


Ατομική Διπλωματική Εργασία

**ΣΥΣΤΗΜΑ ΥΠΟΛΟΓΙΣΤΙΚΗΣ ΝΟΗΜΟΣΥΝΗΣ ΓΙΑ ΔΙΑΓΝΩΣΗ  
ΣΤΗΝ ΙΑΤΡΙΚΗ: Η ΠΕΡΙΠΤΩΣΗ ΤΗΣ ΠΡΟΕΚΚΛΑΜΨΙΑΣ**

Αντώνης Καρταπάνη

**ΠΑΝΕΠΙΣΤΗΜΙΟ ΚΥΠΡΟΥ**



**ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ**

Μάιος 2011

# **ΠΑΝΕΠΙΣΤΗΜΙΟ ΚΥΠΡΟΥ**

## **ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ**

Σύστημα Υπολογιστικής Νοημοσύνης για διάγνωση στην Ιατρική:

Η περίπτωση της Προεκλαμψίας

**Αντώνης Καρταπάνη**

Επιβλέπων Καθηγητής

Χρίστος Ν. Σχίζας

Η Ατομική Διπλωματική Εργασία υποβλήθηκε προς μερική εκπλήρωση των απαιτήσεων απόκτησης του πτυχίου Πληροφορικής του Τμήματος Πληροφορικής του Πανεπιστημίου Κύπρου.

Μάιος 2011

## Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον επιβλέποντα Καθηγητή Χρίστο Ν. Σχίζα που με εμπιστεύθηκε για την εκπόνηση αυτής της διπλωματικής εργασίας. Επίσης τον ευχαριστώ για την υποστήριξη, την υπομονή και την καθοδήγηση που μου πρόσφερε κατά την διάρκεια αυτής της εργασίας.

Θα ήθελα, επίσης, να ευχαριστήσω τον κ. Κλεάνθη Νεοκλέους για τις ιδέες, τις συμβουλές και την καθοδήγηση που μου πρόσφερε με αποτέλεσμα να βελτιωθεί στο μέγιστο η εργασία αυτή.

Τέλος, ευχαριστώ πάρα πολύ όλους τους φίλους και την οικογένεια μου για την υποστήριξη και την βοήθεια που μου παρείχαν κατά την εκπόνηση της διπλωματικής μου εργασίας

# Περίληψη

Η διπλωματική αυτή εργασία έχει ως σκοπό τη χρήση υπολογιστικών συστημάτων μάθησης στην προσπάθεια επίλυσης ενός πραγματικού προβλήματος στο τομέα της Ιατρικής. Την περίπτωση της Προεκλαμψίας (Preeclampsia) και ειδικότερα την πρόβλεψη παρουσίας της πάθησης αυτής στις εγκύους γυναίκες. Γενικός μας στόχος είναι να καταλήξουμε σε ένα νευρωνικό δίκτυο, που θα είναι όσο το πιο δυνατό ακριβές γίνεται, στο να μας υποδεικνύει αν κάποια ασθενής με βάση τα δεδομένα που έχουμε γι' αυτή (παράμετροι) έχει τη πιθανότητα να παρουσιάσει την πάθηση εν' ονόματι Προεκλαμψία.

Στην εργασία αυτή αναπτύσσονται η όλη διαδικασία που ακολουθήθηκε για την εύρεση συστήματος πρόβλεψης της παρουσίας της Προεκλαμψίας σε κάποια ασθενή βασιζόμενοι σε πραγματικά δεδομένα ασθενών που έχουμε λάβει από το Harris Birthright Research Centre for Fetal Medicine του King's College Hospital Medical School, που βρίσκεται στο Λονδίνο. Τα δεδομένα αυτά καλύπτουν ένα αριθμό 33602 ασθενών.

Αρχικά μελετήθηκαν η ίδια η πάθηση της Προεκλαμψίας ούτως ώστε να γίνει αντιληπτή καλύτερα και ουσιαστικά για να γνωρίζουμε τι είναι ουσιαστικά αυτό που θα έχουμε να αντιμετωπίσουμε. Στη συνέχεια μελετήθηκε παλαιότερη δουλειά που έχει γίνει αναφορικά με το θέμα αυτό της προεκλαμψίας σε σχέση πάντα με την υπολογιστική νοημοσύνη και ειδικότερα της πρόβλεψης της. Ενώ έγινε και μια περαιτέρω μελέτη αναφορικά με τα νευρωνικά δίκτυα/αλγόριθμους που θα δοκιμαστούν για να υπάρχει καλύτερη αντίληψη και ορθότερη χρήση αυτών στη διάρκεια του μετ' έπειτα πιο πρακτικού κομματιού της εργασίας αυτής.

