



ΣΧΟΛΗ ΕΠΙΣΤΗΜΗΣ ΤΗΣ
ΠΛΗΡΟΦΟΡΙΑΣ & ΠΛΗΡΟΦΟΡΙΚΗΣ
ΤΜΗΜΑ ΑΡΧΕΙΟΝΟΜΙΑΣ, ΒΙΒΛΙΟΘΗΚΟΝΟΜΙΑΣ
& ΜΟΥΣΕΙΟΛΟΓΙΑΣ

ΨΗΦΙΑΚΗ ΔΙΑΧΕΙΡΙΣΗ ΠΟΛΙΤΙΣΜΙΚΗΣ ΠΛΗΡΟΦΟΡΙΑΣ
Π.Μ.Σ.: ΔΙΑΧΕΙΡΙΣΗ ΤΕΚΜΗΡΙΩΝ ΠΟΛΙΤΙΣΜΙΚΗΣ ΚΛΗΡΟΝΟΜΙΑΣ &
ΝΕΕΣ ΤΕΧΝΟΛΟΓΙΕΣ

Διπλωματική Εργασία

«Λογισμικά Υπολογιστικής Νοημοσύνης: Θεωρία και
εφαρμογές»

ΕΠΙΜΕΛΕΙΑ:

Νίκος ΒΡΑΧΛΙΩΤΗΣ
ΑΜ:ΜΑΒΜ201702

ΚΑΘΗΓΗΤΗΣ:

Μάριος ΠΟΥΛΟΣ

Κέρκυρα, 2019

Στη μνήμη του πατέρα μου

Ευχαριστίες

Έχοντας πια φτάσει στο τέλος των μεταπτυχιακών σπουδών μου θα ήθελα να ευχαριστήσω και να εκφράσω την ευγνωμοσύνη μου στον κύριο Πούλο. Τον ευχαριστώ για την ευκαιρία που μου έδωσε να ασχοληθώ με το συγκεκριμένο θέμα καθώς και για την εμπιστοσύνη του. Χάρη στην ενδιαφέρουσα διδασκαλία και στις θεματικές ενότητες που προσέφερε στους φοιτητές, οφείλεται η επιλογή του συγκεκριμένου θέματος διπλωματικής εργασίας.

Οφείλω φυσικά, να ευχαριστήσω και όλους τους καθηγητές, από την διδασκαλία των οποίων διδάχθηκα πολλά σε έναν σχετικά νέο τομέα για μένα.

Κατά τη διάρκεια του μεταπτυχιακού προγράμματος, η οικογένεια μου δοκιμάστηκε από ένα πολύ δυσάρεστο γεγονός. Νιώθω πραγματικά την ανάγκη να τους ζητήσω συγγνώμη για το χρόνο που τους «έκλεψα» όταν όλοι θα έπρεπε να μείνουμε ενωμένοι. Ευχαριστώ βαθιά τη μητέρα, την αδελφή, τον ανηψιό μου και τη γυναίκα μου για την αδιάκοπη στήριξη και την υπομονή τους.

Περιεχόμενα

Περιεχόμενα	iii
Περίληψη	v
Κεφάλαιο 1	Εισαγωγή
1.1	Υπολογιστική Νοημοσύνη
1.2	Γενικά περί Τ.Ν.Δ.
1.3	Ιστορική αναδρομή
1.4	Αρχιτεκτονική
1.4.1	Δίκτυα Hopfield
1.4.2	Δίκτυα Kohonen (SOM)
1.4.3	Adaline (Adaptive Linear Neyrone) και Madaline (Multiple ADaptive LINear Elements)
1.4.4	Δίκτυα πολλών επιπέδων (Multilayer Perceptron, M.L.P.)
1.4.5	RBFN (Radial Basis Function Network)
1.4.6	Δίκτυα PNN (Probabilistic Neural Network)
1.5	Συνάρτηση μεταφοράς (Transfer function)
1.6	Εκπαίδευση
1.7	Data set
1.8	Γενίκευση δικτύου (Generalization)
1.9	Δίκτυα πρόσθιας τροφοδότησης (Feed-forward, FF): Διαδικασία της μάθησης
1.10	Δίκτυα M.L.P.: Διαδικασία της μάθησης
1.11	Μέτρα αξιολόγησης μοντέλων - Σφάλματα
1.11.1	Συναρτήσεις σφάλματος ή κόστους
1.11.2	Πίνακας σύγχυσης (Confusion Matrix)
1.11.3	Άλλες μετρικές με βάση τον Πίνακα Σύγχυσης
Κεφάλαιο 2	Εφαρμογές Τ.Ν.Δ. σε Κτηριακές Εγκαταστάσεις
2.1	Ανάλυση των Τ.Ν.Δ. σε κτηριακές εφαρμογές και ενέργεια

2.2	Κτήρια και μονάδες παραγωγής ενέργειας	45
2.3	Ανανεώσιμες Πηγές Ενέργειας	51
2.3.1	Ηλιακοί συλλέκτες	51
2.3.2	Φωτοβολταϊκά	52
2.3.3	Γεωθερμία	53
2.3.4	Βιομάζα	54
2.4	Εσωτερικές θερμικές συνθήκες	55
2.4.1	Θερμικές παράμετροι	55
2.4.2	Θερμική άνεση	58
2.4.3	Ποιότητα αέρα σε εσωτερικούς χώρους	62
2.5	Εξωτερικές συνθήκες	63
2.5.1	Εκπομπές αερίων	63
2.5.2	Ηλιακή ακτινοβολία	65
2.5.3	Αιολική ενέργεια	66
2.5.4	Εξωτερική θερμοκρασία	68
2.6	Άλλες εφαρμογές	69
2.6.1	Φωτισμός	69
2.6.2	Ακουστική	72
2.7	Συμπεράσματα	73
Παράρτημα: Ανάλυση papers		75
Κατάλογος σχημάτων		91
Κατάλογος πινάκων		95
Ευρετήριο		97
Βιβλιογραφικές Αναφορές		105

Περίληψη

Η Υπολογιστική Νοημοσύνη βασίζεται στη μίμηση στοιχείων ευφυΐας που παρατηρούνται στα έμβια όντα και προσφέρει τεχνικές, οι οποίες είναι ικανές να επιλύουν πολύπλοκα προβλήματα.

Πολλές εφαρμογές της μηχανικής αξιοποιούν αυτά τα εργαλεία της Υπολογιστικής Νοημοσύνης και συγκεκριμένα τα τεχνητά νευρωνικά δίκτυα (Τ.Ν.Δ.), για την προσομοίωση της ενεργειακής απόδοσης των κτηρίων, για την πρόβλεψη μιας συγκεκριμένης παραμέτρου ή για την αξιολόγηση των εσωτερικών θερμικών συνθηκών σε συγκεκριμένα περιβάλλοντα. Πολλά και διαφορετικά Τ.Ν.Δ. είναι διαθέσιμα χωρίς να είναι εκ των προτέρων γνωστό ποιο μοντέλο δίνει καλύτερα αποτελέσματα σε ένα συγκεκριμένο πεδίο.

Ο σκοπός της παρούσας εργασίας είναι η επισκόπηση εκείνων των εφαρμογών στον τομέα της μηχανικής που αξιοποιούν τα τεχνητά νευρωνικά δίκτυα. Πιο συγκεκριμένα γίνεται αναφορά σε μελέτες σχετικές με θέματα όπως:

- η κατανάλωση ενέργειας στα κτήρια,
- η αξιολόγηση των εκπομπών αερίων,
- ο υπολογισμός θερμικών συνθηκών σε εσωτερικούς και εξωτερικούς χώρους,
- η διερεύνηση ανανεώσιμων πηγών ενέργειας και
- οι εφαρμογές φωτισμού και ακουστικής.

Μια βαθιά ανάλυση αυτών των προβλημάτων απαιτεί γενικά πολλούς πόρους. Πολλές μελέτες έχουν διεξαχθεί προκειμένου να βελτιωθεί η διαθέσιμη μεθοδολογία σε προβλήματα μηχανικής. Ενδιαφέρουσες λύσεις προσφέρουν τα τεχνητά νευρωνικά δίκτυα.

Η ιδιαιτερότητα των T.N.Δ. είναι η δυνατότητα προσομοίωσης και επίλυσης σύνθετων προβλημάτων χάρη στην αρχιτεκτονική τους, η οποία επιτρέπει τον προσδιορισμό του συνδυασμού των εμπλεκόμενων παραμέτρων ακόμα και όταν αυτές είναι υπερβολικά πολλές.

Η διάρθρωση της δομής της παρούσας εργασίας έχει ως ακολούθως: Στο εισαγωγικό κεφάλαιο γίνεται μια συνοπτική περιγραφή των βασικών στοιχείων των T.N.Δ. που αφορούν στην αρχιτεκτονική, στην παρουσίαση διαφόρων δικτύων και γενικά στην εκπαίδευση. Ιδιαίτερη αναφορά γίνεται σε σφάλματα των τεχνικών προβλέψεων (μέτρα αξιολόγησης μοντέλων) όπως το μέσο τετραγωνικό σφάλμα (MSE), το μέσο απόλυτο σφάλμα (MAE), η τετραγωνική ρίζα μέσου τετραγωνικού σφάλματος (RMSE) και αρκετών ακόμα.

Στην αρχή του δεύτερου κεφάλαιου έγινε μια ανάλυση των κύριων παραμέτρων που επηρεάζουν την υλοποίηση των T.N.Δ. στα εξετασθέντα papers, και στη συνέχεια περιγράφονται οι εφαρμογές των T.N.Δ. στο πεδίο της ενέργειας και των κτηρίων που βρέθηκαν στη βιβλιογραφία.

Αξίζει να αναφερθεί ότι παράλληλα με την παρούσα διπλωματική εργασία αναπτύχθηκε ένα on-line λεξικό 9.657 όρων απ' το γνωστικό πεδίο της Επιστήμης της Πληροφόρησης, εμπλουτισμένο και με την ορολογία των νευρωνικών δικτύων. Το λεξικό διατίθεται ελεύθερα στη διεύθυνση: <http://lexiko.nivra1.com>.

1 | Εισαγωγή

1.1 Υπολογιστική Νοημοσύνη

Η Υπολογιστική Νοημοσύνη (Computational Intelligence, C.I.) είναι ένας αναπτυσσόμενος ερευνητικός τομέας που περιλαμβάνει έναν συνεχώς αυξανόμενο αριθμό μεθοδολογιών, που βασίζονται στη μίμηση στοιχείων ευφυΐας που παρατηρούνται στα έμβια όντα. Θεωρείται κλάδος (υποσύνολο) της Τεχνητής Νοημοσύνης¹ (Artificial Intelligence, A.I.). Παραδοσιακά οι τρεις κύριοι πυλώνες της C.I. ήταν:

1. τα *Τεχνητά Νευρωνικά Δίκτυα*, που επιτρέπουν στο σύστημα να μάθει, λειτουργώντας όπως τα βιολογικά συστήματα,
2. τα *Ασαφή Συστήματα (Fuzzy logic systems)*, όπου μεταξύ των πολλών εφαρμογών επιτρέπουν στον υπολογιστή να κατανοεί τη φυσική γλώσσα,
3. ο *Εξελικτικός Προγραμματισμός (Evolutionary Computing)*, ο οποίος βασίζεται στη διαδικασία της φυσικής (δαρβινικής) επιλογής,

Με την πάροδο του χρόνου, η C.I., έχει διευρυνθεί με πολλά στοιχεία της Μηχανικής Μάθησης². Αυτός ο συνδυασμός τεχνικών της

¹ Αν και η Τεχνητή Νοημοσύνη και η Υπολογιστική Νοημοσύνη επιδιώκουν έναν παρόμοιο στόχο, την ανάπτυξη έξυπνων μηχανών, παραταύτα είναι διαφορετικές. Η A.I. βασίζεται σε hard computing techniques, ενώ η C.I. βασίζεται σε μεθόδους soft computing.

² Η Μηχανική Μάθηση παρέχει στον υπολογιστή τη δυνατότητα να μάθει χωρίς να έχει προγραμματιστεί ρητά.

C.I. που έχουν την προέλευσή τους από βιολογικά συστήματα με τη Μηχανική Μάθηση καθιστά δυνατή την επίλυση σύνθετων προβλημάτων, το οποίο δεν θα ήταν δυνατόν με συμβατικές μεθοδολογίες. Οι τεχνικές της C.I. καθώς και η επικάλυψη αυτών με τη μηχανική μάθηση φαίνεται στο Σχήμα 1.1.

Κάθε μία από τις διάφορες τεχνικές C.I. έχει πλεονεκτήματα και μειονεκτήματα. Δεν υπάρχει μέθοδος επίλυσης που να είναι καθολικά ανώτερη. Συνήθως οι υβριδικές³ μέθοδοι μπορούν να παράγουν καλύτερα αποτελέσματα από τις μεμονωμένες μεθόδους.

Αξίζει να σημειωθεί ότι, οι διάφοροι ορισμοί και όροι στον τομέα της Α.Ι. δεν χρησιμοποιούνται ομοιογενώς και σταθερά στη βιβλιογραφία. Οι διαφορές όμως, βασίζονται περισσότερο στο υπόβαθρο των χρηστών παρά στη μαθηματική ουσία.


Στο πλαίσιο της παρούσας διπλωματικής μελετήθηκαν ιδιαίτερας τα νευρωνικά δίκτυα και η χρησιμότητα τους στην επίλυση προβλημάτων μηχανικής.

1.2 Γενικά περί Τ.Ν.Δ.

Πολλά διαφορετικά προβλήματα μηχανικής επιλύονται με την εφαρμογή παραδοσιακών λογισμικών τα οποία, χάρη σε αναλυτικούς μαθηματικούς αλγόριθμους, επιτρέπουν τον υπολογισμό των αναμενόμενων αποτελεσμάτων. Όλοι αυτοί οι αλγόριθμοι έγιναν πολύ χρήσιμοι και είναι συχνοί σε εφαρμογές μηχανικής και σε πολλούς διαφορετικούς τομείς αλλά, δεν μπορούν να θεωρηθούν «έξυπνες συσκευές» επειδή δεν είναι σε θέση να επιλύσουν συγκεκριμένα προβλήματα που είναι πολύ εύκολα για τον ανθρώπινο εγκέφαλο. Κατά συνέπεια, τελείως διαφορετικοί τύποι αλγόριθμων υλοποιούνται σε πεδία επιστημονικής έρευνας: τα τεχνητά νευρωνικά δίκτυα (Τ.Ν.Δ.).

Τα τεχνητά νευρικά δίκτυα είναι ένα είδος συστημάτων επεξεργα-

³Παραδείγματα υβριδικών μεθόδων αποτελούν τα νευρο-ασαφή συστήματα (Neuro-Fuzzy Systems), τα δίκτυα ακτινωτής βάσης (RBF), οι μηχανές διανυσμάτων υποστήριξης (SVMs), οι γνωσιακοί χάρτες (Cognitive Maps) κ.λπ.




Σχήμα 1.1 – Τεχνικές της Υπολογιστικής Νοημοσύνης

σίας πληροφοριών ικανά να προσομοιώνουν τη συμπεριφορά του βιολογικού νευρικού συστήματος του ανθρώπινου εγκεφάλου για την επίλυση ενός συγκεκριμένου προβλήματος. Αυτός ο ορισμός των Τ.Ν.Δ. δείχνει ότι δεν είναι ένας εύκολος και κοινός αλγόριθμος γραμμένος από προγραμματιστή, αλλά μοντέλα επεξεργασίας πληροφοριών ικανά να εκτελούν πολύπλοκες διαδικασίες με ένα μικρό και αποδεκτό λάθος.

Για να γίνει κατανοητή η πολυπλοκότητα και η πραγματική λειτουργία ενός Τ.Ν.Δ. είναι απαραίτητη η γνώση του πώς λειτουργεί το βιολογικό νευρικό σύστημα.

Το πιο σημαντικό και θεμελιώδες συστατικό του βιολογικού νευρικού συστήματος είναι ο νευρώνας: αυτό το κύτταρο αποτελείται από έναν πυρήνα και δύο τύπους επεκτάσεων (δενδριτών και αξόνων) ικανών να ανταλλάσσουν τις πληροφορίες (ηλεκτρικοί παλμοί) μέσω συναπτικών συνδέσεων. Σε αυτό το πλαίσιο, ο εγκέφαλος μπορεί να θεωρηθεί ως ένα πολύ περίπλοκο, μη γραμμικό και παράλληλο σύστημα επεξεργασίας, όπου όλοι οι νευρώνες συνεργάζονται για την επίλυση των προβλημάτων (Σχήμα 1.2).



Σχήμα 1.2 – Σχέδιο νευρώνα.

Τα Τ.Ν.Δ. είναι μαθηματικά μοντέλα και μοντέλα επεξεργασίας

που αποσκοπούν στην αναπαραγωγή της συμπεριφοράς των βιολογικών νευρώνων για την επίλυση σύνθετων και μη γραμμικών προβλημάτων με την εφαρμογή απλών στοιχείων που αλληλοσυνδέονται μεταξύ τους. Η ικανότητα μάθησης των μαθηματικών και στατιστικών αυτών μοντέλων από την εμπειρία είναι η σημαντικότερη ιδιαιτερότητα των T.N.Δ. Αυτό το κύριο χαρακτηριστικό δεν επιτρέπει στα T.N.Δ. να αξιολογήσουν ρητά τη μαθηματική σχέση μεταξύ εισόδων και εξόδων. Τα T.N.Δ. είναι επομένως ένα είδος μοντέλου μαύρου κουτιού επειδή δεν είναι δυνατόν να γνωρίζουμε με αδιαμφισβήτητο τρόπο πώς επιτυγχάνουν τα αποτελέσματά τους και δεν προγραμματίζονται ως ένας κοινός κώδικας υπολογισμού, αλλά εκπαιδεύονται μέσω μιας μαθησιακής διαδικασίας που βασίζεται σε εμπειρικά δεδομένα.

Τα βασικά χαρακτηριστικά του βιοσυστήματος, που δίνουν ιδιαίτερη σημασία στο νευρικό δίκτυο, είναι η μη γραμμικότητα, ο υψηλός διαχωρισμός, η ευρωστία, η μάθηση, η ικανότητα διαχείρισης των ασαφών και ανεπαρκώς σαφών πληροφοριών, καθώς και η ικανότητα για γενίκευση.

Τα τεχνητά μοντέλα με αυτά τα χαρακτηριστικά είναι επιθυμητά επειδή:

1. η μη γραμμικότητα παρέχει καλύτερη προσαρμογή των δεδομένων,
2. η μη ευαισθησία στον θόρυβο παρέχει την ακριβή πρόβλεψη ακόμα και με την παρουσία σφαλμάτων και αναξιόπιστων δεδομένων (fault-tolerant),
3. ο υψηλός παραλληλισμός επιτρέπει την ταχεία επεξεργασία δεδομένων,
4. η εκμάθηση και η προσαρμοστικότητα δίνουν στο σύστημα τη δυνατότητα να ενημερώνει όλη την εσωτερική δομή και
5. η γενίκευση κάνει ικανή την εφαρμογή του μοντέλου σε δεδομένα που δεν περιλαμβάνονται στη διαδικασία εκμάθησης των δικτύων.

Ο κύριος στόχος των Τ.Ν.Δ. βασισμένος στον υπολογισμό είναι η ανάπτυξη των μαθηματικών αλγορίθμων που καθιστούν δυνατή την εκμάθηση με την μίμηση της μάθησης και επεξεργασίας της πληροφορίας όπως στον ανθρώπινο εγκέφαλο. Τα μοντέλα των Τ.Ν.Δ. έχουν εμπειρικό χαρακτήρα, ωστόσο μπορούν να δώσουν τις σωστές λύσεις για ακριβή και σωστά διατυπωμένα προβλήματα καθώς και για τα φαινόμενα που μπορούν να εξηγηθούν μόνο πειραματικά.

Για να εξηγήσουμε και να επικεντρωθούμε στην πραγματική δυνατότητα των Τ.Ν.Δ., το ακόλουθο παράδειγμα μπορεί να είναι χρήσιμο. Ένας μηχανικός που θέλει να σχεδιάσει εγκαταστάσεις θέρμανσης για κτήρια πρέπει να υπολογίσει τα θερμικά φορτία και να σχεδιάσει τη μονάδα θέρμανσης χρησιμοποιώντας ένα συγκεκριμένο λογισμικό ή να κάνει τους κατάλληλους υπολογισμούς. Όμως ένας παλαιότερος μηχανικός που εργάζεται και σχεδιάζει εγκαταστάσεις θέρμανσης για πολλά χρόνια είναι σε θέση να σχεδιάσει το εργοστάσιο χωρίς να χρησιμοποιήσει λογισμικό ή χωρίς να κάνει υπολογισμούς χάρη στην εμπειρία του. Τα Τ.Ν.Δ. είναι σαν τον παλαιότερο μηχανικό. Στην πραγματικότητα, αν εφαρμοστούν σωστά, είναι σε θέση να επιλύσουν ένα συγκεκριμένο πρόβλημα με βάση την εμπειρία τους, δηλ. χάρη στη μαθησιακή διαδικασία με βάση τα εμπειρικά δεδομένα.

1.3 Ιστορική αναδρομή

Τα Νευρωνικά Δίκτυα δεν είναι ένας νέος τομέας. Οι προσπάθειες για την ανάπτυξη τους έχουν ξεκινήσει αρκετές δεκαετίες, πριν ακόμα και απ' τους Η/Υ. Έχουν περάσει διάφορες φάσεις, ωστόσο μεγάλη ώθηση δόθηκε μετά το 1980. Οι κυριότερες αρχιτεκτονικές και λειτουργίες των Τ.Ν.Δ. φαίνονται στην ακόλουθη λίστα.

- **1943:** McCulloch & Pitts – Δημιουργούν το πρώτο μοντέλο Τ.Ν.Δ.
- **1949:** Hebb, «The organisation of behavior» – Δημιουργεί το ομώνυμο μοντέλο μάθησης.

- **1957:** Rosenblatt – Προτείνει το μοντέλο του αισθητήρα (perceptron)
- **1969:** Minsky & Papert – Αποδεικνύουν μαθηματικά ότι τα T.N.Δ. ενός επιπέδου δεν μπορούν να λύσουν μη γραμμικά προβλήματα.
- **1974-85:** Fukushima, «A self-organizing multilayered neural network».
- **1982:** Hopfield – Μαθηματική απόδειξη ότι ένα T.N.Δ. πολλών επιπέδων μπορεί να χρησιμοποιηθεί ως αποθηκευτικός χώρος
- **1986:** McClelland και Rumelhart «Parallel Distributed Processing» – Προτείνουν τη μέθοδο οπισθοδιάδοσης (backpropagation) για την εκπαίδευση T.N.Δ.
- **1988:** Broomhead & Lowe, «Multivariable functional interpolation and adaptive networks» – Εισάγουν στη βιβλιογραφία των νευρωνικών δικτύων, τα δίκτυα Radial Basis Function, RBF.
- **1988:** Specht & Donald, «Probabilistic Neural Networks for Classification, Mapping, or Associative Memory» – Η αντικατάσταση της σιγμοειδούς συνάρτησης μεταφοράς που χρησιμοποιείται συχνά σε νευρωνικά δίκτυα με την εκθετική, δημιουργεί ένα πιθανοτικό νευρωνικό δίκτυο (Probabilistic Neural Network, PNN) που μπορεί να υπολογίσει τα μη γραμμικά όρια απόφασης προσεγγίζοντας το βέλτιστο του Bayes.
- **1995:** Cortes & Vapnik «Support vector networks» – Οι Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines, SVM) αποτελούν μια μέθοδο επεξεργασίας δεδομένων σε προβλήματα ταξινόμησης καθώς καταφέρνει τον διαχωρισμό ενός ζεύγους κλάσεων από μια διαχωριστική ευθεία (ή επίπεδο/υπερεπίπεδο).

