

# **Ανοικτό Πανεπιστήμιο Κύπρου**

**Σχολή Θετικών και Εφαρμοσμένων Επιστημών**

**Μεταπτυχιακό Πρόγραμμα Σπουδών Διαχείριση και  
Προστασία Περιβάλλοντος**

## **Μεταπτυχιακή Διατριβή**



**Πρόγνωση Παραγωγής Μονάδας Αιολικής Ενέργειας με τη  
χρήση Νευρωνικών Δικτύων**

**Τρύφωνας Κανελλόπουλος**

**Επιβλέπων Καθηγητής  
Ασπασία Ευθυμιάδου**

**Δεκέμβριος 2017**

# **Ανοικτό Πανεπιστήμιο Κύπρου**

**Σχολή Θετικών και Εφαρμοσμένων Επιστημών**

**Μεταπτυχιακό Πρόγραμμα Σπουδών Διαχείριση και  
Προστασία Περιβάλλοντος**

## **Μεταπτυχιακή Διατριβή**

**Πρόγνωση Παραγωγής Μονάδας Αιολικής Ενέργειας με τη  
χρήση Νευρωνικών Δικτύων**

**Τρύφωνας Κανελλόπουλος**

**Επιβλέπων Καθηγητής  
Ασπασία Ευθυμιάδου**

Η παρούσα μεταπτυχιακή διατριβή υποβλήθηκε προς μερική εκπλήρωση των απαιτήσεων για απόκτηση μεταπτυχιακού τίτλου σπουδών στη Διαχείριση και Προστασία Περιβάλλοντος από τη Σχολή Θετικών και Εφαρμοσμένων Επιστημών του Ανοικτού Πανεπιστημίου Κύπρου.

**Δεκέμβριος 2017**



## Περίληψη

Τα τελευταία έτη παρατηρείται μια ευρύτατη διείσδυση των μονάδων παραγωγής ηλεκτρικής ενέργειας από ανανεώσιμες πηγές, στα σύγχρονα συστήματα παραγωγής, με αποτέλεσμα την αύξηση της εγκατεστημένης ισχύος στην Ευρώπη αλλά και παγκοσμίως. Η αιολική ενέργεια είναι μια από τις ευρύτερα χρησιμοποιούμενες εναλλακτικές μορφές ενέργειας, ωστόσο η διακοπτόμενη φύση της και η έντονη μεταβλητότητα της καθιστούν δύσκολη την ενσωμάτωση της στα συστήματα ηλεκτρικής ενέργειας, εφόσον η παραγωγή των μονάδων αυτών είναι μη ελεγχόμενη, σε αντίθεση με τις συνήθεις συμβατικές μονάδες παραγωγής ηλεκτρικής ενέργειας. Προς την κατεύθυνση επίλυσης του προβλήματος αυτού συμβάλλει αποφασιστικά η πρόβλεψη της αιολικής ισχύος, ώστε να καθίσταται ευκολότερη η διαχείριση και η ενσωμάτωση της στο δίκτυο.

Στόχος της παρούσας διπλωματικής εργασίας είναι η πιθανοτική πρόβλεψη της αιολικής ισχύος με τη χρήση νευρωνικών δικτύων. Αναλυτικότερα θα εξεταστεί η ικανότητα πρόβλεψης των προγραμμάτων λογισμικού Zaitun και NeuroXL Predictor που στηρίζονται στα νευρωνικά δίκτυα. Τα προγράμματα αυτά είναι στατιστικά μοντέλα που δέχονται ως είσοδο απευθείας δεδομένα αριθμητικής πρόγνωσης καιρού και στην έξοδο παρουσιάζονται οι πιθανότητες εμφάνισης τιμών αιολικής ισχύος για δεδομένο χρονικό ορίζοντα.

Αρχικά πραγματοποιείται μια αναλυτική παρουσίαση των βιολογικών και τεχνητών νευρωνικών δικτύων καθώς και οι βασικοί αλγόριθμοι εκπαίδευσης των δεύτερων. Έπειτα περιγράφεται η ενεργειακή κατάσταση στην Ευρώπη και στην Ελλάδα με έμφαση στην αιολική πραγματικότητα. Στη συνέχεια περιγράφονται κύρια χαρακτηριστικά και τα στατιστικά του ανέμου καθώς και οι ορίζοντες πρόβλεψης, τα μοντέλα πρόβλεψης και αναφοράς. Τέλος μελετάται η ικανότητα πρόβλεψης των προαναφερόμενων μοντέλων και αποτιμάται η αξιοπιστία τους.

**Λέξεις Κλειδιά:** Ηλεκτρική ενέργεια, ανανεώσιμες πηγές, συστήματα παραγωγής, διακοπτόμενη φύση, έντονη μεταβλητότητα, πρόβλεψη της αιολικής ισχύος, νευρωνικά δίκτυα, στατιστικά μοντέλα, δεδομένα αριθμητικής πρόγνωσης καιρού, ορίζοντες πρόβλεψης, αξιοπιστία.

## Summary

In recent years there has been a widespread penetration of renewable power plants into modern production systems, resulting in an increase in installed capacity in Europe and globally. Wind power is one of the most widely used alternative forms of energy, but its intermittent nature and its high volatility make it difficult to integrate into power systems, since production of these units is uncontrolled, unlike usual conventional units of production of electrical power. In order to solve this problem, the wind power prediction is decisively contributing to making it easier to manage and integrate into the grid.

The aim of this present diploma thesis is the probabilistic prediction of wind power using neural networks. In more detail, we will examine the prediction ability of Zaitun and NeuroXL Predictor software programs, which based on neural networks. These programs are statistical models that accept direct numerical weather forecast data as input, and the output presents the chances of wind power values for a given time horizon.

Initially, a detailed presentation of the biological and artificial neural networks as well as the basic training algorithms of the second ones is carried out. Then, the energy situation in Europe and Greece with emphasis on wind reality is described. On the other hand the main features and wind statistics, as well as the forecasting horizons, predictive and reference models are described below. Finally, the prediction ability of the aforementioned models is studied and their reliability is evaluated.

**Key words:** Electricity, renewable energy, production systems, intermittent nature, high volatility, wind power prediction, neural networks, statistical models, weather forecasting data, forecast horizons, reliability.

## **Ευχαριστίες**

Για την ολοκλήρωση της μεταπτυχιακής αυτής διατριβής, ευχαριστώ θερμά την Ασπασία Ευθυμιάδου και τους Τασσόπουλο Θεόδωρο και Κωνσταντίνο Καλογερόπουλο.



3.4. Ερευνητική Διαδικασία .....	91
3.5. Ανάλυση Αποτελεσμάτων .....	99
4. Κεφάλαιο 4: Αποτελέσματα .....	101
4.1. Παρουσίαση Αποτελεσμάτων .....	101
5. Κεφάλαιο 5: Συζήτηση-Συμπεράσματα-Εισηγήσεις .....	105



# Κεφάλαιο 1

## Εισαγωγή

Οι ανανεώσιμες πηγές ενέργειας (ΑΠΕ) αποτελούν το δυναμικότερο κεφάλαιο της σύγχρονης ενεργειακής πραγματικότητας. Η ανάπτυξη τους κατά τις τελευταίες δεκαετίες υπήρξε ραγδαία, τόσο λόγω των οικονομικών κινήτρων που έχουν δοθεί από τα διάφορα κράτη παγκοσμίως, όσο και της ανάγκης μείωσης του περιβαλλοντικού αποτυπώματος του ενεργειακού τομέα (Carvalho, 2012). Οι ΑΠΕ σε όλες τις μορφές τους (αιολική ενέργεια, ηλιακή ενέργεια, υδροηλεκτρική ενέργεια, γεωθερμική ενέργεια, βιομάζα, βιοκαύσιμα και ενέργεια κυματική ή παλιρροϊκή) είναι πρακτικά ανεξάντλητες και φιλικές ως προς το περιβάλλον και αποτελούν την κυριότερη προσπάθεια απεξάρτησης από τις εξαντλούμενες πλέον συμβατικές πηγές ενέργειας (κυρίως ορυκτών καυσίμων), η αλόγιστη χρήση των οποίων (Pachauri, Meyer, 2014) έχει εντείνει την περιβαλλοντική αλλοίωση και την κλιματική αλλαγή σε βαθμό ίσως μη αντιστρέψιμο (Bointner, Pezzutto, Grilli, Sparber, 2016). Η εισαγωγή της βιώσιμης ανάπτυξης στην διεθνή κοινότητα αρκετά χρόνια πριν, η οποία προσδιορίζει το περιβάλλον και την προστασία του ως έναν από τους βασικούς πυλώνες ανάπτυξης, οδήγησε σταδιακά μέσω της εξέλιξης των τεχνολογιών και των εφαρμοζόμενων πολιτικών στα σημερινά ενεργειακά δεδομένα, όπου οι ΑΠΕ διαρκώς αυξάνουν το ποσοστό συμμετοχής τους στην ηλεκτροπαραγωγή. Πρωτοπόρος στην κατεύθυνση αυτή είναι Ευρωπαϊκή Ένωση, που κατέχει ηγετική θέση στις τεχνολογίες των ΑΠΕ ενώ παράλληλα εξελίσσει διαρκώς και το αντίστοιχο νομοθετικό της πλαίσιο (EUROPA, 2009).

Η συνεχόμενη ανάπτυξη των ΑΠΕ οφείλεται στη δυνατότητα βελτίωσης της απόδοσης τους, ώστε να αποτελούν σημαντική εναλλακτική συνιστώσα αποφόρτισης του ενεργειακού προβλήματος, ενώ κάθε νέο τεχνολογικό βήμα εξέλιξης τους

πραγματοποιείται με γνώμονα το κόστος τους να είναι συγκρίσιμο με αυτό των συμβατικών πηγών. Η εγκατάσταση και λειτουργία αυτών, πέραν του φιλικού περιβαλλοντικού χαρακτήρα και του μεγάλου χρόνου ζωής, επιφέρει μια σημαντική σειρά πλεονεκτημάτων: αποκέντρωση του συστήματος ενέργειας, αποφόρτιση των υποδομών, μείωση σε απώλειες ενέργειας (λόγω διασποράς τους), εθνική ανεξαρτησία και ασφάλεια, ορθολογική κατανάλωση ενεργειακών πόρων, ανεπηρέαστο και χαμηλό κόστος χρήσης, δημιουργία θέσεων εργασίας (Markandya, Arto, González-Eguino, Román, 2016) και τοπική οικονομική-κοινωνική αναβάθμιση. Από την άλλη πλευρά, τα χαρακτηριστικά που καθιστούν την αξιοποίηση τους δυσχερή είναι οι περιορισμοί στην πυκνότητα, συγκέντρωση και αποθήκευση (BARTOSZ WAŚKOWICZ, 2017) της ενέργειας που παράγουν, οι μεγάλες εγκαταστάσεις τους, το κόστος επένδυσης (Ioannou, Angus, Brennan, 2017) και ο μικρός συντελεστής απόδοσης τους. Το μεγαλύτερο πρόβλημα όμως οφείλεται στην μεταβλητότητα που παρουσιάζουν αυτές ως προς την παραγωγή τους.

Έτσι, η αύξηση του μεριδίου των ΑΠΕ στο μείγμα της ηλεκτροπαραγωγής (DeMarco, Baone, Han, Lesieutre, 2012) αποτελεί πρόκληση για την αποτελεσματική λειτουργία των σύγχρονων αγορών ηλεκτρικής ενέργειας και την διαχείριση των Συστημάτων Ηλεκτρικής Ενέργειας (ΣΗΕ). Σε αντίθεση με τους συμβατικούς σταθμούς όπου η παραγωγή μπορεί πολύ εύκολα να προγραμματιστεί και να ελεγχθεί, η περιορισμένη προβλεψιμότητα και η υψηλή μεταβλητότητα των ΑΠΕ καθιστούν την παραγωγή τους μη ελεγχόμενη και μη καταμενόμενη από τον Διαχειριστή των ΣΗΕ, δυσχεραίνοντας την αποδοτική λειτουργία των συστημάτων και άρα των αγορών ηλεκτρικής ενέργειας, διότι με βάση το ποσοστό διείσδυσης τους στο ενεργειακό μείγμα (Wang, Guo, Huang, 2011), επηρεάζεται άμεσα ο προγραμματισμός παραγωγής των υπόλοιπων μονάδων του συστήματος, η συντήρηση των μονάδων και γραμμών μεταφοράς, τα αναγκαία επίπεδα εφεδρείας του συστήματος, οι τιμές εκκαθάρισης της ημερήσιας αγοράς ηλεκτρικής ενέργειας κ. α.

Επομένως είναι επιτακτική η ανάπτυξη και χρήση μοντέλων πρόβλεψης της παραγόμενης ενέργειας από ΑΠΕ (Graeber, Kleine, 2013) σε διαφορετικές χρονικές κλίμακες (βραχυπρόθεσμες, μεσοπρόθεσμες), εφόσον η βελτιωμένη εκτίμηση παραγωγής τους ενισχύει τις συνθήκες βέλτιστης και ομαλής κατανομής φορτίου, ασφάλειας, οικονομίας και αξιοπιστίας του συστήματος. Τέτοια μοντέλα πρόβλεψης

είναι προηγμένα λογισμικά ελέγχου, τα οποία απαιτούν όσο το δυνατόν ακριβέστερες πληροφορίες εισόδου προς επεξεργασία. Τα Νευρωνικά Δίκτυα που αναπτύχθηκαν μέσα από τις διεξαγωγές ερευνών στο χώρο της Τεχνικής Νοημοσύνης, αποτελούν ευφυή υπολογιστικά συστήματα ικανά να μιμηθούν τον ανθρώπινο εγκέφαλο όσον αφορά την αρχιτεκτονική, τη λειτουργία του και τον τρόπο παραγωγής πληροφορίας (Διαμαντάρας, 2007). Έτσι αυτά εφαρμόζονται με μεγάλη επιτυχία σε μεγάλο φάσμα τομέων της επιστήμης και της τεχνολογίας, οπουδήποτε τίθεται θέμα πρόβλεψης, ταξινόμησης ή ελέγχου. Ένα εκπαιδευμένο τεχνητό νευρωνικό δίκτυο μπορεί να συνδυάσει τις διαφορές εισόδους στους νευρώνες, όπως είναι η ταχύτητα και η κατεύθυνση του ανέμου, η ηλιακή ακτινοβολία, η θερμοκρασία κ. α. δίνοντας απευθείας πρόβλεψη της ηλεκτρικής ισχύος πολλών σταθμών ΑΠΕ και διευκολύνοντας τον Διαχειριστή του Συστήματος.

Η παρούσα διπλωματική εργασία επικεντρώνεται στην πρόβλεψη της παραγωγής ενέργειας των αιολικών μονάδων, λόγω της διακοπτόμενης φύσης τους και της έντονης μεταβλητότητας που παρουσιάζουν. Σκοπός της είναι η δημιουργία ενός μοντέλου πιθανοτικής πρόβλεψης ισχύος με τη χρήση νευρωνικών δικτύων για την ευκολότερη διαχείριση και ενσωμάτωση τους στο δίκτυο. Στο πλαίσιο αυτό θα εξεταστούν οι λειτουργίες πρόγνωσης συγκεκριμένων λογισμικών εργαλείων και η ελαχιστοποίηση του σφάλματος τους με βάση τις ανάγκες και τις απαιτήσεις των μονάδων ΑΠΕ καθώς και των αγορών ηλεκτρικής ενέργειας.


# Κεφάλαιο 2

## Βιβλιογραφική Ανασκόπηση

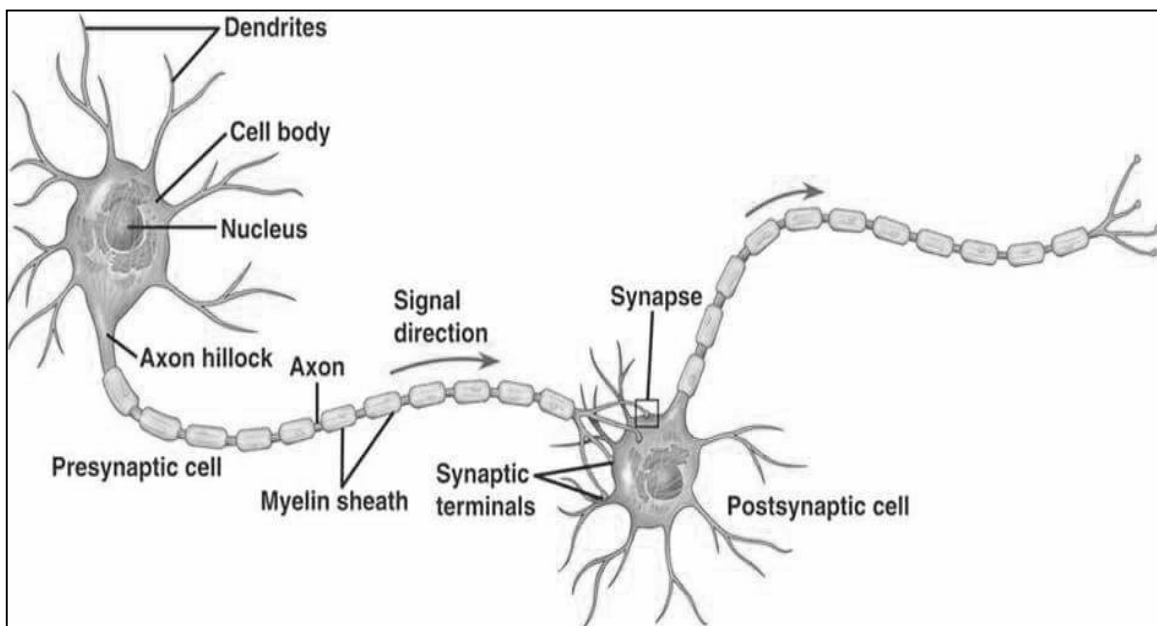
### 2.1 Βιολογικά Νευρωνικά Δίκτυα

Τα βιολογικά νευρωνικά δίκτυα (neural nets) των ζώντων οργανισμών παίζουν μεγάλο ρόλο στην επιστήμη των νευρωνικών δικτύων διότι σε αυτά οφείλεται η έμπνευση και οι ιδέες υλοποίησης και λειτουργίας τους. Στον άνθρωπο θεωρούμε ότι η βασική μονάδα δόμησης του εγκεφάλου είναι ένα εξειδικευμένο κύτταρο που ονομάζεται νευρώνας. Ο αριθμός των νευρώνων αυτών είναι πολύ μεγάλος, της τάξης του  $10^{10}$  και όλοι διαφορετικοί μεταξύ τους. Κάθε νευρώνας συνδέεται με πολλούς άλλους νευρώνες με συνδέσεις που ονομάζονται συνάψεις (περίπου  $10^4$  συνάψεις ανά νευρώνα). Ένας αριθμός νευρώνων με τις συνάψεις τους αποτελούν ένα νευρωνικό δίκτυο ενώ το σύνολο των νευρωνικών δικτύων αποτελεί το κεντρικό νευρικό σύστημα του ανθρώπινου οργανισμού (Διαμαντάρας, 2007).

Οι νευρώνες ως κύτταρα, από πολύ νωρίς δεν πολλαπλασιάζονται και δεν αναπαράγονται περαιτέρω σε αντίθεση με τις συνάψεις όπου μπορούν να δημιουργούνται νέες και να καταστρέφονται παλιές ανάλογα τα ερεθίσματα και τις εμπειρίες που δέχεται ο εγκέφαλος από το περιβάλλον. Ο ρόλος του νευρώνα στο νευρωνικό δίκτυο είναι η λήψη, η επεξεργασία και η μετάδοση ηλεκτρικών σημάτων (παλμών). Αποτελείται από το κυρίως σώμα στο οποίο συμβαίνουν οι απαραίτητες χημικές δράσεις, έναν άξονα που εφάπτεται με άλλους νευρώνες για τη μετάδοση σημάτων και τους δενδρίτες, οι οποίοι σε επαφή με άλλους νευρώνες δέχονται τα εισερχόμενα σήματα. Οι συνδέσεις μεταξύ των νευρώνων με τους άξονες και τους δενδρίτες, γίνονται στις πολύπλοκες επαφές που ονομάζονται συνάψεις. Μια σύναψη αποτελείται από το συναπτικό χάσμα, την προσυναπτική και τη μετασυναπτική μεμβράνη και τα συναπτικά κυστίδια που απελευθερώνουν τους νευρομεταβιβαστές, δηλαδή το σήμα που θα φτάσει στο νευρώνα δέκτη.



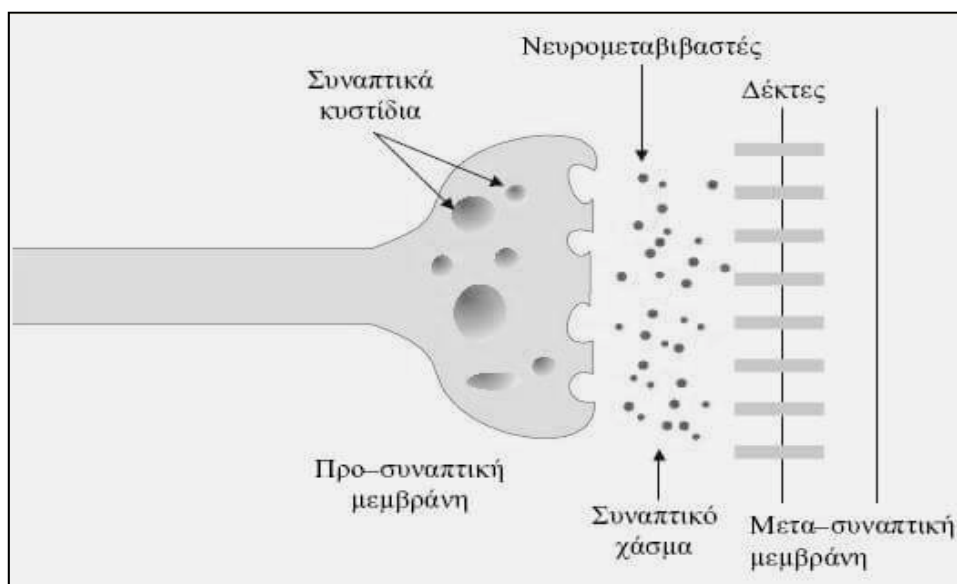
**Εικόνα 1:** Ο βιολογικός νευρώνας, Πηγή:  
<https://www.cs.uaf.edu/2007/fall/cs441/proj1notes/schamel/>



**Εικόνα 2:** Συνάψεις μεταξύ δύο βιολογικών νευρώνων, Πηγή:  
<https://mikerbio.weebly.com/structure--function.html>

Κάθε νευρώνας έχει δύο δυνατές καταστάσεις λειτουργίας: την ενεργό και τη μη ενεργό, επομένως λειτουργεί σαν δυαδικό στοιχείο. Η παραγωγή και η μετάδοση του σήματος από το νευρώνα οφείλεται σε μεμβρανικά δυναμικά και είναι αποτέλεσμα της ευαισθησίας του νευρώνα, δηλαδή της ικανότητας του να αντιδρά σε εξωτερικά ερεθίσματα (μηχανικά, θερμικά, χημικά κ.α.). Τα σήματα που καταφθάνουν σε ένα νευρώνα αθροίζονται και αυτός πυροδοτεί παλμό μόνο αν το άθροισμα των δυναμικών

τους ξεπεράσει μια δεδομένη τιμή (δυναμικό κατωφλίου), αλλιώς αυτός παραμένει αδρανής. Ο παλμός του νευρώνα έχει πάντα το ίδιο μέγεθος και ταξιδεύει στο νευρωνικό δίκτυο χωρίς να ελαττωθεί καθόλου ενώ ο νευρώνας επιστρέφει σε ηρεμία μέχρι να ενεργοποιηθεί πάλι. Έτσι δίκτυα μεταφέρουν ηλεκτρικά σήματα σε ολόκληρο το κεντρικό νευρικό σύστημα ελέγχοντας κάθε λειτουργία του (Adelman, Smith, 1997).



Εικόνα 3: Λεπτομερής απεικόνιση μιας βιολογικής σύναψης, (Αργυράκης, 2001).

## 2.2 Τεχνητά Νευρωνικά Δίκτυα

Τα τεχνητά νευρωνικά δίκτυα (artificial neural nets) αποτελούν μια νέα σχετικά περιοχή για τις φυσικές επιστήμες, ουσιαστικά διεθνώς μετά το 1980, καθώς η ανάπτυξη τους στηρίχθηκε στην τεράστια ανάπτυξη των ηλεκτρονικών υπολογιστών, Η/Υ (υλικό, λογισμικό, αλγόριθμοι εκπαίδευσης). Πρόκειται για υπολογιστικά προγράμματα που χρησιμοποιούνται για να λύσουν διαφορετικά προβλήματα με τη χρήση Η/Υ, με διαφορετική όμως φιλοσοφία, συνδυάζοντας τον τρόπο σκέψης του ανθρώπινου εγκεφάλου με τον αφηρημένο μαθηματικό τρόπο σκέψης. Έχουν επομένως την ικανότητα να ανταποκρίνονται σε ερεθίσματα που δέχονται στην είσοδο τους και μαθαίνουν να προσαρμόζονται στο περιβάλλον τους. Η αποτελεσματικότητά τους στηρίζεται στην εκπαίδευση τους αφού έτσι αποκτούν γνώση και εμπειρίες και στη δυνατότητα χρήσης πολύπλοκων μαθηματικών εργαλείων. Επομένως, το αντικείμενο των τεχνητών νευρωνικών δικτύων (ΤΝΔ) είναι η ανάπτυξη κατάλληλων αλγορίθμων

εκπαίδευσης και ανάκλησης της πληροφορίας που αυτά περιέχουν ώστε να προσομοιάζονται ευφυείς διαδικασίες.

Πέραν της απόκτησης και της αποθήκευσης γνώσης, διαφέρουν ακόμα σημαντικά από τα βιολογικά νευρωνικά δίκτυα, αφού χρησιμοποιούν πολύ απλοποιημένα μοντέλα νευρώνων χωρίς αυτό να σημαίνει ότι δεν μπορούν να δημιουργήσουν ενδιαφέροντα δίκτυα αρκεί το δίκτυο να αποτελείται από πολλούς νευρώνες με ρυθμιζόμενες παραμέτρους. Έτσι επιτυγχάνεται ο καταμερισμός της πληροφορίας, ο παραλληλισμός της επεξεργασίας και διευκολύνεται η μάθηση. Πιο αναλυτικά τα τεχνητά διαφέρουν από τα βιολογικά νευρωνικά δίκτυα (Αργυράκης, 2001):

1. Στον αριθμό των νευρώνων και των συνάψεων τους που είναι σημαντικά περιορισμένος.
2. Στον τρόπο και αριθμό των συνάψεων (συνδεσμολογία) που είναι πιο απλές.
3. Στον χρόνο μάθησης που είναι πιο εκτεταμένος.
4. Στον τρόπο ενημέρωσης των μονάδων του δικτύου που γίνεται σε διακριτό χρόνο και όχι σε συνεχή όπως στα βιολογικά.
5. Στην ταχύτητα μετάδοσης σήματος που είναι χιλιάδες φορές μεγαλύτερη στα τεχνητά αλλά δεν επαρκεί για να καλύψει τις υπόλοιπες διαφορές.

Οι εφαρμογές των ΤΝΔ όπως έχουν προκύψει τα τελευταία χρόνια, περιλαμβάνουν κυρίως αναγνώριση προτύπων, υπολογισμό συναρτήσεων, βελτιστοποίηση, πρόβλεψη, αυτόματο έλεγχο, χημική ανάλυση ενώ τα επόμενα χρόνια πολύ μεγαλύτερος αριθμός εφαρμογών τους αναμένεται να ακολουθήσει εφόσον ο κλάδος βρίσκεται ακόμα σε νηπιακή ηλικία. Συνοπτικά μερικές εφαρμογές των ΤΝΔ σε διάφορους τομείς της επιστήμης και τις τεχνολογίας παρουσιάζονται παρακάτω ενώ πολλές έχουν ήδη υλοποιηθεί (Αργυράκης, 2001):

- **Βιολογία:** δυνατότητα μεγαλύτερης κατανόησης της λειτουργίας του εγκεφάλου, ανάπτυξη μοντέλων όρασης.
- **Επιχειρήσεις:** δυνατότητα επιλογής κατάλληλου προσωπικού σε αντίστοιχες θέσεις στις επιχειρήσεις, αναγνώριση γραφικού χαρακτήρα.
- **Ιατρική:** δυνατότητα κατανόησης επιληπτικών κρίσεων, ανάγνωση και ανάλυση των ακτινών Χ, προβλέψεις αντιδράσεων των οργανισμών στη

φαρμακευτική λήψη, δυνατότητα διάγνωσης και θεραπείας από τα συμπτώματα, έλεγχος χειρουργείου, ανάλυση ομιλίας για την κατασκευή ακουστικών βαρηκοΐας, πρόγνωση ασθενειών, ανάλυση καρκινικών κυττάρων καθώς και ηλεκτροκαρδιογραφημάτων και ηλεκτροεγκεφαλογραφημάτων .

- **Άμυνα:** δυνατότητα αναγνώρισης και παρακολούθησης στόχων, κωδικοποίηση σημάτων με ραντάρ, χειρισμός μη επανδρωμένων οχημάτων, δημιουργία έξυπνων όπλων, βελτιστοποίηση αξιοποίησης αποθεμάτων,
- **Χρηματοοικονομικά:** ανάλυση της επικινδυνότητας των δανείων, αναγνώριση των πλαστογραφιών, μετάφραση χειρόγραφων κειμένων, αξιολόγηση επενδύσεων και ανάλυση χαρτοφυλακίων, εκτίμηση τιμών μετοχών και συναλλάγματος, ανάλυση αγοράς.
- **Βιομηχανία:** αυτοματοποίηση συστημάτων ελέγχου, δυνατότητα ελέγχου παραγωγής και επιθεώρησης της ποιότητας κατασκευής, σωστή συναρμολόγηση, ανάλυση και σχεδίαση προϊόντων, διάγνωση βλαβών, έλεγχος τροχιάς ρομπότ, μορφοποίηση ολοκληρωμένων κυκλωμάτων, μηχανική όραση.
- **Περιβάλλον:** πρόβλεψη καιρού, ανάλυση τάσεων και παρατηρήσεων, ανάλυση περιβαλλοντικής μόλυνσης.
- **Γεωλογία:** δυνατότητα ανάλυσης πετρωμάτων, εκτίμηση για την ύπαρξη κοιτασμάτων σε γεωλογικά πετρώματα.
- **Αεροπλοΐα:** ανάπτυξη προγραμμάτων προσομοίωσης πτήσης, αυτόματων πιλότων και συστημάτων ανίχνευσης ελαττωμάτων.
- **Τηλεπικοινωνίες:** συμπίεση εικόνας και δεδομένων, μεταφορά πραγματικού χρόνου, αυτοματοποιημένες υπηρεσίες πληροφοριών, συστήματα επεξεργασίας πληρωμών.

### 2.2.1.1. Ιστορική Αναδρομή

Όπως αναφέραμε πριν, αν και η επιστήμη των νευρωνικών δικτύων βρίσκεται στο προσκήνιο μόλις μερικές δεκαετίες, η ανάπτυξη τους πέρασε όμως από πολλές φάσεις και εξελίξεις. Το πρώτο μοντέλο νευρωνικού δικτύου (McCulloch, Pitts, 1943) παρουσιάστηκε το 1943 από τους McCulloch και Pitts. Θεωρείται ιστορικά η πρώτη εμφάνιση νευρωνικού δικτύου και σε αυτό θεωρείται ως βασική μονάδα του δικτύου ο νευρώνας με τις διασυνδέσεις του. Το 1947 οι ίδιοι συγγραφείς προχώρησαν σε ένα πιο εξελιγμένο πρότυπο για την αναγνώριση σχημάτων, στο οποίο ο νευρώνας μπορεί να έχει μόνο δύο καταστάσεις (πυροδότηση και ηρεμία), ενώ μπορεί να δέχεται πολλές



εισόδους αλλά δίνει μόνο μία έξοδο που οδηγεί υποχρεωτικά σε είσοδο άλλου νευρώνα. Οι απολήξεις των νευρώνων δρουν ανασταλτικά ή διεγερτικά ενώ η ροή της πληροφορίας μέσα στο νευρώνα ελέγχεται από πύλες. Οι λειτουργίες γίνονται σε διακριτό χρόνο και συγχρονισμένα.

Τα δίκτυα McCulloch και Pitts προσπάθησαν για πρώτη φορά να εξηγήσουν τη λειτουργία της μνήμης, θεωρώντας ότι η ύπαρξη κλειστών διαδρομών του σήματος μέσα στο δίκτυο μέσω ενός μηχανισμού ανάδρασης (feedback) ίσως να αποτελεί ένα πιθανό μηχανισμό μνήμης. Λίγα χρόνια μετά ο J. Von Neumann, χρησιμοποίησε τις εργασίες τους, ως παράδειγμα υπολογιστικών μηχανών (Von Neumann, 1958) κατά την εμφάνιση και διάδοση του Η/Υ. Ξεκινούν οι προσπάθειες δημιουργίας των πρώτων τεχνητών νευρωνικών δικτύων με υπόβαθρο τα βιολογικά. Συγκεκριμένα ο J. Von Neumann χρησιμοποιώντας εξιδανικευμένα στοιχεία από τον νευρώνα McCulloch-Pitts (Aspray, Burks, 1987), έθεσε τις βάσεις για την δημιουργία ενός νέου δυαδικής αριθμητικής υπολογιστή, του EDVAC (Electronic Discrete Variable Automatic Computer), στον οποίο συνυπάρχουν στη μνήμη τόσο τα προγράμματα όσο και τα δεδομένα. Αποτελεί διάδοχο του ENIAC (Electronic Numerical Integrator and Computer), του πρώτου δηλαδή γενικής χρήσης ψηφιακού ηλεκτρονικού υπολογιστή, που παρουσιάστηκε το 1946 στο Πανεπιστήμιο της Pennsylvania.

Το 1948, ο Wiener στο βιβλίο του «Cybernetics» δημοσιεύει κάποιες σημαντικές σκέψεις για τον έλεγχο, τις επικοινωνίες και τη στατιστική επεξεργασία του σήματος (Wiener, 1948) ενώ το 1961 στον δεύτερο τόμο του βιβλίου του ενισχύει τις έννοιες της μάθησης και της αυτοοργάνωσης (Wiener, 1961), κατανοώντας τη φυσική σημασία της στατιστικής μηχανικής στο περιβάλλον ενδιαφέροντος του αντικειμένου.

Την ίδια περίπου εποχή (1949), εμφανίζεται το μοντέλο του Hebb φέρνοντας μεγάλη ανάπτυξη στα νευρωνικά δίκτυα και αυτό με κεντρική ιδέα τις συνδέσεις μεταξύ των νευρώνων του συστήματος (Hebb, 1949), εισάγει όμως τον κανόνα μάθησης Hebb για τη συναπτική τροποποίηση, σύμφωνα με τον οποίο κάθε φορά που το δίκτυο χρησιμοποιεί τις νευρωνικές συνδέσεις του, αυτές ενισχύονται άρα αυξάνεται και η αποτελεσματικότητα διέγερσης, όπως αναφέρεται στο βιβλίο του «The organization of behavior». Ακολουθεί η πρώτη προσπάθεια εξομοίωσης από υπολογιστή για τον έλεγχο

καλά ορισμένης νευρωνικής θεωρίας, βασισμένης στον κανόνα μάθησης Hebb (Rochester et al, 1956).

Το 1956, ο Uttley απέδειξε ότι ένα νευρωνικό δίκτυο με τροποποιημένες συνάψεις, μπορεί να λειτουργήσει ως ταξινομητής απλών δυαδικών προτύπων στις αντίστοιχες κλάσεις (Uttley, 1956). Εισηγάγε επιπλέον τον νευρώνα ενσωμάτωσης και πυροδότησης (leaky integrate and fire neuron), που αναλύθηκε επίσημα το 1961 από τον Caianiello (Caianiello, 1961), ενώ το 1979 μελέτησε την αποτελεσματικότητα της μεταβλητής σύναψης του νευρικού συστήματος και υπέθεσε ότι εξαρτάται από την στατιστική σχέση των δυναμικών καταστάσεων που διαμορφώνονται και στις δύο πλευρές της (Uttley, 1979).

Το 1952 ο Ashby στο βιβλίο του «Design of a Brain: The Origin of Adaptive Behavior», υπέδειξε ότι η προσαρμοστική συμπεριφορά δεν είναι έμφυτη αλλά επίκτητη και η οποία μέσω της εκπαίδευσης συνεχώς βελτιώνεται (Ashby, 1952). Το 1961, ο Minsky δημοσιεύει μια άριστη εργασία (Minsky, 1961), μεγάλο μέρος της οποίας αναφέρεται στα σημερινά τεχνητά νευρωνικά δίκτυα ενώ στο βιβλίο του «Computation: Finite and Infinite Machines» το 1967, επεκτείνει τα αποτελέσματα των McCulloch και Pitts σε περιβάλλον θεωρίας αυτομάτων και υπολογισμού. Το 1954, ο Gabor (Gabor, 1954) παρουσιάζει την ιδέα του μη γραμμικού προσαρμοστικού φίλτρου (nonlinear adaptive filter). Η εκπαίδευση της αντίστοιχης μηχανής που κατασκεύασε μαζί με συνεργάτες του (Gabor, Wilby, Woodcock, 1960), γινόταν με τροφοδοσία των δειγμάτων και του αναμενόμενου στόχου σε αυτή, μέσω μιας στοχαστική διαδικασίας.

Στην περίοδο αυτή επίσης δημοσιεύεται μια εργασία του Taylor (Taylor, 1956) πάνω στη συσχετιζόμενη μνήμη (associative memory), στην οποία στηρίχθηκε μετέπειτα ο πίνακας μάθησης (learning matrix) του Steinbuch (Steinbuch, 1961). Το 1969, δημοσιεύεται η εργασία των Willshaw, Buneman και Longuet-Higgins (Willshaw, Buneman, Longuet-Higgins, 1969) πάνω στη μη ολογραφική συσχετιζόμενη μνήμη, ενώ σημαντικές είναι οι συνεισφορές των Anderson (Anderson, 1972), Kohonen (Kohonen, 1972) και Nakano (Nakano, 1972) οι οποίοι εισήγαγαν την ιδέα του συσχετιζόμενου πίνακα μνήμης (correlation matrix memory), βασισμένη στον κανόνα εκπαίδευσης εξωτερικού γινομένου (outer product). Οι Winograd και Cowan το 1963, προτείνουν την χρήση κατανεμημένης ταυτολογικής αναπαράστασης στην εκπαίδευση των

νευρωνικών δικτύων και υπέδειξαν ότι ένας μεγάλος αριθμός στοιχείων μπορεί, εντείνοντας τη συλλογικότητα, τη δυναμικότητα και τον παραλληλισμό, να αναπαραστήσει μια ατομική σκέψη (Winograd, Cowan, 1963).

Το 1957, το μοντέλο του αισθητήρα (perceptron) από τον F. Rosenblatt, είναι το πρώτο hardware μοντέλο που μπόρεσε να εκτελέσει πολλές και διαφορετικές διεργασίες στηριζόμενο μονοδρομικά σε δύο επίπεδα (την είσοδο και την έξοδο). Το αναγνωρισμένο κατόρθωμα της ερευνάς του, είναι το θεώρημα σύγκλισης του perceptron (Rosenblatt, 1960), που αποδείχθηκε από τον ίδιο αλλά και από τον Novikoff (Novikoff, 1962). Στο βιβλίο «Perceptrons» των Minsky και Papert το 1969, αποδεικνύεται με αναλυτικά μαθηματικά ότι υπάρχουν και περιορισμοί στις δυνατότητες του μονοεπίπεδου perceptron, οι οποίοι δεν αίρονταν στην πολυεπίπεδη έκδοση (Minsky, Papert, 1969).

Το 1960, οι Widrow και Hoff εισάγουν τον αλγόριθμο (Widrow, Hoff, 1960) ελαχίστων μέσων τετραγώνων (least mean square, LMS algorithm) και αναπτύσσουν γραμμικά προσαρμοστικά μοντέλα Adaline (adaptive linear element) και Madaline (multi-adaline), τα οποία χρησιμοποιήθηκαν με επιτυχία σε πρακτικά προβλήματα (Widrow, 1962). Τα μοντέλα adaline και perceptron διαφέρουν στη διαδικασία εκπαίδευσης. Το 1967, χρησιμοποιείται η μέθοδος στοχαστικής κλίσης (Amari, 1967) για την προσαρμοστική ταξινόμηση των προτύπων από τον Amari, ενώ το 1965 στο βιβλίο του Nilsson «Learning Machines» παρουσιάζεται η ταξινόμηση γραμμικά διαχωριζόμενων προτύπων σε υπερεπιφάνειες (Nilsson, 1965).

Από τη δεκαετία του '60 μέχρι και την δεκαετία του '80, το πρόβλημα της απόδοσης αξιοπιστίας στους κρυφούς νευρώνες του δικτύου ή αλλιώς (Minsky, 1961) το πρόβλημα εκχώρησης πίστωσης (credit assignment problem) το κατά τον σχεδιασμό ενός πολυεπίπεδου perceptron (Multilayer perceptron, MLP), δεν είχε ακόμα επιλυθεί αν και υπήρχαν οι αναγκαίες ιδέες και αρχές. Η αργοπορία αυτή (Cowan, 1990) ήταν αποτέλεσμα τεχνολογικών, ψυχολογικών και οικονομικών παραγόντων. Στις σημαντικότερες δραστηριότητες αυτής της χρονικής περιόδου εντάσσονται οι απεικονίσεις αυτοοργάνωσης (self-organizing maps) μέσω της ανταγωνιστικής μάθησης (Von der Malsburg, 1973), (Willshaw, Von der Malsburg, 1976) και η προσαρμοστική θεωρία συντονισμού (adaptive resonance theory) κατά την οποία αν το

πρότυπο εισόδου και το πρότυπο εκπαίδευσης από ανάδραση ταιριάζουν λαμβάνει χώρα ένας προσαρμοστικός συντονισμός (Grossberg, 1976), (Grossberg, 1980).

Χρειάστηκαν 20 περίπου χρόνια, οπότε και ο Hopfield το 1982, με τη χρήση μιας συνάρτησης ενέργειας διατύπωσε ένα νέο δρόμο για την κατανόηση του υπολογισμού των αναδρομικών δικτύων με συμμετρικές συναπτικές συνδέσεις (Hopfield, 1982). Απέδειξε ότι ένα νευρωνικό δίκτυο μπορεί να χρησιμοποιηθεί ως αποθηκευτικός χώρος ενώ επίσης μπορεί να επανακτά πλήρως την πληροφορία του συστήματος ακόμα και αν του δοθεί μέρος του συστήματος. Τα δίκτυα με ανάδραση στην πορεία καθιερώθηκαν ως δίκτυα Hopfield. Η αρχή της αποθήκευσης της πληροφορίας σε δυναμικά δίκτυα και η εγγυημένη σύγκλιση σε μία σταθερή κατάσταση οδήγησε στο 1983, στο θεώρημα Cohen-Grossberg για την αποτίμηση της ευστάθειας μια περιεχομένου-διεύθυνσης μνήμης (content-addressable memory), (Cohen, Grossberg, 1983). Το 1982 επίσης δημοσιεύεται η εργασία του Kohonen για τις απεικονίσεις αυτοοργάνωσης (Kohonen, 1982), το μοντέλο του οποίου διαφοροποιείται σε σχέση με το μοντέλο των Willshaw και Von der Malsburg και αποτέλεσε σημείο αναφοράς.

Το 1983 οι Kirkpatrick, Gelatt και Vecchi παρουσιάζουν τη διαδικασία simulated annealing για την επίλυση συνδυαστικών προβλημάτων βελτιστοποίησης που πηγάζει από την στατιστική μηχανική (Kirkpatrick, Gelatt, Vecchi, 1983) και η οποία χρησιμοποιήθηκε αργότερα από τους Ackley, Hinto και Sejnowskin, για την ανάπτυξη της μηχανής Boltzmann, του πρώτου δηλαδή επιτυχημένου πολυεπίπεδου νευρωνικού δικτύου (Ackley, Hinto, Sejnowskin, 1985). Η μηχανή αυτή αναίρεσε τις υποθέσεις των Minsky και Rapert και έθεσε τις βάσεις για την ανάπτυξη των σιγμοειδών δικτύων εμπιστοσύνης από τον Neal (Neal, 1992) το 1992, τα οποία πέτυχαν τη σημαντική βελτίωση στην εκπαίδευση καθώς και τη διασύνδεση νευρωνικών δικτύων με δίκτυα εμπιστοσύνης. Η θεωρία του μέσου πεδίου που πηγάζει και αυτή στη στατιστική μηχανική το 1996, θα βελτιώσει περαιτέρω την απόδοση της εκπαίδευσης των σιγμοειδών δικτύων εμπιστοσύνης (Saul, Jakkolla, Jordan, 1996).

Το 1986, παρουσιάζεται ο αλγόριθμος της οπίσθιας διάδοσης του σφάλματος (error-back propagation algorithm) από τους Rumelhart, Hinton και Williams, που αποτελεί τον πιο δημοφιλή αλγόριθμο για την εκπαίδευση πολυεπίπεδων perceptron (Rumelhart, Hinton, Williams, 1986) και δημοσιεύεται το πασίγνωστο βιβλίο «Parallel Distributed

Processing: Explorations in the Microstructures of Cognition» (Rumelhart, McClelland, 1986). Στο βιβλίο αυτό οι Rumelhart και McClelland, παρουσίασαν την ιδέα χρήσης του νευρωνικού δικτύου ως παράλληλου επεξεργαστή, με αποτέλεσμα να είναι δυνατή η ύπαρξη και άλλων επίπεδων νευρώνων όχι μόνο αυτών της εισόδου και της εξόδου, ώστε πλέον το δίκτυο να έχει εσωτερική δομή. Επίσης το δίκτυο εκπαιδεύεται πλέον με τη μέθοδο της οπίσθιας διάδοσης (back propagation) που χρησιμοποιείται μέχρι σήμερα. Η βασική ιδέα της οπίσθιας διάδοσης ξεκινάει από το βιβλίο «Applied Optimal Control» των Bryson και Ho το 1969 (Bryson, Ho, 1969).

Το 1988, ο Linsker διατυπώνει την αρχή της μέγιστης αμοιβαίας πληροφορίας (maximum mutual information), για την αυτοοργάνωση σε ένα αντιληπτικό δίκτυο (perceptual network) και η εργασία του (Linsker, 1988) είχε τεράστιο ενδιαφέρον για την εφαρμογή της θεωρίας της πληροφορίας στα νευρωνικά δίκτυα. Την ίδια χρονιά οι Broomhead και Love περιέγραψαν μια διαδικασία σχεδιασμού εμπρόσθια τροφοδοτούμενων δικτύων με επίπεδα, χρησιμοποιώντας ακτινικής βάσης συναρτήσεις (radial basis functions, RBF) με αποτέλεσμα τα δίκτυα αυτά να διαφοροποιούνται από τα πολυεπίπεδα perceptron. Η εργασία τους (Broomhead, Lowe, 1988) επίσης, εντατικοποίησε την έρευνα για την σύνδεση του σχεδιασμού των νευρωνικών δικτύων με μια σημαντική περιοχή της αριθμητικής ανάλυσης και των γραμμικών προσαρμοστικών φίλτρων. Το 1990, συναρτήσεις αυτές εμπλουτίστηκαν περαιτέρω από τους Poggio και Girosi οι οποίοι εφάρμοσαν τη θεωρία ομαλοποίησης (Poggio, Girosi, 1990). Στις αρχές της δεκαετίας του '90, ανακαλύπτονται τα πανίσχυρα δίκτυα support vector machines (Vapnik, 1998), επιβλεπόμενης μάθησης από πεπερασμένου μεγέθους δείγματα, για την επίλυση προβλημάτων αναγνώρισης προτύπων, παλινδρόμησης και υπολογισμού πυκνότητας στα οποία ενσωματώνεται η διάσταση VC (Vapnik-Chervonenkis) κατά τον σχεδιασμό τους και αποτελεί μετρό ικανότητας μάθησης αυτών (Vapnik, Chervonenkis, 1971).

Γενικότερα από το 1985 και μετά, αρχίζουν τα πρώτα συνέδρια αποκλειστικά στον τομέα αυτό από την American Physical society και την IEEE (Institute of Electrical and Electronics Engineers), δημιουργούνται ειδικές επαγγελματικές εταιρίες και εκδίδονται τα πρώτα περιοδικά νευρωνικών δικτύων και δημοσιεύονται εκατοντάδες εργασίες. Τέλος, τα τελευταία χρόνια έχουν δημιουργηθεί και εμπορικές εταιρίες αποκλειστικά

στην επιστημονική περιοχή αυτή, οι οποίες παράγουν εξειδικευμένα προγράμματα για τη λύση συγκεκριμένων προβλημάτων με αρκετή επιτυχία.

