



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ
ΣΧΟΛΗ ΕΠΙΣΤΗΜΩΝ ΥΓΕΙΑΣ
ΤΜΗΜΑ ΙΑΤΡΙΚΗΣ**



Διδακτορική Διατριβή

**«Η ΧΡΗΣΗ ΤΩΝ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ ΓΙΑ ΤΗΝ ΕΚΤΙΜΗΣΗ
ΤΗΣ ΕΞΩΣΩΜΑΤΙΚΗΣ ΛΙΘΟΤΡΙΨΙΑΣ ΩΣ ΘΕΡΑΠΕΙΑ ΤΗΣ ΛΙΘΙΑΣΗΣ ΤΟΥ
ΟΥΡΟΠΟΙΗΤΙΚΟΥ ΣΤΗ ΘΕΣΣΑΛΙΑ.»**

υπό

ΑΘΑΝΑΣΙΟΥ ΤΣΙΤΣΙΦΛΗ

Μαθηματικού

Αναλυτή Συστημάτων και Διαδικασιών

Υπεβλήθη για την εκπλήρωση μέρους των
απαιτήσεων για την απόκτηση του
Διδακτορικού Διπλώματος
Λάρισα, 2023

«Η έγκριση της διδακτορικής διατριβής από το Τμήμα Ιατρικής της Σχολής Επιστημών Υγείας του Πανεπιστημίου Θεσσαλίας δεν υποδηλώνει αποδοχή των απόψεων του συγγραφέα (σύμφωνα με τις διατάξεις του άρθρου 202, παράγραφος 2 του Ν. 5343/1932)».

Τριμελής Επιτροπή:

1. ΚΑΡΑΤΖΑΣ ΑΝΑΣΤΑΣΙΟΣ,

Αναπληρωτής Καθηγητής Ουρολογίας, Τμ. Ιατρικής, Παν. Θεσσαλίας

2. ΤΖΩΡΤΖΗΣ ΒΑΣΙΛΕΙΟΣ,

Καθηγητής Ουρολογίας, Τμ. Ιατρικής, Παν. Θεσσαλίας

3. ΣΤΕΦΑΝΙΔΗΣ ΙΩΑΝΝΗΣ,

Καθηγητής Παθολογίας-Νεφρολογίας, Τμ. Ιατρικής, Παν. Θεσσαλίας

Εγκρίθηκε από τα Μέλη της Επταμελούς Εξεταστικής Επιτροπής (20/2/2023):

1^{ος} Εξεταστής (Επιβλέπων): ΚΑΡΑΤΖΑΣ ΑΝΑΣΤΑΣΙΟΣ

Αναπληρωτής Καθηγητής Ουρολογίας, Τμ. Ιατρικής, Παν. Θεσσαλίας

2^{ος} Εξεταστής: ΤΖΩΡΤΖΗΣ ΒΑΣΙΛΕΙΟΣ

Καθηγητής Ουρολογίας, Τμ. Ιατρικής, Παν. Θεσσαλίας

3^{ος} Εξεταστής: ΣΤΕΦΑΝΙΔΗΣ ΙΩΑΝΝΗΣ

Καθηγητής Παθολογίας-Νεφρολογίας, Τμ. Ιατρικής, Παν. Θεσσαλίας

4^{ος} Εξεταστής: ΖΑΧΑΡΟΥΛΗΣ ΔΗΜΗΤΡΙΟΣ

Καθηγητής Γενικής Χειρουργικής, Τμ. Ιατρικής, Παν. Θεσσαλίας

5^{ος} Εξεταστής: ΜΠΑΛΟΓΙΑΝΝΗΣ ΙΩΑΝΝΗΣ

Επίκουρος Καθηγητής Χειρουργικής, Τμ. Ιατρικής, Παν. Θεσσαλίας

6^{ος} Εξεταστής: ΑΡΝΑΟΥΤΟΓΛΟΥ ΕΛΕΝΗ

Καθηγήτρια Αναισθησιολογίας, Τμ. Ιατρικής, Παν. Θεσσαλίας

7^{ος} Εξεταστής: ΣΥΜΕΩΝΙΔΗΣ ΔΗΜΗΤΡΙΟΣ

Επίκουρος Καθηγητής Χειρουργικής, Τμ. Ιατρικής, Παν. Θεσσαλίας

ΕΥΧΑΡΙΣΤΙΕΣ

Η παρούσα διδακτορική διατριβή είναι αποτέλεσμα επίμονης προσωπικής προσπάθειας, μελέτης και έρευνας που ξεκίνησε το 2016 και ολοκληρώθηκε το 2021. Στο χρονικό διάστημα αυτών των 6 χρόνων, η εξέλιξη της δοκιμάστηκε από διάφορες δυσκολίες που με τη βοήθεια της Παναγίας μας και την υποστήριξη κάποιων ανθρώπων που επιθυμώ να μνημονεύσω, ξεπεράστηκαν.

Ξεκινώ από τον επιβλέποντα Καθηγητή κ. Αναστάσιο Καρατζά τον οποίο θέλω να ευχαριστήσω για την εμπιστοσύνη που μου έδειξε δίνοντας μου αυτή τη διατριβή. Με τις επιστημονικές γνώσεις του οριοθέτησε τους στόχους και την δομή της διατριβής και έδωσε κατευθύνσεις σε πλήθος διευκρινήσεων που χρειάστηκαν σε ιατρικά θέματα.

Ένα μεγάλο ευχαριστώ στους Καθηγητές μου κ.κ. Ηλία Ζιντζαρά, Ιωάννη Στεφανίδη και Απόστολο Μπατσίδα οι οποίοι στο πλαίσιο του ΠΜΣ “Μεθοδολογία Βιοϊατρικής Έρευνας, Βιοστατιστική & Κλινική Βιοπληροφορική” του Πανεπιστημίου Θεσσαλίας, δίδαξαν, καθοδήγησαν και ενίσχυσαν τις επιστημονικές γνώσεις μου στην Βιοστατιστική. Ιδιαίτερη μνεία θα ήθελα να κάνω στον επιστήμονα της Πληροφορικής κ. Θεόδωρο Μπρότση που με την επιστημονική του κατάρτιση, την μεταδοτικότητα στη διδασκαλία και τη θετική του ενέργεια, έδωσε αμέριστη βοήθεια σε θέματα στατιστικής.

Θα ήθελα να ευχαριστήσω τους συναδέλφους μου στην Εθνική Τράπεζα που μου συμπαραστάθηκαν, κατανοώντας την προσπάθειά μου για την εκπόνηση της διατριβής παράλληλα με τα καθήκοντά μου στην Τράπεζα.

Τέλος, αμέριστη ευγνωμοσύνη οφείλω στην οικογένεια μου, τη σύζυγό μου Μαρία και τα τρία παιδιά μου, τη Βίβιαν, το Χρήστο και τη Δήμητρα που με στήριξαν και μου έδειχναν συνεχώς πόσο με αγαπούν. Λυπάμαι για το χρόνο που δεν τους αφιέρωσα όσο έγραφα τη διατριβή και δυστυχώς δεν μπορώ να τον αναπληρώσω. Θα μεγαλώσουν και θα καταλάβουν.

*Η εργασία αυτή αφιερώνεται σε όλους όσους στάθηκαν δίπλα μου
κατά την πραγματοποίησή της.*

Στους Καθηγητές/Δασκάλους μου.

Στην Οικογένειά μου.

Στη μνήμη του πατέρα μου και της αδελφής μου...

ΠΕΡΙΛΗΨΗ

Η εξωσωματική λιθοτριψία (ESWL – *Extracorporeal ShockWave Lithotripsy*), κατά την οποία επιχειρείται κατακερματισμός των λίθων στο ουροποιητικό σύστημα με εξωτερικά μέσα (εφαρμογή κρουστικών κυμάτων) χωρίς χειρουργική πράξη, αποτελεί ιατρικό ορόσημο γενικότερα που έφερε επανάσταση στην Ουρολογία.

Η εκτίμησή της ως μέθοδος επιλογής για τη θεραπεία της λιθίασης, σχεδιάστηκε στην παρούσα διατριβή να γίνει με την ανάπτυξη ενός τεχνητού νευρωνικού δικτύου. Για την πραγματοποίηση του στόχου καταγράφηκαν τα ιατρικά δεδομένα 716 ασθενών που υπεβλήθησαν σε εξωσωματική λιθοτριψία και από τα οποία προέκυψαν 2 βασικά χαρακτηριστικά: η εμφάνιση επιπλοκών στους ασθενείς με το πέρας της διαδικασίας (ασφάλεια μεθόδου) και η επιτυχία της λιθοτριψίας (αποτελεσματικότητα μεθόδου). Ως επιπλοκές της μεθόδου χαρακτηρίζονται η εμφάνιση πόνου ή φλεγμονής στον ασθενή. Η αποτελεσματικότητα της μεθόδου κρίνεται από τον επιτυχή θρυμματισμό του λίθου ή όχι.

Τα ιατρικά δεδομένα των ασθενών συγκεντρώθηκαν και καταχωρήθηκαν σε βάση δεδομένων με τη βοήθεια της εφαρμογής MS Excel, από το αρμόδιο και εξειδικευμένο προσωπικό χειρισμού του εξοπλισμού του λιθοτρίπτη, στο χώρο λειτουργίας του μηχανήματος στο Πανεπιστημιακό Νοσοκομείο Λάρισας, υπό την καθοδήγηση και επίβλεψη του ιατρικού προσωπικού, σε χρονικό ορίζοντα δεκαετίας. Στη συνέχεια μορφοποιήθηκαν, για τους σκοπούς της παρούσας διατριβής, προκειμένου να καταλήξουν σε μορφή επεξεργάσιμη από τα υπολογιστικά προγράμματα που χρησιμοποιήθηκαν. Η στατιστική ανάλυση στην οποία υποβλήθηκαν τα δεδομένα, κινήθηκε αρχικά στην κατεύθυνση της μονοπαραγοντικής τους ανάλυσης με στόχο την εύρεση πιθανών συσχετίσεων με το αποτέλεσμα. Στη συνέχεια έγινε πολυπαραγοντική ανάλυση μεταξύ των στατιστικά σημαντικών μεταβλητών και του αποτελέσματος. Ιδιαίτερη βαρύτητα δόθηκε στις μεταβλητές που έδειξαν συσχέτιση με το αποτέλεσμα. Για τη διαδικασία αυτή χρησιμοποιήθηκε το στατιστικό πακέτο SPSS.

Τα δεδομένα εισήχθησαν σε τεχνητό νευρωνικό δίκτυο που σχεδιάστηκε για το σκοπό αυτό. Ένας μοναδικός αλγόριθμος γραμμένος σε περιβάλλον MATLAB, εκπαιδευσε το δίκτυο και στη συνέχεια το εκτίμησε, αφού προηγήθηκε κατηγοριοποίηση των ιατρικών δεδομένων των ασθενών. Η ίδια διαδικασία ακολουθήθηκε τόσο για την εκτίμηση της ασφάλειας όσο και για την εκτίμηση της αποτελεσματικότητας της εξωσωματικής λιθοτριψίας. Η συμπεριφορά του δικτύου αξιολογήθηκε και στις 2 περιπτώσεις, αρχικά με

δεδομένα εισόδου το σύνολο των μεταβλητών και στη συνέχεια μόνο των στατιστικά σημαντικών μεταβλητών που προέκυψαν από τη στατιστική ανάλυση και έδειξαν ότι συσχετίζονται με το εκάστοτε αποτέλεσμα.

Από τα αποτελέσματα εκπαίδευσης και εκτίμησης έγινε σαφές ότι το τεχνητό νευρωνικό δίκτυο μπορεί να δώσει αξιόλογα αποτελέσματα, κυρίως στην περίπτωση μεγάλου πλήθους δεδομένων στα οποία συμπεριλαμβάνονται οι στατιστικά σημαντικές μεταβλητές.

ABSTRACT

Extracorporeal shockwave lithotripsy (ESWL), a medical method that attempts to partition urinary stones by external means without surgery, is a medical milestone that brought revolution in Urology.

Its evaluation, as a method of choice for the treatment of lithiasis, was designed to be done in this thesis, by the development of an artificial neural network. To accomplish this goal, the medical records of 716 patients, who were treated by ESWL, were recorded and 2 main features were distinguished: the occurrence of complications at the end of the procedure (i.e. the safety of the method) and the successfulness of lithotripsy (i.e. the effectiveness of the method). We define as complications of the method, the occurrence of pain or infection in the patient. The effectiveness of the method is the result of ESWL, i.e. the successful defragmentation of the stone or not.

Patients' medical data were collected and entered into a database with the use of MS Excel, by the authorized and special trained personnel that is responsible and handles the lithotripter, in a specially designed area at the University Hospital of Larissa, under the guidance and supervision of the medical staff, in a period of a decade. Then, data were formatted for the purpose of this thesis, in order to come up in a compatible form by the computer programs used. Statistical analysis of data took place in the direction of univariate and multivariate analysis. There was an effort to find possible correlations between each input variable and the result and then, with the use of the statistically significant variables, to create a multivariate model. The importance of statistically significant variables was noticed during the analysis. The IBM SPSS statistical software was used.

Data were inserted into an artificial neural network that was designed especially for this purpose. A unique algorithm that was programmed in MATLAB environment, trained the network with the use of relative functions and then evaluated it with appropriate sets of patients' data. The same procedure was followed for both the evaluation of safety and the evaluation of efficacy of lithotripsy. The behavior and the results of the network in evaluation set were evaluated in both cases, initially with input data, that were consisted of all categorical variables and then only with the statistically significant variables, that came out from the statistical analysis and showed correlation with the result (output values).

From the training and evaluation results it became clear that the artificial neural network can provide valuable results, especially in the case of large amounts of data that include statistically significant variables.

ΠΕΡΙΕΧΟΜΕΝΑ

ΓΕΝΙΚΟ ΜΕΡΟΣ	1
ΜΕΡΟΣ ΠΡΩΤΟ:	2
ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ: ΙΣΤΟΡΙΚΗ ΑΝΑΔΡΟΜΗ & ΒΑΣΙΚΕΣ ΕΝΝΟΙΕΣ	2
1. ΕΙΣΑΓΩΓΗ	3
2. ΤΟ ΑΝΘΡΩΠΙΝΟ ΝΕΥΡΙΚΟ ΣΥΣΤΗΜΑ	4
3. ΙΣΤΟΡΙΚΗ ΑΝΑΔΡΟΜΗ ΣΤΑ ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ	5
4. ΤΟ ΜΑΘΗΜΑΤΙΚΟ ΜΟΝΤΕΛΟ ΕΝΟΣ ΝΕΥΡΩΝΙΚΟΥ ΚΥΤΤΑΡΟΥ	13
5. ΑΡΧΙΤΕΚΤΟΝΙΚΕΣ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ	17
6. ΜΕΘΟΔΟΙ ΕΚΠΑΙΔΕΥΣΗΣ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ	19
7. ΕΙΔΗ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ	22
ΜΕΡΟΣ ΔΕΥΤΕΡΟ:	34
ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΕΦΑΡΜΟΓΕΣ ΣΤΗΝ ΙΑΤΡΙΚΗ	34
8. ΕΙΣΑΓΩΓΗ	35
9. ΕΦΑΡΜΟΓΕΣ ΤΩΝ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ	36
10. ΤΑ ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΣΤΗΝ ΙΑΤΡΙΚΗ	49
11. ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΟΥΡΟΛΟΓΙΑ	53
ΕΙΔΙΚΟ ΜΕΡΟΣ	62
12. ΕΙΣΑΓΩΓΗ	63
13. ΣΚΟΠΟΣ ΕΡΕΥΝΑΣ	64
14. ΠΛΗΘΥΣΜΟΣ ΜΕΛΕΤΗΣ ΚΑΙ ΜΕΘΟΔΟΣ ΑΝΑΛΥΣΗΣ	65
14.1 Στατιστική Ανάλυση: Μεθοδολογία και Αποτελέσματα	67
14.2 Νευρωνικό δίκτυο: Σχεδιασμός, Υλοποίηση, Αποτελέσματα	81
14.3 Σύγκριση αποτελεσμάτων έρευνας	96
15. ΣΥΖΗΤΗΣΗ – ΣΥΜΠΕΡΑΣΜΑΤΑ	97
16. ΒΙΒΛΙΟΓΡΑΦΙΑ	103

ΓΕΝΙΚΟ ΜΕΡΟΣ

ΜΕΡΟΣ ΠΡΩΤΟ:

ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ: ΙΣΤΟΡΙΚΗ ΑΝΑΔΡΟΜΗ & ΒΑΣΙΚΕΣ ΕΝΝΟΙΕΣ

1. ΕΙΣΑΓΩΓΗ

Τα νευρωνικά δίκτυα έχουν χαρακτηριστεί από μία έκρηξη ενδιαφέροντος τις τελευταίες δεκαετίες καθώς εφαρμόζονται επιτυχώς σε ένα μεγάλο εύρος επιστημονικών πεδίων όπως τα οικονομικά, η ιατρική, η μηχανική, η γεωλογία, η φυσική και η βιολογία. Ο ενθουσιασμός πηγάζει από το γεγονός ότι τα δίκτυα αυτά προκύπτουν από προσπάθειες να προσομοιωθούν οι δυνατότητες/λειτουργίες του ανθρώπινου εγκεφάλου. Από πλευράς στατιστικής, τα νευρωνικά δίκτυα έχουν ενδιαφέρον λόγω της χρήσης τους σε προβλήματα πρόβλεψης και ταξινόμησης.


Τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ) είναι ισχυρά εργαλεία για μοντελοποίηση καθώς είναι μη γραμμικά, δεν εξαρτώνται από τη φύση των δεδομένων και είναι εκπαιδευόμενα. Ο όρος “τεχνητό” σημαίνει ότι τα νευρωνικά δίκτυα υλοποιούνται από προγράμματα ηλεκτρονικών υπολογιστών τα οποία είναι σε θέση να χειριστούν έναν μεγάλο αριθμό απαραίτητων υπολογισμών κατά τη διάρκεια της μαθησιακής διαδικασίας. Κάθε ΤΝΔ μπορεί να εντοπίσει και να μάθει συσχετισμένα μοτίβα μεταξύ των ομάδων δεδομένων εισόδου και των αντίστοιχων τιμών στόχων. Μετά από εκπαίδευση, μπορούν να χρησιμοποιηθούν για την πρόβλεψη του αποτελέσματος νέων, ανεξάρτητων δεδομένων εισόδου. Μιμούνται, ή πιο σωστά σχεδιάζονται για να έχουν τη δυνατότητα να μιμηθούν, τη διαδικασία μάθησης του ανθρώπινου εγκεφάλου και να μπορούν να επεξεργάζονται προβλήματα που αφορούν μη γραμμικά και περίπλοκα δεδομένα, ακόμη και αν τα δεδομένα αυτά είναι ασαφή και δυσδιάκριτα.

Ένα πολύ σημαντικό χαρακτηριστικό αυτών των δικτύων είναι ο προσαρμοστικός τους χαρακτήρας όπου η “μάθηση με παράδειγμα” αντικαθιστά τον “προγραμματισμό” στην επίλυση προβλημάτων. Αυτό το χαρακτηριστικό καθιστά τέτοια υπολογιστικά μοντέλα πολύ ελκυστικά σε τομείς εφαρμογής όπου κάποιος έχει μικρή ή ελλιπή κατανόηση του προβλήματος που πρέπει να επιλυθεί αλλά με τα δεδομένα εκπαίδευσης να είναι άμεσα διαθέσιμα.

Τα δίκτυα αυτά λέγονται “νευρωνικά” υπό την έννοια ότι να έχουν εμπνευστεί από τη λειτουργία των νευρώνων του εγκεφάλου, όχι απαραίτητα επειδή είναι πιστά μοντέλα βιολογικών νευρώνων ή γνωστικών φαινομένων. Στην πραγματικότητα, η πλειοψηφία του δικτύου συνδέεται στενότερα με παραδοσιακά μαθηματικά και στατιστικά μοντέλα όπως μη-παραμετροποιημένα πρότυπα μοτίβων, αλγόριθμους ομαδοποίησης, μη γραμμικά φίλτρα και μοντέλα στατιστικής παλινδρόμησης από ό,τι μοντέλα νευροβιολογίας.

2. ΤΟ ΑΝΘΡΩΠΙΝΟ ΝΕΥΡΙΚΟ ΣΥΣΤΗΜΑ


Το βασικό στοιχείο με επεξεργαστική ικανότητα στα βιολογικά συστήματα είναι ο νευρώνας, ο οποίος δέχεται ηλεκτροχημικά σήματα από διαφορετικές πηγές (άλλους νευρώνες) και παράγει ηλεκτρικούς παλμούς προς μετάδοση σε άλλους νευρώνες. Το ανθρώπινο νευρικό σύστημα αποτελείται από 10^{10} έως 10^{12} νευρώνες οι οποίοι μπορούν να αποθηκεύουν πολλά κομμάτια πληροφορίας (Σχήμα 1). Κάθε νευρώνας λειτουργεί σαν



Σχήμα 1: Μικροσκοπική απεικόνιση τμήματος του εγκεφάλου όπου φαίνονται οι νευρώνες, οι συνάψεις, οι άξονες και οι δενδρίτες

απλός επεξεργαστής και μόνο η συνδυασμένη, μαζική αλληλεπίδραση μεταξύ των νευρώνων και η παράλληλη επεξεργασία τους καθιστά δυνατές τις ικανότητες του εγκεφάλου. Περίπου το 10% των νευρώνων είναι μόνο είσοδος και έξοδος σημάτων ενώ οι υπόλοιποι διασυνδέονται με άλλους νευρώνες που πραγματοποιούν αποθήκευση πληροφοριών και μετασχηματισμό των σημάτων που διαδίδονται μέσω του δικτύου που δημιουργούν.

Όπως φαίνεται στο Σχήμα 2, ένας νευρώνας αποτελείται από έναν πυρήνα, ένα κυτταρικό σώμα, πολυάριθμους συνδέσμους (δενδρίτες) που παρέχουν συνδέσεις εισόδου



Σχήμα 2: Απλοποιημένη αναπαράσταση ενός νευρωνικού κυττάρου

σημάτων από άλλους νευρώνες μέσω συνάψεων και ενός κορμού άξονα που μεταφέρει την ενέργεια εξόδου σε άλλους νευρώνες μέσω συνάψεων και δενδριτών. Οι συνδέσεις μεταξύ των νευρώνων είναι προσαρμοστικές, πράγμα που σημαίνει ότι η δομή τους αλλάζει δυναμικά. Έχει διατυπωθεί επιστημονικά ότι η ικανότητα μάθησης του ανθρώπινου εγκεφάλου βασίζεται σε αυτή την προσαρμογή.

Στην προσπάθεια αναπαράστασης της δομής του εγκεφάλου, ένα ΤΝΔ αποτελείται από ένα σύνολο διασυνδεδεμένων μονάδων επεξεργασίας που ονομάζονται *κόμβοι* ή *μονάδες*. Κάθε κόμβος σχεδιάζεται έτσι ώστε να μιμείται το βιολογικό αντίστοιχο, δηλαδή τον νευρώνα. Δέχεται ένα σταθμισμένο σύνολο εισόδων και ανταποκρίνεται με μία έξοδο. Έτσι, κάθε ΤΝΔ αντικατοπτρίζει το δίκτυο των αλληλοσυνδεδεμένων φυσικών νευρώνων, στην απόκτηση γνώσης μέσα από παραδείγματα και αποθηκεύοντας αυτές τις πληροφορίες, μέσα στις δυνάμεις σύνδεσης μεταξύ των κόμβων που ονομάζονται *βάρη*.

3. ΙΣΤΟΡΙΚΗ ΑΝΑΔΡΟΜΗ ΣΤΑ ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ

Η αρχική θεωρητική ιδέα της ύπαρξης, δομής και λειτουργίας των νευρώνων στον ανθρώπινο εγκέφαλο, προπομπός των σύγχρονων νευρωνικών δικτύων, υπήρξε, σε ανεξάρτητες εργασίες, από τον Alexander Bain [1] και τον William James [2]. Κεντρική ιδέα των εργασιών τους είναι ότι τόσο οι σκέψεις όσο και η σωματική δραστηριότητα προέρχονται από νευρωνικές διεργασίες στον εγκέφαλο. Για τον Bain, κάθε πιθανή δραστηριότητα απαιτούσε την ενεργοποίηση ενός συγκεκριμένου συνόλου νευρώνων. Οι


ιδέες του Bain φαινόταν την εποχή εκείνη, ότι απαιτείται ένας υπερβολικά μεγάλος αριθμός νευρικών συνδέσεων μέσα στον εγκέφαλο, αν και είναι όλο και πιο προφανές ότι ο εγκέφαλος είναι ένα εξαιρετικά περίπλοκο όργανο και το “υλικό” από το οποίο αποτελείται μπορεί να επεξεργάζεται πολλαπλά προβλήματα και ταυτόχρονες εισόδους ερεθισμάτων (δεδομένων).

Η θεωρία του James ήταν παρόμοια, κατά κάποιον τρόπο, με αυτή του Bain, ωστόσο στο μοντέλο του ο James πρότεινε ότι οι μνήμες και οι ενέργειες, προκύπτουν από ηλεκτρικά σήματα που ρέουν μεταξύ νευρώνων. Αυτό θεωρήθηκε ως σημαντική καινοτομία καθώς δεν απαιτούνταν πολλές διακριτές ομάδες νευρώνων που να αποθηκεύουν μνήμες ή να παρακινούν σε ενέργειες.

Ο Robert Hooke, στα μέσα του 17^{ου} αιώνα εισήγαγε τη λέξη *κύτταρο* (*cell* από το λατινικό *cellula*: μικρό εξάρτημα), μετά από παρατηρήσεις μικροσκοπικών ορθογώνιων σχημάτων σε φέτες φελλού, με τη χρήση ενός υποτυπώδους μικροσκοπίου. Το 1838, στο άρθρο “*Contributions to Phytogenesis*”, ο βοτανολόγος Mattias Schleiden αναγνώρισε κυτταρικές δομές σε φυτά, μια ιδέα η οποία επεκτάθηκε ένα χρόνο αργότερα από τον φυσιολόγο Theodor Schwann στο βιβλίο του: “*Microscopical Researches into the Accordance in the Structure and Growth of Animals and Plants*”. Ο Schwann παρατήρησε παρόμοιες κυτταρικές δομές στα όργανα των ζώων. Έτσι, ξεκίνησε η ανάπτυξη της θεωρίας των κυττάρων, η ιδέα ότι όλα τα ζωντανά υλικά, είτε σε φυτά είτε σε ζώα, αποτελούνται από κύτταρα. Οι Alexander και Morton [5] αναφέρουν ότι η έρευνα για τα δομικά στοιχεία του εγκεφάλου ξεκίνησε από την ανακάλυψη ότι όλα τα ζωντανά πράγματα είναι “φτιαγμένα” από κύτταρα.

Ο Camillio Golgi (1843-1926) ανέπτυξε επιτυχώς τεχνικές χρώσης χρησιμοποιώντας νιτρικό άργυρο για να εξακριβώσει την ύπαρξη των νευρικών ιστών. Με τον τρόπο αυτό κατάφερε να φέρει στο προσκήνιο αόρατες έως τότε ίνες στον νευρικό ιστό, περιγράφοντας έτσι τη δομή των νευρώνων καθώς και τη δικτυακή διασύνδεσή τους. Την ίδια χρονική περίοδο, ο Santiago Ramon y Cajal (ο οποίος μοιράστηκε τελικά το βραβείο Nobel in Physiology or Medicine με τον Golgi το 1906) προχώρησε στη δημιουργία γραφικών σχεδίων του νευρικού ιστού, πρωτοποριακών για την επιστήμη της νευρολογίας [6]. Με τον τρόπο αυτό ο Cajal ανέπτυξε τη θεμελιώδη ιδέα ότι οι δενδρίτες ήταν αγωγοί των αξόνων, οι οποίοι με τη σειρά τους συνδέονταν με τερματικές συνδέσεις σε δενδρίτες

άλλων νευρώνων (Σχήμα 3). Προσδιόρισε έτσι τον νευρώνα ως μοναδικό στοιχείο με μονόδρομη λειτουργία.



Σχήμα 3: Γραφικές απεικονίσεις των νευρώνων κατά τον Santiago Ramon y Cajal (1852-1934)

Οι πρώτες εργασίες στον τομέα της τεχνητής νοημοσύνης ξεκίνησαν με μεγάλο ενθουσιασμό στις δεκαετίες του 1940 και 1950. Τα θεμέλια όσων έχουν γίνει γνωστά ως “νευρωνικά συστήματα” ή “νευρωνικά δίκτυα” έβαλαν το 1943 ο νευροφυσιολόγος Warren McCulloch και ο μαθηματικός Walter Pitts. Προκειμένου να περιγράψουν τον τρόπο λειτουργίας των βασικών στοιχείων επεξεργασίας του εγκεφάλου, οι McCulloch και Pitts έδειξαν πως απλά ηλεκτρικά κυκλώματα που συνδέουν ομάδες γραμμικών συναρτήσεων με όρια θα μπορούσαν να υπολογίσουν διάφορες λογικές λειτουργίες. Συνέλαβαν την ιδέα ότι (α) οι νευρώνες μπορούν να λάβουν θετική ή αρνητική διέγερση ώστε να ενεργοποιηθούν, γεγονός που εξαρτάται από τη φύση της σύναψης (διεγερτική ή ανασταλτική) και (β) κατά την ενεργοποίηση-πυροδότηση, ο νευρώνας έχει πραγματοποιήσει έναν “υπολογισμό”, ορμώμενος από το είδος της διέγερσης, ο οποίος δύναται να προσδιορισθεί μαθηματικά μαζί με το αποτέλεσμα της διέγερσης [3].

Οι McCulloch και Pitts δημοσίευσαν πέντε παραδοχές [3] οι οποίες προσδιορίζουν τη λειτουργία των νευρώνων. Αυτές είναι:


- 1) ο νευρώνας λειτουργεί ως συσκευή δυαδικής επεξεργασίας με δύο καταστάσεις: ενεργός ή μη,
- 2) κάθε νευρώνας έχει ένα προκαθορισμένο όριο (κατώφλι),
- 3) ο νευρώνας, μπορεί να δέχεται από τις διεγερτικές συνάψεις ως είσοδο, σήματα της ίδιας αξίας (βάρους),

- 4) ο νευρώνας μπορεί να δέχεται από τις ανασταλτικές συνάψεις ως είσοδο, σήματα τα οποία τον καταστέλλουν και τον αποτρέπουν από τη διέγερση,
- 5) υπάρχει χρονικό διάστημα κατά την διάρκεια του οποίου ολοκληρώνονται οι είσοδοι των σημάτων μέσω των συνάψεων.

Έτσι, ο νευρώνας λειτουργεί ως εξής: κατά το προκαθορισμένο χρονικό διάστημα εισόδου των σημάτων στο νευρώνα μέσω των συνάψεων, εάν δεν εισέλθει σήμα από ανασταλτική σύναψη, αθροίζεται ο αριθμός των διεγερτικών σημάτων (που εισήλθαν από διεγερτικές συνάψεις) και εάν υπερβεί ένα συγκεκριμένο όριο τιμής, ο νευρώνας ενεργοποιείται. Διαφορετικά, ο νευρώνας καταστέλλεται και δεν παράγει σήμα.

Το αποτέλεσμα των McCulloch – Pitts έδειξε ότι τα τεχνητά νευρωνικά δίκτυα θα μπορούσαν να προσδιοριστούν από τα μαθηματικά, με αποτέλεσμα να μπορούν να εκτελέσουν υπολογισμούς μεγάλης πολυπλοκότητας και ισχύος. Με τον τρόπο αυτό, οι McCulloch – Pitts άνοιξαν το δρόμο σε μια νέα μορφή επεξεργασίας και υπολογισμού, η οποία βασίζεται στο σχεδιασμό τεχνητών νευρωνικών δικτύων και όχι σε προγραμματισμό μηχανών [4].

Το μαθηματικό μοντέλο που ανέπτυξαν οι McCulloch – Pitts, ακολούθησε το 1949 η δημοσίευση σημαντικών ιδεών σχετικά με τη μάθηση των νευρωνικών δικτύων από τον ψυχολόγο Donald Olding Hebb (Σχήμα 4). Στο βιβλίο του: “*The Organization of Behavior: A Neuropsychological Theory*”, ο Hebb προτείνει ότι οι “νευρωνικές οδοί”, οι συνδέσεις



Σχήμα 4: Η εξέλιξη των τεχνητών νευρωνικών δικτύων

δηλαδή μεταξύ κυττάρων/νευρώνων, ενισχύονται κάθε φορά που χρησιμοποιούνται και το υποστήριξε ως θεμελιώδη γνώση για την κατανόηση των τρόπων με τους οποίους οι

άνθρωποι μαθαίνουν. Θεώρησε ως ιδέα, την εξεύρεση συσχετίσεων κατά την ανταλλαγή σημάτων μεταξύ των συνδεδεμένων κυττάρων, οι οποίες προκαλούν την αύξηση ή τη μείωση της ισχύος τους. Αυτή η βασική διαδικασία είναι γνωστή ως “*εκμάθηση κατά Hebb*” (Hebbian learning) [7]. Στην εκμάθησή κατά Hebb, σκοπός είναι να βρεθεί η συσχέτιση ενός δοθέντος διανύσματος εξόδου B με ένα διάνυσμα εισόδου A όπου και τα δύο συνδέονται πλήρως μέσω συνδέσεων/καναλιών με βάρη ανά σύνδεση w_{ij} . Ως αποτέλεσμα αυτού, καθίσταται δυνατή η αυτόματη τροποποίηση των βαρών σύνδεσης με σκοπό τη δημιουργία οποιασδήποτε γραμμικής αντιστοίχισης μεταξύ του διανύσματος εισόδου και εξόδου. Αν οι αλλαγές των βαρών είναι αρκετά μικρές, η συσχέτιση θα φτάσει τελικά σε ένα σύνολο βαρών τα οποία συντελούν στο επιθυμητό διάνυσμα εξόδου, δοθέντος του διανύσματος εισόδου. Με τη μέθοδο αυτή ο Hebb έδειξε ότι είναι δυνατόν να εκπαιδευτεί ένα μοντέλο συσχέτισης που να ρυθμίζει τα βάρη των συνδέσεων και να διαμορφώνει μία επιθυμητή αντιστοίχιση μεταξύ εισόδου και εξόδου.

Το 1952, οι Alan Lloyd Hodgkin και Andrew Huxley διατύπωσαν ότι κατά την πυροδότηση, ο άξονας ξεκινά μία αντιστροφή της πολικότητας του φορτίου που ταξιδεύει μέσω αυτού, για να προκαλέσει την ενεργοποίηση της σύναψης στο τέλος [8]. Με αυτό τον τρόπο, ένας νευρώνας έχει την ικανότητα ηλεκτροχημικής σύνδεσης με άλλους νευρώνες και έτσι μπορούμε να θεωρήσουμε ότι το νευρικό δίκτυο είναι ένα δίκτυο ανεξάρτητων κυττάρων που κωδικοποιούν και μεταδίδουν πληροφορίες σε όλο τον εγκέφαλο.

Το πρώτο νευρωνικό δίκτυο που περιγράφεται αλγοριθμικά παρουσιάστηκε από τον Frank Rosenblatt τον Ιανουάριο του 1957. Σύμφωνα με τον Rosenblatt: “Αυξημένη προσοχή έχει εστιαστεί στη σκοπιμότητα κατασκευής μίας συσκευής που να επεξεργάζεται ανθρώπινες λειτουργίες όπως η αντίληψη, η αναγνώριση, ο σχηματισμός ιδεών και η δυνατότητα της γενίκευσης από την εμπειρία. Συγκεκριμένα, το ενδιαφέρον επικεντρώνεται στην ιδέα μιας μηχανής η οποία θα είναι ικανή να εξομοιώνει ερεθίσματα από το φυσικό περιβάλλον όπως φως, ήχος, θερμοκρασία, κ.α. αντί να απαιτεί την παρέμβαση ενός ανθρώπινου παράγοντα για να αφομοιώσει και να κωδικοποιήσει τις απαραίτητες πληροφορίες.” [9]. Συνεχίζοντας ο Rosenblatt αναφέρει: “*Μία βασική απαίτηση ενός τέτοιου συστήματος είναι ότι πρέπει να είναι σε θέση να αναγνωρίζει σύνθετες μορφές πληροφορίας που μπορεί να είναι φαινομενικά όμοιες ή να σχετίζονται με εμπειρίες; μία διαδικασία που αντιστοιχεί στα ψυχολογικά φαινόμενα της “συσχέτισης” και της “γενίκευσης ερεθισμάτων”.* Το σύστημα πρέπει να αναγνωρίζει την ίδια οντότητα ακόμη και σε διαφορετικούς προσανατολισμούς, μεγέθη, χρώματα ή μετασχηματισμούς καθώς και σε διαφορετικά


υπόβαθρα. Η αναγνώριση των παρόμοιων μορφών μπορεί να πραγματοποιηθεί, σε κάποιο βαθμό, από αναλυτικές διαδικασίες σε έναν ηλεκτρονικό υπολογιστή, κάτι όμως δύσκολο να πραγματοποιηθεί χωρίς την ύπαρξη αποθηκευμένων σε μία βιβλιοθήκη αναφορών, με τις οποίες θα μπορεί να συγκριθεί μία αντίληψη. Γενικά, οντότητες αυτού του είδους πρέπει να απομνημονευθούν ή να αποκτηθούν από την εμπειρία και επειδή το σύστημα δεν έχει απεριόριστη μνήμη, ο αριθμός των λειτουργικών μονάδων στο αποθηκευτικό τμήμα θα πρέπει να είναι πολύ μικρότερος από τον αριθμό των μορφών ή των αναμνήσεων που θα διατηρούνται.” [9]. Στην ίδια δημοσίευση ο Rosenblatt προσθέτει: “Το προτεινόμενο σύστημα εξαρτάται από πιθανολογικές και όχι αιτιοκρατικές αρχές για τη λειτουργία του ενώ κερδίζει την αξιοπιστία του από την αξία των στατιστικών μετρήσεων που προέρχονται από μεγάλους πληθυσμούς δεδομένων. Ένα σύστημα που λειτουργεί σύμφωνα με αυτές τις αρχές θα ονομάζεται *perceptron*.” [9].

Στο μοντέλο του Rosenblatt, οι συνάψεις αναπαρίστανται από μεταβλητές, πολλαπλασιαστές του σήματος εισόδου οι οποίοι συστηματικά προσαρμόζονται για να απομακρύνουν τα σφάλματα. Ο Rosenblatt στο άρθρο του “*The Principles of Neurodynamics*” (1961) αναλύει τη διαδικασία σύγκλισης ενός *perceptron* [10]. Η διαδικασία αυτή θεωρήθηκε ως σημαντική πρόοδος της εκμάθησης κατά Hebb για τον υπολογισμό των βαρών σε σύνθετα δίκτυα. Απέδειξε ότι εάν τα μοτίβα που χρησιμοποιούνται για την εκπαίδευση του *perceptron* σε ένα νευρώνα προέρχονται από δύο γραμμικά διαχωρίσιμες κατηγορίες (κλάσεις), τότε ο αλγόριθμος που διέπει το *perceptron* συγκλίνει και τοποθετεί το αποτέλεσμα (επιφάνεια απόφασης) με τη μορφή υπερεπιπέδου μεταξύ των δύο κατηγοριών. Με την επέκταση του επιπέδου εξόδου (output layer) ώστε να συμπεριλάβει περισσότερους από ένα νευρώνες, μπορεί να πραγματοποιηθεί ταξινόμηση με περισσότερες από δύο κατηγορίες (κλάσεις). Ωστόσο, οι κατηγορίες πρέπει να είναι γραμμικά διαχωρίσιμες για να λειτουργεί σωστά το *perceptron* και επειδή αυτό δεν συμβαίνει πάντα, εξετάζεται μόνο η περίπτωση της εφαρμογής σε ένα νευρώνα.

Στα τέλη της δεκαετίας του ’60, και συγκεκριμένα το 1969, οι Minsky και Papert δημοσίευσαν την κριτική τους πάνω στις απόψεις του Rosenblatt με τίτλο: “*Perceptrons: An introduction to Computational Geometry*”. Στο έργο αυτό επισημαίνονται ορισμένοι περιορισμοί στο μοντέλο του Rosenblatt. Ειδικότερα έδειξαν ότι το *perceptron* δεν είναι σε θέση να υπολογίσει μη γραμμικά διαχωρίσιμες λειτουργίες με αποτέλεσμα την μη πρακτική εφαρμογή του [11]. Εξαιτίας αυτής της έκδοσης, η εξέλιξη της έρευνας πάνω στη μάθηση των νευρωνικών δικτύων επιβραδύνθηκε απότομα.

Καθ' όλη τη διάρκεια της δεκαετίας του '70 και στις αρχές της δεκαετίας του '80, πολύ λίγοι επιστήμονες ασχολήθηκαν ουσιαστικά με το πεδίο των τεχνητών νευρωνικών δικτύων. Το 1982, ο φυσικός John Hopfield (1933-σήμερα) έκανε γνωστή τη σχέση των ΤΝΔ με τη φυσική, χρησιμοποιώντας ιδέες από τη στατιστική φυσική. Ανέλυσε τη συμπεριφορά ενός απλού δυαδικού δικτύου κυττάρων, όπως τα όρισαν οι McCulloch – Pitts, στο οποίο η έξοδος κάθε νευρώνα συνδέεται με τις εισόδους άλλων νευρώνων. Ο Hopfield θεώρησε ότι σε ένα τέτοιο δίκτυο, σε οποιαδήποτε χρονική στιγμή, η έξοδος όλων των νευρώνων θα πρέπει να θεωρείται από κοινού ως “προσωρινή κατάσταση” του δικτύου [12]. Απέδειξε ότι μόλις εμφανιστεί ένα τυχαίο αρχικό διάνυσμα, ένα τέτοιο δίκτυο θα περάσει από μία σειρά μεταβατικών καταστάσεων μέχρι να πέσει σε μία συγκεκριμένη αλληλουχία πυροδοτήσεων, μετά από πεπερασμένο αριθμό επαναλήψεων. Με τον τρόπο αυτό, το δίκτυο λειτουργεί ως ένας αμφίδρομος συσχετιστής προτύπων, συνδέοντας ένα τυχαίο διάνυσμα εισόδου με ένα διάνυσμα εξόδου. Ως εκ τούτου, η μάθηση στο δίκτυο Hopfield απλώς συνεπάγεται το σχεδιασμό των βαρών έτσι ώστε το δίκτυο να αναγκάζεται να παραμείνει σε συγκεκριμένες επιθυμητές καταστάσεις. Ο Hopfield πρότεινε ότι ένα δυαδικό δίκτυο που αποτελείται από N νευρώνες μπορεί αξιόπιστα να αποθηκεύσει 2^N διαφορετικές σταθερές ενεργειακές καταστάσεις. Στο βασικό μοντέλο Hopfield ο νευρώνας μπορεί να βρεθεί σε μία από τις δύο καταστάσεις: ενεργός ή ανενεργός ($[-1, +1]$ ή $[0, 1]$). Ο Hopfield ανέλυσε τόσο ένα σύγχρονο δίκτυο όπου όλοι οι νευρώνες ενεργοποιούνται ταυτόχρονα όσο και ασύγχρονα δίκτυα όπου κάθε νευρώνας ενεργοποιείται ανεξάρτητα από τους υπόλοιπους, με ένα μέσο ρυθμό W προσπαθειών το δευτερόλεπτο.

Το 1985, μετά από τη δημοσίευση “*Neural computation of decisions in optimization problems*” τα δίκτυα Hopfield εφαρμόστηκαν σε δύσκολα προβλήματα βελτιστοποίησης [13]. Η εργασία του Hopfield οδήγησε στην ανάπτυξη της “*Μηχανής Boltzmann*” [14]. Η “*Μηχανή Boltzmann*” αποτελείται από απλές μονάδες επεξεργασίας οι οποίες συνδέονται μέσω αμφίδρομων ζεύξεων (Σχήμα 5). Οι συνδέσεις αυτές αντιπροσωπεύονται από διανύσματα τιμών με πραγματικά βάρη και οι μονάδες επεξεργασίας μπορεί να είναι ενεργοποιημένες ή απενεργοποιημένες. Έτσι, η “*Μηχανή Boltzmann*” μπορεί να θεωρηθεί ως στοχαστική και παραγωγική επέκταση των δικτύων Hopfield. Αν και η “*Μηχανή Boltzmann*” ήταν ένα από τα πρώτα παραδείγματα αρχιτεκτονικής νευρωνικών δικτύων, ικανών να αφομοιώνουν εσωτερικές αναπαραστάσεις, δεν αποδείχθηκαν χρήσιμα σε πρακτικά προβλήματα στη μηχανική μάθηση λόγω πολλών σοβαρών πρακτικών ζητημάτων σχετικά με το χρόνο εκμάθησης [15].