1.4 Αρχιτεκτονική

Ομοίως με τα βιολογικά δίκτυα, τα T.N.Δ. αποτελούνται από βασικά στοιχεία που επιτρέπουν την επεξεργασία όλων των πληροφοριών και δεδομένων. Αυτά τα στοιχεία ονομάζονται τεχνητοί νευρώνες (ή νευρώνες) και μπορούν να χωριστούν σε διαφορετικά επίπεδα (επίπεδο εισόδου, κρυφά επίπεδα και επίπεδο εξόδου). Κάθε νευρώνας συγκεκριμένου επιπέδου μπορεί να συνδεθεί με αυτούς ενός άλλου επίπεδο με συνδέσεις, όπως οι βιολογικές συνάψεις. Με αυτόν τον τρόπο, οι πληροφορίες επεξεργάζονται μέσω του διαμορφώμενου δικτύου που διέρχεται από το επίπεδο εισόδου στην έξοδο, χάρη στις συνδέσεις των νευρώνων.

Βασικά στοιχεία της αρχιτεκτονικής των T.N.Δ. είναι:


- Ο αριθμός των ενδιάμεσων κρυφών επιπέδων,
- Ο αριθμός των νευρώνων ανά επίπεδο,
- Ο τρόπος σύνδεσης των νευρώνων μεταξύ τους,
- Η τιμή ενεργοποίησης (τιμή κατωφλίου),
- Η χρησιμοποιούμενη συνάρτησης μεταφοράς,
- Οι τιμές των αρχικών βαρών μεταξύ των νευρώνων,
- Οι αλγόριθμοι μάθησης που χρησιμοποιούνται.

Λαμβάνοντας υπόψη τις συνδέσεις μεταξύ των νευρώνων, τα T.N.Δ. ταξινομούνται σε:

- *πλήρως συνδεδεμένα δίκτυα*: κάθε νευρώνας ενός επιπέδου συνδέεται με κάθε νευρώνα άλλου επιπέδου,
- *μερικώς συνδεδεμένα δίκτυα*: κάθε νευρώνας ενός επιπέδου συνδέεται μόνο με μια συγκεκριμένη ομάδα νευρώνων ενός άλλου επιπέδου.

Ωστόσο, η πιο συνηθισμένη ταξινόμηση είναι εκείνη όπου εξετάζεται ο τρόπος μετάδοσης των πληροφοριών ανεξάρτητα από τη σύνδεση μεταξύ των νευρώνων. Στην περίπτωση αυτή διακρίνονται δύο τύποι Δικτύων:


- *Δίκτυα πρόσθιας τροφοδότησης (Feed-forward, FF)*: οι συνδέσεις μεταξύ των νευρώνων είναι σε θέση να μεταδίδουν τις πληροφορίες μόνο προς τα εμπρός,




Σχήμα 1.3 – Δίκτυο πρόσθιας τροφοδότησης (Feed-forward)

- *Δίκτυα οπίσθιας τροφοδότησης (Feed-back) ή ανατροφοδοτούμενα T.N.Δ. (recurrent ANN)*: οι συνδέσεις μεταξύ των νευρώνων μπορούν να μεταδώσουν τις πληροφορίες τόσο προς τα εμπρός όσο και προς τα πίσω (μηχανισμός ανάδρασης).
 - Αν η ανατροφοδότηση αφορά νευρώνες στο ίδιο επίπεδο, τότε τα δίκτυα καλούνται *αυτοσυσχετιζόμενες μνήμες (autoassociated memories)* διαφορετικά, (Σχήμα 1.4)
 - καλούνται *ετεροσυσχετιζόμενες μνήμες (heteroassociated memories)*⁴ (Σχήμα 1.5)

⁴Όταν το δίκτυο ανατροφοδοτείται από κρυφό επίπεδο προς το επίπεδο εισόδου, τότε ονομάζεται



Σχήμα 1.4 – Παράδειγμα αυτοσυσχετιζόμενης μνήμης




Σχήμα 1.5 – Παράδειγμα ετεροσυσχετιζόμενης μνήμης ή δίκτυο τύπου Elman

Στη συνέχεια παρουσιάζονται ορισμένα απ' τα πιο γνωστά δίκτυα.

1.4.1 Δίκτυα Hopfield

Χαρακτηριστικό παράδειγμα ανατροφοδοτούμενου (recurrent) δικτύου αποτελεί το δίκτυο Hopfield και παρουσιάζεται στο Σχήμα 1.6. Ένα δίκτυο Hopfield είναι μια μη-γραμμική, συσχετιστική μνήμη (autoassociative memory), ενός επιπέδου με συμμετρικούς πίνακες βαρών. Η βασική λειτουργία του είναι η ανάκτηση ενός προτύπου, που αποθηκεύτηκε σε αυτή τη μνήμη.



Σχήμα 1.6 – Δίκτυο Hopfield

Χαρακτηριστικά της δομής των δικτύων Hopfield:

- Αποτελούνται μόνο από ένα επίπεδο, με N υπολογιστικούς νευρώνες.
- Κάθε νευρώνας:
 - Στέλνει την έξοδο του στους άλλους νευρώνες
 - Δέχεται είσοδο από όλους τους άλλους νευρώνες (Μηχανισμός Ανάδρασης).
 - Όχι όμως και από τον εαυτό του.

Η μάθηση στα δίκτυα Hopfield γίνεται με επίβλεψη, με συνάρτηση μεταφοράς τη συνάρτηση προσήμου. Χρησιμοποιούνται σε προβλήματα βελτιστοποίησης. Στα ανατροφοδοτούμενα Τ.Ν.Δ. δεν υπάρχουν συνήθως άνω του ενός κρυφά επίπεδα. Αν και τα ανατροφοδοτούμενα δίκτυα (recurrent ANN) είναι πολύ χρήσιμα, τα περισσότερα νευρωνικά δίκτυα είναι πρόσθιας τροφοδότησης.

Η αρχιτεκτονική ενός δικτύου πρόσθιας τροφοδότησης (feed-forward) παρουσιάζεται στο Σχήμα 1.3. Περιλαμβάνει ένα μόνο επίπεδο εισόδου (I), ένα ή περισσότερα κρυφά επίπεδα (H) και μόνο ένα επίπεδο εξόδου (O) όπου η έξοδος (y) του δικτύου επιστρέφεται. Όπως φαίνεται στο Σχήμα 1.3, τα βέλη υπογραμμίζουν ότι η μετάδοση πληροφοριών λαμβάνει χώρα μόνο σε μία κατεύθυνση (προς τα εμπρός).


Καθώς τα πρότυπα των δικτύων είναι διαφορετικά, έτσι και η διαδικασία της μάθησης μπορεί να είναι διαφορετική. Τα πρόσθιας τροφοδότησης (FF) νευρωνικά δίκτυα είναι τα πλέον χρησιμοποιούμενα σε προβλήματα μηχανικής. Στην ενότητα 1.9 παρουσιάζεται μια σύντομη θεωρητική περιγραφή της μαθησιακής διαδικασίας, προκειμένου να επισημανθούν τα απαραίτητα βήματα και η ιδιαιτερότητα της μαθησιακής διαδικασίας.

1.4.2 Δίκτυα Kohonen (SOM)

Τα δίκτυα Kohonen, ή Αυτο-οργανούμενη Απεικόνιση Χαρακτηριστικών SOM (Self-organizing Feature Map), είναι δίκτυα δύο επιπέδων που μετατρέπουν τα n -διαστατά πρότυπα εισόδου σε δεδομένα χαμηλότερης τάξης και χρησιμοποιούνται για συμπίεση δεδομένων.

Το πρώτο επίπεδο είναι το επίπεδο εισόδου. Το δεύτερο επίπεδο είναι οργανωμένο σε μορφή πλέγματος, που μπορεί να έχει οποιαδήποτε διάσταση. Τα δύο αυτά επίπεδα έχουν πλήρη συνδεσμολογία. Ιδιαίτερη σημασία έχει η θέση των νευρώνων στο πλέγμα.

Τα δίκτυα Kohonen, βρίσκουν εφαρμογή στην αναγνώριση και την ταξινόμηση των προτύπων. Η εκπαίδευση τους γίνεται χωρίς επίβλεψη και μαθαίνουν να ξεχωρίζουν πρότυπα τα οποία διαφέρουν μεταξύ



1. Έχει αυστηρά 2 επίπεδα
2. Κάθε νευρώνας εισόδου συνδέεται με όλους του νευρώνες στο επίπεδο εξόδο

Σχήμα 1.7 – Δίκτυο Kohonen

τους.

1.4.3 Adaline (Adaptive Linear Neyrone) και Madaline (Multiple ADaptive LINear Elements)

Το Adaline⁵ (Adaptive Linear element) είναι από τα πιο απλά μοντέλα καθώς αποτελείται από ένα επίπεδο το οποίο περιέχει ένα μόνο νευρώνα. Αναπτύχθηκε για να αναγνωρίζει δυαδικά μοτίβα, όπως τις αλληλουχίες bits στις τηλεφωνικές γραμμές ώστε να είναι δυνατή η πρόβλεψη του επόμενου bit.

Χαρακτηρίζεται δηλαδή, απ' την ικανότητα εκμάθησης και ταξινόμησης ψηφιακών γραμμικών διαχωρίσιμων διανυσμάτων εισόδου. Στο Adaline δίνονται n -διάστατα διανύσματα εισόδου $\mathbf{x}$ μαζί με την επιθυμητή έξοδο $\mathbf{d}$. Σκοπός είναι τα συναπτικά βάρη w_i και το κατώφλι θ να προσαρμοσθούν, ώστε μετά την διαδικασία εκπαίδευσης η εμφάνιση ενός διανύσματος $\mathbf{x}$ στην είσοδο να δίνει έξοδο ίση με το $\mathbf{x}$ ⁶.

Για την εκμάθηση του δικτύου αρχικά χρησιμοποιήθηκε η μέθοδος του ελάχιστου τετραγωνικού σφάλματος, LMS (Least Mean Squares)

⁵Η διαφορά μεταξύ του perceptron (McCulloch-Pitts) και του Adaline εντοπίζεται στην διαδικασία εκπαίδευσης.

⁶Προσοχή απαιτείται στις αρχικές τιμές των βαρών καθώς πρέπει να είναι τυχαίες ώστε να μην παγιδευτεί ο αλγόριθμος εκπαίδευσης σε τυχόν τοπικά ελάχιστα του υπερχώρου των βαρών.

(κανόνας Δέλτα).

Μία επέκταση του Adaline είναι το Madaline (Multiple ADaptive LINear Elements) που δημιουργείται με την παράλληλη σύνδεση πολλών Adalines και χρησιμοποιήθηκε ως φίλτρο για να εξαλείψει την ηχώ σε τηλεφωνικές γραμμές (φιλτράρισμα δεδομένων). Γενικά, με το Madaline συσχετίζονται διανύσματα εισόδου με διανύσματα εξόδου. Βρίσκει εφαρμογή στην αναγνώριση φωνής, στην πρόβλεψη του καιρού κ.α.

Και τα 2 ανωτέρω μοντέλα ήταν απ' τα πρώτα που χρησιμοποιήθηκαν σε πρακτικά προβλήματα.

1.4.4 Δίκτυα πολλών επιπέδων (Multilayer Perceptron, M.L.P.)

Τα δίκτυα πολλών επιπέδων, χαρακτηρίζονται από ένα ή περισσότερα κρυφά επίπεδα. Σε κάθε επίπεδο μπορούν να οριστούν πολλοί διαφορετικοί νευρώνες. Η αρχιτεκτονική ενός feed-forward M.L.P. παρουσιάζεται στο Σχήμα 1.3, όπου επισημαίνονται τα διαφορετικά επίπεδα και οι νευρώνες. Σε αυτή την ιδιαίτερη και πιο σύνθετη αρχιτεκτονική, η οποία είναι πολύ χρήσιμη στην ανάλυση μη γραμμικών προβλημάτων, οι έξοδοι του κάθε επιπέδου γίνονται είσοδοι του επόμενου επιπέδου, επομένως οι πληροφορίες και η συνάρτηση σφάλματος επεξεργάζονται σε περισσότερα βήματα. Στην πλειοψηφία των εφαρμογών χρησιμοποιούνται δίκτυα πρόσθιας τροφοδότησης ενός κρυφού επιπέδου με πλήρως συνδεδεμένους νευρώνες.

1.4.5 RBFN (Radial Basis Function Network)

Το δίκτυο RBF (Datta & Tassou (1998)) είναι επίσης ένα εποπτευόμενο, feed-forward νευρωνικό δίκτυο με ένα κρυφό επίπεδο με νευρώνες (συνήθως τα δίκτυα RBF αποτελούνται από τρία επίπεδα: εισόδου, κρυφό και εξόδου. Το επίπεδο εξόδου με τη σειρά του αποτελείται από έναν γραμμικό νευρώνα). Μπορεί να χρησιμοποιηθεί για τους ίδιους τύπους προβλημάτων όπως το M.L.P., (για προσέγγιση

συνεχών συναρτήσεων, για πρόβλεψη χρονοσειρών, για ταξινόμηση και ελέγχο συστημάτων) αλλά διαφέρει από τα δίκτυα που βασίζονται σε perceptron με δύο τρόπους.

Πρώτον, οι έξοδοι που σχηματίζει το κρυφό επίπεδο δεν είναι απλώς το εσωτερικό γινόμενο των δεδομένων εισόδου και των βαρών, αλλά είναι το μέτρο του πόσο μακριά είναι τα δεδομένα από ένα κέντρο. Αυτό το κέντρο είναι η θέση του κόμβου σε ένα χωροταξικό σύστημα που ορίζεται από τα πεδία εισαγωγής των δεδομένων, γνωστά ως χώρος δεδομένων.

Δεύτερον, στο κρυφό επίπεδο οι συναρτήσεις μεταφοράς των κόμβων διέπονται από μη γραμμικές συναρτήσεις (ακτινικού τύπου). Αντίθετα στο επίπεδο εξόδου η συνάρτηση μεταφοράς είναι γραμμική. Αυτό έχει σαν αποτέλεσμα ένα γραμμικό συνδυασμό μη γραμμικών (ακτινικών) συναρτήσεων.

Η εκπαίδευση στο κρυφό επίπεδο αφορά στα κέντρα και στα εύρη των κρυφών νευρώνων και γίνεται με κάποια μέθοδο ομαδοποίησης (clustering), ενώ στο επίπεδο εξόδου στις τιμές των συναπτικών βαρών και γίνεται με κάποια μέθοδο εκπαίδευσης με επίβλεψη.

Το πλεονέκτημα του RBF είναι ότι η εκπαίδευση είναι πολύ πιο γρήγορη από ό,τι με το M.L.P. και ότι το RBF μπορεί να μοντελοποιεί τοπικά clustered data πιο εύκολα από ένα M.L.P. Οι αδυναμίες του RBF είναι η φτωχή του ικανότητα να αναπαράγει τις καθολικές ιδιότητες των δεδομένων και η δυσκολία του προσδιορισμού των βέλτιστων θέσεων των κέντρων των συναρτήσεων. Οι παράμετροι που πρέπει να ληφθούν υπόψη κατά την ανάπτυξη ενός δικτύου RBF είναι ο αριθμός των κέντρων που απαιτούνται για την ακριβή μοντελοποίηση των δεδομένων, η τοποθέτηση των κέντρων και ο τύπος της ακτινικής συνάρτησης.


Ο αριθμός των κέντρων εξαρτάται σε μεγάλο βαθμό από την πολυπλοκότητα του προβλήματος. Πολύ λίγα κέντρα έχουν ως αποτέλεσμα κακή απόδοση. Πολλά κέντρα έχουν ως αποτέλεσμα την υπερπροσαρμογή (over-fitting) των δεδομένων και κακή γενίκευση. Ο βέλτιστος αριθμός κέντρων προσδιορίζεται πειραματικά.

Το αρχικό RBF χρησιμοποίησε μια Gaussian συνάρτηση. Ωστόσο, υπάρχουν πολλές άλλες συναρτήσεις, συγκεκριμένα το spline, η πολυωνυμική και η αντίστροφη πολυωνυμική που μπορούν να χρησιμοποιηθούν.

1.4.6 Δίκτυα PNN (Probabilistic Neural Network)

Τα Πιθανοτικά Νευρωνικά Δίκτυα, PNN (Probabilistic Neural Network) είναι εποπτευόμενα νευρωνικά δίκτυα που λειτουργούν ως ταξινομητές προτύπων.

Η αρχιτεκτονική ενός PNN μοιάζει με αυτήν των Feed-forward δικτύων, παρόλο που περιορίζεται σε 4 επίπεδα, Σχήμα 1.8.



Σχήμα 1.8 – Δίκτυο PNN

- Το επίπεδο **εισόδου** έχει ένα νευρώνα για κάθε γνώρισμα του διανύσματος εισόδου.
- Το επίπεδο **προτύπων** έχει έναν νευρώνα προτύπου για κάθε πρότυπο εκπαίδευσης.

- Το επίπεδο **άθροισης** αθροίζει τα αποτελέσματα από τους νευρώνες προτύπων που συνδέονται με μια δεδομένη κατηγορία.
- Το επίπεδο **εξόδου** έχει τόσους νευρώνες όσες και οι υπάρχουσες κατηγορίες. Σε αυτό το επίπεδο επιλέγεται η κατηγορία με τη μεγαλύτερη τιμή εξόδου.

Τα δίκτυα PNN παράγουν μία αντιπροσωπευτική κατανομή πιθανότητας για κάθε κατηγορία (από τα παραδείγματα εκπαίδευσης) και μετά με χρήση του κανόνα απόφασης Bayes υλοποιούν την ταξινόμηση.

Συνήθως σαν συναρτήσεις βάσης επιλέγονται οι Γκαουσιανές συναρτήσεις (Gaussians).

Τα δίκτυα PNN ουσιαστικά βασίζονται στον Μπεϋζιανό⁷ ταξινομητή (Bayesian). Ενώ όμως ο ταξινομητής Bayes θεωρεί κανονικές τις κατανομές πιθανότητας των κλάσεων, τα νευρωνικά δίκτυα PNN εκτιμούν την κάθε μία Συνάρτηση Πυκνότητας Πιθανότητας (Probability Density Function-PDF) μέσω μη παραμετρικών μεθόδων.

Τα δίκτυα PNN χαρακτηρίζονται από γρήγορη διαδικασία εκπαίδευσης και τη δυνατότητα τους να παράγουν επίπεδα εμπιστοσύνης για τις αποφάσεις ταξινόμησής τους. Επομένως τα PNN δίκτυα, είναι ταξινομητές που συνδυάζουν μερικές από τις καλύτερες ιδιότητες της στατιστικής αναγνώρισης προτύπων και των πρόσθιας τροφοδότησης (Feed-forward) νευρωνικών δικτύων. Επιπλέον δεν κινδυνεύουν να παγιδευτούν σε τοπικά ελάχιστα και δεν επηρεάζονται από ακραία σημεία (outliers).

Στα μειονεκτήματα των PNNs είναι η μεγάλη απαίτηση σε μνήμη και υπολογιστικό χρόνο όταν αυξάνονται η διάσταση των δειγμάτων και το μέγεθος του συνόλου εκπαίδευσης.

Τα PNNs βρίσκουν εφαρμογή στην:

- αναγνώριση χαρακτήρων (character recognition),

⁷τεχνική που ελαχιστοποιεί το σφάλμα ταξινόμησης ενός προτύπου.

- αναγνώριση ομιλητών,
- μακροπρόθεσμη πρόβλεψη,

καθώς και σε άλλα προβλήματα ταξινόμησης προτύπων.

1.5 Συνάρτηση μεταφοράς (Transfer function)


Το αποτέλεσμα σε κάθε νευρώνα καθορίζεται από την συνάρτηση μεταφοράς ή συνάρτηση ενεργοποίησης. Υπολογίζει την έξοδο του δικτύου και εφαρμόζεται στο εσωτερικό γινόμενο των βαρών και των εισόδων. Συνήθως είναι μία μη γραμμική συνάρτηση, η οποία ενεργοποιεί ή κρατάει απενεργοποιημένο τον νευρώνα. Αυτό εξαρτάται από την τιμή της συνολικής εισόδου U (εσωτερικού γινομένου βαρών και εισόδων). Στη βιβλιογραφία προτείνονται και αναπτύσσονται πολλές διαφορετικές συναρτήσεις, (Πίνακας 1.1) αλλά οι πιο χρησιμοποιούμενες, ειδικά για εφαρμογές μηχανικής, είναι οι γραμμικές και οι σιγμοειδείς συναρτήσεις (sigmoid functions). Μεταξύ αυτών των δύο συναρτήσεων, προτείνονται οι σιγμοειδείς, επειδή μειώνουν τον υπολογιστικό χρόνο που απαιτείται για την ελαχιστοποίηση της συνάρτησης σφάλματος (βλ ενότητα 1.11.1).

1.6 Εκπαίδευση

Η διαδικασία μάθησης είναι ένα σημαντικό βήμα ως εκ τούτου πρέπει να αξιολογηθεί και να επιλεγεί σωστά, επειδή η αποτελεσματικότητα των Τ.Ν.Δ. επηρεάζεται κυρίως από αυτή τη διαδικασία. Γενικά, η επιλογή της μαθησιακής διαδικασίας εξαρτάται από το είδος του ερευνητικού αποτελέσματος ή από τους σκοπούς που αναμένονται από το Δίκτυο. Υπάρχουν τρία διαφορετικά είδη μάθησης:

1. *Επιβλεπόμενη Μάθηση*, (Supervised Learning): πρέπει να παρέχονται τόσο οι παράμετροι εισόδου όσο και οι έξοδοι (στόχοι) για την εκπαίδευση του Δικτύου. Χάρη στον αλγόριθμο μάθησης, π.χ. back-propagation, τα δεδομένα χρησιμοποιούνται για

να τροποποιήσουν τον πίνακα βαρών, ώστε να ελαχιστοποιηθεί το σφάλμα που επιστρέφεται από το Τ.Ν.Δ. (Σχήμα 1.9).



Σχήμα 1.9 – Εκπαίδευση με επίβλεψη με χρήση του αλγορίθμου μάθησης backpropagation

Χρησιμοποιείται σε προβλήματα:

- Ταξινόμησης (Classification)
- Πρόγνωσης (Prediction)

2. *Μη Επιβλεπόμενη Μάθηση*, (Unsupervised Learning): παρέχονται μόνο τα δεδομένα εισόδου, επομένως τα βάρη τροποποιούνται χρησιμοποιώντας μόνο αυτού του είδους τις πληροφορίες. Αυτός ο τύπος αλγόριθμου προσπαθεί να ομαδοποιήσει τα δεδομένα εισόδου και να προσδιορίσει τα κατάλληλα συμπλέγματα (clusters).

Χρησιμοποιείται σε προβλήματα:

- Ομαδοποίησης (Clustering)
- Ανάλυσης Συσχετισμών (Association Analysis)

Παράδειγμα Τ.Ν.Δ. που εφαρμόζεται η μη επιβλεπόμενη εκπαίδευση είναι το δίκτυο Kohonen (βλ. ενότ. 1.4.2).

3. *Μάθηση με ενίσχυση*, (Reinforcement Learning): δεν παρέχονται δεδομένα στο δίκτυο, αλλά είναι σε θέση να αλληλεπιδρά με το

περιβάλλον το οποίο ανταποκρίνεται μέσω θετικών ή αρνητικών ερεθισμάτων. Αυτές οι αποκρίσεις οδηγούν τον αλγόριθμο κατά τη διάρκεια της εκπαίδευσης.


Μεταξύ αυτών των μεθόδων, η πιο σύνθετη είναι η τελευταία (μάθηση με ενίσχυση), αλλά παρέχει πιο ρεαλιστικό και πιο ευέλικτο δίκτυο σε σχέση με τις άλλες διαδικασίες μάθησης.

Ο τρόπος που αλλάζουν τα βάρη κατά την εκπαίδευση ενός T.N.Δ. αποτελεί σημαντικό στοιχείο της αρχιτεκτονικής του και υλοποιείται απ' το ίδιο το δίκτυο. Οι πιο γνωστοί αλγόριθμοι μάθησης είναι:


- Αλγόριθμος οπισθοδιάδοσης λάθους (Backpropagation),
- Ανταγωνιστική μάθηση (Competitive learning),
- Τυχαία μάθηση (Random learning).

1.7 Data set

Για την εκμάθηση ενός καθορισμένου δικτύου (επιβλεπόμενης εκπαίδευσης) το σύνολο δεδομένων (Data set) χωρίζεται σε 2 ανεξάρτητα υποσύνολα (Σχήμα 1.10 -1.11).



