας υψηλής ποιότητας TDS μπορεί να εφαρμοστεί και σε άλλους τομείς, βελτιώνοντας την εκπαίδευση νευρωνικών δικτύων [29].

Οι Naseri και Hum δημιούργησαν μια αποδοτική μέθοδο παραγωγής δεδομένων εκπαίδευσης για ηλεκτρομαγνητικές μεταεπιφάνειες (Electromagnetic Metamaterials - EMMS), λαμβάνοντας υπόψη τις ηλεκτρομαγνητικές αλληλεπιδράσεις. Αντί για χρονοβόρες προσομοιώσεις ολόκληρων δομών,

προσομοιώνονται μόνο οι επιμέρους σκεδαστές και αποθηκεύονται οι γενικοί πίνακες σκέδασης (GSMs), οι οποίοι στη συνέχεια συνδυάζονται για την εξαγωγή των συνολικών αποτελεσμάτων. Η προσέγγιση αξιοποιεί μοντέλα μηχανικής μάθησης (VAE και παλινδρόμηση) για τη δημιουργία EMMS με βάση επιθυμητούς συντελεστές σκέδασης, επιτρέποντας τη βελτιστοποίηση στον λανθάνοντα χώρο αντί για εξαντλητική αναζήτηση. Αυτή η μέθοδος μειώνει σημαντικά τον υπολογιστικό φόρτο, διατηρώντας υψηλή ακρίβεια και επιτρέποντας τη διερεύνηση νέων σχεδιάσεων χωρίς επιπλέον προσομοιώσεις [30].

1.8 Επιμέρους Στόχοι / Μεθοδολογία

Η παρούσα εργασία έχει ως βασικό αντικείμενο την υλοποίηση και αξιολόγηση συγκεκριμένων στόχων, οι οποίοι επιμερίζονται ως εξής:

Πρώτον, θα αναπτυχθεί και θα υλοποιηθεί σε γλώσσα Python ένας αλγόριθμος για τον υπολογισμό της λαμβανόμενης ισχύος σήματος (Received Signal Strength Indication - RSSI) από μια δισδιάστατη ανακλαστική επιφάνεια. Η επιφάνεια αυτή θα αποτελείται από πλέγμα ορθογώνιων υπομονάδων ή μοναδιαίων κελιών (subcells / unit cells) με διαστάσεις μικρότερες από το μήκος κύματος του σήματος. Η εκτίμηση της RSSI θα βασίζεται στην υπέρθεση όλων των επιμέρους σημάτων που προέρχονται από κάθε στοιχείο του πλέγματος, λαμβάνοντας υπόψη τόσο τη χωρική του θέση όσο και τα χαρακτηριστικά ανάκλασης (πλάτος και φάση) κάθε στοιχείου.

Ο δείκτης RSSI αποτελεί κρίσιμο παράγοντα απόδοσης (Key Performance Indicator - KPI) σε συστήματα ασύρματης επικοινωνίας, καθώς επηρεάζει άμεσα παραμέτρους όπως ο ρυθμός μετάδοσης, η πιθανότητα σφάλματος ή ακόμα και η απώλεια σύνδεσης. Η σημασία της λαμβανόμενης ισχύος υπογραμμίζεται από το θεώρημα Shannon, σύμφωνα με τον τύπο (1):

$$C = B \log_2 \left(1 + \frac{S}{N} \right) \quad (1)$$

όπου το επίπεδο θορύβου θεωρείται χαρακτηριστικό του καναλιού, ενώ το διαθέσιμο εύρος ζώνης είναι συνήθως δεδομένο.

Σκοπός είναι η βελτιστοποίηση της γεωμετρικής διαμόρφωσης της μεταεπιφάνειας ώστε να επιτευχθεί η μέγιστη δυνατή τιμή του RSSI. Προς αυτή την κατεύθυνση, θα αναπτυχθούν και θα εφαρμοστούν διάφοροι αλγόριθμοι ML, με στόχο την αποδοτική και ταχεία διαμόρφωση των χαρακτηριστικών κάθε στοιχείου της επιφάνειας. Σε γενικές γραμμές, η διαμόρφωση της μεταεπιφάνειας μπορεί να πραγματοποιείται offline, με υπολογισμό και αποθήκευση πιθανών σεναρίων ανάκλασης και σχηματισμού δέσμης (beamforming). Ωστόσο, είναι απαραίτητο ο εκ νέου προγραμματισμός να είναι γρήγορος και αποτελεσματικός.

Για τον λόγο αυτό, θα εξεταστούν τεχνικές μηχανικής μάθησης, με έμφαση στη μελέτη και αξιολόγηση βαθιών νευρωνικών δικτύων (Deep Learning Neural Networks - DLNN). Πιο συγκεκριμένα, θα εξεταστούν τα Προωθητικά Νευρωνικά Δίκτυα (Feed-forward Neural Networks - FFNN) τα οποία είναι κατάλληλα για εφαρμογές που απαιτούν γρήγορη απόκριση και τα Συνελκτικά Νευρωνικά Δίκτυα Convolutional Neural Networks - CNN) τα οποία μπορούν να γενικεύσουν καλά και να επιτυγχάνουν υψηλή ακρίβεια σε νέα και πραγματικά δεδομένα. Θα εξεταστούν επίσης και τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (Recurrent Neural Networks - RNNs) τα οποία επεξεργάζονται διαδοχικά δεδομένα έχουν την ικανότητα να θυμούνται προηγούμενες εισόδους.

Η επιλογή αυτής της προσέγγισης βασίζεται σε ερευνητικά αποτελέσματα που καταδεικνύουν την υπεροχή της, ιδιαίτερα σε ό,τι αφορά την ταχύτητα και αποδοτικότητα της διαδικασίας βελτιστοποίησης [12].

Οργάνωση

Η υπόλοιπη εργασία οργανώνεται ως εξής. Στο Κεφάλαιο 2 αναπτύσσεται ένας αλγόριθμος για τον υπολογισμό της ισχύος λήψης, ο οποίος βασίζεται στη θεωρία της διατομής σκέδασης ραντάρ, με σκοπό την αξιολόγηση τόσο της ακρίβειας όσο και της πρακτικής αξίας της προτεινόμενης μεθόδου. Το Κεφάλαιο 3 επικεντρώνεται στην περιγραφή του αλγορίθμου που παράγει τα απαιτούμενα δεδομένα για τη διαδικασία μηχανικής μάθησης, ενώ παράλληλα εξετάζονται και εφαρμόζονται βασικές αρχιτεκτονικές νευρωνικών δικτύων στο πλαίσιο της παρούσας μελέτης. Στο Κεφάλαιο 4 παρουσιάζονται τα αποτελέσματα που προέκυψαν από την εφαρμογή τεχνικών βαθιάς μάθησης, καθώς και η σύγκρισή τους, η οποία συμβάλλει καθοριστικά στην αξιολόγηση της αποτελεσματικότητας των χρησιμοποιούμενων μεθόδων. Τέλος, το Κεφάλαιο 5 συνοψίζει τα συμπεράσματα της ερευνητικής προσέγγισης σχετικά με την ανάλυση και το σχεδιασμό έξυπνων επιφανειών, ενώ παράλληλα επισημαίνει θέματα που θα μπορούσαν να αποτελέσουν αντικείμενο μελλοντικής έρευνας.

1.9 Επίλογος

Η έρευνα στις ασύρματες επικοινωνίες βρίσκεται σε συνεχή εξέλιξη, με την έκτη γενιά δικτύων (6G) να προωθεί καινοτόμες τεχνολογίες, όπως οι αναδιαμορφώσιμες έξυπνες επιφάνειες (RIS), για την αντιμετώπιση των αυξανόμενων απαιτήσεων σε ταχύτητα, καθυστέρηση και ενεργειακή απόδοση. Οι RIS, ως παθητικές δομές, προσφέρουν δυναμικό έλεγχο του ραδιοπεριβάλλοντος μέσω ευφυούς ανάκλασης των ηλεκτρομαγνητικών κυμάτων, βελτιώνοντας την κάλυψη και τη φασματική απόδοση χωρίς επιπλέον ενεργειακό κόστος. Ωστόσο, η πλήρης αξιοποίησή τους εξαρτάται από την επίλυση κρίσιμων προκλήσεων, όπως η ακριβής εκτίμηση της κατάστασης του καναλιού (CSI) και η βέλτιστη διαμόρφωση των ανακλαστικών στοιχείων σε πραγματικό χρόνο.

Η εφαρμογή τεχνικών μηχανικής μάθησης (ML) και τεχνητής νοημοσύνης (AI) αναδεικνύεται ως υποσχόμενη λύση, καθώς επιτρέπει την αυτοματοποιημένη προσαρμογή των RIS σε δυναμικά περιβάλλοντα, βελτιστοποιώντας την απόδοση ακόμη και με μερική CSI. Πρωτοποριακές μέθοδοι, όπως τα νευρωνικά δίκτυα και οι γενετικοί αλγόριθμοι, απλοποιούν τον σχεδιασμό και τη διαχείριση των RIS, ενώ πειραματικά πρωτότυπα όπως το RFocus και το NTT, επιβεβαιώνουν τη σκοπιμότητά τους.

Κεφάλαιο 2ο: Ανάπτυξη αλγορίθμου υπολογισμού της ισχύος λήψης σε μία έξυπνη επαναδιαμορφώσιμη επιφάνεια (RIS)

2.1 Εισαγωγή


Στη σύγχρονη εποχή των ασύρματων επικοινωνιών, η αξιόπιστη εκτίμηση της ποιότητας σύνδεσης μεταξύ πομπού και δέκτη αποτελεί κρίσιμο παράγοντα για τη βελτιστοποίηση των τηλεπικοινωνιακών δικτύων. Μια βασική παράμετρος που χρησιμοποιείται για αυτόν τον σκοπό είναι η Ισχύς Λαμβανόμενου Σήματος (RSSI – Received Signal Strength Indicator), η οποία μετρά την ισχύ του σήματος που φτάνει στον δέκτη και συνδέεται άμεσα με το Ισοζύγιο Ισχύος Ζεύξης (Link Budget). Η ανάπτυξη αλγορίθμων για τον ακριβή υπολογισμό του RSSI είναι ζωτικής σημασίας, ιδιαίτερα σε συστήματα που αξιοποιούν Έξυπνες Ανακλαστικές Επιφάνειες.

Στην παρούσα εργασία, παρουσιάζεται ένας αλγόριθμος υπολογισμού της ισχύος λήψης, βασισμένος στην ηλεκτρομαγνητική θεωρία της Φυσικής Οπτικής (physical Optics, PO), χρησιμοποιώντας την έννοια της γενικευμένης διατομής σκέδασης ραντάρ (RCS – Radar Cross Section) και την εξίσωση του ραντάρ. Ο αλγόριθμος αυτός εστιάζει στην ανάλυση της αλληλεπίδρασης μεταξύ των ηλεκτρομαγνητικών κυμάτων και των δομημένων επιφανειών RIS, οι οποίες αποτελούνται από επαναδιαμορφώσιμα μοναδιαία κελιά. Στόχος είναι η σύγκριση των αποτελεσμάτων με προηγμένες μεθοδολογίες σχεδίασης RIS, όπως αυτές που προτείνονται στη βιβλιογραφία, ώστε να αξιολογηθεί η ακρίβεια και η εφαρμοσιμότητα της προτεινόμενης μεθόδου.

2.2 Ισοζύγιο ισχύος ζεύξης (Link Budget)

Μια αξιόπιστη αξιολόγηση της ποιότητας της σύνδεσης μεταξύ δύο σημείων μπορεί να επιτευχθεί μέσω της ανάλυσης της ισχύος του σήματος που λαμβάνει ο δέκτης [31]. Στον τομέα των ασύρματων επικοινωνιών, η τιμή αυτή είναι γνωστή ως RSSI και συνδέεται άμεσα με το ισοζύγιο ισχύος της ζεύξης. Αποτελεί μία από τις κύριες μετρικές για την εκτίμηση της απόδοσης ενός επικοινωνιακού συστήματος. Στην παρούσα μελέτη, η παράμετρος αυτή θα χρησιμοποιηθεί ως ο κύριος δείκτης για τον σχεδιασμό έξυπνων επιφανειών.

Το ισοζύγιο ισχύος μιας ζεύξης αποτυπώνει και συνδυάζει όλα τα επιμέρους κέρδη και απώλειες ισχύος που υφίσταται ένα σήμα σε ένα τηλεπικοινωνιακό σύστημα, το οποίο περιλαμβάνει τον πομπό, το μέσο ή κανάλι επικοινωνίας (όπως ραδιοκύματα, καλώδιο, κυματοδηγό ή οπτική ίνα) και τον δέκτη.



Εικόνα 2.1: Ασύρματη ζεύξη επικοινωνίας με υποβοήθηση RIS. Στη δεξιά πλευρά απεικονίζεται το μοναδιαίο στοιχείο του RIS με τις γωνίες και τις διαστάσεις του [33]

Πρόκειται για μια εξίσωση που ξεκινώντας από την ισχύ εκπομπής και λαμβάνοντας υπόψη τη μείωση λόγω διάδοσης, τα κέρδη των κεραιών, τις απώλειες στη γραμμή τροφοδοσίας και την ενίσχυση του σήματος στον δέκτη ή σε τυχόν επαναλήπτες, προσδιορίζει τη λαμβανόμενη ισχύ. Το ισοζύγιο ισχύος αποτελεί βασικό εργαλείο για τον σχεδιασμό ενός επικοινωνιακού συστήματος, διασφαλίζοντας ότι η λαμβανόμενη ισχύς είναι επαρκής ώστε οι πληροφορίες να μεταδίδονται αξιόπιστα, με ικανοποιητικό λόγο σήματος προς θόρυβο.

Μια απλή μορφή υπολογισμού του ισοζυγίου ισχύος ζεύξης έχει ως εξής:

$$\text{Λαμβανόμενη ισχύς (dBm)} = \text{μεταδιδόμενη ισχύς (dBm)} + \text{κέρδη (dB)} - \text{απώλειες (dB)} \quad [32].$$

Στη μοντελοποίηση της έξυπνης ανακλαστικής επιφάνειας (RIS), η επικοινωνία μεταξύ πομπού και δέκτη μπορεί να περιγραφεί ως ένα τυπικό σύστημα οπισθοσκέδασης. Στην εικόνα 2.1 απεικονίζεται η σχηματική αναπαράσταση του ισοζυγίου ισχύος για μια τέτοια ζεύξη, όπου δύο διακριτές κεραιές βρίσκονται σε διαφορετικές θέσεις και χρησιμοποιούνται αντίστοιχα για την εκπομπή (TX) και τη λήψη (RX) του σήματος.

Παράδειγμα Ασύρματης Επικοινωνίας με RIS

Στη συνέχεια μελετούμε μια ασύρματη ζεύξη επικοινωνίας που υποβοηθείται από RIS, όπως παρουσιάζεται στην εικόνα 2.1. Πρόκειται για ένα σύστημα ασύρματης επικοινωνίας μονής εισόδου-μονής εξόδου (SISO), στο οποίο υποθέτουμε ότι ο πομπός και ο δέκτης βρίσκονται υπό συνθήκες μη οπτικής επαφής (NLOS). Η επικοινωνία τους πραγματοποιείται αποκλειστικά μέσω του RIS. Σύμφωνα με την εικόνα 2.1, ο πομπός (Tx) και ο δέκτης (Rx) απέχουν αντίστοιχα αποστάσεις R_t και R_r από το κέντρο του RIS. Και οι δύο μπορούν να βρίσκονται είτε στην εγγύς είτε στην απότερη περιοχή πεδίου της δομής του RIS. Το RIS αποτελείται από $N \times M$ μοναδιαία στοιχεία $u_{n,m}$, τα οποία έχουν διαστάσεις μικρότερες του μήκους κύματος και είναι διατεταγμένα στο επίπεδο xy . Κάθε μοναδιαίο στοιχείο έχει μήκος D_x και πλάτος D_y . Βάσει της βιβλιογραφίας, το RIS προσεγγίζεται ως ένα σύνολο διακριτών ορθογώνιων σκεδαστών.

Το σήμα εκπέμπεται από τον πομπό προς το RIS, όπου τα επιμέρους μοναδιαία στοιχεία το ανακλούν και το διαχέουν προς τον δέκτη. Οι γωνίες αζιμουθίου και ανύψωσης που καθορίζουν την κατεύθυνση του σήματος από τον πομπό προς το $u_{n,m}$ συμβολίζονται ως $\varphi_{n,m}^t$ και $\theta_{n,m}^t$, ενώ οι αντίστοιχες γωνίες από το $u_{n,m}$ προς τον δέκτη είναι $\varphi_{n,m}^r$ και $\theta_{n,m}^r$. Η ισχύς λαμβανόμενου σήματος P_r σε ασύρματες επικοινωνίες που υποβοηθούνται από RIS, μπορεί να υπολογιστεί σύμφωνα με την σχέση (2.1) [33].

$$P_r = P_t \frac{\lambda^2}{(4\pi)^3} \left| \sum_{n=1}^N \sum_{m=1}^M \frac{\sqrt{G_{Tx}(\theta_{n,m}^t, \varphi_{n,m}^t) G_{Rx}(\theta_{n,m}^r, \varphi_{n,m}^r)} e^{r \cdot \sqrt{\sigma_{n,m}}} e_t}{r_{n,m}^t r_{n,m}^r} e^{-j[k_0(r_{n,m}^r + r_{n,m}^t)]} \right|^2 \quad (2.1)$$

Σε αυτήν την εξίσωση, το λ αντιπροσωπεύει το μήκος κύματος του προσπίπτοντος επίπεδου κύματος, ενώ οι δείκτες n και m αναφέρονται στην αντίστοιχη σειρά και στήλη της προγραμματιζόμενης επιφάνειας. Τα μεγέθη $r_{n,m}^t$ και $r_{n,m}^r$ εκφράζουν την απόσταση της μονάδας κελιού (n, m) από τον πομπό (Tx) και τον δέκτη (Rx), αντίστοιχα. Οι γωνίες ανύψωσης και οι αζιμουθιακές γωνίες του πομπού και του δέκτη, όπως ορίζονται σε σχέση με τη μονάδα κελιού (n, m) , είναι οι $\theta_{n,m}^t, \varphi_{n,m}^t, \theta_{n,m}^r, \varphi_{n,m}^r$. Ο όρος σκέδασης σ που φαίνεται στην εξίσωση (2.1), συμπεριλαμβάνει και όρο φάσης ανάκλασης, καθώς και φαινόμενα πόλωσης [33] και περιγράφεται παρακάτω.

Σύμφωνα με την εξίσωση (2.1) αλλά και την εικόνα 2.1, ο πομπός εκπέμπει ένα σήμα προς το RIS με ισχύ P_t μέσω κεραιάς με κέρδος ισχύος $G_t(\theta_{n,m}^t, \varphi_{n,m}^t)$ με κανονικοποιημένο διάγραμμα ακτινοβολίας ισχύος. Το σήμα ανακλάται από το RIS και στη συνέχεια λαμβάνεται από τον δέκτη, ο οποίος έχει

κέρδος $G_r(\theta_{n,m}^t, \varphi_{n,m}^t)$ με αντίστοιχα κανονικοποιημένο διάγραμμα ακτινοβολίας ισχύος. Επιπλέον, θεωρούμε ότι η πόλωση του πομπού και του δέκτη παραμένει πάντοτε σωστά ευθυγραμμισμένη, ακόμη και μετά την ανάκλαση του σήματος στην επιφάνεια του RIS. Για μια μη ιστροπική κεραία εκπομπής, η πυκνότητα ισχύος \mathcal{P} προς την κατεύθυνση $\theta_{n,m}^t, \varphi_{n,m}^t$, σύμφωνα με τον ορισμό του κέρδους κεραίας και τη διατύπωση της εξίσωσης μετάδοσης του Friis, μπορεί να εκφραστεί ως:

$$\mathcal{P} = \frac{P_t}{4\pi R_t^2} G_t \quad (2.2)$$

Η εξίσωση μετάδοσης του Friis περιγράφει τη σχέση μεταξύ της ισχύος που λαμβάνεται και της ισχύος που εκπέμπεται από δύο κεραίες που βρίσκονται σε απόσταση R . Αν η ισχύς εισόδου στους ακροδέκτες του πομπού, όπως φαίνεται στο σχήμα 2.1, είναι P_t , τότε η ισότροπη πυκνότητα ισχύος \mathcal{P} σε απόσταση R από την κεραία ισούται με το πηλίκο της ισχύος P_t προς το τετράγωνο της απόστασης R , πολλαπλασιασμένο με το κέρδος της κεραίας G_t . Η πυκνότητα ισχύος \mathcal{P} εκφράζεται σε Watt ανά τετραγωνικό μέτρο (W/m^2) [34].

Διατομή σκέδασης ραντάρ (Radar Cross Section, RCS)

Στην εξίσωση (2.1) χρησιμοποιείται η διατομή σκέδασης ραντάρ (Radar Cross Section - RCS), που συμβολίζεται με σ και εκφράζει την ανακλώμενη ισχύ από έναν στόχο προς μια συγκεκριμένη κατεύθυνση, όταν αυτός δέχεται ακτινοβολία από ένα επίπεδο ηλεκτρομαγνητικό κύμα. Με απλούστερα λόγια, το RCS αντιπροσωπεύει την ισοδύναμη επιφάνεια που αναχαιτίζει την προσπίπτουσα ισχύ και, όταν τη διασκορπίζει ομοιόμορφα, δημιουργεί στον δέκτη την ίδια πυκνότητα ισχύος με αυτή που θα προερχόταν από τον πραγματικό στόχο. Ο ακριβής υπολογισμός του γίνεται μέσω της σχέσης ορισμού.

$$\sigma = \lim_{R \rightarrow \infty} 4\pi R^2 \frac{|E_s|^2}{|E_i|^2}$$

όπου R είναι η απόσταση του ραντάρ από τον στόχο, E_s η ένταση του ηλεκτρικού πεδίου του σκεδαζόμενου κύματος και E_i η ένταση του ηλεκτρικού πεδίου του προσπίπτοντος κύματος. Η διατομή σκέδασης ραντάρ σ μετριέται σε τετραγωνικά μέτρα (m^2) και συχνά εκφράζεται σε λογαριθμική κλίμακα $\text{dB}(\text{m}^2)$ ή dBsm , σύμφωνα με τη σχέση:

$$\sigma(\text{dBsm}) = 10 \log\left(\frac{\sigma}{1\text{m}^2}\right)$$

λόγω της μεγάλης διακύμανσης των πιθανών τιμών της. Το RCS αποτελεί μια χαρακτηριστική παράμετρο ενός ανακλαστικού αντικειμένου και εξαρτάται από διάφορους παράγοντες, όπως η γεωμετρία και τα εξωτερικά χαρακτηριστικά του στόχου, η κατεύθυνση του ηλεκτρομαγνητικού κύματος που εκπέμπει το ραντάρ, η συχνότητά του και το υλικό κατασκευής του αντικειμένου.

Επιπλέον, το RCS ενός στόχου επηρεάζεται από τη γωνία πρόσπτωσης, τη συχνότητα και την πόλωση του κύματος, χωρίς να αντιστοιχεί απαραίτητα σε κάποια φυσική επιφάνεια του αντικειμένου. Αν οι διαστάσεις του αντικειμένου είναι πολύ μεγαλύτερες από το μήκος κύματος, τότε το RCS μιας αγωγίμης πλάκας προσεγγίζει τη φυσική της επιφάνεια A στη διεύθυνση κάθετης πρόσπτωσης.

Γενικά, το RCS υπολογίζεται για απλά γεωμετρικά σχήματα μέσω μαθηματικών μεθόδων, ενώ για πιο σύνθετες δομές απαιτούνται υπολογιστικές τεχνικές.

Το ισοζύγιο ισχύος της ζεύξης σε περίπτωση σκέδασης από μια δομή περιγράφεται μέσω της εξίσωσης του ραντάρ [35]. Συγκεκριμένα, για έναν στόχο με διατομή σκέδασης ραντάρ (RCS) σ , ο οποίος

βρίσκεται σε απόσταση R_t από την κεραία εκπομπής με κέρδος G_t και απόσταση R_r από την κεραία λήψης με κέρδος G_r , η ισχύς λήψης προκύπτει από τις σχέσεις (2.1) και (2.2) ως εξής:

$$P_r = P' A_{r,eff} = \frac{\sigma \mathcal{P}}{4\pi R_r^2} \frac{\lambda^2}{4\pi} G_r = P_t \frac{\lambda^2 G_t G_r \sigma}{(4\pi)^3 R_t^2 R_r^2} \quad (2.3)$$

Η (2.3) είναι η εξίσωση του ραντάρ, η οποία και θα εφαρμοστεί για τον υπολογισμό της ισχύος λήψης λόγω ανάκλασης από μια επιφάνεια RIS, μέσω της υπέρθεσης των επιμέρους κυμάτων που προέρχονται από κάθε μοναδιαίο κελί της επιφάνειας. Στον υπολογισμό αυτό λαμβάνονται υπόψη τόσο το μέτρο όσο και η φάση του συντελεστή ανάκλασης κάθε κελιού, καθώς και η φάση του κύματος που οφείλεται στη διαφορά διαδρομής από τον πομπό προς την επιφάνεια και από την επιφάνεια προς τον δέκτη. Μια τέτοια μεθοδολογία εφαρμόζεται και σε παλιότερα μοντέλα υπολογισμού της λαμβανόμενης ισχύος από επιφάνεια RIS, τα οποία υπάρχουν στη βιβλιογραφία [4].

Ωστόσο, για την ορθή εξαγωγή ενός ακριβούς και συνεπούς μοντέλου βάσει της θεωρίας της Φυσικής Οπτικής, χρησιμοποιείται μία τροποποιημένη εκδοχή της διατομής σκέδασης, η οποία εμπεριέχει και πληροφορία φάσης, κάτι που δεν συμπεριλαμβάνεται στο συμβατικό ορισμό της (2.2) αλλά και την πληροφορία της πόλωσης, τόσο της κεραίας του πομπού, όσο και της κεραίας του δέκτη [33]. Ειδικότερα, η γενικευμένη τετραγωνική ρίζα της διατομής σκέδασης ορίζεται ως

$$\sqrt{\sigma_{n,m}^{uv}} = \lim_{R \rightarrow \infty} \sqrt{4\pi R} \frac{\mathbf{E}_s \cdot \hat{\mathbf{u}}}{\mathbf{E}_i \cdot \hat{\mathbf{v}}} \quad (2.4)$$

όπου u, v δύο αυθαίρετες κατευθύνσεις πόλωσης στον τρισδιάστατο χώρο και οι συνιστώσες, αντίστοιχα, του σκεδαζόμενου (s) και προσπίπτοντος κύματος (i) περιλαμβάνουν και την πληροφορία φάσης. Κατά συνέπεια, σε ένα σύστημα σφαιρικών συντεταγμένων η γενικευμένη τετραγωνική ρίζα της διατομής σκέδασης παίρνει τη μορφή ενός ταυστή (tensor) ή πίνακα της μορφής

$$\overline{\overline{\sqrt{\sigma_{n,m}}}} = \begin{bmatrix} \sqrt{\sigma_{n,m}^{\theta\theta}} & \sqrt{\sigma_{n,m}^{\theta\phi}} \\ \sqrt{\sigma_{n,m}^{\phi\theta}} & \sqrt{\sigma_{n,m}^{\phi\phi}} \end{bmatrix} \quad (2.5)$$

Επομένως, ανάλογα με την πόλωση \mathbf{e}_t του εκπεμπόμενου κύματος (της κεραίας εκπομπής) και, αντίστοιχα, την πόλωση \mathbf{e}_r της κεραίας του δέκτη, οι οποίες μπορεί να είναι είτε κάθετη (TE ή $\hat{\phi}$) είτε παράλληλη (TM ή $\hat{\theta}$), ο σύνθετος όρος σκέδασης $\mathbf{e}_r \cdot \overline{\overline{\sqrt{\sigma_{n,m}}}} \mathbf{e}_t$ της εξίσωσης (2.1) παίρνει απλά τη μορφή ενός από τα τέσσερα στοιχεία του πίνακα (2.5). Τέλος, βάσει της θεωρίας της φυσικής οπτικής, αποδεικνύεται [33] ότι τα στοιχεία του πίνακα (2.5) για κάθε μοναδιαίο κελί (παραλείπουμε τους δείκτες m, n για απλότητα) δίνονται από τις ακόλουθες απλές εκφράσεις

$$\begin{aligned} \sqrt{\sigma_{\theta\theta}} &= \frac{D_x D_y k_0}{\sqrt{4\pi}} I_{xy} \cos\varphi [\cos\theta_t (1 + \Gamma_{TM}) - \cos\theta (1 - \Gamma_{TM})]^2 \\ \sqrt{\sigma_{\phi\theta}} &= \frac{D_x D_y k_0}{\sqrt{4\pi}} I_{xy} \sin\varphi [(1 - \Gamma_{TM}) - \cos\theta \cos\theta_t (1 + \Gamma_{TM})]^2 \\ \sqrt{\sigma_{\theta\phi}} &= \frac{D_x D_y k_0}{\sqrt{4\pi}} I_{xy} \sin\varphi [\cos\theta \cos\theta_t (1 - \Gamma_{TE}) - (1 + \Gamma_{TE})]^2 \\ \sqrt{\sigma_{\phi\phi}} &= \frac{D_x D_y k_0}{\sqrt{4\pi}} I_{xy} \cos\varphi [\cos\theta_t (1 - \Gamma_{TE}) - \cos\theta (1 + \Gamma_{TE})]^2 \end{aligned} \quad (2.6)$$

όπου υποθέτουμε, χωρίς να βλάπτεται η γενικότητα, επίπεδο πρόσπτωσης το xz ($\varphi_t = 0$), θ_t είναι η γωνία πρόσπτωσης (ως προς τον άξονα z), φ η γωνία (αζιμούθιο) του επιπέδου ανάκλασης ως προς τον άξονα x και θ η γωνία ανάκλασης ως προς τον άξονα z . Ο όρος I_{xy} δίνεται από τη σχέση

$$I_{xy} = \frac{\sin\left(\frac{k_0 D_x}{2} \sin\theta \cos\varphi\right) \sin\left(\frac{k_0 D_y}{2} \sin\theta \sin\varphi\right)}{\frac{k_0 D_x}{2} \sin\theta \cos\varphi} \frac{\sin\left(\frac{k_0 D_y}{2} \sin\theta \sin\varphi\right)}{\frac{k_0 D_y}{2} \sin\theta \sin\varphi} \quad (2.7)$$

ενώ Γ_{TM} και Γ_{TE} είναι οι συντελεστές ανάκλασης του μοναδιαίου κελιού, για τις αντίστοιχες πολώσεις και οι οποίοι εξάγονται από την υπολογιστική ανάλυση του μοναδιαίου κελιού σε λογισμικό πλήρως κυματικής ανάλυσης. Στην παρούσα εργασία, οι συντελεστές ανάκλασης θεωρούνται γνωστοί και λαμβάνονται από σχετικό αρχείο που έχει προκύψει από την ανάλυση του μοναδιαίου κελιού. Οι παραπάνω σχέσεις συνθέτουν το συνολικό μοντέλο διάδοσης για τη σύνθετη επιφάνεια RIS, το οποίο έχει επαληθευτεί για την ορθότητά του σε σχέση με λογισμικό πλήρως κυματικής ανάλυσης [33]. Το μοντέλο αυτό παρουσιάζει σημαντική πολυπλοκότητα ως προς το σχεδιασμό και την ανάπτυξή του και εφαρμόζει με συνεπή και ορθό τρόπο τις αρχές της ηλεκτρομαγνητικής θεωρίας. Η εφαρμογή του, ωστόσο, είναι αρκετά απλή, καθώς υλοποιεί τη σχέση (2.1) ως ένα διπλό άθροισμα, με εφαρμογή της κατάλληλης κάθε φορά, ανάλογα με την πόλωση του προσπίπτοντος και του σκεδαζόμενου πεδίου, διατομή σκέδασης από τη (2.6) και τη (2.7), σε συνδυασμό με απλές γεωμετρικές σχέσεις για τον υπολογισμό των γωνιών και των αποστάσεων. Ειδικότερα, το μοντέλο επιτυγχάνει υψηλή ακρίβεια, αντίστοιχη με πλήρως κυματικές υπολογιστικές μεθόδους και σχετικό εμπορικό λογισμικό, αλλά σε χρόνους της τάξης του δευτερολέπτου σε έναν κοινό H/Y, τάξεις μεγέθους μικρότερους από τους χρόνους που απαιτούν οι παραπάνω υπολογιστικές μέθοδοι. Σημειώνεται ότι η χρήση των μεθόδων αυτών σε μεγάλες μεταεπιφάνειες, διαστάσεων μεγαλύτερων από μερικά μήκη κύματος είναι συνήθως απαγορευτική, λόγω περιορισμού μνήμης αλλά και υπολογιστικού χρόνου, ενώ το μοντέλο [33] παρέχει ταχύτατη ανάλυση και στις περιπτώσεις επιφανειών RIS μεγάλου μεγέθους. Κατά συνέπεια, η μεθοδολογία αυτή αποτελεί ένα ισχυρότατο και ταχύτατο εργαλείο σχεδίασης μεταεπιφανειών RIS.