Σχήμα 5: Γραφική απεικόνιση της αρχιτεκτονικής της "Μηχανής του Boltzman" όπου L ο αριθμός των νευρώνων στο κρυφό επίπεδο και K ο αριθμός των νευρώνων στο ορατό επίπεδο.

Μία καθοριστική στιγμή στην εξέλιξη των τεχνητών νευρωνικών δικτύων στη δεκαετία του '80, ήταν η ανάπτυξη ενός κανόνα μάθησης που μπορεί να εφαρμοστεί σε δίκτυα πολλαπλών επιπέδων. Σε αυτά τα δίκτυα υπάρχουν νευρώνες οι οποίοι είναι "κρυμμένοι", δηλαδή οι κόμβοι επεξεργασίας δεν συνδέονται απευθείας με την έξοδο του δικτύου. Ο αλγόριθμος στον οποίο οι ερευνητές έδωσαν την μεγαλύτερη σημασία ήταν αυτός των Rumelhart, Hinton και Williams [16] σε συνεργασία με την ομάδα PDP (Parallel Distributed Processing) από το Πανεπιστήμιο της Καλιφόρνια, με το όνομα "αλγόριθμος οπισθοδρομικής μετάδοσης σφάλματος" (backpropagation algorithm) γνωστός και ως "κανόνας Δέλτα" (generalised Delta rule). Ο αλγόριθμος λειτουργεί υπολογίζοντας αρχικά την τιμή σφάλματος μεταξύ της τιμής εξόδου και της πραγματικής τιμής. Στη συνέχεια, μεταδίδει την τιμή σφάλματος αντίστροφα προς τους κόμβους εισόδου, διορθώνοντας τα βάρη κάθε σύνδεσης από την οποία περνάει. Έτσι, επιτυγχάνεται ελαχιστοποίηση του συνολικού σφάλματος πρόβλεψης του δικτύου. Ο αλγόριθμος αυτός βελτιώθηκε από τους Broomhead και Lowe [17] και πήρε το όνομα "radial basis function". Μπορεί να χρησιμοποιηθεί σε οποιοδήποτε είδος μοντέλου (γραμμικό ή μη) καθώς και σε οποιοδήποτε είδος δικτύου (ενός επιπέδου ή πολλαπλών). Ένα δίκτυο αυτής της μορφής είναι μη γραμμικό εάν οι συναρτήσεις του μπορούν να μετακινηθούν ή να αλλάζουν μέγεθος ή εάν υπάρχουν περισσότερα του ενός κρυμμένα επίπεδα.


Με την ανάπτυξη του perceptron πολλαπλών επιπέδων και την ευρεία αποδοχή του αλγόριθμου οπισθοδρομικής μετάδοσης σφάλματος, μαζί με τη βελτίωση του που αναφέρθηκε προηγουμένως, πολλές από τις βασικές επικρίσεις των Minsky και Papert διευθετήθηκαν. Έτσι, στις επόμενες δεκαετίες υπήρξε μία έκρηξη δημοσιεύσεων τα οποία

περιγράφουν λεπτομερώς τις εφαρμογές των τεχνητών νευρωνικών δικτύων σε διάφορα επιστημονικά πεδία.

4. ΤΟ ΜΑΘΗΜΑΤΙΚΟ ΜΟΝΤΕΛΟ ΕΝΟΣ ΝΕΥΡΩΝΙΚΟΥ ΚΥΤΤΑΡΟΥ

Η προσομοίωση του μαθηματικού μοντέλου ξεκινά με την παραδοχή ότι κάθε συναπτική είσοδος αναπαρίσταται από μία μεταβλητή w_i της οποίας οι τιμές απεικονίζουν το βαθμό στον οποίο ο νευρώνας θα πρέπει να αντιδράσει στην i -οστή είσοδο. Τη μεταβλητή αυτή την ονομάζουμε *βάρος* ή *αξία* (*weight*). Συμφωνούμε ότι τα *βάρη* με θετικές τιμές αντιπροσωπεύουν διεγερτικές συνάψεις ενώ αν έχουν αρνητικές τιμές αντιπροσωπεύουν ανασταλτικές. Συμβολίζουμε με b μία σταθερή μεταβλητή με την τιμή 1, η οποία προστίθεται ως είσοδος σε κάθε νευρώνα (*bias*). Θεωρητικά, η τιμή αυτή είναι έξοδος από άλλο νευρώνα. Η προσθήκη αυτής της μεταβλητής έχει να κάνει με την δυνατότητα που δίνεται σε έναν *ταξινομητή* να μετατοπίσει το όριο απόφασης αριστερά ή δεξιά. Στα μαθηματικά, ένας ταξινομητής “μεταφράζει” και “προσαρμόζει” την είσοδο που δέχεται. Έτσι, η μεταβλητή αυτή βοηθά το μοντέλο με τέτοιο τρόπο ώστε να μπορεί να προσαρμόζει καλύτερα τα δεδομένα εισόδου.

Στο Σχήμα 6, φαίνονται οι παραπάνω έννοιες και επιπλέον $x_1, x_2, x_3, \dots, x_n$ είναι τα δεδομένα εισόδου στο νευρώνα μαζί με τα αντίστοιχα βάρη τους $w_1, w_2, w_3, \dots, w_n$ τα οποία



Σχήμα 6: Μαθηματική αναπαράσταση ενός τεχνητού νευρώνα.

προσομοιώνουν τις συναπτικές νευρωνικές συνδέσεις σε βιολογικά δίκτυα με τέτοιο τρόπο ώστε να αυξάνουν ή να μειώνουν τα σήματα εισόδου στο νευρώνα. Τα δεδομένα εισόδου,

πολλαπλασιαζόμενα με τα αντίστοιχα βάρη τους και προστιθέμενα μαζί με το b , συνιστούν την είσοδο στο νευρώνα που τη συμβολίζουμε με net . Έτσι:

$$net = x_1 * w_1 + x_2 * w_2 + x_3 * w_3 + \dots + x_n * w_n + b = \sum_{i=0}^n (x_i * w_i) + b$$


Ο νευρώνας λειτουργεί όπως μία συνάρτηση στα μαθηματικά: παίρνει την είσοδο x και αποδίδει, μέσω μίας συνάρτησης f , μία τιμή y . Η συνάρτηση ονομάζεται *συνάρτηση ενεργοποίησης* ή *μεταφοράς* και γράφεται ως εξής:

$$y = f(net) = f\left(\sum_{i=1}^n (x_i * w_i) + b\right)$$

Μερικά παραδείγματα συναρτήσεων ενεργοποίησης ή μεταφοράς είναι τα εξής:

1) Γραμμική συνάρτηση ενεργοποίησης:

Στην περίπτωση αυτή, η γραφική παράσταση της συνάρτησης φαίνεται στο Σχήμα 7 και είναι της μορφής $y = f(x) = ax + b$:




Σχήμα 7: Γραφική παράσταση γραμμικής συνάρτησης

2) Συνάρτηση ενεργοποίησης με όριο:

Λέγεται και *δυναδική συνάρτηση*. Εδώ, η τιμή της εξαρτημένης μεταβλητής y περιορίζεται σε 2 μόνο τιμές: $+1$ ή -1 (μπορεί και 0) η οποία εξαρτάται από τη συμπεριφορά του δικτύου. Η μορφή της συνάρτησης είναι:

$$y = f(net) = \begin{cases} +1, & net > 0 \\ -1, & net < 0 \end{cases}$$


και η γραφική παράσταση της φαίνεται στο Σχήμα 8:



Σχήμα 8: Γραφική παράσταση συνάρτησης με όριο

3) Σιγμοειδής συνάρτηση:

Λέγεται και *λογιστική συνάρτηση*. Η γραφική παράσταση της μοιάζει με S, όπως φαίνεται στο Σχήμα 9 καθώς δίνει τιμές (y) μεταξύ 0 και +1. Η μαθηματική συνάρτηση είναι: $y = f(net) = \frac{1}{1+e^{-net}}$




Σχήμα 9: Γραφική παράσταση σιγμοειδούς συνάρτησης

Η βασική χρήση της συνάρτησης αυτής είναι σε μοντέλα που σχεδιάζονται για πρόβλεψη πιθανότητας.

4) Υπερβολική εφαπτομένη:

Είναι παρόμοια με τη σιγμοειδή συνάρτηση. Η γραφική παράσταση της συνάρτησης $\tanh$ είναι στο διάστημα $(-1, +1)$. Έχει και αυτή σχήμα S όπως φαίνεται στο Σχήμα

10. Η συνάρτηση δίνεται από τη σχέση: $y = \tanh(\text{net}) = \frac{e^{\text{net}} - e^{-\text{net}}}{e^{\text{net}} + e^{-\text{net}}}$



Σχήμα 10: Γραφική παράσταση υπερβολικής εφαπτομένης


Κατά τους McCulloch – Pitts, ένα τεχνητό νευρωνικό δίκτυο είναι ένα πλήθος νευρώνων διασυνδεδεμένων μεταξύ τους. Το νευρωνικό δίκτυο ενός στρώματος, αποτελείται από ένα μόνο στρώμα νευρώνων μεταξύ του διανύσματος τιμών εισόδου και του διανύσματος εξόδου. Σε ένα νευρωνικό δίκτυο πολλαπλών στρωμάτων, η έξοδος κάθε νευρώνα που ανήκει στο στρώμα εξόδου, θα σχηματίσει ένα στοιχείο του διανύσματος εξόδου του δικτύου. Σε ένα κρυφό στρώμα του δικτύου, το οποίο μπορεί να είναι ένα οποιοδήποτε στρώμα νευρώνων των οποίων οι εξοδοί δεν αποτελούν την έξοδο του δικτύου, η έξοδος των νευρώνων διαμορφώνει την είσοδο σε έναν ή περισσότερους νευρώνες σε ένα επόμενο στρώμα. Ένα ανατροφοδοτούμενο νευρωνικό δίκτυο λειτουργεί παίρνοντας την έξοδο ενός ή περισσότερων νευρώνων και τροφοδοτεί/μεταδίδει αντίστροφα προς την είσοδο των νευρώνων του ιδίου ή προηγούμενων στρωμάτων. Έτσι, η διαδικασία της νευρωνικής επεξεργασίας σε υπολογιστικό περιβάλλον προσπαθεί να προσεγγίσει το υπολογιστικό πρότυπο με το οποίο λειτουργεί ο εγκέφαλος. Μπορούμε να πούμε ότι είναι ένα υπολογιστικό στυλ που βασίζεται στη μάθηση από την εμπειρία, σε αντίθεση με τις κλασσικές, αυστηρά προσδιορισμένες μαθηματικές μεθόδους. Οι Aleksander and Morton ορίζουν ως νευρωνική επεξεργασία: “η μελέτη δικτύων με ευπροσάρμοστους κόμβους οι οποίοι, μέσω μίας διαδικασίας μάθησης από απτά παραδείγματα, αποθηκεύουν βιωματική γνώση που είναι διαθέσιμη προς χρήση” [18].

5. ΑΡΧΙΤΕΚΤΟΝΙΚΕΣ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Ένα τεχνητό νευρωνικό δίκτυο προσδιορίζεται ως ένα σύστημα επεξεργασίας δεδομένων που αποτελείται από ένα μεγάλο αριθμό διασυνδεδεμένων επεξεργαστικών στοιχείων (νευρώνες, κόμβοι), σε μια αρχιτεκτονική διάταξη εμπνευσμένη από τη δομή του εγκεφάλου. Υπάρχουν διάφοροι τύποι αρχιτεκτονικής των νευρωνικών δικτύων. Οι πιο ευρέως χρησιμοποιούμενοι είναι δύο: *εμπρόσθιας τροφοδότησης* (feed forward) και *ανατροφοδοτούμενα* (recurrent).

Εμπρόσθιας τροφοδότησης:

Σε ένα νευρωνικό δίκτυο εμπρόσθιας τροφοδότησης, η πληροφορία μεταδίδεται προς μία κατεύθυνση κατά μήκος των συνδέσεων, από το επίπεδο εισόδου, μέσω κρυμμένων επιπέδων προς το επίπεδο εξόδου. Δεν υπάρχουν βρόγχοι με αποτέλεσμα η έξοδος οποιουδήποτε επιπέδου δεν επηρεάζει το ίδιο ή κάποιο προηγούμενο επίπεδο (Σχήμα 11).




Σχήμα 11: Νευρωνικό δίκτυο πολλαπλών επιπέδων εμπρόσθιας τροφοδότησης

Ένα δίκτυο πολλαπλών επιπέδων εμπρόσθιας τροφοδότησης αποτελείται από ένα επίπεδο εισόδου, ένα επίπεδο εξόδου και ένα μεταβλητό αριθμό κρυφών επιπέδων. Στο επίπεδο εισόδου δεν λαμβάνει χώρα καμία επεξεργαστική λειτουργία. Όλες οι συνδέσεις μεταξύ των επιπέδων επιτρέπονται. Συνδέσεις μεταξύ κόμβων του ίδιου επιπέδου, όπως επίσης και συνδέσεις βρόγχων προς τα πίσω δεν επιτρέπονται. Πιθανές συνδέσεις μεταξύ μη διαδοχικών επιπέδων ονομάζονται “*απευθείας συνδέσεις*”. Στο Σχήμα 11 παρουσιάζονται με τη μορφή διανυσμάτων.

Τα δίκτυα αυτά ανήκουν σε μία κατηγορία μάθησης με επιτήρηση. Λειτουργούν με ένα σύνολο δεδομένων για εκπαίδευση τα οποία συμμετέχουν ως ζεύγη της τιμής εισόδου με το αποτέλεσμα της εξόδου. Τα δεδομένα εισόδου εμφανίζονται στο δίκτυο μόνο μία φορά, συνήθως σε τυχαία σειρά, και οι τιμές εξόδου, μετά τους υπολογισμούς στο δίκτυο, συγκρίνονται με τις τιμές στόχους με σκοπό την αναπροσαρμογή των βαρών. Μία τέτοια διαδρομή (epoch) περιλαμβάνει την εμφάνιση όλων των δειγμάτων δεδομένων στο δίκτυο. Η εκπαίδευση του δικτύου πραγματοποιείται με την επανάληψη τέτοιων διαδρομών έως ότου ικανοποιηθεί ένα προαποφασισμένο κριτήριο σύγκλισης.

Ανατροφοδοτούμενα:

Αυτά τα δίκτυα διαφέρουν στην αρχιτεκτονική από τα εμπρόσθιας τροφοδότησης καθώς υπάρχει τουλάχιστον ένας βρόγχος ανακατεύθυνσης [19]. Έτσι, θα μπορούσε να υπάρχει ένα επίπεδο με τέτοιους βρόγχους όπως φαίνεται στο Σχήμα 12. Θα μπορούσαν



Σχήμα 12: Ανατροφοδοτούμενο νευρωνικό δίκτυο

επίσης, να υπάρχουν νευρώνες με βρόγχους έτσι ώστε η έξοδος ενός νευρώνα να τροφοδοτεί τον εαυτό του ως είσοδος.

Η ιδέα πίσω από τα ανατροφοδοτούμενα νευρωνικά δίκτυα είναι να κάνουν χρήση διαδοχικών πληροφοριών. Σε ένα απλό δίκτυο κάνουμε την παραδοχή ότι όλες οι εισοδοί είναι ανεξάρτητες η μία από την άλλη. Έτσι, για παράδειγμα, για να βρεθεί η επόμενη λέξη σε μία πρόταση, θα ήταν χρήσιμο να ξέραμε την προηγούμενη. Για τον υπολογισμό κάθε στοιχείου στην ακολουθία του δικτύου, εκτελείται η ίδια εργασία, με την έξοδο όμως κάθε

φορά να εξαρτάται από προηγούμενους υπολογισμούς. Ενώ στη θεωρία το ανατροφοδοτούμενο δίκτυο είναι απλό και ταυτόχρονα ισχυρό μοντέλο, στην πράξη είναι δύσκολο να εκπαιδευθεί σωστά. Μεταξύ των κυριότερων λόγων για τους οποίους το μοντέλο αυτό είναι τόσο δυσμεταχειρίστο είναι προβλήματα διάρθρωσης όπως περιγράφονται από τους Bengio et al. [20].


Οι επαναληπτικές συνδέσεις είναι εφικτές, αν και απαιτούνται προσαρμογές στον αλγόριθμο εκπαίδευσης. Η γεωμετρική διάταξη των νευρώνων μέσα σε ένα επίπεδο είναι διαχειρίζεται συνήθως από την εκάστοτε εφαρμογή. Στις φασματοσκοπικές εφαρμογές για παράδειγμα, τα επίπεδα ακολουθούν την γραμμική τοπολογία. Η βέλτιστη διάταξη εξαρτάται από την πολυπλοκότητα του μοντέλου που μελετάται. Γενικά, τα σφάλματα που συναντώνται στην ποσοτική ανάλυση είναι λιγότερο περίπλοκα από αυτά που εμφανίζονται στην ποιοτική. Οι μέθοδοι για τον προσδιορισμό του βέλτιστου αριθμού κρυμμένων επιπέδων μπορούν να χωριστούν σε δύο ομάδες. Η πρώτη ξεκινάει από ένα πολύ απλό δίκτυο και αυξάνει την πολυπλοκότητά του μέχρι να βρεθεί η βέλτιστη δομή. Στη δεύτερη ομάδα, η βέλτιστη αρχιτεκτονική αναζητείται με αντίστροφο τρόπο: ξεκινάει από ένα μεγάλο σε αριθμό κόμβων και κρυφών επιπέδων δίκτυο, και παρακολουθείται η συμπεριφορά του καθώς αφαιρούνται σταδιακά κόμβοι ή επίπεδα. Και στις δύο περιπτώσεις, πρέπει να εκτελεστεί ένας μεγάλος αριθμός πλεοναζόντων υπολογισμών προκειμένου να βρεθεί η βέλτιστη κατάσταση. Ωστόσο, σε πολλές πρακτικές εφαρμογές, μία τέτοια εκτεταμένη αναζήτηση της βέλτιστης αρχιτεκτονικής δεν είναι δικαιολογημένη και μπορεί να χρησιμοποιηθεί ένας εμπειρικός κανόνας σύμφωνα με τον οποίο ο αριθμός των ρυθμιζόμενων παραμέτρων πρέπει να είναι περίπου ο μισός του αριθμού των δειγμάτων.

6. ΜΕΘΟΔΟΙ ΕΚΠΑΙΔΕΥΣΗΣ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Όπως ακριβώς υπάρχουν διαφορετικοί τρόποι με τους οποίους ο άνθρωπος μαθαίνει από το περιβάλλον γύρω του, έτσι συμβαίνει και με τα νευρωνικά δίκτυα. Γενικεύοντας, μπορούμε να κατηγοριοποιήσουμε τις διαδικασίες μάθησης μέσω των οποίων τα νευρωνικά δίκτυα λειτουργούν, ως εξής: μάθηση με επιτήρηση (*supervised learning*) και μάθηση χωρίς επιτήρηση (*unsupervised learning*). Στη δεύτερη μορφή μάθησης ορίζεται επιπλέον μία υποκατηγορία, αυτή της ενισχυόμενης μάθησης (*reinforcement learning*). Αυτές οι διαφορετικές μορφές μάθησης που εκτελούνται σε νευρωνικά δίκτυα είναι παρόμοιες με τον ανθρώπινο τρόπο μάθησης.

Μάθηση με επιτήρηση:

Είναι γνωστή και ως “μάθηση με δάσκαλο”. Στο Σχήμα 13 φαίνεται το διάγραμμα μάθησης με επιτήρηση. Κάνοντας μία εννοιολογική αντιστοίχιση, μπορούμε να πούμε ότι ο



Σχήμα 13: Διάγραμμα της μάθησης με επιτήρηση. Το τμήμα χρωματισμένο μπλε απεικονίζει ανατροφοδότηση

“δάσκαλος” έχει γνώση του περιβάλλοντος, η οποία αναπαρίσταται από ένα σύνολο παραδειγμάτων εισόδου/εξόδου. Το νευρωνικό δίκτυο δεν έχει καμία απολύτως γνώση για το περιβάλλον. Υποθέτουμε τώρα ότι ο δάσκαλος μαζί με το νευρωνικό δίκτυο έρχονται αντιμέτωποι με ένα παράδειγμα (είσοδος διανύσματος) που προέρχεται από το κοινό περιβάλλον. Ο δάσκαλος είναι σε θέση να παρέχει στο δίκτυο μία επιθυμητή απάντηση για το συγκεκριμένο διάνυσμα. Πράγματι, η απάντηση αυτή αντιπροσωπεύει την βέλτιστη ενέργεια που πρέπει να γίνει από το νευρωνικό δίκτυο. Οι παράμετροι του δικτύου ρυθμίζονται από τη συνδυασμένη επίδραση του διανύσματος εκπαίδευσης και του σήματος σφάλματος. Το σήμα σφάλματος ορίζεται ως η διαφορά μεταξύ της της επιθυμητής και της πραγματικής απόκρισης του δικτύου. Η προσαρμογή αυτή πραγματοποιείται σταδιακά με τελικό σκοπό το νευρωνικό δίκτυο να μιμηθεί τον δάσκαλο. Με τον τρόπο αυτό, η γνώση του περιβάλλοντος την οποία διαθέτει ο δάσκαλος, μεταφέρεται στο νευρωνικό δίκτυο μέσω εκπαίδευσης και αποθηκεύεται με τη μορφή σταθερών συναπτικών βαρών που λειτουργούν ως μακροπρόθεσμη μνήμη. Όταν επιτευχθεί η συνθήκη αυτή, απομακρύνεται ο δάσκαλος και αφήνουμε το νευρωνικό δίκτυο να διαχειριστεί το περιβάλλον από μόνο του. Αυτός ο τρόπος εκπαίδευσης με επιτήρηση είναι η βάση της διόρθωσης λάθους μέσω μάθησης.

Μάθηση χωρίς επιτήρηση:

Σε σχέση με την προηγούμενη περίπτωση, εδώ δεν υπάρχει δάσκαλος να επιβλέπει τη διαδικασία μάθησης, όπως φαίνεται στο Σχήμα 14. Πρόκειται ουσιαστικά για την



Σχήμα 14: Διάγραμμα της μάθησης χωρίς επιτήρηση


εκτίμηση μίας ανεξάρτητης μέτρησης που προκύπτει από την ποιοτική αντιπροσώπευση του δικτύου, την οποία λαμβάνουν υπόψη όλες οι παράμετροι του δικτύου κατά την διαδικασία της προσαρμογής και βελτιστοποίησης. Έτσι, όταν το δίκτυο φτάσει στη βέλτιστη δομή του, αναπτύσσει την ικανότητα να σχηματίζει εσωτερικές αναπαραστάσεις κωδικοποίησης χαρακτηριστικών των δεδομένων εισόδου και κατά συνέπεια δημιουργεί αυτόματα νέες κατηγορίες [21].

Για να πραγματοποιηθεί η μάθηση χωρίς επίβλεψη, μπορούμε να χρησιμοποιήσουμε έναν κανόνα ανταγωνιστικής μάθησης. Έτσι για παράδειγμα, θεωρούμε ένα νευρωνικό δίκτυο το οποίο αποτελείται από δύο επίπεδα: το επίπεδο εισόδου των δεδομένων και το “ανταγωνιστικό” επίπεδο. Το επίπεδο εισόδου λαμβάνει τα δεδομένα. Το “ανταγωνιστικό” επίπεδο αποτελείται από νευρώνες που ανταγωνίζονται μεταξύ τους, ακολουθώντας όλοι την ίδια διαδικασία μάθησης, για την ευκαιρία να ανταποκριθούν στα χαρακτηριστικά που περιέχονται/εμφανίζονται στα δεδομένα εισόδου. Σε μία απλουστευμένη μορφή, το δίκτυο λειτουργεί με τη στρατηγική του νικητή να τα παίρνει όλα. Σε μία τέτοια στρατηγική, ο νευρώνας με το μεγαλύτερο συνολικό τίμημα “κερδίζει” τον ανταγωνισμό και ενεργοποιείται. Όλοι οι υπόλοιποι νευρώνες παραμένουν ανενεργοί.

Ενισχυόμενη μάθηση:

Κατά τη διαδικασία της ενισχυόμενης μάθησης, η εύρεση της σχέσης μεταξύ δεδομένων εισόδου και εξόδου πραγματοποιείται μέσω μίας συνεχούς αλληλεπίδρασης με το περιβάλλον που έχει ως στόχο την ελαχιστοποίηση ενός κλιμακωτού δείκτη απόδοσης.

Στο Σχήμα 15 απεικονίζεται, με τη μορφή διαγράμματος, ένα είδος ενισχυόμενης μάθησης με επίκεντρο έναν “κριτή”, ο οποίος μετατρέπει ένα αρχικό σήμα που λαμβάνεται από το



Σχήμα 15: Διάγραμμα της ενισχυόμενης μάθησης. Το Σύστημα Μάθησης και το Περιβάλλον βρίσκονται και τα δύο σε βρόγχο ανατροφοδότησης

περιβάλλον, σε ένα ενισχυμένο, καλύτερης ποιότητας σήμα, που ονομάζεται σήμα ευρετικής ενίσχυσης. Και οι δύο εισοδοί είναι βαθμωτές [22]. Το σύστημα έχει σχεδιαστεί να μαθαίνει υπό καθυστέρηση το ενισχυόμενο σήμα καθώς παρατηρεί για περιορισμένο χρονικό διάστημα μία ακολουθία ερεθισμάτων που επίσης λαμβάνονται από το περιβάλλον, τα οποία καταλήγουν τελικά στη δημιουργία του σήματος ευρετικής ενίσχυσης.

Ο στόχος της ενισχυόμενης μάθησης είναι να ελαχιστοποιήσει την προσδοκία του σωρευτικού κόστους των ενεργειών που έχουν αναληφθεί σε μία σειρά βημάτων αντί του άμεσου κόστους. Μπορεί να αποδειχθεί ότι ορισμένες ενέργειες που έγιναν νωρίτερα σε αυτή την ακολουθία χρονικών βημάτων, είναι στην πραγματικότητα οι καλύτεροι καθοριστικοί παράγοντες της συνολικής συμπεριφοράς του συστήματος. Η λειτουργία του συστήματος είναι να ανακαλύψει αυτές τις ενέργειες και να τις τροφοδοτήσει πίσω στο περιβάλλον.


7. ΕΙΔΗ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Η προσπάθεια μοντελοποίησης περιβαλλοντικών καταστάσεων, περιλαμβάνει την ανάπτυξη ποικίλων προσεγγίσεων, ενδεχομένως σε συνδυασμό. Η επιλογή της καταλληλότερης προσέγγισης εξαρτάται από την πολυπλοκότητα του προβλήματος που

αντιμετωπίζεται και από το βαθμό κατανόησής του. Υποθέτοντας την ύπαρξη επαρκών δεδομένων και επεξεργαστικών πόρων και εάν υπάρχει μία ισχυρή θεωρητική κατανόηση του προβλήματος, τότε ένα πλήρες αριθμητικό μοντέλο είναι ίσως η πιο επιθυμητή λύση. Εντούτοις, σε γενικές γραμμές, καθώς η πολυπλοκότητα ενός προβλήματος αυξάνει, η θεωρητική κατανόηση μειώνεται λόγω των κακώς καθορισμένων αλληλεπιδράσεων μεταξύ συστημάτων. Τα τελευταία χρόνια, η χρήση των νευρωνικών δικτύων και ειδικότερα των perceptron πολλών επιπέδων, έχει αποδειχθεί ως αποτελεσματικές εναλλακτικές λύσεις έναντι των παραδοσιακών στατιστικών τεχνικών [23].

Τα τεχνητά νευρωνικά δίκτυα μπορούν να χωριστούν σε τρεις κατηγορίες ανάλογα με το είδος των προβλημάτων που μπορούν να αντιμετωπίσουν (Σχήμα 16):

- Perceptron πολλών επιπέδων (multilayer perceptron - MLP),
- Δίκτυα λειτουργίας ακτινικής βάσης συνάρτηση (Radial Basis Function - RBF),
- Λειτουργία αυτο-οργάνωσης σε χάρτη (self-organizing map – SOM ή SOFM).




Σχήμα 16: Σχηματική παράσταση αρχιτεκτονικών νευρωνικών δικτύων (Jain et al., 1996)

Multilayer perceptron:

Σε αντίθεση με άλλες στατιστικές τεχνικές, το MLP δεν κάνει εκ των προτέρων παραδοχές σχετικά με την κατανομή των δεδομένων. Μπορεί να μοντελοποιεί υψηλής κλίμακας μη γραμμικές συναρτήσεις και μπορεί να εκπαιδευτεί έτσι ώστε να γενικεύει με ακρίβεια νέα, πρωτοεμφανιζόμενα δεδομένα. Οι ιδιότητες αυτές καθιστούν το perceptron πολλών επιπέδων ελκυστική, εναλλακτική προσέγγιση για την ανάπτυξη αριθμητικών μοντέλων και στατιστικών επιλογών.

Το MLP αποτελείται από ένα σύστημα απλών, διασυνδεδεμένων νευρώνων (κόμβων), όπως φαίνεται στο Σχήμα 17, δημιουργώντας έτσι ένα μοντέλο που αναπαριστά



Σχήμα 17: Perceptron πολλών επιπέδων με 2 κρυφά επίπεδα

μία μη γραμμική αντιστοίχιση μεταξύ ενός διανύσματος εισόδου και ενός διανύσματος εξόδου. Οι κόμβοι συνδέονται μεταξύ τους με βάρη και σήματα εξόδου τα οποία είναι συνάρτηση του αθροίσματος των σημάτων εισόδου στον κόμβο, μετασχηματισμένα από μία απλή, μη γραμμική συνάρτηση ενεργοποίησης ή μεταφοράς. Είναι η σύνθεση πολλών μη γραμμικών συναρτήσεων μεταφοράς που επιτρέπουν στο *multilayer perceptron* να προσεγγίζει εξαιρετικά μη γραμμικές συναρτήσεις [54, 55, 56, 57, 58]. Εάν η συνάρτηση μεταφοράς ήταν γραμμική, το *multilayer perceptron* θα μπορούσε να μοντελοποιήσει τότε μόνο γραμμικές συναρτήσεις. Λόγω της εύκολα υπολογίσιμης παραγώγου, η πιο συνήθης συνάρτηση μεταφοράς είναι η λογιστική συνάρτηση. Η έξοδος από έναν κόμβο εξαρτάται από το βάρος της σύνδεσης και τροφοδοτείται προς τα εμπρός έτσι ώστε να γίνει είσοδος στους κόμβους στο επόμενο επίπεδο του δικτύου. Αυτό συνεπάγεται μία κατεύθυνση της επεξεργασίας της πληροφορίας καθώς το *multilayer perceptron* λειτουργεί ως εμπρόσθιας τροφοδότησης δίκτυο.

Η αρχιτεκτονική ενός MLP είναι μεταβλητή, γενικά όμως θα αποτελείται από διάφορα επίπεδα νευρώνων. Το επίπεδο εισόδου δεν συμμετέχει σε υπολογισμούς, χρησιμεύει όμως για την είσοδο του διανύσματος δεδομένων στο δίκτυο. Μπορεί να


υπάρχουν ένα ή περισσότερα κρυμμένα επίπεδα και τέλος το επίπεδο εξόδου. Τα MLP περιγράφονται ως πλήρως διασυνδεδεμένα, με κάθε κόμβο να συνδέεται σε κάθε κόμβο στο επόμενο αλλά και στο προηγούμενο επίπεδο. Επιλέγοντας ένα κατάλληλο σύνολο βαρών για τις συνδέσεις και για τις συναρτήσεις μεταφοράς, έχει αποδειχθεί ότι το *multilayer perceptron* μπορεί να προσεγγίσει οποιαδήποτε ομαλή, μετρήσιμη συνάρτηση μεταξύ του διανύσματος εισόδου και του διανύσματος εξόδου [24]. Τα perceptron πολλαπλών επιπέδων έχουν τη δυνατότητα να μαθαίνουν μέσω εκπαίδευσης. Η εκπαίδευση προϋποθέτει ένα σύνολο δεδομένων από υπάρχουσες μετρήσεις, τα οποία συνθέτουν τα διανύσματα εισόδου και εξόδου. Κατά τη διάρκεια της εκπαίδευσης τα δεδομένα παραμένουν στο δίκτυο μέχρι να καθοριστούν τα βάρη των συνδέσεων και να οριστικοποιηθεί η αντιστοίχιση μεταξύ δεδομένων εισόδου-εξόδου. Χρησιμοποιούν τη μέθοδο της μάθησης με επιτήρηση. Κατά τη διάρκεια της εκπαίδευσης, το αποτέλεσμα στο επίπεδο εξόδου, για ένα δοθέν διάνυσμα εισόδου, ενδέχεται να είναι διαφορετικό από το επιθυμητό. Έτσι, ορίζεται ένα σήμα σφάλματος (error signal) ως η διαφορά μεταξύ της πραγματικής και της επιθυμητής εξόδου. Κατά τη διαδικασία της εκπαίδευσης χρησιμοποιείται το μέγεθος του σήματος σφάλματος με σκοπό να προσδιοριστεί σε ποιο βαθμό τα βάρη στις συνδέσεις μεταξύ των κόμβων πρέπει να ρυθμιστούν ώστε το συνολικό σφάλμα να ελαχιστοποιηθεί. Υπάρχουν πολλοί αλγόριθμοι που μπορούν να χρησιμοποιηθούν για την εκπαίδευση ενός τέτοιου δικτύου. Με την ολοκλήρωση της εκπαίδευσης, το δίκτυο μπορεί να γενικεύσει και να επεξεργαστεί νέα, πρωτοεισερχόμενα δεδομένα.

Το αρχικό πρόβλημα που πρέπει να αντιμετωπιστεί με τη χρήση του perceptron πολλών επιπέδων είναι ο καθορισμός της αρχιτεκτονικής του δικτύου, δηλαδή ο αριθμός των επιπέδων και των κόμβων σε κάθε επίπεδο. Δεν υπάρχουν κανόνες που να καθορίζουν τη διαδικασία αυτή. Ο αριθμός των κόμβων εισόδου εξόδου αποφασίζεται κατά τον αρχικό σχεδιασμό του προβλήματος. Από τεχνικής άποψης, χρειάζεται μόνο ένα κρυφό επίπεδο για την προσέγγιση κάθε ομαλής, μετρήσιμης συνάρτησης μεταξύ εισόδου και εξόδου [24]. Ο βέλτιστος αριθμός κόμβων που απαιτείται στο κρυφό επίπεδο εξαρτάται από το πρόβλημα και εξαρτάται από την πολυπλοκότητα της αντιστοίχισης των δεδομένων εισόδου/εξόδου, την ποσότητα αχρείαστων δεδομένων και το μέγεθος του δείγματος δεδομένων προς εκπαίδευση. Εάν ο αριθμός των κόμβων στο κρυφό επίπεδο είναι σχετικά μικρός, ο αλγόριθμος οπισθοδρομικής μετάδοσης σφάλματος θα αποτύχει να συγκλίνει σε ένα ελάχιστο κατά τη διάρκεια της εκπαίδευσης. Αντίθετα, μεγάλος αριθμός κόμβων θα έχει ως

αποτέλεσμα να υπερκεράσει το δίκτυο τα δεδομένα εκπαίδευσης καταλήγοντας σε κακή απόδοση γενίκευσης.

Η αρχή της γενίκευσης απαιτεί περαιτέρω προσοχή. Αν δώσουμε σε ένα δίκτυο με πολλούς κόμβους και πολλά κρυφά επίπεδα δεδομένα για εκπαίδευση, είναι πολύ πιθανόν ότι το δίκτυο θα μάθει τελικά όλα τα πρότυπα που ακολουθούνται από τη συγκεκριμένη ομάδα δεδομένων, με αποτέλεσμα να μην μπορέσει να αξιολογήσει αξιόπιστα νέα, διαφορετικά δεδομένα (*overfitting*). Σε ένα πρόβλημα με “άσχετα” ή “προβληματικά” δεδομένα, το δίκτυο θα επηρεαστεί και αναγκαστικά θα μάθει και τα δεδομένα αυτά. Δεδομένου ότι αυτά τα “ενοχλητικά” δεδομένα βρίσκονται διάσπαρτα κατανεμημένα, παρόμοιες τεχνικές εκπαίδευσης με διαφορετικούς βαθμούς τέτοιων δεδομένων θα αντιμετωπιστούν ως ανόμοιες από το δίκτυο. Ένα τέτοιο δίκτυο, ανεπαρκώς εκπαιδευμένο, θα ταξινομήσει λανθασμένα κάθε νέα ομάδα δεδομένων καθώς δεν θα έχει παρατηρηθεί στα δεδομένα εκπαίδευσης. Η μείωση του αριθμού των κρυφών επιπέδων και κόμβων χρησιμεύει ως φίλτρο, δίνοντας το μήνυμα στο δίκτυο να αγνοήσει τα “ενοχλητικά” δεδομένα και να εστιάσει στη μάθηση των προτύπων των δεδομένων που ενδιαφέρουν πραγματικά.

Είναι σημαντικό να υπενθυμίσουμε ότι ο συνήθης σκοπός της εκπαίδευσης ενός *multilayer perceptron* είναι να επιτευχθεί ικανοποιητική γενίκευση σε πρωτοεμφανιζόμενα δεδομένα όπως για παράδειγμα σε προβλήματα πρόβλεψης. Η μέγιστη απόδοση γενίκευσης θα συμβεί προτού το συνολικό σφάλμα εκπαίδευσης του δικτύου φτάσει την ελάχιστη τιμή, όπως φαίνεται στο Σχήμα 18. Ένα δίκτυο που εκπαιδεύεται με δεδομένα που περιέχουν και



Σχήμα 18: Γραφική παράσταση σφάλματος εκπαίδευσης και αξιολόγησης

“προβληματικές” τιμές για να φτάσει το συνολικό ελάχιστο θεωρείται υπερεκπαιδευμένο (*overtrained*). Ένας τρόπος για να διασφαλιστεί ότι αυτό δεν θα συμβεί και η απόδοση της γενίκευσης θα είναι καλή είναι να διαιρεθούν τα δεδομένα εισαγωγής στο δίκτυο σε τρεις ομάδες: στα δεδομένα εκπαίδευσης, στα δεδομένα αξιολόγησης και στα δεδομένα ελέγχου. Η πρώτη ομάδα χρησιμοποιείται για την εκπαίδευση του δικτύου. Τα δεδομένα αξιολόγησης εισάγονται στο δίκτυο με την ολοκλήρωση της εκπαίδευσης. Σκοπός τους είναι να εκτιμηθεί η ικανότητα γενίκευσης του δικτύου. Τα δεδομένα ελέγχου εισάγονται για πρώτη φορά στο δίκτυο και χρησιμεύουν στην αξιολόγηση της συνολικής απόδοσης του.

Υπάρχουν πολλές συναρτήσεις που μπορούν να χρησιμοποιηθούν στη θέση της λογιστικής συνάρτησης. Θεωρητικά, όλες οι μη-γραμμικές συναρτήσεις μπορούν να χρησιμοποιηθούν, ωστόσο, λόγω του αλγορίθμου οπισθοδρομικής μετάδοσης σφάλματος, η συνάρτηση θα πρέπει να είναι διαφορίσιμη. Συνήθως προτιμώνται οριακές συναρτήσεις που μπορούν να εμποδίσουν τα βάρη από το να πάρουν πολύ μεγάλες τιμές, κάτι που θα επιβράδυνε τη σύγκλιση κατά την εκπαίδευση. Μία εναλλακτική λύση στη χρήση της λογιστικής συνάρτησης είναι η υπερβολική εφραπτομένη. Διαφορετικά επίπεδα στο δίκτυο μπορούν να έχουν διαφορετικές συναρτήσεις ενεργοποίησης. Είναι συχνά χρήσιμο, για παράδειγμα, να χρησιμοποιείται μία συνάρτηση που εκτείνεται στο άπειρο (π.χ. η $y=x$) στο επίπεδο εξόδου. Έτσι, δίνεται η δυνατότητα στις εξόδους να παίρνουν ένα εύρος τιμών χωρίς να περιορίζονται στα όρια της συνάρτησης, όπως για παράδειγμα μεταξύ 0 και 1 για τη λογιστική συνάρτηση.

Αφού εκπαιδευτούν, τα *multilayer perceptrons* είναι σε θέση να αναπαραστήσουν σχέσεις, συχνά με εκπληκτική ακρίβεια, που δεν είναι πλήρως κατανοητές από παραδοσιακές θεωρίες. Προσοχή πρέπει να δοθεί στη δομή των δικτύων αυτών καθώς υπάρχουν λειτουργίες που δεν είναι σαφώς εξηγήσιμες και ορισμένες (*black-box*). Δεν υπάρχουν επιστημονικές απόψεις ή σχετικές θεωρίες που να επιτρέπουν την ανάλυση των βαρών των συνδέσεων, ώστε να προσδιοριστεί επακριβώς τι έμαθε το δίκτυο από την εκπαίδευση. Υπάρχουν τεχνικές για τον προσδιορισμό μιας σχετικής σημασίας των δεδομένων εισόδου [25]. Οι τεχνικές αυτές κυμαίνονται από μία απλή ανάλυση των βαρών στο επίπεδο εισόδου και στο κρυφό επίπεδο έως πιο πολύπλοκους αλγόριθμους στους οποίους λαμβάνονται υπόψη τα βάρη αυτών των επιπέδων [26]. Άλλες προσεγγίσεις περιλαμβάνουν τον υπολογισμό των μερικών παραγώγων των εξόδων λαμβάνοντας υπόψη την διαφορετικότητα των δεδομένων εισόδου. Όλες αυτές οι προσεγγίσεις έχουν τους περιορισμούς τους και συχνά παρέχουν αντικρουόμενα αποτελέσματα. Η εφαρμογή έχει

δείξει ότι εάν το πρόβλημα που καλείται να λυθεί, με τη χρήση ενός MLP, είναι πρόβλημα πρόγνωσης ή ταξινόμησης, τότε οι περιορισμοί από το “*black-box*” θεωρούνται ασήμαντοι. Στις περιπτώσεις όπου το πρόβλημα αφορά την αύξηση της γνώσης λειτουργίας μίας φυσικής διαδικασίας ή την αλληλεπίδραση διαφόρων μηχανισμών τότε τυχόν περιορισμοί από τη λειτουργία του “*black-box*” θα περιορίσουν τη χρησιμότητα του μοντέλου. Μία πολλά υποσχόμενη υπό ανάπτυξη τεχνική περιλαμβάνει τον περιορισμό του δικτύου μετά από την εκπαίδευση, αφαιρώντας πλεονάζοντα βάρη. Το εναπομένον δίκτυο θα μπορεί τότε να περιγραφεί ευκολότερα [27].

Radial Basis Function Networks:

Η ιδέα πίσω από τα δίκτυα λειτουργίας ακτινικής βάσης (RBS) προέρχεται από τη θεωρία των “κατά προσέγγιση” συναρτήσεων (*function approximation*). Υπάρχουν δύο βασικές υποδιαιρέσεις στα προβλήματα στατιστικής ανάλυσης: παραμετρικά και μη παραμετρικά. Στην παραμετρική ανάλυση, το είδος της συνάρτησης που συνδέει τις εξαρτημένες με τις ανεξάρτητες μεταβλητές είναι γνωστή, μπορεί όμως να περιέχει και παραμέτρους των οποίων οι τιμές είναι άγνωστες και μπορούν να εκτιμηθούν από τα δεδομένα εκπαίδευσης. Το διακριτό χαρακτηριστικό της μη παραμετρικής ανάλυσης είναι ότι δεν υπάρχει, σχεδόν καθόλου, προ υπάρχουσα γνώση σχετικά με την μορφή της συνάρτησης υπολογισμού. Η συνάρτηση διαμορφώνεται με τη βοήθεια μιας εξίσωσης που περιέχει ελεύθερες παραμέτρους, αλλά με τέτοιο τρόπο που επιτρέπει την κατηγορία των συναρτήσεων που το μοντέλο μπορεί να αναπαραστήσει, να είναι ευρεία. Τυπικά, αυτό συνεπάγεται τη χρήση πολλών ελεύθερων παραμέτρων που μπορεί να μην έχουν σχέση με το πρόβλημα. Στην παραμετρική ανάλυση υπάρχει συνήθως ένας μικρός αριθμός παραμέτρων που να έχουν φυσική ερμηνεία.