Σχήμα 1.10 – Εκπαίδευση σε καθορισμένο δίκτυο



Σχήμα 1.11 – Χωρισμός του συνόλου δεδομένων (Data set) σε 2 ανεξάρτητα υποσύνολα

- Στο σύνολο εκπαίδευσης (*Training set*): ένα σύνολο προτύπων που χρησιμοποιείται αποκλειστικά για την εκπαίδευση του δικτύου (π.χ. για τον υπολογισμό των βαρών) και
- στο σύνολο δοκιμής (*Test set*): ένα σύνολο προτύπων το οποίο δεν επηρεάζει καθόλου τη διαδικασία εκπαίδευσης και χρησιμοποιείται μόνο για να αξιολογήσει την απόδοση ενός πλήρως εκπαιδευμένου δικτύου.


Συνήθως το training set αποτελεί τα $2/3$ του συνόλου δεδομένων και το test set το υπόλοιπο $1/3$.

Προφανώς όσο περισσότερα προτύπα εκπαίδευσης παροχετεύονται στο δίκτυο τόσο καλύτερη εκπαίδευση επιτυγχάνεται. Είναι σημαντικό η επιλογή των προτύπων να περιέχει τα σημαντικά χαρακτηριστικά γνωρίσματα (attributes) ώστε να επιτευχθεί η γενίκευση. Η εκπαίδευση θεωρείται πλήρης όταν φθάνει το νευρωνικό δίκτυο σε επίπεδο απόδοσης που έχει καθορίσει ο χρήστης.


Από το σύνολο εκπαίδευσης υπολογίζεται το σφάλμα εκπαίδευσης που δείχνει πόσο καλά προσεγγίζει το μοντέλο τα πρότυπα εκπαίδευσης με τα οποία εκπαιδεύτηκε ενώ απ' το σύνολο δοκιμής υπολογίζεται το σφάλμα ελέγχου που δείχνει πόσο καλά γενικεύει το μοντέλο σε νέα πρότυπα ελέγχου.

Στην περίπτωση όπου δεν έχει καθοριστεί το μοντέλο που θα χρησιμοποιηθεί, τότε το Data set χωρίζεται και σε ένα τρίτο σύνολο (Σχήμα 1.12 - 1.13).

Το σύνολο επικύρωσης (*Validation set*): πρόκειται για ένα σύνολο προτύπων για τη βέλτιστη ρύθμιση των παραμέτρων του ταξινομητή (π.χ. εύρεση βέλτιστου αριθμού νευρώνων). Από το σύνολο επικύρωσης υπολογίζεται το σφάλμα επικύρωσης το οποίο χρησιμοποιείται για τη διακοπή του αλγορίθμου όταν αυτό αυξάνει για ένα αριθμό βημάτων Σχήμα 1.14.



Σχήμα 1.12 – Εκπαίδευση σε μη καθορισμένο δίκτυο




Σχήμα 1.13 – Χωρισμός του συνόλου δεδομένων (Data set) σε 3 ανεξάρτητα υποσύνολα

1.8 Γενίκευση δικτύου (Generalization)

Στόχος της διαδικασίας της εκπαίδευσης ενός αλγορίθμου είναι η ελαχιστοποίηση μίας συνάρτησης κόστους (cost function) η οποία μετράει το ποσοστό σφάλματος (error rate) μεταξύ των προβλεπομένων και των πραγματικών τιμών. Υπό αυτήν την έννοια, η διαδικασία της εκπαίδευσης μπορεί να χαρακτηριστεί ως ένα πρόβλημα βελτιστοποίησης με αντικειμενικό σκοπό όμως την γενίκευση (generalization) του μοντέλου, να έχει δηλαδή το T.N.Δ. καλή απόκριση όταν του παρέχονται άγνωστες σε αυτό είσοδοι. Σχήματα 1.18 και 1.21. Για το λόγο αυτό η παραγόμενη συνάρτηση κατά την εκπαίδευση δεν πρέπει να είναι απόλυτα προσαρμοσμένη στα δεδομένα εκπαίδευσης.

Έτσι προκειμένου να επιτευχθεί ο σκοπός της γενίκευσης θα πρέπει να υπάρχει ισορροπία μεταξύ της πόλωσης και της διακύμανσης.

- **Πόλωση (Bias):** είναι ένα μέτρο που δείχνει πόσο μακριά είναι οι εκτιμώμενες τιμές του μοντέλου από τις πραγματικές τιμές. Πρόκειται για το λάθος από εσφαλμένες υποθέσεις στον αλγόριθμο μάθησης.



Σχήμα 1.14 – Σημείο διακοπής αλγορίθμου

- **Διακύμανση (Variance):** αναφέρεται στην αλλαγή στις εκτιμήσεις παραμέτρων σε διαφορετικά σύνολα δεδομένων. Είναι το σφάλμα από την ευαισθησία στις μικρές διακυμάνσεις στο σύνολο εκπαίδευσης.


Το άθροισμα αυτών των δύο σφαλμάτων συνθέτει το σφάλμα γενίκευσης (ολικό σφάλμα) κατά την απόκριση του δικτύου. Γενικά ισχύει ότι:

$$GeneralizationError = Bias^2 + Variance + Noise \quad (1.1)$$

όπου: Noise ο «θόρυβος» ανάμεσα στην πραγματική σχέση μεταξύ εισόδων και εξόδων.

Υψηλή πόλωση μπορεί να οδηγήσει στο πρόβλημα της υποπροσαρμογής των δεδομένων ενώ υψηλή διακύμανση στο πρόβλημα της υπερπροσαρμογής.

Αναλυτικότερα:




Σχήμα 1.15 – Σχέση της πόλωσης και της διακύμανσης με το ολικό σφάλμα και την πολυπλοκότητα του δικτύου


- *Υπερπροσαρμογή (overfitting)*, το μοντέλο καταγράφει το θόρυβο των δεδομένων, χαρακτηρίζεται από μεγάλη διακύμανση αλλά χαμηλή πόλωση.
- *Υποπροσαρμογή (underfitting)*, το μοντέλο δεν μπορεί να καταγράψει την τάση των δεδομένων, χαρακτηρίζεται από χαμηλή διακύμανση αλλά υψηλή πόλωση.

Στα Σχήματα 1.16 - 1.21 δείχνεται η περίπτωση ενός μοντέλου παλινδρόμησης και ενός ταξινομητή.

Γενικά η ικανότητα γενίκευσης ενός νευρωνικού δικτύου, εκτός από την επάρκεια του συνόλου εκπαίδευσης, εξαρτάται από την αρχιτεκτονική και τη δομή, οι οποίες πρέπει να επιτρέπουν την κατασκευή μια επαρκούς αναπαράστασης του χώρου.



Σχήμα 1.16 – Regression: Underfitting Σχήμα 1.17 – Regression: Overfitting




Σχήμα 1.18 – Regression: Καλή προσαρμογή

1.9 Δίκτυα πρόσθιας τροφοδότησης (Feed-forward, FF): Διαδικασία της μάθησης


Τα πιο εφαρμοσμένα και χρησιμοποιημένα Τ.Ν.Δ. σε εφαρμογές μηχανικής είναι τα νευρωνικά δίκτυα πρόσθιας τροφοδότησης (FF), πιθανώς λόγω της ευκολότερης εφαρμογής τους σε σχέση με τα άλλα. Όταν υλοποιείται ένα feed-forward νευρωνικό δίκτυο, διαφορετικοί τύποι διαδικασιών μάθησης είναι δυνατόν να εφαρμοστούν. Ωστόσο, κάθε διαδικασία μάθησης βασίζεται στην ίδια μεθοδολογία και θεωρία.

Θα περιγραφούν οι κύριες έννοιες που επηρεάζουν τις διαφορετικές διαδικασίες μάθησης, όμως, για μία πιο εμπειριστατωμένη μελέτη, μπορεί να ανατρέξει κανείς στα (Haykin (1999); Hagan et al. (2014)).

Η μέθοδος της διαδικασίας μάθησης δεν εξαρτάται ούτε από τον αριθμό των επιπέδων που ορίζονται απ' την τοπολογία του δικτύου ούτε από τον αριθμό των νευρώνων. Αυτές οι δύο παράμετροι μπορούν



Σχήμα 1.19 – Classification: Underfitting Σχήμα 1.20 – Classification: Overfitting




Σχήμα 1.21 – Classification: Καλή προσαρμογή

στην πραγματικότητα να επηρεάσουν μόνο τον χρόνο που απαιτείται για τη διαδικασία της μάθησης, αλλά όχι τη μεθοδολογία της μάθησης.

Ενώ η μαθησιακή διαδικασία δεν διαφέρει ανάλογα με τον τύπο του δικτύου, μπορεί να είναι χρήσιμο να εξεταστεί το ευκολότερο μοντέλο για να εξηγηθεί καλύτερα η διαδικασία μάθησης ενός feed-forward δικτύου. Το ευκολότερο πρότυπο feed-forward δικτύου φαίνεται στο Σχήμα 1.22 και αποτελείται μόνο από έναν νευρώνα (perceptron), με n συνδέσεις και n παραμέτρους εισόδου, και μόνο μία σύνδεση με την έξοδο. Στο Σχήμα 1.22 παρουσιάζονται επίσης όλες οι παράμετροι που επηρεάζουν και χαρακτηρίζουν κάθε νευρώνα του Τ.Ν.Δ.: το δυναμικό ενεργοποίησης (v), η συνάρτηση μεταφοράς, (ϕ) και η τιμή κατωφλίου ($x_0 = \theta$), η οποία επιτρέπει την ενεργοποίηση του νευρώνα. Το δυναμικό ενεργοποίησης (v), επιτρέπει στον νευρώνα να επεξεργαστεί τις σταθμισμένες πληροφορίες που προέρχονται από το επίπεδο εισόδου, ενώ η συνάρτηση μεταφοράς (ϕ) επιτρέπει τον

υπολογισμό της εξόδου λαμβάνοντας υπόψη το δυναμικό ενεργοποίησης του νευρώνα. Επιπλέον, κάθε δεδομένο εισόδου συνδέεται με τον νευρώνα μέσω μιας μόνο σύνδεσης, που χαρακτηρίζεται από ένα βάρος (w_i) το οποίο εφαρμόζεται στις πληροφορίες που παρέχονται από την είσοδο (x_i).



Σχήμα 1.22 – Perceptron: η ευκολότερη αρχιτεκτονική ενός F.F. νευρωνικού δικτύου.

Λαμβάνοντας υπόψη το σχήμα που παρουσιάζεται στο Σχήμα 1.22, οι πληροφορίες που προέρχονται από το επίπεδο εισόδου σταθμίζονται από τα βάρη w_i των συνδέσεων και διορθώνονται από το κατώφλι (θ) του νευρώνα. Εν συνεχεία υπολογίζεται το δυναμικό ενεργοποίησης (v), και στη συνέχεια μεταφέρεται στο επίπεδο εξόδου (ϕ). Επομένως, η έξοδος (y) που επιστρέφεται από το δίκτυο υπολογίζεται με την ακόλουθη εξίσωση:

$$y = \phi\left(\sum_{i=1}^n w_i \cdot x_i - \theta\right) \quad (1.2)$$

Η διαδικασία μάθησης του T.N.Δ. συνίσταται στη διόρθωση των βαρών της σύνδεσης μεταξύ των παραμέτρων εισόδου και του νευρώνα, μέχρις ότου επιτευχθεί η επιθυμητή έξοδος (στόχος). Όταν υιοθετείται μια μέθοδος με επίβλεψη, ο αλγόριθμος που χρησιμοποιείται για τη διαδικασία μάθησης είναι ο κανόνας Δέλτα (Delta rule), ο οποίος επιτρέπει την ελαχιστοποίηση της συνάρτησης σφάλματος. Η συνάρτηση σφάλματος (E) (βλ. MSE, ενότητα 1.11.1) υπολογίζεται ως η τετραγωνική διαφορά μεταξύ του παρεχόμενου στόχου (d_c), δηλαδή της επιθυμητής εξόδου και του αποτελέσματος που επέστρεψε το Δίκτυο (y_c), για το Δίκτυο που παρουσιάζεται στο Σχήμα 1.22 μπορεί να υπολογιστεί από την εξίσωση:

$$E = \frac{1}{2} \sum_{c=1}^s (d_c - y_c)^2 \quad (1.3)$$

Με βάση το παραγόμενο σφάλμα ($d_c - y_c$) πραγματοποιούνται μεταβολές στα βάρη και στις πολώσεις του δικτύου. Στόχος αυτών των μεταβολών είναι η έξοδος του δικτύου να προσεγγίσει σταδιακά την επιθυμητή έξοδο-στόχο. Αυτό πραγματοποιείται με την ελαχιστοποίηση της συνάρτησης 1.3. Αυτή η σταδιακή μεταβολή των βαρών συνεχίζεται μέχρι το σύστημα να φτάσει σε μία κατάσταση κατά την οποία οι μεταβολές στα βάρη του, γίνονται πολύ μικρές, οπότε η διαδικασία μάθησης του δικτύου τερματίζεται.

Η μεταβολή του βάρους δίνεται απ' τη σχέση (1.4)

$$\Delta w_i = -n \cdot \frac{\partial E}{\partial w_i} \quad (1.4)$$

Όπου n ($0 < n < 1$) ο ρυθμός μάθησης, ο οποίος χαρακτηρίζει τη μαθησιακή διαδικασία του νευρώνα.

Μετά τον προσδιορισμό της μεταβολής το νέο βάρος είναι:

$$w_i(t+1) = \Delta w_i + w_i(t) \quad (1.5)$$

Η ευστάθεια⁸ αυτού του συστήματος εξαρτάται άμεσα από την παράμετρο που ορίσαμε πριν ως ρυθμό μάθησης η . Μικρή τιμή του η μπορεί να καθυστερήσει πολύ τη διαδικασία και να οδηγήσει σε πολύ αργή σύγκλιση. Αντίθετα, πολύ υψηλή τιμή του η μπορεί να προκαλέσει αστάθεια του αλγορίθμου με αποτέλεσμα τη μη επίτευξη σύγκλισης. Για αυτό το λόγο απαιτείται προσεκτική επιλογή της τιμής του ρυθμού μάθησης που θα χρησιμοποιηθεί καθώς ο ρόλος του είναι πολύ σημαντικός για την απόδοση του αλγορίθμου.

1.10 Δίκτυα M.L.P.: Διαδικασία της μάθησης

Η ίδια επαναληπτική διαδικασία μπορεί να εφαρμοστεί τόσο στο ευκολότερο πρότυπο (όπως αυτό που ήδη περιγράφηκε) όσο και σε πιο περίπλοκα δίκτυα, όπως τα M.L.P. (εξίσωση 1.5). Για το δίκτυο M.L.P. (MultiLayer Perceptron network), η μεθοδολογία που περιγράφηκε προηγουμένως ονομάζεται μάθηση με οπισθοδιάδοση σφάλματος (Back Error Propagation) και είναι ο πιο συνηθισμένος αλγόριθμος που χρησιμοποιείται για τη διαδικασία εκμάθησης ενός feed-forward M.L.P. Τα πολυεπίπεδα T.N.Δ. στα οποία ακολουθείται αυτή η μέθοδος εκπαίδευσης, καλούνται Backpropagation T.N.Δ. (Backpropagation ANN).

Η μάθηση με οπισθοδιάδοση σφάλματος (Back Error Propagation) είναι μια αργή διαδικασία μάθησης, επομένως διαφορετικές παραλλαγές αυτής της μεθόδου έχουν προταθεί στη Βιβλιογραφία. Αυτές οι μεθοδολογίες ονομάζονται Νευτώνιοι αλγόριθμοι και επιτρέπουν την προσέγγιση της διαδικασίας που περιγράφηκε προηγουμένως, προκειμένου να επιταχυνθεί η διαδικασία μάθησης του T.N.Δ.

Μεταξύ των Νευτώνιων αλγορίθμων, ο περισσότερο χρησιμοποιούμενος στις εφαρμογές της μηχανικής είναι ο Levenberg-Marquardt,

⁸Η συγκεκριμένη εκπαίδευση αποτελεί ένα παράδειγμα συστήματος με ανάδραση κλειστού βρόχου (βλ. Σχήμα 1.9).

που είναι η ταχύτερη μέθοδος που μπορεί να βρεθεί στη Βιβλιογραφία για την εκπαίδευση ενός πρόσθιας τροφοδότησης (FF) νευρωνικού δικτύου.

Τέλος σημαντικός παράγοντας που μπορεί να επηρεάσει την ταχύτητα της μαθησιακής διαδικασίας είναι η επιλογή της συνάρτησης μεταφοράς (φ).

1.11 Μέτρα αξιολόγησης μοντέλων - Σφάλματα

Μετά την κατασκευή ενός μοντέλου, πρέπει να αξιολογηθεί η ποιότητα του αποτελέσματος που επιτυγχάνεται. Τα σφάλματα του συνόλου εκπαίδευσης δεν είναι κατάλληλα γιατί βασίζονται στα δεδομένα εκπαίδευσης. Συνήθως, χρησιμοποιείται ένα σύνολο ελέγχου.

1.11.1 Συναρτήσεις σφάλματος ή κόστους

Για την αξιολόγηση της ικανότητας και της αξιοπιστίας των Τ.Ν.Δ. χρησιμοποιούνται οι συναρτήσεις σφάλματος (στατιστικοί δείκτες), ώστε να υπολογιστούν τα σφάλματα των μοντέλων. Ως γνωστόν κατά την εκπαίδευση αλλάζουν οι εσωτερικές παράμετροι με σκοπό να ελαχιστοποιήσουν τη συνάρτηση σφάλματος. Όσο μικρότερη γίνεται η τιμή της συνάρτησης σφάλματος, τόσο ακριβέστερη είναι η παραγόμενη έξοδος. Τα σφάλματα υπολογίζονται από διάφορες μαθηματικές σχέσεις, καθένα από τα οποία παρέχει διαφορετική πληροφορία. Υπάρχουν διάφορες συναρτήσεις σφάλματος για τις περιπτώσεις των νευρωνικών δικτύων (Haykin (1999); Theodoridis & Koutroumbas (2009)).

Συννηθισμένες συναρτήσεις σφάλματος είναι το μέσο απόλυτο σφάλμα και το απόλυτο τετραγωνικό σφάλμα.

Μέσο απόλυτο σφάλμα (Mean Absolute Error, MAE)

Αυτό το μέτρο δείχνει πόσο καλά προσεγγίζει το μοντέλο τα παραδείγματα (εκπαίδευσης ή ελέγχου) αλλά απαλείφει την έμφαση που δίνεται από τον τετραγωνισμό του MSE στα μεγάλα σφάλματα:

$$MAE = \underbrace{\frac{1}{\# \text{ of patterns}}}_{\text{μέσος όρος}} \sum_{i=1}^{\# \text{ of patterns}} \overbrace{|\mathbf{y}^i - \phi(\mathbf{x}^i)|}^{\text{σφάλμα}} \quad (1.6)$$

όπου: $\mathbf{y}$, η πραγματική έξοδος και
 $\phi(\mathbf{x})$, η παραγόμενη (εκτιμώμενη) έξοδος.

Μέσο τετραγωνικό σφάλμα (Mean Square Error, MSE)

Σχεδόν όλοι οι αλγόριθμοι εκπαίδευσης των feed-forward νευρωνικών δικτύων καθώς και πολλών άλλων αρχιτεκτονικών ελαχιστοποιούν αυτό το μέτρο κόστους. Το MSE δείχνει πόσο καλά προσεγγίζει το μοντέλο μας τα N πρότυπα (εκπαίδευσης ή ελέγχου).

$$MSE = \underbrace{\frac{1}{N} \sum_{i=1}^N}_{\text{μέσος όρος}} \overbrace{[\mathbf{y}^i - \phi(\mathbf{x}^i)]^2}^{\text{σφάλμα}} \quad (1.7)$$

Όταν ένα μοντέλο έχει N εξόδους $\phi_j(\mathbf{x}^i)$ για L κλάσεις τότε το MSE θα είναι ο μέσος όρος των MSE των L εξόδων.

$$MSE = \frac{1}{N} \cdot \frac{1}{L} \sum_{i=1}^N \sum_{j=1}^L [\mathbf{y}^i - \phi(\mathbf{x}^i)]^2 \quad (1.8)$$

Τετραγωνική ρίζα μέσου τετραγωνικού σφάλματος (Root Mean Squared Error, RMSE)

Το RMSE έχει το πλεονέκτημα σε σχέση με το MSE να τιμωρεί μεγάλα σφάλματα, ώστε να είναι πιο ενδεδειγμένο σε μερικές περιπτώ-

σεις. Δεδομένου ότι τα σφάλματα τετραγωνίζονται προτού καταμετρηθούν, το RMSE δίνει ένα σχετικά μεγάλο βάρος σε μεγάλα σφάλματα. Αυτό σημαίνει ότι το RMSE είναι πιο χρήσιμο απ' το MSE, όταν μεγάλα σφάλματα είναι ιδιαίτερα ανεπιθύμητα.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N [y^i - \phi(\mathbf{x}^i)]^2} \quad (1.9)$$

Μέσο απόλυτο ποσοστιαίο σφάλμα (Mean Absolute Percentage Error, MAPE)

Το μέσο απόλυτο ποσοστιαίο σφάλμα (MAPE) είναι το πιο κοινό μέτρο του σφάλματος πρόβλεψης. Λειτουργεί καλύτερα όταν δεν υπάρχουν ακραίες τιμές στα δεδομένα (συμπεριλαμβανομένων των μηδενικών). Με μηδενικές ή σχεδόν μηδενικές τιμές στα δεδομένα, το MAPE μπορεί να δώσει μια παραμορφωμένη εικόνα σφάλματος. Το σφάλμα σε ένα σχεδόν μηδενικό στοιχείο μπορεί να είναι απεριόριστα υψηλό, προκαλώντας στρέβλωση του συνολικού ποσοστού σφάλματος. Για προβλέψεις στοιχείων που οι τιμές τους είναι κοντά στο μηδέν ή είναι μηδέν, το συμμετρικό μέσο απόλυτο ποσοστιαίο σφάλμα (sMAPE) είναι καλύτερη μετρική.

Το MAPE είναι ο μέσος όρος του απόλυτου ποσοστού σφάλματος:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y^i - \phi(\mathbf{x}^i)}{y^i} \right| \cdot 100\% \quad (1.10)$$

Συμμετρικό μέσο απόλυτο ποσοστιαίο σφάλμα (Symmetric Mean Absolute Percentage Error, sMAPE)

Το συμμετρικό μέσο απόλυτο ποσοστιαίο σφάλμα (sMAPE) είναι μία εναλλακτική λύση έναντι του μέσου απόλυτου ποσοστιαίο σφάλματος (MAPE) όταν υπάρχουν μηδενικές ή σχεδόν μηδενικές τιμές στα στοιχεία. Το sMAPE περιορίζει την επίδραση των (σχεδόν) μηδενικών στοιχείων τα οποία είναι προβληματικά επειδή οι υψηλές τιμές

τους μπορούν να εξουδετερώσουν το συνολικό ποσοστό σφάλματος.

$$sMAPE = \frac{2}{N} \sum_{i=1}^N \left| \frac{\mathbf{y}^i - \phi(\mathbf{x}^i)}{\mathbf{y}^i + \phi(\mathbf{x}^i)} \right| \cdot 100\% \quad (1.11)$$

Μέσο σφάλμα εκτίμησης (Mean Bias Error, MBE)

Το μέσο σφάλμα εκτίμησης, MBE εκφράζει την μέση απόκλιση του μοντέλου υπολογίζοντας το συστηματικό σφάλμα.

$$MBE = \frac{1}{N} \sum_{i=1}^N \frac{\phi(\mathbf{x}^i) - \mathbf{y}^i}{\mathbf{y}^i} \quad (1.12)$$

Μέση απόλυτη απόκλιση (Average Absolute Deviation, AAD ή Mean Absolute Deviation, MAD)

Η μέση απόλυτη απόκλιση, MAD ενός συνόλου δεδομένων είναι ο μέσος όρος των απόλυτων αποκλίσεων από ένα κεντρικό σημείο.

$$MAD = AAD = \frac{1}{N} \sum_{i=1}^N |\mathbf{x}_i - \bar{\mathbf{x}}| \quad (1.13)$$

Συντελεστής προσδιορισμού (Coefficient of determination, R^2)

Η συντελεστής προσδιορισμού, R^2 είναι ένα μέτρο της γραμμικής συσχέτισης μεταξύ των παρατηρήσεων και των προσδοκώμενων τιμών.

$$R^2 = \frac{1}{N} \sum_{i=1}^N (\mathbf{x}_i - \bar{\mathbf{x}})^2 \quad (1.14)$$

Συνάρτηση κόστους διασταυρωμένης εντροπίας (Cross-Entropy Error, CEE)

Στην εργασία της κατηγοριοποίησης με νευρωνικά δίκτυα, όταν η έξοδος είναι δυαδικές τιμές 0 ή 1, τότε μία διαφορετική συνάρτηση

κόστους μπορεί να χρησιμοποιηθεί, η συνάρτηση κόστους διασταυρωμένης εντροπίας. Αυτή η συνάρτηση γενικεύεται και σε περισσότερες L εξόδους που παράγουν 1 ή 0 για κάθε j κλάση και δίνεται από τη σχέση:

$$CEE = \frac{1}{N} \sum_{i=1}^N \sum_{j=1}^L (\mathbf{y}^i) \cdot \ln(\phi(\mathbf{x}^i)) \quad (1.15)$$

όπου πάλι $f_j(\mathbf{x}^i)$ είναι η έξοδος j και $\mathbf{y}^i$ η επιθυμητή έξοδος.