2.3 Θεωρητικός υπολογισμός φάσης

Μια έξυπνη επιφάνεια RIS μπορεί να χρησιμοποιηθεί για τον πλήρη έλεγχο των ηλεκτρομαγνητικών κυμάτων, επιτυγχάνοντας αυτό μέσω της κατάλληλης ρύθμισης της μετατόπισης φάσης που εισάγει ο συντελεστής ανάκλασης κάθε μοναδιαίου κελιού [36]. Οι βέλτιστες φάσεις της επιφάνειας για τη μεγιστοποίηση της ισχύος στη θέση του δέκτη μπορούν να προσδιοριστούν αναλυτικά σύμφωνα με τον θεωρητικό τύπο:

$$\angle\sigma_{n,m} = k_0(r_{n,m}^r + r_{n,m}^t) \quad (2.8)$$

Ωστόσο, για την κατασκευή ενός πραγματικού RIS που θα προσεγγίζει τη συμπεριφορά μιας ιδανικής επιφάνειας, οι υπολογισμένες ιδανικές φάσεις από την εξίσωση (2.4) πρέπει να μεταφραστούν σε φυσικές γεωμετρικές παραμέτρους του RIS. Αυτές περιλαμβάνουν το σχήμα της μονάδας κυψέλης, την περιοδικότητα, το πάχος του διηλεκτρικού υλικού και τη διηλεκτρική σταθερά.

Επιπλέον, οι απαιτούμενες μετατοπίσεις φάσης μπορούν να επιτευχθούν μέσω ρυθμιζόμενων ηλεκτρονικών στοιχείων, όπως διόδους ελεγχόμενες από τάση (varactors), που συνδέονται σε κάθε μοναδιαίο κελί της επιφάνειας [37].

Αλγόριθμος υπολογισμού της ισχύος λήψης

Ο αλγόριθμος, που στηρίζεται στον τύπο (2.1), περιγράφεται αναλυτικά στις αντίστοιχες οδηγίες του αλγορίθμου:

Αλγόριθμος 1: Υπολογισμός Ισχύος Λήψης RIS

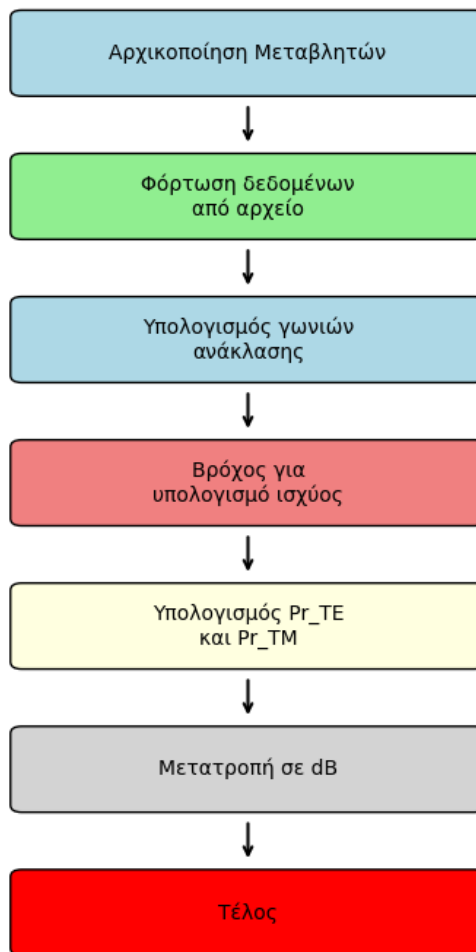
1. Είσοδος λίστας χωρητικότητας (capacity_list)
2. Λήψη δεδομένων από αρχείο για τον υπολογισμό των φάσεων.
3. Εντοπισμός της χωρητικότητας από την λίστα στο αρχείο και εξαγωγή του αριθμού που της αντιστοιχεί.
4. Υπολογισμός του $\angle(\Gamma_{n,m})$ και τοποθέτηση του σε λίστα.
5. Ορισμός αριθμού κελιών και σειρών, ορισμός μεγέθους κελιού, ορισμός μήκους κύματος, αρχικοποίηση $\theta_{n,m}^t$ και δημιουργία της κενής λίστας για τις γωνίες $\theta_{n,m}^r$
6. **for** $l = 1, 2, \dots, \text{angles}$ do
7. Υπολογισμός της γωνίας $\theta_{m,n}^r$, εισαγωγή της στην λίστα και μηδενισμός της ισχύος λήψης P_r
8. **for** $m = 1, 2, \dots, N_x$ do
9. **for** $n = 1, 2, \dots, N_y$ do
10. Υπολογισμός της απόστασης για την γωνία της $\theta_{n,m}^t$ και της $\theta_{n,m}^n$ και τοποθέτηση τους σε πίνακα.
11. Υπολογισμός των γωνιών $\theta_{n,m}^t$ και $\theta_{n,m}^r$.
12. Υπολογισμός του $\sigma(\theta_{n,m}^t, \theta_{n,m}^r)$.
13. Υπολογισμός της ισχύος P_{r_TE} και P_{r_TM} για κάθε γωνία ανάκλασης με χρήση του τύπου αθροίσματος της ισχύος:

$$P_r = P_t \frac{\lambda^2}{(4\pi)^3} \left| \sum_{n=1}^N \sum_{m=1}^M \frac{\sqrt{G_{Tx}(\theta_{n,m}^t, \varphi_{n,m}^t) G_{Rx}(\theta_{n,m}^r, \varphi_{n,m}^r)} \epsilon_r \cdot \sqrt{\sigma_{n,m}} e_t}{r_{n,m}^t r_{n,m}^r} e^{-j[k_0(r_{n,m}^r + r_{n,m}^t)]} \right|^2$$
14. **end for**
15. **end for**
16. **end for**
17. Υπολογισμός της πυκνότητας ισχύος ($10 \times \log_{10}$ (άθροισμα ισχύος ανάκλασης για κάθε προσπίπτουσα γωνία προς την μέγιστη ισχύ από την λίστα των αθροισμάτων ισχύος)).

Πρακτικά ο αλγόριθμος ξεκινά με την αρχικοποίηση των μεταβλητών, όπου ορίζονται όλες οι απαραίτητες παράμετροι που θα χρησιμοποιηθούν στη συνέχεια, όπως αρχικές τιμές, σταθερές και διανύσματα. Στη συνέχεια, γίνεται φόρτωση των δεδομένων από αρχείο, το οποίο περιέχει τις πληροφορίες εισόδου για τον υπολογισμό, όπως τα διάφορα γεωμετρικά χαρακτηριστικά και ακολουθεί

ο υπολογισμός των γωνιών ανάκλασης, κρίσιμος για την ανάλυση της συμπεριφοράς των κυμάτων κατά την πρόσπτωσή τους σε επιφάνειες. Έπειτα, υλοποιείται ένας βρόχος για τον υπολογισμό της ισχύος, όπου πραγματοποιούνται επαναλαμβανόμενοι υπολογισμοί για διάφορες παραμέτρους ή σημεία, ώστε να εξαχθεί η συνολική ισχύς. Με βάση αυτά τα αποτελέσματα, υπολογίζονται ξεχωριστά οι τιμές Pr_{TE} και Pr_{TM} , που αντιστοιχούν στις δύο διαφορετικές πολώσεις του προσπίπτοντος κύματος TE (Transverse Electric) και TM (Transverse Magnetic).

Στη συνέχεια, οι τιμές ισχύος μετατρέπονται σε dB (ντεσιμπέλ), κάτι που διευκολύνει τη σύγκριση και ανάλυση των αποτελεσμάτων. Ο αλγόριθμος ολοκληρώνεται αφού εκτελεστούν όλοι οι υπολογισμοί και παραχθούν τα επιθυμητά αποτελέσματα. Ακολουθεί ένα ενδεικτικό διάγραμμα ροής για τον αλγόριθμο υπολογισμού της ισχύος λήψεως (Εικόνα 2.2).




Εικόνα 2.2: Διάγραμμα ροής αλγορίθμου

2.4 Υλοποίηση του αλγορίθμου

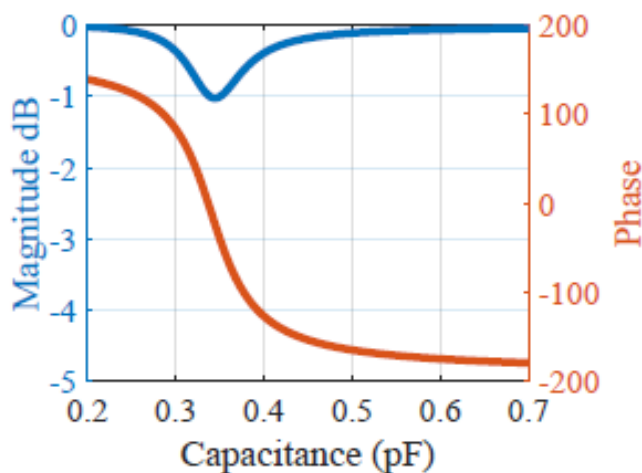
Κατά τη φάση της υλοποίησης και επαλήθευσης του αλγορίθμου, η σχεδίαση στηρίζεται στην εφαρμογή της θεωρίας της ανώμαλης ανάκλασης, η οποία βασίζεται σε θεμελιώδεις αρχές της κυματικής θεωρίας, όπως η αρχή του Fermat. Σύμφωνα με αυτήν, το φως διανύει την απόσταση μεταξύ δύο σημείων ακολουθώντας τη διαδρομή με τον ελάχιστο απαιτούμενο χρόνο σε σχέση με εναλλακτικές κοντινές διαδρομές [38]. Με βάση αυτές τις γενικές αρχές, έχουν αναπτυχθεί προσεγγιστικές αναλυτικές λύσεις για τον υπολογισμό των απαραίτητων χαρακτηριστικών των ηλεκτρονικών στοιχείων και ειδικότερα, των χωρητικοτήτων των διόδων varactor, οι οποίες και χρησιμοποιούνται για τον έλεγχο της ανάκλασης

από κάθε μοναδιαίο κελί και την επίτευξη της λειτουργίας επαναδιαμόρφωσης. Αυτές οι λύσεις λειτουργούν ως εξαιρετικές αρχικές τιμές σε μια διαδικασία ταχείας βελτιστοποίησης, με στόχο τη βέλτιστη απόδοση του συστήματος. Δεδομένου ότι ο αλγόριθμος που παρουσιάζεται στην παρούσα μελέτη αποτελεί μια εντελώς διαφορετική προσέγγιση σε σύγκριση με αυτήν της εργασίας [38], η σύγκριση των αποτελεσμάτων του με εκείνα της εν λόγω μελέτης αποτελεί έναν εξαιρετικό τρόπο επαλήθευσης και αξιολόγησής του.



Εικόνα 2.3: Μονάδα κελιού μορφής Jerusalem Cross [33]

Η ανακλαστική επιφάνεια που εξετάζεται αποτελείται από μια ανομοιόμορφη διάταξη μονάδων κελιών, όπως η μονάδα που φαίνεται στην εικόνα 2.3. Ο σχεδιασμός τους είναι εμπνευσμένος από τη γεωμετρική μορφή του σταυρού της Ιερουσαλήμ (Jerusalem Cross, JC), όπως περιγράφεται και στη σχετική βιβλιογραφία. Από ηλεκτρομαγνητική άποψη, η συγκεκριμένη δομή μπορεί να θεωρηθεί ως ένας τύπος τεχνητού μαγνητικού αγωγού, διαμορφωμένου ως ηλεκτρομαγνητική επιφάνεια που προσομοιώνει αποτελεσματικά τη συμπεριφορά ενός ιδανικού μαγνητικού αγωγού [39].




Εικόνα 2.4: Πλάτος και φάση του συντελεστή ανάκλασης σε συνάρτηση με τη μεταβολή της χωρητικότητας των διόδων varactor [33]

Στην παρούσα εργασία, η γεωμετρία του σταυρού της Ιερουσαλήμ έχει τροποποιηθεί με την προσθήκη φαρδιών αγωγίμων λωρίδων και κενών στα άκρα των κλάδων του, προκειμένου να ενισχυθούν οι χωρητικές του ιδιότητες.

Όπως απεικονίζεται στην εικόνα 2.4, μπορεί να επιτευχθεί μετατόπιση φάσης έως και 320° με ελάχιστη απώλεια πλάτους, μικρότερη από 1 dB. Αξίζει επίσης να τονιστεί ότι μόνο οι δίοδοι varactor που είναι ευθυγραμμισμένες με την πόλωση του ηλεκτρικού πεδίου επηρεάζουν τον συντελεστή ανάκλασης. Αυτό το χαρακτηριστικό είναι ιδιαίτερα αξιοσημείωτο, καθώς επιτρέπει τον σχεδιασμό της μονάδας ώστε να ανταποκρίνεται διαφορετικά σε συνθήκες πόλωσης τύπου TM (εγκάρσια μαγνητική) και TE (εγκάρσια ηλεκτρική) και ανεξάρτητα η μία από την άλλη.

Βασισμένο στη συγκεκριμένη δομή μονάδας κελιού, το RIS έχει σχεδιαστεί ως μια περιοδική επιφάνεια, στην οποία επαναλαμβάνεται μια συστάδα κελιών ή υπερκυψέλη (supercell) που περιλαμβάνει πεπερασμένο αριθμό μονάδων κελιών, κάθε μία με διαφορετική τιμή χωρητικότητας των varactor. Ο σχεδιασμός προήλθε από την εργασία [40] και ακολουθεί μια ταχεία αναλυτική διαδικασία που βασίζεται στην ανάλυση κυμάτων Floquet σε περιοδικές δομές, προσφέροντας μια εξαιρετική αρχική προσέγγιση για το προφίλ ή την κατανομή της χωρητικότητας σε κάθε κελί του supercell. Το συγκεκριμένο προφίλ διαθέτει δύο σημαντικά πλεονεκτήματα: όχι μόνο κατευθύνει την ανακλώμενη ισχύ σχεδόν πλήρως σύμφωνα με τις προδιαγραφές της ανάλυσης Floquet, αλλά επίσης ενισχύει τη συνολική απόδοση της επιφανειακής ακτινοβολίας. Επιπλέον, η προσομοίωση μπορεί να εφαρμοστεί σε ένα ευρύ φάσμα επιθυμητών γωνιών ανάκλασης για ανώμαλη ανάκλαση, αντιστοιχώντας σε διαφορετικές τιμές του αριθμού των μοναδιαίων κελιών ανά supercell.

Η θεωρία Floquet περιγράφει την ανάκλαση ηλεκτρομαγνητικών κυμάτων από περιοδικές επιφάνειες, όπως αυτή που απεικονίζεται στην εικόνα 2.5. Σύμφωνα με τη θεωρία, όταν ένα επίπεδο κύμα προσπίπτει υπό γωνία θ_i , γενικά δημιουργούνται πολλαπλά ανακλώμενα κύματα προς διάφορες κατευθύνσεις, γνωστά ως αρμονικές ή ρυθμοί (κυματικές μορφές) Floquet. Στη γενική τους μορφή, δημιουργείται ένα χωρικό φάσμα άπειρων τέτοιων αρμονικών, ωστόσο ένα μόνον πεπερασμένο σύνολο από αυτές διαδίδεται και ακτινοβολείται στο χώρο.



Εικόνα 2.5: Σενάριο ανώμαλης ανάκλασης ενός transverse electric (TE) πολωμένου επιπέδου κύματος από μια περιοδική αδιαπέραστη επίπεδη επιφάνεια [40]

Το αν αυτές οι αρμονικές θα είναι διαδιδόμενα (propagating) ή αποσβεννόμενα (evanescent) κύματα εξαρτάται τόσο από τη γωνία πρόσπτωσης όσο και, κυρίως, από την περιοδικότητα D , δηλαδή τη διάσταση της υπερκυψέλης στην περιοδική διάταξη. Στην παρακάτω ανάλυση θεωρούμε περιοδικότητα της τάξης του μήκους κύματος, έτσι ώστε η επιφάνεια να υποστηρίζει το μικρότερο δυνατό πλήθος ρυθμών Floquet για ανώμαλη ανάκλαση.

Για δεδομένη περίοδο επανάληψης D και γωνία πρόσπτωσης θ_i , ο κυματικός αριθμός της n -οστής αρμονικής Floquet κατά μήκος της επιφάνειας εκφράζεται ως $\beta_n = k_0 \sin \theta_i + 2\pi n/D$, ενώ ο κυματικός αριθμός στην κάθετη διεύθυνση είναι $q_n = \sqrt{k_0^2 - \beta_n^2}$, όπου $k_0 = 2\pi f/c$ είναι ο κυματικός αριθμός στο κενό. Για να μπορεί η n -οστή αρμονική να διαδίδεται, πρέπει να ισχύει η ανισότητα $k_0 > \beta_n$.

Δεδομένου ότι, σύμφωνα με την κυματική θεωρία, $\beta_n = k_0 \sin \theta_r$ όπου θ_r είναι η γωνία ανάκλασης, η διάσταση της υπερκυψέλης προκύπτει από τη σχέση $D = n\lambda / |\sin \theta_r - \sin \theta_i|$, όπου λ είναι το μήκος κύματος. Για απλούστευση, επιλέγεται να διαδίδονται μόνο αρμονικές Floquet με τάξη $-1 \leq n \leq 1$ [40].

Η προαναφερθείσα μονάδα κελιού έχει προσομοιωθεί και στην μελέτη αναφοράς με τη χρήση εξειδικευμένου λογισμικού ηλεκτρομαγνητικής προσομοίωσης, ενσωματώνοντας και τη διόδο varactor στη συχνότητα των 5.8 GHz, που είναι χαρακτηριστική για εφαρμογές στη μεσαία ζώνη του 5G. Οι διαστάσεις της μονάδας κελιού καθορίστηκαν ως $p = \lambda/10$, ώστε η κατανομή του συντελεστή ανάκλασης στα κελιά του supercell να είναι ομαλή, ενώ το κενό ρυθμίστηκε ώστε να προσαρμόζεται στις φυσικές διαστάσεις μιας διόδου varactor.

Μέσω αυτής της προσομοίωσης, υπολογίστηκε ο συντελεστής ανάκλασης (σε μέτρο και φάση) ο οποίος αποτελεί κρίσιμο παράγοντα για την εκτίμηση της ισχύος λήψης μέσω της σχέσης (2.1) και, συνεπώς, για τον καθορισμό του διαγράμματος ακτινοβολίας της επιφάνειας RIS. Οι τιμές του συντελεστή ανάκλασης συναρτήσει της χωρητικότητας του varactor καταγράφηκαν εκ των προτέρων σε αρχείο, σε συνεργασία με τους συγγραφείς της μελέτης [33]. Με αυτό τον τρόπο είναι διαθέσιμες οι απαιτούμενες χωρητικότητες των διόδων varactor σε κάθε μονάδα κελιού του supercell, προκειμένου να επιτευχθεί ανάκλαση προς την επιθυμητή γωνία.

Η ανάλυση της σκέδασης των επιφανειών RIS που σχεδιάστηκαν στην εργασία αναφοράς ως περιοδικές επιφάνειες άπειρων διαστάσεων, πραγματοποιείται εδώ για μια πεπερασμένη τετράγωνη επιφάνεια διαστάσεων $a = b = D = M \times p$ (όπου M είναι το πλήθος μοναδιαίων κελιών στο supercell) στο μακρινό πεδίο, με γωνία πρόσπτωσης $\theta_t = 0^\circ$. Ο υπολογισμός γίνεται με την προσέγγιση διπλής άθροισης, χρησιμοποιώντας τη σχέση (2.1) και τους τύπους της διατομής σκέδασης (2.6). Στην προσομοίωση λαμβάνονται υπόψη τόσο η δομή των υπερκυψελών όσο και ο συντελεστής ανάκλασης κάθε μοναδιαίου κελιού.

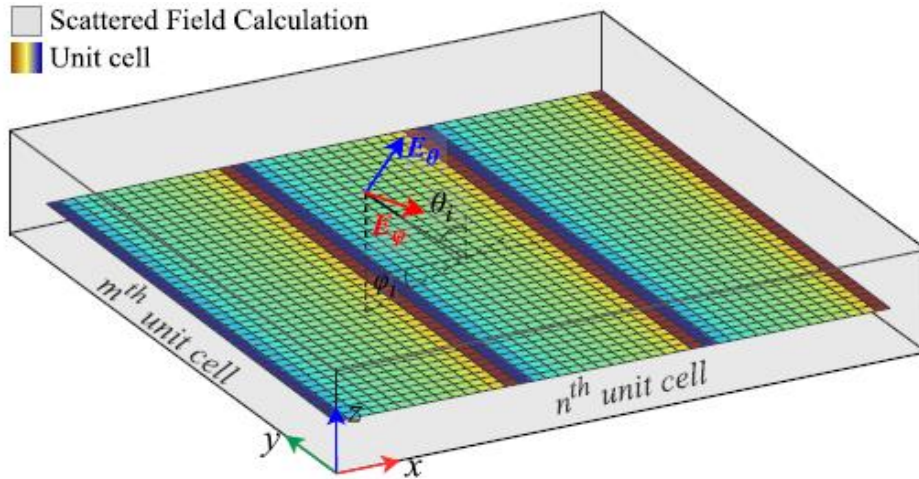
Συγκεκριμένα, αξιολογούνται οι επαναδιαμορφώσιμες ανακλαστικές επιφάνειες της εργασίας αναφοράς, όπου ένα επίπεδο κύμα που προσπίπτει κάθετα μετατρέπεται σε ανακλώμενο κύμα σε γωνίες ανάκλασης εντός του εύρους $\theta_r \in [30^\circ, 65^\circ]$. Για κάθετη πρόσπτωση ($\theta_i = 0$), οι αρμονικές Floquet με τάξη $n > 1$ είναι αποσβεννύμενες όταν $\theta_r \geq 30^\circ$, συνεπώς υπάρχουν δυνητικά τρία σκεδαζόμενα κύματα στις γωνίες 0° , θ_r και $-\theta_r$. Ωστόσο, η ίδια θεωρητική ανάλυση εξακολουθεί να ισχύει και για γωνίες $\theta_r < 30^\circ$, όπου ενδέχεται να εμφανιστούν περισσότερες μορφές ακτινοβολίας, οι οποίες πρέπει να διερευνηθούν περαιτέρω. Οι γωνίες ανάκλασης που μελετώνται καθορίζονται από τις διαστάσεις του υπερκελιού, σύμφωνα με τη σχέση $D = M \times p$, όπου M αντιπροσωπεύει τον αριθμό των μοναδιαίων κελιών στο υπερκελί και p είναι η διάσταση του μοναδιαίου κελιού. Επομένως, οι δυνατές γωνίες ανάκλασης παίρνουν συγκεκριμένες τιμές, όπως παρουσιάζονται στον πίνακα 2.1, βάσει της εξίσωσης:

$$D = \frac{n\lambda}{|\sin \theta_r - \sin \theta_i|}$$

Γωνία ανάκλασης	56°	65°
Πλήθος κελιών ανά supercell	12	11

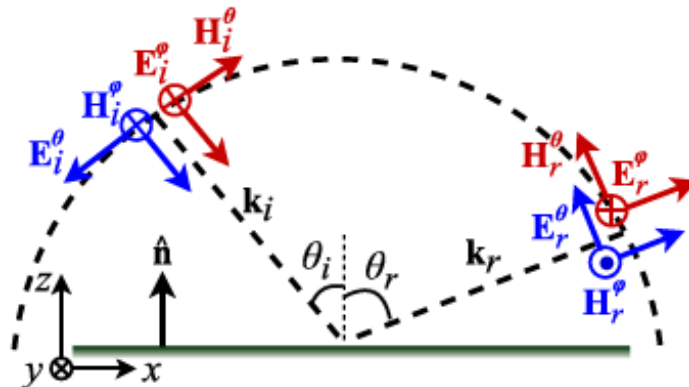
Πίνακας 2.1: Πλήθος μονάδων κελιών ανά supercell για διαφορετικές γωνίες ανάκλασης θ_r

Πιο συγκεκριμένα, η υπό εξέταση δομή της εργασίας αναφοράς περιλαμβάνει τη διακριτή δομή του RIS, όπου $N = M = 42$, όπως φαίνεται στην εικόνα 2.6, το οποίο σχηματίζει μια πεπερασμένη περιοδική δομή. Στο πλαίσιο της προσομοίωσης της δομής του RIS, εφαρμόζεται ανισοτροπική οριακή συνθήκη επιφανειακής αντίστασης για την αποδοτική απεικόνιση της απόκρισης των κυψελών. Η διέγερση λαμβάνει υπόψη τα χαρακτηριστικά του πομπού, με χρήση επιπέδου ή σφαιρικού κύματος, ανάλογα με την απόστασή του από το RIS. Η περιοχή προσομοίωσης περιβάλλεται από perfectly matched layers (PML), ενώ σε περιπτώσεις συμμετρίας εφαρμόζεται επίπεδο συμμετρίας για μείωση του υπολογιστικού κόστους.



Εικόνα 2.6: Σχηματική απεικόνιση της περιοχής πλήρους κυματικής προσομοίωσης με τη διακριτή δομή του RIS, όπου $N = M = 42$ (14 μονάδες κελιών ανά περίοδο) [33]

Είναι επίσης σημαντικό να επισημανθεί ότι μόνο οι δίοδοι μεταβλητής χωρητικότητας που ευθυγραμμίζονται με την πόλωση του ηλεκτρικού πεδίου επηρεάζουν τον συντελεστή ανάκλασης. Αυτό προσδίδει ιδιαίτερο ενδιαφέρον, καθώς δίνει τη δυνατότητα σχεδιασμού της μοναδιαίας κυψέλης με τρόπο που να αποκρίνεται διαφορετικά ανάλογα με το αν το προσπίπτον κύμα έχει TM ή TE πόλωση (Εικόνα 2.7).

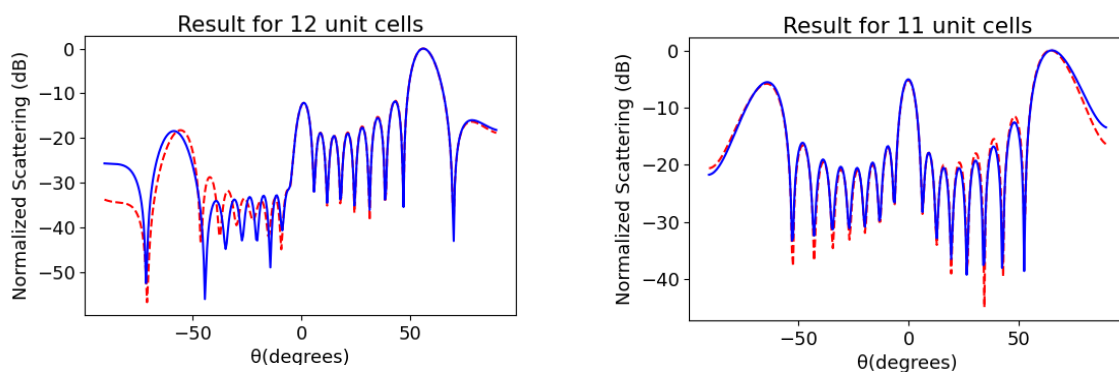


Εικόνα 2.7: Σενάριο ανώμαλης ανάκλασης από μια αδιαπέραστη επιφάνεια μηδενικού πάχους με σύνθετη αντίσταση. (Κόκκινο) Τρόπος πόλωσης εγκάρσιου ηλεκτρικού πεδίου (TE) και (μπλε) τρόπος πόλωσης εγκάρσιου μαγνητικού πεδίου (TM) [33]

2.5 Αποτελέσματα

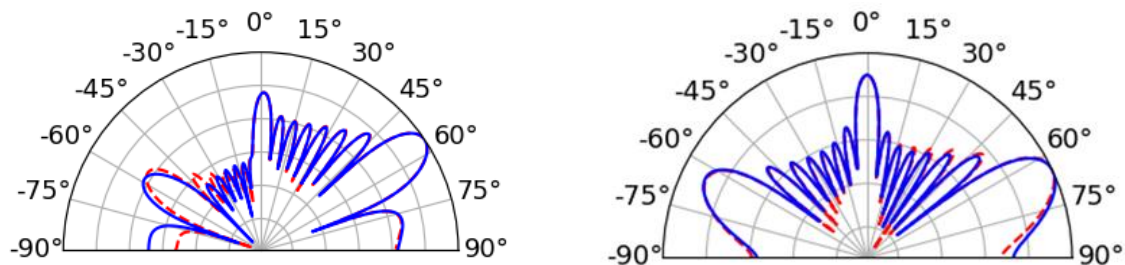
Για την εξαγωγή των αποτελεσμάτων, το πρόγραμμα υπολογισμού της ισχύος λήψης, υλοποιημένο σε γλώσσα Python, εκτελέστηκε δύο φορές, μία για κάθε supercell, με 12 και 11 μονάδες κελιών αντίστοιχα. Χρησιμοποιήθηκε 8-πύρηνη CPU της AMD (AMD Ryzen 7 3800X 8-Core Processor 3.90 GHz).

Σε κάθε εκτέλεση, από το αρχείο δεδομένων αντλήθηκε ο αντίστοιχος αριθμός τιμών συντελεστών ανάκλασης, ανάλογα με το πλήθος των μονάδων κελιών που συγκροτούν κάθε supercell. Για γωνίες ανάκλασης περίπου 56° και 65° , οι οποίες κρίθηκαν ότι αποτελούν τις πλέον απαιτητικές σχεδιάσεις, και μετά την εκτέλεση του κώδικα που υλοποιεί τον Αλγόριθμο 1, τα αποτελέσματα παρουσιάζονται σε καρτεσιανή μορφή για την κατανομή της ισχύος λήψης στην εικόνα 2.8 και σε πολικά διαγράμματα για την κατευθυντικότητα της ισχύος λήψης στην εικόνα 2.9.



Εικόνα 2.8: Διαγράμματα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης για γωνίες ανάκλασης 56° και 65° , και πλήθους μονάδων κυψελών ανά supercell 12 και 11 αντίστοιχα TE (κόκκινο), TM (μπλε)

Τα διαγράμματα ακτινοβολίας, όπως παρουσιάζονται σε καρτεσιανή και πολική μορφή, οδηγούν σε επαρκή συμπεράσματα όσον αφορά τη σύγκρισή τους με τη θεωρητική συμπεριφορά της άπειρης μεταεπιφάνειας, όπως αυτή σχεδιάστηκε. Συγκεκριμένα, παρατηρείται μια σχετικά ικανοποιητική συμφωνία στην περίπτωση της ανώμαλης ανάκλασης για γωνίες 56° και 65° . Αξίζει να σημειωθεί ότι όσο μεγαλύτερη είναι η απόκλιση της επιθυμητής γωνίας ανάκλασης από τη γωνία πρόσπτωσης ($\theta_0 = 0$), τόσο πιο απαιτητική γίνεται η σχεδίαση, καθώς αυξάνεται τόσο το εύρος του κύριου λοβού όσο και το ύψος των πλευρικών λοβών.