Τα δίκτυα αυτά, αλλά και γενικότερα τα νευρωνικά δίκτυα, είναι μη παραμετρικά μοντέλα και τα βάρη τους, μαζί με άλλες παραμέτρους, δεν έχουν ιδιαίτερη σημασία σε σχέση με τα προβλήματα στα οποία εφαρμόζονται. Ο υπολογισμός των βαρών σε ένα νευρωνικό δίκτυο και γενικότερα των παραμέτρων οποιουδήποτε μη παραμετρικού μοντέλου, δεν είναι ποτέ ο βασικός στόχος της μάθησης με εποπτεία. Πρωταρχικός στόχος είναι ο προσδιορισμός εκείνης της συνάρτησης μεταφοράς που θα εκτιμήσει τις τιμές εξόδου σε σχέση με τις επιθυμητές τιμές εισόδου. Από την άλλη πλευρά, ο βασικός στόχος της παραμετρικής ανάλυσης συνήθως είναι η εκτίμηση των τιμών των παραμέτρων λόγω της ουσιαστικής τους σημασίας.

Σε προβλήματα ταξινόμησης, ο στόχος είναι να καταταχθούν προηγουμένως άγνωστα δεδομένα, σε αντίστοιχες κατηγορίες, με βάση προηγούμενα παραδείγματα από κάθε κατηγορία. Έτσι, η έξοδος του αλγορίθμου εκπαίδευσης είναι ένα διακριτό σύνολο πιθανών κατηγοριών και όχι η τιμή μιας συνεχούς συνάρτησης όπως σε μία μη παραμετρική ανάλυση. Εντούτοις, τα προβλήματα ταξινόμησης ενδέχεται να φαίνονται σαν μη παραμετρική ανάλυση εάν οι έξοδοι της εκτιμώμενης συνάρτησης ερμηνεύονται ανάλογα με την πιθανότητα η είσοδος να ανήκει στην αντίστοιχη κατηγορία.

Η ακτινικές συναρτήσεις είναι μία ειδική κατηγορία συναρτήσεων. Κύριο χαρακτηριστικό τους είναι ότι η απόκρισή τους μειώνεται ή αυξάνεται μονοτονικά, σε απόσταση από ένα σταθερό σημείο. Το κέντρο, η κλίμακα απόστασης και το ακριβές σχήμα της ακτινικής συνάρτησης αποτελούν παραμέτρους του μοντέλου, όλες προκαθορισμένες εάν η συνάρτηση είναι γραμμική. Μία τυπική, ακτινική συνάρτηση είναι η Gaussian η οποία για διαφορετικές τιμές της ανεξάρτητης μεταβλητής x , δίνεται από τη σχέση:

$$h(x) = \exp\left(-\frac{(x - c)^2}{r^2}\right)$$

Οι παράμετροι της συνάρτησης είναι το κέντρο c και η ακτίνα r . Το Σχήμα 19 απεικονίζει τη γραφική παράσταση της συνάρτησης Gauss όπου $c = 0$ και $r = 1$.



Σχήμα 19: Η συνάρτηση Gauss RBF με $c=0$ και $r=1$

Παρατηρούμε πως μειώνεται μονοτονικά με απόσταση από το κέντρο. Τα δίκτυα αυτά θεωρούνται τοπικά καθώς η απόκριση που δίνουν βρίσκεται πάντα σε μία καθορισμένη


περιοχή κοντά στο κέντρο. Επιπλέον, επειδή η απόκριση είναι πεπερασμένη, είναι πιο κοντά σε βιολογικές προσεγγίσεις.

Self-organizing maps:

Ανάμεσα σε διάφορες αρχιτεκτονικές των νευρωνικών δικτύων και αλγόριθμους εκπαίδευσης, ο χάρτης αυτό-οργάνωσης του Kohonen (*self-organizing map*) είναι ένα από τα πλέον δημοφιλή μοντέλα αυτών των δικτύων [28]. Είναι ένας αλγόριθμος μάθησης χωρίς επιτήρηση, με απλή δομή και υπολογιστική μορφή, επηρεασμένος από την συσχέτιση αμφιβληστροειδούς-φλοιού εγκεφάλου. Η αποτύπωση και η ανάλυση της χαρτογράφησης είναι σημαντικές για την κατανόηση του τρόπου με τον οποίο ο εγκέφαλος αντιλαμβάνεται, αναγνωρίζει, κωδικοποιεί και επεξεργάζεται τα πρότυπα που δέχεται και επομένως, χρησιμεύει στην εφαρμογή μέσω υπολογιστή. Η αυτο-οργάνωση αποτελεί μία θεμελιώδη διαδικασία αναγνώρισης προτύπων στην οποία οι εσωτερικές διαδικασίες, ανάμεσα στα ερεθίσματα και τις αποκρίσεις, αναδεικνύονται χωρίς την ύπαρξη ενδεχόμενης μεροληπτικής ή υποκειμενικής εξωτερικής επιρροής. Τα δίκτυα SOM μπορούν να παρέχουν αναλλοίωτο τον τοπολογικό χάρτη μεταξύ εισόδου και εξόδου.

Η αυτό-οργάνωση συχνά περιλαμβάνει τόσο ανταγωνισμό όσο και σχετιζόμενη μάθηση. Με την εμφάνιση ενός ερεθίσματος, οι νευρώνες ανταγωνίζονται μεταξύ τους για την κατοχή ή ιδιοκτησία αυτού. Οι νικητές νευρώνες ενισχύουν τότε τα βάρη τους ή τη σχέση τους με το συγκεκριμένο ερέθισμα. Η “*εκμάθηση κατά Hebb*” είναι ο πιο διαδεδομένος τρόπος εκμάθησης σε αυτά τα δίκτυα [7]. Ο Kohonen (1982) αναθεώρησε τις αρχές και τη λειτουργία των δικτύων SOM και πρότεινε έναν πιο απλουστευμένο μηχανισμό μάθησης, ο οποίος ενσωματώνει έξυπνα την “*εκμάθηση κατά Hebb*” μαζί με κανόνες πλευρικών διασυνδέσεων και μπορεί να προσομοιώσει το αυτο-οργανωτικό μαθησιακό αποτέλεσμα [28]. Αν και ο αλγόριθμος που προκύπτει, με τον ένα ή τον άλλο τρόπο, λειτουργεί εξερευνητικά (*heuristic*), είναι ένα απλουστευμένο και γενικευμένο μοντέλο της διαδικασίας αυτο-οργάνωσης [29]. Τα δίκτυα SOM χρησιμοποιούν ένα σύνολο νευρώνων, συνήθως δισδιάστατα διατεταγμένο σε ορθογώνιο ή εξαγωνικό πλέγμα, για να σχηματίσει μία διακριτή, τοπολογική χαρτογράφηση ενός διανύσματος εισόδου $X \in \mathbb{R}^n$ που είναι ο

χάρτης (Σχήμα 20). Κάθε τιμή του διανύσματος εισόδου συνδέεται με έναν κόμβο στο χάρτη. Η εκπαίδευση καθιστά τον χάρτη αυστηρά προσδιορισμένο, δηλαδή κάθε περιοχή



Σχήμα 20: Το μοντέλο του Kohonen (*self-organizing map*)

στο χάρτη έχει ορισμένο χώρο στο επίπεδο και συγκεκριμένη αξία. Οι εσωτερικές συνδέσεις διέγερσης και καταστολής μεταξύ των κόμβων είναι εικονικές, συμμετέχουν όμως στη διαδικασία εκμάθησης καθώς ακολουθούν έναν μαθηματικό μετασχηματισμό τοπικής ανταλλαγής.


Τα δίκτυα SOM προορίζονται για να προσομοιώσουν ένα πολύ συγκεκριμένο υποσύνολο των αρχών που έχουν εμπνευσθεί από τις παρατηρήσεις της διαδικασίας οργάνωσης του ανθρώπινου εγκεφάλου. Κάποιοι μπορεί να φανταστούν τα δίκτυα αυτά ως δομές που απεικονίζουν πραγματική βιολογική συμπεριφορά, συμπεριλαμβανομένων των συνάψεων, των νευρώνων, των βιοχημικών αλληλεπιδράσεων και άλλων. Αυτή σκέψη όμως απέχει από την πραγματικότητα [30]. Δεν μπορούν να προσομοιώσουν τις περίπλοκες, παράλληλες εργασίες του ανθρώπινου νευρικού συστήματος, αλλά αποσκοπούν στην αναπαραγωγή μίας παρατηρούμενης βασικής συμπεριφοράς και, για το λόγο αυτό, αναδεικνύονται σε πολύ ισχυρά εργαλεία. Η βασική αρχή που προσπαθούν μιμηθούν αυτά τα δίκτυα είναι η χαρτογράφηση δεδομένων μεγάλης κλίμακας σε ένα μοντέλο μικρότερης κλίμακας με τοπολογική συμπεριφορά. Με απλά λόγια, ομοειδή δεδομένα εισόδου να απεικονίζονται σε παρόμοιες εξόδους. Αυτό το χαρακτηριστικό καθιστά αυτά τα δίκτυα ιδιαίτερα χρήσιμα για εργασίες απεικόνισης πολύπλοκων δομών που δύσκολα αναγνωρίζονται από άλλες προσπάθειες.

Ένα μέρος του ανθρώπινου εγκεφάλου, ο οπτικός φλοιός, είναι ένα παράδειγμα που περιγράφει τις αρχές οργάνωσης των SOM. Το οπτικό πεδίο, όπως αυτό γίνεται αντιληπτό από τα αισθητήρια κύτταρα στο ανθρώπινο μάτι, απεικονίζεται στον οπτικό φλοιό και χαρτογραφείται έτσι ώστε συνεχείς περιοχές στην όραση να εμφανιστούν επίσης συνεχόμενες στην έξοδο ενός νευρωνικού δικτύου [31]. Έτσι, παρόμοιες περιοχές στο πεδίο εισόδου του ματιού χαρτογραφούνται σε παρόμοιες περιοχές στο χώρο εξόδου του εγκεφάλου. Αποθηκεύοντας και επεξεργάζοντας οπτικές πληροφορίες μεγάλου όγκου δεδομένων στον οπτικό φλοιό, ο εγκέφαλος θα πρέπει να τα κατηγοριοποιήσει σαφώς στην νευρολογική τοπολογία του. Ακόμη περισσότερο, τα τμήματα της εικόνας τα οποία είναι πιο σημαντικά για την αναγνώρισή της (κεντρικά μέρη), τοποθετούνται σε σχετικά μεγάλες περιοχές στο χάρτη, ακόμη και αν αποτελούν μικρές περιοχές ολόκληρου του οπτικού πεδίου. Συνεπώς, η πυκνότητα της πληροφορίας είναι ανόμοια και καθορίζεται από την σημαντικότητά της.

Ένας χάρτης αυτο-οργάνωσης αποτελείται από δύο δομικά στοιχεία: έναν αριθμό κόμβων με τέτοια δομή που να αντιπροσωπεύει το πραγματικό περιεχόμενο του χάρτη και αλγόριθμους που ισχύουν σε αυτούς τους κόμβους. Η εφαρμογή των αλγορίθμων στο σύνολο των κόμβων αποτελεί την ουσιαστική διαδικασία οργάνωσης, καθώς τροποποιούνται οι κόμβοι ανάλογα με τα διανύσματα εισόδου και έτσι η οργάνωση προσεγγίζει την έννοια της μάθησης με βιολογικούς όρους. Βασικές αρχές στην κατασκευή δικτύων αυτο-οργάνωσης είναι ο καθορισμός βασικών, λειτουργικών παραμέτρων, η αρχικοποίηση του συνόλου των κόμβων και η εφαρμογή των αλγορίθμων. Το αποτέλεσμα οποιασδήποτε τέτοιας διαδικασίας είναι ακριβώς το σύνολο των κόμβων του που αντιπροσωπεύει την τελική κατάσταση του δικτύου, γι' αυτό και αναφέρεται ως σύνολο κόμβων εξόδου. Στην αρχική μορφή κάθε SOM, το σύνολο των κόμβων εξόδου βρίσκεται σε κατάσταση αναμονής και απαιτείται επιπλέον επεξεργασία για την εξαγωγή περεταίρω πληροφοριών. Σε αντίθεση με τα νευρωνικά δίκτυα που εκτελούν μάθηση με επιτήρηση, τα δίκτυα αυτο-οργάνωσης σε χάρτη μπορούν να μαθαίνουν και χωρίς επιτήρηση.

Το σύνολο των κόμβων εξόδου απεικονίζεται στο χάρτη και αντιπροσωπεύει την εσωτερική του κατάσταση. Οι κόμβοι στο χάρτη έχουν δύο χαρακτηριστικά: μία σταθερή θέση και μεταβλητό βάρος. Η θέση αναφέρεται στην τοπολογική θέση πάνω στο χάρτη ενώ το βάρος περιέχει τον πραγματικό όγκο πληροφοριών που σχετίζεται με τον κόμβο. Χρησιμοποιώντας βιολογικούς όρους, ο χάρτης αντιστοιχεί σε ένα δίκτυο μνήμης

αποτελούμενο από νευρώνες (Σχήμα 21). Να σημειώσουμε εδώ ότι το σύνολο των κόμβων και ο χάρτης είναι διαφορετικές αναπαραστάσεις ενός δικτύου αυτο-οργάνωσης και, ανάλογα με το σχεδιαστικό πλαίσιο, είναι βολικό οι κόμβοι να αντιμετωπίζονται ως ομάδες



Σχήμα 21: Κόμβοι με τα βάρη τους και η απεικόνισή τους στο χάρτη

του “κόμβου εξόδου” που έχουν οριστεί με μαθηματικό τρόπο ή ως δομές με βάση τη θέση τους στο χάρτη. Για λόγους ευκολίας, είναι καταλληλότερη η απεικόνιση σε χάρτη έτσι ώστε να μπορεί οποιοσδήποτε να καταλάβει την τοπολογική διάταξη του δικτύου.

Τα δίκτυα αυτο-οργάνωσης σε χάρτη μπορούν να αποτελέσουν πολύτιμα εργαλεία για ένα ευρύ φάσμα εφαρμογών, που επωφελούνται από την ταξινόμηση των δεδομένων εισόδου κατά βαθμό ομοιότητας. Η βασική τους δομή επιτρέπει την είσοδο σχεδόν κάθε είδους δεδομένων, με την προϋπόθεση της ύπαρξης κάποιας παραμέτρου και η ικανότητά τους να εκπαιδεύονται χωρίς εποπτεία τους επιτρέπει να υιοθετούν πρωτοεμφανιζόμενα πρότυπα. Τα πλεονεκτήματα αυτά καθιστούν τα δίκτυα SOM δημοφιλείς επιλογές για εργασίες ομαδοποίησης δεδομένων (*clustering*) [32], συμπίεσης εικόνας (*image compression*) [33], χρωματικής ανάλυσης εικόνων (*image color quantization*) [34] ή ακόμα οργάνωσης συλλογών κειμένων εγγράφων [35].

ΜΕΡΟΣ ΔΕΥΤΕΡΟ:
ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΕΦΑΡΜΟΓΕΣ ΣΤΗΝ ΙΑΤΡΙΚΗ

8. ΕΙΣΑΓΩΓΗ

Τα τελευταία χρόνια, τα τεχνητά νευρωνικά δίκτυα (ΤΝΔ) έχουν γίνει δημοφιλές και χρήσιμο μοντέλο στην αντιμετώπιση προβλημάτων ταξινόμησης (*classification*), ομαδοποίησης (*clustering*), αναγνώρισης προτύπων (*pattern recognition*) και πρόβλεψης (*prediction*) σε πολλούς κλάδους. Είναι ένας τύπος μοντέλου για την εκμάθηση μηχανών (*machine learning*) και έχει γίνει σχετικά ανταγωνιστικός με τα συμβατικά μοντέλα στατιστικής όσον αφορά τη χρησιμότητα [36]. Η τεχνητή νοημοσύνη μαζί με την ασφάλεια της πληροφορίας, το Internet, την αποθήκευση και διαχείριση τεράστιου όγκου δεδομένων και τις επιστήμες υγείας αποτελούν σημεία ενδιαφέροντος της επιστήμης της πληροφορικής και των επικοινωνιών. Οι εφαρμογές των τεχνητών νευρωνικών δικτύων μπορούν να αξιολογηθούν σε σχέση με παράγοντες της ανάλυσης δεδομένων όπως η ακρίβεια, η ταχύτητα επεξεργασίας, η καθυστέρηση, οι επιδόσεις, η ανοχή στα σφάλματα, το μέγεθος, η δυνατότητα επέκτασης και η σύγκλιση [37, 38]. Το κύριο προσόν τους είναι η μεγάλη ταχύτητα επεξεργασίας που παρέχεται σε συμπαγή, παράλληλη εφαρμογή και αυτό έχει αυξήσει την ανάγκη για έρευνα στον τομέα αυτό [39]. Μπορούν να αναπτυχθούν και να χρησιμοποιηθούν για αναγνώριση εικόνων και επεξεργασία της φυσικής ομιλίας. Στις μέρες μας, χρησιμοποιούνται κυρίως για τη βελτίωση των συναρτήσεων σε αριθμητικά παραδείγματα λόγω των εξαιρετικών ιδιοτήτων στην αυτοεκπαίδευση, στην προσαρμοστικότητα, στην ανοχή στα σφάλματα, στη μη γραμμικότητα και στην απεικόνιση σε χάρτη [40].

Παράγοντες της ανάλυσης δεδομένων δίνουν τους λόγους για τους οποίους τα τεχνητά νευρωνικά δίκτυα είναι αποτελεσματικά, αποδοτικά και παρέχουν υψηλή δυνατότητα στην αντιμετώπιση, πολυσύνθετων και μη, προβλημάτων σε πολλούς τομείς της ζωής. Έτσι, χρησιμοποιούνται στην αντιμετώπιση προβλημάτων στη γεωργία, στην ιατρική, στην εκπαίδευση, στα οικονομικά, στο εμπόριο, στη διοίκηση, στην ασφάλεια, στη μηχανική και στις τέχνες. Επίσης, σε θέματα στον τομέα της μεταποίησης, των μεταφορών, της ασφάλειας πληροφοριακών συστημάτων, τραπεζικής, ασφάλισης, διαχείρισης ακινήτων, ενέργειας, διαφήμισης καθώς και σε εκείνους τους τομείς που δεν μπορούν να βρεθούν λύσεις με παραδοσιακές υπολογιστικές μεθόδους και συμβατικά μαθηματικά. Εκτός από το μεγάλο εύρος εφαρμογών, υπάρχει μεγάλη ανάγκη στην αντιμετώπιση του προβλήματος της υιοθέτησης μίας συστηματικής προσέγγισης στην ανάπτυξη των ΤΝΔ για τη βελτίωση της απόδοσής τους. Για παράδειγμα, μία προσέγγιση για την αντιμετώπιση της επιλογής των συνόλων δεδομένων (μέγεθος, όγκος, μικρό, μεγάλο και άλλα), την ακρίβειά

τους, τη δομή τους, το είδος τους, την κατανομή τους, την εγκυρότητά τους και των τεχνικών επεξεργασίας τους.

Άλλες βασικές προκλήσεις ή ζητήματα που έχουν ενδιαφέρον και χρειάζονται επιπλέον διερεύνηση κατά τον σχεδιασμό των ΤΝΔ, περιλαμβάνουν αναπτυξιακές τεχνικές που μπορούν να βελτιώσουν τη δημιουργία στιβαρών μοντέλων, με ξεκάθαρα πρότυπα που να προσφέρουν χρήσιμη γνώση κατά την εκπαίδευσή τους. Πολλές είναι οι προκλήσεις στη βελτίωση της ικανότητας υπολογισμού των σχέσεων μεταξύ μεταβλητών, με επέκταση της γνώσης σε άγνωστους χώρους με αβεβαιότητα και υψηλό ρίσκο. Επιπλέον, υπάρχει το πρόβλημα του προσδιορισμού και της ανάλυσης των δεδομένων λόγω της ύπαρξης άχρηστων παραμέτρων. Επίσης, η ανάγκη διευθέτησης του ορίου σφαλμάτων με τη βοήθεια ποσοτικού προσδιορισμού των μεταβλητών και η χρονοβόρα, σε κάποιες περιπτώσεις, σύγκλιση όπου εφαρμόζεται η μάθηση με επιτήρηση.

Ένα από τα μεγαλύτερα πλεονεκτήματα των τεχνητών νευρωνικών δικτύων είναι η ικανότητά τους να μαθαίνουν από το περιβάλλον. Η ικανότητα αυτή είναι χρήσιμη σε εφαρμογές όπου η πολυπλοκότητα του περιβάλλοντος (ερεθίσματα και διεργασίες) καθιστά μη πρακτικές τις υλοποιήσεις άλλων τύπων λύσεων. Έτσι, μπορούν να χρησιμοποιηθούν σε πλήθος εφαρμογών. Η επιλογή της βέλτιστης τοπολογίας του νευρωνικού δικτύου εξαρτάται από το είδος της εφαρμογής και την αναπαράσταση των δεδομένων ενός συγκεκριμένου προβλήματος. Για την επιλογή και κατ' επέκταση για τη χρήση των ΤΝΔ, θα πρέπει να υπάρχει εξοικείωση με τις αρχιτεκτονικές και τους αλγορίθμους εκπαίδευσης. Η πολυπλοκότητα του επιλεγμένου μοντέλου είναι καθοριστική. Η χρήση ενός απλουστευμένου μοντέλου για συγκεκριμένη εργασία συνήθως οδηγεί σε ελλιπή ή εσφαλμένα αποτελέσματα ενώ αντίθετα, ένα περίπλοκο μοντέλο μπορεί να οδηγήσει σε λάθη κατά την διαδικασία της εκπαίδευσης. Περίπλοκο μοντέλο εφαρμοσμένο σε απλή εργασία καταλήγει σε απομνημόνευση και όχι σε μάθηση. Υπάρχει ένας μεγάλος αριθμός αλγορίθμων εκπαίδευσης με συσχετίσεις μεταξύ τους και σχεδόν όλοι είναι κατάλληλοι για κάθε τύπου μοντέλο δικτύου. Η εμπειρία μαζί με την γνώση είναι απαραίτητα προσόντα για την επιλογή του κατάλληλου αλγόριθμου σε μία συγκεκριμένη εργασία. Όταν ο σχεδιασμός του δικτύου μαζί με τον αλγόριθμο εκπαίδευσης έχουν επιλεγεί σωστά, το αποτέλεσμα θα είναι ένα ισχυρό εργαλείο για την επίλυση συγκεκριμένων προβλημάτων.

9. ΕΦΑΡΜΟΓΕΣ ΤΩΝ ΤΕΧΝΗΤΩΝ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Οι περιοχές εφαρμογής των τεχνητών νευρωνικών δικτύων μπορούν να χωριστούν στις παρακάτω κατηγορίες:

Ταξινόμηση και διάγνωση:

Η ταξινόμηση (*classification*) είναι η διαδικασία πρόβλεψης της κατηγορίας/κλάσης (*class*) ενός δοθέντος συνόλου δεδομένων. Οι κατηγορίες μερικές φορές αναφέρονται και ως *ετικέτες*. Τα τεχνητά νευρωνικά δίκτυα έχουν εφαρμοστεί στους τομείς της διάγνωσης στην ιατρική, στη μηχανική και στις κατασκευές, με σκοπό την ακριβή συσχέτιση μεταξύ των προτύπων εισόδου που αντιπροσωπεύουν κάποιες μορφές μη φυσιολογικής συμπεριφοράς, με την αντίστοιχη ασθένεια ή τύπο του σφάλματος. Η διάγνωση (*diagnosis*) μπορεί να οριστεί ως ο προσδιορισμός της αιτίας ή της φύσης μιας ασθένειας με αξιολόγηση των σημάδιων, των συμπτωμάτων και των αποτελεσμάτων εξετάσεων σε ένα συγκεκριμένο ασθενή [41].

Τα κριτήρια ταξινόμησης είναι τυποποιημένοι ορισμοί οι οποίοι αποσκοπούν πρωτίστως στη δημιουργία καλά καθορισμένων και σχετικά ομογενών ομάδων για κλινική έρευνα. Δεν στοχεύουν να συμπεριλάβουν το σύνολο των πιθανών ασθενών αλλά την πλειοψηφία αυτών που έχουν κοινά βασικά χαρακτηριστικά μίας κατάστασης. Συνεπώς, ο στόχος της ταξινόμησης διαφέρει από εκείνον της διάγνωσης. Τα επικυρωμένα κριτήρια ταξινόμησης θεωρούνται κρίσιμα για την ερμηνεία των ευρημάτων της μελέτης και των συγκρίσεων των αποτελεσμάτων μεταξύ των μελετών. Παρά τη διευκόλυνση της σύγκρισης των αποτελεσμάτων κάθε μελέτης, τα κριτήρια ταξινόμησης έχουν τη δυνατότητα να περιορίζουν την εξωτερική εγκυρότητα των μελετών, καθώς οι παρεμβάσεις μπορούν να εκτελούνται διαφορετικά στους συμμετέχοντες στη μελέτη, που πληρούν τα κριτήρια ταξινόμησης μίας νόσου, σε σχέση με ένα μεγαλύτερο σύνολο ατόμων που έχουν διαγνωσθεί με την ίδια νόσο. Με άλλα λόγια, εκείνα που μοιράζονται μόνο μερικές και όχι κάποιες άλλες εκδηλώσεις της ασθένειας που λαμβάνονται υπόψη στα κριτήρια ταξινόμησης.

Τα κριτήρια διάγνωσης είναι ένα σύνολο σημάδιων, συμπτωμάτων και εξετάσεων που χρησιμοποιούνται στη συνήθη, καθημερινή κλινική περίθαλψη και καθοδηγούν τη φροντίδα σε μεμονωμένους ασθενείς. Είναι γενικά ευρέως διαδεδομένα και πρέπει να αντανακλούν τα διαφορετικά χαρακτηριστικά μίας νόσου, με στόχο να εντοπιστούν με ακρίβεια όσο το δυνατόν περισσότεροι άνθρωποι που τα εμφανίζουν. Λόγω αυτής της πολυπλοκότητας, η ανάπτυξη και η επικύρωση διαγνωστικών κριτηρίων αποτελεί

πρόκληση. Στη ρευματολογία για παράδειγμα, υπάρχουν πολύ λίγα πιστοποιημένα διαγνωστικά κριτήρια και οι κλινικοί ιατροί συνήθως καθορίζουν μία διάγνωση βασισμένη στον υποκειμενικό συνδυασμό κλινικών συμπτωμάτων και αποτελεσμάτων εξετάσεων, καθώς επίσης και στην εμπειρία διαχείρισης της επιδημιολογίας της γεωγραφικής περιοχής [41].

Ενώ τα κριτήρια διάγνωσης μπορεί να διαφέρουν από τα κριτήρια ταξινόμησης, τουλάχιστον για τον επιδιωκόμενο σκοπό τους, στην πραγματικότητα αντιπροσωπεύουν τα δύο άκρα της ίδιας “συνέχειας”. Η απόσταση μεταξύ των διαγνωστικών κριτηρίων και των κριτηρίων ταξινόμησης σε αυτή τη “συνέχεια” εξαρτάται από διάφορους παράγοντες, περιλαμβάνει όμως την ταυτότητα της νόσου, τη γεωγραφική περιοχή και κάποιους ακόμη παράγοντες. Όπου η αιτιολογία της νόσου είναι καλά ορισμένη, όπως στην αρθρίτιδα και στη νόσο του Lyme, τα κριτήρια διάγνωσης και ταξινόμησης μπορεί να είναι παρόμοια και να χρησιμοποιούνται εναλλακτικά. Εάν αποδειχθεί επαρκής εσωτερική και εξωτερική εγκυρότητα για τη διάγνωση σε συγκεκριμένο πληθυσμό, τα κριτήρια ταξινόμησης μπορεί να είναι και διαγνωστικά. Θεωρητικά, μία διάγνωση εφαρμόζει κριτήρια ταξινόμησης σε έναν μεμονωμένο ασθενή [42]. Επομένως, όταν τα κριτήρια ταξινόμησης έχουν άριστη ευαισθησία (sensitivity) και ακρίβεια (specificity) (κοντά στο 100%), τα κριτήρια ταξινόμησης είναι ταυτόσημα με αυτά της διάγνωσης και μπορούν να προσδιορίζουν σωστά κάθε μεμονωμένη περίπτωση [43]. Ωστόσο, επειδή τα χαρακτηριστικά μίας συγκεκριμένης νόσου δεν είναι τυπικά πανομοιότυπα μεταξύ των ασθενών που την εμφανίζουν, τα κριτήρια ταξινόμησης δεν είναι 100% ακριβή, αφήνοντας ένα ποσοστό ασθενών εσφαλμένα ταξινομημένο. Εξαιτίας αυτής της πιθανότητας, δεν ισοδυναμούν με διάγνωση. Μόνο οι γιατροί που εξετάζουν τα χαρακτηριστικά συγκεκριμένου ασθενούς, πέραν εκείνων που αντιπροσωπεύονται στα κριτήρια ταξινόμησης, και επιπρόσθετων εξωγενών παραγόντων (κοινές τοπικές συνθήκες με διαφορετική διάγνωση), μπορούν να αποδείξουν μία διάγνωση για μεμονωμένο ασθενή.

Τα μοντέλα διαγνωστικής ταξινόμησης (ΜΔΤ) συνήθως προωθούνται από αναλυτές ως σημαντικές εναλλακτικές μέθοδοι για την επεξεργασία δεδομένων απόκρισης σε καταστάσεις όπου πολυπαραγοντικές ταξινομήσεις των ερωτηθέντων γίνονται με βάση πολλαπλές πιθανές υποκείμενες ικανότητες. Επισημαίνεται ότι τα μοντέλα αυτά μπορούν να εφαρμοστούν και σε περιπτώσεις εκτός εκπαιδευτικών σκοπών επειδή η εκτίμηση που παρέχουν δεν απαιτεί να αιτιολογείται η ύπαρξη μη προφανών μεταβλητών. Για παράδειγμα, μπορούν να παρέχουν πολυδιάστατες ταξινομήσεις των ερωτηθέντων με βάση

συμπεριφορικές διαθέσεις στην κλινική ψυχολογία [44]. Σε γενικό επίπεδο, είναι κατάλληλα σε περιπτώσεις όπου ζητούνται στατιστικά καθοδηγούμενες ταξινομήσεις ερωτηθέντων με πολλαπλά υποκειμενικά χαρακτηριστικά.

Τα ΜΔΤ είναι πολυδιάστατα επιβεβαιωτικά μοντέλα που περιέχουν σαφείς, υποκείμενες μεταβλητές και δημιουργούν πολλαπλές κλάσεις. Αναπτύσσονται για να ταξινομήσουν τους ερωτηθέντες με βάση διακριτά δεδομένα απόκρισης από διαγνωστικές αξιολογήσεις. Παρά τη μεγάλη δυναμική τους, έχει παρατηρηθεί σποραδική εφαρμογή σε διάφορους κλάδους, γεγονός που οφείλεται εν μέρει στις αυστηρές απαιτήσεις των θεωριών απόκρισης, από την εφαρμοσμένη γνωστική ψυχολογία και τις σχετικές επιστήμες. Είναι επίσης αποτέλεσμα έλλειψης δεδομένων από κατάλληλα ερευνητικά σχέδια που ταιριάζουν με αυτές τις υποθέσεις, καθώς και έλλειψη αξιοσημείωτων πακέτων λογισμικού που είναι απαραίτητα για τη βαθμονόμηση τέτοιων δεδομένων [45].

Ο τομέας των ειδικών στις “μετρήσεις” με αντικείμενο τα μοντέλα διαγνωστικής ταξινόμησης, καλείται να αντιμετωπίσει την πολυπλοκότητα τους και την απαίτηση σε πόρους, με έναν σαφή και διακριτό τρόπο για τον καθένα που ενδιαφέρεται για το πεδίο αυτό. Είναι βασικό, οι ενασχολούμενοι ειδικοί να αναπτύξουν μία ρεαλιστική εικόνα της ισορροπίας μεταξύ των θεωρητικών δυνατοτήτων των μοντέλων και των πρακτικών περιορισμών που αφορούν την εφαρμογή τους, λαμβάνοντας ιδιαίτερα υπόψη ότι εναλλακτικές πολυδιάστατες διαβαθμίσεις, με μεγαλύτερες ερευνητικές βάσεις δεδομένων, είναι διαθέσιμες. Ο ενθουσιασμός τους, ενδέχεται να είναι κάπως συγκρατημένος, εξαιτίας των πραγματικών περιορισμών που έχει η ζωή και επηρεάζουν τις εφαρμογές πληροφορικής γενικότερα. Ταυτόχρονα, είναι πιθανό να δημιουργηθεί μία υγιή κατάσταση αισιοδοξίας, που μπορεί να βοηθήσει τους ειδικούς να συνειδητοποιήσουν τα πρόσθετα οφέλη που μπορεί να έχει μία διαμορφωμένη διαγνωστική εκτίμηση, προσεκτικά σχεδιασμένη και ρυθμισμένη από ένα μοντέλο διαγνωστικής ταξινόμησης. Δημιουργείται ελπίδα ότι μία τέτοια ισορροπημένη προοπτική θα οδηγήσει σε πιο εμπειριστατωμένες απεικονίσεις της πραγματικής αλλά και της δυνητικής ισχύος των ΜΔΤ, σε σχέση με εναλλακτικές λύσεις [45].

Αναγνώριση μοτίβων:

Ως “μοτίβο” μπορεί να οριστεί η ποσοτική ή δομική περιγραφή ενός αντικειμένου ή οποιασδήποτε οντότητας, όχι απαραίτητα ορατής, ακόμη και ενός συνόλου δεδομένων. Κατά συνέπεια, ένα μοτίβο μπορεί να είναι ένα σύνολο από πρότυπα τα οποία μοιράζονται

κάποιες κοινές ιδιότητες. Έτσι, γίνεται δυνατή η διαφοροποίηση μεταξύ δομών διαφορετικών μοντέλων. Με αυτό τον τρόπο, δεν θα είχαμε καμία δυσκολία να αναγνωρίσουμε, για παράδειγμα, αλφαριθμητικούς χαρακτήρες, ακόμη και αν είναι γραμμένοι με διαφορετικές γραμματοσειρές και διαφορετικά μεγέθη. Μπορούμε επίσης, να διαφοροποιήσουμε τους άντρες από τις γυναίκες ή τους ανθρώπους που προέρχονται από το βόρειο ημισφαίριο με αυτούς που προέρχονται από το νότιο ή τα φορτηγά από τα επιβατικά αυτοκίνητα ακόμη και διαφορετικών κατασκευαστών. Αυτό οφείλεται στο γεγονός ότι η πρώτη ομάδα ορίζεται ως διαφορετική κατηγορία προτύπων από τη δεύτερη για το συγκεκριμένο πρόβλημα [46].

Η αναγνώριση μοτίβων είναι μία διαδικασία κατηγοριοποίησης δειγμάτων από μετρήσεις ή από παρατηρήσεις, ως μέλος μίας από τις διάφορες κλάσεις ή κατηγορίες. Λόγω του γεγονότος ότι αποτελεί βασική ιδιότητα των ανθρώπων αλλά και άλλων ζωντανών οργανισμών, θεωρείται δεδομένη λειτουργικότητα. Αναμένεται τώρα να ανακαλυφθεί ο μηχανισμός της αναγνώρισης, να προσομοιωθεί και να εφαρμοστεί, με τη βοήθεια της σύγχρονης τεχνολογίας, στους ανθρώπους. Η έρευνα επικεντρώνεται στον τρόπο ανάκτησης της πληροφορίας από τα ανθρώπινα αισθητήρια όργανα, στην επεξεργασία των πληροφοριών αυτών και στον τρόπο λήψης αποφάσεων από τον εγκέφαλο. Η αναγνώριση μοτίβων είναι μία διακλάδωση της τεχνητής νοημοσύνης και αποτελεί διεπιστημονικό θέμα καθώς εμπλέκονται επιστήμονες και μηχανικοί διάφορων κλάδων. Πολλοί επιστήμονες εφαρμόζουν αυτή την τεχνολογία για την επίλυση προβλημάτων στα αντίστοιχα πεδία, όπως στην αρχαιολογία, στην αστρονομία, στην αεροπορία, στη χημεία, στην άμυνα/κατασκοπία, στη διαχείριση των φυσικών πόρων, στην εγκληματολογία, στη γεωγραφία, στην ιατρική, στη γεωλογία, στη μετεωρολογία, την ωκεανογραφία και άλλες. Ψυχολόγοι, φυσιολόγοι, βιολόγοι και νευροφυσιολόγοι επικεντρώνουν την προσπάθειά τους στην διερεύνηση πώς τα έμβια όντα αντιλαμβάνονται τα αντικείμενα. Ηλεκτρολόγοι μηχανικοί και μηχανικοί ηλεκτρονικών υπολογιστών, μαζί με μαθηματικούς των εφαρμοσμένων μαθηματικών, αφιερώνονται στην ανάπτυξη θεωριών και τεχνικών για την υλοποίηση ενός συγκεκριμένου έργου αναγνώρισης με τη χρήση υπολογιστή [46].

Η τεχνική της αναγνώρισης προτύπων είναι εφαρμόσιμη όταν (α) έχει αποτύχει η φυσιολογική ανάλυση, (β) η δημιουργία στιβαρού και αξιόπιστου μοντέλου είναι ανεπαρκής και (γ) η προσομοίωση είναι αναποτελεσματική. Υπό αυτές τις συνθήκες, η τεχνική αναγνώρισης προτύπων δείχνει χρήσιμη και σημαντική εναλλακτική λύση. Υπάρχουν δύο τύποι στοιχείων στα οποία μπορεί να εφαρμοστεί η αναγνώριση προτύπων: 1. *Συμπαγή*

στοιχεία. Αυτού του είδους τα στοιχεία απεικονίζονται και ερμηνεύονται ευκολότερα. Δύο υποκατηγορίες αυτών είναι τα αντικείμενα που καταλαμβάνουν χώρο και αυτά που εκτείνονται στο χρόνο, έχουν δηλαδή διάρκεια. Παραδείγματα αντικειμένων που καταλαμβάνουν χώρο είναι σκηνές, εικόνες, σύμβολα (π.χ. σύμβολα κυκλοφορίας), χαρακτήρες (π.χ. αλφαριθμητικοί, αλφάβητα διάφορων χωρών), οδικοί χάρτες, χάρτες εξέλιξης καιρικών φαινομένων, και άλλα. Παραδείγματα αντικειμένων που εκτείνονται στο χρόνο είναι η κυματομορφή της ομιλίας σε πραγματικό χρόνο, το ηλεκτροκαρδιογράφημα καθώς και κάθε άλλη κυματομορφή στο χρόνο. Κάποια από αυτά είναι μονοδιάστατα όπως η κυματομορφή της ομιλίας, το ηλεκτροκαρδιογράφημα, το ηλεκτροεγκεφαλογράφημα, τα σεισμικά κύματα, και άλλα. Κάποια είναι δύο διαστάσεων όπως οι χάρτες, τα σύμβολα, οι εικόνες, απεικονίσεις με ακτίνες Χ, εικόνες από τομογράφο, και άλλα. Υπάρχουν και αντικείμενα τριών διαστάσεων. 2. *Αφηρημένα (εννοιολογικά) αντικείμενα*. Παραδείγματα είναι ιδέες, επιχειρήματα, κλπ. Ο τρόπος γραφής με τον οποίο μπορούμε, για παράδειγμα, να ξεχωρίσουμε ένα διήγημα από ένα ποίημα. Ή ακόμη, μπορούμε να διακρίνουμε κάποιο συγγραφέα από έναν άλλο από το πώς γράφουνε. Η γραφή αποτελεί ένα είδος μοτίβου. Το ίδιο μπορεί να συμβεί με τη μουσική και τους δημιουργούς της. Ο ρυθμός είναι επίσης ένα είδος μοτίβου. Ωστόσο, η αναγνώριση μοτίβων όπως τα παραπάνω (αναφέρεται ως εννοιολογική αναγνώριση) ανήκει σε άλλο κλάδο της τεχνητής νοημοσύνης [46].

Τα τεχνητά νευρωνικά δίκτυα εφαρμόζονται επιτυχώς στην αναγνώριση περίπλοκων μοτίβων όπως στην ομιλία, στη γραφή και σε ένα πλήθος εφαρμογών στην επεξεργασία εικόνας. Με δεδομένη την ικανότητα τους να διαχειρίζονται μεγάλο αριθμό δεδομένων εισόδου, να τα επεξεργάζονται και να αναπτύσσουν κρυμμένες, μη γραμμικές και περίπλοκες σχέσεις, διαδραματίζουν σημαντικό ρόλο στην αναγνώριση εικόνας και χαρακτήρων. Η αναγνώριση χαρακτήρων όπως η χειρόγραφη, έχει πολλές εφαρμογές στην ανίχνευση απάτης, ιδίως οικονομικής, καθώς και σε εκτιμήσεις που αφορούν την εθνική ασφάλεια. Η αναγνώριση εικόνων είναι ένα συνεχώς αναπτυσσόμενο πεδίο με μεγάλο εύρος εφαρμογών, από την αναγνώριση προσώπων στα μέσα κοινωνικής δικτύωσης, την εξέλιξη του καρκίνου στην ιατρική έως την επεξεργασία δορυφορικών εικόνων για χρήση στη γεωργία ή στην άμυνα. Η έρευνα στα ΤΝΔ έχει προχωρήσει σημαντικά με τη βελτίωση των μεθόδων μάθησης και έχει σημειωθεί πρόοδος στον τομέα της ηλεκτρονικής όρασης, στην αναγνώριση και επεξεργασία της φυσικής ομιλίας, με πρόσφατα παραδείγματα τα αυτοκινούμενα οχήματα χωρίς οδηγό.

Μοντελοποίηση:

Ένα νευρωνικό δίκτυο είναι ένα ισχυρό εργαλείο μοντελοποίησης με την ικανότητα να συλλαμβάνει και να απεικονίζει πολυσύνθετες σχέσεις δεδομένων εισόδου/εξόδου. Η πραγματική ισχύς και το πλεονέκτημά τους έγκειται στην ικανότητά τους να αναπαριστούν τόσο γραμμικές όσο και μη γραμμικές σχέσεις, καθώς και στο γεγονός πως μαθαίνουν τις σχέσεις αυτές από τα ίδια δεδομένα που συμμετέχουν στη μοντελοποίηση. Ο σκοπός του νευρωνικού δικτύου είναι να δημιουργήσει ένα μοντέλο που να απεικονίζει σωστά την είσοδο με την έξοδο, χρησιμοποιώντας γνωστά δεδομένα, έτσι ώστε το μοντέλο να μπορεί στη συνέχεια να χρησιμοποιηθεί για την παραγωγή της εξόδου όταν η επιθυμητή έξοδος είναι άγνωστη.

Η χρήση τεχνικών μοντελοποίησης με τη χρήση υπολογιστών είναι εκτεταμένη στην επιστημονική έρευνα. Τα τεχνητά νευρωνικά δίκτυα έχουν πλέον εδραιωθεί στη βιβλιογραφία κάθε φορά που εμπλέκονται υπολογιστικές προσεγγίσεις. Τα υλικά που έχει στη διάθεσή της η επιστημονική κοινότητα μαζί με την μηχανική έρευνα, συνεχίζει να επωφελείται από τις νέες εξελίξεις στους τομείς αυτούς, με διαφορετικές εφαρμογές που αναδύονται τακτικά, σε συνδυασμό με το βαθμό εξειδίκευσης που απαιτείται. Ωστόσο, με αυτή την αυξανόμενη χρήση υπάρχει δυστυχώς μία αναπτυσσόμενη τάση με κακή εφαρμογή των μεθοδολογιών γύρω από τα νευρωνικά δίκτυα, γεγονός που περιορίζει το δυνητικό τους όφελος. Κεντρικό στοιχείο του προβλήματος είναι η χρήση υπερβολικά περίπλοκων δικτύων τα οποία είναι συχνά ακαθόριστα από τα μαθηματικά και χρησιμοποιούν περιορισμένα δεδομένα για εκπαίδευση και δοκιμές [47].

