



# ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΤΟΜΕΑΣ ΗΛΕΚΤΡΙΚΩΝ ΒΙΟΜΗΧΑΝΙΚΩΝ ΔΙΑΤΑΞΕΩΝ ΚΑΙ ΣΥΣΤΗΜΑΤΩΝ ΑΠΟΦΑΣΕΩΝ

## Πρόβλεψη Χρονοσειρών μέσω Εικόνων με χρήση Γεννητικών Ανταγωνιστικών Νευρωνικών Δικτύων

### ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

ΕΛΕΝΑΣ - ΜΠΙΑΝΚΑ Ν. ΜΑΡΚΟΥΛΕΣΚΟΥ

**Επιβλέπων:** Βασίλειος Ασημακόπουλος  
Καθηγητής Ε.Μ.Π.

**Υπεύθυνος:** Ευάγγελος Σπηλιώτης  
Διδάκτωρ Ε.Μ.Π.

ΜΟΝΑΔΑ ΠΡΟΒΛΕΨΕΩΝ ΚΑΙ ΣΤΡΑΤΗΓΙΚΗΣ

Αθήνα, Φεβρουάριος 2021





Εθνικό Μετσόβιο Πολυτεχνείο  
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών  
Τομέας Ηλεκτρικών Βιομηχανικών Διατάξεων και Συστημάτων Αποφάσε-  
ων  
Μονάδα Προβλέψεων και Στρατηγικής

# Πρόβλεψη Χρονοσειρών μέσω Εικόνων με χρήση Γεννητικών Ανταγωνιστικών Νευρωνικών Δικτύων

## ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

της

**ΕΛΕΝΑΣ - ΜΠΙΑΝΚΑ Ν. ΜΑΡΚΟΥΛΕΣΚΟΥ**

**Επιβλέπων:** Βασίλειος Ασημακόπουλος  
Καθηγητής Ε.Μ.Π.

**Υπεύθυνος:** Ευάγγελος Σπηλιώτης  
Διδάκτωρ Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την .....

(Υπογραφή)

(Υπογραφή)

(Υπογραφή)

.....

Βασίλειος  
Ασημακόπουλος

Καθηγητής Ε.Μ.Π.

.....

Ιωάννης Ψαρράς

Καθηγητής Ε.Μ.Π.

.....

Δημήτριος Ασκούνης

Καθηγητής Ε.Μ.Π.

Αθήνα, Φεβρουάριος 2021





Εθνικό Μετσόβιο Πολυτεχνείο  
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών  
Τομέας Ηλεκτρικών Βιομηχανικών Διατάξεων και Συστημάτων Αποφάσε-  
ων  
Μονάδα Προβλέψεων και Στρατηγικής

(Υπογραφή)

.....  
**ΕΛΕΝΑ - ΜΠΙΑΝΚΑ ΜΑΡΚΟΥΛΕΣΚΟΥ**

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

Copyright © 2021 Έλενα - Μπιάνκα Μαρκουλέσκου, 2021.

Με επιφύλαξη παντός δικαιώματος. –All rights reserved

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

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



# Ευχαριστίες

Η παρούσα διπλωματική εργασία εκπονήθηκε σε στενή συνεργασία με τη Μονάδα Προβλέψεων και Στρατηγικής, που ανήκει στον τομέα Βιομηχανικών Διατάξεων και Συστημάτων Αποφάσεων της Σχολής Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου.

Στο πλαίσιο αυτό θα ήθελα να ευχαριστήσω θερμά τον Καθηγητή κ. Βασίλειο Ασημακόπουλο για την ευκαιρία που μου έδωσε να ασχοληθώ με ένα πολύ δημοφιλές και πολυσυζητημένο θέμα, που αποτελεί η Μηχανική Μάθηση, εφαρμοσμένη στον τομέα των Προβλέψεων. Ακόμα, θα ήθελα να ευχαριστήσω τους Καθηγητές κ. Ιωάννη Ψαρρά και κ. Δημήτριο Ασκούνη για τη συμμετοχή τους στην τριμελή εξεταστική επιτροπή της παρούσας διπλωματικής εργασίας.

Τις θερμές μου ευχαριστίες θα ήθελα να δώσω στον Διδάκτορα κ. Ευάγγελο Σπηλιώτη, η συνεισφορά του οποίου ήταν καθοριστική για την ολοκλήρωση αυτής της εργασίας. Η συνεχής του καθοδήγηση και οι συμβουλές και υποδείξεις του ήταν πολύτιμες. Επιπρόσθετα, θα ήθελα να εκφράσω την ευγνωμοσύνη μου προς τον Υποψήφιο Διδάκτορα κ. Αρτέμιο Σεμένογλου για τις γνώσεις που μοιράστηκε μαζί μου πάνω στον τομέα της μηχανικής μάθησης.

Τέλος, θα ήθελα να ευχαριστήσω την οικογένεια και τους φίλους μου για την υποστήριξή τους καθ' όλη τη διάρκεια των σπουδών μου.

Έλενα - Μπιάνκα Μαρκουλέσκου  
Αθήνα, Φεβρουάριος 2021





# Περίληψη

Σκοπός της διπλωματικής εργασίας είναι η ανάπτυξη μιας μεθοδολογίας για την παραγωγή προβλέψεων μέσω γραφικών αναπαραστάσεων χρονοσειρών, με τη χρήση μοντέλων μηχανικής μάθησης. Οι προβλέψεις αποτελούν αναπόσπαστο κομμάτι των επιχειρήσεων. Η ορθότητά τους είναι πολύ σημαντική για τη λήψη αποφάσεων, που καθορίζουν το μέλλον μιας επιχείρησης. Ακόμα, η επιστήμη των νευρωνικών δικτύων τα τελευταία χρόνια έχει στραφεί προς το χώρο της εικόνας, όπου έχουν εφευρεθεί πολυάριθμες τεχνικές για επεξεργασία, κατηγοριοποίηση ή παραγωγή τους. Έτσι, είναι επόμενο να αναζητήσει κανείς τρόπους για να αξιοποιήσει αυτές τις καλά εδραιωμένες τεχνικές σε άλλους τομείς, όπως αυτός των προβλέψεων.

Στα πλαίσια της παρούσας διπλωματικής εργασίας παρουσιάζεται μια πλήρης μεθοδολογία για την πρόβλεψη μελλοντικών συμπεριφορών χρονοσειρών από εικόνες. Αρχικά προτείνεται μια μέθοδος για μετατροπή των χρονοσειρών σε εικόνες των γραφικών τους αναπαραστάσεων, σε μορφή κατάλληλη για εισαγωγή σε κάποιο νευρωνικό μοντέλο. Στη συνέχεια μελετάται η αρχιτεκτονική αυτού του μοντέλου. Τέλος, αναλύεται ένας αλγόριθμος για την μετατροπή των εξαγόμενων εικόνων σε αριθμητικά δεδομένα χρονοσειρών, έτσι ώστε να καταστεί δυνατή η ποσοτική μελέτη των αποτελεσμάτων.

Το νευρωνικό μοντέλο που προτείνεται για την παραγωγή προβλέψεων είναι αυτό των Γεννητικών Ανταγωνιστικών Δικτύων. Τα Γεννητικά Ανταγωνιστικά δίκτυα προτάθηκαν για πρώτη φορά το 2014 από τον Ian Goodfellow και έκτοτε έχουν βρει πολλές εφαρμογές, κυρίως σε ό,τι αφορά την επεξεργασία και παραγωγή εικόνων αλλά και σε άλλους τομείς όπως είναι η κινούμενη εικόνα ή ακόμα και η ασφάλεια. Το μεγάλο πλεονέκτημά τους είναι η δυνατότητά τους να παράγουν αληθοφανείς εικόνες, που δεν ξεχωρίζουν από τις πραγματικές.

Η διπλωματική εργασία περατώνεται με τον υπολογισμό και τη μελέτη ποσοτικών αποτελεσμάτων και ποιοτικών χαρακτηριστικών των εξαγόμενων από τα μοντέλα εικόνων και αντίστοιχων τιμών. Συγκρίνονται διάφορες αρχιτεκτονικές τόσο μεταξύ τους όσο και με κλασικές στατιστικές μεθόδους. Διατυπώνονται συμπεράσματα και προτείνονται τρόποι για περαιτέρω βελτίωση και αξιοποίηση της παρούσας μελέτης.

## Λέξεις Κλειδιά

Προβλέψεις, Χρονοσειρά, Γραφική Αναπαράσταση, Εικόνα, Μηχανική Μάθηση, Νευρωνικό Δίκτυο, Αυτοκωδικοποιητής, Γεννητικό Ανταγωνιστικό Δίκτυο



# Abstract

The aim of this diploma thesis is to develop a methodology for time series forecasting with neural networks, based on time series' graphic representation. Forecasting is for supporting decisions in enterprises and their accuracy determines the future path of a business. Moreover numerous breakthroughs have been made during the past years, regarding the editing, classification and generation of images with the help of machine learning models. It is only natural for someone to think of ways to make good use of these techniques for other tasks such as forecasting.

This thesis proposes a methodological approach for predicting a time series' future behavior through its graph. Firstly, an algorithm is proposed with duty to transform a time series into its graph in a way that is suitable for feeding it into a machine learning model. Secondly, neural networks architectures are studied. Last but not least, in order to compare the results quantitatively, a method which converts time series images into their values is developed.

The proposed model for image to image forecasting is a Generative Adversarial Network (GAN). GANs were first proposed in 2014 by Ian Goodfellow. Since then, they have been used in numerous applications dealing not only with image processing and generation but also video and even security. Their biggest advantage is their ability to produce images which are indistinguishable from the real ones.

The thesis ends by presenting the results and calculating the method's accuracy as well as qualitative characteristics. Different architectures are compared with classical forecasting models. Conclusions are drawn regarding the methodology and its outcome. Future improvements and practical uses are suggested.

## Keywords

Forecasting, Time Series, Time Series Graph, Picture, Machine Learning, Neural Network, Autoencoder, Generative Adversarial Network, GAN



# Περιεχόμενα

Ευχαριστίες	1
Περίληψη	3
Abstract	5
Περιεχόμενα	9
Κατάλογος Σχημάτων	12
Κατάλογος Πινάκων	13
<b>1 Εισαγωγή</b>	<b>15</b>
1.1 Αντικείμενο της Εργασίας	15
1.2 Οργάνωση της Εργασίας	17
<b>2 Τεχνικές Προβλέψεων και Δείκτες Ακρίβειας</b>	<b>19</b>
2.1 Χρονοσειρές και Χαρακτηριστικά	19
2.1.1 Ποιοτικά χαρακτηριστικά των χρονοσειρών	19
2.1.2 Γραφική αναπαράσταση χρονοσειράς	21
2.2 Γενικά για τις Προβλέψεις	22
2.2.1 Μοντέλα Πρόβλεψης	22
2.2.2 Βασικά βήματα της διαδικασίας της πρόβλεψης	24
2.3 Στατιστικές Μέθοδοι Προβλέψεων	25
2.3.1 Αφελής Μέθοδος (Naive)	25
2.3.2 Μέθοδοι Εκθετικής Εξομάλυνσης	25
2.3.3 Η Μέθοδος Theta	28
2.3.4 Νευρωνικά Δίκτυα (Neural Networks)	29
2.4 Δείκτες Ακρίβειας	30

<b>3</b>	<b>Νευρωνικά Δίκτυα</b>	<b>33</b>
3.1	Εισαγωγή στα Νευρωνικά Δίκτυα . . . . .	33
3.1.1	Τι είναι τα Νευρωνικά Δίκτυα . . . . .	33
3.1.2	Ιδιότητες των νευρωνικών δικτύων . . . . .	34
3.2	Μοντέλα Νευρώνων . . . . .	35
3.3	Συναρτήσεις Ενεργοποίησης . . . . .	37
3.3.1	Σιγμοειδής Συνάρτηση . . . . .	37
3.3.2	Συνάρτηση Υπερβολικής Εφαπτομένης . . . . .	37
3.3.3	Συνάρτηση ReLU . . . . .	37
3.3.4	Συνάρτηση Leaky ReLU . . . . .	38
3.4	Αρχιτεκτονικές Δικτύων . . . . .	38
3.4.1	Το Perceptron . . . . .	38
3.4.2	Δίκτυα Πρόσθιας Τροφοδότησης Μοναδικού Επιπέδου . . . . .	40
3.4.3	Δίκτυα Πρόσθιας Τροφοδότησης Πολλαπλών Επιπέδων . . . . .	40
3.4.4	Μια ενδιαφέρουσα αρχιτεκτονική: ο Αυτοκωδικοποιητής . . . . .	42
3.5	Διαδικασίες Μάθησης . . . . .	43
3.5.1	Μάθηση με Εκπαιδευτή . . . . .	44
3.5.2	Μάθηση χωρίς Εκπαιδευτή . . . . .	44
3.5.3	Ο Αλγόριθμος Backpropagation . . . . .	45
<b>4</b>	<b>Συνελικτικά και Γεννητικά Νευρωνικά Δίκτυα</b>	<b>49</b>
4.1	Συνελικτικά Δίκτυα . . . . .	49
4.1.1	Η Συνέλιξη . . . . .	49
4.1.2	Πλεονεκτήματα Συνελικτικών Νευρωνικών Δικτύων . . . . .	50
4.1.3	Τα Στάδια ενός Συνελικτικού Επιπέδου . . . . .	52
4.2	Γεννητικά Δίκτυα . . . . .	54
4.3	Γεννητικά Ανταγωνιστικά Δίκτυα . . . . .	54
4.3.1	Δημοφιλείς Εφαρμογές με Ανταγωνιστικά Γεννητικά Δίκτυα . . . . .	56
<b>5</b>	<b>Προτεινόμενη Μεθοδολογία</b>	<b>61</b>
5.1	Γενική Περιγραφή Προτεινόμενου Πλαισίου . . . . .	61
5.2	Προεπεξεργασία Εικόνων . . . . .	62
5.3	Αρχιτεκτονική Μοντέλου . . . . .	64
5.3.1	Συνελικτικό Μπλοκ . . . . .	64
5.3.2	Αυτοκωδικοποιητής . . . . .	66

---

5.3.3	Γεννητικό Ανταγωνιστικό Δίκτυο . . . . .	67
5.3.4	Υλοποίηση . . . . .	69
5.4	Εκπαίδευση Μοντέλου . . . . .	71
5.5	Εξαγωγή Προβλέψεων . . . . .	73
5.6	Επεξεργασία Αποτελεσμάτων . . . . .	73
5.7	Παράδειγμα . . . . .	74
<b>6</b>	<b>Αποτελέσματα και Αξιολόγηση</b>	<b>77</b>
6.1	Πειραματικό Σύνολο Δεδομένων . . . . .	77
6.2	Σημείο Αναφοράς και Δείκτες Αξιολόγησης . . . . .	78
6.3	Επικύρωση των Αποτελεσμάτων . . . . .	78
6.4	Ποσοτικά αποτελέσματα . . . . .	79
6.4.1	Ευρωστία Μοντέλου . . . . .	81
6.4.2	Σύγκριση Μοντέλων . . . . .	81
6.5	Χρόνοι Εκπαίδευσης . . . . .	83
<b>7</b>	<b>Συμπεράσματα και προεκτάσεις</b>	<b>85</b>
7.1	Συμπεράσματα . . . . .	85
7.2	Προεκτάσεις . . . . .	87
7.2.1	Βελτίωση Αρχιτεκτονικής Μοντέλου Μηχανικής Μάθησης . . . . .	87
7.2.2	Βελτίωση της Διαδικασίας Προεπεξεργασίας των Εικόνων . . . . .	87
7.3	Πρακτική Εφαρμογή . . . . .	88
<b>A'</b>	<b>Παραδείγματα Προβλέψεων</b>	<b>89</b>
A'.1	GAN με 3 συνελικτικά μπλοκ και skip connections . . . . .	90
A'.2	Απλός Αυτοκωδικοποιητής με 3 συνελικτικά μπλοκ . . . . .	91
	<b>Βιβλιογραφία</b>	<b>92</b>





# Κατάλογος Σχημάτων

2.1	Οι χαμηλότερες ημερίσιες θερμοκρασίες (σε °Κελσίου) για τη δεκαετία 1981-1990 στη Μελβούρνη . . . . .	21
2.2	Μηνιαίες πωλήσεις σαμπουάν σε διάστημα 3 ετών . . . . .	22
2.3	Κατηγορίες Μεθόδων Εξομάλυνσης. Πηγή: [6] . . . . .	26
2.4	Γραμμές Theta μιας χρονοσειράς. Πηγή: [6] . . . . .	29
3.1	Μοντέλο Νευρώνα. Χάριν απλότητας συμβολίζεται $v_k = u_k + b_k$ (τοπικό πεδίο)	36
3.2	Το υπερεπίπεδο ως όριο απόφασης σε ένα πρόβλημα ταξινόμησης προτύπων με δύο κλάσεις . . . . .	39
3.3	Αριστερά: ζεύγος μη γραμμικά διαχωρίσιμων προτύπων, δεξιά: ζεύγος γραμμικά διαχωρίσιμων προτύπων . . . . .	40
3.4	Νευρωνικό δίκτυο μοναδικού επιπέδου με τρεις νευρώνες εξόδου. . . . .	41
3.5	Νευρωνικό δίκτυο με δύο κρυφά επίπεδα και δύο νευρώνες εξόδου . . . . .	41
3.6	Σχηματικό αυτοκωδικοποιητή. Η είσοδος $x$ ανακατασκευάζεται στην έξοδο $r$ μέσω μιας εσωτερικής αναπαράστασης $h$ . Αποτελείται από δύο μέρη: τον κωδικοποιητή $f$ που μετασχηματίζει την είσοδο $x$ στον κώδικα $h$ και τον αποκωδικοποιητή $g$ που ανακατασκευάζει τον $h$ στην έξοδο $r$ . . . . .	42
3.7	Υποπλήρης αυτοκωδικοποιητής με 3 κρυμμένα επίπεδα. Το bottleneck έχει μικρότερη διάσταση από την είσοδο. Ο αποκωδικοποιητής είναι συμμετρικός ως προς τον κωδικοποιητή. . . . .	43
4.1	Δισδιάστατη συνέλιξη. Η έξοδος περιορίζεται μόνο σε τμήματα στα οποία ο πυρήνας καλύπτει πλήρως την είσοδο. Σε αυτή την περίπτωση ονομάζεται “έγκυρη” (valid). Πηγή:[14] . . . . .	51
4.2	Εφαρμογές του δικτύου Pix2Pix. Από αριστερά προς τα δεξιά φαίνονται η μετατροπή σχεδίων κτιρίων σε προσόψεις, η μετατροπή αεροφωτογραφιών σε χάρτες, η εναλλαγή ημέρας σε νύχτα. Πηγή:[20] . . . . .	56
4.3	Εικόνες υπνοδωμάτων που έχουν παραχθεί με το DCGAN. Πηγή:[5] . . . . .	57

4.4	Αριθμητική λογική μεταξύ των διανυσμάτων εισόδου με το DCGAN. Εικόνες Ανδρών με Γυαλιά - Εικόνες Ανδρών + Εικόνες Γυναικών = Εικόνες Γυναικών με Γυαλιά. Πηγή:[5] . . . . .	57
4.5	Εικόνες πουλιών από περιγραφές κειμένων. Στην εικόνα φαίνονται η παραγωγή τους περνώντας μέσα από 2 στάδια, στοίβαγμένα το ένα επάνω στο άλλο. Πηγή:[12] . . . . .	58
4.6	Στο μοντέλο εισάγεται μια στατική εικόνα και προσπαθεί να προβλέψει τα επόμενα frames. Τα βέλη δείχνουν τη θέση κινούμενων στοιχείων στο χρόνο. Αν και το μοντέλο δεν παράγει το σωστό βίντεο, ωστόσο το παραγόμενο σενάριο είναι πολλές φορές εφικτό. Πηγή:[8] . . . . .	58
4.7	Ομιλούντα πρόσωπα παραγόμενα από διάσημα πορτραίτα. Πηγή:[10] . . . . .	59
4.8	Η αρχιτεκτονική του μοντέλου. Η Eve προσπαθεί να αναχαιτίσει τα μηνύματα της Alice προς τον Bob. Παράλληλα η Alice κατασκευάζει ένα μοντέλο κρυπτογράφησης που είναι αδύνατο να κατανοήσει η Eve. Πηγή:[17] . . . . .	59
5.1	Εικόνες που προκύπτουν μετά από την προεπεξεργασία . . . . .	64
5.2	Συνελικτικό Μπλοκ . . . . .	66
5.3	Συνελικτικός Αυτοκωδικοποιητής με 2 Συνελικτικά Μπλοκ Συνάρτηση Ενεργοποίησης: ReLU . . . . .	67
5.4	Διευκρινιστής . . . . .	68
5.5	Κωδικοποιητής - αποκωδικοποιητής με 2 συνελικτικά μπλοκ και skip connections . . . . .	69
5.6	Υπό Συνθήκη Γεννητικό Ανταγωνιστικό Δίκτυο . . . . .	69
6.1	Απώλειες Δημιουργού και Διευκρινιστή και συνολική απώλεια ανά Εποχή στο Σύνολο Εκπαίδευσης . . . . .	79
6.2	Δείκτης sMAPE ανά Εποχή στο Σύνολο Επικύρωσης. Η εποχή 7 έχει το μικρότερο sMAPE στο σύνολο επικύρωσης και συνεπώς η ίδια εποχή επιλέγεται ως καλύτερη και για το σύνολο αξιολόγησης . . . . .	80
6.3	Προβλέψεις Αυτοκωδικοποιητή με 3 συνελικτικά μπλοκ. Αριστερά η είσοδος, δεξιά η πρόβλεψη. Παρατηρείται η αδυναμία εξαγωγής πρόβλεψης στις περισσότερες εικόνες. Ακόμα και για τις χρονοσειρές 485 και 2435 η πρόβλεψη είναι ελλιπής. . . . .	80
A'.1	Παραδείγματα Προβλέψεων και Ανακατασκευών Μοντέλου GAN με 3 συνελικτικά μπλοκ και skip connections . . . . .	90
A'.2	Παραδείγματα Προβλέψεων και Ανακατασκευών Μοντέλου Αυτοκωδικοποιητή με 3 συνελικτικά μπλοκ . . . . .	91

# Κατάλογος Πινάκων

6.1	Υποκατηγορίες Ετήσιων Χρονοσειρών του M4. Πηγή: [23]	77
6.2	Δείκτες Ακρίβειας Κλασικών Μεθόδων Πρόβλεψης	79
6.3	Ευρωστία μοντέλου GAN	81
6.4	Σύγκριση Μετρικών Εξεταζόμενων Μοντέλων	83
6.5	Χρόνοι Εκπαίδευσης και Πρόβλεψης Μοντέλων	84



# Κεφάλαιο 1

## Εισαγωγή

### 1.1 Αντικείμενο της Εργασίας

Η πρόβλεψη είναι μια εκτίμηση του τι μπορεί να συμβεί ή της τιμής που μπορεί να πάρει ένα μέγεθος στο μέλλον. Οι προβλέψεις επηρεάζουν άμεσα πολλές πτυχές της ανθρώπινης ζωής, από καθημερινά γεγονότα, μέχρι αποφάσεις που σχετίζονται με τον εργασιακό χώρο και τις επιχειρήσεις.

Στο χώρο των επιχειρήσεων η γνώση για το μέλλον είναι μείζονος σημασίας, καθώς καθορίζει ποιες αποφάσεις θα παρθούν με σκοπό τη μεγιστοποίηση του κέρδους ή αντίστοιχα την ελαχιστοποίηση του κόστους. Έτσι, ήδη εδώ και πολλές δεκαετίες έχουν αναπτυχθεί πολυάριθμες τεχνικές προβλέψεων. Βασιζόμενες στη στατιστική, σκοπό έχουν να δώσουν όσο γίνεται ακριβέστερες προβλέψεις και να μειώσουν όσο το δυνατό περισσότερο το σφάλμα ανάμεσα στην προβλεφθείσα και την πραγματική τιμή.

Οι τεχνικές αυτές συνήθως λαμβάνουν ως είσοδο τα ιστορικά δεδομένα μιας χρονοσειράς, για τα οποία ο επιστήμονας έχει γνώση, και στην έξοδο παράγουν μια σειρά από προβλέψεις. Τα γνωστότερα μοντέλα που χρησιμοποιούνται ακόμα και σήμερα είναι οι μέθοδοι εξομάλυνσης, η απλή ή πολλαπλή γραμμική παλινδρόμηση, το μοντέλο Theta ή μοντέλα ARIMA. Όμως, οι τεχνικές αυτές στηρίζονται στην προϋπόθεση ότι η μελλοντική συμπεριφορά μιας χρονοσειράς παραμένει αμετάβλητη. Συχνά, αυτό δε συμβαίνει καθώς πολλοί είναι οι παράγοντες που επηρεάζουν και μεταβάλλουν τα εσωτερικά μοτίβα των χρονοσειρών. Έτσι, είναι ανάγκη για εύρεση πιο περίπλοκων μοντέλων.

Καθώς η τεχνητή νοημοσύνη γίνεται όλο και δημοφιλέστερη, το ενδιαφέρον των επιστημόνων έχει στραφεί στο πώς μπορούν να αξιοποιήσουν τη μηχανική μάθηση και τους έξυπνους αλγόριθμους για την ανάπτυξη μη γραμμικών μεθόδων πρόβλεψης, που θα αντιμετωπίσουν τα προβλήματα των κλασικών μεθόδων. Ήδη έχουν εφαρμοστεί ποικίλες τεχνικές μηχανικής μάθησης για πρόβλεψη χρονοσειρών, όπως για παράδειγμα απλά, αναδρομικά ή και άλλα νευρωνικά δίκτυα πολλών επιπέδων, δέντρα αποφάσεων, διάφοροι αλγόριθμοι όπως αυτός των  $k$  κοντινότερων γειτόνων, support vector regression και άλλα. Παρά την πολυπλοκότητά τους, όμως, έχει αποδειχτεί ότι σε πολλές περιπτώσεις υστερούν απέναντι στα κλασικά στατιστικά

μοντέλα, πράγμα που παρακινεί για περαιτέρω βελτίωσή τους[22].

Τα τελευταία χρόνια το ενδιαφέρον της επιστημονικής κοινότητας που απασχολείται με τη μηχανική μάθηση έχει στραφεί γύρω από το χώρο της εικόνας, όπου έχουν εφαρμοστεί ποικίλες τεχνικές για την κατηγοριοποίηση, επεξεργασία, ανάλυση ή παραγωγή εικόνων. Συνεπώς είναι επόμενο να αναρωτηθεί κανείς αν μπορεί να αξιοποιήσει τις τεχνικές αυτές και σε άλλους κλάδους, όπως αυτός των προβλέψεων. Ήδη έχουν πραγματοποιηθεί μελέτες γύρω από αυτό τον κλάδο. Αξιοσημείωτες είναι οι παρακάτω:

- Οι Xixi Li και συνεργάτες στο άρθρο *Forecasting with time series imaging*[24] αξιοποιούν την όραση υπολογιστών για να εξάγουν χρήσιμα χαρακτηριστικά από γραφικές αναπαραστάσεις χρονοσειρών τα οποία στη συνέχεια χρησιμοποιούν στη διαδικασία της πρόβλεψης.
- Τα άρθρα *Image Processing Tools for Financial Time Series Classification*[7] και *Classification of Time-Series Images Using Deep Convolutional Neural Networks*[19] χρησιμοποιούν συνελκτικά νευρωνικά δίκτυα σε συνδυασμό με άλλες τεχνικές εικόνων για ταξινόμηση χρονοσειρών σε κατηγορίες.
- Οι Naftali Cohen et al. στο *Visual Forecasting of Time Series with Image-to-Image Regression*[18] μεταφέρουν το πρόβλημα των προβλέψεων αποκλειστικά στο χώρο των εικόνων και χρησιμοποιώντας συνελκτικούς αυτοκωδικοποιητές εξάγουν προβλέψεις από γραφικές παραστάσεις χρονοσειρών.
- Οι Guoqiang Zhang και Jifeng Guo προτείνουν στο άρθρο *A novel ensemble method for hourly residential electricity consumption forecasting by imaging time series*[11] μια περίπλοκη μέθοδο που περιλαμβάνει γεννητικά ανταγωνιστικά δίκτυα για την πρόβλεψη της ηλεκτρικής κατανάλωσης μέσα από εικόνες χρονοσειρών.

Σκοπός της παρούσας διπλωματικής εργασίας αποτελεί η πρόβλεψη χρονοσειρών μέσω της γραφικής τους παράστασης, με τη βοήθεια μοντέλων μηχανικής μάθησης. Στα πλαίσια της προτείνεται μια πλήρης μεθοδολογία που αφορά την προεπεξεργασία των χρονοσειρών, την ανάπτυξη των κατάλληλων μοντέλων μηχανικής μάθησης και την εξαγωγή ποσοτικών αποτελεσμάτων. Πιο συγκεκριμένα, αναπτύσσεται ένας αλγόριθμος που μετατρέπει τις χρονοσειρές σε εικόνες των γραφικών τους αναπαραστάσεων, κατάλληλες ώστε να εισαχθούν σε ένα νευρωνικό μοντέλο. Στη συνέχεια κατασκευάζεται ένα νευρωνικό μοντέλο κατάλληλο για παραγωγή νέων εικόνων που περιέχουν την επιθυμητή πρόβλεψη. Το προτεινόμενο μοντέλο αποτελεί ένα υπό συνθήκη γεννητικό ανταγωνιστικό δίκτυο (conditional generative adversarial network - cGAN), μια τεχνολογία που επιτρέπει την παραγωγή νέων δεδομένων από εικόνες. Για την ποσοτική αξιολόγηση των προβλέψεων αναπτύσσεται αλγόριθμος που εξάγει τις πραγματικές τιμές των προβλέψεων από τις εικόνες των γραφικών τους παραστάσεων.

Η προτεινόμενη μέθοδος πλεονεκτεί έναντι των κλασικών μεθόδων σε περιπτώσεις όπου δεν υπάρχει αρκετή πληροφορία σχετικά με τις ακριβείς τιμές των παρατηρήσεων μιας χρονοσειράς, αλλά είναι γνωστή μόνο η μορφή της. Εξάλλου, σε αρκετές περιπτώσεις ενδιαφέρον

παρουσιάζει η γνώση της μορφής που επίκειται να πάρει μια χρονοσειρά και όχι η ακριβής τιμή. Εξάλλου, οι επαγγελματίες του χώρου των προβλέψεων βασίζονται σε γραφικές παραστάσεις για να δικαιολογήσουν τις επιλογές τους και όχι στις τιμές καθαυτές. Τέλος, αξίζει να μελετηθεί αν η γραφική αναπαράσταση μιας χρονοσειράς προσφέρει χρήσιμες πληροφορίες (σε ένα νευρωνικό δίκτυο αλλά και γενικότερα) για την μελλοντική της συμπεριφορά.

## 1.2 Οργάνωση της Εργασίας

Στο 2ο Κεφάλαιο της παρούσας εργασίας γίνεται μια εισαγωγή στην επιστήμη των προβλέψεων. Αρχικά δίνεται ο ορισμός της χρονοσειράς και αναλύονται τα χαρακτηριστικά της. Ορίζεται ακόμα η γραφική αναπαράσταση της χρονοσειράς και αποκαλύπτεται η χρησιμότητά της. Στη συνέχεια παρουσιάζονται οι προβλέψεις, η σημαντικότητά τους και τα βήματα που ακολουθούνται για την εξαγωγή τους. Οι σημαντικότερες στατιστικές μέθοδοι προβλέψεων που χρησιμοποιούνται στην παρούσα διπλωματική εργασία αναφέρονται συνοπτικά. Το κεφάλαιο τελειώνει με τους βασικούς δείκτες ακρίβειας που χρησιμοποιούνται από την επιστημονική κοινότητα για την αξιολόγηση των προβλέψεων.

Το 3ο Κεφάλαιο αποτελεί εισαγωγή στα μηχανική μάθηση. Ορίζονται τα νευρωνικά δίκτυα και οι σπουδαιότερες ιδιότητές τους. Αναλύονται τα μοντέλα νευρώνων και οι επικρατέστερες συναρτήσεις ενεργοποίησης που χρησιμοποιούνται ευρέως σήμερα. Ακολουθεί η οργάνωση των νευρώνων σε νευρωνικά δίκτυα πρόσθιας τροφοδότησης. Τέλος, παρουσιάζονται οι διαδικασίες μάθησης των δικτύων αυτών και ο αλγόριθμος backpropagation με τη βοήθεια του οποίου πραγματοποιείται η μάθηση.

Στο 4ο Κεφάλαιο παρουσιάζονται τα συνελκτικά δίκτυα, που χρησιμοποιούνται ευρέως για τη δημιουργία, επεξεργασία και ταξινόμηση εικόνων. Ακολουθεί η παρουσίαση των γεννητικών δικτύων και δίνεται έμφαση στα γεννητικά ανταγωνιστικά δίκτυα, που είναι το μοντέλο που χρησιμοποιείται στην παρούσα διπλωματική εργασία. Το κεφάλαιο κλείνει με κάποιες δημοφιλείς εφαρμογές των γεννητικών ανταγωνιστικών δικτύων.

Το 5ο Κεφάλαιο είναι αφιερωμένο στην αναλυτική παρουσίαση της μεθοδολογίας που ακολουθήθηκε για την εκπόνηση της διπλωματικής εργασίας. Περιγράφεται το γενικότερο πλαίσιο της μεθόδου και αναλύεται ο αλγόριθμος παραγωγής εικόνων από χρονοσειρές για εισαγωγή στα μοντέλα πρόβλεψης. Παρουσιάζεται εκτενώς η αρχιτεκτονική των μοντέλων και δικαιολογούνται οι επιλογές που έγιναν, σύμφωνα με τη βιβλιογραφία. Γίνεται αναφορά στα εργαλεία που χρησιμοποιήθηκαν για την κατασκευή τους. Ακολουθεί η διαδικασία εκπαίδευσης, η εξαγωγή των προβλέψεων και η περιγραφή του αλγόριθμου μετατροπής τους από εικόνες ξανά σε χρονοσειρές. Στο τέλος δίνονται ποιοτικά παραδείγματα της παραπάνω διαδικασίας όπου φαίνεται η προεπεξεργασία των εικόνων από χρονοσειρές και η αντίστροφη μετατροπή των εικόνων σε τιμές στο χρόνο.