Εικόνα 2.9: Πολικό διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης για τις καλύτερες τιμές χωρητικότητας του test set στις 560 και 12 μονάδων κυψελών ανά supercell. TE (κόκκινο), TM (μπλε)

Παρόλα αυτά, είναι προφανές ότι η σχέση (2.1) παρέχει μια αξιόπιστη μεθοδολογία για τον υπολογισμό της ισχύος λήψης (RSSI) από μια πεπερασμένων διαστάσεων έξυπνη επιφάνεια RIS. Μια επιπλέον επιβεβαίωση της ορθότητας του μοντέλου προκύπτει και από τη σύγκριση και σχετική συμφωνία των

αποτελεσμάτων με αυτά της εργασίας [40], στην οποία ο υπολογισμός έγινε με τελείως διαφορετική μεθοδολογία (ανάλυση πεπερασμένων στοιχείων στις δύο διαστάσεις).

Τέλος, ως ένα επιπλέον ιδιαίτερα σημαντικό στοιχείο κρίνεται το ότι η εφαρμογή απλών μεθόδων βελτιστοποίησης στην εργασία [40] δεν οδηγεί σε ιδιαίτερα αποτελεσματικές σχεδιάσεις, καθώς όπως φαίνεται από τις εικόνες 2.8 και 2.9, τα επίπεδα των μη επιθυμητών λοβών ακτινοβολίας στις 0° και τις -56° (ή -65°) που αντιστοιχούν στα κύματα Floquet 0 και -1, αντίστοιχα, είναι αρκετά υψηλά, μόλις 4-5 dB κάτω από τον επιθυμητό λοβό για την περίπτωση των 65° . Συνεπώς κρίνεται ως ιδιαίτερα επιτακτική η ανάγκη εφαρμογής αποτελεσματικότερων μεθόδων σχεδίασης, στις οποίες το ύψος των μη επιθυμητών λοβών ακτινοβολίας να κρατείται σε χαμηλά επίπεδα. Στο πρόβλημα αυτό θα δώσει λύση η εφαρμογή των μεθόδων μηχανικής μάθησης που θα περιγραφεί στη συνέχεια.

2.6 Επίλογος

Η ανάπτυξη και η αξιολόγηση ενός αλγορίθμου για τον υπολογισμό της ισχύος λήψης (RSSI) σε συστήματα με επιφάνειες RIS αποτέλεσε το κύριο αντικείμενο της παρούσας φάσης της εργασίας. Ο προτεινόμενος αλγόριθμος βασίστηκε στη θεωρία της ανώμαλης ανάκλασης, στις αρχές της κυματικής θεωρίας και, τελικά, στην εφαρμογή της εξίσωσης (2.1), η οποία αθροίζει τις επιμέρους συνεισφορές κάθε μοναδιαίου κελιού της RIS, λαμβάνοντας υπόψη τη διατομή σκέδασης ραντάρ (RCS) και τη φάση του ανακλώμενου κύματος. Μέσα από τη χρήση εξειδικευμένων μεθόδων, όπως η θεωρία Floquet και η εφαρμογή μιας μεθόδου βελτιστοποίησης, επιτεύχθηκε μια βασική σχεδίαση μεταεπιφανειών, με πολλά ωστόσο περιθώρια βελτίωσης.

Τα αποτελέσματα των προσομοιώσεων επιβεβαίωσαν την εγκυρότητα της προσέγγισης, καταδεικνύοντας την ικανότητα των προτεινόμενων δομών να κατευθύνουν την ανακλώμενη ισχύ σύμφωνα με τις απαιτούμενες προδιαγραφές. Η συμφωνία των υπολογισμένων διαγραμμάτων ακτινοβολίας με τις θεωρητικές προβλέψεις υπογραμμίζει την αξιοπιστία της μεθοδολογίας, ενώ η ευελιξία του σχεδιασμού καθιστά δυνατή την προσαρμογή της επιφάνειας RIS σε διαφορετικές εφαρμογές και λειτουργικές απαιτήσεις. Συνεπώς, ο ταχύτατος αλγόριθμος για τον υπολογισμό της ισχύος λήψης μπορεί να αποτελέσει τη βάση για ρεαλιστικό σχεδιασμό RIS χρησιμοποιώντας τεχνικές μηχανικής μάθησης, οι οποίες θα αποτελέσουν το αντικείμενο της επόμενης ενότητας της παρούσας μελέτης.

Κεφάλαιο 3ο: Τεχνικές μηχανικής μάθησης και σχεδίαση επιφάνειας RIS

3.1 Εισαγωγή

Η βελτιστοποίηση της μετατόπισης φάσης του RIS έχει προσεγγιστεί μέσω τριών κύριων μεθόδων: μοντέλα βασισμένα στη φυσική της μεταεπιφάνειας, ευρετικούς αλγορίθμους και τεχνικές μηχανικής μάθησης (ML). Οι φυσικές προσεγγίσεις χρησιμοποιούν προσεγγιστικά αλλά αξιόπιστα μαθηματικά μοντέλα για τη διάδοση των σημάτων, ενώ οι ευρετικοί αλγόριθμοι προσφέρουν ταχύτερες, αλλά επίσης προσεγγιστικές λύσεις, εξισορροπώντας την πολυπλοκότητα με την απόδοση. Ωστόσο, πολλές από αυτές τις τεχνικές προϋποθέτουν τέλεια γνώση του καναλιού (CSI), γεγονός που συχνά περιορίζει την πρακτική εφαρμογή τους. Αντιθέτως, οι αλγόριθμοι μηχανικής μάθησης επιτρέπουν την προσαρμογή στο περιβάλλον επικοινωνίας χωρίς την ανάγκη ακριβούς μοντελοποίησης ή πλήρους πληροφορίας καναλιού, καθιστώντας τους μια υποσχόμενη εναλλακτική [41].

Ο σχεδιασμός των παραμέτρων των έξυπνων επιφανειών RIS αποτελεί ένα κρίσιμο ερευνητικό ζήτημα για την ανάπτυξη των σύγχρονων και μελλοντικών ασύρματων επικοινωνιών. Συνήθως, η διαδικασία αυτή διατυπώνεται ως ένα πρόβλημα βελτιστοποίησης. Ωστόσο, η αντιμετώπιση τέτοιων προβλημάτων παρουσιάζει δύο βασικές προκλήσεις:

- Λόγω των μετατοπίσεων φάσης του συντελεστή ανάκλασης κάθε μοναδιαίου κελιού, η επίλυση του προβλήματος μπορεί να είναι NP-hard (Non-deterministic polynomial-time hardness), καθιστώντας το υπολογιστικά απαιτητικό.
- Υπάρχει ένας εγγενής συσχετισμός μεταξύ των μετατοπίσεων φάσης και άλλων παραμέτρων, όπως η ακτινοβολία της δέσμης, που προκύπτει από την αλληλεπίδραση μεταξύ του χρήστη, του σταθμού βάσης (BS) και της επιφάνειας RIS. Αυτός ο συσχετισμός συμβάλλει στην επίτευξη του στόχου της βελτιστοποίησης, αλλά ταυτόχρονα εισάγει περιορισμούς. Δεδομένου ότι τα περισσότερα προβλήματα βελτιστοποίησης σε δίκτυα με έξυπνες επιφάνειες RIS είναι NP-hard, η εξεύρεση μιας συνολικά βέλτιστης λύσης είναι ανέφικτη [42].

Εξαιτίας της πολυπλοκότητας του προβλήματος και του μεγάλου αριθμού παραμέτρων, η χρήση αλγορίθμων κυρτής βελτιστοποίησης (convex optimization) δεν είναι γενικά εφικτή. Επίσης, οι αλγόριθμοι βελτιστοποίησης, όπως η βελτιστοποίηση τοπολογίας, ο γενετικός αλγόριθμος και οι μέθοδοι βασισμένες στην κλίση της προς ελαχιστοποίηση συνάρτησης (gradient-based), παρόλο που αυτοματοποιούν τη διαδικασία και μειώνουν την ανθρώπινη παρέμβαση, παρουσιάζουν προκλήσεις, όπως η εξάρτηση από την αρχικοποίηση, η πιθανότητα σύγκλισης σε τοπικά αντί για συνολικά βέλτιστες λύσεις, καθώς και η ανάγκη επαναβελτιστοποίησης σε περίπτωση αλλαγής των σχεδιαστικών απαιτήσεων. Συνεπώς, απαιτείται η εφαρμογή μιας βέλτιστης μεθοδολογίας, βασισμένης σε μια υπολογιστικά εφικτή προσέγγιση.

Ως εναλλακτική προσέγγιση, επιλέγουμε τη βαθιά μάθηση η οποία αποτελεί ένα ισχυρό εργαλείο μηχανικής μάθησης με εξαιρετική ικανότητα γενίκευσης και παραγωγής. Χρησιμοποιείται για τον σχεδιασμό μεταεπιφανειών μέσω διαφορετικών προσεγγίσεων, όπως διαδοχικά νευρωνικά δίκτυα, δίκτυα βαθιάς μάθησης Q-learning και γενετικά δίκτυα. Αυτές οι τεχνικές επιτρέπουν την αυτόματη και άμεση δημιουργία σχεδιάσεων χωρίς ανθρώπινη παρέμβαση, επιταχύνοντας τη διαδικασία σχεδιασμού. Ωστόσο, η απόδοση των βαθιών νευρωνικών δικτύων εξαρτάται σε μεγάλο βαθμό από τα δεδομένα

εκπαίδευσής τους. Για απλές δομές, η εκπαίδευση είναι εύκολη, αλλά σε πιο σύνθετα προβλήματα, η συλλογή επαρκών δεδομένων αποτελεί σημαντική πρόκληση.

3.2 Μηχανική Μάθηση και Νευρωνικά Δίκτυα

Καθώς η έρευνα στις μεταεπιφάνειες εξελίσσεται, η τεχνητή νοημοσύνη (AI) γνωρίζει επίσης ραγδαία ανάπτυξη, με εφαρμογές σε πολλούς διαφορετικούς τομείς. Η AI βασίζεται σε αλγορίθμους μηχανικής μάθησης και βαθιάς μάθησης, επιτρέποντας στις μηχανές να προσομοιώνουν την ανθρώπινη σκέψη και να επιλύουν σύνθετα προβλήματα. Η κύρια ιδέα της είναι ότι ένας υπολογιστής εκπαιδεύεται μέσω της ανάλυσης μεγάλων συνόλων δεδομένων, ώστε να μπορεί να λαμβάνει ορθές αποφάσεις.

Η μηχανική μάθηση (ML) έχει τραβήξει το ενδιαφέρον στον τομέα των επικοινωνιών, και ειδικά στα RIS, χάρη στην ικανότητά της να μαθαίνει και να εξερευνά μεγαλύτερα σύνολα πιθανών λύσεων. Η μεταβολή της φάσης στα ανακλαστικά στοιχεία του RIS, καθιστά τη δημιουργία μιας αποτελεσματικής παθητικής τεχνολογίας διαμόρφωσης δέσμης ιδιαίτερα περίπλοκη, ενώ οι παραδοσιακές μέθοδοι απαιτούν χρονοβόρες και ενεργοβόρες διαδικασίες για τη ρύθμιση του RIS. Τα τελευταία χρόνια, οι ερευνητές προσπαθούν να ξεπεράσουν αυτές τις προκλήσεις, εφαρμόζοντας διάφορες τεχνικές ML, ώστε τα συστήματα να μπορούν να αναγνωρίζουν και να επιλύουν προβλήματα αυτόνομα.

Οι περισσότερες προσεγγίσεις μηχανικής μάθησης στηρίζονται στην εκπαίδευση παραμέτρων και στη διαμόρφωση ενός πλαισίου βελτιστοποίησης που καθοδηγεί τις αποφάσεις, βασιζόμενο στα δεδομένα εισόδου. Η αποτελεσματικότητα και η ακρίβεια των μαθηματικών μεθόδων βελτιστοποίησης παίζουν καθοριστικό ρόλο στην ανάπτυξη και την εφαρμογή μοντέλων ML, ιδιαίτερα στη σύγχρονη εποχή της επεξεργασίας μεγάλων όγκων δεδομένων [11].

Τεχνικές Μηχανικής Μάθησης

Η μηχανική μάθηση διαθέτει διάφορες τεχνικές. Οι κυριότερες από αυτές είναι:

1. **Εποπτευόμενη μάθηση (Supervised Learning)** – Εκπαιδεύει ένα μοντέλο με δεδομένα εισόδου και εξόδου για να προβλέπει νέα αποτελέσματα.
2. **Μη εποπτευόμενη μάθηση (Unsupervised Learning)** – Αναλύει μη επισημασμένα δεδομένα για να ανακαλύψει συσχετίσεις και να σχηματίσει ομάδες.
3. **Ενισχυτική μάθηση (Reinforcement Learning)** – Ο πράκτορας μαθαίνει μέσω αλληλεπίδρασης με το περιβάλλον, λαμβάνοντας ανταμοιβές για τις ενέργειές του.
4. **Βαθιά μάθηση (Deep Learning)** – Υποσύνολο της ML που χρησιμοποιεί νευρωνικά δίκτυα για ιεραρχική επεξεργασία δεδομένων και έχει εφαρμογές σε οπτική αναγνώριση, γλώσσα και μεγάλα δεδομένα.
5. **Ομοσπονδιακή μάθηση (Federated Learning)** – Επιτρέπει την αποκεντρωμένη εκπαίδευση μοντέλων σε πολλές συσκευές, διατηρώντας ιδιωτικότητα στην χρήση και στο διαμοιρασμό των δεδομένων.
6. **Μάθηση με μεταφορά (Transfer Learning)** – Χρησιμοποιεί γνώση από προηγούμενες εργασίες για τη βελτίωση της απόδοσης σε νέες εργασίες, εξοικονομώντας πόρους εκπαίδευσης [10].

Οι τεχνικές αυτές είναι κρίσιμες για την ανάπτυξη της τεχνητής νοημοσύνης και της ανάλυσης μεγάλων δεδομένων, προσφέροντας λύσεις σε διάφορους τομείς, όπως η επιστήμη δεδομένων, η ρομποτική και οι επικοινωνίες.

Βαθιά Μάθηση και Αντίστροφος Σχεδιασμός RIS

Η βαθιά μάθηση (DL) στην οποία θα εστιάσουμε στην παρούσα εργασία, βασίζεται στη χρήση τεχνητών νευρωνικών δικτύων (Artificial Neural Networks - ANNs) για την εκμάθηση της σχέσης μεταξύ των δομικών χαρακτηριστικών ενός μετα-ατόμου και των διακριτών ηλεκτρομαγνητικών αποκρίσεών του. Αυτά τα δίκτυα, γνωστά ως προωθητικά νευρωνικά δίκτυα (Feedforward Neural Network - FFNNs), λειτουργούν ως «μαύρα κουτιά» κατά τη διαδικασία εκπαίδευσης, επιτρέποντας υψηλή ευελιξία στη δομή τους. Μπορούν να συγκροτηθούν από διαφορετικούς τύπους νευρωνικών δικτύων, όπως CNNs ή αναδρομικά νευρωνικά δίκτυα (*Recursive Neural Networks* - RNNs).

Η θεωρητική ικανότητα ενός δικτύου πρόβλεψης να γενικεύει τα αποτελέσματά του εξαρτάται από τη δομή του. Επομένως, κατά τη δημιουργία ενός δικτύου βαθιάς μάθησης, δοκιμάζονται διαφορετικές εκδοχές των forward neural networks ή prediction neural networks (PNNs), με ποικιλία στον αριθμό επιπέδων και κόμβων, τις συναρτήσεις ενεργοποίησης και τους τρόπους σύνδεσης των επιπέδων, μέχρι να επιτευχθεί η επιθυμητή ακρίβεια πρόβλεψης. Επιπλέον, η βέλτιστη δομή του PNN εξαρτάται άμεσα από το εκάστοτε πρόβλημα και το αντίστοιχο σύνολο δεδομένων εκπαίδευσης.

Κατά τη διαδικασία σχεδιασμού μεταεπιφανειών και μετα-ατόμων, το κύριο ενδιαφέρον επικεντρώνεται όχι τόσο στη δομή των PNNs ή στα δεδομένα εκπαίδευσης, αλλά κυρίως στις μεθόδους παραμετρικού σχεδιασμού της γεωμετρίας και των λειτουργιών των μετα-ατόμων, καθώς και στον αντίστροφο σχεδιασμό ως μέρος μιας ευρύτερης έξυπνης σχεδιαστικής διαδικασίας [43].

Χωρίς την ανάγκη βελτιστοποίησης, ένα αντίστροφο τεχνητό νευρωνικό δίκτυο (ANN), το οποίο εξάγει τις γεωμετρικές παραμέτρους από έναν προκαθορισμένο ηλεκτρομαγνητικό στόχο, μπορεί να αποτελέσει μια αποδοτική εναλλακτική λύση στον σχεδιασμό, αξιοποιώντας την ικανότητά του να διαχειρίζεται μη γραμμικές σχέσεις.

Στην αντίστροφη προσέγγιση, οι ηλεκτρομαγνητικές αποκρίσεις εισάγονται ως δεδομένα εισόδου στο ANN, ενώ οι γεωμετρικές μεταβλητές αποτελούν τις εξόδους, χωρίς να απαιτείται επιπλέον κόστος εκπαίδευσης. Μετά την ολοκλήρωση της διαδικασίας εκμάθησης, το αντίστροφο μοντέλο μπορεί να παράγει άμεσα τις επιθυμητές λύσεις.

Επομένως, για τον σχεδιασμό ηλεκτρομαγνητικών συστημάτων, η άμεση χρήση ενός αντίστροφου μοντέλου είναι σημαντικά ταχύτερη από τις ηλεκτρομαγνητικές προσομοιώσεις ή από τα προωθητικά ANN, τα οποία απαιτούν πολλαπλές εκτελέσεις μέσω αλγορίθμων βελτιστοποίησης για να επιτευχθεί το επιθυμητό αποτέλεσμα [44].

3.3 Αρχιτεκτονικές Νευρωνικών Δικτύων

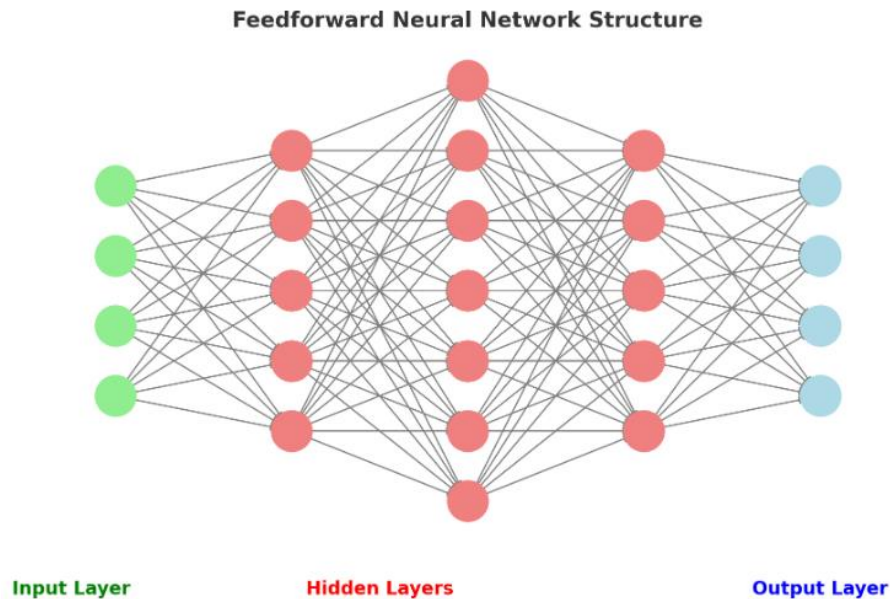
Στις επόμενες ενότητες, θα διερευνήσουμε ορισμένες βασικές αρχιτεκτονικές νευρωνικών δικτύων (Neural Networks - NNs) που εφαρμόζονται σε αυτήν την έρευνα.

Feedforward Neural Network (FFNN)

Τα Προωθητικά Νευρωνικά Δίκτυα (Feed-forward Neural Networks - FFNN) είναι τεχνητά νευρωνικά δίκτυα (ANN) που αποτελούνται από τουλάχιστον τρία επίπεδα με προωθητική ροή δεδομένων, ενώ έχουν την δυνατότητα να διαθέτουν επιπλέον κρυφά επίπεδα (Εικόνα 3.1). Τα FFNN χαρακτηρίζονται από το γεγονός ότι κάθε νευρώνας συνδέεται αποκλειστικά με τους νευρώνες του επόμενου επιπέδου. Αυτό σημαίνει ότι τα δεδομένα κινούνται μονόδρομα, από το επίπεδο εισόδου προς το επίπεδο εξόδου, χωρίς να υπάρχει μηχανισμός ανάδρασης ή επιστροφής πληροφορίας.

Κάθε τεχνητός νευρώνας ή κόμβος του δικτύου, είναι συνδεδεμένος με άλλους κόμβους και διαθέτει καθορισμένο βάρος και κατώφλι ενεργοποίησης. Όταν η έξοδος ενός κόμβου υπερβαίνει μια προκαθορισμένη τιμή κατωφλίου, ενεργοποιείται και μεταφέρει δεδομένα στο επόμενο επίπεδο του δικτύου. Σε διαφορετική περίπτωση, η μεταφορά πληροφοριών δεν πραγματοποιείται [45].

Τα κρυφά επίπεδα του προωθητικού νευρωνικού δικτύου (FFNN) διαθέτουν μεταβαλλόμενο αριθμό νευρώνων, που συνδέονται πλήρως μεταξύ τους. Αυτή η δομή επιτρέπει στο FFNN να προσεγγίζει μη γραμμικές συναρτήσεις διαφορετικής πολυπλοκότητας, με την ικανότητά του να εξαρτάται από το μέγεθος του δικτύου και τη ρύθμιση των υπερπαραμέτρων.



Εικόνα 3.1: Δομή Feedforward Neural Network. Η πληροφορία κινείται μόνο προς μία κατεύθυνση, από την είσοδο έως την έξοδο

Ένα βασικό μειονέκτημα του FFNN είναι ότι επεξεργάζεται τις εισόδους ως ανεξάρτητες μεταξύ τους, χωρίς να λαμβάνει υπόψη τη χρονική τους σχέση. Εξαιτίας της έλλειψης μνήμης και ανάδρασης, αδυνατεί να διαχειριστεί δεδομένα με ακολουθιακές εξαρτήσεις, όπως η πρόβλεψη χρονοσειρών ή η αναγνώριση ομιλίας.

Παρόλα αυτά, το FFNN παρουσιάζει χαμηλή χρονική καθυστέρηση, καθώς οι υπολογισμοί σε κάθε νευρώνα είναι απλοί, γεγονός που το καθιστά ιδανικό για εφαρμογές που απαιτούν γρήγορη απόκριση. Η συνολική πολυπλοκότητά του εξαρτάται από τον αριθμό των επιπέδων και των νευρώνων ανά επίπεδο. Λόγω αυτών των χαρακτηριστικών, αν και έχει περιορισμούς, το FFNN παραμένει χρήσιμο για πολλές εφαρμογές τεχνητής νοημοσύνης [46].

Convolutional Neural Network (CNN)

Το Συνελικτικό Νευρωνικό Δίκτυο (CNN) είναι ένας τύπος προωθητικού νευρωνικού δικτύου που εξάγει χαρακτηριστικά από δεδομένα με συνελικτικές δομές. Σε αντίθεση με τις παραδοσιακές μεθόδους εξαγωγής χαρακτηριστικών, το CNN αυτοματοποιεί αυτή τη διαδικασία, εμπνευσμένο από την ανθρώπινη οπτική αντίληψη. Οι τεχνητοί νευρώνες του CNN προσομοιώνουν τη λειτουργία των βιολογικών νευρώνων, ενώ οι πυρήνες συνέλιξης δρουν ως υποδοχείς που ανιχνεύουν διάφορα χαρακτηριστικά των δεδομένων.

Για την κατασκευή ενός CNN, απαιτούνται βασικά δομικά στοιχεία. Η συνέλιξη αποτελεί το κεντρικό στάδιο εξαγωγής χαρακτηριστικών, δημιουργώντας χάρτες χαρακτηριστικών. Για την αποφυγή απώλειας πληροφορίας στις άκρες της εικόνας, χρησιμοποιείται συμπλήρωση (padding), ενώ το βήμα (stride) ελέγχει την πυκνότητα των υπολογισμών. Μετά τη συνέλιξη, εφαρμόζεται pooling για τη μείωση των περιττών δεδομένων, αποτρέποντας την υπερπροσαρμογή. Οι κύριες τεχνικές pooling είναι η μέγιστη (max pooling) και η μέση (average pooling). Το CNN παρουσιάζει σημαντικά πλεονεκτήματα σε σχέση με τα πλήρως συνδεδεμένα δίκτυα:

- Οι τοπικές συνδέσεις μειώνουν τις παραμέτρους και επιταχύνουν τη σύγκλιση.
- Η κοινή χρήση βαρών μειώνει περαιτέρω τον αριθμό των απαιτούμενων παραμέτρων.
- Η δειγματοληψία (downsampling), μέσω του pooling, το CNN μειώνει τη διάσταση των δεδομένων, διατηρώντας όμως τις πιο κρίσιμες πληροφορίες.

Με αυτά τα χαρακτηριστικά, το CNN αποτελεί έναν από τους πιο αποτελεσματικούς αλγόριθμους στη βαθιά μάθηση, με εφαρμογές στην επεξεργασία εικόνων, την αναγνώριση προτύπων και πολλές άλλες περιοχές τεχνητής νοημοσύνης [47].

Για τη μείωση της υπολογιστικής πολυπλοκότητας στη διαδικασία σχεδιασμού μιας RIS, μπορούν να αξιοποιηθούν αλγόριθμοι βασισμένοι σε CNN για την επίλυση προβλημάτων βελτιστοποίησης. Τα αποτελέσματα προσομοιώσεων έδειξαν ότι τέτοιοι αλγόριθμοι επιτυγχάνουν ταχεία σύγκλιση, βελτιώνοντας τόσο τον συνολικό ρυθμό μετάδοσης όσο και την ενεργειακή απόδοση. Επιπλέον, η γρήγορη σύγκλιση και η χαμηλή υπολογιστική απαίτηση της μεθόδου που βασίζεται σε CNN καθιστούν εφικτή την εφαρμογή της στην τεχνολογία 6G [48].

Recurrent Neural Networks (RNN)

Τα Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNNs) αποτελούν μια κατηγορία τεχνητών νευρωνικών δικτύων (ANN) που επιτρέπουν τη σύνδεση ενός νευρώνα με νευρώνες προηγούμενων επιπέδων.

Ανάλογα με τη συνάρτηση ενεργοποίησης και τον τρόπο σύνδεσης των νευρώνων, τα RNNs μπορούν να διαμορφωθούν σε διάφορες αρχιτεκτονικές, όπως:

- α) στοχαστικά νευρωνικά δίκτυα,
- β) αμφίδρομα νευρωνικά δίκτυα (Binarized Neural Networks - BNNs),
- γ) πλήρως επαναλαμβανόμενα νευρωνικά δίκτυα (Fully Recurrent Neural Network - FRNN),
- δ) νευρωνικές μηχανές Turing (NTMs),
- ε) δίκτυα μακροπρόθεσμης-βραχυπρόθεσμης μνήμης (Long short-term memory - LSTMs),
- στ) δίκτυα κατάστασης αντήχησης (echo state networks),
- ζ) απλά επαναλαμβανόμενα νευρωνικά δίκτυα (Structural Recurrent Neural Network - SRNNs), και
- η) μονάδες πύλης επαναλαμβανόμενου νευρωνικού δικτύου (Gated Recurrent Unit - GRUs) [49]

Σε αντίθεση με τα CNNs, τα RNNs χρησιμοποιούνται κυρίως στην ανάλυση κειμένου και ομιλίας. Το βασικό τους πλεονέκτημα είναι η ικανότητά τους να μαθαίνουν από προηγούμενες καταστάσεις και να προβλέπουν μελλοντικές τιμές, επιτρέποντας την επεξεργασία ακολουθιών δεδομένων όπου κάθε στοιχείο εξαρτάται από το προηγούμενο. Ωστόσο, τα RNNs αντιμετωπίζουν το πρόβλημα της εξαφάνισης ή έκρηξης της κλίσης (gradient vanishing/exploding), γεγονός που οδήγησε στην ανάπτυξη των δικτύων LSTM. Τα LSTM έχουν σχεδιαστεί ειδικά για την επεξεργασία και την πρόβλεψη χρονοσειρών με αβέβαιες χρονικές καθυστερήσεις, χρησιμοποιώντας τρεις βασικές πύλες: την πύλη εισόδου, την πύλη λήθης και την πύλη εξόδου [50].

Τα RNNs είναι πρωτοποριακές αρχιτεκτονικές σχεδιασμένες για την επεξεργασία ακολουθιακών δεδομένων, ενσωματώνοντας μια κρυφή κατάσταση που λειτουργεί ως μνήμη. Χρησιμοποιούνται για την πρόβλεψη της κατάστασης του καναλιού (CSI), ένα κρίσιμο ζήτημα όπου οι παραδοσιακές μέθοδοι παρουσιάζουν περιορισμούς σε ακρίβεια και υπολογιστικό κόστος. Τα RNNs είναι ιδανικά για την επεξεργασία χρονοσειρών και την ανάλυση ασύρματων καναλιών, ιδιαίτερα σε συστήματα massive Multiple-Input Multiple-Output (mMIMO), ενώ η RNN-based πρόβλεψη CSI εμφανίζεται να είναι αποδοτική και να υπερέρχει σε απόδοση έναντι παραδοσιακών μεθόδων, προσφέροντας ακριβέστερα και οικονομικότερα αποτελέσματα [51].

3.4 Αλγόριθμος δημιουργίας του dataset

Η εκπαίδευση των βαθιών νευρωνικών δικτύων (NN) που σχεδιασμός τους θα παρουσιαστεί στη συνέχεια, αξιοποιεί ένα εκτενές σύνολο δεδομένων που δημιουργείται από μια προηγμένη τεχνική προσαρμοστικού beamforming. Η συγκεκριμένη τεχνική βασίζεται στον Αλγόριθμο 1 που παρουσιάστηκε στο Κεφάλαιο 2 και εμπεριέχεται στον Αλγόριθμο δημιουργίας του dataset.

Αλγόριθμος δημιουργίας του dataset

Ο αλγόριθμος δημιουργίας του dataset ακολουθεί μια δομημένη διαδικασία που περιλαμβάνει την αρχικοποίηση παραμέτρων, την επεξεργασία δεδομένων, τον υπολογισμό φυσικών μεγεθών και την αποθήκευση των αποτελεσμάτων. Το dataset που παράγει μπορεί να χρησιμοποιηθεί για εκπαίδευση νευρωνικών δικτύων που θα βρίσκουν βέλτιστους συνδυασμούς χωρητικότητας για εστιασμένη ακτινοβολία.

Αρχικά, ορίζονται οι φυσικές σταθερές που σχετίζονται με το σύστημα, όπως η συχνότητα λειτουργίας, το μήκος κύματος και οι διαστάσεις του πλέγματος εκπομπής και λήψης. Παράλληλα, φορτώνονται οι προκαθορισμένες τιμές χωρητικότητας που θα χρησιμοποιηθούν για τη δημιουργία των δειγμάτων. Ορίζονται επίσης η γωνία στόχευσης και οι γωνίες απωλειών, οι οποίες παίζουν κρίσιμο ρόλο στον υπολογισμό της πυκνότητας ισχύος.

Στη συνέχεια, πραγματοποιείται η ανάγνωση του αρχείου δεδομένων που περιέχει πληροφορίες για τις χωρητικότητες και τους αντίστοιχους συντελεστές ανάκλασης. Για κάθε γωνία λήψης, γίνεται αντιστοίχιση των διαθέσιμων χωρητικότητας με τους συντελεστές ανάκλασης και υπολογίζονται οι αποστάσεις μεταξύ των στοιχείων της διάταξης κεραιών και των σημείων εκπομπής και λήψης. Επιπλέον, χρησιμοποιείται η συνάρτηση sinc για να ληφθούν υπόψη οι επιδράσεις της γωνίας διάδοσης στο τελικό σήμα. Το συνολικό άθροισμα του μεταδιδόμενου σήματος υπολογίζεται και από αυτό προκύπτει η απόλυτη τιμή της πυκνότητας ισχύος.