Ακολούθως μπαίνοντας και στο πιο πρακτικό μέρος έγινε μια πρώτη επαφή με τα δεδομένα που είχαμε στη διάθεση μας και θα χρησιμοποιούσαμε στα διάφορα δίκτυα που θα δοκιμαστούν και κατά συνέπεια κατανόηση αυτών όσο το δυνατό καλύτερα από μέρους μου. Έπειτα για χρήση αυτών έγινε η κατάλληλη προ-επεξεργασία και κανονικοποίηση των δεδομένων σε αριθμητικές τιμές (όπου χρειαζόταν) για είσοδο τους στο δίκτυο.

Στο κύριο μέρος πλέον της όλης διαδικασίας έγινε με τη βοήθεια του λογισμικού Neuroshell 2, το οποίο χρησιμοποιήσαμε επί το πλείστο για να γίνουν τα διάφορα simulations που χρειάζονται, μέσα από τα οποία θα ελέγξουμε την αποτελεσματικότητα των διάφορων δομών/αρχιτεκτονικών νευρωνικών δικτύων με απώτερο σκοπό την εύρεση του καλύτερου. Αυτό θα κριθεί με βάση τα ποσοστά επιτυχίας πρόβλεψης που θα παίρνουμε από τα άγνωστα δεδομένα προς το ανάλογο εκπαιδευμένο δίκτυο. Παρόλα αυτά λόγω κάποιου προβλήματος και δυσκολίας κατευθυνθήκαμε σε μια ελαφρώς διαφορετική οδό, στα πλαίσια πάντα του γενικού στόχου της εργασίας αυτής. Θα γίνει εκπαίδευση των δικτύων με πιο ισορροπημένα σετ δεδομένων για καλύτερη εκπαίδευση αυτών. Τα αποτελέσματα αυτής της νέας “ανορθόδοξης οδού” που ακολουθήσαμε ήταν αρκετά ενθαρρυντικά δίνοντας ταυτόχρονα την ευκαιρία για μελλοντική εργασία και συνέχεια γύρω από το θέμα αυτό.

# Περιεχόμενα

|                   |                                                        |           |
|-------------------|--------------------------------------------------------|-----------|
| <b>Κεφάλαιο 1</b> | <b>Εισαγωγή – Θεωρία.....</b>                          | <b>1</b>  |
|                   | 1.1 Εισαγωγή στην Υπολογιστική Νοημοσύνη               | 1         |
|                   | 1.2 Νευρωνικά Δίκτυα                                   | 3         |
|                   | 1.2.1 Νευρωνικά Δίκτυα – Σύντομη ιστορική αναδρομή     | 3         |
|                   | 1.2.2 Τεχνητά Νευρωνικά Δίκτυα                         | 4         |
|                   | 1.3 Εισαγωγή στην Προεκλαμψία (Preeclampsia)           | 7         |
|                   | 1.4 Προηγούμενες προσπάθειες για πρόβλεψη προεκλαμψίας | 10        |
| <br>              |                                                        |           |
| <b>Κεφάλαιο 2</b> | <b>Πρόβλημα προς επίλυση.....</b>                      | <b>14</b> |
|                   | 2.1 Σύντομη περιγραφή προβλήματος                      | 14        |
|                   | 2.2 Δεδομένα                                           | 15        |
|                   | 2.2.1 Ανάλυση δεδομένων                                | 16        |
|                   | 2.2.2 Προ-επεξεργασία/Κανονικοποίηση δεδομένων         | 18        |
| <br>              |                                                        |           |
| <b>Κεφάλαιο 3</b> | <b>Μεθοδολογία.....</b>                                | <b>21</b> |
|                   | 3.1 Αλγόριθμοι/Αρχιτεκτονικές που χρησιμοποιήθηκαν     | 21        |
|                   | 3.1.1 Back-propagation                                 | 22        |
|                   | 3.1.1.1 Backpropagation - Standard Connections         | 22        |
|                   | 3.1.1.2 Backpropagation - Jump Connections             | 23        |
|                   | 3.1.1.3 Backpropagation - Ward Networks                | 24        |
|                   | 3.1.2 General Regression Neural Network (GRNN)         | 25        |
|                   | 3.2 Διαδικασία που ακολουθήθηκε                        | 25        |
|                   | 3.2.1 Προσπάθειες με 13538 περιπτώσεις ασθενών         | 27        |
|                   | 3.2.2 Προσπάθειες με ισορροπημένη εκπαίδευση           | 29        |
|                   | 3.2.2.1 Προσπάθειες με 860 περιπτώσεις ασθενών         | 30        |
|                   | 3.2.2.2 Προσπάθεια με 3346 περιπτώσεις ασθενών         | 31        |