1.11.2 Πίνακας σύγχυσης (Confusion Matrix)

Στον τομέα της μηχανικής μάθησης και ειδικότερα στη στατιστική ταξινόμηση, ένας πίνακας σύγχυσης, ή μήτρα σφάλματος, είναι ένας ειδικός πίνακας που δίνει μια σύνοψη των αποτελεσμάτων πρόβλεψης ενός αλγορίθμου, συνήθως εποπτευόμενης⁹ μάθησης. Δείχνει ταυτόχρονα, όχι μόνο τα σφάλματα που κάνει ο ταξινομητής αλλά κυρίως τους τύπους των σφαλμάτων. Πρόκειται για πίνακα 2 διαστάσεων («πραγματικό» και «προβλεπόμενο»). Κάθε στήλη του πίνακα αντιπροσωπεύει τις περιπτώσεις σε μια προβλεπόμενη κλάση ενώ κάθε γραμμή αντιπροσωπεύει τις περιπτώσεις σε μια πραγματική κλάση. Το όνομα «πίνακας σύγχυσης» πηγάζει από το γεγονός ότι καθίσταται εύκολη η απεικόνιση της σύγχυσης που το σύστημα προκαλεί σε δύο κατηγορίες.

Όταν υπάρχουν πολλές κλάσεις η παραδοσιακή τεχνική εξέτασης του πίνακα σύγχυσης (Witten et al. (2016)) είναι πολύ πληροφοριακή, για όλα τα είδη αλγορίθμων των ταξινομητών.

όπου:

- Τα αληθώς θετικά στιγμιότυπα, TP (true positive), που ο αλγόριθμος τα ταξινόμησε σωστά.

⁹Στις περιπτώσεις μη εποπτευόμενης μάθησης, ο πίνακας συνήθως ονομάζεται μήτρα αντιστοιχίας.

	Predicted Yes	Predicted No		
Actual Yes	TP True Positive	FN False Negative	Recall=TPR= $\frac{TP}{TP+FN}$	FNR= $\frac{FN}{TP+FN}$
Actual No	FP False Positive	TN True Negative	Specificity=TNR= $\frac{TN}{TN+FP}$	FPR= $\frac{FP}{TN+FP}$
	Precision=PPV= $\frac{TP}{TP+FP}$		Accuracy=ACC= $\frac{TP+TN}{TP+TN+FP+FN}$	
			Error Rate= $\frac{FP+FN}{TP+TN+FP+FN}$	

Σχήμα 1.23 – Παράδειγμα Confusion matrix και μετρικές με βάση τον Πίνακα Σύγκυσης

- Τα ψευδώς αρνητικά στιγμιότυπα, FN (false negative), που ο αλγόριθμος τα ταξινομήσε λανθασμένα.
- Τα ψευδώς θετικά στιγμιότυπα, FP (false positive), που ο αλγόριθμος τα ταξινομήσε λανθασμένα.
- Τα αληθώς αρνητικά στιγμιότυπα, TN (true negative), που ο αλγόριθμος τα ταξινομήσε σωστά.

Ο πίνακας στο Σχήμα 1.23 εφαρμόζεται σε προβλήματα δύο κλάσεων. Σύμφωνα με τα στιγμιότυπα, ο αριθμός τελικά που προβλέπονται σωστά είναι το άθροισμα των TP και TN, ενώ αυτά που προβλέπονται λανθασμένα είναι τα FP και FN.

1.11.3 Άλλες μετρικές με βάση τον Πίνακα Σύγκυσης

Παρόλο που ο πίνακας σύγκυσης (Σχήμα 1.23) παρέχει την πληροφορία που απαιτείται για να αξιολογηθεί το μοντέλο, πολλές φορές είναι προτιμότερο η πληροφορία να εκφραστεί με έναν μοναδικό αριθμό που είναι πιο εύχρηστο για τις συγκρίσεις μεταξύ διαφόρων μοντέλων.

Αυτό μπορεί να πραγματοποιηθεί χρησιμοποιώντας μετρικές απόδοσης. Τα περισσότερα μέτρα απόδοσης μπορούν να εκφραστούν σε σχέση με τον αριθμό των αληθώς θετικών (True Positives), αληθώς αρνητικών (True Negatives TN), ψευδώς θετικών (False Positives FP), και ψευδώς αρνητικών (False Negative FN) ταξινομήσεων που αφορούν την κάθε κλάση.

Η ακρίβεια (precision) και η ανάκληση (recall) είναι δύο δημοφιλείς μετρικές για την αξιολόγηση μεθόδων ταξινόμησης δανεισμένες από το χώρο της ανάκτησης πληροφορίας.

Ακρίβεια (Precision ή positive predictive value (PPV))

Η ακρίβεια (Witten et al. (2016)) σε σχέση με μία κλάση c , είναι η πιθανότητα του γεγονότος να επιλεγεί τυχαία ένα αντικείμενο o , που έχει ταξινομηθεί στην κλάση c και να είναι σωστή αυτή η ταξινόμηση. Δηλαδή εκφράζει το ποσοστό των δειγμάτων που ο ταξινομητής έχει ταξινομήσει ως θετικά είναι πραγματικά θετικά.

$$Precision = PPV = \frac{TP}{TP + FP} \quad (1.16)$$

Όσο μεγαλύτερη είναι η ακρίβεια, τόσο μικρότερος είναι ο αριθμός των FP.

Ανάκληση (Recall ή Sensitivity, ή true positive rate (TPR))

Η ανάκληση σε σχέση με μία κλάση c , είναι η πιθανότητα του γεγονότος ένα τυχαίο αντικείμενο o της τάξης c , όντως να ταξινομήθηκε σε αυτήν την κλάση. Δηλαδή εκφράζει το ποσοστό των θετικών δειγμάτων που ο ταξινομητής κατάφερε να βρει.

$$Recall = TPR = \frac{TP}{TP + FN} \quad (1.17)$$

Όσο μεγαλύτερη είναι η ανάκληση, τόσο λιγότερα θετικά δείγματα έχουν ταξινομεί λάθος (=TPR).

Ένας ταξινομητής που τα ταξινομεί όλα τα δείγματα ως θετικά έχει την καλύτερη ανάκληση με τη χειρότερη ακρίβεια.

F-measure

Η μετρική F-measure (Witten et al. (2016)) αποτελεί το συνδυασμό της ανάκλησης και της ακρίβειας. Είναι ο αρμονικός μέσος (Harmonic mean) αυτών των δύο μετρικών και δίνεται απ' τη σχέση:

$$F = \frac{2 \cdot recall \cdot precision}{recall + precision} = \frac{2TP}{2TP + FP + FN} \quad (1.18)$$

Γενικά, τείνει να είναι πιο κοντά στο μικρότερο από τα δύο. Υψηλή τιμή της μετρικής F-measure σημαίνει ότι και τα δύο (precision, recall) είναι ικανοποιητικά μεγάλα.

Ιδιαιτερότητα (Specificity, SPC ή True Negative Rate, TNR)

Το ποσοστό των αρνητικών δειγμάτων που κατηγοριοποιούνται σωστά, δίνεται απ' τη σχέση:

$$SPC = TNR = \frac{TN}{TN + FP} = 1 - FPR \quad (1.19)$$

Ποσοστό ψευδώς θετικών αποτελεσμάτων (False Positive Rate, FPR)

Το ποσοστό των αρνητικών δειγμάτων που κατηγοριοποιούνται λάθος (δηλαδή, ως θετικά), δίνεται απ' τη σχέση:

$$FPR = \frac{FP}{TN + FP} \quad (1.20)$$

Ποσοστό ψευδώς αρνητικών αποτελεσμάτων (False Negative Rate, FNR)

Το ποσοστό των θετικών δειγμάτων που κατηγοριοποιούνται λανθασμένα (δηλαδή, ως αρνητικά), δίνεται απ' τη σχέση:

$$FNR = \frac{FN}{TP + FN} \quad (1.21)$$

Accuracy (ACC) & Error Rate

Δύο μετρικές ακόμη (Witten et al. (2016)) που αφορούν στη συνολική απόδοση του ταξινομητή, ανεξαρτήτου τάξης, είναι η ακρίβεια ή ορθότητα (accuracy, success rate), και το σφάλμα (error rate). Η ορθότητα εκφράζεται ως το πλήθος των ορθών προβλέψεων προς το σύνολο των προβλέψεων και δίνεται απτή σχέση:








$$Accuracy = \frac{f_{11} + f_{00}}{f_{11} + f_{00} + f_{01} + f_{10}} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1.22)$$

Ισοδύναμα, η συνολική απόδοση του μοντέλου εκφράζεται με το ποσοστό σφάλματος (error rate), που είναι το πλήθος εσφαλμένων προβλέψεων προς το σύνολο προβλέψεων και δίνεται απτήν ακόλουθη σχέση:

$$Error\ Rate = \frac{f_{01} + f_{10}}{f_{11} + f_{00} + f_{01} + f_{10}} = \frac{FP + FN}{TP + TN + FP + FN} \quad (1.23)$$

Προφανώς ισχύει: $Error\ Rate(c) = 1 - Accuracy(c)$

Πίνακας 1.1 – Συνήθεις συναρτήσεις μεταφοράς

Συνάρτηση	Ορισμός	Πεδίο τιμών	1D Γράφημα
Γραμμική	x	$(-\infty, +\infty)$	
Logistic sigmoid	$\frac{1}{1 + e^{-x}}$	$(0, +1)$	
Hyperbolic tangent	$\frac{e^x - e^{-x}}{e^x + e^{-x}}$	$(-1, +1)$	
Βηματική	$0 \quad , \quad x < 0$ $1 \quad , \quad x \geq 0$	$[0, +1]$	
Αναρρίχησης	$-1 \quad , \quad x \leq -1$ $x \quad , \quad -1 \leq x \leq 1$ $1 \quad , \quad x \geq 1$	$[-1, +1]$	
Προσήμου	$1 \quad , \quad x > 0$ $0 \quad , \quad x = 0$ $-1 \quad , \quad x < 0$	$-1, +1$	
Radial Basis Function		$[-1, +1]$	


2 | Εφαρμογές Τ.Ν.Δ. σε Κτηριακές Εγκαταστάσεις

2.1 Ανάλυση των Τ.Ν.Δ. σε κτηριακές εφαρμογές και ενέργεια

Υπάρχουν πολλά paper στη βιβλιογραφία για εφαρμογές των Τ.Ν.Δ. σχετικά με την ενέργεια και τα κτήρια. Πραγματοποιήθηκε ανάλυση των μελετών που επικεντρώθηκαν στην εφαρμογή της ενεργειακής μηχανικής και περιγράφεται στις επόμενες ενότητες. Για λόγους σαφήνειας εξετάστηκαν πέντε διαφορετικά πεδία εφαρμογής:

- Κτήρια και μονάδες παραγωγής ενέργειας (κατανάλωση ενέργειας κτηρίων και παραδοσιακές μονάδες παραγωγής ενέργειας).
- Ανανεώσιμες πηγές ενέργειας.
- Εξωτερικές συνθήκες (εφαρμογή των Τ.Ν.Δ. για τις εξωτερικές θερμικές συνθήκες).
- Εσωτερικές θερμικές συνθήκες (εφαρμογή των Τ.Ν.Δ. για την πρόβλεψη εσωτερικών θερμικών παραμέτρων).
- Άλλες εφαρμογές (φωτισμός, ακουστική κ.ο.κ.).

Στο Σχήμα 2.1 φαίνεται ότι τα ΤΝΔ χρησιμοποιούνται ως επί το πλείστον σε υπαίθριες και εσωτερικές θερμικές συνθήκες, σε ποσοστά περίπου 29% και 21% αντίστοιχα (τα ποσοστά προέκυψαν από τις 40 και πλέον μελέτες που αναλύθηκαν). Συγκεκριμένα, ένα υψηλό



Σχήμα 2.1 – Ποσοστό των μελετών που πραγματοποιήθηκαν σε διαφορετικά πεδία εφαρμογής.

ποσοστό των papers επικεντρώνεται στον υπολογισμό της ηλιακής ακτινοβολίας σε συγκεκριμένο τόπο (10%), ή στις εσωτερικές θερμικές συνθήκες, όπως η αξιολόγηση της θερμοκρασίας του εσωτερικού αέρα (12%).

Ένα άλλο σημαντικό θέμα, όπου, η εφαρμογή των T.N.Δ. φαίνεται να είναι πολύ συχνή, αφορά στα κτήρια και στις μονάδες παραγωγής ενέργειας, με περίπου το 17% των εξετασθεισών μελετών. Ειδικότερα, πολλές μελέτες επικεντρώνονται σε μοντέλα T.N.Δ. που χρησιμοποιούνται για την πρόβλεψη της κατανάλωσης ενέργειας των κτηρίων (12%). Οι ανανεώσιμες πηγές ενέργειας (ΑΠΕ) είναι ένα άλλο σημαντικό θέμα που διερευνάται με τη χρήση των T.N.Δ. (17% των εξετασθεισών μελετών). Επιπλέον, μελετήθηκαν μερικές ενδιαφέρουσες εφαρμογές σε πηγές γεωθερμικής ενέργειας (5%) και φωτοβολταϊκά συστήματα ενέργειας (5%).

Με βάση τις μελέτες σε αυτά τα διαφορετικά πεδία εφαρμογής, πραγματοποιήθηκε ανάλυση των δημοσιεύσεων (papers) λαμβάνοντας

υπόψη τις κύριες παραμέτρους που μπορούν να επηρεάσουν την υλοποίηση των δικτύων. Όπως έχει ήδη επισημανθεί, πολλές παράμετροι μπορούν να επηρεάσουν την υλοποίηση ενός δικτύου, οι σημαντικότεροι παράγοντες που πρέπει να διερευνηθούν για τα feed-forward νευρωνικά δίκτυα είναι ο αριθμός των κρυφών επιπέδων που χρησιμοποιούνται για την υλοποίηση και οι νευρώνες που ορίζονται σε κάθε κρυφό επίπεδο. Στην πραγματικότητα, και οι δύο παράμετροι επηρεάζουν την αποτελεσματικότητα της διαδικασίας μάθησης και μπορούν να οδηγήσουν σε υπερπροσαρμογή (over-fitting), γεγονός που αποτελεί κοινό πρόβλημα σε αυτού του είδους τα δίκτυα.


Παρ' όλα αυτά, δεν περιγράφουν την υλοποίηση των T.N.Δ. όλα τα έργα που βρέθηκαν στη βιβλιογραφία, αλλά εστιάζουν περισσότερο στην ιδιαιτερότητα της διερευνηθείσας περιπτωσιολογικής μελέτης ή στην αποτελεσματικότητα του T.N.Δ. σε σχέση με άλλες μεθόδους που υπάρχουν στη βιβλιογραφία. Σε αυτή την περίπτωση, λοιπόν, αν δεν παρέχονται κάποιες πληροφορίες για τα T.N.Δ. εισάγονται ως n.a. (not available) σε αυτήν την ανάλυση.

Η πρώτη παράμετρος που ελέγχεται και αξιολογείται είναι ο αριθμός των κρυφών επιπέδων που ορίζονται στην αρχιτεκτονική του προτύπου υλοποιούμενου T.N.Δ. Πολλές διαφορετικές εργασίες πραγματοποίησαν ανάλυση ευαισθησίας, προκειμένου να ελέγξουν και να προσδιορίσουν τον καλύτερο αριθμό κρυφών επιπέδων που θα χρησιμοποιηθούν. Ωστόσο, όπως φαίνεται στο Σχήμα 2.2, το 18% των ερευνών που διερευνήθηκαν δεν παρείχαν πληροφορίες σχετικά με την αρχιτεκτονική του εφαρμοσμένου Δικτύου. Στο 82% των μελετών που παρείχαν αυτές τις πληροφορίες, οι εφαρμογές των T.N.Δ. που χρησιμοποίησαν μόνο ένα κρυφό επίπεδο είναι ανέρχονται στο 49%, ενώ το 33% χρησιμοποίησαν δύο ή περισσότερα κρυφά επίπεδα.

Ξεκινώντας από αυτή την προκαταρκτική ανάλυση, εξετάζονται και άλλες δύο παράμετροι: ο αριθμός των εισόδων και ο αριθμός των νευρώνων που ορίζονται στα κρυφά επίπεδα.

Η ανάλυση αφορά περίπου 40 papers.


Το Σχήμα 2.3 δείχνει ότι σε περίπου 60% αυτών των μελετών



Σχήμα 2.2 – Αριθμός κρυφών επιπέδων που ορίζονται στην υλοποίηση του T.N.Δ.

εφαρμόστηκε ένα T.N.Δ. χρησιμοποιώντας λίγες παραμέτρους εισόδου (1-3 και 4-7) και μόνο σε λίγες περιπτώσεις παρέχεται μεγαλύτερος αριθμός παραμέτρων εισόδου για τη διαδικασία της μάθησης του δικτύου. Ανάλογη κατανομή διαπιστώθηκε και για τον αριθμό των νευρώνων που χρησιμοποιήθηκαν για τις εφαρμογές των T.N.Δ. Ο αριθμός ποικίλει από 1-25 (περισσότερες από το 78% των περιπτώσεων) και μόνο σε μερικές εφαρμογές ένας αριθμός νευρώνων στα κρυφά επίπεδα ήταν απαραίτητο να είναι υψηλότερος από 25.

Η τελευταία ανάλυση επικεντρώνεται στο είδος της συνάρτησης μεταφοράς που χρησιμοποιείται στο κρυφό επίπεδο, η οποία επηρεάζει το χρόνο της διαδικασίας μάθησης του δικτύου. Η ανάλυση πραγματοποιήθηκε εξετάζοντας μόνο τα έγγραφα που παρείχαν πληροφορίες σχετικά με τον αριθμό των κρυφών επιπέδων που χρησιμοποιήθηκαν για την υλοποίηση των δικτύων. Όπως δείχνει το Σχήμα 2.4, παρότι ορισμένες έρευνες έδωσαν πολλές πληροφορίες για την υλοποίηση του δικτύου, σε περίπου 23% δεν δηλώνουν τη συνάρτηση μεταφοράς που ορίζεται στο κρυφό επίπεδο, επομένως η χρήση άλλων μαθηματικών




Σχήμα 2.3 – Αριθμός εισόδων και νευρώνων που χρησιμοποιούνται για την εκτέλεση των Τ.Ν.Δ.

συναρτήσεων δεν μπορεί να εξαιρεθεί. Όπως είναι γνωστό από τη θεωρία (βλ ενότητα 1.5), υπάρχουν πολλές συναρτήσεις μεταφοράς, αλλά, όπως επισημαίνεται στο Σχήμα 2.4, γενικά χρησιμοποιούνται μόνο λίγα είδη για αυτό το είδος εφαρμογών. Συγκεκριμένα η συνάρτηση υπερβολικής εφαπτομένης (hyperbolic tan) κυριαρχεί με 34% και ακολουθούν η log sigmoid (14%), ο συνδυασμός γραμμικής και λογαριθμικής συνάρτησης (5%) καθώς και διάφοροι άλλοι συνδυασμοί (7%).

2.2 Κτήρια και μονάδες παραγωγής ενέργειας

Η εφαρμογή των ΤΝΔ στην αξιολόγηση της ενεργειακής απόδοσης των κτηρίων και των εγκαταστάσεων είναι πολύ κοινή και με πολύ καλή ανάδραση στην επιστημονική έρευνα. Πολλοί ερευνητές σε όλο τον κόσμο διερεύνησαν την εφαρμογή των Τ.Ν.Δ. σε αυτό το θέμα, με διαφορετικούς σκοπούς και αποτελέσματα.

Τα πρώτα διαθέσιμα έγγραφα που βρέθηκαν στη βιβλιογραφία χρο-




Σχήμα 2.4 – Χρήση της συνάρτησης μεταφοράς στα κρυμμένα επίπεδα.

νολογούνται από το 2000 και επικεντρώνονται στα κρίσιμα ζητήματα που σχετίζονται με τη διαδικασία μάθησης για την εφαρμογή των T.N.Δ. Συγκεκριμένα, σε ορισμένες από αυτές τις εργασίες τα T.N.Δ. υλοποιήθηκαν για ποικίλους και διαφορετικούς σκοπούς, όπως η πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας ενός καταστήματος λιανικής πώλησης τροφίμων (Datta & Tassou (1998)) ή ενός παθητικού ηλιακού κτηρίου (Kalogirou & Bojic (2000)) ή ενός κτηρίου γραφείων εξετάζοντας την επίδραση του ηλιακού φωτός (Wong et al. (2010)).

Στο (Datta & Tassou (1998)), το ηλεκτρικό φορτίο ενός καταστήματος λιανικής πώλησης τροφίμων διερευνήθηκε και προσομοιάστηκε χρησιμοποιώντας δύο διαφορετικά είδη δικτύων. Το πρώτο είναι ένα M.L.P. που ήδη περιγράφηκε στην ενότητα 1.4.4 (σελ. 14), ενώ το δεύτερο δίκτυο είναι ένα Ακτινικό Δίκτυο Radial Basis (RBF), το οποίο είναι ένα συγκεκριμένο feed-forward δίκτυο με μόνο ένα κρυφό επίπεδο και όπου η ακτινική συνάρτηση ορίζεται στο επίπεδο εξόδου του εφαρμοσμένου προτύπου. Το RBF έχει ένα σημαντικό πλεονέκτημα σε σχέση με τα παραδοσιακά δίκτυα M.L.P.: η διαδικασία εκ-

παίδευσης είναι ταχύτερη και τα συγκεντρωτικά δεδομένα μπορούν να μοντελοποιηθούν τοπικά πιο εύκολα από το M.L.P. Τα δύο δίκτυα εκπαιδεύτηκαν και επικυρώθηκαν (validated) χρησιμοποιώντας πειραματικά δεδομένα που σχετίζονταν με περίοδο 2 μηνών και στη συνέχεια δοκιμάστηκαν για την πρόβλεψη της κατανάλωσης ηλεκτρικής ενέργειας.



Σχήμα 2.5 – Σύγκριση μεταξύ των προβλεπόμενων και των πραγματικών δεδομένων σε περίοδο 6 ημερών με χρήση (αριστερά) ενός M.L.P. δικτύου, (δεξιά) ενός R.B.F. δικτύου.

Οι καταναλώσεις ηλεκτρικής ενέργειας που προσομοιώθηκαν από τα δύο δίκτυα που εφαρμόστηκαν συγκρίθηκαν αρχικά με τα παρακολουθούμενα δεδομένα (Σχήμα 2.5) και έπειτα το ένα με το άλλο, για να επισημανθεί το καλύτερο δίκτυο που επιτρέπει την καλύτερη προσομοίωση των πραγματικών ηλεκτρικών καταναλώσεων των ελεγχόμενων καταστημάτων λιανικής πώλησης τροφίμων. Τα αποτελέσματα έδειξαν (Πίνακας 2.1) ότι τα νευρωνικά δίκτυα είναι ένα κατάλληλο εργαλείο για την πρόβλεψη του ηλεκτρικού φορτίου σε ένα κτήριο. Η δομή M.L.P. παρείχε καλύτερα αποτελέσματα από το RBF, αλλά προτείνονται περαιτέρω βελτιώσεις στο δίκτυο για να αυξηθεί η ακρίβεια.