Για να καταστεί δυνατή η συγκριτική ανάλυση των δεδομένων, η πυκνότητα ισχύος κανονικοποιείται με βάση τη μέγιστη τιμή που παρατηρείται στις επιλεγμένες γωνίες στόχευσης και απωλειών. Η κανονικοποίηση διασφαλίζει ότι όλες οι τιμές βρίσκονται σε κλίμακα μεταξύ 0 και 1, διευκολύνοντας έτσι την περαιτέρω επεξεργασία τους σε αλγόριθμους μηχανικής μάθησης.

Το dataset δημιουργείται επιλέγοντας τυχαία δείγματα από τις διαθέσιμες τιμές χωρητικότητας. Για κάθε σύνολο επιλεγμένων τιμών, υπολογίζεται η αντίστοιχη κανονικοποιημένη πυκνότητα ισχύος και το αποτέλεσμα αποθηκεύεται ως ένα νέο δείγμα δεδομένων. Αυτή η διαδικασία επαναλαμβάνεται μέχρι να συγκεντρωθεί ο επιθυμητός αριθμός δειγμάτων, δημιουργώντας ένα εκτενές και αξιόπιστο σύνολο δεδομένων.

Τέλος, το dataset αποθηκεύεται σε αρχείο κειμένου, όπου κάθε δείγμα περιλαμβάνει τόσο τις κανονικοποιημένες τιμές ισχύος όσο και τις αντίστοιχες χωρητικότητες. Όλες οι αριθμητικές τιμές

στρογγυλοποιούνται στα τρία δεκαδικά ψηφία, διασφαλίζοντας την ακρίβεια και την ομοιομορφία των δεδομένων. Με την ολοκλήρωση της διαδικασίας, το αρχείο περιέχει ένα ολοκληρωμένο σύνολο δεδομένων, έτοιμο για χρήση σε εφαρμογές ανάλυσης και εκπαίδευσης μοντέλων νευρωνικών δικτύων.

Αλγόριθμος 2: Δημιουργίας Dataset

1. Είσοδος λίστας χωρητικότητας (capacity_list)
2. Λήψη δεδομένων από αρχείο για τον υπολογισμό των φάσεων.
3. Εντοπισμός της χωρητικότητας από την λίστα στο αρχείο και εξαγωγή του αριθμού που της αντιστοιχεί.
4. Υπολογισμός του $\angle(\Gamma_{n,m})$ και τοποθέτηση του σε λίστα.
5. Ορισμός αριθμού κελιών και σειρών, ορισμός μεγέθους κελιού, ορισμός μήκους κύματος, αρχικοποίηση $\theta_{n,m}^t$ και δημιουργία της κενής λίστας για τις γωνίες $\theta_{n,m}^r$
6. **for** $l = 1, 2, \dots$, angles **do**
7. Υπολογισμός της γωνίας $\theta_{m,n}^r$, εισαγωγή της στην λίστα και μηδενισμός της ισχύος λήψης P_r
 1. **for** $m = 1, 2, \dots$, N_x **do**
 2. **for** $n = 1, 2, \dots$, N_y **do**
 3. Υπολογισμός της απόστασης για την γωνία της $\theta_{n,m}^r$ και τοποθέτηση της σε πίνακα.
 4. Υπολογισμός της γωνίας $\theta_{n,m}^r$.
 5. Υπολογισμός του $\sigma(\theta_{n,m}^r)$.
6. Υπολογισμός της ισχύος P_r για κάθε γωνία ανάκλασης με χρήση του τύπου αθροίσματος της ισχύος:
$$P_r = P_t \frac{\lambda^2}{(4\pi)^3} \left| \sum_{n=1}^N \sum_{m=1}^M \frac{\sqrt{G_{Tx}(\theta_{n,m}^t, \varphi_{n,m}^t) G_{Rx}(\theta_{n,m}^r, \varphi_{n,m}^r)} e_r \cdot \sqrt{\sigma_{n,m}} e_t}{r_{n,m}^t r_{n,m}^r} e^{-j[k_0(r_{n,m}^r + r_{n,m}^t)]} \right|^2$$
7. **end for**
8. **end for**
9. **end for**
10. Υπολογισμός της πυκνότητας ισχύος $10 \times \log_{10}$ (άθροισμα ισχύος ανάκλασης για κάθε προσπίπτουσα γωνία **προς** την μέγιστη ισχύ από την λίστα των αθροισμάτων ισχύος).
11. Κανονικοποίηση της τιμής ως προς τη μέγιστη τιμή από τη λίστα των αθροισμάτων ισχύος.
12. Αποθήκευση των αποτελεσμάτων σε αρχείο dataset.

Υλοποίηση αλγορίθμου 2 και δημιουργία του dataset

Στην υλοποίηση, λαμβάνονται υπόψη δύο γραμμικές διατάξεις υπερκελιών μεταεπιφάνειας που αποτελούνται από 11 και 12 μοναδιαία κελιά και αντιστοιχούν στις γωνίες στόχους των 65 και 56 μοιρών. Ο αλγόριθμος τροποποιείται κατάλληλα ώστε να δημιουργήσει σύνολα δεδομένων με μεγάλο

πλήθος δειγμάτων. Κάθε δείγμα περιλαμβάνει 11 τυχαίες χωρητικότητες για τις 65ο και 12 για τις 56ο. Αν και θεωρητικά θα μπορούσαμε να χρησιμοποιήσουμε τιμές από το πλήρες σύνολο των χωρητικοτήτων των varactor, δηλαδή ένα συνεχές σύνολο τιμών μεταξύ των 0.2 και 0.7 pF, εισάγουμε εδώ την εξής μεθοδολογία, η οποία και είναι περισσότερο προσαρμοσμένη στη λογική της φυσικής υλοποίησης μιας έξυπνης μεταεπιφάνειας, μέσω ψηφιακών διατάξεων και διακοπτικών στοιχείων: συγκεκριμένα επιλέγουμε μόνον τέσσερις ή οκτώ προκαθορισμένες τιμές χωρητικοτήτων (για υλοποίηση 2 και 3 bit αντίστοιχα), οι οποίες καλύπτουν ομοιόμορφα τις διαθέσιμες τιμές της φάσης του συντελεστή ανάκλασης σε όλο το εύρος τιμών $\{-180^\circ, 180^\circ\}$. Ειδικότερα, επιλέγουμε τιμές χωρητικοτήτων $\{0.411, 0.352, 0.321, 0.218\}$, οι οποίες δίνουν φάσεις του συντελεστή ανάκλασης $\{-135^\circ, -45^\circ, 45^\circ, 135^\circ\}$, αντίστοιχα, για την περίπτωση των τεσσάρων τιμών και χωρητικότητες $\{0.7, 0.411, 0.371, 0.352, 0.337, 0.321, 0.295, 0.218\}$, οι οποίες δίνουν φάσεις του συντελεστή ανάκλασης $\{-180^\circ, -135^\circ, -90^\circ, -45^\circ, 0^\circ, 45^\circ, 90^\circ, 135^\circ\}$, αντίστοιχα, για την περίπτωση των τεσσάρων τιμών. Με την παραπάνω διαδικασία παράγονται δύο σύνολα 400,000 δειγμάτων για την περίπτωση των τεσσάρων τιμών χωρητικότητας και 200.000 για την περίπτωση των οκτώ τιμών. Για κάθε τυχαίο συνδυασμό των 11 ή 12 χωρητικοτήτων υπολογίζουμε την κανονικοποιημένη ισχύ λήψης, σε καθαρό αριθμό, από τον αλγόριθμο 2 στις τρεις γωνίες των κυμάτων Floquet για γωνίες $65^\circ, 0^\circ, -65^\circ$ και $56^\circ, 0^\circ$ και -56° αντίστοιχα.

Στη συνέχεια, στο βαθύ νευρωνικό δίκτυο που υλοποιείται, κάθε τριάδα τιμών κανονικοποιημένης ισχύος χρησιμοποιείται ως είσοδος (π.χ., 0.126, 1.0, 0.532) και συνδέεται άμεσα με μια ακολουθία 11 ή 12 χωρητικοτήτων που χρησιμοποιείται ως τιμή εξόδου (π.χ., 0.218, 0.352, 0.321, ..., 0.218), σχηματίζοντας ζευγάρια εισόδου-εξόδου. Αυτή η αντιστοιχία υποδηλώνει ότι το δίκτυο εκτελεί μια μορφή απεικόνισης όπου οι τρεις εισροές μετασχηματίζονται σε μια πιο πολύπλοκη έξοδο με συγκεκριμένα μοτίβα. Ο χρόνος που απαιτήθηκε για την παραγωγή του συνόλου δεδομένων είναι περίπου 10 ώρες για 200.000 εγγραφές και περίπου 20 ώρες για 400.000 εγγραφές, με χρήση επεξεργαστή AMD Ryzen 7 3800X 8 πυρήνων στα 3.90 GHz και 16GB μνήμης RAM DDR4. Η παραγωγή μεγάλου αριθμού δεδομένων συμβάλλει στην αποφυγή της υπερπροσαρμογής όπου το σφάλμα στο σύνολο εκπαίδευσης είναι σημαντικά μικρότερο από αυτό στο σύνολο δοκιμής, εξασφαλίζοντας την ανάπτυξη ενός μοντέλου με καλή ικανότητα γενίκευσης.


Ο συνολικός αριθμός των πιθανών συνδυασμών για κάθε σύνολο δεδομένων χωρίς δειγματοληψία, υπολογίζεται σε 4^{11} , 4^{12} , 8^{11} και 8^{12} δηλαδή στην μέγιστη περίπτωση των υπολογισμών αυτό ισοδυναμεί με 68,719,476,736 διαφορετικούς συνδυασμούς. Στο πραγματικό dataset που δημιουργείται, η επιλογή της δειγματοληψίας εξασφαλίζει την υπολογιστική εφικτότητα της διαδικασίας. Μια εξαντλητική απαρίθμηση όλων των πιθανών συνδυασμών θα απαιτούσε σημαντικά περισσότερους πόρους, συμπεριλαμβανομένης της μνήμης, η οποία θα έπρεπε να είναι τουλάχιστον δεκαπλάσια, του χρόνου εκτέλεσης, ο οποίος θα αυξανόταν δραματικά λόγω των επαναλαμβανόμενων υπολογισμών ισχύος. Παρά αυτές τις περιορισμένες δυνατότητες, τα δείγματα που δημιουργούνται θεωρούνται επαρκή για την εκπαίδευση μοντέλων μηχανικής μάθησης, εφόσον καλύπτουν επαρκώς τις διάφορες κατηγορίες συμπεριφοράς του συστήματος, όπως υψηλή ή χαμηλή κατευθυντικότητα, με στόχο τη μεγιστοποίηση της ισχύος στις γωνίες στόχους και την ελαχιστοποίησή της σε ανεπιθύμητες κατευθύνσεις.

Ουσιαστικά η υλοποίηση του Αλγορίθμου 2 παρέχει ένα αυτοματοποιημένο εργαλείο για τη δημιουργία δεδομένων που συνδέουν ηλεκτρομαγνητική συμπεριφορά με ρυθμίσεις υλικού. Μπορεί να βοηθήσει στη βελτίωση συστημάτων επικοινωνίας, έξυπνων επιφανειών, χρησιμοποιώντας τεχνικές μηχανικής μάθησης και βελτιστοποίησης.

3.5 Σχεδίαση RIS

Στο επόμενο στάδιο της υλοποίησης, εξετάζεται η ικανότητα των NNs να υποκαταστήσουν τις συμβατικές ντετερμινιστικές μεθόδους διαμόρφωσης δέσμης στην τεχνική null-steering και στην Αυτόματη Διαμόρφωση Δέσμης (ABF). Δομές όπως τα FFNN, τα CNN, καθώς και τα RNN, έχουν αποδείξει κατ' επανάληψη ότι αποτελούν αξιόλογες εναλλακτικές λύσεις, πετυχαίνοντας ισοδύναμη απόδοση στην κατεύθυνση της δέσμης και εξαιρετικά υψηλή ακρίβεια στην εφαρμογή του null-steering. Η συμβολή αυτών των προσεγγίσεων είναι καθοριστική στη μείωση της καθυστέρησης κατά τη διαμόρφωση της δέσμης, δεδομένου ότι η παραγωγή του διανύσματος βαρών αποτελεί κρίσιμο στοιχείο της συνολικής διαδικασίας. Τελικός στόχος είναι η αξιοποίηση των προαναφερθέντων τεχνικών ML για την εκπαίδευση NNs, με σκοπό την ανάπτυξη μοντέλων που παρουσιάζουν μειωμένη χρονική καθυστέρηση.

Η έρευνα επικεντρώνεται στη χρήση NNs ως τεχνική διαμόρφωσης δέσμης χαμηλής πολυπλοκότητας και συγκρίνει διαφορετικές δομές βαθιών νευρωνικών δικτύων ως προς την ακρίβεια και την χρονική απόκριση. Οι Ενότητες 3.5.1, 3.5.2 και 3.5.3 που ακολουθούν, περιγράφουν τη διαδικασία πίσω από τις υλοποιήσεις των FFNN, CNN και RNN και εξηγούν τη διαδικασία αναγνώρισης της βέλτιστης αρχιτεκτονικής για κάθε τύπο νευρωνικού δικτύου πριν από την εκπαίδευση και αξιολόγηση κάθε μοντέλου για να προσδιοριστεί το πιο υποσχόμενο μοντέλο NN. Η υλοποίηση πραγματοποιήθηκε σε γλώσσα προγραμματισμού Python η οποία επιλέχθηκε γιατί αποτελεί μια ιδανική επιλογή για έργα ML και AI, χάρη στην απλότητά της, την αξιοπιστία της και τη συνεπή συμπεριφορά της. Παρέχει επίσης άμεση πρόσβαση σε πληθώρα έτοιμων βιβλιοθηκών και εργαλείων που διευκολύνουν και επιταχύνουν την ανάπτυξη. Επιπλέον, συνεργάζεται εύκολα με άλλες γλώσσες προγραμματισμού και προσφέρει ένα καλά οργανωμένο περιβάλλον για τον έλεγχο και την αποσφαλμάτωση του κώδικα.



Εικόνα 3.2: Δομή Feedforward Neural Network της εφαρμογής. Η έξοδος μεταβάλλεται ανάλογα με την γωνία στόχο (11 για τις 65° και 12 για τις 56°)

3.5.1 Σχεδίαση RIS με FFNN

Ο κώδικας που υλοποιήθηκε αποτελεί ένα ολοκληρωμένο pipeline ML με στόχο την πρόβλεψη των διαμορφώσεων χωρητικότητας βάσει δεδομένων που σχετίζονται με κανονικοποιημένες πυκνότητες ισχύος. Η υλοποίηση γίνεται με τη χρήση της βιβλιοθήκης PyTorch και περιλαμβάνει όλα τα στάδια, από τη φόρτωση και προεπεξεργασία των δεδομένων, μέχρι την εκπαίδευση του μοντέλου, την οπτικοποίηση των αποτελεσμάτων και την επιλογή των βέλτιστων παραμέτρων.

Αρχιτεκτονική Νευρωνικού Δικτύου

Το δίκτυο που χρησιμοποιείται είναι ένα πλήρως συνδεδεμένο πολυεπίπεδο νευρωνικό δίκτυο (Feedforward Neural Network), το οποίο αποτελείται από τρία γραμμικά στρώματα. Τα δύο πρώτα στρώματα διαθέτουν κατά περίπτωση από 8 έως 128 νευρώνες το καθένα και συνοδεύονται από Rectified Linear Unit (ReLU) συνάρτηση ενεργοποίησης η οποία μπορεί να εξάγει μια τιμή που είναι ευθέως ανάλογη προς την είσοδο, παράλληλα διαθέτουν και μηχανισμό Dropout για την αποφυγή υπερπροσαρμογής (Εικόνα 3.2).

Το τελικό στρώμα επιστρέφει τις προβλεπόμενες τιμές χωρητικότητας, οι οποίες είναι συνεχείς μεταβλητές.

Η επιλογή αυτής της αρχιτεκτονικής είναι κατάλληλη για προβλήματα παλινδρόμησης, όπως το παρόν, όπου το μοντέλο μαθαίνει να αντιστοιχίζει διανύσματα εισόδου με συνεχή αποτελέσματα εξόδου.

Φόρτωση και Επεξεργασία Δεδομένων

Η διαδικασία ξεκινά με τη φόρτωση ενός αρχείου κειμένου που περιέχει εναλλάξ γραμμές με κανονικοποιημένες πυκνότητες ισχύος και τις αντίστοιχες διαμορφώσεις χωρητικότητας. Συγκεκριμένα, κάθε ζεύγος γραμμών αντιστοιχεί σε ένα παράδειγμα εκπαίδευσης: η πρώτη γραμμή περιέχει τα χαρακτηριστικά εισόδου (features) και η δεύτερη την αναμενόμενη έξοδο (labels). Τα δεδομένα φορτώνονται σε πίνακες NumPy για περαιτέρω επεξεργασία.

Κατά την προετοιμασία των δεδομένων, οι πίνακες μετατρέπονται σε Tensors του PyTorch και στη συνέχεια διαχωρίζονται σε τρία σύνολα:

- Εκπαιδευτικό σύνολο (70%),
- Σύνολο επικύρωσης (20%),
- Σύνολο δοκιμής (10%).

Αυτός ο διαχωρισμός είναι ιδιαίτερα σημαντικός ώστε να επιτευχθεί σωστή εκπαίδευση του μοντέλου χωρίς υπερπροσαρμογή, καθώς και να αξιολογηθεί η γενικευσιμότητα του.

Εκπαίδευση του Μοντέλου

Η εκπαίδευση γίνεται μέσω της συνάρτησης απώλειας Mean Squared Error (MSE), η οποία είναι ιδανική για προβλήματα παλινδρόμησης. Ο αλγόριθμος που επιλέγεται είναι ο Adam (Adaptive Moment Estimation), ένας βελτιωμένος αλγόριθμος κατηφορικής καθόδου (gradient descent), ο οποίος συνδυάζει τα πλεονεκτήματα της διατήρησης πρώτης τάξης ροπών (momentum) με την κανονικοποίηση του βήματος εκμάθησης ανά παράμετρο. Επιπλέον, εφαρμόζεται κανονικοποίηση L2 - γνωστή και ως weight decay - με σταθερά τακτοποίησης λ ίση με 0.01. Η συγκεκριμένη προσέγγιση λειτουργεί ως μορφή ποινής στις υψηλές τιμές βαρών, καθιστώντας το μοντέλο πιο γενικεύσιμο και ανθεκτικό σε υπερεκπαίδευση.

Ένα σημαντικό χαρακτηριστικό της διαδικασίας εκπαίδευσης είναι η χρήση *early stopping*, δηλαδή η διακοπή της εκπαίδευσης όταν η απόδοση στο *validation set* σταματήσει να βελτιώνεται για έναν προκαθορισμένο αριθμό εποχών. Αυτό προστατεύει από υπερπροσαρμογή και εξοικονομεί χρόνο υπολογισμού. Κατά την εκπαίδευση καταγράφονται και αποθηκεύονται οι απώλειες (*losses*) για το *training* και το *validation set*, έτσι ώστε να μπορούν να αναλυθούν γραφικά.

Οπτικοποίηση Απώλειας

Μετά την ολοκλήρωση της εκπαίδευσης, δημιουργείται γράφημα των τιμών απώλειας ανά εποχή χρησιμοποιώντας τη βιβλιοθήκη *Matplotlib*. Αυτή η γραφική απεικόνιση προσφέρει ξεκάθαρη κατανόηση για το σημείο στο οποίο το μοντέλο άρχισε να παρουσιάζει υπερπροσαρμογή (δηλαδή, αύξηση της απώλειας στο σύνολο επικύρωσης) και για τις εποχές κατά τις οποίες η διαδικασία μάθησης ήταν πιο αποδοτική. Εάν για παράδειγμα η καμπύλη του *validation loss* αρχίζει να αυξάνεται ενώ το *training loss* συνεχίζει να μειώνεται, υποδεικνύεται φαινόμενο υπερεκπαίδευσης.

Επιλογή Βέλτιστης Διαμόρφωσης Χωρητικότητας

Ο κώδικας περιλαμβάνει δύο διαφορετικές στρατηγικές για την επιλογή της αποτελεσματικότερης διαμόρφωσης χωρητικότητας και αφορούν τον υπολογισμό της μέγιστης εγγύτητας στη διάμεσο και του ελάχιστου άθροισματος οι οποίες αναλύονται ως εξής:

Μέγιστη εγγύτητα στη διάμεσο:

Η συνάρτηση `find_best_mid_capacitance_set()` εντοπίζει το δείγμα του οποίου οι δεύτερη και τρίτη τιμές εισόδου είναι πιο κοντά στη διάμεσο του αντίστοιχου χαρακτηριστικού στον συνολικό πληθυσμό. Αυτή η στρατηγική επιλέγει μια “αντιπροσωπευτική” διαμόρφωση.

Ελάχιστο άθροισμα:

Η `find_best_capacitance_set()` επιλέγει το δείγμα που έχει το μικρότερο άθροισμα της δεύτερης και τρίτης στήλης, υπό την προϋπόθεση ότι η πρώτη στήλη είναι 1.0 (σηματοδοτεί ενεργή κατάσταση). Αυτό μπορεί να αντιπροσωπεύει τη βέλτιστη λειτουργία με βάση κάποιου είδους “κόστους”.

Και στις δύο περιπτώσεις, η συνάρτηση επιστρέφει τον καλύτερο συνδυασμό τιμών χωρητικότητας και τον χρόνο που χρειάστηκε για να τον εντοπίσει.

Σταυροειδής Επικύρωση (Cross-validation)

Η διασταυρούμενη επικύρωση είναι μια τεχνική που βασίζεται στην επαναδειγματοληψία και στον καταμερισμό των δεδομένων σε διαφορετικά σύνολα, τα οποία χρησιμοποιούνται εναλλάξ για την εκπαίδευση και την αξιολόγηση ενός μοντέλου σε πολλαπλές επαναλήψεις. Εφαρμόζεται κυρίως σε περιπτώσεις όπου ζητούμενο είναι η πρόβλεψη και επιδιώκεται η εκτίμηση της ακρίβειας με την οποία ένα μοντέλο μπορεί να αποδώσει σε πραγματικές συνθήκες. Επιπλέον, χρησιμεύει στην αξιολόγηση της αποτελεσματικότητας ενός μοντέλου που έχει ήδη προσαρμοστεί στα δεδομένα, καθώς και στη μελέτη της σταθερότητας των παραμέτρων του. Παράλληλα συμβάλλει στη βελτίωση της εκτίμησης της γενικευσιμότητας του μοντέλου και αποτρέπει την εξάρτηση από ένα συγκεκριμένο διαχωρισμό των δεδομένων.

Η αξιοπιστία του μοντέλου αξιολογείται περαιτέρω μέσω σταυροειδούς επικύρωσης (5-πτυχη, $K=5$). Η διαδικασία αυτή περιλαμβάνει:

- Τυχαία διαίρεση του *dataset* σε 5 υποσύνολα.
- Εκπαίδευση του μοντέλου σε 4 υποσύνολα και έλεγχος στο πέμπτο.

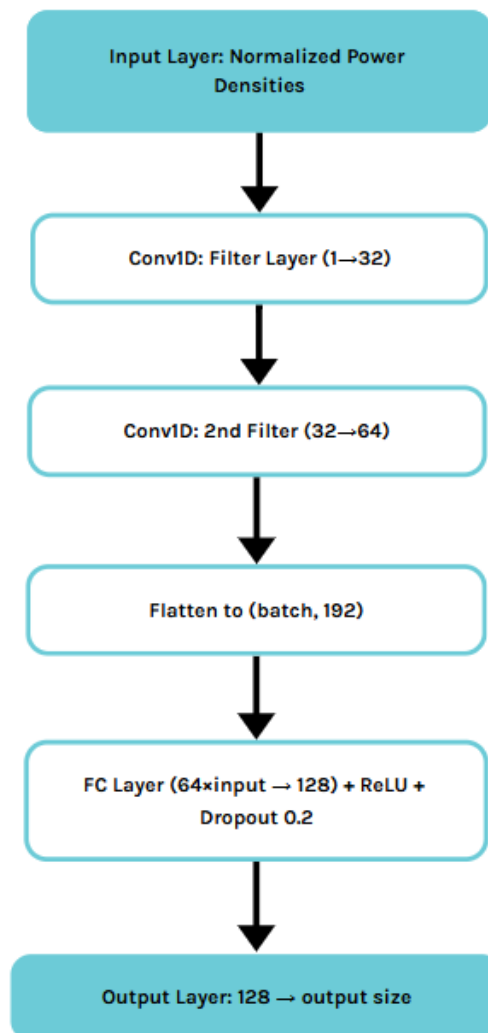
- Επανάληψη της διαδικασίας για κάθε πτυχή.
- Υπολογισμός του μέσου όρου της απώλειας επικύρωσης.

Τελική Εκπαίδευση και Αποθήκευση Μοντέλου

Αφού ολοκληρωθεί το cross-validation, το μοντέλο εκπαιδεύεται ξανά, αυτή τη φορά χρησιμοποιώντας ολόκληρο το training set, και αποθηκεύεται στο αρχείο "final_model.pth". Αυτό το μοντέλο είναι το τελικό και χρησιμοποιείται για να εντοπιστεί η βέλτιστη διαμόρφωση χωρητικότητας από το test set και ολόκληρο το dataset.

Τελική Αξιολόγηση και Αποτελέσματα

Κατά την ολοκλήρωση της διαδικασίας, το σύστημα δίνει τη δυνατότητα εύρεσης της βέλτιστης παραμετροποίησης χωρητικότητας βάσει συγκεκριμένων ενεργειακών κριτηρίων. Πιο συγκεκριμένα, γίνεται έλεγχος των παρατηρήσεων για τις οποίες η πρώτη τιμή κανονικοποιημένης πυκνότητας ισχύος ισούται με 1.0, και από αυτές επιλέγεται εκείνη που ελαχιστοποιεί το άθροισμα των επόμενων δύο τιμών. Με αυτόν τον τρόπο, το δίκτυο υποστηρίζει τη λήψη αποφάσεων στο πεδίο της αποδοτικότερης κατανομής ενέργειας, αξιοποιώντας την πρόβλεψη των εξόδων για την ανάκτηση του πιο «αποδοτικού» συνδυασμού χωρητικότητων.



Εικόνα 3.3: Flow Chart εφαρμογής του Convolutional Neural Network

3.5.2 Σχεδίαση RIS με CNN

Εναλλακτικά υλοποιήθηκε και ένα σύστημα μηχανικής μάθησης βασισμένο σε ένα 1D Συνελικτικό Νευρωνικό Δίκτυο (1D CNN), το οποίο έχει σχεδιαστεί για την πρόβλεψη των κατάλληλων παραμέτρων χωρητικότητας με βάση την κανονικοποιημένη ενεργειακή πυκνότητα ισχύος. Το σύστημα αυτό αποτελεί μία απόπειρα ενσωμάτωσης τεχνικών βαθιάς μάθησης στη βελτιστοποίηση σύνθετων ηλεκτρονικών διαμορφώσεων, με βασικό στόχο τη διαμόρφωση της πιο αποδοτικής διάταξης σύμφωνα με συγκεκριμένες ενεργειακές απαιτήσεις.

Το νευρωνικό δίκτυο που υλοποιείται διαθέτει πανομοιότυπο τρόπο φόρτωσης και επεξεργασίας δεδομένων με αυτόν του FFNN. Ως πυρήνα έχει μία αρχιτεκτονική συνελικτικού τύπου, η οποία προσαρμόζεται κατάλληλα για να επεξεργάζεται μονοδιάστατα δεδομένα εισόδου (Εικόνα 3.3). Σε αντίθεση με τα συμβατικά πλήρως συνδεδεμένα δίκτυα τα οποία παρουσιάζουν υψηλή υπολογιστική πολυπλοκότητα και ενδέχεται να υπερεκπαιδευτούν σε δεδομένα μικρών διαστάσεων, η επιλογή του CNN εδώ προσφέρει πολλαπλά πλεονεκτήματα.

Πιο συγκεκριμένα, οι συνελικτικές στρώσεις αξιοποιούν χωρικές συσχετίσεις εντός της ακολουθίας εισόδου, συλλαμβάνοντας τοπικά μοτίβα τα οποία μπορεί να έχουν λειτουργική σημασία για την πρόβλεψη των παραμέτρων εξόδου.

Η αρχιτεκτονική αποτελείται από δύο συνελικτικές στρώσεις (Conv1D), οι οποίες εφαρμόζονται σε είσοδο διαστάσεων (batch_size, input_length), μετασχηματισμένη σε (batch_size, 1, input_length) ώστε να εισαχθεί το κανάλι πληροφορίας. Η πρώτη στρώση χρησιμοποιεί 32 φίλτρα, ενώ η δεύτερη 64, με πυρήνα μεγέθους 3 και padding ώστε να διατηρηθούν οι διαστάσεις.

Μετά από κάθε συνελικτική στρώση εφαρμόζεται η μη γραμμική συνάρτηση ενεργοποίησης ReLU, η οποία ενισχύει την εκφραστικότητα του μοντέλου, περιορίζοντας παράλληλα το πρόβλημα της έκρηξης ή εξαφάνισης των βαθμίδων (gradient explosion/vanishing).

Μετά την επεξεργασία από τις συνελικτικές στρώσεις, τα δεδομένα επίπεδοποιούνται (flattening) και περνούν από μία πλήρως συνδεδεμένη στρώση με 128 νευρώνες, όπου και εφαρμόζεται εκ νέου ReLU. Έπειτα εισάγεται μία τεχνική τακτικής που βασίζεται στο dropout με ποσοστό 20%, για την αποφυγή υπερεκπαίδευσης. Η τελική στρώση είναι επίσης πλήρως συνδεδεμένη και αποδίδει ένα διάνυσμα εξόδου που αντιστοιχεί στις εκτιμώμενες παραμέτρους χωρητικότητας. Η χρήση του dropout λειτουργεί ως ένας μηχανισμός regularization, μειώνοντας την εξάρτηση του μοντέλου από συγκεκριμένες ενεργοποιήσεις νευρώνων κατά την εκπαίδευση.

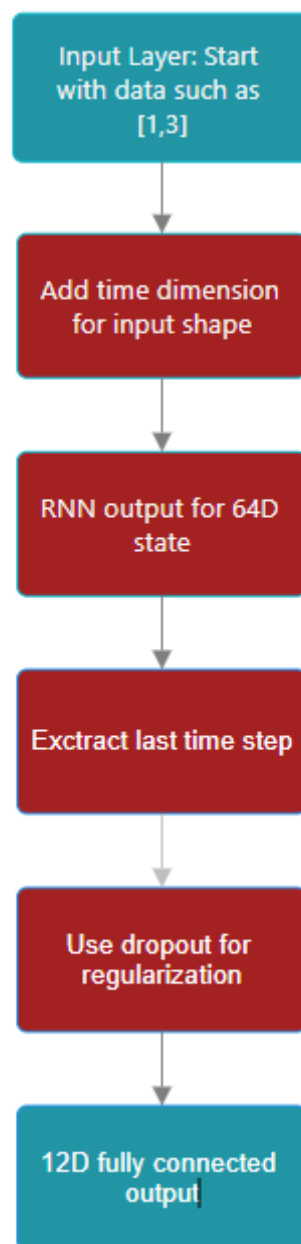
Στα στάδια της εκπαίδευσης της αξιολόγησης και της απεικόνισης, η υλοποίηση είναι παρόμοια με αυτή της FFNN.

Συνολικά, η προσέγγιση που ακολουθείται στο συγκεκριμένο σύστημα εναρμονίζεται με τις σύγχρονες θεωρητικές και τεχνικές αρχές της μηχανικής μάθησης. Ο συνδυασμός συνελικτικής αρχιτεκτονικής, μεθόδων regularization, βελτιστοποίησης τύπου Adam και αξιολόγησης μέσω cross-validation προσδίδει στο σύστημα ευελιξία, γενικευσιμότητα και πρακτική αξία. Ιδιαίτερη σημασία έχει και η εστίαση όχι μόνο στην εκπαίδευση αλλά και στην απόδοση επί μη γνωστών δεδομένων, κάτι που είναι ουσιώδες για τη μετάβαση από τη θεωρία στην εφαρμογή. Μέσω αυτής της πολυεπίπεδης προσέγγισης, το CNN δίκτυο επιδεικνύει τη δυναμική του στη μοντελοποίηση μη γραμμικών σχέσεων σε εφαρμογές σχεδιασμού και βελτιστοποίησης ηλεκτρονικών συστημάτων.