Στο 6ο Κεφάλαιο παρουσιάζονται τα ποσοτικά αποτελέσματα της παραπάνω διαδικασίας. Περιγράφεται το σύνολο δεδομένων (dataset) που χρησιμοποιήθηκε για την διεξαγωγή των πειραμάτων και υπολογίζονται οι δείκτες ακρίβειας κάποιων κλασικών μεθόδων προβλέψεων,

που χρησιμοποιούνται ως σημεία αναφοράς. Προτείνεται τρόπος επικύρωσης των αποτελεσμάτων ως λύση στο πρόβλημα μη-σύγκλισης των γεννητικών ανταγωνιστικών δικτύων. Στη συνέχεια υπολογίζονται οι δείκτες ακρίβειας των υπό μελέτη μοντέλων και συγκρίνονται μεταξύ τους και με τα σημεία αναφοράς, με στόχο την εύρεση της καλύτερης αρχιτεκτονικής, ενώ παρουσιάζονται οι χρόνοι εκπαίδευσης των νευρωνικών μοντέλων.

Στο 7ο Κεφάλαιο παρουσιάζονται συνοπτικά τα αποτελέσματα, εξάγονται τα συμπεράσματα και διερευνώνται τρόποι επέκτασης της διεξαχθείσας μελέτης.



## Κεφάλαιο 2

# Τεχνικές Προβλέψεων και Δείκτες Ακριβείας

### 2.1 Χρονοσειρές και Χαρακτηριστικά

Η χρονοσειρά ή χρονολογική σειρά ορίζεται ως ένα σύνολο διαδοχικών χρονολογικών παρατηρήσεων της τιμής ενός φυσικού ή άλλου μεγέθους. Σημαντικό χαρακτηριστικό των χρονοσειρών είναι ότι οι παρατηρήσεις δεν είναι ανεξάρτητες μεταξύ τους, αλλά οι μελλοντικές τιμές μπορούν να προσδιοριστούν με ακριβή τρόπο από τα ιστορικά δεδομένα. Η διαδικασία αυτή ονομάζεται ντετερμινιστική.

Ωστόσο, αυτό δεν είναι απολύτως σωστό καθώς στις πραγματικές χρονοσειρές οι μελλοντικές παρατηρήσεις εξαρτώνται μερικώς από το παρελθόν ενώ σε αυτές επενεργούν και άλλοι παράγοντες, όπως για παράδειγμα εξωτερικοί παράγοντες όπως ειδικά γεγονότα ή ακόμα και τυχαιότητα. Έτσι μελλοντικές τιμές των χρονοσειρών δε μπορούν να προσδιοριστούν πλήρως και έτσι θεωρείται ότι ακολουθούν μια στοχαστική διαδικασία, αφού ο τυχαίος παράγοντας επηρεάζει την εξέλιξή τους.

#### 2.1.1 Ποιοτικά χαρακτηριστικά των χρονοσειρών

Οι κλασικές στατιστικές μέθοδοι ανάλυσης των χρονοσειρών ασχολούνται κατά κύριο λόγο με την αποσύνθεση της χρονοσειράς. Η αποσύνθεση είναι μια μέθοδος κατά την οποία μια χρονοσειρά διαχωρίζεται σε τέσσερις επιμέρους χρονοσειρές, που φανερώνουν την τάση, την εποχιακότητα, την κυκλικότητα και τυχόν μη κανονικές διακυμάνσεις. Η ανάλυση αυτή είναι πολύ χρήσιμη όχι μόνο για την εφαρμογή της κλασικής μεθόδου αποσύνθεσης ως μέθοδο εξαγωγής προβλέψεων, αλλά και για τη μελέτη των ποιοτικών χαρακτηριστικών μιας χρονοσειράς.

Αναλυτικά, τα ποιοτικά χαρακτηριστικά είναι τα ακόλουθα:

- Η **τάση** φανερώνει μια μακροπρόθεσμη μεταβολή του μέσου επιπέδου των παρατηρήσεων της χρονοσειράς. Ωστόσο, το πρόβλημα με αυτόν τον ορισμό έγκειται στο τι θεωρεί

κάνεις ως μακροπρόθεσμη μεταβολή. Για παράδειγμα, χρονοσειρές που σχετίζονται με περιβαλλοντικές μεταβολές παρουσιάζουν μια κυκλική διακύμανση σε χρονικό διάστημα περίπου 50 ετών. Έτσι, αν κάποιος είχε στοιχεία μόνο για μια εικοσαετία θα μπορούσε εσφαλμένα να θεωρήσει τη μεταβολή του μέσου επιπέδου των τιμών ως τάση. Σε άλλες χρονοσειρές, όπως για παράδειγμα η ζήτηση προϊόντων λιανικής πώλησης, είναι αρκετή η πληροφορία μερικών ετών για να καθοριστεί η τάση. Κατά συνέπεια, χρειάζεται προσοχή στον καθορισμό του κατάλληλο μήκους περιόδων, που είναι διαφορετικό ανάλογα με την κάθε περίπτωση, στο οποίο μπορεί κανείς να αναζητήσει τάση.

- Η **κυκλικότητα** ορίζεται ως μια κυματοειδής μεταβολή που οφείλεται σε εξωτερικούς παράγοντες και εμφανίζεται κατά περιόδους. Οι περίοδοι αυτές συνήθως δεν είναι σταθερές ενώ συνήθως το μήκος τους είναι μεγαλύτερο του έτους. Από κυκλικότητα χαρακτηρίζονται συνήθως οι χρονοσειρές των περισσότερων κυκλικών μεγεθών όπως αυτές του Ακαθάριστου Εθνικού Προϊόντος ή των τιμών μετοχών. Οι μεταβολές αυτές οφείλονται στις εξωγενείς οικονομικές συνθήκες, οι οποίες παρουσιάζουν ανόδους και υφέσεις. Στον κλάδο της οικονομίας ονομάζονται επιχειρηματικός κύκλος.
- Η **εποχιακότητα** χαρακτηρίζεται ως περιοδική διακύμανση σε σταθερό μήκος μικρότερο του έτους. Η διακύμανση αυτή είναι συνήθως κατανοητή και προβλέψιμη, αφού επαναλαμβάνεται με ίδιο ή παρόμοιο τρόπο μέσα στο έτος. Έτσι, τέτοιες μεταβολές είναι εύκολα μετρήσιμες και μπορούν να απομονωθούν και να αφαιρεθούν από την αρχική χρονοσειρά ώστε να προκύψουν τα αποεποχικοποιημένα δεδομένα. Παράδειγμα χρονοσειρών με εποχιακότητα είναι οι πωλήσεις παγωτών, που εμφανίζουν μεγάλη αύξηση κατά τους καλοκαιρινούς μήνες.
- **Ασυνέχειες** ονομάζονται οι παρατηρήσεις που εμφανίζονται στη γραφική παράσταση μιας χρονοσειράς και αποτελούν απότομες αλλαγές στο μοτίβο ή τη συμπεριφορά της, ενώ είναι εξαιρετικά δύσκολο ή ακόμα και αδύνατο να προβλεφθούν. Όταν οι μεταβολές αυτές έχουν παροδικό χαρακτήρα ονομάζονται outliers ή special events και δεν επιδρούν στη χρονοσειρά με καθοριστικό τρόπο. Ένα τέτοιο παράδειγμα είναι μια απεργία που μπορεί να προκαλέσει μείωση στην παραγωγή μιας βιομηχανίας. Αντίθετα, αν οι αλλαγές είναι μόνιμες ονομάζονται level-shifts αφού έχουν ως αποτέλεσμα τη μόνιμη αλλαγή του μέσου επιπέδου μιας χρονοσειράς. Τέτοιου είδους ασυνέχειες συμβαίνουν όταν, για παράδειγμα, εισέρχεται ένας νέος ανταγωνιστής στην αγορά με αποτέλεσμα τη μόνιμη μείωση της ζήτησης του προϊόντος της ήδη υπάρχουσας επιχείρησης. Επειδή τα γεγονότα που επιφέρουν τέτοιες αλλαγές δεν σχετίζονται άμεσα με τις υπό μελέτη χρονοσειρές, αλλά εμφανίζονται λόγω εξωτερικών παραγόντων, χρειάζεται κανείς εξειδικευμένη γνώση, κριτική σκέψη αλλά και κοινή λογική για να τα κατανοήσει και να τα ερμηνεύσει.
- Οι **μη κανονικές διακυμάνσεις** μπορούν να προσδιοριστούν όταν τα υπόλοιπα χαρακτηριστικά (τάση, κυκλικότητα, εποχιακότητα) έχουν απομονωθεί. Οι διακυμάνσεις

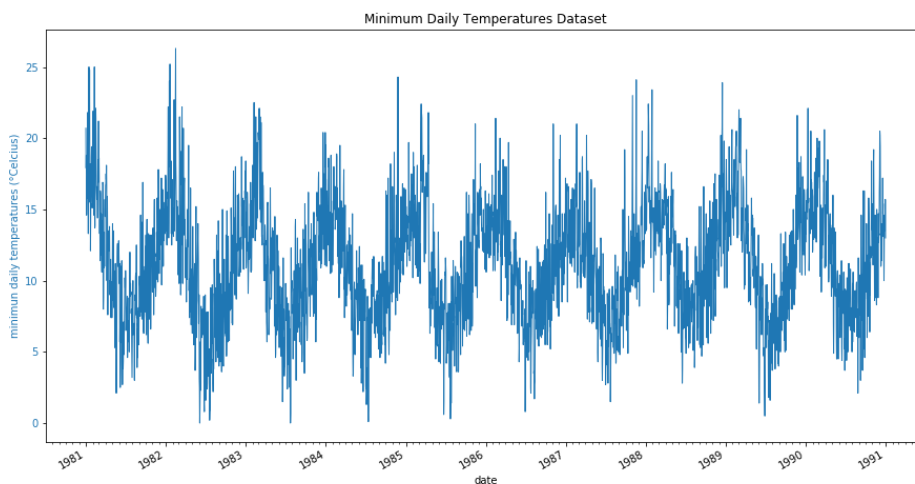
αυτές μπορεί να αντιπροσωπεύουν τυχαίο θόρυβο στις χρονοσειρές ή κάποια ασυνέχεια, όπως αυτές που ορίστηκαν παραπάνω.

### 2.1.2 Γραφική αναπαράσταση χρονοσειράς


Όπως έχει αναφερθεί, η χρονοσειρά είναι μια διαδοχική σειρά παρατηρήσεων ως προς το χρόνο. Έτσι, μπορεί κανείς να απεικονίζει τη γραφική παράσταση μιας χρονοσειράς με οριζόντιο άξονα τον χρόνο. Η γραφική αναπαράσταση έγκειται στην διδιάστατη απεικόνιση των πραγματικών τιμών των δεδομένων ως προς το χρόνο.

Η γραφική παράσταση αποτελεί σπουδαίο εργαλείο για την ανάλυση της χρονοσειράς και εξαγωγή των ποιοτικών χαρακτηριστικών της αλλά και κατά τη διαδικασία της πρόβλεψης. Από την αναπαράσταση των δεδομένων μπορεί κανείς να διακρίνει χαρακτηριστικά όπως τάση, εποχιακότητα, κύκλο, ακόμα και ασυνέχειες και τυχαιότητα. Επιπλέον, η γραφική αναπαράσταση μπορεί να εμφανίσει λανθασμένες τιμές ή ακραίες παρατηρήσεις (outliers). Τέλος, η παρατήρηση της μορφής των δεδομένων μπορεί να βοηθήσει τον ερευνητή να επιλέξει την κατάλληλη μέθοδο πρόβλεψης, η οποία θα φέρει τα βέλτιστα αποτελέσματα και το μικρότερο σφάλμα στις προβλέψεις.

Παρακάτω παρουσιάζονται δύο παραδείγματα γραφικών αναπαραστάσεων χρονοσειρών από δύο πολύ διαδεδομένα σύνολα δεδομένων. Η εικόνα 2.1 παρουσιάζει τις ημερήσιες χαμηλότερες θερμοκρασίες (σε °Κελσίου) στη Μελβούρνη για τη δεκαετία 1981-1990. Εύκολα παρατηρείται ο εποχιακός χαρακτήρας της χρονοσειράς καθώς και το σχετικά σταθερό μέσο επίπεδο. Στην εικόνα 2.2 απεικονίζονται οι μηνιαίες πωλήσεις σε σαμπουάν για 3 έτη (36 μήνες). Η ανοδική τάση της χρονοσειράς διακρίνεται εύκολα, παρά την τυχαιότητα που έχει.



Σχήμα 2.1: Οι χαμηλότερες ημερήσιες θερμοκρασίες (σε °Κελσίου) για τη δεκαετία 1981-1990 στη Μελβούρνη



Σχήμα 2.2: Μηνιαίες πωλήσεις σαμπουάν σε διάστημα 3 ετών

## 2.2 Γενικά για τις Προβλέψεις

Οι προβλέψεις αποτελούν αναπόσπαστο κομμάτι των επιχειρήσεων αλλά ακόμα και της καθημερινότητας. Μικρές και μεγάλες επιχειρήσεις χρησιμοποιούν τις προβλέψεις για να πάρουν σημαντικές στρατηγικές αποφάσεις, εξαλείφοντας όσο το δυνατό περισσότερο την αβεβαιότητα για το μέλλον. Οι προβλέψεις αυτές αφορούν μεγέθη όπως το ύψος της παραγωγής προϊόντων και υπηρεσιών ή επενδυτικές αποφάσεις και έχουν άμεσο αντίκτυπο στις μελλοντικές καταστάσεις και στο κέρδος μιας επιχείρησης.

Για τους παραπάνω λόγους η επιστήμη των προβλέψεων έχει λάβει μεγάλο ενδιαφέρον από την επιστημονική κοινότητα και όχι μόνο, ενώ οι τελευταίες δεκαετίες έχουν αποτελέσει σημαντικές στην ανάπτυξη πολύ αποδοτικών τεχνικών προβλέψεων. Οι τεχνικές αυτές βασίζονται στα πρότυπα συμπεριφοράς των χρονοσειρών και στηρίζονται στην παραδοχή ότι αυτά παραμένουν σταθερά με το πέρασμα του χρόνου. Η παραδοχή αυτή αδυνατεί να κάνει πρόβλεψη τυχαίων ή ειδικών γεγονότων, όμως έχει αποδειχτεί ότι οι επικρατούσες τεχνικές προβλέψεων φέρουν πολύ καλά αποτελέσματα.

### 2.2.1 Μοντέλα Πρόβλεψης

Η έννοια του μοντέλου έχει να κάνει με την αναπαράσταση μιας διαδικασίας με έναν αφαιρετικό τρόπο. Ένα μοντέλο πρόβλεψης αναπαριστά μια διαδικασία με την οποία παράγονται προβλέψεις. Τα μοντέλα ποσοτικών μεθόδων διακρίνονται σε δύο κατηγορίες, το μοντέλο χρονοσειρών (timeseries model) και το αιτιοκρατικό μοντέλο (casual relationship ή explanatory model).

### Το Μοντέλο Χρονοσειρών

Είναι το δημοφιλέστερο μοντέλο ποσοτικών προβλέψεων. Στηρίζεται στα ιστορικά δεδομένα των χρονοσειρών και κάνει την υπόθεση ότι το πρότυπο συμπεριφοράς τους παραμένει σταθερό. Έτσι, η πρόβλεψη παράγεται από την επέκταση αυτού του προτύπου. Η είσοδος  $X$  ενός τέτοιου συστήματος είναι τα ιστορικά δεδομένα του παρελθόντος μιας χρονοσειράς. Η έξοδος  $Y$  (δηλαδή η πρόβλεψη) είναι μια γραμμική συνάρτηση της εισόδου:

$$Y = f(X_1, X_2, \dots, X_n)$$

όπου  $X_1, X_2, X_n$  τα ιστορικά δεδομένα για τις αντίστοιχες χρονικές περιόδους. Στο μοντέλο χρονοσειρών συγκαταλέγονται η αποσύνθεση (decomposition), η εξομάλυνση (smoothing) και οι αυτοπαλινδρομικές μέθοδοι κινητού μέσου όρου (autoregressive moving average).

Το μοντέλο χρονοσειρών φέρει εξαιρετικά αποτελέσματα όταν η υπό εξέταση χρονοσειρά διατηρεί το μοτίβο συμπεριφοράς της αλλά αδυνατεί να συσχετίσει τις προβλέψεις με εξωτερικές ενέργειες, όπως για παράδειγμα την αλλαγή στη διαφημιστική πολιτική μιας εταιρίας. Παρόλα αυτά, οι προαναφερθείσες μέθοδοι επιλέγονται συχνά, όταν ενδιαφέρεται κανείς να συμπεράνει το τι θα συμβεί και όχι το γιατί. Εξάλλου, η συσχέτιση τέτοιων εξωγενών παραγόντων αλλά και ο ακριβής τρόπος αλληλεπίδρασης με την πρόβλεψη είναι μια δύσκολη διαδικασία.

### Το Αιτιοκρατικό Μοντέλο

Το αιτιοκρατικό μοντέλο βασίζεται στην υπόθεση ότι υπάρχει σχέση μεταξύ του υπό πρόβλεψη μεγέθους  $y$  και ορισμένων παραμέτρων  $X_1, X_2, \dots, X_n$ . Το μοντέλο αυτό είναι ένα σύστημα με εισόδους τις παραμέτρους  $X_i, i = 1, 2, \dots, n$  (ανεξάρτητες μεταβλητές) και έξοδο το προβλεπόμενο μέγεθος  $y$  (εξαρτημένη μεταβλητή). Μεταξύ των δύο υπάρχει μια σχέση της μορφής:

$$y = f(X_1, X_2, \dots, X_n)$$

. Ένα παράδειγμα ενός τέτοιου μοντέλου είναι αν θεωρήσει κανείς ως εξαρτημένη μεταβλητή το ύψος των πωλήσεων ενός προϊόντος ενώ οι ανεξάρτητες παράμετροι είναι η τιμή πώλησής του καθώς και το κόστος των διαφημίσεων.

Η διαφορά μεταξύ των δύο προηγούμενων μοντέλων βασίζεται στο γεγονός ότι, ενώ για το μοντέλο χρονοσειρών η συνάρτηση που περιγράφει το σύστημα προκαθορίζεται με βάση το πρότυπο συμπεριφοράς της ίδιας της χρονοσειράς, στο αιτιοκρατικό μοντέλο η συνάρτηση αυτή δεν είναι προκαθορισμένη. Αρχικά, ορίζονται οι μεταβλητές που επηρεάζουν το υπό εξέταση μέγεθος και έπειτα προσδιορίζεται το είδος και η ακριβής μορφή αυτής της εξάρτησης. Η προκύπτουσα σχέση χρησιμοποιείται μαζί με τις προκαθορισμένες τιμές των ανεξάρτητων μεταβλητών και εξάγεται η ζητούμενη πρόβλεψη.

Είναι προφανές ότι το αιτιοκρατικό μοντέλο απαιτεί περισσότερα δεδομένα, καθώς εκτός από τα ιστορικά δεδομένα της υπό εξέταση μεταβλητής απαιτούνται πληροφορίες που σχετίζονται με τα ανεξάρτητα μεγέθη. Ακόμα, τα μοντέλα αυτά είναι αρκετά ευαίσθητα σε αλλαγές του περιβάλλοντος του συστήματος και πολλές φορές έχουν μεγάλο υπολογιστικό κόστος.

Παρόλα αυτά είναι χρήσιμα καθώς επιτρέπουν στον χρήστη να προβλέπει τη μελλοντική τιμή ενός μεγέθους για διάφορους συνδυασμούς των ανεξάρτητων μεταβλητών. Αν υποθέσει κάποιος ότι οι ανεξάρτητες αυτές μεταβλητές αντικατοπτρίζουν τις αποφάσεις που καλείται να πάρει η επιχείρηση, το αιτιοκρατικό μοντέλο χρησιμεύει στην εξέταση όλων των εναλλακτικών σεναρίων και την επιλογή του βέλτιστου συνδυασμού αποφάσεων.

### 2.2.2 Βασικά βήματα της διαδικασίας της πρόβλεψης

Για την παραγωγή και αξιολόγηση των προβλέψεων ακολουθούνται τα παρακάτω 5 βήματα, σύμφωνα με τους Μακρυδάκη, Wheelright και Hyndman (1998):

1. **Καθορισμός του προβλήματος.** Συνήθως αποτελεί το σημαντικότερο και πιο δύσκολο μέρος της διαδικασίας, καθώς είναι απαραίτητος ο σαφής προσδιορισμός του τι καλείται να προβλέψει κανείς καθώς και ποιος θα χρησιμοποιήσει τις παραχθείσες προβλέψεις και για ποιο σκοπό.
2. **Συλλογή των δεδομένων.** Η διαδικασία αυτή μπορεί να αποβεί αρκετά χρονοβόρα καθώς είναι μείζονος σημασίας η συλλογή των σωστών ιστορικών δεδομένων αλλά και η ενημέρωση και επικύρωσή τους. Μεγάλης χρησιμότητας αποδεικνύονται και δεδομένα που σχετίζονται με την πείρα και εξειδικευμένη γνώση των εργαζομένων σε μια επιχείρηση για την ίδια χρονική περίοδο.
3. **Προεπεξεργασία και ανάλυση των ιστορικών δεδομένων.** Σε αυτό το βήμα εξετάζονται τα ποιοτικά χαρακτηριστικά των χρονοσειρών έτσι ώστε να διεξαχθούν τυχόντα μοτίβα τάσης και εποχιακότητας αλλά και ασυνέχειες ή άλλες ασυνήθιστες τιμές. Τα δεδομένα προσαρμόζονται ανάλογα με το πρόβλημα, διορθώνονται κενές ή λανθασμένες τιμές ή διαχωρίζονται οι χρονοσειρές στις επιμέρους συνιστώσες τους. Μελετώνται οι μη κανονικές διακυμάνσεις και εντοπίζονται outliers και τα ειδικά γεγονότα που ευθύνονται για αυτά. Έτσι, οι χρονοσειρές εξομαλύνονται και μετατρέπονται σε μορφή κατάλληλη για εισαγωγή στα μοντέλα προβλέψεων.
4. **Επιλογή μεθόδου πρόβλεψης.** Στο στάδιο αυτό ορίζεται ο ορίζοντας πρόβλεψης και επιλέγεται κατάλληλο στατιστικό μοντέλο πρόβλεψης. Καθορίζονται ακόμα οι βέλτιστες παράμετροι του μοντέλου που προκύπτουν από τα ιστορικά δεδομένα αλλά και από τις ιδιότητές του. Η τελική πρόβλεψη προκύπτει από την προέκταση των παρατηρήσεων από το στατιστικό μοντέλο, με βάση κριτική πρόβλεψη ή με συνδυασμό των μοντέλων.
5. Τέλος, κρίνεται σκόπιμη η **αξιολόγηση της μεθόδου** που εφαρμόστηκε. Στο βήμα αυτό αρχικά εξάγεται ο προκαθορισμένος αριθμός προβλέψεων και έπειτα η ακρίβειά τους αξιολογείται με βάση στατιστικούς δείκτες ακρίβειας. Αυτό δε γίνεται στιγμιαία, αλλά μέσα στο χρόνο, όταν οι πραγματικές τιμές των προβλεφθέντων παρατηρήσεων γίνουν διαθέσιμες. Έτσι, με την πάροδο του χρόνου κρίνεται αν το επιλεγμένο μοντέλο είναι αποδοτικό ενώ διορθώνονται λάθη με σκοπό την ακριβέστερη πρόβλεψη και την εξάλειψη της προκατάληψης της εκάστοτε μεθόδου πρόβλεψης.

## 2.3 Στατιστικές Μέθοδοι Προβλέψεων

Οι στατιστικές μέθοδοι προβλέψεων αναφέρονται στην εφαρμογή αιτιοκρατικών μοντέλων ή μοντέλων χρονοσειρών πάνω σε μια σειρά από δεδομένα με σκοπό την αυτοματοποιημένη εξαγωγή προβλέψεων. Οι στατιστικές προβλέψεις προϋποθέτουν ότι η συμπεριφορά μιας χρονοσειράς θα είναι ίδια στο μέλλον και είναι σχετικά ακριβείς, αν και δε λαμβάνουν υπόψη ειδικά γεγονότα ή άλλες ενέργειες. Είναι εύκολες στη χρήση και εφαρμόζονται εύκολα με τη βοήθεια ειδικών πληροφορικών συστημάτων, χωρίς να απαιτούν εξειδικευμένη γνώση. Στην παρούσα διπλωματική εργασία αναφέρονται διάφορες στατιστικές μέθοδοι προβλέψεων, οι οποίες αναλύονται παρακάτω.

### 2.3.1 Αφελής Μέθοδος (Naive)

Η Naive αποτελεί την πιο απλή μέθοδο πρόβλεψης. Η πρόβλεψη μιας χρονικής στιγμής ( $t$ ) προκύπτει από την παρατήρηση της αμέσως προηγούμενης περιόδου ( $t-1$ ).

$$F(t) = Y(t - 1)$$

όπου

- $t$  η χρονική περίοδος
- $F(t)$  η πρόβλεψη κατά τη χρονική περίοδο  $t$ .
- $Y(t - 1)$  η παρατήρηση της χρονοσειράς κατά την περίοδο  $t - 1$

Το μεγάλο πλεονέκτημα της αφελούς μεθόδου είναι το χαμηλό υπολογιστικό κόστος. Ωστόσο, λόγω της απλότητάς της δεν παράγει ακριβείς προβλέψεις και για αυτό χρησιμοποιείται για την πρόβλεψη λίγων περιόδων στο μέλλον (συνήθως μιας περιόδου). Η απλότητά της την καθιστά ιδανική για να χρησιμοποιηθεί ως σημείο αναφοράς (benchmark) για τη σύγκριση της ακρίβειας άλλων μεθόδων. Κατ' αυτόν τον τρόπο χρησιμοποιείται και στην παρούσα διπλωματική εργασία.

### 2.3.2 Μέθοδοι Εκθετικής Εξομάλυνσης


Οι μέθοδοι εκθετικής εξομάλυνσης αναπτύχθηκαν κατά τις αρχές της δεκαετίας του 1950 και έκτοτε είναι πολύ δημοφιλείς, κυρίως λόγω της ευκολίας στη χρήση, του χαμηλού υπολογιστικού κόστους και του γεγονότος ότι απαιτούν λίγα δεδομένα για την παραγωγή ακριβών προβλέψεων. Τα δεδομένα εξομαλύνονται με σκοπό την αφαίρεση του θορύβου. Στηρίζονται κυρίως στην προέκταση του μοτίβου των ιστορικών δεδομένων, όπως του κύκλου ή της τάσης, ενώ δίνεται μεγαλύτερο βάρος στα πιο πρόσφατα γεγονότα καθώς κρίνεται ότι αυτά εμπεριέχουν την πιο σημαντική πληροφορία. Οι μέθοδοι αυτές είναι κατάλληλες κυρίως για την εξαγωγή βραχυπρόθεσμων και μεσοπρόθεσμων προβλέψεων, ενώ είναι περισσότερο αποδοτικές σε χρονοσειρές που παρουσιάζουν στασιμότητα ή μικρό ρυθμό ανάπτυξης. Αποτελέσματα

μελετών έχουν δείξει ότι οι μέθοδοι αυτές φέρουν αρκετά καλά ποσοστά ακρίβειας ακόμα και σε σχέση με πιο πολύπλοκες μεθόδους πρόβλεψης.

Οι μέθοδοι εξομάλυνσης χωρίζονται σε κατηγορίες ανάλογα με τη γραφική παράσταση των ιστορικών δεδομένων ως προς το χρόνο.

- Το μοντέλο σταθερού επιπέδου (constant level) που προϋποθέτει την απουσία τάσης και σχετικά σταθερού μέσου όρου μιας χρονοσειράς. Η πρόβλεψη αποτελεί επέκταση μιας ευθείας γραμμής και συνήθως χρησιμοποιείται για την πρόβλεψη ενός βήματος (one-step-ahead forecasting).
- Το μοντέλο γραμμικής τάσης (linear trend) σύμφωνα με το οποίο οι προβλέψεις προκύπτουν από την προέκταση μιας ευθείας γραμμής και χρησιμοποιείται για οποιονδήποτε ορίζοντα πρόβλεψης.
- Το μοντέλο εκθετικής τάσης κάνει την παραδοχή ότι το ποσοστό αύξησης των πωλήσεων μεγαλώνει διαρκώς και για αυτό εφαρμόζεται με επιτυχία όταν ένα προϊόν βρίσκεται στα αρχικά στάδια του κύκλου ζωής του. Έχει αποδειχτεί ότι το μοντέλο αυτό όπως και το προηγούμενο είναι υπεραισιόδοξα για μακροχρόνιες προβλέψεις.
- Το μοντέλο φθίνουσας τάσης, σύμφωνα με το οποίο το ποσοστό αύξησης των πωλήσεων μειώνεται σταδιακά. Αυτό το μοντέλο προτιμάται για προβλέψεις με μεγαλύτερο ορίζοντα πρόβλεψης.

Φυσικά, όλα τα παραπάνω μοντέλα μπορούν να εφαρμοστούν σε εποχιακές χρονοσειρές, προσθετικά ή πολλαπλασιαστικά όπως φαίνεται στην εικόνα 2.3.



Σχήμα 2.3: Κατηγορίες Μεθόδων Εξομάλυνσης. Πηγή: [6]



### Απλή Εκθετική Εξομάλυνση - Μοντέλο Σταθερού Επιπέδου (Simple Exponential Smoothing)

Μια από τις γνωστότερες μεθόδους εξομάλυνσης που χρησιμοποιείται ως σημείο αναφοράς στην παρούσα διπλωματική εργασία αποτελεί η Απλή Εκθετική Εξομάλυνση. Το μοντέλο σταθερού επιπέδου περιγράφεται από τις εξισώσεις:

$$\begin{aligned}e(t) &= Y(t) - F(t) \\S(t) &= S(t-1) + a \cdot e(t) \\F(t+1) &= S(t)\end{aligned}$$

όπου:

- $t$  η χρονική περίοδο (με  $t = 1$  τη στιγμή της πρώτης παρατήρησης)
- $e(t)$  το σφάλμα (διαφορά της πρόβλεψης από την πραγματική τιμή) τη χρονική στιγμή  $t$
- $S(t)$  το επίπεδο
- $Y(t)$  η πραγματική παρατήρηση τη χρονική στιγμή  $t$  (μπορεί να αναφέρεται και σε επεξεργασμένα δεδομένα ή ακόμα και παρατηρήσεις τις αποεποχικοποιημένης χρονοσειράς)
- $F(t)$  την πρόβλεψη
- $a$  τον συντελεστή εξομάλυνσης ο οποίος λαμβάνει τιμές στο διάστημα  $[0,1]$

Παρατηρώντας τις παραπάνω εξισώσεις έχουμε:

$$\begin{aligned}F(t+1) = S(t) &= S(t-1) + a \cdot e(t) \xrightarrow{F(t)=S(t-1)} F(t+1) = F(t) + a \cdot e(t) \\&\xrightarrow{e(t)=Y(t)-F(t)} F(t+1) = F(t) + a \cdot (Y(t) - F(t)) \\&\Rightarrow F(t+1) = a \cdot Y(t) + (1-a) \cdot F(t)\end{aligned}$$

Δηλαδή η επόμενη πρόβλεψη αποτελεί γραμμικό συνδυασμό της προηγούμενης πρόβλεψης και της προηγούμενης παρατήρησης, πολλαπλασιασμένες με βάρη που καθορίζονται από τον συντελεστή εξομάλυνσης  $a$ .

Ο συντελεστής εξομάλυνσης  $a$  εξαρτάται από δύο παράγοντες, το θόρυβο και τη σταθερότητα του μέσου όρου μιας χρονοσειράς. Όσο πιο θορυβώδης είναι μια χρονοσειρά, τόσο μικρότερο καθορίζεται το  $a$  έτσι ώστε να αποφευχθούν οι υπερβολικές διακυμάνσεις λόγω του θορύβου. Ωστόσο, αν ο μέσος όρος έχει μεγάλες μεταβολές, το  $a$  καθορίζεται σε υψηλή τιμή έτσι ώστε οι προβλέψεις να ακολουθούν τις διακυμάνσεις που παρουσιάζουν οι παρατηρήσεις. Αξίζει να σημειωθεί ότι για  $a = 1$  η απλή εκθετική εξομάλυνση ταυτίζεται με τη Naïve ενώ για  $a = 0$  η πρόβλεψη είναι σταθερή, ίση με την αρχική τιμή. Στα σύγχρονα πληροφοριακά συστήματα η βέλτιστη παράμετρος  $a$  καθορίζεται με αυτόματο τρόπο.

Καθώς το μοντέλο είναι αναδρομικό, είναι αναγκαία η εύρεση της αρχικής συνθήκης, δηλαδή του αρχικού επιπέδου  $S(0)$ , έτσι ώστε να ξεκινήσει η διαδικασία υπολογισμού του μοντέλου. Ως αρχικό επίπεδο, συνήθως χρησιμοποιείται:

- ο μέσος όρος των παρατηρήσεων
- ο μέσος όρος των πρώτων  $n$  παρατηρήσεων
- η πρώτη παρατήρηση
- το σταθερό επίπεδο από άλλο στατιστικό μοντέλο, αυτό της γραμμικής παλινδρόμησης

Η επιλογή της καταλληλότερης εναλλακτικής σχετίζεται με τα ποιοτικά χαρακτηριστικά της χρονοσειράς και πρέπει να επιλεγεί με προσοχή καθώς αν το αρχικό επίπεδο δεν είναι αντιπροσωπευτικό των δεδομένων ενδέχεται να δράσει αρνητικά τόσο στις εξαγόμενες προβλέψεις όσο και στην επιλογή του συντελεστή εξομάλυνσης  $a$ .

### 2.3.3 Η Μέθοδος Theta

Η μέθοδος Theta (Assimakopoulos και Nikolopoulos, 2000) είναι μια μονοδιάστατη μέθοδος πρόβλεψης που στηρίζεται στη μεταβολή των τοπικών καμπυλοτήτων μιας χρονοσειράς μέσα από μια παράμετρο  $\theta$  (theta) η οποία εφαρμόζεται πολλαπλασιαστικά στις διαφορές δεύτερης τάξης των ιστορικών δεδομένων. Η μέθοδος αυτή διαχωρίζει την αρχική χρονοσειρά σε δύο ή περισσότερες γραμμές Theta (Theta lines). Κάθε γραμμή Theta χαρακτηρίζει τη βραχυπρόθεσμη ή μακροπρόθεσμη συμπεριφορά της αρχικής χρονοσειράς (ανάλογα με την τιμή της παραμέτρου  $\theta$ ) και προεκτείνεται ξεχωριστά προς το μέλλον. Η τελική πρόβλεψη προκύπτει από τον συνδυασμό των επιμέρους γραμμών, οι οποίες προεκτείνονται με κάποια άλλη μέθοδο προβλέψεων.