Τα τεχνητά νευρωνικά δίκτυα εμπνεύστηκαν αρχικά από προσπάθειες που έγιναν ώστε να παρουσιαστούν απλά μοντέλα της εγκεφαλικής λειτουργίας και του τρόπου μάθησης [3]. Αν και αυτό εξακολουθεί να είναι η γραμμή της έρευνας, ένας σημαντικός και σε μεγάλο βαθμό ξεχωριστός κλάδος νευρωνικών υπολογισμών έχει αναπτυχθεί, ο οποίος ασχολείται κυρίως με την αξιοποίηση της κατανεμημένης επεξεργασίας με σκοπό τη δημιουργία μοντέλων πολυδιάστατων συνόλων δεδομένων. Καθώς η αναλογία με τον εγκέφαλο μπορεί να έχει ιστορική σημασία για τη σύλληψη τέτοιων νευρωνικών δικτύων, είναι αμφισβητήσιμο κατά πόσο η συσχέτιση αυτή συμβάλλει πραγματικά στην κατανόηση της τεχνικής σε περιβάλλον μοντελοποίησης δεδομένων. Ομοίως, αν και η παράλληλα κατανεμημένη επεξεργασία είναι μία κεντρική ιδέα, συχνά οι υπολογιστές στους οποίους υλοποιούνται τα νευρωνικά δίκτυα, δεν είναι παράλληλοι επεξεργαστές. Οι διαφορές μεταξύ του εγκεφάλου και των ΤΝΔ είναι τόσο σημαντικές ώστε πιθανόν να καθιστούν ευκολότερη την απευθείας εκμάθηση της φύσης αυτής της τεχνικής ανάλυσης δεδομένων,

παρά να γίνει προσπάθεια με τη βοήθεια του εγκεφάλου. Όποια προσπάθεια γίνεται ώστε να βρεθούν οι αναλογίες τέτοιας προοπτικής, εμφανίζει αντίστοιχες δυσαναλογίες. Αυτό δεν αποτελεί πρόβλημα όσο οι χρήστες της αναλογίας γνωρίζουν καλά το βαθμό στον οποίο εκτείνεται η αναλογία, δηλαδή μέχρι ποιο βαθμό υλοποιείται με όφελος. Από την άλλη πλευρά, υπάρχει πάντοτε ο κίνδυνος της παραπλάνησης από την κακή εκτίμηση των δυσαναλογιών. Στην περίπτωση του είδους του ΤΝΔ που μελετάμε, η χρησιμότητα της αναλογίας με τον εγκέφαλο είναι αμφίβολη λαμβάνοντας υπόψη τις τρέχουσες χρήσεις της τεχνικής αυτής [48].

Τόσο τα θεωρητικά επιστημονικά μοντέλα όσο και τα μοντέλα ανάλυσης δεδομένων χρησιμοποιούν μαθηματικές στρατηγικές για την εξεύρεση λύσεων. Ένα θεωρητικό επιστημονικό μοντέλο αναπτύσσεται χρησιμοποιώντας επιστημονικές θεωρίες και έννοιες και το οποίο εφαρμόζεται σε ένα συγκεκριμένο φαινόμενο. Ένα παράδειγμα είναι ένα μοντέλο για τη μεταβολή της θερμοκρασίας στην ατμόσφαιρα της Γης, όπου κάποιος θέλει να καθορίσει πως η θερμοκρασία στην ατμόσφαιρα μεταβάλλεται σε σχέση με την απόσταση από την Γη. Αυτό μπορεί να γίνει σε μεγάλο βαθμό, με βάση τις θεωρητικές υποθέσεις που προκύπτουν από τις θεωρίες της μεταφοράς της ακτινοβολίας, της θερμοδυναμικής και των ιδιοτήτων των αερίων. Ο πυρήνας του μοντέλου προέρχεται από αυτές τις υποθέσεις, λαμβάνοντας ενδεχομένως υπόψη ελάχιστα δεδομένα, τα οποία στη συνέχεια επιτρέπουν στο σχεδιαστή του μοντέλου να λύσει συγκεκριμένες εξισώσεις. Ανεξάρτητα από το μέγεθος των δεδομένων (πολλά ή λίγα), το ενδιαφέρον επικεντρώνεται στον καθορισμό των τιμών ορισμένων σημαντικών, με φυσική αξία παραμέτρων ή εκείνων των παραμέτρων που έχουν ως στόχο την καλύτερη κατανόηση της φυσικής και της χημείας της ατμόσφαιρας [48].

Τα υπολογιστικά μοντέλα ανάλυσης δεδομένων έχουν ως στόχο να προσομοιώσουν τη σχέση μεταξύ δύο χώρων, όπως για παράδειγμα τα αστρικά φάσματα με τις φυσικές συνθήκες που υπάρχουν μέσα στα αστέρια. Όπως ειπώθηκε και προηγουμένως, οι βέλτιστες τιμές ορισμένων παραμέτρων σε ένα μοντέλο (π.χ. τα βάρη σε ένα νευρωνικό δίκτυο) μπορούν να προσδιοριστούν από κάποια δεδομένα. Ωστόσο, το ενδιαφέρον εδώ δεν είναι ο ρητός προσδιορισμός των τιμών αυτών. Αντίθετα, το πρωταρχικό ενδιαφέρον είναι ο τρόπος εκπαίδευσης ενός μοντέλου ώστε να είναι εφικτές προγνώσεις, δηλαδή να μπορούμε να καθορίσουμε τις φυσικές συνθήκες σε κάποια άλλα αστέρια με βάση το φάσμα τους, χρησιμοποιώντας τη γνώση που απορρέει από τα δεδομένα εκπαίδευσης. Οι παράμετροι του μοντέλου είναι το εργαλείο (μέσον) προς το αποτέλεσμα και δεν χρειάζεται απαραίτητα να

έχουν φυσική σημασία. Αυτό οφείλεται στο γεγονός ότι αυτά τα μοντέλα σχεδιάζονται ανεξάρτητα από τις θεωρίες και τις έννοιες των διαφόρων προβλημάτων στα οποία μπορούν να εφαρμοστούν. Τα μοντέλα σχεδιάζονται επαρκώς γενικευμένα ώστε να μπορούν να εφαρμοστούν σε μία ευρεία κατηγορία προβλημάτων όπου θα πρέπει να πληρούνται γενικές απαιτήσεις. Συνεπώς, πέραν του στόχου που είναι η ακριβής πρόβλεψη, η επιστημονική γνώση που παρέχουν τα υπολογιστικά μοντέλα δεδομένων σε μία συγκεκριμένη περίπτωση, μπορεί να είναι περιορισμένη. Η φυσική κατανόηση των συγκεκριμένων πτυχών των φυσικών συνθηκών σε ένα άστρο που δίνουν ώθηση σε συγκεκριμένα σημεία του φάσματος είναι μεν χρήσιμη, αλλά δευτερεύουσα όταν ο βασικός στόχος είναι η ακριβής ταξινόμηση, ανεξάρτητα από το βαθμό πολυπλοκότητας στη σχεδίαση του μοντέλου (εντός εφικτών ορίων) [48].

Πρόγνωση και πρόβλεψη:

Ένας σημαντικός τομέας εφαρμογής των τεχνητών νευρωνικών δικτύων είναι η πρόγνωση (*forecasting*) [49]. Τα ΤΝΔ παρέχουν ένα ελκυστικό εναλλακτικό εργαλείο τόσο για τους ερευνητές όσο και για τους επαγγελματίες αναλυτές. Πολλά χαρακτηριστικά γνωρίσματα των ΤΝΔ τα καθιστούν εξαιρετικά εργαλεία σε προβλήματα πρόγνωσης. Σε αντίθεση με τις παραδοσιακές μεθόδους σχεδιασμού μοντέλων, τα ΤΝΔ είναι μέθοδοι αυτοπροσδιορισμού βασισμένες στα δεδομένα καθώς είναι ελάχιστες οι περιπτώσεις μοντέλων που ταιριάζουν σε όλα τα προβλήματα, ανεξάρτητα από τα δεδομένα. Μαθαίνουν από παραδείγματα και καταγράφουν λεπτές λειτουργικές σχέσεις μεταξύ των δεδομένων, ακόμη και αν οι υποκείμενες σχέσεις είναι άγνωστες ή απροσδιόριστες. Έτσι, τα ΤΝΔ είναι κατάλληλα για προβλήματα των οποίων οι λύσεις απαιτούν γνώσεις που είναι δύσκολο να προσδιοριστούν, αλλά για τις οποίες υπάρχουν επαρκή δεδομένα ή παρατηρήσεις. Μπορούν να αντιμετωπίζονται ως μία από τις πολυμεταβλητές, μη γραμμικές, μη παραμετρικές στατιστικές μεθόδους [50, 51, 52]. Αυτή η προσέγγιση μοντελοποίησης με την ικανότητα της μάθησης από παραδείγματα (εμπειρία), είναι πολύ χρήσιμη για πολλά πρακτικά προβλήματα καθώς είναι συνήθως πιο εύκολο να έχουμε δεδομένα παρά να έχουμε καλές θεωρητικές υποθέσεις σχετικά με τους υποκείμενους νόμους που διέπουν τα συστήματα από τα οποία προκύπτουν τα εκάστοτε δεδομένα. Το πρόβλημα με την προσέγγιση της μοντελοποίησης μέσω των δεδομένων είναι ότι οι υποβόσκοντες κανόνες δεν είναι πάντα εμφανείς και οι παρατηρήσεις συχνά καλύπτονται από θόρυβο. Παρ' όλα αυτά, παρέχει μία πρακτική και σε μερικές περιπτώσεις, το μόνο εφικτό τρόπο για την επίλυση πραγματικών προβλημάτων.

Η ιδέα της χρήσης των ΤΝΔ ως εργαλείο πρόγνωσης είναι αρκετά παλιά. Η πρώτη εφαρμογή έκανε την εμφάνισή της το 1964. Ο Hu (1964), στην διατριβή του, χρησιμοποιεί το προσαρμοστικό γραμμικό δίκτυο του Widrow για την πρόγνωση του καιρού [70, 80]. Λόγω της έλλειψης ενός αλγόριθμου εκπαίδευσης για γενική χρήση σε δίκτυα πολλαπλών επιπέδων εκείνη την εποχή, η έρευνα ήταν περιορισμένη. Μόνο το 1986, με την δημοσιοποίηση του αλγόριθμου οπισθοδρομικής μετάδοσης σφάλματος (backpropagation algorithm), υπήρξε μεγάλη ανάπτυξη στη χρήση των ΤΝΔ για πρόγνωση [16]. Ο Werbos (1974, 1988) αρχικά διατυπώνει τον αλγόριθμο οπισθοδρομικής μετάδοσης σφάλματος και διαπιστώνει ότι τα τεχνητά νευρωνικά δίκτυα που εκπαιδεύονται με αυτόν, ξεπερνούν τις παραδοσιακές στατιστικές μεθόδους όπως η παλινδρόμηση και οι προσεγγίσεις των Box-Jenkins [71, 72, 63]. Οι Lapedes και Farber (1987) διεξάγουν μία μελέτη προσομοίωσης και συμπεραίνουν ότι τα ΤΝΔ μπορούν να χρησιμοποιηθούν για μοντελοποίηση και πρόγνωση μη γραμμικών χρονοσειρών [73]. Οι Weigend et al. (1990, 1992) και Cottrell et al. (1995) αντιμετώπισαν το ζήτημα της δομής του δικτύου για την πρόγνωση χρονοσειρών στον πραγματικό κόσμο [74, 75, 76]. Οι Tang et al. (1991), Sharda και Patil (1992) και οι Tang και Fishwick (1993), μεταξύ άλλων, αναφέρουν αποτελέσματα από διάφορες συγκρίσεις πρόγνωσης μεταξύ των Box-Jenkins και μοντέλων τεχνητών νευρωνικών δικτύων [77, 78, 79, 63].

Τα ΤΝΔ έχουν την ικανότητα της γενίκευσης. Αφού διαβάσουν τα δεδομένα που εισάγονται (δείγμα), μαθαίνουν τη συμπεριφορά τους και έτσι μπορούν συχνά να συμπεράνουν το άγνωστο μέρος ενός πληθυσμού, ακόμη και αν τα δείγματα δεδομένων περιέχουν θορυβώδεις ή αλλοιωμένες πληροφορίες. Καθώς η πρόγνωση πραγματοποιείται μέσω της πρόβλεψης της μελλοντικής συμπεριφοράς από παραδείγματα συμπεριφοράς στο παρελθόν (το άγνωστο τμήμα του πληθυσμού), δημιουργείται μία ιδανική ερευνητική περιοχή για τα ΤΝΔ, τουλάχιστον στη θεωρία. Επίσης, τα ΤΝΔ, με τις κατάλληλες σχεδιαστικές προϋποθέσεις, μπορούν να προσεγγίσουν οποιαδήποτε συνεχή συνάρτηση με οποιαδήποτε επιθυμητή ακρίβεια [53, 24, 59, 60, 61, 62]. Σχεδιάζονται έτσι ώστε να έχουν πιο γενικές και ευέλικτες λειτουργικές μορφές από ό,τι οι παραδοσιακές στατιστικές μέθοδοι μπορούν να διαχειριστούν αποτελεσματικά. Κάθε μοντέλο πρόγνωσης υποθέτει ότι υπάρχει μία υποκείμενη σχέση (γνωστή ή άγνωστη), μεταξύ των δεδομένων εισόδου (παρελθοντικές τιμές στη διάρκεια του χρόνου) και των δεδομένων εξόδου (μελλοντικές τιμές). Συχνά, τα παραδοσιακά στατιστικά μοντέλα πρόγνωσης έχουν περιορισμούς στον προσδιορισμό της συνάρτησης που ερμηνεύει την υποκείμενη σχέση λόγω της πολυπλοκότητας του

πραγματικού συστήματος. Τα τεχνητά νευρωνικά δίκτυα βελτιώνονται συνεχώς για να πετύχουν τον ασφαλή προσδιορισμό αυτής της συνάρτησης.

Η πρόγνωση αποτελούσε για πολύ καιρό το πεδίο εφαρμογής της κλασσικής στατιστικής με γραμμικές συναρτήσεις. Τα τεχνητά νευρωνικά δίκτυα είναι μη γραμμικά. Οι παραδοσιακές προσεγγίσεις στην πρόγνωση χρονοσειρών προϋποθέτουν ότι οι υπό μελέτη χρονοσειρές παράγονται από γραμμικές διεργασίες [63, 64]. Τα γραμμικά μοντέλα έχουν πλεονεκτήματα επειδή κατανοούνται εύκολα, μπορούν να αναλυθούν με μεγάλη λεπτομέρεια και είναι εύκολο να εξηγηθούν και να εφαρμοστούν. Εντούτοις, μπορεί να αποδειχθούν εντελώς ακατάλληλα στην περίπτωση που η διαδικασία είναι μη γραμμική. Δεν είναι λογικό να υποθέτουμε εκ των προτέρων ότι μία συγκεκριμένη υλοποίηση μίας δεδομένης χρονικής αλληλουχίας παράγεται από γραμμική διαδικασία. Στην πραγματικότητα, τα συστήματα του κόσμου γύρω μας είναι κυρίως μη γραμμικά [65]. Την τελευταία δεκαετία αναπτύχθηκαν διάφορα μοντέλα μη γραμμικών χρονοσειρών όπως το μοντέλο 2 παραμέτρων (*bilinear model*) [66], το μοντέλο ορίου αυτόματης οπισθοδρόμησης (*threshold autoregressive (TAR) model*) [67], και του υπό συνθήκη μοντέλου της ετεροσκεδαστικότητας (*autoregressive conditional heteroscedastic (ARCH) model*) [68, 69]. Αυτά τα μη γραμμικά μοντέλα έχουν ακόμη περιορισμούς στο γεγονός ότι μία σαφής σχέση των χρονοσειρών πρέπει να υποστεί υποθέσεις λόγω της ελάχιστης γνώσης της υποκείμενης σχέσης. Στην πραγματικότητα, η διαμόρφωση ενός μη γραμμικού μοντέλου σε ένα συγκεκριμένο σύνολο δεδομένων είναι ένα πολύ δύσκολο έργο, από τη στιγμή που υπάρχουν πάρα πολλά πιθανά μη γραμμικά πρότυπα και ένα τέτοιο προκαθορισμένο μοντέλο μπορεί να μην είναι αρκετά γενικευμένο ώστε να συμπεριλαμβάνει όλα τα σημαντικά χαρακτηριστικά. Τα τεχνητά νευρωνικά δίκτυα που είναι μη γραμμικές προσεγγίσεις δεδομένων, σε αντίθεση με τα προαναφερθέντα μη γραμμικά μοντέλα, είναι ικανά να πραγματοποιούν μη γραμμική προσέγγιση χωρίς εκ των προτέρων γνώση των σχέσεων μεταξύ μεταβλητών εισόδου και εξόδου. Έτσι, αποτελούν ένα γενικότερο και ευέλικτο εργαλείο μοντελοποίησης για πρόγνωση.

Η πρόγνωση έχει γίνει απαραίτητη σε καθημερινές επιχειρηματικές αποφάσεις (πωλήσεις, χρηματοδοτήσεις, παραγωγική ικανότητα), στην οικονομική και νομισματική πολιτική, στην τραπεζική και χρηματιστηριακή αγορά. Πιο συχνά, τα προβλήματα πρόγνωσης είναι περίπλοκα, όπως για παράδειγμα η πρόγνωση των τιμών των μετοχών η οποία περιλαμβάνει πολλούς υποκείμενους παράγοντες (μερικούς γνωστούς και μερικούς αθέατους). Τα παραδοσιακά μοντέλα πρόγνωσης περιλαμβάνουν περιορισμούς στις


περιπτώσεις όπου λαμβάνονται υπόψη περίπλοκες μη γραμμικές σχέσεις. Τα τεχνητά νευρωνικά δίκτυα, όταν εφαρμόζονται με σωστό τρόπο, μπορούν να προσφέρουν ισχυρή εναλλακτική λύση, δεδομένης της ικανότητας να μοντελοποιούν και να εξάγουν αόρατα χαρακτηριστικά και σχέσεις. Επιπλέον, σε αντίθεση με τα παραδοσιακά μοντέλα, τα ΤΝΔ δεν προϋποθέτουν περιορισμό στα δεδομένα εισόδου ούτε και στις κατανομές τους. Δείχνουν υψηλή αποδοτικότητα ως εργαλείο πρόγνωσης, εξετάζοντας τις τρέχουσες πληροφορίες και προβλέποντας τι πρόκειται να συμβεί.

Εκτίμηση και Έλεγχος:

Τα τεχνητά νευρωνικά δίκτυα έχουν δυναμική εφαρμογή στον τομέα του αυτόματου ελέγχου σε περιοχές όπως η αναγνώριση συστήματος, ο προσαρμοστικός έλεγχος, η εκτίμηση και βελτίωση παραμέτρων και πολλές άλλες εφαρμογές στον τομέα αυτό. Όπως προαναφέρθηκε, βασική παράμετρος για τα πλεονεκτήματα των ΤΝΔ και στις περιπτώσεις της εκτίμησης (estimation) και του ελέγχου (control) είναι το γεγονός ότι το μοντέλο δεν είναι γραμμικό σε όλες τις παραμέτρους του. Η προσαρμογή των παραμέτρων κλίμακας, κατεύθυνσης και θέσης της σιγμοειδούς συνάρτησης, επιτρέπει να προσαρμόζονται στον καθορισμό της συνάρτησης στόχου. Είναι δυνατή η μη γραμμική ρύθμιση των συναρτήσεων της ημιτονοειδούς κυματομορφής και της πολυωνυμικής καμπύλης και αναμένεται ότι παρόμοια όρια προσέγγισης και εκτίμησης μπορούν να ληφθούν σε κάθε μία από αυτές τις περιπτώσεις [81, 82].

Μεγάλο μέρος της τρέχουσας ερευνητικής προσπάθειας στη βιβλιογραφία σχετικά με τον έλεγχο (control), επικεντρώνεται στην ανάπτυξη μη γραμμικών μεθόδων ελέγχου που δίνουν καλή απόδοση ακόμη και με παρουσία “θορύβου” ή άλλου είδους μη παραμετροποιήσιμης οντότητας. Πολλές ερευνητικές εργασίες σημειώνουν ότι τα νευρωνικά δίκτυα εμφανίζουν πλήθος ιδιοτήτων που απαιτούνται σε μη γραμμικές προσομοιώσεις χρονοσειρών καθώς και σε μη γραμμικούς ελέγχους [83, 84, 85, 86]. Στο πλαίσιο αυτό, ο μη γραμμικός εσωτερικός έλεγχος μοντέλων (IMC) που γίνεται με τη βοήθεια των ΤΝΔ, παρέχει ένα ευέλικτο και πρακτικό εργαλείο για την αντιμετώπιση προβλημάτων που προκύπτουν. Η μεθοδολογία αυτή (IMC) έχει μελετηθεί εκτενώς [87] και η βασική αρχή αυτής είναι ότι για μία σταθερή διαδικασία ανοιχτού βρόγχου μπορεί να βρεθεί ένας ιδανικός ελεγκτής (controller) αναστρέφοντας το τμήμα της ελάχιστης φάσης του μοντέλου διεργασίας. Οι Hunt και Sbarbaro (1991) καθώς και οι Koivisto et.al (1992) έδειξαν ότι τα τεχνητά νευρωνικά δίκτυα μπορούν να εφαρμοστούν απευθείας στο πεδίο αυτό [88, 89].

Η πιο συνηθισμένη τεχνική ελέγχου η οποία χρησιμοποιεί μοντέλα νευρωνικών δικτύων είναι η τεχνική πρόγνωσης (predictive control technique). Ορίζεται ως ένα σχήμα ελέγχου στο οποίο ο ελεγκτής (controller) προσδιορίζει ένα διαχειρίσιμο μεταβλητό προφίλ που χειρίζεται και προσπαθεί να βελτιώσει τις επιδόσεις-στόχους ανοιχτών βρόγχων, από την τρέχουσα χρονική στιγμή έως έναν καθορισμένο χρονικό ορίζοντα. Ο μη γραμμικός έλεγχος πρόβλεψης αναφέρεται στη γενική περίπτωση στην οποία το μοντέλο, ο στόχος απόδοσης και οι περιορισμοί αποδίδονται με μη γραμμικές συναρτήσεις για τις μεταβλητές του συστήματος. Στην περίπτωση αυτή, τα νευρωνικά δίκτυα χρησιμοποιούνται ως κατάλληλα ταυτοποιημένα μοντέλα για να αντικαταστήσουν τα πρωτότυπα στη διαδικασία της προσομοίωσης. Η αυξανόμενη δημοτικότητα της πρόγνωσης με τη χρήση τεχνητών νευρωνικών δικτύων, οφείλεται στην ελκυστικότητα της χρήσης μοντέλων νευρωνικών δικτύων, σε αντίθεση με άλλες μορφές μοντέλων που αναπαριστούν αποτελεσματικά σύνθετα, μη γραμμικά συστήματα στο πλαίσιο της προγνωστικής μεθοδολογίας [90]. Μερικά από τα πλεονεκτήματα της χρήσης των ΤΝΔ στη βελτίωση των στρατηγικών ελέγχου, παρουσιάζονται στην εργασία των Edwards και Goh [91]. Ο αλγόριθμος που χρησιμοποιείται για την πρόγνωση, ουσιαστικά προσπαθεί να ελαχιστοποιήσει τις αποκλίσεις, στις τιμές εξόδου των δεδομένων, σε σχέση με τις τιμές-στόχο ενώ ταυτόχρονα, λαμβάνει κατάλληλα υπόψη την ακολουθία ελέγχου μαζί με τυχόν περιορισμούς που είναι απαραίτητα για την επίτευξη του επιθυμητού αποτελέσματος (Σχήμα 22). Αυτή η



Σχήμα 22: Γενικευμένο μοντέλο νευρωνικού δικτύου με στόχο τον προγνωστικό έλεγχο

στρατηγική πρόγνωσης πολλαπλών βημάτων έχει αποδειχθεί ότι λειτουργεί ικανοποιητικά σε ασταθή λειτουργικά περιβάλλοντα και σχετικές εφαρμογές, με αρνητικό στοιχείο τον μεγάλο χρόνο υπολογισμού. Τα νευρωνικά δίκτυα είναι επαρκώς κατάλληλα για την υλοποίηση αυτής της προσέγγισης καθώς είναι γνωστή η ικανότητα να προβλέψουν πολλαπλές διακριτές τιμές εξόδου [92].

10. ΤΑ ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΣΤΗΝ ΙΑΤΡΙΚΗ

Υπάρχει πλήθος απόψεων σχετικά με την εφαρμογή των τεχνητών νευρωνικών δικτύων στην ιατρική διάγνωση. Η ιδέα παρουσιάστηκε για πρώτη φορά το 1988 σε μία πρωτοποριακή εργασία των Szolovits et al. [93] την οποία ακολούθησε πλήθος δημοσιεύσεων. Η γενική εφαρμογή των ΤΝΔ στην ιατρική περιγράφεται σε εργασία των Alkim et al. [94]. Ενδεικτικά, τα τεχνητά νευρωνικά δίκτυα εφαρμόζονται στη διάγνωση: (i) καρκίνου στο παχύ έντερο [95], (ii) βλαβών πολλαπλής σκλήρυνσης [96], (iii) καρκίνου στο στομάχι [97], (iv) ασθενειών στο πάγκρεας [98], (v) γυναικολογικών παθήσεων [99], (vi) πρώιμου διαβήτη [100] και άλλων. Επιπρόσθετα, τα ΤΝΔ έχουν εφαρμοστεί στην ανάλυση δεδομένων και στη διαγνωστική ταξινόμηση ασθενών με αδιευκρίνιστη δυσπεψία στην γαστρεντερολογία [101] και στην έρευνα για βιοδείκτες [102]. Ένα καινοτόμο, γρήγορο, γενικό και προσαρμοστικό σύστημα διάγνωσης της νόσου έχει αναπτυχθεί με βάση την δυνατότητα εκμάθησης των ΤΝΔ. Αυτός ο αλγόριθμος είναι ο πρώτος προτεινόμενος προσαρμοστικός αλγόριθμος και μπορεί να εφαρμοστεί σε εντελώς διαφορετικές παθήσεις, όπως για παράδειγμα έχει αποδειχθεί από την ακρίβεια ταξινόμησης της τάξης του 99,5% που επιτεύχθηκε τόσο για τον καρκίνο του μαστού όσο και για εκείνον του θυροειδή [103]. Ο καρκίνος, ο διαβήτης και οι καρδιοαγγειακές παθήσεις είναι μεταξύ των σοβαρότερων και ποικιλόμορφων ασθενειών. Η ποσότητα των δεδομένων που προέρχονται από την κλινική και εργαστηριακή ανάλυση αυτών των παθήσεων είναι αρκετά μεγάλη και συνεπώς η ανάπτυξη κατάλληλων εργαλείων για τη διευκόλυνση της διάγνωσης έχει μεγάλη σημασία. Παρουσιάζεται στη συνέχεια, μια σύντομη επισκόπηση της προόδου στην εφαρμογή των τεχνητών νευρωνικών δικτύων, στον τομέα της διάγνωσης για καθεμία από τις αναφερθείσες ασθένειες:

Καρδιοαγγειακές παθήσεις:

Οι καρδιοαγγειακές παθήσεις (CVDs) ορίζονται ως όλες εκείνες οι ασθένειες που επηρεάζουν την καρδιά ή τα αιμοφόρα αγγεία, τόσο τις φλέβες όσο και τις αρτηρίες [103]. Πρόκειται για μία από τις σημαντικότερες αιτίες θανάτου σε πολλές χώρες. Σύμφωνα με το National Center of Health Statistics (NCHS, www.cdc.gov/nchs), αποτελούν την κύρια αιτία θανάτου στις Η.Π.Α. Έτσι, οι καρδιοαγγειακές παθήσεις έγιναν ένας σημαντικός τομέας έρευνας και μελέτης τα τελευταία 20 χρόνια [103].

Από την έρευνα που έγινε στη βιβλιογραφία (ScienceDirect), περισσότερες από χίλιες εργασίες έχουν δημοσιευθεί από το 2008 σχετικά με την χρήση των ΤΝΔ σε καρδιοαγγειακές παθήσεις και συναφή θέματα. Σύμφωνα με το NCHS, η στεφανιαία νόσος

είναι σήμερα η κύρια αιτία θανάτου παγκοσμίως, επομένως η έγκαιρη διάγνωσή της είναι επιτακτική. Έχοντας αυτό ως σκοπό, οι Karabulut και Ibrikci (2012) εφάρμοσαν το μοντέλο των τεχνητών νευρωνικών δικτύων με τη χρήση του αλγόριθμου οπισθοδρομικής μετάδοσης σφάλματος των Levenberg-Marquardt [104, 173]. Η διάγνωση της στεφανιαίας νόσου επιτεύχθηκε με ακρίβεια 91,2% από δεδομένα που συλλέχθηκαν χωρίς επέμβαση και με εύκολο τρόπο από τους πάσχοντες. Άλλα δεδομένα όπως η ηλικία, οι τιμές χοληστερόλης ή η αρτηριακή υπέρταση ελήφθησαν επίσης υπόψη στη διαδικασία της διάγνωσης [105]. Το μοντέλο που σχεδιάστηκε και εκτελέστηκε με την μεγαλύτερη ακρίβεια (93%), ήταν εκείνο που περιλάμβανε τόσο γενετικούς όσο και μη γενετικούς παράγοντες σχετικούς με την πάθηση. Παρά το πολλά υποσχόμενο αποτέλεσμα με το συγκεκριμένο μοντέλο, θα πρέπει να σημειωθεί ότι για άλλα μοντέλα που δοκιμάστηκαν, η ακρίβεια ήταν μικρότερη από 90%.

Τα τεχνητά νευρωνικά δίκτυα έχουν επίσης εφαρμοστεί και σε άλλες καρδιακές παθήσεις όπως ελαττωματική καρδιακή βαλβίδα [106]. Καρδιακές ηχογραφήσεις λήφθηκαν από 120 άτομα με τη χρήση στηθοσκοπίου και ταξινομήθηκαν ως φυσιολογικές, πνευμονικές και μιτροειδείς βαλβίδες. Η σωστή ταξινόμηση επιτεύχθηκε για το 95% των διαφορετικών ήχων. Μία μέση ακρίβεια 99,8% και 99,2% επιτεύχθηκε με δύο διαφορετικά μοντέλα που αναπτύχθηκαν από τον Özbay (2009) για τη διάγνωση αρρυθμιών [107]. Συνεπώς τα ΤΝΔ μπορούν να εφαρμοστούν στην ιατρική διάγνωση εντελώς διαφορετικών παθήσεων όπως για παράδειγμα των αρρυθμιών ή της στεφανιαίας νόσου. Η ακρίβεια ταξινόμησης με ποσοστό υψηλότερο του 90% συνήθως επιτυγχάνεται με ορισμένες περιπτώσεις να πλησιάζει το 99%. Έτσι, η διάγνωση καρδιοαγγειακών παθήσεων με τη βοήθεια τεχνητών νευρωνικών δικτύων αποτελούν σημαντική προοπτική.

Καρκίνος:

Σύμφωνα με την Αμερικανική Εταιρία Καρκίνου (American Cancer Society, www.cancer.org), κάθε χρόνο εμφανίζονται περισσότερα από 1 εκατομμύριο νέα διαγνωσμένα κρούσματα καρκίνου στις Η.Π.Α. Η άμεση και σωστή διάγνωση είναι απαραίτητη για την κλινική αντιμετώπισή του που θα περιλαμβάνει και την επιλογή της πλέον κατάλληλης θεραπευτικής προσέγγισης. Η χρήση των ΤΝΔ στο διαχωρισμό συγκεκριμένων τύπων καρκίνων ή την πρόβλεψη εξάπλωσής του, εμφανίστηκε στα τέλη της δεκαετίας του 1990 ως ένα ελπιδοφόρο υπολογιστικό διαγνωστικό εργαλείο που χρησιμοποιεί διάφορες εισόδους δεδομένων. Η χρήση καινοτόμων μοριακών προσεγγίσεων όπως οι οθόνες micro-RNA, διευρύνει τις δυνατότητες εφαρμογής των ΤΝΔ στην αναζήτηση εξειδικευμένων μοτίβων, κατάλληλων για συγκεκριμένες ασθένειες, όπως για

παράδειγμα ο καρκίνος του ορθού και η ανταπόκρισή του στην κυτταροαναγωγική θεραπεία [108]. Το 1994 αξιολογήθηκε η εφαρμογή των τεχνητών νευρωνικών δικτύων που εκπαιδεύτηκαν σε καθορισμένα σύνολα δεδομένων, για τον καρκίνο του μαστού και των ωοθηκών, ανοίγοντας έτσι μία μεγάλη συζήτηση σχετικά με την καταλληλότητα συγκεκριμένων δεδομένων εισόδου για ανάλυση από το ΤΝΔ όπως δημογραφικά (ηλικία), ακτινολογικά (στοιχεία NMR), ογκολογικά (δείκτες CA 15-3 ή CA 125) και βιοχημικά (χοληστερόλη, τριγλυκερίδια, αλβουμίνη, απολιποπρωτεΐνες A1 και B) [109]. Αργότερα, η εύλογη πρόγνωση της μετρούμενης σε εργαστηριακό περιβάλλον (*in vitro*), χημειοθεραπευτικής απόκρισης με βάση την τιμή ^1H NMR των δειγμάτων βιοψίας του γλοιώματος, επιτεύχθηκε με τη χρήση τεχνητού νευρωνικού δικτύου ώστε να ληφθεί και αυτόματη διαφορική διάγνωση της ασθένειας [110]. Επιπλέον, οι προηγμένες αναλυτικές μέθοδοι όπως η φασματογραφία μάζας, μπορούν να προσφέρουν κατάλληλες πληροφορίες για σχετική κλινική ανάλυση με ΤΝΔ. Η τεχνική αυτή εφαρμόστηκε με επιτυχία στη διάγνωση του καρκίνου των ωοθηκών. Μετά από την ταυτοποίηση των σημείων με την ουσιαστικότερη πληροφορία της καμπύλης φάσματος μάζας, ο δείκτης ευαισθησίας ενός ΤΝΔ εμπρόσθιας τροφοδότησης έδωσε συνολική ευαισθησία 98% και ακρίβεια 96%, ξεπερνώντας τις γνωστές στατιστικές μεθόδους όπως το Student's t-test [111].

Οι εφαρμογές των τεχνητών νευρωνικών δικτύων στην ακτινολογία στοχεύουν στην ανάπτυξη αυτοματοποιημένων συστημάτων υποστήριξης αποφάσεων, που να βοηθούν για παράδειγμα στην ταξινόμηση των όγκων στον εγκέφαλο μετά από μαγνητικό συντονισμό [112]. Η ιδέα και ο σχεδιασμός που αναπτύχθηκαν από τον Tate (2006), εφαρμόστηκαν από τον Brougham (2011) και τους συνεργάτες του στον καρκίνο του πνεύμονα [113]. Σε αυτή τη διαδικασία, το ίδιο πειραματικό πρωτόκολλο διεξήχθη από 2 διαφορετικές ομάδες ερευνητών που εξέτασαν 2 σειρές του φάσματος ^1H NMR ενός ολοκληρωμένου κυττάρου σε διαφορετικούς χρόνους. Φάσματα ^1H NMR πλήρους κυττάρου καταγράφηκαν σε 2 ομάδες κυτταρικών γραμμών καρκινώματος ανθρώπινου πνεύμονα, οι οποίες αναπτύχθηκαν σε καλλιέργεια και περιλάμβαναν: (i) τη γονική κυτταρική γραμμή DLKP, ένα ανθρώπινο, βαθμωτό, κανονικού μεγέθους καρκίνωμα από τον πνεύμονα, (ii) DLKP-A και DLKP-A5F, δύο (2) ανθεκτικές θυγατρικές κυτταρικές γραμμές και (iii) A549, μία κυτταρική γραμμή ανθρώπινου πνευμονικού αδενοκαρκινώματος. Παρά τις επιδεικνυόμενες από τον αναλυτή-σχεδιαστή του ΤΝΔ πηγές της διακύμανσης στο δίκτυο, το ΤΝΔ ήταν σε θέση να ταξινομήσει σωστά την κυτταρική γραμμή στο 100% των περιπτώσεων, ανεξάρτητα από τα φάσματα που επιλέχθηκαν για εκπαίδευση και

αξιολόγηση. Κατά συνέπεια, αποδείχθηκε η αξιοπιστία των ΤΝΔ για την ταξινόμηση διαφόρων τύπων καρκίνου του πνεύμονα σε πραγματικές κλινικές ή εργαστηριακές συνθήκες. Συνοπτικά, τα ΤΝΔ έχειδειχθεί ότι χρησιμοποιούν διάφορα πρωταρχικά δεδομένα, από κλινικές παραμέτρους έως βιοχημικές τιμές και παρέχουν αυξημένη διαγνωστική ακρίβεια για διάφορα είδη καρκίνων.

Διαβήτης:

Ο διαβήτης αντιπροσωπεύει ένα σοβαρό πρόβλημα υγείας στις ανεπτυγμένες χώρες, με εκτιμώμενο αριθμό ασθενών να φθάνει τα 366 εκατομμύρια το 2030, σε παγκόσμιο επίπεδο [114]. Ο συνηθέστερος τύπος διαβήτη είναι ο τύπου II στον οποίο η κυτταρική απόκριση στην ινσουλίνη είναι εξασθενημένη, οδηγώντας σε διαταραχή της ομοιόστασης του ιστού και σε υπεργλυκαιμία. Η τυποποιημένη διαδικασία στη παρακολούθηση του διαβήτη είναι η άμεση μέτρηση της συγκέντρωσης γλυκόζης σε δείγματα αίματος. Οι μη επεμβατικές μέθοδοι που βασίζονται σε φασματοσκοπία υπέρυθρων ή Raman για την παρακολούθηση των επιπέδων γλυκόζης, ξεκίνησαν το 1992 [115]. Το δίκτυο εξάγει τις συγκεντρώσεις γλυκόζης από την καμπύλη του φάσματος, επιτρέποντας έτσι την εύκολη παρακολούθηση της εξέλιξης του διαβήτη κατά τη διάρκεια των καθημερινών δραστηριοτήτων.

Η ίδια η ποιότητα ζωής, συμπεριλαμβανομένης της ικανοποίησης, των κοινωνικών αλληλεπιδράσεων και της κατάθλιψης, έχει οριστεί ως ένα ολοκληρωμένο μέτρο έκβασης στη διαχείριση του σακχαρώδη διαβήτη. Το 2009, οι Narasingarao et al ανέπτυξαν ένα πρωτότυπο μοντέλο νευρωνικού δικτύου με σκοπό τη μέτρηση της ποιότητας ζωής σε διαβητικούς ασθενείς [116]. Για τον ίδιο σκοπό, χρησιμοποιήθηκαν ως δεδομένα εισόδου βιολογικές ή βιογραφικές μεταβλητές όπως ηλικία, φύλο, βάρος και γλυκόζη πλάσματος. Τα αποτελέσματα ήταν συγκρίσιμα με αυτά των παραδοσιακών στατιστικών μεθόδων. Το 1997, πραγματοποιήθηκαν μελέτες προσομοίωσης με τη χρήση τεχνητού νευρωνικού δικτύου, για την πρόγνωση της συγκέντρωσης της γλυκόζης στον υποδόριο ιστό [117]. Με σκοπό τον έλεγχο αξιοπιστίας του αποτελέσματος, ο Trajanoski και οι συνεργάτες του συνδύασαν τον τρόπο ελέγχου του δικτύου με έναν μη γραμμικό τρόπο ελέγχου πρόβλεψης. Η προσέγγιση αυτή επέτρεψε την ύπαρξη μεγάλων επιπέδων θορύβου και χρονικών καθυστερήσεων. Ωστόσο, η χορήγηση ινσουλίνης ή ανάλογων ουσιών, αποδείχθηκε ακατάλληλη για τον γρήγορο έλεγχο ενώ ήταν επαρκής μόνο στον έλεγχο αργών διαταραχών. Αργότερα, ένα νέο σύστημα ελέγχου αναπτύχθηκε με το όνομα *νευρο-ασαφές σύστημα ελέγχου* (neuro-fuzzy control system), το οποίο χρησιμοποιεί αρχές ασαφούς

λογικής (fuzzy logic) και νευρωνικών δικτύων, χρησιμοποιώντας ελάχιστο αριθμό δεδομένων για σωστή έξοδο [118]. Το σύστημα αυτό είναι ιδιαίτερα κατάλληλο για άμεσο έλεγχο των ασθενών με διαβήτη σε κρίσιμη κατάσταση, με παροχή ενδοφλέβιας διατροφής, καθώς μείωσε την ανάγκη συνεχούς μέτρησης της τιμής της γλυκόζης στο αίμα και περιόρισε τον κίνδυνο υπογλυκαιμίας. Το επίπεδο της γλυκόζης στο αίμα έχει επίσης παρατηρηθεί με τη χρήση αντίστροφου βέλτιστου νευρωνικού ελέγχου ως προκαταρκτική μελέτη σε ασθενείς με διαβήτη τύπου I [114].

Ανατροφοδοτούμενα τεχνητά νευρωνικά δίκτυα χρησιμοποιήθηκαν για τον έλεγχο του επιπέδου της γλυκόζης και της ινσουλίνης, ακολουθώντας μία επιθυμητή διαδρομή (φυσιολογική απορρόφηση γλυκόζης από ένα υγιές άτομο), για να αποφευχθεί τόσο η υπογλυκαιμία όσο και η υπεργλυκαιμία. Τα ΤΝΔ έχουν εφαρμοστεί εκτός από την παρακολούθηση της γλυκόζης, και στη διάγνωση του διαβήτη. Αναπτύχθηκε ένα διαγνωστικό σύστημα από τους Chan et al. βασισμένο σε τεχνητό νευρωνικό δίκτυο με σκοπό την πρόβλεψη θανατηφόρων επεισοδίων υπογλυκαιμίας σε ασθενείς με διαβήτη τύπου I [119]. Τα δεδομένα συλλέχθηκαν από μία ομάδα 420 ασθενών και περιλάμβαναν: (i) φυσιολογικές παραμέτρους, (ii) το ρυθμό μεταβολής του καρδιακού ρυθμού, (iii) το διορθωμένο διάστημα QT που παράγεται από το ηλεκτροκαρδιογράφημα, και (iv) το ρυθμό μεταβολής του διορθωμένου διαστήματος QT. Δεδομένα από 320 ασθενείς χρησιμοποιήθηκαν για την εκπαίδευση του δικτύου ενώ οι υπόλοιποι 100 ασθενείς για την επαλήθευσή του. Επιτεύχθηκε ευαισθησία σε ποσοστό 79,30% και ακρίβεια με ποσοστό 60,53%, τιμές πολύ καλύτερες από εκείνες που προέκυψαν χρησιμοποιώντας άλλες μεθόδους όπως στατιστική ανάλυση ή ασαφής λογική. Συμπερασματικά, η χρήση των τεχνητών νευρωνικών δικτύων στη διάγνωση του διαβήτη, παρέχει βελτίωση στην ακρίβεια και στην ευαισθησία σε σύγκριση με άλλες μαθηματικές μεθόδους, συμβάλλοντας έτσι στην καλύτερη κλινική διαχείριση του σακχαρώδους διαβήτη.

11. ΤΕΧΝΗΤΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΚΑΙ ΟΥΡΟΛΟΓΙΑ

Η αυξανόμενη αποδοχή των τεχνητών νευρωνικών δικτύων είναι πλέον δημοφιλές φαινόμενο στην επιστημονική κοινότητα με πολλές εφαρμογές να έχουν αναπτυχθεί και να συνεχίζουν να αναπτύσσονται. Χρησιμοποιούνται σε τομείς όπως η διάγνωση, η απεικόνιση, η ανάλυση της κυματομορφής του καρδιογραφήματος, η πρόγνωση του αποτελέσματος, η φαρμακολογία και η ταυτοποίηση παθολογικών δειγμάτων. Δεδομένης της ισχύος των ΤΝΔ στην εκτέλεση εργασιών αναγνώρισης προτύπων, οι πρώτες εφαρμογές

παρέμειναν σε ερευνητικό επίπεδο. Αρκετές ουρολογικές εφαρμογές έχουν ήδη αναπτυχθεί με τη χρήση των ΤΝΔ. Ιδιαίτερο ενδιαφέρον έχει επικεντρωθεί από τους ερευνητές σε διάφορους τομείς της Ουρολογίας όπως η ανδρική υπογονιμότητα, η ογκολογία και άλλες. Από τις πρώτες μελέτες ήταν το 1991 των MacIin et al. όπου προτάθηκε η χρήση των ΤΝΔ στην ουροακτινολογία. Συγκεκριμένα, σχεδίασαν ένα σύστημα ταξινόμησης νεφρικών μαζών από εικόνες υπερήχων όπως όγκος (καρκίνος), κύστη ή άλλης μορφής. Χρησιμοποιώντας υπολογιστή με επεξεργαστή Intel 386 και ένα τεχνητό νευρωνικό δίκτυο τριών επιπέδων, πέτυχαν ακρίβεια της τάξης του 99% [120].

Στην Ουρολογία, ο καρκίνος του προστάτη χρησιμεύει ως καλό παράδειγμα για την ανάπτυξη τεχνητών νευρωνικών δικτύων. Μεταβολές στους τρόπους απεικόνισης, η ανάγκη για έγκαιρη διάγνωση, η ανάγκη για δειγματοληψία ιστού από συγκεκριμένο όργανο είναι μερικά βασικά ζητήματα μέχρι τη διάγνωση. Επιπλέον, εάν οριστικοποιηθεί τελικά η διάγνωση του καρκίνου στον προστάτη, υπάρχει ανάγκη για διαβάθμιση, πρόβλεψη του αποτελέσματος (πρόγνωση), εξάλειψη παραγόντων κινδύνου, λήψη αποφάσεων σχετικά με τη θεραπεία και παρακολούθηση και ενδεχομένως η διαχείριση της πιθανότητας επανεμφάνισης. Είναι η δεύτερη πιο συχνή αιτία θανάτου από καρκίνο στους άντρες στις ΗΠΑ. Το 2015, διαγνώστηκαν 220.800 άντρες με καρκίνο του προστάτη ενώ σημειώθηκαν 27.540 θάνατοι που σχετίζονταν με αυτό τον τύπο καρκίνου. Η πιθανότητα εμφάνισης καρκίνου στον προστάτη αυξάνεται με την ηλικία. Από όλες τις πρωτοεμφανιζόμενες περιπτώσεις, μόνο το 0,6% διαγιγνώσκεται σε άνδρες ηλικίας κάτω των 44 ετών, με την πλειονότητα των περιπτώσεων να διαγιγνώσκεται σε ηλικίες από 65 έως 74. Ο καρκίνος του προστάτη είναι γενικά ασυμπτωματικός μέχρις ότου φτάσει σε προχωρημένο στάδιο, γεγονός που αποτελεί ένα ισχυρό κίνητρο για την εκτεταμένη χρήση του PSA, με τη συνδρομή των υπερήχων, για έγκαιρη ανίχνευση μέσα στο πλαίσιο θεραπείας [121].

Η λήψη αποφάσεων στην ογκολογία βασιζόταν ανέκαθεν σε περιστατικά και προβλέψεις για ανεξάρτητους, μεμονωμένους ασθενείς. Η ερμηνεία των περιστατικών έπρεπε να γίνεται από κλινικό ιατρό, ο οποίος στηριζόμενος στην εμπειρία του, κατέτασσε τους ασθενείς σε ομάδες κινδύνου ώστε να μπορέσει να αποφασίσει την καλύτερη θεραπευτική επιλογή γι' αυτούς. Παραδοσιακά, για το σκοπό αυτό έχουν χρησιμοποιηθεί μοντέλα στατιστικής ανάλυσης. Καθώς τα δεδομένα αυξάνονταν, νεότερες μελέτες μπορούσαν να εξετάσουν ένα τυποποιημένο αποτέλεσμα για μία μεγαλύτερη ομάδα ατόμων με παρόμοια χαρακτηριστικά. Δεδομένου ότι η παραδοσιακή στατιστική χρησιμοποιεί σταθερούς αντί για απλοποιημένους συσχετισμούς, που απαιτούν ή υποθέτουν γραμμικές

σχέσεις για την ερμηνεία των γεγονότων, το υπολογιζόμενο αποτέλεσμα μπορεί μόνο να αποκαλύψει περιορισμένα πρότυπα και συσχετίσεις μεταξύ των δεδομένων και επομένως, είναι κάπως περιορισμένο [122].

Οι Prater και Richard (1992) περιέγραψαν μία μέθοδο, με τη χρήση τεχνητών νευρωνικών δικτύων, που είχε ως στόχο τη διάκριση μεταξύ του προστάτη και στοιχείων ομοειδών με προστάτη που εμφανίζονται σε εικόνες υπερήχων [123]. Σχεδίασαν ένα δίκτυο τριών επιπέδων και διαμόρφωση 5-6-2 (5 κόμβοι στο επίπεδο εισόδου, 6 κόμβοι στο κρυφό επίπεδο, 2 κόμβοι στο επίπεδο εξόδου) και το εκπαιδύσαν, έχοντας δεδομένα από 1334 σχέδια που ελήφθησαν από εικόνες υπερήχων, που είχαν προηγουμένως μελετηθεί και επεξεργαστεί. Το δίκτυο αυτό είχε ακρίβεια της τάξης του 87% στην πρόβλεψη εάν ένα εικονοστοιχείο (pixel) από την εικόνα υπερήχων προερχόταν πράγματι από τον προστάτη στη διαδικασία της εκτίμησης (evaluation). Οι ίδιοι ερευνητές ανέπτυξαν στη συνέχεια ένα άλλο ΤΝΔ τριών επιπέδων, με διαμόρφωση 61-10-2, το οποίο εκπαιδεύτηκε με 7500 πρότυπα εισόδου-εξόδου. Σε αυτή την περίπτωση, το δίκτυο μπόρεσε να ταξινομήσει σωστά σχεδόν το 99% των εικονοστοιχείων κατά τη διαδικασία της εκτίμησης. Έτσι, η χρήση των τεχνητών νευρωνικών δικτύων σε παρόμοιες περιπτώσεις, παρέχει τη δυνατότητα αυτοματοποίησης της διαδικασίας και θα μπορούσε να εξοικονομήσει χρόνο και έξοδα [124].

Εδώ και καιρό, η μεγαλύτερη εμπειρία στη χρήση των ΤΝΔ στην Ουρολογία υπήρξε στον τομέα της ογκολογίας. Οι μελέτες, στην περιοχή της διάγνωσης του καρκίνου του προστάτη, ξεκίνησαν το 1994 από τους Snow et al. όταν ανέπτυξαν δύο χωριστές εφαρμογές για να προσδιορίσουν ποιος ασθενής θα έπρεπε να υποβληθεί σε βιοψία προστάτη [125]. Με τη χρήση ενός προγράμματος (Neuroshell-2), σχεδίασαν δίκτυο με διαμόρφωση 14-50-1. Κατάφεραν να προβλέψουν με ακρίβεια το αποτέλεσμα της βιοψίας, εκπαιδεύοντας το δίκτυο με περισσότερες από 1500 περιπτώσεις που προέκυψαν από βάση δεδομένων ελέγχου καρκίνου του προστάτη, σε δείγμα 209 περιπτώσεων που χρησιμοποιήθηκαν για εκτίμηση. Το δίκτυο είχε ευαισθησία 70% και ακρίβεια 92%. Ωστόσο, δεν υπήρξαν επιπλέον σύνολα για δοκιμές που να εφαρμοστούν στον συγκεκριμένο αλγόριθμο. Στην ίδια μελέτη, οι ερευνητές περιέγραψαν επίσης ένα δεύτερο τεχνητό νευρωνικό δίκτυο σχεδιασμένο να προβλέπει την επανεμφάνιση του καρκίνου μετά από ριζική προστατεκτομή. Στο δίκτυο αυτό εισήχθησαν 12 μεταβλητές στο επίπεδο εισόδου με μία τιμή εξόδου, την πρόβλεψη επανεμφάνισης καρκίνου. Επετεύχθη ακρίβεια της τάξης του 90% χωρίς και εδώ επιπλέον ομάδες δεδομένων για διασταύρωση (evaluation). Σχετική

μελέτη που δημοσιεύτηκε το 1996 από τους Douglas et al. παρουσίασε ακρίβεια 97% στην πρόβλεψη της υποτροπής, χρησιμοποιώντας τεχνητό νευρωνικό δίκτυο [126]. Αυτές ήταν οι πρώτες ενθαρρυντικές μελέτες που έδωσαν ώθηση και σε άλλους ερευνητές να χρησιμοποιήσουν τεχνητά νευρωνικά δίκτυα στην ουρο-ογκολογία [127, 128].

Το προστατικό αντιγόνο (PSA) αναγνωρίζεται παγκοσμίως για την κλινική του χρησιμότητα στην έγκαιρη διάγνωση του καρκίνου του προστάτη. Υπάρχει μία σημαντική αλληλοεπικάλυψη μεταξύ των τιμών PSA από ασθενείς με καρκίνο του προστάτη και ασθενών με καλοήγη υπερπλασία ή φλεγμονή που είναι πιο κρίσιμη στη λεγόμενη “γκρίζα” περιοχή για τιμές 4-10ng/ml. Η συχνότητα εμφάνισης καρκίνου του προστάτη στους άντρες με τιμή PSA μεταξύ των τιμών 4-10ng/ml είναι περίπου 22% στην αρχική βιοψία ενώ ένα ποσοστό της τάξης του 10% ανακαλύπτεται επιπλέον με τη δεύτερη βιοψία [129].

Μελέτες πάνω στους παράγοντες που επηρεάζουν την πρόγνωση του καρκίνου, έχουν δείξει ότι υπάρχει μεγάλη ανάγκη για ακριβή πρόγνωση καθώς από αυτό θα εξαρτηθεί η ακρίβεια της προτεινόμενης θεραπείας και η αποτελεσματικότητά της. Οι στόχοι της εφαρμογής των παραγόντων αυτών σε ένα μοντέλο στατιστικής ανάλυσης είναι να δοθεί η ένδειξη της πρόγνωσης και να βοηθηθεί ο κλινικός ιατρός στον προγραμματισμό της θεραπείας. Ειδικά στην ογκολογία, τα στατιστικά μοντέλα μπορούν να χρησιμεύσουν στην κατηγοριοποίηση των ασθενών σε ομάδες κινδύνου, στην εκτίμηση του σταδίου της νόσου και να προβλέψουν τόσο την έκβαση της θεραπείας όσο και την πιθανότητα επανεμφάνισης. Διάφορες δημοσιεύσεις αναφέρουν ότι τα τεχνητά νευρωνικά δίκτυα μπορούν να παράσχουν ακριβείς προβλέψεις σε αντίστοιχο βαθμό αξιοπιστίας με τις αναλύσεις στατιστικής παλινδρόμησης και συνήθως αποδίδουν καλύτερα όταν συγκρίνονται με λειτουργικά χαρακτηριστικά του δέκτη (ROC – Receiver Operating Characteristics) και τις περιοχές κάτω από την καμπύλη (AUC – Areas Under Curve) [122].

Οι Babaian et al. το 2000, ανέπτυξαν έναν αλγόριθμο και τον εφάρμοσαν σε τεχνητό νευρωνικό δίκτυο, το οποίο τροφοδοτούνταν από αναδρομικά δεδομένα 151 ανδρών με τιμές PSA μεταξύ 2,5ng/ml και 4ng/ml, οι οποίοι υπεβλήθησαν σε βιοψία με τη βοήθεια 11 δειγμάτων από διάφορα σημεία του προστάτη[130]. Στο δίκτυο εισήχθησαν μεταβλητές όπως η ηλικία, το συνολικό PSA, οι τιμές PAP, η κρεατινίνη κινάση (creatinine kinase) και οι τιμές του free PSA. Ο αλγόριθμος επεξεργαζόταν τα δεδομένα από τρία διαφορετικά τεχνητά νευρωνικά δίκτυα τα οποία με τη σειρά τους έπαιρναν τα δεδομένα από τρεις διαφορετικές πηγές. Διαγνώστηκε καρκίνος στο 24,4% των ασθενών (σε 37 από τους 151).

Η αξιολόγηση των τιμών της ευαισθησίας, της ακρίβειας, της θετικής τιμής πρόβλεψης (PPV – Positive Predictive Value) και της αρνητικής τιμής πρόβλεψης (NPV – Negative Predictive Value) που προέκυψαν από το δίκτυο με τις υπόλοιπες τιμές PSA έδειξαν ότι ο δείκτης ανίχνευσης καρκίνου του προστάτη ήταν σημαντικά καλύτερος, όσον αφορά τις τιμές της ευαισθησίας, όταν οι τιμές της ακρίβειας ήταν σταθερές στο 92%. Οι ερευνητές κατέληξαν στο συμπέρασμα ότι μπορεί να υπάρξει σημαντική μείωση κόστους από περιττές βιοψίες, στο σύστημα υγειονομικής περίθαλψης, της τάξης του 39% εάν γίνεται χρήση των δεικτών ενός τεχνητού νευρωνικού δικτύου αντί των τιμών PSA.

Το 2002, οι Djavan et al. δημοσίευσαν την ακρίβεια πρόγνωσης από δύο διαφορετικά τεχνητά νευρωνικά δίκτυα, με σκοπό την έγκαιρη ανίχνευση του καρκίνου σε άντρες με τιμές PSA μεταξύ 2,5-4ng/ml στο πρώτο δίκτυο και μεταξύ 4-10ng/ml στο δεύτερο [131]. Σε αυτό το άρθρο, τα ΤΝΔ αναπτύσσονται προοπτικά για να προβλέψουν την παρουσία του καρκίνου στον προστάτη και η ακρίβεια της πρόβλεψής τους συγκρίνεται με αυτή που λαμβάνεται από την κλασική μονοπαραγοντική στατιστική ανάλυση των τιμών του PSA, του PSAD, του PSA-TZ, του PSAV, του τομέα TZ και της συνολικής έκτασης του προστάτη. Οι μεταβλητές που χρησιμοποιήθηκαν για είσοδο στο δίκτυο ως πιο προβλέψιμες για τα επίπεδα του συνολικού PSA (2,5-4ng/ml) ήταν, κατά σειρά σπουδαιότητας, PSA-TZ, αναλογία PSA, PSAD. Αντίστοιχα, οι μεταβλητές που χρησιμοποιήθηκαν για είσοδο στο δίκτυο ως πιο προβλέψιμες για τα επίπεδα του συνολικού PSA (4-10ng/ml) ήταν, κατά σειρά σπουδαιότητας, αναλογία PSA, PSA-TZ, PSAV, free PSA, ο τομέας TZ, το συνολικό PSA και PSAD. Οι συγγραφείς κατέληξαν στο συμπέρασμα ότι η ακρίβεια πρόγνωσης και των δύο μοντέλων ΤΝΔ ήταν ανώτερη από αυτή των συμβατικών παραμέτρων PSA και οδήγησε σε λιγότερες, μη απαραίτητες βιοψίες, αν και η διαφορά μεταξύ των δύο μεθόδων (ΤΝΔ και στατιστική ανάλυση) δεν ήταν πάντοτε στατιστικά σημαντική.

Οι Finne et al. (2000), έχουν αναφέρει μία σύγκριση των διαγνωστικών επιδόσεων στην πρόβλεψη της έκβασης της βιοψίας, μεταξύ ενός τεχνητού νευρωνικού δικτύου perceptron πολλαπλών επιπέδων, παραδοσιακής στατιστικής ανάλυσης (Logistic Regression - LR) και μονοπαραγοντικής ανάλυσης σχετικά με την αναλογία PSA [132].

]. Οι μεταβλητές που χρησιμοποιήθηκαν στο δίκτυο περιλάμβαναν το συνολικό PSA, την αναλογία PSA, τον όγκο του προστάτη, την τιμή DRE ενώ για τη στατιστική ανάλυση χρησιμοποιήθηκαν οι ίδιες μεταβλητές, με επιπλέον την ηλικία και το ιστορικό εκδήλωσης του καρκίνου στον προστάτη. Το συμπέρασμα των συγγραφέων ήταν ότι για την

ευαισθησία που δόθηκε στην περιοχή 89%-99%, το τεχνητό νευρωνικό δίκτυο παρουσίασε καλύτερη ακρίβεια από τα άλλα δύο μοντέλα ανάλυσης, καθώς επίσης ήταν ακριβέστερο από το μοντέλο στατιστικής ανάλυσης σε υψηλότερα επίπεδα ευαισθησίας.

Το ενδιαφέρον για τις εφαρμογές της ουρο-ογκολογίας με τη χρήση τεχνητών νευρωνικών δικτύων δεν περιορίστηκε στον καρκίνο του προστάτη [128]. Ένας άλλος τομέας διαγνωστικής αξίας υπάρχει για τους άντρες με μη σεμινωματοώδη οίδημα στους όρχεις, επιπέδου I (*nonseminomatous germ cell testis tumors*), καθώς σε ποσοστό έως 40% θα επανεμφανιστεί εάν επιλεγεί η αναμονή και η παρακολούθηση ως στρατηγικές διαχείρισης του προβλήματος. Με τη χρήση ενός ειδικά σχεδιασμένου ΤΝΔ, ο Moul και οι συνεργάτες του (1995) αξιολόγησαν την δυνατότητα χρήσης αυτής της μεθόδου ως διαγνωστικού εργαλείου για την πρόβλεψη παθολογικού σταδίου σε άνδρες με κλινική εικόνα επιπέδου I [133]. Χρησιμοποιήθηκαν επτά διακεκριμένα ιστολογικά κριτήρια ως δεδομένα εισόδου στο δίκτυο και χρησιμοποιήθηκε ο αλγόριθμος οπισθοδρομικής μετάδοσης σφάλματος για την εκπαίδευση του δικτύου. Οι ερευνητές πέτυχαν ακρίβεια της τάξης του 92% και κατέληξαν στο συμπέρασμα ότι αυτή η μέθοδος μπορεί να παρέχει κλινικά χρήσιμες πληροφορίες για αυτή την ομάδα ανδρών με καρκίνο στους όρχεις, αν και η ποιότητα του δικτύου εξαρτάται από την τεχνογνωσία του προγραμματιστή.

Για λόγους παρόμοιους με εκείνους που ισχύουν στην ακτινολογία, η χρήση τεχνητών νευρωνικών δικτύων στην Ουρολογία μπορεί να είναι ιδιαίτερος κατάλληλη. Οι ουρολόγοι εργάζονται γενικά με μεγάλο αριθμό εικόνων, οι οποίες απαιτούν ταξινόμηση με βάση την αναγνώριση ιστολογικών μοτίβων. Μια τέτοια μεθοδολογία συνδυάζει τόσο τη χρήση ΤΝΔ όσο και μία στατιστική μέθοδο ταξινόμησης που να κατηγοριοποιεί τον καρκίνο του προστάτη σε μέτρια ή κακή διαφοροποίηση [134]. Αυτό είχε ως αποτέλεσμα ένα σύστημα του οποίου η ακρίβεια κυμαινόταν μεταξύ 54% και 77%. Άλλα τέτοια συστήματα, με συνδυασμό ΤΝΔ και στατιστικής ανάλυσης, που έχουν σχεδιαστεί για να αναλύουν την ουρολοίμωξη καθώς και τα καρκινικά κύτταρα που είναι επικαλυμμένα από αντισώματα στην ουροδόχο κύστη, έχουν αναφερθεί ότι έχουν ακρίβεια συγκρίσιμη με εκείνη των ιατρικών αποτελεσμάτων [135, 136].

Άλλες, κλινικά σημαντικές εφαρμογές των τεχνητών νευρωνικών δικτύων για τους ουρολόγους, περιλαμβάνουν την πρόβλεψη του αποτελέσματος της εξέτασης βιοψίας, της λιθοτριψίας και της γονιμοποίησης. Ο Neiderberger και οι συνεργάτες του το 1996 πρωτοστάτησαν στους τομείς αυτούς. Σε δύο ξεχωριστές πιλοτικές μελέτες σχεδίασαν 2

τεχνητά νευρωνικά δίκτυα [137, 138]. Το πρώτο δίκτυο χρησιμοποιήθηκε με σκοπό την πρόβλεψη αποτελεσμάτων γονιμοποίησης, με τα πειράματα να γίνονται σε εργαστηριακό περιβάλλον, πετυχαίνοντας διαγνωστική ακρίβεια 100%. Το ίδιο δίκτυο (ο ίδιος αλγόριθμος) χρησιμοποιήθηκε για την πρόβλεψη αποτελεσμάτων βιοψίας στους όρχεις, πετυχαίνοντας διαγνωστική ακρίβεια 91% [137]. Το δεύτερο δίκτυο έδωσε επίσης ενθαρρυντικά αποτελέσματα στην πρόβλεψη του αποτελέσματος της εξωσωματικής λιθοτριψίας (ESWL). Ορίστηκαν 16 μεταβλητές για είσοδο σε αυτό (input variables) οι οποίες ήταν η ηλικία, το φύλο, η εθνικότητα, η σύνθεση του λίθου, η θέση του, το σχήμα του, το ιστορικό του ασθενούς όσον αφορά τον μεταβολισμό ή τυχόν μολυσματικές ασθένειες, η παρουσία θραυσμάτων από προηγούμενη εξωσωματική λιθοτριψία, λήψη φαρμακευτικής αγωγής, ανατομικές ανωμαλίες, ύπαρξη κατετήρα, ιστορικότητα ύπαρξης παλαιότερων λίθων, συνύπαρξη περισσότερων από έναν λίθους στο ουροποιητικό σύστημα και ο χρόνος από την τελευταία επίσκεψη σε ουρολόγο για το συγκεκριμένο πρόβλημα. Ενενήντα οκτώ ασθενείς χωρίστηκαν τυχαία σε δύο ομάδες: η μία ομάδα αποτελούνταν από εξήντα πέντε ασθενείς και τα δεδομένα τους εισήχθησαν στο δίκτυο για να το εκπαιδεύσουν και η δεύτερη ομάδα με τριάντα τρεις ασθενείς, χρησιμοποιήθηκαν για την αξιολόγηση του. Οι Neiderberger *et al.* πέτυχαν ακρίβεια της τάξης του 90% με τη χρήση του δικτύου η οποία ήταν ανώτερη από την παράλληλη γραμμική στατιστική ανάλυση [138].

Όλο και περισσότερο, οι διαχειριστές της υγειονομικής περίθαλψης επικεντρώνουν το ενδιαφέρον τους στην ποιότητα ζωής μετά από ουρολογικές επεμβάσεις, με αποτέλεσμα να έχει σημειωθεί σημαντική πρόοδος στον τομέα αυτό [139, 140]. Ο πιθανός ρόλος των τεχνητών νευρωνικών δικτύων στην Ουρολογία έχει ερευνηθεί. Οι Krongrad και συνεργάτες, το 1997, εκμεταλλεύτηκαν τις ικανότητες ταξινόμησης των διασυνδεδεμένων συστημάτων για τον εντοπισμό των μεταβλητών που πιθανώς επηρεάζουν την πρόβλεψη για την ποιότητα ζωής μετά από θεραπεία για καλοήγη υπερπλασία του προστάτη και καρκίνο του προστάτη [141]. Ιδιαίτερα σημαντική η ανάλυσή τους με τη χρήση ΤΝΔ, η οποία αποκάλυψε συγκεκριμένους κοινωνικούς, ψυχολογικούς και λειτουργικούς τομείς που σχετίζονται με την ποιότητα ζωής των ασθενών με ασθένεια στον προστάτη. Αναμφίβολα, το έργο τους θέτει ένα νέο όριο για εφαρμογές των τεχνητών νευρωνικών δικτύων στην Ουρολογία.

Μεγάλη αισιοδοξία έχουν προκαλέσει οι επιτυχίες του “ProstAsure Index” ως διαγνωστικού εργαλείου για τον πρώιμο και πιθανώς θεραπεύσιμο καρκίνο στον προστάτη, καθώς υποδηλώνουν τη δυνατότητα ανάπτυξης μιας εντελώς νέας γραμμής προϊόντων για

τη χρήση πρόσθετων κλινικών μεταβλητών, όπως το ποσοστό του free PSA, η φυλή και το οικογενειακό ιστορικό ως ενδεικτική αναφορά. Κάθε μία από τις παραπάνω μεταβλητές, μπορεί να συνεισφέρει σε μία διαφορετική περιοχή εφαρμογής, όπως είναι η διάγνωση, η πρόγνωση και η διαχείριση του καρκίνου στον προστάτη. Με τη συνεχόμενη ανάπτυξη νέων ορών, ιστών και γενετικών δεικτών οι οποίοι γίνονται διαθέσιμοι με οικονομικούς όρους, μπορούν να προστεθούν επιπλέον μεταβλητές στην παραμετροποίηση νέων ερευνητικών δοκιμών. Οι καλοήθεις ουρολογικές παθήσεις που αποτελούν μεγάλη διαγνωστική πρόκληση, όπως η κυστίτιδα (interstitial cystitis), η βακτηριακή προστατίτιδα (bacterial prostatitis) και η προστατοδυνία (prostatodynia), μπορούν επίσης να επωφεληθούν από την ανάπτυξη νέων και καλύτερων εφαρμογών επεξεργασίας διαγνωστικών πληροφοριών που βασίζονται στη χρήση τεχνητών νευρωνικών δικτύων [142]. Άλλοι τομείς της Ουρολογίας όπου ένα διαγνωστικό εργαλείο όπως τα TNΔ μπορεί να είναι χρήσιμο, είναι στην κατηγοριοποίηση του καρκίνου στον προστάτη και στην πρόβλεψη της απόκρισης των ασθενών σε διάφορες θεραπείες που χρησιμοποιούνται στη διαχείριση της συγκεκριμένης νόσου. Συμπεραίνεται λοιπόν ότι πέραν των διαγνωστικών δεικτών (diagnostic indexes), ο επιστήμονας μπορεί να εντυπώσει, με την ανάπτυξη των TNΔ, σε δείκτες κατηγοριοποίησης (staging indexes) και προγνωστικούς δείκτες (prognostic indexes). Οι ουρολόγοι πρέπει να είναι σε θέση να αξιολογούν αξιόπιστα και στη συνέχεια να εκτιμούν την πρόγνωση για τους ασθενείς μετά την ολοκλήρωση της αρχικής οριστικής θεραπείας, έτσι ώστε να λαμβάνονται έγκαιρα οι κατάλληλες αποφάσεις σχετικά με τη χρήση επικουρικών θεραπειών και στην περίπτωση αυτή, ο χρόνος και ο τρόπος εφαρμογής τους. [143].

Να σημειώσουμε ότι μία σημαντική πρόοδος στην ουρολογική έρευνα είναι η ταυτοποίηση νέων βιοδεικτών με βελτιωμένη ειδικότητα για τον κλινικά σημαντικό καρκίνο του προστάτη. Μία νέα υποσχόμενη δοκιμασία βασισμένη στο ειδικό για τον προστάτη αντιγόνο PSA, είναι ο δείκτης υγείας του προστάτη (Prostate Health Index - PHI) ο οποίος έχει εγκριθεί στις Η.Π.Α., στην Ευρώπη και στην Αυστραλία [144]. Ο PHI είναι ένας μαθηματικός τύπος που συνδυάζει το συνολικό PSA, το free PSA και το [-2] proPSA σε ένα ενιαίο σκορ, που μπορεί να χρησιμοποιηθεί για να βοηθήσει στην κλινική λήψη αποφάσεων. Υπολογίζεται από τη σχέση: $([-2] \text{ proPSA} / \text{free PSA}) \times \sqrt{\text{PSA}}$. Ο τύπος αυτός έχει νόημα σε εκείνους τους άνδρες ασθενείς με υψηλότερο συνολικό PSA και pPSA, με χαμηλότερη τιμή του free PSA και συνεπάγεται μεγαλύτερη πιθανότητα να εμφανίσουν κλινικά καρκίνο στον προστάτη [145]. Μεγάλος αριθμός μελετών έχουν δείξει με συνέπεια ότι ο PHI ξεπερνά τα

επιμέρους συστατικά του για την πρόβλεψη του συνόλου και της υψηλής βαθμίδας του καρκίνου του προστάτη κατά τη βιοψία. Ο συγκεκριμένος δείκτης προβλέπει επίσης την πιθανότητα εξέλιξης, κατά τη διάρκεια ενεργής παρακολούθησης, παρέχοντας μία επιπλέον μη επεμβατική μέθοδο για την πιθανή επιλογή και παρακολούθηση αυτού του πληθυσμού ασθενών [146].

Καθώς κινούμαστε στον 21^ο αιώνα, οι εφαρμογές των τεχνητών νευρωνικών δικτύων στην Ουρολογία έχουν αυξητική τάση. Η ελπίδα τροφοδοτείται από τις μοναδικές ιδιότητες των ΤΝΔ, οι οποίες αν αξιοποιηθούν κατάλληλα και καταφέρουμε να βελτιώσουμε την διάγνωση, την κατηγοριοποίηση και την προγνωστική ακρίβεια μεμονωμένων μεταβλητών, θα βοηθηθεί ο ουρολόγος στην επιτυχή θεραπεία. Πράγματι, τα τεχνητά νευρωνικά δίκτυα αξίζει να μελετηθούν περαιτέρω καθώς έχουν εμφανή ενθαρρυντικά αποτελέσματα στην κλινική Ουρολογία.

ΕΙΔΙΚΟ ΜΕΡΟΣ

12. ΕΙΣΑΓΩΓΗ

Η ουρολιθίαση είναι μία από τις συχνότερες ασθένειες παγκοσμίως, με ποσοστό εμφάνισης από 2% έως 3% [147]. Στις βιομηχανικές χώρες, η συχνότητα εμφάνισης είναι αυξανόμενη. Η εισαγωγή της εξωσωματικής λιθοτριψίας με τη χρήση κρουστικών κυμάτων (ESWL – *Extracorporeal ShockWave Lithotripsy*), κατά την οποία γίνεται κατακερματισμός των λίθων του ουροποιητικού με εξωτερικά μέσα, αποτελεί ιατρικό ορόσημο γενικότερα και επανάσταση στην Ουρολογία.

Η αρχική έρευνα για τη μέθοδο αυτή ξεκίνησε το 1967. Στα τέλη του 1972, οι W. Hepp και G. Hoff από το Dornier Development and Research, προσπάθησαν να εντοπίσουν έναν κλινικό εταίρο για την εφαρμογή του ESWL σε ανθρώπους. Οι E. Schmiedt και F. Eisenberger (Τμήμα Ουρολογίας, Ludwig-Maximilians-Univ. Munich) συμφώνησαν να συμμετάσχουν στο πρόγραμμα. Στο πλαίσιο της συνεργασίας, η προκλινική και κλινική έρευνα πραγματοποιήθηκε σε συνεργασία με το Ινστιτούτο Surgical Research (W. Brendel). Η ομάδα αυτή με επικεφαλής τον Ch. Chaussy ζήτησε χρηματοδότηση από το Γερμανικό Research and Technology Ministry (BMFT). Η παραγωγή κρουστικών κυμάτων έγινε με την εκφόρτιση σπινθήρων σε υδάτινο περιβάλλον και τα κύματα εστίασαν σε λίθο στα νεφρά, μέσω μίας ημιελλειψοειδούς κατασκευής. Παρά τις αρχικές προσδοκίες, ο σχεδιασμός της πρώτης εφαρμογής σε άνθρωπο αποδείχθηκε υπερβολικά αισιόδοξος.

Η πρώτη πειραματική φάση της έρευνας, σε δοκιμές *in-vivo*⁽¹⁾ και *in-vitro*⁽²⁾, των επιπτώσεων των κρουστικών κυμάτων, σχεδιάστηκε και διεξήχθη από τους Ch. Chaussy, F. Eisenberger, B. Forssmann και W. Hepp, το 1974 [148, 149]. Το επόμενο πειραματικό στάδιο ήταν η μελέτη με μικρά ζώα, το 1975. Στα πειράματα αυτά, δεν έγινε εφικτό να ανιχνευθούν σχετικές μακροσκοπικές ή μικροσκοπικές παθολογικές μεταβολές στα συνηθισμένα όργανα, ακόμη και μετά από πολλαπλές εκθέσεις [150, 151, 152]. Τον Φεβρουάριο του 1980, οι Ch. Chaussy, B. Forssmann και D. Jocham δοκίμασαν τον εξωσωματικό λιθοτρίπτη σε ασθενή, ο οποίος επιλέχθηκε με πολύ αυστηρά κριτήρια [153]. Ο ασθενής έπασχε από την επανεμφάνιση λίθου στα νεφρά για τέταρτη φορά. Η θεραπεία πραγματοποιήθηκε με αναισθησία μέσω σπονδυλικής στήλης (ITN - *Intrathecal Narcotic anesthesia*). Ο λίθος διασπάστηκε σε τυχαία αποφορτισμένα θραύσματα και η παρακολούθηση έδειξε τη διέλευσή τους προς την ουροδόχο κύστη, χωρίς ιδιαίτερα προβλήματα.

(1) Ο όρος *in vivo* αναφέρεται σε μία ιατρική δοκιμασία, ένα πείραμα ή μία διαδικασία που γίνεται σε ζωντανό οργανισμό, όπως εργαστηριακό ζώο ή άνθρωπο.

(2) Ο όρος *in vitro*, σε αντίθεση με το *in vivo*, αναφέρεται σε μία ιατρική μελέτη ή ένα πείραμα που πραγματοποιείται στο εργαστήριο, μέσα στα όρια ενός δοκιμαστικού σωλήνα ή εργαστηριακού δίσκου.

Παρόμοιες πρακτικές που ακολούθησαν, πραγματοποιήθηκαν επίσης με τη χρήση ITN, το 1981 [151, 154, 155]. Σύντομα έγινε φανερό ότι αυτού του είδους η αναισθησία ήταν η ενδεδειγμένη. Σε μία πρώιμη κλινική μελέτη μετά από τα πρώτα αποτελέσματα, 206 ασθενείς υποβλήθηκαν στην θεραπεία αυτής της μορφής, κάτω από αυστηρά κριτήρια επιλογής. Αργότερα, την ίδια χρονιά, η μέθοδος ονομάστηκε “ESWL” (Extracorporeal ShockWave Lithotripsy ή SWL) [147].

Στις 20 Μαΐου 1982, το πρώτο κέντρο λιθοτριψίας ξεκίνησε επίσημα τη λειτουργία του στο Μόναχο, κάτω από την εποπτεία του Ch. Chaussy, του τμήματος Ουρολογίας, του Πανεπιστημίου του Μονάχου [156]. Έτσι, έγινε δυνατή η ταχύτερη περαιτέρω κλινική αξιολόγηση των ενδείξεων της πάθησης. Η επιτυχία αυτής της μεθόδου προκάλεσε τεράστιο ενδιαφέρον στη Γερμανία αλλά και στον υπόλοιπο κόσμο. Το 1983, άνοιξε το δεύτερο κέντρο λιθοτριψίας στη Στουτγκάρδη (F. Eisenberger) [157, 158, 159]. Η πρώτη συσκευή ESWL που χρησιμοποιήθηκε στις Η.Π.Α., εγκαταστάθηκε το Φεβρουάριο του 1984 στην Ινδιανάπολη (D. Newman, J. Lingeman) και σε σύντομο χρονικό διάστημα ακολούθησαν άλλες πέντε.


Με την αποδοχή και εξάπλωση της εξωσωματικής λιθοτριψίας, ελαχιστοποιήθηκε η επιλογή της ανοιχτής χειρουργικής για την απομάκρυνση λίθων από το ουροποιητικό σύστημα. Σήμερα υπάρχουν περισσότερα από 5000 εγκατεστημένα μηχανήματα λιθοτριψίας παγκοσμίως και η χρήση τους σε περισσότερες από 1 εκατομμύριο περιπτώσεις αποδεικνύουν την καθολική αποδοχή της μεθόδου [147]. Η εξωσωματική λιθοτριψία παραμένει αντικείμενο επιστημονικού ενδιαφέροντος και έρευνας, καθώς αποτελεί ουσιαστική επιλογή των ουρολόγων στην αντιμετώπιση της ουρολιθίασης, γεγονός που επιβεβαιώνεται από τον μεγάλο αριθμό σχετικών δημοσιεύσεων κάθε χρόνο.

13. ΣΚΟΠΟΣ ΕΡΕΥΝΑΣ

Κύριος σκοπός της συγγραφής της παρούσας διατριβής είναι η εκτίμηση της ασφάλειας και της αποτελεσματικότητας της εξωσωματικής λιθοτριψίας (ESWL), ως μέθοδος θεραπείας της εμφάνισης λίθου στο ουροποιητικό σύστημα, στον πληθυσμό της Θεσσαλίας, με τη χρήση ειδικού ηλεκτρομαγνητικού λιθοτρίπτη Dornier II.

Ως ασφάλεια της εξωσωματικής λιθοτριψίας ορίζουμε την εμφάνιση ή όχι επιπλοκών με το πέρας της διαδικασίας. Οι επιπλοκές που μας ενδιαφέρουν και έχουν τα μεγαλύτερα ποσοστά εμφάνισης είναι ο πόνος και φλεγμονή. Ως αποτελεσματικότητα της

εξωσωματικής λιθοτριψίας ορίζουμε τον επιτυχή ή όχι κατακερματισμό του λίθου και την φυσική απομάκρυνσή του από το ουροποιητικό σύστημα. Ο λίθος μπορεί να βρίσκεται σε οποιοδήποτε όργανο του ουροποιητικού συστήματος. Το ανθρώπινο ουροποιητικό



Σχήμα 23: Το ανθρώπινο ουροποιητικό σύστημα

σύστημα, κατά μία απλουστευμένη περιγραφή, αποτελείται από τα δύο νεφρά, τους δύο ουρητήρες, την ουροδόχο κύστη και την ουρήθρα (Σχήμα 23).

14. ΠΛΗΘΥΣΜΟΣ ΜΕΛΕΤΗΣ ΚΑΙ ΜΕΘΟΔΟΣ ΑΝΑΛΥΣΗΣ

Πρόκειται για μία κλινική, αναδρομική, μη τυχαιοποιημένη μελέτη στην οποία συμμετέχουν ασθενείς με ουρολιθίαση από την περιοχή της Θεσσαλίας και έχουν υποβληθεί σε εξωσωματική λιθοτριψία (Extracorporeal Shock Wave Lithotripsy - ESWL), στο τμήμα Ουρολογίας του Πανεπιστημιακού Νοσοκομείου Λάρισας, την περίοδο 2005 – 2015 (10 έτη). Οι ασθενείς που συμμετείχαν στη μελέτη πληρούσαν όλα τα κριτήρια για την επιλογή της λιθοτριψίας ως θεραπεία της νόσου, όπως υπαγορεύεται από τις οδηγίες της Ευρωπαϊκής Ένωσης Ουρολογίας (European Association of Urology). Επιπλέον, όλοι έδωσαν γραπτή συγκατάθεση για τη συγκέντρωση και στατιστική επεξεργασία των ιατρικών δεδομένων τους.

Ένα σύνολο 716 ασθενών, με λίθο σε κάποιο σημείο του ουροποιητικού τους συστήματος, υποβλήθηκαν σε εξωσωματική λιθοτριψία. Από αυτούς, 347 παρουσίασαν κάποια επιπλοκή (πόνος ή/και λοίμωξη) με το πέρας της διαδικασίας της λιθοτριψίας. 508 ασθενείς από τους 716 είχαν επιτυχή θρυμματισμό του λίθου και απομάκρυνση του από το

ουροποιητικό σύστημα. Καταγράφηκαν ιατρικά δεδομένα για κάθε ασθενή (ανεξάρτητες μεταβλητές), κάποια πριν την έναρξη της θεραπείας και κάποια κατά τη διάρκεια της. Τα δεδομένα που συλλέχθηκαν πριν την έναρξη της λιθοτριψίας περιλαμβάνουν το φύλο, την ηλικία, το δείκτη μάζας-σώματος (B.M.I.), τη θέση του λίθου (δεξιό νεφρό, αριστερό νεφρό, κύστη, αριστερός ουρητήρας, δεξιός ουρητήρας), το μέγεθος του λίθου (σε χιλιοστά), τη συνοσηρότητα (λήψη αντιπηκτικών, καρδιολογικά προβλήματα, σακχαρώδης διαβήτης, αρτηριακή υπέρταση, διαταραχές πήξης), την υποβολή σε προηγούμενη λιθοτριψία, την αναλγησία και την ύπαρξη pig-tail. Κατά τη διάρκεια της λιθοτριψίας έλαβαν χώρα και καταγράφηκαν τρία επιπλέον δεδομένα όπως οι κρούσεις, η ένταση και η χρήση υδρονέφωσης. Το σύνολο των ιατρικών δεδομένων που συλλέχθηκαν για κάθε ασθενή είναι 20. Στον Πίνακα 1 παρουσιάζεται η μορφή των δεδομένων σε αρχείο MS Excel:

Πίνακας 1

		ΑΣΘΕΝΗΣ 1	ΑΣΘΕΝΗΣ 2	ΑΣΘΕΝΗΣ 3	ΑΣΘΕΝΗΣ 4	
Θέση λίθου	Φύλο	0	0	0	0	
	Ηλικία	66	62	61	58	
	B.M.I.	25,39	32,27	34,42	29,38	
	Δεξιό νεφρό	0	0	1	0	
	Αριστερό νεφρό	0	1	0	0	
	Κύστη	0	0	0	0	
	Δεξιός ουρητήρας	1	0	0	1	
	Αριστερός ουρητήρας	0	0	0	0	
	Μέγεθος λίθου	10	15	12	10	
	Αντιπηκτικά	1	0	0	0	
Συνοσηρότητα	Καρδιακά προβλήματα	1	0	0	1	
	Σακχαρώδης διαβήτης	0	0	0	0	
	Αρτηριακή υπέρταση	0	0	1	0	
	Διαταραχές πήξης	1	0	0	0	
	Προηγούμενη θεραπεία	1	0	1	1	
	Αναλγησία	0	0	0	0	
	Αριθμός κρούσεων	3500	3000	2500	3000	
	Ένταση	0,9	0,8	0,8	0,75	
	Υπαρξη pig-tail	0	0	1	0	
	Υδρονέφωση	1	1	0	0	
Αποτέλεσμα ESWL	Επιλοκές	1	1	1	1	
	Θρυμματισμός λίθου	1	1	1	1	

Οι ασθενείς αποτελούνται από άντρες και γυναίκες, και συμβολίζονται με 0 (άντρες) και 1 (γυναίκες). Η ηλικία των ασθενών καταγράφεται από έναν θετικό αριθμό. Ο δείκτης μάζας-σώματος έχει υπολογιστεί και είναι ένας θετικός δεκαδικός αριθμός για κάθε ασθενή. Ο λίθος, όπου η ύπαρξή του αποτελεί απαραίτητη προϋπόθεση για να υποβληθεί κάποιος σε εξωσωματική λιθοτριψία, θα βρίσκεται σε ένα από τα 5 βασικά όργανα του ουροποιητικού συστήματος (θέση λίθου). Σημειώνουμε με 1 το όργανο στο οποίο παρατηρήθηκε ο λίθος και 0 την απουσία του από τα άλλα όργανα. Για κάθε ασθενή, ο λίθος βρίσκεται μόνο σε ένα όργανο του ουροποιητικού συστήματος και η θεραπεία είναι στοχοποιημένη. Ο λίθος

θεωρείται κατά προσέγγιση σφαιρικός και η μεγαλύτερη διάστασή του μετριέται σε χιλιοστά (διάμετρος) και καταχωρείται στο μέγεθος λίθου. Η συνοσηρότητα περιγράφεται από 5 ιατρικές περιπτώσεις οι οποίες μπορεί να συνυπάρχουν σε κάθε ασθενή ή να μην εμφανίζεται καμία από αυτές. Έτσι, στην ύπαρξη κάποιας από τις περιπτώσεις συνοσηρότητα σε έναν ασθενή σημειώνουμε 1 ενώ σημειώνουμε 0 στην περίπτωση απουσίας. Εάν ο ασθενής έχει υποβληθεί στο παρελθόν σε θεραπεία εξωσωματικής λιθοτριψίας τουλάχιστον μία φορά, σημειώνουμε 1, ενώ σημειώνουμε 0 όταν δεν έχει υποβληθεί. Ως αναλγησία στην ιατρική ορίζεται η ολική απώλεια του αισθήματος του πόνου. Σημειώνουμε 1 εάν χορηγήθηκε φαρμακευτικό σκεύασμα για την ανακούφιση του ασθενή από τον πόνο λόγω της παρουσίας λίθου και 0 για τη μη χορήγηση σκευάσματος. Στην περίπτωση που έχει τοποθετηθεί στον ασθενή αυτοσυγκρατούμενος ουρητηρικός καθετήρας (*jj stent* ή *pigtail*) σημειώνουμε 1 και 0 σε μη τοποθέτηση. Κατά την είσοδο του ασθενούς στο μηχάνημα εξωσωματικής λιθοτριψίας, ρυθμίζονται παράμετροι του μηχανήματος όπως οι κρούσεις (ηλεκτρομαγνητικοί παλμοί), η ένταση τους και η χρήση υδρονέφωσης. Οι κρούσεις καταγράφονται ως ένας θετικός αριθμός ενώ η ένταση ως θετικό ποσοστό (δεκαδικός αριθμός < 1) ενώ αξίζει να σημειωθεί ότι είναι δύο ανεξάρτητες μεταξύ τους ρυθμίσεις. Εάν έχει γίνει χρήση υδρονέφωσης, σημειώνουμε 1 και σε αντίθετη περίπτωση σημειώνουμε 0.