|                              |                                                           |               |
|------------------------------|-----------------------------------------------------------|---------------|
| <b>Κεφάλαιο 4</b>            | <b>Αποτελέσματα.....</b>                                  | <b>33</b>     |
|                              | 4.1 Αποτελέσματα προσπαθειών με 13538 περιπτώσεις ασθενών | 34            |
|                              | 4.1.1 Σχολιασμός αποτελεσμάτων (με 13538 περιπτώσεις)     | 39            |
|                              | 4.2 Αποτελέσματα προσπαθειών με 860 περιπτώσεις ασθενών   | 40            |
|                              | 4.2.1 Αποτελέσματα με το balanced1 set                    | 40            |
|                              | 4.2.2 Αποτελέσματα με το balanced 2/3/4/5 sets            | 43            |
|                              | 4.3 Αποτελέσματα προσπαθειών με 3346 περιπτώσεις ασθενών  | 46            |
| <br><b>Κεφάλαιο 5</b>        | <br><b>Συμπεράσματα.....</b>                              | <br><b>48</b> |
|                              | 7.1 Γενικά Συμπεράσματα                                   | 48            |
|                              | 7.2 Μελλοντική εργασία                                    | 51            |
| <br><b>Βιβλιογραφία.....</b> |                                                           | <br><b>54</b> |

# Κεφάλαιο 1

## Εισαγωγή

---

|                                                        |    |
|--------------------------------------------------------|----|
| 1.1 Εισαγωγή στην Υπολογιστική Νοημοσύνη               | 1  |
| 1.2 Νευρωνικά Δίκτυα                                   | 3  |
| 1.2.1 Νευρωνικά Δίκτυα – Σύντομη ιστορική αναδρομή     | 3  |
| 1.2.2 Τεχνητά Νευρωνικά Δίκτυα                         | 4  |
| 1.3 Εισαγωγή στην Προεκλαμψία (Preeclampsia)           | 7  |
| 1.4 Προηγούμενες προσπάθειες για πρόβλεψη προεκλαμψίας | 10 |

---

### 1.1 Εισαγωγή στην Υπολογιστική Νοημοσύνη

Σήμερα η επιστήμη της Πληροφορικής έχει αποκτήσει ένα πολύ-επιστημονικό ρόλο. Ένα σύγχρονο πεδίο που προέκυψε τα τελευταία χρόνια από τον κλάδο της Πληροφορικής είναι η Τεχνητή Νοημοσύνη. Άρα είναι εμφανές ότι είναι συνδυασμός της Πληροφορικής και της έννοιας ‘Νοημοσύνη’. Δεν υπάρχει καθολική συμφωνία για το τι είναι νοημοσύνη. Δεν χρειάζεται όμως ακριβής ορισμός της, όπως δεν χρειάζεται να ορίσουμε πολλές άλλες έννοιες για να τις αντιληφθούμε και να τη χρησιμοποιήσουμε. Ένας πρακτικός ορισμός για τη νοημοσύνη μπορούμε να πούμε ότι είναι: “Η γενική ικανότητα που εκφράζεται μέσα από τις διαδικασίες υπολογισμών, συλλογισμών, λογικής, διακρίβωσης, μάθησης, χρήσης γλώσσας, αντίληψης του περιβάλλοντος σε διαφορετικούς βαθμούς λεπτομέρειας, εξοικείωσης σε νέο περιβάλλον, αυτό-διόρθωσης, και επινόησης”.

Οι όροι τεχνητή νοημοσύνη και υπολογιστική νοημοσύνη χρησιμοποιούνται συνήθως έτσι που να σημαίνουν το ίδιο πράγμα. Ο όρος Τεχνητή Νοημοσύνη είναι πιο γενικός υπό την έννοια ότι υποδηλώνει κάθε είδος νοημοσύνης που δεν είναι βιολογική.

Ο όρος Υπολογιστική Νοημοσύνη υποδηλώνει κάθε είδος νοημοσύνης που μπορεί να εκδηλωθεί με υπολογιστικές διαδικασίες. [1]

Έτσι υπολογιστική Νοημοσύνη είναι ένα κλάδος τη πληροφορικής που μπορούμε να πούμε σχετίζεται με την Τεχνητή Νοημοσύνη. Ειδικότερα είναι ένα σύνολο μεθοδολογιών και προσεγγίσεων για την αντιμετώπιση των πολύπλοκων προβλημάτων του πραγματικού κόσμου που η εφαρμογή των παραδοσιακών (first principles, probabilistic, black-box, κλπ.) μεθοδολογιών και προσεγγίσεων δεν είναι αποτελεσματική ή ανέφικτη.