Οι Kalogirou & Bojic (2000) ανέπτυξαν ένα T.N.Δ. για την πρόβλεψη της κατανάλωσης ενέργειας σε μια συγκεκριμένη μελέτη περίπτωσης, ενός παθητικού ηλιακού κτηρίου. Τα T.N.Δ. εφαρμόστηκαν υιοθετώντας την ίδια μεθοδολογία που περιγράφεται στην ενότητα 1.10 (σελ. 29), καθορίστηκε ένα πρότυπο M.L.P. και η λογα-

Πίνακας 2.1 – Σύγκριση αποτελεσμάτων (Datta & Tassou (1998))

Output	RMS error	Mean absolute	Mean absolute (%)
MLP network	24.19	17.38	4.59
RBF network	34.92	26.92	7.11

ριθμική σιγμοειδής συνάρτηση χρησιμοποιήθηκε ως συνάρτηση μεταφοράς στο επίπεδο εξόδου. Καταγράφηκαν 40 διαφορετικές διαμορφώσεις πάχους και τύποι τοιχοποιίας χρησιμοποιώντας ένα δυναμικό μοντέλο κτηρίου ονομαζόμενο ZID¹ και επελέγησαν ως παράμετροι εισόδου που πρέπει να παρέχονται για την εκπαίδευση των δικτύων, ενώ η κατανάλωση ενέργειας του κτηρίου σε kWh καθορίστηκε ως έξοδος-στόχος. Το εφαρμοσμένο Δίκτυο χρησιμοποιήθηκε ως εκ τούτου για την πρόβλεψη της κατανάλωσης ενέργειας του κτηρίου σε δύο διαφορετικά άγνωστα σενάρια (σε χειμερινές και θερινές συνθήκες) και τα αποτελέσματα στη συνέχεια συγκρίθηκαν με τα πραγματικά δεδομένα. Διαπιστώθηκε καλή συμφωνία μεταξύ των προβλεπόμενων και των πραγματικών δεδομένων, με αποτέλεσμα το δίκτυο να μπορεί να χρησιμοποιηθεί με αποτελεσματικότητα για τον σκοπό της πρόβλεψης της κατανάλωσης ενέργειας στα κτήρια και μπορεί να βοηθήσει στον σχεδιασμό των συστημάτων θέρμανσης και ψύξης.

Άλλες ενδιαφέρουσες μελέτες επικεντρώθηκαν στον θερμικό χαρακτηρισμό των οικοδομικών εγκαταστάσεων. Οι Sözen et al. (2007) χρησιμοποίησαν την δυνατότητα των T.N.Δ. για τον υπολογισμό των θερμοδυναμικών ιδιοτήτων ενός εναλλακτικού ψυκτικού μέσου και συγκεκριμένα η προτεινόμενη προσέγγιση αποσκοπεί στον υπολογισμό

¹Το ZID είναι ένας κώδικας (μαθηματικό μοντέλο) που αναπτύχθηκε από το Κέντρο Διαχείρισης Ενέργειας του Πανεπιστημίου Kragujevac και χρησιμοποιείται για την εκτίμηση της κατανάλωσης ενέργειας των κτηρίων. Το ZID στηρίζεται στους φυσικούς νόμους για τον υπολογισμό του θερμικού φορτίου των κτηρίων με αριθμητικό τρόπο. Χρησιμοποιείται για τον σχεδιασμό και την αναβάθμιση των κτηρίων. Αυτό το μοντέλο λαμβάνει υπόψη τις χρονικές διακυμάνσεις της εξωτερικής θερμοκρασίας και της ηλιακής ακτινοβολίας.

των τιμών του ειδικού όγκου, της ενθαλπίας και της εντροπίας του ψυκτικού μέσου R508b τόσο στις ζώνες κορεσμένου υγρού-ατμού όσο και στις υπέρθερμες ζώνες (Sözen et al. (2007)). Οι Tan et al. (2009) ανέπτυξαν ένα T.N.Δ. ικανό να προσομοιώνει τη θερμική απόδοση ενός εναλλάκτη θερμότητας αέρα με υγρό εργασίας μίγμα νερού / αιθυλενογλυκόλης ως αντιψυκτικό. Το T.N.Δ. χρησιμοποιήθηκε για την πρόβλεψη της θερμικής μεταφοράς και τα αποτελέσματά του συγκρίθηκαν με τα πειραματικά δεδομένα. Οι συγγραφείς επεσήμαναν ότι το εφαρμοζόμενο T.N.Δ. ήταν σε θέση να προβλέψει τη μεταφορά θερμότητας με υψηλότερο βαθμό ακρίβειας από τα διαθέσιμα συμβατικά και μη γραμμικά μοντέλα παλινδρόμησης.

Ένα εκπαιδευμένο δίκτυο ορίζεται ως γενικευμένο (βλ. ενότ. 1.8), όταν χαρακτηρίζεται από την ικανότητα να χρησιμοποιείται με διαφορετικές εισόδους από εκείνες που παρέχονται για τη μαθησιακή διαδικασία και αποδίδει με ακρίβεια την επιθυμητή έξοδο.

Οι Buratti, Barbanera, & Palladino (2014) χρησιμοποίησαν την ικανότητα των T.N.Δ. για την πρόβλεψη των παγκόσμιων δεικτών ενεργειακών επιδόσεων των κτηρίων, υπολογιζομένων σύμφωνα με τους ευρωπαϊκούς κανονισμούς, οι οποίοι παρέχουν ενεργειακές πληροφορίες για το εξεταζόμενο κτήριο. Το ανεπτυγμένο σύστημα T.N.Δ. χρησιμοποιήθηκε όχι μόνο για την προσομοίωση των ενεργειακών επιδόσεων των κτηρίων που ερευνήθηκαν αλλά και για τον έλεγχο των πιστοποιητικών ενεργειακών επιδόσεων που εκπονήθηκαν στην περιφέρεια Umbria, σύμφωνα με τους ευρωπαϊκούς και τους εθνικούς κανονισμούς. Το T.N.Δ. αρχικά εκπαιδεύτηκε χρησιμοποιώντας έναν μικρότερο αριθμό παραμέτρων εισόδου και στη συνέχεια βελτιώθηκε για να ελαχιστοποιήσει το σφάλμα που επέστρεφε το δίκτυο μετά τη γενίκευση. Οι συγγραφείς επεσήμαναν μια καλή συμφωνία μεταξύ των ενεργειακών δεικτών που προσομοιάστηκαν από το T.N.Δ. και των πειραματικών δεδομένων και ότι το T.N.Δ. μπορεί να είναι ένα χρήσιμο και ενδιαφέρον εναλλακτικό εργαλείο που μπορεί να χρησιμοποιηθεί για τον έλεγχο των ενεργειακών πιστοποιητικών.

Για το σκοπό αυτό, εισήχθη ένας νέος δείκτης ενέργειας, που ονο-

μάζεται Δείκτης Νευρωνικής Ενεργειακής Απόδοσης N.E.P.I. (Neural Energy Performance Index), ο οποίος ορίστηκε ως ο λόγος μεταξύ του Παγκόσμιου Δείκτη Ενέργειας που προσομοιώνεται από το T.N.Δ. και του προσομοιωμένου με το παραδοσιακό λογισμικό και δηλώθηκε στις ενεργειακές πιστοποιήσεις. Όταν ο N.E.P.I. είναι ίσος ή πολύ κοντά στο 1, αυτό σημαίνει ότι το T.N.Δ. προσομοιώνει την ίδια κατανάλωση ενέργειας που δηλώνεται στην ενεργειακή πιστοποίηση, επομένως η ενεργειακή πιστοποίηση μπορεί να θεωρηθεί σωστή και δεν απαιτεί πρόσθετο έλεγχο. Όταν είναι χαμηλότερος από 1, σημαίνει ότι στην ενεργειακή πιστοποίηση έχει δηλωθεί μια καλύτερη ενεργειακή κλάση απ' ότι θα έπρεπε. Επομένως, συνιστώνται περισσότεροι και βαθύτεροι έλεγχοι. Αντίθετα όταν είναι μεγαλύτερος από 1, σημαίνει ότι στην ενεργειακή πιστοποίηση έχει δηλωθεί χαμηλότερη ενεργειακή τάξη.

Ο Εκονομου (2010) πρότεινε μια ενδιαφέρουσα εφαρμογή των T.N.Δ. ικανή να βελτιώσει την αποτελεσματική εφαρμογή των ενεργειακών πολιτικών στην Ελλάδα. Ειδικότερα, ο σκοπός του paper ήταν να εκπαιδεύσει ένα T.N.Δ. ώστε να είναι σε θέση να προβλέψει την ετήσια τελική ζήτηση ενέργειας της Ελλάδας, προκειμένου να χρησιμοποιηθεί στην υποστήριξη αξιολογήσεων έργων μηχανικών ή στις πολιτικές επιλογές της Ελλάδας. Τα κύρια στοιχεία που επηρεάζουν την τελική κατανάλωση ενέργειας στην Ελλάδα παρέχονται ως εξής: η θερμοκρασία περιβάλλοντος, η εγκατεστημένη ισχύς, η κατανάλωση ηλεκτρικής ενέργειας και το Α.Ε.Π. Τα ανωτέρω χρησιμοποιήθηκαν ως παράμετροι εισόδου, εξετάζοντας την τάση τους κατά την περίοδο 1992-2008. Στη συνέχεια αναπτύχθηκε το T.N.Δ. για την πρόβλεψη της κατανάλωσης ενέργειας σε διάφορα σενάρια: 2005-2008, 2010, 2012 και 2015. Προκειμένου να ελεγχθεί η αποτελεσματικότητα του Δικτύου, εφαρμόστηκαν άλλες δύο κοινές μέθοδοι: το μοντέλο παλινδρόμησης και μοντέλο SVM (Support Vector Model). Η σύγκριση έδειξε ότι μετά το 2008 οι τρεις μέθοδοι παρείχαν υψηλότερη τελική κατανάλωση ενέργειας σε σύγκριση με προηγούμενες περιόδους, αλλά πάντα πολύ κοντά μεταξύ τους, ως εκ τούτου, το


T.N.Δ. προσεγγίζει κατά πολύ την ενεργειακή πρόβλεψη, με αποδεκτή ακρίβεια. Ο Οικονόμου πρότεινε να χρησιμοποιήσει την ικανότητα του εκπαιδευμένου T.N.Δ. για την αποτελεσματική εφαρμογή των ενεργειακών πολιτικών, καθώς η σωστή πρόβλεψη της κατανάλωσης ενέργειας επηρεάζει τις επενδύσεις κεφαλαίου και την περιβαλλοντική ποιότητα.

2.3 Ανανεώσιμες Πηγές Ενέργειας

Ένα άλλο σημαντικό ζήτημα που διερευνάται με χρήση της ικανότητας των T.N.Δ. είναι οι ανανεώσιμες πηγές ενέργειας. Οι περισσότερες μελέτες επικεντρώνονται στην αξιολόγηση της θερμικής και ενεργειακής απόδοσης των ηλιακών συστημάτων, ωστόσο, μερικές μελέτες προσπάθησαν να εφαρμόσουν τα T.N.Δ. στη βιομάζα, σε φωτοβολταϊκά συστήματα, και σε πηγές γεωθερμικής ενέργειας.

2.3.1 Ηλιακοί συλλέκτες

Οι Kalogirou et al. (1998) ανέπτυξαν ένα T.N.Δ. για τη μοντελοποίηση της λειτουργίας ενός παραβολικού συλλέκτη (Σχήμα 2.6). Το T.N.Δ. εκπαιδεύτηκε για την πρόβλεψη του προφίλ θερμοκρασίας του συστήματος χρησιμοποιώντας πειραματικά δεδομένα, όπως θερμοκρασία περιβάλλοντος, ηλιακή ακτινοβολία, ενεργή επιφάνεια κατόπτρου, είδη δοχείων ανάκτησης ατμού καθώς και διαστάσεις (ύψος, διάμετρος και πάχος) αυτών των δοχείων. Τα αποτελέσματα έδειξαν ότι το δίκτυο προέβλεψε σωστά την απόκριση του συστήματος, όπως επισημαίνεται από την τιμή $R^2 = 0.999$ (βλ. ενότ. 1.11.1 σελ. 33). Σε συμφωνία με τα αποτελέσματα, το εφαρμοσμένο T.N.Δ. έδωσε μεγαλύτερη ακρίβεια από τα αναλυτικά μοντέλα και ήταν ένα πιο ευέλικτο και ταχύτερο σχεδιαστικό εργαλείο.



Σχήμα 2.6 – Experimental solar steam generator.

2.3.2 Φωτοβολταϊκά

Οι Almonacid et al. (2013) ανέπτυξαν ένα T.N.Δ. που είναι σε θέση να εκτιμήσει τη μέγιστη ισχύ μιας φωτοβολταϊκής μονάδας υψηλής απόδοσης, η οποία δεν είναι εύκολο να προσδιοριστεί ή να υπολογιστεί. Πολλές διαφορετικές μεθοδολογίες είναι διαθέσιμες για την εκτίμηση της μέγιστης ισχύος με καλά αποτελέσματα, αλλά απαιτούν πολλά δεδομένα εισόδου, που δεν είναι πάντα εύκολο να βρεθούν. Ως εκ τούτου, στο (Gunasekar et al. (2015)), οι συγγραφείς προσπάθησαν να προτείνουν ένα νέο μοντέλο εκτίμησης για την αξιολόγηση της μέγιστης ισχύος ενός στοιχείου υψηλής απόδοσης φωτοβολταϊκών την προσέγγιση των T.N.Δ. Το T.N.Δ. εκπαιδεύτηκε, δεχόμενο ως είσοδο εύκολα μετρήσιμες ατμοσφαιρικές παραμέτρους για τη διαδικασία μάθησης και παρέχοντας τη μέγιστη ισχύ που παρακολουθείται επί τόπου. Τα αποτελέσματα έδειξαν ότι το υλοποιούμενο T.N.Δ. είναι σε θέση να προβλέψει σωστά τη δύναμη ενός Φωτοβολταϊκού Συστήματος Υψηλής Απόδοσης με ένα πολύ μικρό σφάλμα (τετραγωνική ρίζα μέσου τετραγωνικού σφάλματος, RMSE περίπου 3,29% (βλ. ενότ. 1.11.1, σελ. 31)). Σε συμφωνία με τα αποτελέσματα,


οι συγγραφείς πρότειναν επίσης ότι το αναπτυγμένο T.N.Δ. να χρησιμοποιηθεί για την εκτίμηση της μέγιστης ισχύος τέτοιων συστημάτων που βρίσκονται στη νότια Ισπανία.

2.3.3 Γεωθερμία

Πολλοί διαφορετικοί συγγραφείς διεξήγαγαν ενδιαφέρουσες μελέτες όπου τα T.N.Δ. εφαρμόστηκαν σε άλλες ανανεώσιμες πηγές ενέργειας. Οι Kumar et al. (2006) προσπάθησαν να επαληθεύσουν την ικανότητα των T.N.Δ. για να προβλέψουν τη δυνατότητα θέρμανσης και ψύξης ενός εναλλάκτη θερμότητας γης-αέρα. Σκοπός της μελέτης ήταν να αναπτυχθεί ένα εργαλείο σχεδίασης ικανό να αξιολογήσει οποιαδήποτε πτυχή του εναλλάκτη θερμότητας γης-αέρα και τη συμπεριφορά της τελικής διαμόρφωσης. Λαμβάνοντας υπόψη τον υψηλό αριθμό παραμέτρων που μπορούν να επηρεάσουν το ενεργειακό ισοζύγιο, πραγματοποιήθηκε ανάλυση ευαισθησίας, προκειμένου να επιλεγούν μόνο οι παράμετροι επιρροής που πρέπει να παρέχονται για την υλοποίηση του δικτύου. Το T.N.Δ. επικυρώθηκε (validated) με πειραματικά δεδομένα και ήταν σε θέση να υπολογίσει τη θερμοκρασία του αέρα εξόδου και το δυναμικό θέρμανσης και ψύξης του εξεταζόμενου εναλλάκτη.

Οι Kalogirou et al. (2012) διεξήγαγαν μια παρόμοια μελέτη, αλλά σε αυτή την περίπτωση το T.N.Δ. εφαρμόστηκε για να προβλέψει τη θερμοκρασία της γης σε διάφορα βάθη στην Κύπρο (Σχήμα 2.7). Οι συγγραφείς εφάρμοσαν ένα T.N.Δ. για την παραγωγή γεωθερμικών χαρτών σε τρία διαφορετικά βάθη (20, 50, 100 m), παρέχοντας πειραματικά δεδομένα 41 γεωτρήσεων για τη διαδικασία εκπαίδευσης. Δεδομένα όπως η γεωμορφολογία της περιοχής, η θερμοκρασία περιβάλλοντος, οι τοπικές βροχοπτώσεις και η θερμοκρασία εδάφους παρέχονται για τη διαδικασία της μάθησης. Σε συμφωνία με τα αποτελέσματα και λαμβάνοντας υπόψη την καλή συσχέτιση που βρέθηκε με τα πειραματικά δεδομένα ($R^2 = 0.9918$), οι συντάκτες πρότειναν ότι το εκπαιδευμένο T.N.Δ. μπορεί να είναι ένα χρήσιμο εργαλείο για


τους μηχανικούς που θα σχεδιάσουν γεωθερμικά συστήματα στην Κύπρο.



Σχήμα 2.7 – Γεωθερμικός χάρτης για τρία διαφορετικά βάθη (20, 50, 100 m).

2.3.4 Βιομάζα

Ορισμένα papers διερεύνησαν τη δυνατότητα εφαρμογής των Τ.Ν.Δ. για προσομοίωση διεργασιών σε μονάδες παραγωγής ενέργειας από βιομάζα. Οι De et al. (2007) πρότειναν έναν προσομοιωτή με Τ.Ν.Δ. για έναν κύκλο ατμού σε εργοστάσιο παραγωγής ενέργειας από βιομάζα και άνθρακα στη Σουηδία. Στην εργασία αυτή έγιναν δύο Τ.Ν.Δ. (Σχήμα 2.8) συνδεδεμένα σε σειρά: το πρώτο επέτρεψε την πρόβλεψη του ατμού που παράγεται στον λέβητα, που ήταν η τιμή εισόδου για το δεύτερο νευρωνικό δίκτυο, που χρησιμοποιήθηκε για την αξιολόγηση της ισχύος που παρέχεται από τον ατμοστρόβιλο. Τα προτεινόμενα μοντέλα Τ.Ν.Δ. αποκάλυψαν μια πολύ καλή ακρίβεια προβλέψεων, αλλά οι συγγραφείς υπογράμμισαν ότι για κάθε αλλαγή του συστήματος απαιτείται επανεκπαίδευση των Τ.Ν.Δ.



Σχήμα 2.8 – Αριστερά: η εκπαίδευση του Τ.Ν.Δ., Δεξιά: σχηματική αναπαράσταση του δικτύου.

Τα T.N.Δ. μπορεί επίσης να είναι χρήσιμα για την αξιολόγηση της παραγωγής ενέργειας από βιομάζα. Οι Kana et al. (2012) ανέπτυξαν ένα T.N.Δ. για τη βελτιστοποίηση της απόδοσης βιοαερίου από την αναερόβια χώνευση πριονιδιού και άλλων υποπροϊόντων. Τα αποτελέσματα που προέκυψαν ενθάρρυναν τη διεξαγωγή περαιτέρω εργασιών ώστε να συμπεριλάβουν την ενεργειακή και οικονομική διάσταση για μια εφαρμογή σε βιομηχανική κλίμακα.

2.4 Εσωτερικές θερμικές συνθήκες

Στην παρούσα ενότητα, η ανάλυση της τεχνολογίας επεκτείνεται στην εφαρμογή των T.N.Δ. στην πρόβλεψη χρήσιμων χαρακτηριστικών κατά τη διάρκεια της φάσης σχεδιασμού ενός κτηρίου, όπως οι θερμικές παράμετροι ή οι θερμικές ιδιότητες κτηρίου.

2.4.1 Θερμικές παράμετροι

Εστιάζοντας στην εκτίμηση των θερμικών χαρακτηριστικών σε εσωτερικούς χώρους, μία από τις πρώτες μελέτες πραγματοποιήθηκε από τους Ferreira et al. (2002), οι οποίοι ανέπτυξαν ένα T.N.Δ. ικανό να προσομοιώνει τη θερμοκρασία του εσωτερικού αέρα ενός υδροπονικού θερμοκηπίου παραγωγής λαχανικών. Σε αυτό το έργο, η θερμοκρασία του εξωτερικού αέρα, η ηλιακή ακτινοβολία και η εσωτερική σχετική υγρασία παρέχονται ως δεδομένα εισόδου, απαραίτητα για την υλοποίηση του δικτύου. Ομοίως, οι Ömer Altan Dombayci & Gölcü (2009) εφάρμοσαν ένα μοντέλο T.N.Δ. ικανό να προβλέψει την ημερήσια μέση θερμοκρασία περιβάλλοντος στο Denizli της Τουρκίας. Σε αυτό το έργο, το T.N.Δ. εκπαιδεύτηκε με μετεωρολογικά δεδομένα τριών χρόνων (2003-2005) και δοκιμάστηκε χρησιμοποιώντας τα δεδομένα που σχετίζονταν με το 2006.

Οι Moon et al. (2013) ανέπτυξαν ένα μοντέλο T.N.Δ. για την εκτίμηση της θερμοκρασίας του εσωτερικού αέρα και για να αποκτήσουν τον βέλτιστο έλεγχο των ανοιγμάτων σε εσωτερικές και εξωτερικές

πλευρές ενός πραγματικού κτηρίου διπλού περιβλήματος. Το διπλό περιβλήμα επιτρέπει τη μείωση της κατανάλωσης ενέργειας, ενεργώντας ως θερμική ζώνη προστασίας μεταξύ του εσωτερικού και του εξωτερικού. Σε αυτό το έργο οι συγγραφείς παρατήρησαν ότι το T.N.Δ. μπορεί να εφαρμοστεί με επιτυχία στον θερμικό έλεγχο λόγω της ακριβούς πρόβλεψης της θερμοκρασίας του εσωτερικού αέρα. Επιπλέον, τα T.N.Δ. παρουσιάζουν ένα σημαντικό πλεονέκτημα σε σχέση με άλλες μεθόδους της τεχνητής νοημοσύνης AI, όπως η Fuzzy Logic και το Adaptive Neuro-Fuzzy Inference System (ANFIS), χάρη στη μεγαλύτερη ποσότητα εισόδων που μπορούν να χρησιμοποιηθούν. Το T.N.Δ. δημιουργήθηκε με ένα επίπεδο εισόδου με 7 νευρώνες, ένα κρυμμένο επίπεδο με 15 νευρώνες και ένα επίπεδο εξόδου. Η θερμοκρασία του εσωτερικού αέρα, η θερμοκρασία του εξωτερικού αέρα, η θερμοκρασία της κοιλότητας, η ηλιακή ακτινοβολία, οι συνθήκες ανοίγματος των εσωτερικών και εξωτερικών επιφανειών παρέχονταν ως παράμετροι εισόδου, χρησιμοποιήθηκαν συνολικά 121 σύνολα δεδομένων (data sets) για την υλοποίηση του δικτύου. Η ανάλυση των αποτελεσμάτων έδειξε ότι το αναπτυγμένο μοντέλο T.N.Δ. έδωσε μια καλή ακρίβεια πρόβλεψης με σταθερές τιμές RMSE, MSE (βλ. ενότητα 1.11.1 σελ. 31) και τιμές θερμοκρασιακής διαφοράς, έτσι ώστε το προτεινόμενο μοντέλο T.N.Δ. να έχει τη δυνατότητα να εφαρμοστεί για τη θερμική αξιολόγηση σε κτήρια.