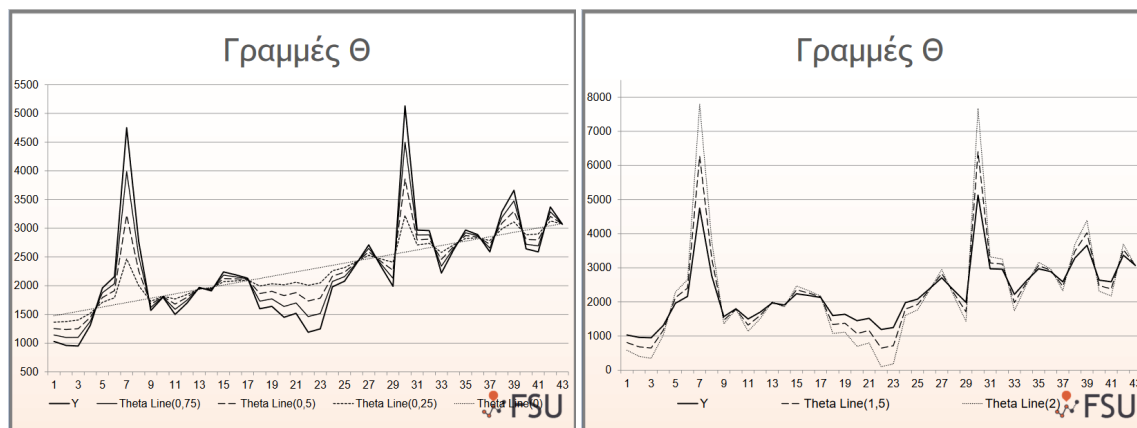
Για τις διάφορες τιμές της παραμέτρου  $\theta$  μπορεί να γίνει καλύτερη προσέγγιση της μακροπρόθεσμης ή βραχυπρόθεσμης συμπεριφοράς της χρονοσειράς. Συγκεκριμένα, όσο μικρότερη είναι η τιμή του  $\theta$  τόσο μεγαλύτερος ο βαθμός μείωσης των καμπυλοτήτων και τόσο καλύτερα προσεγγίζεται η μακροπρόθεσμη συμπεριφορά. Στην περίπτωση όπου  $\theta = 0$  η χρονοσειρά ισοδυναμεί με την ευθεία της απλής γραμμικής παλινδρόμησης (LRL). Η τιμή  $\theta = -1$  αντιστοιχεί στη συμμετρική της αρχικής χρονοσειράς ως προς την ευθεία της γραμμικής παλινδρόμησης. Αντίθετα, τιμές της  $\theta > 1$  ενισχύουν τις καμπυλότητες και έτσι η χρονοσειρά παρουσιάζεται διογκωμένη. Όσο μεγαλύτερος ο βαθμός διόγκωσης τόσο δίνεται έμφαση στη βραχυπρόθεσμη συμπεριφορά της αρχικής χρονοσειράς. Ακολουθώντας αυτή τη διαδικασία η χρονοσειρά διαχωρίζεται σε περισσότερες γραμμές Theta, οι οποίες υπολογίζονται ως:

$$Y_t^\theta = \theta \cdot Y_t'' \text{ όπου } Y_t'' = Y_t - 2 \cdot Y_{t-1} + Y_{t-2}$$

Ένα απλό παράδειγμα αποτελεί το κλασικό μοντέλο Theta που αποτελείται από δύο συνιστώσες για  $\theta = 0$  και  $\theta = 2$  και υπολογίζεται ως:

$$Y_t = \frac{1}{2}(Y_t^{\theta=0} + Y_t^{\theta=2})$$

Η πρώτη γραμμή Theta με παράμετρο  $\theta = 0$  είναι η απλή γραμμική παλινδρόμηση και προσδιορίζει τη μακροπρόθεσμη συμπεριφορά, ενώ η δεύτερη έχει τις διπλάσιες δεύτερες διαφορές σε σχέση με την αρχική χρονοσειρά, ενισχύοντας έτσι τη βραχυπρόθεσμη συμπεριφορά της αρχικής χρονοσειράς. Συνήθως προεκτείνεται με τη μέθοδο απλής εκθετικής εξομάλυνσης.



Σχήμα 2.4: Γραμμές Theta μιας χρονοσειράς. Πηγή: [6]

Τα βήματα που περιγράφουν τη μεθοδολογία της κλασικής μεθόδου Theta είναι:

1. Αρχικά η αρχική χρονοσειρά ελέγχεται αν έχει εποχιακότητα
2. Εφόσον πρόκειται για εποχιακή χρονοσειρά αυτή υφίσταται αποεποχικοποίηση μέσω της κλασικής μεθόδου πολλαπλασιαστικής αποσύνθεσης
3. Η χρονοσειρά αποσυντίθεται σε δύο γραμμές Theta με παραμέτρους  $\theta = 0$  και  $\theta = 2$
4. Ακολουθεί η πρόβλεψη. Η γραμμή με παράμετρο  $\theta = 0$  προεκτείνεται με τη μέθοδο γραμμικής παλινδρόμησης, ενώ η γραμμή με  $\theta = 2$  με τη μέθοδο της απλής εκθετικής εξομάλυνσης
5. Οι παραγόμενες προβλέψεις των δύο παραπάνω συνιστωσών συνδυάζονται με ίσα βάρη
6. Σε περίπτωση εποχιακών χρονοσειρών, οι προβλέψεις εποχικοποιούνται χρησιμοποιώντας του δείκτες εποχιακότητας που προέκυψαν κατά την αποεποχικοποίηση.

#### 2.3.4 Νευρωνικά Δίκτυα (Neural Networks)

Τα νευρωνικά δίκτυα είναι σε θέση να αναγνωρίζουν πρότυπα και να διακρίνουν μη γραμμικές σχέσεις ανάμεσα στις ανεξάρτητες μεταβλητές, οι οποίες στην εξεταζόμενη περίπτωση είναι τα ιστορικά δεδομένα μιας χρονοσειράς. Συνεπώς, μπορούν να φανούν χρήσιμα εκεί που τα υπόλοιπα στατιστικά μοντέλα αδυνατούν να προσαρμοστούν στις παρατηρήσεις. Η κεντρική ιδέα της μεθόδου είναι η τροφοδοσία των παρατηρήσεων μέσα από ένα ή περισσότερα κρυφά επίπεδα πριν την εξαγωγή μιας ή περισσότερων προβλέψεων από το τελικό επίπεδο εξόδου του δικτύου.

Στην παρούσα διπλωματική εργασία η μέθοδος αυτή δε χρησιμοποιείται αυτούσια, αλλά αποτελεί έναυσμα για την κατασκευή ενός πιο περίπλοκου νευρωνικού δικτύου, το οποίο καλείται να κάνει προβλέψεις από τη μορφή των ιστορικών δεδομένων ως προς το χρόνο, σε αντίθεση με τις απόλυτες τιμές των παρατηρήσεων. Το δίκτυο αυτό θα αναλυθεί λεπτομερώς στα επόμενα κεφάλαια.

## 2.4 Δείκτες Ακρίβειας

Αντίθετα με τη βασική στατιστική ανάλυση, για την οποία απαιτούνται μόνο οι πραγματικές παρατηρήσεις μιας χρονοσειράς, οι στατιστικοί δείκτες ακρίβειας απαιτούν μια σειρά πρόβλεψης, που προκύπτει από ένα μοντέλο προβλέψεων. Ορίζεται το σφάλμα, που αποτελεί τη διαφορά μεταξύ πραγματικής τιμής  $Y$  και πρόβλεψης  $F$  για μια χρονική περίοδο  $t$ :

$$e(t) = Y(t) - F(t)$$

Ένα στατιστικό μοντέλο προβλέψεων υπολογίζει προβλέψεις τόσο για τις αντίστοιχες τιμές των ιστορικών δεδομένων (με εξαίρεση ενδεχομένως κάποιες αρχικές περιόδους λόγω των απαιτούμενων αρχικοποιήσεων) όσο και για κάποιον ορίζοντα στο μέλλον. Οι ακόλουθοι δείκτες αναφέρονται στο σφάλμα του μοντέλου πρόβλεψης για τις γνωστές παρατηρήσεις in-sample error, ωστόσο με μικρές αλλαγές στις περιόδους υπολογισμού μπορούν να εφαρμοστούν για τον υπολογισμό των μελλοντικών (out-of-sample) προβλέψεων, εφόσον οι πραγματικές τιμές γίνουν γνωστές. Οι μεταβλητές των παρακάτω μεθόδων εκφράζουν αντίστοιχα:

- $t$  τη χρονική περίοδο
- $n$  το πλήθος των παρατηρήσεων της χρονοσειράς
- $Y$  τις πραγματικές τιμές της χρονοσειράς (μπορεί να αναφέρεται και σε επεξεργασμένα δεδομένα ή ακόμα και παρατηρήσεις τις αποεποχικοποιημένης χρονοσειράς)
- $F$  την πρόβλεψη

Οι σημαντικότεροι δείκτες ακρίβειας είναι οι ακόλουθοι:

- **Μέσο Σφάλμα (Mean Error)**

$$ME = \frac{1}{n} \sum_{t=1}^n (Y(t) - F(t))$$

Υπολογίζεται από τον απλό προσημασμένο μέσο όρο των διαφορών των προβλέψεων από την πραγματική τιμή, για την ίδια χρονική περίοδο. Μια τιμή κοντά στο 0 υποδεικνύει ότι τα σφάλματα είναι τυχαία και όχι συστηματικά. Ονομάζεται και *bias* γιατί φανερώνει αν το μοντέλο μεροληπτεί: μια θετική τιμή υποδηλώνει ένα απαισιόδοξο μοντέλο καθώς οι προβλέψεις είναι μικρότερες από τα σφάλματα ενώ μια αρνητική τιμή υποδηλώνει αισιόδοξία στο μοντέλο.

- **Μέσο Απόλυτο Σφάλμα (Mean Absolute Error)**

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y(t) - F(t)|$$

Φανερώνει ένα μέτρο της ακρίβειας των προβλέψεων από την πραγματική τιμή, ενώ έχει τις ίδιες μονάδες μέτρησης με την αρχική χρονοσειρά. Ωστόσο, σε αντίθεση με το μέσο σφάλμα, δεν εκφράζει τη μεροληψία του μοντέλου.

- **Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error)**

$$MSE = \frac{1}{n} \sum_{t=1}^n (Y(t) - F(t))^2$$

Όπως και το μέσο απόλυτο σφάλμα, είναι ένα μέτρο της ακρίβειας της πρόβλεψης από την πραγματική τιμή. Όμως, είναι πιο ευαίσθητο σε μεγάλα σφάλματα, καθώς λόγω του τετραγώνου δίνεται μεγαλύτερο βάρος σε αυτά. Είναι από τα βασικά σφάλματα που χρησιμοποιούνται για τον υπολογισμό των βέλτιστων παραμέτρων στα μοντέλα εξομάλυνσης.

- **Ρίζα Μέσου Τετραγωνικού Σφάλματος (Root Mean Squared Error)**

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y(t) - F(t))^2}$$

Υπολογίζεται άμεσα από το μέσο τετραγωνικό σφάλμα, αν πάρει κανείς την τετραγωνική του ρίζα. Έχει τις ίδιες ιδιότητες με αυτό αλλά διατηρεί τις μονάδες μέτρησης της αρχικής χρονοσειράς.

- **Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (Mean Absolute Percentage Error)**

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y(t) - F(t)}{Y(t)} \right| \cdot 100(\%)$$

Το σφάλμα αυτό υπολογίζει το σφάλμα της πρόβλεψης σε ποσοστιαία μορφή. Αποδεικνύεται ιδιαίτερα χρήσιμο σε περιπτώσεις που επιθυμεί κανείς να εξάγει την ακρίβεια μιας μεθόδου πρόβλεψης όταν αυτή εφαρμόζεται σε παραπάνω από μια χρονοσειρές, που έχουν διαφορετικό μέσο επίπεδο. Είναι ακόμα χρήσιμο όταν οι πραγματικές τιμές της χρονοσειράς είναι μεγάλες. Το μέσο απόλυτο ποσοστιαίο σφάλμα εκφράζεται επί τοις εκατό και παίρνει τιμές μεγαλύτερες του μηδενός.

Εύκολα παρατηρεί κανείς ότι λόγω της πραγματικής τιμής  $Y$  στον παρονομαστή, το σφάλμα αυτό δε μπορεί να εφαρμοστεί σε δεδομένα διακοπτόμενης ζήτησης ή σε δεδομένα με μηδενικές τιμές, καθώς καταλήγει σε απροσδιοριστία.

- **Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (Symmetric Mean Absolute Percentage Error)**

$$sMAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y(t) - F(t)}{\frac{Y(t)+F(t)}{2}} \right| \cdot 100 = \frac{1}{n} \sum_{t=1}^n \left| \frac{2 \cdot (Y(t) - F(t))}{Y(t) + F(t)} \right| \cdot 100(\%)$$

Το σφάλμα αυτό στον παρονομαστή λαμβάνει το ημίθροισμα της πραγματικής τιμής και της πρόβλεψης, πράγμα που λύνει το πρόβλημα των μηδενικών τιμών του προηγούμενου σφάλματος. Η αλλαγή αυτή επιφέρει και ένα άνω όριο στο σφάλμα και έτσι παίρνει τιμή στο διάστημα  $[0\%, 200\%]$ . Ωστόσο, ο δείκτης αυτός δεν είναι συμμετρικός, όπως

υποδηλώνει το όνομά του. Στο ακόλουθο παράδειγμα γίνεται ξεκάθαρο ότι οι αισιόδοξες και οι απαισιόδοξες προβλέψεις μεταχειρίζονται διαφορετικά:

- Αισιόδοξη πρόβλεψη:  $Y = 100, F = 110 \Rightarrow sMAPE = 4,76\%$
- Απαισιόδοξη πρόβλεψη:  $Y = 100, F = 90 \Rightarrow sMAPE = 5,26\%$

• **Μέσο Απόλυτο Κανονικοποιημένο Σφάλμα (Mean Absolute Scaled Error)**

$$MASE = \frac{\frac{1}{n} \sum_{t=1}^n |Y(t) - F(t)|}{\frac{1}{n-1} \sum_{t=2}^n |Y(t) - Y(t-1)|}$$

Ο δείκτης αυτός θυμίζει το μέσο απόλυτο σφάλμα στον αριθμητή, με τη διαφορά ότι είναι κανονικοποιημένος με τη μέση τιμή των πρώτων διαφορών της χρονοσειράς. Ουσιαστικά, ο παρονομαστής δίνει το μέσο απόλυτο σφάλμα, όταν η μέθοδος πρόβλεψης είναι η αφελής μέθοδος. Μια τιμή MASE μικρότερη της μονάδας φανερώνει ότι η εφαρμοσμένη μέθοδος είναι καλύτερη από την αφελή, ενώ σε αντίθετη περίπτωση η εφαρμοσμένη μέθοδος είναι χειρότερη από την αφελή.

Ο δείκτης αυτός προτάθηκε από τους Hyndman και Koehler αφού αντιμετωπίζει τα προβλήματα απροσδιοριστίας των MAPE και sMAPE αλλά και δίνει την ίδια βαρύτητα σε μικρά και μεγάλα σφάλματα, σε αντίθεση με τους MSE και RMSE. Η μοναδική περίπτωση κατά την οποία ο MASE καταλήγει σε απροσδιοριστία είναι όταν όλες οι παρατηρήσεις των ιστορικών δεδομένων είναι ίσες μεταξύ τους, πράγμα αρκετά απίθανο.

## Κεφάλαιο 3

# Νευρωνικά Δίκτυα

### 3.1 Εισαγωγή στα Νευρωνικά Δίκτυα

#### 3.1.1 Τι είναι τα Νευρωνικά Δίκτυα

Η κεντρική ιδέα πίσω από την κατασκευή των τεχνητών νευρωνικών δικτύων (ή απλώς νευρωνικών δικτύων, όπως αποκαλούνται χάριν συντομίας) ήταν ο ανθρώπινος εγκέφαλος. Ο ανθρώπινος εγκέφαλος πραγματοποιεί υπολογισμούς με διαφορετικό τρόπο από έναν ψηφιακό υπολογιστή, καθώς είναι περίπλοκος, μη γραμμικός, ενώ έχει τη δυνατότητα να οργανώνει τις δομικές του μονάδες (τους νευρώνες) με συγκεκριμένο τρόπο, ώστε να εκτελούν υπολογισμούς με μεγάλη ταχύτητα. Η ικανότητα οργάνωσης που έχει δίνει τη δυνατότητα στον ανθρώπινο εγκέφαλο να προσαρμόζεται ανάλογα με το περιβάλλον του και να κατασκευάζει δικούς του κανόνες συμπεριφοράς που συνήθως αποκαλούνται "έμπειρία". Με αντίστοιχο τρόπο, ένα νευρωνικό δίκτυο είναι μια μηχανή η οποία είναι ειδικά σχεδιασμένη έτσι ώστε να μοντελοποιεί τον τρόπο με τον οποίο ο ανθρώπινος εγκέφαλος εκτελεί μια εργασία. Όπως ο εγκέφαλος οργανώνεται συνάπτοντας συνδέσεις ανάμεσα στις δομικές του μονάδες, έτσι και τα νευρωνικά δίκτυα χρησιμοποιούν έναν μεγάλο αριθμό από απλά, διασυνδεδεμένα μεταξύ τους, υπολογιστικά κύτταρα, τα οποία ονομάζονται "νευρώνες" ή "μονάδες επεξεργασίας".

Ο Simon Haykin στο βιβλίο του "Νευρωνικά Δίκτυα και Μηχανική Μάθηση"[21] ορίζει ένα νευρωνικό δίκτυο ως:

*Ένα νευρωνικό δίκτυο είναι ένας τεράστιος παράλληλος επεξεργαστής με κατανεμημένη αρχιτεκτονική, ο οποίος αποτελείται από απλές μονάδες επεξεργασίας και έχει από τη φύση του τη δυνατότητα να αποθηκεύει εμπειρική γνώση και να την καθιστά διαθέσιμη για χρήση. Μοιάζει με τον ανθρώπινο εγκέφαλο σε δύο σημεία:*

1. Το δίκτυο προσλαμβάνει γνώση από το περιβάλλον του, μέσω μιας διαδικασίας μάθησης
2. Η ισχύς των συνδέσεων μεταξύ των νευρώνων, που αποκαλείται συναπτικό

*βάρος, χρησιμοποιείται για την αποθήκευση της γνώσης που αποκτάται.*

Ένα νευρωνικό δίκτυο υλοποιείται με τη χρήση ηλεκτρονικών μερών ή με την προσομοίωσή τους από εξειδικευμένο λογισμικό. Η διαδικασία μέσα από την οποία επιτυγχάνεται η μάθηση καλείται αλγόριθμος μάθησης. Η μάθηση επιτυγχάνεται μέσα από την τροποποίηση των συναπτικών βαρών του δικτύου, με σκοπό την επίτευξη του επιθυμητού στόχου. Ακόμα, ένα νευρωνικό δίκτυο έχει τη δυνατότητα τροποποίησης της τοπολογίας του, αφού τα βάρη μπορούν να τροποποιούνται έτσι ώστε κάποιοι νευρώνες να απενεργοποιούνται ενώ άλλοι μένουν ενεργοί.

### 3.1.2 Ιδιότητες των νευρωνικών δικτύων

Το μεγαλύτερο πλεονέκτημα των νευρωνικών δικτύων είναι η δυνατότητα γενίκευσης. Η γενίκευση αναφέρεται στη δυνατότητα εξαγωγής λογικών εξόδων από εισόδους πάνω στις οποίες το νευρωνικό δίκτυο δεν έχει εκπαιδευτεί και άρα δεν έχει ξανασυναντήσει. Η ικανότητα αυτή, μαζί με την κατανεμημένη δομή του, του δίνει τη δυνατότητα να δίνει αξιολογικές προσεγγιστικές λύσεις σε πολύπλοκα προβλήματα.

Οι σημαντικότερες ιδιότητες των νευρωνικών δικτύων είναι οι ακόλουθες:

- **Μη γραμμικότητα.** Ένας νευρώνας μπορεί να είναι είτε γραμμικός είτε μη γραμμικός. Ένα νευρωνικό δίκτυο αποτελείται από νευρώνες διασυνδεδεμένους μεταξύ τους, συνεπώς είναι εκ φύσεως μη γραμμικό και αυτή η μη γραμμικότητα είναι κατανεμημένη σε όλο το δίκτυο. Η ιδιότητα αυτή είναι πολύ σημαντική, ιδιαίτερα για μη γραμμικές εισόδους.
- **Αντιστοίχιση Εισόδου-Εξόδου.** Μια από τις πιο δημοφιλείς τεχνικές μάθησης είναι η επιβλεπόμενη μάθηση. Κατά την τεχνική αυτή στο δίκτυο παρουσιάζονται “παραδείγματα εκπαίδευσης”, δηλαδή ζευγάρια από ένα σήμα εισόδου και μια αντίστοιχη επιθυμητή έξοδος (απόκριση). Τα συναπτικά βάρη του δικτύου προσαρμόζονται πάνω σε αυτά τα παραδείγματα, ώστε να ελαχιστοποιηθεί όσο το δυνατό περισσότερο η διαφορά μεταξύ της επιθυμητής εξόδου και της πραγματικής απόκρισης του δικτύου. Η εκπαίδευση επαναλαμβάνεται με πολλά παραδείγματα έως ότου το δίκτυο φτάσει σε μια κατάσταση ισορροπίας.
- **Προσαρμοστικότητα.** Τα νευρωνικά δίκτυα έχουν τη δυνατότητα να προσαρμόζουν τα βάρη τους ανάλογα με τις μεταβολές που συμβαίνουν στο περιβάλλον τους (και εισέρχονται στο δίκτυο ως είσοδοι). Ακόμα, ένα νευρωνικό δίκτυο έχει την ικανότητα να επανεκπαιδεύεται σε πραγματικό χρόνο, ώστε να χειρίζεται μεταβολές στις συνθήκες του περιβάλλοντος λειτουργίας του. Η ιδιότητα αυτή είναι ιδιαίτερα χρήσιμη σε ασταθή περιβάλλοντα, όπως για παράδειγμα η προσαρμοστική αναγνώριση προτύπων. Ωστόσο, η προσαρμοστικότητα δεν οδηγεί πάντα σε ευρωστία. Έτσι, αναζητείται μια ισορροπία ανάμεσα στον ρυθμό ανανέωσης του δικτύου και την ευρωστία (που είναι γνωστό και ως δίλημμα σταθερότητας - πλαστικότητας).



- **Ενδεικτική Απόκριση.** Στο πλαίσιο της ταξινόμησης προτύπων, ένα νευρωνικό δίκτυο μπορεί να παρέχει πληροφορία όχι μόνο για την κατηγορία που επιλέγεται αλλά και για το βαθμό εμπιστοσύνης της ληφθείσας απόφασης. Η πληροφορία αυτή μπορεί να ληφθεί υπόψη σε περίπτωση διφορούμενων ή ασαφών αποτελεσμάτων και κατ' επέκταση να βελτιώσει την ολική απόδοση του δικτύου.
- **Ανοχή σε βλάβες.** Ένα νευρωνικό δίκτυο που είναι υλοποιημένο με υλικό είναι εύρωστο αφού η απόδοσή του μειώνεται βαθμιαία. Αυτό συμβαίνει επειδή η πληροφορία είναι κατανομημένη σε όλο το δίκτυο, συνεπώς αν για παράδειγμα καταστραφούν οι συνδέσεις ενός νευρώνα η δυνατότητα της ανάκλασης μειώνεται, ωστόσο μια τέτοια βλάβη πρέπει να συμβεί σε μεγάλη έκταση του δικτύου για να προκαλέσει αισθητή διαφορά στην ποιότητα ανάκλασης των αποθηκευμένων προτύπων.
- **Γενίκευση.** Τα νευρωνικά δίκτυα μπορούν να εφαρμοστούν σε πληθώρα επιστημονικών πεδίων, χωρίς να αλλάξει η σημειογραφία και ο τρόπος εφαρμογής από το ένα πεδίο στο άλλο. Έτσι, είναι κοινώς αποδεκτά ως επεξεργαστές πληροφοριών. Ο κοινός τους χαρακτήρας του επιτρέπει την υλοποίηση ίδιων θεωριών και αλγορίθμων μάθησης σε διαφορετικές εφαρμογές.
- **Ομοιότητα με τον εγκέφαλο.** Η σχεδίαση ενός νευρωνικού δικτύου βασίζεται κατά κύριο λόγο στη λειτουργία του ανθρώπινου εγκεφάλου και αυτό αποτελεί απόδειξη ότι μια τέτοια αρχιτεκτονική είναι εύρωστη, γρήγορη και ισχυρή. Ακόμα, αποτελεί χρήσιμο ερευνητικό εργαλείο για την ερμηνεία νευροβιολογικών φαινομένων. Από την άλλη, οι μηχανικοί αναζητούν νέες τεχνικές σχεδίασης νευρωνικών δικτύων από τον τομέα της νευροβιολογίας.

## 3.2 Μοντέλα Νευρώνων

Δοκιμή μονάδα των νευρωνικών δικτύων αποτελούν οι **νευρώνες** ή **μονάδες επεξεργασίας**. Ένα βασικό μοντέλο νευρώνα παρουσιάζεται στην εικόνα 3.1 Τα τρία βασικά του στοιχεία είναι:

- Ένα σύνολο συνάψεων ή διασυνδέσεων (μία από κάθε είσοδο), κάθε μία εκ των οποίων έχει δικό της βάρος ή δύναμη. Τα βάρη αυτά πολλαπλασιάζονται με τις αντίστοιχες εισόδους πριν αυτές εισέλθουν στον αθροιστή. Συγκεκριμένα, ένα σήμα  $x_j$  που συνδέεται με ένα νευρώνα  $k$  πολλαπλασιάζεται με ένα βάρος  $w_{kj}$ . Κατά τη βιβλιογραφία, στο συμβολισμό του βάρους είνισται ο πρώτος δείκτης  $k$  να συμβολίζει το νευρώνα, ενώ ο δεύτερος  $j$  την είσοδο της σύναψης με το αντίστοιχο βάρος. Το βάρος αυτό ενός τεχνητού νευρώνα μπορεί να λαμβάνει και θετικές και αρνητικές τιμές.
- Έναν αθροιστή ο οποίος αθροίζει τα σήματα εισόδου αφού έχουν πολλαπλασιαστεί με τα βάρη. Αυτές οι λειτουργίες αποτελούν έναν γραμμικό συνδυαστή (linear combiner).

- Μια συνάρτηση ενεργοποίησης (activation function) ή συνάρτηση περιορισμού (squashing function) η οποία περιορίζει το εύρος του σήματος εξόδου σε κάποια πεπερασμένα όρια. Τυπικά, το εύρος τιμών του πλάτους εξόδου ενός νευρώνα κανονικοποιείται στα διαστήματα  $[0,1]$  ή  $[-1,1]$ .

Το μοντέλο αυτό περιλαμβάνει ακόμα μια εξωτερική πόλωση (bias)  $b_k$  η λειτουργία της οποίας είναι η αύξηση ή η μείωση της διέγερσης της συνάρτησης ενεργοποίησης, ανάλογα με το αν είναι θετική ή αρνητική, αντίστοιχα.

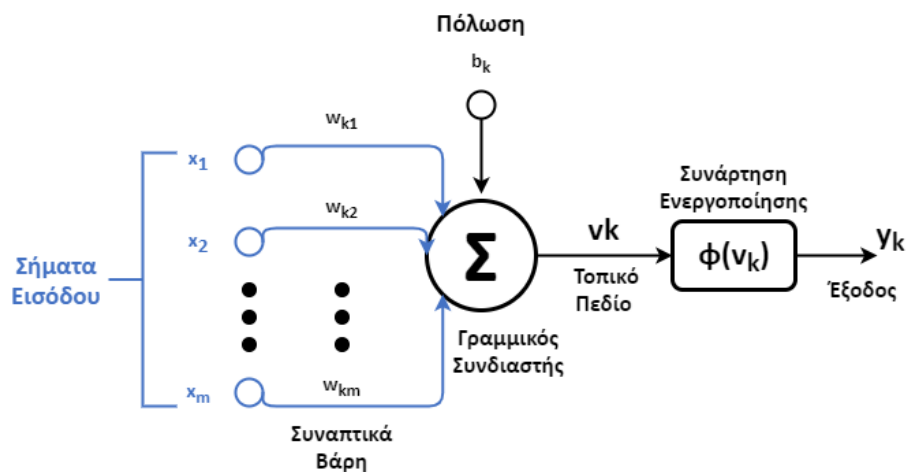
Με μαθηματικούς όρους η λειτουργία του νευρώνα περιγράφεται με τις παρακάτω εξισώσεις:

$$u_k = \sum_{j=1}^m w_{kj} x_j$$

$$y_k = \phi(u_k + b_k)$$

όπου:

- $x_j$  τα σήματα εισόδου
- $w_{kj}$  τα συναπτικά βάρη που αντιστοιχούν στον νευρώνα  $k$  για τις αντίστοιχες εισόδους  $x_j$
- $u_k$  η έξοδος του γραμμικού συνδυαστή
- $b_k$  η πόλωση
- $\phi(\cdot)$  η συνάρτηση ενεργοποίησης
- $y_k$  η τελική έξοδος του νευρώνα  $k$



Σχήμα 3.1: Μοντέλο Νευρώνα. Χάρην απλότητας συμβολίζεται  $v_k = u_k + b_k$  (τοπικό πεδίο)

### 3.3 Συναρτήσεις Ενεργοποίησης

Η συνάρτηση ενεργοποίησης ενός νευρώνα ορίζει την έξοδό του με βάση την τιμή του τοπικού πεδίου  $v$ . Συνήθως συμβολίζεται με  $\phi(v)$  και λειτουργεί σαν περιοριστής: περιορίζει το τοπικό πεδίο σε προκαθορισμένα όρια. οι συναρτήσεις ενεργοποίησης που θα χρησιμοποιηθούν στην παρούσα διπλωματική εργασία είναι οι ακόλουθες:

#### 3.3.1 Σιγμοειδής Συνάρτηση

Η σιγμοειδής συνάρτηση είναι μια αύξουσα συνάρτηση η γραφική παράσταση της οποίας θυμίζει το αγγλικό γράμμα "S". Ένα παράδειγμα σιγμοειδούς συνάρτησης είναι η λογιστική συνάρτηση η οποία ορίζεται ως:

$$\phi(v) = \frac{1}{1 + \exp(-av)}$$

όπου  $v = \sum_{j=1}^m w_j x_j + b$ , το τοπικό πεδίο του νευρώνα και  $a$  η παράμετρος κλίσης. Όσο πιο μεγάλη η τιμή του  $a$  τόσο πιο "άπτομη" γίνεται η κλίση της σιγμοειδούς συνάρτησης στην αρχή των αξόνων. Έχει επικρατήσει στα νευρωνικά δίκτυα να χρησιμοποιείται  $a = 1$ [9].

Ο ρόλος της συνάρτησης αυτής είναι να περιορίσει τις εξόδους του γραμμικού τμήματος του νευρώνα σε ένα συνεχές πεδίο μεταξύ των τιμών 0 και 1. Η συνάρτηση αυτή είναι διαφορίσιμη.

#### 3.3.2 Συνάρτηση Υπερβολικής Εφαπτομένης

Η σιγμοειδής συνάρτηση έχει πεδίο τιμών μεταξύ των 0 και +1. Σε πολλές περιπτώσεις όμως είναι επιθυμητό το πεδίο τιμών να παίρνει τιμές μεταξύ των -1 και +1. Μια πολύ δημοφιλής συνάρτηση ενεργοποίησης που πληροί τις προϋποθέσεις είναι η συνάρτηση υπερβολικής εφαπτομένης η οποία ορίζεται ως:

$$\phi(v) = \tanh(v) = \frac{e^v - e^{-v}}{e^v + e^{-v}}$$

#### 3.3.3 Συνάρτηση ReLU

Οι δύο προηγούμενες συναρτήσεις ενεργοποίησης, αν και είναι πολύ δημοφιλείς προκαλούν προβλήματα στα βαθιά δίκτυα (δηλαδή δίκτυα με πολλά επίπεδα), όπως μηδενισμό των παραγώγων κατά τη διαδικασία της μάθησης (βλέπε ενότητα 3.5). Ο μηδενισμός αυτός προκαλεί την απενεργοποίηση κάποιων νευρώνων με αποτέλεσμα να παρεμποδίζεται η εκπαίδευση.

Η Rectified Linear Unit που είναι ευρέως γνωστή ως ReLU αποτελεί τη δημοφιλέστερη συνάρτηση ενεργοποίησης που χρησιμοποιείται στα βαθιά δίκτυα[9] (βλέπε κεφάλαιο ;). Ορίζεται ως:

$$\phi(v) = \max(0, v) = \begin{cases} v, & \text{αν } v \geq 0 \\ 0, & \text{αν } v < 0 \end{cases}$$

Η συνάρτηση αυτή “διορθώνει” τις τιμές των αρνητικών εισόδων, αναγκάζοντάς τις να γίνουν 0 και εξαλείφοντας έτσι το πρόβλημα μηδενισμού των παραγώγων κάποιων νευρώνων. Συνήθως χρησιμοποιείται στα κρυμμένα στρώματα των νευρωνικών δικτύων ενώ στο επίπεδο εξόδου χρησιμοποιούνται οι προαναφερθείσες συναρτήσεις.

Λόγω της σχετικής γραμμικότητάς της προσφέρει ταχύτητα στους υπολογισμούς. Όμως, έχει αποδειχτεί ότι έχει μεγάλη ευαισθησία κατά την εκπαίδευση και αρκετές φορές οδηγεί σε μηδενισμό των παραγώγων (“νεκροί νευρώνες”) και με αποτέλεσμα να μην ανανεώνονται τα συναπτικά βάρη κάποιων νευρώνων[9].

### 3.3.4 Συνάρτηση Leaky ReLU

Μια παραλλαγή της ReLU αποτελεί η Leaky ReLU η οποία έχει ένα μικρό αρνητικό μέρος και δεν επιστρέφει 0 για τις αρνητικές τιμές του τοπικού πεδίου  $v$ . Ορίζεται ως:

$$\phi(v) = av + v = \begin{cases} v, & \text{αν } v > 0 \\ av, & \text{αν } v \leq 0 \end{cases}$$

όπου το  $a$  είναι μια παράμετρος που παίρνει μικρές τιμές της τάξης του 0,01. Η τροποποίηση αυτή πραγματοποιήθηκε για να λύσει το πρόβλημα των “νεκρών νευρώνων”, αφού έτσι καμία παράγωγος δε μηδενίζεται κατά τη διαδικασία εκπαίδευσης.

## 3.4 Αρχιτεκτονικές Δικτύων

Ο τρόπος με τον οποίο είναι δομημένοι οι νευρώνες σε ένα δίκτυο είναι γνωστός ως αρχιτεκτονική του δικτύου. Παρακάτω παρουσιάζονται μερικές από τις δημοφιλέστερες αρχιτεκτονικές νευρωνικών δικτύων.