Τι ακριβώς όμως είναι Υπολογιστική νοημοσύνη και ποιά είναι η σχέση της με άλλους κλάδους της επιστήμης των υπολογιστών, όπως η Τεχνητή Νοημοσύνη (AI), η ταξινόμηση (classification), η γνωστική πληροφορική (cognitive informatics), connectionism, γραφικές μεθόδους, ευφυείς πράκτορες (intelligent agents) και ευφυή συστήματα, ανακάλυψη γνώσης σε δεδομένα (KnowledgeDiscoveryData), intelligent machines, μάθηση μηχανών, κατανεμημένη παράλληλη επεξεργασία, αναγνώριση προτύπων, probabilistic methods, soft computing, πολυδιάστατη στατιστική και βελτιστοποίηση; Αυτό είναι ένα πολύ μπερδεμένο και πολυσυζητημένο ζήτημα. Υπολογιστική νοημοσύνη έγινε μια λέξη που πλέον σημαίνει διαφορετικά πράγματα σε διαφορετικούς ανθρώπους.

Οι διάφοροι επιστημονικοί κλάδοι δεν ορίζονται, αλλά αναπτύσσονται σιγά-σιγά μέσω ανταλλαγής και ομαδοποίηση κοινών ενδιαφερόντων. Στην Υπολογιστική νοημοσύνη τα ενδιαφέροντα αυτά γενικά επικεντρώνονται σε προβλήματα που μόνο οι άνθρωποι και τα ζώα μπορούν να λύσουν, δηλαδή προβλήματα που απαιτούν νοημοσύνη. Επίσης μερικά από αυτά τα ενδιαφέροντα εστιάζονται στις μεθόδους και τα εργαλεία που εφαρμόζονται σε αυτού του είδους τα προβλήματα. Αρχικά με κάποιες μελέτες, σεμινάρια, που με το χρόνο έγιναν συνεδρία και εξειδικευμένα περιοδικά, αρκετοί κλάδοι της Υπολογιστικής νοημοσύνης εξελίσσονται σε πολλές κατευθύνσεις, συχνά αρκετά μακριά από τις αρχικές τους ρίζες και ιδέες. Έτσι νέες κοινότητες σχηματίζονται με την ανάγκη να καθορίσουν την ταυτότητά τους με τον καθορισμό κάποιων συνόρων, που να τις διακρίνουν από άλλες επιστημονικές κοινότητες. Τεχνητή Νοημοσύνη ήταν η πρώτη μεγάλη επιστημονική κοινότητα, που θεσπίστηκε στα μέσα του 1950, και εργάζεται για τα προβλήματα που απαιτούν νοημοσύνη για να επιλυθούν.

Το IEEE Υπολογιστικής Νοημοσύνης καθορίζει τα θέματα ενδιαφέροντός της, όπως νευρωνικά δίκτυα, ασαφή συστήματα (fuzzy systems) και εξελικτικό υπολογισμό (evolutionary computation), συμπεριλαμβανομένου και της swarm intelligence. Επίσης μέσω της Υπολογιστικής Νοημοσύνης συνδυάζονται η μάθηση, η εξέλιξη, η προσαρμοστικότητα (προσαρμογή με επίβλεψη, χωρίς επίβλεψη και εξαναγκασμένη προσαρμογή), η αυτό-διοργάνωση και η λεγόμενη ασαφής λογική (fuzzy logic) για τη δημιουργία προγραμμάτων και συστημάτων που μπορούμε να τα βάλουμε υπό κάποια άποψη, στην κατηγορία των ευφυή συστημάτων. Αξιοσημείωτο είναι ότι η Υπολογιστική Νοημοσύνη δεν απορρίπτει τελείως τις στατιστικές μεθόδους αλλά αντιθέτως απλά προτείνει κάποιες επιπρόσθετες ή συμπληρωματικές μεθόδους και απόψεις. Η προσέγγιση που υιοθετείται από πολλούς όσον αφορά την Υπολογιστική Νοημοσύνη είναι σαν μια ομπρέλα κάτω από την οποία όλο και περισσότερες μέθοδοι θα προστίθενται. Ένας καλός ορισμός του πεδίου είναι συνεπώς αδύνατο, γιατί διαφορετικοί άνθρωποι προσθέτουν ή αποκλείουν διάφορες μεθόδους κάτω από την έννοια της Υπολογιστικής Νοημοσύνης. [3]

Από αυτά καταλαβαίνουμε ότι η Υπολογιστική Νοημοσύνη είναι ένας κλάδος της πληροφορικής με αρκετό μέλλον που μπορεί να συνδυαστεί και να συνεργαστεί με αρκετούς άλλους κλάδους και επιστήμες. Γι' αυτό και μπορούμε να πούμε ότι αυτή έχει αρκετά μεγάλη σημασία στη επίλυση προβλημάτων και ιδιαίτερα σε αυτά που ακόμη δεν έχουν βρεθεί κάποιες λύσεις που να καλύπτουν όλες τις δυνατές πτυχές που παρουσιάζουν τα διάφορα αυτά προβλήματα.