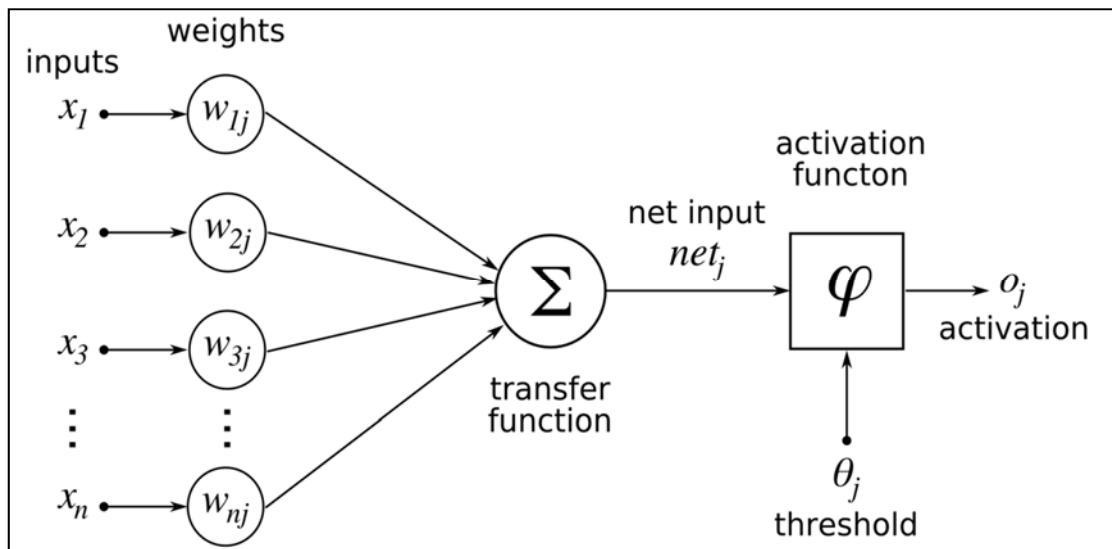
### 2.2.1.2 Το Μοντέλο του Τεχνητού Νευρώνα

Κάθε νευρωνικό δίκτυο λοιπόν αποτελείται από ένα αριθμό απλών υπολογιστικών κόμβων, διασυνδεδεμένων μεταξύ τους, τους νευρώνες (artificial neurons). Κάθε νευρώνας δέχεται ένα σύνολο αριθμητικών εισόδων (από το περιβάλλον ή από άλλους νευρώνες), επιτελεί έναν υπολογισμό με βάση αυτές και παράγει μία έξοδο, η οποία κατευθύνεται στο περιβάλλον ή ως είσοδος σε άλλους νευρώνες του δικτύου. Δηλαδή τα σήματα εισόδου  $x_1, x_2, \dots, x_n$ , στο νευρώνα πολλαπλασιάζονται με το αντίστοιχο συναπτικό βάρος  $w_i$  (ή τιμή βάρους), τα γινόμενα αυτά αθροίζονται και το ολικό άθροισμα αυτό τροφοδοτείται ως όρισμα στη συνάρτηση ενεργοποίησης  $\phi(\cdot)$  που υλοποιείται εσωτερικά στο νευρώνα. Η τιμή που λαμβάνει αυτή η συνάρτηση είναι η έξοδος  $y$  του νευρώνα για τις τρέχουσες εισόδους και βάρη. Το συναπτικό βάρος δείχνει πόσο σημαντική είναι η συνεισφορά του κάθε σήματος στη διαμόρφωση της δομής του δικτύου για τους δύο νευρώνες που συνδέει, δηλαδή όσο μεγαλύτερη είναι η τιμή  $w_i$  του βάρους τόσο μεγαλύτερη και η συνεισφορά του σήματος (σε αντιστοιχία με το χημικό δεσμό ανάμεσα σε δύο άτομα στο μόριο). Επομένως το σώμα του τεχνητού νευρώνα χωρίζεται σε δύο μέρη, τον αθροιστή (sum) και τη συνάρτηση ενεργοποίησης (activation function).

Η μοναδικότητα της εξόδου του νευρώνα αναφέρεται στην τιμή της εξόδου όχι στο πλήθος των εξόδων που σημαίνει ότι αν ένας νευρώνας έχει πολλές εξόδους αυτές θα έχουν την ίδια τιμή εξόδου. Η μαθηματική σχέση που δίνει την έξοδο του  $k$  τεχνητού νευρώνα είναι:

$$y_k = \Phi(\sum_{i=0}^n x_{ki} w_{ki}) \quad (2.1)$$

όπου  $x_{ki}$  η  $i$ -οστή είσοδος του  $k$  νευρώνα,  $w_{ki}$  το  $i$ -οστό συναπτικό βάρος του  $k$  νευρώνα και  $\phi(\cdot)$  η συνάρτηση ενεργοποίησης του νευρωνικού δικτύου. Το συναπτικό βάρος  $w_{k0}$  του  $k$  νευρώνα έχει ιδιαίτερη σημασία και καλείται κατώφλι (bias, threshold). Η τιμή της εισόδου του είναι πάντα  $x_{k0}=1$ . Αυτό σημαίνει ότι αν το συνολικό άθροισμα από τις υπόλοιπες εισόδους του νευρώνα ξεπερνά την τιμή αυτή, ο νευρώνας ενεργοποιείται, αλλιώς παραμένει ανενεργός (Haykin, 1999).



**Εικόνα 4:** Το μοντέλο του τεχνητού νευρώνα, Πηγή:  
[https://commons.wikimedia.org/wiki/File:ArtificialNeuronModel\\_english.png](https://commons.wikimedia.org/wiki/File:ArtificialNeuronModel_english.png)

Σε ένα νευρωνικό δίκτυο μπορεί να υπάρχουν νευρώνες διαφορετικού τύπου, δηλαδή με διαφορετικές συναρτήσεις ενεργοποίησης. Μια συνάρτηση ενεργοποίησης μπορεί βηματική, γραμμική, μη γραμμική ή άλλης μορφής. Μόνο ελάχιστοι νευρώνες ενός δικτύου μπορούν να είναι γραμμικοί, διότι η μη γραμμικότητα του δικτύου αποτελεί πλεονέκτημα στην αντιμετώπιση διάφορων προβλημάτων σε σχέση με άλλες μεθόδους. Οι μαθηματικές σχέσεις των κυριότερων συναρτήσεων είναι (Διαμαντάρας, 2007), (Haykin, 1999):

**1. Γραμμική συνάρτηση ενεργοποίησης (linear activation function):**

$$\Phi(x) = x \tag{2.2}$$

**2. Συνάρτηση προσήμου (sign activation function)**

$$\Phi(x) = \begin{cases} +1, & x \geq 0 \\ -1, & x < 0 \end{cases} \tag{2.3}$$

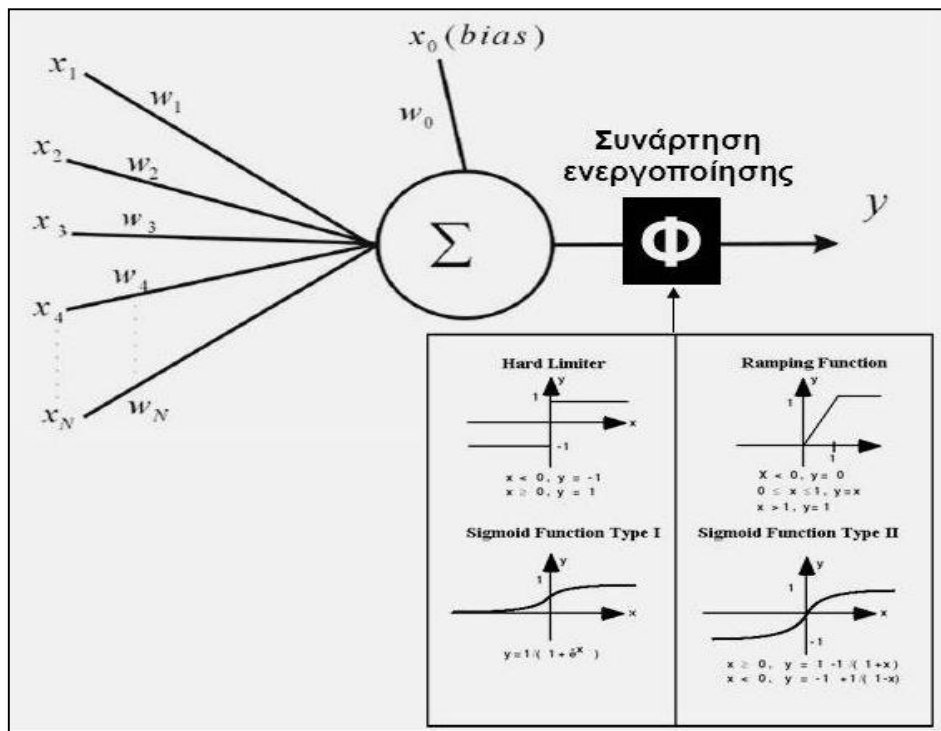
**3. Βηματική συνάρτηση ενεργοποίησης (step activation function):**

$$\Phi(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \tag{2.4}$$

**4. Μη γραμμική (σιγμοειδής) συνάρτηση ενεργοποίησης (non linear activation function, sigmoid):**

$$\Phi(x) = \frac{1}{1+e^x} \tag{2.5}$$

$$\Phi(x) = \tanh(x) \tag{2.6}$$



**Εικόνα 5:** Οι γραφικές απεικονίσεις των συναρτήσεων ενεργοποίησης του νευρώνα, Πηγή: <http://slideplayer.gr/slide/2620830/>

Οι τιμές που μπορούν να πάρουν τα σήματα εξόδου άρα και τα σήματα εισόδου είναι πεπερασμένες. Στους νευρώνες με βηματική συνάρτηση, η έξοδος μπορεί να είναι 0 ή 1, στους νευρώνες με συνάρτηση προσήμου, η έξοδος μπορεί να είναι -1 ή 1, στους νευρώνες με σιγμοειδή συνάρτηση, η έξοδος μπορεί να είναι 0 έως 1. Τα βάρη μπορούν να πάρουν οποιαδήποτε τιμή ωστόσο πολλές φορές κανονικοποιούνται.

### 2.2.1.3 Εκπαίδευση Νευρωνικού Δικτύου και Πλεονεκτήματα

Τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ) μπορούν να επιλύσουν συγκεκριμένα προβλήματα ή να επιτελέσουν από μόνα τους ορισμένες διεργασίες, μόνο αν προηγουμένως αυτά εκπαιδευτούν κατάλληλα. Η μάθηση ή εκπαίδευση, είναι και το βασικό χαρακτηριστικό των δικτύων αυτών. Τα ΤΝΔ πραγματοποιούν δύο βασικές λειτουργίες: τη μάθηση και την ανάκληση. Ανάκληση (recall) είναι η διαδικασία υπολογισμού ενός διάνυσματος εξόδου για συγκεκριμένο διάνυσμα εισόδου και τιμές βαρών ενώ μάθηση (learning) είναι η διαδικασία τροποποίησης της τιμής των βαρών του δικτύου ώστε για συγκεκριμένο διάνυσμα εισόδου να προκύψει συγκεκριμένο εξόδο. Η μάθηση γίνεται με την παρουσίαση αντίστοιχων προτύπων στο δίκτυο μέσω κατάλληλου αλγορίθμου εκπαίδευσης. Το δίκτυο μέσα από μια διαδικασία επανάληψης μεταβάλλει τις αρχικά τυχαίες τιμές των παραμέτρων του (τιμές βαρών και κατωφλίων), μέχρι να εκπαιδευτεί



πλήρως. Δηλαδή τροποποιεί την εσωτερική δομή του μέχρι να βρει τη σωστή οπότε και οι παράμετροι δεν μεταβάλλονται πλέον διότι το λάθος στην έξοδο έχει γίνει μηδέν ή τείνει στο μηδέν. Τότε το δίκτυο μπορεί και λύνει προβλήματα ίδιας φύσης και ίδιων χαρακτηριστικών με αυτά της εκπαίδευσης (training) που όμως δεν τα έχει δει πριν. Η διαδικασία που χρησιμοποιείται για την εκτέλεση της μαθησιακής διαδικασίας ονομάζεται αλγόριθμος εκπαίδευσης, μέσω του οποίου γίνεται η τροποποίηση των συναπτικών βαρών του δικτύου με βάση κανόνες μάθησης. Υπάρχουν πολλοί αλγόριθμοι εκπαίδευσης, δηλαδή προσαρμογής των παραμέτρων ενός ΤΝΔ, καθένας με τα δικά του πλεονεκτήματα.

Βασικό λειτουργικό χαρακτηριστικό ενός εκπαιδευμένου πλέον ΤΝΔ, είναι η ικανότητα γενίκευσης (generalization), δηλαδή η ικανότητα του εκτιμά με επιτυχία στόχους για άγνωστα δεδομένα εισόδου που είναι και το ζητούμενο της εκπαίδευσης. Η ικανότητα αυτή επηρεάζεται από: την επάρκεια και την αντιπροσωπευτικότητα της γνώσης που του παρέχεται, την πολυπλοκότητα του προβλήματος και το μέγεθος του ΤΝΔ (Hush, Horne, 1993). Η γνώση που αποκτά το ΤΝΔ τελικά, αποθηκεύεται στα βάρη που δε βρίσκονται στους νευρώνες, επομένως η τελική διαμόρφωση των βαρών αντιπροσωπεύει και τη γνώση των δικτύων αυτών (Haykin, 1999).

Τα βήματα της μάθησης είναι πάντα τα ίδια: το ΤΝΔ διεγείρεται από το περιβάλλον με αποτέλεσμα να υφίσταται εσωτερικές αλλαγές και επομένως αντιδρά με νέο τρόπο στο περιβάλλον λόγω των αλλαγών που σημειώθηκαν στην εσωτερική του δομή. Μαθηματικά αυτό μπορεί να περιγραφεί από τη σχέση:

$$w_{ki}(n + 1) = w_{ki}(n) + \Delta w_{ki}(n), \quad (2.7)$$

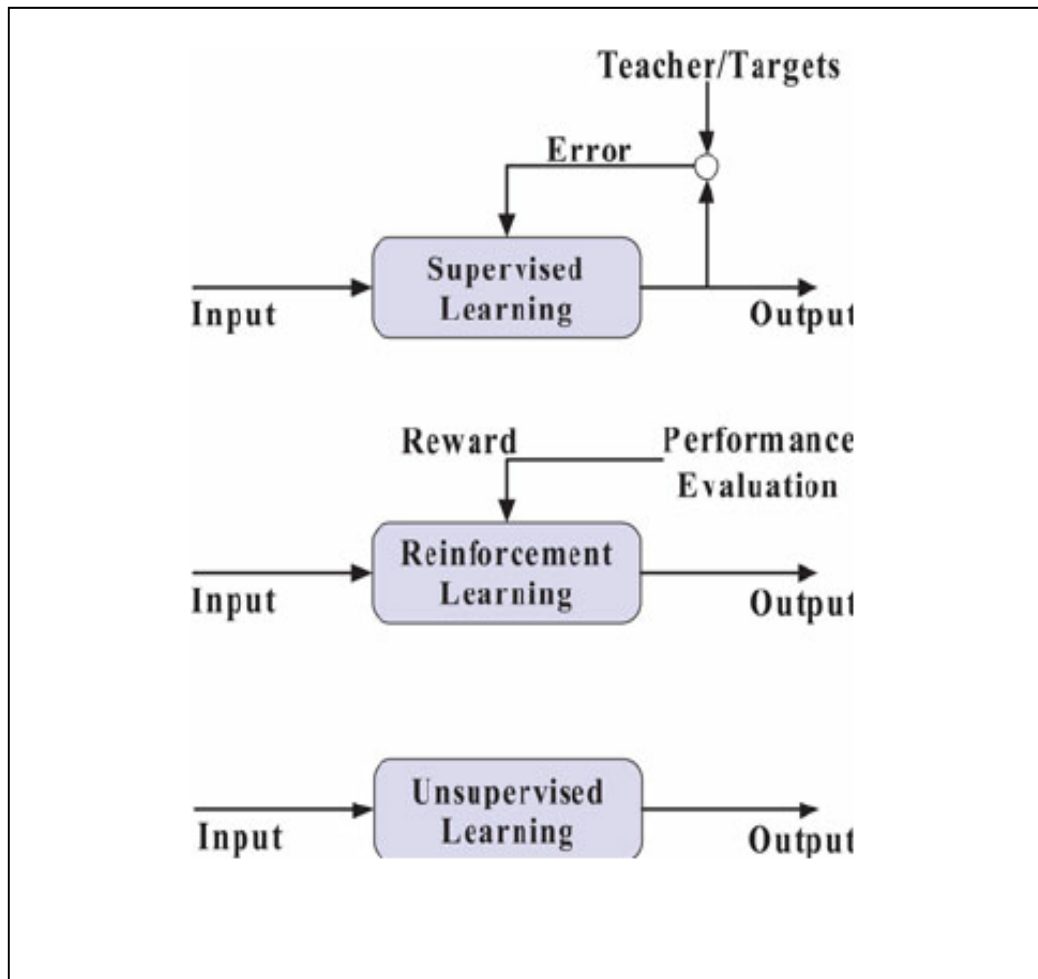
όπου  $w_{ki}(n)$  η τιμή του συναπτικού βάρους του νευρώνα  $k$  διεγερμένου από το στοιχείο  $x_i(n)$  του διανύσματος διέγερσης  $x(n)$  και  $w_{ki}(n + 1)$  η ανανεωμένη τιμή, σύμφωνα με την προσαρμογή  $\Delta w_{ki}(n)$  που εφαρμόζεται στο βάρος  $w_{ki}$ , ως αποτέλεσμα της διέγερσης από κάποιο περιβάλλον. Η παρουσία του χρόνου στην εξίσωση δηλώνει ότι το δίκτυο προσαρμόζει σταδιακά τα συναπτικά του βάρη και επομένως μπορεί να θεωρηθεί ως ο αριθμός των φορών που έχει ενημερωθεί ο νευρώνας ή πόσα παραδείγματα εκπαίδευσης έχουν εκτελεστεί.

Σύμφωνα με τον Kohonen, ένας άλλος παράγοντας που πρέπει να ληφθεί υπόψη κατά τη διάρκεια της μάθησης είναι ο τρόπος με τον οποίο ένα ΤΝΔ σχετίζεται με το

περιβάλλον του, δηλαδή τι είδους πληροφορίες είναι διαθέσιμες στο δίκτυο (Kohonen, 2001). Στο πλαίσιο αυτό, ένα παράδειγμα μάθησης αναφέρεται σε ένα μοντέλο περιβάλλοντος στο οποίο λειτουργεί το δίκτυο. Υπάρχουν τρία βασικά παραδείγματα μάθησης: η επίβλεψη, η επιτήρηση και η ενίσχυση.

- 1. Μάθηση με επίβλεψη (supervised learning):** Ο εκπαιδευτής που έχει γνώση του περιβάλλοντος, παρέχει τις τιμές των εισόδων και των στόχων που πρέπει να μάθει το δίκτυο, δηλαδή του παρέχει συγκεκριμένα εκπαιδευτικά πρότυπα (training set). Η επιθυμητή έξοδος (στόχος) είναι η βέλτιστη ενέργεια που πρέπει να εκτελέσει το ΤΝΔ. Η διαφορά επιθυμητής εξόδου και τρέχουσας εξόδου αποτελεί το σφάλμα εξόδου, το οποίο και ελαχιστοποιείται μέσα από διαδοχικές αναπροσαρμογές των βαρών (αρχικά τυχαίων) του δικτύου, ώστε αυτό να φτάσει σε μία κατάσταση που θα προσομοιώνει πλέον τη συμπεριφορά του εκπαιδευτή. Η διαδικασία αυτή μπορεί να χρειαστεί πολλές διορθώσεις και άρα μεγάλους υπολογιστικούς χρόνους. Έτσι, η γνώση του περιβάλλοντος μεταφέρεται εντός δικτύου και αποθηκεύεται με τη μορφή σταθερών συναπτικών βαρών που αποτελούν και την μακροπρόθεσμη μνήμη του δικτύου (Hush, Horne, 1993).
- 2. Μάθηση χωρίς επίβλεψη (unsupervised learning):** Ο εκπαιδευτής παρέχει και εδώ τις απαραίτητες τιμές εισόδου όχι όμως και τους αντίστοιχους στόχους επομένως η διαδικασία δεν χρειάζεται επίβλεψη. Το δίκτυο δεν χρησιμοποιεί κάποια εξωτερική παράμετρο για την αλλαγή των βαρών του αλλά μέσω ενός μηχανισμού ανάδρασης (feedback), μπορεί και διορθώνει τα σφάλματα στα δεδομένα, δηλαδή αυτό-οργανώνεται (Becker, 1991). Εδώ τα εκπαιδευτικά πρότυπα ταξινομούνται εσωτερικά σύμφωνα με κάποιο κριτήριο ομοιότητας.
- 3. Ενισχυτική μάθηση (reinforcement learning):** Στην μάθηση χωρίς επίβλεψη ανήκει και η ενισχυτική μάθηση (reinforcement learning). Εδώ χρησιμοποιείται ένα συνολικό μέτρο της επάρκειας της προκύπτουσας απόκρισης γνωστό ως ενισχυτικό σήμα (reinforcement signal), το οποίο μπορεί να οδηγήσει με ανατροφοδότηση το δίκτυο στην επιθυμητή συμπεριφορά, επιβραβεύοντας (reward) τις ορθές συμπεριφορές και τιμωρώντας (penalize) τις λανθασμένες (Barto, Sutton, Anderson, 1983). Έτσι αυξάνονται οι τιμές των βαρών που συνέβαλαν σε καλή συμπεριφορά ή μειώνονται οι τιμές των βαρών που προκάλεσαν κακή συμπεριφορά. Σε κάθε

περίπτωση που το δίκτυο δεν μεταβάλλει πλέον τις τιμές των βαρών του, η εκπαίδευση έχει ολοκληρωθεί.



**Εικόνα 6:** Βασικές δομές των τριών μαθησιακών παραδειγμάτων, Πηγή: [https://www.researchgate.net/figure/260652455\\_fig1\\_Fig-1-Basic-structures-of-the-three-learning-paradigms-supervised-learning](https://www.researchgate.net/figure/260652455_fig1_Fig-1-Basic-structures-of-the-three-learning-paradigms-supervised-learning)

Η χρήση των ΤΝΔ προσφέρει συνοπτικά τις ακόλουθες πολύ χρήσιμες δυνατότητες και ιδιότητες:

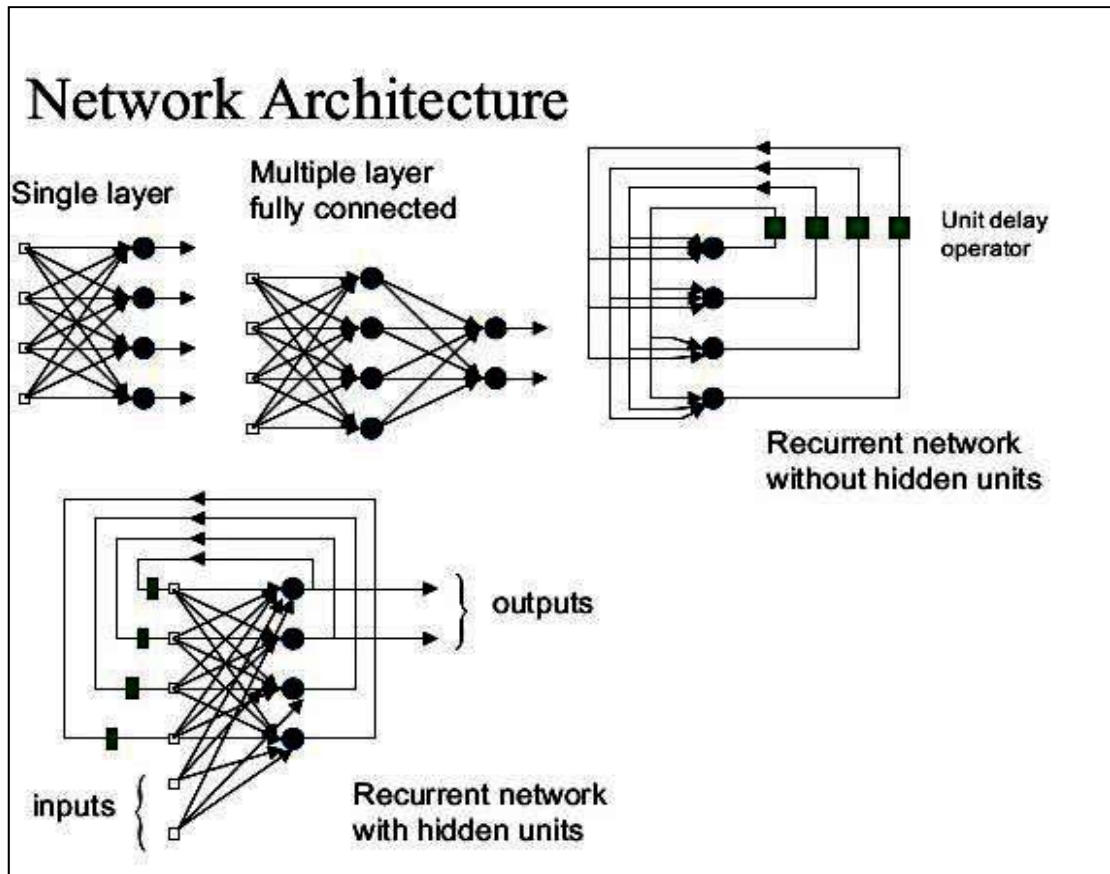
1. **Μη γραμμικότητα:** Το ΤΝΔ αποτελείται από πλήθος μη γραμμικών νευρώνων κυρίως.
2. **Συσχέτιση εισόδου και εξόδου:** Δημιουργείται μια συσχέτιση δεδομένων εισόδου και εξόδου στο ΤΝΔ, μέσω της διαδικασίας της εκπαίδευσής του.
3. **Προσαρμογή:** Τα ΤΝΔ έχουν την ικανότητα να μεταβάλλουν τα βάρη τους ανάλογα με το περιβάλλον τους (πρότυπα εισόδου).

4. **Απόκριση βασισμένη σε ενδείξεις:** Τα ΤΝΔ μπορούν να ταξινομήσουν τα πρότυπα εισόδου σε κλάσεις και να δίνουν επιπλέον τον βαθμό εμπιστοσύνης αυτής της απόφασης. Η ταξινόμηση μπορεί να επεκταθεί και σε άγνωστα πρότυπα (ικανότητα γενίκευσης)
5. **Συναφείς πληροφορίες:** Η γνώση αντιπροσωπεύεται από την δομή, την κατάσταση του ΤΝΔ και τις αλληλεπιδράσεις μεταξύ των νευρώνων του. Συναφείς πληροφορίες αντιμετωπίζονται με φυσικό τρόπο.
6. **Ανεκτικότητα σε σφάλματα:** Η απόδοση του συστήματος μειώνεται ομαλά σε περίπτωση λάθους, έτσι το ΤΝΔ δεν αχρηστεύεται.
7. **Ομοιομορφία ανάλυσης και σχεδιασμού:** Όλα τα μοντέλα ΤΝΔ μοιράζονται κάποιες κοινές βασικές αρχές (νευρώνας, σύνδεσμοι, εκπαίδευση).
8. **Βιολογική αναλογία:** Αμφίδρομη σχέση έρευνας και ανάπτυξης μεταξύ βιολογικών και τεχνητών νευρωνικών δικτύων.
9. **Παράλληλος τρόπος λειτουργίας:** Μια εργασία μοιράζεται σε όλους τους νευρώνες του δικτύου και σε συνδυασμό με τη μαζικά παράλληλη φύση τους, έχει ως αποτέλεσμα την πολύ γρήγορη απόκριση του συστήματος και τη δυνατότητα VLSI υλοποίησης (Very Large Scale Integration, VLSI).
10. **Κατανεμημένη μνήμη και μνήμη συσχέτισης:** Τα ΤΝΔ χαρακτηρίζονται έτσι, διότι η κωδικοποίηση που δημιουργούν κατανέμεται σε όλα τα βάρη της συνδεσμολογίας και διότι η αποθήκευση της πληροφορίας σε αυτά, γίνεται μέσω κατάλληλων συσχετίσεων από τα δεδομένα της εκπαίδευσης. Η ανάκληση της πληροφορίας γίνεται με βάση το περιεχόμενο και όχι τη διεύθυνση, όπως συμβαίνει με τον ανθρώπινο εγκέφαλο.

#### **2.2.1.4 Αρχιτεκτονική Τεχνητών Νευρωνικών Δικτύων**

Τα Νευρωνικά Δίκτυα αποτελούνται από ένα σύνολο τεχνητών νευρώνων. Η τεχνητή δομή των νευρώνων παρέχει μια λειτουργική περιγραφή ενός ΤΝΔ. Ο τρόπος με τον οποίο συνδέονται οι νευρώνες μεταξύ τους, καθορίζει την αρχιτεκτονική του δικτύου. Η αρχιτεκτονική αυτή, έχει μεγάλη σημασία τόσο στη σχεδίαση ενός ΤΝΔ ώστε αυτό να μπορεί να επιλύσει συγκεκριμένα προβλήματα, όσο και στην επιλογή των κατάλληλων αλγορίθμων εκπαίδευσης. Υπάρχουν τρεις διαφορετικές τάξεις αρχιτεκτονικών δικτύου, που μπορούν να αναπαρασταθούν με το λεγόμενο αρχιτεκτονικό γράφημα (Haykin, 1999):

- 1. Μονοεπίπεδα προς τα εμπρός τροφοδοτούμενα νευρωνικά δίκτυα (single layer feed forward networks):** Σε ένα Νευρωνικό Δίκτυο με επίπεδα, οι νευρώνες οργανώνονται με τη μορφή επιπέδων (layers). Οι νευρώνες κάθε επιπέδου δεν συνδέονται μεταξύ τους, αλλά έχουν διασυνδέσεις από και προς νευρώνες άλλων επιπέδων ή έχουν συνδέσεις εισόδου και εξόδου του δικτύου. Στην απλούστερη του μορφή το δίκτυο αποτελείται από ένα επίπεδο εισόδου με πηγαίους κόμβους, το οποίο προβάλλεται πάνω σε ένα επίπεδο εξόδου από νευρώνες (υπολογιστικοί κόμβοι), αλλά όχι το αντίστροφο για το λόγο αυτό ονομάζεται και τροφοδοτούμενο προς τα εμπρός (feed forward). Ο χαρακτηρισμός μονοεπίπεδο αναφέρεται στο επίπεδο εξόδου και όχι στο επίπεδο εισόδου στο οποίο δεν συμβαίνει κανένας υπολογισμός. Το σήμα μεταδίδεται από το επίπεδο εισόδου στο επίπεδο εξόδου.
- 2. Πολυεπίπεδα προς τα εμπρός τροφοδοτούμενα νευρωνικά δίκτυα (multi layer feed forward networks):** διακρίνονται για την παρουσία ενός ή περισσοτέρων κρυφών επιπέδων, των οποίων οι υπολογιστικοί κόμβοι καλούνται κρυφοί νευρώνες. Οι νευρώνες σε κάθε επίπεδο έχουν σαν εισόδους τα σήματα εξόδου μόνο του προηγούμενου επιπέδου, όποτε και διακρίνονται σε δίκτυα πλήρους ή μερικής διασύνδεσης (δηλαδή κάθε κόμβος σε κάθε στρώμα είναι είτε συνδεδεμένος είτε όχι με κάθε κόμβο στο επόμενο στρώμα). Με την προσθήκη περισσοτέρων κρυφών επιπέδων, το δίκτυο είναι ικανό να μοντελοποιεί πιο σύνθετες σχέσεις μεταξύ των μεταβλητών εισόδου και εξόδου. Το σήμα μεταδίδεται από το επίπεδο εισόδου στο επίπεδο εξόδου μέσω των κρυφών επιπέδων ενώ επεξεργασία συμβαίνει μόνο στους κρυφούς νευρώνες και στους νευρώνες εξόδου.
- 3. Αναδρομικά Δίκτυα (recurrent neural networks):** διακρίνεται από τα προηγούμενα διότι διαθέτει τουλάχιστον ένα βρόχο ανάδρασης. Η έξοδος κάθε νευρώνα του δικτύου ανατροφοδοτεί την είσοδο άλλων νευρώνων του ίδιου επιπέδου ή ακόμα και την δική του (αυτό-ανάδραση). Η παρουσία των βρόχων ανάδρασης επηρεάζει την εκπαίδευση του δικτύου και την απόδοσή του. Επιπλέον οι βρόχοι ανάδρασης περιλαμβάνουν τη χρήση στοιχείων καθυστέρησης (delay units) σε κάποιες διασυνδέσεις που επιτρέπουν στο δίκτυο να αποκτήσει μη γραμμική δυναμική συμπεριφορά. Τα αναδρομικά δίκτυα μπορούν να θεωρηθούν ως μια προσπάθεια ενσωμάτωσης του χρόνου και της μνήμης σε ένα νευρωνικό δίκτυο.



Εικόνα 7: Αρχιτεκτονική Δικτύων, Πηγή:  
<https://www.slideshare.net/MohammedBennamoun/artificial-neural-networks-lect2-neurobiology-architectures-of-anns>

## 2.3 Κανόνες Εκπαίδευσης Τεχνητών Νευρωνικών Δικτύων

Ένα προκαθορισμένο σύνολο από καλά ορισμένους κανόνες για την επίλυση ενός προβλήματος εκπαίδευσης καλείται αλγόριθμος εκπαίδευσης. Υπάρχει ποικιλία διαφορετικών αλγορίθμων και άρα πλεονεκτημάτων που προσφέρουν. Διαφοροποιούνται όμως μεταξύ τους, στον τρόπο με τον οποίο διατυπώνεται η ρύθμιση ενός συναπτικού βάρους ενός νευρώνα και στον τρόπο με τον οποίο το νευρωνικό δίκτυο σχετίζεται με το περιβάλλον του. Υπάρχουν τέσσερις βασικοί τύποι κανόνων μάθησης: η μάθηση διόρθωσης σφάλματος, η μάθηση Hebbian, η μάθηση Boltzmann και η ανταγωνιστική μάθηση. Η μάθηση διόρθωσης σφάλματος βασίζεται στη θεωρία βελτιστοποίησης, ενώ η Hebbian και η ανταγωνιστική μάθηση προέρχονται από τη νευρολογία. Η μάθηση Boltzmann διαφοροποιείται και βασίζεται σε ιδέες που προέρχονται από τη θερμοδυναμική και τη θεωρία πληροφοριών (Haykin, 1999).

- **Μάθηση διόρθωσης σφάλματος (error-correcting learning):** Αν συμβολίζουμε με  $d_k(n)$  την επιθυμητή απόκριση ενός  $k$  νευρώνα τη χρονική στιγμή  $n$  και με  $y_k(n)$  την αντίστοιχη πραγματική απόκριση του που παράγεται από ένα διάνυσμα διέγερσης  $x(n)$ , τότε προκύπτει ένα σήμα σφάλματος  $e_k(n)$  από τη σύγκριση της πραγματικής και της επιθυμητής απόκρισης ώστε:

$$e_k(n) = d_k(n) - y_k(n). \quad (2.8)$$

Το σήμα σφάλματος ενεργοποιεί ένα μηχανισμό ελέγχου ο οποίος επιφέρει διορθωτικές ρυθμίσεις στα συναπτικά βάρη του  $k$  νευρώνα ώστε το σήμα εξόδου  $y_k(n)$  να πλησιάσει το επιθυμητό σήμα  $d_k(n)$ . Η απλούστερη μορφή του κανόνα διόρθωσης σφάλματος είναι η διαδικασία σύγκλισης του Perceptron. Αυτός ο κανόνας είναι μη γραμμικός και η προσαρμογή των βαρών χρησιμοποιεί σφάλμα κβαντισμού (quantize error) που ορίζεται ως η διαφορά μεταξύ της επιθυμητής εξόδου και της εξόδου του κβαντοποιητή (Widrow, Lehr, 2003). Η προσαρμογή αυτή δίνεται από τη σχέση:


$$\Delta w_{ki} = \begin{cases} 0, & \text{αν } y_k = d_k \\ +x_i, & \text{αν } y_k = 0, d_k = 1 \\ -x_i, & \text{αν } y_k = 1, d_k = 0 \end{cases} \quad (2.9)$$

Αν  $e_k = 0$ , δεν γίνεται καμία προσαρμογή των βαρών, ειδικά η ενημέρωση των βαρών γίνεται προσθέτοντας ή αφαιρώντας το σήμα εισόδου σε αυτά, ανάλογα το σφάλμα είναι θετικό ή αρνητικό αντίστοιχα.


Άλλος τύπος του κανόνα διόρθωσης σφάλματος βασίζεται στη μέθοδο καθόδου κλίσης (Gradient descent rule). Σκοπός της μεθόδου αυτής είναι η ελαχιστοποίηση μιας συνάρτησης κόστους, η οποία βασίζεται στο σήμα σφάλματος  $e_k$ , ώστε η πραγματική απόκριση κάθε νευρώνα εξόδου να προσεγγίσει την απόκριση στόχου για τον εν λόγω νευρώνα. Επομένως μόλις επιλεγεί μια συνάρτηση κόστους στο πρόβλημα βελτιστοποίησης που προκύπτει μπορεί να εφαρμοστεί η θεωρία της βελτιστοποίησης. Ένα κριτήριο που χρησιμοποιείται για τη συνάρτηση κόστους όπως θα αναπτυχθεί παρακάτω είναι η στιγμιαία τιμή του κριτηρίου του μέσου τετραγωνικού σφάλματος.

Μπορούμε να επεξηγήσουμε τη μέθοδο καθόδου κλίσης, σχεδιάζοντας τη συνάρτηση σφάλματος συναρτήσει των συναπτικών βαρών. Αυτή η γραφική

παράσταση απεικονίζει έναν πολυδιάστατο χώρο βάρους που καλείται επιφάνεια σφάλματος.



**Εικόνα 8:** Η επιφάνεια σφάλματος στη γραμμική περίπτωση για ένα βάρος. Η κλίση του  $E$  στο χώρο του βάρους υπολογίζεται και το βάρος μετακινείται κατά μήκος της αρνητικής κλίσης, Πηγή: <http://rslab.movsom.com/paper/somrs/html/chapter3.php>



**Εικόνα 9:** Η επιφάνεια του σφάλματος στη μη γραμμική περίπτωση για ένα βάρος. Η κλίση του  $E$  στο χώρο του βάρους υπολογίζεται και το βάρος μετακινείται κατά μήκος της αρνητικής κλίσης, Πηγή: <http://rslab.movsom.com/paper/somrs/html/chapter3.php>

Σύμφωνα με την εικόνα 8, στη γραμμική περίπτωση η συνάρτηση σφάλματος γίνεται τετραγωνική στις παραμέτρους της και μπορεί να βρεθεί εύκολα μια γενική ελαχίστη λύση. Όμως στις περισσότερες περιπτώσεις η έξοδος ενός ΤΝΔ είναι μια μη γραμμική λόγω της επιλογής μη γραμμικής συνάρτησης ενεργοποίησης, με αποτέλεσμα να μην μπορεί να βρεθεί βέλτιστη λύση για τα βάρη. Ένας τρόπος να αποφευχθεί αυτό είναι η εισαγωγή όπως θα δούμε στην εξίσωση ενός όρου ορμής.



Οι πρώτοι που δημοσίευσαν ένα τέτοιο κανόνα ήταν οι Widrow και Hoff το 1960, γνωστό ως αλγόριθμο μέσου τετραγωνικού σφάλματος ή κανόνα Δέλτα των Widrow-Hoff και ήταν γραμμικός με την έννοια ότι η προσαρμογή των βαρών χρησιμοποιεί το γραμμικό σφάλμα  $e_k$ , που ορίζεται ως η διαφορά επιθυμητής εξόδου και αυτής του γραμμικού συνδυαστή (Widrow, Lehr, 2003). Η προσαρμογή αυτή δίνεται από τη σχέση:

$$\Delta w_{ki}(n) = \eta e_k(n) x_i(n), \quad (2.10)$$

όπου  $\eta$  η παράμετρος ρυθμού εκπαίδευσης και  $x_i$  το σήμα εισόδου. Η παράμετρος ρυθμού εκπαίδευσης είναι κρίσιμη για τη μάθηση διόρθωσης σφάλματος αφού καθορίζει τη σταθερότητα, την ταχύτητα σύγκλισης και την τελική ακρίβεια.

Γενίκευση του παραπάνω κανόνα αποτελεί ο γενικευμένος κανόνας Δέλτα που προϋποθέτει συνεχείς συναρτήσεις ενεργοποίησης και τουλάχιστον μια φορά διαφορίσιμες. Ο κανόνας αυτός είναι μη γραμμικός και για την προσαρμογή των βαρών χρησιμοποιείται το σιγμοειδές σφάλμα  $e_k$ , που ορίζεται ως η διαφορά επιθυμητής εξόδου και αυτής του μη γραμμικού συνδυαστή. Ο πιο δημοφιλής αλγόριθμος εκπαίδευσης που το υλοποιεί είναι αλγόριθμος οπίσθιας διάδοσης του σφάλματος (Error Back Propagation, BP).

- **Μάθηση Hebbian (Hebbian learning):** είναι ένας αλγόριθμος εκπαίδευσης χωρίς επίβλεψη στον οποίο το συναπτικό βάρος  $w_{ki}$ , από το νευρώνα  $i$  στον νευρώνα  $k$  αυξάνεται εάν και οι δύο αυτοί νευρώνες είναι ταυτόχρονα ενεργοί. Αν αυτοί ενεργοποιούνται ασύγχρονα, η ισχύς της σύνδεσης τους εξασθενεί, δηλαδή μειώνεται το συναπτικό βάρος μεταξύ τους. Η προσαρμογή λοιπόν που εφαρμόζεται στο συναπτικό βάρος  $w_{ki}$ , δίνεται από τη σχέση:

$$\Delta w_{ki}(n) = \alpha y_k(n) [c x_i(n) - w_{ki}(n)], \quad (2.11)$$

όπου  $\alpha$  μια θετική σταθερά,  $w_{ki}$  το συναπτικό βάρος,  $x_i$  το σήμα εισόδου και  $y_k$  η πραγματική απόκριση τη χρονική στιγμή  $n$ , ενώ  $c$  ορίζεται ο λόγος  $\eta/\alpha$ . Σύμφωνα με την προσαρμογή αυτή έχει επιβληθεί περιορισμός στην ανάπτυξη των συναπτικών βαρών ώστε κατά την επαναλαμβανόμενη εφαρμογή του σήματος εισόδου να αποφευχθεί ο κορεσμός στο συνολικό συναπτικό βάρος. Έτσι η αύξηση επιτρέπεται μέχρι το σημείο όπου  $c x_i(n) - w_{ki}(n) = 0$ , οπότε και σταματά η περεταίρω ενημέρωση των βαρών διότι έχει επιτευχθεί ένα σημείο ισορροπίας.

- **Ανταγωνιστική μάθηση (competitive learning):** είναι μια διαδικασία όπου οι νευρώνες εξόδου του δικτύου ανταγωνίζονται μεταξύ τους για να ενεργοποιηθούν με αποτέλεσμα μόνο ένας νευρώνας εξόδου να είναι ενεργός κάθε χρονική στιγμή. Στην ανταγωνιστική μάθηση υπάρχουν τρία βασικά στοιχεία: οι νευρώνες ανταποκρίνονται διαφορετικά στα σήματα εισόδου, στη δύναμη κάθε νευρώνα επιβάλλεται ένα όριο και εφαρμόζεται ένας ανταγωνιστικός μηχανισμός. Οι νευρώνες που κερδίζουν τον ανταγωνισμό γίνονται εξειδικευμένοι για να ανταποκρίνονται σε συγκεκριμένα χαρακτηριστικά στα δεδομένα εισόδου. Στην απλούστερη μορφή ανταγωνιστικής μάθησης το νευρωνικό δίκτυο αποτελείται από ένα επίπεδο εισόδου με πηγαίους κόμβους, το οποίο προβάλλεται πάνω σε ένα επίπεδο νευρώνων εξόδου σε πλήρη διασύνδεση. Περιλαμβάνει όμως και πλευρικές συνδέσεις μεταξύ των νευρώνων για να πραγματοποιείται η πλευρική παρεμπόδιση, όπου κάθε νευρώνας τείνει να αναστέλλει τον νευρώνα με τον οποίο συνδέεται πλευρικά. Ο νευρώνας  $k$ , είναι ο νικητής όταν για δεδομένο σήμα εισόδου παρουσιάζει τη μεγαλύτερη δραστηριότητα για τις εισροές που δέχεται (πρόσθιες και ανάδρασης). Τότε το σήμα εξόδου του νευρώνα  $k$  είναι το ένα και για τους άλλους το μηδέν. Ένας νευρώνας μαθαίνει μετατοπίζοντας τα συναπτικά του βάρη, τα οποία κατανέμονται μεταξύ των κόμβων εισόδου του, από τους ανενεργούς τους ενεργούς, ενώ καμία μάθηση δεν λαμβάνει χώρα αν ο νευρώνας δεν ανταποκρίνεται σε συγκεκριμένο σήμα εισόδου. Η προσαρμογή στο συναπτικό βάρος  $w_{ik}$  ορίζεται από τυπικό κανόνα ανταγωνιστικής μάθησης:

$$\Delta w_{ki} = \begin{cases} \eta(x_i - w_{ki}), & \text{εάν ο νευρώνας } k \text{ κερδίζει} \\ 0, & \text{εάν ο νευρώνας } k \text{ χάνει} \end{cases} \quad (2.12)$$

όπου  $\eta$  η παράμετρο ρυθμού εκπαίδευσης,  $w_{ki}$  το συναπτικό βάρος και  $x_i$  το σήμα εισόδου. Το αποτέλεσμα του κανόνα αυτού είναι ότι το συναπτικό βάρος του νικητή νευρώνα  $k$  κινείται προς το διάνυσμα εισόδου.

### 2.3.1.1 Βασικοί Αλγόριθμοι εκπαίδευσης

Οι βασικοί αλγόριθμοι εκπαίδευσης που θα αναπτύξουμε παρακάτω είναι ο αλγόριθμος μέσου ελάχιστου τετραγωνικού σφάλματος (Least Mean Square, LMS), ο αλγόριθμος του αισθητήρα (Perceptron) και ο αλγόριθμος οπίσθιας διάδοσης του σφάλματος (Error Back Propagation, BP).

**Ο Αλγόριθμος Ελάχιστου Μέσου Τετραγωνικού Σφάλματος (LMS):** Αφορά μια πρωτόγονη κατηγορία νευρωνικών δικτύων που αποτελούνται από ένα απλό νευρώνα και λειτουργούν γραμμικά. Είναι όμως σημαντική κατηγορία γιατί σε αυτή στηρίζεται η θεωρία των προσαρμοστικών γραμμικών φίλτρων, η μελέτη της οποίας οδήγησε στην ανάπτυξη μη γραμμικών νευρωνικών δικτύων πολλών επιπέδων και γιατί αποτελεί προϊόν πρωτοποριακής δουλειάς πάνω στον τομέα αυτό τη δεκαετία του 1960.

Ορίζουμε τους εξής συμβολισμούς:

1.  $x_1, x_2, \dots, x_p$ : είναι τα σήματα που παράγονται από  $p$  αισθητήρες τοποθετημένους σε διαφορετικά σημεία στο χώρο.
2.  $w_1, w_2, \dots, w_p$ : είναι τα βάρη στα οποία εφαρμόζονται τα παραγόμενα σήματα.
3.  $y = \sum_{k=1}^p w_k x_k$ : είναι η έξοδος που παράγουν τα αθροιζόμενα ζυγισμένα σήματα.
4.  $d$ : είναι η επιθυμητή έξοδος.
5.  $e = d - y$ : είναι το σήμα σφάλματος.
6.  $J = \frac{1}{2} E[e^2]$ : είναι το μέσο τετραγωνικό λάθος που είναι ένα μέτρο επίδοσης ή συνάρτησης κόστους.
7.  $E$ : είναι ο τελεστής μέσης τιμής.

Με βάση τα παραπάνω πρέπει να καθορισθεί το βέλτιστο σύνολο βαρών  $w_1, w_2, \dots, w_p$  για το οποίο το μέσο τετραγωνικό λάθος είναι ελάχιστο (φίλτρο Wiener). Χρησιμοποιούμε τις σχέσεις:

$$y = \sum_{k=1}^p w_k x_k \quad (2.13)$$

$$e = d - y \quad (2.14)$$

$$J = \frac{1}{2} E[e^2] \quad (2.15)$$

Οπότε με αντικατάσταση των σχέσεων (2.13) και (2.14) στη (2.15) προκύπτει:

$$J = \frac{1}{2} E[d^2] - E\left[\sum_{k=1}^p w_k x_k d\right] + \frac{1}{2} E\left[\sum_{j=1}^p \sum_{k=1}^p w_j w_k x_j x_k\right]. \quad (2.16)$$

Η σχέση (2.16), στην οποία το διπλό άθροισμα αναπαριστά το τετράγωνο του αθροίσματος, μπορεί να πάρει την παρακάτω μορφή:

$$J = \frac{1}{2} E[d^2] - \sum_{k=1}^p w_k E[x_k d] + \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^p w_j w_k E[x_j x_k], \quad (2.17)$$

επειδή ο τελεστής  $E$  είναι γραμμικός και τα  $w$  θεωρούνται σταθερές.