3.5.3 Σχεδίαση RIS με RNN

Με στόχο την καλύτερη δυνατή πρόβλεψη διατάξεων χωρητικότητας με βάση κανονικοποιημένες ενεργειακές πυκνότητες, υλοποιήθηκε και εκπαιδεύτηκε μια ακόμη αρχιτεκτονική βαθιάς μάθησης, ένα επαναληπτικό νευρωνικό δίκτυο RNN. Ο κώδικας ξεκινά (όπως και στο FFNN και CNN), με την εισαγωγή των απαραίτητων βιβλιοθηκών, όπως το PyTorch για την υλοποίηση του νευρωνικού δικτύου, το NumPy για την αριθμητική επεξεργασία δεδομένων και το scikit-learn για τη διαχείριση της διασταυρούμενης επικύρωσης (K-Fold Cross Validation). Το σύνολο δεδομένων φορτώνεται από ένα αρχείο κειμένου όπου κάθε δύο γραμμές περιέχουν μία είσοδο και την αντίστοιχη έξοδο. Οι εισοδοί είναι κανονικοποιημένες ενεργειακές πυκνότητες, ενώ οι έξοδοι είναι διατάξεις χωρητικότητας.

Η διαχείριση των δεδομένων γίνεται μέσω των DataLoader του PyTorch, που επιτρέπουν την αποδοτική μεταφορά των δεδομένων σε παρτίδες (batches) κατά τη διάρκεια της εκπαίδευσης.



Εικόνα 3.4: Flow Chart μιας εφαρμογής του Recurrent Neural Network

Η αρχιτεκτονική του δικτύου βασίζεται σε έναν επαναληπτικό νευρωνικό υπολογιστή, δηλαδή ένα RNN. Τα RNNs είναι σχεδιασμένα να επεξεργάζονται ακολουθιακά δεδομένα (sequential data), καθώς διατηρούν μια εσωτερική κατάσταση (hidden state) που ενημερώνεται σε κάθε χρονικό βήμα. Έτσι, είναι κατάλληλα για προβλήματα στα οποία η σειρά των εισόδων έχει σημασία. Στην παρούσα περίπτωση, το μοντέλο μπορεί να αξιοποιήσει την αλληλουχία των τιμών στις εισόδους για να προβλέψει μία σύνθετη έξοδο.

Ο κώδικας χρησιμοποιεί επαναληπτική μονάδα LSTM, μία προηγμένη μορφή RNN που αντιμετωπίζει το πρόβλημα της έκρηξης ή εξαφάνισης της κλίσης (vanishing/exploding gradient problem). Τα LSTM περιέχουν μηχανισμούς πύλης που ελέγχουν τη ροή των πληροφοριών, επιτρέποντας στο δίκτυο να «θυμάται» ή να «ξεχνά» συγκεκριμένες πληροφορίες. Με αυτό το τρόπο εκπαιδεύει πιο αποτελεσματικά μοντέλα σε δεδομένα ακολουθιών, αποφεύγοντας τα προβλήματα σταθερότητας που προκαλούν τα κλασικά RNN και διατηρώντας καλύτερη μακροπρόθεσμη μνήμη.

Στο στάδιο του forward pass, το δίκτυο παίρνει την είσοδο, την μετατρέπει σε μορφή κατάλληλη για επεξεργασία ως ακολουθία με την χρήση της μεθόδου unsqueeze και τη στέλνει στη μονάδα LSTM. Η έξοδος το τελευταίο κρυφό στάδιο περνάει από ένα πλήρως συνδεδεμένο στρώμα και ακολούθως από ένα dropout στρώμα, που δρα ως regularization για την αποφυγή υπερεκπαίδευσης (Εικόνα 3.4).. Στην συνέχεια η υλοποίηση δεν διαφέρει από αυτή των προηγούμενων αρχιτεκτονικών βαθιάς μάθησης που παρουσιάστηκαν.

Συνοψίζοντας, ο κώδικας που υλοποιήθηκε αποτελεί μία ολοκληρωμένη προσέγγιση υλοποίησης, εκπαίδευσης, επικύρωσης και αξιολόγησης ενός RNN βασισμένου σε LSTM για πρόβλεψη διατάξεων χωρητικότητας. Αξιοποιεί προηγμένες τεχνικές της μηχανικής μάθησης, όπως regularization, early stopping και k-fold cross-validation, με στόχο τη βελτίωση της ακρίβειας και της γενίκευσης του μοντέλου. Η επιλογή των LSTM ως πυρήνας της αρχιτεκτονικής υποδηλώνει την ανάγκη για διατήρηση χρονικών εξαρτήσεων στα δεδομένα, ακόμη και αν αυτές δεν είναι εμφανώς χρονικές, αποδεικνύοντας τη γενική χρηστικότητα αυτής της κατηγορίας νευρωνικών δικτύων.

3.6 Επίλογος

Σε αυτό το κεφάλαιο, παρουσιάστηκε ο αλγόριθμος και η υλοποίηση ενός εκτενούς και ρεαλιστικού dataset, εξετάστηκε ο ρόλος της μηχανικής μάθησης στον σχεδιασμό και τη βελτιστοποίηση επιφανειών RIS. Αναλύθηκαν οι βασικές αρχιτεκτονικές νευρωνικών δικτύων, όπως τα FFNN, τα CNN και τα RNN, εστιάζοντας στις εφαρμογές τους στη διαμόρφωση δέσμης και την πρόβλεψη της κατάστασης του καναλιού (CSI). Επιπλέον, διερευνήθηκε η σημασία της αντίστροφης σχεδίασης μέσω νευρωνικών δικτύων για την ταχεία και αποδοτική ανάπτυξη μεταεπιφανειών.

Η ενσωμάτωση αυτών των τεχνικών στην τεχνολογία RIS βελτιώνει σημαντικά την απόδοση των ασύρματων επικοινωνιών, μειώνοντας την ανάγκη για ακριβή γνώση του καναλιού και επιταχύνοντας τη διαδικασία βελτιστοποίησης. Καθώς η τεχνητή νοημοσύνη συνεχίζει να προοδεύει, οι μελλοντικές εξελίξεις αναμένεται να ενισχύσουν περαιτέρω την αποδοτικότητα και την προσαρμοστικότητα των RIS, προωθώντας καινοτόμες λύσεις για τα δίκτυα 6G και πέραν αυτών.

Κεφάλαιο 4ο: Αποτελέσματα τεχνικών μηχανικής μάθησης για την σχεδίαση RIS

4.1 Εισαγωγή

Τα αποτελέσματα παράχθηκαν με την χρήση scripts που αναπτύχθηκαν σε γλώσσα python και υλοποίησαν τα NNs που περιγράφονται στο προηγούμενο κεφάλαιο. Τα απαραίτητα δεδομένα εκπαίδευσης, αξιολόγησης και δοκιμής δημιουργήθηκαν από κώδικα που βασίστηκε στον Αλγόριθμο 2 ο οποίος περιγράφεται στην παράγραφο 3.4.1. Θα πρέπει να σημειωθεί ότι υλοποίηση των scripts πραγματοποιήθηκε με την βιβλιοθήκη PyTorch, μια ανοιχτού κώδικα βιβλιοθήκη για μηχανική μάθηση εξειδικευμένη μεταξύ άλλων και στην βαθιά μάθηση. Για την εκτέλεση των προγραμμάτων χρησιμοποιήθηκε 8-πύρηνη CPU της AMD (AMD Ryzen 7 3800X 8-Core Processor 3.90 GHz).

Στην είσοδο των NNs δίδονται τέσσερα διαφορετικά dataset με συνδυασμούς τεσσάρων χωρητικότητας (400000 στοιχεία) και οκτώ χωρητικότητας (200000 στοιχεία) στις 56° και 65°. Δοκιμάστηκαν learning rates 0,001, 0,005 και 0,01 ενώ εφαρμόστηκαν και διαφορετικοί αριθμοί νευρώνων στα κρυφά επίπεδα στην κλίμακα μεταξύ 8 και 128. Πρώιμες δοκιμές απέδειξαν ότι το επίπεδο δυσκολίας του προβλήματος δεν απαιτούσε μεγαλύτερη πολυπλοκότητα στο νευρωνικό δίκτυο.

Αποτελέσματα αρχιτεκτονικής FFNN για συνδυασμούς χωρητικότητας 4 στοιχείων

Η σύγκριση διαφορετικών αρχιτεκτονικών FFNN με μεταβαλλόμενα μεγέθη κρυφών επιπέδων αναδεικνύει σημαντικές συσχετίσεις ανάμεσα στην πολυπλοκότητα του μοντέλου, την αποδοτικότητά του και τον χρόνο που απαιτείται για την εκπαίδευσή του.

Οι πίνακες με τα αποτελέσματα που ακολουθούν αφορούν 400000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικότητας στις 56°.

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.005177	0.005234	0.005257	0.005256	0.072496	78.38
0.0050	0.005150	0.005266	0.005283	0.005273	0.072613	95.01
0.0100	0.005178	0.005284	0.005285	0.005284	0.072689	131.42

Πίνακας 4.1a: Αποτελέσματα με 8 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.005157	0.005228	0.005184	0.005180	0.071973	130.48
0.0050	0.005152	0.005261	0.005184	0.005172	0.071913	153.47
0.0100	0.005125	0.005281	0.005210	0.005223	0.072271	91.70

Πίνακας 4.1b: Αποτελέσματα με 16 κρυφούς νευρώνες ανά επίπεδο

Κεφάλαιο 4

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.005161	0.005226	0.005225	0.005226	0.072294	94.68
0.0050	0.005157	0.005257	0.005301	0.005301	0.072809	95.80
0.0100	0.005134	0.005278	0.005301	0.005311	0.072879	107.73

Πίνακας 4.1c: Αποτελέσματα με 32 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.005149	0.005225	0.005205	0.005196	0.072082	83.20
0.0050	0.005131	0.005258	0.005254	0.005240	0.072389	114.49
0.0100	0.005172	0.005279	0.005503	0.005503	0.074181	134.56

Πίνακας 4.1d: Αποτελέσματα με 64 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.005158	0.005225	0.005255	0.005254	0.072483	106.24
0.0050	0.005141	0.005257	0.005211	0.005213	0.072201	78.66
0.0100	0.005092	0.005275	0.005277	0.005283	0.072687	158.63

Πίνακας 4.1e: Αποτελέσματα με 128 κρυφούς νευρώνες ανά επίπεδο

Οι πίνακες με τα αποτελέσματα που ακολουθούν αφορούν 400000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικοτήτων στις 65°.

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.005136	0.005189	0.005237	0.005232	0.072332	71.69
0.0050	0.005108	0.005213	0.005335	0.005339	0.073068	83.63
0.0100	0.005093	0.005228	0.005156	0.005158	0.071820	107.53

Πίνακας 4.2a: Αποτελέσματα με 8 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.005129	0.005189	0.005183	0.005194	0.072068	97.49
0.0050	0.005145	0.005211	0.005157	0.005170	0.071903	107.42
0.0100	0.005120	0.005232	0.005312	0.005315	0.072902	92.54

Πίνακας 4.2b: Αποτελέσματα με 16 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.005134	0.005191	0.005178	0.005166	0.071876	95.50
0.0050	0.005128	0.005210	0.005179	0.005176	0.071946	167.43
0.0100	0.005090	0.005227	0.005221	0.005214	0.072209	130.85

Πίνακας 4.2c: Αποτελέσματα με 32 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.005145	0.005187	0.005219	0.005200	0.072113	99.19
0.0050	0.005120	0.005209	0.005167	0.005175	0.071939	165.70
0.0100	0.005072	0.005227	0.005174	0.005170	0.071904	199.34

Πίνακας 4.2d: Αποτελέσματα με 64 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.005120	0.005186	0.005200	0.005207	0.072161	180.52
0.0050	0.005082	0.005207	0.005203	0.005205	0.072148	101.32
0.0100	0.005086	0.005225	0.005231	0.005229	0.072310	76.49

Πίνακας 4.2e: Αποτελέσματα με 128 κρυφούς νευρώνες ανά επίπεδο

Η ανάλυση των αποτελεσμάτων των πειραμάτων του FFNN μοντέλου με αποτελέσματα που αφορούν 400000 στοιχεία στην είσοδο του NN (Πίνακες 4.1 και 4.2), με παραμέτρους που περιλαμβάνουν τον αριθμό των νευρώνων ανά επίπεδο, το learning rate και τα σύνολα δεδομένων στους 56° και 65°, προσφέρει τα ακόλουθα συμπεράσματα για κάθε μετρική απόδοσης.

Ξεκινώντας από το learning rate, παρατηρείται ότι οι τιμές 0.001 και 0.005 προσφέρουν σταθερά και αξιόπιστα αποτελέσματα σε όλες τις αρχιτεκτονικές. Η χρήση του μεγαλύτερου learning rate (0.01), αν και σε κάποιες περιπτώσεις οδήγησε σε γρήγορη εκπαίδευση, συνοδεύτηκε από μικρές επιδεινώσεις στο Validation Loss και στο Test MSE, κυρίως σε δίκτυα με περισσότερους νευρώνες, πιθανώς λόγω υπερπροσαρμογής ή αριθμητικής αστάθειας κατά τη φάση της βελτιστοποίησης.

Ο δείκτης Cross Validation Loss (CV Loss) παρουσιάζει εντυπωσιακή συνέπεια μεταξύ των διαφορετικών παραμετροποιήσεων, γεγονός που υποδεικνύει καλή ικανότητα γενίκευσης των μοντέλων. Η στενή σύγκλιση μεταξύ CV Loss, Train Loss και Validation Loss είναι ένδειξη ότι το μοντέλο μαθαίνει ισορροπημένα, χωρίς φαινόμενα σοβαρού overfitting. Ειδικά για τα δίκτυα με 32 νευρώνες, η απόδοση σε όλους τους δείκτες ήταν ιδιαίτερα καλή, προσφέροντας έναν εντυπωσιακό συνδυασμό ακρίβειας και σταθερότητας.

Η Train Loss ακολουθεί επίσης σταθερή πορεία, ιδιαίτερα κοντά στις τιμές του CV Loss, επιβεβαιώνοντας ότι το μοντέλο δεν υπερεκπαιδεύεται, ενώ ταυτόχρονα απορροφά ικανοποιητικά τα χαρακτηριστικά των δεδομένων εκπαίδευσης. Η συμπεριφορά αυτή ισχύει τόσο για τα δεδομένα των

56° όσο και για τα 65°, αποδεικνύοντας τη γενική σταθερότητα της μεθοδολογίας. Οι μικρές διαφορές στο Validation Loss εντός κάθε αρχιτεκτονικής δείχνουν πως το μοντέλο ανταποκρίνεται αξιόπιστα σε άγνωστα δεδομένα επικύρωσης.

Η μέτρηση της απόδοσης στο test set μέσω των δεικτών Test MSE και RMSE είναι κρίσιμη για την αξιολόγηση της πραγματικής δυνατότητας πρόβλεψης του μοντέλου. Αν και οι διαφορές στις τιμές RMSE είναι σχετικά μικρές (μεταξύ 0.0718 και 0.0741), είναι ενδεικτικές σε εφαρμογές υψηλής ακρίβειας. Τα βέλτιστα αποτελέσματα σημειώνονται κυρίως με δίκτυα των 8 και 32 νευρώνων, γεγονός που καταδεικνύει ότι η αύξηση της πολυπλοκότητας πέρα από ένα σημείο δεν οδηγεί απαραίτητα σε καλύτερη απόδοση. Συγκεκριμένα, το δίκτυο με 8 νευρώνες κατέγραψε το μικρότερο Test MSE και RMSE, δείχνοντας πως ακόμα και απλούστερες αρχιτεκτονικές μπορούν να είναι ιδιαίτερα αποτελεσματικές.

Αντίστοιχα, τα δίκτυα με 32 νευρώνες φαίνεται να προσφέρουν μια πιο σφαιρικά ισορροπημένη λύση. Παρόλο που το RMSE ήταν ελαφρώς υψηλότερο σε σύγκριση με αυτό των 8 νευρώνων, ο χρόνος εκπαίδευσης ήταν αισθητά μικρότερος και οι τιμές του CV Loss εξίσου χαμηλές. Αυτό καθιστά τα μοντέλα αυτά ιδανικά για περιπτώσεις που απαιτείται συνδυασμός ακρίβειας και ταχύτητας, κάτι που τα δίκτυα με περισσότερους νευρώνες δεν κατόρθωσαν να επιτύχουν εξίσου αποτελεσματικά.

Ο χρόνος εκπαίδευσης παρουσιάζει τη μεγαλύτερη διακύμανση μεταξύ των διαφορετικών παραμετροποιήσεων. Όπως ήταν αναμενόμενο, γενικά αυξάνεται με τον αριθμό των νευρώνων στο κρυφό επίπεδο, αν και η σχέση αυτή δεν είναι απόλυτα γραμμική. Παράγοντες όπως η αρχικοποίηση των βαρών, το computational load του συστήματος και η δυναμική του optimizer φαίνεται να επηρεάζουν το τελικό training time. Είναι χαρακτηριστικό ότι σε ορισμένες περιπτώσεις, δίκτυα με περισσότερους νευρώνες είχαν μικρότερο χρόνο εκπαίδευσης από άλλα με λιγότερους, επιβεβαιώνοντας την πολυπαραγοντική φύση του προβλήματος.



Εικόνα 4.1: Γράφημα απεικόνισης του Training Loss και του Validation Loss με 32 νευρώνες

Το δίκτυο με 64 νευρώνες παρουσίασε εξαιρετικά αποτελέσματα σε ό,τι αφορά το CV Loss, όμως συνοδευόταν από σημαντική αύξηση στον χρόνο εκπαίδευσης. Αντίστοιχα, το δίκτυο με 128 νευρώνες, ενώ παρουσίασε σχετικά καλό χρόνο εκπαίδευσης, δεν κατάφερε να ξεπεράσει τις μικρότερες αρχιτεκτονικές σε κανένα βασικό δείκτη, γεγονός που ενισχύει τη διαπίστωση ότι μεγαλύτερη πολυπλοκότητα δεν συνεπάγεται κατ' ανάγκη καλύτερη απόδοση.

Η γενική εικόνα που προκύπτει είναι πως τα μοντέλα με 8 έως 32 νευρώνες στο κρυφό επίπεδο αποτελούν την πιο αποδοτική λύση για το υπό εξέταση πρόβλημα (Πίνακας 4.3). Το δίκτυο με 8 νευρώνες υπερέχει στην απόλυτη ακρίβεια πρόβλεψης, όμως εκείνο με 32 νευρώνες συνδυάζει εξαιρετική ακρίβεια, γρήγορη εκπαίδευση και υψηλή ικανότητα γενίκευσης (Εικόνα 4.1). Το δίκτυο με 16 νευρώνες αποτελεί μια ενδιάμεση επιλογή, χωρίς όμως να προσφέρει ουσιαστικά πλεονεκτήματα έναντι των άλλων δύο.

Νευρώνες ανά επίπεδο	Καλύτερο Test MSE	Καλύτερο Test RMSE	Learning Rate	Χρόνος Εκπαίδευσης (sec)
8	0.005158	0.071820	0.0100	107.53
16	0.005170	0.071973	0.0010	130.48
32	0.005166	0.071876	0.0010	95.50
64	0.005169	0.071904	0.0100	199.34
128	0.005206	0.072148	0.0050	101.32

Πίνακας 4.3: Πίνακας Καλύτερων Αποτελεσμάτων ανά μέγεθος κρυφού επιπέδου για συνδυασμούς χωρητικότητας 4 στοιχείων

Για εφαρμογές μεγαλύτερης κλίμακας, όπως η επεξεργασία εκατομμυρίων δεδομένων, το δίκτυο με 64 νευρώνες μπορεί να προσφέρει ένα πλεονέκτημα σε ό,τι αφορά τη σταθερότητα γενίκευσης, ωστόσο ο αυξημένος χρόνος εκπαίδευσης και οι υψηλότερες απαιτήσεις σε πόρους περιορίζουν τη χρησιμότητά του σε πραγματικά συστήματα. Δεν συνιστάται η χρήση μοντέλων με περισσότερους από 64 νευρώνες, καθώς δεν προκύπτουν ουσιαστικά οφέλη από την υπερβολική αύξηση των παραμέτρων.

Συνοψίζοντας, το FFNN με 32 νευρώνες στο κρυφό επίπεδο και χαρακτηριστικά εισόδου στις 56°, σε συνδυασμό με learning rate 0.001 ή 0.005, αποτελεί την πιο ισορροπημένη και αποδοτική επιλογή. Προσφέρει εξαιρετική γενίκευση, χαμηλό χρόνο εκπαίδευσης και πολύ καλή ακρίβεια πρόβλεψης, καθιστώντας το ιδανικό μοντέλο για πρακτική εφαρμογή, ιδιαίτερα όταν οι διαθέσιμοι υπολογιστικοί πόροι είναι περιορισμένοι ή όταν επιζητείται σταθερότητα και προβλεψιμότητα. Σε κάθε περίπτωση, η μελέτη αυτή αναδεικνύει τη σημασία της σωστής επιλογής αρχιτεκτονικής και υπερπαραμέτρων, προκειμένου να επιτευχθεί το βέλτιστο ισοζύγιο απόδοσης, ακρίβειας και υπολογιστικού κόστους.

Αποτελέσματα αρχιτεκτονικής FFNN για συνδυασμούς χωρητικότητας 8 στοιχείων

Οι πίνακες με τα αποτελέσματα που ακολουθούν αφορούν 200000 στοιχεία στην είσοδο του NN από συνδυασμό 8 χωρητικότητας στις 56°.

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.018122	0.018313	0.018295	0.018417	0.135711	98.31
0.0050	0.018131	0.018383	0.018269	0.018450	0.135830	35.28
0.0100	0.018206	0.018457	0.018289	0.018315	0.135331	52.83

Πίνακας 4.4a: Αποτελέσματα με 8 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.018133	0.018278	0.018371	0.018292	0.135248	42.37
0.0050	0.018127	0.018356	0.018619	0.018527	0.136115	87.31
0.0100	0.018139	0.018444	0.018342	0.018316	0.135338	69.55

Πίνακας 4.4b Αποτελέσματα με 16 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.018140	0.018262	0.018217	0.018255	0.135111	71.44
0.0050	0.018116	0.018403	0.018212	0.018275	0.135183	37.05
0.0100	0.018155	0.018442	0.018820	0.018957	0.137683	71.27

Πίνακας 4.4c: Αποτελέσματα με 32 κρυφούς νευρώνες ανά επίπεδο

Οι πίνακες με τα αποτελέσματα που ακολουθούν αφορούν 200000 στοιχεία στην είσοδο του NN από συνδυασμό 8 χωρητικότητας στις 65°.

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.018122	0.018223	0.018199	0.018191	0.134875	41.23
0.0050	0.018116	0.018296	0.018371	0.018396	0.135631	53.77
0.0100	0.018135	0.018349	0.018226	0.018330	0.135389	35.30

Πίνακας 4.5a: Αποτελέσματα με 8 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.018057	0.018185	0.018306	0.018355	0.135480	35.16
0.0050	0.018073	0.018287	0.018343	0.018367	0.135523	60.79
0.0100	0.018069	0.018333	0.018191	0.018184	0.134847	73.34

Πίνακας 4.5b: Αποτελέσματα με 16 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.0010	0.018095	0.018226	0.018160	0.018174	0.134812	62.13
0.0050	0.018104	0.018309	0.018263	0.018320	0.135351	63.14
0.0100	0.018120	0.018366	0.018323	0.018463	0.135877	98.86

Πίνακας 4.5c: Αποτελέσματα με 32 κρυφούς νευρώνες ανά επίπεδο

Μετά την ανάλυση των αποτελεσμάτων των πινάκων 4.1 και 4.2, για συνδυασμούς τεσσάρων χωρητικότητας δεν κρίθηκε απαραίτητο να παραχθούν στη συνέχεια αποτελέσματα για μεγέθη κρυφών επιπέδων 64 και 128 νευρώνων. Η ανάλυση των αποτελεσμάτων για 8, 16 και 32 νευρώνες από τα δείχνει με σαφήνεια ότι το μέγεθος του νευρωνικού δικτύου δεν παίζει καθοριστικό ρόλο στην τελική απόδοσή του. Συγκεκριμένα, και οι τρεις διαμορφώσεις αρχιτεκτονικών νευρωνικών δικτύων αποδίδουν σχεδόν το ίδιο, με πολύ μικρές διαφορές στις τιμές των MSE και RMSE, οι οποίες κυμαίνονται περίπου στο 0.018 και 0.135 αντίστοιχα. Η μικρή υπεροχή του δικτύου με 32 νευρώνες όσον αφορά τα σφάλματα είναι αμελητέα σε πρακτικό επίπεδο, γεγονός που υποστηρίζει την άποψη ότι ακόμη και ένα μικρότερο δίκτυο με 8 νευρώνες ανά επίπεδο, μπορεί να είναι απολύτως επαρκές για το συγκεκριμένο πρόβλημα. Επιπλέον, αυτό το μικρότερο δίκτυο έχει το πλεονέκτημα του συντομότερου χρόνου εκπαίδευσης, που το καθιστά ιδιαίτερα χρήσιμο σε εφαρμογές όπου η ταχύτητα έχει σημασία.

Τα αποτελέσματα των πινάκων 4.4 και 4.5 για τις δύο διαφορετικές διαμορφώσεις εισόδου (56° και 65° για συνδυασμούς 8 χωρητικότητας) εμφανίζουν ενδιαφέρουσες τάσεις στις επιδόσεις του μοντέλου. Για τη διαμόρφωση με 56° συνδυασμό, οι τιμές του CV Loss, Train Loss, Val Loss, Test MSE και Test RMSE παραμένουν σταθερές σε όλες τις περιπτώσεις, με ελάχιστες διακυμάνσεις ανάλογα με το learning rate και τον αριθμό των κρυφών νευρώνων. Οι τιμές αυτές κυμαίνονται γύρω από 0.018 για τα CV, Train και Val Loss, ενώ το Test MSE είναι επίσης κοντά σε αυτό το εύρος, με Test RMSE περίπου 0.135. Ο χρόνος εκπαίδευσης ποικίλλει σημαντικά, από 35.28 έως 98.31 δευτερόλεπτα, με το μικρότερο learning rate (0.001) να απαιτεί συνήθως περισσότερο χρόνο.

Νευρώνες ανά επίπεδο	Καλύτερο Test MSE	Καλύτερο Test RMSE	Learning Rate	Train Time (sec)
8	0.018191	0.134875	0.0010	41.23
16	0.018292	0.135248	0.0010	42.37
32	0.018174	0.134812	0.0010	62.13

Πίνακας 4.6: Πίνακας Καλύτερων Αποτελεσμάτων ανά μέγεθος κρυφού επιπέδου για συνδυασμούς χωρητικότητας 8 στοιχείων

Στη διαμόρφωση με 65° συνδυασμό, τα αποτελέσματα είναι παρόμοια, αλλά με ελαφρώς βελτιωμένες μετρικές, ιδιαίτερα στο Test RMSE, που φτάνει έως και 0.134. Ο χρόνος εκπαίδευσης εδώ είναι γενικά μικρότερος, παρατηρώντας τον πίνακα 4.6 διαπιστώνουμε ότι με την περίπτωση των 8 κρυφών νευρώνων και learning rate 0.001 καταγράφει τον μικρότερο χρόνο (41.23 δευτερόλεπτα). Η διαφορά στις μετρικές μεταξύ των δύο διαμορφώσεων υποδηλώνει ότι η δεύτερη διαμόρφωση (65°) μπορεί να προσφέρει ελαφρώς καλύτερη γενίκευση, αν και οι διαφορές είναι ελάχιστες.

Οι βέλτιστες χωρητικότητες στο test set ποικίλλουν ανάλογα με τη διαμόρφωση και τον αριθμό των νευρώνων, χωρίς να φαίνεται κάποια σαφής τάση. Ο χρόνος πρόβλεψης για τις βέλτιστες χωρητικότητες είναι πολύ μικρός (γύρω στα 0.15 δευτερόλεπτα), γεγονός που υποδηλώνει αποτελεσματικότητα στην εκτέλεση του μοντέλου. Συνολικά, τα αποτελέσματα δείχνουν ότι το μοντέλο είναι σταθερό και αξιόπιστο, με ελάχιστες διακυμάνσεις στις επιδόσεις του ανάλογα με τις παραμέτρους. Η επιλογή του learning rate και του αριθμού των κρυφών νευρώνων φαίνεται να επηρεάζει περισσότερο τον χρόνο εκπαίδευσης παρά την τελική ακρίβεια, γεγονός που υποδηλώνει ότι το μοντέλο είναι αρκετά ευέλικτο και ανθεκτικό σε διαφορετικές ρυθμίσεις.

Αναφορικά με τον ρυθμό μάθησης, παρατηρείται ότι η τιμή 0.001 προσφέρει τη μεγαλύτερη σταθερότητα και ακρίβεια στις περισσότερες διαμορφώσεις, καθώς οδηγεί σε χαμηλότερα σφάλματα χωρίς απότομες διακυμάνσεις κατά τη διάρκεια της εκπαίδευσης. Από την άλλη πλευρά, η τιμή 0.005 μπορεί να προσφέρει ταχύτερη εκπαίδευση χωρίς μεγάλη απώλεια στην απόδοση, αλλά ενδέχεται να μην είναι τόσο αξιόπιστη σε όλες τις περιπτώσεις. Σε ορισμένα πειράματα, η χρήση ακόμη υψηλότερων τιμών, όπως 0.01, οδήγησε σε λιγότερο σταθερή σύγκλιση και αυξημένο χρόνο εκπαίδευσης, όπως φαίνεται στο δίκτυο των 32 νευρώνων, όπου απαιτήθηκαν πάνω από 98.86 δευτερόλεπτα για την ολοκλήρωση της διαδικασίας (Πίνακας 4.5c).

Η γενική απόδοση του μοντέλου χαρακτηρίζεται από υψηλή ακρίβεια, κάτι που αποδεικνύεται από τις πολύ χαμηλές τιμές MSE και RMSE. Το μοντέλο καταφέρνει να προβλέψει με συνέπεια τους συνδυασμούς χωρητικότητας, τόσο όταν χρησιμοποιούνται τέσσερις όσο και οκτώ χωρητικότητες κάτι που δείχνει καλή γενίκευση. Επιπλέον, η διαδικασία αναζήτησης του βέλτιστου συνδυασμού είναι εξαιρετικά ταχεία, με χρόνους κάτω από 0.2 δευτερόλεπτα στο test set και περίπου 1.5 δευτερόλεπτο για ολόκληρο το dataset, γεγονός που καθιστά το σύστημα ιδιαίτερα πρακτικό για εφαρμογές σε πραγματικό χρόνο.

Υπάρχουν, ωστόσο, περιθώρια για βελτιστοποίηση, ιδιαίτερα ως προς την αποδοτικότητα. Η δοκιμή δικτύων, όπως αυτό με 4 νευρώνες, ενδέχεται να διατηρήσει την ακρίβεια σε ικανοποιητικά επίπεδα μειώνοντας παράλληλα περαιτέρω τον χρόνο εκπαίδευσης. Ο πειραματισμός με μικρότερες τιμές learning rate, όπως 0.0005 ή 0.0001, θα μπορούσε επίσης να οδηγήσει σε ακόμη πιο σταθερή εκπαίδευση. Επιπλέον, η χρήση regularization τεχνικών όπως το L2 μπορεί να προσφέρει βελτιωμένη γενίκευση, ειδικά σε περιβάλλοντα με μεγαλύτερη πολυπλοκότητα. Τέλος, αν απαιτείται ακόμη μεγαλύτερη ακρίβεια, μπορούν να διερευνηθούν βαθύτερες ή εναλλακτικές αρχιτεκτονικές, όπως τα CNN που θα παρουσιαστεί στη συνέχεια, ιδίως για δεδομένα που παρουσιάζουν κάποια χωρική δομή.