## **1.2 Νευρωνικά Δίκτυα**

### **1.2.1 Νευρωνικά Δίκτυα – Σύντομη ιστορική αναδρομή**

Η ιστορία των νευρωνικών δικτύων μπορούμε να πούμε ότι άρχισε στα τέλη του 1800 με τις επιστημονικές προσπάθειες για τη μελέτη της λειτουργίας του ανθρώπινου εγκεφάλου. Το 1890, ο William James δημοσίευσε τις πρώτες εργασίες σχετικά με τα πρότυπα της εγκεφαλικής δραστηριότητας (brain activity patterns).

Η ουσιαστική όμως περίοδος των νευρωνικών δικτύων άρχισε με την πρωτοποριακή για τα δεδομένα εποχή δουλειά των McCulloch και Pitts το 1943 [2]. Συγκεκριμένα παρήγαγαν ένα μοντέλο του νευρώνα που χρησιμοποιείται ακόμα και σήμερα στα πλαίσια των τεχνητών νευρωνικών δικτύων. Αυτό το μοντέλο είναι σπασμένο σε δύο μέρη: ένα άθροισμα πάνω από σταθμισμένο εισόδους (weighted inputs) και μια λειτουργία εξόδου του αθροίσματος. Η πλείστη εργασία των McCulloch και Pitts έγινε μέσα σε ένα σύνολο που ασχολούνταν με τους νευρώνες στο πανεπιστήμιο του Σικάγο για πάνω από 5 χρόνια. Αυτή η εργασία περιέγραφε το λογικό λογισμό των νευρωνικών δικτύων.

Φυσικά από τότε μέχρι και σήμερα τα νευρωνικά δίκτυα έχουν σίγουρα διανύσει πολύ δρόμο και έχουν υποστεί πολλές και σημαντικές αλλαγές μέσω νέων ανακαλύψεων που έγιναν από επιστήμονες της κάθε εποχής και συνεχίζονται να γίνονται και θα συνεχίζονται για πολλά ακόμη χρόνια αφού είναι ένας τομέας έρευνας ανοιχτός προς πολλές κατευθύνσεις χωρίς ιδιαίτερους περιορισμούς. Γεγονός που οφείλεται επί το πλείστο στην πολυπλοκότητα του ανθρώπινου εγκεφάλου και στο ότι δεν έχει κατανοηθεί πλήρως ακόμη.

Ένας από τους πιο άγνωστους αλγόριθμους που σχετίζεται με τα νευρωνικά δίκτυα, ο αλγόριθμος Backpropagation, ανακαλύπτεται αρχικά από Werbos το 1974 [14]. Αργότερα όμως έρχεται να ανακαλυφθεί ξανά το 1986 με το βιβλίο *Learning Internal Representation by Error Propagation* του Rumelhart, Hinton και Williams.

Το 1987 πραγματοποιήθηκε το πρώτο IEEE ετήσιο διεθνές συνέδριο για ANN ερευνητές. Το 1987 η Διεθνής Κοινωνία Νευρωνικών Δικτύων (International Neural Network Society - INNS) διαμορφώθηκε, σε συνδυασμό με το INNS περιοδικό Neural Networking το 1988.


### **1.2.2 Τεχνητά Νευρωνικά Δίκτυα**

Τα νευρωνικά δίκτυα (artificial neural network) τα οποία όπως προαναφέραμε ανήκουν μέσα στο τομέα αυτό της Υπολογιστικής Νοημοσύνης και με τα οποία θα ασχοληθούμε ιδιαίτερα είναι υπολογιστικά συστήματα μάθησης που βασίζονται στα βιολογικά