Τώρα μπορούμε να ορίσουμε τα εξής:

1.  $E[d^2]$ : είναι η μέση τετραγωνική τιμή του  $d$ , άρα ορίζουμε:

$$r_d = E[d^2] \quad (2.18)$$

2.  $E[d_{x_k}]$ : είναι η συνάρτηση ετεροσυσχέτισης (cross correlation) μεταξύ του  $d$  και του  $x_k$ , άρα ορίζουμε:

$$r_{dx}(k) = E[d_{x_k}], \quad k = 1, 2, \dots, p \quad (2.19)$$

3.  $E[x_j x_k]$ : είναι η συνάρτηση αυτοσυσχέτισης (auto correlation) του συνόλου των σημάτων εισόδου, άρα ορίζουμε:

$$r_x(j, k) = E[x_j x_k], \quad j, k = 1, 2, \dots, p \quad (2.20)$$

Η σχέση (2.17) μπορεί πλέον να πάρει την μορφή:

$$J = \frac{1}{2} r_d - \sum_{k=1}^p w_k r_{dx}(k) + \frac{1}{2} \sum_{j=1}^p \sum_{k=1}^p w_j w_k r_x(j, k). \quad (2.21)$$

Μια σχεδίαση πολλών διαστάσεων της συνάρτησης κόστους  $J$ , ως προς τα βάρη  $w$ , αποτελεί την επιφάνεια απόδοσης σφάλματος ή την επιφάνεια σφάλματος του φίλτρου. Έχει κοίλο σχήμα με καλά καθορισμένο πυθμένα, δηλαδή σημεία ολικού ελαχίστου. Αυτό το σημείο είναι και το βέλτιστο του φίλτρου αφού το μέσο τετραγωνικό σφάλμα ελαχιστοποιείται. Για τον προσδιορισμό της ελάχιστης τιμής του  $J_{min}$ , παραγωγίζουμε μερικώς τη συνάρτηση κόστους  $J$ , ως προς  $w_k$  και μηδενίζουμε το αποτέλεσμα για κάθε  $k$ . Επομένως:

$$\nabla_{w_k} J = \frac{dJ}{dw_k}, \quad k = 1, 2, \dots, p \quad (2.22)$$

$$\nabla_{w_k} J = -r_{dx}(k) + \sum_{j=1}^p w_j r_x(j, k) \quad (2.23)$$

Με την βέλτιστη συνθήκη για το φίλτρο που ορίζεται από τη σχέση:

$$\nabla_{w_k} J = 0, \quad k = 1, 2, \dots, p \quad (2.24)$$

Προκύπτουν τελικά οι βέλτιστες τιμές των βαρών  $w_{ok}$  από την σχέση:

$$\sum_{j=1}^p w_{oj} r_x(j, k) = r_{dx}(k), \quad k = 1, 2, \dots, p \quad (2.25)$$

Το σύνολο αυτών των εξισώσεων καλούνται εξισώσεις Wiener-Hopf και το φίλτρο του οποίου τα βάρη τις ικανοποιούν λέγεται φίλτρο Wiener-Hopf.

Μπορούμε να λύσουμε τις εξισώσεις αυτές με τη μέθοδο της Ταχύτερης Καθόδου (Steepest Descent). Υποθέτουμε ότι τα βάρη του φίλτρου είναι χρονικά μεταβαλλόμενα

και ότι οι τιμές τους διορθώνονται με ένα επαναληπτικό τρόπο κατά μήκος της επιφάνειας λάθους, μετακινώντας τα προοδευτικά προς τη βέλτιστη λύση. Η μέθοδος αναζητεί συνεχώς τη βέλτιστη λύση. Έστω  $w_k(n)$ , η τιμή του βάρους  $w_k$  τη χρονική στιγμή  $n$ . Η κλίση της επιφάνειας σφάλματος του φίλτρου ως προς τα βάρη έχει τη μορφή:

$$\nabla_{w_k} J(n) = -r_{dx}(k) + \sum_{j=1}^p w_j(n)r_x(j, k), \quad (2.26)$$

όπου οι δείκτες  $j, k$  αναφέρονται σε θέσεις διαφορετικών αισθητήρων στο χώρο και ο δείκτης  $n$ , σε χρονική στιγμή ή επανάληψη.

Η διόρθωση που εφαρμόζεται στο βάρος  $w_k(n)$ , σύμφωνα με τη μέθοδο, τη χρονική στιγμή  $n$  είναι:

$$\Delta w_k(n) = -\eta \nabla_{w_k} J(n), \quad k = 1, 2, \dots, p, \quad (2.27)$$

όπου  $\eta$  μια θετική σταθερά που ονομάζεται παράμετρος μάθησης (learning rate). Η ενημερωμένη τιμή βάρους την επόμενη χρονική στιγμή  $n+1$  είναι:

$$w_k(n+1) = w_k(n) + \Delta w_k(n) = w_k(n) - \eta \nabla_{w_k} J(n), \quad k = 1, 2, \dots, p. \quad (2.28)$$

Δηλαδή η ενημερωμένη τιμή του  $k$ -στου βάρους ενός φίλτρου Wiener, ισούται με την παλιά τιμή συν μια διόρθωση που είναι ανάλογη της αρνητικής κλίσης της επιφάνειας σφάλματος ως προς αυτό το συγκεκριμένο βάρος. Συνδυάζοντας τις σχέσεις (2.26) και (2.28) προκύπτει:

$$w_k(n+1) = w_k(n) + \eta [r_{dx}(k) - \sum_{j=1}^p w_j(n)r_x(j, k)], \quad k = 1, 2, \dots, p. \quad (2.29)$$

Η μέθοδος της Ταχύτερης Καθόδου, περιορίζεται από την ανάγκη γνώσης των χωρικών συναρτήσεων συσχέτισης  $r_{dx}(k)$  και  $r_x(j, k)$ , δηλαδή εφαρμόζεται σε γνωστό περιβάλλον. Σε άγνωστο περιβάλλον λειτουργίας του φίλτρου, αυτές δεν είναι διαθέσιμες και αναγκάστηκα χρησιμοποιούμε τις εκτιμήσεις τους. Σε άγνωστο περιβάλλον εφαρμόζεται ο αλγόριθμος LMS. Βασίζεται στη χρήση στιγμιαίων εκτιμήσεων των συναρτήσεων ετεροσυσχέτισης  $r_{dx}(k)$  και αυτοσυσχέτισης  $r_x(j, k)$ . Οι εκτιμήσεις αυτές συνάγονται από τις σχέσεις (2.13) και (2.14) ως εξής:

$$\hat{r}_k(j, k; n) = x_j(n)x_k(n), \quad (2.30)$$

$$\hat{r}_{dx}(k; n) = x_k(n)d(n), \quad (2.31)$$

Τα σήματα των αισθητήρων και οι επιθυμητές αποκρίσεις είναι χρονικά μεταβαλλόμενες. Αντικαθιστώντας τις εκτιμήσεις στη σχέση (2.23) προκύπτει:

$$\begin{aligned}
\hat{w}_k(n+1) &= \hat{w}_k(n) + \eta[x_k(n)d(n) - \sum_{j=1}^p \hat{w}_j(n)x_j(n)x_k(n)] = \\
&= \hat{w}_k(n) + \eta[d(n) - \sum_{j=1}^p \hat{w}_j(n)x_j(n)]x_k(n) = \\
&= \hat{w}_k(n) + \eta[d(n) - y(n)]x_k(n), \quad k = 1, 2, \dots, p,
\end{aligned} \tag{2.32}$$

όπου  $y(n)$  η έξοδος του χωρικού φίλτρου κατά την  $n$ -στη επανάληψη σύμφωνα με τον αλγόριθμο LMS, δηλαδή:

$$y(n) = \sum_{j=1}^p \hat{w}_j(n)x_j(n). \tag{2.33}$$

Ο αλγόριθμος LMS λειτουργεί τόσο σε στάσιμο όσο και σε μη στάσιμο περιβάλλον, αναζητά και ανιχνεύει το βέλτιστο. Όσο μικρότερη η παράμετρος μάθησης  $\eta$ , τόσο καλύτερη η σύγκλιση του αλγορίθμου με μικρότερο ρυθμό προσαρμογής όμως. Επιπλέον ελαχιστοποιεί το στιγμιαίο λάθος και άρα τις απαιτήσεις μνήμης. Χρησιμοποιήθηκε πρωτοποριακά στα Γραμμικά Προσαρμοστικά Στοιχεία ADALINE για ταξινόμηση προτύπων.

**Ο αλγόριθμος του αισθητήρα (Perceptron):** Το μοντέλο του αισθητήρα (perceptron) είναι η απλούστερη μορφή Νευρωνικού δικτύου και χρησιμοποιείται για την ταξινόμηση γραμμικά διαχωριζόμενων προτύπων, δηλαδή προτύπων που χωρίζονται στο δειγματοχώρο με γραμμικές συναρτήσεις. Ο στοιχειώδης αισθητήρας αποτελείται μόνο από ένα νευρώνα και είναι το πιο απλό αυτοδύναμο σύστημα που υπάρχει και μπορεί να επιτελέσει μια ορισμένη διεργασία. Δέχεται πολλές εισόδους αλλά παράγει μόνο μία έξοδο (μοντέλο McCulloch-Pitts). Πρόκειται δηλαδή για ένα γραμμικό ταξινομητή, ακολουθούμενο από ένα στοιχείο κατωφλίου, που παράγει έξοδο  $\pm 1$ . Κάθε εισερχόμενο σήμα  $x_i$  συνδέεται με τον νευρώνα με μια τιμή βάρους  $w_i$  και η έξοδος του δίνεται από τη σχέση:

$$y = f(\sum_{i=1}^p w_i x_i - \theta), \tag{2.34}$$

ενώ η διέγερση του νευρώνα δηλαδή το συνολικό σήμα που λαμβάνει δίνεται από τη σχέση:

$$v = \sum_{i=1}^p w_i x_i - \theta, \tag{2.35}$$

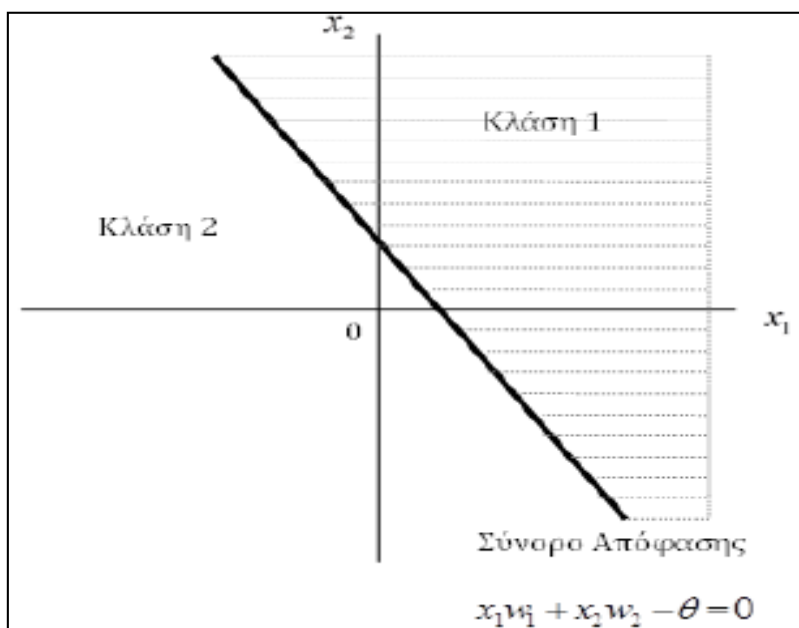
όπου  $\theta$  η τιμή κατωφλίου του νευρώνα δηλαδή η τιμή πάνω από την οποία αυτός ενεργοποιείται. Η συνάρτηση ενεργοποίησης  $f$  απεικονίζει το ολικό διάνυσμα εισόδου στην έξοδο  $y$ .

Ο αλγόριθμος που εκπαιδεύει το δίκτυο αυτό αναπτύχθηκε από τον F. Rosenblatt, ο οποίος απέδειξε ότι αν τα διανύσματα εκπαίδευσης του αισθητήρα προέρχονται από δύο γραμμικά διαχωριζόμενες κλάσεις, τότε ο αλγόριθμος αυτός συγκλίνει σε πεπερασμένο αριθμό επαναλήψεων και τοποθετεί τη διαχωριστική επιφάνεια της απόφασης με τη μορφή ενός υπερεπιπέδου μεταξύ των δύο κλάσεων.

Ο απλός αισθητήρας ταξινομεί ένα σύνολο εισόδων σε μία από τις κλάσεις  $l_1$  και  $l_2$ . Ο κανόνας απόφασης για την ταξινόμηση είναι να αναθέτει το σημείο που αναπαριστούν οι είσοδοι  $x_1, x_2, \dots, x_p$  στην κλάση  $l_1$  αν η έξοδος είναι  $y = +1$  ή στην κλάση  $l_2$  αν η έξοδος είναι  $y = -1$ . Οι περιοχές απόφασης διαχωρίζονται από το υπερεπίπεδο που ορίζεται από τη σχέση:

$$v = \sum_{i=1}^p w_i x_i - \theta = 0 \Leftrightarrow w_1 x_1 + w_2 x_2 - \theta = 0, \quad (2.36)$$

και φαίνεται στο παρακάτω σχήμα:



**Εικόνα 10:** Το όριο και οι περιοχές απόφασης για ένα δισδιάστατο πρόβλημα ταξινόμησης 2 κλάσεων, (Αργυράκης, 2001).

Παρατηρούμε στο σχήμα ότι η τιμή κατωφλίου μετατοπίζει το όριο απόφασης από την αρχή των αξόνων. Τα συναπτικά βάρη του αισθητήρα μπορούν να προσαρμοστούν επαναληπτικά, σύμφωνα με τον κανόνα σύγκλισης του Perceptron που στηρίζεται στον κανόνα σφάλματος-διόρθωσης (error-correction learning), επομένως ορίζουμε τους εξής συμβολισμούς:

1.  $x(n) = [-1, x_1(n), x_2(n), \dots, x_p(n)]^T$ , το  $(p + 1) \times 1$  διάνυσμα εισόδου.
2.  $w(n) = [\theta(n), w_1(n), w_2(n), \dots, w_p(n)]^T$ , το  $(p + 1) \times 1$  διάνυσμα βαρών.
3.  $\theta(n)$ : την τιμή κατωφλίου που αποτελεί συναπτικό βάρος συνδεδεμένο σε σταθερή είσοδο -1.
4.  $y(n)$ : την πραγματική έξοδο του αισθητήρα.
5.  $d(n)$ : την επιθυμητή έξοδο του αισθητήρα.
6.  $\eta$ : την παράμετρο ρυθμού εκπαίδευσης, θετική σταθερά  $< 1$ .
7.  $v(n) = w^T(n)x(n)$ , η έξοδος του γραμμικού συνδυαστή.

Αν λοιπόν τα διανύσματα εισόδου και βαρών είναι:

$$x(n) = [-1, x_1(n), x_2(n), \dots, x_p(n)]^T \text{ και } w(n) = [\theta(n), w_1(n), w_2(n), \dots, w_p(n)]^T,$$

η έξοδος του γραμμικού συνδυαστή τότε θα είναι:

$v(n) = w^T(n)x(n)$ . Τότε αν οι κλάσεις  $l_1$  και  $l_2$  είναι γραμμικά διαχωριζόμενες υπάρχει ένα διάνυσμα βαρών που:

$$\begin{cases} w^T x \geq 0 & \forall x \in l_1 \\ w^T x < 0 & \forall x \in l_2 \end{cases} \quad (2.37)$$

Το πρόβλημα για το απλό Perceptron είναι η εύρεση του βάρους  $w$  που ικανοποιεί τις σχέσεις της (2.37). Σύμφωνα με τον αλγόριθμο:

1. Δεν γίνεται διόρθωση στο  $w(n)$  όταν το  $n$ -οστό διάνυσμα εκπαίδευσης  $x(n)$  ταξινομείται σωστά, δηλαδή:

$$w(n+1) = w(n), \text{ αν } w^T(n)x(n) \geq 0 \text{ \& } x(n) \in l_1 \text{ και}$$

$$w(n+1) = w(n), \text{ αν } w^T(n)x(n) < 0 \text{ \& } x(n) \in l_2 \quad (2.38)$$

2. Αλλιώς το διάνυσμα βαρών του Perceptron ενημερώνεται σύμφωνα με τον κανόνα:

$$w(n+1) = w(n) - \eta(n)x(n), \text{ αν } w^T(n)x(n) \geq 0 \text{ \& } x(n) \in l_2 \text{ και}$$

$$w(n+1) = w(n) + \eta(n)x(n), \text{ αν } w^T(n)x(n) < 0 \text{ \& } x(n) \in l_1 \quad (2.39)$$

Το μεγαλύτερο μειονέκτημα του μοντέλου του απλού αισθητήρα είναι ότι δεν μπορεί να λύσει προβλήματα που είναι μη γραμμικά διαχωρίσιμα όπως συνήθως συμβαίνει στον πραγματικό κόσμο.



**Ο Αλγόριθμος Οπίσθιας Διάδοσης του Σφάλματος (BP):** Αφορά την σημαντική τάξη των πολυεπίπεδων προς τα εμπρός τροφοδοτούμενων νευρωνικών δικτύων (Li, Fu, Li, Zhang, 2009). Έχουμε ήδη αναφέρει ότι ένα τέτοιο δίκτυο αποτελείται από το επίπεδο εισόδου (σύνολο αισθητήρων), ένα ή περισσότερα κρυφά επίπεδα υπολογιστικών κόμβων (κρυφών νευρώνων) και από το επίπεδο εξόδου ενώ το σήμα εισόδου διαδίδεται μέσα στο δίκτυο από επίπεδο σε επίπεδο με κατεύθυνση προς τα εμπρός. Τα νευρωνικά αυτά δίκτυα που αναφέρονται και σαν πολυεπίπεδα Perceptrons (Multi layer Perceptrons, MLPs), έχουν εφαρμοστεί επιτυχώς στην επίλυση δύσκολων προβλημάτων. Εκπαιδεύονται με επίβλεψη μέσω του αλγόριθμου BP, ο οποίος στηρίζεται στον κανόνα διόρθωσης σφάλματος (error-correction learning). Η εκπαίδευση αυτή αποτελείται από δύο περάσματα διαμέσου των διαφορετικών επιπέδων του δικτύου:

- Εμπρόσθιο πέρασμα (forward pass): ένα διάνυσμα εισόδου εφαρμόζεται στο νευρωνικό επίπεδο εισόδου και η επίδραση του διαδίδεται μέσα στο δίκτυο από επίπεδο σε επίπεδο, ώστε να παραχθεί ένα σύνολο από εξόδους που αποτελεί και την πραγματική απόκριση του δικτύου. Κατά την διάρκεια του εμπρός περάσματος τα συναπτικά βάρη παραμένουν σταθερά.
- Οπίσθιο πέρασμα (backward pass): η πραγματική απόκριση αφαιρείται από την επιθυμητή απόκριση ώστε να δημιουργηθεί ένα σήμα σφάλματος (error signal), το οποίο στην συνέχεια διαδίδεται προς τα πίσω στο δίκτυο αντίθετα από τη διεύθυνση των συνδέσεων. Κατά την διάρκεια του οπίσθιου περάσματος τα συναπτικά βάρη ρυθμίζονται με βάση τον κανόνα διόρθωσης σφάλματος, ώστε η πραγματική απόκριση του δικτύου να πλησιάσει την επιθυμητή.

Τα MLPs έχουν τα εξής διακριτικά χαρακτηριστικά:

- Το μοντέλο κάθε νευρώνα στο δίκτυο περιλαμβάνει μια μη γραμμική συνάρτηση ενεργοποίησης, που είναι παραγωγίσιμη παντού και συνήθως σιγμοειδούς μορφής. Η μη γραμμικότητα που είναι βιολογικά εμπνευσμένη, είναι σημαντική διότι διαφορετικά, η σχέση εισόδου και εξόδου θα ελαττωνόταν σε αυτή του απλού perceptron ενός επιπέδου.
- Το δίκτυο περιέχει ένα ή περισσότερα κρυφά επίπεδα που δεν ανήκουν στο επίπεδο εισόδου ή εξόδου και καθιστούν το δίκτυο ικανό να μάθει πολύπλοκες

εργασίες αποσπώντας προοδευτικά τα πιο σημαντικά χαρακτηριστικά των διανυσμάτων εισόδου (πρότυπα).

- Το δίκτυο επιδεικνύει έναν υψηλό βαθμό διασύνδεσης που καθορίζεται από τις συνδέσεις του δικτύου. Αλλαγή στον τρόπο διασύνδεσης συνεπάγεται αλλαγή στο σύνολο των συνδέσεων ή των βαρών τους.

Ο συνδυασμός των παραπάνω χαρακτηριστικών μαζί με την αποκτούμενη εμπειρία μέσω της εκπαίδευσης αναδεικνύει την υπολογιστική ικανότητα των MLPs, αλλά και τις αδυναμίες τους. Η μη γραμμικότητα και η υψηλή διασύνδεση του δικτύου δυσχεραίνουν την θεωρητική ανάλυση του ενώ η χρήση των κρυφών νευρώνων δυσκολεύει την διαδικασία εκπαίδευσης του. Η ανάπτυξη του αλγορίθμου BP αποτελεί ορόσημο στα ΤΝΔ διότι αποτέλεσε μια υπολογιστικά αποτελεσματική μέθοδο εκπαίδευσης των MLPs, χωρίς βέβαια να παρέχει βέλτιστη λύση σε όλα τα προβλήματα.

Για την παρουσίαση του αλγορίθμου BP, θεωρούμε το MLP της εικόνας 7, το οποίο περιέχει όμως δύο κρυφά επίπεδα και το επίπεδο εξόδου ενώ είναι πλήρως διασυνδεδεμένο που σημαίνει ότι κάθε νευρώνας (κόμβος) σε ένα επίπεδο συνδέεται με όλους τους άλλους νευρώνες του προηγούμενου επιπέδου. Η ροή της πληροφορίας μέσω του σήματος εισόδου όπως αναφέραμε γίνεται από επίπεδο σε επίπεδο με κατεύθυνση προς τα εμπρός μέσα στο δίκτυο. Τα είδη σημάτων που διαδίδονται στο δίκτυο (Parker, 1987) είναι τα λειτουργικά σήματα (functional signals) και τα σήματα σφάλματος (error signals). Τα πρώτα είναι οι διεγέρσεις δηλαδή τα σήματα εισόδου που εμφανίζονται στο τέλος του επιπέδου εισόδου του δικτύου και διαδιδόμενα προς τα εμπρός τελικά εμφανίζονται στην έξοδο, ως σήματα εξόδου υπεύθυνα για την εκτέλεση μιας χρήσιμης λειτουργίας. Σε κάθε νευρώνα αυτά υπολογίζονται ως μια συνεχής μη γραμμική συνάρτηση των σημάτων εισόδου που φτάνουν σε αυτόν και των αντίστοιχων βαρών του. Τα δεύτερα προέρχονται από ένα νευρώνα εξόδου και διαδίδονται και αυτά από επίπεδο σε επίπεδο αλλά με κατεύθυνση προς τα πίσω ενώ ο υπολογισμός τους από κάθε νευρώνα εμπεριέχει μια συνάρτηση εξαρτώμενη από το σφάλμα. Τα κρυφά επίπεδα του δικτύου αποτελούνται νευρώνες υπεύθυνους για τον υπολογισμό του λειτουργικού σήματος στην έξοδο τους καθώς και για τον υπολογισμό μιας στιγμιαίας εκτίμησης του διανύσματος κλίσης, χρήσιμης για την οπίσθια διάδοση.

Ορίζουμε τους εξής συμβολισμούς:

1. Οι δείκτες  $i, j, k$  αναφέρονται σε διαφορετικούς νευρώνες του δικτύου κατά τη φορά διάδοσης του σήματος, με διαδοχική σειρά.
2. Η επανάληψη  $n$  (ή χρονικό βήμα) αναφέρεται στο  $n$ -οστό διάνυσμα εκπαίδευσης που παρουσιάστηκε στο δίκτυο ως είσοδος.
3.  $E(n)$ : είναι το στιγμιαίο άθροισμα των τετραγώνων του σφάλματος στην  $n$ -στη επανάληψη, ή στιγμιαία συνολική ενέργεια σφάλματος.
4.  $e_j(n)$ : το σήμα σφάλματος στην έξοδο του  $j$  νευρώνα για τη  $n$ -στη επανάληψη.
5.  $d_j(n)$ : η επιθυμητή απόκριση για τον  $j$  νευρώνα.
6.  $y_j(n)$ : το λειτουργικό σήμα στην έξοδο του  $j$  νευρώνα στην  $n$ -στη επανάληψη.
7.  $w_{ji}(n)$ : το συναπτικό βάρος που συνδέει την έξοδο του  $i$  νευρώνα στην είσοδο του  $j$  νευρώνα στην  $n$ -στη επανάληψη.
8.  $\Delta w_{ji}(n)$ : η διόρθωση που εφαρμόζεται στο βάρος αυτό στην  $n$ -στη επανάληψη.
9.  $v_j(n)$ : το σήμα που εφαρμόζεται στη συνάρτηση ενεργοποίησης του  $j$  νευρώνα στην  $n$ -στη επανάληψη.
10.  $\phi_j(\cdot)$ : η συνάρτηση ενεργοποίησης του  $j$  νευρώνα.
11.  $x_i(n)$ : το  $i$ -στο στοιχείο του διανύσματος εισόδου.
12.  $o_k(n)$ : το  $k$ -στο στοιχείο του ολικού διανύσματος εξόδου.
13.  $\eta$ : η παράμετρος ρυθμού εκπαίδευσης
14.  $b_j(n)$ : η τιμή κατωφλίου του  $j$  νευρώνα. Αναπαρίσταται από σύναψη βάρους  $w_{j0} = b_j$ , συνδεδεμένη με σταθερή είσοδο  $+1$ .
15.  $m_l$ : το πλήθος των κόμβων στο  $l$  επίπεδο του MLP, με  $l = 1, 2, \dots, L$  το εύρος του δικτύου.

Με βάση τα παραπάνω το σήμα σφάλματος του  $j$  νευρώνα στη  $n$ -στη επανάληψη ορίζεται από τη σχέση:

$$e_j(n) = d_j(n) - y_j(n), \text{ όπου } j \text{ νευρώνας αντιστοιχεί σε κόμβο εξόδου.} \quad (2.40)$$

Αν ορίσουμε την στιγμιαία ενέργεια σφάλματος του  $j$  νευρώνα ως  $\frac{1}{2}e_j^2(n)$ , τότε η στιγμιαία συνολική ενέργεια σφάλματος προκύπτει αθροίζοντας τις στιγμιαίες ενέργειες σφάλματος του επιπέδου της εξόδου, δηλαδή:

$$E(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n), \quad (2.41)$$

με το σύνολο  $C$  να συμπεριλαμβάνει όλους τους νευρώνες στο επίπεδο εξόδου.

Αν  $N$  το σύνολο των σημάτων εισόδου (όλα τα πρότυπα), τότε η ενέργεια του μέσου τετραγωνικού σφάλματος προκύπτει από τη σχέση:

$$E_{AV} = \frac{1}{N} \sum_{n=1}^N E(n). \quad (2.42)$$

Για ένα σύνολο εκπαίδευσης η  $E_{AV}$  αναπαριστά τη συνάρτηση κόστους ως μέτρο επίδοσης της εκπαίδευσης. Στόχος της εκπαίδευσης είναι να ρυθμίσει τις ελεύθερες παραμέτρους του δικτύου, δηλαδή τα συναπτικά βάρη και τις τιμές κατωφλίου, ώστε να ελαχιστοποιήσει την  $E_{AV}$ . Η ελαχιστοποίηση γίνεται με μια απλή μέθοδο εκπαίδευσης, στην οποία τα βάρη ανανεώνονται πρότυπο με πρότυπο μέχρι μια εποχή (epoch), δηλαδή μέχρι την παρουσίαση του συνόλου εκπαίδευσης (προτύπων) στο δίκτυο. Οι ρυθμίσεις στα βάρη γίνονται σε συμφωνία με τα αντίστοιχα υπολογισμένα σφάλματα για κάθε πρότυπο που παρουσιάστηκε στο δίκτυο.

Θεωρούμε ότι ο  $j$  νευρώνας τροφοδοτείται από ένα σύνολο λειτουργικών σημάτων που παράγονται από ένα προηγούμενο επίπεδο νευρώνων. Τότε το σήμα που εφαρμόζεται στη συνάρτηση ενεργοποίησης του  $j$  νευρώνα στην  $n$ -στη επανάληψη δίνεται από τη σχέση:

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) y_i(n), \quad (2.43)$$

όπου  $m$  όπως έχουμε αναφέρει ο συνολικός αριθμός εισόδων εκτός της τιμής κατωφλίου που εφαρμόζονται σε αυτόν. Επομένως το λειτουργικό σήμα στην έξοδο του  $j$  νευρώνα στην  $n$ -στη επανάληψη δίνεται από τη σχέση:

$$y_j(n) = \phi_j(v_j(n)). \quad (2.44)$$

Ο αλγόριθμος BP εφαρμόζει μια διόρθωση  $\Delta w_{ji}(n)$  στο συναπτικό βάρος  $w_{ji}(n)$ , ανάλογη της μερικής παραγώγου  $\partial E(n)/\partial w_{ij}(n)$ , η οποία αποτελεί ένα παράγοντα ευαισθησίας που καθορίζει την κατεύθυνση αναζήτησης στο χώρο των βαρών για το συναπτικό βάρος  $w_{ji}(n)$ . Η κλίση εκφράζεται από τη σχέση (κανόνας αλυσίδας):

$$\frac{\partial E(n)}{\partial w_{ij}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ij}(n)}, \quad (2.45)$$

$$\text{Διαφορίζοντας τη σχέση (2.41) ως προς } e_j(n), \text{ προκύπτει: } \frac{\partial E(n)}{\partial e_j(n)} = e_j(n), \quad (2.46)$$

$$\text{ενώ διαφορίζοντας τη σχέση (2.40) ως προς } y_j(n), \text{ προκύπτει: } \frac{\partial e_j(n)}{\partial y_j(n)} = -1. \quad (2.47)$$

Διαφορίζοντας στη συνέχεια τη σχέση (2.44) ως προς  $v_j(n)$ , προκύπτει:

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \phi'_j(v_j(n)), \quad (2.48)$$

ενώ διαφορίζοντας τη σχέση (2.43) ως προς  $w_{ij}(n)$ , προκύπτει:  $\frac{\partial v_j(n)}{\partial w_{ij}(n)} = y_i(n)$ . (2.49)

Τότε η (2.45) παίρνει τη μορφή:

$$\frac{\partial E(n)}{\partial w_{ij}(n)} = -e_j(n)\phi'_j(v_j(n))y_i(n). \quad (2.50)$$

Η διόρθωση  $\Delta w_{ji}(n)$  στο συναπτικό βάρος  $w_{ji}(n)$  ορίζεται από τον κανόνα Δέλτα, επομένως:

$$\Delta w_{ij}(n) = -\eta \partial E(n) / \partial w_{ij}(n), \quad (2.51)$$

όπου  $\eta$  η παράμετρος ρυθμού εκπαίδευσης ενώ το αρνητικό πρόσημο ερμηνεύεται σαν πτώση της κλίσης στο χώρο των βαρών. Συνδυασμός των σχέσεων (2.50) και (2.51) οδηγεί στην σχέση:

$$\Delta w_{ij}(n) = \eta \delta_j(n) y_i(n), \quad (2.52)$$

με την τοπική κλίση να ορίζεται από τη σχέση:

$$\delta_j(n) = -\frac{\partial E(n)}{\partial v_j(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n)\phi'_j(v_j(n)). \quad (2.53)$$

Η τοπική κλίση δείχνει τις απαιτούμενες αλλαγές στα συναπτικά βάρη και ορίζεται από το γινόμενο του αντίστοιχου σήματος σφάλματος στην έξοδο του  $j$  νευρώνα και της παραγώγου της συνάρτησης ενεργοποίησης του. Το σήμα σφάλματος  $e_j(n)$ , αποτελεί βασικό παράγοντα για τον υπολογισμό της ρύθμισης του βάρους  $\Delta w_{ij}(n)$ , στην έξοδο του  $j$  νευρώνα. Μπορούμε να διακρίνουμε δύο περιπτώσεις, εξαρτώμενες από την τοποθεσία του  $j$  νευρώνα στο δίκτυο:

1. Ο  $j$  νευρώνας είναι κόμβος εξόδου: όταν ο  $j$  νευρώνας βρίσκεται στο επίπεδο εξόδου, τότε τροφοδοτείται με μια δική του επιθυμητή έξοδο, επομένως το σήμα σφάλματος του προσδιορίζεται από τη σχέση (2.40) και έπειτα η τοπική κλίση προσδιορίζεται από τη σχέση (2.53).
2. Ο  $j$  νευρώνας είναι κρυφός κόμβος: όταν ο  $j$  νευρώνας βρίσκεται σε ένα κρυφό επίπεδο του δικτύου δεν υπάρχει καθορισμένη επιθυμητή έξοδος για αυτόν, επομένως το σήμα σφάλματος του καθορίζεται επαναληπτικά, από όλους τους άμεσα με αυτόν συνδεδεμένους νευρώνες. Η τοπική κλίση τότε προσδιορίζεται για αυτόν από τη σχέση:

$$\delta_j(n) = -\frac{\partial E(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = -\frac{\partial E(n)}{\partial y_j(n)} \phi'_j(v_j(n)). \quad (2.54)$$

Για να υπολογίσουμε τη μερική παράγωγο  $\partial E(n)/\partial y_j(n)$ , τροποποιούμε τη σχέση (2.41), ώστε να αναφέρεται σε έναν  $k$  νευρώνα εξόδου, αφού ο  $j$  νευρώνας είναι κρυφός κόμβος, οπότε προκύπτει η σχέση:  $E(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n)$ , (2.55)

$$\text{άρα: } \frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)}. \quad (2.56)$$

Αν αντίστοιχα η σχέση (2.40) πάρει τη μορφή:

$$e_k(n) = d_k(n) - y_k(n) = d_k(n) - \phi_k(v_k(n)), \quad (2.57)$$

$$\text{τότε: } \frac{\partial e_k(n)}{\partial v_k(n)} = -\phi'_k(v_k(n)), \quad (2.58)$$

$$\text{ενώ αν η σχέση (2.43) πάρει τη μορφή: } v_k(n) = \sum_{j=0}^m w_{kj}(n) y_j(n), \quad (2.59)$$

$$\text{τότε: } \frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n). \quad (2.60)$$

Η σχέση (2.54) τότε θα πάρει την μορφή:

$$\delta_j(n) = -\frac{\partial E(n)}{\partial y_j(n)} \phi'_j(v_j(n)) = \phi'_j(v_j(n)) \sum_k e_k(n) \phi'_k(v_k(n)) w_{kj}(n). \quad (2.61)$$

$$\text{ή με βάση τη σχέση (2.59) τελικά: } \delta_j(n) = \phi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n), \quad (2.62)$$

όπου ο παράγοντας  $\phi'_j(v_j(n))$  εξαρτάται μόνο από τη συνάρτηση ενεργοποίησης του κρυφού  $j$  νευρώνα, ο παράγοντας  $\delta_k(n)$  απαιτεί τη γνώση των σημάτων σφάλματος  $e_k(n)$  όλων των άμεσα διασυνδεδεμένων νευρώνων δεξιά του  $j$  κρυφού νευρώνα ενώ ο παράγοντας  $w_{kj}(n)$  αφορά τα βάση των διασυνδέσεων αυτών.

Συνοψίζοντας για τον αλγόριθμο BP, σύμφωνα με τον κανόνα Δέλτα:

1. Η διόρθωση  $\Delta w_{ij}(n)$  που εφαρμόζεται στο συναπτικό βάρος που συνδέει τους νευρώνες  $i$  και  $j$ , ορίζεται από τη προαναφερόμενη σχέση:  $\Delta w_{ij}(n) = \eta \delta_j(n) y_i(n)$ .
2. Η τοπική κλίση  $\delta_j(n)$  εξαρτάται από την τοποθεσία του  $j$  νευρώνα στο δίκτυο, δηλαδή αν αυτός αποτελεί κρυφό νευρώνα ή νευρώνα εξόδου. Αν αποτελεί

νευρώνα εξόδου τότε:  $\delta_j(n) = e_j(n)\phi'_j(u_j(n))$ , ενώ αν αποτελεί κρυφό νευρώνα τότε:  $\delta_j(n) = \phi'_j(u_j(n))\sum_k \delta_k(n)w_{kj}(n)$ .

Στην εφαρμογή του αλγορίθμου BP όπως έχουμε αναφέρει πραγματοποιούνται δύο διαφορετικά περάσματα υπολογισμών: το εμπρόσθιο πέρασμα (forward pass) και το οπίσθιο πέρασμα (backward pass).

- Κατά το εμπρόσθιο πέρασμα, το λειτουργικό σήμα που εμφανίζεται στην έξοδο του  $j$  νευρώνα υπολογίζεται από τη σχέση:  $y_j(n) = \phi_j(u_j(n))$  και το σήμα του εφαρμόζεται στην συνάρτηση ενεργοποίησης του  $j$  νευρώνα υπολογίζεται από τη σχέση:  $u_j(n) = \sum_{i=0}^m w_{ji}(n)y_i(n)$ . Αν ο  $j$  νευρώνας βρίσκεται στο πρώτο κρυφό επίπεδο του δικτύου, τότε  $m = m_0$  και ο δείκτης  $i$  αναφέρεται στην  $i$ -στη είσοδο του δικτύου για την οποία ισχύει  $y_i(n) = x_i(n)$ , με  $x_i(n)$  το  $i$ -στο στοιχείο του διανύσματος εισόδου. Αν όμως ο  $j$  νευρώνας βρίσκεται στο επίπεδο εξόδου του δικτύου, τότε  $m = m_L$  και ο δείκτης  $j$  αναφέρεται στην  $j$ -στη έξοδο του δικτύου για την οποία ισχύει  $y_j(n) = o_j(n)$ , με  $o_j(n)$  το  $j$ -στο στοιχείο του διανύσματος εξόδου. Αυτή η έξοδος συγκρίνεται με την επιθυμητή  $d_j(n)$  και προκύπτει το σήμα σφάλματος του  $j$  νευρώνα. Δηλαδή το εμπρόσθιο πέρασμα υπολογισμού ξεκινά στο πρώτο κρυφό επίπεδο παρουσιάζοντας σε αυτό το διάνυσμα εισόδου και τερματίζει στο επίπεδο εξόδου παράγοντας το σήμα σφάλματος κάθε νευρώνα του ενώ στην διάρκεια του τα συναπτικά βάρη παραμένουν σταθερά.
- Το οπίσθιο πέρασμα υπολογισμού ξεκινά από το επίπεδο εξόδου, μεταφέροντας τα σήματα σφάλματος προς τα αριστερά μέσω του δικτύου από επίπεδο σε επίπεδο και υπολογίζοντας αναδρομικά την τοπική κλίση επαναληπτικά για κάθε νευρώνα, επιτρέποντας έτσι στα συναπτικά βάρη να αναπροσαρμόζονται με βάση τον κανόνα Δέλτα. Η σχέση (2.52) χρησιμοποιείται για τις αλλαγές στα βάρη όλων των συνδέσεων που τροφοδοτούν το επίπεδο εξόδου. Η σχέση (2.62) χρησιμοποιείται για να υπολογιστούν οι τοπικές κλίσεις όλων των νευρώνων του προτελευταίου επιπέδου άρα και τις αλλαγές στα βάρη για όλες τις συνδέσεις που καταλήγουν σε αυτό, εφόσον έχουν υπολογιστεί οι τοπικές κλίσεις του επιπέδου εξόδου. Ο αναδρομικός υπολογισμός συνεχίζεται από επίπεδο σε επίπεδο, διαδίδοντας τις αλλαγές σε όλα τα συναπτικά βάρη του

δικτυού. Σε κάθε παράδειγμα εκπαίδευσης το πρότυπο εισόδου δεν αλλάζει μέχρι την ολοκλήρωση και των δύο περασμάτων.

Στην εφαρμογή του αλγορίθμου BP επιπλέον, όπως έχουμε αναφέρει, κάθε νευρώνας στο δίκτυο περιλαμβάνει μια μη γραμμική συνάρτηση ενεργοποίησης, παραγωγίσιμη παντού, ώστε να μπορεί να υπολογιστεί η τοπική κλίση  $\delta_j(n)$  για κάθε νευρώνα. Οι πιο συνηθισμένες συνεχείς μη γραμμικές συναρτήσεις ενεργοποίησης στα MLPs, είναι σιγμοειδείς συναρτήσεις (λογιστική συνάρτηση, υπερβολική εφαπτομένη). Η εφαρμογή της μέθοδου της Ταχύτερης Καθόδου (Steepest Descent) για την αναπροσαρμογή των βαρών, κατά μήκος της επιφάνειας λάθους προοδευτικά προς τη βέλτιστη λύση, οδηγεί σε τροποποίηση του κανόνα Δέλτα ώστε να περιοριστεί η αστάθεια στο δίκτυο που οφείλεται στην αύξηση της παραμέτρου του ρυθμού εκπαίδευσης  $\eta$ . Η νέα σχέση που προκύπτει είναι:

$$\Delta w_{ij}(n) = m\Delta w_{ij}(n-1) + \eta\delta_j(n)y_i(n), \quad (2.63)$$

όπου  $m$  είναι η σταθερά ορμής (momentum constant) και είναι συνήθως ένας θετικός αριθμός που καθορίζει πόσο μεγάλη είναι η αλλαγή του βάρους στον επόμενο υπολογισμό. Η σχέση (2.63) αποτελεί τον γενικευμένο κανόνα Δέλτα (generalized Delta rule) και μεταπίπτει στην απλή μορφή (2.52) αν  $m = 0$ .

Η σχέση (2.63) γράφεται τώρα ως μια χρονοσειρά με δείκτη  $t$ , για να γίνει ορατή η επίδραση των ακολουθιών από παρουσιάσεις προτύπων πάνω τα βάρη, λόγω της σταθεράς ορμής  $m$ , όπου ο δείκτης  $t$  παίρνει τιμές από 0 έως  $n$ . Προκύπτει η διαφορική πρωτοβάθμια εξίσωση της μορφής:

$$\Delta w_{ij}(n) = \eta \sum_{t=0}^n m^{n-t} \delta_j(t)y_i(t), \text{ δηλαδή μια χρονοσειρά μεγέθους } n+1, \quad (2.64)$$

η οποία μετατρέπεται με βάση στις σχέσεις (2.44) και (2.47) στην μορφή:

$$\Delta w_{ij}(n) = -\eta \sum_{t=0}^n m^{n-t} \delta_j(t) \frac{\partial E(t)}{\partial w_{ij}(t)}. \quad (2.65)$$

Στην σχέση (2.65):

- Η διόρθωση  $\Delta w_{ij}(n)$  ως εκθετική χρονοσειρά συγκλίνει όταν το πεδίο τιμών της σταθεράς ορμής είναι  $0 < |m| < 1$ , ενώ αν  $m = 0$ , ο αλγόριθμος BP λειτουργεί χωρίς αυτή.
- Όταν το πρόσημο της μερικής παραγώγου  $-\eta \frac{\partial E(t)}{\partial w_{ij}(t)}$  είναι αλγεβρικά σταθερό σε διαδοχικές επαναλήψεις, η χρονοσειρά μεγαλώνει σε μέγεθος τάξεως και το



βάρος ρυθμίζεται σημαντικά. Ο συνυπολογισμός της ορμής επιπλέον, επιταχύνει την κάθοδο σε σταθερές καθοδικές κατευθύνσεις.

- Όταν όμως το πρόσημο της μερικής παραγώγου  $-\eta \frac{\partial E(t)}{\partial w_{ij}(t)}$  είναι αντίθετο σε διαδοχικές επαναλήψεις, η χρονοσειρά μικραίνει σε μέγεθος τάξεως και το βάρος ρυθμίζεται σε μικρό ποσό. Ο συνυπολογισμός της ορμής εδώ δρα σταθεροποιητικά στις κατευθύνσεις αλλαγής του πρόσημου.

Κατά την εφαρμογή του Αλγορίθμου BP, ο συνυπολογισμός της ορμής επιφέρει εν γένει θετικές επιδράσεις στην συμπεριφορά μάθησης, ενώ μπορεί να εμποδίσει τον τερματισμό τις διαδικασίας σε ένα τοπικό ελάχιστο στην επιφάνεια σφάλματος. Η παράμετρος ρυθμού εκπαίδευσης που την ορίσαμε ως σταθερά κανονικά πρέπει να είναι εξαρτώμενη από τη σύνδεση, δηλαδή να ορίζεται ως  $\eta_{ij}$  οπότε να διαφοροποιείται μέσα στο δίκτυο επιταχύνοντας τη σύγκλιση. Μπορούμε επομένως να επιλέξουμε αν τα βάρη στο δίκτυο θα είναι όλα μεταβαλλόμενα κατά την εκπαίδευση ή ένας αριθμός τους θα παραμένει αμετάβλητος και αυτό γίνεται αν  $\eta_{ij} = 0$  για τα αντίστοιχα βάρη  $w_{ij}$ . Όσον αφορά τον τρόπο εκπαίδευσης του δικτύου με τον αλγόριθμο BP για ένα σύνολο εκπαίδευσης, μπορεί να προχωρήσει είτε μαζικά είτε ακολουθιακά. Στον ακολουθιακό τρόπο, που αναφέρεται και ως on line ή στοχαστικός, η ανανέωση των βαρών πραγματοποιείται μετά από την παρουσίαση κάθε παραδείγματος εκπαίδευσης και η διαδικασία συνεχίζεται μέχρι να ολοκληρωθεί η παρουσίαση του σύνολο των προτύπων εκπαίδευσης (epoch). Στον μαζικό τρόπο, η ανανέωση των βαρών πραγματοποιείται μετά από την παρουσίαση ολόκληρου του συνόλου των προτύπων (epoch) στο δίκτυο. Τότε η σχέση (2.36) τροποποιείται στη μορφή:

$$E_{AV} = \frac{1}{2N} \sum_{n=1}^N \sum_{j \in C} e_j^2(n), \quad (2.66)$$

όπου η εσωτερική άθροιση ως προς το  $j$  εκτελείται για όλους τους νευρώνες του επιπέδου εξόδου του δικτύου, ενώ η εξωτερική άθροιση ως προς το  $n$ , εκτελείται για το όλο σύνολο προτύπων της εκπαίδευσης. Η διόρθωση  $\Delta w_{ji}(n)$  στο συναπτικό βάρος  $w_{ji}(n)$  που γίνεται στο τέλος της εποχής, ορίζεται από τον κανόνα Δέλτα στην περίπτωση αυτή ως:

$$\Delta w_{ij}(n) = -\eta \frac{\partial E_{AV}}{\partial w_{ij}(n)} = -\frac{\eta}{N} \sum_{n=1}^N e_j(n) \frac{\partial e_j(n)}{\partial w_{ij}(n)}. \quad (2.67)$$

Παρόλο που ο μαζικός τρόπος εκπαίδευσης παρέχει εγγυημένη σύγκλιση σε ένα τοπικό ελάχιστο και διευκολύνει τον παραλληλισμό, ο ακολουθιακός τρόπος είναι πιο

δημοφιλής, αν και η στοχαστική φύση του δυσκολεύει την σύγκλιση του, διότι είναι πιο απλός στην υλοποίηση, παρέχει αποτελεσματικές λύσεις σε δύσκολα προβλήματα, υπερέρχει σε εκπαίδευση όπου στο σύνολο των προτύπων περιέχονται πολλά αντίγραφα, απαιτεί μικρότερο αποθηκευτικό χώρο ανά σύνδεση και ελαχιστοποιεί την περίπτωση παγίδευσης του αλγορίθμου σε κάποιο τοπικό ελάχιστο.

Τα κριτήρια τερματισμού του αλγόριθμου BP δεν είναι σαφώς ορισμένα αλλά είναι κυρίως λογικά κριτήρια που μπορούν να τερματίσουν τις αναπροσαρμογές στα βάρη. Επομένως:

- Ο αλγόριθμος BP θεωρείται ότι συγκλίνει όταν η Ευκλείδεια νόρμα (μετρική) του διανύσματος κλίσης  $g(w)$ , φτάσει σε ένα ικανοποιητικά μικρό κατώφλι κλίσης. Οι χρόνοι εκπαίδευσης όμως εδώ μπορεί να είναι μεγάλοι.
- Ο αλγόριθμος BP θεωρείται ότι συγκλίνει όταν ο απόλυτος ρυθμός μεταβολής στο μέσο τετραγωνικό λάθος ανά εποχή είναι ικανοποιητικά μικρός (0,1% με 1%), ή η μέγιστη τιμή του μέσου τετραγωνικού σφάλματος  $E_{AV}(w)$ , να είναι ίση ή μικρότερη από ένα ικανοποιητικά μικρό κατώφλι κλίσης.
- Ο αλγόριθμος BP θεωρείται ότι συγκλίνει όταν μετά από την εκπαίδευση, η γενική απόδοση του έχει γίνει αυξηθεί ή κορυφωθεί.

Ο αλγόριθμος BP είναι πολύ δημοφιλής, διότι είναι εύκολος στη χρήση (λίγες παράμετροι προς ρύθμιση, εύκολη υλοποίηση) και μπορεί να εφαρμοστεί σε ευρεία περιοχή δεδομένων από την άλλη πλευρά όμως η εκπαίδευση είναι αργή, πρέπει να παρέχονται συνεχώς νέα στοιχεία για να διατηρείται το δίκτυο ενημερωμένο, μπορεί να συγκλίνει σε κάποιο τοπικό ελάχιστο της συνάρτησης κόστους αντί σε ολικό και δεν είναι εγγυημένη γενίκευση ακόμα και με ελάχιστο σφάλμα.

### **2.3.1.2 Μέθοδοι Ελαχιστοποίησης του Σφάλματος**

Κατά την υλοποίηση ενός νευρωνικού δικτύου που χρησιμοποιεί τον αλγόριθμο BP, υπάρχουν ορισμένοι μέθοδοι που βελτιώνουν σημαντικά την απόδοση του. Συνοπτικά μπορούμε να αναφέρουμε τα εξής:

- Σε μεγάλο σύνολο δεδομένων εκπαίδευσης προτιμάται ο ακολουθιακός τρόπος εκπαίδευσης έναντι του μαζικού όπως αναφέραμε προηγουμένως και επιπλέον το

σύνολο αυτό, μπορεί να διαχωριστεί σε έναν κατάλληλο αριθμό υποσυνόλων τα οποία και παρουσιάζονται μεμονωμένα στο δίκτυο, ένα κάθε φορά ανάλογα το πρόβλημα.