### 3.4.1 Το Perceptron

Το perceptron είναι η απλούστερη μορφή ενός νευρωνικού δικτύου και χρησιμοποιείται για την ταξινόμηση προτύπων, όταν αυτά είναι “γραμμικά διαχωρίσιμα”, όταν δηλαδή μπορούν να χωριστούν σε δύο κλάσεις, των οποίων τα δείγματα βρίσκονται σε αντίθετες πλευρές ενός υπερπεπίπεδου. Το perceptron προτάθηκε από τον Rosenblatt ο οποίος απέδειξε ότι αν τα δείγματα που χρησιμοποιούνται για την εκπαίδευση είναι γραμμικά διαχωρίσιμα τότε ο αλγόριθμος του perceptron συγκλίνει και τοποθετεί ένα διαχωριστικό υπερπεπίπεδο “άποφασης” μεταξύ των δύο κλάσεων.

Το perceptron βασίζεται στον μη γραμμικό νευρώνα που περιγράφηκε παραπάνω και αποτελείται από έναν γραμμικό συνδυαστή και μια μη γραμμική συνάρτηση ενεργοποίησης. Η έξοδος του είναι +1 ή -1, ανάλογα με το αν η συνάρτηση ενεργοποίησης δίνει θετικό ή αρνητικό αποτέλεσμα αντίστοιχα. Όπως και στην προηγούμενη ενότητα, η έξοδος του γραμμικού

τιμήματος του νευρώνα και κατ' επέκταση η είσοδος του περιοριστή είναι

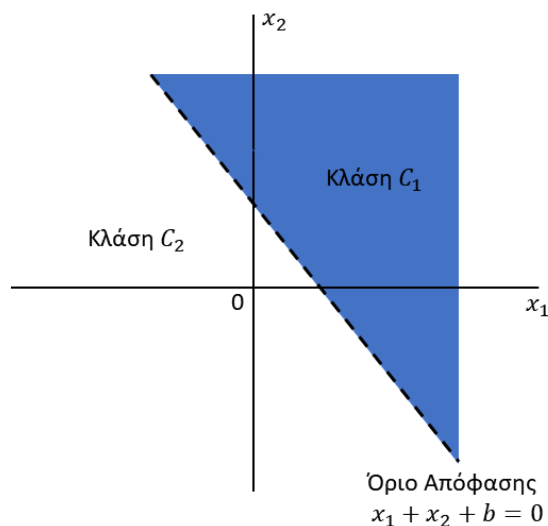
$$u = \sum_{j=1}^m w_j x_j + b$$

όπου με  $x_j$  συμβολίζονται οι είσοδοι, με  $w_j$  τα συναπτικά βάρη και με  $b$  η πόλωση.

Στόχος του perceptron είναι να ταξινομήσει τις εισόδους (όπου κάθε είσοδος είναι ένα διάνυσμα εξωτερικών διεγέρσεων  $x = [x_1, x_2, \dots, x_m]$ ) σε δύο κλάσεις  $C_1$  και  $C_2$ . Ο κανόνας απόφασης υπαγορεύει ότι η είσοδος  $x$  αντιστοιχεί στην κλάση  $C_1$  αν η αντίστοιχη έξοδος του perceptron είναι  $+1$ . Σε περίπτωση που η έξοδος είναι  $-1$  η αντίστοιχη είσοδος ανήκει στην κλάση  $C_2$ . Στην απλή αυτή περίπτωση όπου οι κλάσεις είναι δύο, οι δύο περιοχές απόφασης διαχωρίζονται από το υπερεπίπεδο

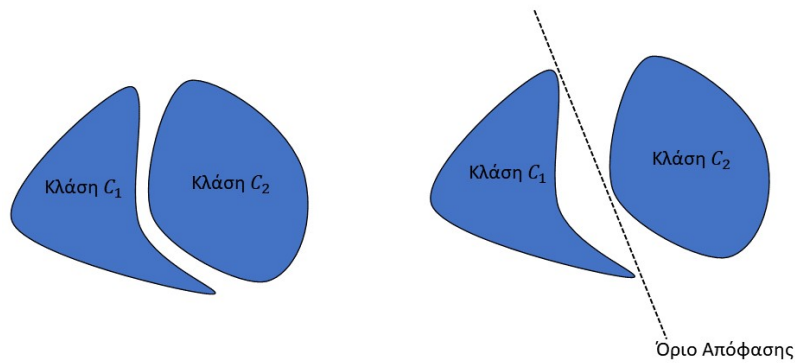
$$\sum_{j=1}^m w_j x_j + b = 0$$

Η ύπαρξη της πόλωσης απλώς μετατοπίζει το υπερεπίπεδο σε σχέση με την αρχή των αξόνων.



Σχήμα 3.2: Το υπερεπίπεδο ως όριο απόφασης σε ένα πρόβλημα ταξινόμησης προτύπων με δύο κλάσεις

Είναι σημαντικό να τονιστεί ότι ένα τέτοιο δίκτυο μπορεί να παράγει έγκυρη έξοδο μετά την εκπαίδευσή του μόνο αν οι κλάσεις είναι γραμμικά διαχωρίσιμες, δηλαδή τα πρότυπα που ανήκουν σε διαφορετικές κλάσεις να έχουν επαρκείς διαφορές μεταξύ τους ώστε να μπορεί να βρεθεί ένα υπερεπίπεδο διαχωρισμού. Τα συναπτικά βάρη του perceptron προσαρμόζονται με μια επαναληπτική διαδικασία, που ονομάζεται μάθηση, μέσα από την οποία στο σύστημα παρουσιάζονται παραδείγματα από διαφορετικές κλάσεις και η αντίστοιχη επιθυμητή κλάση στην οποία πρέπει να ταξινομηθούν. Για την προσαρμογή των βαρών χρησιμοποιείται ένας κανόνας διόρθωσης σφαλμάτων, που είναι γνωστός ως αλγόριθμος σύγκλισης του perceptron.




Σχήμα 3.3: Αριστερά: ζεύγος μη γραμμικά διαχωρίσιμων προτύπων, δεξιά: ζεύγος γραμμικά διαχωρίσιμων προτύπων

### 3.4.2 Δίκτυα Πρόσθιας Τροφοδότησης Μοναδικού Επιπέδου

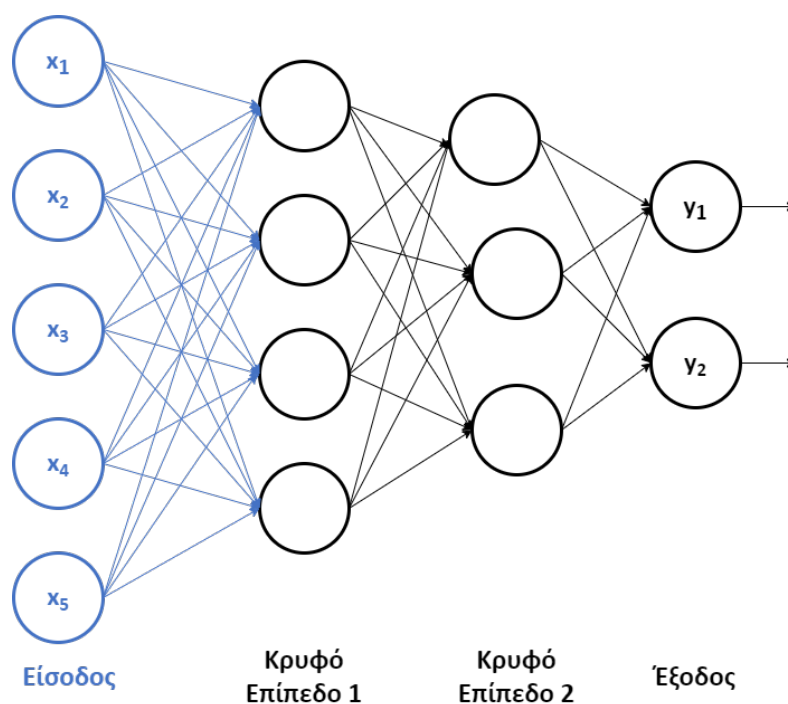
Μια ιδιαίτερα δημοφιλής κατηγορία αρχιτεκτονικών είναι τα δίκτυα εμπρόσθιας τροφοδότησης feedforward networks. Σε αυτή την κατηγορία ανήκουν δίκτυα τα οποία οργανώνονται σε επίπεδα. Οι κόμβοι (νευρώνες) ενός επιπέδου συνδέονται απευθείας με τους κόμβους του επόμενου, αλλά όχι αντίστροφα. Στην περίπτωση όπου ένα επίπεδο εισόδου (που αποτελείται από κόμβους που αναπαριστούν τις συνιστώσες των διανυσμάτων εισόδου και ονομάζονται πηγαίοι κόμβοι) συνδέονται απευθείας με ένα επίπεδο εξόδου (υπολογιστικοί κόμβοι), το δίκτυο ονομάζεται δίκτυο πρόσθιας τροφοδότησης ‘ένός επιπέδου’. Το χαρακτηριστικό αυτό αναφέρεται μόνο στα επίπεδα υπολογιστικών κόμβων και έτσι το επίπεδο εισόδου δεν προσμετράται.

### 3.4.3 Δίκτυα Πρόσθιας Τροφοδότησης Πολλαπλών Επιπέδων

Τα δίκτυα πρόσθιας τροφοδότησης πολλών επιπέδων χαρακτηρίζονται από την παρουσία ενός ή περισσότερων “κρυφών επιπέδων” που συνδέουν το επίπεδο εισόδου με αυτό της εξόδου. Οι νευρώνες των κρυφών επιπέδων ονομάζονται “κρυφοί νευρώνες” ή “κρυφοί κόμβοι”. Η ονομασία “κρυφός” αναφέρεται στο γεγονός ότι το μέρος αυτό του δικτύου δεν είναι άμεσα ορατό ούτε από την είσοδο αλλά ούτε από την έξοδο και έχει τον ρόλο του “μεσάζοντα” μεταξύ των δύο αυτών επιπέδων. Το επίπεδο εισόδου συνδέεται με το πρώτο επίπεδο κρυφών νευρώνων, το πρώτο κρυφό επίπεδο με το δεύτερο (αλλά όχι ανάποδα) και ούτω καθεξής. Το τελευταίο κρυφό επίπεδο συνδέεται με το επίπεδο εξόδου. Προσθέτοντας κρυφά επίπεδα, το δίκτυο έχει τη δυνατότητα να εξάγει υψηλότερης ποιότητας χαρακτηριστικά και στατιστικά, γενικεύοντας την προοπτική του, παρά τον τοπικό χαρακτήρα των συνδέσεών του. Οι κόμβοι του τελικού επιπέδου (εξόδου) παράγουν τη συνολική απόκριση του δικτύου για συγκεκριμένη είσοδο που εφαρμόζεται στο πηγαίο επίπεδο.




Σχήμα 3.4: Νευρωνικό δίκτυο μοναδικού επιπέδου με τρεις νευρώνες εξόδου.



Σχήμα 3.5: Νευρωνικό δίκτυο με δύο κρυφά επίπεδα και δύο νευρώνες εξόδου

### 3.4.4 Μια ενδιαφέρουσα αρχιτεκτονική: ο Αυτοκωδικοποιητής

Ένας αυτοκωδικοποιητής (autoencoder) είναι ένα δίκτυο που εκπαιδεύεται με στόχο την αναπαραγωγή της εισόδου στην έξοδο. Εσωτερικά έχει ένα κρυμμένο επίπεδο (που συχνά αποκαλείται bottleneck) που περιγράφει έναν κώδικα ο οποίος χρησιμεύει για την ανακατασκευή της εισόδου. Ο αυτοκωδικοποιητής αποτελείται από δύο μέρη: τον κωδικοποιητή (encoder) που μαθαίνει μια συνάρτηση  $h = f(x)$  και τον αποκωδικοποιητή (decoder) που παράγει μια αναπαράσταση της εισόδου  $r = g(h)$ . Είναι πολύ εύκολο για έναν αυτοκωδικοποιητή να καταφέρει να αντιγράψει απλά την είσοδο, αλλά αυτό δεν είναι επιθυμητό. Αντίθετα, οι αυτοκωδικοποιητές σχεδιάζονται έτσι ώστε να μη μπορούν να αντιγράψουν την είσοδο τέλεια, αλλά κατά προσέγγιση. Με τον τρόπο αυτό μαθαίνουν να θέτουν προτεραιότητα στα σημαντικά χαρακτηριστικά των εισόδων, μαθαίνοντας στην πορεία χρήσιμες ιδιότητες των εισόδων.



Σχήμα 3.6: Σχηματικό αυτοκωδικοποιητή. Η είσοδος  $x$  ανακατασκευάζεται στην έξοδο  $r$  μέσω μιας εσωτερικής αναπαράστασης  $h$ . Αποτελείται από δύο μέρη: τον κωδικοποιητή  $f$  που μετασχηματίζει την είσοδο  $x$  στον κώδικα  $h$  και τον αποκωδικοποιητή  $g$  που ανακατασκευάζει τον  $h$  στην έξοδο  $r$ .

Η συνηθέστερη αρχιτεκτονική για τους αυτοκωδικοποιητές είναι οι υποπλήρεις (under-complete autoencoders). Στους υποπλήρεις αυτοκωδικοποιητές η διάσταση του bottleneck  $h$  είναι μικρότερη από εκείνη της εισόδου  $x$ . Η μείωση στη διαστατικότητα επιτρέπει στο δίκτυο να αποτυπώσει τα πιο σημαντικά χαρακτηριστικά της εισόδου. Στους αυτοκωδικοποιητές με πολλά κρυμμένα επίπεδα συνηθίζεται ο κωδικοποιητής να έχει τη μορφή “χωνιού” με διαδοχική μείωση της διαστατικότητας σε κάθε επίπεδο, ενώ ο αποκωδικοποιητής είναι συμμετρικός προς τον κωδικοποιητή.

Η διαδικασία μάθησης είναι η ίδια όπως στην πλειοψηφία των δικτύων πρόσθιας τροφοδότησης και έχει στόχο την ελαχιστοποίηση κάποιας συνάρτησης (που ονομάζεται συνάρτηση απώλειας - loss function):


$$L(x, g(f(x)))$$

όπου

- $L$  η συνάρτηση απώλειας
- $x$  το διάνυσμα εισόδου
- $f(\cdot)$  η συνάρτηση κωδικοποίησης
- $g(\cdot)$  η συνάρτηση αποκωδικοποίησης, που επιστρέφει την ανακατασκευή της εισόδου  $r$



Η συνάρτηση απώλειας είναι μια συνάρτηση (όπως για παράδειγμα το μέσο τετραγωνικό σφάλμα) που επιβάλλει ποινή στην ανακατασκευή όταν είναι ανόμοια με την αντίστοιχη είσοδο.



Σχήμα 3.7: Υποπλήρης αυτοκωδικοποιητής με 3 κρυμμένα επίπεδα. Το bottleneck έχει μικρότερη διάσταση από την είσοδο. Ο αποκωδικοποιητής είναι συμμετρικός ως προς τον κωδικοποιητή.

### Εφαρμογές Αυτοκωδικοποιητών

Μια από τις σπουδαιότερες εφαρμογές αυτών των δικτύων, η οποία πυροδότησε και την περαιτέρω μελέτη τους είναι η μείωση της διαστατικότητας των εισόδων. Η ιδιότητά τους να μαθαίνουν χρήσιμα χαρακτηριστικά τα καθιστά κατάλληλα για δημιουργία νέων πιο συμπυκνώνων δεδομένων από τα αρχικά. Οι μικρότερης διάστασης αναπαραστάσεις μπορούν να χρησιμοποιηθούν σε άλλα δίκτυα, βελτιώνοντας την απόδοση, αφού χρησιμοποιούν λιγότερη μνήμη και χρειάζονται λιγότερο χρόνο εκπαίδευσης. Άλλες εφαρμογές που κάνουν χρήση αυτής της αρχιτεκτονικής είναι η εξάλειψη του θορύβου από δεδομένα (κυρίως από εικόνες) (denoising autoencoders) αλλά και η παραγωγή νέων δεδομένων, όπως για παράδειγμα πρόβλεψη του επόμενου κάδρου σε μια αλληλουχία εικόνων (βίντεο).

## 3.5 Διαδικασίες Μάθησης

Υπάρχουν διαφορετικοί τρόποι με τους οποίους μπορεί να εκπαιδευτεί κανείς ένα νευρωνικό δίκτυο. Οι τρόποι αυτοί μπορούν να χωριστούν σε δύο μεγάλες κατηγορίες, τη μάθηση με εκπαιδευτή και τη μάθηση χωρίς εκπαιδευτή.

### 3.5.1 Μάθηση με Εκπαιδευτή

Η μάθηση με εκπαιδευτή η οποία αποκαλείται και επιβλεπόμενη μάθηση (supervised learning) είναι ένα σύστημα που αποτελείται από δύο τμήματα: το νευρωνικό δίκτυο και τον εκπαιδευτή. Ο εκπαιδευτής έχει γνώση του περιβάλλοντος η οποία αποτυπώνεται ως ένα σύνολο παραδειγμάτων εισόδου - εξόδου. Ωστόσο, το περιβάλλον είναι άγνωστο στο νευρωνικό δίκτυο. Η λειτουργία του εκπαιδευτή είναι να παρέχει στο νευρωνικό δίκτυο την επιθυμητή απόκριση για το διάνυσμα που έχει δεχτεί ως είσοδο από το περιβάλλον. Αντίστοιχα, το νευρωνικό δίκτυο παράγει την πραγματική απόκριση για τη συγκεκριμένη είσοδο. Οι ελεύθερες παράμετροι του δικτύου, που είναι τα συναπτικά βάρη των νευρώνων του, προσαρμόζονται σύμφωνα με την επιρροή του διανύσματος εκπαίδευσης (εισόδου) και ενός σήματος σφάλματος. Το σήμα αυτό ορίζεται ως η διαφορά μεταξύ επιθυμητής και πραγματικής απόκρισης. Η διαδικασία αυτή εκτελείται επαναληπτικά και με τον τρόπο αυτό μεταφέρεται γνώση από τον εκπαιδευτή στο νευρωνικό δίκτυο.

Η παραπάνω διαδικασία αποτελεί μάθηση μέσω διόρθωσης σφαλμάτων. Ως μέσο απόδοσης χρησιμοποιείται κάποιο στατιστικό σφάλμα, όπως το μέσο τετραγωνικό σφάλμα ή το άθροισμα των τετραγώνων των σφαλμάτων για το σύνολο εκπαίδευσης. Ελεύθερες μεταβλητές αποτελούν τα συναπτικά βάρη του δικτύου. Η λειτουργία αυτή μπορεί να αποδοθεί ως μια πολυδιάστατη επιφάνεια σφάλματος. Στόχος είναι η διαδοχική μετατόπιση των βαρών του δικτύου προς ένα ελάχιστο σημείο αναφοράς σφάλματος. Ένα σύστημα επιβλεπόμενης μάθησης έχει τη δυνατότητα να το κάνει αυτό μέσω της πληροφορίας που διαθέτει σχετικά με την κλίση (gradient) της επιφάνειας σφάλματος, που αντιστοιχεί στην κατάσταση του συστήματος την τρέχουσα χρονική στιγμή. Στην πραγματικότητα, το σύστημα διαθέτει μια εκτίμηση της κλίσης αυτής. Παρόλα αυτά, με τη χρήση ενός ειδικά σχεδιασμένου αλγορίθμου, ένα επαρκές σύνολο ζευγών εισόδου - εξόδου και αρκετές επαναλήψεις το νευρωνικό δίκτυο μπορεί να προσεγγίσει το ζητούμενο ελάχιστο ικανοποιητικά, πετυχαίνοντας έτσι την αντιστοίχιση άγνωστων ζευγών εισόδου - εξόδου με ικανοποιητικό τρόπο.

### 3.5.2 Μάθηση χωρίς Εκπαιδευτή

Στην επιβλεπόμενη μάθηση η εκπαίδευση γίνεται με την καθοδήγηση ενός εκπαιδευτή. Ωστόσο, στη μάθηση χωρίς εκπαιδευτή, όπως υποδηλώνεται και από το όνομα, δεν υπάρχει κάποιος συντελεστής που να επιβλέπει τη διαδικασία, ούτε χαρακτηριστικά παραδείγματα της επιθυμητής απόκρισης του δικτύου. Σε αυτή την κατηγορία εντάσσονται η ενισχυτική μάθηση και η μη επιβλεπόμενη μάθηση.

#### Ενισχυτική Μάθηση

Στην ενισχυτική μάθηση η εκπαίδευση πάνω σε ένα ζεύγος εισόδου - εξόδου πραγματοποιείται μέσω συνεχούς αλληλεπίδρασης του δικτύου με το περιβάλλον, με σκοπό την ελαχιστοποίηση ενός βαθμωτού δείκτη απόδοσης. Η διαδικασία αυτή βασίζεται σε έναν μηχανισμό που λειτουργεί ως κριτής, ο οποίος μετατρέπει ένα ληφθέν από το περιβάλλον σήμα σε ένα

σήμα υψηλότερης ποιότητας, που καλείται ευρετικό σήμα ενίσχυσης. Έτσι, το δίκτυο μαθαίνει μέσω μιας καθυστερούμενης ενίσχυσης, μέσω της οποίας το δίκτυο παρατηρεί μια ακολουθία ερεθισμάτων που λαμβάνει από το περιβάλλον, από την οποία ο κριτής παράγει το ευρετικό σήμα ενίσχυσης.

Η διαδικασία της ενισχυτικής μάθησης έχει στόχο την εύρεση μιας ακολουθίας ενεργειών που ελαχιστοποιούν μια συνάρτηση τρέχοντος κόστους. Τελικά, το δίκτυο καλείται να βρει μια ακολουθία βημάτων που προβλέπουν και βελτιστοποιούν το αθροιστικό κόστος και όχι απλά το άμεσο κόστος μιας ενέργειας.

### Μη Επιβλεπόμενη Μάθηση

Στη μη επιβλεπόμενη ή αυτο-οργανούμενη μάθηση δεν υπάρχει εκπαιδευτής ούτε κριτής που να επιβλέπει τη διαδικασία εκπαίδευσης. Ωστόσο, υπάρχει ένα ανεξάρτητο μέτρο ποιότητας της αναπαράστασης, το οποίο καλείται να μάθει το νευρωνικό δίκτυο. Με το τρόπο αυτό το νευρωνικό δίκτυο μαθαίνει να σχηματίζει εσωτερικές αναπαραστάσεις στα δεδομένα εκπαίδευσης και να βρίσκει νέα χαρακτηριστικά, δημιουργώντας αυτόματα καινούριες κλάσεις.

Για την εκτέλεση της μη επιβλεπόμενης μάθησης μπορεί να χρησιμοποιηθεί ένας κανόνας ανταγωνιστικής μάθησης. Ένα απλό παράδειγμα τέτοιου δικτύου είναι ένα δίκτυο δύο επιπέδων: το πρώτο επίπεδο λαμβάνει την είσοδο, ενώ οι νευρώνες του δεύτερου ανταγωνίζονται μεταξύ τους για μια "έυκαιρία" να αποκριθούν στα χαρακτηριστικά της εισόδου. Μόνο ένας νευρώνας επικρατεί κάθε φορά (στρατηγική "winner takes it all").

### 3.5.3 Ο Αλγόριθμος Backpropagation

Η διαδικασία με την οποία μαθαίνει ένα νευρωνικό δίκτυο πρόσθιας τροφοδότησης με επιβλεπόμενη μάθηση συνιστάται στην ελαχιστοποίηση ενός σφάλματος μεταξύ της πραγματικής εξόδου και της επιθυμητής εξόδου (συνάρτηση απώλειας). Αυτό συμβαίνει μέσω της προσαρμογής των συναπτικών βαρών του δικτύου παράδειγμα προς παράδειγμα (on-line μάθηση). Η θέαση όλων των παραδειγμάτων ενός συνόλου εκπαίδευσης από το μοντέλο συνιστά μια εποχή (epoch). Η δημοτικότητα της μεθόδου αυτής έχει βελτιωθεί ακόμα περισσότερο με την ανάπτυξη του αλγορίθμου backpropagation (BK). Ο αλγόριθμος backpropagation επιτρέπει την προσαρμογή των βαρών όλων των νευρώνων ενός δικτύου ενώ παράλληλα υπολογίζει το ποσοστό του συνολικού σφάλματος που αντιστοιχεί στα βάρη κάθε νευρώνα ακόμα και των κρυφών επιπέδων με μια αναδρομική διαδικασία. Η διόρθωση των βαρών που συνδέει έναν νευρώνα  $i$  με έναν άλλο νευρώνα  $j$  δίνεται από τον κανόνα Δέλτα:

$$\Delta w_{ji}(n) = \eta \times \delta_j(n) \times y_i(n) \quad (3.1)$$

όπου

- $\Delta w_{ij}(n)$  η διόρθωση βάρους (κατά την επανάληψη  $n$ )
- $\eta$  η παράμετρος του ρυθμού μάθησης

- $\delta_j(n)$  η τοπική κλίση του νευρώνα  $j$
- $y_i(n)$  το σήμα εισόδου του νευρώνα  $j$  (που αποτελεί σήμα εξόδου του νευρώνα  $i$ )

Η βασική ιδέα του αλγορίθμου είναι ότι κάνει δύο περάσματα υπολογισμών: ένα πέρασμα με κατεύθυνση προς τα εμπρός και ένα πέρασμα με κατεύθυνση προς τα πίσω. Στο πρώτο πέρασμα τα συναπτικά βάρη μένουν αμετάβλητα σε όλη την έκταση του δικτύου, ενώ υπολογίζονται νευρώνα προς νευρώνα τα λειτουργικά σήματα του δικτύου και λαμβάνεται το σήμα εξόδου από το τελευταίο επίπεδο. Η έξοδος αυτή συγκρίνεται με την επιθυμητή απόκριση και υπολογίζεται το μεταξύ τους σφάλμα. Δηλαδή το πέρασμα προς το εμπρός ξεκινάει από το πρώτο κρυφό επίπεδο, παρουσιάζοντάς του το διάνυσμα εισόδου και καταλήγει στην έξοδο με τον υπολογισμό του σφάλματος κάθε νευρώνα του επιπέδου εξόδου.

Το πέρασμα με κατεύθυνση προς τα πίσω ξεκινά από το επίπεδο εξόδου και στέλνει το σήμα του σφάλματος προς τα πίσω στα κρυφά επίπεδα του δικτύου, υπολογίζοντας αναδρομικά την τοπική κλίση κάθε νευρώνα. Η αναδρομική αυτή διαδικασία ενημερώνει τα συναπτικά βάρη σε κάθε επίπεδο σύμφωνα με τον κανόνα Δέλτα, όπου οι τοπικές κλίσεις υπολογίζονται με τη βοήθεια των πρώτων παραγώγων των αντίστοιχων εξόδων, όπως περιγράφεται αναλυτικά στη συνέχεια. Με δεδομένα τα  $\delta$  για τους νευρώνες εξόδου υπολογίζονται οι κλίσεις για τους νευρώνες του τελευταίου κρυφού επιπέδου και αναδρομικά προς τα πίσω και για τα υπόλοιπα επίπεδα.

### Αναλυτική Παρουσίαση των Σχέσεων του Αλγορίθμου

Έστω ένας νευρώνας  $j$  που αποτελεί μέρος ενός ευρύτερου νευρωνικού δικτύου. Το τοπικό πεδίο του στην επανάληψη  $n$  περιγράφεται από τη σχέση

$$v_j(n) = \sum_{i=0}^m w_{ji}(n)y_i(n)$$

όπου  $m$  ο συνολικός αριθμός εισόδων (χωρίς την πόλωση). Το βάρος  $w_{j0}$  αντιστοιχεί με την πόλωση  $b_j$  για σταθερή είσοδο  $y_0 = +1$ . Το λειτουργικό σήμα που εμφανίζεται στην έξοδο του ίδιου νευρώνα είναι

$$y_j(n) = \phi_j(v_j(n))$$

Ο αλγόριθμος ΒΚ εφαρμόζει διόρθωση βαρών όπως ορίστηκε παραπάνω η οποία είναι ανάλογη με τη μερική παράγωγο της στιγμιαίας ενέργειας σφάλματος του νευρώνα ως προς το βάρος

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_i(n)} \frac{\partial y_i(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)}$$

όπου

- $E(n)$  η στιγμιαία ενέργεια σφάλματος του νευρώνα με  $E(n) = \frac{1}{2}e_j^2(n)$
- $e_j(n)$  το σήμα σφάλματος όπου  $e_j(n) = d_j(n) - y_j(n)$  με  $d_j(n)$  την επιθυμητή απόκριση και  $y_j(n)$  την πραγματική απόκριση του νευρώνα  $j$  (κατά την επανάληψη  $n$ )

- $y_i(n)$  η είσοδος του νευρώνα  $j$  (από τον νευρώνα  $i$ ),  $v_j$  το τοπικό του πεδίο και  $w_{ji}$  τα βάρη από τον νευρώνα  $i$  στον  $j$

Η παράγωγος αυτή αντιπροσωπεύει έναν συντελεστή ευαισθησίας και καθορίζει την κατεύθυνση αναζήτησης στον χώρο βαρών για το συναπτικό βάρος  $w_{ji}$ .

Από τις παραπάνω εξισώσεις προκύπτει

$$\frac{\partial E(n)}{\partial w_{ji}} = -e_j(n)\phi'_j(v_j(n))y_i(n)$$

Η διόρθωση των βαρών γίνεται σύμφωνα με την εξίσωση

$$\Delta w_{ji} = -\eta \frac{\partial E(n)}{\partial w_{ji}} = \eta \delta_j(n) y_i(n)$$

όπου  $\eta$  ο ρυθμός μάθησης του αλγορίθμου και  $\delta_j(n)$  η τοπική κλίση με

$$\delta_j(n) = e_j(n)\phi'_j(v_j(n)) = p d v E(n) y_i(n) \phi'_j(v_j(n))$$

Για να υπολογίσει κανείς την τοπική κλίση χρειάζεται να ξέρει την παράγωγο της συνάρτησης ενεργοποίησης (που υπολογίζεται εύκολα) και το σήμα σφάλματος, για το οποίο πρέπει να λάβει υπόψη δύο περιπτώσεις:

- Ο νευρώνας  $j$  είναι νευρώνας εξόδου και τροφοδοτείται με τη δική του επιθυμητή απόκριση. Τότε το σφάλμα υπολογίζεται απευθείας από την εξίσωση  $e_j(n) = d_j(n) - y_j(n)$ .
- Ο νευρώνας  $j$  ανήκει σε κρυφό επίπεδο και συνεπώς δεν υπάρχει προκαθορισμένη επιθυμητή απόκριση γι' αυτόν. Στην περίπτωση αυτή το σφάλμα καθορίζεται αναδρομικά, δουλεύοντας προς τα πίσω, με βάση τα σφάλματα όλων των νευρώνων με τους οποίους ο  $j$  συνδέεται άμεσα. Αποδεικνύεται ότι για κρυφό νευρώνα  $j$  η τοπική κλίση δίνεται από τον τύπο:

$$\delta_j(n) = \phi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n)$$

όπου  $\delta_k(n)$  οι τοπικές κλίσεις όλων των νευρώνων που βρίσκονται στο αμέσως βαθύτερο επίπεδο από τον νευρώνα  $j$  και συνδέονται άμεσα με αυτόν και  $w_{kj}(n)$  τα συναπτικά βάρη που σχετίζονται με αυτές τις συνδέσεις. Η εξίσωση αυτή είναι γνωστή ως τύπος οπισθοδιάδοσης.

### Κριτήρια Τερματισμού

Γενικά, δε μπορεί να αποδειχτεί ότι ο αλγόριθμος backpropagation συγκλίνει και δεν υπάρχουν καλά ορισμένα κριτήρια για τον τερματισμό του. Ωστόσο, υπάρχουν κάποια λογικά κριτήρια σύμφωνα με τα οποία τερματίζεται η διαδικασία προσαρμογής των βαρών. Τα κριτήρια αυτά στηρίζονται στις ιδιότητες των τοπικών και του ολικού ελαχίστου μιας επιφάνειας σφάλματος.

Έστω ότι το διάνυσμα βαρών  $\mathbf{w}^*$  συμβολίζει ένα ελάχιστο. Μια αναγκαία συνθήκη για τον παραπάνω ισχυρισμό είναι η κλίση της επιφάνειας σφάλματος ως προς τα βάρη να είναι μηδέν σε αυτό το σημείο. Κατά συνέπεια, ένα εύλογο κριτήριο σύγκλισης είναι: *Ο αλγόριθμος BK θεωρείται ότι συγκλίνει όταν η Ευκλείδεια νόρμα του διανύσματος κλίσης φτάσει σε ένα επαρκώς μικρό κατώφλι*[21].

Μια άλλη ιδιότητα ενός ελαχίστου είναι ότι σε αυτό το σημείο η συνάρτηση κόστους είναι στατική. Συνεπώς, το κριτήριο τερματισμού διατυπώνεται ως: *Ο αλγόριθμος BK θεωρείται ότι συγκλίνει όταν ο ρυθμός μεταβολής της συνάρτησης κόστους ανά εποχή είναι επαρκώς μικρός*[21].

## Κεφάλαιο 4

# Συνελικτικά και Γεννητικά Νευρωνικά Δίκτυα

### 4.1 Συνελικτικά Δίκτυα

Τα συνελικτικά δίκτυα (convolutional neural networks - CNNs) είναι μια ειδική κατηγορία νευρωνικών δικτύων που εξειδικεύονται στην επεξεργασία δεδομένων με τοπολογία πλέγματος, όπως για παράδειγμα χρονοσειρές (που μπορεί κανείς να τις σκεφτεί ως πλέγματα μιας διάστασης) ή εικόνες (που αποτελούν δύο διαστάσεων πλέγματα από εικονοστοιχεία). Η ονομασία τους οφείλεται στο ότι χρησιμοποιούν την πράξη της συνέλιξης και όχι πολλαπλασιασμό πινάκων τουλάχιστον σε ένα στρώμα τους.

#### 4.1.1 Η Συνέλιξη

Η συνέλιξη είναι μια γραμμική πράξη ανάμεσα σε δύο συναρτήσεις μιας πραγματικής τιμής. Έστω πραγματική συνάρτηση  $x(t)$  μιας πραγματικής μεταβλητής  $t$  και συνάρτηση  $w(a)$  μιας πραγματικής μεταβλητής  $a$ . Η πράξη της συνέλιξης ορίζεται ως:

$$s(t) = \int x(a)w(t-a)da$$

Συνήθως, η συνέλιξη συμβολίζεται με αστερίσκο:

$$s(t) = (x * w)(t)$$

Σε γενικές γραμμές, η συνέλιξη ορίζεται για οποιεσδήποτε συναρτήσεις για τις οποίες το παραπάνω ολοκλήρωμα έχει νόημα. Στα συνελικτικά δίκτυα ο πρώτος όρος (συνάρτηση  $x$ ) συνήθως ονομάζεται **είσοδος** (input) και ο δεύτερος (συνάρτηση  $w$ ) **πυρήνας** (kernel) ή **φίλτρο** (filter). Το αποτέλεσμα αποκαλείται **χάρτης χαρακτηριστικών** (feature map).