Οι δύο τελευταίες γραμμές του Πίνακα 1 παρουσιάζουν τα αποτελέσματα της εξωσωματικής λιθοτριψίας ανά ασθενή. Συγκεκριμένα, για την εκτίμηση των επιπλοκών (πόνος ή/και φλεγμονή) βάζουμε την τιμή 1 εάν ο ασθενής παρουσιάσει κάποια επιπλοκή με το πέρας της διαδικασίας της λιθοτριψίας ενώ βάζουμε 0 εάν δεν εμφανιστεί καμία επιπλοκή. Το αποτέλεσμα της λιθοτριψίας καταγράφεται στην τελευταία γραμμή του πίνακα όπου εάν η διαδικασία είναι επιτυχής, βάζουμε την τιμή 1 ενώ στην περίπτωση μη θρυμματισμού του λίθου βάζουμε την τιμή 0.

Τα δεδομένα συγκεντρώθηκαν σε πίνακα στο MS Excel και επεξεργάστηκαν με τη βοήθεια του IBM SPSS Statistics (συντομογραφία του Statistical Package for Social Sciences) το οποίο χρησιμοποιείται εκτενώς από ερευνητές για να πραγματοποιήσουν στατιστική ανάλυση. Στη συνέχεια, σχεδιάστηκε ένα τεχνητό νευρωνικό δίκτυο και ένας μοναδικός κώδικας εκτέλεσης, με τη βοήθεια του δημοφιλούς προγραμματιστικού περιβάλλοντος, MATLAB (Neural Network toolbox).

14.1 Στατιστική Ανάλυση: Μεθοδολογία και Αποτελέσματα

Ως **Στατιστική (Statistic)** ορίζεται η επιστήμη που απασχολείται με τη συγκέντρωση (συλλογή), οργάνωση, παρουσίαση και ανάλυση δεδομένων. Δηλαδή ασχολείται με την:

- Συλλογή και επιλογή ενός δείγματος από τον πληθυσμό και λήψη μετρήσεων από αυτό.
- Οργάνωση των δεδομένων με την χρήση των Η/Υ μέσω διαφόρων λογιστικών φύλλων (π.χ. Excel) ή στατιστικών πακέτων (π.χ. SPSS, STATA, SAS, R, SPlus, Minitab κ.ά).
- Παρουσίαση περιγραφικών χαρακτηριστικών των δεδομένων με χρήση πινάκων συχνοτήτων, γραφημάτων και περιγραφικών μέτρων.
- Στατιστική συμπερασματολογία με χρήση μοντέλων [π.χ. γραμμική παλινδρόμηση (linear regression)].

Η επιστήμη της Στατιστικής χωρίζεται σε δύο μεγάλους κλάδους, την Περιγραφική Στατιστική (Descriptive Statistics) και την Στατιστική Συμπερασματολογία (Inferential Statistics) [180].


Όλα τα δεδομένα αναλύθηκαν χρησιμοποιώντας περιγραφικά χαρακτηριστικά. Για τις ποσοτικές μεταβλητές που χρησιμοποιήθηκαν παρουσιάζεται η μέση τιμή, η τυπική απόκλιση, η μέγιστη και η ελάχιστη τιμή. Για τις ποιοτικές μεταβλητές παρουσιάζεται ο απόλυτος αριθμός παρατηρήσεων (N) και η σχετική συχνότητα (%) για κάθε κατηγορία της μεταβλητής. Όλοι οι προβλεπτικοί παράγοντες (δημογραφικά και κλινικά στοιχεία, φαρμακευτική αγωγή, ερευνητικά αποτελέσματα) ελέγχθηκαν σε επίπεδο μονοπαραγοντικών μοντέλων ως προς την προγνωστική τους ισχύ για την εμφάνιση επιπλοκών καθώς και για την αποτελεσματικότητα της θεραπείας. Χρησιμοποιήθηκε πολυπαραγοντική ανάλυση - γενικευμένο γραμμικό μοντέλο (generalized linear model: Binomial distribution, link function=logit) για την πρόβλεψη ενδεχομένης εμφάνισης επιπλοκών καθώς και την αποτελεσματικότητα της θεραπείας. Στις πολυπαραγοντικές αναλύσεις, συμπεριλάβαμε όλες τις στατιστικά σημαντικές μεταβλητές των μονοπαραγοντικών μοντέλων μαζί με κάποιους παράγοντες κινδύνου ανεξάρτητης στατιστικής σημαντικότητας (φύλο και ηλικία). Τα δεδομένα της παρούσας έρευνας αναλύθηκαν στατιστικά με το λογισμικό SPSS Statistics (version 25).

Δημογραφικά χαρακτηριστικά:


Στον Πίνακα 2, παρουσιάζονται τα ατομικά χαρακτηριστικά για το σύνολο του πληθυσμού. Στην έρευνα συμμετείχαν συνολικά 716 ασθενείς (N=716) εκ των οποίων το 56.4% (N=404) είναι άντρες και το 43.6% (N=312) είναι γυναίκες με μέση ηλικία 54.65 έτη (± 14.18). Όσον αφορά τον δείκτη μάζας σώματός των ασθενών παρατηρούμε ότι μόλις το 0.4% (N=3) είναι λιποβαρείς, το 27.4% (N=196) έχουν φυσιολογικό βάρος, ενώ αξιοσημείωτο είναι το ποσοστό που καταλαμβάνουν οι υπέρβαροι με 46.5% (N=333), καθώς και οι παχύσαρκοι όπου παρατηρήθηκαν με 25.7% (N=184).

		N	%
Φύλο	<i>Αντρας</i>	404	56.4
	<i>Γυναίκα</i>	312	43.6
Ηλικία (σε έτη)	<i>Μέση τιμή (Τυπική απόκλιση)</i>	54.65 (14.18)	
	<i>Ελάχιστη-Μέγιστη</i>	19-96	
BMI	<i>Μέση τιμή (Τυπική απόκλιση)</i>	27.65(4.25)	
	<i>Ελάχιστη-Μέγιστη</i>	17.8-43.3	
BMI	<i>Λιποβαρής</i>	3	0.4
	<i>Φυσιολογικός</i>	196	27.4
	<i>Υπέρβαρος</i>	333	46.5
	<i>Παχύσαρκος</i>	184	25.7

Πίνακας 2: Δημογραφικά χαρακτηριστικά των ασθενών (N=716)



Γράφημα 1: Κατανομή δείγματος ως προς το φύλο των ασθενών




Γράφημα 2: Κατανομή δείγματος ως προς τον δείκτη μάζας σώματος των ασθενών

Περιγραφικά χαρακτηριστικά σχετικά με τον λίθο:

Στον Πίνακα 3, παρουσιάζονται τα περιγραφικά χαρακτηριστικά των ασθενών σχετικά με την ύπαρξη ή όχι λίθου στα 5 ζωτικά όργανα του ουροποιητικού συστήματος. Το 34.1% (N=244) των ασθενών παρατηρήθηκε να έχουν λίθο στο δεξιό νεφρό, το 33.1% (N=237) των ασθενών παρατηρήθηκε να έχουν λίθο στο αριστερό νεφρό, το 2.1% (N=15) των ασθενών παρατηρήθηκε να έχουν λίθο στην κύστη, το 14.9% (N=107) των ασθενών παρατηρήθηκε να έχουν λίθο στον αριστερό ουρητήρα και τέλος το 15.9% (N=114) των ασθενών παρατηρήθηκε να έχουν λίθο στον δεξιό ουρητήρα.

		N	%
Δεξί νεφρό	Όχι	472	65.9
	Ναι	244	34.1
Αριστερό νεφρό	Όχι	479	66.9
	Ναι	237	33.1
Κύστη	Όχι	701	97.9
	Ναι	15	2.1
Αριστερός ουρητήρας	Όχι	609	85.1
	Ναι	107	14.9
Δεξιός ουρητήρας	Όχι	602	84.1
	Ναι	114	15.9

Πίνακας 3: Περιγραφικά χαρακτηριστικά για την ύπαρξη ή όχι λίθου σε 5 ζωτικά όργανα των ασθενών



Γράφημα 3: Κατανομή δείγματος ως προς την ύπαρξη λίθου στα ζωτικά όργανα των ασθενών

Στον Πίνακα 4, παρουσιάζονται τα βασικά περιγραφικά χαρακτηριστικά για το μέγεθος του λίθου που είχαν οι ασθενείς στα ζωτικά όργανα. Παρατηρούμε ότι, οι ασθενείς είχαν λίθο μέσης διαμέτρου 11.5 χιλιοστών (± 4.45), με το μικρότερο λίθο να έχει διάμετρο ίση με 4 χιλιοστά και τον μεγαλύτερο λίθο να έχει διάμετρο 32 χιλιοστά.

	N	Μέση τιμή	Τυπική απόκλιση	Ελάχιστη τιμή	Μέγιστη τιμή
Μέγεθος λίθου (χιλιοστά)	716	11.5	4.45	4	32


Πίνακας 4: Περιγραφικά χαρακτηριστικά για το μέγεθος του λίθου στα ζωτικά όργανα των ασθενών

Περιγραφικά χαρακτηριστικά σχετικά με τη συνοσηρότητα:

Από τον Πίνακα 5 παρατηρούμε ότι το 13% (N=93) των ασθενών έχουν κάνει χρήση αντιπηκτικών και το 11.3% (N=81) των ασθενών έχουν καρδιολογικά προβλήματα. Επίσης, αναφορικά με την ύπαρξη σακχαρώδη διαβήτη, μόλις το 7.5% (N=54) δήλωσε ότι πάσχει ενώ μεγαλύτερο ήταν το ποσοστό 24.4% (N=175) των ασθενών που δήλωσε ότι έχει αρτηριακή πίεση. Τέλος, χαμηλό φάνηκε να είναι το ποσοστό των ασθενών που δήλωσε ότι έχει διαταραχές πήξης στο αίμα 9.2% (N=66).

		N	%
Αντιπηκτικά	Όχι	623	87
	Ναι	93	13
Καρδιολογικά προβλήματα	Όχι	635	88.7
	Ναι	81	11.3
Σακχαρώδης διαβήτης	Όχι	662	92.5
	Ναι	54	7.5
Αρτηριακή υπέρταση	Όχι	541	75.6
	Ναι	175	24.4
Διαταραχές πήξης	Όχι	650	90.8
	Ναι	66	9.2

Πίνακας 5: Περιγραφικά χαρακτηριστικά για την ύπαρξη συνοσηρότητας στους ασθενείς




Γράφημα 4: Κατανομή δείγματος ως προς την ύπαρξη κάποιου είδους συνοσηρότητας των ασθενών

Περιγραφικά χαρακτηριστικά σχετικά με προηγούμενες θεραπείες:

Στον πίνακα 6, παρουσιάζονται τα βασικά περιγραφικά χαρακτηριστικά ως προς την ύπαρξη προηγούμενης θεραπείας και αναλγησίας των ασθενών. Συγκεκριμένα, 57% (N=408) των ασθενών δήλωσε ότι έχει υποβληθεί σε προηγούμενη θεραπεία, ενώ μόλις το 6.6% (N=47) των ασθενών δήλωσε ότι έχει υποβληθεί σε αναλγητική θεραπεία με τη χρήση κάποιου φαρμακευτικού σκευάσματος.

		N	%
Προηγούμενη θεραπεία	Όχι	308	43
	Ναι	408	57
Αναλγησία	Όχι	669	93.4
	Ναι	47	6.6

Πίνακας 6: Περιγραφικά χαρακτηριστικά για την ύπαρξη προηγούμενης θεραπείας και αναλγησίας των ασθενών



Γράφημα 5: Κατανομή δείγματος ως προς την ύπαρξη προηγούμενης θεραπείας και αναλγησίας των ασθενών

Περιγραφικά χαρακτηριστικά σχετικά με τις παραμέτρους του λιθοτρίπτη:

Στον Πίνακα 7, παρουσιάζονται τα βασικά περιγραφικά χαρακτηριστικά για τον αριθμό κρούσεων (που παίρνει για τιμές θετικούς αριθμούς) και την ένταση κρούσεων (που παίρνει για τιμές ποσοστά (%)) με μορφή δεκαδικών αριθμών) του δείγματος (N=716) των ασθενών. Συγκεκριμένα, στο σύνολο των ασθενών με ελάχιστο αριθμό κρούσεων (1000) και μέγιστο (Max = 4500), παρατηρήθηκε ότι ο μέσος αριθμός κρούσεων των ασθενών είναι 3,050.5 (± 484.92). Αναφορικά με την ένταση των κρούσεων των ασθενών, η μέση ένταση κρούσεων, είχε βαθμολογία 72% ($\pm 10.3\%$), με την ελάχιστη ένταση να είναι στο 30% και τη μέγιστη ένταση να είναι στο 100%.


	N	Μέση τιμή	Τυπική απόκλιση	Ελάχιστη τιμή	Μέγιστη τιμή
Αριθμός κρούσεων	716	3,050.5	484.92	1000	4500
Ένταση κρούσεων	716	0.72	0.103	0.3	1

Πίνακας 7: Περιγραφικά χαρακτηριστικά για την ηλικία και τον δείκτη μάζας σώματος των ασθενών.

Στον Πίνακα 8, παρουσιάζονται τα βασικά περιγραφικά χαρακτηριστικά ως προς την ύπαρξη pig-tail και τη χρήση υδρονέφωσης από τους ασθενείς. Συγκεκριμένα, το 22.1% (N=158) δήλωσε ότι έχει υποβληθεί σε τοποθέτηση pig-tail, ενώ το 29.5% (N=211) δήλωσε ότι έχει παρουσιάσει υδρονέφωση.

		N	%
Pig-tail	Όχι	558	77.9
	Ναι	158	22.1
Υδρονέφωση	Όχι	505	70.5
	Ναι	211	29.5

Πίνακας 8: Περιγραφικά χαρακτηριστικά για την ύπαρξη pig-tail και τη χρήση υδρονέφωσης από τους ασθενείς



Γράφημα 6: Κατανομή δείγματος ως προς για την ύπαρξη pig-tail και τη χρήση υδρονέφωσης από τους ασθενείς

Περιγραφικά χαρακτηριστικά σχετικά με τις επιπλοκές και τα αποτελέσματα της θεραπείας:

Στον Πίνακα 9, παρουσιάζονται τα βασικά περιγραφικά χαρακτηριστικά ως προς τα αποτελέσματα των επιπλοκών και τα αποτελέσματα της θεραπείας στους ασθενείς. Παρατηρήθηκε ότι το 51.5% (N=369) των ασθενών δεν παρουσίασε επιπλοκές, ενώ το 48.5% (N=347) παρουσίασε. Τέλος, στη σημαντική πλειοψηφία των ασθενών με ποσοστό 70.9% (N=508) η θεραπεία ολοκληρώθηκε με επιτυχία, ενώ στο 29.1% (N=208) των ασθενών η θεραπεία απέτυχε.

		N	%
Αποτέλεσμα επιπλοκών	Απουσία επιπλοκών	369	51,5
	Υπαρξη επιπλοκών	347	48,5
Αποτέλεσμα θεραπείας	Αποτυχία	208	29,1
	Επιτυχία	508	70,9

Πίνακας 9: Περιγραφικά χαρακτηριστικά για τα αποτελέσματα των επιπλοκών και τα αποτελέσματα της θεραπείας



Γράφημα 7: Κατανομή δείγματος ως προς τα αποτελέσματα των επιπλοκών και τα αποτελέσματα της θεραπείας στους ασθενείς.

Πραγματοποιήθηκαν 2 στατιστικές αναλύσεις, μία για την εκτίμηση της προγνωστική ισχύος του αποτελέσματος των επιπλοκών και μία για την εκτίμηση της προγνωστικής ισχύος του αποτελέσματος της λιθοτριψίας, οι οποίες παρουσιάζονται στη συνέχεια.

Μονοπαραγοντική και πολυπαραγοντική ανάλυση για τις επιπλοκές

Όλοι οι προβλεπτικοί παράγοντες (δημογραφικά και σωματομετρικά στοιχεία, συννοσηρότητες και θεραπευτικές αγωγές) ελέγχθηκαν σε επίπεδο μονοπαραγοντικών μοντέλων ως προς την προγνωστική τους ισχύ για το αποτέλεσμα των επιπλοκών. Χρησιμοποιήθηκε πολυπαραγοντική ανάλυση για την πρόβλεψη του αποτελέσματος των επιπλοκών, στην οποία συμπεριλήφθηκαν όλες οι στατιστικά σημαντικές μεταβλητές των μονοπαραγοντικών μοντέλων μαζί με κάποιους παράγοντες κινδύνου ανεξάρτητης στατιστικής σημαντικότητας, όπως το φύλο και η ηλικία. Στον Πίνακα 10 παρουσιάζονται τα αποτελέσματα της λογιστικής παλινδρόμησης:

	Crude OR (95% CI)	p-value	Adjusted OR (95% CI)	p-value
Φύλο				
<i>Αντρας</i>	0.90(0.67-1.21)	0.470	0.89(0.65-1.22)	0.467
<i>Γυναίκα</i>	Κατ. Αναφοράς		Κατ. αναφοράς	
Ηλικία (σε έτη)	0.99(0.99-1.01)	0.526	1.00(0.99-1.02)	0.512
BMI	0.99(0.96-1.03)	0.857	Κατ. αναφοράς	
Δεξί νεφρό				
<i>Ναι</i>	0.88(0.64-1.20)	0.407	-	-
<i>Όχι</i>	Κατ. Αναφοράς			
Αριστερό νεφρό				
<i>Ναι</i>	1.17(0.85-1.60)	0.329	-	-
<i>Όχι</i>	Κατ. Αναφοράς			
Κύστη				
<i>Ναι</i>	1.22(0.44-3.40)	0.703	-	-
<i>Όχι</i>	Κατ. Αναφοράς			
Αριστερός ουρητήρας				
<i>Ναι</i>	1.31(0.87-1.98)	0.198	-	-
<i>Όχι</i>	Κατ. Αναφοράς			
Δεξιός ουρητήρας				
<i>Ναι</i>	0.71(0.47-1.06)	0.093	-	-
<i>Όχι</i>	Κατ. Αναφοράς			
Μέγεθος λίθου (χιλιοστά)	1.02(0.99-1.05)	0.264	-	-
Αντιπηκτικά				
<i>Ναι</i>	0.99(0.64-1.54)	0.987	-	-
<i>Όχι</i>	Κατ. Αναφοράς			

Καρδιολογικά προβλήματα				
<i>Ναι</i>	1.30(0.82-2.07)	0.264	-	-
<i>Όχι</i>	Κατ. Αναφοράς			
Σακχαρώδης διαβήτης				
<i>Ναι</i>	1.74(0.98-3.07)	0.056	1.86(1.02-3.42)	0.044
<i>Όχι</i>	Κατ. Αναφοράς		Κατ. αναφοράς	
Αρτηριακή υπέρταση				
<i>Ναι</i>	1.17(0.83-1.65)	0.367	-	-
<i>Όχι</i>	Κατ. Αναφοράς			
Διαταραχές πήξης				
<i>Ναι</i>	0.94(0.56-1.55)	0.799	-	-
<i>Όχι</i>	Κατ. Αναφοράς			
Προηγούμενη θεραπεία				
<i>Ναι</i>	0.29(0.22-0.40)	<0.001	0.32(0.23-0.44)	<0.001
<i>Όχι</i>	Κατ. Αναφοράς		Κατ. αναφοράς	
Αναλγησία				
<i>Ναι</i>	2.16(1.16-4.03)	0.015	2.12(1.07-4.19)	0.031
<i>Όχι</i>	Κατ. Αναφοράς		Κατ. αναφοράς	
Αριθμός κρούσεων				
<i>Ένταση κρούσεων</i>	1.00(1.00-1.00)	0.787	-	-
<i>Ένταση κρούσεων</i>	1.65(0.39-6.87)	0.488	-	-
Pig-tail				
<i>Ναι</i>	1.05(0.74-1.49)	0.797	-	-
<i>Όχι</i>	Κατ. Αναφοράς			
Υδρονέφωση				
<i>Ναι</i>	2.60(1.86-3.63)	<0.001	2.37(1.68-3.36)	<0.001
<i>Όχι</i>	Κατ. Αναφοράς		Κατ. αναφοράς	

Πίνακας 10: Μονοπαραγοντική και πολυπαραγοντική λογιστική παλινδρόμηση για την εξαρτημένη μεταβλητή «Αποτέλεσμα επιπλοκών» (OR: Odds Ratio, CI: Confidence Interval)

Με βάση τα αποτελέσματα της μονοπαραγοντικής ανάλυσης, παρατηρήθηκε ότι ο σακχαρώδης διαβήτης, η προηγούμενη θεραπεία, η αναλγησία και η υδρονέφωση είναι μεταβλητές που σχετίζονται στατιστικά σημαντικά με το αποτέλεσμα των επιπλοκών. Στην πλειονότητα των αναλύσεων, η τιμή του “α” ίση με 0.05 χρησιμοποιείται ως όριο στατιστικής σημαντικότητας (κατώφλι στατιστικού σφάλματος). Επιπλέον, εάν η τιμή p-value είναι μικρότερη από 0.05 τότε απορρίπτουμε την μηδενική υπόθεση (H_0), που στην περίπτωση μας ορίζεται ότι δεν υπάρχει στατιστική συσχέτιση μεταξύ των δεδομένων (δηλ. το αποτέλεσμα δεν επηρεάζεται από τις τιμές, άρα και από το είδος των δεδομένων που συγκρίνω) και έτσι συμπεραίνουμε ότι υπάρχει στατιστική συσχέτιση της κατηγορίας που

εξετάζεται με το αποτέλεσμα. Συγκεκριμένα, για τους ασθενείς που είχαν σακχαρώδη διαβήτη η πιθανότητα εμφάνισης επιπλοκών είναι αυξημένη κατά 74% σε σχέση με όσους δεν είχαν σακχαρώδη διαβήτη ($OR=1.74$, $p\text{-value}=0.056$). Αντιθέτως, οι ασθενείς που είχαν κάνει προηγούμενη θεραπεία είχαν μειωμένη πιθανότητα εμφάνισης επιπλοκών κατά 71% ($OR=0.29$, $p\text{-value}<0.001$) σε σχέση με όσους δεν είχαν κάνει προηγούμενη θεραπεία. Οι ασθενείς που έκαναν χρήση αναλγησίας (ΝΑΙ) σε σχέση με αυτούς που δεν έκαναν (ΟΧΙ) έχουν 2,16 φορές αυξημένη πιθανότητα να εμφανίσουν επιπλοκές ($OR=2.16$, $p\text{-value}=0.015$). Τέλος, οι ασθενείς στους οποίους έγινε χρήση υδρονέφωσης κατά τη λιθοτριψία σε σχέση με αυτούς που δεν έγινε, έχουν 2,60 φορές αυξημένη πιθανότητα να εμφανίσουν επιπλοκές ($OR=2.60$, $p\text{-value}=0.015$).

Στη συνέχεια, το φύλο, η ηλικία και οι μεταβλητές οι οποίες βρέθηκαν να συσχετίζονται σε στατιστικά σημαντικό βαθμό, συμπεριλήφθηκαν στο τελικό πολυπαραγοντικό μοντέλο (σακχαρώδης διαβήτης, προηγούμενη θεραπεία, αναλγησία, και υδρονέφωση). Συγκεκριμένα, για τους ασθενείς που είχαν σακχαρώδη διαβήτη, η πιθανότητα εμφάνισης επιπλοκών είναι αυξημένη κατά 86% σε σχέση με όσους δεν είχαν σακχαρώδη διαβήτη ($OR=1.86$, $p\text{-value}=0.044$) κρατώντας σταθερούς τους υπόλοιπους παράγοντες. Μειωμένη πιθανότητα εμφάνισης επιπλοκών κατά 68% παρατηρήθηκε στους ασθενείς που είχαν λάβει προηγούμενη θεραπεία ($OR=0.32$, $p\text{-value}<0.001$). Επιπλέον, οι ασθενείς που απάντησαν “ΝΑΙ” στην αναλγησία σε σχέση με αυτούς που απάντησαν “ΟΧΙ” έχουν 2,12 φορές αυξημένη πιθανότητα να εμφανίσουν επιπλοκές ($OR=2.12$, $p\text{-value}=0.031$). Τέλος, οι ασθενείς που απάντησαν “ΝΑΙ” στην υδρονέφωση σε σχέση με αυτούς που απάντησαν “ΟΧΙ” έχουν 2,37 φορές αυξημένη πιθανότητα να εμφανίσουν επιπλοκές ($OR=2.37$, $p\text{-value}=0.015$).

Μονοπαραγοντική και πολυπαραγοντική ανάλυση για την αποτελεσματικότητα

Κατ’ αναλογία με την προηγούμενη μέθοδο, όλοι οι προβλεπτικοί παράγοντες (δημογραφικά και σωματομετρικά στοιχεία, συννοσηρότητες και θεραπευτικές αγωγές) ελέγχθηκαν σε επίπεδο μονοπαραγοντικών μοντέλων ως προς την προγνωστική τους ισχύ για το αποτέλεσμα της θεραπείας. Χρησιμοποιήθηκε πολυπαραγοντική ανάλυση - γενικευμένο γραμμικό μοντέλο (generalized linear model: Binomial distribution, link function=logit) για την πρόβλεψη του αποτελέσματος της θεραπείας. Στην πολυπαραγοντική ανάλυση συμπεριλήφθηκαν όλες οι στατιστικά σημαντικές μεταβλητές των μονοπαραγοντικών μοντέλων μαζί με κάποιους παράγοντες κινδύνου ανεξάρτητης

στατιστικής σημαντικότητας, όπως το φύλο και η ηλικία. Στον Πίνακα 11 παρουσιάζονται τα αποτελέσματα της λογιστικής παλινδρόμησης:

	Crude OR (95% CI)	p-value	Adjusted OR (95% CI)	p-value
Φύλο				
<i>Ανδρας</i>	1.33(0.96-1.84)	0.086	1.49(1.05-2.09)	0.026
<i>Γυναίκα</i>	Κατ.αναφοράς			
Ηλικία (σε έτη)	0.99(0.98-1.00)	0.137	0.99(0.98-1.00)	0.115
Δείκτη μάζας σώματος	0.98(0.95-1.02)	0.345		
Δεξί νεφρό				
<i>Ναι</i>	1.20 (0.85-1.69)	0.307		
<i>Όχι</i>	Κατ.αναφοράς			
Αριστερό νεφρό				
<i>Ναι</i>	1.20 (0.85-1.70)	0.307		
<i>Όχι</i>	Κατ.αναφοράς			
Κύστη				
<i>Ναι</i>	1.65(0.46-5.92)	0.440		
<i>Όχι</i>	Κατ.αναφοράς			
Αριστερός ουρητήρας				
<i>Ναι</i>	1.00(0.64-1.58)	0.985		
<i>Όχι</i>	Κατ.αναφοράς			
Δεξιός ουρητήρας				
<i>Ναι</i>	0.52(0.34-0.79)	0.002	0.56(0.35-0.89)	0.015
<i>Όχι</i>	Κατ.αναφοράς			
Μέγεθος λίθου	0.94(0.90-0.97)	<0.001	0.93(0.90-0.97)	<0.001
Αντιπηκτικά				
<i>Ναι</i>	1.13(0.69-1.85)	0.622		
<i>Όχι</i>	Κατ.αναφοράς			
Καρδιολογικά προβλήματα				

<i>Ναι</i>	1.76(0.99-3.12)	0.053		
<i>Όχι</i>	Κατ.αναφοράς			
Σακχαρώδης διαβήτης				
<i>Ναι</i>	1.32(0.69-2.51)	0.403		
<i>Όχι</i>	Κατ.αναφοράς			
Αρτηριακή υπέρταση				
<i>Ναι</i>	1.03(0.71-1.50)	0.872		
<i>Όχι</i>	Κατ.αναφοράς			
Διαταραχές πήξης				
<i>Ναι</i>	1.44(0.79-2.62)	0.237		
<i>Όχι</i>	Κατ.αναφοράς			
Προηγούμενη θεραπεία				
<i>Ναι</i>	0.99(0.71-1.37)	0.937		
<i>Όχι</i>	Κατ.αναφοράς			
Αναλγησία				
<i>Ναι</i>	0.78(0.42-1.46)	0.436		
<i>Όχι</i>	Κατ.αναφοράς			
Αριθμός κρούσεων	0.99(0.99-1.00)	<0.001	0.99(0.99-1.00)	0.001
Ένταση κρούσεων	0.05(0.01-0.30)	0.001	0.53(0.07-4.14)	0.543
Pig-tail				
<i>Ναι</i>	0.55(0.38-0.79)	0.002	0.65(0.44-0.97)	0.034
<i>Όχι</i>	Κατ.αναφοράς			
Υδρονέφωση				
<i>Ναι</i>	1.01 (0.71-1.44)	0.957		
<i>Όχι</i>	Κατ.αναφοράς			

Πίνακας 11: Μονοπαραγοντική και πολυπαραγοντική λογιστική παλινδρόμηση για την εξαρτημένη μεταβλητή «Αποτέλεσμα λιθοτριψίας» (OR: Odds Ratio, CI: Confidence Interval)

Με βάση τα αποτελέσματα της μονοπαραγοντικής ανάλυσης, παρατηρήθηκε ότι ο δεξιός ουρητήρας, το μέγεθος λίθου, ο αριθμός κρούσεων, η ένταση κρούσεων και το pig-tail είναι μεταβλητές που σχετίζονται στατιστικά σημαντικά με το αποτέλεσμα της θεραπείας. Και εδώ, εάν η τιμή p-value είναι μικρότερη από 0.05 τότε απορρίπτουμε την μηδενική υπόθεση (H_0), που στην περίπτωση μας ορίζεται ότι δεν υπάρχει στατιστική συσχέτιση μεταξύ των δεδομένων (δηλ. το αποτέλεσμα δεν επηρεάζεται από τις τιμές, άρα και από το είδος των δεδομένων που συγκρίνω) και έτσι συμπεραίνουμε ότι υπάρχει στατιστική σημαντικότητα της κατηγορίας που εξετάζεται. Πιο συγκεκριμένα, για τους ασθενείς που παρατηρήθηκε λίθος στο δεξιό ουρητήρα, η πιθανότητα επιτυχίας της θεραπείας είναι μειωμένη κατά 48% σε σχέση με όσους δεν είχαν λίθο στο δεξιό ουρητήρα ($OR=0.52$, $p\text{-value}=0.002$). Παρόμοιο συμπέρασμα προέκυψε και για τους ασθενείς στους οποίους είχε τοποθετηθεί το pig-tail ($OR=0.55$, $p\text{-value}=0.002$). Επιπλέον, με την αύξηση του μεγέθους του λίθου παρατηρήθηκε μειωμένη πιθανότητα επιτυχίας της θεραπείας κατά 6% ($OR=0.94$, $p\text{-value}<0.001$). Η αύξηση του αριθμού των κρούσεων που χρησιμοποιήθηκαν για τον θρυμματισμό λίθων οδήγησε σε μειωμένη πιθανότητα επιτυχίας της θεραπείας κατά 1% ($OR=0.99$, $p\text{-value}<0.001$), καθώς και η αύξηση της έντασης των κρούσεων σημείωσε μειωμένη πιθανότητα επιτυχίας κατά 95% ($OR=0.05$, $p\text{-value}=0.001$).

Επιπλέον, το φύλο, η ηλικία και οι μεταβλητές οι οποίες βρέθηκαν να συσχετίζονται σε στατιστικά σημαντικό βαθμό, συμπεριλήφθηκαν στο τελικό πολυπαραγοντικό μοντέλο (δεξιός ουρητήρας, μέγεθος λίθου, αριθμός κρούσεων, ένταση κρούσεων και pig-tail). Συγκεκριμένα, για τις γυναίκες παρατηρήθηκε αυξημένη πιθανότητα κατά 49% να έχουν επιτυχή θεραπεία σε σχέση με τους άνδρες ($OR=1.49$, $p\text{-value}=0.026$). Για τους ασθενείς που παρατηρήθηκε λίθος στο δεξιό ουρητήρα, η πιθανότητα επιτυχίας της θεραπείας είναι μειωμένη κατά 44% σε σχέση με όσους δεν είχαν λίθο στον αντίστοιχο ουρητήρα ($OR=0.56$, $p\text{-value}=0.015$). Μειωμένη πιθανότητα επιτυχίας της θεραπείας κατά 35% παρατηρήθηκε, επίσης, και στους ασθενείς με pig-tail ($OR=0.65$, $p\text{-value}=0.034$). Επιπλέον, το μέγεθος του λίθου λειτούργησε επιβαρυντικά για την έκβαση της θεραπείας, καθώς η αύξηση του μεγέθους του οδήγησε σε μειωμένη πιθανότητα επιτυχίας κατά 7% ($OR=0.93$, $p\text{-value}<0.001$). Τέλος, ο αριθμός των κρούσεων που χρησιμοποιήθηκαν για τον θρυμματισμό λίθων, επηρέασε το αποτέλεσμα της θεραπείας μειώνοντας κατά 1% την πιθανότητα επιτυχίας ($OR=0.99$, $p\text{-value}=0.001$).

14.2 Νευρωνικό δίκτυο: Σχεδιασμός, Υλοποίηση, Αποτελέσματα

Ένα από τα σημαντικότερα προβλήματα που καλούνται να αντιμετωπίσουν οι σχεδιαστές τεχνητών νευρωνικών δικτύων είναι το κατάλληλο μέγεθος του δικτύου, μαζί με την κατάλληλη επιλογή των ποσοστών από την βάση δεδομένων, που θα χρησιμοποιηθούν για εκπαίδευση, εκτίμηση και δοκιμή για μία δεδομένη εφαρμογή. Το μέγεθος του δικτύου αφορά την αρχιτεκτονική σε επίπεδα και περιλαμβάνει τον αριθμό των επιπέδων, τον αριθμό των κόμβων σε κάθε επίπεδο και τον αριθμό των συνδέσεων. Ο Haykin το 1998, δήλωσε ότι ενώ είναι δυνατόν να σχεδιαστεί ένα τεχνητό νευρωνικό δίκτυο χωρίς κανένα κρυφό επίπεδο, η ταξινόμηση των δεδομένων τους θα είναι γραμμικώς διαχωρίσιμη, γεγονός που θα περιορίζει σημαντικά τις εφαρμογές τους [30]. Οι Medsker και Liebowitz το 1994, θεώρησαν ότι ένα τεχνητό νευρωνικό δίκτυο που περιέχει κρυφά επίπεδα έχει τη δυνατότητα να διαχειριστεί σθεναρά μη γραμμικά και περίπλοκα προβλήματα και κατά συνέπεια μπορεί να χρησιμοποιηθεί σε πιο ενδιαφέρουσες εφαρμογές [163]. Όσον αφορά τα ποσοστά κατανομής του συνόλου των δεδομένων προς εκπαίδευση του δικτύου, έχουν προταθεί διαφορετικά ποσοστά κατανομής τους στη βιβλιογραφία, ωστόσο δεν έχουν διατυπωθεί μαθηματικοί κανόνες για τον προσδιορισμό των απαιτούμενων μεγεθών αυτών των συνόλων. Ο Looney (1996) προτείνει το 65% του συνόλου δεδομένων να χρησιμοποιείται για εκπαίδευση, το 25% για εκτίμηση και το 10% για δοκιμή (αναφορά από τους Basheer και Hajmeer το 2000), ενώ οι Demuth et al. (2010) προτείνουν 60% για εκπαίδευση, 20% για εκτίμηση και 20% για δοκιμή όπως και οι Niaki & Abbasi (2005) [164, 165, 166]. Αρκετοί συγγραφείς χρησιμοποιούν το ίδιο ποσοστό για εκτίμηση και δοκιμή [169].

Ένα τεχνητό νευρωνικό δίκτυο δημιουργείται ακολουθώντας μία συστηματική, βήμα-βήμα διαδικασία για τη βελτιστοποίηση ενός κριτηρίου απόδοσης ή την παρακολούθηση κάποιων έμμεσων εσωτερικών περιορισμών, που συνήθως αναφέρεται ως *κανόνας μάθησης*. Ο εξειδικευμένος αναλυτής επιλέγει την τοπολογία του δικτύου όπως τον αριθμό των δεδομένων εισόδου, τα κρυφά επίπεδα, τον αριθμό των κόμβων ανά επίπεδο, τις συναρτήσεις μεταφοράς και το κριτήριο διακοπής της φάσης εκπαίδευσης. Ο προσδιορισμός των βαρών μπορεί να γίνει είτε από τον σχεδιαστή του δικτύου ή να ρυθμιστούν αυτόματα από το σύστημα [169].

Η πιο ευρέως διαδεδομένη τεχνική χρήσης των ΤΝΔ στην αναγνώριση προτύπων είναι αυτή του *multilayer perceptron* (MLP) [16, 167]. Αποτελείται από τρία επίπεδα: το επίπεδο εισόδου, το κρυφό επίπεδο και το επίπεδο εξόδου. Το επίπεδο εισόδου αποτελείται από κόμβους που αντιπροσωπεύουν τις μεταβλητές εισόδου του προβλήματος, το επίπεδο εξόδου με κόμβους που αντιστοιχούν στις εξαρτημένες μεταβλητές και είναι αυτό που


ουσιαστικά γίνεται προσπάθεια να μοντελοποιηθεί, και ένα ή περισσότερα κρυφά επίπεδα που περιέχουν κόμβους για να καταγράψουν τη μη γραμμικότητα των δεδομένων. Η βασική λειτουργία του επιπέδου εισόδου είναι η διανομή των πληροφοριών εισόδου στο επόμενο επίπεδο επεξεργασίας ενώ η λειτουργία του επιπέδου εξόδου είναι ο καθορισμός του προτύπου [168]. Το δίκτυο εκπαιδεύεται και δοκιμάζεται προτού περάσει στην ανάπτυξη για αναγνώριση προτύπων. Υιοθετείται συνήθως η μάθηση με επιτήρηση. Η διαδικασία εκμάθησης πραγματοποιείται μέσω της προσαρμογής των βαρών των συνδέσεων μεταξύ του επιπέδου εισόδου και του κρυφού επιπέδου καθώς και μεταξύ του κρυφού επιπέδου και του επιπέδου εξόδου ώστε να ελαχιστοποιείται το σφάλμα μεταξύ της πραγματικής και της επιθυμητής εξόδου.

Υπάρχουν διάφοροι τύποι αλγορίθμων εκπαίδευσης με τους οποίους το multilayer perceptron (MLP) μαθαίνει από τα δεδομένα και δημιουργεί συσχετισμούς, αλλά είναι δύσκολο να γνωρίζουμε ποιος μπορεί να είναι κατάλληλος για την κατάρτιση μοντέλου αναγνώρισης προτύπων μιας πολυπαραγοντικής διαδικασίας. Η επιλογή εξαρτάται από πολλούς παράγοντες όπως ο αριθμός των βαρών και των σταθερών μεταβλητών, ο βαθμός του λάθους καθώς και ο αριθμός των επαναλήψεων της εκπαιδευτικής διαδικασίας (*epochs*). Ο αλγόριθμος *οπισθοδρομικής μετάδοσης σφάλματος* (*backpropagation algorithm*), είναι ο συνηθέστερος και ευρύτερα χρησιμοποιούμενος αλγόριθμος για την εκπαίδευση ενός τεχνητού νευρωνικού δικτύου και μαθαίνει τη σχέση των δεδομένων υπολογίζοντας το σφάλμα ανάμεσα στην επιθυμητή και την πραγματική έξοδο, μεταδίδοντας το στη συνέχεια προς τα πίσω, σε κάθε κόμβο του δικτύου [169]. Το μεταδιδόμενο σφάλμα, χρησιμοποιείται για να οδηγήσει τη μάθηση σε κάθε κόμβο. Υπάρχουν πολλές παραλλαγές του αλγορίθμου αυτού. Ενδεικτικά αναφέρονται οι δημοφιλέστεροι: Levenberg-Marquardt, scaled conjugate, quasi-Newton, gradient descent with momentum, gradient descent και resilient backpropagation.

Ο αλγόριθμος των Levenberg-Marquardt (συνάρτηση *trainlm*) συνδυάζει τη μέθοδο της *απότομης καθόδου* (*steep descent*) με τον αλγόριθμο των Gauss-Newton καθώς κληρονομεί τη σταθερότητα (απότομη κάθοδος) και την ταχύτητα (Gauss-Newton) [174]. Παρέχει μία αριθμητική λύση στο πρόβλημα της ελαχιστοποίησης μίας συνάρτησης που συνήθως είναι μη γραμμική, πάνω σε ένα σύνολο παραμέτρων της συνάρτησης. Έχει σταθερή σύγκλιση, είναι γρήγορη και είναι σε θέση να πετύχει χαμηλότερο μέσο τετραγωνικό σφάλμα από οποιονδήποτε άλλο αλγόριθμο [173]. Ο αλγόριθμος *scaled conjugate gradient* (συνάρτηση *trainscg*) σχεδιάστηκε για να αποφευχθεί η χρονοβόρος

μονοσήμαντη αναζήτηση μεταξύ των αλγορίθμων της κατηγορίας *conjugate gradient*, οι οποίοι απαιτούν γενικά υψηλούς επεξεργαστικούς πόρους, καθώς προϋποθέτει ότι η απόκριση του δικτύου προς όλα τα δεδομένα εισόδου υπολογίζεται αρκετές φορές για κάθε αναζήτηση. Η συνάρτηση *trainscg* είναι γρήγορη, όπως και η *trainlm*, και σε κάποιες περιπτώσεις μπορεί να επιτύχει χαμηλότερο μέσο τετραγωνικό σφάλμα [175]. Η κατηγορία των αλγορίθμων quasi-Newton (συνάρτηση *trainbfg*) βασίζεται στη μέθοδο του Νεύτωνα (Newton), η οποία δεν απαιτεί τον υπολογισμό των πινάκων Hessian των δεύτερων παραγώγων, αλλά λαμβάνει υπόψη μία προσέγγιση των πινάκων που βασίζεται στην κλίση της καθόδου (gradient descent) και ενημερώνεται κατάλληλα σε κάθε επανάληψη του αλγορίθμου. Οι μέθοδοι quasi-Newton θεωρούνται πιο αποτελεσματικές, πιο αξιόπιστες και γενικά πιο εφαρμόσιμες. Ο Schittkowski (1987, 1989) και οι Hock & Schittkowski (1981) ανέλυσαν εκτενώς τις μεθόδους αυτές και τις εκτίμησαν μαζί με άλλες μεθόδους, χρησιμοποιώντας μια σειρά από μη γραμμικά ειδικά σχεδιασμένα προβλήματα. Το συμπέρασμά τους ήταν ότι οι μέθοδοι quasi-Newton είναι ανώτερες από άλλες [170, 171, 172]. Η μέθοδος *gradient descent with momentum* (συνάρτηση *traingdm*) επιτρέπει σε ένα δίκτυο να ανταποκρίνεται όχι μόνο στην τοπική κλίση, αλλά και σε τάσεις που εμφανίζονται κοντά στην περιοχή των λαθών [176]. Η μέθοδος *gradient descent* (συνάρτηση *traingd*) είναι συνήθως πιο αργή στη σύγκλιση [177, 178]. Τα βάρη και οι σταθερές της μεθόδου ενημερώνονται προς την κατεύθυνση της αρνητικής κλίσης της συνάρτησης απόδοσης και μόνο μετά την εφαρμογή ολόκληρου του συνόλου δεδομένων προς εκπαίδευση στο δίκτυο. Η μέθοδος *resilient backpropagation* (συνάρτηση *trainrp*) είναι μία τεχνική βελτιστοποίησης με στόχο την ελαχιστοποίηση της συνάρτησης σφάλματος. Ο σκοπός του αλγόριθμου εκπαίδευσης της μεθόδου αυτής (συνάρτηση *Rprop*) είναι να εξαλείψει τις αρνητικές επιδράσεις των μερικών παραγώγων, όταν η υψηλότερη απότομη κάθοδος χρησιμοποιείται για να για την εκπαίδευση ενός MLP με σιγμοειδείς συναρτήσεις. Οι σιγμοειδείς συναρτήσεις χαρακτηρίζονται από το γεγονός ότι οι κλίσεις τους πλησιάζουν το μηδέν όταν ο αριθμός των δεδομένων εισόδου μεγαλώνει. Η απαίτηση μνήμης για την *Rprop* είναι σχετικά μικρή σε σύγκριση με άλλους αλγόριθμους [179].