Συνοψίζοντας, τα αποτελέσματα δείχνουν ένα εξαιρετικά σταθερό και ακριβές μοντέλο με απλές ρυθμίσεις, το οποίο μπορεί να χρησιμοποιηθεί άμεσα σε πρακτικές εφαρμογές. Παράλληλα, προσφέρεται η δυνατότητα περαιτέρω βελτιώσεων μέσω στοχευμένων αλλαγών στην αρχιτεκτονική και στις υπερπαραμέτρους.


Συγκριτικά συμπεράσματα για αποτελέσματα τύπου FFNN

Για τη γωνία 56° η καλύτερη προέρχεται από 400.000 δείγματα (συνδυασμός τεσσάρων χωρητικότητας) και περιλαμβάνει 16 νευρώνες, με learning rate 0.005. Η απόδοση στο test set ήταν MSE 0.005170 και RMSE 0.071903, ενώ ο χρόνος εκπαίδευσης ανήλθε σε 107.42 δευτερόλεπτα. Αντίστοιχα, για τη γωνία 65° περιλαμβάνει συνδυασμό τεσσάρων χωρητικότητας και 400.000 δείγματα.

Η βέλτιστη αρχιτεκτονική περιλαμβάνει 16 νευρώνες με learning rate 0.010, επιτυγχάνοντας Test MSE 0.005180 και Test RMSE 0.071973, με χρόνο εκπαίδευσης 130.48 δευτερόλεπτα.

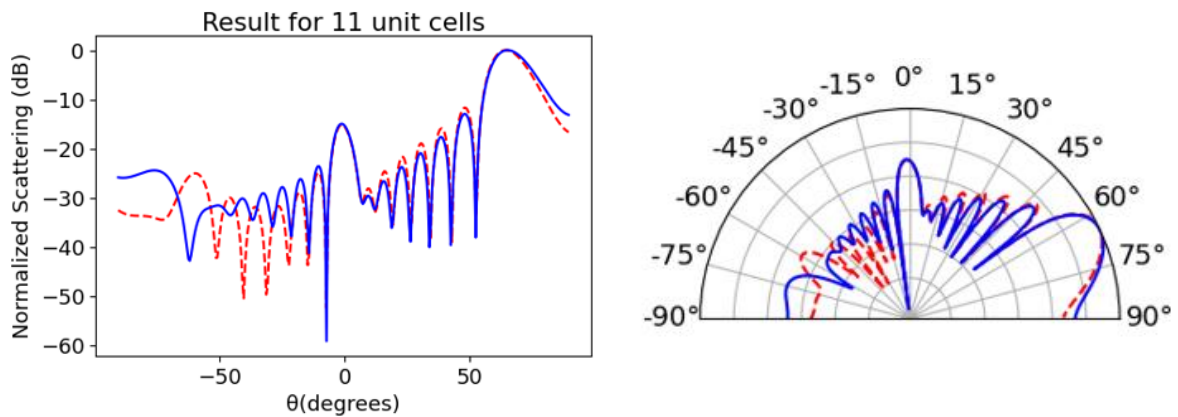
Για εφαρμογές που απαιτούν ελάχιστο σφάλμα, τα δεδομένα των 65° με 8 νευρώνες συνιστούν την κορυφαία επιλογή. Αντίθετα, για προβλήματα που σχετίζονται με τις 56° , ένα δίκτυο με 32 νευρώνες προσφέρει καλή ισορροπία ανάμεσα σε ακρίβεια και ταχύτητα.

Θα πρέπει να σημειωθεί ότι η διαφορά στις γωνίες ενδέχεται να αντανακλά διαφορετικές φυσικές συμπεριφορές ή απαιτήσεις στο υπό εξέταση πρόβλημα.



Εικόνα 4.2: Διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης και πολικό διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης για τις καλύτερες τιμές χωρητικότητας του test set στις 56° και 12 μονάδων κυψελών ανά supercell. TE (κόκκινο), TM (μπλε)

Για τη γωνία 56°, ο βέλτιστος συνδυασμός χωρητικότητας στο test set ήταν 0.218, 0.321, 0.218, 0.321, 0.321, 0.352, 0.352, 0.352, 0.411, 0.411, 0.218, 0.411 (συνδυασμός τεσσάρων χωρητικότητας). Το διάγραμμα που παράχθηκε με την υλοποίηση του Αλγόριθμου 1 απεικονίζεται στην εικόνα 4.2.



Εικόνα 4.3: Διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης και πολικό διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης για τις καλύτερες τιμές χωρητικότητας του test set στις 65° και 11 μονάδων κυψελών ανά supercell. TE (κόκκινο), TM (μπλε)

Αντίστοιχα τα αποτελέσματα για τη γωνία 65° στο test set ο βέλτιστος συνδυασμός χωρητικότητας ήταν 0.352, 0.352, 0.321, 0.411, 0.411, 0.411, 0.218, 0.321, 0.321, 0.218, 0.352 (συνδυασμός τεσσάρων χωρητικότητας) (Εικόνα 4.3).

Η ανάλυση αυτών των συνδυασμών αποκαλύπτει ότι στη γωνία 65° παρατηρείται μεγαλύτερη σταθερότητα, με συχνή εμφάνιση επαναλαμβανόμενων τιμών όπως 0.337, 0.411 και 0.700, γεγονός που δείχνει πως συγκεκριμένες χωρητικότητες είναι κρίσιμες για τη μείωση της απώλειας. Αντίθετα, στη γωνία 56° οι βέλτιστοι συνδυασμοί παρουσιάζουν μεγαλύτερη ποικιλία, κάτι που αντανακλά την αυξημένη πολυπλοκότητα του προβλήματος λόγω των περισσότερων χωρητικότητας.

Ο χρόνος αναζήτησης του βέλτιστου συνδυασμού ήταν μικρός, κάτω από 0.2 δευτερόλεπτα για το test set και περίπου 1.5 δευτερόλεπτο για το πλήρες dataset, ανεξάρτητα από τη γωνία. Συμπερασματικά, οι συνδυασμοί για τις 65° είναι πιο συνεπείς και οδηγούν μέσω του χαμηλότερου RMSE σε καλύτερη απόδοση, ενώ για τις 56° απαιτείται μεγαλύτερη ευελιξία στις χωρητικότητες. Και στις δύο περιπτώσεις,

οι προτεινόμενες αρχιτεκτονικές εξισορροπούν ικανοποιητικά την ακρίβεια και το υπολογιστικό κόστος.

Αποτελέσματα αρχιτεκτονικής CNN για συνδυασμούς χωρητικότητας 4 και 8 στοιχείων

Το CNN μοντέλο αποτελείται από δύο συνελκτικά (convolutional) επίπεδα, ένα πλήρως συνδεδεμένο (fully connected) επίπεδο και ένα επίπεδο εξόδου. Το πρώτο συνελκτικό επίπεδο (conv1) διαθέτει 1 κανάλι εισόδου και 32 φίλτρα (κανάλια εξόδου) με πυρήνα μεγέθους 3 και padding ίσο με 1, ώστε να διατηρούνται οι διαστάσεις. Ακολουθεί το δεύτερο συνελκτικό επίπεδο (conv2), με 32 εισερχόμενα κανάλια και 64 εξόδους, ίδια παραμετροποίηση φίλτρων και ενεργοποίησης. Η έξοδος από το conv2 επιπεδοποιείται (flatten) και περνά σε ένα πλήρως συνδεδεμένο επίπεδο (fc1) με 128 νευρώνες και ενεργοποίηση ReLU. Τα πειράματα διεξήχθησαν για τις δύο διαφορετικές γωνίες (65° και 56°) και για τους δύο διαφορετικούς συνδυασμούς χωρητικότητας (4 και 8) με στόχο την εξέταση της επίδρασης αυτών των παραμέτρων στην απόδοση του μοντέλου. Οι πίνακες με τα αποτελέσματα που ακολουθούν αφορούν 200000 και 400000 στοιχεία στην είσοδο του NN από συνδυασμό 8 και 4 χωρητικότητας στις 65° και 56° .

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.020232	0.033073	0.020434	0.020374	0.142737	90.56
0.005	0.019898	0.03322	0.020914	0.020739	0.144009	100.98
0.01	0.020017	0.033392	0.019879	0.019886	0.141019	127.2

Πίνακας 4.7a: Αποτελέσματα που αφορούν 200000 στοιχεία στην είσοδο του NN από συνδυασμό 8 χωρητικότητας στις 65°

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.020119	0.03203	0.020562	0.020268	0.142365	154.7
0.005	0.019871	0.032118	0.020417	0.020384	0.142773	103.56
0.01	0.019921	0.032269	0.02197	0.021835	0.147766	162.71

Πίνακας 4.7b: Αποτελέσματα που αφορούν 200000 στοιχεία στην είσοδο του NN από συνδυασμό 8 χωρητικότητας στις 56°

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.006932	0.015615	0.007064	0.00708	0.084142	276.09
0.005	0.00684	0.015645	0.00691	0.006905	0.083096	235.98
0.01	0.006791	0.015689	0.007126	0.007135	0.08447	336.99

Πίνακας 4.7c: Αποτελέσματα που αφορούν 400000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικότητας στις 65°

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.007283	0.016502	0.007413	0.007414	0.086104	181.37
0.005	0.00712	0.01653	0.007355	0.007355	0.085762	236.37
0.01	0.007163	0.016579	0.007359	0.007357	0.085771	238.73

Πίνακας 4.7e: Αποτελέσματα που αφορούν 400000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικότητων στις 56°

Εξετάζοντας τα αποτελέσματα της περίπτωσης των 200.000 στοιχείων για τις 65° και τις τρεις τιμές του learning rate (Πίνακες 4.7), παρατηρούμε ότι οι τιμές του CV Loss κυμαίνονται πολύ κοντά μεταξύ τους, με μικρή υπεροχή του learning rate 0.005 (0.019898). Η χαμηλότερες όμως τιμές Validation Loss (0.019879) και Test MSE (0.019886) επιτυγχάνονται με learning rate 0.01, γεγονός που δείχνει ότι η αύξηση του ρυθμού εκμάθησης σε αυτήν την περίπτωση βελτιώνει την ικανότητα πρόβλεψης του μοντέλου, έστω και ελαφρώς. Η διαφορά στο Train Time είναι αισθητή, με το μεγαλύτερο learning rate να απαιτεί περίπου 127 δευτερόλεπτα. Η Test RMSE παραμένει σταθερά γύρω στο 0.14, χωρίς σημαντικές διακυμάνσεις.

Στην περίπτωση των 200.000 στοιχείων για τις 56°, το learning rate 0.005 δίνει πάλι την πιο ισορροπημένη επίδοση ως προς το CV Loss (0.019871) και Validation Loss (0.020417), ωστόσο το μικρότερο Test MSE (0.020268) εμφανίζεται με learning rate 0.001. Το learning rate 0.01 φαίνεται να χειροτερεύει ελαφρώς την ακρίβεια με αυξημένο Validation Loss (0.02197) και Test MSE (0.021835). Αυτό δείχνει μια ενδεχόμενη υπερπροσαρμογή ή υπερβολική επιθετικότητα στη μάθηση. Αν και το Train Time δεν διαφέρει έντονα, φτάνει ως τα 162 δευτερόλεπτα στο μεγαλύτερο learning rate, γεγονός που πρέπει να ληφθεί υπόψη σε εφαρμογές μεγάλης κλίμακας.

Στα δεδομένα των 400.000 στοιχείων (4 χωρητικότητες) στις 56°, παρατηρείται αισθητά χαμηλότερο CV Loss (περίπου 0.0071) και Test MSE (περίπου 0.0074), επισημαίνοντας τη βελτίωση της ακρίβειας λόγω της αύξησης του πλήθους των δεδομένων. Οι επιδόσεις είναι σχεδόν ισοδύναμες μεταξύ των διαφορετικών learning rates, με το 0.005 να δίνει την ελαφρώς καλύτερη ισορροπία. Ο χρόνος εκπαίδευσης αυξάνεται σημαντικά, φτάνοντας και τα 238 δευτερόλεπτα. Η Test RMSE μειώνεται επίσης αισθητά (0.0857 περίπου), κάτι που ενισχύει τη θέση ότι τα περισσότερα δεδομένα οδηγούν σε σταθερότερο και πιο γενικεύσιμο μοντέλο.

Τέλος, στα 400.000 στοιχεία στις 65°, η εικόνα είναι παρόμοια με την προηγούμενη, όμως εμφανίζεται μικρή βελτίωση στους δείκτες με learning rate 0.005, το οποίο επιτυγχάνει το χαμηλότερο Test MSE (0.006905) και αντίστοιχα το μικρότερο RMSE (0.083096). Παρά την αύξηση του χρόνου εκπαίδευσης, οι μικρές διαφορές στις αποδόσεις δείχνουν ότι το σύστημα είναι ήδη καλά ρυθμισμένο, και η επιλογή learning rate καθορίζει κυρίως τον ρυθμό σύγκλισης.

Συνολικά, το learning rate 0.005 αποδεικνύεται η πιο σταθερή και αξιόπιστη επιλογή στις περισσότερες περιπτώσεις. Τα αποτελέσματα επιβεβαιώνουν ότι η αύξηση του όγκου των δεδομένων συνεισφέρει ουσιαστικά στη μείωση των σφαλμάτων και στη γενίκευση του μοντέλου, ιδιαίτερα όταν ο αριθμός των χωρητικότητων μειώνεται, βελτιώνοντας έτσι την πυκνότητα πληροφορίας ανά συνδυασμό.

Τα αποτελέσματα δείχνουν ξεκάθαρα ότι ο αριθμός των στοιχείων που χρησιμοποιούνται για την εκπαίδευση του δικτύου (συνδυασμοί χωρητικότητων), παίζει καθοριστικό ρόλο στην ακρίβεια των προβλέψεων (Πίνακας 4.8).

Συγκεκριμένα, τα μοντέλα που εκπαιδεύτηκαν με συνδυασμό τεσσάρων χωρητικότητων (400 χιλ. στοιχεία) έδειξαν σημαντικά καλύτερη απόδοση σε σύγκριση με εκείνα των οκτώ χωρητικότητων (200 χιλ. στοιχεία) με το RMSE να μειώνεται κατά περίπου 40%. Αυτό υποδηλώνει ότι η μείωση της πολυπλοκότητας του προβλήματος μέσω της μείωσης του αριθμού των παραμέτρων ελέγχου οδηγεί σε πιο αξιόπιστες προβλέψεις.

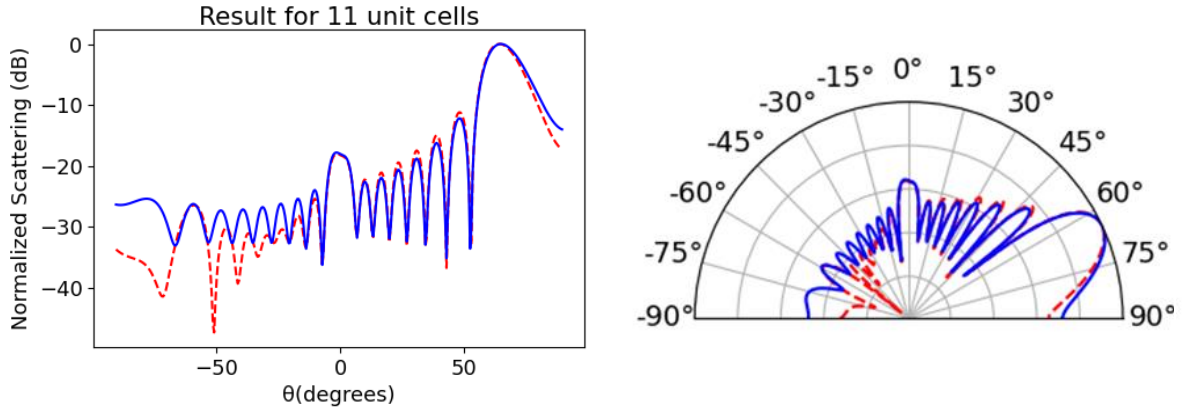
Γωνία	Αριθμός Στοιχείων	Καλύτερο Test MSE	Καλύτερο Test RMSE	Learning Rate	Train Time (sec)
65°	200 χιλ.	0.019886	0.141019	0.01	127.20
65°	400 χιλ.	0.006905	0.083096	0.005	235.98
56°	200 χιλ.	0.020268	0.142365	0.001	154.70
56°	400 χιλ.	0.007355	0.085762	0.005	236.37

Πίνακας 4.8: Πίνακας Καλύτερων Αποτελεσμάτων ανά γωνία και συνδυασμό χωρητικότητας

Μια άλλη σημαντική παρατήρηση αφορά τη διαφορά στην απόδοση μεταξύ των δύο γωνιών. Για τον ίδιο αριθμό συνδυασμού χωρητικότητας, τα μοντέλα για τις 65° παρουσίασαν ελαφρώς καλύτερα αποτελέσματα σε σύγκριση με εκείνα για τις 56°. Αυτή η διαφορά, αν και μικρή, θα μπορούσε να αποδοθεί στις ιδιαιτερότητες της φυσικής συμπεριφοράς του συστήματος στις δύο γωνίες. Για παράδειγμα, η γωνία των 65° μπορεί να επιτρέπει πιο ευέλικτες διαμορφώσεις χωρητικότητας, οι οποίες είναι ευκολότερο να προβλεφθούν από το νευρωνικό δίκτυο. Επιπλέον, η σταθερότητα των αποτελεσμάτων σε διαφορετικά learning rates υποδηλώνει ότι το μοντέλο είναι αρκετά εύρωστο και δεν επηρεάζεται δραστικά από μικρές αλλαγές σε αυτήν την υπερπαραμέτρο. Ωστόσο, το learning rate 0.005 φαίνεται να προσφέρει τις καλύτερες επιδόσεις στις περιπτώσεις συνδυασμών τεσσάρων χωρητικότητας, ενώ για συνδυασμών οκτώ χωρητικότητας, η βέλτιστη επιλογή εξαρτάται από τη γωνία.

Οι βέλτιστες διαμορφώσεις συνδυασμών χωρητικότητας που προέκυψαν από την ανάλυση παρουσιάζουν ενδιαφέροντα μοτίβα. Για παράδειγμα, στις 65°, οι τιμές 0.337, 0.411 και 0.352 εμφανίζονται συχνά στις βέλτιστες διαμορφώσεις, ενώ στις 56° επικρατούν οι τιμές 0.321, 0.411 και 0.218. Αυτές οι τιμές προφανώς αντιστοιχούν σε συγκεκριμένα επίπεδα χωρητικότητας που είναι ιδιαίτερα αποτελεσματικά για τις αντίστοιχες γωνίες. Είναι αξιοσημείωτο ότι η τιμή 0.700, αν και παρουσιάζεται σε ορισμένες διαμορφώσεις, δεν είναι τόσο συχνή, γεγονός που μπορεί να υποδηλώνει ότι χρησιμοποιείται μόνο σε ειδικές περιπτώσεις. Η ταχύτητα με την οποία το μοντέλο μπορεί να εντοπίσει αυτές τις βέλτιστες διαμορφώσεις είναι ένα ακόμη πλεονέκτημα, καθώς ο χρόνος εκτέλεσης για την αναζήτηση της βέλτιστης διαμόρφωσης είναι εξαιρετικά μικρός, μικρότερος από 0.31 δευτερόλεπτα για το test set και κάτω από 3 δευτερόλεπτα για ολόκληρο το dataset.

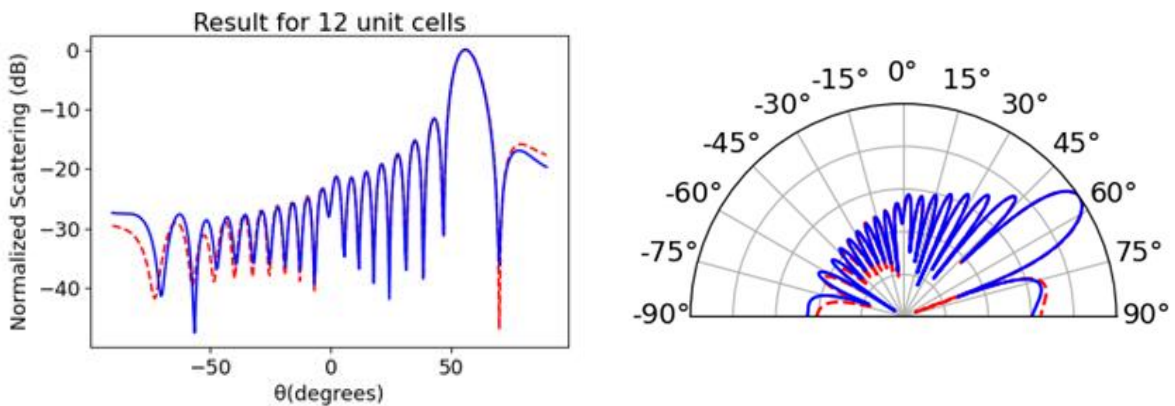
Αναλύοντας τα αποτελέσματα με βάση τους συνδυασμούς χωρητικότητας, για τη γωνία 65° στο test set οι καλύτερες τιμές ήταν 0.352, 0.321, 0.352, 0.352, 0.411, 0.411, 0.218, 0.352, 0.218, 0.218, 0.321. Ακολουθεί διάγραμμα που παράχθηκε με την υλοποίηση του Αλγόριθμου 1 (Εικόνα 4.4).



Εικόνα 4.4: Διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης και πολικό διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης για τις καλύτερες τιμές χωρητικότητας του test set στις 65° και 11 μονάδων κυψελών ανά supercell. TE (κόκκινο), TM (μπλε)

Οι χρόνοι εκπαίδευσης του μοντέλου κυμαίνονται από 127 έως 236 δευτερόλεπτα, ανάλογα με το μέγεθος του προβλήματος. Αυτοί οι χρόνοι είναι αποδεκτοί για πρακτικές εφαρμογές, ειδικά αν ληφθεί υπόψη η πολυπλοκότητα του προβλήματος και ο όγκος των δεδομένων. Επιπλέον, η χρήση ολόκληρου του dataset για την εύρεση της βέλτιστης διαμόρφωσης φαίνεται να προσφέρει πιο αξιόπιστες και γενικεύσιμες λύσεις, καθώς περιλαμβάνει μεγαλύτερη ποικιλία δεδομένων. Αυτό είναι ιδιαίτερα σημαντικό σε πραγματικές εφαρμογές, όπου η ικανότητα του μοντέλου να γενικεύει είναι κρίσιμη.

Για τη γωνία 56°, ο αντίστοιχος βέλτιστος συνδυασμός στο test set ήταν 0.411, 0.411, 0.411, 0.218, 0.218, 0.321, 0.321, 0.218, 0.352, 0.352, 0.321, 0.352. Ακολουθεί διάγραμμα που παράχθηκε με την υλοποίηση του Αλγόριθμου 1 (Εικόνα 4.5).



Εικόνα 4.5: Διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης και πολικό διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης για τις καλύτερες τιμές χωρητικότητας του test set στις 56° και 12 μονάδων κυψελών ανά supercell. TE (κόκκινο), TM (μπλε)

Συνολικά, τα αποτελέσματα αυτής της ανάλυσης παρέχουν πολύτιμες πληροφορίες για τη βελτιστοποίηση των διαμορφώσεων χωρητικότητας με τη χρήση νευρωνικών δικτύων. Η διαπίστωση ότι η μείωση του αριθμού των χωρητικότητας οδηγεί σε σημαντική βελτίωση της απόδοσης είναι ένα σημαντικό εύρημα που μπορεί να καθοδηγήσει μελλοντικές μελέτες και εφαρμογές. Επιπλέον, η ταχύτητα και η ακρίβεια του μοντέλου το καθιστούν μια πρακτική λύση για πραγματικές εφαρμογές, όπου η γρήγορη και αξιόπιστη πρόβλεψη των βέλτιστων διαμορφώσεων είναι απαραίτητη. Τέλος, οι

παρατηρούμενες διαφορές μεταξύ των δύο γωνιών ανοίγουν νέες ερωτήσεις για τη φυσική συμπεριφορά του συστήματος και τις βέλτιστες στρατηγικές για τη βελτιστοποίησή του, θέτοντας τις βάσεις για μελλοντικές έρευνες.

Αρχιτεκτονική RNN για συνδυασμούς χωρητικότητας 4 στοιχείων

Το μοντέλο RNN για συνδυασμούς χωρητικότητας 4 στοιχείων με LSTM αρχιτεκτονική, επέδειξε συνεπή και ικανοποιητική απόδοση σε όλες τις παραμετρικές διαμορφώσεις που δοκιμάστηκαν, με τα σφάλματα να παραμένουν σε πολύ χαμηλά επίπεδα.

Η λεπτομερής αξιολόγηση των αποτελεσμάτων για τις δύο γωνίες έδειξε πως τα δεδομένα που προέρχονταν από τη γωνία των 65° παρείχαν ελαφρώς καλύτερα αποτελέσματα, με μικρότερα σφάλματα και πιο σταθερή απόδοση. Αυτή η διαφοροποίηση ενδέχεται να αντανακλά τα χαρακτηριστικά του προβλήματος και τις ιδιαιτερότητες των δεδομένων για κάθε γωνία, με τα δεδομένα των 65° να παρουσιάζουν μεγαλύτερη ευκολία πρόβλεψης.

Οι πίνακες με τα αποτελέσματα που ακολουθούν αφορούν 400000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικότητας στις 56° .

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.007230	0.016502	0.007422	0.007406	0.086056	157.53
0.005	0.007114	0.016521	0.007201	0.007214	0.084933	144.18
0.01	0.007057	0.016547	0.007172	0.007167	0.084659	140.45

Πίνακας 4.9a: Αποτελέσματα με 8 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.007291	0.0165	0.007383	0.007393	0.085982	181.59
0.005	0.007071	0.016521	0.007293	0.007306	0.085474	264.0
0.01	0.007073	0.016547	0.007408	0.007405	0.086053	138.76

Πίνακας 4.9b: Αποτελέσματα με 16 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.007286	0.016503	0.007326	0.007307	0.085483	291.17
0.005	0.007172	0.016523	0.007589	0.007589	0.087116	140.68
0.01	0.007153	0.016548	0.00766	0.007675	0.087607	193.56

Πίνακας 4.9c: Αποτελέσματα με 32 κρυφούς νευρώνες ανά επίπεδο

Οι πίνακες με τα αποτελέσματα που ακολουθούν αφορούν 400000 στοιχεία στην είσοδο του NN από συνδυασμό 4 χωρητικότητας στις 65° .

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.006935	0.015614	0.007018	0.007022	0.083798	333.63
0.005	0.006738	0.015636	0.007055	0.007042	0.083919	428.68
0.01	0.006746	0.01566	0.007438	0.007436	0.086232	219.33

Πίνακας 4.10a: Αποτελέσματα με 8 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.006933	0.015616	0.007103	0.007081	0.084148	339.72
0.005	0.006857	0.015636	0.006934	0.006937	0.08329	166.5
0.01	0.006765	0.015659	0.006924	0.006932	0.08326	212.45

Πίνακας 4.10b: Αποτελέσματα με 16 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.006946	0.015615	0.007096	0.007088	0.084188	221.88
0.005	0.006825	0.015636	0.007072	0.007084	0.084169	324.9
0.01	0.006881	0.015662	0.007198	0.007188	0.084785	238.72

Πίνακας 4.10c: Αποτελέσματα με 32 κρυφούς νευρώνες ανά επίπεδο

Η ανάλυση των επιδόσεων του μοντέλου RNN (Πίνακες 4.9 και 4.10) ως προς τις μεταβλητές Learning Rate, CV Loss, Train Loss, Val Loss, Test MSE, Test RMSE και Train Time προσφέρει ουσιώδεις ενδείξεις αναφορικά με τη συμπεριφορά του μοντέλου υπό διαφορετικές παραμετρικές ρυθμίσεις. Εστιάζοντας στην παράμετρο του Learning Rate, παρατηρείται ότι, ανεξαρτήτως γωνίας (56° ή 65°) και πλήθους κρυφών νευρώνων (8, 16, ή 32), η τιμή του Learning Rate δεν επηρεάζει σημαντικά την Train Loss, γεγονός που υποδηλώνει σταθερότητα κατά τη φάση της εκπαίδευσης. Αντιθέτως, στις τιμές Validation Loss και Test MSE, διαφαίνεται μία τάση βελτίωσης της γενικευτικής ικανότητας του μοντέλου όταν χρησιμοποιούνται μικρότερες τιμές Learning Rate, και ιδίως η τιμή 0.005. Η τάση αυτή είναι πιο εμφανής σε διαμορφώσεις με ενδιάμεση χωρητικότητα, όπως στην περίπτωση των 16 κρυφών νευρώνων. Στις τιμές της CV Loss παρατηρούμαι ότι όσο αυξάνεται ο αριθμός των κρυφών νευρώνων και μειώνεται το Learning Rate, το CV Loss εμφανίζει ελαφρώς μικρότερες τιμές, ιδίως στις περιπτώσεις με 400.000 δείγματα. Οι χαμηλότερες τιμές CV Loss καταγράφονται για Learning Rate 0.005 ή 0.01, με ενδεικτική την τιμή 0.006738 στους 8 νευρώνες στις 65° . Οι διαφορές είναι μικρές, ωστόσο υποδηλώνουν ότι πιο βαθιές αρχιτεκτονικές ή χαμηλότερα Learning Rates μπορεί να προσφέρουν σταθερότερη απόδοση.

Η στήλη Train Loss δείχνει ελάχιστες διαφοροποιήσεις ανεξαρτήτως μεγέθους του δικτύου ή Learning Rate, κυμαινόμενη σταθερά γύρω στο 0.0156 για δεδομένα στις 65° και 0.0165 για δεδομένα στις 56° ,

αποδεικνύοντας ότι το μοντέλο μαθαίνει καλά τα δεδομένα εκπαίδευσης, ανεξαρτήτως πολυπλοκότητας. Ωστόσο, το πιο κρίσιμο μέγεθος, η Val Loss, είναι αυτή που αντικατοπτρίζει τη δυνατότητα του μοντέλου να γενικεύει. Σε αυτό το πλαίσιο, η χαμηλότερη Val Loss παρατηρείται κυρίως σε δίκτυα με 16 κρυφούς νευρώνες και Learning Rate 0.005 ή 0.01, όπως για παράδειγμα το 0.006924 για τα δεδομένα στις 65° και το 0.007172 για τις 56°, στοιχείο που δείχνει πιο βελτιστοποιημένη χωρητικότητα και καλύτερη γενίκευση.

Όσον αφορά το Test MSE και Test RMSE, η εικόνα είναι αντίστοιχη με τα παραπάνω. Οι μικρότερες τιμές Test MSE (~0.00693–0.00717) εμφανίζονται με Learning Rate 0.005 και μεσαίο μέγεθος δικτύου, καταδεικνύοντας καλή ακρίβεια στην πρόβλεψη πάνω σε άγνωστα δεδομένα. Η Test RMSE, που είναι η τετραγωνική ρίζα του MSE, ενισχύει τη διαίσθηση για την ακρίβεια του μοντέλου. Οι τιμές RMSE παραμένουν σε πολύ ικανοποιητικά επίπεδα (περίπου 0.083–0.086), και η χαμηλότερη τιμή σημειώνεται στα 0.08326 όταν χρησιμοποιούνται 16 νευρώνες και Learning Rate 0.01 στις 65°.

Τα αποτελέσματα της Train Time παρουσιάζουν μεγαλύτερες διαφοροποιήσεις. Η αύξηση του αριθμού νευρώνων από 8 σε 32 προκαλεί αναμενόμενη αύξηση στον χρόνο εκπαίδευσης, κάτι που είναι ιδιαίτερα εμφανές σε ορισμένες περιπτώσεις, όπως στους 16 νευρώνες με Learning Rate 0.005, όπου ο χρόνος φτάνει τα 264 δευτερόλεπτα. Παρ' όλα αυτά, δεν υπάρχει γραμμική συσχέτιση ανάμεσα στον αριθμό νευρώνων και τον χρόνο, καθώς ενίοτε η στοχαστικότητα των RNN και οι διακυμάνσεις στο backpropagation through time προκαλούν απρόβλεπτες διακυμάνσεις.