νευρωνικά δίκτυα. Πιο απλά μπορεί να λεχθεί ότι είναι αλγόριθμοι που προσπαθούν να μιμηθούν τα νευρωνικά δίκτυα του ανθρώπινου εγκεφάλου. Το αντικείμενο των τεχνητών νευρωνικών δικτύων γνωρίζει ραγδαία ανάπτυξη τα τελευταία 25 χρόνια και αποτελεί πλέον ένα ευρύ και αυτόνομο επιστημονικό πεδίο, που σχετίζεται με το γενικότερο πλαίσιο της τεχνητής νοημοσύνης και των ευφυών συστημάτων. Αποτελούνται από τους λεγόμενους τεχνητούς νευρώνες (κόμβους) που επεξεργάζονται πληροφορίες χρησιμοποιώντας συνήθως τη υπολογιστική προσέγγιση Connectionism και επίσης ανάλογα με τον αλγόριθμο μάθησης με τον οποίο εκπαιδεύουμε το σύστημα μας. Επιπρόσθετα αξιοσημείωτο είναι ότι τα νευρωνικά δίκτυα (artificial neural network) αλλάζουν τη δομή τους καθώς πληροφορίες εισέρχονται στο σύστημα κατά τη φάση της μάθησης αυτού. Και χρησιμοποιούνται επί το πλείστον για τη μοντελοποίηση σύνθετων και πολύπλοκων προβλημάτων ούτως ώστε να βρουν κάποια πρότυπα (patterns) στα δεδομένα που θα μπορούν να επαναχρησιμοποιηθούν και για άλλα δεδομένα.



**VS.**



**Σχήμα 1.1: Biological Neural Network και Artificial Neural Network**

Η αρχική έμπνευση για τα τεχνητά νευρωνικά δίκτυα προήλθε από το κεντρικό νευρικό σύστημα και τους νευρώνες, άξονες, δενδρίτες και συνάψεις του, που αποτελούν και τα δομικά στοιχεία ενός βιολογικού νευρωνικού δικτύου που ερευνώνται από τη νευρολογία. Σε ένα τεχνητό νευρωνικό δίκτυο, απλοί τεχνητοί κόμβοι, που ονομάζονται και “νευρώνες”, συνδέονται μεταξύ τους για να σχηματίσουν ένα δίκτυο κόμβων που μιμείται τα βιολογικά νευρωνικά δίκτυα για αυτό και ονομάστηκαν “τεχνητά νευρωνικά δίκτυα”.

Επειδή η νευρολογία είναι ακόμα γεμάτη από αναπάντητα ερωτήματα, και επειδή υπάρχουν πολλά επίπεδα αφαιρετικότητας και ως εκ τούτου πολλά ακόμη για να μάθουμε από τον εγκέφαλο, δεν υπάρχει ενιαία επίσημος ορισμός του τι ένα τεχνητό νευρωνικό δίκτυο. Γενικά μπορούμε να πούμε ότι πρόκειται για ένα δίκτυο από απλά στοιχεία επεξεργασίας που παρουσιάζουν μια πολύπλοκη συμπεριφορά που καθορίζεται από τις συνδέσεις μεταξύ των στοιχείων αυτών. Επιπρόσθετα ένα τεχνητό νευρωνικό δίκτυο, χρησιμοποιεί αλγόριθμους που αποσκοπούν να τροποποιήσουν τα λεγόμενα βάρη των συνδέσεων στο δίκτυο για να παραγάγει μια επιθυμητή ροή σήματος.

Τα δίκτυα αυτά είναι επίσης παρόμοια με τα βιολογικά νευρωνικά δίκτυα, από την άποψη ότι οι λειτουργίες εκτελούνται παράλληλα από τις μονάδες. Επί του παρόντος, ο όρος τεχνητά νευρωνικά δίκτυα αναφέρεται κυρίως σε μοντέλα νευρωνικών δικτύων που ασχολούνται με τους τομείς της στατιστικής, της γνωστικής ψυχολογίας και της τεχνητής νοημοσύνης.

Στις σύγχρονες εφαρμογές λογισμικού των τεχνητών νευρωνικών δικτύων, η προσέγγιση που εμπνέεται από τη βιολογία έχει εγκαταλειφθεί σε μεγάλο βαθμό για χάρη μιας πιο πρακτικής προσέγγισης που βασίζεται σε στατιστικές και επεξεργασίας σήματος. Σε μερικά από αυτά τα συστήματα, τα νευρωνικά δίκτυα χρησιμοποιούνται ως συστατικά για μεγαλύτερα συστήματα.

### 1.3 Εισαγωγή στην Προεκλαμψία (Preeclampsia)


Προεκλαμψία, Toxemia, PIH, PET, όλοι είναι όροι που αναφέρονται σε σοβαρές, στενά συνδεδεμένες υπερτασικές συνθήκες της εγκυμοσύνης. Toxemia είναι ένας παλαιότερος όρος βασιζόμενος στο ότι η κατάσταση αυτή ήταν το αποτέλεσμα τοξινών στο αίμα. PET (preeclamptic toxemia) είναι ένας όρος που χρησιμοποιείται από παλαιότερους γιατρούς σε διάφορες χώρες. PIH (Pregnancy Induced Hypertension), ένας νεότερος όρος, σημαίνει βασικά υπέρταση κύησης. Ο όρος προεκλαμψία χρησιμοποιείται για να καλύψει όλες τις παραλλαγές υπερτασικών διαταραχών της κύησης.