Μια άλλη ενδιαφέρουσα μελέτη διεξήχθη από τους Buratti, Lascaro, et al. (2014). Ανέπτυξαν ένα μοντέλο T.N.Δ. ικανό να προσομοιώσει και να προβλέψει τη θερμοκρασία του εσωτερικού αέρα των κτηρίων (κατοικιών), λαμβάνοντας υπόψη τις εξωτερικές θερμικές συνθήκες και τα θερμικά χαρακτηριστικά του κελύφους του κτηρίου. Πολλά κτήρια κατοικιών διερευνήθηκαν πειραματικά κατά τη διάρκεια της ψυχρής περιόδου, για περίπου μία εβδομάδα για κάθε κατοικία. Κατά τη διάρκεια των πειραμάτων παρακολούθηθηκαν οι εξωτερικές θερμικές συνθήκες και η θερμοκρασία του εσωτερικού αέρα και εκτιμήθηκαν τα θερμικά χαρακτηριστικά του περιβλήματος του κτηρίου. Έγινε ανάλυση ευαισθησίας προκειμένου να επιλεγεί το καλύτερο πρό-

τυπο που θα χρησιμοποιηθεί και το καλύτερο ελήφθη χρησιμοποιώντας δύο κρυφά επίπεδα με 75 και 35 νευρώνες στο πρώτο και στο δεύτερο επίπεδο, αντίστοιχα. Το καλύτερα εκπαιδευμένο T.N.Δ. παρουσίασε ένα καλό R^2 σε όλες τις διαδικασίες ($> 0,9625$), γεγονός που έδειξε την καλή εκπαίδευση του δικτύου. Λαμβάνοντας υπόψη τη θερμοκρασία του εσωτερικού αέρα που προσομοιώθηκε από το T.N.Δ., επιτεύχθηκε επίσης ένα πολύ μικρό σφάλμα (χαμηλότερο από $0,4^\circ\text{C}$ σε σχέση με την παρακολουθούμενη θερμοκρασία σε όλα τα κτήρια που ερευνήθηκαν). Το ανεπτυγμένο T.N.Δ. τέλος, προτάθηκε επίσης για την εκτίμηση της θερμοκρασίας του εσωτερικού αέρα, για την εξέταση καινοτόμων λύσεων για συστήματα παραθύρων. Ειδικά εξετάστηκαν και προσομοιώθηκαν δύο διαφορετικά παράθυρα με κοκκώδη και μονολιθική αερογέλη (DGM) στον ενδιάμεσο χώρο. Τα αποτελέσματα έδειξαν ότι το εφαρμοσμένο T.N.Δ. προσομοιώνει σωστά την τάση της θερμοκρασίας του αέρα μέσα στο δωμάτιο και είναι σε καλή συμφωνία με αυτή που προσομοιώνεται με έναν δυναμικό κώδικα λαμβάνοντας υπόψη τις δύο υιοθετημένες λύσεις. Σε συμφωνία με τα αποτελέσματα, το εφαρμοσμένο T.N.Δ. θεωρήθηκε ένα χρήσιμο και ενδιαφέρον εργαλείο για την εσωτερική θερμική πρόβλεψη, το οποίο επέτρεψε να αξιολογηθεί γρήγορα, απλά και σε πραγματικό χρόνο η επίδραση διαφορετικών λύσεων στις εσωτερικές θερμικές συνθήκες.

Οι Buratti et al. (2012) χρησιμοποίησαν την ικανότητα των μοντέλων των T.N.Δ. για να προβλέψουν τη θερμική διαπερατότητα² U των ξύλινων παραθύρων, η οποία εξαρτάται από πολλές παραμέτρους. Η μελέτη στοχεύει στην ανάπτυξη ενός εναλλακτικού εργαλείου στις αριθμητικές μεθόδους που είναι διαθέσιμες για τον υπολογισμό της θερμικής διαπερατότητας.

Το εφαρμοζόμενο δίκτυο είναι σε θέση να προβλέψει την τιμή U των παραθύρων χρησιμοποιώντας μόνο 10 παραμέτρους εισόδου (Σχήμα 2.9): τύπος παραθύρων, είδος ξύλου, πάχος πλαισίου και παρα-

²Η θερμική διαπερατότητα U , ενός παράθυρου, εκφράζει την ροή θερμότητας μέσα από αυτό, σε μονάδες $\text{W}/\text{m}^2\text{K}$. Έτσι, όσο η τιμή αυτή είναι πιο κοντά στο μηδέν τόσο καλύτερη απόδοση έχει το παράθυρο. Αντίθετα όσο μεγαλύτερη είναι η τιμή του U , τόσο μεγαλύτερη ροή θερμότητας παρατηρείται, άρα και μεγαλύτερη απώλεια ενέργειας απ' το παράθυρο.



Σχήμα 2.9 – Δομή T.N.Δ. για την πρόβλεψη της θερμικής διαπερατότητας των ξύλινων παραθύρων (Buratti et al. (2012))

θυρόφυλλων, διαχωριστικό υαλοπινάκων, χαρακτηριστικά διασταύρωσης άνω πλαισίου, τιμή U των υαλοπινάκων και μέγεθος υαλοπινάκων. 282 ξύλινα παράθυρα χρησιμοποιήθηκαν ως δείγματα για την υλοποίηση του δικτύου. Με βάση τα αποτελέσματα, το αναπτυγμένο T.N.Δ. εκτίμησε σε πραγματικό χρόνο την τιμή U των παραθύρων με πολύ μικρό σφάλμα (περίπου 1%) σε σχέση με αυτά που προκύπτουν με εφαρμογή των μεθόδων της υπολογιστικής ρευστοδυναμικής (CFD).

2.4.2 Θερμική άνεση

Για αρκετά χρόνια οι ερευνητές προσπαθούν να καθορίσουν εναλλακτικές μεθόδους για να προβλέψουν την εσωτερική θερμική άνεση και την ποιότητα του αέρα εσωτερικών χώρων. Τα T.N.Δ. συνεχώς μελετούν με επιτυχία λόγω της ικανότητάς τους να παρέχουν καλά αποτελέσματα στην αξιολόγηση της άνεσης, καθώς έχουν την ιδιαιτερότητα να αντιλαμβάνονται πώς να αντιδρούν σε κάποιες εξωτερικές αιτίες ξεκινώντας από έναν ορισμένο αριθμό δεδομένων. Στην περίπτωση της άνεσης, τα δεδομένα εισόδου συντίθεται συχνά από τα


χαρακτηριστικά των κτηρίων και των κατοίκων, ενώ το δεδομένο εξόδου είναι γενικά το επίπεδο άνεσης, το οποίο εκφράζεται με δείκτες που αναφέρονται στη βιβλιογραφία. Ο πιο συχνά χρησιμοποιούμενος ονομάζεται Πρόβλεψη Μέσης Εκτίμησης (PMV³)

Τα πρώτα έργα που αφορούσαν την θερμική άνεση επικεντρώθηκαν στην αυτοματοποίηση των κτηρίων κατοικιών. Ο Mozer (1998), στα τέλη της δεκαετίας του '90, πρότεινε ένα «Neural Network House»: ένα πλήρως αυτοματοποιημένο σπίτι που μαθαίνει από τον τρόπο ζωής των κατοίκων του, να ελέγχει τα βασικά οικιακά συστήματα, δηλαδή την θέρμανση του αέρα και του νερού, τον εξαερισμό και τον φωτισμό. Το σύστημα, που ονομάζεται ACHE⁴ (Adaptive Control of Home Environments) είχε δύο δηλωμένους στόχους: την πρόβλεψη των αναγκών των κατοίκων ώστε να παρέχει υψηλού επιπέδου άνεση καθώς και την εξοικονόμηση όσο το δυνατόν περισσότερης ενέργειας, ρυθμίζοντας τον φωτισμό στο ελάχιστο και απενεργοποιώντας τις οικιακές συσκευές όταν δεν υπάρχει ζήτηση, μειώνοντας έτσι την κατανάλωση ενέργειας.

Αυτοί οι δύο στόχοι είναι εύκολο να επιτευχθούν αν θεωρηθούν ανεξάρτητοι, αλλά ο σκοπός του ACHE ήταν να τους προσεγγίσει ταυτόχρονα, αποτελώντας την πραγματική πρόκληση του συστήματος. Εφαρμόστηκε ένα T.N.Δ., χρησιμοποιώντας ως εισόδους τόσο τις μεταβλητές που εμπλέκονται (όσον αφορά τις μέσες τιμές, τις ελάχιστες, τις μέγιστες τιμές και τις τιμές διακύμανσης) όσο και την δραστηριότητα των χώρων. Το δίκτυο επέστρεφε την πρόβλεψη της μελλοντικής κατάστασης του χώρου και της μελλοντικής κατάστασης των μεταβλητών που καθορίζουν το επίπεδο άνεσης, έτσι ώστε να μπορεί να ληφθεί απόφαση για τη λειτουργία των ενεργειακών συσκευών (Σχήμα 2.10). Αφού το T.N.Δ. επιστρέψει την πρόβλεψη των

³Πρόκειται για έναν αριθμητικό δείκτη που προτάθηκε από τον Fanger, ο οποίος εκφράζει την θερμική άνεση του περιβάλλοντος με βαθμολογία από το -3 (πολύ κρύο) έως +3 (πολύ ζεστό), όπου 0 αντιπροσωπεύει τη θερμική ουδετερότητα.

⁴Το ACHE παρακολουθεί το περιβάλλον, παρατηρεί τις ενέργειες των κατοίκων (π.χ., ρύθμιση του θερμοστάτη, ρύθμιση μια συγκεκριμένης διαμόρφωσης του φωτισμού, κ.ά) και προσπαθεί να προβλέψει μοτίβα στο οικιακό περιβάλλον που υποδηλώνουν αυτές τις ενέργειες.



Σχήμα 2.10 – Αρχιτεκτονική του συστήματος ACHE, (Mozier (1998))

μελλοντικών καταστάσεων, το σύστημα πρέπει να πάρει μια απόφαση ελέγχου για τις συσκευές. Η διαδικασία λήψης αποφάσεων χωρίστηκε σε δύο στάδια: μια γεννήτρια σημείων ρύθμισης (setpoint generator) καθορίζει ένα προφίλ καθορισμένων σημείων, προσδιορίζοντας την τιμή-στόχο ορισμένων περιβαλλοντικών μεταβλητών (επίπεδο φωτισμού, θερμοκρασία αέρα, θερμοκρασία νερού κ.λπ.). Ένας ελεγκτής ρυθμίζει τις φυσικές συσκευές που επιτρέπουν την επίτευξη της επιθυμητής τιμής. Χάρη στη διαίρεση της διαδικασίας λήψης αποφάσεων, εάν οι προτιμήσεις των κατοίκων ή τα περιβαλλοντικά χαρακτηριστικά αλλάξουν, μόνο η γεννήτρια ρύθμισης και ο ελεγκτής πρέπει να επανεκκινήσουν αντίστοιχα. Με αυτό τον τρόπο, οι συγγραφείς απέκτησαν ένα σύστημα το οποίο επέτρεπε τη διαχείριση της άνεσης υπό ρεαλιστικές συνθήκες λειτουργίας, με τα σχετικά οφέλη.

Ένα άλλο επαναλαμβανόμενο πεδίο εφαρμογής των Τ.Ν.Δ. είναι η βελτιστοποίηση της κατανάλωσης ενέργειας των συστημάτων θέρμανσης, εξαερισμού και κλιματισμού (Heating, Ventilating and Air Conditioning systems, HVAC). Η σημασία αυτού του θέματος σχετίζεται με την αυξανόμενη ευαισθησία στην εξοικονόμηση ενέργειας. Η βέλτιστη λειτουργία ενός συστήματος HVAC είναι θεμελιώδης δε-

δομένου ότι οι άνθρωποι ξοδεύουν το μεγαλύτερο μέρος του χρόνου τους μέσα στα κτήρια. Στις εξεταζόμενες περιπτώσεις, το εφαρμοζόμενο T.N.Δ. αποσκοπεί στην αξιολόγηση της άνεσης σε πραγματικό χρόνο, προκειμένου να ελέγξει τα συστήματα θέρμανσης ή ψύξης, ελαχιστοποιώντας την ζήτηση ενέργειας. Σε αυτά τα έργα οι συγγραφείς πρότειναν τη χρήση των T.N.Δ. για την εκτίμηση του PMV, του οποίου ο αναλυτικός προσδιορισμός απαιτεί υψηλές υπολογιστικές προσπάθειες ή / και μεγάλο αριθμό μετρούμενων παραμέτρων. Η περίπτωση εφαρμογής των T.N.Δ., απαιτεί τη χρήση ενός εκτεταμένου δικτύου αισθητήρων, λόγω των πολλών παραμέτρων όπως ο μεταβολικός ρυθμός, η μόνωση των ενδυμάτων, η θερμοκρασία του αέρα, η μέση θερμοκρασία λόγω ακτινοβολίας, η σχετική υγρασία και η ταχύτητα του αέρα. Η χρήση των T.N.Δ. για την εκτίμηση της τιμής του PMV επιτρέπει τη μείωση του χρόνου και του κόστους του υπολογισμού, ώστε μπορεί να συνεργάζεται με τα συστήματα HVAC, ρυθμίζοντας σε πραγματικό χρόνο τη λειτουργία και ικανοποιώντας το αίτημα άνεσης των κατοίκων. Αυτό έχει ως αποτέλεσμα τη μείωση της κατανάλωσης ενέργειας, χάρη στη βελτιστοποίηση του συστήματος HVAC.


Άλλες μελέτες διερεύνησαν τη δυνατότητα εκτίμησης του PMV μέσω των T.N.Δ., επιτυγχάνοντας καλά αποτελέσματα. Συγκεκριμένα, οι Buratti et al. (2015) εφάρμοσαν ένα feed-forward N.Δ. με τη χρήση του Matlab, με σκοπό τον προσδιορισμό του PMV με λιγότερες παραμέτρους εισόδου από την αναλυτική μέθοδο, έτσι ώστε να μην πραγματοποιούνται πειραματικές έρευνες και να απαιτείται λιγότερος χρόνος. Το T.N.Δ. εκπαιδεύτηκε με βάση πειραματικά δεδομένα και από 272 ερωτηματολόγια, χρησιμοποιώντας εννέα παραμέτρους εισόδου για την διαδικασία μάθησης: θερμική αντίσταση ρούχων, φύλο, μεταβολισμός, ηλικία, θέση μέσα στο χώρο (σε μορφή συντεταγμένων x, y), εσωτερική και εξωτερική θερμοκρασία αέρα και εσωτερική σχετική υγρασία. Το T.N.Δ. εφαρμόστηκε με επιτηρούμενη μάθηση, στο οποίο ο στόχος ήταν η θερμική αίσθηση που αναφέρθηκε στα ερωτηματολόγια. Μόλις επικυρώθηκε, εφαρμόστηκε το T.N.Δ. για

την πρόβλεψη της θερμικής αίσθησης υπό τις ίδιες συνθήκες αλλά σε διαφορετική χρονική περίοδο. Τα αποτελέσματα έδειξαν ότι το T.N.Δ. κατάφερε να προβλέψει σωστά τη θερμική αίσθηση που δηλώνεται στα ερωτηματολόγια, υποδηλώνοντας ότι το εκπαιδευμένο T.N.Δ. μπορεί να αποτελέσει χρήσιμο εργαλείο για αυτές τις εφαρμογές. Επιπλέον, συγκρίνοντας τα αποτελέσματα των ερωτηματολογίων με αυτά που προέβλεπε το T.N.Δ. και το στατικό μοντέλο του Fanger (Σχήμα 2.11), βρέθηκε καλύτερος συσχετισμός μεταξύ των προβλέψεων του T.N.Δ. και των ερωτηματολογίων σε σχέση με τα μοντέλα του Fanger και τα δεδομένα που προέκυπταν απ' τα ερωτηματολόγια.

2.4.3 Ποιότητα αέρα σε εσωτερικούς χώρους

Μια λιγότερο κοινή χρήση των T.N.Δ. σε εφαρμογές κτηρίων ασχολείται με την πρόβλεψη της ποιότητας του εσωτερικού αέρα. Παρ' όλα αυτά, η ποιότητα του αέρα των εσωτερικών χώρων είναι ένας σημαντικός τομέας έρευνας λόγω του αντίκτυπου στην υγεία και στην άνεση των ανθρώπων. Τα T.N.Δ. έχουν την ικανότητα να αξιολογήσουν την ποιότητα του αέρα, καθιστώντας δυνατή την πρόβλεψη της συγκέντρωσης ρύπων μέσα στα κτήρια. Στο Das et al. (2014) οι συγγραφείς ήταν σε θέση να μοντελοποιήσουν τη συγκέντρωση του CO_2 μέσω ενός T.N.Δ. Αναλύοντας ως μελέτη περίπτωσης μία πολυκατοικία στη Φινλανδία και συγκεντρώνοντας δεδομένα θερμοκρασίας, σχετικής υγρασίας και συγκέντρωσης CO_2 από 8 διαμερίσματα. Ένα δίκτυο πολλαπλών επιπέδων (M.L.P.) εφαρμόστηκε χρησιμοποιώντας ένα κρυφό επίπεδο με 10 νευρώνες. Πριν από την εκπαίδευση του δικτύου, πραγματοποιήθηκε προεπεξεργασία των διαθέσιμων δεδομένων, αφαιρώντας τις ακραίες τιμές (outliers) και εξάγοντας τις παρακολουθούμενες λειτουργίες χρησιμοποιώντας ένα χρονικό παράθυρο 60 λεπτών. Για κάθε σύνολο οι εισοδοί ήταν 7 στατιστικές παράμετροι που εξήχθησαν από δεδομένα θερμοκρασίας και σχετικής υγρασίας, ενώ ως στόχοι χρησιμοποιήθηκαν οι μετρούμενες συγκεντρώσεις CO_2 . Συμπερασματικά, οι συγγραφείς παρατήρησαν ότι η

πρόβλεψη του CO_2 μέσω των Τ.Ν.Δ. είναι δύσκολη, όταν χρησιμοποιούνται ως δεδομένα εισόδου η θερμοκρασία και η σχετική υγρασία.



Σχήμα 2.11 – Σύγκριση δεικτών PMV: Τεχνητό νευρωνικό δίκτυο έναντι στατικού μοντέλου του Fanger (Buratti et al. (2015))

2.5 Εξωτερικές συνθήκες

Όπως επισημαίνεται στο Σχήμα 2.1, (σελ. 42) η εφαρμογή των Τ.Ν.Δ. στην αξιολόγηση των εξωτερικών θερμικών συνθηκών είναι κοινή και εφαρμόστηκε με διαφορετικούς και μερικές φορές ενδιαφέροντες σκοπούς. Συγκεκριμένα, οι μελέτες επικεντρώθηκαν στην αξιολόγηση των εκπομπών των αερίων του θερμοκηπίου και περιβαλλοντικών παραμέτρων όπως η θερμοκρασία του αέρα και η ηλιακή ενέργεια μέσω ακτινοβολίας.

2.5.1 Εκπομπές αερίων

Η μείωση των εκπομπών των αερίων του θερμοκηπίου είναι ένα τρέχον θέμα που συνδέεται με την ανάγκη μείωσης της κατανάλωσης ενέργειας. Μια από τις πρώτες εφαρμογές των Τ.Ν.Δ. σε αυτό το είδος θεμάτων υλοποιήθηκε από τους Mok & Tam (1998). Η ικανότητα των Τ.Ν.Δ. χρησιμοποιήθηκε για τη βραχυπρόθεσμη πρόβλεψη της συγκέντρωσης του SO_2 στο Μακάο, όπου, λόγω της οικονομικής

ανάπτυξης αυτών των ετών, αποκαλύφθηκε μια σημαντική επιδείνωση της ποιότητας του αέρα. Η ικανότητα των T.N.Δ. χρησιμοποιήθηκε για την πρόβλεψη της συγκέντρωσης του SO_2 τα επόμενα 5 χρόνια. Χάρη στην καλή ακρίβεια που αποκτήθηκε σε δύο διαφορετικές περιόδους δοκιμών του εφαρμοσμένου T.N.Δ., οι συγγραφείς πρότειναν να χρησιμοποιήσουν το αναπτυγμένο T.N.Δ. ως μοντέλο πρόβλεψης για μια αποτελεσματική ανάλυση της ποιότητας του αέρα της πόλης.

Έγιναν και άλλες ενδιαφέρουσες μελέτες σχετικά με τον υπολογισμό και την πρόβλεψη των εκπομπών αερίων. Οι Zhou et al. (2004) πρότειναν μια νέα προσέγγιση χρησιμοποιώντας τα T.N.Δ. για την πρόβλεψη της εκπομπής οξειδίων του αζώτου (NO_x) από ένα λέβητα άνθρακα. Οι Sayin et al. (2007) πρότειναν να χρησιμοποιηθεί η δυνατότητα των T.N.Δ. για την πρόβλεψη της κατανάλωσης καυσίμου, της θερμικής απόδοσης, της θερμοκρασίας των καυσαερίων και των εκπομπών καυσαερίων ενός βενζινοκινητήρα.

Μια ενδιαφέρουσα ανάλυση διεξήχθη από τους Sipöcz et al. (2011): η ικανότητα των T.N.Δ. να επιλύει μη γραμμικές διεργασίες χρησιμοποιήθηκε για τη μοντελοποίηση της μονάδας δέσμευσης CO_2 . Το T.N.Δ. εκπαιδεύτηκε με δεδομένα που δημιουργήθηκαν χρησιμοποιώντας έναν προσομοιωτή διεργασίας για μια διαδικασία δέσμευσης CO_2 μετά την καύση. Κατά τη διάρκεια της διαδικασίας επικύρωσης (validation) του δικτύου, προέκυψε ένα πολύ μικρό μέσο σφάλμα, με μέγιστη τιμή περίπου 3,1%. Χάρη στην καλή ανταπόκριση και την ακρίβεια του δικτύου, οι συγγραφείς πρότειναν τη χρήση για διαγνωστικούς σκοπούς που σχετίζονται με τη δέσμευση CO_2 στα φυτά.

Στο (Khoshnevisan et al. (2013)) αναπτύχθηκε ένα T.N.Δ. για την πρόβλεψη της απόδοσης της παραγωγής σιτηρών και εκπομπών αερίων θερμοκηπίου στο Esfahan (Ιράν), παρέχοντας μόνο ενεργειακές εισόδους για την εκπαίδευση του δικτύου. Για την υλοποίηση του δικτύου χρησιμοποιήθηκαν δεδομένα από 260 αγροκτήματα. Συγκεκριμένα, ως παράμετροι εισόδου παρασχέθηκαν η ανθρώπινη εργασία, τα χημικά λιπάσματα, τα φυσικά λιπάσματα, το πετρέλαιο, το νερό άρδευσης, ο ηλεκτρισμός, τα παρασιτοκτόνα και τα μηχανήματα, ενώ η από-

δοση και οι εκπομπές CO_2 επιλέχθηκαν ως έξοδοι στην προσομοίωση από το T.N.Δ. Διαφορετικά νευρωνικά δίκτυα αναπτύχθηκαν και η ακρίβεια και η επιλογή των καλύτερα εκπαιδευμένων δικτύων πραγματοποιήθηκε λαμβάνοντας υπόψη τον συντελεστή προσδιορισμού (R^2). Όπως φάνηκε, οι εφαρμογές των T.N.Δ. σε αυτού του είδους προβλημάτων επιτρέπουν την εκτίμηση του ποσού της παραγωγής ενέργειας και των εκπομπών των αερίων θερμοκηπίου λαμβάνοντας υπόψη όχι μόνο το μέγεθος του αγροκτήματος, αλλά και την πραγματική ζήτηση και κατανάλωση ενέργειας.


Άλλες ενδιαφέρουσες μελέτες πρότειναν την εφαρμογή των T.N.Δ. για την αξιολόγηση εξωτερικών περιβαλλοντικών παραμέτρων, όπως η θερμοκρασία του αέρα, η ταχύτητα του αέρα και η ηλιακή ακτινοβολία.