Λαμβάνοντας υπόψη τις αναφορές της διεθνούς βιβλιογραφίας και με τη σχετική γνώση και εμπειρία του συγγραφέα, σχεδιάστηκε ένα τεχνητό νευρωνικό δίκτυο με τα εξής στοιχεία: ο αριθμός των κόμβων στο επίπεδο εισόδου είναι ίσος με το πλήθος των ανεξάρτητων μεταβλητών. Εάν όλες οι μεταβλητές ήταν μονοσήμαντες για κάθε κατηγορία δεδομένων τότε το δίκτυο θα σχεδιαζόταν όπως φαίνεται στο Σχήμα 24. Το επίπεδο εισόδου




Σχήμα 24: Απεικόνιση τεχνητού νευρωνικού δικτύου

θα αποτελούνταν από 12 κόμβους. Επειδή η “Θέση λίθου” και η “Συνοσηρότητα” όμως παίρνουν περισσότερες από μία τιμές (5 τιμές για κάθε κατηγορία), ο αριθμός των κόμβων στο επίπεδο εισόδου προσαρμόστηκε, ώστε να είναι αρχικά ίσος με 20. Ακόμη, από την στατιστική ανάλυση προέκυψε ότι κάποιες μεταβλητές είναι στατιστικά σημαντικές. Έτσι, το δίκτυο που σχεδιάστηκε στη συνέχεια για τη μελέτη μόνο αυτών, θα περιλαμβάνει στο επίπεδο εισόδου αριθμό κόμβων ίσο με τον αριθμό των ανεξάρτητων μεταβλητών. Ο αριθμός των κόμβων στο επίπεδο εξόδου για το συγκεκριμένο δίκτυο, ορίζεται σε 1. Οι τιμές εξόδου είναι διακριτές και ίσες με 0 ή 1. Στο κρυφό επίπεδο, μετά από δοκιμές πολλαπλών επιλογών, επιλέχθηκε αριθμός κόμβων ίσος με αυτόν του επιπέδου εισόδου. Στα δίκτυα πολλών επιπέδων, η πιο συχνά χρησιμοποιούμενη συνάρτηση μεταφοράς είναι η λογαριθμική σιγμοειδής συνάρτηση μεταφοράς (*logsig*, λογιστική συνάρτηση). Έτσι, για τη μεταφορά και μετατροπή των δεδομένων εισόδου προς το κρυφό επίπεδο χρησιμοποιούμε την *logsig* η οποία δίνει τιμές μεταξύ 0 και +1 αφού το πρόβλημα που μελετάμε ανήκει στην κατηγορία της “αναγνώρισης προτύπων”, οι επιθυμητές έξοδοι είναι διακριτές τιμές και στην περίπτωσή μας είναι δυαδικές (0 ή 1). Η ίδια συνάρτηση επιλέγεται και για την

μεταφορά των δεδομένων από το κρυφό επίπεδο στο επίπεδο εξόδου. Για την εκπαίδευση του δικτύου χρησιμοποιούμε τη συνάρτηση *trainlm* η οποία ανανεώνει τα βάρη (weights) και τις σταθερές (biases), σύμφωνα με τον αλγόριθμο των Levenberg-Marquardt [173]. Η συνάρτηση *trainlm* εκφράζει τον γρηγορότερο αλγόριθμο οπισθοδρομικής μετάδοσης σφάλματος (backpropagation algorithm) και προτείνεται αβίαστα ως πρώτη επιλογή για μάθηση με επιτήρηση, αν και απαιτεί περισσότερη χρήση μνήμης από άλλες σχετικές συναρτήσεις. Η εκπαίδευση θα εκτελεστεί με δεδομένα εξόδου τις τιμές των επιπλοκών για την εκτίμηση της ασφάλειας αρχικά, ενώ στη συνέχεια, με δεδομένα εξόδου τις τιμές του αποτελέσματος της λιθοτριψίας για την εκτίμηση της αποτελεσματικότητας.


Για την περίπτωση της εκτίμησης της ασφάλειας των επιπλοκών, οι 716 ασθενείς χωρίστηκαν σε 2 ομάδες: στην ομάδα εκπαίδευσης του δικτύου που αποτελούνταν από 549 ($=77\% \cdot 716$) ασθενείς και στην ομάδα εκτίμησης με 167 ασθενείς ($=23\% \cdot 716$). Ο επιμερισμός των ασθενών έγινε με χαρακτηριστικά τήρησης της ομοιομορφίας, της αναλογικότητας και της ισοβαρούς κατανομής, ειδικά για την ομάδα εκπαίδευσης. Έτσι, στην ομάδα εκπαίδευσης συμμετέχουν 270 ασθενείς που παρουσίασαν επιπλοκές, έναντι 279 ασθενών που δεν παρουσίασαν. Από τους 270 ασθενείς, οι 152 είναι άντρες και οι 118




Σχήμα 25: Η διαδικασία εκπαίδευσης όπως απεικονίζεται στο MATLAB

γυναίκες ενώ από τους υπόλοιπους 279, οι 156 είναι άντρες και οι 123 γυναίκες. Τα δεδομένα εισήχθησαν στο δίκτυο προς εκπαίδευση, όπως φαίνεται στο Σχήμα 25.


Η εκπαίδευση ορίστηκε να τερματιστεί μετά από 900 επαναλήψεις (epochs) του αλγορίθμου ή όταν επιτευχθεί ποσοστό μεγαλύτερο του 90% στην απόδοση του δικτύου (Απόδοση=Προγνωστικές τιμές/πραγματικές τιμές) καθώς αυτό προγραμματίστηκε ως κατώφλι απόδοσης. Από το Σχήμα 25 λαμβάνουμε πληροφόρηση για τον αριθμό της επανάληψης που βρίσκεται η διαδικασία (468), το χρόνο που απαιτήθηκε για την ολοκλήρωση της εκπαίδευσης, την απόδοση που αφορά το πλήθος των ελαχιστοποιημένων σφαλμάτων που εμφανίζονται κατά τη διάρκεια της εκπαίδευσης (0.0128), τη βαθμίδα (gradient) που δείχνει πόση διακύμανση συμβαίνει στο ρυθμό σφάλματος ($8.56e-08$), την παράμετρος “Mu”, η τιμή της οποίας καθορίζει το μέγιστο αριθμό επιρροής των λαθών για έως 6 επαναλήψεις της διαδικασίας και την παράμετρο “Validation Checks” η οποία υποδεικνύει εάν η τρέχουσα ολοκληρωμένη επανάληψη (εδώ η 468^η) έχει ελαχιστοποιημένο σφάλμα σε σύγκριση με τις προηγούμενες επαναλήψεις. Γενικά οι ρυθμίσεις παρέμειναν στις προκαθορισμένες τιμές τους. Στο Σχήμα 26 εμφανίζεται το γράφημα σύγκλισης της απόδοσης (συνάρτηση *plotperform*), στο Σχήμα 27 εμφανίζεται το γράφημα εξέλιξης των υπολοίπων παραμέτρων της εκπαίδευσης (συνάρτηση *plottrainstate*) και στο Σχήμα 28 η διακύμανση της γραμμικής παλινδρόμησης (συνάρτηση *plotregression*).



Σχήμα 26: Γραφική απεικόνιση της σύγκλισης της απόδοσης (MATLAB)



Σχήμα 27: Γραφική απεικόνιση διακύμανσης παραμέτρων με την ολοκλήρωση της εκπαίδευσης (MATLAB)



Σχήμα 28: Διακύμανση της γραμμικής παλινδρόμησης (MATLAB)

Τα αποτελέσματα της εκπαίδευσης του δικτύου έφτασαν σε απόδοση το 98.72% Για την εύρεση της ευαισθησίας (sensitivity) και της ακρίβειας (specificity) υπολογίστηκαν οι εξής 4 αριθμοί: αληθώς θετικό (true positive ή TP), αληθώς αρνητικό (true negative ή TN), ψευδώς θετικό (false positive ή FP) και ψευδώς αρνητικό (false negative ή FN). Στην στατιστική ορίζουμε ως “ευαισθησία”, την πιθανότητα εύρεσης μίας κατάστασης μέσα σε έναν πληθυσμού όπου υπάρχει η κατάσταση ενώ ορίζουμε ως “ακρίβεια”, την πιθανότητα εύρεσης αυτών που δεν έχουν μία κατάσταση σε έναν πληθυσμό που δεν υπάρχει η κατάσταση. Η ευαισθησία αναφέρεται στην ικανότητα μιας δοκιμής (test) να εντοπίζει σωστά ασθενείς που έχουν μία κατάσταση (π.χ. ασθένεια) και η ακρίβεια σχετίζεται με την ικανότητα μιας δοκιμής να απορρίπτει σωστά τους υγιείς ασθενείς. Επιπλέον, υπολογίστηκαν οι πιθανότητες θετικής πρόγνωσης (positive predictive value) και αρνητικής πρόγνωσης (negative predictive value).

Για την εκτίμηση των αποτελεσμάτων εκπαίδευσης υλοποιήθηκε κώδικας στο MATLAB, ο οποίος αφού “διαβάσει” την παραμετροποίηση του δικτύου (βάρη, σταθερές), όπως αυτή προέκυψε από τη διαδικασία εκπαίδευσης, αξιολογεί την ικανότητα πρόβλεψης του δικτύου χρησιμοποιώντας τη βάση δεδομένων των υπολοίπων 167 ασθενών με τον υπολογισμό της απόδοσης, της ευαισθησίας και της ακρίβειας για την ομάδα των 167 ασθενών που χρησιμοποιήθηκε για εκτίμηση του αποτελέσματος της εκπαίδευσης. Τα αποτελέσματα φαίνονται στον πίνακα που ακολουθεί:


	"Εκπαίδευση" 549 ασθενών	"Εκτίμηση" 167 ασθενών
Απόδοση (performance)	98.72%	81.43%
Ευαισθησία (sensitivity)	98.88%	74.02%
Ακρίβεια (specificity)	98.56%	87.77%
Θετική πρόγνωση (PPV)	98.52%	83.82%
Αρνητική πρόγνωση (NPV)	98.92%	79.79%

Πίνακας 12: Αποτελέσματα εκπαίδευσης και εκτίμησης

Από τα ποσοστά στον Πίνακα 12 προκύπτει πως το τεχνητό νευρωνικό δίκτυο που σχεδιάστηκε, έδωσε ενθαρρυντικά αποτελέσματα για την εκτίμηση των επιπλοκών ασθενών που υποβάλλονται σε εξωσωματική λιθοτριψία, έχοντας ως δεδομένα εισόδου τις τιμές από 12 κατηγορίες ιατρικών δεδομένων.

Από την στατιστική ανάλυση που προηγήθηκε (§14.1), προέκυψαν 4 κατηγορίες μεταβλητών που εμφανίζουν συσχέτιση με το αποτέλεσμα (στατιστική σημαντικότητα): ο σακχαρώδης διαβήτης, η προηγούμενη θεραπεία, η αναλγησία και η υδρονέφρωση. Αυτές οι

4 μεταβλητές, μαζί με το φύλο και την ηλικία των ασθενών, θα εισαχθούν σε ένα νέο τεχνητό νευρωνικό δίκτυο, σε αναλογία με το προηγούμενο, για την εκτίμηση της ασφάλειας της λιθοτριψίας (επιπλοκές) και τη σύγκριση των αποτελεσμάτων των 2 δικτύων. Συγκεκριμένα, το νέο δίκτυο θα αποτελείται και αυτό από 3 επίπεδα (εισόδου, κρυφό, εξόδου), θα έχει τις ίδιες συναρτήσεις μεταφοράς όπως και το προηγούμενο και θα εκπαιδευτεί με τον ίδιο αλγόριθμο εκπαίδευσης (Levenberg-Marquardt) (Σχήμα 29). Η διαφορά τους θα βρίσκεται



Σχήμα 29: Απεικόνιση τεχνητού νευρωνικού δικτύου με 3 επίπεδα και 6 μεταβλητές εισόδου

στο πλήθος των κόμβων εισόδου (6 αντί για 20) και στο πλήθος των κόμβων στο κρυφό επίπεδο που θα είναι επίσης 6 (αντί για 20). Η ομάδα εκπαίδευσης του δικτύου θα αποτελείται από τους ίδιους ασθενείς ενώ τα δεδομένα που θα εισαχθούν στο δίκτυο θα είναι μόνο οι 6 κατηγορίες που προέκυψαν από την στατιστική ανάλυση. Η ομάδα εκτίμησης θα αποτελείται από τους υπόλοιπους 167 ασθενείς όπως προηγουμένως, επίσης με τις αντίστοιχες 6 κατηγορίες δεδομένων μόνο. Τα δεδομένα εισάγονται στο νέο δίκτυο και προκύπτουν τα παρακάτω αποτελέσματα:

	"Εκπαίδευση" 549 ασθενών	"Εκτίμηση" 167 ασθενών
Απόδοση (performance)	74.13%	68.86%
Εναισθησία (sensitivity)	71.85%	66.23%
Ακρίβεια (specificity)	76.34%	71.11%
Θετική πρόγνωση (PPV)	74.61%	66.23%
Αρνητική πρόγνωση (NPV)	73.70%	71.11%

Πίνακας 13:

Αποτελέσματα εκπαίδευσης και εκτίμησης των μεταβλητών που προέκυψαν από την στατιστική ανάλυση ως "σημαντικές"

Από τα ποσοστά στον Πίνακα 13 προκύπτει πως το τεχνητό νευρωνικό δίκτυο που σχεδιάστηκε, έδωσε στατιστικώς ενδιαφέροντα αποτελέσματα για την εκτίμηση της ασφάλειας της λιθοτριψίας ως μέθοδος επιλογής ασθενών που υποβάλλονται σε εξωσωματική λιθοτριψία, έχοντας ως δεδομένα εισόδου τις τιμές από 6 κατηγορίες ιατρικών δεδομένων.


Για την περίπτωση της εκτίμησης του αποτελέσματος της εξωσωματικής λιθοτριψίας, οι 716 ασθενείς χωρίστηκαν, όπως και προηγουμένως, σε 2 ομάδες: στην ομάδα εκπαίδευσης του δικτύου και στην ομάδα εκτίμησης. Από τους 716 ασθενείς, οι 508 είχαν επιτυχή θρυμματισμό του λίθου και απομάκρυνσή του από το ουροποιητικό σύστημα ενώ για τους υπόλοιπους 208 δεν στέφθηκε με επιτυχία η διαδικασία. Επειδή ο επιμερισμός των ασθενών θα πρέπει να έχει χαρακτηριστικά ομοιομορφίας, αναλογικότητας και ισοβαρούς κατανομής βάσει κάποιων χαρακτηριστικών τους, ειδικά για την ομάδα εκπαίδευσης, θα κάνουμε επιλογή ασθενών καθώς υπάρχει σημαντική απόκλιση του δείγματος. Έτσι, από τους 208 ασθενείς παίρνουμε τους 167 (το 80%) ως ένα τμήμα για τη δημιουργία της ομάδας εκπαίδευσης. Αντίστοιχα, παίρνουμε άλλους 167 ασθενείς από τους 508. Έτσι η ομάδα για εκπαίδευση θα αποτελείται από 334 ασθενείς. Η επιλογή των ασθενών δεν γίνεται τυχαία καθώς φροντίζουμε επιπλέον ώστε το 50% των ασθενών κάθε ομάδας να έχει εμφανίσει επιπλοκές και το υπόλοιπο 50% να μην έχει εμφανίσει. Έτσι, στην ομάδα εκπαίδευσης συμμετέχουν 83 ασθενείς που παρουσίασαν επιπλοκές με επιτυχή θρυμματισμό λίθου, 84 ασθενείς που παρουσίασαν επιπλοκές με αποτυχία θρυμματισμού λίθου, 84 ασθενείς με επιτυχή θρυμματισμό λίθου χωρίς επιπλοκές και 83 ασθενείς με αποτυχία θρυμματισμό λίθου χωρίς επιπλοκές. Ο επιμερισμός φαίνεται στον πίνακα που ακολουθεί:

ΑΣΘΕΝΕΙΣ	Επιτυχής θρυμματισμός λίθου	Αποτυχία θρυμματισμό λίθου
Εμφάνισαν επιπλοκές	83	84
Δεν εμφανισαν επιπλοκές	84	83
	167	167

Πίνακας 14:


Επιμερισμός των ασθενών για τη δημιουργία της βάσης δεδομένων εκπαίδευσης

Από τους 334 ασθενείς, οι 188 είναι άντρες και οι 146 γυναίκες. Τα δεδομένα εισήχθησαν στο δίκτυο προς εκπαίδευση, όπως φαίνεται στο Σχήμα 30:




Σχήμα 30: Η διαδικασία εκπαίδευσης του ΤΝΔ στο MATLAB


Η εκπαίδευση ορίστηκε να τερματιστεί μετά από 900 επαναλήψεις (epochs) του αλγορίθμου ή όταν επιτευχθεί ποσοστό μεγαλύτερο του 90% στην απόδοση του δικτύου (Απόδοση=Προγνωστικές τιμές/πραγματικές τιμές) καθώς αυτό προγραμματίστηκε ως κατώφλι απόδοσης. Από το Σχήμα 30 λαμβάνουμε πληροφόρηση για τον αριθμό της επανάληψης που βρίσκεται η διαδικασία (466), το χρόνο που απαιτήθηκε για την ολοκλήρωση της εκπαίδευσης, την απόδοση που αφορά το πλήθος των ελαχιστοποιημένων σφαλμάτων που εμφανίζονται κατά τη διάρκεια της εκπαίδευσης (0.00997), τη βαθμίδα (gradient) που δείχνει πόση διακύμανση συμβαίνει στο ρυθμό σφάλματος (0.758) και την παράμετρος “Mu”, η τιμή της οποίας καθορίζει το μέγιστο αριθμό επιρροής των λαθών για έως 6 επαναλήψεις της διαδικασίας. Γενικά οι ρυθμίσεις παρέμειναν στις προκαθορισμένες τιμές τους. Στο Σχήμα 31 εμφανίζεται το γράφημα σύγκλισης της απόδοσης (συνάρτηση *plotperform*), στο Σχήμα 32 εμφανίζεται το γράφημα εξέλιξης των υπολοίπων παραμέτρων της εκπαίδευσης (συνάρτηση *plottrainstate*) και στο Σχήμα 33 η διακύμανση της γραμμικής παλινδρόμησης (συνάρτηση *plotregression*).



Σχήμα 31: Γραφική απεικόνιση της σύγκλισης της απόδοσης (MATLAB)



Σχήμα 32: Γραφική απεικόνιση διακύμανσης παραμέτρων με την ολοκλήρωση της εκπαίδευσης (MATLAB)



Σχήμα 33: Διακύμανση της γραμμικής παλινδρόμησης (MATLAB)

Τα αποτελέσματα της εκπαίδευσης του δικτύου έφτασαν σε απόδοση το 99.1%. Για την εκτίμηση της ευαισθησίας (sensitivity) και της ακρίβειας (specificity) υπολογίστηκαν οι αριθμοί αληθώς θετικό (true positive ή TP), αληθώς αρνητικό (true negative ή TN), ψευδώς θετικό (false positive ή FP) και ψευδώς αρνητικό (false negative ή FN). Επιπλέον, υπολογίστηκαν οι πιθανότητες θετικής πρόγνωσης (positive predictive value) και αρνητικής πρόγνωσης (negative predictive value).


Για την εκτίμηση των αποτελεσμάτων εκπαίδευσης χρησιμοποιήθηκε ο προηγούμενος κώδικας στο MATLAB, ο οποίος αφού “διαβάσει” την παραμετροποίηση του δικτύου (βάρη, σταθερές), όπως αυτή προέκυψε από τη διαδικασία εκπαίδευσης, αξιολογεί την ικανότητα πρόβλεψης του δικτύου χρησιμοποιώντας τη βάση δεδομένων των υπολοίπων 84 ασθενών με τον υπολογισμό της απόδοσης, της ευαισθησίας και της ακρίβειας για την ομάδα των 84 ασθενών που χρησιμοποιήθηκε για εκτίμηση του αποτελέσματος της εκπαίδευσης. Τα αποτελέσματα φαίνονται στον πίνακα που ακολουθεί:

	"Εκπαίδευση" 334 ασθενών	"Εκτίμηση" 84 ασθενών
Απόδοση (performance)	99.1%	75%
Ευαισθησία (sensitivity)	99.4%	71.18%
Ακρίβεια (specificity)	98.8%	84%
Θετική πρόγνωση (PPV)	98.8%	91.3%
Αρνητική πρόγνωση (NPV)	99.39%	55.26%

Πίνακας 15: Αποτελέσματα εκπαίδευσης και εκτίμησης

Από τα ποσοστά στον Πίνακα 15 προκύπτει πως το τεχνητό νευρωνικό δίκτυο που σχεδιάστηκε, έδωσε ενθαρρυντικά αποτελέσματα για την εκτίμηση της αποτελεσματικότητας της εξωσωματικής λιθοτριψίας, σε ασθενείς που υποβάλλονται σε αυτήν, έχοντας ως δεδομένα εισόδου τις τιμές από 12 κατηγορίες ιατρικών δεδομένων.

Από την στατιστική ανάλυση που προηγήθηκε (§14.1), προέκυψαν 5 κατηγορίες μεταβλητών που εμφανίζουν συσχέτιση με το αποτέλεσμα (στατιστική σημαντικότητα): η ύπαρξη λίθου στον δεξιό ουρητήρα, το μέγεθος λίθου, ο αριθμός των κρούσεων, η ένταση των κρούσεων και η ύπαρξη pig-tail. Οι 5 μεταβλητές, μαζί με το φύλο και την ηλικία των ασθενών, θα εισαχθούν σε ένα νέο τεχνητό νευρωνικό δίκτυο, σε αναλογία με το προηγούμενο, για την εκτίμηση του αποτελέσματος της λιθοτριψίας και τη σύγκριση των αποτελεσμάτων των 2 δικτύων. Συγκεκριμένα, το νέο δίκτυο θα αποτελείται και αυτό από 3 επίπεδα (εισόδου, κρυφό, εξόδου), θα έχει τις ίδιες συναρτήσεις μεταφοράς όπως και το προηγούμενο και θα εκπαιδευτεί με τον ίδιο αλγόριθμο (Levenberg-Marquardt) (Σχήμα 34).



Σχήμα 34: Απεικόνιση τεχνητού νευρωνικού δικτύου με 3 επίπεδα και 7 μεταβλητές εισόδου

Η διαφορά τους θα βρίσκεται στο πλήθος των κόμβων εισόδου (7 αντί για 20) και στο πλήθος των κόμβων στο κρυφό επίπεδο που θα είναι επίσης 7 (αντί για 20). Η ομάδα εκπαίδευσης του δικτύου θα αποτελείται από τους ίδιους 334 ασθενείς ενώ τα δεδομένα που θα εισαχθούν στο δίκτυο θα είναι μόνο οι 7 κατηγορίες που προέκυψαν από την στατιστική ανάλυση. Η ομάδα εκτίμησης θα αποτελείται από τους υπόλοιπους 84 ασθενείς όπως προηγουμένως, επίσης με τις αντίστοιχες 7 κατηγορίες δεδομένων μόνο. Τα δεδομένα εισάγονται στο νέο δίκτυο και προκύπτουν τα παρακάτω αποτελέσματα:

	"Εκπαίδευση" 334 ασθενών	"Εκτίμηση" 84 ασθενών
Απόδοση (performance)	92.81%	59.52%
Ευαισθησία (sensitivity)	93.41%	55.93%
Ακρίβεια (specificity)	92.21%	68%
Θετική πρόγνωση (PPV)	92.3%	80.48%
Αρνητική πρόγνωση (NPV)	93.33%	39.53%

Πίνακας 16:

Αποτελέσματα εκπαίδευσης και εκτίμησης των μεταβλητών που προέκυψαν από την στατιστική ανάλυση ως "σημαντικές"

Από τα ποσοστά στον Πίνακα 16 προκύπτει πως το τεχνητό νευρωνικό δίκτυο που σχεδιάστηκε, έδωσε στατιστικώς ενδιαφέροντα αποτελέσματα για την εκτίμηση της ασφάλειας της λιθοτριψίας ως μέθοδος επιλογής ασθενών που υποβάλλονται σε εξωσωματική λιθοτριψία, έχοντας ως δεδομένα εισόδου τις τιμές από 6 κατηγορίες ιατρικών δεδομένων.

14.3 Σύγκριση αποτελεσμάτων έρευνας

Για την εκτίμηση τόσο της ασφάλειας της εξωσωματικής λιθοτριψίας όσο και της αποτελεσματικότητας της μεθόδου, ελήφθησαν υπόψη τα αποτελέσματα της στατιστικής ανάλυσης τα οποία εφαρμόστηκαν σε τεχνητό νευρωνικό δίκτυο. Η στατιστική ανάλυση που έγινε αρχικά μονοπαραγοντικά στα 20 χαρακτηριστικά των 716 ασθενών του δείγματος, έδωσε 4 από αυτά με στατιστική σημαντικότητα σε σχέση με το αποτέλεσμα (επιπλοκές). Η εκπαίδευση του δικτύου με δεδομένα εισόδου τις 20 μεταβλητές, έδωσε πολύ υψηλό ποσοστό σύγκλισης (απόδοση 98.72%) μεταξύ πραγματικών και υπολογιζόμενων τιμών εξόδου ενώ το ίδιο δίκτυο, με δεδομένα εισόδου 6 στατιστικά σημαντικών μεταβλητών έδωσε ικανοποιητικό ποσοστό σύγκλισης (απόδοση 74.13%). Παρατηρείται μία απόκλιση της τάξης του 24.59% μεταξύ των 2 υπολογισμών ενώ δεν είναι εμφανής ο λόγος αυτής της διαφοράς, τη στιγμή που από τη γενικότερη συμπεριφορά του δικτύου στη συνέχεια, προκύπτει ότι η εκπαίδευση δεν αναμένεται να τερματιστεί με ποσοστό μικρότερο του 90%.

Η εκτίμηση της εκπαίδευσης του δικτύου και κατά συνέπεια, η αξιολόγηση του σχεδιασμού του, έδωσε στην πρώτη περίπτωση υψηλό ποσοστό σύγκλισης (απόδοση 81.43% ή πρόβλεψη 4 στους 5 ασθενείς) ενώ στην περίπτωση των στατιστικά σημαντικών μεταβλητών έδωσε ικανοποιητικό ποσοστό σύγκλισης (απόδοση 68.86% ή πρόβλεψη 2 στους 3 ασθενείς).

Στην περίπτωση της αποτελεσματικότητας της εξωσωματικής λιθοτριψίας, η στατιστική ανάλυση στα 20 χαρακτηριστικά των 716 ασθενών του δείγματος, έδωσε 5 από αυτά με στατιστική σημαντικότητα σε σχέση με το αποτέλεσμα (θρυμματισμός λίθου). Επειδή προέκυψε ανισοκατανομή του πληθυσμού όσον αφορά τα αποτελέσματα της μεθόδου (ESWL), η έρευνα συνεχίστηκε σε δείγμα 418 ασθενών από τον ίδιο πληθυσμό, ομοιόμορφα κατανομημένο ως προς το αποτέλεσμα. Έτσι, η εκπαίδευση του δικτύου με δεδομένα εισόδου τις 20 μεταβλητές, έδωσε πολύ υψηλό ποσοστό σύγκλισης (απόδοση 99.1%) μεταξύ πραγματικών και υπολογιζόμενων τιμών εξόδου ενώ το ίδιο δίκτυο, με δεδομένα εισόδου 7 στατιστικά σημαντικών μεταβλητών έδωσε επίσης υψηλό ποσοστό σύγκλισης (απόδοση 92.81%). Η εκτίμηση της εκπαίδευσης του δικτύου και κατά συνέπεια, η αξιολόγηση του σχεδιασμού του, έδωσε στην πρώτη περίπτωση πολύ καλό ποσοστό σύγκλισης (απόδοση 75% ή πρόβλεψη 3 στους 4 ασθενείς) ενώ στην περίπτωση των στατιστικά σημαντικών μεταβλητών έδωσε ικανοποιητικό ποσοστό σύγκλισης (απόδοση 59.52% ή πρόβλεψη 3 στους 5 ασθενείς).

15. ΣΥΖΗΤΗΣΗ – ΣΥΜΠΕΡΑΣΜΑΤΑ

Από τη σύγκριση των αποτελεσμάτων της έρευνας προκύπτει αρχικά ότι η στατιστική ανάλυση έδωσε συσχετίσεις μεταξύ των δεδομένων οι οποίες είναι λογικά και ιατρικά αποδεκτές. Έτσι, στην περίπτωση των δεδομένων των ασθενών για τους οποίους εξετάστηκε η αποτελεσματικότητα της μεθόδου, η στατιστική ανάλυση διέκρινε ορθά την σημαντικότητα και την συσχέτιση με το αποτέλεσμα της θέσης του λίθου και του μεγέθους του. Θα ήταν στατιστικά παράδοξο να μην υπήρχαν οι 2 αυτές μεταβλητές στις στατιστικά σημαντικές. Ακόμη, από το πλήθος των δεδομένων που εισάγονται στο τεχνητό νευρωνικό δίκτυο προκύπτει αβίαστα το συμπέρασμα ότι περισσότερα δεδομένα δίνουν καλύτερα αποτελέσματα. Και στις 2 περιπτώσεις που εξετάσαμε, το τεχνητό νευρωνικό δίκτυο ανταποκρίθηκε επιτυχώς στην πρόβλεψη των αποτελεσμάτων δίνοντας ποσοστά επιτυχίας 81.43% για τις επιπλοκές και 75% για το αποτέλεσμα της λιθοτριψίας.

Στην αξιολόγηση και ερμηνεία των αποτελεσμάτων που λάβαμε από το ΤΝΔ θα πρέπει αναπόφευκτα να λάβουμε υπόψη τις παραμέτρους σχεδίασης του. Για να σχεδιαστεί ένα νευρωνικό δίκτυο με καλές/αποδεκτές επιδόσεις, πρέπει να υπάρχει διαθέσιμη επαρκής ποσότητα πειραματικών δεδομένων. Επίσης, κατά τη διάρκεια τόσο της διαδικασίας εκπαίδευσης (*training*) όσο και της εκτίμησης (*evaluation*), η δομή, ο αλγόριθμος μάθησης καθώς και άλλες παράμετροι του νευρωνικού δικτύου θα πρέπει να βελτιστοποιηθούν για το συγκεκριμένο πρόβλημα που εξετάζεται. Όταν το δίκτυο έχει επαρκώς βελτιστοποιηθεί με τα συγκεκριμένα δεδομένα, τότε είναι δυνατόν να παραχθούν ικανοποιητικά αποτελέσματα όταν δοκιμαστούν νέα δεδομένα εισόδου που δεν έχουν χρησιμοποιηθεί ξανά [47].

Ο αριθμός των νευρώνων στο κρυφό επίπεδο αυξάνει τον αριθμό των συνδέσεων και κατ' αναλογία τα βάρη που πρέπει να υπολογιστούν. Αυτός ο αριθμός δεν μπορεί να αυξηθεί χωρίς περιορισμούς διότι μπορεί να φτάσουμε σε μία κατάσταση όπου θα ξεπεραστούν τα διαθέσιμα για εκπαίδευση ζεύγη δεδομένων. Αν και το νευρωνικό δίκτυο θα μπορεί ακόμη να εκπαιδευτεί, οδηγεί σε μαθηματική απροσδιοριστία. Στα Μαθηματικά, δεν είναι δυνατόν να προσδιοριστούν περισσότερες παράμετροι προσαρμογής από τα διαθέσιμα σημεία δεδομένων. Για παράδειγμα, απαιτούνται τουλάχιστον δύο σημεία για την γραφική απεικόνιση της γραμμικής παλινδρόμησης (ευθεία γραμμή), τρία τουλάχιστον σημεία για την γραφική απεικόνιση ενός πολυωνύμου δευτέρου βαθμού (παραβολή) και ούτω καθεξής. Στην πράξη, για αξιόπιστη απόδοση της παλινδρόμησης, χρησιμοποιούνται περισσότερα σημεία από τον ελάχιστο αριθμό που απαιτείται, με σκοπό την αύξηση της στατιστικής σημαντικότητας. Εάν για παράδειγμα, πάρουμε δύο μόνο σημεία για να καθορίσουμε την κλίση μέσω γραμμικής παλινδρόμησης, το τυπικό σφάλμα της κλίσης που υπολογίζεται θα τείνει στο άπειρο (πολύ μεγάλο) [160,161]. Έτσι, η κλίση που υπολογίζεται με δύο σημεία δεν έχει στατιστική σημασία και οδηγεί σε λάθη [47].

Για πολλά πολυπαραγοντικά και περίπλοκα προβλήματα είναι δύσκολο να ποσοτικοποιηθεί με ακρίβεια η σχέση μεταξύ των δύο ομάδων δεδομένων (δεδομένα εισόδου και δεδομένα εξόδου) αποκλειστικά από φυσικές αρχές και κατά συνέπεια, τα βάρη που υπολογίζονται δεν είναι εφικτό να αποδοθούν σύμφωνα με φυσικές αρχές. Αντιθέτως, τα βάρη πρέπει να προσδιοριστούν από την εκπαίδευση του δικτύου, με τη βοήθεια ενός προκαθορισμένου εύρους τιμών καθώς έχουν ήδη οριστεί τα ιδανικά αποτελέσματα (τιμές στόχοι). Με τον τρόπο αυτό, το δίκτυο μαθαίνει τη σχέση από τα δεδομένα εκπαίδευσης. Η εκπαίδευση επιτυγχάνεται με τη συνεχή ρύθμιση των βαρών, μέχρι να ελαχιστοποιηθεί η

διαφορά μεταξύ των πραγματικών τιμών εξόδου του δικτύου και των τιμών στόχων. Αυτό ακριβώς είναι ένα πολυπαραγοντικό, μη γραμμικό πρόβλημα βελτιστοποίησης. Το δίκτυο στην πραγματικότητα, δεν λαμβάνει καμία πληροφορία για τα χαρακτηριστικά του εύρους τιμών που να σχετίζονται με την ταξινόμηση. Αυτή η πληροφόρηση προκύπτει από την εκπαίδευση των δεδομένων εισόδου. Ουσιαστικά, η μόνη υπόθεση που κάνει το δίκτυο για το πρόβλημα είναι ότι οι τιμές εξόδου προκύπτουν με κάποια φυσική συνάρτηση των δεδομένων εισόδου [48].

Η βέλτιστη αρχιτεκτονική του δικτύου εξαρτάται από την πολυπλοκότητα των σχέσεων που θα εφαρμοστούν στο μοντέλο. Γενικά, οι περιοχές εμφάνισης σφάλματος που συναντώνται στην ποσοτική ανάλυση είναι λιγότερο πολύπλοκες από εκείνες που χρησιμοποιούνται στην ποιοτική ανάλυση. Οι μεθοδολογίες για τον προσδιορισμό του βέλτιστου αριθμού κρυμμένων επιπέδων μπορούν να χωριστούν σε δύο ομάδες. Η μία ξεκινά από ένα απλό δίκτυο με ένα κρυμμένο επίπεδο και σταδιακά αυξάνεται η πολυπλοκότητα μέχρι να βρεθεί η βέλτιστη αρχιτεκτονική. Η άλλη ομάδα, προσπαθεί να πετύχει τη βέλτιστη αρχιτεκτονική κινούμενη προς την αντίθετη κατεύθυνση. Ξεκινά από ένα μεγάλο δίκτυο με πολλά κρυμμένα επίπεδα, παρατηρώντας τις συνέπειες μείωσης των κρυφών επιπέδων καθώς και των συνδέσεων μεταξύ των κόμβων. Και στις δύο περιπτώσεις πρέπει να εκτελεστεί ένας τεράστιος αριθμός περιττών υπολογισμών στην προσπάθεια να επιτευχθεί το βέλτιστο. Ωστόσο, για πολλές πρακτικές εφαρμογές, μία τέτοια εκτενής αναζήτηση της βέλτιστης αρχιτεκτονικής του δικτύου, δεν είναι δικαιολογημένη. Γενικά, χρησιμοποιείται ένας εμπειρικός κανόνας, σύμφωνα με τον οποίο ο αριθμός των ρυθμιζόμενων παραμέτρων μπορεί να είναι περίπου το μισό του αριθμού των δειγμάτων [162].

Στη διεθνή βιβλιογραφία (ELSEVIER, Science Direct, κα.) δεν βρέθηκαν μελέτες που να προσεγγίζουν την εξωσωματική λιθοτριψία και τα αποτελέσματά της με τον τρόπο που μελετήθηκαν και αναπτύχθηκαν στην παρούσα διατριβή. Στις δημοσιεύσεις που ακολουθούν παρουσιάζονται εν συντομία τα στοιχεία τους, ώστε ο αναγνώστης να έχει ολοκληρωμένη άποψη για την έρευνα σχετικά με το αντικείμενο μελέτης:

Το 1998, οι MICHAELS et al. δημοσίευσαν μία έρευνα σε δείγμα 98 ασθενών, με λίθο στο ουροποιητικό σύστημα, όπου ο σκοπός ήταν η πρόβλεψη επανεμφάνισης λίθου μετά από εξωσωματική λιθοτριψία ή ενδεχόμενη αύξηση μεγέθους του. Σχεδίασαν τεχνητό νευρωνικό δίκτυο και χώρισαν τους ασθενείς σε μία ομάδα εκπαίδευσης με 65 ασθενείς και μία ομάδα εκτίμησης με 33 ασθενείς. Για κάθε ασθενή υπήρχαν καταγεγραμμένα ιατρικά

δεδομένα όπως η θέση του λίθου, προηγούμενη θεραπεία, λήψη φαρμακευτικής αγωγής, ανωμαλίες μεταβολισμού, σύσταση λίθου (;) κα. Προηγήθηκε στατιστική ανάλυση των δεδομένων με το Wilk's GLR test όπου δεν βρέθηκε καμία στατιστικά σημαντική μεταβλητή. Η ομάδα εκτίμησης έδωσε απόδοση ίση με 91%, ευαισθησία 91% και ακρίβεια 92% [181].

Οι CUMMINGS et al., δημοσίευσαν το 2000 έρευνα σε δείγμα 181 ασθενών με λίθο στο ουροποιητικό σύστημα, όπου ο σκοπός ήταν η πρόβλεψη του ποσοστού των ασθενών που χρειάζονται εξωσωματική λιθοτριψία σε σχέση με το ποσοστό εκείνων των ασθενών που απέβαλλαν το λίθο χωρίς ιατρική παρέμβαση. Σχεδίασαν τεχνητό νευρωνικό δίκτυο και χώρισαν τους ασθενείς σε μία ομάδα εκπαίδευσης με 125 ασθενείς και μία ομάδα εκτίμησης με 55 ασθενείς. Για κάθε ασθενή υπήρχαν καταγεγραμμένα ιατρικά δεδομένα όπως το φύλο, η ηλικία, η φυλή, η οικογενειακή κατάσταση, η θέση του λίθου, προηγούμενη θεραπεία, υδρονέφωση, επιπλοκές κα. Δεν έγινε κανενός είδους στατιστική ανάλυση των δεδομένων. Η ομάδα εκτίμησης έδωσε απόδοση ίση με 76%, εκ του οποίου προβλέφθηκε το 57% των ασθενών που χρειάστηκε ESWL ενώ προβλέφθηκαν σε ποσοστό 100% οι ασθενείς που απέβαλλαν το λίθο φυσιολογικά [182].

Το 2003, οι HAMID et al. δημοσίευσαν μία έρευνα σε δείγμα 82 ασθενών με λίθο στο ουροποιητικό σύστημα, όπου ο σκοπός ήταν η πρόβλεψη του ποσοστού των ασθενών που επιτυχώς θρυμματίστηκε ο λίθος με εξωσωματική λιθοτριψία, σε ένα προκαθορισμένο εύρος κρούσεων. Όλοι οι ασθενείς είχαν επιτυχή θρυμματισμό του λίθου με το πέρας της διαδικασίας. Σχεδίασαν τεχνητό νευρωνικό δίκτυο και χώρισαν τους ασθενείς σε μία ομάδα εκπαίδευσης με 60 ασθενείς και μία ομάδα εκτίμησης με 22 ασθενείς. Για κάθε ασθενή υπήρχαν καταγεγραμμένα ιατρικά δεδομένα όπως το φύλο, η ηλικία, το μέγεθος του λίθου, υδρονέφωση, ένταση, αριθμός κρούσεων, ουρολογικές μετρήσεις κα. Δεν πραγματοποιήθηκε κανενός είδους στατιστική ανάλυση των δεδομένων. Η ομάδα εκτίμησης έδωσε απόδοση ίση με 77.27% στην επιτυχή πρόβλεψη των ασθενών των οποίων θρυμματίστηκε ο λίθος όταν ο αριθμός κρούσεων ήταν <13000 κρούσεις/λίθο [183].

Η πιο σχετική δημοσίευση έγινε από τους MOHAMED G. et al. το 2004, όπου πραγματοποιήθηκε έρευνα σε δείγμα 984 ασθενών που υπεβλήθησαν σε εξωσωματική λιθοτριψία. 919 από αυτούς βρέθηκαν χωρίς λίθο με το πέρας της διαδικασίας. Σκοπός της μελέτης ήταν η σύγκριση των αποτελεσμάτων πρόγνωσης μεταξύ ενός στατιστικού μοντέλου που ανέπτυξαν και ενός ΤΝΔ. Συγκεντρώθηκαν ιατρικά δεδομένα των ασθενών

όπως η ηλικία, το φύλο, η θέση του λίθου, το μέγεθος του λίθου, η νεφρική ανατομία, η ύπαρξη pig-tail, προηγούμενη θεραπεία κα. Στα δεδομένα έγινε στατιστική ανάλυση η οποία έδωσε μόνο μία στατιστικά σημαντική μεταβλητή, τη θέση του λίθου. Οι συγγραφείς συμπεριέλαβαν ως στατιστικά σημαντική και την ύπαρξη pig-tail αν και έδωσε $p\text{-value}=0.86<0.05$. Σχεδίασαν τεχνητό νευρωνικό δίκτυο και χώρισαν τους ασθενείς σε μία ομάδα εκπαίδευσης με 688 ασθενείς και μία ομάδα εκτίμησης με 296 ασθενείς. Υπολόγισαν τις τιμές της απόδοσης, της ευαισθησίας, της ακρίβειας, της θετικής και της αρνητικής πρόγνωσης τόσο με την μέθοδο της στατιστικής ανάλυσης που ακολούθησαν όσο και με το τεχνητό νευρωνικό δίκτυο. Τα αποτελέσματά τους από τη στατιστική ανάλυση και το ΤΝΔ ήταν 93.2% και 77.7% για την απόδοση, 100% και 77.9% για την ευαισθησία, 0% και 75% για την ακρίβεια και 93.2% και 97.2% για τη θετική πρόγνωση αντίστοιχα [184].