Αρα η προεκλαμψία είναι βασικά μια νόσος όπου εμφανίζεται κατά την εγκυμοσύνη ή και τη περίοδο μετά το τοκετό και επηρεάζει τόσο τη μητέρα όσο και το μωρό. Κατά τη νόσο αυτή και ειδικότερα την εγκυμοσύνη μιας γυναίκας παρατηρείται αύξηση της πίεσης αλλά υψηλές ποσότητες πρωτεϊνών στα ούρα. Πρήξιμο (στα χέρια, στα πόδια ή ακόμα και στο πρόσωπο-κυρίως γύρω από τα μάτια), ξαφνική αύξηση βάρους, πονοκέφαλοι, ναυτία, πόνος στην άνω κοιλιακή χώρα και προβλήματα στην όραση είναι κάποια από τα σημαντικότερα συμπτώματα που μπορεί να παρουσιαστούν. Επίσης μπορεί να προκαλέσει σπασμούς, εγκεφαλικά και πολλαπλή οργανική ανεπάρκεια. Ωστόσο, σε κάποιες γυναίκες λόγω του ότι η νόσος αυτή εξελίσσεται σε πολύ πιο γρήγορους ρυθμούς παρουσιάζουν λιγότερα συμπτώματα.

Κύριοι λόγοι που μπορεί να οδηγήσουν στην προεκλαμψία (κύριοι παράγοντες) είναι κατά πόσο η ασθενής είχε τη νόσο ξανά, αν είναι κάτω των 18 ετών ή άνω των 40, αν έχει υψηλή πίεση (ακόμη και πριν την εγκυμοσύνη), αν έχει διαβήτη, αν χρησιμοποιήθηκε εξωσωματική γονιμοποίηση και αν υπάρχει οικογενειακό ιατρικό ιστορικό σε διαβήτη, υψηλή πίεση και φυσικά προεκλαμψία.[7]

Συνήθως η προεκλαμψία εμφανίζεται προς το τέλος του δεύτερου τριμήνου ή κατά το τρίτο τρίμηνο της εγκυμοσύνης. Παρόλο που σε κάποιες περιπτώσεις μπορεί να εμφανιστεί νωρίτερα. Αν δεν προσεχθεί μπορεί όμως να εξελιχθεί σε εκδηλώσεις συνδρόμου HELLP ή εκλαμψία (αναφέρονται πιο κάτω εκτενώς). Αξιοσημείωτο είναι ότι η προεκλαμψία προσβάλλει τουλάχιστον ένα ποσοστό του 5-8% του συνόλου των εγκυμοσύνων και ότι δεν υπάρχει κάποια άμεση θεραπεία εκτός από την πρόωρη γέννα.

Γι' αυτό δυστυχώς οφείλεται και σε χιλιάδες θανάτους μητέρων και βρεφών παγκοσμίως. Το μόνο που μπορεί να γίνει είναι έγκαιρη διάγνωση της νόσου και καλή προγεννητική φροντίδα. Η έρευνα γύρω από τη προεκλαμψία έχει αρχίσει να βρίσκει κάποιες από τις μοριακές ανωμαλίες που υπάρχουν στις γυναίκες με προεκλαμψία και εκφράζεται η ελπίδα ότι αυτές οι πρόσφατες ανακαλύψεις μπορεί να οδηγήσουν στην ανάπτυξη μιας θεραπείας. Με βάση εκτιμήσεις οι διαταραχές αυτές που προκαλούνται κατά τη νόσο είναι υπεύθυνες για τους θανάτους 76.000 μητέρων και 500.000 παιδιών κάθε χρόνο, αλλά και για το 20% πρόωγων γεννών κάθε χρόνο. Επιπρόσθετα η πιθανότητα να προσβληθεί μια γυναίκα που είχε ήδη την ασθένεια σε προηγούμενη εγκυμοσύνη κυμαίνεται από 5 μέχρι 80%, ανάλογα με το πότε εμφάνισε προεκλαμψία σε προηγούμενη εγκυμοσύνη, πόσο σοβαρή ήταν, και τη γενική υγεία της κατά τη σύλληψη.