- Κάθε παράδειγμα εκπαίδευσης θα πρέπει επιλέγεται ώστε να μεγιστοποιείται το περιεχόμενο της πληροφορίας του σε σχέση με το αντίστοιχο πρόβλημα. Αυτό επιτυγχάνεται με τη χρήση παραδείγματος που παράγει το μεγαλύτερο σφάλμα κατά την εκπαίδευση ή τη χρήση παραδείγματος ριζοσπαστικά διαφοροποιημένου από τα υπόλοιπα. Προέκυψαν έτσι οι τεχνικές της τυχαιοποίησης (σπάνια επανάληψη ίδιου προτύπου) και του σχήματος έμφασης (παρουσίαση πιο δύσκολων προτύπων).
- Το εκπαιδευόμενο δίκτυο μαθαίνει πιο γρήγορα όταν η σιγμοειδής συνάρτηση ενεργοποίησης είναι αντισυμμετρική (περιττή δηλαδή ως προς την μεταβλητή της) παρά συμμετρική, όπως η μορφή της υπερβολικής εφαπτομένης. Οι επιθυμητές τιμές εξόδου θα πρέπει να επιλέγονται εντός πεδίου τιμών της συνάρτησης αυτής.
- Για να επιταχυνθεί η διαδικασία της εκπαίδευσης θα πρέπει οι τιμές εισόδου του συνόλου της εκπαίδευσης (LeCun, 1992) να έχουν κανονικοποιηθεί (μέση τιμή κοντά στο μηδέν) και να είναι μη συσχετιζόμενες (Haykin, 1999).
- Η επιλογή αρχικών τιμών στα συναπτικά βάρη και στις τιμές κατωφλίων (αρχικοποίηση) γίνεται έτσι ώστε να αποφεύγονται οι μεγάλες ή οι μικρές τιμές, κυρίως με τη μέθοδο Nguyen και Widrow (Nguyen, Widrow, 1990), (Looney, 1997).
- Η εκπαίδευση από παραδείγματα μπορεί να γενικευτεί ώστε να περιλαμβάνει εκπαίδευση από υποδείξεις, επιτρέποντας να συμπεριληφθεί και προηγούμενη πληροφορία της συνάρτησης ενεργοποίησης, για επιτάχυνση και βελτίωση της τελικής προσέγγισης (Abu Mostafa, 1995).
- Για την παράμετρο του ρυθμού εκπαίδευσης οι Fahlman (Fahlman, 1988) και Jacobs (Jacobs, 1988) πρότειναν ότι αυτή πρέπει να έχει μικρότερη τιμή στα τελευταία επίπεδα του δικτύου σε σχέση με τα πρώτα, ώστε να διατηρείται όμοιος ο χρόνος εκπαίδευσης για όλους τους νευρώνες του δικτύου. Ο LeCun πρότεινε επίσης (LeCun, 1992) ότι για ένα νευρώνα, αυτή θα πρέπει να είναι αντιστρόφως ανάλογη με την τετραγωνική ρίζα των συναπτικών συνδέσεων που τον συνθέτουν. Μια διαδομένη τεχνική για τον υπολογισμό της παραμέτρου, στηριζόμενη στο γεγονός ότι αυτή πρέπει να διαφέρει από επανάληψη σε επανάληψη, είναι αυτή των Vogl, Mangis, Rigler, Zink, και Alkon (Vogl, Mangis, Rigler, Zink, Alkon, 1988).

- Βελτίωση της μεθόδου της ταχύτερης καθόδου με τη συνθήκη ελάττωσης του Armijo (Armijo, 1966) και την μέθοδο Barzilai και Borwein (Barzilai, Borwein, 1988).


## 2.4 Ανανεώσιμες Πηγές Ενέργειας

Οι ανανεώσιμες πηγές ενέργειας ή ήπιες μορφές ενέργειας αποτελούν μορφές εκμεταλλεύσιμης ενέργειας που πηγάζουν από διάφορες φυσικές διαδικασίες. Ως ανανεώσιμες αποτελούν ίσως την μόνη εναλλακτική λύση σε σχέση με τις συμβατικές πηγές ενέργειας, ενώ ως ήπιες δεν απαιτούν κάποια ενεργητική παρέμβαση για την εκμετάλλευσή τους και είναι περιβαλλοντικά φιλικές. Το ενδιαφέρον για την ευρύτερη αξιοποίηση τους, καθώς και για την ανάπτυξη αξιόπιστων και οικονομικά αποδοτικών τεχνολογιών να μπορούν να δεσμεύσουν το δυναμικό τους, εντοπίζεται χρονικά τέλη της δεκαετίας του '70 ως αποτέλεσμα των πετρελαϊκών κρίσεων της εποχής και κορυφώνεται την τελευταία δεκαετία, με την συνειδητοποίηση σε παγκόσμιο επίπεδο της αλλοίωσης του περιβάλλοντος και της υποβάθμισης της ποιότητας ζωής από την χρήση των κλασικών πηγών ενέργειας (ορυκτά καύσιμα). Έχουμε αναφέρει κατά την εισαγωγή τα κυριότερα πλεονεκτήματα συνοδεύουν τις ΑΠΕ, με αποτέλεσμα για πολλές χώρες αυτές να αποτελούν πλέον σημαντική εγχώρια πηγή ενέργειας με μεγάλες αναπτυξιακές δυνατότητες. Συνεισφέρουν σημαντικά στο ενεργειακό ισοζύγιο, ενισχύοντας την ασφάλεια του ενεργειακού εφοδιασμού και συμβάλλοντας στην μείωση ενεργειακών εισαγωγών. Στο Άρθρο 2 της Οδηγίας 2009/28/ΕΚ του Ευρωπαϊκού Κοινοβουλίου, ορίζεται ως ενεργεία από ανανεώσιμες μη ορυκτές πηγές: η αιολική, η ηλιακή, η αεροθερμική, η γεωθερμική, η υδροθερμική και η ενέργεια των ωκεανών, η υδροηλεκτρική, η βιομάζα και τα εκλυόμενα αέρια από χώρους υγειονομικής ταφής, επεξεργασίας λυμάτων και βιοαερίων.

### 2.4.1.1 Η κατάσταση στην Ευρώπη:

Ο ευρωπαϊκός ενεργειακός τομέας, όπως αναφέρει και η δεύτερη Έκθεση (1/2/2017) της Ευρωπαϊκής Επιτροπής για την κατάσταση της Ενεργειακής Ένωσης, βρίσκεται σε τροχιά προόδου ως προς τους στόχους που έχουν τεθεί για το 2020 (EUROPA, 2017), αντιμετωπίζοντας παράλληλα μια σειρά μεγάλων προκλήσεων που περιλαμβάνει: την αυξανόμενη ενεργειακή εξάρτηση, τις υψηλές και ασταθείς τιμές των ενεργειακών πόρων, τη διογκούμενη παγκόσμια ενεργειακή ζήτηση, την περιορισμένη διαφοροποίηση, τους κινδύνους ασφαλούς παραγωγής και μεταφοράς ενέργειας, την

κλιματική αλλαγή (Damm, Köberl, Prettenthaler, Rogler, Töglhofer, 2017), την βραδεία πρόοδο της ενεργειακής απόδοσης, την αύξηση του μεριδίου των ΑΠΕ στην ενεργειακή κατάσταση καθώς και την διεύρυνση και διασύνδεση στις ενεργειακές αγορές. Αν και τα κράτη-μέλη της Ε.Ε. (Ευρωπαϊκής Ένωσης) έχουν πολύ διαφορετικά ενεργειακά μείγματα, μοιράζονται τους ίδιους στόχους, που εκφράζουν και την εφαρμοζόμενη ενεργειακή πολιτική της Ε.Ε. Αυτοί είναι: η ασφάλεια εφοδιασμού, η ανταγωνιστικότητα και η βιωσιμότητα. Το 2014 σύμφωνα με τη EUROSTAT (EUROPA, 2016), η παραγωγή πρωτογενούς ενέργειας στην Ευρώπη των 28, ήταν 17,3% χαμηλότερη σε σχέση με την προηγούμενη δεκαετία, γεγονός που οφείλεται στην εξάντληση των πρώτων υλών ή στη μη επικερδή πλέον εκμετάλλευσή τους. Η παραγωγή αυτή κάλυπτε ένα ευρύ φάσμα διαφορετικών πηγών ενέργειας: 29,4% πυρηνική ενέργεια, 25,5% ΑΠΕ, 19,4% στερεά καύσιμα, φυσικό αέριο 15,2% και αργό πετρέλαιο 9,1%. Η αύξηση της παραγωγής πρωτογενούς ενέργειας από ΑΠΕ, υπερέβη την παραγωγή των υπολοίπων την χρονική περίοδο 2004-2014, παρουσιάζοντας αύξηση 73,1%. Τα επίπεδα παραγωγής όλων των άλλων πηγών ενέργειας συρρικνώθηκαν σημαντικά κατά την ίδια χρονική περίοδο. Αυτό είχε ως αποτέλεσμα την αύξηση της ενεργειακής εξάρτησης της Ε.Ε. από εισαγωγές προκειμένου να καλυφθεί η ζήτηση. Από το 2004 οι καθαρές εισαγωγές ενέργειας ήταν υψηλότερες από την πρωτογενή παραγωγή της, καλύπτοντας περισσότερο από το ήμισυ της ακαθάριστης εγχώριας κατανάλωσης ενέργειας .



**Διάγραμμα 2.1:** Παραγωγή πρωτογενούς ενέργειας, Ε.Ε.-28, 2014, (% επί του συνόλου, με βάση τόνους ισοδύναμου πετρελαίου), (EUROSTAT, 2016)

**Πίνακας 2.1:** Παραγωγή ενέργειας, 2004-2014 (εκατομμύρια τόνοι ισοδύναμου πετρελαίου), (EUROSTAT, 2016)

	Total production of primary energy		Share of total production, 2014 (%)				
	2004	2014	Nuclear energy	Solid fuels	Natural gas	Crude oil	Renewable energy
<b>EU-28</b>	931,7	770,7	29,3	19,4	15,2	9,1	25,4
<b>Belgium</b>	13,5	12,2	71,2	0,0	0,0	0,0	223,4
<b>Bulgaria</b>	10,2	11,3	36,5	45,3	1,4	0,2	16,4
<b>Czech Republic</b>	33,1	29,1	27,0	58,0	0,7	0,9	12,6
<b>Denmark</b>	30,9	15,8	0,0	0,0	26,3	51,2	19,9
<b>Germany</b>	136,8	119,9	20,9	36,8	5,7	2,9	30,0
<b>Estonia</b>	3,7	5,8	0,0	78,5	0,0	0,0	20,3
<b>Ireland</b>	1,9	2,0	0,0	48,3	6,1	0,0	42,5
<b>Greece</b>	10,3	8,8	0,0	72,5	0,1	0,7	26,5
<b>Spain</b>	32,4	34,9	42,3	4,7	0,1	0,9	51,5

<b>France</b>	135,4	135,9	82,8	0,0	0,0	0,8	15,5
<b>Croatia</b>	4,7	4,4	0,0	0,0	33,2	13,9	52,7
<b>Italy</b>	29,2	36,8	0,0	0,1	15,9	16,6	64,2
<b>Cyprus</b>	0,1	0,1	0,0	0,0	0,0	0,0	94,2
<b>Latvia</b>	1,8	2,4	0,0	0,1	0,0	0,0	99,6
<b>Lithuania</b>	5,1	1,5	0,0	1,9	0,0	5,6	91,3
<b>Luxembourg</b>	0,1	0,2	0,0	0,0	0,0	0,0	78,8
<b>Hungary</b>	10,2	10,0	40,3	15,8	14,3	8,2	20,4
<b>Malta</b>	0,0	0,0	0,0	0,0	0,0	0,0	100,0
<b>Nederland</b>	68,2	58,4	1,8	0,0	85,8	3,4	7,8
<b>Austria</b>	9,9	12,1	0,0	0,0	9,0	7,6	77,6
<b>Poland</b>	78,1	66,9	0,0	80,2	5,6	1,4	12,0
<b>Portugal</b>	3,9	6,0	0,0	0,0	0,0	0,0	97,6
<b>Romania</b>	28,6	26,6	11,3	16,7	33,0	15,8	22,9
<b>Slovenia</b>	3,4	3,7	44,6	22,2	0,1	0,0	32,0
<b>Slovakia</b>	6,2	6,3	64,1	9,2	1,3	0,2	22,8
<b>Finland</b>	15,7	18,1	33,7	8,9	0,0	0,4	55,8
<b>Sweden</b>	33,8	34,1	49,0	0,4	0,0	0,0	48,8
<b>United kingdom</b>	224,3	107,6	15,3	6,3	30,6	38,1	9,0
<b>Iceland</b>	2,3	5,2	0,0	0,0	0,0	0,0	100,0
<b>Norway</b>	228,8	196,3	0,0	0,6	48,4	44,3	6,6
<b>Montenegro</b>	0,0	0,7	0,0	52,6	0,0	0,0	47,5
<b>FUR of Macedonia</b>	1,6	1,3	0,0	78,0	0,0	0,0	22,0
<b>Albania</b>	1,1	1,9	0,0	0,0	1,3	65,6	33,1
<b>Serbia</b>	12,0	9,4	0,0	60,8	4,7	12,4	22,0
<b>Turkey</b>	24,1	31,2	0,0	52,0	1,3	8,1	38,5
<b>Bosnia and Herzegovina</b>	3,6	6,0	0,0	62,3	0,0	0,0	37,7
<b>Kosovo</b>	1,3	1,6	0,0	83,6	0,0	0,0	16,4

Θεσμικά, μετά την ενσωμάτωση του Πρωτοκόλλου του Κιότο στην Κοινοτική Νομοθεσία με τις Οδηγίες 2003/87/ΕΚ και 2004/101/ΕΚ, η Συνθήκη της Λισαβόνας το 2007 εισάγει ειδικό κεφάλαιο σε σχέση με την ενεργειακή πολιτική στις ιδρυτικές συνθήκες της Ε.Ε., διατηρώντας και τις προϋπάρχουσες ρυθμίσεις για τα διευρωπαϊκά δίκαια. Προβλέπει ειδική νομική βάση στον τομέα της ενέργειας με το άρθρο 194 της Συνθήκης, σύμφωνα με το οποίο η Ε.Ε. εξουσιοδοτείται να εγκρίνει μέτρα σε ευρωπαϊκό επίπεδο για:

- Να διασφαλίσει την καλή λειτουργία της αγοράς ενέργειας.
- Να διασφαλίσει τον ενεργειακό εφοδιασμό της Ε.Ε.
- Να προωθήσει την ενεργειακή αποδοτικότητα, την εξοικονόμηση ενέργειας και την ανάπτυξη των ΑΠΕ.
- Να προωθήσει τη διασύνδεση ενεργειακών δικτύων.

Έτσι το νομοθετικό υλικό (Κανονισμοί, Οδηγίες, Αποφάσεις) της Ευρωπαϊκής Κοινότητας στον κλάδο της ενέργειας απαρτίζεται από (ΡΑΕ, 2017):

- Την «1<sup>η</sup> δέσμη» μέτρων που περιλαμβάνει: την Οδηγία 96/92/ΕΚ σχετικά με τους κοινούς κανόνες για την εσωτερική αγορά της ηλεκτρικής ενέργειας και την Οδηγία 98/30/ΕΚ σχετικά με τους κοινούς κανόνες για την εσωτερική αγορά του φυσικού αερίου.
- Τη «2<sup>η</sup> δέσμη μέτρων» που περιλαμβάνει: την Οδηγία 2003/54/ΕΚ σχετικά με τους κοινούς κανόνες για την εσωτερική αγορά της ηλεκτρικής ενέργειας, τον Κανονισμό (ΕΚ) 1228/2003 σχετικά με τους όρους πρόσβασης στο δίκτυο για τις διασυνοριακές ανταλλαγές ηλεκτρικής ενέργειας, την Οδηγία 2003/55/ΕΚ σχετικά με τους κοινούς κανόνες για την εσωτερική αγορά του φυσικού αερίου, τον Κανονισμό (ΕΚ) 1775/2005 σχετικά με τους όρους πρόσβασης στα δίκτυα φυσικού αερίου και την Απόφαση 2003/796/ΕΚ σχετικά με τη σύσταση ευρωπαϊκής ομάδας ρυθμιστικών αρχών για την ηλεκτρική ενέργεια και το φυσικό αέριο.
- Την «3<sup>η</sup> δέσμη» μέτρων που περιλαμβάνει: τον Κανονισμό (ΕΚ) 713/2009 για την ίδρυση Οργανισμού Συνεργασίας των Ρυθμιστικών Αρχών Ενέργειας, τον Κανονισμό (ΕΚ) 714/2009 σχετικά με τους όρους πρόσβασης στο δίκτυο για τις διασυνοριακές ανταλλαγές ηλεκτρικής ενέργειας, τον Κανονισμό (ΕΚ) 715/2009



σχετικά με τους όρους πρόσβασης στα δίκτυα φυσικού αερίου, την Οδηγία 2009/72/EK σχετικά με τους κοινούς κανόνες για την εσωτερική αγορά της ηλεκτρικής ενέργειας και την Οδηγία 2009/73/EK σχετικά με τους κοινούς κανόνες για την εσωτερική αγορά του φυσικού αερίου.

Το 2008, η Ευρωπαϊκή Επιτροπή πρότεινε δεσμευτική νομοθεσία για την υλοποίηση των στόχων 20-20-20 (20% μείωση των εκπομπών αερίων θερμοκηπίου, 20% βελτίωση της ενεργειακής απόδοσης, 20% άντληση της ενέργειας από ΑΠΕ στην Ε.Ε.), την γνωστή «δέσμη για το κλίμα και την ενέργεια», η οποία νομοθετήθηκε το 2009 και περιλαμβάνει, (ΥΠΕΚΑ, 2017):

- Την Οδηγία 2009/29/EK για τη βελτίωση και την επέκταση του συστήματος εμπορίας δικαιωμάτων εκπομπής αερίων θερμοκηπίου της Κοινότητας.
- Την Απόφαση 406/2009/EK περί των προσπαθειών των κρατών-μελών να μειώσουν τις οικείες εκπομπές αερίων θερμοκηπίου μέχρι το 2020.
- Την Οδηγία 2009/28/EK σχετικά με την προώθηση της χρήσης ενέργειας από ανανεώσιμες πηγές.
- Την Οδηγία 2009/31/EK σχετικά με την αποθήκευση διοξειδίου του άνθρακα σε γεωλογικούς σχηματισμούς.
- Την Οδηγία 2012/27/EK για την ενεργειακή απόδοση.

Η δεύτερη Έκθεση (1/2/2017) της Ευρωπαϊκής Επιτροπής για την κατάσταση της Ενεργειακής Ένωσης, δείχνει ότι ο εκσυγχρονισμός της οικονομίας της Ε.Ε. και η μετάβαση σε μια εποχή χαμηλών ανθρακούχων εκπομπών αποτελούν πλέον γεγονός. Η Ευρώπη βρίσκεται σε καλό δρόμο για την επίτευξη των στόχων που έχει θέσει για το 2020. Όσον αφορά την τελική κατανάλωση ενέργειας (οικιακή χρήση, βιομηχανία, υπηρεσίες), ο στόχος έχει ήδη επιτευχθεί αφού μειώθηκε κατά 11% στη χρονική περίοδο 2005-2014. Το 2014 συγκεκριμένα, η Ε.Ε. κατανάλωσε 1062 Mtoe (εκατομμύρια τόνοι ισοδύναμου πετρελαίου), ποσοστό 2,2% χαμηλότερο από τον ενδεικτικό στόχο κατανάλωσης ενέργειας του 2020. Όσον αφορά την κατανάλωση πρωτογενούς ενέργειας, αυτή μειώθηκε κατά 12%, στη χρονική περίοδο 2005-2014, υπερβαίνοντας όμως το στόχο του 2020 κατά 1,6%. Όσον αφορά τις ΑΠΕ, το 2014 το ποσοστό τους στην τελική κατανάλωση ενέργειας ανέρχεται στο 16% και δεδομένου ότι από το 2011 μέχρι το 2014, από το 21,7% παραγωγής της ηλεκτρικής ενέργειας

στην Ε.Ε. έφτασαν στο 27,5%, αναμένεται να φτάσουν το στόχο του 20% στην τελική κατανάλωση ενέργειας το 2020. Επιπλέον από πλευράς κόστους αυτές, έχουν γίνει πολύ ανταγωνιστικές ίσως και φθηνότερες από τα ορυκτά καύσιμα σε ορισμένες περιπτώσεις, ενώ οι ερευνητικές προσπάθειες της Ε.Ε. συνέβαλαν σημαντικά στην ανάπτυξη τους. Όσον αφορά τις θερμοκηπικές εκπομπές, την περίοδο 1990-2012 μειώθηκαν κατά 18% (Jackson, Canadell, Le Quéré, Andrew, Korsbakken, Peters, Nakicenovic, 2015). Όσον αφορά τον τομέα των μεταφορών, επικρατεί ένα θετικό έναυσμα στα βιοκαύσιμα «δεύτερης γενιάς» ενώ από το 2007, τρέχουν τα προγράμματα ΕΕΕ και ΕΕΕ II (Ευφυής Ενέργεια για την Ευρώπη) για την διείσδυση των τεχνολογιών στην αγορά και τη συνεργασία με χρηματοπιστωτικά ιδρύματα για την κινητοποίηση επενδύσεων, που αναμένεται να αποφέρουν εξοικονόμηση ενέργειας άνω των 2000 GWh/Έτος (EUROPA, 2013).

Στηριζόμενη στο πλαίσιο για το 2020, η Ε.Ε. έχει θέσει μακροπρόθεσμους κλιματικούς και ενεργειακούς στόχους για το 2030 και για το 2050. Το 2014, το Ευρωπαϊκό Συμβούλιο (Πράσινη Βίβλος) καθόρισε τέσσερεις σημαντικούς στόχους για το 2030, (EUROPA, 2013), (Bointner et al, 2016):

- Μείωση των εκπομπών αερίων του θερμοκηπίου κατά 40%
- Άντληση ενέργειας από ΑΠΕ κατά 27%
- Βελτίωση της ενεργειακής απόδοσης κατά 27%
- Επίτευξη ηλεκτρικής διασύνδεσης κατά 10% ως το 2020 και κατά 15% ως το 2030

Τέλος για το 2050, ο ουσιαστικός μακροπρόθεσμος στόχος είναι η μείωση των εκπομπών αερίων του θερμοκηπίου κατά 80-95% κάτω από τα επίπεδα του 1990, σύμφωνα με τον Χάρτη Πορείας για το 2050 (EUROPA, 2011), τον Ενεργειακό Χάρτη Πορείας για το 2050 και τη Λευκή Βίβλο (EUROPA, 2017).

#### **2.4.1.2 Η κατάσταση στην Ελλάδα:**

Η Ελληνική ενεργειακή αγορά τα τελευταία χρόνια βρίσκεται σε πορεία ραγδαίων και ριζικών εξελίξεων. Η συνεχόμενη πρόοδος των ενεργειακών τεχνολογιών, οι διαχρονικές περιβαλλοντικές επιταγές, τα ευρωπαϊκά πλαίσια συνεργασίες και οι άλλες διακρατικές συμφωνίες οδήγησαν σε αναδιάρθρωση του ενεργειακού μοντέλου της

χώρας, το οποίο μέχρι πρότινος χαρακτηριζόταν από υψηλή κατανάλωση συμβατικών καυσίμων (κυρίως λιγνίτη) και μεγάλες εισαγωγές αδιύλιστου πετρελαίου και φυσικού αερίου, ώστε αυτό να εναρμονιστεί με τη διεθνή πραγματικότητα. Η Ελληνική ενεργειακή αγορά έχει να αντιμετωπίσει σημαντικές προκλήσεις όπως: την απελευθέρωση της αγοράς του φυσικού αερίου και της ηλεκτρικής ενέργειας, της αύξησης της ανταγωνιστικότητας, την εγχώρια και διακρατική αναβάθμιση των δικτύων μεταφοράς της ενέργειας, την αύξηση παραγωγής ενέργειας από ΑΠΕ και την αντίστοιχη μείωση της από συμβατικές, την περιβαλλοντική προστασία, την ελεύθερη επιλογή προμηθευτή, την ανεξαρτητοποίηση και διαχωρισμό της παραγωγής από την προμήθεια καθώς και την εξοικονόμηση ενέργειας. Οι εξελίξεις αυτές όμως θα πρέπει να συμβαδίζουν με τα πλαίσια της ενεργειακής πολιτικής που στηρίζεται σε τρεις βασικούς άξονες: την εξεύρεση, την εξασφάλιση και τη διαχείριση των ενεργειακών πόρων ώστε να διασφαλίζεται η ασφαλής, ομαλή και αδιάλειπτη κάλυψη των ενεργειακών αναγκών της χώρας, την δημιουργία ενεργειακών αποθεμάτων, συμμαχιών και εναλλακτικών οδών για την κάλυψη ενεργειακών αναγκών της χώρας σε περιόδους ενεργειακών κρίσεων και την βιώσιμη και αειφόρο ανάπτυξη ολόκληρου του φάσματος του ενεργειακού τομέα.

Οι σημαντικότεροι φορείς του κλάδου των ΑΠΕ όπως έχουν διαμορφωθεί κατά την τελευταία εικοσαετία είναι:

- Η Ρυθμιστική Αρχή Ενέργειας (ΡΑΕ) που συγκροτήθηκε το 2000 και αποτελεί ανεξάρτητη διοικητική αρχή με αρμοδιότητα την παρακολούθηση και εξέλιξη της αγοράς ενέργειας, τόσο την εγχώρια όσο και πώς αυτή λειτουργεί και αναπτύσσεται σε σχέση με τις ξένες αγορές ενέργειας και κυρίως με αυτές με τις οποίες διασυνδέεται. Στις αρμοδιότητες της σήμερα πλέον εντάσσονται: η παρακολούθηση και ο έλεγχος της αγοράς ενέργειας σε όλους τους τομείς (συμβατικά καύσιμα, ΑΠΕ, φυσικό αέριο), η γνωμοδότηση στη χορήγηση αδειών παραγωγής ηλεκτρικής ενέργειας από συμβατικά καύσιμα, η χορήγηση αδειών από ΑΠΕ, η διασφάλιση πρόσβασης τρίτων στο δίκτυο της χώρας καθώς και η λειτουργία του διασυνδεδετικού εμπορίου εισαγωγών και εξαγωγών, η ομαλή λειτουργία της αγοράς ηλεκτρικής ενέργειας που εκτελεί ο ΔΕΣΜΗΕ, η γνωμοδότηση για τη χορήγηση αδειών προμήθειας ηλεκτρικής ενέργειας, η

τήρηση κανόνων υγιούς ανταγωνισμού και προστασίας του καταναλωτή και η έναρξη διαδικασίας επιβολής κυρώσεων σε συνεργασία με άλλους φορείς.

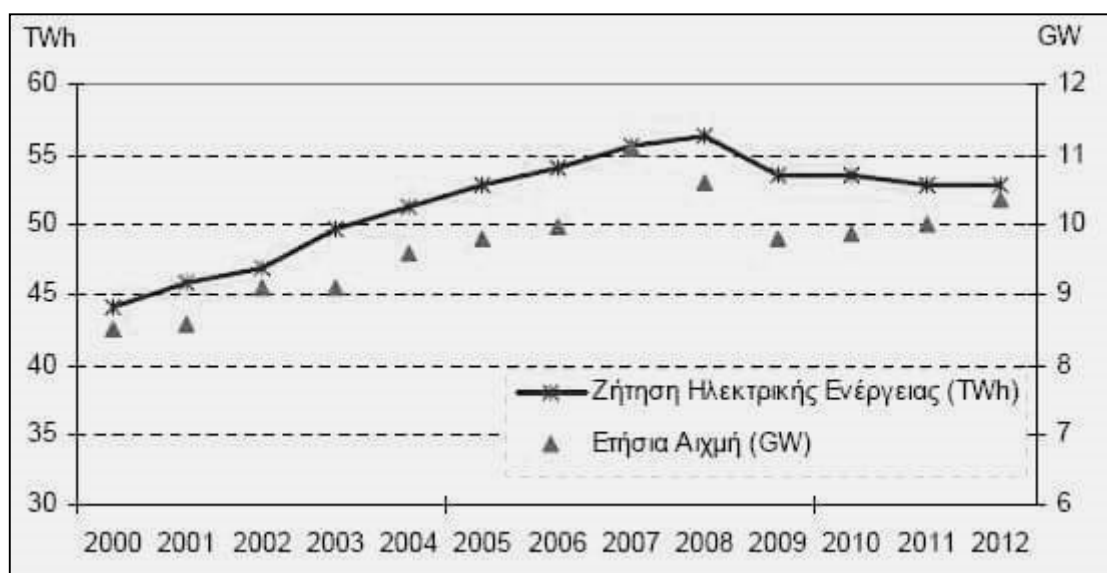
- Ο Ανεξάρτητος Διαχειριστής Μεταφοράς Ηλεκτρικής Ενέργειας (ΑΔΜΗΕ) που από το 2012 έχει αναλάβει τις δραστηριότητες σχετικά με λειτουργία, συντήρηση και ανάπτυξη Ελληνικού Συστήματος Μεταφοράς Ηλεκτρικής Ενέργειας (ΕΣΜΗΕ), ώστε να διασφαλίζεται ο ενεργειακός εφοδιασμός της χώρας με τρόπο ασφαλή, αποδοτικό και αξιόπιστο.
- Ο Λειτουργός της Αγοράς Ηλεκτρικής ενέργειας (ΛΑΓΗΕ) που από το 2012 έχει αναλάβει τις εξής αρμοδιότητες: διενεργεί τον Ημερήσιο Ενεργειακό Προγραμματισμό, συνεργάζεται με τον ΑΔΜΗΕ σύμφωνα με τον Κώδικα Συναλλαγών και τον κώδικα Διαχείρισης, τηρεί το Ειδικό Μητρώο Συμμετεχόντων στην Αγορά Ηλεκτρικής Ενέργειας και πραγματοποιεί τις εγγραφές αυτών, παρέχει έγκαιρα τις απαραίτητες πληροφορίες για τη συμμετοχή τους στην Αγορά αποφεύγοντας κάθε είδους διακρίσεις, συμμετέχει σε κοινές επιχειρήσεις για τη δημιουργία περιφερειακών αγορών στο πλαίσιο της εσωτερικής αγοράς ενέργειας, εισπράττει τέλη από τους Συμμετέχοντες και τηρεί τους αναγκαίους λογαριασμούς σύμφωνα με τον Κώδικα Συναλλαγών, συμμετέχει έμμεσα στη δημιουργία ενιαίας εσωτερικής αγοράς ηλεκτρικής ενέργειας, συνάπτει συμβάσεις πώλησης ηλεκτρικής ενέργειας και διενεργεί τη διευθέτηση των χρηματικών συναλλαγών στο πλαίσιο του Ημερήσιου Ενεργειακού Προγραμματισμού.
- Το Κέντρο Ανανεώσιμων Πηγών Ενέργειας (ΚΑΠΕ) που ιδρύθηκε το 1987 (Π.Δ. 375/1987, ΦΕΚ Α'-167) και αποτελεί σήμερα τον εθνικό φορέα για την προώθηση των ΑΠΕ, για την ορθολογική χρήση και εξοικονόμηση της ενέργειας καθώς και για την κάθε είδους υποστήριξη δραστηριοτήτων στους εν λόγω τομείς. Δραστηριοποιείται δυναμικά στο πλαίσιο της εθνικής και κοινοτικής πολιτικής και νομοθεσίας, για την προστασία του περιβάλλοντος κι την αειφόρο ανάπτυξη, υλοποιώντας καινοτόμα έργα και σημαντικές δράσεις για τη διάδοση και εδραίωση νέων ενεργειακών τεχνολογιών. Διαθέτει εργαστήρια πιστοποίησης τεχνολογιών ΑΠΕ, εκπονεί μελέτες προσδιορισμού του φυσικού και οικονομικού δυναμικού των ΑΠΕ και συμμετέχει ενεργά στην αξιολόγηση και παρακολούθηση των επενδύσεων του χώρου (ICAP, 2012).

Σύμφωνα με την μελέτη επάρκειας ισχύος για την περίοδο 2013-2020 του Ανεξάρτητου Διαχειριστή Μεταφοράς Ηλεκτρικής Ενέργειας (ΑΔΜΗΕ), το 2013 η εγκατεστημένη ισχύς στο Ελληνικό Σύστημα Μεταφοράς Ηλεκτρικής Ενέργειας (ΕΣΜΗΕ) ανερχόταν στα 17,4 GW, προερχόμενη από Θερμικές Μονάδες, Υδροηλεκτρικές Μονάδες με ταμιευτήρα, ΑΠΕ και ΣΗΘΥΑ (Πίνακας 2.2). Όσον αφορά τις Θερμικές Μονάδες, αυτές αποτελούν την πλειονότητα του συστήματος ηλεκτροπαραγωγής (58,8% της συνολικής εγκατεστημένης ισχύος) και περιλαμβάνουν λιγνιτικές, πετρελαϊκές και μονάδες φυσικού αερίου που καλύπτουν το μεγαλύτερο μέρος της ενεργειακής ζήτησης (78,6% για το 2012). Ο στόλος των Θερμικών Μονάδων χαρακτηρίζεται ως πεπαλαιωμένος αφού οι περισσότερες μονάδες έχουν ξεπεράσει την εικοσαετή λειτουργία. Υπό ένταξη, βρίσκονται 3 νέες μονάδες συνολικής ισχύος 1848 MW. Όσον αφορά τις Υδροηλεκτρικές Μονάδες, ενώ η εγκατεστημένη ισχύς τους στο σύστημα παραγωγής είναι σημαντική (17%), η συνεισφορά τους στο ενεργειακό ισοζύγιο είναι σχετικά μικρή, λόγω περιορισμένης διαθεσιμότητας νερών και επομένως χρησιμοποιούνται κυρίως για κάλυψη αιχμών. Υπό ένταξη, βρίσκονται 6 νέες μονάδες συνολικής ισχύος 688,5 MW. Όσον αφορά τις Μονάδες ΑΠΕ και ΣΗΘΥΑ (Συμπααραγωγή Ηλεκτρισμού και Θερμότητας Υψηλής Αποδοτικότητας), το 2013 στο ΕΣΜΗΕ λειτουργούσαν σταθμοί ΑΠΕ συνολικής εγκατεστημένης ισχύος 4170 MW (1495 MW αφορούν αιολικά πάρκα (Α/Π) και 2322 MW φωτοβολταϊκά Φ/Β), ενώ ο ΑΔΜΗΕ έχει δεσμεύσει για σύνδεση Α/Π συνολικής ισχύος 4800 MW επιπλέον.

**Πίνακας 2.2:** Υφιστάμενη Κατάσταση του Συστήματος Ηλεκτροπαραγωγής ανά Τεχνολογία, (ΑΔΜΗΕ, 2013).

<b>ΤΕΧΝΟΛΟΓΙΑ</b>	<b>ΕΓΚΑΤΕΣΤΗΜΕΝΗ ΙΣΧΥΣ (MW)</b>	<b>(%)</b>
Θερμικές Μονάδες	10.238,5	58,8
Υδροηλεκτρικές Μονάδες με ταμιευτήρα	3.017,7	17,3
ΑΠΕ και ΣΗΘΥΑ	4.169,81	23,9
<b>ΣΥΝΟΛΟ</b>	<b>17.426,01</b>	<b>100,0</b>

Σύμφωνα με την ίδια μελέτη, η εξέλιξη της Συνολικής Καθαρής Ζήτησης Ηλεκτρικής Ενέργειας (Διάγραμμα 2.1), χαρακτηρίζεται από μια συνεχή αύξηση το χρονικό διάστημα 2000-2008, με μέσο ετήσιο ρυθμό αύξησης 3,1% και από μια συνεχή μείωση το χρονικό διάστημα 2008-2012 (συνολικά περίπου 6%), λόγω της σημαντικής μείωσης των βιομηχανικών (20,19%) και οικιακών φορτίων (3,63%) συνέπεια της οικονομικής κρίσης.



**Διάγραμμα 2.2:** Εξέλιξη της Συνολικής Καθαρής Ζήτησης Ηλεκτρικής Ενέργειας κατά την περίοδο 2000-2012, (ΑΔΜΗΕ, 2013).

Το Νομοθετικό πλαίσιο σε Εθνικό επίπεδο (Νόμοι, Κοινές Υπουργικές Αποφάσεις, Προεδρικά Διατάγματα) για την ενέργεια και τις ΑΠΕ εμφανίζεται το 1985 και παρουσιάζει την παρακάτω διαχρονική εξέλιξη (ΡΑΕ, 2017):

- Ν. 1559/1985 «Ρύθμιση θεμάτων εναλλακτικών μορφών ενέργειας και ειδικών θεμάτων ηλεκτροπαραγωγής από συμβατικά καύσιμα και άλλες διατάξεις». Ο Νόμος αυτός αποτελεί την απαρχή του κλάδου των ΑΠΕ στην Ελλάδα.
- Ν. 2244/1994 «Ρύθμιση θεμάτων ηλεκτροπαραγωγής από ΑΠΕ και από συμβατικά καύσιμα και άλλες διατάξεις».
- Ν. 2773/1999 «Απελευθέρωση της αγοράς ηλεκτρικής ενέργειας» προς επικύρωση της ευρωπαϊκής Οδηγίας L27/30.1.1997 για την απελευθέρωση των εσωτερικών αγορών ηλεκτρικής ενέργειας των κρατών-μελών. Με το Νόμο αυτό προέκυψε η δημιουργία των νέων φορέων: της Ρυθμιστικής Αρχής Ενέργειας (ΡΑΕ) και του Διαχειριστή του δικτύου (ΔΕΣΜΗΕ Α.Ε.).

- Ν. 3175/2003 σχετικά με την ενίσχυση και προώθηση του ανταγωνισμού στην αγορά ηλεκτρικής ενέργειας με παράλληλα προσπάθεια διασφάλιση της επάρκειας της.
- Ν. 2941/2001 «Απλοποίηση διαδικασιών ίδρυσης εταιριών, αδειοδότηση ΑΠΕ και άλλες διατάξεις»
- ΚΥΑ 1726/2003 «Διαδικασία προκαταρκτικής εκτίμησης και αξιολόγησης, έγκρισης περιβαλλοντικών όρων καθώς και έγκρισης, επέμβασης ή παραχώρησης δάσους ή δασικής έκτασης στα πλαίσια της έκδοσης άδειας εγκατάστασης σταθμών ηλεκτροπαραγωγής από ΑΠΕ)».
- Ν. 3468/2006 σχετικά με την προώθηση της παραγωγής ηλεκτρικής ενέργειας από μονάδες ΑΠΕ και μονάδες Συμπαγωγής, προς επικύρωση της ευρωπαϊκής Οδηγίας 2001/77/ΕΚ, L283.
- Ν. 3752/2009 «Τροποποίηση επενδυτικών νόμων και άλλες διατάξεις».
- Ν. 3734/2009 «Προώθηση της συμπαγωγής δύο ή περισσότερων χρήσιμων μορφών ενέργειας», προς εναρμόνιση με την ευρωπαϊκή Οδηγία 2004/8/ΕΚ.
- ΚΥΑ 49828/2008 «Ειδικό Πλαίσιο Χωροταξικού Σχεδιασμού και Αειφόρου Ανάπτυξης για τις ΑΠΕ»
- Ν. 3468/2006 «Παραγωγή Ενέργειας από ΑΠΕ και ΣΗΘΥΑ και λοιπές διατάξεις»
- Ν. 3734/2009 «Προώθηση της συμπαγωγής δύο ή περισσότερων χρήσιμων μορφών ενέργειας, ρύθμιση ζητημάτων με το Υδροηλεκτρικό Έργο Μεσοχώρας και άλλες διατάξεις»
- Ν. 3851/2010 «Επιτάχυνση της ανάπτυξης των ΑΠΕ για την αντιμετώπιση της κλιματικής αλλαγής και άλλες διατάξεις», σε εναρμόνιση με την ευρωπαϊκή Οδηγία 2009/28/ΕΚ, με τον οποίο καθορίζονται και οι Εθνικοί στόχοι για την διείσδυση των ΑΠΕ ως το 2020: 1) Συμμετοχή της ενέργειας που παράγεται από ΑΠΕ στην ακαθάριστη τελική κατανάλωση ενέργειας σε ποσοστό 20%, 2) Συμμετοχή της ενέργειας που παράγεται από ΑΠΕ στην ακαθάριστη τελική κατανάλωση ενέργειας για θέρμανση και ψύξη σε ποσοστό 20%, 3) Συμμετοχή της ενέργειας που παράγεται από ΑΠΕ στην ακαθάριστη τελική κατανάλωση ενέργειας στις μεταφορές σε ποσοστό 10%, 4) Συμμετοχή της ηλεκτρικής ενέργειας που παράγεται από ΑΠΕ στην ακαθάριστη κατανάλωση ηλεκτρικής ενέργειας σε ποσοστό 40%.
- Ν. 4001/2011 «Για τη λειτουργία Ενεργειακών Αγορών Ηλεκτρισμού και Φυσικού Αερίου, για Έρευνα, Παραγωγή και δίκτυα μεταφοράς

Υδρογονανθράκων και άλλες ρυθμίσεις». Στα Άρθρα 117 και 118 ο Λειτουργός της Αγοράς Ηλεκτρικής Ενέργειας (ΛΑΓΗΕ Α.Ε.) αντικαθιστά σε καθήκοντα τον ΔΕΣΜΗΕ Α.Ε.

- ΚΥΑ Φ1/14810/2011 «Κανονισμός Αδειών Ηλεκτρικής Ενέργειας με χρήση ΑΠΕ και μέσω ΣΗΘΥΑ».

Το 2015, σύμφωνα με στοιχεία της EUROSTAT, το μερίδιο ενεργειακής κατανάλωσης από ΑΠΕ στην Ελλάδα διαμορφώθηκε στο 15,4% έναντι 16,1% στην Ε.Ε. των 28. Από το 2004 έως το 2015 η ενεργειακή κατανάλωση από ΑΠΕ αυξήθηκε από 8,5% σε 16,1%, ενώ στην Ελλάδα αυξήθηκε από 6,9% σε 15,4%. Η Ελλάδα πρέπει να φτάσει το στόχο του 18% έως το 2020. Στην επισκόπηση της προόδου προς τον πρώτο ενδιάμεσο στόχο το 2013 (Πίνακας 2.3), φαίνεται ότι η Ελλάδα τον έχει ξεπεράσει σε πολύ μικρό βαθμό όμως (EUROPA, 2013).


**Πίνακας 2.3:** Επισκόπηση προόδου προς τον 1ο ενδιάμεσο στόχο, σύμφωνα με την έκθεση προόδου της 27ης Μαρτίου 2013, (EUROPA, 2013).

<b>Κράτος μέλος</b>	<b>Μερίδιο ΑΠΕ 2005</b>	<b>Μερίδιο ΑΠΕ 2010</b>	<b>1<sup>ος</sup> ενδιάμεσος στόχος</b>	<b>Στόχος ΑΠΕ 2020</b>
Αυστρία	23,3%	30,1%	25,4%	34%
Βέλγιο	2,2%	5,4%	4,4%	13%
Βουλγαρία	9,4%	13,8%	10,7%	16%
Κύπρος	2,9%	5,7%	4,9%	13%
Τσέχικη Δημοκρατία	6,1%	9,4%	7,5%	13%
Γερμανία	5,8%	11%	8,2%	18%
Δανία	17%	22,2%	19,6%	30%
Εσθονία	18%	24,3%	19,4%	25%
Ελλάδα	6,9%	9,7%	9,1%	18%
Ισπανία	8,7%	13,8%	10,9%	20%
Φιλανδία	28,5%	33%	30,4%	38%
Γαλλία	10,3%	13,5%	12,8%	23%
Ουγγαρία	4,3%	8,8%	6%	13%
Ιρλανδία	3,1%	5,8%	5,7%	16%
Ιταλία	5,2%	10,4%	7,6%	17%
Λιθουανία	15%	19,7%	16,6%	23%



Λουξεμβούργο	0,9%	3%	2,9%	11%
Λετονία	32,6%	32,6%	34%	40%
Μάλτα	0%	0,4%	2%	10%
Κάτω Χώρες	2,4%	3,8%	4,7%	14%
Πολωνία	7,2%	9,5%	8,8%	15%
Πορτογαλία	20,5%	24,6%	22,6%	31%
Ρουμανία	17,8%	23,6%	19%	24%
Σουηδία	39,8%	49,1%	41,6%	49%
Σλοβενία	16%	19,9%	17,8%	25%
Σλοβακία	6,7%	9,8%	8,2%	14%
Ηνωμένο Βασίλειο	1,3%	3,3%	4%	15%
<b>Ε.Ε.</b>	<b>8,5%</b>	<b>12,7%</b>	<b>10,7%</b>	<b>20%</b>

Σύμφωνα με στοιχεία από τον Λειτουργό της αγοράς της Ηλεκτρικής Ενέργειας, την περίοδο 2007-2011, η συνολική εγκατεστημένη ισχύς των μονάδων παραγωγής ηλεκτρικής ενέργειας από ΑΠΕ, παρουσίασε μέσο ετήσιο ρυθμό μεταβολής 25% και ανήλθε σε 2,412 MW το 2011. Σημαντικότερη ετήσια αύξηση την ίδια χρονιά παρουσίασαν τα φωτοβολταϊκά, που σε σχέση με το προηγούμενο έτος η εγκατεστημένη ισχύς τους σχεδόν τριπλασιάστηκε. Διαχρονικά όμως, η εγκατεστημένη ισχύς των αιολικών πάρκων καλύπτει το μεγαλύτερο ποσοστό επί του συνόλου των ΑΠΕ (68% το 2011), ενώ ακολουθούν τα φωτοβολταϊκά πάρκα (21,6% το 2011) και οι μικροί υδροηλεκτρικοί σταθμοί (8,5% το 2011). Η συνολική παραχθείσα ηλεκτρική ενέργεια από ΑΠΕ την ίδια χρονική περίοδο κινήθηκε ανοδικά παρουσιάζοντας ρυθμό αύξησης της τάξης του 20% και ανήλθε σε 4,651 GWh το 2011 (71,3% τα αιολικά πάρκα, 12,5% οι μικροί υδροηλεκτρικοί σταθμοί και 11,9% τα φωτοβολταϊκά πάρκα. Οι συνολικές πωλήσεις ηλεκτρικής ενέργειας από ΑΠΕ, παρουσίασαν εντυπωσιακή αύξηση την ίδια χρονική περίοδο, με μέσο ετήσιο ρυθμό 36% και ανήλθαν σε €639,5 εκατ. το 2011.



**Διάγραμμα 2.3:** 2014-2016, Εγκατεστημένη ισχύς (MW) μονάδων ΑΠΕ σε λειτουργία στο Διασυνδεδεμένο Σύστημα (ΑΑΡΘΡΟ 9 Ν. 3468/2006) κι Φ/Β στεγών ≤10kW, (ΛΑΓΗΕ, 2016)

Με την εφαρμογή του Εθνικού Σχεδίου Δράσης (ΥΠΕΚΑ, 2017) για τις ΑΠΕ καθώς και την αναβάθμιση και επέκταση του δικτύου μεταφοράς ηλεκτρικής ενέργειας σε περιοχές που χαρακτηρίζονται από υψηλό αιολικό δυναμικό, αναμένεται να επέλθει δυναμική αύξηση του επιπέδου διείσδυσης των ΑΠΕ στην παραγωγή ενέργειας, ως προς την επίτευξη των στόχων της ενεργειακής πολιτικής του 2020, τον περιορισμό της εξάρτησης συμβατικούς ενεργειακούς πόρους και την ισχυροποίηση της χώρας στον παγκόσμιο ενεργειακό χάρτη.



**Διάγραμμα 2.4:** ΕΘΝΙΚΟΙ ΔΕΣΜΕΥΤΙΚΟΙ ΣΤΟΧΟΙ & ΕΚΤΙΜΗΣΗ ΔΙΕΙΣΔΥΣΗΣ ΑΠΕ, (ΥΠΕΚΑ, ΑΠΕ, 2017)

Συμπερασματικά λοιπόν, με βάση τα παραπάνω στοιχεία, η διαχρονική ανάπτυξη των ΑΠΕ στην Ελλάδα και οι μελλοντικοί στόχοι που έχουν τεθεί για την ενεργειακή πορεία της χώρας, συμβαδίζουν με την ανάγκη βελτιστοποίησης της τεχνολογίας των ΑΠΕ και την ανάπτυξη και χρήση κατάλληλων μοντέλων πρόβλεψης της παραγόμενης ενέργειας τους, ώστε να αξιοποιείται στο μεγαλύτερο δυνατό βαθμό η απόδοσή τους.