Συνολικά, το RNN μοντέλο παρουσιάζει σταθερή απόδοση, με σαφείς ενδείξεις ότι ένα μέτριο μέγεθος δικτύου (16 νευρώνες ανά επίπεδο) και Learning Rate στο εύρος 0.005–0.01 επιτυγχάνουν την καλύτερη ισορροπία μεταξύ ακρίβειας πρόβλεψης και χρόνου εκπαίδευσης. Οι διαφορές μεταξύ των δύο γωνιακών συνθηκών (56° και 65°) είναι αμελητέες, υποδεικνύοντας ότι το μοντέλο είναι επαρκώς γενικεύσιμο.

Η επιλογή της βέλτιστης αρχιτεκτονικής αποδείχθηκε εξαρτημένη από τη γωνία. Για τα δεδομένα των 56°, η πιο συμπαγής διαμόρφωση με 8 κρυφούς νευρώνες έδωσε τα καλύτερα αποτελέσματα, ενώ για τα δεδομένα των 65°, η μεσαίου μεγέθους αρχιτεκτονική με 16 νευρώνες υπερέτερουσε. Είναι αξιοσημείωτο ότι η μεγαλύτερη διαμόρφωση με 32 νευρώνες δεν προσέφερε σημαντικά καλύτερα αποτελέσματα, παρά τον αυξημένο υπολογιστικό κόστος, υποδηλώνοντας ότι η πρόβλεψη βέλτιστων χωρητικότητας δεν απαιτεί υπερβολικά πολύπλοκα μοντέλα.

Οι βέλτιστες διαμορφώσεις χωρητικότητας που προέκυψαν από το μοντέλο για τις δύο γωνίες εμφάνισαν ενδιαφέρουσες ομοιότητες, με επαναλαμβανόμενες τιμές γύρω από συγκεκριμένους αριθμούς (0.218, 0.321, 0.352 και 0.411). Αυτό το μοτίβο υποδηλώνει την ύπαρξη ορισμένων βέλτιστων συνδυασμών που ελαχιστοποιούν την απώλεια ισχύος, ανεξάρτητα από τη γωνία. Επιπλέον, η ταχύτητα με την οποία το μοντέλο μπορεί να εντοπίσει αυτούς τους βέλτιστους συνδυασμούς – μικρότερη από 0.5 δευτερόλεπτο - το καθιστά ιδανικό για εφαρμογές πραγματικού χρόνου.

Αξιολογώντας τα μοντέλα των RNNs για συνδυασμούς χωρητικότητας 4 στοιχείων και ανεξαρτήτως γωνίας, προκύπτει ότι το καλύτερο μοντέλο ως προς το Test MSE εντοπίζεται στην αρχιτεκτονική με 16 νευρώνες, με Learning Rate 0.01, τιμή Test MSE 0.006932 και χρόνο εκπαίδευσης 212.45 δευτερόλεπτα. Το μοντέλο με 8 νευρώνες εμφανίζει ελαφρώς υψηλότερο MSE (0.007022) αλλά και χαμηλότερο χρόνο εκπαίδευσης, ενώ το μοντέλο με 32 νευρώνες, αν και πιο σύνθετο, δεν προσφέρει αξιοσημείωτη βελτίωση στην ακρίβεια σε σχέση με τα άλλα δύο (Πίνακας 4.11).

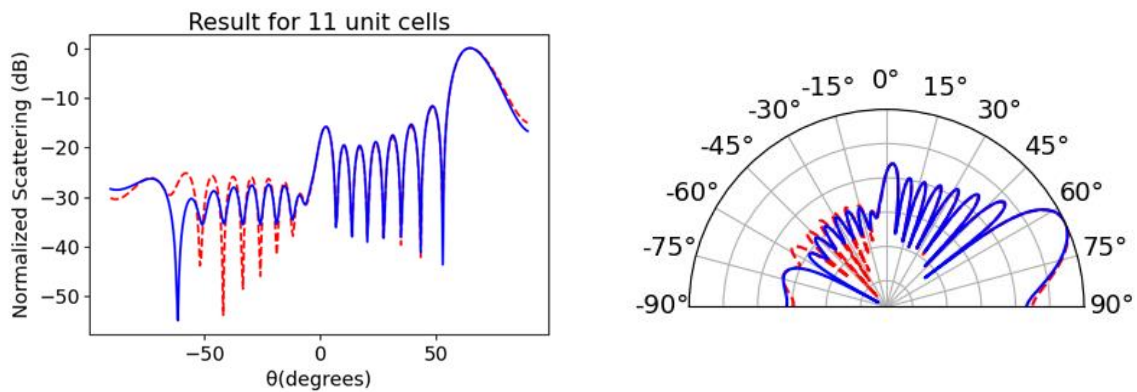
Ο πίνακας που ακολουθεί συνοψίζει τα καλύτερα αποτελέσματα για κάθε μέγεθος κρυφού επιπέδου, περιλαμβάνοντας τόσο την τιμή του Test MSE όσο και την αντίστοιχη τιμή του καλύτερου Validation Loss, μαζί με το Learning Rate και τον χρόνο εκπαίδευσης:

Νευρώνες ανά επίπεδο	Καλύτερο Test MSE	Καλύτερο Validation Loss	Learning Rate	Train Time (sec)
8	0.007022	0.07018	0.0010	333.63
16	0.006932	0.06924	0.0100	212.45
32	0.007084	0.07072	0.0050	324.90

Πίνακας 4.11: Πίνακας Καλύτερων Αποτελεσμάτων RNN για συνδυασμούς χωρητικότητας 4 στοιχείων

Η σύγκλιση των τιμών του Validation Loss με αυτές του Test MSE σε όλες τις περιπτώσεις επιβεβαιώνει την καλή γενίκευση των μοντέλων και την απουσία overfitting. Παρατηρείται επίσης ότι τα καλύτερα αποτελέσματα επιτυγχάνονται για διαφορετικούς Learning Rates ανά αρχιτεκτονική, γεγονός που αναδεικνύει τη σημασία της σωστής παραμετροποίησης κατά την εκπαίδευση.

Συνολικά, το μοντέλο με 16 νευρώνες φαίνεται να προσφέρει τον καλύτερο συνδυασμό ακρίβειας και αποδοτικότητας, καθιστώντας το την πιο ισορροπημένη επιλογή για το συγκεκριμένο πρόβλημα. Αναλύοντας τα αποτελέσματα με βάση τους συνδυασμούς χωρητικότητας, για τη γωνία 65° στο test set οι καλύτερες τιμές χωρητικότητας ήταν 0.352, 0.321, 0.218, 0.321, 0.352, 0.352, 0.352, 0.411, 0.411, 0.218, 0.218. Ακολουθεί διάγραμμα που παράχθηκε με την υλοποίηση του Αλγόριθμου 1 (Εικόνα 4.6).



Εικόνα 4.6: Διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης και πολικό διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης για τις καλύτερες τιμές χωρητικότητας του test set στις 65° και 11 μονάδων κυψελών ανά supercell. TE (κόκκινο), TM (μπλε)

Αρχιτεκτονική RNN για συνδυασμούς χωρητικότητας 8 στοιχείων

Το μοντέλο RNN με βάση τα αποτελέσματα που παρατίθενται στη συνέχεια, παρουσίασε για άλλη μια φορά σταθερή και ικανοποιητική απόδοση στην πρόβλεψη βέλτιστων διαμορφώσεων χωρητικότητας, με σφάλματα που διατηρήθηκαν σε χαμηλά επίπεδα για όλες τις δοκιμασμένες παραμετρικές συνθέσεις.

Οι πίνακες με τα αποτελέσματα που ακολουθούν αφορούν 200000 στοιχεία στην είσοδο του NN από συνδυασμό 8 χωρητικότητας στις 56°.

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.021044	0.03332	0.021048	0.021175	0.145518	145.3
0.005	0.020792	0.033367	0.021336	0.021329	0.146045	71.52
0.01	0.020850	0.033411	0.021192	0.021344	0.146098	91.42

Πίνακας 4.12a: Αποτελέσματα με 8 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.021044	0.03332	0.021048	0.021175	0.145518	145.3
0.005	0.020792	0.033367	0.021336	0.021329	0.146045	71.52
0.01	0.020850	0.033411	0.021192	0.021344	0.146098	91.42

Πίνακας 4.12b: Αποτελέσματα με 16 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.020991	0.033336	0.0211	0.02099	0.14488	88.86
0.005	0.020820	0.033368	0.021033	0.021008	0.144942	176.82
0.01	0.020719	0.033406	0.020791	0.020983	0.144853	104.05

Πίνακας 4.12c: Αποτελέσματα με 32 κρυφούς νευρώνες ανά επίπεδο

Οι πίνακες με τα αποτελέσματα που ακολουθούν αφορούν 200000 στοιχεία στην είσοδο του NN από συνδυασμό 8 χωρητικοτήτων στις 65°.

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.020467	0.032121	0.020458	0.020659	0.143733	112.24
0.005	0.020438	0.032185	0.020894	0.020802	0.144228	79.95
0.01	0.020207	0.032215	0.020285	0.020477	0.143098	198.54

Πίνακας 4.13a: Αποτελέσματα με 8 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.020559	0.032143	0.020625	0.020569	0.143419	100.65
0.005	0.020330	0.032178	0.021017	0.020994	0.144892	121.39
0.01	0.020346	0.032246	0.020446	0.02027	0.142372	121.78

Πίνακας 4.13b: Αποτελέσματα με 16 κρυφούς νευρώνες ανά επίπεδο

Learning Rate	CV Loss	Train Loss	Val Loss	Test MSE	Test RMSE	Train Time
0.001	0.020581	0.032142	0.020774	0.020701	0.143878	221.28
0.005	0.020411	0.032183	0.020693	0.020669	0.143767	266.77
0.01	0.020202	0.032219	0.021039	0.021176	0.145519	110.04

Πίνακας 4.13c: Αποτελέσματα με 32 κρυφούς νευρώνες ανά επίπεδο

Η εξετάζοντας τα αποτελέσματα που βρίσκονται στους πίνακες 4.12 - 4.13 και εστιάζοντας στη στήλη του Learning Rate, διαπιστώνεται ότι όλες οι τιμές που δοκιμάστηκαν (0.001, 0.005 και 0.01) προσφέρουν παρόμοιο επίπεδο απόδοσης, με μόνο ήπιες αποκλίσεις μεταξύ τους. Παρ' όλα αυτά, το learning rate 0.01 εμφανίζει ορισμένες φορές ελαφρώς βελτιωμένα αποτελέσματα στο CV Loss και στο Test RMSE. Σε άλλες περιπτώσεις όμως, συνοδεύεται από σημαντική αύξηση στον χρόνο εκπαίδευσης, γεγονός που το καθιστά λιγότερο αποτελεσματικό από πλευράς υπολογιστικού κόστους.

Η CV Loss διατηρείται σχεδόν σταθερή και εξαιρετικά χαμηλή σε όλες τις περιπτώσεις, υποδεικνύοντας καλή ικανότητα γενίκευσης. Οι διαφορές είναι της τάξης του τέταρτου δεκαδικού ψηφίου, γεγονός που δείχνει ότι το μοντέλο παραμένει συνεπές, ανεξαρτήτως αρχιτεκτονικής και Learning Rate. Αξιοσημείωτο είναι πως με 32 νευρώνες στους 65°, το CV Loss αγγίζει τις καλύτερες τιμές με Learning Rate 0.01, στοιχείο που ενδεχομένως σχετίζεται με την αυξημένη ικανότητα του δικτύου να αποτυπώνει πιο σύνθετα πρότυπα στα δεδομένα.

Η Train Loss και η Validation Loss παρουσιάζουν επίσης σταθερότητα. Οι τιμές του Train Loss είναι πάντα υψηλότερες από το CV Loss και το Val Loss, κάτι που ενδεχομένως οφείλεται στην τυπική διαδικασία regularization ή στον τρόπο κατανομής των δεδομένων. Η μικρή απόκλιση ανάμεσα στο Val Loss και το Train Loss φανερώνει ότι το μοντέλο δεν υπερπροσαρμόζεται και παραμένει σε καλή ισορροπία εκμάθησης.

Αναφορικά με το Test MSE και το Test RMSE, οι τιμές κυμαίνονται σε εξαιρετικά χαμηλά επίπεδα σε όλες τις δοκιμές. Το RMSE πέφτει ακόμη και κάτω από 0.143, ιδίως με learning rate 0.01 και 32 νευρώνες στους 65°, κάτι που αποδεικνύει την υψηλή ακρίβεια πρόβλεψης ακόμη και σε δεδομένα που δεν χρησιμοποιήθηκαν στην εκπαίδευση. Αυτή η τάση εδραιώνει την εμπιστοσύνη στο μοντέλο.

Τέλος, η στήλη Train Time παρουσιάζει τη μεγαλύτερη διακύμανση, με τιμές που κυμαίνονται από περίπου 70 έως και πάνω από 260 δευτερόλεπτα. Δεν παρατηρείται απόλυτη συσχέτιση μεταξύ πλήθους νευρώνων και χρόνου εκπαίδευσης, καθώς π.χ. σε ορισμένες περιπτώσεις με περισσότερους νευρώνες ο χρόνος είναι μικρότερος από μοντέλα με λιγότερους, πιθανόν λόγω παραγόντων όπως το learning rate ή ο εσωτερικός μηχανισμός βελτιστοποίησης.

Συνολικά, τα αποτελέσματα δείχνουν ότι τα δίκτυα RNN, ακόμη και με απλό σχεδιασμό, έχουν ισχυρή γενίκευση και ικανοποιητική ακρίβεια. Το Learning Rate 0.01 συχνά υπερτερεί ελαφρώς σε απόδοση, χωρίς όμως να ξεπερνά σε σταθερότητα το 0.001. Οι 32 νευρώνες φαίνεται να προσφέρουν έναν ιδανικό συνδυασμό ακρίβειας και αξιοπιστίας, ιδιαίτερα στη γωνία των 65°, ενώ το κόστος χρόνου εκπαίδευσης πρέπει πάντα να συνυπολογίζεται, ειδικά σε μεγαλύτερες υλοποιήσεις.

Η σύγκριση μεταξύ των δύο γωνιών επιβεβαιώνει τις ελαφρώς καλύτερες επιδόσεις για την περίπτωση των 65°, όπου το καλύτερο Test MSE έφτασε το 0.020270, ένα αποτέλεσμα που επιτεύχθηκε με αρχιτεκτονική 16 κρυφών νευρώνων και ρυθμό μάθησης 0.01. Αυτή η διαφορά ενδέχεται να οφείλεται σε μικρές διακυμάνσεις στη δομή των δεδομένων ή στη φύση του προβλήματος για τις συγκεκριμένες γωνίες.

Νευρώνες ανά επίπεδο	Καλύτερο Test MSE	Καλύτερο Validation Loss	Learning Rate	Train Time (sec)
8	0.020477	0.020285	0.0100	198.54
16	0.020270	0.020446	0.0100	121.78
32	0.020669	0.020693	0.0050	266.77

Πίνακας 4.14: Πίνακας Καλύτερων Αποτελεσμάτων RNN για συνδυασμούς χωρητικότητας 8 στοιχείων

Η επιλογή της βέλτιστης αρχιτεκτονικής αποδείχθηκε κρίσιμη για την επίδοση του μοντέλου. Το μεσαίου μεγέθους δίκτυο με 16 νευρώνες επέδειξε την καλύτερη ισορροπία μεταξύ ακρίβειας και υπολογιστικού κόστους, ενώ η μεγαλύτερη διαμόρφωση με 32 δεν προσέφερε σημαντική βελτίωση στην απόδοση παρά τον αυξημένο χρόνο εκπαίδευσης (Πίνακας 4.14).. Ο ρυθμός μάθησης επηρέασε έντονα τη συμπεριφορά του μοντέλου, με το μεγαλύτερο ρυθμό του 0.01 να είναι η βέλτιστη επιλογή για τις μεγαλύτερες αρχιτεκτονικές.

Οι ιδανικές διαμορφώσεις χωρητικότητας που προέκυψαν από το μοντέλο παρουσίασαν αξιοσημείωτες ομοιότητες, καθώς ορισμένες συγκεκριμένες τιμές (όπως 0.218, 0.295, 0.321 κ.ά.) εμφανίζονται επανειλημμένα σε διαφορετικούς συνδυασμούς. Το επαναλαμβανόμενο αυτό μοτίβο και σε αυτή την περίπτωση, υποδηλώνει την ύπαρξη ορισμένων βέλτιστων ρυθμίσεων που οδηγούν σε ελαχιστοποίηση της απώλειας ισχύος, ανεξάρτητα από τη γωνία.

Συγκριτικά συμπεράσματα για αποτελέσματα αρχιτεκτονικής RNN


Η σύγκριση μεταξύ των δύο αρχιτεκτονικών ανέδειξε αξιοπρόσεκτες διαφορές στην απόδοσή τους και στη λειτουργία των μοντέλων. Παρόλο που η αρχιτεκτονική των 8 χωρητικότητας εκπαιδεύτηκε με μικρότερο δείγμα, παρουσίασε ελαφρώς αυξημένα σφάλματα - MSE μεταξύ 0.020 και 0.033, σε σύγκριση με περίπου 0.007 για τις 4 χωρητικότητες. Ωστόσο, διατήρησε παρόμοια τάση ως προς τη διαδικασία βελτιστοποίησης, με τον αριθμό των 16 νευρώνων να παραμένει η βέλτιστη επιλογή. Το γεγονός αυτό υποδηλώνει ότι η αύξηση της πολυπλοκότητας του προβλήματος, από 4 σε 8 χωρητικότητες, επιβαρύνει ελαφρώς την ακρίβεια πρόβλεψης, χωρίς όμως να μειώνεται σημαντικά η συνολική αποτελεσματικότητα του μοντέλου.

Οι βέλτιστες διαμορφώσεις και στις δύο περιπτώσεις εμφάνισαν επαναλαμβανόμενες τιμές (π.χ. 0.218, 0.352), γεγονός που επιβεβαιώνει την ύπαρξη συγκεκριμένων βέλτιστων συνδυασμών. Ενδιαφέρον παρουσιάζει ότι οι χρόνοι εκπαίδευσης ήταν παρόμοιοι παρά τη διαφορά στο μέγεθος του δείγματος, πιθανώς λόγω της ικανότητας του LSTM να διαχειρίζεται αποτελεσματικά την αυξημένη

πολυπλοκότητα. Συνολικά, τα αποτελέσματα επιβεβαιώνουν την αποτελεσματικότητα του προτεινόμενου μοντέλου, με την αρχιτεκτονική των 16 νευρώνων και ρυθμό μάθησης 0.01 να ξεχωρίζει ως η βέλτιστη επιλογή.

Για εφαρμογές που απαιτούν υψηλή ακρίβεια, η αρχιτεκτονική με 4 χωρητικότητες είναι προτιμότερη. Για προβλήματα με μεγαλύτερη πολυπλοκότητα, το μοντέλο με 8 χωρητικότητες προσφέρει ικανοποιητική λύση με παρόμοια ταχύτητα πρόβλεψης, μικρότερη του 0.2 δευτερολέπτων. Η κλιμάκωση σε μεγαλύτερα δίκτυα δεν φαίνεται να προσφέρει και σε αυτή την περίπτωση σημαντικά οφέλη, υπογραμμίζοντας την επάρκεια μεσαίων αρχιτεκτονικών. Ωστόσο, η έρευνα θα μπορούσε να επεκταθεί με τη δοκιμή εναλλακτικών αρχιτεκτονικών ή την εφαρμογή πιο προηγμένων τεχνικών βελτιστοποίησης, που ενδέχεται να οδηγήσουν σε περαιτέρω βελτίωση της απόδοσης. Η σταθερότητα των αποτελεσμάτων και η ταχύτητα πρόβλεψης καθιστούν το μοντέλο ιδιαίτερα ελκυστική επιλογή για πρακτικές εφαρμογές.

Για τη γωνία 56° η καλύτερη αρχιτεκτονική περιλαμβάνει 400.000 δείγματα, 8 νευρώνες, με Learning Rate 0.01. Η απόδοση στο test set ήταν MSE 0.007167 και RMSE 0.084659, ενώ ο χρόνος εκπαίδευσης ανήλθε σε 140.45 δευτερόλεπτα. Για τη γωνία 65° , με συνδυασμό τεσσάρων χωρητικότητας και 400.000 δείγματα, η βέλτιστη αρχιτεκτονική περιλαμβάνει 16 νευρώνες με Learning Rate 0.01, επιτυγχάνοντας Test MSE 0.006932 και Test RMSE 0.08326, με χρόνο εκπαίδευσης 212.45 δευτερόλεπτα.



Εικόνα 4.7: Διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης και πολικό διάγραμμα ακτινοβολίας της κανονικοποιημένης ισχύος λήψης για τις καλύτερες τιμές χωρητικότητας του test set στις 65° και 11 μονάδων κυψελών ανά supercell. TE (κόκκινο), TM (μπλε)

Αναλύοντας τα αποτελέσματα για τη γωνία 56° , ο αντίστοιχος βέλτιστος συνδυασμός στο test set ήταν 0.411, 0.411, 0.411, 0.218, 0.218, 0.321, 0.321, 0.218, 0.352, 0.352, 0.321, 0.352 και δημιουργήθηκαν με συνδυασμούς τεσσάρων χωρητικότητας (Εικόνα 4.5).

Αντίστοιχα, τα αποτελέσματα με βάση τους συνδυασμούς χωρητικότητας, για τη γωνία 65° στο test set οι καλύτερες τιμές ήταν 0.295, 0.295, 0.337, 0.352, 0.352, 0.411, 0.411, 0.321, 0.700, 0.218, 0.352. Το διάγραμμα που παράχθηκε με την υλοποίηση του Αλγόριθμου 1 απεικονίζεται στην εικόνα 4.7.

4.2 Συγκριτικά συμπεράσματα αποτελεσμάτων αρχιτεκτονικών FFNN, CNN, RNN

Η συγκριτική αξιολόγηση των αποτελεσμάτων που προέκυψαν από την εφαρμογή των αρχιτεκτονικών FFNN, CNN και RNN αναδεικνύει ουσιαστικές διαφορές αλλά και κοινά χαρακτηριστικά, τα οποία δύνανται να συμβάλουν στην τεκμηριωμένη επιλογή της καταλληλότερης αρχιτεκτονικής, ανάλογα με τις ιδιαίτερες απαιτήσεις του εκάστοτε προβλήματος. Η παρούσα ανάλυση βασίστηκε σε εκτενή σύνολα

δεδομένων και εστίασε σε τρεις κρίσιμες μεταβλητές, την ακρίβεια πρόβλεψης, τη δυνατότητα γενίκευσης του μοντέλου και το υπολογιστικό κόστος, όπως αυτό εκφράζεται μέσω του χρόνου εκπαίδευσης. Τα ευρήματα που προέκυψαν παρουσιάζουν σημαντική ποικιλομορφία, προσφέροντας πολύτιμες ενδείξεις τόσο για τη θεωρητική προσέγγιση της μοντελοποίησης όσο και για την αποτελεσματική εφαρμογή των εν λόγω αρχιτεκτονικών σε πρακτικά πεδία.

Η αρχιτεκτονική FFNN παρουσίασε εξαιρετική απόδοση, ιδιαίτερα για την μικρότερη διάσταση του προβλήματος, των τεσσάρων χωρητικότητας. Τα αποτελέσματα έδειξαν ότι η αύξηση του μεγέθους του κρυφού επιπέδου δεν οδηγεί απαραίτητα σε βελτίωση της απόδοσης. Συγκεκριμένα, το δίκτυο με μόλις 8 νευρώνες στο κρυφό επίπεδο σημείωσε το μικρότερο Test MSE (0.005158) και RMSE (0.071820), ενώ μεγαλύτερα δίκτυα όπως αυτό με τους 128 νευρώνες, είχαν ελαφρώς χειρότερα αποτελέσματα. Ωστόσο, το δίκτυο με 32 νευρώνες αναδείχθηκε ως η πιο ισορροπημένη επιλογή, συνδυάζοντας καλή ακρίβεια με RMSE 0.071876, ταχύτητα εκπαίδευσης στα 95.5 δευτερόλεπτα και ικανότητα γενίκευσης (CV Loss) 0.005090. Για μεγαλύτερα προβλήματα με 8 χωρητικότητες, τα FFNNs έδειξαν παρόμοια απόδοση ανεξάρτητα από το μέγεθος του δικτύου, με μικρές διαφορές στο RMSE που κυμαίνονταν περίπου στο 0.135, υποστηρίζοντας τη χρήση μικρότερων και αποδοτικότερων αρχιτεκτονικών.

Τα CNNs μοντέλα επέδειξαν σημαντικά καλύτερη απόδοση σε προβλήματα με τον μικρότερο συνδυασμό χωρητικότητας των τεσσάρων στοιχείων, όπου το RMSE μειώθηκε κατά περίπου 40% σε σύγκριση με προβλήματα συνδυασμών οκτώ χωρητικότητας. Αυτό υποδηλώνει ότι τα CNNs είναι ιδιαίτερα αποτελεσματικά όταν η πολυπλοκότητα του προβλήματος είναι περιορισμένη. Παράλληλα, παρατηρήθηκε ότι τα CNNs είχαν μεγαλύτερους χρόνους εκπαίδευσης σε σύγκριση με τα FFNNs, γεγονός που σχετίζεται με την αυξημένη υπολογιστική πολυπλοκότητα των συνελκτικών επιπέδων. Επιπλέον, τα CNNs έδειξαν ελαφρώς καλύτερη απόδοση για γωνία 65° σε σύγκριση με αυτή των 56°, πιθανώς λόγω της φύσης των δεδομένων. Οι βέλτιστες διαμορφώσεις χωρητικότητας που προέκυψαν από τα CNNs εμφάνισαν επαναλαμβανόμενες τιμές (π.χ. 0.352, 0.411), υποδηλώνοντας συγκεκριμένα μοτίβα βελτιστοποίησης.

Τα RNNs με αρχιτεκτονική LSTM παρουσίασαν σταθερή απόδοση σε όλες τις περιπτώσεις, με Test MSE περίπου 0.007 για συνδυασμό τεσσάρων χωρητικότητας και περίπου 0.020 με 0.033 για 8 χωρητικότητες. Η βέλτιστη αρχιτεκτονική εμπειρίχε 16 νευρώνες, με Learning Rate 0.01, επιτυγχάνοντας Test MSE 0.006932 και χρόνο εκπαίδευσης 212.45 για συνδυασμό τεσσάρων χωρητικότητας. Τα RNNs έδειξαν ελαφρώς καλύτερη απόδοση για γωνία 65° και διατήρησαν υψηλή ταχύτητα πρόβλεψης, περίπου στα 0.5 δευτερόλεπτα, κάτι που τα καθιστά ιδανικά για εφαρμογές πραγματικού χρόνου. Ωστόσο, οι χρόνοι εκπαίδευσης ήταν υψηλότεροι σε σύγκριση με τα FFNNs, λόγω της πολυπλοκότητας των LSTM κελιών. Επιπλέον, τα RNN επέδειξαν καλή γενίκευση, με τις τιμές του validation loss να συγκλίνουν με αυτές του Test MSE, υποδηλώνοντας απουσία overfitting.

Συγκριτικά, τα FFNNs φαίνεται να είναι η πιο αποδοτική επιλογή για μικρά και μεσαία προβλήματα, όπου η απλότητα και η ταχύτητα εκπαίδευσης είναι κρίσιμες. Τα CNNs, παρόλο που απαιτούν περισσότερους υπολογιστικούς πόρους, προσφέρουν καλύτερη απόδοση σε προβλήματα με περιορισμένη πολυπλοκότητα και μπορούν να ανακαλύψουν χωρικά μοτίβα στα δεδομένα. Τα RNNs, από την άλλη πλευρά, είναι ιδανικά για προβλήματα όπου η χρονική ή διαδοχική φύση των δεδομένων παίζει σημαντικό ρόλο, παρόλο που η εκπαίδευσή τους είναι πιο απαιτητική.

Όσον αφορά τη βέλτιστη αρχιτεκτονική ανάλογα με το μέγεθος του προβλήματος, για συνδυασμό τεσσάρων χωρητικότητας, το FFNN με 32 νευρώνες και το RNN με 16 νευρώνες προσφέρουν την καλύτερη ισορροπία ακρίβειας και ταχύτητας. Για συνδυασμό οκτώ χωρητικότητας, το FFNN με 8 ή 16 νευρώνες και το RNN με 16 νευρώνες φαίνονται να είναι οι καταλληλότερες επιλογές. Τα CNN, ενώ

αποδίδουν καλά σε προβλήματα συνδυασμού τεσσάρων χωρητικότητων, δεν φαίνεται να προσφέρουν σημαντικά πλεονεκτήματα για μεγαλύτερες διαστάσεις.

Σε επίπεδο γενίκευσης, και οι τρεις αρχιτεκτονικές έδειξαν ικανοποιητική απόδοση σε μη ορατά δεδομένα, με τα FFNNs και RNNs να έχουν ελαφρώς καλύτερες επιδόσεις. Οι βέλτιστες διαμορφώσεις χωρητικότητας που προέκυψαν από όλα τα μοντέλα εμφάνισαν επαναλαμβανόμενες τιμές (π.χ. 0.218, 0.352, 0.411), υποδηλώνοντας κοινά μοτίβα βελτιστοποίησης ανεξάρτητα από την αρχιτεκτονική. Αυτό μπορεί να αποτελέσει πολύτιμη πληροφορία για μελλοντικές εφαρμογές και έρευνα.

Συνολικά, η επιλογή της βέλτιστης αρχιτεκτονικής εξαρτάται από τις απαιτήσεις του προβλήματος. Για γρήγορη και αποδοτική επίλυση, τα FFNNs είναι η προτιμώμενη επιλογή. Για προβλήματα με χωρική δομή, τα CNNs μπορούν να προσφέρουν καλύτερη απόδοση, ενώ για προβλήματα με χρονική ή διαδοχική διάσταση, τα RNNs είναι τα καταλληλότερα. Η μελέτη αυτή υπογραμμίζει τη σημασία της σωστής επιλογής αρχιτεκτονικής και των υπερπαραμέτρων, καθώς και την ανάγκη για ισορροπία μεταξύ ακρίβειας, γενίκευσης και υπολογιστικού κόστους.

4.3 Επίλογος

Σε αυτό το κεφάλαιο, γίνεται φανερό ότι η χρήση βαθιών νευρωνικών δικτύων για τη διαμόρφωση δέσμης σε έξυπνες επιφάνειες RIS αποτελεί μια πολλά υποσχόμενη προσέγγιση για την αντιμετώπιση της πολυπλοκότητας των σχετικών προβλημάτων βελτιστοποίησης. Αξιολογήθηκαν διαφορετικές αρχιτεκτονικές NN, με στόχο την υποκατάσταση των συμβατικών μεθόδων null-steering και ABF. Τα αποτελέσματα καταδεικνύουν ότι οι προτεινόμενες μέθοδοι επιτυγχάνουν υψηλή ακρίβεια, μειωμένο χρόνο απόκρισης και χαμηλότερη υπολογιστική απαίτηση, γεγονός που ενισχύει τη δυνατότητα ενσωμάτωσής τους σε πραγματικές εφαρμογές. Παρόλο που υπάρχουν προκλήσεις, όπως η ανάγκη για μεγάλα σύνολα δεδομένων και η βελτιστοποίηση των αρχιτεκτονικών, τα πλεονεκτήματα της προσέγγισης είναι σημαντικά.

Κεφάλαιο 5ο: Συμπεράσματα ή/και προτάσεις βελτίωσης

Η παρούσα μελέτη παρουσίασε μια οργανωμένη προσέγγιση στην ανάλυση και το σχεδιασμό έξυπνων, προσαρμοζόμενων μεταεπιφανειών τύπου RIS, με σκοπό την εφαρμογή τους σε σύγχρονα ασύρματα και κινητά επικοινωνιακά συστήματα. Οι υπό μελέτη μεταεπιφάνειες διαμορφώθηκαν ως περιοδικές δομές που βασίζονται στην επαναλαμβανόμενη χρήση ενός υπερκελίου (supercell), το οποίο αποτελείται από 11 έως 12 μικρότερα μοναδιαία κελιά. Κάθε μονάδα σχεδιάστηκε ως επίπεδο τυπωμένο κύκλωμα και ενσωματώνει varactor, των οποίων η μεταβαλλόμενη χωρητικότητα επηρεάζει τον βαθμό ανάκλασης του κάθε στοιχείου.