Στην πράξη, στα υπολογιστικά συστήματα οι συναρτήσεις δεν είναι συνεχείς αλλά παίρνουν

διακριτές τιμές. Έτσι, η πράξη της συνάρτησης για διακριτές συναρτήσεις ορίζεται ως:

$$s(t) = (x * w)(t) = \sum_{a=-\infty}^{\infty} x(a)w(t-a)$$

Στις εφαρμογές μηχανικής μάθησης η είσοδος είναι συχνά ένας πολυδιάστατος πίνακας δεδομένων ενώ ο πυρήνας είναι ένας πολυδιάστατος πίνακας με εκπαιδευσιμες παραμέτρους. Επειδή οι πίνακες αυτοί είναι πολυδιάστατοι, η συνέλιξη μπορεί να γίνει σε περισσότερους από έναν άξονες ταυτόχρονα. Για παράδειγμα, έστω μια δισδιάστατη είσοδος  $I$  και ένας δισδιάστατος πυρήνας  $K$ . Η δισδιάστατη συνέλιξη διατυπώνεται ως:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i-m, j-n) = \sum_m \sum_n I(i-m, j-n)K(m, n)$$

Η παραπάνω ισότητα ισχύει λόγω της αντιμεταθετικής ιδιότητας της συνέλιξης.

Στην πραγματικότητα, μπορεί κανείς να σκεφτεί τη συνέλιξη ως μια μετατόπιση του πυρήνα πάνω από την είσοδο. Σε κάθε μετατόπιση υπολογίζεται το άθροισμα των γινομένων των παραμέτρων του πυρήνα επί τις τιμές στις αντίστοιχες θέσεις της εισόδου. Αυτό γίνεται κατανοητό στην εικόνα 4.1. Η πράξη αυτή ονομάζεται cross-correlation και φέρει ίδια αποτελέσματα με τη συνέλιξη, με τη διαφορά ότι δεν αντιστρέφεται ο πυρήνας, όπως συμβαίνει στην συνέλιξη και γίνεται εύκολα αντιληπτό από το αρνητικό πρόσημο στον ορισμό της.


#### 4.1.2 Πλεονεκτήματα Συνελικτικών Νευρωνικών Δικτύων

Οι λόγοι για να διαλέξει κανείς μια αρχιτεκτονική με συνελικτικό δίκτυο είναι ποικίλοι. Οι σημαντικότεροι είναι οι ακόλουθοι:

##### Αραιοί Πίνακες Βαρών

Τα κλασικά νευρωνικά δίκτυα υπολογίζουν τους πίνακες βαρών τους κάνοντας πολλαπλασιασμούς μεταξύ πινάκων με μια ξεχωριστή παράμετρο που περιγράφει την αλληλεπίδραση μεταξύ εισόδου και εξόδου. Αυτό σημαίνει ότι κάθε μονάδα εξόδου αλληλεπιδρά με κάθε νευρώνα εισόδου. Οι συνελικτικοί νευρώνες, ωστόσο, έχουν περιορισμένες αλληλεπιδράσεις. Αυτό επιτυγχάνεται με το να δίνεται ένας πυρήνας με μικρότερες διαστάσεις από την είσοδο. Για παράδειγμα, στην περίπτωση επεξεργασίας εικόνας, η είσοδος μπορεί να απαρτίζεται από χιλιάδες εικονοστοιχεία, αλλά ακόμα και ένας πυρήνας δεκάδων ή εκατοντάδων εικονοστοιχείων μπορεί να εντοπίσει χρήσιμα χαρακτηριστικά, όπως ακμές και γωνίες. Αυτό έχει ως αποτέλεσμα μείωση του πλήθους των εκπαιδευσιμων παραμέτρων που πρέπει να αποθηκευτούν, πράγμα που μειώνει τις ανάγκες μνήμης του μοντέλου αλλά και βελτιώνει τη στατιστική απόδοση. Ακόμα, χρειάζονται λιγότερες πράξεις για να υπολογιστεί η έξοδος, πράγμα που μειώνει την ανάγκη σε υπολογιστικούς πόρους που χρειάζεται το μοντέλο.





Σχήμα 4.1: Δισδιάστατη συνέλιξη. Η έξοδος περιορίζεται μόνο σε τμήματα στα οποία ο πυρήνας καλύπτει πλήρως την είσοδο. Σε αυτή την περίπτωση ονομάζεται “έγκυρη” (valid). Πηγή:[14]

### Διαμοιρασμός Παραμέτρων

Σε ένα κλασικό νευρωνικό δίκτυο κάθε παράμετρος του πίνακα συναπτικών βαρών χρησιμοποιείται μια μόνο φορά για τον υπολογισμό της εξόδου ενός επιπέδου. Πολλαπλασιάζεται με ένα μοναδικό στοιχείο της εισόδου και δε χρησιμοποιείται ξανά. Αντίθετα, στα συνελικτικά δίκτυα κάθε στοιχείο του πυρήνα χρησιμοποιείται σε κάθε θέση της εισόδου (εκτός ίσως από τα ακριανά σημεία). Ο διαμοιρασμός αυτός των παραμέτρων πρακτικά σημαίνει πως αντί το δίκτυο να μαθαίνει ένα ξεχωριστό σύνολο παραμέτρων για κάθε θέση, το δίκτυο μαθαίνει ένα μοναδικό σύνολο για όλη την τοπολογία. Αυτό κάνει τη συνέλιξη πολύ πιο αποδοτική όσον αφορά στους αποθηκευτικούς πόρους από τον κλασικό πολλαπλασιασμό πινάκων.

### Ισοδύναμες Αναπαραστάσεις

Ο παραπάνω τρόπος διαμοιρασμού παραμέτρων προκαλεί σε κάθε συνελικτικό στρώμα ένα χαρακτηριστικό που ονομάζεται *ισοδυναμία μετατόπισης*. Μια συνάρτηση  $f(x)$  είναι ισοδύναμη με μια συνάρτηση  $g(x)$  όταν ισχύει  $f(g(x)) = g(f(x))$ . Αν σε ένα συνελικτικό επίπεδο η συνάρτηση  $g$  είναι μια συνάρτηση που μετατοπίζει την είσοδο τότε η συνάρτηση αυτή είναι ισοδύναμη με τη συνέλιξη (με την έννοια της αντιμετάθεσης).

Έστω μια εικόνα  $I$  που εφαρμόζεται ως είσοδος σε ένα συνελικτικό επίπεδο και μια συνάρτηση  $I'(x, y) = g(I) = I(x - 1, y)$  η οποία μετατοπίζει κάθε εικονοστοιχείο μια θέση προς τα δεξιά. Αν κάποιος εφαρμόσει στην εικόνα πρώτα τη μετατόπιση και έπειτα τη συνέλιξη θα έχει το ίδιο αποτέλεσμα με το να εφαρμόσει πρώτα τη συνέλιξη και έπειτα τη συνάρτηση  $g$ . Αυτό σημαίνει ότι μια συνάρτηση μετατόπισης και η συνέλιξη είναι ισοδύναμες ως προς τη μετάθεση.

Η πρακτική σημασία αυτής της ιδιότητας είναι ότι η συνέλιξη σχηματίζει έναν χάρτη για το πού βρίσκονται στο χώρο διάφορα χαρακτηριστικά της εισόδου. Αν ένα αντικείμενο της εικόνας εισόδου μετακινηθεί, η αντίστοιχη αναπαράσταση στην έξοδο θα μετακινηθεί με τον ίδιο τρόπο και σε ίση ποσότητα. Αυτό είναι χρήσιμο όταν γνωρίζει κανείς έναν μικρό πυρήνα ο οποίος προσφέρει χρήσιμες ιδιότητες όταν εφαρμοστεί σε ολόκληρη την εικόνα. Για παράδειγμα, στην ανάλυση εικόνων είναι χρήσιμος ο εντοπισμός ακμών στο πρώτο επίπεδο ενός συνελικτικού δικτύου. Παντού στην εικόνα εμφανίζονται περίπου οι ίδιες ακμές, συνεπώς είναι χρήσιμος ο διαμοιρασμός παραμέτρων σε ολόκληρη την εικόνα.

Η ιδιότητα αυτή δεν ισχύει σε οποιονδήποτε μετασχηματισμό της εικόνας, όπως ισχύει στη μετατόπιση. Για άλλους μετασχηματισμούς χρησιμοποιούνται άλλες τεχνικές.

#### 4.1.3 Τα Στάδια ενός Συνελικτικού Επιπέδου

Ένα τυπικό συνελικτικό στρώμα αποτελείται από τρία στάδια: το πρώτο υπολογίζει τη **συνέλιξη**, όπως έχει περιγραφεί παραπάνω, το δεύτερο περνάει το αποτέλεσμα από μια **μη γραμμική συνάρτηση**, όπως για παράδειγμα η ReLU. Στο τρίτο στάδιο η έξοδος υφίσταται μια **ομαδοποίηση (pooling)**.

Μια συνάρτηση ομαδοποίησης αντικαθιστά την έξοδο του πλέγματος σε ένα συγκεκριμένο σημείο (που έχει προκύψει από τη συνέλιξη και έχει περάσει από τη μη γραμμική συνάρτηση) με κάποιο στατιστικό δείκτη των γειτονικών εξόδων. Για παράδειγμα, η συνάρτηση max pooling φέρει ως αποτέλεσμα το μέγιστο μεταξύ γειτονικών εικονοστοιχείων σε μια ορθογώνιου σχήματος γειτονιά.

Οι συναρτήσεις ομαδοποίησης χρησιμοποιούνται κατά κύριο λόγο επειδή καθιστούν τις αναπαραστάσεις στην έξοδο σχεδόν αμετάβλητες σε αλλαγές της εισόδου. Αν δηλαδή ένα αντικείμενο στην εικόνα μετατοπιστεί κατά πολύ λίγο το αποτέλεσμα της ομαδοποίησης δε θα αλλάξει. Η ιδιότητα αυτή είναι ιδιαίτερα χρήσιμη στην περίπτωση που αναζητείται η παρουσία κάποιου χαρακτηριστικού της εισόδου και όχι η ακριβής τοποθεσία του. Παράλληλα, η ομαδοποίηση μπορεί να μειώσει τις διαστάσεις της εισόδου, πράγμα που είναι χρήσιμο σε αρχιτεκτονικές όπως οι συνελικτικοί αυτοκωδικοποιητές.

Στις πιο σύγχρονες αρχιτεκτονικές είναι προτιμητέο η μείωση των διαστάσεων να γίνεται πάλι με **συνέλιξη**, επειδή οι παράμετροί της μπορούν να εκπαιδευτούν και δεν είναι σταθερές όπως στην ομαδοποίηση. Η μείωση της διαστατικότητας γίνεται με τη μετατόπιση του πυρήνα πάνω στην είσοδο με βήμα (stride) μεγαλύτερο από 1. Έτσι, η προκύπτουσα έξοδος έχει διαστάσεις μικρότερες από την είσοδο. Οι σύγχρονες αρχιτεκτονικές περιλαμβάνουν συνήθως και κάποιο ή κάποια από τα παρακάτω στάδια:

### Κανονικοποίηση Δέσμης (Batch Normalization)

Η εκπαίδευση των νευρωνικών δικτύων γίνεται σε δέσμες (batches), δηλαδή τυχαία δείγματα από ένα σύνολο δεδομένων εκπαίδευσης. Σκοπός αυτού του σταδίου είναι η κανονικοποίηση της δέσμης έτσι ώστε οι έξοδοι να έχουν μέση τιμή κοντά στο 0 και τυπική απόκλιση κοντά στο 1. Κατά την εκπαίδευση του δικτύου η πράξη που εκτελεί το στάδιο αυτό είναι[2]:

$$normalized\_batch = \frac{batch - mean(batch)}{var(batch) + \epsilon} \cdot \gamma + \beta$$

όπου

- $batch$  η υπό εξέταση δέσμη
- $normalized\_batch$  το αποτέλεσμα της κανονικοποίησης
- $mean(\cdot)$  ο μέσος όρος
- $var(\cdot)$  η τυπική απόκλιση
- $\epsilon$  μια μικρή σταθερά
- $\gamma, \beta$  εκπαιδευσιμες παράμετροι

Κατά το στάδιο πρόβλεψης του δικτύου, δεν υπολογίζονται ο μέσος όρος και η τυπική απόκλιση της δέσμης αλλά χρησιμοποιούνται οι τιμές που το δίκτυο έχει μάθει κατά την εκπαίδευση.

Συνήθως το στάδιο αυτό πραγματοποιείται πριν το πέρασμα από τη μη γραμμική συνάρτηση. Έχει αποδειχτεί ότι το στάδιο αυτό βοηθά στην σταθεροποίηση της διαδικασίας εκπαίδευσης, με αποτέλεσμα το δίκτυο να μαθαίνει γρηγορότερα και πιο αποτελεσματικά.

### Dropout

Το στάδιο του dropout συνήθως εφαρμόζεται ύστερα από όλα τα υπόλοιπα. Το στρώμα αυτό θέτει κάποια διανύσματα της εισόδου του ίσα με 0, με τυχαίο τρόπο με συγκεκριμένη αναλογία (rate) σε κάθε βήμα εκπαίδευσης. Η αναλογία αυτή ορίζεται κατά τη σχεδίαση του δικτύου. Οι τιμές των μη μηδενικών εισόδων πολλαπλασιάζονται κατά παράγοντα  $\frac{1}{1-rate}$  έτσι ώστε το άθροισμα όλων των διανυσμάτων να παραμείνει αμετάβλητο. Αυτό συμβαίνει μόνο κατά την εκπαίδευση και όχι στη λειτουργία πρόβλεψης του νευρωνικού δικτύου[3].

Ο λόγος ύπαρξης αυτού του σταδίου είναι γιατί αποτρέπει ένα νευρωνικό δίκτυο από την υπερεκπαίδευση. Δηλαδή, εμποδίζει το νευρωνικό δίκτυο από το να μάθει με μεγάλη λεπτομέρεια τις δοσμένες εισόδους και έτσι να είναι σε θέση να γενικεύει και για εισόδους που είναι άγνωστες σε αυτό.

## 4.2 Γεννητικά Δίκτυα

Τα γεννητικά δίκτυα ανήκουν κατά κύριο λόγο στην κατηγορία μη επιβλεπόμενης μάθησης. Στόχος τους είναι, με είσοδο κάποια πληροφορία, να παράγουν νέα δεδομένα, που μοντελοποιούν τη δοσμένη πληροφορία με τον καλύτερο δυνατό τρόπο. Συγκεκριμένα, σε γεννητικό δίκτυο παρουσιάζονται δεδομένα  $x$  με μια άγνωστη κατανομή  $p_{data}(x)$ . Βασικός στόχος του δικτύου είναι να μάθει μια κατανομή  $p_{model}(x)$  η οποία προσεγγίζει την προηγούμενη με όσο πιο ακριβή τρόπο γίνεται. Έτσι, το δίκτυο είναι σε θέση να δημιουργεί καινούρια δεδομένα τα οποία έχουν ίδια (ή σχεδόν ίδια) κατανομή με τα αρχικά. Ο πιο συστηματικός τρόπος για να βρεθεί η ζητούμενη προσέγγιση είναι να υπάρξει μια παραμετρική συνάρτηση  $p_{model}(x; \theta)$  η οποία ελέγχεται από την παράμετρο  $\theta$  και ψάχνει για μια τιμή της παραμέτρου η οποία καθιστά τις δύο κατανομές όσο πιο όμοιες γίνεται. Μια δημοφιλής πρακτική για να βρεθεί αυτή η παράμετρος είναι μέσω της εκτίμησης μέγιστης πιθανοφάνειας, όπως αυτή ορίζεται στη Στατιστική[13].

Τα γεννητικά δίκτυα είναι σε θέση ακόμα να ευρίσκουν μια υπό συνθήκη κατανομή  $p(x|y)$  όπου δεδομένης μιας εξόδου  $y$  το δίκτυο επιζητεί την κατανομή της αντίστοιχης εισόδου που οδηγεί σε αυτή την έξοδο. Τότε τα δίκτυα ονομάζονται υπό συνθήκη γεννητικά δίκτυα.

Στο πεδίο της μηχανικής μάθησης έχουν αναπτυχθεί τρεις μεγάλες κατηγορίες γεννητικών δικτύων: οι μηχανές boltzmann, οι variational autoencoders και τα γεννητικά ανταγωνιστικά δίκτυα.

## 4.3 Γεννητικά Ανταγωνιστικά Δίκτυα

Τα γεννητικά ανταγωνιστικά δίκτυα είναι μια ειδική κατηγορία των γεννητικών δικτύων. Τα γεννητικά ανταγωνιστικά δίκτυα Generative Adversarial Networks - GANs προτάθηκαν το 2014 από τους Goodfellow et. al.[13] και βασίζονται σε ένα παίγνιο (με την έννοια της θεωρίας παιγνίων). Σε αυτά τα δίκτυα ένας δημιουργός (generator) ανταγωνίζεται έναν αντίπαλο. Στην απλούστερη μορφή τους ο δημιουργός (που συνήθως είναι ένα νευρωνικό δίκτυο) λαμβάνει στην είσοδο ένα τυχαίο διάνυσμα  $z$  και παράγει ένα δείγμα  $x$  σύμφωνα με μια παραμετρική συνάρτηση  $x = g(z; \theta^{(g)})$  με παράμετρο  $\theta^{(g)}$ . Το αντίπαλο δίκτυο, που ονομάζεται διευκρινιστής (discriminator) επιχειρεί να διακρίνει μεταξύ “πραγματικών” παραδειγμάτων που προέρχονται από το σύνολο δεδομένων της εκπαίδευσης και μεταξύ παραδειγμάτων που παράγει ο δημιουργός, τα οποία θεωρούνται “ψεύτικα”. Ο διευκρινιστής εξάγει μια πιθανότητα  $d(x; \theta^{(d)})$  η οποία μεταφράζεται στην πιθανότητα ένα δείγμα  $x$  να είναι ένα πραγματικό παράδειγμα του συνόλου δεδομένων εκπαίδευσης και όχι ένα παραγόμενο παράδειγμα που εξήγαγε ο δημιουργός.

Ο απλούστερος τρόπος για να εκπαιδευτεί ένα τέτοιο δίκτυο είναι το παίγνιο “μηδενικού αθροίσματος” (zero-sum game) κατά το οποίο ορίζεται μια συνάρτηση κόστους του διευκρινιστή ως  $v(\theta^{(g)}, \theta^{(d)})$  ενώ ο δημιουργός παίρνει την αντίθετη συνάρτηση  $-v(\theta^{(g)}, \theta^{(d)})$  ως δική

του συνάρτηση απώλειας. Η συνηθέστερη επιλογή αυτής της συνάρτησης αποτελεί η

$$v(\theta^{(g)}, \theta^{(d)}) = E_{x \sim p_{data}} \log(d(x)) + E_{x \sim p_{model}} \log(1 - d(x))$$

όπου με  $E$  συμβολίζεται η αναμενόμενη ή μέση τιμή της αντίστοιχης τυχαίας μεταβλητής: Έστω διακριτή τυχαία μεταβλητή  $X$  με τιμές στο  $\{a_1, a_2, \dots\}$  και συνάρτηση πυκνότητας πιθανότητας  $f_X$ . Η μέση ή αναμενόμενη τιμή ορίζεται ως:

$$E(X) = \sum_{i=1}^{\infty} a_i f_X(a_i)$$

Η παραπάνω συνάρτηση οδηγεί τον διευκρινιστή στο να μάθει να ταξινομεί πρότυπα σε αληθινά και ψεύτικα. Παράλληλα, ο δημιουργός επιχειρεί να ξεγελάσει τον διευκρινιστή έτσι ώστε ο δεύτερος να πιστεύει ότι τα παραδείγματά του είναι αληθινά. Ιδανικά, κατά τη σύγκλιση τα ψεύτικα δείγματα είναι σχεδόν πανομοιότυπα με τα αληθινά και ισχύει:

$$g^* = \arg \min_g \max_d v(g, d)$$

Η παραπάνω σχέση, ωστόσο, είναι δύσκολο να επιτευχθεί στην πράξη όταν οι συναρτήσεις  $g$  και  $d$  παριστάνουν νευρωνικά δίκτυα και έτσι τα γεννητικά ανταγωνιστικά δίκτυα συνήθως δε συγκλίνουν. Αντί αυτού επιδιώκεται μια ισορροπία μεταξύ διευκρινιστή και δημιουργού. Αυτό συμβαίνει γιατί το δίκτυο εκπαιδεύεται με παραδείγματα και όχι μέσω στατιστικών μεθόδων. Ωστόσο, δεν είναι γνωστός ο βαθμός στον οποίο το πρόβλημα αυτό επηρεάζει τα GANs.

Μια άλλη διατύπωση των συναρτήσεων απώλειας για την εκπαίδευση των γεννητικών ανταγωνιστικών δικτύων σχετίζεται με τη εφαρμογή της εκτίμησης μέγιστης πιθανοφάνειας όταν ο διευκρινιστής βρίσκεται στη βέλτιστη κατάσταση, αλλά και αυτή η πρακτική στην πράξη δεν επιφέρει σύγκλιση. Στα πραγματικά πειράματα μια τρίτη πρακτική έχει δεσπόζουσα θέση: πρακτικά ο δημιουργός στοχεύει στο να μεγιστοποιήσει τη λογαριθμική πιθανότητα ο διευκρινιστής να κάνει λάθος, παρά στο να ελαχιστοποιήσει την πιθανότητα ο διευκρινιστής να είναι σωστός. Αυτό δικαιολογείται από την παρατήρηση ότι η παράγωγος της συνάρτησης κόστους του δημιουργού ως προς την έξοδο του διευκρινιστή παραμένει αρκετά μεγάλη, ακόμα και στην περίπτωση που ο δεύτερος απορρίπτει όλα τα παραδείγματα του δημιουργού ως ψεύτικα, όπως περιγράφεται στο [14].

Αν και η ισορροπία των GANs παραμένει ένα πρόβλημα που ακόμα διερευνάται από την επιστημονική κοινότητα, υπάρχουν πρακτικές εφαρμογές που αφορούν στην αρχιτεκτονική και τις υπερπαραμέτρους, όπως αυτές που παρουσιάζονται στο [15], και καθιστούν την εκπαίδευση επιτυχημένη. Κάποιες αφορούν στη χρήση ισχυρότερων αρχιτεκτονικών, όπως βαθιών συνελικτικών δικτύων, εξάλειψη ντετερμινιστικών παραγόντων, όπως pooling στρωμάτων, χρήση batch normalization επιπέδων μετά από τα συνελικτικά στάδια κ.ά. Ορισμένες τέτοιες πρακτικές αναλύονται κατά την πειραματική διαδικασία στο κεφάλαιο 5.

Η εκπαίδευση των GANs μπορεί να απλοποιηθεί με το σπάσιμο της διαδικασίας σε περισσότερα στάδια τα οποία έχουν να κάνουν με τη σταδιακή αύξηση του επιπέδου λεπτομέρειας που αναζητείται. Είναι δυνατό για ένα GAN να μάθει την κατανομή μιας δεσμευμένης πιθανότητας  $p(x|y)$ , δηλαδή την κατανομή μιας τυχαίας μεταβλητής εισόδου  $x$  δεδομένης της

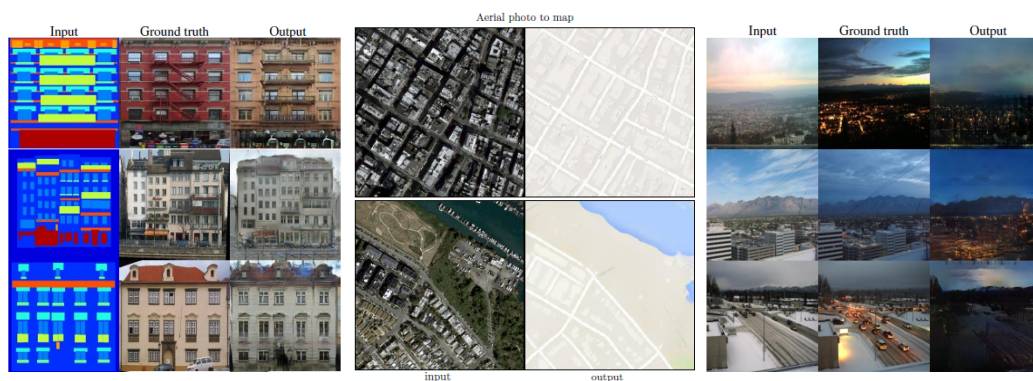
μεταβλητής εξόδου  $y$ . Σε αυτή την περίπτωση τα δίκτυα μετονομάζονται σε υπό συνθήκη γεννητικά ανταγωνιστικά δίκτυα (Conditional GANs). Αυτό έχει πολλές πρακτικές εφαρμογές, οι οποίες αφορούν στην παραγωγή δεδομένων (όπως εικόνων) από ένα συγκεκριμένο dataset τα οποία πληρούν συγκεκριμένες προϋποθέσεις.

### 4.3.1 Δημοφιλείς Εφαρμογές με Ανταγωνιστικά Γεννητικά Δίκτυα

Τα τελευταία χρόνια τα GANs έχουν βρει πολλές πρακτικές εφαρμογές, οι περισσότερες των οποίων αφορούν εικόνες ή βίντεο. Σπανιότερα χρησιμοποιούνται και σε άλλους τομείς, όπως η κρυπτογραφία. Παρακάτω παρουσιάζονται κάποια από τα δημοφιλέστερα μοντέλα GANs και οι εφαρμογές τους.

#### Pix2Pix GAN[20]

Η αρχιτεκτονική του Pix2Pix GAN αποτελεί την έμπνευση αυτής της διπλωματικής εργασίας. Το Pix2Pix GAN είναι ένα δίκτυο που εξειδικεύεται στη “μετάφραση” μιας εικόνας σε μια άλλη (image-to-image translation). Χαρακτηριστικά παραδείγματα αποτελούν η μετατροπή εικόνων κτιρίων από σχέδια σε προσόψεις, η μετατροπή αεροφωτογραφιών σε σχέδια χαρτών ή η εναλλαγή από μέρα σε νύχτα, όπως φαίνεται στην εικόνα 4.2.




Σχήμα 4.2: Εφαρμογές του δικτύου Pix2Pix. Από αριστερά προς τα δεξιά φαίνονται η μετατροπή σχεδίων κτιρίων σε προσόψεις, η μετατροπή αεροφωτογραφιών σε χάρτες, η εναλλαγή ημέρας σε νύχτα. Πηγή:[20]

Αξιοσημείωτη είναι η ευελιξία αυτού του δικτύου, καθώς για όλες τις εφαρμογές που προαναφέρθηκαν χρησιμοποιήθηκε η ίδια αρχιτεκτονική με αλλαγή μόνο του dataset.

#### DCGAN[5]

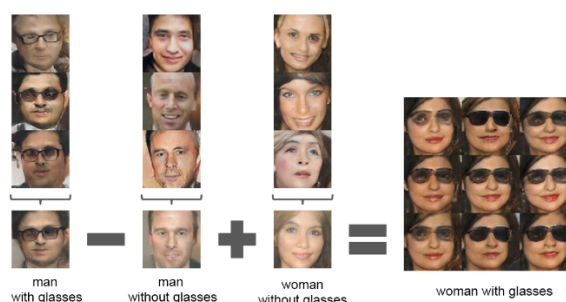
Το ακρωνύμιο προέρχεται από την ονομασία Deep Convolutional Generative Adversarial Network και ήταν από τις πρώτες αρχιτεκτονικές που χρησιμοποίησαν συνελικτικά επίπεδα στα GANs, αντί για ντετερμινιστικές συναρτήσεις χωρικών ομαδοποιήσεων (pooling layers).

Απέδειξαν την υπεροχή αυτής της αρχιτεκτονικής καθώς και τη χρησιμότητα των συνελικτικών δικτύων για εφαρμογές μη επιβλεπόμενης μάθησης (έως τότε τα συνελικτικά δίκτυα χρησιμοποιούνταν για προβλήματα επιβλεπόμενης μάθησης). Στην εικόνα 4.3 φαίνονται εικόνες από υπνοδωμάτια που παράχθηκαν με το DCGAN.



Σχήμα 4.3: Εικόνες υπνοδωματίων που έχουν παραχθεί με το DCGAN. Πηγή:[5]

Σε αυτό το paper απέδειξαν ακόμα τη δυνατότητα πραγματοποίησης αριθμητικής λογικής μεταξύ των διανυσμάτων εισόδου με εκπληκτικά αποτελέσματα, όπως φαίνεται στην εικόνα 4.4.



Σχήμα 4.4: Αριθμητική λογική μεταξύ των διανυσμάτων εισόδου με το DCGAN. Εικόνες Ανδρών με Γυαλιά - Εικόνες Ανδρών + Εικόνες Γυναικών = Εικόνες Γυναικών με Γυαλιά. Πηγή:[5]

### StackGAN[12]

Το δίκτυο αυτό αποδεικνύει τη δυνατότητα παραγωγής αληθοφανών εικόνων από κείμενα με τις αντίστοιχες περιγραφές. Αποτελείται από στοιβαγμένα μεταξύ τους γεννητικά ανταγωνιστικά δίκτυα (όπου η έξοδος του ενός είναι η είσοδος του επόμενου), τα οποία αποτυπώνουν διαφορετικά επίπεδα λεπτομέρειας με τελικό αποτέλεσμα μια εικόνα  $256 \times 256$  εικονοστοιχείων.



Σχήμα 4.5: Εικόνες πουλιών από περιγραφές κειμένων. Στην εικόνα φαίνονται η παραγωγή τους περνώντας μέσα από 2 στάδια, στοίβαγμα το ένα επάνω στο άλλο. Πηγή:[12]

### Πρόβλεψη Επόμενου Πλάνου[8]

Το μοντέλο που προτείνεται εδώ αφορά στην πρόβλεψη μέχρι και ενός δευτερολέπτου ή 24 πλαισίων (frames) κυρίως στατικών στοιχείων μιας εικόνας. Το δίκτυο περιλαμβάνει χωρικά και χρονικά συνελικτικά στρώματα τα οποία μαθαίνουν να ξεχωρίζουν το προσκήνιο από το παρασκήνιο σε βίντεο και εικόνες. Έτσι, είναι σε θέση να προβλέψουν πιθανά μελλοντικά σενάρια για στατικές εικόνες.



Σχήμα 4.6: Στο μοντέλο εισάγεται μια στατική εικόνα και προσπαθεί να προβλέψει τα επόμενα frames. Τα βέλη δείχνουν τη θέση κινούμενων στοιχείων στο χρόνο. Αν και το μοντέλο δεν παράγει το σωστό βίντεο, ωστόσο το παραγόμενο σενάριο είναι πολλές φορές εφικτό. Πηγή:[8]

### Neural Talking Heads Model[10]

Το μοντέλο αυτό είναι σε θέση να παράγει βίντεο μερικών κάδρων (frames) που προσομοιάζουν ομιλούντα πρόσωπα. Πιο συγκεκριμένα, μετά από κατάλληλη εκπαίδευση το δίκτυο αυτό μπορεί να παράξει ένα προσωποποιημένο βίντεο ολίγων κάδρων ενός ομιλούντος προσώπου έχοντας δει μόνο λίγες ή ακόμα και μια μοναδική εικόνα του πορτραίτου του. Τα ίδια εντυπωσιακά αποτελέσματα μπορεί να φέρει ακόμα και με έναν πίνακα ζωγραφικής.






Σχήμα 4.7: Ομιλούντα πρόσωπα παραγόμενα από διάσημα πορτραίτα. Πηγή:[10]

### Adversarial Neural Cryptography[17]

Το δίκτυο αυτό έχει προταθεί από τη Google και σκοπό έχει να δημιουργήσει κρυπτογραφικούς κώδικες χωρίς την ανθρώπινη παρέμβαση. Αν και η αρχιτεκτονική αυτού του δικτύου διαφέρει από τη συνήθη αρχιτεκτονική των γεννητικών ανταγωνιστικών δικτύων, υπό μια έννοια υπάγεται στην ίδια κατηγορία: είναι γεννητικό, αφού παράγει ένα κρυπτογράφημα, όπως επίσης και ανταγωνιστικό αφού αποτελείται από αντιπάλους που αντιπαρατίθενται μεταξύ τους. Συγκεκριμένα, αποτελείται από τρεις παίχτες (καθένας από τους οποίους προσομοιάζεται με ένα νευρωνικό δίκτυο): την Alice, τον Bob και την Eve. Η Alice στέλνει ένα κρυπτογραφημένο μήνυμα στον Bob, δουλειά του οποίου είναι να το αποκρυπτογραφήσει. Παράλληλα η Eve προσπαθεί και εκείνη να αποκρυπτογραφήσει το ίδιο μήνυμα. Μέσα από τη διαδικασία της εκπαίδευσης η Alice μαθαίνει να κρυπτογραφεί μηνύματα με τέτοιον τρόπο ώστε ο Bob να μπορεί να τα αποκρυπτογραφήσει αλλά να είναι αδύνατο να τα διαβάσει η Eve. Αν και οι παραγόμενοι κώδικες δεν είναι το ίδιο περίπλοκοι με αυτούς που έχουν δημιουργηθεί με ανθρώπινη παρέμβαση, αποτελεί ένα πρώτο βήμα για χρήση νευρωνικών δικτύων στην κρυπτογραφία.



Σχήμα 4.8: Η αρχιτεκτονική του μοντέλου. Η Eve προσπαθεί να αναχαιτίσει τα μηνύματα της Alice προς τον Bob. Παράλληλα η Alice κατασκευάζει ένα μοντέλο κρυπτογράφησης που είναι αδύνατο να κατανοήσει η Eve. Πηγή:[17]



## Κεφάλαιο 5

# Προτεινόμενη Μεθοδολογία

### 5.1 Γενική Περιγραφή Προτεινόμενου Πλαισίου

Στόχος της προτεινόμενης μεθόδου αποτελεί η παραγωγή προβλέψεων χρονοσειρών από τις γραφικές τους αναπαραστάσεις με τη χρήση ενός δικτύου μηχανικής μάθησης. Ένα δίκτυο μηχανικής μάθησης εκπαιδεύεται με εικόνες που έχουν προκύψει από τις γραφικές αναπαραστάσεις ενός συνόλου χρονοσειρών, έπειτα από ειδική προεπεξεργασία. Το εκπαιδευμένο δίκτυο καλείται έπειτα να προβλέψει εικόνες χρονοσειρών από ένα σύνολο αξιολόγησης που το νευρωνικό μοντέλο δεν έχει ξαναδεί κατά την εκπαίδευση. Από την έξοδο του μοντέλου λαμβάνονται οι καινούριες εικόνες που αποτελούν τις προβλέψεις πάνω στο σύνολο αξιολόγησης. Για να ελεγχθούν ποσοτικά τα αποτελέσματα χρειάζεται να εξαχθούν οι πραγματικές τιμές των προβλέψεων από τις παραχθείσες εικόνες. Αυτό επιτυγχάνεται με μια αντιστρόφως ανάλογη διαδικασία από αυτή της προεπεξεργασίας. Τέλος, οι εξαγόμενες τιμές αξιολογούνται ως προς συγκεκριμένους δείκτες ακρίβειας.