2.5.2 Ηλιακή ακτινοβολία

Το κύριο μέρος των δημοσιεύσεων που μελετήθηκαν επικεντρώνεται στην αξιολόγηση της ηλιακής ακτινοβολίας σε ένα συγκεκριμένο τόπο ή χώρα και οι μεθοδολογίες που υιοθετήθηκαν για την εφαρμογή των T.N.Δ. είναι πολύ κοντά μεταξύ τους. Για παράδειγμα, στο (Sözen et al. (2004)) ένα T.N.Δ. εκπαιδεύτηκε για τη χαρτογράφηση του ηλιακού δυναμικού της Τουρκίας. Ο Mubiru (2008) ανέπτυξε ένα T.N.Δ. ικανό να προβλέψει τη μέση ημερήσια συνολική ηλιακή ακτινοβολία σε επίπεδη επιφάνεια στην Ουγκάντα. Οι Bosch et al. (2008) εφάρμοσαν ένα μοντέλο T.N.Δ. για την εκτίμηση της καθημερινής ηλιακής ακτινοβολίας σε μια ορεινή περιοχή, προκειμένου να αναπτύξουν ένα χρήσιμο εργαλείο για το σχεδιασμό ενεργών και παθητικών συστημάτων ηλιακής ενέργειας.

Ο Jiang (2009) διεξήγαγε μια συγκριτική ανάλυση μεταξύ των αποτελεσμάτων που επέστρεφε το εφαρμοσμένο T.N.Δ. και εκείνων που προέκυπταν με την εφαρμογή άλλων εμπειρικών μοντέλων παλινδρόμησης. Το T.N.Δ. (Σχήμα 2.12) εκπαιδεύτηκε για να υπολογίσει την ανά μήνα μέση ημερήσια παγκόσμια ακτινοβολία ($\overline{H}_g$) στην Κίνα χρησιμοποιώντας πειραματικά δεδομένα που έχουν συγκεντρωθεί σε

μετεωρολογικούς σταθμούς που βρίσκονται σε Haerbin και σε άλλες 7 πόλεις, ενώ τα δεδομένα που παρακολουθούνται στο Kashi και σε άλλες 5 πόλεις χρησιμοποιήθηκαν για τη δοκιμή της ακρίβειας του μοντέλου. Τα αποτελέσματα συγκρίθηκαν με τα παρακολουθούμενα



Σχήμα 2.12 – Η αρχιτεκτονική του εφαρμοζόμενου feed-forward ANN.

και με αυτά που υπολογίστηκαν με τη χρήση εμπειρικών μοντέλων πρόγνωσης που προτείνονται στη βιβλιογραφία, θεωρώντας ως στατιστικές μεταβλητές το μέσο ποσοστό σφάλματος (MPE⁵), το μέσο σφάλμα εκτίμησης (MBE) και την τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) (βλ. ενότ. 1.11.1 σελ. 33 και 31 αντίστοιχα). Το εκπαιδευμένο Τ.Ν.Δ. έδειξε υψηλότερη τιμή R^2 και χαμηλότερα MPE, MBE και RMSE (Πίνακας 2.2) σε σχέση με αυτά που ελήφθησαν με τις άλλες εφαρμοζόμενες μεθόδους, έτσι ώστε το Τ.Ν.Δ. θεωρήθηκε πιο κατάλληλο για την πρόβλεψη της ηλιακής ακτινοβολίας.


2.5.3 Αιολική ενέργεια

Άλλες μελέτες, επικεντρώνονται στην εφαρμογή των Τ.Ν.Δ. για την πρόβλεψη της ταχύτητας του αέρα. Ο Çam et al. (2005) ανέπτυξαν ένα Τ.Ν.Δ. για την ταχύτητα ανέμου και την εκτίμηση της

⁵MPE: Mean Percentage Error

Πίνακας 2.2 – Σφάλματα πρόβλεψης των 7 μοντέλων για 8 πόλεις


	R^2	MPE (%)	MBE (MJ/m^2)	RMSE (MJ/m^2)
Model 1	0.89	0.70	0.002	1.100
Model 2	0.90	0.65	-0.005	1.090
Model 3	0.90	-1.16	-0.276	1.133
Model 4	0.90	0.75	-0.012	1.081
Model 5	0.90	-6.85	-1.305	2.508
Model 6	0.90	-6.02	-1.185	2.396
T.N.Δ.	0.97	0.48	-0.021	0.867

Σχήμα 2.13 – Η μετρούμενη σε σχέση με την προβλεπόμενη απ' το ANN τιμή της μέσης ημερήσιας παγκόσμιας ακτινοβολίας $\bar{H}_g$ σε 8 πόλεις της Κίνας

αιολικής ενέργειας σε επτά περιφέρειες της Τουρκίας, χρησιμοποιώντας πειραματικά δεδομένα των τελευταίων 50 ετών, ενώ οι Bilgili et al. (2007) εφάρμοσαν ένα μοντέλο T.N.Δ. για την πρόβλεψη της μέσης μηνιαίας ταχύτητας του ανέμου στην περιοχή της Μεσογείου κοντά στην Τουρκία.

Εστιάζοντας στην πρόβλεψη του πραγματικού δυναμικού της ταχύτητας του ανέμου, ο Fadare (2010) διεξήγαγε μια ενδιαφέρουσα μελέτη για τη χαρτογράφηση του προφίλ της ταχύτητας του ανέμου για την παραγωγή ενέργειας στη Νιγηρία. Το δίκτυο εκπαιδεύτηκε

και δοκιμάστηκε με δεδομένα που παρακολουθούνταν για 20 χρόνια σε 28 επίγειους σταθμούς (10 μέτρα πάνω από το έδαφος). Για την εκπαίδευση χρησιμοποιήθηκαν 18 σταθμοί και 10 σταθμοί για τη δοκιμή του δικτύου. Οι πληροφορίες σχετικά με την τοποθεσία (γεωγραφικές παράμετροι) και τον μήνα του έτους παρασχέθηκαν ως παράμετροι εισόδου, ενώ η μηνιαία ταχύτητα ανέμου χρησιμοποιήθηκε ως έξοδος. Το καλύτερο εκπαιδευμένο Τ.Ν.Δ. αποκτήθηκε με μέσο



Σχήμα 2.14 – Αρχιτεκτονική Τ.Ν.Δ. για την πρόβλεψη της ταχύτητας του αέρα.

απόλυτο ποσοστό σφάλματος, MAPE 8,9% (βλ. ενότ. 1.11.1, σελ. 32) και συντελεστή συσχέτισης, $R=0,938$. Η προβλεπόμενη από το Τ.Ν.Δ. μηνιαία ταχύτητα ανέμου κυμάνθηκε από 0,9-13,1 m / s με μέση ετήσια τιμή περίπου 4,7 m/s. Όπως πρότεινε ο συγγραφέας, το αναπτυγμένο Τ.Ν.Δ. μπορεί να αποτελέσει χρήσιμο εργαλείο για την αξιολόγηση του αιολικού δυναμικού σε διάφορες τοποθεσίες της Νιγηρίας.

2.5.4 Εξωτερική θερμοκρασία

Όπως επισημανθηκε, μεγάλο μέρος των μελετών που βρέθηκαν στη βιβλιογραφία επικεντρώνεται στην πρόβλεψη της ηλιακής ακτινοβολίας ή της ταχύτητας του ανέμου. Ωστόσο, η θερμοκρασία του εξωτερικού αέρα είναι μια άλλη σημαντική παράμετρος που πρέπει να αξιολογηθεί. Οι Papantoniou & Kolokotsa (2016) εφάρμοσαν την

προσέγγιση των T.N.Δ. για την αξιολόγηση της θερμοκρασίας του εξωτερικού αέρα σε τέσσερις πόλεις: Ανκόνα (Ιταλία), Χανιά (Ελλάδα), Γρανάδα και Mollet (Ισπανία). Η αποτελεσματικότητα του δικτύου δοκιμάστηκε χρησιμοποιώντας τις παραδοσιακές παραμέτρους ελέγχου R^2 και MSE. Το δίκτυο εκπαιδεύτηκε παρέχοντας χρόνο (λεπτά της ημέρας), εξωτερική θερμοκρασία, ηλιακή ακτινοβολία, ταχύτητα ανέμου και σχετική υγρασία. Ήταν σε θέση να προβλέψει τη θερμοκρασία του εξωτερικού αέρα με χρονικό ορίζοντα 4-24 h. Τα αποτελέσματα έδειξαν μια πολύ καλή συσχέτιση μεταξύ πειραματικών και προσομοιωμένων δεδομένων, με πολύ υψηλό R^2 και αποδεκτό MSE. Ειδικά το μικρότερο MSE βρέθηκε όταν η θερμοκρασία του εξωτερικού αέρα προβλεπόταν σε πιο κοντινό χρονικό ορίζοντα.


2.6 Άλλες εφαρμογές

Πολλές άλλες ενδιαφέρουσες πτυχές ερευνώνται στη βιβλιογραφία χρησιμοποιώντας τα μοντέλα των T.N.Δ. Σχετικά με τα κτήρια και τα ενεργειακά πεδία, τα θέματα φωτισμού και ακουστικής είναι άλλα δύο σημαντικά θέματα όπου η εφαρμογή των T.N.Δ. οδήγησε σε ενδιαφέροντα αποτελέσματα.


2.6.1 Φωτισμός

Πολλές μελέτες που βρέθηκαν στη βιβλιογραφία επικεντρώνονται στην εκτίμηση των συνθηκών εσωτερικού φωτισμού, αναλύοντας τόσο τον εσωτερικό φυσικό φωτισμό όσο και τον τεχνητό φωτισμό.

Οι Kazanasmaz et al. (2009) ανέπτυξαν ένα T.N.Δ. για την πρόβλεψη του φωτισμού της ημέρας σε κτήρια γραφείων (Σχήμα 2.15), ενώ οι Wong et al. (2010) εφάρμοσαν ένα T.N.Δ. για την ανάλυση της ενέργειας, εξετάζοντας τις επιδράσεις του φωτισμού της ημέρας σε κτήρια γραφείων (Σχήμα 2.16). Μια ενδιαφέρουσα εφαρμογή διερευνήθηκε από τους Kialashaki & Reisel (2013), όπου ανέπτυξαν ένα T.N.Δ. για να εκτιμήσουν την παγκόσμια απαίτηση ενέργειας των οικιστικών κτηρίων συγκρίνοντας δύο διαφορετικά μοντέλα. Μοντέλα




Σχήμα 2.15 – Αρχιτεκτονική Τ.Ν.Δ. για την αξιολόγηση του φυσικού φωτισμού σε κτήρια γραφείων (Kazanasmaz et al. (2009)).



Σχήμα 2.16 – Τοπολογία του Μ.Λ.Ρ. που εξετάζει την ανάλυση της ενέργειας λόγω της επίδρασης του φωτισμού σε κτήρια γραφείων.


παλινδρόμησης και T.N.Δ. Προκειμένου να αναπτυχθεί ένας αλγόριθμος ικανός να προβλέψει τη μελλοντική ενεργειακή ζήτηση των κτηρίων, ελήφθησαν υπόψη όλοι οι ενεργειακοί φορείς, συμπεριλαμβανομένων και των καταναλωτών φωτισμού.

Στο (Wang & Tan (2013)) δοκιμάστηκε μία άλλη εφαρμογή T.N.Δ. Οι συγγραφείς περιέγραψαν την υλοποίηση ενός T.N.Δ. για την εκτίμηση της φωτεινότητας από φωτιστικά LED με ρυθμιζόμενο (dimmable) φωτισμό εντός ενός γραφείου. Σκοπός του έργου ήταν η εξατομίκευση μιας μεθόδου τόσο για την ικανοποίηση των προτιμήσεων φωτισμού των χρηστών των γραφείων όσο και για την ελαχιστοποίηση της κατανάλωσης ενέργειας του συστήματος φωτισμού. Οι στόχοι αυτοί μπορούν να επιτευχθούν με τη βελτιστοποίηση των επιπέδων φωτισμού των κατανεμημένων φωτιστικών (Σχήμα 2.17). Το προτεινόμενο σύστημα, βασισμένο στην εφαρμογή ενός T.N.Δ.



Σχήμα 2.17 – Αριστερά: Οι ισούψεις με πλήρη φωτισμό. Δεξιά: Οι ισούψεις μετά απ' τον βέλτιστο έλεγχο.

λόγω της μη γραμμικότητας του προβλήματος, απέτρεψε την έντονη φωτεινότητα, η οποία επηρεάζει την όραση και την αποτελεσματικότητα των χρηστών και βελτιώνει την εξοικονόμηση ενέργειας. Η προτεινόμενη αρχιτεκτονική περιελάμβανε ένα δίκτυο πρόσθιας τροφοδότησης (feed-forward) δύο επιπέδων, με 14 επίπεδα γενικού φωτισμού ως είσοδοι και τις τιμές φωτεινότητας σε 12 γραφεία ως έξοδοι (Σχήμα 2.18). Ως δεδομένα μάθησης συγκεντρώθηκαν 600 σύνολα



Σχήμα 2.18 – Δύο επιπέδων feed-foreword δίκτυο.

με τις εισόδους-στόχους: για κάθε σύνολο χρησιμοποιήθηκε ως είσοδος συνδυασμός 14 επιπέδων γενικού φωτισμού, ενώ οι στόχοι ήταν οι μετρηθείσες αντίστοιχες τιμές φωτεινότητας στα γραφεία. Το σύστημα ελέγχου φωτισμού ολοκληρώθηκε με έναν αλγόριθμο με σκοπό την εξεύρεση της βέλτιστης διαμόρφωσης φωτισμού για όλα τα φωτιστικά, γεγονός που επέτρεψε την ελάχιστη ζήτηση ενέργειας. Οι συγγραφείς επεσήμαναν ένα σημαντικό πλεονέκτημα αυτού του συστήματος. Μετά την εκπαίδευση του Τ.Ν.Δ. και την ολοκλήρωση της χαρτογράφησης (mapping) εισόδου-εξόδου του επιπέδου δοκιμής, δεν χρειάζονται περισσότεροι αισθητήρες φωτός ως ανάδραση στον ελεγκτή και τα φωτιστικά δεν θα αλλάξουν τις τιμές φωτεινότητας κατά τη διάρκεια της φάσης ελέγχου.

2.6.2 Ακουστική


Το θέμα της ακουστικής διερευνήθηκε επίσης εφαρμόζοντας τα μοντέλα των Τ.Ν.Δ. Οι Nannariello & Fricke (1999) προσπάθησαν να χρησιμοποιήσουν την ικανότητα των Τ.Ν.Δ. για την πρόβλεψη του χρόνου αντήχησης και για τα επίπεδα ομιλίας στις πανεπιστημιακές τάξεις (Nannariello et al. (2001)). Οι Too et al. (2007) πρότειναν μια νέα προσέγγιση για τη μέτρηση της ακουστικής σύνθετης αντίστασης ενός τοίχου ή υλικού. Η προτεινόμενη μέθοδος συνίσταται στην ανάπτυξη ενός Τ.Ν.Δ. ικανό να προβλέψει την άγνωστη ακουστική σύνθετη αντίσταση ενός εξεταζόμενου υλικού ξεκινώντας από δεδομένα που αξιολογούνται χρησιμοποιώντας ένα πρότυπο κουτί με γνωστές οριακές συνθήκες.

Θεωρώντας τα παράθυρα ως το ασθενέστερο μέρος της πρόσοψης

των κτηρίων από ακουστική άποψη, οι Buratti et al. (2013) πρότειναν μια νέα μεθοδολογία για την αξιολόγηση των ηχομονωτικών ιδιοτήτων των ξύλινων παραθύρων. Ο σταθμισμένος δείκτης ηχομόνωσης R_w προβλεπόταν ως αντιπροσωπευτική παράμετρος της ακουστικής μόνωσης προσόψεων, η οποία μετράται γενικά με εργαστηριακές δοκιμές σύμφωνα με το ISO 140-3. Σε αυτή τη μελέτη, οι συγγραφείς ανέπτυξαν ένα τεχνητό νευρωνικό δίκτυο ικανό να προβλέψει την τιμή R_w χρησιμοποιώντας δεδομένα που αποκτήθηκαν κατά τη διάρκεια εργαστηριακών δοκιμών σε 55 ξύλινα παράθυρα. Οι είσοδοι που πρέπει να δωθούν για την υλοποίηση του δικτύου επιλέχθηκαν λαμβάνοντας υπόψη εκείνες που έχουν μεγαλύτερη επίδραση στην τιμή R_w . Ειδικότερα, μετά από μια προκαταρκτική μελέτη, ο τύπος των παραθύρων, το πάχος του πλαισίου, το πάχος των παραθυρόφυλλων και ο αριθμός των παρεμβυσμάτων παρέχονται ως παράμετροι εισόδου, ενώ η τιμή R_w χρησιμοποιήθηκε ως στόχος. Το δίκτυο εκπαιδεύτηκε χρησιμοποιώντας δύο κρυφά επίπεδα και το RMSE (βλ. ενότ. 1.11.1, σελ. 31) θεωρήθηκε ως παράμετρος ελέγχου για τον έλεγχο της αποτελεσματικότητας της διαδικασίας της μάθησης. Τα αποτελέσματα έδειξαν ότι το T.N.Δ. είναι σε θέση να προβλέψει την τιμή R_w των ξύλινων παραθύρων Σχήμα 2.19 με σφάλμα εντός του $\pm 3\%$, που αντιστοιχεί περίπου $\pm 1,2$ dB (συγκρίσιμο με την αβεβαιότητα των μετρήσεων). Σε συμφωνία με τα αποτελέσματα, οι συγγραφείς πρότειναν το εφαρμοσμένο δίκτυο ως ένα χρήσιμο εργαλείο για την εύκολη εκτίμηση της ακουστικής απόδοσης των παραθύρων χωρίς εργαστηριακές δοκιμές.

2.7 Συμπεράσματα

Παρουσιάστηκε μια επισκόπηση των T.N.Δ. σε ενεργειακές εφαρμογές κτηρίων και σχετικά θέματα. Η αντιμετώπιση προβλημάτων με τη χρήση T.N.Δ. είναι πολύ συχνή στους τομείς της ενέργειας και πολλοί ερευνητές, επισημαίνουν την αποτελεσματικότητα και τα πλεονεκτήματα της εφαρμογής αυτού του είδους των αλγορίθμων στην ανάλυση αυτών των προβλημάτων.



Σχήμα 2.19 – Προβλεπόμενες τιμές R_w που ελήφθησαν από τα μοντέλα T.N.Δ. έναντι μετρούμενων τιμών R_w (Buratti et al. (2013))

Στον τομέα της πρόβλεψης της κατανάλωσης ενέργειας στα κτήρια, η απόκριση των T.N.Δ ήταν πολύ καλή, όπως επισημάνθηκε κατά τη σύγκριση των αποτελεσμάτων με τα πειραματικά αποτελέσματα. Σχεδόν όλες οι μελέτες που εξετάστηκαν, επικεντρώθηκαν στη ικανότητα γενίκευσης των T.N.Δ. και υπογράμμισαν ότι είναι ένας εναλλακτικός τρόπος προσέγγισης που δίνει εξίσου καλά αποτελέσματα με τις συμβατικές μεθοδολογίες. Πολλοί ερευνητές υπογράμμισαν επίσης την ικανότητα αυτών των μοντέλων να προβλέπουν το τελικό αποτέλεσμα, χρησιμοποιώντας ορισμένα απ' τα δεδομένα εισόδου σε αντίθεση με τις κλασσικές μεθοδολογίες.

Παρατηρήθηκε ότι αν και μπορούν να υπάρξουν προσεγγίσεις με διάφορους τύπους T.N.Δ., εφαρμόζονται κυρίως τα Feed-Forward νευρωνικά δίκτυα, πιθανώς λόγω της ευκολότερης διαδικασίας μάθησης και εφαρμογής τους.

Υπήρξαν όμως και εξαιρέσεις. Παρατηρήθηκε ότι σε τομείς όπως η θερμική άνεση, η φωτεινότητα και η ακουστική άνεση η εφαρμογή

των Τ.Ν.Δ. δεν δίνει καλά αποτελέσματα επειδή οι εκτιμώμενες έξοδοι είναι υποκειμενικές (πχ. εξαρτώνται απ' το φύλο, ηλικία, διάθεση κτλ) καθώς επίσης εξαρτώνται από πολλούς άλλους παράγοντες. Έτσι, αν και η αρχιτεκτονική και η μεθοδολογία που εφαρμόζονται είναι οι ίδιες με εκείνες που περιγράφουν τις ενεργειακές εφαρμογές των κτηρίων, ωστόσο δεν διαπιστώθηκε πάντοτε πολύ καλή απόκριση λόγω του είδους των προσομοιωμένων παραμέτρων. Η αξιοπιστία των Τ.Ν.Δ. φαίνεται να χρειάζεται βελτίωση σε αυτού του τύπου τις εφαρμογές.

Γενικά, τα αποτελέσματα επιδοκιμάζουν τη χρήση των Τ.Ν.Δ. σε όλα τα εξεταζόμενα θέματα. Υπογραμμίζεται η πολύ καλή απόκριση των μοντέλων όταν υπάρχει αυστηρή σύνδεση των επιλεγμένων εισόδων με τις εξόδους ή εάν είναι διαθέσιμα πολλά δεδομένα για την εκπαίδευση του δικτύου. Αν δεν υπάρχει αυτή η αυστηρή σύνδεση, τότε είναι απαραίτητο να εκπαιδεύσουμε το δίκτυο χρησιμοποιώντας χιλιάδες δεδομένα για κάθε επιλεγμένη παράμετρο εισόδου, προκειμένου να αποκτήσει καλή αξιοπιστία το δίκτυο. Επιπλέον τα Τ.Ν.Δ. έχουν πολύ καλή απόκριση, με μικρότερη δαπάνη πόρων (όσον αφορά το χρόνο, το κόστος και τα μέσα) σε σχέση με τις παραδοσιακές μεθοδολογίες.

A' | Ανάλυση papers

Πίνακας A'.1 – Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Datta & Tassou (1998)	MLP	6	1	4	1	Hyperbolic tan (tanh)	BP

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Datta & Tassou (1998)	RBF	6	1		1	Gaussian basis function	n.a.
Kalogirou & Bojic (2000)	multilayer recurrent “Jordan Elman recurrent network”	5	2	46	1	log sigmoid	BP
Sözen et al. (2007)	FF MLP	2	1	7	4	log sigmoid	LM & SCG

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Sözen et al. (2007)	FF MLP	3	2	8	3	log sigmoid	LM & SCG
Tan et al. (2009)	FF MLP	6	1	6	1	Hyperbolic tan (tanh)	BP
Tan et al. (2009)	SOM						
Buratti, Barbanera, & Palladino (2014)	2-layer FF MLP	12	1	75	1	linear & logistic	BP

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Ekonomou (2010)	MLP	4	2	37	1	Sigmoid	LM
Kalogirou et al. (1998)		8	3	24	4	Linear & Hyperbolic tan (tanh) & Logistic	BP
De et al. (2007)	2 sub modules	27	2	n.a.	8	Hyperbolic tan (tanh)	n.a.
Kana et al. (2012)	MLP	5	1	2	1	Sigmoid	LM

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Almonacid et al. (2013)	FF MLP	5	1	7	1	n.a.	LM
Gunasekar et al. (2015)	FF MLP	4	1	15	4	log sigmoid	LM
Kumar et al. (2006)	2-layer FF MLP	1	1	6	1	Hyperbolic tan (tanh)	LM
Kalogirou et al. (2012)	FF 5 Slabs	9	3	15	1	gaussian & Hyperbolic tan (tanh)	BP

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Ferreira et al. (2002)	RBF						LM
Ömer Altan Dombaycı & Gölcü (2009)	2-layer FF MLP	3	1	6	1	Hyperbolic tan (tanh)	LM
Moon et al. (2013)	n.a.	7	1	15	1	Hyperbolic tan (tanh)	LM

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Buratti, Las- caro, et al. (2014)	3-layer FF MLP	20	2	110	1	Sigmoid	BP
Buratti et al. (2012)	FF MLP	10	2	22	1	Binary sigmoid function	BP
Mozer (1998)	FF	n.a.	n.a.	n.a.	n.a.	n.a.	BP
Buratti et al. (2015)	2-layer FF MLP	9	1	41	1	Sigmoid	LM

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Das et al. (2014)	FF Cascade forward	3	2	6	2	Hyperbolic tan (tanh)	Bayesian
Das et al. (2014)	FF Cascade forward	3	2	12	2	Hyperbolic tan (tanh)	LM
Mok & Tam (1998)	3-layer FF MLP	n.a.	2	21	1	Sigmoid	BP
Zhou et al. (2004)	3-layer FF MLP	29	1	31	1	Sigmoid	BP

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Sayin et al. (2007)	MLP	4	1	15	5	Hyperbolic tan (tanh)	LM
Sipöcz et al. (2011)	1-hidden layer FF	6	1	36	3	Hyperbolic tan (tanh)	LM & SCG
Khoshnevisan et al. (2013)	MLP	11	2	10	2	non linear	BP
Sözen et al. (2004)							

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Çam et al. (2005)	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.
Bilgili et al. (2007)	FF MLP	5	2	18	1	linear & logistic	Resilient Propagation RP
Mubiru (2008)	FF MLP	6	1	15	1	Hyperbolic tan (tanh)	LM
Bosch et al. (2008)	MLP	n.a.	1		1	Hyperbolic tan (tanh)	n.a.