Αναπτύχθηκε επίσης ένας υπολογιστικός αλγόριθμος για την παραγωγή του διαγράμματος ακτινοβολίας της RIS επιφάνειας, ο οποίος χρησιμοποιείται για την αξιολόγηση της απόδοσής της. Ο εν λόγω αλγόριθμος αποτέλεσε το θεμέλιο για τον βελτιστοποιημένο σχεδιασμό μεταεπιφανειών με συγκεκριμένες επιθυμητές ιδιότητες, μέσω κατάλληλων τεχνικών βελτιστοποίησης.

Επιπλέον, διαμορφώθηκε ένα πλαίσιο συγκριτικής μελέτης, εστιάζοντας σε συνθήκες εσωτερικού χώρου, με στόχο την ανάκλαση σε διαφορετικές γωνίες. Παρουσιάστηκαν μετρήσεις κατευθυντικότητας και αξιολογήθηκαν δύο διαφορετικές διατάξεις υπερκελιών. Από προηγούμενες εργασίες προέκυψε ότι τα διαγράμματα ακτινοβολίας παρουσιάζουν έναν κύριο λοβό προς την επιθυμητή κατεύθυνση, με περιορισμένη ισχύ σε άλλες διευθύνσεις.

Επίσης, διαπιστώθηκε πως η σχέση (2.1) αποτελεί ένα αξιόπιστο εργαλείο για τον υπολογισμό της RSSI από πεπερασμένου μεγέθους RIS επιφάνειες και μπορεί να αξιοποιηθεί για ρεαλιστικό σχεδιασμό, υποστηριζόμενο από τεχνικές βελτιστοποίησης, ανοίγοντας δρόμους για μελλοντικές εξελίξεις στον τομέα.

Στο επόμενο στάδιο, υλοποιείται ο αλγόριθμος δημιουργίας του dataset, ο οποίος βασίζεται στον υπολογισμό του διαγράμματος ακτινοβολίας της μεταεπιφάνειας RIS. Η διαδικασία ακολουθεί μια οργανωμένη προσέγγιση που περιλαμβάνει την αρχικοποίηση των απαιτούμενων παραμέτρων, την επεξεργασία των δεδομένων, τον υπολογισμό σχετικών φυσικών μεγεθών και την καταγραφή των τελικών αποτελεσμάτων. Τα παραγόμενα σύνολα δεδομένων αξιοποιήθηκαν για την εκπαίδευση νευρωνικών δικτύων, τα οποία κατάφεραν να εντοπίσουν τους ιδανικούς συνδυασμούς χωρητικότητας, με σκοπό την επίτευξη στοχευμένης κατευθυντικότητας στην ακτινοβολία.

Σχετικά με την καθαυτό βελτιστοποίηση, η συγκριτική μελέτη των αρχιτεκτονικών FFNN, CNN και RNN ανέδειξε σημαντικές διαφορές και ομοιότητες, με βασικά κριτήρια την ακρίβεια πρόβλεψης, την ικανότητα γενίκευσης και το υπολογιστικό κόστος (χρόνος εκπαίδευσης). Τα FFNNs παρουσίασαν εξαιρετικές επιδόσεις σε προβλήματα μικρότερης διάστασης (συνδυασμούς χωρητικότητας 4 στοιχείων), με την πιο αποδοτική διαμόρφωση να περιλαμβάνει 32 νευρώνες, συνδυάζοντας υψηλή ακρίβεια και χαμηλό χρόνο εκπαίδευσης. Σε προβλήματα μεγαλύτερης διάστασης (συνδυασμούς χωρητικότητας 8 στοιχείων), η απόδοση των FFNNs παρέμεινε σταθερή ανεξάρτητα από το μέγεθος του δικτύου, γεγονός που υποστηρίζει τη χρήση απλούστερων μοντέλων.

Τα CNNs έδειξαν ιδιαίτερα καλή απόδοση σε προβλήματα χαμηλότερης πολυπλοκότητας, με σημαντική μείωση του RMSE. Ωστόσο, απαιτούν μεγαλύτερο χρόνο εκπαίδευσης λόγω της αυξημένης υπολογιστικής πολυπλοκότητας των συνελκτικών επιπέδων. Τα CNNs φάνηκαν ευαίσθητα σε γωνίες παρατήρησης, με ελαφρώς καλύτερα αποτελέσματα στη γωνία 65° , και εμφάνισαν συγκεκριμένα μοτίβα στις βέλτιστες χωρητικότητες.

Τα RNNs παρουσίασαν σταθερή και αξιόπιστη απόδοση, ειδικά σε προβλήματα με χρονική ή διαδοχική δομή, διατηρώντας παράλληλα υψηλή ταχύτητα πρόβλεψης, κατάλληλη για εφαρμογές πραγματικού χρόνου. Αν και η εκπαίδευση ήταν πιο αργή, επέδειξαν πολύ καλή γενίκευση, χωρίς σημάδια υπερπροσαρμογής.

Συνολικά, τα FFNNs είναι προτιμητέα για μικρής και μεσαίας κλίμακας προβλήματα λόγω απλότητας και ταχύτητας. Τα CNNs υπερέχουν σε χωρικά προβλήματα περιορισμένης πολυπλοκότητας, ενώ τα RNNs είναι κατάλληλα για δυναμικά δεδομένα. Η μελέτη υπογραμμίζει τη σημασία επιλογής κατάλληλης αρχιτεκτονικής, λαμβάνοντας υπόψη την ισορροπία μεταξύ ακρίβειας, γενίκευσης και κόστους. Το ιδιαίτερα σημαντικό στοιχείο που προέκυψε από την μεθοδολογία που παρουσιάστηκε είναι η δυνατότητα επίτευξης πολύ ικανοποιητικών σχεδιάσεων μεταεπιφάνειας, με ένα πολύ περιορισμένο σετ παραμέτρων χωρητικότητας των varactor, αρκεί να καλύπτεται ένα ευρύ σύνολο τιμών της φάσης του συντελεστή ανάκλασης. Η χρήση των τεχνικών ML αποκάλυψε τη δυνατότητα αυτή, με ιδιαίτερη επιτυχία.

Η παρούσα εργασία μπορεί να αποτελέσει αφετηρία για ποικίλες μελλοντικές επεκτάσεις και ερευνητικές προσεγγίσεις. Συγκεκριμένα, ορισμένα ζητήματα που προσφέρονται για περαιτέρω διερεύνηση περιλαμβάνουν:

- Τη μελέτη εναλλακτικών γεωμετριών για τα μοναδιαία κελιά, με στόχο την ενίσχυση της λειτουργικότητας και τη διεύρυνση των παραμέτρων του συντελεστή ανάκλασης. Η διερεύνηση τέτοιων δομών, πιθανώς με χρήση διαφορετικών υλικών ή κυκλωματικών στοιχείων, απαιτεί εξειδικευμένες μεθόδους ηλεκτρομαγνητικής ανάλυσης μέσω κατάλληλων λογισμικών εργαλείων. Για τον λόγο αυτό, η ανάλυση τέτοιων περιπτώσεων δεν εντάχθηκε στο πεδίο της παρούσας μελέτης.
- Παρόλο που οι τεχνικές βαθιάς μάθησης απέδωσαν πολύ καλά στην επίλυση του προβλήματος σχεδιασμού των RIS επιφανειών με γρήγορο και αποδοτικό τρόπο, αξίζει να εξεταστούν και άλλες μεθοδολογίες βελτιστοποίησης, όπως οι αλγόριθμοι Bayesian Optimization ή άλλες τεχνικές από το ευρύτερο φάσμα της μηχανικής μάθησης. Αν και σε μια πραγματική εφαρμογή δεν είναι απαραίτητη η άμεση (real-time) επανασχεδίαση των RIS, η επίτευξη του καλύτερου δυνατού αποτελέσματος στον ελάχιστο δυνατό χρόνο παραμένει επιθυμητή.
- Επιπλέον, σημαντική προοπτική αποτελεί η ενσωμάτωση παραμέτρων του ίδιου του πρωτοκόλλου ασύρματης επικοινωνίας – όταν αυτό οριστεί – ώστε να επιτυγχάνονται δείκτες απόδοσης όπως η χωρητικότητα καναλιού, η εξυπηρέτηση πολλών χρηστών και η διασφάλιση ποιότητας υπηρεσιών (Quality of Service - QoS).
- Τέλος, έχει ιδιαίτερο ενδιαφέρον η ανάπτυξη και κατασκευή ενός πειραματικού πρωτοτύπου RIS, προκειμένου να επαληθευτούν πειραματικά τα θεωρητικά αποτελέσματα του σχεδιασμού που παρουσιάστηκαν στην εργασία.

ΒΙΒΛΙΟΓΡΑΦΙΑ

Φωτογραφία Εξώφυλλου: A. Al-Hilo, M. Samir, M. Elhatab, C. Assi, and S. Sharafeddine, “Reconfigurable Intelligent Surface Enabled Vehicular Communication: Joint User Scheduling and Passive Beamforming,” *IEEE Transactions on Vehicular Technology*, vol. 71, no. 3, pp. 2333–2345, Mar. 2022.

[1] M. Renzo et al., “Smart Radio Environments Empowered by Reconfigurable Intelligent Surfaces: How It Works, State of Research, and The Road Ahead,” *IEEE Journal on Selected Areas in Communications*, vol. 38, no. 11, pp. 2450–2525, Jul. 2020.

[2] Contributors to Wikimedia projects, “5G,” Wikipedia. 2025. [Online]. Available: <https://en.wikipedia.org/w/index.php?title=5G&oldid=1281423756>

[3] P. F. M. Smulders, “The road to 100 Gb/s wireless and beyond: basic issues and key directions,” *IEEE Communications Magazine*, vol. 51, no. 12, pp. 86–91, Dec. 2013.

[4] W. Tang et al., “Wireless Communications With Reconfigurable Intelligent Surface: Path Loss Modeling and Experimental Measurement,” *IEEE Transactions on Wireless Communications*, vol. 20, no. 1, pp. 421–439, Jan. 2021.

[5] M. Jian et al., “Reconfigurable intelligent surfaces for wireless communications: Overview of hardware designs, channel models, and estimation techniques,” *Intelligent and Converged Networks*, vol. 3, no. 1, pp. 1–32, Mar. 2022.

[6] S. Nassirpour, A. Vahid, D.-T. Do, and D. Bharadia, “Beamforming Design in Reconfigurable Intelligent Surface-Assisted IoT Networks Based on Discrete Phase Shifters and Imperfect CSI,” *IEEE Internet of Things Journal*, vol. 11, no. 3, pp. 5301–5315, Feb. 2024.

[7] A. Taneja, S. Rani, A. Alhudhaif, D. Koundal, and E. S. Gündüz, “An optimized scheme for energy efficient wireless communication via intelligent reflecting surfaces,” *Expert Systems with Applications*, vol. 190, p. 116106, Mar. 2022.

[8] Rehman, H. U. Rehman, F. Bellili, A. Mezghani, and E. Hossain, “Modulating Intelligent Surfaces for Multiuser MIMO Systems: Beamforming and Modulation Design,” *IEEE Transactions on Communications*, vol. 70, no. 5, pp. 3234–3249, May 2022.

[9] W. Khalid, A.-A. A. Boulogeorgos, T. V. Chien, J. Lee, H. Lee, and H. Yu, “Optimal Operation of Active RIS-Aided Wireless Powered Communications in IoT Networks,” *IEEE Internet of Things Journal*, pp. 1–1, 2024.

[10] K. M. Faisal and W. Choi, “Machine Learning Approaches for Reconfigurable Intelligent Surfaces: A Survey,” *IEEE Access*, vol. 10, pp. 27343–27367, 2022.

[11] K. M. Faisal and W. Choi, “A Study on Machine Learning-based Approaches for Reconfigurable Intelligent Surface,” in *2021 International Conference on Information and Communication Technology Convergence (ICTC)*, IEEE, Oct. 2021, pp. 227–232.

[12] P. Wang et al., “A Machine Learning Framework for the Design of STCDME Structures in RIS Applications,” *IEEE Transactions on Microwave Theory and Techniques*, vol. 72, no. 3, pp. 1467–1479, Mar. 2024.

[13] C. Liaskos, S. Nie, A. Tsioliariidou, A. Pitsillides, S. Ioannidis, and I. Akyildiz, “Realizing Wireless Communication Through Software-Defined HyperSurface Environments,” in *2018 IEEE 19th*

International Symposium on “A World of Wireless, Mobile and Multimedia Networks” (WoWMoM), IEEE, pp. 14–15, Jun. 2018.

[4] Y. Li, M. Jiang, Q. Zhang, and J. Qin, “Joint Beamforming Design in Multi-Cluster MISO NOMA Reconfigurable Intelligent Surface-Aided Downlink Communication Networks,” *IEEE Transactions on Communications*, vol. 69, no. 1, pp. 664–674, Jan. 2021.

[15] C. Pan et al., “Multicell MIMO Communications Relying on Intelligent Reflecting Surfaces,” *IEEE Transactions on Wireless Communications*, vol. 19, no. 8, pp. 5218–5233, Aug. 2020.

[16] B. Di, H. Zhang, L. Song, Y. Li, Z. Han, and H. V. Poor, “Hybrid Beamforming for Reconfigurable Intelligent Surface based Multi-User Communications: Achievable Rates With Limited Discrete Phase Shifts,” *IEEE Journal on Selected Areas in Communications*, vol. 38, no. 8, pp. 1809–1822, Aug. 2020.

[17] P. Nepa and A. Buffi, “Near-Field-Focused Microwave Antennas: Near-field shaping and implementation,” *IEEE Antennas and Propagation Magazine*, vol. 59, no. 3, pp. 42–53, Jun. 2017.

[18] J. Yuan, H. Q. Ngo, and M. Matthaiou, “Large Intelligent Surface (LIS)-based Communications: New Features and System Layouts,” in *ICC 2020 - 2020 IEEE International Conference on Communications (ICC)*, IEEE, Jun. 2020, pp. 1–6.

[19] A. Elzanaty, A. Guerra, F. Guidi, D. Dardari, and M.-S. Alouini, “Toward 6G Holographic Localization: Enabling Technologies and Perspectives,” *IEEE Internet of Things Magazine*, vol. 6, no. 3, pp. 138–143, Sep. 2023.

[20] L. Li et al., “Electromagnetic reprogrammable coding-metasurface holograms,” *Nature Communications*, vol. 8, no. 1, Aug. 2017.

[21] S. Zahra et al., “Electromagnetic Metasurfaces and Reconfigurable Metasurfaces: A Review,” *Frontiers in Physics*, vol. 8, Jan. 2021.

[22] F. Yang and Y. Rahmat-Samii, *Surface Electromagnetics: With Applications in Antenna, Microwave, and Optical Engineering*. Cambridge University Press, 2019.

[23] V. Arun and H. Balakrishnan, “RFocus: Beamforming Using Thousands of Passive Antennas,” *USENIX*. 2025. [Online]. Available: <https://www.usenix.org/conference/nsdi20/presentation/arun>

[24] R. Sharma, “DOCOMO Conducts World’s First Trial of Transparent Dynamic Metasurface for 5G,” *The Fast Mode*, Jan. 20, 2020. [Online]. Available: <https://www.thefastmode.com/technology-solutions/16253-docomo-conducts-worlds-first-trial-of-transparent-dynamic-metasurface-for-5g>.

[25] M. Ahmed et al., “A Comprehensive Survey of Artificial Intelligence Advances in RIS-Assisted Wireless Networks,” *Institute of Electrical and Electronics Engineers (IEEE)*, Aug. 2024.

[26] B. Peng, K.-L. Besser, R. Raghunath, V. Jamali, and E. A. Jorswieck, “RISnet: A Scalable Approach for Reconfigurable Intelligent Surface Optimization with Partial CSI,” in *GLOBECOM 2023 - 2023 IEEE Global Communications Conference*, IEEE, Dec. 2023, pp. 4810–4816.

[27] C. Liu, F. Yang, M. Li, and S. Xu, “Deep-Learning-Empowered Inverse Design for Freeform Reconfigurable Metasurfaces,” *arXiv.org*, 2022. [Online]. Available: <http://arxiv.org/abs/2211.08296> [cs.LG]. <http://arxiv.org/abs/2211.08296>

[28] J. Gao, C. Zhong, X. Chen, H. Lin, and Z. Zhang, “Unsupervised Learning for Passive Beamforming,” *IEEE Communications Letters*, vol. 24, no. 5, pp. 1052–1056, May 2020.

- [29] Z. Wei et al., “Equivalent Circuit Theory-Assisted Deep Learning for Accelerated Generative Design of Metasurfaces,” *IEEE Transactions on Antennas and Propagation*, vol. 70, no. 7, pp. 5120–5129, Jul. 2022, doi: 10.1109/tap.2022.3152592.
- [30] P. Naseri and S. V. Hum, “A Generative Machine Learning-Based Approach for Inverse Design of Multilayer Metasurfaces,” *IEEE Transactions on Antennas and Propagation*, vol. 69, no. 9, pp. 5725–5739, Sep. 2021.
- [31] J. Wang and J. G. Park, “A Novel Indoor Ranging Algorithm Based on a Received Signal Strength Indicator and Channel State Information Using an Extended Kalman Filter,” *Applied Sciences*, vol. 10, no. 11, p. 3687, May 2020.
- [32] Contributors to Wikimedia projects, “Link budget,” *Wikipedia*. 2025. [Online]. Available: https://en.wikipedia.org/wiki/Link_budget
- [33] K. Ntokos, A. C. Iossifides, and T. V. Yioultsis, “A Rigorous Physical Optics Inspired Path Loss Model for Reconfigurable Intelligent Surfaces”, *IEEE Trans. Antennas Propag.* (under review) 2025.
- [34] C. A. Balanis, *Antenna Theory: Analysis and Design*. John Wiley & Sons, 2005.
- [35] W. K. Chen, *The Electrical Engineering Handbook*. Elsevier, 2004.
- [36] J. Li et al., “Mechanisms of 2π phase control in dielectric metasurface and transmission enhancement effect,” *Optics Express*, vol. 27, no. 16, p. 23186, Jul. 2019.
- [37] Costa, F. Costa and M. Borgese, “Electromagnetic Model of Reflective Intelligent Surfaces,” *IEEE Open Journal of the Communications Society*, vol. 2, pp. 1577–1589, 2021.
- [38] Contributors to Wikimedia projects, “Fermat’s principle,” *Wikipedia*. 2025. [Online]. Available: https://en.wikipedia.org/wiki/Fermat%27s_principle
- [39] M. Hosseini and M. Hakkak, “Characteristics Estimation for Jerusalem Cross-Based Artificial Magnetic Conductors,” *IEEE Antennas and Wireless Propagation Letters*, vol. 7, pp. 58–61, 2008.
- [40] K. Ntokos, P. Mavrikakis, A. C. Iossifides, and T. V. Yioultsis, “A systematic approach for reconfigurable reflecting metasurface synthesis: From periodic analysis to far-field scattering,” *AEU - International Journal of Electronics and Communications*, vol. 170, p. 154780, Oct. 2023 June 2023.
- [41] P. Fondo-Ferreiro, F. B. Saghezchi, F. Gil-Castiñeira, and J. Rodriguez, “Neural Networks for Phase Shift Optimization of Reconfigurable Intelligent Surfaces Under Imperfect Channel State Information,” *IEEE Access*, vol. 13, pp. 53694–53705, 2025.
- [42] B. Feng, J. Gao, Y. Wu, W. Zhang, X.-G. Xia, and C. Xiao, “Optimization Techniques in Reconfigurable Intelligent Surface Aided Networks,” *IEEE Wireless Communications*, vol. 28, no. 6, pp. 87–93, Dec. 2021.
- [43] Y. Yang et al., “Intelligent metasurfaces: Integration of artificial intelligence technology and metasurfaces,” *Chinese Journal of Physics*, vol. 89, pp. 991–1008, Jun. 2024.
- [44] L.-Y. Xiao, F.-L. Jin, B.-Z. Wang, Q. H. Liu, and W. Shao, “Efficient Inverse Extreme Learning Machine for Parametric Design of Metasurfaces,” *IEEE Antennas and Wireless Propagation Letters*, vol. 19, no. 6, pp. 992–996, Jun. 2020.

- [45] K. Shafique and M. Alhassoun, “Going Beyond a Simple RIS: Trends and Techniques Paving the Path of Future RIS,” *IEEE Open Journal of Antennas and Propagation*, vol. 5, no. 2, pp. 256–276, Apr. 2024.
- [46] G. Bebis, and M. Georgiopoulos, “Feed-forward neural networks,” *IEEE Potentials*, 13 (4), 27–31, 1994.
- [47] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, “A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects,” *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 12, pp. 6999–7019, Dec. 2022.
- [48] M. Lan, Y. Hei, J. Ding, M. Huo, and W. Li, “Phase Modulated Hybrid Precoding Design for Multi-RIS Aided Cell-Free mmWave MIMO System,” *IEEE Transactions on Wireless Communications*, vol. 23, no. 12, pp. 18083–18095, Dec. 2024.
- [49] M. Chen, U. Challita, W. Saad, C. Yin, and M. Debbah, “Artificial Neural Networks-Based Machine Learning for Wireless Networks: A Tutorial,” *IEEE Communications Surveys & Tutorials*, vol. 21, no. 4, pp. 3039–3071, 2019.
- [50] A. Ly and Y.-D. Yao, “A Review of Deep Learning in 5G Research: Channel Coding, Massive MIMO, Multiple Access, Resource Allocation, and Network Security,” *IEEE Open Journal of the Communications Society*, vol. 2, pp. 396–408, 2021.
- [51] I. I. Ioannou et al., “DeepRISBeam: Deep Learning-Based RIS Beam Management for Radio Channel Optimization,” *IEEE Access*, vol. 12, pp. 81646–81681, 2024

ΠΑΡΑΡΤΗΜΑ: ΑΠΟΤΕΛΕΣΜΑΤΑ

Οι καλύτεροι συνδυασμοί χωρητικότητας οργανωμένοι ανά αρχείο (συνδυασμός χωρητικότητας), γωνία και μέγεθος κρυφών νευρώνων που εξάχθηκαν από τα test set.

FFNN

Dataset με 400000 στοιχεία (Συνδυασμός 4 χωρητικότητας στις 560)

Επίπεδο Κρυφού Δικτύου 8 Νευρώνων

Best capacitance from test set:

0.321, 0.352, 0.411, 0.218, 0.411, 0.218, 0.321, 0.321, 0.352, 0.218, 0.352, 0.411

Time taken: 0.3059 sec

Επίπεδο Κρυφού Δικτύου 16 Νευρώνων

Best capacitance from test set:

0.218, 0.321, 0.218, 0.321, 0.321, 0.352, 0.352, 0.352, 0.411, 0.411, 0.218, 0.411

Time taken: 0.3527 sec

Επίπεδο Κρυφού Δικτύου 32 Νευρώνων

Best capacitance from test set:

0.218, 0.411, 0.218, 0.218, 0.321, 0.321, 0.352, 0.321, 0.352, 0.411, 0.352, 0.411

Time taken: 0.3089 sec

Επίπεδο Κρυφού Δικτύου 64 Νευρώνων

Best capacitance from test set:

0.218, 0.352, 0.321, 0.218, 0.411, 0.321, 0.321, 0.352, 0.352, 0.411, 0.411, 0.218

Time taken: 0.2729 sec

Επίπεδο Κρυφού Δικτύου 128 Νευρώνων

Best capacitance from test set:

0.218, 0.352, 0.321, 0.218, 0.411, 0.321, 0.321, 0.352, 0.352, 0.411, 0.411, 0.218

Time taken: 0.3039 sec

Dataset με 400000 στοιχεία (Συνδυασμός 4 χωρητικότητας στις 650)

Επίπεδο Κρυφού Δικτύου 8 Νευρώνων

Best capacitance from test set:

0.352, 0.352, 0.321, 0.411, 0.411, 0.411, 0.218, 0.321, 0.321, 0.218, 0.352

Time taken: 0.2964 sec

Επίπεδο Κρυφού Δικτύου 16 Νευρώνων

Best capacitance from test set:

0.352, 0.411, 0.411, 0.218, 0.218, 0.352, 0.321, 0.218, 0.321, 0.352, 0.352

Time taken: 0.3223 sec

Επίπεδο Κρυφού Δικτύου 32 Νευρώνων

Best capacitance from test set:

0.352, 0.218, 0.352, 0.352, 0.411, 0.218, 0.411, 0.321, 0.218, 0.321, 0.352

Time taken: 0.2879 sec

Επίπεδο Κρυφού Δικτύου 64 Νευρώνων

Best capacitance from test set:

0.352, 0.352, 0.352, 0.411, 0.411, 0.218, 0.218, 0.352, 0.321, 0.218, 0.321

Time taken: 0.3014 sec

Επίπεδο Κρυφού Δικτύου 128 Νευρώνων

Best capacitance from test set:

0.352, 0.411, 0.411, 0.218, 0.352, 0.218, 0.218, 0.321, 0.352, 0.321, 0.352

Time taken: 0.2924 sec

Dataset με 200000 Στοιχεία (Συνδυασμός 8 Χωρητικοτήτων στις 56°)

Επίπεδο Κρυφού Δικτύου 8 Νευρώνων

Best capacitance test set:

0.337, 0.411, 0.411, 0.700, 0.321, 0.295, 0.218, 0.352, 0.352, 0.321, 0.700, 0.352

Time taken: 0.1512 sec

Επίπεδο Κρυφού Δικτύου 16 Νευρώνων

Best capacitance test set:

0.321, 0.352, 0.337, 0.371, 0.371, 0.700, 0.411, 0.218, 0.321, 0.218, 0.352, 0.295

Time taken: 0.1573 sec

Επίπεδο Κρυφού Δικτύου 32 Νευρώνων

Best capacitance test set:

0.371, 0.700, 0.295, 0.321, 0.411, 0.411, 0.295, 0.337, 0.295, 0.337, 0.411, 0.352

Time taken: 0.1522 sec

Dataset με 200000 Στοιχεία (Συνδυασμός 8 Χωρητικοτήτων στις 65°)

Επίπεδο Κρυφού Δικτύου 8 Νευρώνων

Best capacitance test set:

0.371, 0.700, 0.218, 0.218, 0.321, 0.337, 0.321, 0.371, 0.337, 0.371, 0.411

Time taken: 0.1489 sec

Επίπεδο Κρυφού Δικτύου 16 Νευρώνων

Best capacitance test set:

0.371, 0.352, 0.700, 0.218, 0.411, 0.295, 0.295, 0.321, 0.337, 0.352, 0.411

Time taken: 0.1397 sec

Επίπεδο Κρυφού Δικτύου 32 Νευρώνων

Best capacitance test set:

0.371, 0.352, 0.218, 0.371, 0.700, 0.218, 0.337, 0.295, 0.371, 0.295, 0.377

Time taken: 0.1473 sec

CNN

Dataset με 200000 στοιχεία (Συνδυασμός 8 χωρητικοτήτων στις 65°)

Best capacitance from test set:

0.295, 0.371, 0.371, 0.700, 0.295, 0.295, 0.700, 0.337, 0.337, 0.321, 0.371, 0.411

Time taken: 0.1741 sec

Dataset με 200000 στοιχεία (Συνδυασμός 8 χωρητικοτήτων στις 56°)

Best capacitance from test set:

0.337, 0.337, 0.411, 0.371, 0.411, 0.700, 0.295, 0.218, 0.321, 0.321, 0.371

Time taken: 0.1539 sec

Dataset με 400000 στοιχεία (Συνδυασμός 4 χωρητικοτήτων στις 56°)

Best capacitance from test set:

0.411, 0.411, 0.411, 0.218, 0.218, 0.321, 0.321, 0.218, 0.352, 0.352, 0.321, 0.352

Time taken: 0.3092 sec

Dataset με 400000 στοιχεία (Συνδυασμός 4 χωρητικοτήτων στις 65°)

Best capacitance from test set:

0.352, 0.321, 0.352, 0.352, 0.411, 0.411, 0.218, 0.352, 0.218, 0.218, 0.321

Time taken: 0.3090 sec

RNN

Αρχείο με 400000 στοιχεία (Συνδυασμός 4 χωρητικοτήτων στις 56ο)

Επίπεδο Κρυφού Δικτύου 8 Νευρώνων

Best capacitance from test set:

0.411, 0.411, 0.411, 0.218, 0.218, 0.321, 0.321, 0.218, 0.352, 0.352, 0.321, 0.352

Time taken: 0.3022 sec

Επίπεδο Κρυφού Δικτύου 16 Νευρώνων

Best capacitance from test set:

0.218, 0.352, 0.352, 0.321, 0.411, 0.352, 0.218, 0.411, 0.411, 0.321, 0.218, 0.321

Time taken: 0.3092 sec

Επίπεδο Κρυφού Δικτύου 32 Νευρώνων

Best capacitance from test set:

0.218, 0.411, 0.321, 0.218, 0.321, 0.321, 0.352, 0.352, 0.411, 0.352, 0.411, 0.218

Time taken: 0.2935 sec

Dataset με 400000 Στοιχεία (Συνδυασμός 4 Χωρητικοτήτων στις 65°)

Επίπεδο Κρυφού Δικτύου 8 Νευρώνων

Best capacitance from test set:

0.352, 0.352, 0.321, 0.352, 0.411, 0.411, 0.218, 0.352, 0.218, 0.321, 0.218

Time taken: 0.3241 sec

Επίπεδο Κρυφού Δικτύου 16 Νευρώνων

Best capacitance from test set:

0.352, 0.321, 0.218, 0.321, 0.352, 0.352, 0.352, 0.411, 0.411, 0.218, 0.218

Time taken: 0.2691 sec

Επίπεδο Κρυφού Δικτύου 32 Νευρώνων

Best capacitance from test set:

0.352, 0.352, 0.352, 0.411, 0.411, 0.218, 0.218, 0.352, 0.321, 0.218, 0.321

Time taken: 0.3276 sec

Dataset με 200000 στοιχεία (Συνδυασμός 8 χωρητικοτήτων στις 56ο)

Επίπεδο Κρυφού Δικτύου 8 Νευρώνων

Best capacitance from test set:

0.700, 0.352, 0.700, 0.371, 0.295, 0.371, 0.218, 0.295, 0.700, 0.337, 0.337, 0.337

Time taken: 0.1577 sec

Επίπεδο Κρυφού Δικτύου 16 Νευρώνων

Best capacitance from test set:

0.337, 0.411, 0.411, 0.371, 0.337, 0.218, 0.700, 0.295, 0.700, 0.337, 0.337, 0.321

Time taken: 0.1665 sec

Επίπεδο Κρυφού Δικτύου 32 Νευρώνων

Best capacitance from test set:

0.700, 0.337, 0.371, 0.411, 0.218, 0.352, 0.218, 0.295, 0.411, 0.321, 0.352, 0.321

Time taken: 0.1589 sec

Dataset με 200000 στοιχεία (Συνδυασμός 8 χωρητικότητων στις 650)

Επίπεδο Κρυφού Δικτύου 8 Νευρώνων

Best capacitance from test set:

0.295, 0.295, 0.337, 0.352, 0.352, 0.411, 0.411, 0.321, 0.700, 0.218, 0.352

Time taken: 0.1489 sec

Επίπεδο Κρυφού Δικτύου 16 Νευρώνων

Best capacitance from test set:

0.295, 0.295, 0.337, 0.352, 0.352, 0.411, 0.411, 0.321, 0.700, 0.218, 0.352

Time taken: 0.1536 sec

Επίπεδο Κρυφού Δικτύου 32 Νευρώνων

Best capacitance from test set:

0.371, 0.371, 0.700, 0.218, 0.321, 0.700, 0.352, 0.321, 0.218, 0.337, 0.352

Time taken: 0.1693 sec