Τα νευρωνικά μοντέλα που υλοποιήθηκαν για το προτεινόμενο πείραμα ανήκουν σε δύο κατηγορίες: αυτή των αυτοκωδικοποιητών και αυτή των γεννητικών ανταγωνιστικών δικτύων (GANs). Αρχική ιδέα αποτέλεσε η πρόβλεψη μέσω εικόνων με χρήση αυτοκωδικοποιητή. Ο αυτοκωδικοποιητής λαμβάνει στην είσοδο την αποτύπωση των γνωστών παρατηρήσεων μιας χρονοσειράς και εκπαιδεύεται ώστε να απεικονίζει τη ζητούμενη πρόβλεψη σε μια νέα εικόνα (που εξάγεται από την έξοδό του). Κατά την πειραματική διαδικασία παρατηρήθηκε αδυναμία των μοντέλων με αυτοκωδικοποιητή να κατασκευάσουν μια ολοκληρωμένη πρόβλεψη (σύμφωνα με τις προδιαγραφές του πειράματος), έτσι προέκυψε η ιδέα για χρήση μοντέλων GAN ως επέκταση του πειράματος. Η αρχιτεκτονική για τα μοντέλα GAN βασίστηκε σε αυτή των αυτοκωδικοποιητών, με κατάλληλες αλλαγές που προτείνονται από τη βιβλιογραφία.

Η μεθοδολογία που ακολουθήθηκε περιλαμβάνει τα εξής διακριτά βήματα, τα οποία θα αναλυθούν στη συνέχεια:

- **Προεπεξεργασία Εικόνων**

Το στάδιο αυτό περιλαμβάνει την παραγωγή συνόλων δεδομένων που θα χρησιμοποι-

ηθούν για την εκπαίδευση και αξιολόγηση ενός νευρωνικού μοντέλου. Αναπτύσσεται ένας αλγόριθμος ο οποίος μετατρέπει τις χρονοσειρές στις αντίστοιχες γραφικές αναπαραστάσεις οι οποίες αποθηκεύονται σε μορφή εικόνας. Προκαθορίζεται το μέγεθος των γραφικών αναπαραστάσεων, ο ορίζοντας πρόβλεψης και άλλες παράμετροι που αφορούν στην ομοιομορφία των απεικονίσεων που θα εισαχθούν στα μοντέλα.

- **Σχεδίαση Μοντέλου Μηχανικής Μάθησης**

Για την παραγωγή όσο γίνεται πιο ακριβών προβλέψεων η επιλογή της πιο κατάλληλης αρχιτεκτονικής για το μοντέλο μηχανικής μάθησης είναι μείζονος σημασίας. Σχεδιάζεται μοντέλο αυτοκωδικοποιητή αλλά και γεννητικό ανταγωνιστικό δίκτυο, επιλέγεται ο κατάλληλος αριθμός επιπέδων για κάθε δίκτυο, συγκρίνονται και βελτιστοποιούνται έτσι ώστε να βρεθεί η καλύτερη λύση.

- **Εκπαίδευση και Εξαγωγή Προβλέψεων**

Αξιοποιούνται τα παραπάνω δεδομένα για την εκπαίδευση των μοντέλων και παράγονται προβλέψεις πάνω σε δεδομένα αξιολόγησης. Από τις παραχθείσες εικόνες εξάγονται οι αντίστοιχες τιμές των προβλέψεων έτσι ώστε να μπορούν να αξιολογηθούν οι προβλέψεις ποσοτικά.

- **Αξιολόγηση του Μοντέλου**

Εδώ εξάγονται οι τιμές ποιοτικών και ποσοτικών μετρικών με σκοπό τη μέτρηση της ακρίβειας των εξεταζόμενων μοντέλων πάνω στα δεδομένα αξιολόγησης.

## 5.2 Προεπεξεργασία Εικόνων

Για την εκπαίδευση και αξιολόγηση του νευρωνικού δικτύου ορίζονται δύο σύνολα δεδομένων, το σύνολο εισόδου ( $X_{train}$ ) και το σύνολο εξόδου ( $Y_{train}$ ). Τόσο τα σύνολα εκπαίδευσης όσο και τα σύνολα αξιολόγησης αποτελούνται από εικόνες πραγματικών χρονοσειρών και όχι απλώς τυχαίες γραφικές παραστάσεις. Έτσι, είναι απαραίτητη η εύρεση αλγορίθμου για τη δημιουργία εικόνων στην κατάλληλη μορφή.

Αρχικά επιλέγεται ο ορίζοντας πρόβλεψης και οι χρονοσειρές διαχωρίζονται στα ιστορικά δεδομένα (in-sample), τα οποία θεωρούνται γνωστά, και την πρόβλεψη (forecast) που είναι το ζητούμενο άγνωστο μέγεθος. Η είσοδος του νευρωνικού δικτύου λαμβάνει τη γραφική παράσταση των ιστορικών δεδομένων μιας χρονοσειράς ενώ η έξοδος συγκρίνεται με τη γραφική παράσταση των ιστορικών δεδομένων μαζί με την επιθυμητή πρόβλεψη. Για να είναι όσο το δυνατό πιο ομοιόμορφες οι γραφικές παραστάσεις επιλέγεται ένα μέγεθος εισόδου **input size**, το οποίο είναι ίδιο για όλα τα δεδομένα. Χρονοσειρές με μικρότερο μήκος προεκτείνονται προς το παρελθόν με την τεχνική “back casting” με τη μέθοδο Naive, ενώ για εκείνες με μεγαλύτερο μήκος λαμβάνονται υπόψιν οι τελευταίες “input size” μετρήσεις. Στο πείραμα επιλέχθηκε  $input\_size = 18$  ενώ ο ορίζοντας πρόβλεψης  $forecasting\_horizon = 6$ . Το μήκος του ορίζοντα πρόβλεψης επιλέχθηκε με βάση τις επίσημες προδιαγραφές του συνόλου δεδομένων που χρησιμοποιήθηκε για εκπαίδευση και αξιολόγηση των μοντέλων (ετήσια δε-

δομένα του διαγωνισμού M4, βλέπε κεφάλαιο 6). Το μήκος εισόδου καθορίστηκε έτσι ώστε να είναι δυνατή η εξαγωγή 6 προβλέψεων με τα αντίστοιχα δεδομένα εισόδου. Οι κλασικές μέθοδοι προβλέψεων συνιστούν ότι από 18 ιστορικά δεδομένα παράγονται 6 προβλέψεις με ικανοποιητική ακρίβεια.

Στη συνέχεια γίνεται κανονικοποίηση της χρονοσειράς μεταξύ των 0 και 1 και κάθε τιμή της  $x$  αντικαθίσταται με μια νέα τιμή  $x'$  με βάση τον τύπο

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}}$$

όπου  $x_{min}, x_{max}$  η ελάχιστη και η μέγιστη τιμή του δείγματος των ιστορικών δεδομένων αντίστοιχα.

Ακολούθως, η μορφή της κανονικοποιημένης χρονοσειράς σκιαγραφείται με λευκό χρώμα σε μαύρο φόντο. Ο λόγος που επιλέχθηκε ασπρόμαυρη εικόνα αντί για έγχρωμη είναι γιατί το χρώμα στην προκειμένη περίπτωση δεν προσφέρει κάποια πληροφορία. Ζητούμενο είναι η αποτύπωση της μορφής μιας χρονοσειράς και όχι το χρώμα της γραφικής αναπαράστασης. Ακόμα, εξοικονομούνται μνήμη και υπολογιστικοί πόροι κατά τη διαδικασία εκπαίδευσης του δικτύου αφού μια ασπρόμαυρη εικόνα κωδικοποιείται σε έναν διδιάστατο πίνακα με διαστάσεις όσο οι διαστάσεις της εικόνας, ενώ μια έγχρωμη έχει μια επιπλέον διάσταση για τα 3 κανάλια χρωμάτων. Κάθε τιμή του πίνακα αναπαριστά ένα εικονοστοιχείο (pixel). Η επιλογή των δύο χρωμάτων πηγάζει από το γεγονός ότι στην αναπαράσταση RGB το λευκό χρώμα κωδικοποιείται με τη μέγιστη τιμή 255 ενώ το μαύρο με την τιμή 0. Έτσι, είναι προτιμητέο η σημαντική πληροφορία να αναπαριστάται με υψηλότερες τιμές.

Οι άξονες της γραφικής παράστασης ορίζονται χειροκίνητα και είναι ίδιοι για τα σύνολα εισόδου και εξόδου. Τα όρια τίθενται έτσι ώστε στον οριζόντιο άξονα  $X$  να καταγράφονται τόσο οι περίοδοι του in-sample δείγματος όσο και της πρόβλεψης ακόμα και στον σύνολο εισόδου. Οι αρχικές τιμές του κάθετου άξονα  $Y$  βρίσκονται μεταξύ των 0 και 1 λόγω της προηγούμενης κανονικοποίησης όμως αυτός προεκτείνεται με σκοπό να αφήνονται κατάλληλα περιθώρια πάνω και κάτω από τη γραφική παράσταση για να είναι εφικτή η επέκτασή της με νέες τιμές. Τα όρια καθορίζονται από το εκάστοτε σύνολο δεδομένων. Για το προτεινόμενο πλαίσιο, τα όρια των αξόνων ορίζονται ως εξής:

- **Οριζόντιος Άξονας X**


Αντικατοπτρίζει τις  $18 + 6 = 24$  παρατηρήσεις του κάθε δείγματος. Και στα δύο άκρα αφήνονται επιπλέον περιθώρια μήκους 0,5 έτσι ώστε η γραφική παράσταση να είναι καλά ορισμένη μέσα στο κάδρο.

- **Κάθετος Άξονας Y**

Μετά την κανονικοποίηση οι χρονοσειρές έχουν τιμές στο διάστημα  $[0, 1]$ . Έπειτα από πειραματισμούς πάνω στο σύνολο εκπαίδευσης τα όρια του κάθετου άξονα τοποθετούνται στο διάστημα  $[-0, 6, 2, 3]$ . Το άνω περιθώριο αφήνεται μεγαλύτερο, αφού οι χρονοσειρές εξ' ορισμού στην πλειοψηφία τους είναι αύξουσες.

Έτσι, αποθηκεύονται οι δύο τελικές εικόνες διαστάσεων  $(64 \times 64)$  εικονοστοιχείων, όπως φαίνεται στα παραδείγματα της εικόνας 5.1:

- Μια εικόνα που δίνει τη μορφή της χρονοσειράς για τα ιστορικά δεδομένα.
- Μια εικόνα που αναπαριστά ολόκληρη τη χρονοσειρά, μαζί με το τμήμα που καλείται να προβλέψει το μοντέλο.



Σχήμα 5.1: Εικόνες που προκύπτουν μετά από την προεπεξεργασία

Ο παραπάνω αλγόριθμος δίνεται σε ψευδοκώδικα στον αλγόριθμο 1.

## 5.3 Αρχιτεκτονική Μοντέλου

### 5.3.1 Συνελικτικό Μπλοκ

Ορίζουμε το συνελικτικό μπλοκ (convolutional block), που αποτελεί τη δομική μονάδα των πιο περίπλοκων δικτύων που θα κατασκευαστούν στη συνέχεια, ως εξής:

Τρεις διαδοχικά συνδεδεμένες υπομονάδες, όπου η καθεμιά αποτελείται από 1 Συνελικτικό Στρώμα (Convolutional Layer), ένα στρώμα Κανονικοποίησης (Batch Normalization Layer) και ένα στρώμα Ενεργοποίησης (Activation Layer) (δηλαδή μια συνάρτηση ενεργοποίησης). Η συνέλιξη του κάθε συνελικτικού στρώματος γίνεται με φίλτρα διαστάσεων  $(3 \times 3)$ , βήμα 1 και padding 0, που σημαίνει ότι η συνέλιξη δεν ξεφεύγει από τα όρια της αρχικής εικόνας. Έτσι, οι διαστάσεις της εικόνας παραμένουν αναλλοίωτες ενώ διέρχεται από το μπλοκ. Η αρχιτεκτονική αυτή στηρίζεται εν μέρει στην αρχιτεκτονική του δικτύου VGG[16], ενός πολύ δημοφιλούς συνελικτικού δικτύου για ταξινόμηση εικόνων.

Το συνελικτικό αυτό μπλοκ θα χρησιμοποιηθεί ως δομική μονάδα για τον αυτοκωδικοποιητή αλλά και για το γεννητικό ανταγωνιστικό δίκτυο που θα υλοποιηθεί. Η συνάρτηση ενεργοποίησης είναι η ReLU ή η LeakyReLU, ανάλογα με την τοποθεσία του κάθε μπλοκ μέσα στο δίκτυο αλλά και το είδος του δικτύου (αυτοκωδικοποιητής ή GAN). Η αλλαγή στη συνάρτηση ανάλογα με την τοπολογία οφείλεται στη βιβλιογραφία και θα αναλυθεί για κάθε δίκτυο ξεχωριστά.

---

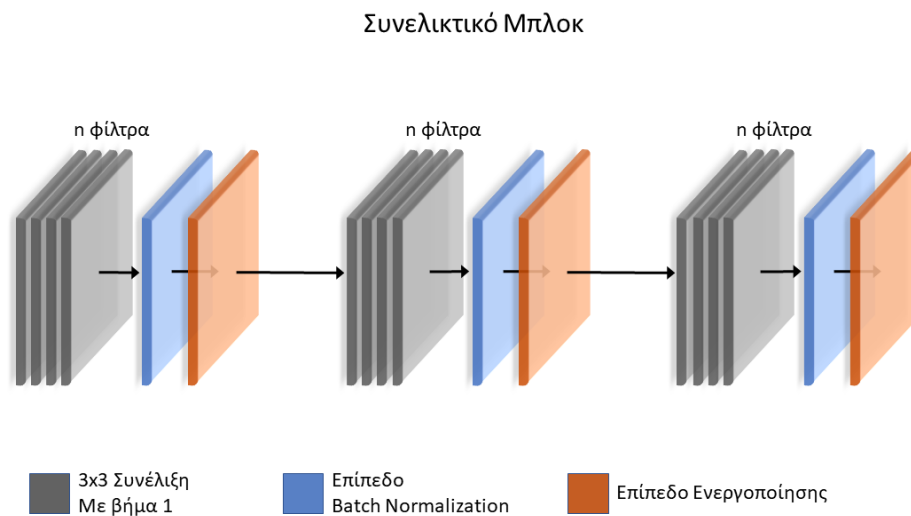
**Αλγόριθμος 1** Προεπεξεργασία Χρονοσειράς σε Εικόνα για Εισαγωγή στο Μοντέλο Μηχανικής Μάθησης

---

**Require:** *input\_size*, *forecasting\_horizon***Require:** *y\_limit\_min*, *y\_limit\_max*

```
1: Procedure PrepareData (timeseries)
2: in_sample = timeseries[1 to input_size]
3: if length(in_sample) < input_size then
4:   in_sample = fill(in_sample, fill_value = in_sample[0])
5: end if
6: forecast = timeseries[input_size + 1 to input_size + forecasting_horizon]
7: x_min = min(in_sample)
8: x_max = max(in_sample)
9: in_sample = (in_sample - x_min) / (x_max - x_min)
10: forecast = (forecast - x_min) / (x_max - x_min)
11:
12: figure1 = plot(in_sample, color='white', background='black')
13: figure1.set_xlim(1, input_size + forecasting_horizon)
14: figure1.set_ylim(y_limit_min, y_limit_max)
15: figure1 = convert_to_image(figure1)
16: figure1 = resize(figure1, (64 × 64))
17:
18: // here we plot the entire timeseries, along with the forecast
19: figure2 = plot(concatenate(in_sample, forecast), color='white', background='black')
20: figure2.set_xlim(1, input_size + forecasting_horizon)
21: figure2.set_ylim(y_limit_min, y_limit_max)
22: figure2 = convert_to_image(figure2)
23: figure2 = resize(figure2, (64 × 64))
24: return figure1, figure2
25: End Procedure
```

---



Σχήμα 5.2: Συνελικτικό Μπλοκ

### 5.3.2 Αυτοκωδικοποιητής

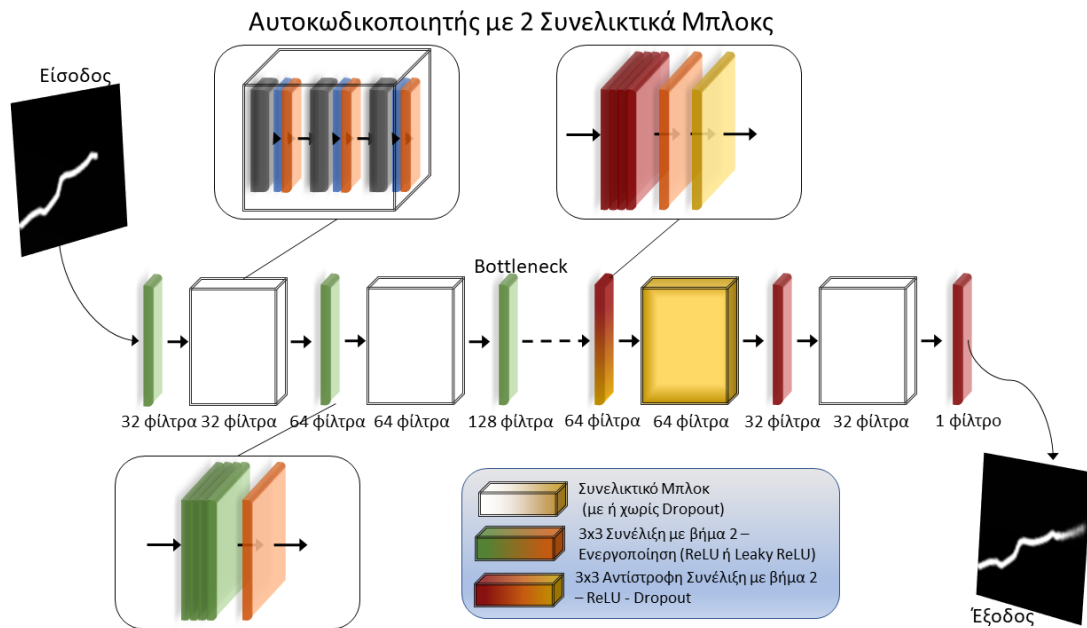
Συνηθισμένη πρακτική για τους συνελικτικούς αυτοκωδικοποιητές είναι η μείωση των διαστάσεων να γίνεται με συνέλιξη με βήμα (stride)  $> 1$  και όχι με κάποιο Pooling Layer. Αντίστοιχα, για την αύξηση των διαστάσεων στον αποκωδικοποιητή χρησιμοποιείται ένα ή περισσότερα στρώματα αντίστροφης συνέλιξης deconvolution layer.

Ο κωδικοποιητής encoder σχηματίζεται με την τοποθέτηση ενός συνελικτικού στρώματος με βήμα 2 ακολουθούμενο από ένα συνελικτικό μπλοκ. Ανάλογα με το επιθυμητό βάθος του αποκωδικοποιητή, τα παραπάνω στρώματα επαναλαμβάνονται μία ή περισσότερες φορές και συνδέονται διαδοχικά μεταξύ τους. Στο bottleneck τοποθετείται ένα ακόμα συνελικτικό στρώμα.

Ο αποκωδικοποιητής decoder είναι συμμετρικός προς τον κωδικοποιητή. Αποτελείται από στρώματα αντίστροφης συνέλιξης με βήμα 2, ακολουθούμενα από συνελικτικά μπλοκ που επαναλαμβάνονται όπως στον κωδικοποιητή. Στα πρώτα στρώματα του αποκωδικοποιητή προστίθεται dropout πιθανότητας 0,5 με σκοπό την αποφυγή της υπερεκπαίδευσης. Στην έξοδο του αυτοκωδικοποιητή τοποθετείται ένα τελευταίο στρώμα αντίστροφης συνέλιξης, με 1 πυρήνα αφού η επιθυμητή εικόνα είναι ασπρόμαυρη και κατά συνέπεια έχει ένα μόνο κανάλι (σε αντίθεση με τις έγχρωμες εικόνες που κωδικοποιούνται με 3 κανάλια).

Ως συνάρτηση ενεργοποίησης για όλα τα στρώματα χρησιμοποιείται η ReLU, με εξαίρεση την έξοδο όπου τη θέση της παίρνει η υπερβολική εφαπτομένη (tanh). Ένα παράδειγμα αυτοκωδικοποιητή με 2 συνελικτικά μπλοκ φαίνεται στην εικόνα 5.3.



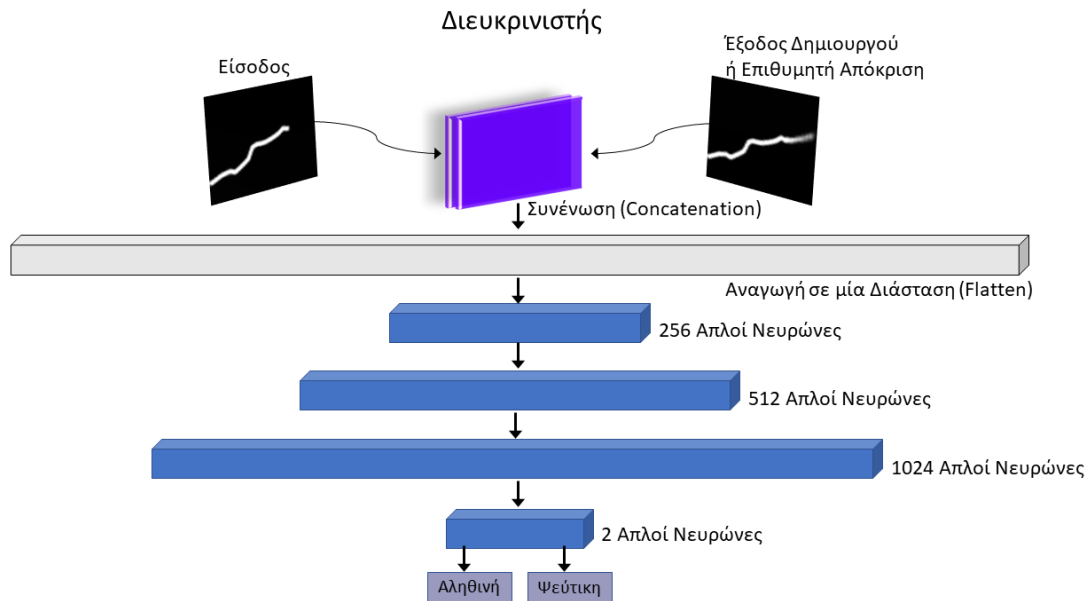


Σχήμα 5.3: Συνελικτικός Αυτοκωδικοποιητής με 2 Συνελικτικά Μπλοκ  
 Συνάρτηση Ενεργοποίησης: ReLU

### 5.3.3 Γεννητικό Ανταγωνιστικό Δίκτυο

Ένα Γεννητικό Ανταγωνιστικό Δίκτυο (Generative Adversarial Network - GAN) αποτελείται από 2 δίκτυα που ανταγωνίζονται μεταξύ τους: τον δημιουργό (generator) και τον διευκρινιστή (discriminator). Ο δημιουργός είναι υπεύθυνος για την εξαγωγή των προβλέψεων, ενώ ο διευκρινιστής φροντίζει να εξετάσει αν η εισαγόμενη σε αυτόν εικόνα είναι πραγματική ή ψεύτικη (δηλαδή η πραγματική έξοδος ή η έξοδος του δημιουργού). Σκοπός του δημιουργού είναι η εξαπάτηση του διευκρινιστή, έτσι ώστε ο δεύτερος να θεωρεί τις εξόδους του πρώτου ως πραγματικές εικόνες. Έτσι, ο δημιουργός χρειάζεται να κατασκευάσει καλά ορισμένες εικόνες χρονοσειρών.

Στόχος είναι η αναπαράσταση όχι μόνο αληθοφανών εικόνων, αλλά εικόνων που μπορούν να αποτελέσουν σωστή πρόβλεψη της εισόδου. Για το λόγο αυτό ο διευκρινιστής λαμβάνει ως είσοδο όχι μόνο την πρόβλεψη (αληθινή ή ψεύτικη) αλλά και την αρχική εικόνα (είσοδος δημιουργού) έτσι ώστε να κρίνει αν η πρόβλεψη είναι πιθανή επέκταση της εισόδου. Ο διευκρινιστής είναι ένα απλό δίκτυο πρόσθιας τροφοδότησης τεσσάρων στρωμάτων. Το τελευταίο επίπεδο έχει 2 νευρώνες, όσες και οι κλάσεις (αληθινή - ψεύτικη) που αναπαριστώνται με κωδικοποίηση one-hot encoding. Η κωδικοποίηση αυτή ορίζει μια αναπαράσταση με δύο τιμές για κάθε έξοδο (αληθινή - ψεύτικη) και θέτει 1 στη κατάλληλη θέση, ανάλογα με την προέλευση της εικόνας, και 0 στις υπόλοιπες. Τα βάρη του διευκρινιστή αρχικοποιούνται με κανονική κατανομή με μέσο όρο 0 και τυπική απόκλιση 0,02. Συνάρτηση ενεργοποίησης είναι η Leaky ReLU, εκτός από το στρώμα εξόδου όπου χρησιμοποιείται η σιγμοειδής. Ένας τέτοιος διευκρινιστής φαίνεται στην εικόνα 5.4.

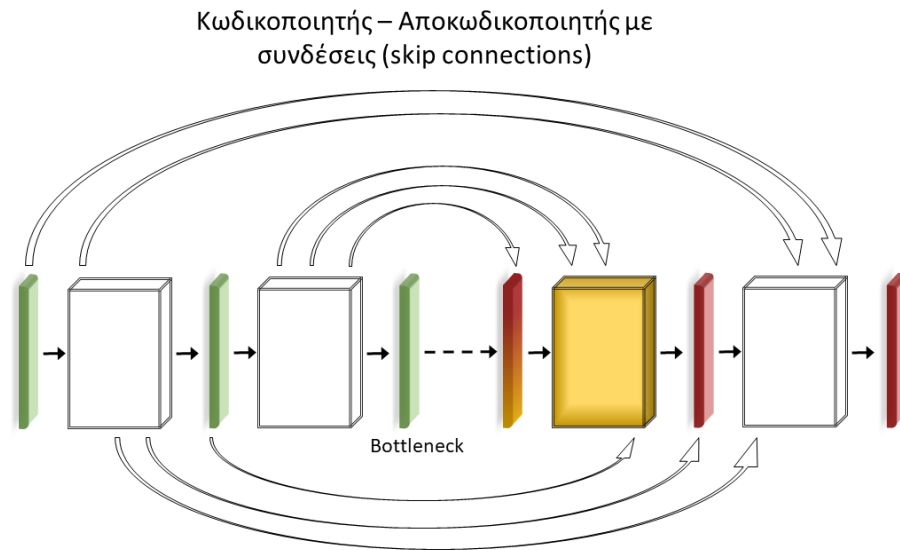


Σχήμα 5.4: Διευκρινιστής

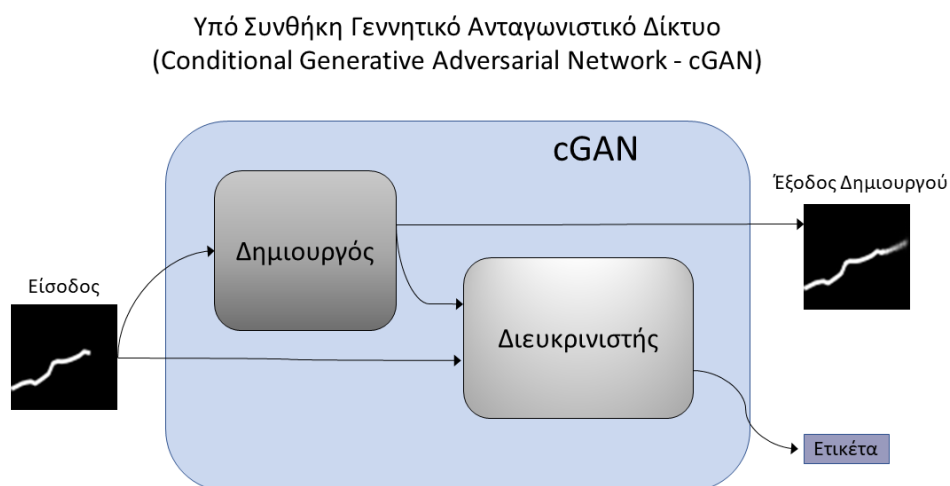
Ο δημιουργός είναι ένας αυτοκωδικοποιητής όπως περιγράφηκε παραπάνω, με τη διαφορά ότι ο κωδικοποιητής λαμβάνει ως συνάρτηση ενεργοποίησης τη Leaky ReLU αντί για απλή ReLU, κατά το προτεινόμενο δίκτυο των Isola και των συνεργατών του[20]. Επειδή η έξοδος με την είσοδο μοιράζονται πολλά κοινά χαρακτηριστικά οι Isola et al. προτείνουν έναν αυτοκωδικοποιητή με συνδέσεις (skip connections) ανάμεσα στα στρώματα  $i$  και  $n - i$  (όπου  $n$  το σύνολο των στρωμάτων του δικτύου). Έτσι, η κοινή αυτή πληροφορία ταξιδεύει απευθείας στα βαθύτερα στρώματα του δικτύου, παρακάμπτοντας το bottleneck. Στην εικόνα 5.5 φαίνεται ένα τέτοιο δίκτυο κωδικοποιητή - αποκωδικοποιητή με συνδέσεις.

Το δίκτυο GAN κατασκευάζεται στοιβάζοντας τα παραπάνω δίκτυα διαδοχικά. Η είσοδος είναι η γραφική παράσταση του in-sample δείγματος ενώ η έξοδος η γραφική παράσταση της πρόβλεψης μαζί με την ετικέτα (αληθινή ή ψεύτικη). Κατά την εκπαίδευση ο δημιουργός κατασκευάζει μια εικόνα η οποία τροφοδοτείται στον διευκρινιστή. Ο διευκρινιστής τη συγκρίνει με την είσοδο και αποφασίζει (με βάση όσα έχει εκπαιδευτεί) αν αποτελεί πραγματική αναπαράσταση χρονοσειράς. Ο δημιουργός θεωρείται επιτυχημένος όταν καταφέρει να ξεγελάσει τον διευκρινιστή. Παράλληλα ο διευκρινιστής εκπαιδεύεται εκ νέου με ψεύτικες και αληθινές εικόνες έτσι ώστε να γίνεται όλο και καλύτερος στο να τις ξεχωρίζει.

Επειδή ο διευκρινιστής λαμβάνει στην είσοδό του και την είσοδο του δημιουργού και όχι μόνο την έξοδό του ή την αληθινή έξοδο (ground truth), το υπό εξέταση δίκτυο εμπίπτει σε μια ειδική κατηγορία που ονομάζεται υπό συνθήκη γεννητικό ανταγωνιστικό δίκτυο (conditional GAN). Η τοπολογία του δικτύου cGAN φαίνεται στην εικόνα 5.6.



Σχήμα 5.5: Κωδικοποιητής - αποκωδικοποιητής με 2 συνελικτικά μπλοκς και skip connections



Σχήμα 5.6: Υπό Συνθήκη Γεννητικό Ανταγωνιστικό Δίκτυο

#### 5.3.4 Υλοποίηση

Η γλώσσα προγραμματισμού που χρησιμοποιήθηκε τόσο κατά την προεπεξεργασία των χρονοσειρών για παραγωγή εικόνων όσο και για την κατασκευή και εκπαίδευση των μοντέλων μηχανικής μάθησης ήταν η Python. Η Python είναι μια γλώσσα πολύ δημοφιλής που προσφέρει πολλά εργαλεία για επεξεργασία μεγάλου όγκου δεδομένων αλλά και για εφαρμογές νευρωνικών μοντέλων. Είναι φιλική προς το χρήστη ενώ εύκολα εξοικειώνεται κανείς με τη

σύνταξη αφού είναι μια γλώσσα υψηλού επιπέδου.

Βασικές βιβλιοθήκες για την προεπεξεργασία των εικόνων ήταν η Pandas, η Matplotlib, η Pillow και η Numpy. Η Pandas προσφέρει ευελιξία κατά την επεξεργασία μεγάλου όγκου δεδομένων, ενώ επιτρέπει την εύκολη ανάγνωση υπολογιστικών φύλλων (excel και csv αρχείων). Με την Pandas διαβάστηκαν τα αρχεία των χρονοσειρών και αποθηκεύτηκαν στη μνήμη σε μορφή pandas dataframe. Ακολούθως, τα dataframes μετατράπηκαν σε πίνακες numpy. Η γραφική απεικόνιση των τιμών των πινάκων έγινε με την βιβλιοθήκη matplotlib. Στη συνέχεια, οι γραφικές παραστάσεις αποθηκεύτηκαν ως εικόνες με τη βοήθεια της βιβλιοθήκης pillow.

Τα μοντέλα που περιγράφηκαν παραπάνω κατασκευάστηκαν μέσω της πλατφόρμας Keras-Tensorflow. Το Keras είναι μια διεπαφή (application programming interface - API) ανοιχτού κώδικα γραμμένη στη γλώσσα προγραμματισμού Python. Χρησιμοποιείται για την επίλυση προβλημάτων βαθιάς μηχανικής μάθησης (deep learning) και τρέχει πάνω στη βιβλιοθήκη της Python, Tensorflow. Παρέχει εντολές υψηλού επιπέδου και έτσι επιτρέπει τον γρήγορο και αποτελεσματικό προγραμματισμό και πειραματισμό, χωρίς να στερείται της ευελιξίας που παρέχουν άλλες βιβλιοθήκες[1]. Η πληθώρα εντολών που διαθέτει επιτρέπει το χτίσιμο εξειδικευμένων μοντέλων που προσαρμόζονται στην εκάστοτε εφαρμογή καθώς και τη βελτιστοποίησή τους μέσω των πολυάριθμων επιλογών ως προς τις παραμέτρους που προσφέρει.

Το Keras πέρα από ευελιξία παρέχει και ταχύτητα, αφού επιτρέπει την εκπαίδευση των μοντέλων πάνω σε μία ή περισσότερες κάρτες γραφικών ή κατανομημένα συστήματα, κάνοντας εφικτή την παραλληλοποίηση των δεδομένων. Έτσι παρατηρείται σημαντική μείωση του χρόνου εκπαίδευσης ακόμα και περίπλοκων μοντέλων. Κατά συνέπεια δεν είναι τυχαίο που χρησιμοποιείται όλο και περισσότερο από την επιστημονική κοινότητα και τη βιομηχανία που ασχολείται με την επιστήμη των δεδομένων και τη μηχανική μάθηση. Στις αρχές του έτους 2020 το Keras ήδη καταμετρούσε πάνω από 375000 μοναδικούς χρήστες[4]. Η κοινότητα που έχει δημιουργηθεί γύρω από τη διεπαφή αυτή επιτρέπει την ανταλλαγή απόψεων και υποστήριξη για ποικίλα ζητήματα. Το αναλυτικό εγχειρίδιο που παρέχεται ελεύθερα στο διαδίκτυο καθιστά εύκολη τη χρήση της ακόμα και από αρχάριους χρήστες.