# Κεφάλαιο 3

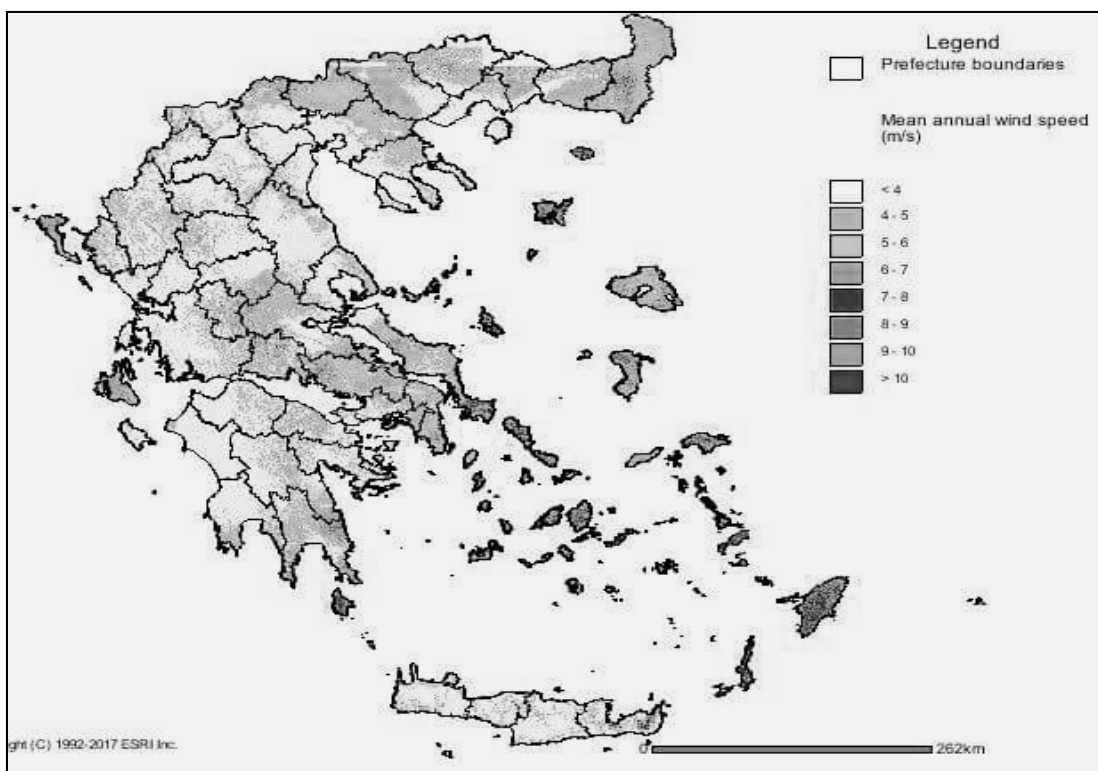
## Μεθοδολογία

### 3.1 Η Αιολική Ενέργεια

Η αιολική ενέργεια παράγεται από την εκμετάλλευση της κινητικής ενέργειας του πνέοντος ανέμου και έμμεσα οφείλεται στην ηλιακή ακτινοβολία, καθώς η ανομοιόμορφη θέρμανση της επιφάνειας της γης προκαλεί τη μετακίνηση μεγάλων αέριων μαζών (ανέμων) από τη μια περιοχή στην άλλη. Είναι ήπια μορφή ενέργειας, φιλική προς το περιβάλλον και πρακτικά ανεξάντλητη, επομένως ανανεώσιμη. Σήμερα για την αξιοποίησή της όπου το αιολικό δυναμικό θεωρείται εκμεταλλεύσιμο, χρησιμοποιούμε τις ανεμογεννήτριες (Α/Γ) κυρίως οριζοντίου άξονα 2 ή 3 πτερυγίων και αποδιδόμενης ισχύος 200–400 kW. Είναι μηχανές που μετατρέπουν την κινητική ενέργεια του ανέμου σε ηλεκτρική και η μετατροπή αυτή περιλαμβάνει δύο στάδια: στο πρώτο στάδιο η κινητική ενέργεια μέσω της πτερωτής μετατρέπεται σε μηχανική ενέργεια περιστροφής του άξονα της Α/Γ και στο δεύτερο μέσω της γεννήτριας η μηχανική ενέργεια μετατρέπεται τελικά σε ηλεκτρική. Μια τυπική Α/Γ οριζοντίου άξονα αποτελείται από (Μπεργελές, 1995): το δρομέα (αποτελείται από 2 ή 3 πτερύγια που προσδένονται σε μια πλήμνη), το σύστημα μετάδοσης της κίνησης (αποτελείται από τον κύριο άξονα, τα έδρανα και το κιβώτιο πολλαπλασιασμού των στροφών), την ηλεκτρική γεννήτρια (συνδέεται με την έξοδο του πολλαπλασιαστή και μετατρέπει τη μηχανική ενέργεια σε ηλεκτρική), το σύστημα προσανατολισμού (που αναγκάζει τον άξονα περιστροφής του δρομέα να βρίσκεται παράλληλα με τη διεύθυνση του ανέμου) και τον πύργο στήριξης (που στηρίζει όλη την ηλεκτρομηχανολογική εγκατάσταση περιλαμβάνοντας στη βάση του τον ηλεκτρονικό πίνακα και τον πίνακα ελέγχου).

Οι Α/Γ χρησιμοποιούνται για την πλήρη κάλυψη των ενεργειακών αναγκών ή έχουν συμπληρωματικό ρόλο. Συνήθως κατασκευάζονται αιολικά πάρκα (Α/Π), που

αποτελούν χερσαίες ή θαλάσσιες εκτάσεις στις οποίες έχει τοποθετηθεί κατάλληλος αριθμός ανεμογεννητριών για μέγιστη αξιοποίηση του αιολικού δυναμικού της περιοχής. Η παραγόμενη ενέργεια είτε καταναλώνεται άμεσα είτε διοχετεύεται στο δίκτυο μεταφοράς για να καταναλωθεί αλλού είτε αποθηκεύεται. Οι οικονομικά βιώσιμοι τρόποι αποθήκευσης της παραγόμενης ηλεκτρικής ενέργειας είναι οι ηλεκτρικοί συσσωρευτές (για μικρής κλίμακας παραγωγικές μη διασυνδεδεμένες στο δίκτυο μονάδες) και η άντληση/ταμίευση ύδατος σε τεχνητές λίμνες κατάλληλου υψόμετρου για την μετέπειτα τροφοδότηση υδροηλεκτρικού σταθμού (για μεγάλης κλίμακας παραγωγικές διασυνδεδεμένες μονάδες). Η Ελλάδα διαθέτει ένα πλούσιο αιολικό δυναμικό που οφείλεται στην εδαφική της ιδιαίτερη μορφολογία (μεγάλη ακτογραμμή, πλήθος νησιών). Το εκμεταλλεύσιμο αιολικό δυναμικό εκτιμάται ότι αντιπροσωπεύει το 13,6% του συνόλου των ηλεκτρικών αναγκών της χώρας. Το μικρότερο αιολικό δυναμικό συγκριτικά, έχει η περιφέρεια της Δυτικής Ελλάδας, όμως αυτό αντισταθμίζεται από το ισχυρό ηλεκτρικό δίκτυο που διαθέτει και από την ύπαρξη ανεμωδών «νησίδων» κατάλληλων για εκμετάλλευση.

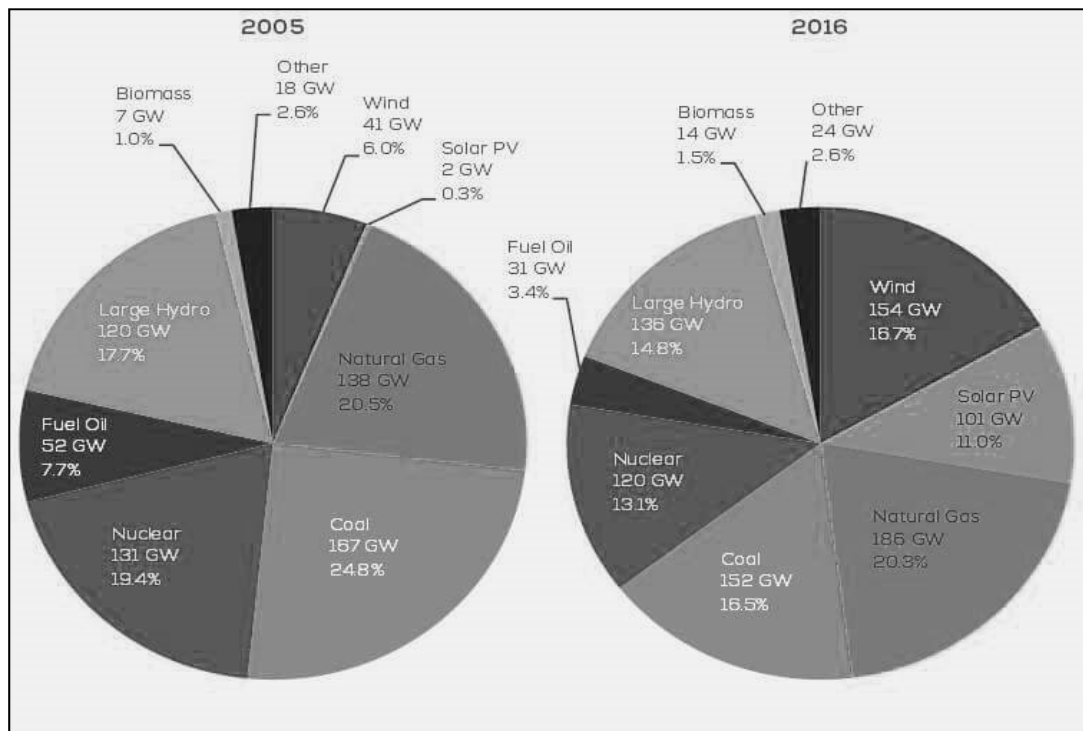


**Εικόνα 11:** Χάρτης αιολικού δυναμικού Ελλάδος, (ΥΠΕΚΑ, 2017)

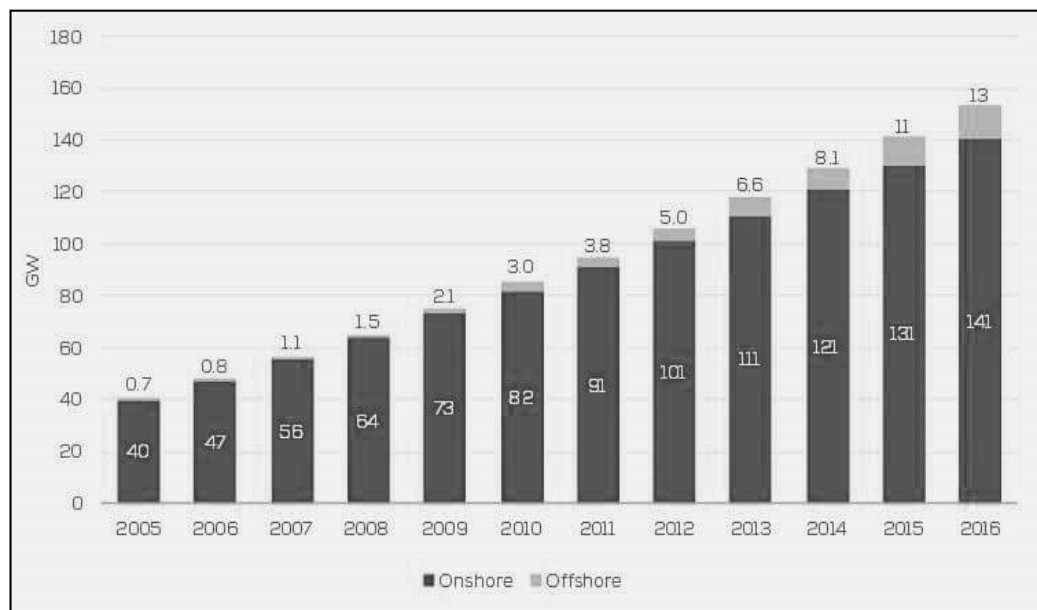
Από τη δεκαετία του 1980 όπου και ξεκίνησε η εγκατάσταση του πρώτου αιολικού πάρκου στην Ελλάδα μέχρι και σήμερα τα δεδομένα στον ενεργειακό τομέα έχουν

αλλάξει ριζικά. Οι αλλαγές στην νομοθεσία, η απελευθέρωση της αγοράς, η συμμετοχή του ιδιωτικού τομέα, η πολιτική της Ευρωπαϊκής Ένωσης για τις ΑΠΕ, κ.α, οδήγησαν σε ανάπτυξη της αιολικής ενέργειας σε ολόκληρη τη χώρα. Το 2016 εγκαταστάθηκε στη χώρα αιολική ισχύς περίπου 240 MW, παρά το χαμηλό επενδυτικό ενδιαφέρον. Έτσι το σύνολο της αιολικής ισχύος σε εμπορική ή δοκιμαστική λειτουργία κατά το τέλος του 2016 ανερχόταν στα 2.375 MW, όταν μόνο στο νησιωτικό χώρο του Αιγαίου το δυναμικό ηλεκτροπαραγωγής εκτιμάται ότι μπορεί να ανέλθει σε τετραπλάσιο νούμερο.


Σύμφωνα με τα ευρωπαϊκά στατιστικά στοιχεία (WindEurope, 2017), το έτος 2016 12,5 GW πρόσθετης συνολικής ενέργειας αιολικής ενέργειας εγκαταστάθηκαν στην Ευρώπη παρουσιάζοντας όμως 3% ελάττωση σε αντιστοιχία με το έτος 2015 (Malvaldi, Weiss, Infield, Browell, Leahy, Foley, 2017). Με 153,7 GW συνολική εγκατεστημένη ισχύ η αιολική ενέργεια ξεπερνά πλέον τον άνθρακα και γίνεται η δεύτερη μεγαλύτερη μορφή παραγωγής ενέργειας. Το μερίδιο της αιολικής ενέργειας στο συνολικό εγκατεστημένο δυναμικό αυξήθηκε από 6% το 2005, σε 16,7% το 2016 παραμένοντας στην πρώτη θέση ανάμεσα στις ΑΠΕ που συνολικά την ίδια περίοδο αύξησαν το μερίδιο τους από 24% σε 46%. Το 2016 στην Ευρώπη η αιολική ενέργεια εγκαταστάθηκε περισσότερο από οποιαδήποτε άλλη μορφή παραγωγής ηλεκτρικής ενέργειας αντιπροσωπεύοντας το 51% των συνολικών εγκαταστάσεων ισχύος (86% συνολικά οι ΑΠΕ), παράγοντας σχεδόν 300 TWh και καλύπτοντας το 10,4% της ζήτησης ηλεκτρικής ενέργειας. Η χρηματοδότηση για την ανάπτυξη μόνο της αιολικής ενέργειας παρουσίασε αύξηση 5% σε σχέση με το 2015, φτάνοντας τα €27,5 δισ.



**Διάγραμμα 3.1:** Μερίδιο σε εγκατεστημένη ισχύ το 2005 και το 2016, (WindEurope, 2017)



**Διάγραμμα 3.2:** Συσσωρευτικές εγκαταστάσεις χερσαίες και υπεράκτιες στην Ε.Ε., (WindEurope, 2017)



**Διάγραμμα 3.3:** Ετήσιες υπεράκτιες και χερσαίες εγκαταστάσεις αιολικής ενεργείας στην Ε.Ε., (WindEurope, 2017)

Σκοπός της παρούσας διπλωματικής εργασίας είναι η δημιουργία ενός μοντέλου πιθανοτικής πρόβλεψης ισχύος με τη χρήση νευρωνικών δικτύων για την ευκολότερη διαχείριση και ενσωμάτωση των αιολικών μονάδων στο δίκτυο. Στο πλαίσιο αυτό θα εξεταστούν οι λειτουργίες πρόγνωσης συγκεκριμένων λογισμικών εργαλείων (Zaitun Time series, NeuroXL Predictor) και η ελαχιστοποίηση του σφάλματος τους με βάση τις ανάγκες και τις απαιτήσεις των μονάδων ΑΠΕ καθώς και των αγορών ηλεκτρικής ενέργειας. Ως είσοδος χρησιμοποιούνται δεδομένα προβλέψεων καιρού (ταχύτητα ανέμου, διεύθυνση ανέμου, τυπική απόκλιση και θερμοκρασία) ενώ στην έξοδο προκύπτουν οι πιθανές τιμές αιολικής ισχύος για δεδομένο χρονικό ορίζοντα.

## 3.2 Κύρια Χαρακτηριστικά Ανέμου

Η δημιουργία των ανέμων όπως έχουμε ήδη αναφέρει οφείλεται στην ανομοιόμορφη θέρμανση της επιφάνειας της γης με αποτέλεσμα την αισθητή οριζόντια κίνηση του ατμοσφαιρικού αέρα. Αυτή η κίνηση όμως είναι διαρκώς μεταβαλλόμενη και διακοπτόμενη, ιδιαίτερα κοντά στην επιφάνεια της γης, όπου και αφορά την πρόβλεψη της ηλεκτρικής ισχύος από εγκατεστημένες Α/Γ. Η γνώση των χαρακτηριστικών του ανέμου έχει άμεσο αντίκτυπο στην επιλογή κατάλληλης θέσης για την εγκατάσταση Α/Π καθώς και για την εκτίμηση της ενέργειας που αυτός περικλείει. Επομένως είναι σημαντικό να γνωρίζουμε τα ακόλουθα χαρακτηριστικά:

- Ταχύτητα ανέμου



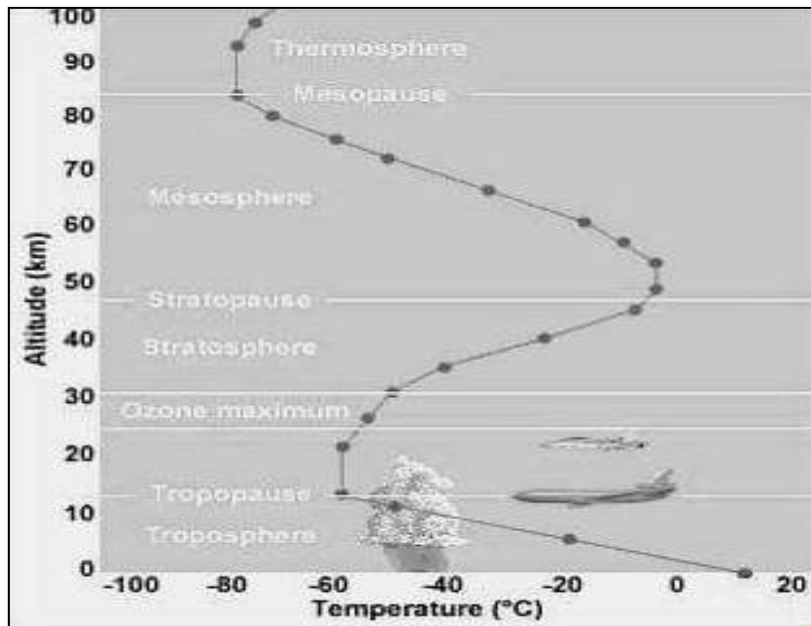
- Διεύθυνση ανέμου
- Στροβιλισμό ανέμου (τύρβη)
- Κατανομή ανέμου (κατά ύψος μεταβολή ταχύτητας ανέμου)
- Ριπές ανέμου (ακραίες τιμές ταχύτητας ανέμου σύντομης χρονικής διάρκειας)

Αυτά τα χαρακτηριστικά όμως, επειδή σχετίζονται με την αλληλεπίδραση του ανέμου με την επιφάνεια της γης ή τη μεταβολή της θερμοκρασιακής διαστρωμάτωσης του κατώτερου ατμοσφαιρικού στρώματος, μεταβάλλονται σε πολύ μικρότερη κλίμακα από αυτή της μετεωρολογίας ή κλιματολογίας, με αποτέλεσμα την ανάγκη χρήσης στατιστικών μεθόδων σε συνδυασμό πάντα με τα μετεωρολογικά δεδομένα για την εκτίμηση της αιολικής παραγωγής. Αξίζει να αναφέρουμε μερικά χρήσιμα στοιχεία για το κατώτερο τμήμα της ατμόσφαιρας, που αποτελεί η τροπόσφαιρα και το οποίο είναι σε επαφή με την επιφάνεια της γης. Τα κύρια χαρακτηριστικά της τροπόσφαιρας είναι (Λαζαρίδης, 2010), (Κατσαφάδος, Μαυροματίδης, 2015):


- Η θερμοκρασία μειώνεται με το ύψος με σταθερό σχεδόν ρυθμό 6,5 °C/Km.
- Η ταχύτητα του αέρα αυξάνεται με το ύψος με τις μέγιστες τιμές να παρατηρούνται στην τροπόπαυση (νοητή επιφάνεια διαχωρισμού τροπόσφαιρας και στρατόσφαιρας).
- Το σύνολο των μετεωρολογικών-καιρικών φαινομένων συμβαίνουν μέσα στην τροπόσφαιρα.
- Στην τροπόσφαιρα περιέχονται τα  $\frac{3}{4}$  της συνολικής μάζας του ατμοσφαιρικού αέρα και σχεδόν όλων των ατμοσφαιρικών αιωρημάτων (aerosols).
- Περιέχει το σύνολο σχεδόν της ποσότητας του νερού της ατμόσφαιρας.

Το κατώτερο τμήμα της τροπόσφαιρας που είναι σε άμεση επαφή με την επιφάνεια της γης αποτελεί το ατμοσφαιρικό οριακό στρώμα (ΑΟΣ). Οι μεταβολές μέσα στο ΑΟΣ προκαλούνται από τις δυνάμεις τριβής, την εξάτμιση, τη μεταφορά θερμότητας, τις εκπομπές αέριων και στερεών ρύπων καθώς και από την τοπογραφία της περιοχής. Μέσα στο ΑΟΣ κυριαρχεί η τυρβώδης ροή στην κίνηση του ανέμου, ο οποίος γενικά στρέφεται από τις υψηλές προς τις χαμηλές πιέσεις με κίνηση σπειροειδή (σπείρα Eckman), ενώ πάνω από το ΑΟΣ πνέει παράλληλα προς τις ισοβαρείς, οπότε και σταματάει να στρέφεται. Η τύρβη, που προκαλείται από οποιοδήποτε στοιχείο μπορεί να εισάγει ανωμαλίες στη ροή του ανέμου όπως η τραχύτητα της επιφάνειας του

εδάφους, δημιουργεί τυχαίους στροβιλισμούς αέρα που επηρεάζουν τόσο την παρεχόμενη αιολική ισχύ όσο και την αντοχή των Α/Π.



**Εικόνα 12:** Η κατακόρυφη κατανομή της θερμοκρασίας στην ατμόσφαιρα, (Κατσαφάδος, Μαυροματίδης, 2015)



**Εικόνα 13:** Ποσοστό μεταβολής καθ' ύψος ταχύτητας του ανέμου, (Μπεργελές, 1995)

Η ταχύτητα του ανέμου όπως αναφέραμε, είναι ιδιαίτερα μεταβλητό μέγεθος. Είναι μηδενική στην επιφάνεια του εδάφους λόγω τριβής ενώ αυξάνεται με το υψόμετρο έντονα κοντά στην επιφάνεια και λιγότερο καθώς απομακρυνόμαστε από αυτήν. Οι

μεταβολές της ταχύτητας του ανέμου συναρτήσει του υψομέτρου, εκφράζονται μέσω των παρακάτω συναρτήσεων:

$$\text{Εκθετική συνάρτηση: } V_{(z)} = V_r \left( \frac{z}{z_r} \right)^\alpha, \quad (3.1)$$

όπου  $z$  είναι το ύψος από την επιφάνεια του εδάφους,  $V_{(z)}$  είναι η ταχύτητα του ανέμου στο ύψος  $z$ ,  $V_r$  είναι η ταχύτητα του ανέμου στο ύψος  $z_r$  πάνω από την επιφάνεια του εδάφους και  $\alpha$  είναι ο δείκτης τραχύτητας εδάφους (κυμαίνεται από 0,1-0,45).

$$\text{Λογαριθμική συνάρτηση: } \frac{V_{(z)}}{V_{(10)}} = \frac{\ln\left(\frac{z}{z_0}\right)}{\ln\left(\frac{10}{z_0}\right)}, \quad (3.2)$$

όπου  $V_{(10)}$  είναι η ταχύτητα του ανέμου σε ύψος 10m από την επιφάνεια του εδάφους και  $z_0$  είναι το μήκος της ανωμαλίας του εδάφους, όπως φαίνεται στον πίνακα που ακολουθεί:

**Πίνακας 3.1:** Παράμετροι τραχύτητας εκθετικού και λογαριθμικού νόμου, Πηγή: [http://ape.chania.teicrete.gr/gr/files/HPIESI\\_Pres\\_01\\_Wind.pdf](http://ape.chania.teicrete.gr/gr/files/HPIESI_Pres_01_Wind.pdf)

<b>Κατηγορία τραχύτητας</b>	<b>Είδος εδάφους</b>	<b><math>\alpha</math></b>	<b><math>z_0</math>(m)</b>
0	Εξομαλυμένο (χιόνι, θάλασσα, άμμος)	0,10-0,13	0,001-0,02
1	Μέτρια βλάστηση (χαμηλή βλάστηση, καλλιέργειες, αγροτικές περιοχές)	0,13-0,20	0,02-0,30
2	Τραχύ έδαφος (δάση, προάστια πόλεων)	0,20-0,27	0,30-2,0
3	Πολύ τραχύ έδαφος (αστικές περιοχές, υψηλά κτίρια)	0,27-0,45	2,0-15,0

### 3.2.1.1 Δυνάμεις και Είδη Ανέμου

Για τον προσδιορισμό του ανέμου απαιτείται η γνώση της κατεύθυνσης (direction) και της ταχύτητας (speed) του. Οι δυνάμεις που ρυθμίζουν την κίνηση της αέριας μάζας είναι οι παρακάτω (Χαλδούπης, 2015), (Κατσαφάδος, Μαυροματίδης, 2015):

- Δύναμη βαροβαθμίδας:** είναι η δύναμη που δέχεται μια αέρια μάζα εξαιτίας των διαφορετικών βαρομετρικών πιέσεων που επικρατούν σε μια περιοχή και την ωθεί από τις υψηλές προς τις χαμηλές πιέσεις. Έχει διεύθυνση πάντα κάθετη στις ισοβαρείς και φορά πάντα προς τις χαμηλές πιέσεις. Η γενική μορφή της στη μονάδα μάζας δίνεται από τη σχέση: 
$$\frac{\vec{F}_p}{m} = -\frac{1}{\rho} \vec{\nabla} P, \quad (3.3)$$
 όπου  $\rho$  η πυκνότητα της αέριας μάζας και  $\vec{\nabla} P$  το άνυσμα της βαθμίδας πίεσης.
- Δύναμη Coriolis:** είναι η δύναμη που ασκείται σε κάθε σώμα που κινείται στην ατμόσφαιρα με αποτέλεσμα αυτό να εκτρέπεται δεξιά στο Βόρειο Ημισφαίριο και αριστερά στο Νότιο Ημισφαίριο. Έχει διεύθυνση πάντα κάθετη στην ταχύτητα του σώματος. Η γενική μορφή της στη μονάδα μάζας δίνεται από τη σχέση: 
$$\frac{\vec{F}_c}{m} = -2\vec{\Omega} \times \vec{V} = -2\vec{\Omega} V \sin\varphi = -f\vec{V}, \quad (3.4)$$
 όπου  $f = 2\Omega \sin\varphi$  η παράμετρος Coriolis και  $\vec{V}$  η σχετική ταχύτητα του σώματος (αέρας).
- Δύναμη τριβής:** οφείλεται στη σχετική κίνηση του ατμοσφαιρικού αέρα πάνω από την επιφάνεια της γης (καθώς και στις εσωτερικές τριβές των κινούμενων σωματιδίων). Έχει κατεύθυνση πάντα αντίθετη με αυτήν της ταχύτητας του σώματος και αυξάνεται με την αύξηση της τραχύτητας του εδάφους. Η γενική μορφή της στη μονάδα μάζας δίνεται από τη σχέση: 
$$\frac{\vec{F}_T}{m} = \nu V^2 \vec{V}, \quad (3.5)$$
 όπου  $\nu$  το κινηματικό ιξώδες του ρευστού και  $\frac{\vec{F}_T}{m} = KV^2 \vec{V}, \quad (3.6)$  όπου  $K$  ο συντελεστής του ιξώδους των στροβίλων.
- Κυκλοστροφική δύναμη (φυγόκεντρος ή κεντρομόλος):** είναι η δύναμη που αφορά την καμπύλωση της τροχιάς κίνησης του σώματος ή την αντίδραση στην καμπύλωση αυτή, με διεύθυνση πάντα αυτή της νοητής ακτίνας. Η γενική μορφή της στη μονάδα μάζας δίνεται από τη σχέση: 
$$\frac{\vec{F}_\Phi}{m} = \Omega^2 \vec{r}, \quad (3.7)$$
 όπου  $\Omega$  ο ρυθμός περιστροφής του συστήματος συντεταγμένων και  $r$  η απόσταση από τον άξονα περιστροφής.
- Δύναμη βαρύτητας:** είναι η δύναμη που δέχεται κάθε σώμα εξαιτίας της έλξης από τη γη με κατεύθυνση πάντα προς το κέντρο της γης. Η γενική μορφή της στη μονάδα μάζας δίνεται από τη σχέση: 
$$\frac{\vec{F}_n}{m} = -\frac{GM}{r^2} \vec{k} = -g_0 \vec{k}, \quad (3.8)$$
 όπου  $G$  η σταθερά παγκόσμιας έλξης,  $M$  η μάζα της γης,  $r$  η απόσταση γης - σώματος  $m$  και  $g_0$  η ένταση του βαρυτικού πεδίου.

Από αυτές της δυνάμεις αυτές που μπορούν να θέσουν σε κίνηση μια αέρια μάζα είναι η δύναμη βαροβαθμίδας και η δύναμη βαρύτητας ενώ οι υπόλοιπες εμφανίζονται όταν το σώμα κινείται. Η εξίσωση της οριζόντιας κίνησης για τη μοναδιαία αέρια μάζα είναι:

$$\frac{d\vec{V}}{dt} = -\frac{1}{\rho}\vec{\nabla}P - 2\vec{\Omega}\times\vec{V} + \vec{F}_T, \quad (3.9)$$

Με βάση τις παραπάνω δυνάμεις προκύπτουν και οι ακόλουθοι τύποι ανέμου (Μετεωρολογική Υπηρεσία, 2011):

- **Γεωστροφικός Άνεμος:** είναι αποτέλεσμα της ισορροπίας των δυνάμεων βαροβαθμίδας και Coriolis. Είναι παράλληλος στις ισοβαρείς (ευθείες γραμμές) και πνέει πάντα πάνω από τα 500m υψόμετρο, έχοντας στα αριστερά του τις χαμηλές πιέσεις.
- **Άνεμος Βαροβαθμίδας (gradient wind):** είναι αποτέλεσμα της ισορροπίας των δυνάμεων βαροβαθμίδας, Coriolis και φυγόκεντρου. Εμφανίζεται στην περίπτωση που οι ισοβαρείς δεν είναι ευθείες αλλά καμπύλες με αποτέλεσμα την εμφάνιση και της φυγόκεντρου δύναμης. Για τον άνεμο αυτό διακρίνουμε δυο τύπους ροής στο Βόρειο Ημισφαίριο: την περίπτωση αντιωρολογιακής ροής ανέμου (Κυκλωνική) και την περίπτωση ωρολογιακής ροής ανέμου (Αντικυκλωνική).
- **Άνεμος Τριβής:** Μέχρι τα 500m εμφανίζεται και η δύναμη Τριβής που εξαρτάται από το ανάγλυφο του εδάφους. Η τελική ισορροπία αυτών των δυνάμεων έχει ως αποτέλεσμα ο άνεμος στην επιφάνεια να μην είναι παράλληλος με τις ισοβαρείς αλλά να έχει μια κλίση πάντα προς τις χαμηλές πιέσεις ενώ η ταχύτητα του είναι μικρότερη σε σχέση με τον άνεμο βαροβαθμίδας.
- **Τοπικοί Άνεμοι:** εδώ ανήκουν η Θαλάσσια Αύρα, η Απόγειος Αύρα, ο Καταβατικός Άνεμος (Αύρα βουνών) και ο Αναβατικός Άνεμος (Αύρα κοιλάδων). Η Θαλάσσια Αύρα πνέει από τη θάλασσα προς την ξηρά κατά την διάρκεια της ημέρας λόγω διαφοράς θερμοκρασίας νερού-ξηράς (ταχύτερη θέρμανση ξηράς). Η Απόγειος Αύρα πνέει από την ξηρά προς την θάλασσα κατά την διάρκεια της νύχτας λόγω διαφοράς θερμοκρασίας νερού-ξηράς (ταχύτερη ψύξη ξηράς). Ο Καταβατικός Άνεμος πνέει προς τα κάτω κατά μήκος της πλαγιάς του βουνού και προκαλείται από τη μεγαλύτερη πυκνότητα αέρα εκεί, λόγω της επιφανειακής ψύξης της πλαγιάς. Ο Αναβατικός Άνεμος πνέει προς τα πάνω


κατά μήκος της πλαγίας του βουνού και προκαλείται από τη μικρότερη πυκνότητα αέρα εκεί, λόγω της επιφανειακής θέρμανσης της πλαγίας.

### 3.2.1.2 Στατιστικά Χαρακτηριστικά Ανέμου

Βασικό στατιστικό χαρακτηριστικό για το αιολικό δυναμικό μιας περιοχής θεωρείται η μέση ταχύτητα του ανέμου. Όμως για την εκτίμηση της αιολικής ενέργειας που μπορεί να προσφέρει μια περιοχή απαιτείται επιπλέον πληροφόρηση σχετικά με τη συχνότητα εμφάνισης της κάθε ταχύτητας του ανέμου και μάλιστα κατά διεύθυνση ώστε να προσδιοριστούν και οι κύριες διευθύνσεις του ανέμου (Manwell, McGowan, Rogers, 2009). Η μελέτη χρονικών διαστημάτων νηνεμίας παρουσιάζει ενδιαφέρον επίσης, γιατί προσδιορίζουν την χρονική περίοδο που η Α/Γ βρίσκεται εκτός λειτουργίας και άρα καθορίζουν τα συστήματα υποστήριξης της. Στην εικόνα 20, φαίνεται η χρονική μεταβολή της ταχύτητας του ανέμου, δηλαδή στιγμιαίες τιμές της καθώς και το χρονικό διάστημα  $T$ , στο οποίο θα προκύψει η μέση τιμή της.

$$\text{Μέση τιμή ταχύτητας: } \bar{V} = \frac{1}{T} \int_t^{t+T} V(t) dt, \text{ για } T \text{ συνήθως } 10 \text{ λεπτά.} \quad (3.10)$$

$$\text{Στιγμιαία τιμή ταχύτητας: } V = \bar{V} + V'(t), \text{ δηλαδή το άθροισμα της μέσης ταχύτητας και της διακύμανσης γύρω από μια μέση τιμή.} \quad (3.11)$$



**Εικόνα 14:** Μετρήσεις ταχύτητας ανέμου με το χρόνο, Πηγή: <http://slideplayer.gr/slide/1924540/>

Η διακύμανση της ταχύτητας του ανέμου γύρω από τη μέση τιμή δίνεται από τη σχέση:

$$[V'(t)]^2 = \sigma_v^2 = \frac{1}{T} \int_t^{t+T} [V(t) - \bar{V}]^2 dt, \text{ για } T \text{ συνήθως } 10 \text{ λεπτά.} \quad (3.12)$$

Η ένταση της τύρβης του ανέμου δίνεται από την σχέση:


$$I = \frac{\sigma_v}{\bar{v}}, \text{ όπου } \sigma_v \text{ η τυπική απόκλιση.} \quad (3.13)$$

Επιπλέον επειδή η ένταση της τύρβης είναι ανάλογη της τραχύτητας του εδάφους και αντιστρόφως ανάλογη του ύψους μελέτης από το έδαφος, προσεγγίζεται ικανοποιητικά με βάση το μήκος της ανωμαλίας  $z_0$  και από τις εξισώσεις:

$$I = \frac{1}{\ln\left(\frac{z}{z_0}\right)}, \text{ για } z_0 \leq 0,20m \quad (3.14)$$

$$I = \frac{-0,14 \ln z_0 + 0,78}{\ln\left(\frac{z}{z_0}\right)}, \text{ για } z_0 > 0,20m. \quad (3.15)$$

Η στατιστική κατανομή της ταχύτητας του ανέμου προκύπτει από ανεμολογικά δεδομένα μετρούμενα σε καθορισμένο ύψος (συνήθως 10 μέτρα) και σε καθορισμένο χρονικό εύρος (συνήθως 10 λεπτά) σε διάστημα ενός έτους. Αυτά τα δεδομένα παρέχουν μέγιστη, ελάχιστη και μέση τιμή ταχύτητας ανέμου καθώς και την τυπική απόκλιση. Επομένως παρέχουν πληροφορίες για τα μέγιστα και ελάχιστα φορτία, το αιολικό δυναμικό και την τύρβη. Από τις μέσες τιμές αυτών, προκύπτει η ετήσια μέση ταχύτητα του ανέμου και η ετήσια σχετική κατανομή του. Αξιόπιστα στατιστικά αποτελέσματα χρειάζονται δεδομένα τουλάχιστον μέχρι δέκα έτη. Η στατιστική κατανομή της συχνότητας της ταχύτητας του ανέμου μετράται ως συνάρτηση της πυκνότητας πιθανότητας ή της αθροιστικής πυκνότητας πιθανότητας. Η πρώτη κατανομή δείχνει απευθείας τις ταχύτητες του ανέμου που εμφανίζονται περισσότερο σε μια περιοχή ενώ η δεύτερη δείχνει ως ποσοστό την περίοδο μέσα στο έτος όπου η ταχύτητα είχε τιμή μικρότερη ή ίση από το συγκεκριμένο σημείο της εν λόγω καμπύλης.




**Εικόνα 15:** Χαρακτηριστικές κατανομές ανέμου

Από τη στατιστική ανάλυση των δεδομένων της ταχύτητας του ανέμου για μια σειρά ετών στις διάφορες περιοχές και προσαρμόζοντας αυτά σε διάφορες συναρτήσεις πυκνότητας πιθανότητας  $f(V)$ , απεδείχθη ότι αυτά προσεγγίζουν καλύτερα την κατανομή Weibull. Η συνάρτηση αυτή (Manwell, McGowan, Rogers, 2009) εξαρτάται από την παράμετρο  $C$  (παράμετρος κλίμακας της κατανομής) που σχετίζεται με τη μέση ταχύτητα ανέμου σε κάθε γεωγραφικό τόπο και την αδιάστατη παράμετρο  $k$  (παράμετρος μορφής της κατανομής) που είναι αντιστρόφως ανάλογη της διακύμανσης του μέτρου των ταχυτήτων του ανέμου ως προς τη μέση ταχύτητα. Και οι δύο παράμετροι χαρακτηρίζουν το αιολικό δυναμικό. Στην περίπτωση που είναι γνωστή μόνο η μέση ταχύτητα ανέμου και εφόσον ο υπολογισμός της παραμέτρου μορφής είναι δύσκολος, λαμβάνεται η τιμή  $k = 2$  και προκύπτει η κατανομή Rayleigh. Και οι δύο κατανομές χρησιμοποιούνται στην ανάλυση δεδομένων ανέμου, με την κατανομή Weibull όμως να μπορεί να αντιπροσωπεύει καλύτερα μια ευρύτερη ποικιλία αιολικών συστημάτων. Οι μαθηματικές τους εκφράσεις δίνονται από τις σχέσεις:

$$\text{Κατανομή Weibull: } f(V) = \left(\frac{k}{c}\right) \left(\frac{V}{c}\right)^{k-1} \exp\left[-\left(\frac{V}{c}\right)^k\right], \quad (3.16)$$

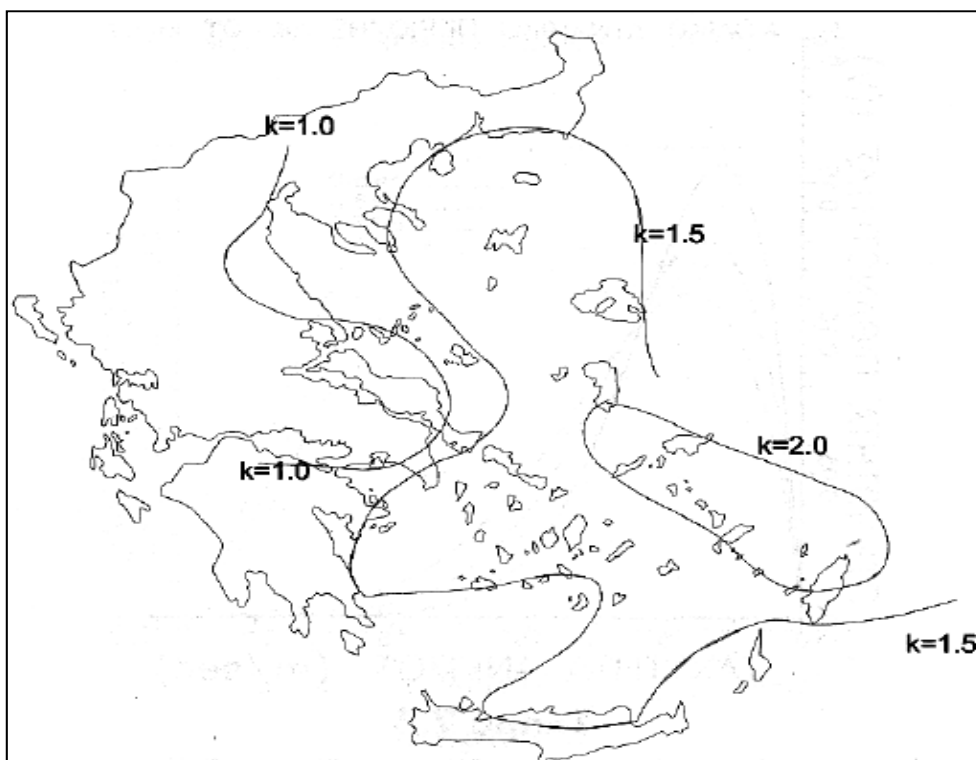
$$\text{Κατανομή Rayleigh: } f(V) = \frac{2}{c^2} V \exp\left[-\left(\frac{V}{c}\right)^2\right]. \quad (3.17)$$



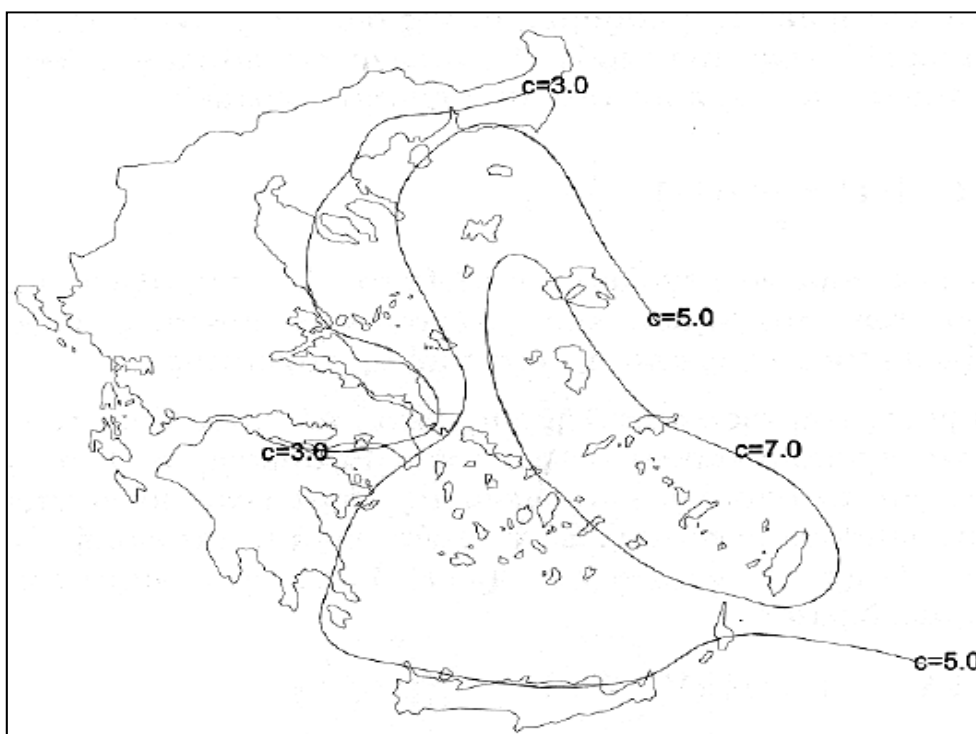


**Εικόνα 16:** Γραφική παράσταση της συνάρτησης πυκνότητας πιθανότητας για  $C=6\text{m/s}$  και μεταβλητό  $k$ , (Manwell et al, 2009)

Σύμφωνα με την εικόνα 21, η παράμετρος  $k$  καθορίζει το σχήμα της συνάρτησης πυκνότητας πιθανότητας Weibull. Η συνάρτηση εμφανίζει μια πιο έντονη κορυφή καθώς το  $k$  αυξάνεται, υποδεικνύοντας την ύπαρξη σταθερών ταχυτήτων ανέμου γύρω από τη μέση ταχύτητα του. Καθώς το  $k$  μειώνεται όμως, παρατηρείται μια ομαλοποίηση, υποδεικνύοντας μεγαλύτερη μεταβολή στην ταχύτητα του ανέμου και μεγαλύτερη συχνότητα εμφάνισης χαμηλών και υψηλών ταχυτήτων ανέμου. Όλη λοιπόν η πληροφορία της συμπεριφοράς του ανέμου συγκεντρώνεται παρέχοντας τις δυο παραμέτρους της κατανομής Weibull, σε συνάρτηση με τη διεύθυνση του ανέμου (Lun, Lam, 2000).




**Εικόνα 7:** Γεωγραφική διανομή παραμέτρου  $k$ , Πηγή: <http://docplayer.gr/10869154-Aiolika-systimata-anemos.html>



**Εικόνα 8:** Γεωγραφική διανομή παραμέτρου  $C$ , Πηγή: <http://docplayer.gr/10869154-Aiolika-systimata-anemos.html>

### 3.2.1.3 Μετατροπή Αιολικής Ισχύος σε Ηλεκτρική Ενέργεια

Η παραγωγή αιολικής ισχύος είναι σε υψηλό βαθμό μεταβλητή, εφόσον συνδέεται άμεσα με την ταχύτητα του ανέμου. Οι Α/Γ μετατρέπουν την κινητική ενέργεια του ανέμου σε ηλεκτρική και η διαδικασία αυτής της ενεργειακής μετατροπής σε κάθε Α/Γ περιγράφεται από τη χαρακτηριστική της καμπύλη, που ονομάζεται καμπύλη ισχύος της Α/Γ. Οι χαρακτηριστικές καμπύλες σε γενικές γραμμές έχουν την ίδια μορφή, ανεξάρτητα από τον κατασκευαστή ή τον τύπο της Α/Γ.



Εικόνα 19: Χαρακτηριστική καμπύλη τυπικής Α/Γ, (Pinson, 2006).

Σύμφωνα με την παραπάνω καμπύλη ισχύος η παραγωγή ισχύος είναι μηδέν κάτω από το όριο έναρξης λειτουργίας της Α/Γ (cut-in speed) δηλαδή σε ταχύτητες ανέμου 2-4  $m/s$  ενώ αυξάνεται απότομα μέχρι να τις ταχύτητες των 12-16  $m/s$  (rated speed). Σε αυτές τις ταχύτητες το επίπεδο παραγωγής φθάνει το ονομαστικό της ( $P_n$ ). Η παραγωγή ισχύος της Α/Γ είναι σχεδόν σταθερή ανάμεσα στις ταχύτητες ανέμου 12-16  $m/s$  και 25-30  $m/s$ . Στην ταχύτητα αποκοπής (cut-off) η λειτουργία της διακόπτεται για λόγους ασφαλείας. Μπορεί να υπάρχει μια μικρή διαφορά της τάξης 10-20%, ανάμεσα στη μέγιστη παραγόμενη ισχύ και την ονομαστική ισχύ της. Η ονομαστική ισχύς ( $P_n$ ), χρησιμεύει σαν τιμή αναφοράς υποδηλώνοντας την ικανότητα της Α/Γ και επιπλέον στον υπολογισμό της αναμενόμενης παραγωγής ισχύος με βάση πάντα τα χαρακτηριστικά της τοποθεσίας (Pinson, 2006).

Η απότομη αύξηση της χαρακτηριστικής καμπύλης στις χαμηλές ταχύτητες ανέμου μπορεί να εξηγηθεί από την σχέση που μας δίνει την περιεχόμενη από τον άνεμο ισχύ, μέρος της οποίας θα μετατραπεί σε ηλεκτρική από την Α/Γ:

$$P_{\text{ανεμου}}(V) = \frac{1}{2} \rho A V^3, \quad (3.18)$$

όπου  $V$  η ταχύτητα του ανέμου στο ύψος της πλήμνης της Α/Γ μια δεδομένη χρονική στιγμή,  $\rho$  η πυκνότητα του ατμοσφαιρικού αέρα και  $A$  η επιφάνεια (εμβαδόν) σάρωσης της έλικας της Α/Γ. Η παραπάνω σχέση δίνει μόνο θεωρητικά τη διαθέσιμη ισχύ από τον άνεμο. Στην πράξη όμως λόγω απωλειών είναι δυνατόν να αποδοθεί μόλις ένα 20-30% της αρχικής διαθέσιμης αιολικής ενέργειας.

Η αεροδυναμική ποιότητα του δρομέα, που χαρακτηρίζεται από τον αεροδυναμικό συντελεστή ισχύος  $C_p$  και εξαρτάται από τον αεροδυναμικό σχεδιασμό των πτερυγίων (υπεύθυνα για απορρόφηση της αιολικής ισχύος), εμφανίζει απώλειες λόγω: της καθυστέρησης λόγω γωνίας πλαγιολίσθησης, της αλλοίωσης της επιφάνειας των πτερυγίων και του φαινομένου σκίασης (tower shadow). Ο συντελεστής ισχύος, δίνεται από τη σχέση:  $C_p = \frac{P_M}{P_A}$ , (3.19)

όπου  $P_M$  η μηχανική ισχύς που παράγεται τελικά από την ανεμογεννήτρια και  $P_A$  η εισερχόμενη αιολική ισχύς. Τελικά η παραγόμενη μηχανική ισχύς κάθε χρονική στιγμή δίνεται από τη βελτιωμένη σχέση:

$$P_M(V) = \frac{1}{2} \rho A_\gamma C_p V^3 n_t, \quad (3.20)$$

όπου  $n_t$  η αποδοτικότητα της ανεμογεννήτριας με μέγιστη τιμή 0.8,  $A_\gamma$  η εκτεθειμένη στον άνεμο επιφάνεια σάρωσης,  $V$  η ταχύτητα του ανέμου στο ύψος της πλήμνης της Α/Γ μια δεδομένη χρονική στιγμή,  $\rho$  η πυκνότητα του ατμοσφαιρικού αέρα και  $C_p$  ο συντελεστής ισχύος που για μια καλά σχεδιασμένη γεννήτρια κυμαίνεται στην τιμή 0,35.