Οι Neeraj K. G. et al., δημοσίευσαν το 2010 έρευνα σε δείγμα 276 ασθενών με λίθο στο ουροποιητικό σύστημα, οι οποίοι υπεβλήθησαν σε εξωσωματική λιθοτριψία. Σκοπός της έρευνας ήταν να ελεγχθεί η ακρίβεια πρόβλεψης της έντασης των κρούσεων καθώς και ο αριθμός των κρούσεων χρησιμοποιώντας μεθόδους στατιστικής ανάλυσης και τεχνητής νοημοσύνης. Για αυτό το λόγο, το τεχνητό νευρωνικό δίκτυο που σχεδιάστηκε είχε 2 εξόδους. Όλοι οι ασθενείς βρέθηκαν χωρίς λίθο μετά από την εφαρμογή της εξωσωματικής λιθοτριψίας. 196 ασθενείς αποτέλεσαν την ομάδα εκπαίδευσης και 80 την ομάδα εκτίμησης. Τα ιατρικά δεδομένα που συγκεντρώθηκαν ήταν η ηλικία, το μέγεθος λίθου, διάφορα χαρακτηριστικά του λίθου, το pH των ούρων και ο αριθμός επαναλήψεων του λιθοτρίπτη. [185]. Οι συγγραφείς υπολόγισαν τους συντελεστές συσχέτισης (coefficient of correlation) μεταξύ των μεταβλητών εισόδου-εξόδου για να εξετάσουν τυχόν μεταβολές των τιμών τους. Κατά την πολυπαραγοντική στατιστική ανάλυση χρησιμοποίησαν όλες τις μεταβλητές για τη δημιουργία των 2 εξισώσεων. Τα αποτελέσματα της έρευνας έδωσαν καλύτερες τιμές του συντελεστή συσχέτισης με το τεχνητό νευρωνικό δίκτυο παρά με τη στατιστική ανάλυση.

Όπως προκύπτει από τις παραπάνω δημοσιευμένες έρευνες, όλοι οι ερευνητές προσδιορίζουν με δικά τους κριτήρια τον στόχο της κάθε έρευνας και τον προσεγγίζουν με διαφορετικές εφαρμογές των εργαλείων που τους δίνονται, τόσο από την πλευρά της στατιστικής επιστήμης όσο και των μηχανογραφικών εφαρμογών. Στην παρούσα διατριβή χρησιμοποιήθηκε ερευνητική μεθοδολογία ευρέως αποδεκτή και υποστηριζόμενη από πλήθος υπολογιστικών προγραμμάτων (π.χ. SPSS, MATLAB). Στον σχεδιασμό και υλοποίηση του τεχνητού νευρωνικού δικτύου χρησιμοποιήθηκαν οι πλέον βασικές μαθηματικές συναρτήσεις ενώ έγινε προσπάθεια να αποφευχθούν περίπλοκες

προγραμματιστικές δομές στην ανάπτυξη του αλγορίθμου. Το τεχνητό νευρωνικό δίκτυο θα μπορούσε να βελτιωθεί με διαφορετική αρχιτεκτονική (αριθμός επιπέδων και κόμβων), διαφορετικές συναρτήσεις μεταφοράς καθώς και εναλλακτικών αλγορίθμων μάθησης. Επιπλέον, μεγαλύτερος αριθμός δεδομένων εισόδου είναι σίγουρο ότι θα βελτιώσει την διαδικασία εκπαίδευσης του δικτύου και θα δώσει μεγαλύτερες ομάδες δεδομένων για εκτίμηση και έλεγχο.

16. ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] Bain, A, (1873), "*Mind and Body. The theories of their relation*", D. Appleton & Co, NY.
- [2] James, W, (1891), "*Psychology (briefer course)*", Holt, New York, USA.
- [3] McCulloch, W.S., Pitts, W., (1943), "*A logical calculus immanent in nervous activity*", Bulletin of Mathematical Biophysics 5, pp. 115-133.
- [4] Turing, A. M., (1937), [Delivered to the Society in November 1936], "*On Computable Numbers, with an Application to the Entscheidungs problem*". Proceedings of the London Mathematical Society. 2 42. pp. 23-65, London, UK.
- [5] Aleksander, I & Morton, H., (2012), "*Aristotle's laptop: the discovery of our informational mind*", World Scientific Publishing, Singapore.
- [6] Santiago Ramón y Cajal (2013) "*Les nouvelles idées sur la structure du système nerveux chez l'homme et chez les vertébrés*", ISBN-10: 2012898157, ISBN-13: 978-2012898158.
- [7] Hebb, D.O. (1949). (2002). "*The Organization of Behavior: A Neuropsychological Theory.*" Lawrence Erlbaum. ISBN: 978-0805843002.
- [8] Hodgkin, A. L. & Huxley, A. F., (1952), "*A quantitative description of membrane current and its application to conduction and excitation in nerve*". Journal of Physiology 117 (4), pp. 500-544.
- [9] Rosenblatt F. (1957), "*The Perceptron: A perceiving and recognizing automaton (Project PARA)*", Report no. 85-460-1, Cornell Aeronautical Laboratory Inc., Buffalo N.Y.
- [10] Rosenblatt F. (1961), "*Principles of neurodynamics: Perceptions and the theory of brain mechanism.*" Spartan Books. Washington, DC.
- [11] Minsky, M & Papert, S., (1969), "*Perceptrons: An introduction to Computational Geometry*", ISBN: 9780262130431, The MIT Press.
- [12] Hopfield, JJ., (1982), "*Neural networks and physical systems with emergent collective computational abilities*", Proc. Nat. Acad. Sci. 79 (8), pp. 2554-2558.
- [13] Hopfield, JJ. and Tank, D. W., (1985), "*Neural computation of decisions in optimization problems*", Biological Cybernetics 55, pp. 141-146.
- [14] Ackley, D.H., Hinton, G.E & Sejnowski, T.J., (1985). "*A Learning Algorithm for Boltzmann Machines.*" Cognitive Science: 9 (1), pp. 147-169.
- [15] Kohonen, T., Barna, G. & Chrisley, R., (1988), "*Statistical Pattern Recognition with Neural Networks*", In: Proceedings of the IEEE Conference on Neural Network 1: 61-68, 24-27 July 1988, San Diego, CA.
- [16] Rumelhart, D.E., Hinton, G.E., Williams, R.J., (1986), "*Learning internal representation by back-propagating errors*", Rumelhart, D.E., McClelland, J.L., the PDP Research Group (Eds.), Parallel Distributed Processing: Explorations in the Microstructure of Cognition. MIT Press, MA.
- [17] Broomhead, D. S. & Lowe, D., (1988), "*Radial basis functions, multi-variable functional interpolation and adaptive networks*" (Technical report). Royal Signals and Radar Establishment RSRE 4148, UK.
- [18] Aleksander, I & Morton, H., (1995), "*An Introduction to Neural Computing, Cengage Learning*", EMEA, Introductory text on neural networks.
- [19] Elman, J. L. (1990), "*Finding Structure in Time*", Cognitive Sci., 14(2), 179

- [20] Bengio, Y., Simard, P., Frasconi, P. (1994), “*Learning long-term dependencies with gradient descent is difficult*”, IEEE Transactions on Neural Networks, 5(2), 157–166.
- [21] Becker, S., (1991), “*Unsupervised learning procedures for neural networks*”, International Journal for Neural Systems, vol. 2, pp. 17-33.
- [22] Barto, A.G., R.S. Sutton, and C.W. Anderson, (1983), “*Neuronlike adaptive elements that can solve difficult learning control problems*”, IEEE Transactions on Systems, Man, and Cybernetics, vol. SMC-13, pp. 834–846.
- [23] Schalkoff, R. (1992), “*Pattern Recognition: Statistical. Structural and Neural Approaches*”, Wiley, New York.
- [Σχήμα 16] Jain, A. K., Mao, J. and Mohiuddin, K. M. (1996), “*Artificial neural networks - a tutorial*”, Computer March, 31-44.
- [24] Hornik, K., Stinchcombe, M. and White, H. (1989), “*Multilayer feedforward networks are universal approximators*”, Neural Networks 2, 359-366.
- [25] Sarle, W. (1997), “*comp.ai.neural-nets Frequently Asked Questions*”, <ftp://ftp.sas.com/pub/neural/FAQ.html>.
- [26] Garson, G. D. (1991), “*Interpreting neural network connection weights*”, Artificial Intelligence Expert, April, 47-51.
- [27] Reed, R. (1993), “*Pruning algorithms-a survey*”, IEEE transactions on Neural Networks 4 (5), 740-747.
- [28] Kohonen T (1982), “*Self-organised formation of topologically correct feature map*”, Biological Cybernetics, 43: 56–69.
- [29] Kohonen T (1999), “*Comparison of SOM point densities based on different criteria*”, Neural Computation, 11: 2081–2095.
- [30] Simon Haykin (1998), “*Neural Networks: A Comprehensive Foundation*”, Prentice Hall PTR, Upper Saddle River, NJ, USA, 2nd edition.
- [31] Raúl Rojas (1996), “*Neural networks: a systematic introduction*”. Springer- Verlag New York, Inc., New York, NY, USA.
- [32] Fernando Bação, Victor Sousa Lobo, Marco Painho (2005), “*Selforganizing maps as substitutes for k-means clustering*”. In Vaidy S. Sunderam, G. Dick van Albada, Peter M. A. Sloot, and Jack Dongarra, editors, International Conference on Computational Science (3), volume 3516 of Lecture Notes in Computer Science, pages 476{483. Springer.
- [33] C. Amerijckx, J.-D. Legat, M. Verleysen (2003), “*Image compression using self-organizing maps*”. Syst. Anal. Model. Simul., 43(11):1529-1543.
- [34] Anthony Dekker (1994), “*Kohonen neural networks for optimal colour quantization*”. Network: Computation in Neural Systems, 5:351-367.
- [35] Timo Honkela, Samuel Kaski, Krista Lagus, Teuvo Kohonen (1997), “*WebSom self-organizing maps of document collections*”. In Neurocomputing, pages 101-117.
- [36] V.S. Dave, K. Dutta (2014), “*Neural network-based models for software effort estimation: a review*”, Artif. Intell. Rev. 42 (2) p. 295-307.

- [37] H. He, E.A. Garcia (2009), “*Learning from imbalanced data*”, IEEE Trans. Knowl. Data Eng. 21 (9) p. 1263-1284.
- [38] A. Mozaffari, M. Emami, A. Fathi (2018), “*A comprehensive investigation into the performance, robustness, scalability and convergence of chaos-enhanced evolutionary algorithms with boundary constraints*”, Artif. Intell. Rev. p. 1-62.
- [39] N. Izeboudjen, C. Larbes, A. Farah (2014), “*A new classification approach for neural networks hardware: from standards chips to embedded systems on chip*”, Artif. Intell. Rev. 41 (4) p. 491-534.
- [40] D. Wang, H. He, D. Liu (2018), “*Intelligent optimal control with critic learning for a nonlinear overhead crane system*”, IEEE Transact. Ind. Inf. 14 (7) p. 2932-2940.
- [41] Rohit Aggarwal et al., (2015), “*Distinctions between Diagnostic and Classification Criteria*”, Arthritis Care Res (Hoboken); 67(7): 891–897. doi:10.1002/acr.22583.
- [42] Yazici H. (2009), “*Diagnostic versus classification criteria - a continuum*”, bulletin of the NYU hospital for joint diseases. 67(2):206–208. [PubMed: 19583555].
- [43] Fries JF, Hochberg MC, Medsger TA Jr, Hunder GG, Bombardier C. (1994), “*Criteria for rheumatic disease. Different types and different functions*”, The American College of Rheumatology Diagnostic and Therapeutic Criteria Committee. Arthritis and rheumatism; 37(4):454–462 [PubMed: 7605403].
- [44] Templin, J. L., & Henson, R. A. (2006), “*Measurement of psychological disorders using cognitive diagnosis models*”, Psychological Methods, 11, 287–305.
- [45] André A. Rupp & Jonathan L. Templin (2008), “*Unique Characteristics of Diagnostic Classification Models: A Comprehensive Review of the Current State-of-the-Art*”, Measurement, 6:4, 219-262, DOI: 10.1080/15366360802490866.
- [46] Sing-Tze Bow (2002), “*Pattern Recognition and Image Preprocessing*”, Northern Illinois University, De Kalb, Illinois, ISBN: 0-8247-0659-5.
- [47] W. Sha, K. L. Edwards (2007), “*The use of artificial neural networks in materials science based research*”, Materials and Design 28 (2007) 1747 – 1752, Science Direct, ELSEVIER.
- [48] DANIELA M. BAILER-JONES & CORYN A. L. BAILER-JONES (2002), “*Modelling data: Analogies in neural networks, simulated annealing and genetic algorithms*”, Analogies in data modelling techniques, New York: Kluwer Academic/Plenum Publishers.
- [49] Sharda, R., (1994), “*Neural networks for the MS/OR analyst: An application bibliography*”, Interfaces 24 (2), 115–130.
- [50] White, H., (1989), “*Learning in artificial neural networks: A statistical perspective*”, Neural Computation 1, 425–464.
- [51] Ripley, B.D., (1993), “*Statistical aspects of neural networks*”, Barndorff-Nielsen, O.E., Jensen, J.L., Kendall, W.S. (Eds.), Networks and Chaos-Statistical and Probabilistic Aspects, Chapman and Hall, London, pp. 40–123.
- [52] Cheng, B., Titterington, D.M., (1994), “*Neural networks: A review from a statistical perspective*”, Statistical Science 9 (1), 2–54.
- [53] Irie, B., Miyake, S., (1988), “*Capabilities of three-layered perceptrons*”, Proceedings of the IEEE International Conference on Neural Networks, I, pp. 641–648.

- [54] Thiria, S., Mejia, C., Badran, F. and Crepon, M. (1993), “A neural network approach for modelling non-linear transfer functions: application for wind retrieval from spaceborne scatterometer data”, *Journal of Geophysical Research* 98 (C12), 22827-22841.
- [55] Butler, C. T., Meredith, R. V. Z. and Stogryn, A. P. (1996), “Retrieving atmospheric temperature parameters from DMSP SSM/T-1 data with a neural network”, *Journal of Geophysical Research* 101 (D3), 7075-7083.
- [56] Badran, F. and Thiria, S. (1991), “Wind ambiguity removal by the use of neural network techniques”, *Journal of Geophysical Research* 96 (C11), 20521-20529.
- [57] Clothiaux, E. E., Penc, R. S., Thomson, D. W., Ackerman, T. P. and Williams, S. R. (1994), “A first-guess feature-based algorithm for estimating wind speed in clear-air Doppler radar spectra”, *Journal of Atmospheric and Oceanic Technology*, 11, 888-908.
- [58] Churnside, J. H., Stermitz, T. A. and Schroeder, J. A. (1994), “Temperature profiling with neural network inversion of microwave radiometer data”, *Journal of Atmospheric and Oceanic Technology* 11 (1), 105-109.
- [59] Cybenko, G., (1989), “Approximation by superpositions of a sigmoidal function”, *Mathematical Control Signals Systems* 2, 303–314.
- [60] Funahashi, K., (1989), “On the approximate realization of continuous mappings by neural networks”, *Neural Networks* 2, 183–192.
- [61] Hornik, K., (1991), “Approximation capabilities of multilayer feedforward networks”, *Neural Networks* 4, 251–257.
- [62] Hornik, K., (1993), “Some new results on neural network approximation”, *Neural Networks* 6, 1069–1072.
- [63] Box, G.E.P., Jenkins, G.M., (1976), “*Time Series Analysis: Forecasting and Control*”, Holden-Day, San Francisco, CA.
- [64] Pankratz, A., (1983), “*Forecasting with Univariate Box-Jenkins Models: Concepts and Cases*”, John Wiley, New York.
- [65] Granger, C.W.J., Terasvirta, T., (1993), “*Modelling Nonlinear Economic Relationships*”, Oxford University Press, Oxford.
- [66] Granger, C.W.J., Anderson, A.P., (1978), “*An Introduction to Bilinear Time Series Models*”, Vandenhoeck and Ruprecht, Gottingen.
- [67] Tong, H., Lim, K.S., (1980), “Threshold autoregressive, limit cycles and cyclical data”, *Journal of the Royal Statistical Society Series B* 42 (3), 245–292.
- [68] Engle, R.F., (1982), “Autoregressive conditional heteroskedasticity with estimates of the variance of UK inflation”, *Econometrica* 50, 987–1008.
- [69] De Gooijer, J.G., Kumar, K., (1992), “Some recent developments in non-linear time series modelling, testing, and forecasting”, *International Journal of Forecasting* 8, 135–156.
- [70] Hu, M.J.C., (1964), “*Application of the adaline system to weather forecasting*”, Master Thesis, Technical Report 6775-1, Stanford Electronic Laboratories, Stanford, CA, June.
- [71] Werbos, P.J., (1974), “*Beyond regression: new tools for prediction and analysis in the behavioral sciences*”, Ph.D. thesis, Harvard University.

- [72] Werbos, P.J., (1988), “*Generalization of backpropagation with application to a recurrent gas market model*”, Neural Networks 1, 339–356.
- [73] Lapedes, A., Farber, R., (1987), “*Nonlinear signal processing using neural networks: prediction and system modeling*”, Technical Report LA-UR-87-2662, Los Alamos National Laboratory, Los Alamos, NM.
- [74] Weigend, A.S., Huberman, B.A., Rumelhart, D.E., (1990), “*Predicting the future: A connectionist approach*”, International Journal of Neural Systems 1, 193–209.
- [75] Weigend, A.S., Huberman, B.A., Rumelhart, D.E., (1992), “*Predicting sunspots and exchange rates with connectionist networks*”, In: Casdagli, M., Eubank, S. (Eds.), Nonlinear Modeling and Forecasting. Addison-Wesley, Redwood City, CA, pp. 395–432.
- [76] Cottrell, M., Girard, B., Girard, Y., Mangeas, M., Muller, C., (1995), “*Neural modeling for time series: a statistical stepwise method for weight elimination*”, IEEE Transactions on Neural Networks 6 (6), 1355–1364.
- [77] Tang, Z., Almeida, C., Fishwick, P.A., (1991), “*Time series forecasting using neural networks vs Box-Jenkins methodology*”, Simulation 57 (5), 303–310.
- [78] Sharda, R., Patil, R.B., (1992), “*Connectionist approach to time series prediction: An empirical test*”, Journal of Intelligent Manufacturing 3, 317–323.
- [79] Tang, Z., Fishwick, P.A., (1993), “*Feedforward neural nets as models for time series forecasting*”, ORSA Journal on Computing 5 (4), 374–385.
- [80] Widrow, B., Hoff, M. E., (1960), “*Adaptive Switching Circuits*”, Technical Report No. 1553-1, Stanford Electronics Laboratory, Stanford University, California.
- [81] Jones, L. K. (1992), “*A simple lemma on greedy approximation in Hilbert space and convergence rates for projection pursuit regression and neural network training*”, Annals of Statistics, 20, 608–613.
- [82] Barron A. R. (1993), “*Universal approximation bounds for superpositions of a sigmoidal function*”, IEEE Transactions on Information Theory, 39, 930–945.
- [83] Bhat N., T. McAvoy (1990), “*Use of neural nets for dynamic modelling and control of chemical processes*”, Comput. Chem. Eng. 14, 573–583.
- [84] Koivisto H. (1990), “*Minimum prediction error neural controller*”, 29th IEEE Conf. on Decision and Control, Honolulu, Dec. 1-5, 1990.
- [85] Narendra K.S., K. Parthasarathy (1990), “*Identification and control of dynamical systems using neural networks*”, IEEE Trans. Neural Network, 1, 4–27.
- [86] Psychogios D.C., L. H. Ungar (1991), “*Direct and indirect model based control using artificial neural networks*”, Ind. Eng. Chem. Res., 30, 2564–2573.
- [87] Morari M., E. Zafiriou (1989), “*Robust Process Control*”, Englewood-Cliffs: Prentice- Hall.
- [88] Hunt K.J., D. Sbarbaro (1991), “*Neural networks for non-linear internal model control*”, IEE Proceedings-D, 138, 431–438.
- [89] Koivisto H., V. Ruoppila, H.N. Koivo (1992), “*Properties of the neural network internal model controller*”, Preprints of IFAC/IFIP/IMACS Int. Symp. on Artificial Intelligence in Real-Time Control, Delft, The Netherlands, 221–226, June 16–18, 1992.

- [90] Morris AJ., Montague GA., Willis MJ. (1994), “*Artificial neural networks: studies in process modelling and control*”, Trans Inst Chem Engng, UK - Part A 1994;72:3-19.
- [91] Edwards NJ, Goh CJ. (1995), “*Direct training method for a continuous-time nonlinear optimal feedback controller*”, J Optimization Theory Applications 1995;84(3):509-528.
- [92] Mohamed Azlan Hussain (1998), “*Review of the applications of neural networks in chemical process control - simulation and online implementation*”, ELSEVIER, Artificial Intelligence in Engineering 13 (1999) 55-68.
- [93] Szolovits P., Patil RS., Schwartz W. (1988), “*Artificial Intelligence in Medical Diagnosis*”, Ann Intern Med. 108: 80-87.
- [94] Alkim E., Gürbüz E., Kiliç E. (2012), “*A fast and adaptive automated disease diagnosis method with an innovative neural network model*”, Neur Networks. 33: 88-96.
- [95] Spelt L., Andersson B., Nilsson J., Andersson R. (2012), “*Prognostic models for outcome following liver resection for colorectal cancer metastases: A systematic review*”, Eur J Surg Oncol. 38: 16-24.
- [96] Mortazavi D., Kouzani A., Soltanian-Zadeh H. (2012), “*Segmentation of multiple sclerosis lesions in MR images: a review*”, Neuroradiology. 54: 299-320.
- [97] Ahmed F. (2005), “*Artificial neural networks for diagnosis and survival prediction in colon cancer*”, Mol Cancer. 4: 29.
- [98] Bartosch-Härlid A., Andersson B., Aho U., Nilsson J., Andersson R. (2008), “*Artificial neural networks in pancreatic disease*”, Br J Surg. 95: 817-826.
- [99] Siristatidis C., Chrelias C., Pouliakis A., Katsimanis E., Kassanos D. (2010), “*Artificial neural networks in gynecological diseases: Current and potential future applications*”, Med Sci Monit. 16: 231-236.
- [100] Shankaracharya, Odedra D., Samanta S., Vidyarthi A. (2010), “*Computational intelligence in early diabetes diagnosis: a review*”, Rev Diabet Stud. 7: 252-262.
- [101] Pace F., Savarino V. (2007), “*The use of artificial neural network in gastroenterology: the experience of the first 10 years*”, Eur J Gastroenterol Hepatol. 19: 1043-1045.
- [102] Bradley B. (2012), “*Finding biomarkers is getting easier*”, Ecotoxicology. 21: 631-636.
- [103] Filippo Amato, Alberto López, Eladia María Peña-Méndez, Petr Vaňhara, Aleš Hampl, Josef Havel (2013), “*Artificial neural networks in medical diagnosis*”, Journal of APPLIED BIOMEDICINE, 11: 47-58, 2013, DOI 10.2478/v10136-012-0031-x, ISSN 1214-0287.
- [104] Karabulut E., Ibrikçi T. (2012), “*Effective diagnosis of coronary artery disease using the rotation forest ensemble method*”, J Med Syst. 36: 3011-3018.
- [105] Atkov O., Gorokhova S., Sboev A., Generozov E., Muraseyeva E., Moroshkina S. and Cherniy N. (2012), “*Coronary heart disease diagnosis by artificial neural networks including genetic polymorphisms and clinical parameters*”, J Cardiol. 59: 190-194.
- [106] Uğuz H. (2012), “*A biomedical system based on artificial neural network and principal component analysis for diagnosis of the heart valve diseases*”, J Med Syst. 36: 61-72.

- [107] Özbay Y. (2009), “A new approach to detection of ECG arrhythmias: Complex discrete wavelet transform based complex valued artificial neural network”, *J Med Syst.* 33: 435-445.
- [108] Kheirelseid E., Miller N., Chang K., Curran C., Hennessey E., Sheehan M., Newell J., Lemetre C., Balls G., Kerin M. (2012), “miRNA expressions in rectal cancer as predictors of response to neoadjuvant chemoradiation therapy”, *Int J Colorectal Dis.*
- [109] Wilding P., Morgan M., Grygotis A., Shoffner M., Rosato E. (1994), “Application of backpropagation neural networks to diagnosis of breast and ovarian cancer”, *Cancer Lett.* 77: 145-153.
- [110] El-Deredy W., Ashmore S., Branston N., Darling J., Williams S., Thomas D. (1997), “Pretreatment prediction of the chemotherapeutic response of human glioma cell cultures using nuclear magnetic resonance spectroscopy and artificial neural networks”, *Cancer Res.* 57: 4196-4199.
- [111] Thakur A., Mishra V., Jain S. (2011), “Feed forward artificial neural network: tool for early detection of ovarian cancer”, *Sci Pharm.* 79: 493-505.
- [112] Tate A., Underwood J., Acosta D., Julià-Sapé M., Majós C., Moreno-Torres A., Howe F., van der Graaf M., Lefournier V., Murphy M., Loosemore A., Ladroue C. et al. (2006), “Development of a decision support system for diagnosis and grading of brain tumours using in vivo magnetic resonance single voxel spectra”, *NMR Biomed.* 19: 411-434.
- [113] Brougham D., Ivanova G., Gottschalk M., Collins D., Eustace A., O’ Connor R., Havel J. (2011), “Artificial neural networks for classification in metabolomic studies of whole cells using ^1H nuclear magnetic resonance”, *J Biomed Biotechnol.* 2011: 158094.
- [114] Leon BS., Alanis AY., Sanchez E., Ornelas-Tellez F., Ruiz-Velazquez E. (2012), “Inverse optimal neural control of blood glucose level for type 1 diabetes mellitus patients”, *J Franklin I.* 349: 1851-1870.
- [115] Arnold M. (1996), “Non-invasive glucose monitoring”, *Curr Opin Biotech.* 7: 46-49.
- [116] Narasingarao M., Manda R., Sridhar G., Madhu K., Rao A. (2009), “A clinical decision support system using multilayer perceptron neural network to assess well being in diabetes”, *J Assoc Physicians India.* 57: 127-133.
- [117] Trajanoski Z., Regittnig W., Wach P. (1998), “Simulation studies on neural predictive control of glucose using the subcutaneous route”, *Comput Meth Progr Biomed.* 56: 133-139.
- [118] Dazzi D., Taddei F., Gavarini A., Uggeri E., Negro R., Pezzarossa A. (2001), “The control of blood glucose in the critical diabetic patient: a neuro-fuzzy method”, *J Diabet Complicat.* 15: 80-87.
- [119] Chan K., Ling S., Dillon T., Nguyen H. (2011), “Diagnosis of hypoglycemic episodes using a neural network based rule discovery system”, *Expert Syst Appl.* 38: 9799-9808.
- [120] Maclin PS, Dempsey J, Brooks J, et al. (1991), “Using neural networks to diagnose cancer”, *J Med Syst* 15: 11-19.
- [121] Abbey Lepor1, William J. Catalona, and Stacy Loeb (2016), “The Prostate Health Index: Its Utility In Prostate Cancer Detection”, *Urol Clin North Am.* 2016 February; 43(1): 1-6. doi:10.1016/j.ucl.2015.08.001.

- [122] Theodore Anagnostou, Mesut Remzi, Michael Lykourinas, Bob Djavan (2003), “*Artificial Neural Networks for Decision-Making in Urologic Oncology*”, *European Urology* 43, pp 596–603, 2003 Elsevier Science B.V.
- [123] Prater JS, and Richard WD. (1992), “*Segmenting ultrasound images of the prostate using neural networks*”, *Ultrason Imaging* 142: 159–185.
- [124] Loch T, Leuschner I, and Bruske T. (1997), “*Neural network analysis of subvisual transrectal ultrasound data: improved prostate cancer detection*”, *J Urol* 157: 364.
- [125] Snow PB, Smith DS, and Catalona WJ. (1994), “*Artificial neural networks in the diagnosis and prognosis of prostate cancer: a pilot study*”, *J Urol* 152: 1923–1926.
- [126] Douglas T, Connelly R, McLeod D, et al. (1996), “*Neural network analysis of pre-operative and post-operative variables to predict pathologic stage and recurrence*”, *J Urol* 155: 487A.
- [127] Tisman G, Strum S, Scholz M, et al. (1997), “*Pre-therapy prediction of the duration of post-therapy non-detectable PSA for prostate cancer patients considering intermittent combined hormonal blockade by use of computerized neural net modeling*”, *Proceedings of the American Society of Clinical Oncology Meeting*, May 1997, abstract 1236.
- [128] Schweiger CR, Maenner GA, Soeregi G, et al. (1994), “*Neural network evaluation of multiple tumor markers for diagnosis of urinary bladder cancer using three different sets of patients*”, *Third International Conference of the Mediterranean Society of Tumor*, Vienna, Austria.
- [129] Djavan B, Zlotta A, Remzi M, Ghawidel K, Basharkhah A, Schulmann CC, et al. (2000), “*Optimal predictors for Prostate Cancer on repeat prostate biopsy*”, *J Urol* 2000;163:1144–8.
- [130] Babaian JR, Fritsche H, Ayala A, Bhadkamkar V, Johnston DA, Naccarato W, et al. (2000), “*Performance of a neural network in detecting prostate cancer in the prostate-specific antigen reflex range of 2.5–4ng/ml.*”, *Urology* 2000;56:1000–6.
- [131] Djavan B, Remzi M, Zlotta A, Seitz C, Snow P, Marberger M. (2002), “*Novel artificial neural network for early detection of prostate cancer*”, *J Clin Oncol* 2002;20:921–9.
- [132] Finne P, Finne R, Auvinen A, Juusela H, Aro J, Määttänen L, et al. (2000), “*Predicting the outcome of prostate biopsy in screen-positive men by a multiplayer perceptron network*”, *Urology* 2000;56:418–22.
- [133] Moul JW, Snow PB, Fernandez EB, et al. (1995), “*Neural network analysis of quantitative histological factors to predict pathological stage in clinical stage I nonseminomatous testicular cancer*”, *J Urol* 153: 1674–1677.
- [134] Stotzka R, Manner R, Bartels PH, et al. (1995), “*A hybrid neural and statistical classifier system for histopathologic grading of prostatic lesions*”, *Analytic Quant Cytol Histol* 17: 204–218.
- [135] Volmer M, Wolthers BG, Metting HJ, et al. (1994), “*Artificial neural network predictions of urinary calculus compositions analyzed with infrared spectroscopy*”, *Clin Chem* 40: 1692–1697.
- [136] Hurst RE, Bonner RB, Ashenayi K, et al. (1997), “*Neural netbased identification of cells expressing the p300 tumor-related antigen using fluorescence image analysis*”, *Cytometry* 27: 36–42.
- [137] Neiderberger C, (1996), “*Computational tools for the modern andrologist*”, *J Androl* 17: 462–466.

- [138] Neiderberger CS, Michaels DK, Cho L, et al. (1996), “*A neural computational model of stone recurrence after ESWL*”, Proceedings of the International Conference on Engineering Applications of Neural Networks, London, June 1996, pp 423–426.
- [139] Litwin MS, Hays RD, Fink A, et al. (1995), “*Quality-of-life outcomes in men treated for localized prostate cancer*”, JAMA 273:129–135.
- [140] Barry MJ, (1990), “*Medical outcomes research and benign prostatic hyperplasia*”, Prostate Suppl 3: 61–74.
- [141] Krongrad A, Granville LJ, Burke MA, et al. (1997), “*Predictors of general quality of life in patients with benign prostate hyperplasia or prostate cancer*”, J Urol 157: 534–538.
- [142] JOHN T. WEI, ZHEN ZHANG, STEPHEN D. BARNHILL, K. RAMA MADYASTHA, HONG ZHANG, and JOSEPH E. OESTERLING (1998), “*UNDERSTANDING ARTIFICIAL NEURAL NETWORKS AND EXPLORING THEIR POTENTIAL APPLICATIONS FOR THE PRACTICING UROLOGIST*”, UROLOGY 52: 161–172, Elsevier Science Inc.
- [143] Partin AW, Kattan MW, Subong EN, et al. (1997), “*Combination of prostate-specific antigen, clinical stage, and Gleason score to predict pathological stage of localized prostate cancer. A multi-institutional update*”, JAMA 277: 1445–1451.
- [144] Catalona, W., Partin, A., Sanda, M., Wei, J., Klee, G., Bangma, C. et al. (2011), “*A multicenter study of [-2]pro-prostate specific antigen combined with prostate specific antigen and free prostate specific antigen for prostate cancer detection in the 2.0 to 10.0 ng/ml prostate specific antigen range*”, J Urol 185: 1650–1655.
- [145] Catalona, W., Bartsch, G., Rittenhouse, H., Evans, C., Linton, H., Amirkhan, A. et al. (2003), “*Serum pro prostate specific antigen improves cancer detection compared to free and complexed prostate specific antigen in men with prostate specific antigen 2 to 4 ng/ml.*”, J Urol 170: 2181–2185.
- [146] Stacy Loeb, William J. Catalona (2013), “*The Prostate Health Index: a new test for the detection of prostate cancer*”, Therapeutic Advances in Urology, Vol. 6(2) 74–77, DOI: 10.1177/1756287213513488.
- [147] C. CHAUSSY, M.D., F. EISENBERGER, M.D., and B. FORSSMANN, Ph.D. (2007), “*Extracorporeal Shockwave Lithotripsy (ESWL®): A Chronology*”, JOURNAL OF ENDOUROLOGY, Volume 21, Number 11, November 2007, DOI: 10.1089/end.2007.9880.
- [148] Chaussy Ch, Eisenberger F, Wanner K, Forssmann B, Hepp W, Schmiedt E, Brendel W, (1976), “*The use of shock waves for the destruction of renal calculi without direct contact*”, Urol Res 1976;4:175.
- [149] Forssmann B, Hepp W, Chaussy C, Eisenberger F, Wanner K, (1977), “*A method for no-contact destruction of kidney stones by means of shock waves*”, Biomed Tech 1977;22:164–168.
- [150] Chaussy Ch, Forssmann B, Brendel W, Jocham D, Eisenberger F, Hepp W, Grohel JM, (1980), “*Beröhrungsfreie Nierensteinzertrümmerung durch extrakorporal erzeugte, fokussierte Stoßwellen*”, In: Chaussy Ch, Staehler G (eds): Beiträge zur Urologie. Basel, S Karger, 1980.
- [151] Chaussy Ch, Jocham, D, Schmiedt E, Walther V, Brendel W, Forssmann B, Hepp W, (1982), “*New aspects in the treatment of kidney stone disease*”, In: Chaussy Ch (ed): Extracorporeal Shock Wave Lithotripsy. Basel: S Karger.
- [152] Eisenberger F, Chaussy Ch, Wanner K, (1977), “*Extrakorporale Anwendung von hochenergetischen Stoßwellen: Ein neuer Aspekt in der Behandlung des Harnsteinleidens*”, Akt Urol 1977;8:3–15.

- [153] Chaussy Ch, Brendel W, Schmiedt E, (1980), “*Extracorporeally induced destruction of kidney stones by shock waves*”, Lancet 1980;2:1265–1268.
- [154] Chaussy Ch, Schmiedt E, Jocham D, Brendel W, Forssmann B, Moser E, (1981), “*Berührungsfreie Nierensteinzertrümmerung durch Stoßwellen: Erste klinische Erfahrungen*”, Deutsch Ärzteblatt 1981;18:881–886.
- [155] Chaussy Ch, Schmiedt E, Jocham D, Brendel W, Forssmann B, Walther V, (1982), “*First clinical experience with extracorporeally induced destruction of kidney stones by shock waves*”, J Urol 1982;127:417–420.
- [156] Alken P, Hutschenreiter G, Gunther R, Marberger M, (1981), “*Percutaneous stone manipulation*”, J Urol 1981;125:463–466.
- [157] Eisenberger F. ESWL. 36th Tagung, Verh Ber Ges Urol, Stuttgart, 1984.
- [158] Eisenberger F, Fuchs G, Miller K, Rassweiler J, (1985), “*Extracorporeal shockwave lithotripsy ESWL and endourology: An ideal combination for the treatment of kidney stones*”, World J Urol 1985;3:41–47.
- [159] Eisenberger F, Fuchs G, Miller K, (1983), “*Nierensteintherapie: Erste klinische Erfahrungen mit der Überührungsfreien Nierensteintherapie (ESWL) am Katharinenhospital Stuttgart*”, frzteblatt Württemberg 1983;12:504–506.
- [160] Mendenhall W, Beaver RJ, (1994), “*Introduction to probability and statistics*”, 9th ed. Belmont (CA): Wadsworth; 1994. p. 447–50.
- [161] Harnett DL, Murphy JL, (1975), “*Introductory statistical analysis*”, Reading (MA): Addison-Wesley; 1975. p. 416–25.
- [162] Dragan A. Clovic, (1997), “*Feed-forward artificial neural networks: applications to spectroscopy*”, Trends in analytical chemistry, vol. 16, no. 3, 1997.
- [163] Medsker, L and Liebowitz, J. (1994), “*Design and development of Expert systems and neural networks*”, New York.
- [164] Basheer, I. A and Hajmeer, M (2000), “*Artificial neural networks: fundamentals, computing, design, and application*”, Journal of Microbiological Methods 43, 3–31.
- [165] Demuth H, Beale M and Hagan A (2010), “*Neural Network Toolbox User’s Guide*”, Math Works, Natick.
- [166] Niaki, S.T.A and Abbasi, B. (2005), “*Fault diagnosis in multivariate control chart using artificial neural networks*”, Quality Reliability Engineering International 21, 825–840.
- [167] Sagiroglu, S., Besdok, E. and Erler, M (2000), “*Control chart Pattern Recognition Using Artificial Neural Networks*”, Turkish Journal of Electrical Engineering. 8(2), 137–147.
- [168] Guh, R.S. and Hsieh, Y.C. (1999), “*A Neural Network Based Model for Abnormal Pattern Recognition of Control Charts*”, Computers and Industrial Engineering 36, 97–108.
- [169] Olatunde Adeoti, Osanaiye Peter (2012), “*Performance Analysis of ANN on Dataset Allocations for Pattern Recognition of Bivariate Process*”, Mathematical Theory and Modeling, ISSN 2224-5804 (Paper), Vol.2, No.10, 2012.
- [170] Schittkowski, K. (1987), “*More Test Examples for Nonlinear Programming Codes*”, Lecture Notes in Economics and Mathematical Systems, Vol. 282, Springer-Verlag, Berlin.

- [171] Schittkowski, K. (1989), “*Knowledge-based software systems in mathematical optimization*” in: J.-P. Perot (ed.), “*New Methods in Optimization and their Industrial Uses*”, International Series on Numerical Mathematics 87, Birkhäuser, Boston, 157-172.
- [172] Hock, W. and Schittkowski, K. (1981), “*Test Examples for Nonlinear Programming*”, Lecture Notes in Economics and Mathematical Systems, Vol. 187, Springer-Verlag, Berlin.
- [173] Henri P. Gavin (2019), “*The Levenberg-Marquardt algorithm for nonlinear least squares curve-fitting problems*”, Department of Civil and Environmental Engineering, Duke University, <http://people.duke.edu/~hpgavin/ce281/lm.pdf> .
- [174] Niclas Börnin (2007), “*Nonlinear Optimization, Least Squares Problems — The Gauss-Newton method*”, Department of Computing Science Umeå University, <https://www8.cs.umu.se/kurser/5DA001/HT07/lectures/lsg-handouts.pdf> .
- [175] MARTIN FODSLETTE MøLLER (1993), “*A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning*”, Neural Networks, Vol. 6, pp. 525-533, 3 Pergamon Press Ltd.
- [176] Ilya Sutskever, James Martens, George Dahl, Geoffrey Hinton (2013), “*On the importance of initialization and momentum in deep learning*”, Proceedings of the 30th International Conference on Machine Learning, Atlanta, Georgia, USA, 2013. JMLR: W&CP volume 28.
- [177] Sebastian Ruder (2017), “*An overview of gradient descent optimization algorithms*”, arXiv:1609.04747v2 [cs.LG], Aylien Ltd., Dublin, <http://sebastianruder.com/optimizing-gradient-descent/index.html> .
- [178] Marcin Andrychowicz et al. (2016), “*Learning to learn by gradient descent*”, 30th Conference on Neural Information Processing Systems (NIPS 2016), Barcelona, Spain.
- [179] Martin Riedmiller and H. Braun (1993), “*A direct adaptive method for faster backpropagation learning: The Rprop algorithm*”, in: H. Ruspini (ed.), “*Proceedings of the IEEE International Conference on Neural Networks (ICNN)*”, pages 586-591, San Francisco.
- [180] ΜΙΛΤΙΑΔΗΣ ΧΑΛΙΚΙΑΣ, ΑΛΕΞΑΝΔΡΑ ΜΑΝΩΛΕΣΣΟΥ, ΠΑΝΑΓΙΩΤΑ ΛΑΛΟΥ (2015), “*Μεθοδολογία Έρευνας και Εισαγωγή στη Στατιστική Ανάλυση Δεδομένων με το IBM SPSS STATISTICS*”, ISBN: 978-960-603-123-6.
- [181] ELI K. MICHAELS, CRAIG S. NIEDERBERGER, RICHARD M. GOLDEN, BRUCE BROWN, LUKE CHO, YOUNG HONG (1998), “*USE OF A NEURAL NETWORK TO PREDICT STONE GROWTH AFTER SHOCK WAVE LITHOTRIPSY*”, ELSEVIER SCIENCE INC., UROLOGY 51: 335-338, 0090-4295/98.
- [182] JAMES M. CUMMINGS, JOHN A. BOULLIER, SETH D. IZENBERG, DAVID M. KITCHENS, RUPA V. KOTHANDAPANI (2000), “*PREDICTION OF SPONTANEOUS URETERAL CALCULOUS PASSAGE BY AN ARTIFICIAL NEURAL NETWORK*”, THE JOURNAL OF UROLOGY, Vol. 164, 326-328, August 2000.
- [183] A. HAMID, U.S. DWIVEDI, T.N. SINGH, M. GOPI KISHORE, M. MAHMOOD, H. SINGH, V. TANDON, P.B. SINGH (2003), “*Artificial neural networks in predicting optimum renal stone fragmentation by extracorporeal shock wave lithotripsy: a preliminary study*”, BJU INTERNATIONAL | 91, 821–824 | doi:10.1046/j.1464-410X.2003.04230.x.
- [184] MOHAMED A. GOMHA, KHALED Z. SHEIR, SAEED SHOWKY, MOHAMED ABDEL-KHALEK, ALAA A. MOKHTAR, KHALED MADBOULY (2004), “*CAN WE IMPROVE THE PREDICTION OF STONE-FREE STATUS AFTER EXTRACORPOREAL SHOCK WAVE*

LITHOTRIPSY FOR URETERAL STONES? A NEURAL NETWORK OR A STATISTICAL MODEL?”, THE JOURNAL OF UROLOGY, Vol. 172, 175–179, July 2004.

[185] Neeraj K. Goyal, Abhay Kumar, Sameer Trivedi, Udai S. Dwivedi, T.N. Singh, Pratap B. Singh (2010), “*A Comparative Study of Artificial Neural Network and Multivariate Regression Analysis to Analyze Optimum Renal Stone Fragmentation by Extracorporeal Shock Wave Lithotripsy*”, Saudi Journal of Kidney Diseases and Transplantation 2010; 21 (6): 1073-1080.