Αξίζει να σημειωθεί πως η διεπαφή αυτή προσφέρει ποικίλους τρόπους για ενσωμάτωση (deployment) των μοντέλων μηχανικής μάθησης σε εφαρμογές, όπως διαδικτυακές ή εφαρμογές για κινητά τηλέφωνα[4], πράγμα που επιτρέπει την εύκολη ανάπτυξη προγραμμάτων που κάνουν χρήση μοντέλων βαθιάς μάθησης.

Τα παραπάνω προγραμματίστηκαν σε περιβάλλον Jupyter Notebook. Το Jupyter Notebook είναι ένα πολύ χρήσιμο εργαλείο καθώς επιτρέπει τη σύνταξη κώδικα και κειμένου στο ίδιο περιβάλλον. Ακόμα, δίνει τη δυνατότητα διαχωρισμού του κώδικα σε πολλά μέρη (κελιά) και εκτέλεση μεμονωμένων κελιών και όχι απαραίτητα ολόκληρου του αρχείου.

## 5.4 Εκπαίδευση Μοντέλου

Η σύγκλιση των GANs είναι ένα πρόβλημα που δεν έχει λυθεί ακόμα από την επιστημονική κοινότητα. Ωστόσο υπάρχουν εμπειρικές τεχνικές που χρησιμοποιούνται ευρέως και βελτιστοποιούν την εκπαίδευση. Κάποιες από αυτές έχουν προαναφερθεί και αφορούν στην αρχιτεκτονική του μοντέλου (όπως η επιλογή των συναρτήσεων ενεργοποίησης και τα επίπεδα Batch Normalization μετά από τα συνελικτικά επίπεδα). Άλλες αφορούν στην διαδικασία της εκπαίδευσης και αναλύονται παρακάτω.

Η εκπαίδευση του GAN γίνεται κατά δέσμες (batches) που προκύπτουν μετά από τυχαία δειγματοληψία από το σύνολο δεδομένων. Ως συνάρτηση απώλειας για τον διευκρινιστή ορίζεται η Binary Cross Entropy (BCE) ενώ για τον δημιουργό η συνάρτηση Μέσου Απόλυτου Σφάλματος (Mean Absolute Error - MAE). Οι συναρτήσεις αυτές ορίζονται ως:

$$BCE = d \cdot \log(y + \epsilon) + (1 - d) \cdot \log(1 - y + \epsilon)$$

$$MAE = |y - d|$$

όπου  $d$  η επιθυμητή απόκριση του δικτύου,  $y$  η πραγματική απόκριση και  $\epsilon$  μια πολύ μικρή σταθερά. Η απώλεια υπολογίζεται ως ο μέσος όρος των απωλειών για όλα τα παραδείγματα μιας δέσμης (batch). Για την ενημέρωση των βαρών του δικτύου χρησιμοποιείται κάποιος βελτιστοποιητής (optimizer) σε συνεργασία με τον αλγόριθμο BK. Στο πείραμα, ως βελτιστοποιητής χρησιμοποιείται ο Adam Optimizer με παραμέτρους  $learning\_rate = 2e - 4$ ,  $beta\_1 = 0,5$ .

Επειδή σκοπός είναι η κατασκευή μιας εικόνας όχι μόνο αληθοφανούς αλλά μιας εφικτής αναπαράστασης της πραγματικότητας (δηλαδή μιας πιθανής πρόβλεψης) δίνεται βάρος  $\lambda = 100$  στην απώλεια του δημιουργού[20]. Έτσι, η ολική συνάρτηση απώλειας υπολογίζεται ως:

$$loss = 1 \cdot BCE + \lambda \cdot MAE \Rightarrow loss = 1 \cdot BCE + 100 \cdot MAE$$

Αναφορικά με τον διευκρινιστή, είναι προτιμότερο να εκπαιδεύεται σε δέσμες αποκλειστικά αληθινών ή ψεύτικων εικόνων. Στην πράξη εκπαιδεύεται εναλλάξ με αληθινές και ψεύτικες εικόνες. Συνηθίζεται η ετικέτα για τις αληθινές εικόνες να είναι 1 ενώ για τις ψεύτικες 0 (αντίστοιχα η θέση της ετικέτας πραγματικών και ψεύτικων εικόνων στην κωδικοποίηση one-hot encoding). Η εξομάλυνση των ετικετών των πραγματικών εικόνων με μια τιμή λίγο μικρότερη του ενός, όπως 0,9 ή στοχαστικά μεταξύ των τιμών 0,9 και 1 αποδίδει καλύτερα αποτελέσματα. Η τεχνική αυτή αποτρέπει τον διευκρινιστή από την υπερεκπαίδευση: αν διαμορφώσει μεγάλα βάρη με αποτέλεσμα να μάθει να ταξινομεί σωστά τις αληθινές εικόνες με πιθανότητα κοντά στο 1 τότε δέχεται μια ποινή η οποία τον ενθαρρύνει να μειώσει αυτά τα βάρη[15].

Αναφορικά με τον δημιουργό, στο τελευταίο επίπεδο ως συνάρτηση ενεργοποίησης χρησιμοποιείται η υπερβολική εφαπτομένη (tanh), η οποία λαμβάνει τιμές μεταξύ των  $[-1, 1]$ . Έτσι, είναι εύλογο και η είσοδος να κανονικοποιηθεί μεταξύ αυτών των τιμών. Στην RGB αναπαράσταση κάθε εικονοστοιχείο παίρνει τιμές στο διάστημα  $[0, 255]$ . Έτσι, κάθε εικονοστοιχείο του δισδιάστατου χώρου  $f(x, y)$  μετατρέπεται στο  $f'(x, y)$  που ανήκει στο διάστημα  $[-1, 1]$  με

βάση τον τύπο

$$f'(x, y) = \frac{f(x, y)}{127,5} - 1$$

Ο διευκρινιστής εκπαιδεύεται ξεχωριστά από το GAN. Ο δημιουργός εκπαιδεύεται διαμέσου του διευκρινιστή κατά την εκπαίδευση του GAN. Κατά τη διάρκεια εκπαίδευσης του GAN, τα βάρη του διευκρινιστή “παγώνουν” και δεν ανανεώνονται.

Ο αλγόριθμος εκπαίδευσης δίνεται σε ψευδκώδικα στον αλγόριθμο 2.

---

## Αλγόριθμος 2 Εκπαίδευση του Μοντέλου GAN

---

**Require:** epochs, batch\_size

```

1: Procedure Train (epochs, batch_size)
2: initialize real_label = 1, fake_label = 0 //we don't use one-hot encoding here
3: X_train, Y_train = load_Dataset() //load the Dataset as 64× 64 images
4: X_train, Y_train = normalize(X_train, Y_train) //scale images from [0,255] to [-1,1]
5: steps_per_epoch = length(X_train)//batch_size+1 //integer part of the division + 1
6:
7: //define the generator, discriminator and GAN architecture discussed above
8: generator = define_generator()
9: discriminator = define_discriminator()
10: gan = define_gan()
11:
12: for epoch in epochs do
13:   for step in steps_per_epoch do
14:     //generates random batch of images (input, output)
15:     X_realA, X_realB = get_batch(X_train, Y_train, batch_size)
16:     discriminator.trainable = True //weights on discriminator can be updated
17:     if step%2 == 0 then
18:       //for even step nr we train on real samples - real_labels may be smoothed
19:       discriminator.train_on_batch(x = [X_realA, X_realB], y = real_label)
20:     else
21:       //for odd step nr we train on generated samples
22:       X_fakeB = generator.predict(X_realA)
23:       discriminator.train_on_batch(x = [X_realA, X_fakeB], y = fake_label)
24:     end if
25:
26:     discriminator.trainable = False //freeze discriminator weights so that they cannot be updated
27:     gan.train_on_batch(x = X_realA, y = [real_labels, X_realB])
28:   end for
29: end for
30:
31: saved_model = save_model(generator)
32: return saved_model
33: End Procedure

```

---

## 5.5 Εξαγωγή Προβλέψεων

Μετά την εκπαίδευση του μοντέλου ακολουθεί η εξαγωγή των προβλέψεων. Οι προβλέψεις γίνονται σε ξεχωριστό σύνολο δεδομένων, το σύνολο αξιολόγησης, το οποίο είναι άγνωστο στο εκπαιδευμένο μοντέλο. Για να εξάγει κανείς προβλέψεις από ένα εκπαιδευμένο μοντέλο χρειάζεται τα δεδομένα αξιολόγησης να είναι στην ίδια μορφή με τα δεδομένα εκπαίδευσης. Συνεπώς, το σύνολο αυτό των χρονοσειρών επιδέχεται την ίδια προεπεξεργασία με το σύνολο εκπαίδευσης για τη δημιουργία των εικόνων αλλά και την κλιμάκωση στο διάστημα  $[-1, 1]$ .

Η πρόβλεψη της χρονοσειράς καθίσταται εφικτή μέσω του δημιουργού. Στο στάδιο αυτό η ύπαρξη του διευκρινιστή δεν είναι αναγκαία, έτσι απορρίπτεται από το εκπαιδευμένο δίκτυο. Τελικά, τα δεδομένα εισόδου του συνόλου αξιολόγησης εισέρχονται μέσα στον δημιουργό, ο οποίος παράγει την επιθυμητή πρόβλεψη, ελαττωμένη στην κλίμακα  $[-1, 1]$ . Συνεπώς, είναι απαραίτητη η αποκλιμάκωση, έτσι ώστε η εικόνα να βρεθεί στην αρχική RGB κωδικοποίηση. Έτσι, κάθε εικονοστοιχείο  $f(x, y)$  αντικαθίσταται με το  $f(x, y)$  από τον τύπο αποκλιμάκωσης:

$$f(x, y) = \frac{f'(x, y) + 1}{127,5}$$

## 5.6 Επεξεργασία Αποτελεσμάτων

Η ποσοτική αξιολόγηση του μοντέλου καθίσταται εφικτή μόνο αν γνωρίζει κανείς τις πραγματικές τιμές των προβλέψεων. Σε αυτή την ενότητα περιγράφεται η εξαγωγή των τιμών αυτών από την εικόνα. Η διαδικασία που ακολουθείται είναι αντιστρόφως ανάλογη της προεπεξεργασίας.

Πρώτο βήμα της διαδικασίας αποτελεί η εκκαθάριση της εξόδου του νευρωνικού δικτύου από τυχόν ανεπιθύμητο θόρυβο. Αυτό επιτυγχάνεται μέσω της κατωφλίωσης (thresholding), ακολουθούμενης από την εφαρμογή ενός φίλτρου ενδιάμεσης τιμής (median filter). Η τιμή του κατωφλίου (threshold) ορίζεται ανάλογα με το πρόβλημα μετά από πειραματισμούς. Σε αυτό το πείραμα χρησιμοποιείται μια σχετικά χαμηλή τιμή  $threshold = 35$ .

Στη συνέχεια χρειάζεται να εξαχθούν οι περιοχές της εικόνας που αντιστοιχούν στη γραφική παράσταση της χρονοσειράς. Αυτές οριοθετούνται από τα λευκά εικονοστοιχεία. Όπως έχει προαναφερθεί, η ασπρόμαυρη εικόνα αναπαριστάται με έναν δισδιάστατο πίνακα. Για κάθε στήλη του πίνακα υπολογίζεται η ενδιάμεση τιμή median των δεικτών (indexes) των λευκών εικονοστοιχείων. Τόσο ο οριζόντιος όσο και ο κάθετος άξονας είναι προκαθορισμένοι, έτσι κάθε δείκτης μπορεί να αντιστοιχηθεί σε μια πραγματική τιμή των αξόνων  $X$  και  $Y$ . Τυχόν κενές στήλες (στήλες που αποτελούνται μόνο από μαύρα εικονοστοιχεία ύστερα από αποτυχία του δικτύου να τις συμπληρώσει ή που έχουν χαθεί λόγω της εφαρμογής των παραπάνω φίλτρων) συμπληρώνονται με γραμμική παρεμβολή.

Με τη παραπάνω διαδικασία λαμβάνονται 64 τιμές: μια τιμή για κάθε στήλη εικονοστοιχείων. Οι τιμές αυτές αντιστοιχίζονται στον προκαθορισμένο άξονα  $X$ . Με δειγματοληψία λαμβάνονται οι τιμές που αντιστοιχούν στα ακέραια  $X$  και είναι όσες και το μέγεθος εισόδου

συν την πρόβλεψη. Τελευταίο βήμα αποτελεί η αντιστροφή της κανονικοποίησης που είχε υποστεί η χρονοσειρά κατά την προεπεξεργασία. Για την αντιστροφή χρειάζονται η ελάχιστη  $x_{min}$  και μέγιστη  $x_{max}$  τιμή των ιστορικών δεδομένων της αρχικής χρονοσειράς καθώς δίνεται από τον τύπο:

$$x = x' \cdot (x_{max} - x_{min}) + x_{min}$$

Ο αλγόριθμος 3 είναι ένα παράδειγμα της παραπάνω διαδικασίας.

---

### Αλγόριθμος 3 Εξαγωγή Πραγματικών Τιμών από την Εικόνα

---

**Require:** threshold

**Require:** x\_limit\_min, x\_limit\_max //limits of the x axis

**Require:** y\_limit\_min, y\_limit\_max //limits of the y axis

**Require:** y\_min, y\_max //in-sample min, max of the real timeseries

```

1: Procedure ExtractValues (image)
2: initialize y_values = [] //empty list
3: for column in image do
4:   y_values.append(median((x, column) if pixel(x, column) > threshold))
5: end for
6:
7: //scale y values based on original Y axis
8: y_scaled = [(y_limit_min + ((y - 0) * (y_limit_max - y_limit_min)/(image.height - 0))) for y in
  y_values]
9:
10: //linear interpolation of y values at integer values on the X axis
11: y_scaled = interpolate(y_scaled, x_old = [x_limit_min, x_limit_max], x_new = int([x_limit_min,
  x_limit_max]))
12: //inverse scaled values to absolute values
13: y_values = y_scaled*(y_max - y_min) + y_min
14: return y_values
15: End Procedure

```


---

## 5.7 Παράδειγμα


Η παραπάνω διαδικασία αναλύεται παρακάτω με δύο παραδείγματα. Το μέγεθος εισόδου είναι ίσο με 18 ενώ ο ορίζοντας πρόβλεψης είναι ίσος με 6.

1. Για το παράδειγμα επιλέγονται η 51η και η 21666η χρονοσειρά του συνόλου δεδομένων με γραφικές παραστάσεις που φαίνονται στη διπλανή εικόνα. Υπολογίζονται οι ελάχιστες και μέγιστες τιμές που θα χρησιμεύσουν στην κανονικοποίηση.






Χρονοσειρά 51, ελάχιστο= 6966,  
μέγιστο= 8184




Χρονοσειρά 21666, ελάχιστο= 120,  
μέγιστο= 8520

2. Η εικόνα εισόδου δίνεται από την ίδια γραφική παράσταση (κανονικοποιημένη) με λευκό χρώμα σε μαύρο φόντο. Αφήνονται περιθώρια ώστε να είναι δυνατή η επέκταση της χρονοσειράς.





3. Ακολουθεί η εκπαίδευση του δικτύου.


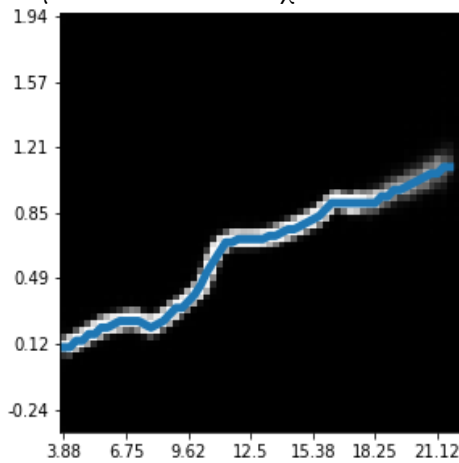
Conditional Generative Adversarial Network (cGAN)



4. Στην έξοδο του νευρωνικού δικτύου λαμβάνεται και στις 2 περιπτώσεις η προέκταση της εισόδου.



5. Από τα λευκά εικονοστοιχεία λαμβάνονται οι αντίστοιχες τιμές των χρονοσειρών. Οι τιμές αυτές είναι κανονικοποιημένες σύμφωνα με τους χειροκίνητα ορισμένους άξονες. Στη δεύτερη περίπτωση φαίνεται η διαδικασία της παρεμβολής μη συμπληρωμένων από το μοντέλο εικονοστοιχείων.



6. Με δειγματοληψία λαμβάνονται οι τιμές στα ακέραια  $x$ .

Χρονοσειρά 51:  $y = [0.01, 0.09, 0.14, 0.18, 0.18, 0.14, 0.23, 0.31, 0.44, 0.64, 0.73, 0.73, 0.77, 0.8, 0.83, 0.9, 1.01, 1.01, 1.01, 1.06, 1.1, 1.15, 1.2, 1.24]$

24 τιμές

Χρονοσειρά 21666:  $y = [0.0, 0.0, 0.0, 0.0, 0.0, 0.0, 0.04, 0.04, 0.08, 0.14, 0.23, 0.37, 0.56, 0.56, 0.58, 0.5, 0.54, 0.7, 0.96, 1.2, 1.17, 1.1, 1.17, 1.2, 1.24]$

24 τιμές

7. Γίνεται αντιστροφή της κανονικοποίησης. Οι τελευταίες 6 τιμές αντιπροσωπεύουν τις προβλέψεις.

Χρονοσειρά 51:  $y = [6978.18, 7075.62, 7136.52, 7185.24, 7185.24, 7136.52, 7246.14, 7343.58, 7501.92, 7745.52, 7855.14, 7855.14, 7903.86, 7940.4, 7976.94, 8062.2, 8196.18, 8196.18, 8196.18, 8257.08, 8305.8, 8366.7, 8427.6, 8476.32]$  Πρόβλεψη

Χρονοσειρά 21666:  $y = [120.0, 120.0, 120.0, 120.0, 120.0, 456.0, 456.0, 792.0, 1296.0, 2052.0, 3228.0, 4824.0, 4824.0, 4992.0, 4320.0, 4656.0, 6000.0, 8184.0, 10200.0, 9948.0, 9360.0, 9948.0, 10200.0, 10536.0]$  Πρόβλεψη

## Κεφάλαιο 6

# Αποτελέσματα και Αξιολόγηση

### 6.1 Πειραματικό Σύνολο Δεδομένων

Τα δεδομένα που επιλέχθηκαν τόσο για την εκπαίδευση όσο και για την αξιολόγηση είναι τα ετήσια δεδομένα του διαγωνισμού M4. Οι διαγωνισμοί M πραγματοποιούνται περίπου μια φορά ανά δεκαετία. Σε αυτούς συμμετέχουν πολυάριθμες ερευνητικές και μη ομάδες με μοναδικό σκοπό την εύρεση των πιο σπουδαίων τεχνικών πρόβλεψης χρονοσειρών.

Το σύνολο αυτό αποτελείται από 23000 χρονοσειρές με μήκη στο in-sample δείγμα μεταξύ των 13 και 835 παρατηρήσεων. Ο ορίζοντας πρόβλεψης είναι ίσος με 6 όπως όριζε ο διαγωνισμός και για τα πειράματα που διεξήχθησαν επιλέχθηκε μέγεθος εισόδου ίσο με 18.

Όλες οι χρονοσειρές είναι συνεχόμενης ζήτησης και δεν περιέχουν μηδενικές τιμές, έτσι ώστε να αποφευχθούν τυχόν σφάλματα στους δείκτες ακρίβειας[23]. Χωρίζονται σε διάφορες υποκατηγορίες, ανάλογα με τον τομέα εφαρμογής, που φαίνονται στον πίνακα 6.1.

	Μικροοικονομία	Βιομηχανία	Μακροοικονομία	Χρηματοοικονομικά	Δημογραφικά Στοιχεία	Άλλα	Σύνολο
Αριθμός ετήσιων χρονοσειρών	6538	3716	3903	6519	1088	1236	<b>23000</b>

Πίνακας 6.1: Υποκατηγορίες Ετήσιων Χρονοσειρών του M4. Πηγή: [23]

Ο λόγος που επιλέχθηκαν τα συγκεκριμένα δεδομένα για την εφαρμογή των πειραμάτων είναι δύο: αφενός το πλήθος των χρονοσειρών είναι ιδανικό για εφαρμογές μηχανικής μάθησης, αφετέρου οι χρονοσειρές δε φέρουν εποχιακότητα, πράγμα που διευκολύνει τον υπολογισμό των σφαλμάτων, αφού παραλείπεται το στάδιο της αποεποχικοποίησης.

Για την εκπαίδευση των μοντέλων χρησιμοποιήθηκε το σύνολο εκπαίδευσης των παραπάνω δεδομένων, που περιλαμβάνει όλες τις χρονοσειρές, αν αφαιρεθεί το παράθυρο των 6 τελευταίων παρατηρήσεων. Το σύνολο αξιολόγησης περιέχει τις ίδιες χρονοσειρές μετατοπισμένες κατά έναν ορίζοντα πρόβλεψης προς το μέλλον.

Όλες οι χρονοσειρές υπέστησαν την προεπεξεργασία που αναλύεται στο κεφάλαιο 5 για να μετατραπούν σε ασπρόμαυρες εικόνες. Είναι σημαντικό να παρατηρήσει κανείς ότι θέτοντας τα όρια των αξόνων των γραφικών παραστάσεων όπως ορίστηκαν στο ίδιο κεφάλαιο, κάποιες χρονοσειρές του συνόλου δεδομένων εξόδου βγαίνουν "εκτός κάδρου". Για σωστότερη εκπαίδευση των μοντέλων οι αντίστοιχες εικόνες θεωρούνται outliers και αφαιρούνται και τελικά προκύπτουν 20118 δείγματα. Το σύνολο αξιολόγησης αποτελείται και από τις 23000 χρονοσειρές.

## 6.2 Σημείο Αναφοράς και Δείκτες Αξιολόγησης

Προκειμένου να συγκριθούν τα εξεταζόμενα μοντέλα χρησιμοποιούνται ως σημείο αναφοράς τρεις τεχνικές πολύ διαδεδομένες στον χώρο των προβλέψεων: η Απλή Εκθετική Εξομάλυνση (Simple Exponential Smoothing - SES), η Αφελής Μέθοδος (Naive) και η Μέθοδος Theta. Για εξαγωγή των προβλέψεων με τις μεθόδους αυτές χρησιμοποιήθηκαν τα αντίστοιχα μοντέλα της βιβλιοθήκης statsmodels της Python.

Η καταμέτρηση των σφαλμάτων γίνεται με δύο δείκτες ακριβείας: το Συμμετρικό Μέσο Απόλυτο Ποσοστιαίο Σφάλμα (sMAPE) και το Μέσο Απόλυτο Κανονικοποιημένο Σφάλμα (MASE) που υπολογίζονται από τους τύπους:

$$sMAPE = \frac{1}{n} \sum_{t=n+1}^{n+h} \left| \frac{2 \cdot (Y(t) - F(t))}{Y(t) + F(t)} \right| \cdot 100(\%)$$

$$MASE = \frac{\frac{1}{h} \sum_{t=n+1}^{n+h} |Y(t) - F(t)|}{\frac{1}{n-1} \sum_{t=2}^n |Y(t) - Y(t-1)|}$$

όπου

- $n$  το πλήθος των γνωστών παρατηρήσεων
- $h$  ο ορίζοντας πρόβλεψης
- $t$  η χρονική στιγμή
- $Y(t)$  η πραγματική τιμή τη χρονική στιγμή  $t$  (μπορεί να αναφέρεται στα ιστορικά δεδομένα ή στις πραγματικές τιμές του out-of-sample δείγματος)
- $F(t)$  η πρόβλεψη τη χρονική στιγμή  $t$

Οι δείκτες ακριβείας για τις παραπάνω μεθόδους πάνω στο σύνολο αξιολόγησης φαίνονται στον πίνακα 6.2.


## 6.3 Επικύρωση των Αποτελεσμάτων

Λόγω της ανταγωνιστικής συμπεριφοράς μεταξύ δημιουργού και διευκρινιστή το δίκτυο δε συγκλίνει ως προς την απώλεια. Αντίθετα, επιδιώκεται μια ισορροπία μεταξύ των δύο υπο-

Μέθοδος	sMAPE(%)	MASE
<b>SES</b>	16,3953	3,9804
<b>Naive</b>	16,3422	3,9744
<b>Theta</b>	14,5933	3,3821

Πίνακας 6.2: Δείκτες Ακρίβειας Κλασικών Μεθόδων Πρόβλεψης

δικτύων. Έτσι, κρίνεται αναγκαία μια ποσοτική μέθοδος εύρεσης του πότε είναι η κατάλληλη στιγμή να σταματήσει κανείς τη διαδικασία εκπαίδευσης.




Σχήμα 6.1: Απώλειες Δημιουργού και Διευκρινιστή και συνολική απώλεια ανά Εποχή στο Σύνολο Εκπαίδευσης

Η μέθοδος αυτή στηρίζεται στη δημιουργία ενός συνόλου “επικύρωσης” (validation set), που προκύπτει με διαχωρισμό του συνόλου εκπαίδευσης σε 19118 δείγματα εκπαίδευσης και 1000 δείγματα επικύρωσης. Τα δείγματα επικύρωσης δε λαμβάνονται υπόψη στη διαδικασία εκπαίδευσης και χρησιμοποιούνται κατά το στάδιο της πρόβλεψης. Έτσι, μετά από κάθε εποχή εκπαίδευσης το μοντέλο καλείται να κάνει πρόβλεψη πάνω στα δείγματα αυτά. Οι προβλέψεις υφίστανται την ίδια επεξεργασία που περιγράφηκε στο κεφάλαιο 5 για την εξαγωγή των πραγματικών τιμών από την εικόνα και για αυτές υπολογίζεται το σφάλμα sMAPE. Ως καλύτερη εποχή για κάθε ξεχωριστή εκπαίδευση ενός μοντέλου ορίζεται η εποχή με το μικρότερο σφάλμα στο σύνολο επικύρωσης βάσει της οποίας εξάγονται οι προβλέψεις πάνω στο σύνολο αξιολόγησης.

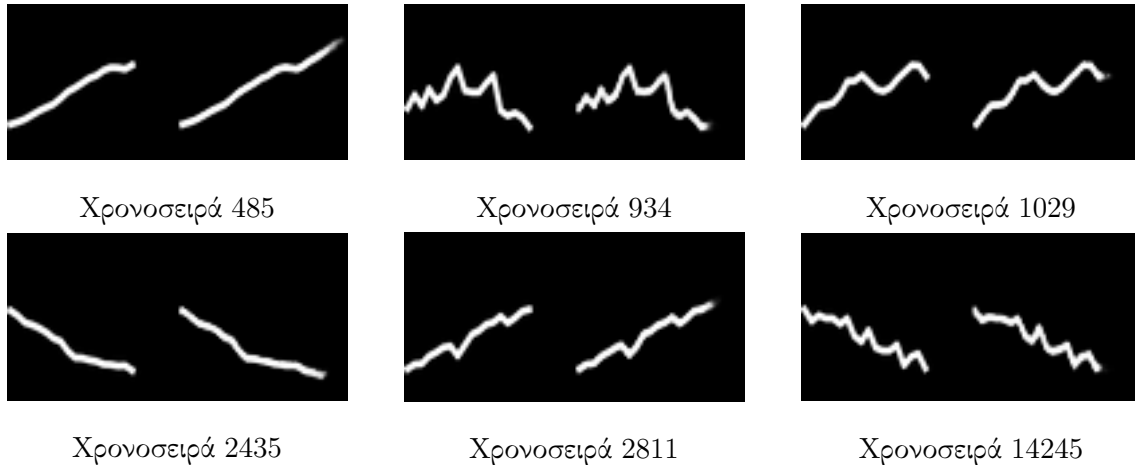
## 6.4 Ποσοτικά αποτελέσματα

Η αρχική ιδέα για τη λύση του προβλήματος ήταν η χρήση συνεχλικτικού αυτοκωδικοποιητή (autoencoder), όπως αυτός που περιγράφηκε στο κεφάλαιο 5. Όμως, τα αρχικά πειράματα έδειξαν πως ένα τέτοιο δίκτυο αδυνατεί να εκπαιδευτεί και να παράξει σωστές προβλέψεις. Συγκεκριμένα, το δίκτυο ήταν σε θέση να αναπαράγει πολύ σωστά την είσοδο, όμως στην πλειοψηφία των περιπτώσεων αδυνατούσε να την επεκτείνει, με εξαίρεση τις πολύ



Σχήμα 6.2: Δείκτης sMAPE ανά Εποχή στο Σύνολο Επικύρωσης. Η εποχή 7 έχει το μικρότερο sMAPE στο σύνολο επικύρωσης και συνεπώς η ίδια εποχή επιλέγεται ως καλύτερη και για το σύνολο αξιολόγησης

ομαλές χρονοσειρές, η μορφή των οποίων είναι σχεδόν ευθεία γραμμή. Παρόλα αυτά, παρατίθενται παρακάτω τα ποσοτικά αποτελέσματα ενός τέτοιου δικτύου με 3 συνελικτικά μπλοκς και χρησιμοποιείται ως σημείο αναφοράς για τα υπόλοιπα δίκτυα.



Σχήμα 6.3: Προβλέψεις Αυτοκωδικοποιητή με 3 συνελικτικά μπλοκ. Αριστερά η είσοδος, δεξιά η πρόβλεψη. Παρατηρείται η αδυναμία εξαγωγής πρόβλεψης στις περισσότερες εικόνες. Ακόμα και για τις χρονοσειρές 485 και 2435 η πρόβλεψη είναι ελλιπής.

Όλα τα μοντέλα GAN εκπαιδεύτηκαν για 50 εποχές με μέγεθος δέσμης  $batch\_size = 128$ . Τα μοντέλα με αυτοκωδικοποιητή εκπαιδεύτηκαν με τις ίδιες συναρτήσεις βελτιστοποίησης και απώλειας, μέχρι τη σύγκλιση με εφαρμογή της τεχνικής της πρόωρης διακοπής (early stopping) ώστε να αποφευχθεί η υπερεκπαίδευση.

### 6.4.1 Ευρωστία Μοντέλου

Για να ελεγχθεί η ευρωστία του μοντέλου, διεξάγεται το ίδιο πείραμα 3 φορές. Στο πίνακα 6.3 φαίνονται τα σφάλματα sMAPE και MASE για το μοντέλο GAN με 3 συνελικτικά μπλοκ και skip connections. Εύκολα παρατηρεί κανείς ότι τα αποτελέσματα είναι αρκετά συνεπή και ανεξάρτητα της στοχαστικότητας του κάθε πειράματος.

Μοντέλο με 3 συνελικτικά μπλοκ και skip connections	sMAPE(%)	MASE	Καλύτερη Εποχή
Εκπαίδευση 1	13,7190	3,1610	7η
Εκπαίδευση 2	13,8897	3,2074	9η
Εκπαίδευση 3	13,7747	3,1928	6η

Πίνακας 6.3: Ευρωστία μοντέλου GAN

### 6.4.2 Σύγκριση Μοντέλων

Παρακάτω συγκρίνονται διάφορες αρχιτεκτονικές του μοντέλου GAN που περιγράφηκε στο κεφάλαιο 5, με τις κλασικές μεθόδους και τον απλό αυτοκωδικοποιητή με 3 συνελικτικά μπλοκ. Συγκεκριμένα, υλοποιήθηκαν οι παρακάτω αρχιτεκτονικές:

- Απλός αυτοκωδικοποιητής με 3 συνελικτικά μπλοκ
- GAN με αυτοκωδικοποιητή με 2 συνελικτικά μπλοκ
- GAN με αυτοκωδικοποιητή με 3 συνελικτικά μπλοκ
- GAN με κωδικοποιητή - αποκωδικοποιητή με 2 συνελικτικά μπλοκ και skip connections
- GAN με κωδικοποιητή - αποκωδικοποιητή με 3 συνελικτικά μπλοκ και skip connections
- Συνδυασμός καλύτερου GAN από τα παραπάνω με τη μέθοδο Theta, όπου οι προβλέψεις υπολογίζονται ως ο μέσος όρος των δύο επιμέρους μοντέλων

Για όλα τα μοντέλα GAN χρησιμοποιήθηκε ο ίδιος διευκρινιστής, όπως ορίστηκε στο κεφάλαιο 5. Με τα παραπάνω πειράματα εξετάζεται κατά πόσο το βάθος (δηλαδή ο αριθμός επιπέδων) του δημιουργού επηρεάζει την ποιότητα και την ακρίβεια των προβλέψεων ή αν οι συνδέσεις (skip connections) έχουν θετική επίδραση για την εξαγωγή αληθοφανών εικόνων και σωστών προβλέψεων. Ο απλός αυτοκωδικοποιητής αποτελεί μέτρο σύγκρισης της υπό εξέταση ποιότητας εικόνων.

Το τελευταίο συνδυαστικό μοντέλο εξετάζεται με σκοπό να διευκρινιστεί αν ένας συνδυασμός των κλασικών μεθόδων με το προτεινόμενο μπορεί να επιφέρει πιο ακριβή αποτελέσματα. Τα συνδυαστικά μοντέλα έχουν προταθεί και στο παρελθόν από πολλές ερευνητικές ομάδες

και έχουν φέρει εξαιρετικά αποτελέσματα στους διαγωνισμούς M. Για παράδειγμα, την πρώτη θέση στον διαγωνισμό M4 έλαβε ο Slawek Smyl, ο οποίος χρησιμοποίησε μια υβριδική μέθοδο που αποτελούταν από το συνδυασμό της μεθόδου εκθετικής εξομάλυνσης και ενός μοντέλου μηχανικής μάθησης με αναδρομικούς νευρώνες[23]. Το προτεινόμενο μοντέλο με GAN είναι ένα καθολικό μοντέλο, δηλαδή το ίδιο για όλες τις προβλέψεις. Συνεπώς έχει νόημα να συνδυαστεί με ένα μοντέλο χρονοσειρών, όπως η μέθοδος Theta.