Ο αεροδυναμικός συντελεστής ισχύος προκύπτει από την αεροδυναμική ποιότητα των πτερυγίων και εξαρτάται από τα κατασκευαστικά τους χαρακτηριστικά δηλαδή από τη γωνία βήματος της έλικας  $\beta$  (pitch) και από το λόγο της ταχύτητας του ακροπτερυγίου  $\lambda$  που δίνεται από τη σχέση:  $\lambda = \frac{\omega R}{V}$ , (3.21)

όπου  $R$  η ακτίνα της έλικας,  $\omega$  η γωνιακή ταχύτητα περιστροφής τους δρομέα και  $V$  η ταχύτητα του ανέμου στο ύψος της πλήμνης της Α/Γ μια δεδομένη χρονική στιγμή.

Μέσω της γωνίας βήματος έλικας  $\beta$  γίνεται συχνά ο έλεγχος ροή ισχύος, ενώ μια μαθηματική σχέση που υπολογίζει επιτυχώς την μεταβολή του  $C_p$  (και άρα της μηχανικής ισχύος) είναι η ακόλουθη (Παπαδόπουλος, 1997):

$$C_p = (1,12 - 0,022\beta^2 - 2,8)e^{-0,38\frac{V}{\omega}}, \quad (3.22)$$

Η μέγιστη τιμή που μπορεί να πάρει ο αεροδυναμικός συντελεστής ισχύος, έχει υπολογιστεί στην τιμή  $C_{p(MAX)} = 0.592$ , που αναφέρεται και ως όριο του Betz. Επομένως σύμφωνα με το νόμο του Betz, μόνο το 59,2% της κινητικής ενέργειας του ανέμου μπορεί να μετατραπεί σε μηχανική ενεργεία μέσω της Α/Γ, για το λόγο αυτό επιδιώκουμε υψηλές τιμές του συντελεστή ισχύος.

Επειδή οι χαμηλές ταχύτητες του ανέμου είναι συχνότερες από τις ισχυρές, είναι κατανοητό ότι οι Α/Γ λειτουργούν στα χαμηλά και απότομα σημεία της καμπύλης ισχύος. Σε αυτή την ζώνη μικρές μεταβολές ταχύτητας προκαλούν μεγάλες μεταβολές στην παραγόμενη ισχύ. Αυτή η μεταβλητότητα οδηγεί σε μια δυναμική συμπεριφορά αιολικής παραγωγής. Επομένως οι Α/Γ δεν παράγουν την ονομαστική τους ισχύ συχνά και άρα η παραγόμενη ενέργεια δεν ισούται με την ονομαστική ισχύ επί το χρόνο λειτουργίας τους. Για το λόγο αυτό καθορίστηκε ο συντελεστής δυναμικότητας αιολικού πάρκου που ορίζεται ως ο λόγος της παραγόμενης ενέργειας προς την ενέργεια που θα παρήγαγε το αιολικό πάρκο αν δούλευε στη μέγιστη ισχύ για την ίδια χρονική περίοδο και αποτελεί δείκτη καλής λειτουργίας του αιολικού πάρκου περιγράφοντας το κέρδος του. Για τα αιολικά πάρκα της ενδοχώρας (onshore) ο δείκτης αυτός κυμαίνεται μεταξύ 25-40% ενώ για τα θαλάσσια (offshore) κυμαίνεται μεταξύ 45-60% και είναι ο λόγος προτίμησης κατασκευής των δεύτερων (Pinson, 2006).

### 3.3 Πρόβλεψη Αιολικής Παράγωγης

Η αυξανόμενη διείσδυση της αιολικής ενέργειας στα συστήματα ηλεκτρικής ενέργειας σύμφωνα με τα στοιχεία που ήδη αναφέραμε και η έντονη μεταβλητότητα και τυχαιότητα που όπως έχουμε ήδη αναφέρει την χαρακτηρίζει, αποτελούν τροχοπέδη για την εξέλιξη και ενσωμάτωση της στο δίκτυο. Για να αντισταθμιστούν οι παράγοντες αυτοί απαιτούνται εργαλεία/μοντέλα πρόβλεψης της αιολικής ισχύος βραχυπρόθεσμα/μεσοπρόθεσμα ώστε να καθίσταται δυνατή η διαχείριση και το εμπόριο της ενέργειας καθώς και οι εξυπηρέτηση των τελικών χρηστών (παραγωγοί, αγοραστές και διαχειριστές ενέργειας). Η πρόβλεψη της παραγωγής ηλεκτρικής ενέργειας (HE) από μία μονάδα ΑΠΕ που εκτελείται τη χρονική στιγμή  $t$  για την εκτίμηση της παραγωγής κατά την μελλοντική χρονική στιγμή  $t + k$ , υπολογίζει τη μέση ισχύ  $p_{t+k|t}$  που αναμένεται να παράγει η μονάδα σε συγκεκριμένο χρονικό διάστημα μελλοντικά, εφόσον λειτουργεί υπό σταθερό και συνεχή άνεμο (Monteiro, Bessa, Miranda, Botterud, Wang, Conzelmann, 2009). Η χρονική ανάλυση της πρόβλεψης υποδηλώνεται από το χρονικό βήμα  $k$ , το οποίο είναι άμεσα συσχετιζόμενο με το καθορισμένο εύρος του χρονικού ορίζοντα  $T$ . Για χρονικούς ορίζοντες 24 έως 72 ωρών, το βήμα είναι συνήθως ωριαίο ενώ χρονικούς ορίζοντες μικρότερους από 4 έως 6 ώρες, το βήμα αφορά συνήθως λεπτά. Δεν λαμβάνονται υπόψη οι μεταβολές της ισχύος άρα και οι επιπτώσεις αυτών στο ενδιάμεσο χρονικό διάστημα του βήματος.

Υπάρχει ένας γενικός διαχωρισμός στη διεθνή βιβλιογραφία για τους χρονικούς ορίζοντες πρόβλεψης. Σύμφωνα με αυτόν ορίζονται (Monteiro et al, 2009), (Wang, Guo, Huang, 2011):

- 1. Πολύ βραχυπρόθεσμη πρόβλεψη:** το εύρος του χρονικού ορίζοντα εδώ είναι μικρότερο από 9 ώρες. Η χρησιμότητα των προβλέψεων αυτών για τις εταιρίες παραγωγής HE αποσκοπεί κυρίως στη συμμετοχή τους στην ενδοημερήσια αγορά HE και αγορά HE πραγματικού χρόνου, ενώ για τον Διαχειριστή των ΣΗΕ αποσκοπεί στον προσδιορισμό των επικουρικών υπηρεσιών, της ένταξης μονάδων παραγωγής, της οικονομικής κατανομής φορτίου και στην διαχείριση συμφόρησης δικτύου.
- 2. Βραχυπρόθεσμη πρόβλεψη:** το εύρος του χρονικού ορίζοντα εδώ είναι μικρότερο από 72 ώρες. Η χρησιμότητα των προβλέψεων αυτών για τις εταιρίες παραγωγής HE αποσκοπεί κυρίως στη συμμετοχή τους στην αγορά HE της

επόμενης ημέρας, στον προγραμματισμό συντήρησης των μονάδων ΑΠΕ και στο συντονισμό των μονάδων παραγωγής και αποθήκευσης, ενώ για τον Διαχειριστή των ΣΗΕ αποσκοπεί στον προσδιορισμό των επικουρικών υπηρεσιών επόμενης ημέρας, της ένταξης μονάδων παραγωγής, της οικονομικής κατανομής φορτίου, στην διαχείριση συμφόρησης δικτύου και στον προγραμματισμό συντήρησης των γραμμών μεταφοράς.

- 3. Μεσοπρόθεσμη πρόβλεψη:** το εύρος του χρονικού ορίζοντα εδώ είναι μικρότερο από 7 ημέρες. Η χρησιμότητα των προβλέψεων αυτών για τις εταιρίες παραγωγής ΗΕ αποσκοπεί στον προγραμματισμό συντήρησης των μονάδων ΑΠΕ και των συμβατικών μονάδων, ενώ για τον Διαχειριστή των ΣΗΕ αποσκοπεί στον προγραμματισμό συντήρησης των γραμμών μεταφοράς.

### **3.3.1.1 Σημασία Πρόβλεψης Αιολικής Παράγωγης**

Έχοντας ήδη παρουσιάσει μια γενική εικόνα για την αναγκαιότητα και σημασία που έχει η πρόβλεψη της αιολικής παραγωγής, μπορούμε πλέον να εστιάσουμε στον πραγματικό χρόνο. Ο Διαχειριστής των ΣΗΕ, έχει την ευθύνη για την ασφαλή λειτουργία του δικτύου κάτι που σημαίνει ότι η παραγόμενη ηλεκτρική ισχύς θα πρέπει να ισούται με την ενέργεια που καταναλώνεται κάθε χρονική στιγμή. Στην αρμοδιότητα του ανήκει ο τρέχον (online) σχεδιασμός και ρύθμιση του συστήματος. Παρέχει επίσης πρόβλεψη της ζήτησης του φορτίου σε σχέση με το σύνολο της αναμενόμενης παραχθείσας ισχύος σε οποιαδήποτε περιοχή του δικτύου και υπολογίζει παράλληλα τις αναμενόμενες ενεργειακές απώλειες. Η ποσότητα και η σειρά με την οποία θα εισέλθει η αιολική ισχύς στο δίκτυο την επόμενη μέρα εξαρτάται από τις αποφάσεις του Διαχειριστή, οπότε και οι μονάδες παραγωγής ΗΕ ορίζονται εκ των προτέρων, για να ανταποκρίνονται στο προφίλ της προβλεπόμενης καταναλισκόμενης ενέργειας. Οι αποφάσεις αυτές (Hippert, Pedreira, Souza, 2001) στηρίζονται στις προβλέψεις της ζήτησης του φορτίου, που συνήθως είναι αρκετά ακριβείς (σφάλμα 1,5-2% για προβλέψεις που αφορούν την επόμενη μέρα και μικρότερο του 5% για προβλέψεις που αφορούν την επόμενη εβδομάδα). Δίνεται έτσι η δυνατότητα στους χειριστές του συστήματος μεταφοράς να αποφασίζουν πόση ενέργεια απαιτείται κάθε ώρα της επόμενης ημέρας για την κάλυψη των αναγκών των καταναλωτών.

Είναι σημαντικό το γεγονός ότι η έρευνα γύρω από τις μεθόδους πρόβλεψης της ζήτησης συνεχίζεται, εφόσον η περαιτέρω μείωση του σφάλματος οδηγεί σε σημαντική

εξοικονόμηση στις μονάδες των μεγάλων διασυνδεδεμένων συστημάτων ενέργειας. Αυτές οι προβλέψεις επιτρέπουν την έγκαιρη ενεργοποίηση των μονάδων παραγωγής ΗΕ, κάποιες από τα οποίες μπορεί να χρειάζονται αρκετές ώρες για να τεθούν σε λειτουργία. Έτσι ο Διαχειριστής αποφασίζει εκ των προτέρων ποια μέσα παραγωγής ΗΕ θα λάβει υπόψη του, δικά του ή ιδιωτικά. Αν τελικά αγοράσει ενέργεια από ιδιώτες παραγωγούς θα πρέπει να εντοπίσει αυτούς που του παρέχουν την ενέργεια που απαιτεί η ζήτηση και στο μικρότερο κόστος. Από την άλλη πλευρά οι ιδιώτες παραγωγοί, κυρίως αιολικής ενέργειας, για να συμμετέχουν στην αγορά/πώληση ΗΕ θα πρέπει να έχουν ήδη προβλέψει την παραγόμενη αιολική ισχύ των μονάδων τους με τη βοήθεια προηγμένων εργαλείων/μοντέλων πρόβλεψης (Pinson, Chevallier, Kariniotakis, 2007).

Τα Συστήματα Ηλεκτρικής Ενέργειας που παρουσιάζουν υψηλό βαθμό διείσδυσης αιολικών μονάδων, αξιοποιούν τις προβλέψεις σχετικά με την παραγωγή αιολικής ισχύος για κάθε ώρα της επόμενης ημέρας ώστε σε συνδυασμό με την πρόβλεψη για τη ζήτηση φορτίου, οι χειριστές να μπορούν να αποφασίσουν ποιές και σε ποιο βαθμό συμβατικές μονάδες θα χρειαστεί να λειτουργήσουν, ποιες θα είναι σε εφεδρεία και ποιες σε συντήρηση ώστε μαζί με την αιολική παραγωγή να εξυπηρετηθεί το φορτίο της επόμενης ημέρας (Lew, Milligan, Jordan, Piwko, 2011). Αναφορικά με τις προβλέψεις όμως, ενώ το σφάλμα της ημερήσιας πρόβλεψης φορτίου είναι σχετικά μικρό, το σφάλμα της αιολικής παραγωγής είναι μεγάλο (15-20%). Κατά συνέπεια είναι αναγκαία η διαρκής προσπάθεια βελτίωσης της πρόβλεψης της αιολικής παραγωγής εφόσον μπορούν να επιτευχθούν πολύ σημαντικά οφέλη στον περιορισμό του κόστους λειτουργίας των ΣΗΕ καθώς και στην αξιοπιστία του συστήματος συνολικά.

### **3.3.1.2 Εργαλεία Πρόβλεψης Αιολικής Παραγωγής**

Βασικό μέρος της πρόβλεψης αποτελούν τα προϊόντα αριθμητικής πρόγνωσης του καιρού (Numerical Weather Prediction, NWP). Η αριθμητική πρόγνωση του καιρού είναι ο κλάδος της Συνοπτικής Μετεωρολογίας που εστιάζει στην κατά το δυνατόν καλύτερη γνώση του καιρού που αναμένεται να επηρεάσει μια περιοχή για κάποιο χρονικό διάστημα, χρησιμοποιώντας μαθηματικά μοντέλα της ατμόσφαιρας και των ωκεανών βασιζόμενη στις τρέχουσες καιρικές συνθήκες. Ένας αριθμός παγκόσμιων και τοπικών (μικρής και μέσης κλίμακας) μοντέλων πρόβλεψης (Numerical Weather Production models, NWP) λειτουργούν σε όλο τον κόσμο, χρησιμοποιώντας ως εισροές τις



τρέχουσες καιρικές παρατηρήσεις που αναμεταδίδονται από ραδιοβολίδες ή μετεωρολογικούς δορυφόρους. Οι παρατηρήσεις αυτές είναι τα κύρια εισερχόμενα στους διάφορους μετεωρολογικούς σταθμούς, οι οποίοι είτε αναφέρουν ωριαία METAR εκθέσεις, είτε κάθε έξι ώρες SYNOP εκθέσεις υπό την επίβλεψη του Παγκόσμιου Μετεωρολογικού Οργανισμού (World Meteorological Organization, WMO). Έπειτα από κατάλληλη επεξεργασία, οι παρατηρήσεις μπορούν να χρησιμοποιηθούν από μοντέλα αυτά, ως σημείο εκκίνησης για πρόβλεψη (Krishnamurti, 1995), (UCAR, 2007). Τα μοντέλα αυτά διαθέτουν ισχυρότατη υπολογιστική ισχύ (υπερυπολογιστές) ώστε να χειρίζονται ένα τεράστιο αριθμό δεδομένων, εκτελώντας ταυτόχρονα τους απαραίτητους πολύπλοκους υπολογισμούς σχετικά σύντομα. Διαφορετικά μοντέλα χρησιμοποιούν διαφορετικές μεθόδους επίλυσης: μερικά παγκόσμια μοντέλα και σχεδόν όλα τα τοπικά χρησιμοποιούν μεθόδους πεπερασμένων διαφορών (Finite Difference Methods) και για τις τρεις χωρικές διαστάσεις, ενώ άλλα παγκόσμια και μερικά τοπικά μοντέλα χρησιμοποιούν φασματικές μεθόδους (Spectral Methods) για τις οριζόντιες διαστάσεις και πεπερασμένες διαφορές για την κάθετη (Pielke, 2002), (Kwon, 2007). Παράγοντες που επηρεάζουν την ακρίβεια των αριθμητικών προβλέψεων αφορούν την πυκνότητα και την ποιότητα των εισερχόμενων παρατηρήσεων (βάση δεδομένων), σε συνδυασμό με τις αδυναμίες των ίδιων των μοντέλων πρόβλεψης (χαοτική φύση διαφορικών εξισώσεων που χρησιμοποιούνται για την προσομοίωση της ατμόσφαιρας με πλήθος διαφορετικών παραμέτρων), πάρα την χρήση τεχνικών βελτίωσης σφάλματος (στατιστικές εξόδου μοντέλου).

Ιστορικά αξίζει να αναφέρουμε ότι το πρώτο επιτυχημένο κλιματικό μοντέλο αναπτύχθηκε από τον Norman Phillips το 1956 (Norman, 1956), (Cox, 2002) και μπορούσε να απεικονίσει ρεαλιστικά μηνιαίες και εποχικές τάσεις στην τροπόσφαιρα. Το πρώτο κλιματικό μοντέλο γενικής κυκλοφορίας που συνδύαζε τις ωκεάνιες και ατμοσφαιρικές αλλαγές αναπτύχθηκε στα τέλη της δεκαετίας του 1960 στο NOAA Εργαστήριο Γεωφυσικής Fluid Dynamics (National Oceanic and Atmospheric Administration, 2008). Από τη δεκαετία του 1980 τα μοντέλα έγιναν πιο ρεαλιστικά (Yongkang, Fennessey, 1996), περιλαμβάνοντας πλέον τις αλληλεπιδράσεις του εδάφους και της βλάστησης με την ατμόσφαιρα, το θαλάσσιο πάγο (Stensrud, 2007) και την επιφανειακή θερμοκρασία της θάλασσας (Houghton, 1985). Τη δεκαετία του 1970 και 1980 αναπτύχθηκε επίσης μια στατιστική σχέση μεταξύ των συμπερασμάτων ενός αριθμητικού μοντέλου και των επακόλουθων συνθηκών στο έδαφος, που είναι

γνωστή ως στατιστικά αποτελέσματα του μοντέλου παραγωγής (Model Output Statistics, MOS). Με το MOS μπορεί να βελτιωθεί ο χειρισμός σφαλμάτων στις αριθμητικές προβλέψεις κοντά στην επιφάνεια της γης που δεν μπορούν να επιλυθούν, λόγω ανεπαρκούς ανάλυσης του δικτύου με βάση την δυναμική της ατμόσφαιρας και προκαταλήψεων του ίδιου του μοντέλου (Hughes, 1976), (Best, Pryor, 1983). Η παραγωγή του MOS αναφέρεται και ως μεταδιαδικασία αφού λειτουργεί από το αντίστοιχο παγκόσμιο ή τοπικό μοντέλο. Από τη δεκαετία του 1990, προβλέψεις συνόλων χρησιμοποιούνται λειτουργικά για να εξηγήσουν την στοχαστική φύση της διαδικασίας του καιρού, δηλαδή την επίλυση αβεβαιοτήτων. Η μέθοδος αυτή περιλαμβάνει ανάλυση πολλαπλών προβλέψεων μοντέλου με τη χρήση διαφορετικών παραμετροποιήσεων ή διαφορετικών αρχικών συνθηκών (Manousos, 2006).

Ένα μοντέλο πρόγνωσης ουσιαστικά είναι ένα πρόγραμμα υπολογιστή, που παράγει μετεωρολογικές πληροφορίες (πυκνότητα, πίεση, θερμοκρασία, ταχύτητα ανέμου, μεταφορά ρύπων και αερολυμάτων) για μελλοντικές εποχές σε δεδομένες τοποθεσίες και γεωγραφικά πλάτη, χρησιμοποιώντας μη γραμμικές διαφορικές εξισώσεις και τον ιδανικό νόμο αερίων πάνω σε ένα τρισδιάστατο πλέγμα σημείων που προσομοιώνει την ατμόσφαιρα (διακριτά σημεία και επίπεδα). Οι εξισώσεις αυτές είναι αδύνατο να λυθούν ακριβώς με αναλυτικές μεθόδους (Strikwerda, 2004) και επιδέχονται κατά προσέγγιση λύσεις (Pielke, 2002) οπότε και προσδιορίζονται οι ρυθμοί μεταβολής που προβλέπουν την κατάσταση της ατμόσφαιράς σε σύντομο χρονικό διάστημα στο μέλλον. Η αύξηση του χρόνου πρόβλεψης ονομάζεται χρονικό βήμα και εντός μοντέλου σχετίζεται με την απόσταση των σημείων στο υπολογιστικό πλέγμα και την αριθμητική σταθερότητα. Για τα παγκόσμια μοντέλα τα χρονικά διαστήματα είναι της τάξης των δεκάδων λεπτών (Sunderam, Dick, Peter, Dongarra, 2005), ενώ για τα τοπικά μοντέλα είναι μεταξύ ενός και τεσσάρων λεπτών (Walter, Norbert, ECMWF, 2001). Τα τοπικά μοντέλα (Limited Area Models, LAMs) χρησιμοποιούνται για την πρόγνωση διαταραχών μικρής κλίμακας χώρου και χρόνου, δηλαδή οι εξισώσεις τους εκτελούνται σε περιορισμένη περιοχή, χρησιμοποιώντας όμως ένα πυκνότερο πλέγμα σημείων με αποτέλεσμα αναλυτικότερα και ποιοτικότερα αποτελέσματα. Για να λειτουργήσει όμως ένα τοπικό μοντέλο χρειάζεται να είναι γνωστή η ροή δεδομένων στα όρια μιας περιοχής από ένα παγκόσμιο μοντέλο. Τα πιο αξιόπιστα παγκόσμια μοντέλα πρόγνωσης είναι: το Ευρωπαϊκό Κέντρο Μεσοπρόθεσμων Μετεωρολογικών Προγνώσεων (European Center for Medium range Weather Forecasting, ECMWF), το Παγκόσμιο

Σύστημα Πρόγνωσης (Global Forecast System, GFS), το Ολοκληρωμένο Σύστημα Πρόγνωσης και Περιβάλλοντος (Global Environment Multiscale Model, GEM), η Εθνική Μετεωρολογική Υπηρεσία του Ηνωμένου Βασιλείου (United Kingdom Meteorology, UKMET) και το Ναυτικό Παγκόσμιο Περιβαλλοντικό Μοντέλο (Navy Global Environmental Model, NAVGEM). Τα κυριότερα LAMs είναι: το MM5 (Fifth Generation Penn State/NCAR Mesoscale Model), το WRF (Weather Research and Forecasting Model), το RAMS (Regional Atmospheric Modeling System), το WASP (Wind Atlas Analysis and Application Program), το HIRLAM (High Resolution Limited Area Model), το SKIRON, το ALADIN (Limited Area, dynamical Adaption, International Development) και το ARPS (Advanced Region Prediction System), (Lynch, 2008).

Τα μοντέλα πρόβλεψης παραγωγής από ΑΠΕ χωρίζονται σε δύο βασικές κατηγορίες: τα φυσικά μοντέλα και τα στατιστικά μοντέλα (Giebel, Kariniotakis, Brownsword, 2003), (Zhao, Zhao, Liu, Su, An, 2016). Συνδυασμός αυτών είναι τα υβριδικά μοντέλα που χρησιμοποιούνται σε ορισμένες περιπτώσεις (Catalao, Pousinho, Mendes, 2011). Τα φυσικά μοντέλα (Lange, Focken, 2008) κατά κύριο λόγο βασίζονται στη χρήση αριθμητικών μοντέλων μετεωρολογικών προβλέψεων (NWP models, NWPs). Τα φυσικά μοντέλα προσπαθούν να συνδυάσουν τα αποτελέσματα των NWPs (τιμές πίεσης, θερμοκρασίας, ηλιακής ακτινοβολίας, ταχύτητας και κατεύθυνσης ανέμου, κ.α.) με κάποια φυσικά χαρακτηριστικά του περιβάλλοντος (μορφολογία εδάφους, φυσικά εμπόδια, διαύγεια ατμόσφαιρας, σχετική νέφωση, κ.α.) στην περιοχή πρόβλεψης, προκειμένου να επιτύχουν μια αρχική εκτίμηση της ταχύτητας του ανέμου ή της ηλιακής ακτινοβολίας. Εν συνεχεία, η ταχύτητα του ανέμου ή η ηλιακή ακτινοβολία μετατρέπονται σε ηλεκτρική ισχύ μέσω τυπικών χαρακτηριστικών καμπυλών και με την εφαρμογή στατιστικών μοντέλων εξόδου (Model Output Statistics, MOS) το προκύπτον σφάλμα μειώνεται (Landberg, 2001). Δηλαδή περιλαμβάνουν τα στάδια της βαθμονόμησης προς τα κάτω (downscaling), της μετατροπής της ταχύτητας του ανέμου σε ισχύ (conversion to power) και τη βαθμονόμηση προ τα πάνω (upscaling). Τα κυριότερα φυσικά μοντέλα είναι: το Previento (Focken, Lange, Waldl, 2001), το Prediktor (Landberg, Watson, 1994), τα LocalPred και RegionPred (Martí Perez, 2002), το HIRPOM (Jørgensen, Moehrlen, Gallagher, Sattler, McKeogh, 2002) και το Ewind (Bailey, Brower, Zack, 1999), (Wang, Guo, Huang, 2011).

Τα στατιστικά μοντέλα από την άλλη πλευρά χρησιμοποιούνται για την άμεση μετατροπή μεταβλητών εισόδου σε ηλεκτρική ισχύ, δηλαδή επιτελούν μόνο στατιστική επεξεργασία (Garcia, De-La-Torre-Vega, 2009). Συσχετίζουν αφού εκπαιδευτούν, τις παλαιότερες τιμές ισχύος καθώς επίσης και τις παλαιότερες τιμές και προβλέψεις των διάφορων μεταβλητών (explanatory variables), με τις μετρήσεις της αιολικής ισχύος, αγνοώντας τα φυσικά φαινόμενα (Pinson, 2006). Όλες οι στατιστικές μέθοδοι βασίζονται στην προσαρμογή ενός συγκεκριμένου μοντέλου στα δεδομένα που χρησιμοποιούνται για την εκπαίδευση του, ώστε να καθοριστεί η κατάλληλη συνάρτηση μεταφοράς  $f$  που δέχεται ως είσοδο την περιγραφή τη προβλεπόμενης ατμοσφαιρικής κατάστασης και την ανάγει σε αιολική ισχύ και είναι της μορφής:

$$\hat{p}_{t+k/t} = f(p_t, p_{t-1}, \dots, p_{t-l}, x_t, x_{t-1}, \dots, x_{t-m}, \hat{x}_{t+k/t}) = f(\Phi_t). \quad (3.23)$$

Η προσαρμογή αυτή βασίζεται στην ελαχιστοποίηση της συνάρτησης κόστους (Cost Function) που σχετίζεται με την απόδοση του στατιστικού μοντέλου και που είναι άμεση συνάρτηση του σφάλματος πρόβλεψης  $e_t$ , με σκοπό τη βέλτιστη επίτευξη σύνδεσης των μεταβλητών εισόδου με την προβλεπόμενη χρονοσειρά της αιολικής ισχύος (έξοδος).

Τα στατιστικά μοντέλα διαχωρίζονται σε δύο κατηγορίες ανάλογα με το εάν λαμβάνουν υπόψη τους τα δεδομένα των NWP's ή όχι (Giebel, Landberg, Kariniotakis, Brownsword, 2003). Στα στατιστικά μοντέλα που δεν λαμβάνουν υπόψη τις εξόδους των NWP's (αποτελούνται μόνο από αυτοπαλινδρομικό μέρος) η πρόβλεψη της αιολικής ισχύος γίνεται είτε απευθείας είτε προβλέπεται αρχικά η ταχύτητα του ανέμου και έπειτα υπολογίζεται η παραγόμενη ισχύς μέσω της τυπικής χαρακτηριστικής καμπύλης της ανεμογεννήτριας. Τα μοντέλα αυτά χρησιμοποιούνται για πολύ βραχυπρόθεσμη ή βραχυπρόθεσμη πρόβλεψη επιτυγχάνοντας ικανοποιητικά αποτελέσματα σε σχέση του μοντέλου παραμένουσας τιμής (μοντέλο αναφοράς). Η ικανότητα τους όμως για παραγωγή αξιόπιστων προβλέψεων σε εκτενέστερους χρονικούς ορίζοντες μειώνεται σημαντικά, ενώ διαφοροποιείται και η ακρίβεια μεταξύ τους σε διαφορετικούς χρονικούς ορίζοντες πρόβλεψης. Στα στατιστικά μοντέλα που λαμβάνουν υπόψη τις εξόδους των NWP's (αποτελούνται από αυτοπαλινδρομικό και μετεωρολογικό μέρος), τα δεδομένα που απαιτούνται για επεξεργασία είναι NWP δεδομένα και online μετρήσεις που δίνονται από ένα σύστημα SCADA (Supervisory Control And Data Acquisition). Έχοντας αυτά δεδομένα, τα στατιστικά μοντέλα μπορούν να δώσουν

εκτίμηση της εξόδου (ισχύος) χωρίς περαιτέρω φυσικές θεωρήσεις και παραμετροποιήσεις της ταχύτητας του ανέμου ή της ηλιακής ακτινοβολίας στην επιλεγμένη περιοχή. Συνδυάζουν όμως, στατιστικές συσχετίσεις παλαιότερων τιμών ισχύος και τιμών και προβλέψεων διαφόρων μεταβλητών, με τις μετρήσεις της ισχύος. Τα μοντέλα αυτά χρησιμοποιούνται για ευρύτερες προβλέψεις (μεγαλύτερες από 12 ώρες) και απαιτούν μεγάλο υπολογιστικό χρόνο (Chen, Qian, Meng, 2013).

Το στατιστικό μπλοκ μπορεί να περιλαμβάνει γραμμικά ή μη γραμμικά μοντέλα τα οποία διακρίνονται σε δομήσιμα (structural models), σε μοντέλα μαύρου κουτιού (black box models) και σε μοντέλα γκρι κουτιού (grey box models). Στα μοντέλα black box ανήκουν τα μοντέλα χρονοσειρών όπως τα μοντέλα αυτοπαλινδρόμησης (AR), μοντέλα κινητού μέσου όρου (MA), μεικτά μοντέλα (ARMA, ARIMA), τα μοντέλα τεχνητής νοημοσύνης (νευρωνικά δίκτυα, NNs), τα υβριδικά μοντέλα, οι αλγόριθμοι εξόρυξης δεδομένων κ.α., (Kariniotakis, Stavrakakis, Nogaret, 1996), (Box, Jenkins, 1976), (Chen, Qian, Meng, 2013).

Τα κυριότερα στατιστικά μοντέλα είναι: το WPPT (Nielsen, Madsen, Tøfting, 1999), το SIPREOLICO (Sánchez, Usaola, Ravelo, Velasco, Domínguez, Lobo, González, Soto, 2002), το AWPT (Durstewitz, Ensslin, Hahn, Hoppe-Kilpper, 2001), τα AWPPS και RAL (Costello, McCoy, O'Donnell, Dutton, Kariniotakis, 2002), (Wang, Guo, Huang, 2011).

Το τελευταίο χρονικό διάστημα έχουν αναπτυχθεί μοντέλα, τα οποία στηρίζονται σε συνδυασμούς διαφόρων μοντέλων και καλούνται υβριδικά (Catalao, Pousinho, Mendes, 2011). Κριτήριο για το συνδυασμό μπορεί να αποτελεί ο ορίζοντας πρόβλεψης ή η ποιότητα λειτουργίας του μοντέλου ή η αύξηση της χωρικής ανάλυσης των NWP ή η καλύτερη πρόβλεψη. Επομένως έχουν προκύψει:

- Συνδυασμός φυσικής και στατιστικής προσέγγισης (μοντέλο ZEPHYR)
- Συνδυασμός μοντέλων μικρού (0-6 ώρες) και μεσαίου (0-48 ώρες) ορίζοντα πρόβλεψης (μοντέλο ARMINES)
- Συνδυασμός εναλλακτικών στατιστικών μοντέλων (μοντέλο SIPREOLICO)

**Πίνακας 3.2:** Μια επισκόπηση των υφιστάμενων βραχυπρόθεσμων μοντέλων πρόβλεψης, (Giebel et al, 2003),

<b>PREDICTION MODEL</b>	<b>DEVELOPER</b>	<b>METHOD</b>	<b>OPERATIONAL STATUS</b>	<b>OPERATIONAL SINCE</b>
Predictor	Risø	Physical	Spain, Denmark, Ireland, Germany, (US)	1993
WPPT	IMM; University of Copenhagen	Statistical	1 GW, Denmark (E&W)	1994
Zephyr, Combination of WPPT and Predictor	Risø and IMM	Physical, Statistical	Denmark	2003
Previento	University of Oldenburg, Germany	Physical	-	-
AWPPS (More-Care)	Armines/Ecole des Mines de Paris	Statistical, Fuzzy-ANN	Ireland, Crete, Madeira	1998, 2002
RAL (More-Care)	RAL	Statistical	Ireland	-
SIPREOLICO	University Carlos III, Madrid Red Electrica de Espana	Statistical	4GW, Spain	2002
LocalPred-RegioPred	CENER	Physical	La Muela, Soria, Alaiz	2001
HIPROM	University College Cork, IDMI	Physical	Under development	
AWPT	ISSET	Statistical, ANN	10GW, Germany	-

	NWP	MOS	MOS+	Micro	Meso	Obs	Time (h)	Ref.
Persistence		○				●	48	
Prediktor	●	●		●		○	48	2
WPPT	●		●			●	48	3
Zephyr	●		●	○		●	48	4
E Wind	●	●			●	○	48	5
Previento	●	●		●		○	48	6
HIRPOM	●	●				○	48	7
MORE-CARE	●		●			●	36	8
LocalPred/RegioPred	●	●			○		48	9
WPMS	●		●			●	48	10

**Εικόνα 20:** Επισκόπηση διαφόρων τύπων συστημάτων πρόβλεψης. Ένας πλήρης κύκλος υποδηλώνει ότι η λειτουργία χρησιμοποιείται πλήρως και ένας ανοικτός ότι χρησιμοποιείται εν μέρει. Σειρά στηλών: όνομα, εισροή NWP, χρήση απλού MOS, χρήση προηγμένου MOS, εισροή από μικρής κλίμακας NWP, εισροή από μέσης κλίμακας NWP, χρήση παρατηρήσεων και χρονικός ορίζοντας πρόβλεψης, (Landberg, Giebel, Nielsen, Nielsen, Madsen, 2003).

### 3.3.1.3 Μοντέλα αναφοράς

Το μεγάλο πλήθος των μοντέλων πρόβλεψης κυρίως της αιολικής παραγωγής από ΑΠΕ και οι διαφορετικές μέθοδοι που χρησιμοποιούν, έκανε επιτακτική την ανάγκη θεώρησης κάποιου μοντέλου αναφοράς, το οποίο να μπορεί να χρησιμοποιηθεί ως βάση σύγκρισης των διαφόρων μοντέλων πρόβλεψης, από το σύνολο της επιστημονικής κοινότητας. Διεθνώς έχουν διαμορφωθεί δύο μοντέλα αναφοράς: το μοντέλο της παραμένουσας τιμής (persistence model) και το νέο μοντέλο αναφοράς (new reference model).

Σύμφωνα με το μοντέλο παραμένουσας τιμής (που είναι και ο πιο απλός τρόπος πρόβλεψης παραγωγής μιας μονάδας ΑΠΕ), η παραγόμενη ισχύς (ταχύτητα ανέμου) που προβλέπεται μια χρονική στιγμή  $t$  για μια χρονική στιγμή  $t + k$ , ισούται με την πραγματική τιμή που έχει μετρηθεί τη χρονική στιγμή  $t$ , ή ελλείψει αυτής, με την πλέον διαθέσιμη τιμή (Giebel, Kariniotakis, Brownsword, 2003). Το μοντέλο βασίζεται δηλαδή στην παραδοχή μιας υψηλής συσχέτισης μεταξύ σημερινών και μελλοντικών τιμών και για την σωστή εφαρμογή της θα πρέπει να χρησιμοποιούνται οι πιο πρόσφατες διαθέσιμες μετρήσεις ταχύτητας ανέμου και δεδομένων SCADA. Η μέθοδος έχει αποδειχθεί αποτελεσματική για τον πολύ βραχυπρόθεσμο ορίζοντα και η ακρίβεια της φθίνει ταχύτατα με την αύξηση του χρόνου πρόβλεψης. Περιγράφεται από την εξίσωση:  $\hat{p}_{t+k|t}^{per} = p_t$ , (3.24)

όπου  $p_t$  είναι η παραγωγή ισχύος σε χρόνο  $t$  και  $\hat{p}_{t+k|t}^{per}$ , είναι η μέση ισχύς που αναμένεται να παραχθεί σε χρόνο  $t + k$ , υπό συνεχή και σταθερό άνεμο.

Βελτίωση του σημείου αναφοράς του μοντέλου persistence, επιτυγχάνεται με τη χρήση του μέσου όρου των  $n$  τελευταίων μετρούμενων τιμών, οπότε και προκύπτει η εξίσωση:

$$\hat{p}_{t+k|t}^{sma} = \frac{1}{n} \sum_{i=1}^n p_{t-i+1}. \quad (3.25)$$

Τέτοια μοντέλα αναφέρονται και ως μοντέλα κινητού μέσου όρου (simple moving average) και χρησιμοποιούνται σε περίπτωση έντονης μεταβλητότητας. Όταν όμως το  $n$  ισούται με το σύνολο των διαθέσιμων παρατηρήσεων για τη χρονική στιγμή  $t$ , τότε προκύπτει η εξίσωση:  $\hat{p}_{t+k|t} = \bar{p}_t$ , (3.26)

όπου  $\bar{p}_t$  είναι ο μέσος όρος όλων των διαθέσιμων παρατηρήσεων για τη χρονική στιγμή  $t$  και αναφέρεται ως κλιματολογικός μέσος. Μπορεί να θεωρηθεί ως μοντέλο αναφοράς με καλύτερες προβλέψεις από αυτές του persistence, για μεγάλο όμως ορίζοντα πρόβλεψης.

Σύμφωνα με Nielsen και την ομάδα του (Nielsen, Joensen, Madsen, Landberg, Giebel, 1998), η χρήση του μοντέλου της παραμένουσας τιμής δεν είναι λογική όταν ο χρονικός ορίζοντας της πρόβλεψης είναι μεγαλύτερος από μερικές ώρες. Όταν αξιολογούνται βραχυπρόθεσμα μοντέλα πρόβλεψης θα πρέπει να χρησιμοποιείται το νέο μοντέλο αναφοράς που αποτελεί ένα συμβιβασμό μεταξύ του μοντέλου της παραμένουσας τιμής και του μέσου όρου των παρατηρήσεων και περιγράφεται από την εξίσωση:  $\hat{p}_{t+k|t} = a_k p_t + (1 - a_k) \bar{p}$ , (3.27)

όπου  $p_t$  είναι η πιο πρόσφατη διαθέσιμη μέτρηση,  $\bar{p} = \frac{1}{n} \sum_{t=1}^n p_t$  ο μέσος όρος των διαθέσιμων μετρήσεων και  $a_k$  είναι ο συντελεστής συσχέτισης μεταξύ  $p_t$  και  $p_{t+k}$ . Το μειονέκτημα του μοντέλου είναι η εξάρτηση της συσχέτισης από τη θέση του σταθμού ΑΠΕ ή την εποχή του χρόνου.

### 3.3.1.4 Αξιολόγηση Μοντέλων Πρόβλεψης ΑΠΕ και Σφάλματα Μέτρησης

Επειδή οι προβλέψεις παραγωγής των μονάδων ΑΠΕ χαρακτηρίζονται από εγγενή αβεβαιότητα, κανένα μοντέλο δεν είναι σε θέση να αποδώσει την ακριβή τιμή παραγόμενης αιολικής ισχύος, εφόσον για τη διαμόρφωση της τιμής αυτής υπεισέρχονται πολλές παράμετροι που δεν μπορούν να εκτιμηθούν επακριβώς. Είναι λοιπόν απαραίτητο για την επιλογή του καλύτερου μοντέλου πρόβλεψης να γίνεται αξιολόγηση των σφαλμάτων πρόβλεψης που αυτά παρουσιάσουν. Αυτό γίνεται



συγκρίνοντας τις προβλέψεις ισχύος (χρονοσειρές) που γίνονται σε μια συγκεκριμένη χρονική στιγμή απευθείας με τις αντίστοιχες πραγματικές μετρήσεις. Η απόκλιση που προκύπτει χαρακτηρίζει την ποιότητα του συγκεκριμένου μοντέλου και υποδηλώνει για τη σωστή ανάλυση της, την ύπαρξη εκτιμήσεων μιας μεγάλης σειράς προβλέψεων.

Το απλό σφάλμα πρόβλεψης ενός μεγέθους ορίζεται ως η διαφορά της προβλεπόμενης από το μοντέλο τιμής από την παρατηρούμενη τιμή των οργάνων μέτρησης και δίνεται από τη σχέση:  $e_{t+k|t} = \hat{y}_{t+k|t} - y_{t+k|t}$ , (3.28)

όπου  $\hat{y}_{t+k|t}$  είναι η πρόβλεψη της αιολικής παραγωγής μετά από  $k$  ώρες και  $y_{t+k|t}$  είναι η πραγματική τιμή της ισχύος  $k$  ώρες μετά. Η πρόβλεψη  $\hat{y}_{t+k|t}$  προκύπτει από τις διαθέσιμες παρατηρήσεις μέχρι τη χρονική στιγμή  $t$ .

Το ανηγμένο σφάλμα πρόβλεψης προκύπτει από τη σχέση:

$$e_{t+k|t} = \frac{1}{P_{inst}} (\hat{y}_{t+k|t} - y_{t+k|t}), \quad (3.29)$$

όπου  $P_{inst}$  είναι η εγκατεστημένη ισχύς.

Με το ανηγμένο σφάλμα καθίσταται δυνατή η σύγκριση της απόδοσης ενός μοντέλου σε διαφορετικές μονάδες παραγωγής ανεξαρτήτως ονομαστικής ισχύος και από πλευράς αγοράς ενέργειας θεωρείται η πιο αντιπροσωπευτική παρουσίαση του σφάλματος.

Τα συνηθέστερα κριτήρια υπολογισμού σφάλματος που χρησιμοποιούνται για την αξιολόγηση της ακρίβειας των μοντέλων πρόβλεψης και υπολογίζονται πάνω στη χρονοσειρά του σφάλματος είναι τα παρακάτω:

- Κλίση πρόβλεψης (forecast bias), που αναφέρεται στο συστηματικό λάθος που παρατηρείται κατά την πρόβλεψη. Ορίζεται ως το μέσο λάθος κατά την περίοδο αποτίμησης και υπολογίζεται ξεχωριστά για κάθε ορίζοντα πρόβλεψης. Δίνεται από τη σχέση:  $Bias(k) = \bar{e}_k = \frac{1}{N} \sum_{t=1}^N e_{t+k|t}$ , (3.30)  
όπου  $N$ , ο αριθμός των προβλέψεων που χρησιμοποιούνται. Το κριτήριο αυτό παρέχει πληροφορίες για την τάση του μοντέλου να υπερεκτιμάει ή υποεκτιμάει την αιολική παραγωγή ισχύος.
- Το Μέσο Τετραγωνικό Σφάλμα (Mean Square Error, MSE), το οποίο αποτελείται από το μέσο όρο όλων των τετραγωνικών σφαλμάτων των δεδομένων ελέγχου.

Το κριτήριο αυτό φανερώνει τη συνεισφορά θετικών και αρνητικών σφαλμάτων στην έλλειψη ακρίβειας. Δίνεται από τη σχέση:

$$MSE_k = \frac{1}{N} \sum_{t=1}^N e_{t+k|t}^2. \quad (3.31)$$

- Η τετραγωνική ρίζα του Μέσου Τετραγωνικού Σφάλματος (Root Mean Square Error, RMSE), που δίνεται από τη σχέση:  $RMSE_k = \sqrt{\frac{1}{N} \sum_{t=1}^N e_{t+k|t}^2}$ . (3.32)

Το κριτήριο αυτό δίνει πολύ μεγάλο βάρος στα μεγάλα σφάλματα και μικρότερο βάρος στα μικρά ενώ σχετίζεται με την υπόθεση των ανεξάρτητων και κατανομημένων λαθών πρόβλεψης.

- Το μέσο απόλυτο σφάλμα (Mean Absolute Error, MAE), που εκφράζει ένα μέτρο αστοχίας της πρόβλεψης χωρίς να δίνει έμφαση στην κατεύθυνση της πρόβλεψης. Μεγαλύτερες τιμές αντιστοιχούν σε μικρότερες ακρίβειες. Δίνεται από τη σχέση:  $MAE = \frac{1}{N} \sum_{t=1}^N |e_{t+k|t}|$ . (3.33)

Τα κριτήρια RMSE και MAE διαιρεμένα με την εγκατεστημένη ισχύ ή μέση παραγωγή ενός σταθμού ΑΠΕ μας δίνουν τα ανηγμένα μεγέθη NRMSE και NMAE (normalized scores), τα οποία αποτελούν ένα ασφαλέστερο κριτήριο εκτίμησης του σφάλματος πρόβλεψης.

### 3.3.1.5 Σύγκριση Ακρίβειας διαφόρων Μεθόδων Πρόβλεψης

Επειδή κατά την εκτίμηση των διάφορων μεθόδων πρόβλεψης υπάρχει η περίπτωση να μην είναι σαφές ποια επικρατεί, καθώς η επίδοση τους μπορεί να μεταβάλλεται με τα κριτήρια αλλά και με τον ορίζοντα πρόβλεψης, είναι η απαραίτητο η εκτίμηση αυτή να βασίζεται σε διεξοδική ανάλυση αποτελούμενη από ένα σύνολο κριτηρίων σφάλματος. Σε αρκετές περιπτώσεις είναι αναγκαία η ποσοτικοποίηση του κέρδους κάποιων μοντέλων πρόβλεψης σε σχέση με ένα επιλεγμένο μοντέλο αναφοράς. Αυτό επιτυγχάνεται με τα παρακάτω κριτήρια (Pinson, 2006):

- Βελτίωση με σεβασμό (improvement with respect) που ορίζεται από τη σχέση:

$$Imp^{ref}(k) = \frac{Y^{ref}(k) - Y(k)}{Y^{ref}(k)}, \quad (3.34)$$

όπου  $Y$  το θεωρούμενο κριτήριο σφάλματος,  $Y^{ref}(k)$  υποδηλώνει την αξία για το μοντέλο αναφοράς και  $Y(k)$  για το μοντέλο πρόβλεψης, για το χρονικό ορίζοντα  $k$ . Το κριτήριο μπορεί να πάρει θετικές είτε αρνητικές τιμές ανάλογα με το αν


έχουμε βελτίωση ή χειροτέρευση της επίδοσης, σε σύγκριση με το μοντέλο αναφοράς.

- Σταθερά αποφασιστικότητας (coefficient of determination) που ορίζεται από τη σχέση:  $R^2(k) = \frac{MSE^0(k) - MSE(k)}{MSE^0(k)}$ , (3.35)

όπου  $MSE^0(k)$  το θεωρούμενο Μέσο Τετραγωνικό Σφάλμα του γενικού μοντέλου. Η σταθερά  $R^2(k)$  για κάθε ορίζοντα πρόβλεψης, αντιπροσωπεύει την ικανότητα του μοντέλου να εξηγεί τη μεταβλητότητα των δεδομένων. Κυμαίνεται από 0 (κακές προβλέψεις) έως 1 (τέλειες προβλέψεις).