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Jiang (2009)	FF MLP	3	1	7	1	Hyperbolic tan (tanh)	BP
Fadare (2010)	MLP	4	2	5	1	Hyperbolic tan (tanh)	LM & SCG
Papantoniou & Kolokotsa (2016)	FF	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.
Papantoniou & Kolokotsa (2016)	Elman	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Papantoniou & Kolokotsa (2016)	Cascade	n.a.	n.a.	n.a.	n.a.	n.a.	n.a.
Kazanasmaz et al. (2009)	3-layer FF MLP	13	1	7	1	n.a.	BP
Wong et al. (2010)	FF MLP	9	1	n.a.	4	log sigmoid	BP
Kialashaki & Reisel (2013)	FF MLP	n.a.	1		1	log sigmoid	BP

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Wang & Tan (2013)	2-layer FF MLP	14	1	10	12	Hyperbolic tan (tanh)	n.a.
Nannariello & Fricke (1999)		15	n.a.	4	n.a.	n.a.	BP
Nannariello et al. (2001)		15	n.a.	n.a.	n.a.	n.a.	BP
Too et al. (2007)	Backward propagation BPN	n.a.	n.a.	n.a.	n.a.	n.a.	BP

συνεχίζεται ...

Πίνακας Α'.1 Ανάλυση papers

paper	A.N.N.	# input para- met- ers	# hidden layers	# neurons in hidden layers	# of outputs	Transfer function	Learning algorithm
Buratti et al. (2013)	FF MLP	5	2	18	1	Binary sigmoid function	BP

Κατάλογος σχημάτων

1.1 Τεχνικές της Υπολογιστικής Νοημοσύνης	3
1.2 Σχέδιο νευρώνα.	4
1.3 Δίκτυο πρόσθιας τροφοδότησης (Feed-forward)	9
1.4 Παράδειγμα αυτοσυσχετιζόμενης μνήμης	10
1.5 Παράδειγμα ετεροσυσχετιζόμενης μνήμης ή δίκτυο τύ- που Elman	10
1.6 Δίκτυο Hopfield	11
1.7 Δίκτυο Kohonen	13
1.8 Δίκτυο PNN	16
1.9 Εκπαίδευση με επίβλεψη με χρήση του αλγορίθμου μά- θησης backpropagation	19
1.10 Εκπαίδευση σε καθορισμένο δίκτυο	20
1.11 Χωρισμός του συνόλου δεδομένων (Data set) σε 2 ανε- ξάρτητα υποσύνολα	20
1.12 Εκπαίδευση σε μη καθορισμένο δίκτυο	22
1.13 Χωρισμός του συνόλου δεδομένων (Data set) σε 3 ανε- ξάρτητα υποσύνολα	22
1.14 Σημείο διακοπής αλγορίθμου	23
1.15 Σχέση της πόλωσης και της διαχύμανσης με το ολικό σφάλμα και την πολυπλοκότητα του δικτύου	24
1.16 Regression: Underfitting	25
1.17 Regression: Overfitting	25
1.18 Regression: Καλή προσαρμογή	25
1.19 Classification: Underfitting	26
1.20 Classification: Overfitting	26
1.21 Classification: Καλή προσαρμογή	26

1.22	Perceptron: η ευκολότερη αρχιτεκτονική ενός F.F. νευρωνικού δικτύου.	27
1.23	Παράδειγμα Confusion matrix και μετρικές με βάση τον Πίνακα Σύγχυσης	35
2.1	Ποσοστό των μελετών που πραγματοποιήθηκαν σε διαφορετικά πεδία εφαρμογής.	42
2.2	Αριθμός κρυφών επιπέδων που ορίζονται στην υλοποίηση του T.N.Δ.	44
2.3	Αριθμός εισόδων και νευρώνων που χρησιμοποιούνται για την εκτέλεση των T.N.Δ.	45
2.4	Χρήση της συνάρτησης μεταφοράς στα κρυμμένα επίπεδα.	46
2.5	Σύγκριση μεταξύ των προβλεπόμενων και των πραγματικών δεδομένων σε περίοδο 6 ημερών με χρήση (αριστερά) ενός M.L.P. δικτύου, (δεξιά) ενός R.B.F. δικτύου.	47
2.6	Experimental solar steam generator.	52
2.7	Γεωθερμικός χάρτης για τρία διαφορετικά βάθη (20, 50, 100 m).	54
2.8	Αριστερά: η εκπαίδευση του T.N.Δ., Δεξιά: σχηματική αναπαράσταση του δικτύου.	54
2.9	Δομή T.N.Δ. για την πρόβλεψη της θερμικής διαπερατότητας των ξύλινων παραθύρων (Buratti et al. (2012))	58
2.10	Αρχιτεκτονική του συστήματος ACHE, (Mozar (1998))	60
2.11	Σύγκριση δεικτών PMV: Τεχνητό νευρωνικό δίκτυο έναντι στατικού μοντέλου του Fanger (Buratti et al. (2015))	63
2.12	Η αρχιτεκτονική του εφαρμοζόμενου feed-forward ANN.	66
2.13	Η μετρούμενη σε σχέση με την προβλεπόμενη απ' το ANN τιμή της μέσης ημερήσιας παγκόσμιας ακτινοβολίας $\overline{H}_g$ σε 8 πόλεις της Κίνας	67
2.14	Αρχιτεκτονική T.N.Δ. για την πρόβλεψη της ταχύτητας του αέρα.	68

2.15 Αρχιτεκτονική T.N.Δ. για την αξιολόγηση του φυσικού φωτισμού σε κτήρια γραφείων (Kazanasmaz et al. (2009)).	70
2.16 Τοπολογία του M.L.P. που εξετάζει την ανάλυση της ενέργειας λόγω της επίδρασης του φωτισμού σε κτήρια γραφείων.	70
2.17 Αριστερά: Οι ισοϋψείς με πλήρη φωτισμό. Δεξιά:Οι ισοϋψείς μετά απ' τον βέλτιστο έλεγχο.	71
2.18 Δύο επιπέδων feed-foreword δίκτυο.	72
2.19 Προβλεπόμενες τιμές R_w που ελήφθησαν από τα μοντέλα T.N.Δ. έναντι μετρούμενων τιμών R_w (Buratti et al. (2013))	74

Κατάλογος πινάκων

1.1 Συνήθεις συναρτήσεις μεταφοράς	39
2.1 Σύγκριση αποτελεσμάτων (Datta & Tassou (1998)) . .	48
2.2 Σφάλματα πρόβλεψης των 7 μοντέλων για 8 πόλεις . . .	67
A'.1 Ανάλυση papers	77

Ευρετήριο*

Ευρετήριο

A

A.I., Artificial Intelligence, [1](#)
AAD, Average Absolute
Deviation, [33](#)
ACC, Accuracy, [38](#)
Association Analysis, [19](#)
attributes, [21](#)
Autoassociated memories, [9](#)

B

Back Error Propagation, [29](#)
Backpropagation, [29](#)
Bias, [22](#)

C

CEE, Cross-Entropy Error, [33](#)
Clustering, [19](#)
Cognitive Maps, [2](#)
Competitive learning, [20](#)
Confusion Matrix, [34](#)

D

Data set, [20](#)

Delta rule, [28](#)

E

Elman δίκτυο, [9](#)
Evolutionary Computing, [1](#)

F

F-measure, [37](#)
Feed-back, [9](#)
FF, Feed-Forward, [25](#)
FPR, False Positive Rate, [37](#)
Fuzzy Logic, [56](#)
Fuzzy Systems, [1](#)

G

Generalization, [22](#)

H

Heteroassociated memories, [9](#)
Hopfield δίκτυα, [7](#), [11](#)

K

Kohonen Δίκτυα, [12](#), [19](#)

L

Levenberg-Marquardt, [30](#)

M

M.L.P., MultiLayer

Perceptron network, [14](#),
[29](#), [46](#), [62 f](#)

MAD, Mean Absolute
Deviation, [33](#)

MAE, Mean Absolute Error,
[31](#)

MAPE, Mean Absolute
Percentage Error, [32](#)

MBE, Mean Bias Error, [33](#)

MSE, Mean Square Error, [31](#)

N

Neuro-Fuzzy Systems, [2](#)

O

Overfitting, [24](#)

P

PNN, Probabilistic Neural
Network, [7](#), [16](#)

PPV, Positive Predictive
Value, [36](#)

Precision, [36](#)

R

Random learning, [20](#)

RBF, Radial Basis Function,
[7](#), [14](#), [39](#), [46](#)

Recall, [36](#)

Recurrent ANN, [9](#)

Reinforcement Learning, [19](#)

RMSE, Root Mean Squared
Error, [31](#)

S

Sensitivity, [36](#)

sMAPE, Symmetric Mean
Absolute Percentage
Error, [32](#)

SOM (Self-Organizing Feature
Map), [12](#)

SPC, Specificity, [37](#)

Supervised Learning, [18](#)

SVM, Support Vector Model,
[7](#), [50](#)

T

Test set, [21](#)

TNR, True Negative Rate, [37](#)

TPR, True Positive Rate, [36](#)

Training set, [21](#)

Transfer function, [18](#), [39](#)

U

Underfitting, [24](#)

Unsupervised Learning, [19](#)

V

Validation set, [21](#)

Variance, [23](#)

Βιβλιογραφικές Αναφορές*

- Almonacid, F., Fernández, E. F., Rodrigo, P., Pérez-Higueras, P., & Rus-Casas, C. (2013). Estimating the maximum power of a high concentrator photovoltaic (hcpv) module using an artificial neural network. *Energy*, 53, 165 - 172. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360544213001382> doi: <https://doi.org/10.1016/j.energy.2013.02.024>
- Bilgili, M., Sahin, B., & Yasar, A. (2007). Application of artificial neural networks for the wind speed prediction of target station using reference stations data. *Renewable Energy*, 32(14), 2350 - 2360. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0960148106003429> doi: <https://doi.org/10.1016/j.renene.2006.12.001>
- Bosch, J., López, G., & Batlles, F. (2008). Daily solar irradiation estimation over a mountainous area using artificial neural networks. *Renewable Energy*, 33(7), 1622 - 1628. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0960148107002881> doi: <https://doi.org/10.1016/j.renene.2007.09.012>
- Buratti, C., Barbanera, M., & Palladino, D. (2014). An original tool for checking energy performance and certification of buildings by means of artificial neural networks. *Applied Energy*, 120, 125 - 132. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0306261914000828> doi: <https://doi.org/10.1016/j.apenergy.2014.01.053>
- Buratti, C., Barelli, L., & Moretti, E. (2012). Application of artificial neural network to predict thermal transmittance of wooden windows. *Applied Energy*, 98, 425 - 432. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0306261912002905> doi: <https://doi.org/10.1016/j.apenergy.2012.04.004>
- Buratti, C., Barelli, L., & Moretti, E. (2013). Wooden windows: Sound insulation evaluation by means of artificial neural networks. *Applied Acoustics*,

- 74(5), 740 - 745. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0003682X12003404> doi: <https://doi.org/10.1016/j.apacoust.2012.12.001>
- Buratti, C., Lascaro, E., Palladino, D., & Vergoni, M. (2014). Building behavior simulation by means of artificial neural network in summer conditions. *Sustainability*, 6(8), 5339–5353. Retrieved from <http://www.mdpi.com/2071-1050/6/8/5339> doi: 10.3390/su6085339
- Buratti, C., Vergoni, M., & Palladino, D. (2015). Thermal comfort evaluation within non-residential environments: Development of artificial neural network by using the adaptive approach data. *Energy Procedia*, 78, 2875 - 2880. Retrieved from <http://www.sciencedirect.com/science/article/pii/S1876610215023887> (6th International Building Physics Conference, IBPC 2015) doi: <https://doi.org/10.1016/j.egypro.2015.11.656>
- Das, P., Shrubsole, C., Jones, B., Hamilton, I., Chalabi, Z., Davies, M., ... Taylor, J. (2014). Using probabilistic sampling-based sensitivity analyses for indoor air quality modelling. *Building and Environment*, 78, 171 - 182. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360132314001139> doi: <https://doi.org/10.1016/j.buildenv.2014.04.017>
- Datta, D., & Tassou, S. (1998). Artificial neural network based electrical load prediction for food retail stores. *Applied Thermal Engineering*, 18(11), 1121 - 1128. Retrieved from <http://www.sciencedirect.com/science/article/pii/S1359431198000349> doi: [https://doi.org/10.1016/S1359-4311\(98\)00034-9](https://doi.org/10.1016/S1359-4311(98)00034-9)
- De, S., Kaiadi, M., Fast, M., & Assadi, M. (2007). Development of an artificial neural network model for the steam process of a coal biomass cofired combined heat and power (chp) plant in sweden. *Energy*, 32(11), 2099 - 2109. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360544207000722> doi: <https://doi.org/10.1016/j.energy.2007.04.008>
- Ekonomou, L. (2010). Greek long-term energy consumption prediction using artificial neural networks. *Energy*, 35(2), 512 - 517. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360544209004514> (ECOS 2008) doi: <https://doi.org/10.1016/j.energy.2009.10.018>
- Fadare, D. (2010). The application of artificial neural networks to mapping of wind speed profile for energy application in nigeria. *Applied Energy*, 87(3), 934 - 942. Retrieved from <http://www.sciencedirect.com/science/article/pii/S036026190900381X> doi: <https://doi.org/10.1016/j.apenergy.2009.09.005>

- Ferreira, P., Faria, E., & Ruano, A. (2002). Neural network models in greenhouse air temperature prediction. *Neurocomputing*, 43(1), 51 - 75. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0925231201006208> (Selected engineering applications of neural networks) doi: [https://doi.org/10.1016/S0925-2312\(01\)00620-8](https://doi.org/10.1016/S0925-2312(01)00620-8)
- Gunasekar, N., Mohanraj, M., & Velmurugan, V. (2015). Artificial neural network modeling of a photovoltaic-thermal evaporator of solar assisted heat pumps. *Energy*, 93, 908 - 922. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360544215012888> doi: <https://doi.org/10.1016/j.energy.2015.09.078>
- Hagan, M. T., Demuth, H. B., & Beale, M. H. (2014). *Neural Network Design, 2nd Edition, Cengage Learning*.
- Haykin, S. (1999). *Self-organizing maps: Neural networks-a comprehensive foundation 2nd edition*. Prentice-Hall.
- Jiang, Y. (2009). Computation of monthly mean daily global solar radiation in china using artificial neural networks and comparison with other empirical models. *Energy*, 34(9), 1276 - 1283. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360544209001820> doi: <https://doi.org/10.1016/j.energy.2009.05.009>
- Kalogirou, S. A., & Bojic, M. (2000). Artificial neural networks for the prediction of the energy consumption of a passive solar building. *Energy*, 25(5), 479 - 491. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360544299000869> doi: [https://doi.org/10.1016/S0360-5442\(99\)00086-9](https://doi.org/10.1016/S0360-5442(99)00086-9)
- Kalogirou, S. A., Florides, G. A., Pouloupatis, P. D., Panayides, I., Joseph-Stylianou, J., & Zomeni, Z. (2012). Artificial neural networks for the generation of geothermal maps of ground temperature at various depths by considering land configuration. *Energy*, 48(1), 233 - 240. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360544212004963> (6th Dubrovnik Conference on Sustainable Development of Energy Water and Environmental Systems, SDEWES 2011) doi: <https://doi.org/10.1016/j.energy.2012.06.045>
- Kalogirou, S. A., Neocleous, C. C., & Schizas, C. N. (1998). Artificial neural networks for modelling the starting-up of a solar steam-generator. *Applied Energy*, 60(2), 89 - 100. Retrieved from <http://www.sciencedirect.com/science/article/pii/S03606261998000191> doi: [https://doi.org/10.1016/S0360-6261\(98\)00019-1](https://doi.org/10.1016/S0360-6261(98)00019-1)

- Kana, E. G., Oloke, J., Lateef, A., & Adesiyun, M. (2012). Modeling and optimization of biogas production on saw dust and other co-substrates using artificial neural network and genetic algorithm. *Renewable Energy*, 46, 276 - 281. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0960148112002145> doi: <https://doi.org/10.1016/j.renene.2012.03.027>
- Kazanasmaz, T., Günaydin, M., & Binol, S. (2009). Artificial neural networks to predict daylight illuminance in office buildings. *Building and Environment*, 44(8), 1751 - 1757. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360132308002795> doi: <https://doi.org/10.1016/j.buildenv.2008.11.012>
- Khoshnevisan, B., Rafiee, S., Omid, M., Yousefi, M., & Movahedi, M. (2013). Modeling of energy consumption and ghg (greenhouse gas) emissions in wheat production in esfahan province of iran using artificial neural networks. *Energy*, 52, 333 - 338. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360544213000480> doi: <https://doi.org/10.1016/j.energy.2013.01.028>
- Kialashaki, A., & Reisel, J. R. (2013). Modeling of the energy demand of the residential sector in the united states using regression models and artificial neural networks. *Applied Energy*, 108, 271 - 280. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0306261913002304> doi: <https://doi.org/10.1016/j.apenergy.2013.03.034>
- Kumar, R., Kaushik, S., & Garg, S. (2006). Heating and cooling potential of an earth-to-air heat exchanger using artificial neural network. *Renewable Energy*, 31(8), 1139 - 1155. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0960148105001709> doi: <https://doi.org/10.1016/j.renene.2005.06.007>
- Mok, K., & Tam, S. (1998). Short-term prediction of so2 concentration in macau with artificial neural networks. *Energy and Buildings*, 28(3), 279 - 286. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0378778898000243> doi: [https://doi.org/10.1016/S0378-7788\(98\)00024-3](https://doi.org/10.1016/S0378-7788(98)00024-3)
- Moon, J. W., Yoon, S.-H., & Kim, S. (2013). Development of an artificial neural network model based thermal control logic for double skin envelopes in winter. *Building and Environment*, 61, 149 - 159. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360132312003320> doi: <https://doi.org/10.1016/j.buildenv.2012.12.010>

- Mozer, M. C. (1998). The neural network house: An environment hat adapts to its inhabitants. In *Proc. aaai spring symp. intelligent environments* (Vol. 58).
- Mubiru, J. (2008). Predicting total solar irradiation values using artificial neural networks. *Renewable Energy*, 33(10), 2329 - 2332. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0960148108000074> doi: <https://doi.org/10.1016/j.renene.2008.01.009>
- Nannariello, J., & Fricke, F. (1999). The prediction of reverberation time using neural network analysis. *Applied Acoustics*, 58(3), 305 - 325. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0003682X98000814> doi: [https://doi.org/10.1016/S0003-682X\(98\)00081-4](https://doi.org/10.1016/S0003-682X(98)00081-4)
- Nannariello, J., Hodgson, M., & Fricke, F. R. (2001). Neural network predictions of speech levels in university classrooms. *Applied Acoustics*, 62(7), 749 - 767. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0003682X00000888> doi: [https://doi.org/10.1016/S0003-682X\(00\)00088-8](https://doi.org/10.1016/S0003-682X(00)00088-8)
- Papantoniou, S., & Kolokotsa, D.-D. (2016). Prediction of outdoor air temperature using neural networks: Application in 4 european cities. *Energy and Buildings*, 114, 72 - 79. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0378778815300839> (SI: Countermeasures to Urban Heat Island) doi: <https://doi.org/10.1016/j.enbuild.2015.06.054>
- Sayin, C., Ertunc, H. M., Hosoz, M., Kilicaslan, I., & Canakci, M. (2007). Performance and exhaust emissions of a gasoline engine using artificial neural network. *Applied Thermal Engineering*, 27(1), 46 - 54. Retrieved from <http://www.sciencedirect.com/science/article/pii/S1359431106001785> doi: <https://doi.org/10.1016/j.applthermaleng.2006.05.016>
- Sipöcz, N., Tobiesen, F. A., & Assadi, M. (2011). The use of artificial neural network models for co2 capture plants. *Applied Energy*, 88(7), 2368 - 2376. Retrieved from <http://www.sciencedirect.com/science/article/pii/S030626191100016X> doi: <https://doi.org/10.1016/j.apenergy.2011.01.013>
- Sözen, A., Arcaklioğlu, E., Özalp, M., & Kanit, E. (2004). Use of artificial neural networks for mapping of solar potential in turkey. *Applied Energy*, 77(3), 273 - 286. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0306261903001375> doi: [https://doi.org/10.1016/S0306-2619\(03\)00137-5](https://doi.org/10.1016/S0306-2619(03)00137-5)
- Sözen, A., Özalp, M., & Arcaklioğlu, E. (2007). Calculation for the thermodynamic properties of an alternative refrigerant (r508b) using

- artificial neural network. *Applied Thermal Engineering*, 27(2), 551 - 559. Retrieved from <http://www.sciencedirect.com/science/article/pii/S1359431106002262> doi: <https://doi.org/10.1016/j.applthermaleng.2006.06.003>
- Tan, C., Ward, J., Wilcox, S., & Payne, R. (2009). Artificial neural network modelling of the thermal performance of a compact heat exchanger. *Applied Thermal Engineering*, 29(17), 3609 - 3617. Retrieved from <http://www.sciencedirect.com/science/article/pii/S135943110900194X> doi: <https://doi.org/10.1016/j.applthermaleng.2009.06.017>
- Theodoridis, S., & Koutroumbas, K. (2009). *Pattern recognition*. Academic Press.
- Too, G.-P., Chen, S., & Hwang, S. (2007). Inversion for acoustic impedance of a wall by using artificial neural network. *Applied Acoustics*, 68(4), 377 - 389. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0003682X0600065X> doi: <https://doi.org/10.1016/j.apacoust.2006.03.013>
- Wang, Z., & Tan, Y. K. (2013). Illumination control of led systems based on neural network model and energy optimization algorithm. *Energy and Buildings*, 62, 514 - 521. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0378778813001977> doi: <https://doi.org/10.1016/j.enbuild.2013.03.029>
- Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2016). *Data mining: Practical machine learning tools and techniques*. Morgan Kaufmann.
- Wong, S., Wan, K. K., & Lam, T. N. (2010). Artificial neural networks for energy analysis of office buildings with daylighting. *Applied Energy*, 87(2), 551 - 557. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0306261909002669> doi: <https://doi.org/10.1016/j.apenergy.2009.06.028>
- Zhou, H., Cen, K., & Fan, J. (2004). Modeling and optimization of the nox emission characteristics of a tangentially fired boiler with artificial neural networks. *Energy*, 29(1), 167 - 183. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0360544203002056> doi: <https://doi.org/10.1016/j.energy.2003.08.004>
- Çam, E., Arcaklıoğlu, E., Çavuşoğlu, A., & Akbıyık, B. (2005). A classification mechanism for determining average wind speed and power in several regions of turkey using artificial neural networks. *Renewable Energy*, 30(2), 227 - 239. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0960148104001879> doi: <https://doi.org/10.1016/j.renene.2004.05.008>

Ömer Altan Dombaycı, & Gölcü, M. (2009). Daily means ambient temperature prediction using artificial neural network method: A case study of turkey. *Renewable Energy*, 34(4), 1158 - 1161. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0960148108002851> doi: <https://doi.org/10.1016/j.renene.2008.07.007>

Βραχλιώτης, Ν. (2018). *Λεξικό της Επιστήμης της Πληροφορίας*. Retrieved 2018-10-31, from <http://lexiko.nivra1.com>