Οι συγκρίσεις γίνονται πάνω στο σύνολο αξιολόγησης των ετήσιων δεδομένων του M4 που αποτελείται από 23000 δείγματα. Εξετάζεται όχι μόνο η ακρίβεια των προβλέψεων αλλά και η ποιότητα των παραγόμενων εικόνων. Έτσι, πέρα από τους προαναφερθέντες δείκτες ακρίβειας, εξετάζονται και ποιοτικές μετρικές, όπως το σύνολο των δειγμάτων στο οποίο το κάθε μοντέλο κατάφερε να εξάγει το πολύ 3 από τις 6 επιθυμητές προβλέψεις ή τον αριθμό των δειγμάτων από το οποίο κάποιο μοντέλο δεν κατάφερε να εξάγει καμία από τις 6 προβλέψεις.

Για μεγαλύτερη ακρίβεια, στα παρακάτω πειράματα οι δείκτες ακριβείας και οι υπόλοιπες μετρικές προκύπτουν ως ο μέσος όρος των προβλέψεων 2 ξεχωριστών εκπαιδεύσεων του ίδιου μοντέλου. Τα αποτελέσματα φαίνονται στον πίνακα 6.4.

Εύκολα γίνεται αντιληπτό ότι το μοντέλο GAN υπερτερεί έναντι του αυτοκωδικοποιητή τόσο στους δείκτες ακρίβειας όσο και στην ποιότητα των εξαγόμενων εικόνων. Συγκεκριμένα, καλύτερο σφάλμα sMAPE αποδίδει το μοντέλο με 3 συνελικτικά μπλοκ χωρίς συνδέσεις, αν και η διαφορά από το αντίστοιχο μοντέλο με συνδέσεις είναι αμελητέα. Το ίδιο μοντέλο πετυχαίνει και μικρότερο σφάλμα MASE.

Ωστόσο, εύκολα γίνεται αντιληπτή η ανωτερότητα του συνδυασμού αυτού του μοντέλου με τη στατιστική μέθοδο Theta. Το τελευταίο πετυχαίνει τα μικρότερα σφάλματα στο σύνολο των χρονοσειρών αξιολόγησης αλλά και μεμονωμένα στο πλήθος των χρονοσειρών με μικρότερα σφάλματα από την απλή εκθετική εξομάλυνση (που χρησιμοποιείται ως σημείο αναφοράς).

Σε γενικές γραμμές φαίνεται πως ένα βαθύτερο δίκτυο έχει μεγαλύτερη ικανότητα επίλυσης του προβλήματος. Αξιοσημείωτο είναι το γεγονός ότι ο απλός αυτοκωδικοποιητής, παρόλο που πηγαίνει χειρότερα στους δείκτες ακρίβειας, φαίνεται να φέρει καλύτερα αποτελέσματα από τη SES σε μεγαλύτερο πλήθος μεμονωμένων δειγμάτων. Αυτό πιθανότατα οφείλεται στην ανακατασκευή που υφίστανται οι χρονοσειρές κατά την επεξεργασία των προβλέψεων με σκοπό την εξαγωγή τιμών από την εικόνα. Έτσι, αν και το μοντέλο αυτό αδυνατεί ως επί το πλείστον να εξάγει προβλέψεις (και αυτό εύκολα παρατηρείται από τις 2 τελευταίες στήλες του πίνακα 6.4), καταφέρνει να εκτιμήσει το σωστό επίπεδο και η ανακατασκευή φέρει σχετικά ακριβή αποτελέσματα. Παρόλα αυτά, ποιοτικά δεν έχει μεγάλη αξία.

Αντίθετα, είναι προφανής η ανωτερότητα στην ποιότητα των εξαγόμενων προβλέψεων στα δίκτυα GANs. Με εξαίρεση το ρηχότερο δίκτυο με 2 συνελικτικά μπλοκ χωρίς συνδέσεις, τα υπόλοιπα δίκτυα έχουν σημαντικά μικρότερο σφάλμα sMAPE από τον αυτοκωδικοποιητή αλλά και από τις κλασικές μεθόδους. Εξάλλου, στην πλειονότητα των μοντέλων οι ελλειπίες προβλέψεις δεν ξεπερνούν το 10% των συνολικών δειγμάτων ενώ οι περιπτώσεις στις οποίες το εκάστοτε μοντέλο αδυνατεί να εξάγει πρόβλεψη είναι αμελητέες.

Όσον αφορά στο βάθος του δημιουργού, ένα βαθύτερο δίκτυο φαίνεται να πηγαίνει κα-



Μοντέλο	sMAPE(%)	MASE	Αριθμός Δειγμάτων με μικρότερο sMAPE από SES	Αριθμός Δειγμάτων με μικρότερο MASE από SES	Αριθμός Δειγμάτων με 3 Προβλέψεις το πολύ	Αριθμός Δειγμάτων χωρίς καμία Πρόβλεψη
Απλή Εκθετική Εξομάλυνση (SES)	16,3953	3,9804	-	-	-	-
Αφελής (Naive)	16,3422	3,9744	-	-	-	-
Theta	14,5933	3,3821	-	-	-	-
Αυτοκωδικοποιητής με 3 συνελικτικά μπλοκ	13,8836	3,1382	15549	15413	20037	403
GAN με 2 συνελικτικά μπλοκ χωρίς συνδέσεις	13,9322	3,2104	13825	13614	3792	<b>0</b>
GAN με 3 συνελικτικά μπλοκ χωρίς συνδέσεις	13,6469	3,0972	14665	14520	2062	12
GAN με 2 συνελικτικά μπλοκ με συνδέσεις	13,7770	3,1816	14260	14082	1121	<b>0</b>
GAN με 3 συνελικτικά μπλοκ με συνδέσεις	13,6679	3,1550	14279	14095	<b>796</b>	3
Συνδυασμός καλύτερου GAN και Theta	<b>13,2210</b>	<b>2,9602</b>	<b>16327</b>	<b>16276</b>	-	-

Πίνακας 6.4: Σύγκριση Μετρικών Εξεταζόμενων Μοντέλων

λύτερα από ένα πιο ρηχό. Στο ρηχό δίκτυο οι συνδέσεις καταφέρνουν σημαντική μείωση των σφαλμάτων, αλλά στο βαθύτερο δίκτυο το βάθος φαίνεται να παίζει σημαντικότερο ρόλο στη μεταφορά πληροφορίας από τις συνδέσεις μεταξύ των επιπέδων.

Αναλυτική σύγκριση της ποιότητας των εικόνων με παραδείγματα γίνεται στο παράρτημα Α'.

## 6.5 Χρόνοι Εκπαίδευσης

Όλα τα πειράματα πραγματοποιήθηκαν στην πλατφόρμα Kaggle, η οποία προσφέρει δωρεάν cloud υπηρεσίες και εικονικά περιβάλλοντα για την εκπαίδευση δικτύων μηχανικής μάθησης.

Σε ένα εικονικό περιβάλλον προσφέρεται μια κάρτα γραφικών (GPU) Nvidia Tesla P100 PCIe με μνήμη RAM στα 16 Gb και 2 κεντρικές μονάδες επεξεργασίας (CPU) Intel Xeon @ 2.00GHz και μνήμη RAM στα 13 Gb.

Όλα τα μοντέλα μηχανικής μάθησης εκπαιδεύτηκαν στη GPU. Το μοντέλο αυτοκωδικοποιητή εκπαιδεύεται μέχρι τη σύγκλιση, ενώ τα μοντέλα GAN για 50 εποχές. Επιπλέον, στα GANs υπολογίζεται το σφάλμα sMAPE για το σύνολο επικύρωσης μετά από κάθε εποχή. Ο αλγόριθμος επικύρωσης τρέχει πάνω σε μια από τις 2 CPU. Παρακάτω παρουσιάζονται οι χρόνοι εκπαίδευσης (καθαροί χρόνοι GPU όσο και συνολικός χρόνος μαζί με την επικύρωση) και πρόβλεψης για όλα τα παραπάνω μοντέλα. Οι χρόνοι προκύπτουν ξανά από το μέσο όρο των χρόνων 2 ξεχωριστών εκπαιδεύσεων.

Μοντέλο	Εποχές Εκπαίδευσης	Συνολικός Χρόνος GPU (min)	Χρόνος GPU ανά εποχή (s)	Συνολικός Χρόνος Εκπαίδευσης (min)	Συνολικός Χρόνος Εκπαίδευσης ανά εποχή (s)	Χρόνος Πρόβλεψης (s)
Αυτοκωδικοποιητής με 3 συνελικτικά μπλοκ	56/65	5,90	5,85	-	-	4,27
GAN με 2 συνελικτικά μπλοκ χωρίς συνδέσεις	50	9,58	11,50	22,80	27,37	3,32
GAN με 3 συνελικτικά μπλοκ χωρίς συνδέσεις	50	10,64	12,77	23,41	28,10	3,87
GAN με 2 συνελικτικά μπλοκ με συνδέσεις	50	10,69	12,82	23,84	28,62	3,55
GAN με 3 συνελικτικά μπλοκ με συνδέσεις	50	12,21	14,66	26,37	31,65	4,42

Πίνακας 6.5: Χρόνοι Εκπαίδευσης και Πρόβλεψης Μοντέλων

## Κεφάλαιο 7

# Συμπεράσματα και προεκτάσεις

### 7.1 Συμπεράσματα

Η εφαρμογή της μηχανικής μάθησης στην επεξεργασία και ταξινόμηση εικόνων είναι ένας κλάδος ιδιαίτερα διαδεδομένος τα τελευταία χρόνια. Αυτό οφείλεται κατά κύριο λόγο στην μεγάλη επιτυχία που έχουν τα συνελκτικά δίκτυα στην επίλυση τέτοιων προβλημάτων. Είναι λοιπόν επόμενο να σκεφτεί κανείς πώς μπορεί να αξιοποιήσει τεχνικές από το χώρο της εικόνας σε άλλους κλάδους, όπως αυτός των προβλέψεων.

Τα αποτελέσματα της παρούσας διπλωματικής εργασίας επιβεβαιώνουν την παραπάνω σκέψη και παρουσιάζουν ενδιαφέρον ως προς την πρόβλεψη χρονοσειρών από εικόνες. Συγκεκριμένα:

- Γίνεται σαφής η ανωτερότητα των Γεννητικών Ανταγωνιστικών Δικτύων απέναντι στους απλούς Αυτοκωδικοποιητές ως προς την ποιότητα των παραγόμενων αποτελεσμάτων. Αυτό φαίνεται στο ότι τα μοντέλα GANs καταφέρνουν να κατασκευάσουν καλά ορισμένες προβλέψεις, ενώ τα δείγματα για τα οποία οι εξαγόμενες προβλέψεις είναι λιγότερες από μισές σε σχέση με τον ζητούμενο αριθμό δεν ξεπερνούν το 10% των συνολικών δειγμάτων στην πλειοψηφία των μοντέλων. Αντίθετα, η ίδια μετρική στο μοντέλο με αυτοκωδικοποιητή είναι 20037 στα 23000 δείγματα, δηλαδή ποσοστό 87%.
- Μελετάται το βάθος του δημιουργού σε σχέση με την απόδοση του δικτύου. Είναι φανερό ότι ένα βαθύτερο δίκτυο καταφέρνει να οργανώσει καλύτερα τις πληροφορίες που παρέχονται με αποτέλεσμα να δίνει πιο σωστές και πιο ποιοτικές προβλέψεις. Στην περίπτωση των GANs με δύο συνελκτικά μπλοκ η παρουσία των συμμετρικών συνδέσεων (skip connections) μεταξύ κωδικοποιητή-αποκωδικοποιητή φαίνεται να παίζουν σημαντικό ρόλο καθώς περνούν την πληροφορία από το ένα επίπεδο στο άλλο. Έτσι, το δίκτυο με συνδέσεις πετυχαίνει sMAPE ίσο με 13,7770% που είναι σημαντική βελτίωση συγκριτικά με το 13,9322% του δικτύου χωρίς συνδέσεις. Στα δίκτυα με τρία συνελκτικά μπλοκ το βάθος φαίνεται να αντισταθμίζει την απουσία (ή παρουσία) συνδέσεων, με το δίκτυο χωρίς συνδέσεις να πετυχαίνει μικρότερο δείκτη sMAPE αν και η διαφορά είναι αμελητέα (13,6469% συγκριτικά με 13,6679%).

- Προτείνεται ένας τρόπος ποσοτικής αξιολόγησης των προβλέψεων, που στηρίζεται στην ανακατασκευή των πραγματικών τιμών από τις εικόνες. Με αυτόν το τρόπο είναι δυνατή η σύγκριση της ποιότητας των εξαγόμενων προβλέψεων με τα κλασικά στατιστικά μοντέλα αλλά και ο συνδυασμός των προβλέψεων που δίνει το νευρωνικό δίκτυο με κάποια άλλη μέθοδο.
- Αποδεικνύεται ότι ο συνδυασμός μιας κλασικής στατιστικής μεθόδου πρόβλεψης, όπως η Theta με ένα μοντέλο μηχανικής μάθησης παρουσιάζει μικρότερα σφάλματα και πετυχαίνει καλύτερα αποτελέσματα σε όλες τις μετρικές που εξετάζονται.

Φυσικά, για να είναι επιτυχημένη η παραπάνω μέθοδος ήταν απαραίτητη αντιμετώπιση προκλήσεων που σχετίζονταν με τη βελτιστοποίηση των μοντέλων μηχανικής μάθησης και την εύρεση της καταλληλότερης μορφής για τις εικόνες εισόδου και εξόδου. Οι λύσεις στα προβλήματα αυτά δόθηκαν με ποικίλους τρόπους:

- Η βελτιστοποίηση των υπερπαραμέτρων των μοντέλων δεν ήταν καθόλου εύκολη υπόθεση, δεδομένου του μεγάλου αριθμού τους και της πληθώρας επιλογών που υπάρχουν. Τη λύση έδωσε η βιβλιογραφία, η οποία προτείνει πρακτικούς κανόνες μάθησης για τα γεννητικά ανταγωνιστικά δίκτυα.
- Η μετατροπή των χρονοσειρών σε εικόνες των γραφικών τους αναπαραστάσεων αποτέλεσε από τις μεγαλύτερες προκλήσεις. Αυτό γιατί η σωστή αναπαράσταση της εισόδου και εξόδου έχει καθοριστική σημασία στα μοντέλα μηχανικής μάθησης. Έτσι, αποφασίστηκε να αφηθούν περιθώρια γύρω από τη γραφική παράσταση με σκοπό να μπορεί το νευρωνικό δίκτυο να την επεκτείνει. Τα περιθώρια έπρεπε να καθοριστούν. Αυτά βρέθηκαν πειραματικά, μετά από ανάλυση των δεδομένων και εκπαιδεύσεις των μοντέλων. Σκοπός ήταν οι πραγματικές προεκτάσεις των εικόνων να βγαίνουν όσο το δυνατό λιγότερο “έκτός κάδρου” αλλά και η μορφή των χρονοσειρών να είναι ευδιάκριτη.
- Για να είναι δυνατή η ποσοτική αξιολόγηση των μοντέλων χρειάστηκε η μετατροπή των εικόνων ξανά σε χρονοσειρές με σκοπό την εύρεση των πραγματικών τιμών των προβλέψεων. Έτσι, κατασκευάστηκε ένας αλγόριθμος αντίθετος με αυτόν της προεπεξεργασίας ο οποίος έκανε εξαγωγή των τιμών από τις εικόνες. Οι δείκτες sMAPE και MASE χρησιμοποιήθηκαν για εξέταση της εγχυρότητας των αποτελεσμάτων.
- Καθώς τα γεννητικά ανταγωνιστικά δίκτυα δε συγχλίνουν, χρειάστηκε να επινοηθεί ένας αλγόριθμος “τερματισμού” έτσι ώστε να βρεθεί η καλύτερη εποχή εκπαίδευσης. Αυτός καθορίστηκε να είναι ο υπολογισμός του δείκτη sMAPE σε ένα σύνολο αξιολόγησης (με χρήση του παραπάνω αλγορίθμου εξαγωγής τιμών από εικόνες) και η επιλογή της εποχής με το μικρότερο δείκτη ως καλύτερη σε κάθε εκπαίδευση.

## 7.2 Προεκτάσεις

Παρά την επιτυχία της προτεινόμενης μεθοδολογίας, υπάρχουν αρκετές βελτιώσεις που θα μπορούσε κανείς να σκεφτεί με σκοπό την περαιτέρω βελτίωση της απόδοσης του μοντέλου. Κάποιες από αυτές παρουσιάζονται στη συνέχεια.

### 7.2.1 Βελτίωση Αρχιτεκτονικής Μοντέλου Μηχανικής Μάθησης

Η αρχιτεκτονική του δικτύου των Isola et al. στο [20] η οποία αποτέλεσε την έμπνευση για το παραπάνω μοντέλο, περιλαμβάνει ένα μεσαίου βάθους συνελικτικό δίκτυο στη θέση του διευκρινιστή. Τα αρχικά πειράματα έδειξαν πως το δίκτυο αυτό δεν είναι κατάλληλο για το πρόβλημα που μελετάται στην παρούσα διπλωματική εργασία, ωστόσο αξίζει να σκεφτεί κανείς πώς θα μπορούσε να αξιοποιηθεί η παραπάνω ιδέα.

Ακόμα, στο ίδιο άρθρο γίνεται χρήση της αρχιτεκτονικής του U-net στη θέση του δημιουργού. Το δίκτυο αυτό είναι ένας συνελικτικός αυτοκωδικοποιητής με συνδέσεις skip-connections. Η διαφορά με το υπάρχον δίκτυο είναι ότι η μείωση της διαστατικότητας υφίσταται σε κάθε επίπεδο, σε αντίθεση με κάθε τρία επίπεδα λόγω των συνελικτικών μπλοκς. Το δεύτερο δίκτυο προτιμήθηκε διότι επιτρέπει την αύξηση του βάθους χωρίς να μειώνει πολύ τις διαστάσεις, πράγμα που ήταν επιθυμητό για εικόνες 64×64 εικονοστοιχείων. Ενδεχομένως το U-net να προτιμηθεί για εικόνες μεγαλύτερων διαστάσεων.

Η παρούσα διπλωματική εργασία αποσκοπούσε στη δημιουργία ενός καθολικού μοντέλου πρόβλεψης χρονοσειρών ανεξαρτήτως της κατηγορίας ή του τομέα στον οποίο αυτές ανήκουν. Ωστόσο, τα δεδομένα που χρησιμοποιήθηκαν για πρόβλεψη και αξιολόγηση ανήκουν σε 6 διαφορετικούς τομείς. Κατά συνέπεια, μια ενδιαφέρουσα προέκταση του μοντέλου θα ήταν η προσθήκη του τομέα ως εξωγενές χαρακτηριστικό στην είσοδο ή η εκπαίδευση πολλαπλών μοντέλων ανάλογα με τον τομέα και η μελέτη σχετικά με το αν φέρουν καλύτερα αποτελέσματα.

### 7.2.2 Βελτίωση της Διαδικασίας Προεπεξεργασίας των Εικόνων

Τα συνελικτικά δίκτυα είναι ιδιαίτερα δημοφιλή για την επεξεργασία και κατηγοριοποίηση εικόνων, τόσο ασπρόμαυρων όσο και έγχρωμων. Στην παρούσα διπλωματική εργασία αξιοποιήθηκε μόνο η ασπρόμαυρη πληροφορία. Έτσι, μια εύλογη σκέψη για τη βελτίωση της μεθοδολογίας αποτελεί η αξιοποίηση των χρωμάτων. Αυτή η πληροφορία θα μπορούσε, παραδείγματος χάριν, να χρησιμοποιηθεί για τον διαχωρισμό των χρονοσειρών σε κατηγορίες, ανάλογα με τον τομέα στον οποίο ανήκουν ή με τη συμπεριφορά της ως προς την τάση (για παράδειγμα αν είναι αύξουσες, φθίνουσες ή σταθερού επιπέδου). Κάθε κατηγορία χρονοσειρών θα μπορούσε να κωδικοποιείται με διαφορετικό χρώμα κατά τη γραφική απεικόνιση.

Το μέγεθος των εικόνων είναι μια παράμετρος που αξίζει να μελετηθεί. Το επιλεγμένο μέγεθος (64×64 εικονοστοιχεία) ήταν τέτοιο ώστε να προσφέρει μια σχετικά ευδιάκριτη αναπαράσταση της χρονοσειράς αλλά παράλληλα να μην επιβαρύνει το υπολογιστικό και χρονικό κόστος των πειραμάτων. Είναι, λοιπόν, σκόπιμο να ερευνηθεί αυτή η παράμετρος, σε σχέση

και με τις αλλαγές στην αρχιτεκτονική του μοντέλου που προτείνονται.

Σίγουρα, σημαντικός παράγοντας αποτελεί ο αλγόριθμος κωδικοποίησης των χρονοσειρών σε εικόνες. Εκτός από τις χρωματικές επιλογές και το μέγεθος των εικόνων βελτίωση επιδέχεται και ο τρόπος απεικόνισης. Συγκεκριμένα, χρειάζεται να βρεθεί ένας πιο συστηματικός τρόπος για υπολογισμό των περιθωρίων. Οι Naftali Cohen και συνεργάτες στο [18] προτείνουν μια απεικόνιση στην οποία αφήνονται περιθώρια μόνο στον κάθετο άξονα της γραφική παράστασης και όχι στον οριζόντιο. Αντίθετα, το μοντέλο τους εκπαιδεύεται να προβλέπει τη χρονοσειρά μετατοπίζοντας το απεικονιζόμενο παράθυρο κατά έναν ορίζοντα πρόβλεψης. Έτσι η χρονοσειρά στην έξοδο έχει ίδιο μήκος με αυτή της εισόδου.

Τέλος, παρατηρείται σημαντική ανισορροπία στο σύνολο δεδομένων, καθώς η πληθώρα των χρονοσειρών είναι αύξουσες. Ίσως ή αύξηση ή η εξισορρόπηση των δεδομένων επιφέρει αύξηση την απόδοσης του μοντέλου.

### 7.3 Πρακτική Εφαρμογή

Τα τελευταία χρόνια οι “έξυπνες” εφαρμογές έχουν μεγάλη απήχηση στους λάτρεις της τεχνολογίας και όχι μόνο. Οι εφαρμογές δηλαδή που συνδυάζουν τη μηχανική μάθηση με τις συμβατικές τεχνολογίες. Επιπλέον, η Tensorflow παρέχει ποικίλους και εύκολους τρόπους για deployment των μοντέλων σε εφαρμογές για android κινητά τηλέφωνα. Έτσι, θα μπορούσε κανείς να κατασκευάσει μια τέτοια εφαρμογή για πρόβλεψη χρονοσειρών από εικόνες σε πραγματικό χρόνο. Χρησιμοποιώντας τη φωτογραφική μηχανή του κινητού τηλεφώνου, η εφαρμογή θα φωτογραφίζει τη γραφική παράσταση και θα εξάγει μια πιθανή προέκτασή της. Αυτό θα μπορούσε να αποτελέσει σημαντικό εργαλείο στα χέρια των ειδικών που ασχολούνται με τις προβλέψεις και την στρατηγική, αλλά και για οποιονδήποτε άλλο επιθυμεί να προβλέψει το μέλλον.

## Παράρτημα Α΄

# Παραδείγματα Προβλέψεων

Παρακάτω παρουσιάζονται και συγκρίνονται παραδείγματα από προβλέψεις

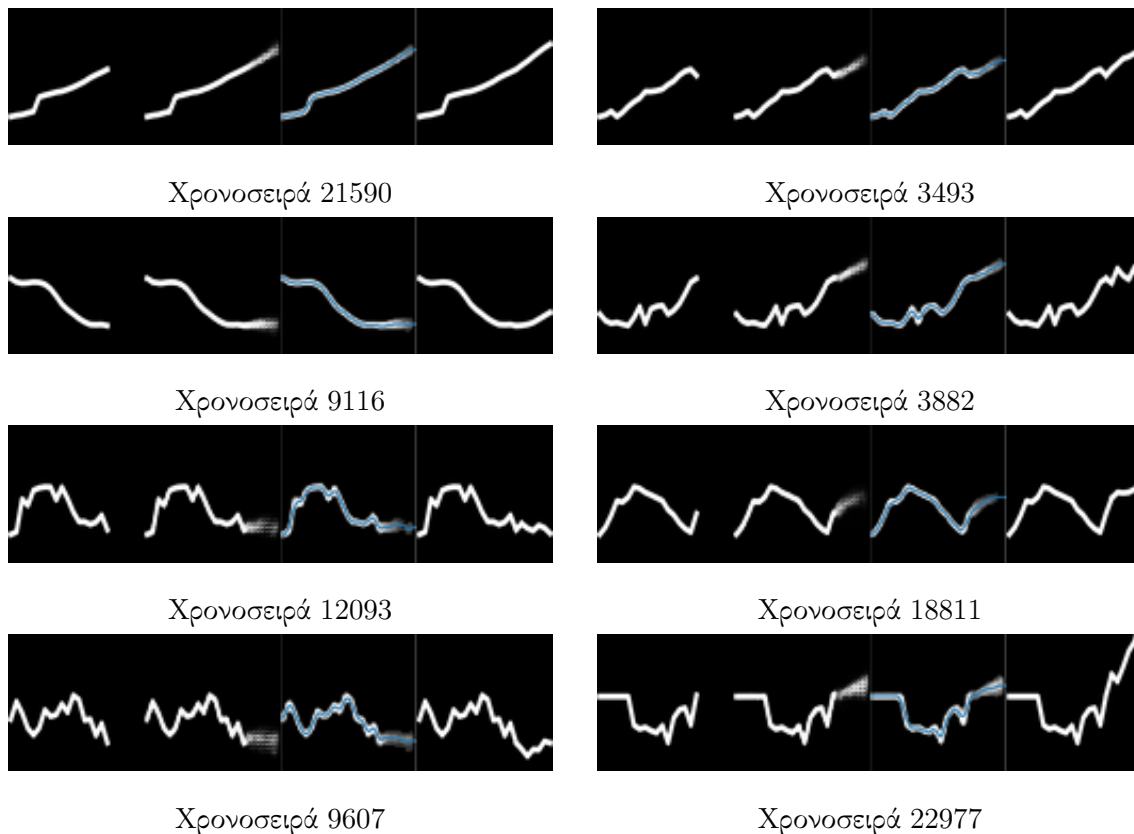
- του μοντέλου GAN με 3 συνελικτικά μπλοκ και skip connections
- του απλού αυτοκωδικοποιητή με 3 συνελικτικά μπλοκ

Καθεμιά από τις παρακάτω εικόνες αποτελούνται με τη σειρά από:

- την είσοδο (input)
- την πρόβλεψη (έξοδος μοντέλου)
- την ανακατασκευή της πρόβλεψης
- την επιθυμητή έξοδο (ground truth)

### Α'.1 GAN με 3 συνελικτικά μπλοκ και skip connections

Είναι προφανές ότι τις χρονοσειρές με πιο απλή μορφή το μοντέλο GAN τις προβλέπει με μεγάλη ακρίβεια. Στις πιο περίπλοκες χρονοσειρές δεν υπάρχει μεγάλη λεπτομέρεια ως προς την πρόβλεψη, παρόλα αυτά το μοντέλο καταφέρνει να προβλέψει το επίπεδο της χρονοσειράς.

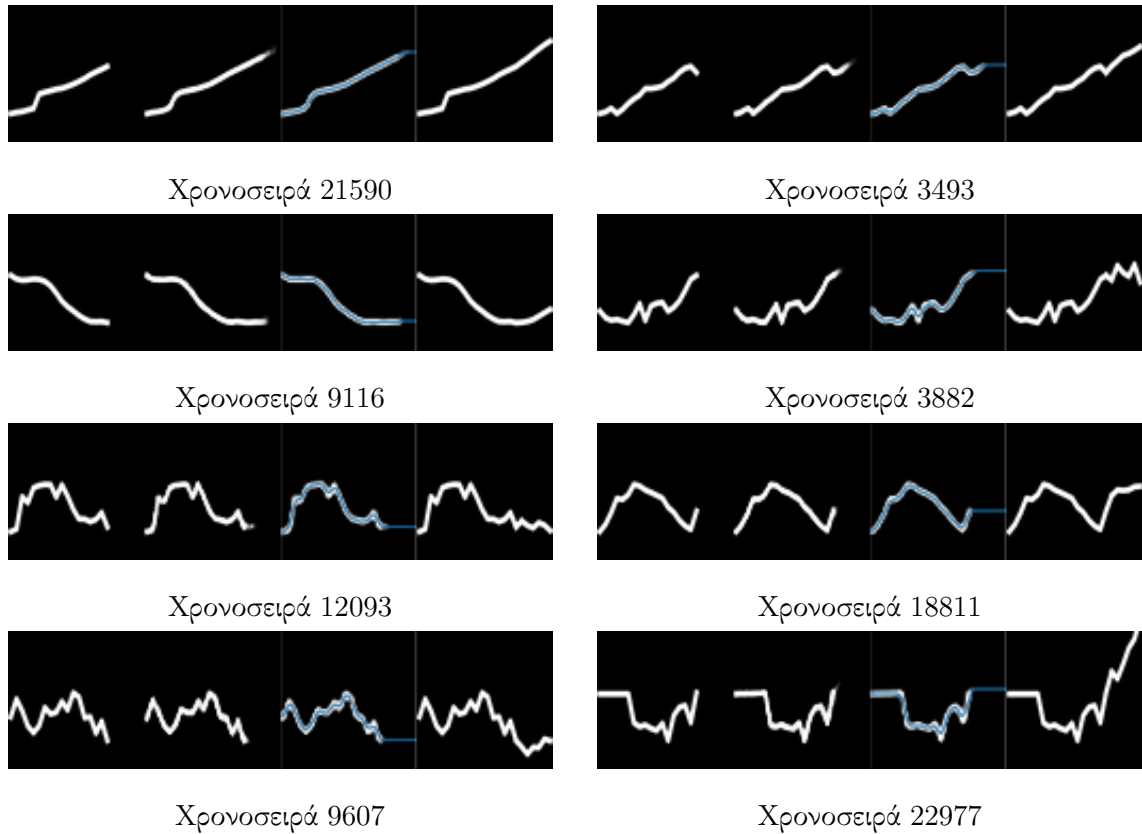


Σχήμα Α'.1: Παραδείγματα Προβλέψεων και Ανακατασκευών Μοντέλου GAN με 3 συνελικτικά μπλοκ και skip connections



## Α'.2 Απλός Αυτοκωδικοποιητής με 3 συνελκτικά μπλοκ

Η αδυναμία πρόβλεψης του απλού αυτοκωδικοποιητή είναι προφανής σε όλα σχεδόν τα παραδείγματα. Παρόλα αυτά, τα σχετικά καλά αποτελέσματα των δεικτών ακριβείας προκύπτουν από την ανακατασκευή των προβλέψεων.



Σχήμα Α'.2: Παραδείγματα Προβλέψεων και Ανακατασκευών Μοντέλου Αυτοκωδικοποιητή με 3 συνελκτικά μπλοκ



# Βιβλιογραφία

- [1] About Keras, <https://keras.io/about/>, visited on: 2020-12-09.
- [2] BatchNormalization layer, [https://keras.io/api/layers/normalization\\_layers/batch\\_normalization/](https://keras.io/api/layers/normalization_layers/batch_normalization/), visited on: 2021-01-28.
- [3] Dropout layer, [https://keras.io/api/layers/regularization\\_layers/dropout/](https://keras.io/api/layers/regularization_layers/dropout/), visited on: 2021-01-28.
- [4] Why choose Keras?, [https://keras.io/why\\_keras/](https://keras.io/why_keras/), visited on: 2020-12-09.
- [5] Alec Radford and Luke Metz and Soumith Chintala. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks. 2016.
- [6] Φώτιος Πετρόπουλος and Βασίλειος Ασημακόπουλος. *Επιχειρησιακές Προβλέψεις*. Συμμετρία, 2013.
- [7] Bairui Du and Delmiro Fernandez-Reyes and Paolo Barucca. Image Processing Tools for Financial Time Series Classification, 2020.
- [8] Carl Vondrick and Hamed Pirsiavash and Antonio Torralba. Generating Videos with Scene Dynamics. *CoRR*, abs/1609.02612, 2016.
- [9] Chigozie Nwankpa and Winifred Ijomah and Anthony Gachagan and Stephen Marshall. Activation Functions: Comparison of trends in Practice and Research for Deep Learning. *CoRR*, abs/1811.03378, 2018.
- [10] Egor Zakharov and Aliaksandra Shysheya and Egor Burkov and Victor S. Lempitsky. Few-Shot Adversarial Learning of Realistic Neural Talking Head Models. *CoRR*, abs/1905.08233, 2019.
- [11] Guoqiang Zhang and Jifeng Guo. A novel ensemble method for hourly residential electricity consumption forecasting by imaging time series. *Energy*, 203:117858, 2020.
- [12] Han Zhang and Tao Xu and Hongsheng Li and Shaoting Zhang and Xiaolei Huang and Xiaogang Wang and Dimitris N. Metaxas. StackGAN: Text to Photo-realistic Image Synthesis with Stacked Generative Adversarial Networks. *CoRR*, abs/1612.03242, 2016.

- 
- [13] Ian Goodfellow and Jean Pouget-Abadie and Mehdi Mirza and Bing Xu and David Warde-Farley and Sherjil Ozair and Aaron Courville and Yoshua Bengio. Generative Adversarial Networks. *Commun. ACM*, 63(11):139–144, oct 2020.
- [14] Ian Goodfellow and Yoshua Bengio and Aaron Courville. *Deep Learning*. MIT Press, 2016. <http://www.deeplearningbook.org>.
- [15] Ian J. Goodfellow. NIPS 2016 Tutorial: Generative Adversarial Networks. *CoRR*, abs/1701.00160, 2017.
- [16] Karen Simonyan and Andrew Zisserman. Very Deep Convolutional Networks for Large-Scale Image Recognition, 2015.
- [17] Martín Abadi and David G. Andersen. Learning to Protect Communications with Adversarial Neural Cryptography. *CoRR*, abs/1610.06918, 2016.
- [18] Naftali Cohen and Srijan Sood and Zhen Zeng and Tucker Balch and Manuela Veloso. Visual Forecasting of Time Series with Image-to-Image Regression, 2020.
- [19] Nima Hatami and Yann Gavet and Johan Debayle. Classification of Time-Series Images Using Deep Convolutional Neural Networks. *CoRR*, abs/1710.00886, 2017.
- [20] Phillip Isola and Jun-Yan Zhu and Tinghui Zhou and Alexei A. Efros. Image-to-Image Translation with Conditional Adversarial Networks. *CoRR*, abs/1611.07004, 2016.
- [21] Simon Haykin. *Νευρωνικά Δίκτυα και Μηχανική Μάθηση*. Παπασωτηρίου, 2010.
- [22] Spyros Makridakis and Evangelos Spiliotis and Vassilios Assimakopoulos. Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS ONE*, 13(3):e0194889, 2018.
- [23] Spyros Makridakis and Evangelos Spiliotis and Vassilios Assimakopoulos. The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1):54 – 74, 2020. M4 Competition.
- [24] Xixi Li and Yanfei Kang and Feng Li. Forecasting with time series imaging. *Expert Systems with Applications*, 160:113680, 2020.