### 3.4 Ερευνητική Διαδικασία

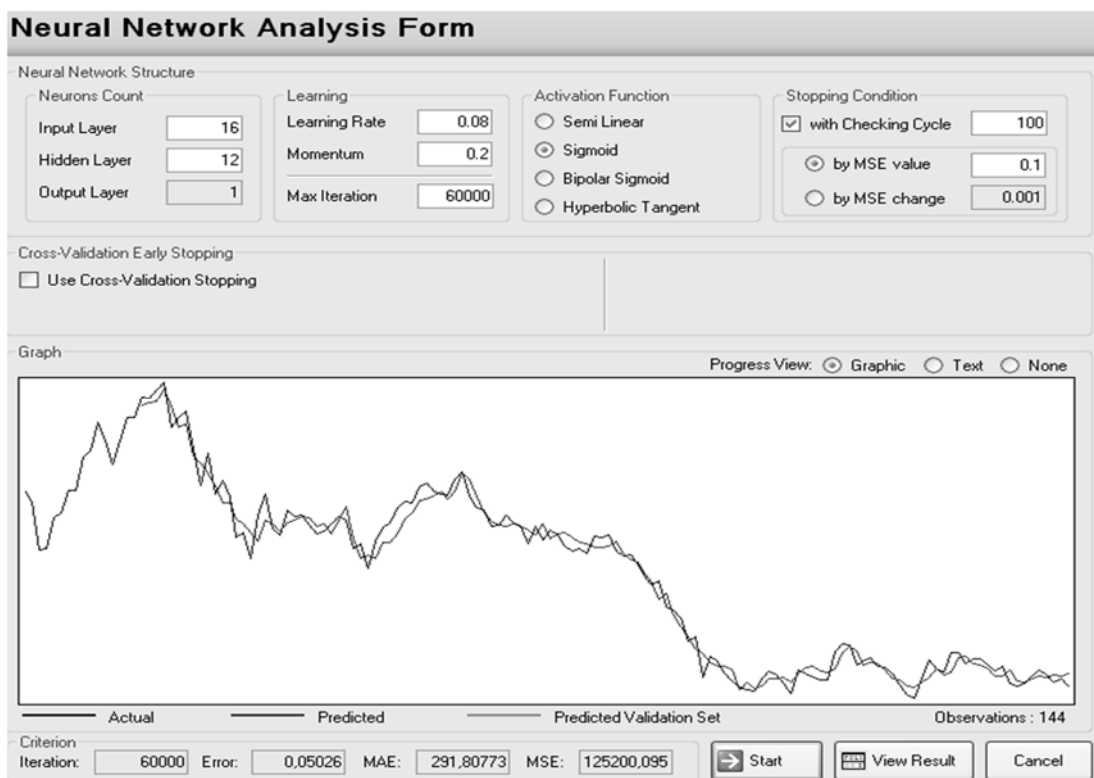
Στο πλαίσιο αυτό θα εξεταστούν οι λειτουργίες πρόγνωσης συγκεκριμένων λογισμικών εργαλείων. Τα λογισμικά εργαλεία αυτά είναι το Zaitun Time Series και NeuroXL Predictor. Το Zaitun Time Series είναι λογισμικό σχεδιασμένο για στατιστική ανάλυση δεδομένων χρονοσειρών παρέχοντας ένα εύκολο τρόπο για μοντελοποίηση και πρόβλεψη χρονοσειρών. Στα στατιστικά δεδομένα περιλαμβάνονται: η ανάλυση τάσεων, η ανάλυση αποσύνθεσης, η κινούμενη μέση ανάλυση, η εκθετική εξομάλυνση, η εμφάνιση της τιμής της συνάρτησης αυτοσυσχέτισης και μοντελοποίηση νευρωνικών δικτύων σε δεδομένα χρονοσειρών. Το NeuroXL Predictor είναι ένα εργαλείο πρόβλεψης νευρωνικών δικτύων που επιλύει γρήγορα και με ακρίβεια προβλήματα πρόβλεψης, ταξινόμησης και εκτίμησης στο Microsoft Excel. Σχεδιάστηκε από την αρχή για να βοηθήσει τους ειδικούς στην επίλυση πραγματικών προβλημάτων πρόβλεψης. Ως είσοδος θα χρησιμοποιηθούν δεδομένα προβλέψεων καιρού. Τα δεδομένα αυτά είναι 10-λεπτες μετρήσεις ταχύτητας ανέμου, διεύθυνσης ανέμου, τυπικής απόκλιση και θερμοκρασίας και οι χρονοσειρές αυτές προέρχονται από μετεωρολογικό ιστό. Αφορούν την χρονική περίοδο από 06/11/2007 έως 3/1/2008 και είναι συνολικά 8.233 μετρήσεις.




Εικόνα 91: Το ΤΝΔ για πρόβλεψη Αιολικής Ενεργείας, (Kurt, Lange, 2014).

**Πρόγνωση με το λογισμικό εργαλείο Zaitun Time Series:** Στο περιβάλλον εργασίας του Zaitun Time Series χρησιμοποιήσαμε μέρος από τα διαθέσιμα ανεμολογικά δεδομένα για να εξετάσουμε αποτελεσματικότητα πρόγνωσης που μπορεί να επιτύχει. Αρχικά προσπαθήσαμε να εκπαιδεύσουμε το νευρωνικό δίκτυο που παρέχει το πρόγραμμα αυτό, ώστε οι επιθυμητές τιμές εξόδου να προσεγγίζουν τις πραγματικές, για τις επόμενες 36 μετρήσεις, δηλαδή για τις επόμενες 6 ώρες. Με την εισαγωγή 10-λεπτων ανεμολογικών στοιχείων μιας ημέρας, το ΤΝΔ έδειξε καλύτερη πρόγνωση με την αύξηση του μέγιστου αριθμού επαναλήψεων (max iteration, MI). Η μείωση του παράγοντα της ορμής (momentum) έδειξε ότι βελτιώνει τις αναμενόμενες εξόδους, ενώ αντίθετα η παράμετρος εκπαίδευσης (learning rate) ανταποκρίθηκε καλύτερα σε μικρή αύξηση. Για τους νευρώνες του δικτύου η επιλογή 16-12-1 έδειξε πιο ικανή. Η συνάρτηση ενεργοποίησης που χρησιμοποιήθηκε και με βάση τα δεδομένα είναι η σιγμοειδής (sigmoid).

- Πρόγνωση του ΤΝΔ για χρονικό ορίζοντα 6 ωρών με βάση τα ανεμολογικά δεδομένα της προηγούμενης ημέρας (144 τιμές)

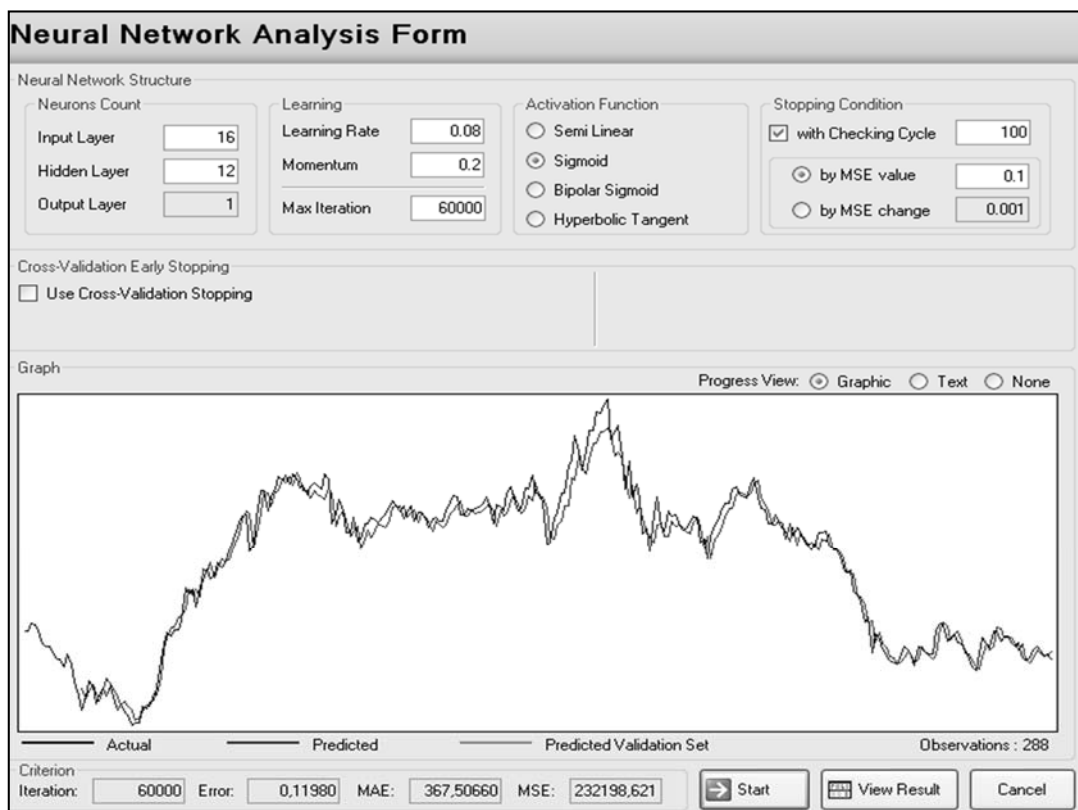


**Εικόνα 22:** Πρόγνωση του ΤΝΔ με την χρήση 144 ανεμολογικών δεδομένων και κριτήρια σφάλματος.




**Εικόνα 103:** Πρόγνωση του ΤΝΔ με την χρήση 144 ανεμολογικών δεδομένων για τις επόμενες 6 ώρες.

- Πρόγνωση του ΤΝΔ για χρονικό ορίζοντα 6 ωρών με βάση τα ανεμολογικά δεδομένα των δύο προηγούμενων ημερών (288 τιμές)

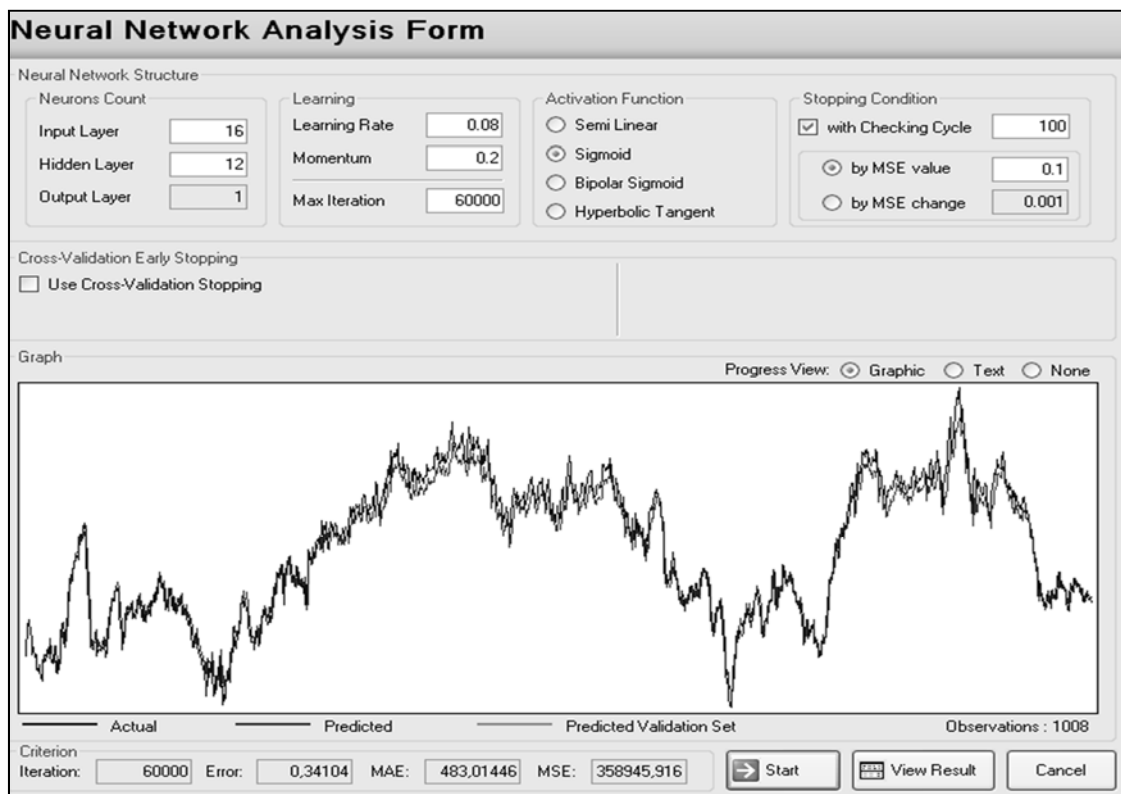


**Εικόνα 11:** Πρόγνωση του ΤΝΔ με την χρήση 288 ανεμολογικών δεδομένων και κριτήρια σφάλματος.

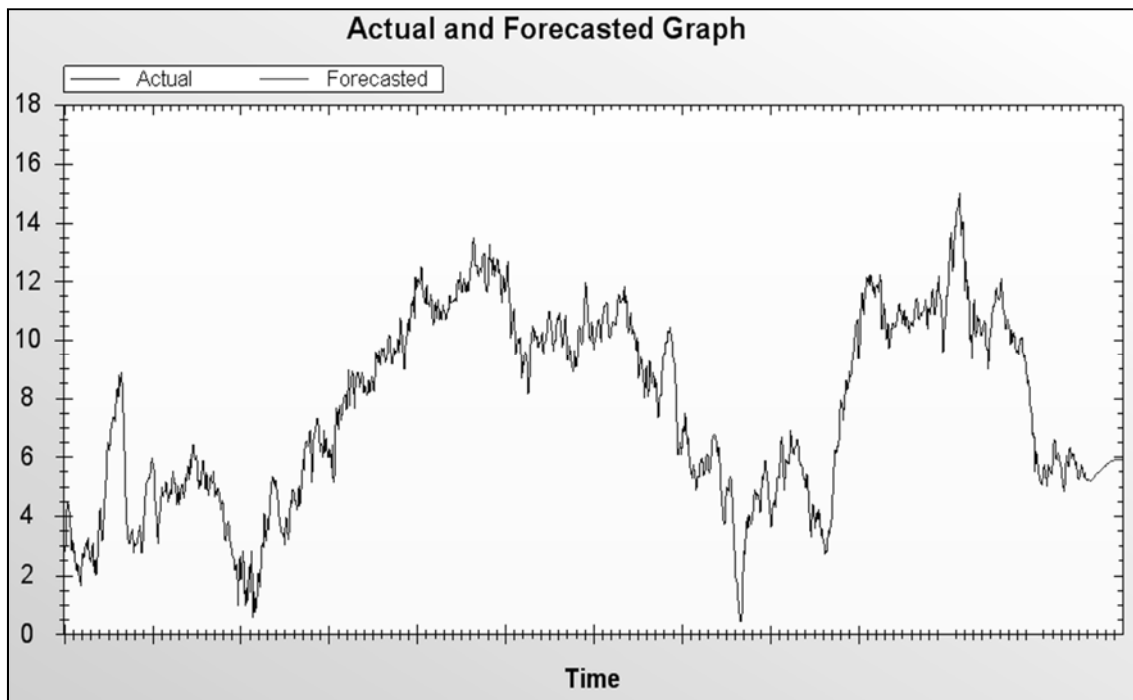


**Εικόνα 25:** Πρόγνωση του ΤΝΔ με την χρήση 288 ανεμολογικών δεδομένων για τις επόμενες 6 ώρες.

- Πρόγνωση του ΤΝΔ για χρονικό ορίζοντα 6 ωρών με βάση τα ανεμολογικά δεδομένα της προηγούμενης εβδομάδας (1008 τιμές)

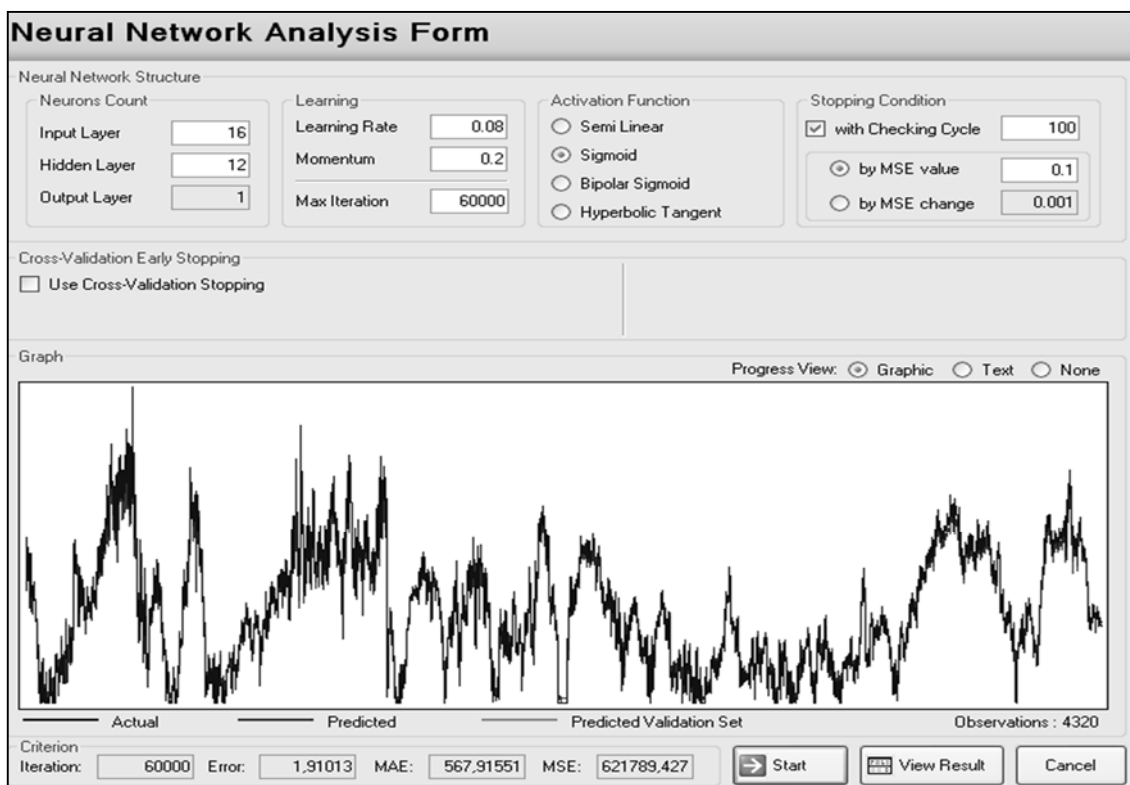


**Εικόνα 12:** Πρόγνωση του ΤΝΔ με την χρήση 1008 ανεμολογικών δεδομένων και κριτήρια σφάλματος.

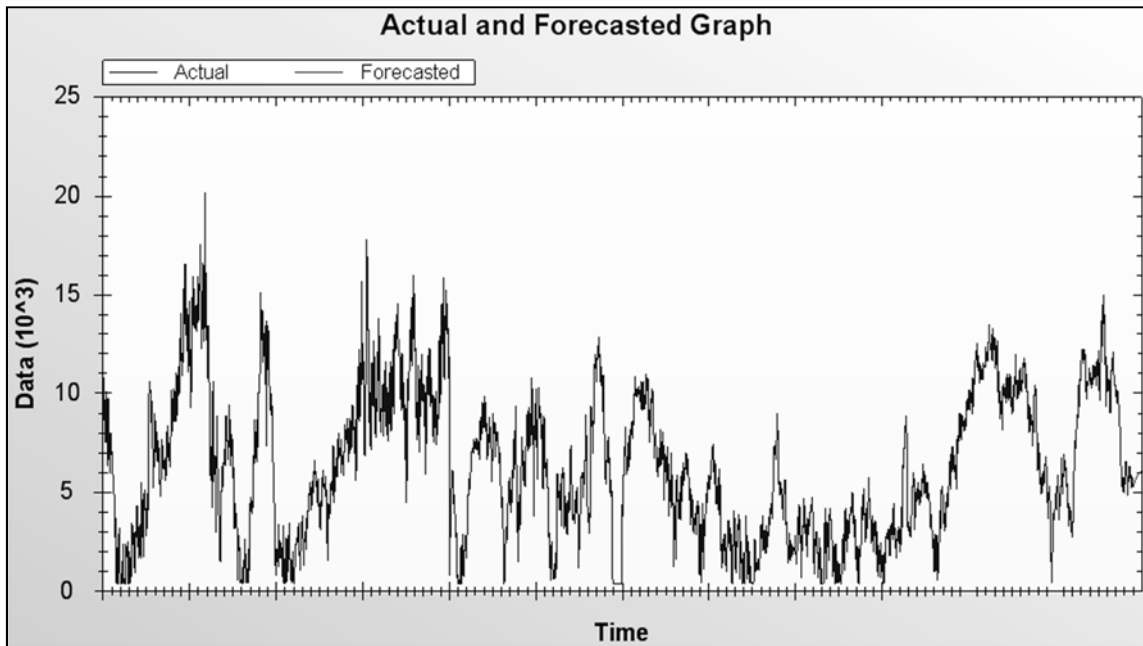


**Εικόνα 13:** Πρόγνωση του ΤΝΔ με την χρήση 1008 ανεμολογικών δεδομένων για τις επόμενες 6 ώρες.

- Πρόγνωση του ΤΝΔ για χρονικό ορίζοντα 6 ωρών με βάση τα ανεμολογικά δεδομένα του προηγούμενου μήνα (4320 τιμές)



**Εικόνα 28:** Πρόγνωση του ΤΝΔ με την χρήση 4320 ανεμολογικών δεδομένων και κριτήρια σφάλματος.



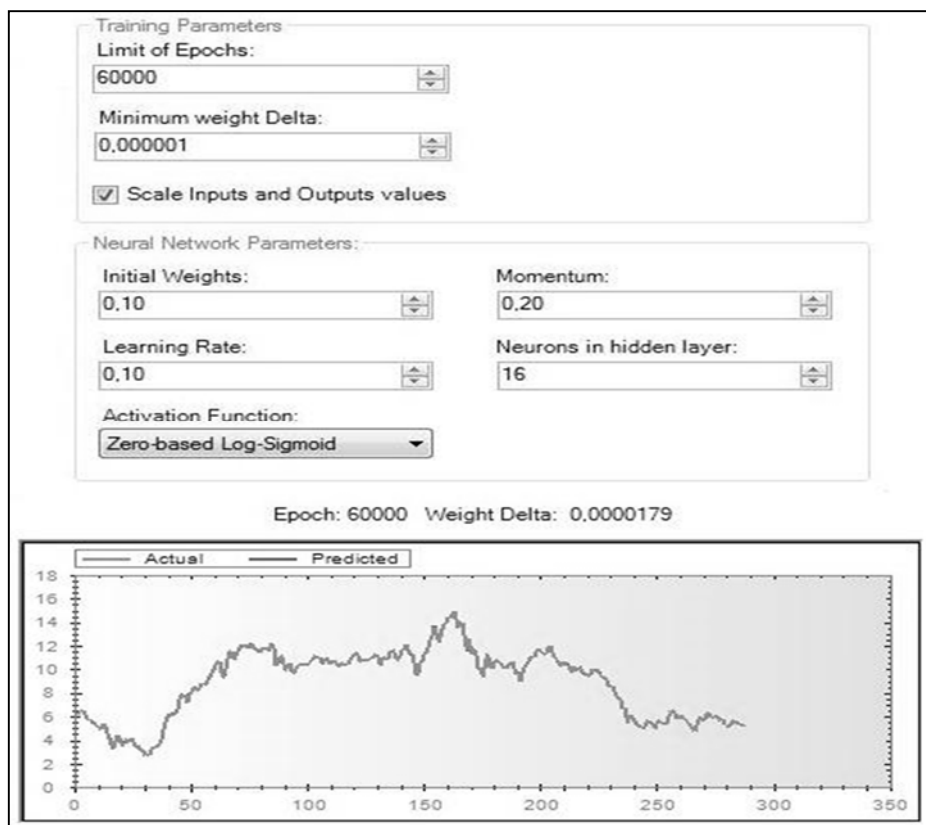
**Εικόνα 14:** Πρόγνωση του ΤΝΔ με την χρήση 4320 ανεμολογικών δεδομένων για τις επόμενες 6 ώρες.

**Πρόγνωση με το λογισμικό εργαλείο NeuroXL Predictor:** Στο περιβάλλον εργασίας του NeuroXL Predictor χρησιμοποιήσαμε μέρος από τα διαθέσιμα ανεμολογικά δεδομένα για να εξετάσουμε αποτελεσματικότητα πρόγνωσης που μπορεί να επιτύχει. Αρχικά προσπαθήσαμε να εκπαιδύσουμε το νευρωνικό δίκτυο που παρέχει το πρόγραμμα αυτό, ώστε οι επιθυμητές τιμές εξόδου να προσεγγίζουν τις πραγματικές, για τις επόμενες 36 μετρήσεις, δηλαδή για τις επόμενες 6 ώρες. Το λογισμικό αυτό έχει λιγότερες δυνατότητες επιλογής σε σχέση με το Zaitun Time Series όμως δέχεται ως είσοδο όλα τα διαθέσιμα δεδομένα πέραν της ταχύτητας του ανέμου, δηλαδή τη διεύθυνση ανέμου, την τυπική απόκλιση και τη θερμοκρασία. Στις εικόνες 30, 31, 32, 33 φαίνονται οι ρυθμίσεις και η εκπαίδευση του ΤΝΔ. Το λογισμικό αυτό παρέχει τις αριθμητικές τιμές εξόδου χωρίς γραφική απεικόνιση. Επιλέξαμε και εδώ 16 κρυφούς νευρώνες ενώ η συνάρτηση ενεργοποίησης που χρησιμοποιήθηκε και με βάση τα δεδομένα είναι η σιγμοειδής (zero-based log-sigmoid). Επιπλέον η παράμετρος εκπαίδευσης έχει βήμα 0.1 και η εκπαίδευση του δικτύου παύει μόλις αυτό συγκλίνει στις τιμές εξόδου που του παρέχουμε.





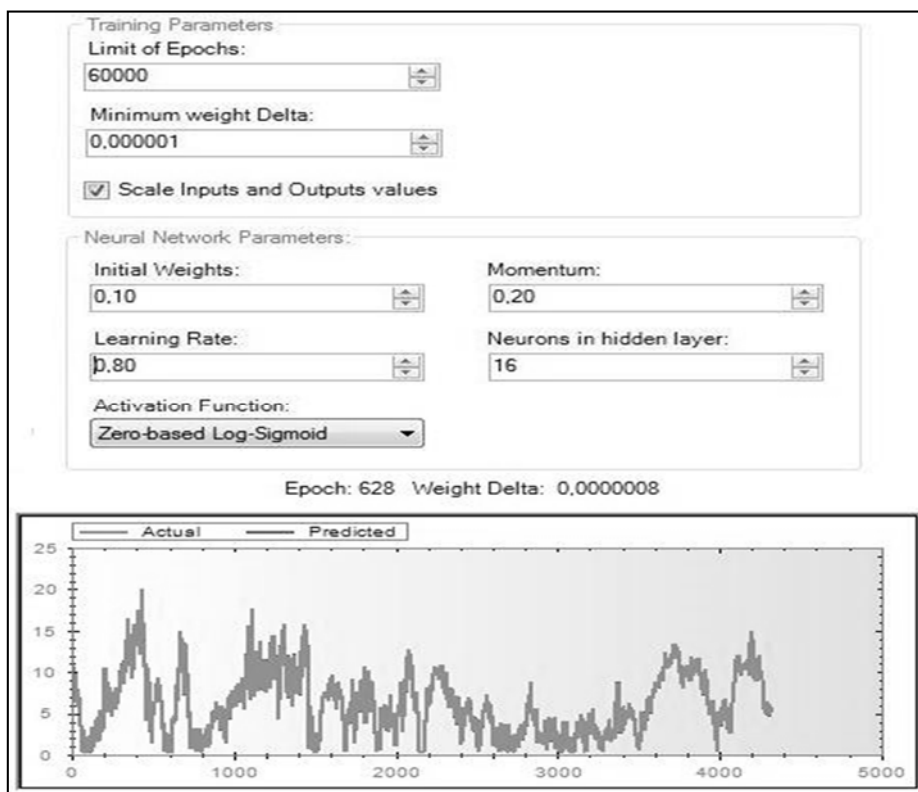
**Εικόνα 15:** Ρυθμίσεις και εκπαίδευση του ΤΝΔ του NeuroXL Predictor με ημερήσια δεδομένα. Οι πραγματικές και οι προβλεπόμενες έξοδοι για 4 σήματα εισόδου έχουν ταυτιστεί.



**Εικόνα 31:** Ρυθμίσεις και εκπαίδευση του ΤΝΔ του NeuroXL Predictor με διήμερα δεδομένα. Οι πραγματικές και οι προβλεπόμενες έξοδοι για 4 σήματα εισόδου έχουν ταυτιστεί.



**Εικόνα 16:** Ρυθμίσεις και εκπαίδευση του ΤΝΔ του NeuroXL Predictor με εβδομαδιαία δεδομένα. Οι πραγματικές και οι προβλεπόμενες έξοδοι για 4 σήματα εισόδου έχουν ταυτιστεί.



**Εικόνα 33:** Ρυθμίσεις και εκπαίδευση του ΤΝΔ του NeuroXL Predictor με μηνιαία δεδομένα. Οι πραγματικές και οι προβλεπόμενες έξοδοι για 4 σήματα εισόδου έχουν ταυτιστεί.

### 3.5 Ανάλυση Αποτελεσμάτων

Σχετικά με την πρόγνωση που πραγματοποιήσαμε, η επιλογή της παραμέτρου εκπαίδευσης είναι πολύ σημαντική καθώς μια υψηλή τιμή μπορεί να προκαλέσει μια πολύ ισχυρή αλλαγή με συνέπεια την απώλεια του επιθυμητού ελαχίστου (Li, Fu, Li, Zhang, 2009), ενώ μια χαμηλή τιμή επιβραδύνει άσκοπα την εκπαίδευση. Στην επιλογή του όρου της ορμής αν η τιμή είναι μηδενική, η αλλαγή του βάρους εξαρτάται αποκλειστικά από την κλίση, ενώ αν είναι 1, η αλλαγή εξαρτάται αποκλειστικά από την προηγούμενη αλλαγή. Σύμφωνα με το λογισμικό εργαλείο Zaitun Time Series όπως φαίνεται και στο κεφάλαιο 4 (πίνακες 4.1 και 4.2), καλύτερα αποτελέσματα για τα 4 πρώτα 10-λεπτα προέκυψαν με ανεμολογικά δεδομένα 2 ημερών, ενώ με τη χρήση εβδομαδιαίων πετύχαμε ταύτιση επιθυμητής και πραγματικής εξόδου για το πρώτο 10-λεπτο. Η έλλειψη ετήσιων δεδομένων είναι σημαντική για την απόκλιση που παρατηρείται στα επόμενα 10-λεπτα διαστήματα, διότι το δίκτυο δεν έχει αποκτήσει μνήμη για την περίοδο αυτή, αλλά ουσιαστικά την προβλέπει μόνο με πρόσφατες τιμές. Από πλευράς κριτηρίων σφάλματος φαίνεται ότι με την αύξηση του όγκου των δεδομένων το σφάλμα αυξάνεται κάτι που σημαίνει ότι το πρόγραμμα θέλει εκ νέου προσαρμογή. Επιπλέον αυξάνει υπερβολικά και ο χρόνος εκπαίδευσης που σημαίνει ότι χρειάζεται μεταβολή της παραμέτρου εκπαίδευσης διότι τα βάρη μπορεί να πάρουν μεγάλες τιμές. Θα πρέπει να επισημάνουμε επίσης και το πρόβλημα των τοπικών ελαχίστων. Εφόσον ακολουθείται η κλίση της επιφάνειας σφάλματος προς τα κάτω με μεταβολή των βαρών μέχρι το σύστημα να φτάσει σε παγκόσμιο ελάχιστο (global), υπάρχει το ενδεχόμενο να υπάρξουν πολλά τοπικά ελάχιστα που να βρίσκονται ψηλότερα από αυτό και στα οποία μπορεί εύκολα να παγιδευτεί το δίκτυο ψάχνοντας για το παγκόσμιο ελάχιστο (εικόνες 8, 9). Τέλος αξίζει να αναφέρουμε ότι το συγκεκριμένο λογισμικό εργαλείο αποδέχεται μόνο μια μεταβλητή για νευρωνική ανάλυση οπότε και επιλέχθηκε η ταχύτητα του ανέμου που αντιστοιχεί όπως έχουμε αναφέρει στη αιολική ισχύ. Η χρήση επιπλέον των μεταβλητών διεύθυνσης ανέμου, τυπικής απόκλιση και θερμοκρασίας θα μπορούσε να βελτιώσει τις αναμενόμενες εξόδους. Το λογισμικό εργαλείο NeuroXL predictor απεναντίας, δέχεται και τις 4 διαθέσιμες μεταβλητές εισόδου και όπως φαίνεται και στο κεφάλαιο 4 (πίνακας 4.3) η πρόγνωση που παρέχει είναι καλύτερη από το πρώτο λογισμικό εργαλείο. Καλύτερα αποτελέσματα συνολικά προέκυψαν με διήμερα και εβδομαδιαία ανεμολογικά δεδομένα, τα οποία σχεδόν ταυτίζονται με τις πραγματικές διαθέσιμες μετρήσεις, ενώ τα μηνιαία δεδομένα συγκλίνουν ικανοποιητικότερα στις τελευταίες 6 μετρήσεις κάτι

που δείχνει ότι έχει σημασία στο εύρος της πρόβλεψης η διαθεσιμότητα μεγάλου αριθμού προηγούμενων διαθέσιμων μετρήσεων. Αντίθετα η πρόβλεψη δείχνει ότι δεν συγκλίνει ικανοποιητικά όταν οι διαθέσιμες μετρήσεις είναι ελάχιστες όπως συμβαίνει με τα δεδομένα της προηγούμενης ημέρας.

# Κεφάλαιο 4

## Αποτελέσματα

### 4.1 Παρουσίαση Αποτελεσμάτων

Με το λογισμικό εργαλείο Zaitun Time Series προέκυψαν τα παρακάτω αποτελέσματα που συγκεντρώθηκαν στον πίνακα 4.1. μαζί με τα κριτήρια αξιολόγησης του σφάλματος που συγκεντρώθηκαν στον πίνακα 4.2:

**Πίνακας 4.1:** Συνολικά αποτελέσματα εξόδων ΤΝΔ και πραγματική έξοδος.

Χρονικός ορίζοντας	Πραγματική έξοδος	Έξοδος ΤΝΔ (144)	Έξοδος ΤΝΔ (288)	Έξοδος ΤΝΔ (1008)	Έξοδος ΤΝΔ (4320)
1	5.182	5.636	5.242	5.182	5.294
2	4.312	5.805	5.269	5.254	5.315
3	5.097	5.841	5.163	5.242	5.339
4	4.294	5.750	4.969	5.209	5.411
5	3.496	5.820	4.914	5.172	5.438
6	3.397	5.965	4.900	5.246	5.466
7	2.911	6.069	4.891	5.253	5.522
8	2.226	6.083	4.910	5.303	5.569
9	1.165	5.966	4.837	5.356	5.627
10	0.454	5.828	4.831	5.401	5.655
11	2.519	5.715	4.865	5.459	5.670
12	2.498	5.627	4.841	5.466	5.708
13	1.004	5.671	4.881	5.477	5.730
14	1.789	5.607	4.916	5.536	5.754
15	1.723	5.547	4.893	5.558	5.781

16	1.956	5.505	4.888	5.583	5.802
17	2.412	5.513	4.915	5.628	5.827
18	2.758	5.563	4.920	5.663	5.848
19	3.656	5.621	4.930	5.695	5.866
20	3.013	5.671	4.943	5.723	5.886
21	2.534	5.684	4.930	5.763	5.904
22	2.710	5.693	4.944	5.793	5.921
23	2.550	5.718	4.958	5.821	5.936
24	2.170	5.761	4.957	5.845	5.947
25	3.076	5.808	4.978	5.863	5.960
26	3.746	5.810	4.990	5.883	5.971
27	4.467	5.806	4.989	5.894	5.982
28	5.576	5.789	5.005	5.902	5.992
29	4.545	5.775	5.021	5.913	6.001
30	4.536	5.767	5.028	5.918	6.010
31	4.714	5.753	5.041	5.920	6.018
32	4.378	5.728	5.052	5.922	6.025
33	5.049	5.691	5.055	5.921	6.033
34	5.201	5.660	5.068	5.918	6.039
35	5.476	5.644	5.076	5.913	6.046
36	6.195	5.641	5.080	5.907	6.051

**Πίνακας 4.2:** Κριτήρια υπολογισμού σφάλματος συγκεντρωτικά.

<b>Κριτήρια σφάλματος</b>	<b>TNA (144)</b>	<b>TNA (288)</b>	<b>TNA (1008)</b>	<b>TNA (4320)</b>
<b>ERROR</b>	0.050265	0.119800	0.341044	1.910130
<b>MSE</b>	125200.095679	232198.621301	358945.916291	621789.427452
<b>MAE</b>	291.807732	367.506601	483.014455	567.915511

Με το λογισμικό εργαλείο NeuroXL Predictor προέκυψαν τα παρακάτω αποτελέσματα που συγκεντρώθηκαν στον πίνακα 4.3. Το εργαλείο αυτό δεν παρέχει κριτήρια αξιολόγησης του σφάλματος.

**Πίνακας 4.3:** Συνολικά αποτελέσματα εξόδων ΤΝΔ και πραγματική έξοδος.

<b>Χρονικός ορίζοντας</b>	<b>Πραγματική έξοδος</b>	<b>Έξοδος ΤΝΔ (144x4)</b>	<b>Έξοδος ΤΝΔ (288x4)</b>	<b>Έξοδος ΤΝΔ (1008x4)</b>	<b>Έξοδος ΤΝΔ (4320x4)</b>
1	5.502	5.626	5.498	5.503	5.508
2	5.449	5.503	5.443	5.448	5.456
3	5.440	5.445	5.432	5.428	5.466
4	6.375	5.426	6.374	6.367	6.365
5	6.590	6.367	6.598	6.593	6.603
6	6.549	6.603	6.552	6.552	6.566
7	5.908	6.557	5.908	5.897	5.898
8	6.052	5.896	6.055	6.061	6.056
9	6.153	6.038	6.157	6.161	6.162
10	5.864	6.144	5.863	5.873	5.865
11	5.827	5.840	5.822	5.831	5.840
12	5.631	5.824	5.635	5.617	5.619
13	5.279	5.622	5.286	5.257	5.260
14	4.983	5.291	4.977	4.972	4.977
15	4.826	5.030	4.845	4.789	4.800
16	5.497	4.894	5.492	5.501	5.495
17	6.076	5.479	6.074	6.083	6.089
18	5.819	6.053	5.814	5.827	5.824
19	5.695	5.785	5.687	5.700	5.697
20	6.321	5.647	6.322	6.314	6.314
21	6.316	6.291	6.316	6.323	6.331
22	5.951	6.299	5.949	5.957	5.965
23	6.107	5.941	6.110	6.113	6.120
24	6.119	6.107	6.122	6.128	6.126
25	5.901	6.108	5.903	5.905	5.915
26	5.723	5.906	5.731	5.725	5.737
27	5.862	5.753	5.865	5.870	5.866
28	5.311	5.853	5.308	5.311	5.310
29	5.227	5.329	5.223	5.225	5.222
30	5.310	5.243	5.304	5.309	5.310

31	5.572	5.320	5.570	5.576	5.577
32	5.743	5.576	5.742	5.723	5.729
33	5.582	5.767	5.580	5.588	5.582
34	5.343	5.575	5.336	5.345	5.334
35	5.471	5.321	5.466	5.476	5.467
36	5.252	5.458	5.248	5.250	5.252

Με βάση τους πίνακες 4.1 και 4.3 φαίνεται η δυνατότητα βραχυπρόθεσμης πρόβλεψης για την παραγωγή αιολικής ενέργειας σε Α/Π, με την χρήση νευρωνικών προγραμμάτων λογισμικού. Η στατιστική προσέγγιση μπορεί να δώσει αξιόπιστα στοιχεία για χρονικό ορίζοντα ωρών κάτι που έχει σημασία όπως έχουμε ήδη αναφέρει για τις εταιρίες παραγωγής ΗΕ και για τον Διαχειριστή των ΣΗΕ. Τα αναμενόμενα αποτελέσματα είναι πιο ακριβή όταν υπάρχουν περισσότερες συναφείς μεταβλητές εισόδου στο ΤΝΔ καθώς και όταν υπάρχει πλούσιο διαθέσιμο ιστορικό μετρήσεων. Η πρόβλεψη τότε δείχνει να είναι πιο αποτελεσματική και σε μεγαλύτερους χρονικούς ορίζοντες. Το Zaitun Time series παρείχε μια σχετικά ικανοποιητική πρόβλεψη μόνο για τα πρώτα τέσσερα 10-λεπτα, ενώ το NeuroXL Predictor παρείχε σωστή πρόβλεψη για της επόμενες 6 ώρες και επιπλέον έδειξε ότι μεγαλύτερο εύρος δεδομένων μπορεί στα αρχικά 10-λεπτα πρόβλεψης να υστερεί αλλά σε μεγάλους χρονικούς ορίζοντες δείχνει να υπερτερεί. Αυτό σημαίνει ότι ετήσια δεδομένα είναι πιο χρήσιμα για μεγαλύτερους ορίζοντες πρόβλεψης. Η εκπαίδευση του δικτύου επίσης εξαρτάται από τη εύρος του διαθέσιμου ιστορικού μετρήσεων. Με την αύξηση των διαθέσιμων μετρήσεων όμως αυξάνεται και ο χρόνος εκπαίδευσης. Η ταχύτητα σύγκλισης μπορεί να βελτιωθεί αυξάνοντας την παράμετρο εκπαίδευσης που όμως θα έχει ως αποτέλεσμα την αύξηση της αστάθειας του δικτύου, με τις τιμές του βάρους να κυμαίνονται λανθασμένα καθώς συγκλίνουν σε μια λύση. Η χρήση του όρου της ορμής επιταχύνει την σύγκλιση αποφεύγοντας την αστάθεια. Και στα 2 λογισμικά εργαλεία η εισαγωγή του όρου της ορμής βελτίωσε την απόδοση του δικτύου όταν επιλέχθηκε όμως μια σχετικά μικρή τιμή. Το NeuroXL Predictor δεν παρέχει τα κριτήρια υπολογισμού σφάλματος ώστε να συγκρίνουμε και ποσοτικά την απόδοση των δυο αυτών λογισμικών. Αξίζει να επισημάνουμε ότι τα δύο αυτά λογισμικά εργαλεία είναι σχετικά απλά εργαλεία πρόβλεψης και άρα περιορισμένων δυνατοτήτων. Μας παρέχουν όμως μια ικανοποιητική εικόνα για την εφαρμογή των ΤΝΔ σε προβλήματα πρόβλεψης.



# Κεφάλαιο 5

## Συζήτηση - Συμπεράσματα

### Εισηγήσεις

Όσον αφορά τα στατιστικά μοντέλα πρόβλεψης αιολικής ισχύς χωρίς τη χρήση NWP, μια από τις πρώτες εργασίες πρόβλεψης της ταχύτητας του ανέμου δημοσιεύτηκε από τον Bossanyi (Bossanyi, 1985). Το μοντέλο αυτό βασίζεται σε ένα φίλτρο Kalman, το οποίο χρησιμοποιεί ως εισόδους, τις τελευταίες έξι μετρήσεις, για να προβλέψει την ταχύτητα του ανέμου για τα επόμενα λίγα λεπτά. Το μοντέλο παρέχει καλύτερα αποτελέσματα σε σχέση με το μοντέλο παραμένουσας τιμής, για την πολύ βραχυπρόθεσμη περίοδο όμως. Η βελτίωση μειώνεται σημαντικά με την αύξηση του χρονικού ορίζοντα.

Επιπλέον, αρκετά μοντέλα στην κατηγορία αυτή βασίζονται στη θεμελιώση προσέγγιση της ανάλυσης χρονοσειρών (Box, Jenkins, 1976), χρησιμοποιώντας μοντέλα αυτοπαλινδρόμησης, κινητού μέσου όρου ή μεικτών μοντέλων (AR, MA, ARMA, ARIMA). Οι Contaxis και Kabouris, χρησιμοποίησαν ένα μοντέλο αυτοπαλινδρόμησης τρίτης τάξης (AR(3)), για την πρόβλεψη της ταχύτητας του ανέμου σε μικρό αυτόνομο ΣΗΕ, με χρονικό ορίζοντα πρόβλεψης 5 ώρες, διαιρεμένο σε 30-λεπτα διαστήματα (Contaxis, Kabouris, 1991). Το σφάλμα πρόβλεψης του ανήλθε στο 15% και η έξοδος του μοντέλου χρησιμοποιήθηκε για τον βραχυπρόθεσμο προγραμματισμό ένταξης και λειτουργίας του ΣΗΕ. Η ερευνητική ομάδα του Torres χρησιμοποίησε μοντέλα ARMA για την πρόβλεψη της ωριαίας ταχύτητας του ανέμου σε χρονικό ορίζοντα 10 ωρών (Torres, García, de Blas, de Francisco, 2005). Η μελέτη τους επεκτείνεται σε πέντε περιοχές με διαφορετικά γεωγραφικά χαρακτηριστικά για εννέα χρόνια και έδειξε ότι η χρήση των μοντέλων ARMA βελτιώνει σημαντικά τις προβλέψεις, επιτυγχάνοντας σφάλματα 12%

έως 20% μικρότερα σε σχέση τα μοντέλα της παραμένουσας τιμής, χωρίς να επηρεάζεται η συμπεριφορά τους από την διαφοροποίηση της μορφολογίας του εδάφους. Παρόμοια μοντέλα χρονοσειρών εφαρμόστηκαν και από την ομάδα του Milligan, για ωριαίες και 10-λεπτες προβλέψεις ανεμοπαραγωγής με χρονικό ορίζοντα 6 ώρες που θεωρείται και το χρονικό όριο εφαρμογής των καθαρά στατιστικών μοντέλων, με τη χρήση πραγματικών δεδομένων ανεμοπαραγωγής από Α/Π στην Αϊόβα και στη Μινεσότα (Milligan, Schwartz, Wan, 2004). Αναφορικά με τις ωριαίες προβλέψεις διαπιστώθηκε σημαντική βελτίωση σε σχέση με τα μοντέλα παραμένουσας τιμής ακόμη και για πολύ βραχυπρόθεσμες προβλέψεις, αλλά η ικανότητα ακρίβειας των μοντέλων ARMA διαφοροποιείται όταν εφαρμόζονται σε διαφορετικούς χρονικούς ορίζοντες, με αποτέλεσμα την ανάγκη υιοθέτησης συνδυαστικών μοντέλων. Αναφορικά με τις 10-λεπτες προβλέψεις διαπιστώθηκε ότι αρκετά από τα μοντέλα ARMA παρουσίασαν καλή απόδοση, με ένα από αυτά να παρουσιάζει το μικρότερο RMSE, για έως και οκτώ 10-λεπτες περιόδους πρόβλεψης. Οι Kavasseri και Seetharaman προτείνουν τα κλασματικά μοντέλα ARIMA (fractional ARIMA, f-ARIMA), βασικό πλεονέκτημα των οποίων είναι η ικανότητα τους να εκμεταλλεύονται τις μακροχρόνιες συσχετίσεις των τιμών μιας χρονοσειράς, οι οποίες υφίστανται όταν η χρονοσειρά παρουσιάζει αργή μείωση της συνάρτησης αυτοσυσχέτισης (Kavasseri, Seetharaman, 2009). Τα μοντέλα εφαρμόστηκαν σε τέσσερις περιοχές της Νότιας Ντακότα για να προβλέψουν τη μέση ωριαία ταχύτητα του ανέμου σε χρονικό ορίζοντα 48 ωρών και επέτυχαν 42% βελτίωση στην ακρίβεια πρόβλεψης σε σχέση με τον μοντέλο παραμένουσας τιμής, με βάση το κριτήριο RMSE.

Διαφορετική προσέγγιση στην πρόβλεψη της ανεμοπαραγωγής αποτελούν από μοντέλα που στηρίζονται σε μεθόδους τεχνητής νοημοσύνης (γενετικοί αλγόριθμοι, νευρωνικά δίκτυα, μοντέλα ασαφούς λογικής, κ.α.). Οι Alexiadis, Dokopoulos, Sahsamanoğlu και Manousaridis προτείνουν τη χρήση νευρωνικών δικτύων για την πρόβλεψη της μέσης ταχύτητας του ανέμου για το επόμενο 10-λεπτο ή ώρα. Η εφαρμογή έγινε με τη χρήση ανεμολογικών δεδομένων σε τρία διαφορετικά νησιά του Νότιου και Κεντρικού Αιγαίου (Alexiadis, Dokopoulos, Sahsamanoğlu, Manousaridis, 1998). Με το προτεινόμενο μοντέλο της χωρικής συσχέτισης, παρατηρείται μείωση κατά 32% στο σφάλμα πρόβλεψης της μέσης ταχύτητας ανέμου για την επόμενη ώρα σε σχέση με το μοντέλο παραμένουσας τιμής ενώ επιτυγχάνεται 16% βελτίωση του σφάλματος πρόβλεψης της ανεμοπαραγωγής. Η ίδια μέθοδος εφαρμόζεται και στην

περιοχή της Θεσσαλονίκης, από την ίδια ερευνητική ομάδα, όπου και παρατηρήθηκε βελτίωση του σφάλματος πρόβλεψης για την ταχύτητα του ανέμου και την ανεμοπαραγωγή 26% και 27% αντίστοιχα, σε σχέση με το μοντέλο παραμένουσας τιμής για 2-ωρο χρονικό ορίζοντα (Alexiadis, Dokopoulos, Sahsamanoğlu, 1999).

Οι Damousis, Alexiadis, Theocharis και Dokopoulos προτείνουν ένα καινοτόμο ασαφές μοντέλο (fuzzy model) για την πρόβλεψη της ταχύτητας του ανέμου και της παραγόμενης ισχύος ενός Α/Π, η εκπαίδευση του οποίου βασίζεται στη χρήση γενετικού αλγόριθμου. Χρησιμοποιήθηκαν κατά την εκπαίδευση δεδομένα ταχύτητας και κατεύθυνσης του ανέμου, σε απόσταση μέχρι και 30 km μακριά από τις θέσεις των Α/Γ, σε δύο διαφορετικά μορφολογικές τοποθεσίες (Θεσσαλονίκη και Σητεία) και τα αποτελέσματα της προσομοίωσης αυτής, ανέδειξαν την συμβολή των απομακρυσμένων δεδομένων στην εξαγωγή ακριβών προβλέψεων. Το μοντέλο παρέχει σημαντική βελτίωση σε σχέση με το μοντέλο παραμένουσας τιμής σε μορφολογικά απλές περιοχές και λιγότερη σε μορφολογικά σύνθετες περιοχές. Τα τοπικά δεδομένα βελτιώνουν τις προβλέψεις και τα 10% έως 25%, ενώ με την προσθήκη απομακρυσμένων δεδομένων η βελτίωση ανέρχεται στο 28% σε επίπεδες εκτάσεις και σε μεγαλύτερους χρονικούς ορίζοντες (Damousis, Alexiadis, Theocharis, Dokopoulos, 2004).

Ο Sfetsos συγκρίνει ως προς την ακρίβεια αποτελεσμάτων σε σχέση με την παραμένουσα και ως προς την ταχύτητα της εξαγωγής αυτών, διαφορές μεθόδους πρόγνωσης χρονοσειράς σε τοποθεσία της Κρήτης, με εφαρμογή σε ωριαίες τιμές ταχύτητας ανέμου για ένα μήνα (Sfetsos, 2000). Γίνεται χρήση τεχνικών τεχνητής νοημοσύνης που στηρίζονται σε γραμμικά μοντέλα παλινδρόμησης (παρόμοια των Box-Jenkins), σε νευρωνικά δίκτυα (Feed Forward Neural Networks-FFNN, Radial Basis Function Networks-RBFN, Elman Recurrent Networks-ERN) και σε συνδυασμούς νευρωνικών δικτύων με ασαφή λογική (Adaptive Network Based Fuzzy Inference System-ANFIS, Neural Logic Network-NLN). Η διαδικασία αυτή, που περιλάμβανε εκπαίδευση, αποτίμηση και πρόβλεψη, οδήγησε στο συμπέρασμα ότι τα μοντέλα τεχνητής νοημοσύνης υπερτερούν των γραμμικών και πως όλα τα μη γραμμικά μοντέλα έχουν περίπου το ίδιο RMS σφάλμα. Καλύτερα αποτελέσματα 4.9% σε σχέση με την παραμένουσα προσφέρει το NLN με ενσωματωμένους λογικούς κανόνες (Logic Rules).

Οι Kusiak, Zheng και Song μελέτησαν τη συμπεριφορά πέντε διαφορετικών αλγόριθμων εξόρυξης δεδομένων (data mining approach) για την πρόβλεψη της ισχύος ενός Α/Π με 100 Α/Γ, σε διαφορετικούς χρονικούς ορίζοντες στο μέλλον υιοθετώντας 10-λεπτα ή ωριαία χρονικά διαστήματα (Kusiak, Zheng, Song, 2009). Εξετάστηκαν οι αλγόριθμοι: Support Vector Machine regression (SVMreg), Multi-layer Perceptron (MLP), Bagging tree, Reducer Error Pruning tree και M5P tree. Ο αλγόριθμος SVMreg ξεπέρασε τους άλλους σχετικά με τις προβλέψεις της παραγόμενης ισχύος και της ταχύτητας του ανέμου σε 10-λεπτα διαστήματα έως 1 ώρα στο μέλλον, ενώ ο αλγόριθμος MLP υπερείχε σε ακρίβεια στην πρόβλεψη έως 4 ώρες στο μέλλον σε ωριαία διαστήματα. Συνολικά όλοι οι αλγόριθμοι βελτίωσαν την ακρίβεια πρόβλεψης των χρονοσειρών ανέμου τουλάχιστον 20%, σε σχέση με το μοντέλο παραμένουσας τιμής.

Οι Catalao, Pousinho και Mendes πρόσφατα προτείνουν ένα υβριδικό μοντέλο για τη βραχυπρόθεσμη πρόβλεψη της ανεμοπαραγωγής στην Πορτογαλία που βασίζεται στο συνδυασμό μεθόδων μετασχηματισμού κυματιδίων (Wavelet Transformation, WT), βελτιστοποίησης σμήνους σωματιδίων (Particle Swarm Optimization, PSO) και συστημάτων ασαφούς εξαγωγής συμπερασμάτων προσαρμοζόμενων δικτύων (Adaptive Network based Fuzzy Inference Systems, ANFIS). Το μοντέλο αυτό χρησιμοποιήθηκε για την πρόβλεψη της παραγόμενης ισχύος σε ορίζοντα 3 ωρών στο μέλλον, λαμβάνοντας υπόψη τα δεδομένα ισχύος των προηγούμενων 12 ωρών, με 15-λεπτο βήμα (Catalao, Pousinho, Mendes, 2011). Η διαδικασία επαναλαμβάνεται μέχρι να γίνει πρόβλεψη τιμών ισχύος των επόμενων 24 ωρών. Σε σύγκριση με επτά διαφορετικά μοντέλα με βάση τα κριτήρια μέσο ποσοστιαίο σφάλμα (MAPE) και ανηγμένο μέσο απόλυτο σφάλμα (NMAE) ξεπέρασε όλα τα υπόλοιπα κατά 4,98% (MAPE) και 2,37% (NMAE).

Στην περίπτωση μακροπρόθεσμης πρόβλεψης του ανέμου, τα απλά στατιστικά μοντέλα δεν μπορούν να ικανοποιήσουν τις απαιτήσεις που προκύπτουν, έτσι θεωρείται αναγκαία η χρήση των NWP ή υβριδικών μοντέλων σε συνδυασμό με NWP (Wang, Guo, Huang, 2011). Οι Duran, Gros και Riquelme χρησιμοποιώντας τα μοντέλα αυτοπαλινδρόμησης AR και ARX σε τρία Α/Π στην Ισπανία, με το δεύτερο να ενσωματώνει επιπλέον τη χρονοσειρά ταχύτητας ανέμου από ένα μοντέλο NWP, κατέδειξαν ότι για χρονικό ορίζοντα 24 ωρών στο μέλλον η ενσωμάτωση αυτή βελτιώνει την ακρίβεια πρόβλεψης του ARX έως 14,1% σε σχέση με το AR και μέχρι

26,3% σε σχέση με το μοντέλο παραμένουσας τιμής (Duran, Cros, Riquelme, 2007). Οι Barbounis, Theocharis, Alexiadis και Dokopoulos χρησιμοποίησαν τρεις τύπους νευρωνικών δικτύων για την μακροπρόθεσμη πρόβλεψη της ταχύτητας του ανέμου και της ανεμοπαραγωγής ενός Α/Π στην ανατολική Κρήτη. Επιλέχθηκαν τα νευρωνικά: IIR-MLP (Infinite Impulse Response Multi-Layer Perceptron), LAF-MLN (Local Activation Feedback Multi-Layer Network) και RNN (Recurrent Neural Network) για προβλέψεις μέχρι και 72 ώρες στο μέλλον λαμβάνοντας υπόψη μετεωρολογικές προβλέψεις από το μοντέλο SKIRON (Barbounis, Theocharis, Alexiadis, Dokopoulos, 2006). Τα αποτελέσματα έδειξαν μείωση του σφάλματος πρόβλεψης έως 50% σε σχέση με την παραμένουσα τιμή καθώς και την υπεροχή τους σε σχέση με τα στατικά νευρωνικά μοντέλα (FIR-NN, MLP). Ένα υβριδικό μοντέλο για πρόβλεψη έως 48 ώρες στο μέλλον, παρουσιάζεται από την ερευνητική ομάδα του Salcedo-Sanz, για ένα Α/Π στην Ισπανία που συνδυάζει το μετεωρολογικό μοντέλο MM5 με κατάλληλο νευρωνικό δίκτυο παρέχοντας ακριβή αποτελέσματα (Salcedo-Sanz, Pérez-Bellidoa, Ortiz-Garcíaa, Portilla-Figuerasa, Prietob, Paredesc, 2009). Οι Sideratos και Hatziargyriou, παρουσιάζουν μια σύνθετη προηγμένη μέθοδο πρόβλεψης ανεμοπαραγωγής που στηρίζεται σε τρία επιμέρους μοντέλα κατάλληλων νευρωνικών δικτύων με την ενσωμάτωση μετεωρολογικών δεδομένων από το μοντέλο HIRLAM. Το σύστημα εφαρμόστηκε σε Α/Π στη Δανία και αποδίδει καλύτερα συγκριτικά από την παραμένουσα τιμή για κάθε χρονικό ορίζοντα (Sideratos, Hatziargyriou, 2007). Διαφορετική προσέγγιση στη μακροπρόθεσμη πρόβλεψη αφορά η χρήση προηγμένων μοντέλων εξόρυξης δεδομένων (Fugon, Juban, Kariniotakis, 2008), (Kusiak, Zheng, Song, 2009) που περιλαμβάνει τόσο γραμμικά όσο και μη γραμμικά μοντέλα πρόβλεψης με τους συγγραφείς να καταλήγουν στο συμπέρασμα ότι όλα τα μοντέλα υπερέχουν της παραμένουσας τιμής ενώ παράλληλα, η ακρίβεια πρόβλεψης εξαρτάται σημαντικά από την μορφολογία του εδάφους.

Τέλος πιο πρόσφατα, αξίζει να αναφέρουμε ότι γενικευμένα νευρωνικά δίκτυα (GRNN) εκπαιδευμένα με στοιχεία από μετεωρολογικά δίκτυα χρησιμοποιήθηκαν για τη χωρική πρόβλεψη των μέσων μηνιαίων ανέμων σε πολύπλοκο ορεινό έδαφος και τα αποτελέσματα επιβεβαίωσαν ότι η ενσωμάτωση τοπογραφικών χαρακτηριστικών βελτιώνει την ακρίβεια πρόβλεψης του χωρικού αέρα (Robert, Foresti, Kanevskic, 2013). Οι Kurt και Lange επιπλέον, για την ανάπτυξη βραχυπρόθεσμης πρόβλεψης σε νέες υπεράκτιες αιολικές εγκαταστάσεις κάνοντας χρήση ΤΝΔ ως καθαρού στατιστικού

μοντέλου κατέληξαν ότι μετά τις πρώτες 25-30 εβδομάδες επιτυγχάνει τα καλύτερα αποτελέσματα σε σχέση με το φυσικό μοντέλο με το οποίο συγκρίθηκε, αρκεί να υπάρχουν αρκετά δεδομένα για την κατάρτιση του ΤΝΔ (Kurt, Lange, 2014).

Η διπλωματική αυτή εργασία επικεντρώθηκε στο επιστημονικό πεδίο των Τεχνητών Νευρωνικών Δικτύων (ΤΝΔ). Έγινε αναφορά στον τρόπο εκπαίδευσης και υλοποίησης τους ενώ μελετήθηκε η δυνατότητα εφαρμογής τους στην πρόγνωση. Ουσιαστικά αποτελεί ένα γενικό πλαίσιο αξιολόγησης των διαθέσιμων ανεμολογικών δεδομένων μιας περιοχής, σε σχέση με τη συμπεριφορά της αιολικής ισχύος, την αντίστοιχη πρόβλεψη της ανεμοπαραγωγής και τη σωστή εκμετάλλευσή της. Με βάση τα παραπάνω λοιπόν, η περεταίρω ανάπτυξη των ΤΝΔ είναι αναγκαία, εφόσον ο κλάδος αυτός μελλοντικά μπορεί να συνεισφέρει σημαντικά στο πεδίο της πρόβλεψης και συγκεκριμένα της ανεμοπαραγωγής, μιας και η αξιοποίηση του Αιολικού δυναμικού θα βρίσκεται στο επίκεντρο του ενδιαφέροντος για πολλές δεκαετίες ακόμα (Bointner et al, 2016). Καθώς η ταχεία ανάπτυξη της αιολικής ενέργειας συνεχίζεται, ένας μεγάλος αριθμός Α/Π θα ενσωματωθεί απευθείας στο δίκτυο, αλλά οι προβλέψεις και οι αλγόριθμοι πρόβλεψης έχουν μικρή εμπειρία μαζί τους. Αυτό είναι και το πρόβλημα για τις στατιστικές βραχυπρόθεσμες προβλέψεις αφού θα πρέπει να εκπαιδεύονται σε ένα μακρύ ιστορικό παραγωγής ενέργειας. Τα ΤΝΔ (Ren, An, Wang, Li, Hu, Shang, 2014) σε σύγκριση με άλλες μεθόδους πρόβλεψης μπορούν και μαθαίνουν από την εμπειρία και παράγουν αποτελέσματα, ακόμα και όταν οι εισροές τους είναι αντιφατικές ή ελλιπείς, ενώ έχουν εξαιρετική απόδοση αν υπάρχουν αρκετά διαθέσιμα δεδομένα (Cali, Lange, Dobschinski, Kurt, Moehrlen, Ernst, 2008). Είτε λαμβάνοντας υπόψη τα ΝWPs είτε όχι, τα ΤΝΔ μπορούν να δώσουν αποτελέσματα σε πολύ δύσκολα προβλήματα και σε σχετικά σύντομο χρόνο. Σημαντικό μειονέκτημα εξακολουθεί να αποτελεί η εκπαίδευση τους που απαιτεί κατάλληλο και ικανό αριθμό παραδειγμάτων ανάλογα με την πολυπλοκότητα του προβλήματος καθώς και η αύξηση των νευρώνων του δικτύου με την αύξηση των διεργασιών του προβλήματος με συνέπεια την αύξηση του απαιτούμενου χρόνου επεξεργασίας του δικτύου για την εξεύρεση βέλτιστης λύσης. Παρά τις δυσκολίες όμως, η ανάπτυξη νέων πιο ρεαλιστικών αλγόριθμων εκπαίδευσης, η αύξηση της υπολογιστικής ισχύος των Υ/Π και η μελλοντική προσθήκη σε αυτούς νευρωνικών δομών, σε συνδυασμό με την πρόοδο στο πεδίο της Τεχνητής Νοημοσύνης και της Βιολογίας, είναι δυνατόν να διευρύνουν την δυνατότητα χρήσης των Νευρωνικών Δικτύων σε περισσότερες και πιο απαιτητικές εφαρμογές. Σε αυτή την

κατεύθυνση ωθεί και ο συνδυασμός αυτών με άλλες τεχνικές όπως η Ασαφής Λογική και οι Γεννητικοί αλγόριθμοι.

# Βιβλιογραφία

1. Abu Mostafa, Y. S. (1995) Hints, *Neural Computations*, volume 7, 639-671.
2. Ackley, D. H., Hinto, G. E., Sejnowskin, T. J. (1985) A learning algorithm for Boltzmann machines, *Cognitive Science*, volume 9, 147-169.
3. Adelman, G., Smith, B. H. (1997) Elsevier's Encyclopedia of Neuroscience. Amsterdam: Elsevier.
4. ΑΔΜΗΕ. (2013) ΜΕΛΕΤΗ ΕΠΑΡΚΕΙΑΣ ΙΣΧΥΟΣ ΓΙΑ ΤΗΝ ΠΕΡΙΟΔΟ 2013 – 2020. [http://www.admie.gr/fileadmin/groups/EDAS\\_DSS/Meleti\\_eparkeias\\_final.pdf](http://www.admie.gr/fileadmin/groups/EDAS_DSS/Meleti_eparkeias_final.pdf).  
[Πρόσβαση: 16.05.17]
5. Alexiadis, M. C., Dokopoulos, P. S., Sahsamanoglou, H. S., Manousaridis, I. M. (1998) Short-term forecasting of wind speed and related electric power, *Solar Energy*, vol. 63, no. 1, pp. 61-68.
6. Alexiadis, M. C., Dokopoulos, P. S., Sahsamanoglou, H. S. (1999) Wind speed and power forecasting based on spatial correlation models, *IEEE Transactions on Energy Conversion*, vol. 14, no. 3, pp. 836-837.
7. Amari, S. (1967) A theory of adaptive patterns classifiers, *IEEE Transactions Electronical Computers*, volume 16, 299-307.
8. Anderson, J. A. (1972) A simple neural network generating an interactive memory, *Mathematical Biosciences*, volume 14, 197-220.
9. Αργυράκης, Π. (2001) *Νευρωνικά Δίκτυα και Εφαρμογές*. Πάτρα: ΕΑΠ.
10. Armijo, L. (1966) Minimization of functions having Lipschitz continuous partial derivatives, *Pacific Journal of Mathematics*, volume 16, 1-3, 1966.
11. Ashby, W. R. (1952) *Design for a Brain, 1st edition*. New York: Wiley.
12. Aspray, W., Burks, A. (1987) *Papers of John Von Neumann on Computing and Computer Theory*. Cambridge, MA: The MIT Press.
13. Bailey, B., Brower, M. C., Zack, J. (1999) Short-term wind forecasting, development and application of a meso-scale model, in *Proceedings of the European Wind Energy Conference, EWEC'99, Nice, France*, pp. 1062-1065.
14. Barbounis, T. G., Theocharis, J. B., Alexiadis, M. C., Dokopoulos, P. S. (2006) Long-term wind speed and power forecasting using local recurrent neural network models, *IEEE Transactions on Energy Conversion*, vol. 21, no. 1, pp. 273-284, Mar. 2006.



15. Barto, A. G., Sutton, R. S., Anderson, C. W. (1983) Neuronlike adaptive elements that can solve difficult learning control problems, *IEEE Transactions on Systems, Man, and Cybernetics*, volume 13, 834-846.
16. BARTOSZ WAŚKOWICZ (2017) Statistical analysis and dimensioning of a wind farm energy storage system, *ARCHIVES OF ELECTRICAL ENGINEERING*, VOL. 66(2), pp. 265-277.
17. Barzilai, J., Borwein, J.M. (1988) Two point step size gradient methods, *IMA Journal of Numerical Analysis*, volume 8, 141-148.
18. Becker, S. (1991) Unsupervised learning procedures for neural networks, *International Journal of Neural Networks*, volume 2, 17-33.
19. Best, D. L., Pryor, S. P. (1983) Air Weather Service Model Output Statistics Systems. *Air Force Global Weather Central*, σελ. 1-90.
20. Bointner, R., Pezzutto, S., Grilli, G., Sparber, W. (2016) Financing Innovations for the Renewable Energy Transition in Europe, *Energies*, 9, 990.
21. Bossanyi, E. A. (1985) Short-Term Wind Prediction Using Kalman Filters, *Wind Engineering*, vol. 9, no. 1, pp. 1-8.
22. Box, G. E., Jenkins, G. (1976) *Time Series Analysis, Forecasting and Control*, Holden Day, 1976.
23. Broomhead, D. S., Lowe, D. (1988) Multivariable functional interpolation and adaptive networks, *Complex Systems*, volume 2, 321-355.
24. Bryson Jr. A. E., Ho, Y. C. (1969) *Applied Optimal Control*, Waltham, MA: Blaisdell.
25. Caianiello, E. R. (1961) Outline of a theory of thought processes and thinking machines, *Journal of Theoretical Biology*, volume 25, 204-235.
26. Cali, Ue., Lange, B., Dobschinski, J., Kurt, M., Moehrlen, C., Ernst, B. (2008) Artificial neural network based wind power forecasting using a multi-model approach, 7th International Workshop on Large Scale Integration of Wind Power and on Transmission Networks for Offshore Wind Farms, Madrid.
27. Carvalho, M. G. (2012) EU energy and climate change strategy, *Energy*, 40, (1) 19-22.
28. Catalao, J. P. S., Pousinho, H. M. I., Mendes, V. M. F. (2011) Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Wind Power Forecasting in Portugal, *IEEE Transactions on Power Systems*, vol. 2, no. 1, pp. 50-59.
29. Chen, N., Qian, Z., Meng, X. (2013) Multistep Wind Speed Forecasting Based on Wavelet and Gaussian Processes, *Mathematical Problems in Engineering*, Volume 2013, 8 pages.

30. Cohen M. A., Grossberg, S. (1983) Absolute stability of global pattern formation and parallel memory storage by competitive neural networks, *IEEE Transactions Systems, Man, and Cybernetics*, volume 13, 815-826.
31. Contaxis, G. C., Kabouris, J. (1991) Short-term scheduling in a wind/diesel autonomous energy system, *IEEE Transactions on Power Systems*, vol. 6, no. 3, pp. 1161-1167.
32. Costello, R., McCoy, D., O'Donnell, P., Dutton, A. G., Kariniotakis, G. N. (2002) Potential Benefits of Wind Forecasting and the Application of More-Care in Ireland. *Paper presented on the 3rd MED POWER conference*, Athens (GR).
33. Cowan, J. D. (1990) Neural networks: The early days, *Advances in Neural Information Processing Systems*, volume 2, 828-842.
34. Cox, J. D. (2002). *Storm Watchers*. NY: John Wiley & Sons, Inc., σελ. 210.
35. Damm, A., Köberl, J., Prettenthaler, F., Rogler, N., Töglhofer, C. (2017) Impacts of +2 °C global warming on electricity demand in Europe, *Climate Services*, 7, 12–30.
36. Damousis, I. G., Alexiadis, M. C., Theocharis, J. B., Dokopoulos, P. (2004) A fuzzy model for wind speed prediction and power generation in wind farms using spatial correlation, *IEEE Transactions on Energy Conversion*, vol. 19, no. 2, pp. 352–361.
37. Διαμαντάρας, Κ. (2007) *Τεχνητά Νευρωνικά Δίκτυα*. Αθήνα: Κλειδάριθμος.
38. Lew, D., Milligan, M., Jordan, G., Piwko, R. (2011) The Value of Wind Power Forecasting, *Presented at the 91st American Meteorological Society Annual Meeting, the Second Conference on Weather, Climate, and the New Energy Economy Washington DC, January 26, 2011*.
39. DeMarco, C. L., Baone, C. A., Han, Y., Lesieutre, B. (2012) Primary and secondary control for high penetration renewables, *Future Grid Initiative White Paper*, US: PSERC Publication.
40. Duran, M. J., Cros, D., Riquelme, J. (2007) Short-Term Wind Power Forecast Based on ARX Models, *Journal of Energy Engineering*, vol. 133, no. 3, pp. 172–180.
41. Durstewitz, M., Ensslin, C., Hahn, B., Hoppe-Kilpper, M., (2001) *Annual Evaluation of the Scientific Measurement and Evaluation Programme (WMEP)*. Kassel, Germany.
42. EUROPA. (2009) DIRECTIVE 2009/28/EC OF THE EUROPEAN PARLIAMENT AND OF THE COUNCIL of 23 April 2009 on the promotion of the use of energy from renewable sources and amending and subsequently repealing Directives 2001/77/EC and 2003/30/EC. *Official Journal of the European Union*. <http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=OJ:L:2009:140:0016:0062:en:PDF>.

- [Πρόσβαση: 11.05.17]
43. EUROPA. (2011) Ενεργειακός χάρτης πορείας για το 2050: είναι εφικτός ενεργειακός τομέας ασφαλής, ανταγωνιστικός και με χαμηλές ανθρακούχες εκπομπές. [http://europa.eu/rapid/press-release\\_IP-11-1543\\_el.htm?locale=EN](http://europa.eu/rapid/press-release_IP-11-1543_el.htm?locale=EN). [Πρόσβαση: 17.05.17]
44. EUROPA. (2017) ΛΕΥΚΗ ΒΙΒΛΟΣ ΓΙΑ ΤΟ ΜΕΛΛΟΝ ΤΗΣ ΕΥΡΩΠΗΣ. [https://ec.europa.eu/commission/sites/beta-political/files/leyki\\_bivlos\\_gia\\_to\\_mellon\\_tis\\_eyropis\\_el.pdf](https://ec.europa.eu/commission/sites/beta-political/files/leyki_bivlos_gia_to_mellon_tis_eyropis_el.pdf). [Πρόσβαση: 17.05.17]
45. EUROPA. (2013) ΠΡΑΣΙΝΗ ΒΙΒΛΟΣ. Πλαίσιο για πολιτικές που αφορούν το κλίμα και την ενέργεια με χρονικό ορίζοντα το έτος 2030. <http://eur-lex.europa.eu/LexUriServ/LexUriServ.do?uri=COM:2013:0169:FIN:EL:PDF>. [Πρόσβαση: 17.05.17]
46. EUROPA. (2013) Προκλήσεις και πολιτική στον τομέα της ενέργειας. Εισήγηση της Ευρωπαϊκής Επιτροπής στο Ευρωπαϊκό Συμβούλιο της 22ας Μαΐου 2013. [http://ec.europa.eu/europe2020/pdf/energy2\\_el.pdf](http://ec.europa.eu/europe2020/pdf/energy2_el.pdf). [Πρόσβαση: 15.05.17]
47. EUROPA. (2017) Renewables: Europe on track to reach its 20% target by 2020. European Commission - Fact Sheet. [http://europa.eu/rapid/press-release MEMO-17-163\\_en.htm](http://europa.eu/rapid/press-release_MEMO-17-163_en.htm). [Πρόσβαση: 15.05.17]
48. EUROPA. (2017) Towards reaching the 20% energy efficiency target for 2020, and beyond. European Commission - Fact Sheet. [http://europa.eu/rapid/press-release MEMO-17-162\\_en.htm](http://europa.eu/rapid/press-release_MEMO-17-162_en.htm). [Πρόσβαση: 15.05.17]
49. EUROPA. (2011) Χάρτης πορείας για τη μετάβαση σε μια ανταγωνιστική οικονομία χαμηλών επιπέδων ανθρακούχων εκπομπών το 2050. [http://www.europarl.europa.eu/meetdocs/2009\\_2014/documents/com/com\\_com\(2011\)0112\\_/com\\_com\(2011\)0112\\_el.pdf](http://www.europarl.europa.eu/meetdocs/2009_2014/documents/com/com_com(2011)0112_/com_com(2011)0112_el.pdf). [Πρόσβαση: 17.05.17]
50. EUROSTAT. (2016) Παραγωγή και εισαγωγές ενέργειας. [http://ec.europa.eu/eurostat/statistics-explained/index.php/Energy\\_production\\_and\\_imports/el](http://ec.europa.eu/eurostat/statistics-explained/index.php/Energy_production_and_imports/el). [Πρόσβαση: 15.05.17]
51. Fahlman, S. E. (1988) An empirical study of learning speed in back-propagation networks, *Technical Report CMU-CS-88-162*, Carnegie Mellon University, Pittsburgh, PA 15213.
52. Focken, U., Lange, M., Waldl, H. P. (2001) Previento – A Wind Power Prediction System With an Innovative Upscaling Algorithm. *Proceedings of the European Wind Energy Conference, Copenhagen, Denmark, 2-6 June 2001, pp. 826-829.*

53. Fugon, L., Juban, J., Kariniotakis, G. (2008) Data mining for Wind Power Forecasting, *in Proceedings of the European Wind Energy Conference EWEC'08*, Brussels, Belgium, April 2008.
54. Gabor, D. (1954) Communication theory and cybernetics, *IRE Transactions on Information Theory*, volume 1, 19-31.
55. Gabor, D., Wilby, W. P. L., Woodcock, R. (1960) A universal nonlinear filter, predictor and simulator which optimizes itself by a learning process. *In the Proceedings of the Institution of Electrical Engineers*, volume 108, 422-435.
56. Garcia, A. R., De-La-Torre-Vega, E. (2009) A Statistical wind power forecasting system – A Mexican wind-farm case study, *European Wind Energy Conference & Exhibition – EWEC Parc Chanot*, Marseille, France, March 2009.
57. Giebel, G., Kariniotakis, G., Brownsword, R. (2003) State of the Art on Short-term Wind Power Prediction, *ANEMOS Deliverable Report D1.1*.
58. Giebel, G., Landberg, L., Kariniotakis, G., Brownsword. R. (2003) State-of-the-Art on Methods and Software Tools for Short-Term Prediction of Wind Energy Production. *European Wind Energy Conference & Exhibition EWEC 2003, Madrid, Spain*.
59. Graeber, D., Kleine, A. (2013) The combination of forecasts in the trading of electricity from renewable energy sources, *J. Bus. Econ.* 83, (5), 409–435.
60. Grossberg, S. (1976) Adaptive pattern classification and universal recoding: II. Feedback, expectation, olfaction, illusions, *Biological Cybernetics*, volume 23, 187-202.
61. Grossberg, S. (1980) How does the brain built a cognitive code?, *Psychological Review*, volume 87, 1-51.
62. Haykin, S. (1999) *Neural Networks: A comprehensive foundation*, New York: Macmillan College Publishing Company.
63. Hebb, D. O. (1949) *The Organization of Behaviour: A Neurophysiological*. New York: Wiley.
64. Hippert, H. S., Pedreira, C. E., Souza, R. C. (2001) Neural networks for short-term load forecasting: a review and evaluation, *IEEE Transactions on Power Systems In Power Systems*, Vol. 16, No. 1. pp. 44-55.
65. Hopfield, J. J. (1982) Neural networks and physical systems with emergent collective computational abilities, *In the Proceedings of the National Academy of Sciences*, volume 79, 2554-2558.

66. Houghton, J. T. (1985) *The Global Climate*. Cambridge: Cambridge University Press, σελ. 49–50.
67. Hughes, H. (1976) Model output statistics forecast guidance. *United States Air Force Environmental Technical Applications Center*, σελ. 1–16.
68. Hush, D. R., Horne, B. G. (1993) Progress in supervised neural networks: What's new since lippmann, *IEEE Signal Processing Magazine*, volume 10, 8–39.
69. ICAP. (2012) Ετήσια έκθεση 2012: Η κατάσταση και οι προοπτικές των ΜΜΕ στην Ελλάδα. ΤΕΤΑΡΤΟ ΠΑΡΑΔΟΤΕΟ: Γ ΕΝΟΤΗΤΑ ΤΗΣ ΕΚΘΕΣΗΣ: ΚΛΑΔΙΚΗ ΚΑΙ ΔΙΚΤΥΑΚΗ ΔΙΑΣΤΑΣΗ ΤΩΝ ΜΜΕ: ΕΜΠΟΡΙΟ, ΥΠΗΡΕΣΙΕΣ, ΚΑΤΑΣΚΕΥΕΣ ΚΑΙ ΕΝΕΡΓΕΙΑ Κλαδική Ανάλυση: Ανανεώσιμες Πηγές Ενέργειας. <http://en.calameo.com/read/002781313827d28c0651f>. [Πρόσβαση: 7.09.17]
70. Ioannou, A., Angus, A., Brennan, F. (2017) Stochastic Prediction of Offshore Wind Farm LCOE through an Integrated Cost Model, *Energy Procedia*, 107, 383 – 389.
71. Jackson, R. B., Canadell, J. G., Le Quéré, C., Andrew, R. M., Korsbakken, J. I., Peters, G. P., Nakicenovic, N. (2015) Reaching peak emissions, *Nat. Clim. Change*, 6, 7–10.
72. Jacobs, R. A. (1988) Increased rates of convergence through learning rate adaptation, *Neural Networks*, volume 1, 295–307.
73. Jørgensen, J., Moehrlen, C., Gallaghóir, B. Ó., Sattler K. McKeogh, E. (2002) HIRPOM: Description of an operational numerical wind power prediction model for large scale integration of on- and offshore wind power in Denmark. *Poster on the Global Windpower Conference and Exhibition*, Paris, France, 2-5 April 2002, 5 p.
74. Kariniotakis, G., Stavrakakis, G. S., Nogaret, E. F. (1996) Wind power forecasting using advanced neural networks models, *IEEE Transactions on Energy Conversion*, vol. 11, no. 4, pp. 762–767.
75. Κατσαφάδος, Π., Μαυροματίδης, Η. (2015) *Εισαγωγή στη Φυσική της Ατμόσφαιρας και την Κλιματική Αλλαγή*. Αθήνα: ΣΕΑΒ, ΕΜΠ.
76. Kavasseri, R. G., Seetharaman, K. (2009) Day-ahead wind speed forecasting using f-ARIMA models, *Renewable Energy*, vol. 34, no. 5, pp. 1388–1393.
77. Kirkpatrick, S., Gelatt, C. D., Vecchi, M. P. (1983) Optimization by simulated annealing, *Science*, volume 220, 671–680.
78. Kohonen, T. (1972) Correlation matrix memories, *IEEE Transactions on Computers*, volume 21, 353–359.

79. Kohonen, T. (1982) Self-Organized formation of topologically correct feature maps, *Biological Cybernetics*, volume 43, 59-69.
80. Kohonen, T. (2001) *Self-Organizing Maps*. Berlin: Springer, third edition.
81. Krishnamurti, T. N. (1995) Numerical Weather Prediction. *Annual Review of Fluid Mechanics*, 27 (1): 195–225.
82. Kurt, M., Lange, B., (2014) Development of short-term forecast quality for new offshore wind farms, *Journal of Physics: Conference Series*, 524, 012184.
83. Kusiak, A., Zheng, H.-Y., Song, Z. (2009) Short-Term Prediction of Wind Farm Power: A Data-Mining Approach, *IEEE Transactions on Energy Conversion*, vol. 24, no. 1, pp. 125–136.
84. Kusiak, A., Zheng, H.-Y., Song, Z. (2009) Wind Farm Power Prediction: A Data-Mining Approach, *Wind Energy*, vol. 12, no. 3, pp. 275–293.
85. Kwon, J. H. (2007) Parallel computational fluid dynamics: parallel computings and its applications. *Proceedings of the Parallel CFD 2006 Conference, Busan city, Korea (May 15–18, 2006)*. Elsevier, σελ. 224.
86. ΛΑΓΗΕ. (2016) ΑΠΕ & ΣΗΘΥΑ. ΣΥΝΟΠΤΙΚΟ ΠΛΗΡΟΦΟΡΙΑΚΟ ΔΕΛΤΙΟ. [http://www.lagie.gr/fileadmin/groups/EDRETH/RES/DELTIO\\_APE\\_MARTIOS\\_2017.pdf](http://www.lagie.gr/fileadmin/groups/EDRETH/RES/DELTIO_APE_MARTIOS_2017.pdf). [Πρόσβαση: 17.05.17]
87. Landberg, L. (2001) Short-term prediction of local wind conditions, *Journal of Wind Engineering and Industrial Aerodynamics*, vol. 89, no. 1, pp. 235-245.
88. Landberg, L., Giebel, G., Nielsen, H. A., Nielsen, T., Madsen, H. (2003) Short-term Prediction-An Overview, *Wind Energy*, 6:273–280.
89. Landberg, L., Watson, S. J. (1994): *Short-term Prediction of Local Wind Conditions*. *Boundary-Layer Meteorology* 70: 171-195.
90. Lange, M., Focken, U. (2008) New developments in wind energy forecasting, *IEEE Power and Energy Society General Meeting 2008 - Conversion and Delivery of Electrical Energy in the 21st Century*, pp. 1-8, 20-24 July 2008.
91. Λαζαρίδης, Μ. (2010) *Ατμοσφαιρική ρύπανση με στοιχεία μετεωρολογίας*. Θεσσαλονίκη: Τζιόλα, 2<sup>η</sup> έκδοση.
92. LeCun, Y. (1992) Efficient Learning and Second-order Methods, *A Tutorial at NIPS 93, Denver*.
93. Li, Y., Fu, Y., Li, H., Zhang, S. W. (2009) The Improved Training Algorithm of Back Propagation Neural Network with Self-adaptive Learning Rate. *International Conference on Computational Intelligence and Natural Computing*, 1: 73–76.

94. Linsker, R. (1988) Self-Organization on a perceptual network, *Computing*, volume 21, 105-117.
95. Looney, C. G. (1997) *Pattern recognition using neural networks*, New York: Oxford University Press.
96. Lun, I. Y. F., Lam, J. C. (2000) A study of Weibull parameters using long-term wind observations. *Renewable Energy*, Volume 20 pp. 145-153.
97. Lynch, P. (2008) The origins of computer weather prediction and climate modeling. *Journal of Computational Physics* 22, 3431–3444.
98. Malvaldi, A., Weiss, S., Infield, D., Browell, J., Leahy, P., Foley, A. M. (2017) A spatial and temporal correlation analysis of aggregate wind power in an ideally interconnected Europe, *Wind Energy*, 20:1315–1329.
99. Manousos, P (2006). Ensemble Prediction Systems. Hydrometeorological Prediction Center. <http://www.wpc.ncep.noaa.gov/ensembletraining/>. [Πρόσβαση: 29.09.17]
100. Manwell, J. F., McGowan, J. G., Rogers, A. L. (2009) *Wind energy explained: Theory, design and application*. West Sussex, United Kingdom: John Wiley & Sons Ltd.
101. Markandya, A., Arto, I., González-Eguino, M., Román, M. V. (2016) Towards a green energy economy? Tracking the employment effects of low-carbon technologies in the European Union, *Applied Energy*, 179, 1342–1350.
102. Martí Perez, I. (2002) Wind Forecasting Activities. *Proceedings of the First IEA Joint Action Symposium on Wind Forecasting Techniques, Norrköping, Sweden, December 2002, pp. 11-20.*
103. McCulloch, W. S., Pitts, W. (1943) A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, volume 5, 115-133.
104. Μετεωρολογική Υπηρεσία (2011). ΣΤΟΙΧΕΙΑ ΜΕΤΕΩΡΟΛΟΓΙΑΣ. [http://www.moa.gov.cy/moa/MS/MS.nsf/all/9785C89ED72AAFFAC22578BD0033E813/\\$file/stoixia\\_meteorologias.pdf?openelement](http://www.moa.gov.cy/moa/MS/MS.nsf/all/9785C89ED72AAFFAC22578BD0033E813/$file/stoixia_meteorologias.pdf?openelement). [Πρόσβαση: 20.09.17]
105. Milligan, M., Schwartz, M. N., Wan, Y. (2004) Statistical Wind Power Forecasting for U.S. Wind Farms, in *Proceedings of the 17th Conference on Probability and Statistics in the Atmospheric Sciences/2004 American Meteorological Society Annual Meeting*, Seattle, Washington, Jan. 11–15.
106. Minsky, M. L. (1961) Steps towards artificial intelligence. *In the Proceedings of the Institute of Radio Engineers*, volume 49, 8-30.
107. Minsky, M. L. (1967) *Computation: Finite and Infinite Machines*. Englewood Cliffs, New Jersey: Prentice Hall.

108. Minsky, M. L., Papert, S. A. (1969) *Perceptrons*, Cambridge MA: MIT Press.
109. Monteiro, C., Bessa, R., Miranda, V., Botterud, A., Wang, J., Conzelmann, G. (2009) Wind Power Forecasting - State-of-the-Art: 2009. *Tech. Report, Argonne National Laboratory*. <http://www.ipd.anl.gov/anlpubs/2009/11/65613.pdf>. [Πρόσβαση: 17.11.17]
110. Μπεργελές, Γ. (1995) *Ανεμοκινητήρες*. Αθήνα: Εκδόσεις Συμμεών.
111. Nakano, K. (1972) Association a model of associative memory, *IEEE Transactions on Systems, Man, and Cybernetics*, volume 2, 380-388.
112. National Oceanic and Atmospheric Administration (2008) The First Climate Model. [https://celebrating200years.noaa.gov/breakthroughs/climate\\_model/welcome.html#vision](https://celebrating200years.noaa.gov/breakthroughs/climate_model/welcome.html#vision). [Πρόσβαση: 27.09.17]
113. Neal, R. M. (1992) Connectionist learning of belief networks, *Artificial Intelligence*, volume 56, 71-113.
114. Nguyen, D., Widrow, B. (1990) Improving the learning speed of 2-layer neural network by choosing initial values of adaptive weights, *Biological Cybernetics*, volume 59, 71-113.
115. Nielsen, T. S., Madsen, H., Tøfting, J. (1999) Experiences with statistical methods for wind power prediction. *Proceedings of the European Wind Energy Conference*, Nice, 1066-1069.
116. Nielsen, T., Joensen, A., Madsen, H., Landberg, L., Giebel, G. (1998) A new reference for Wind Power Forecasting, *Wind Energy*, vol. 1, pp. 29-34.
117. Nilsson, N. J. (1965) *Learning Machines: Foundation of Trainable Pattern-Classifying Systems*, New York: McGrawHull.
118. Norman, A. P. (1956) The general circulation of the atmosphere: a numerical experiment. *Quarterly Journal of the Royal Meteorological Society* 82 (352): 123-154.
119. Novikoff, A. B. J. (1962) On convergence proofs for perceptrons, *In the Proceedings of the Symposium on the Mathematical Theory of Automata*, 615-622.
120. Pachauri, R. K., Meyer, L. (2014) Climate change 2014, *Synthesis Report*, p. 133.
121. Παπαδόπουλος, Μ. Π. (1997) *Παραγωγή Ηλεκτρικής Ενέργειας από Ανανεώσιμες Πηγές*. Αθήνα: ΕΜΠ.
122. Parker, D. B. (1987) Optimal algorithms for adaptive networks: Second order back propagation, second order direct propagation and second order Hebbian learning, *In the Proceedings of the IEEE 1st International Conference on Neural Networks*, volume 2, 593-600.



123. Pielke, R. A. (2002) *Mesoscale Meteorological Modeling*. Academic Press, σελ. 18–19, σελ. 48–49, σελ. 65, σελ. 285–287.
124. Pinson, P. (2006) *Estimation of the uncertainty in wind power forecasting*. École Nationale Supérieure des Mines de Paris. [https://pastel.archives-ouvertes.fr/pastel-00002187/file/Pinson\\_PhDThesis.pdf](https://pastel.archives-ouvertes.fr/pastel-00002187/file/Pinson_PhDThesis.pdf). [Πρόσβαση: 9.10.17]
125. Pinson, P., Chevallier, C., Kariniotakis, G. (2007) Trading wind generation with short-term probabilistic forecasts of wind power, *IEEE Trans. on Power Systems* 22 (3), pp. 1148-1156.
126. Poggio, T., Girosi, F. (1990) Networks for approximation and learning. *In the Proceedings of the IEEE*, volume 78, 1481-1497.
127. PAE. (2017) Συγκεντρωτική Λίστα Κοινοτικής Νομοθεσίας. [http://www.rae.gr/site/categories\\_new/global\\_regulation/global\\_ec/global\\_ec\\_laws.csp](http://www.rae.gr/site/categories_new/global_regulation/global_ec/global_ec_laws.csp). [Πρόσβαση: 16.05.17]
128. PAE. (2017) Συγκεντρωτική Λίστα Εθνικής Νομοθεσίας. [http://www.rae.gr/site/categories\\_new/global\\_regulation/global\\_national/global\\_national\\_laws.csp?s=0&power=ape&type=&low\\_text=&lawfek=&lawcode=&lawdesc=](http://www.rae.gr/site/categories_new/global_regulation/global_national/global_national_laws.csp?s=0&power=ape&type=&low_text=&lawfek=&lawcode=&lawdesc=). [Πρόσβαση: 16.05.17]
129. Ren, C., An, N., Wang, J., Li, L., Hu, B., Shang, D. (2014) Optimal parameters selection for BP neural network based on particle swarm optimization: A case study of wind speed forecasting, *Knowl.-Based Syst*, 56, 226–239.
130. Robert, S., Foresti, L., Kanevskic, M. (2013) Spatial prediction of monthly wind speeds in complex terrain with adaptive general regression neural networks, *Int. J. Climatol*. 33: 1793–1804.
131. Rochester et al (1956) Test's on a cell assembly theory of the action of the brain, using a large digital computer. *IRE Transactions on Information Theory, IT*, volume 2, 80-93.
132. Rosenblatt, F. (1960) On the convergence of reinforcement procedures in simple perceptrons, *Technical Report VG1196G4*, Cornell Aeronautical Laboratory.
133. Rumelhart, D. E., Hinton, G. E., Williams, R. J. (1986) Learning representation of backpropagation errors, *Nature (London)*, volume 323, 533-536.
134. Rumelhart, D. E., McClelland, J.L., (1986) *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, Cambridge, MA: MIT Press.

135. Salcedo-Sanz, S., Pérez-Bellidoa, A. M., Ortiz-García, E. G., Portilla-Figuerasa, A., Prietob, L., Paredesc, D. (2009) Hybridizing the fifth generation mesoscale model with artificial neural networks for short-term wind speed prediction, *Renewable Energy*, vol. 34, no. 6, pp. 1451–1457.
136. Sánchez, I., Usaola, J., Ravelo, O., Velasco, C., Domínguez, J., Lobo, M.G., González, G., Soto, F. (2002) SIPREÓLICO - A Wind Power Prediction System Based on Flexible Combination of Dynamic Models. Application to the Spanish Power System. *Poster on the World Wind Energy Conference in Berlin, Germany*.
137. Saul, L. K., Jakkolla, T., Jordan, M. I. (1996) Mean field theory for sigmoid belief networks, *Journal of Artificial Intelligence Research*, volume 4, 61-76.
138. Sfetsos, A. (2000) A comparison of various forecasting techniques applied to mean hourly wind speed time series, *Renewable Energy*, vol. 21, no. 1, pp. 23–35.
139. Sideratos, G., Hatziaargyriou, N. D. (2007) An Advanced Statistical Method for Wind Power Forecasting, *IEEE Transactions on Power Systems*, vol. 22, no. 1, pp. 258-265.
140. Steinbuch, K. (1961) Die lernmatrix, *Kybernetik*, volume 1, 36-45.
141. Stensrud, D. J. (2007) *Parameterization schemes: keys to understanding numerical weather prediction models*. Cambridge: Cambridge University Press, σελ. 137.
142. Strikwerda, J C. (2004) *Finite difference schemes and partial differential equations*. SIAM, σελ. 165–170.
143. Sunderam, V. S., Dick, A. G., Peter, M. A., Dongarra, S. J. J. (2005) Computational Science – ICCS 2005. *5th International Conference, Atlanta, GA, USA, May 22–25, 2005, Proceedings, Part 1*. Springer, σελ. 132.
144. Taylor, W. K. (1956) Electrical simulation of some nervous system functional activities, *Information Theory*, volume 3, 314-328.
145. Torres, J. L., García, A., de Blas, M., de Francisco, A. (2005) Forecast of hourly averages wind speed with ARMA models in Navarre, *Solar Energy*, vol. 79, no. 1, pp. 65–77.
146. UCAR (2007) The WRF Variational Data Assimilation System (WRF-Var). <http://web.archive.org/web/20070814044336/http://www.mmm.ucar.edu/wrf/WG4/wrfvar/wrfvar-tutorial.htm>. [Πρόσβαση: 29.09.17]
147. Uttley, A. M. (1956) A theory of the mechanism of learning based on the computation of conditional probabilities. *In the Proceedings of the 1st International Conference on Cybernetics*, Namur, Belgium.

148. Uttley, A. M. (1979) *Information Transmission in the Nervous System*, New York, San Francisco: Academic Press.
149. Vapnik, V. N. (1998) *Statistical Learning Theory*, New York: Wiley.
150. Vapnik V. N., Chervonenkis, A. Y. (1971) On the uniform convergence of relative frequencies of events to their probabilities. *Theoretical Probability and Its Applications*, volume 17, 264-280, 1971.
151. Vogl, T. P., Mangis, J. K., Rigler, A. K., Zink, W. T., Alkon, D. L. (1988) Accelerating the convergence of back-propagation method, *Biological Cybernetics*, volume 59, 257-263.
152. Von der Malsburg, C. (1973) Self-Organization of orientation selective cells in the striate cortex, *Kybernetik*, volume 14, 29-40, 1973.
153. Von Neumann, J. (1958) *The Computer and the Brain*. New Haven, CT: Yale University Press.
154. Walter, Z., Norbert, K., European Centre for Medium Range Weather Forecasts (2001) Developments in teracomputing. *Proceedings of the ninth ECMWF Workshop on the Use of High Performance Computing in Meteorology*. World Scientific, σελ. 276.
155. Wang, X., Guo, P., Huang, X. (2011) A Review of Wind Power Forecasting Models, *Energy Procedia*, 12, 770 – 778.
156. Widrow, B. (1962) *Self-Organizing Systems*, Washington DC: Spartan Books.
157. Widrow, B., Hoff, M. E. (1960) Adaptive switching circuits, *IRE WESCON Convention, Human Neurobiology*, volume 4, 96-104.
158. Widrow, B., Lehr, M. A. (2003) Perceptrons, Adalines, and Backpropagation. In M.A. Arbib, editor, *The handbook of brain theory and neural networks*, pages 871-877. Cambridge, MA, USA: MIT Press, 2 edition.
159. Wiener, N. (1948) *Cybernetics: Or Control and Communication in the Animal and the Machine, 1st edition*. New York: Wiley.
160. Wiener, N. (1961) *Cybernetics: Or Control and Communication in the Animal and the Machine, 2nd edition*. New York: Wiley.
161. Willshaw, D. J., Buneman, O. P., Longuet-Higgins, H. C. (1969) Nonholographic associative memory, *Nature (London)*, volume 222, 960-962.
162. Willshaw, D. J., Von der Malsburg, C. (1976) How patterned neural connections can be set up by self-organization, *In the Proceedings of the Royal Society of London Series B*, volume 194, 431-445.

163. WindEurope. (2017) Wind in power. 2016 European statistics. <https://windeurope.org/wp-content/uploads/files/about-wind/statistics/WindEurope-Annual-Statistics-2016.pdf>. [Πρόσβαση: 4.09.17]
164. Winograd, S., Cowan, J. D. (1963) *Reliable Computation in the Presence of Noise*, Cambridge, MA: MIT Press.
165. Χαλδούπης, Χ. (2015) *Εισαγωγή στη Φυσική στην Ατμοσφαιρική Φυσική*. Αθήνα: ΣΕΑΒ, ΕΜΠ.
166. Yongkang, X., Fennessey, M. J. (1996) Impact of vegetation properties on U. S. summer weather prediction, *Journal of Geophysical Research (American Geophysical Union)*, 101, (D3): 7419.
167. ΥΠΕΚΑ. (2017) ΑΙΟΛΙΚΗ ΕΝΕΡΓΕΙΑ. <http://www.ypeka.gr/Default.aspx?tabid=287>. [Πρόσβαση: 5.09.17]
168. ΥΠΕΚΑ. (2017) Εθνικό Σχέδιο Δράσης για τις Ανανεώσιμες Πηγές Ενέργειας. <http://www.ypeka.gr/LinkClick.aspx?fileticket=vBWJVY3FdTk%3d&tabid=37>. [Πρόσβαση: 17.05.17]
169. ΥΠΕΚΑ. (2017) ΚΛΙΜΑΤΙΚΗ ΑΛΛΑΓΗ. ΕΥΡΩΠΑΙΚΗ ΠΟΛΙΤΙΚΗ. <http://www.ypeka.gr/Default.aspx?tabid=446&language=el-GR>. [Πρόσβαση:15.05.17]
170. Zhao, E., Zhao, J., Liu, L., Su, Z., An, N. (2016) Hybrid Wind Speed Prediction Based on a Self-Adaptive ARIMAX Model with an Exogenous WRF Simulation, *Energies*, 9, 7.