**Σχήμα1.2: Προ-συμπτωματικός έλεγχος για προεκλαμψία κατά την πρώτη προγεννητική επίσκεψη μετά από 20 εβδομάδες κύησης και ενέργειες προκειμένου να επιβεβαιωθεί τυχόν υπερτασική διαταραχή της κύησης ή/και παραπομπή στο επόμενο επίπεδο της περίθαλψης**

Εκλαμψία (eclampsia), είναι μια πολύ σοβαρή επιπλοκή που μπορεί να προκύψει από σοβαρής μορφής προεκλαμψίας που χαρακτηρίζεται από επιληπτικές κρίσεις κατά τη διάρκεια της εγκυμοσύνης ή κατά την περίοδο μετά τον τοκετό. Στον ανεπτυγμένο κόσμο, η εκλαμψία είναι σπάνια και συνήθως θεραπεύσιμη εάν φυσικά γίνουν έγκαιρα οι κατάλληλες ενέργειες. Αν αφαιρεθεί χωρίς θεραπεία, οι επιληπτικές κρίσεις κατά αυτήν μπορούν να οδηγήσουν σε κώμα, εγκεφαλική βλάβη, και, ακόμα και σε θάνατο της

μητέρας ή το βρέφους. Η προεκλαμψία ονομάστηκε έτσι επειδή αρχικά αναγνωρίστηκε ως διαταραχή που προηγείται της εκλαμψίας, αν και είναι πλέον γνωστό ότι οι επιληπτικές κρίσεις κατά την εκλαμψία είναι μόνο μία από τις πολλές πιθανές επιπλοκές της νόσου. Επιληπτικές κρίσεις κατά την εκλαμψία εμφανίζονται συνήθως όπως ανέφερα ως μια μεταγενέστερη επιπλοκή της σοβαρής προεκλαμψίας, αλλά μπορεί επίσης να προκύψουν χωρίς προηγούμενα συμπτώματα της νόσου. Το 1974, δημοσιεύτηκε στο “ Journal of the American Medical Association” μια περίπτωση εκλαμψίας στις 16 εβδομάδες εγκυμοσύνης. Ακόμη μια ακραία περίπτωση που αναφέρθηκε ήταν μια που εμφάνισε εκλαμψία μόλις 3 εβδομάδες μετά τον τοκετό.

Σύνδρομο HELLP είναι ακόμη μια από τις σοβαρότερες μορφές της προεκλαμψίας και εμφανίζεται σε 5-12% των ασθενών με προεκλαμψία. Μπορεί να οδηγήσει σε σημαντική βλάβη στο συκώτι της μητέρας, σε βλάβη των ερυθρών αιμοσφαιρίων της και σε μείωση του αριθμού των αιμοπεταλίων. HELLP (hemolysis, elevated liver enzymes, and lowered platelets) σημαίνει: αιμολυσία, αυξημένα ηπατικά ένζυμα, και μειωμένα αιμοπετάλια. Το σύνδρομο HELLP μπορεί αρχικά να μπερδευτεί με μια απλή γρίπη ή προβλήματα χοληδόχου κύστης, επειδή οι πόνοι μπορεί να είναι παρόμοιοι και επειδή μπορεί να συμβεί προτού να εμφανιστούν τα λεγόμενα κλασικά συμπτώματα της προεκλαμψίας.

#### **1.4 Προηγούμενες προσπάθειες για πρόβλεψη προεκλαμψίας**

Έχουν γίνει ξανά προσπάθειες για πρόβλεψη της προεκλαμψίας στο παρελθόν. Κυρίως χρησιμοποιώντας πολυδιάστατες στατιστικές μεθόδους όπως η προσπάθεια που έγινε από τους B. Eskenazi, L. Fenster και S. Sidney, οι οποίοι προχώρησαν σε πολυδιάστατη ανάλυση παραγόντων που αν παρουσιαστούν είναι ένδειξη κινδύνου (multivariate analysis of risk factors for preeclampsia) [4]. Βρήκαν ότι παρουσία προεκλαμψίας σε προηγούμενη εγκυμοσύνη αυξάνει το ρίσκο για παρουσία προεκλαμψίας σε μεταγενέστερες εγκυμοσύνες, ενώ πρόσεξαν ότι οι γυναίκες που παρουσίασαν προεκλαμψία συνήθως ήταν υπέρβαρες, είχαν οικογενειακό ιατρικό ιστορικό υπέρτασης και εργάζονταν κατά τη διάρκεια της εγκυμοσύνης. Επίσης υψηλή πιθανότητα να προσληφθούν από τη νόσο παρατηρήθηκε ότι έχουν οι έγχρωμες

γυναίκες που δεν έχουν ξανά γεννήσει. Το γενικό συμπέρασμα που κατέληξαν ήταν βασικά ότι οι γυναίκες με προηγούμενες εγκυμοσύνες αλλά και αυτές χωρίς, έχουν κάποιους κοινούς παράγοντες ρίσκου για παρουσία της νόσου, όμως χρειάζεται να γίνει έρευνα για να καθοριστεί κατά πόσο οι παράγοντες αυτοί μπορούν να χρησιμοποιηθούν εκτενέστερα για τη πρόβλεψη προεκλαμψίας.


Αντίθετα προσπάθειες για πρόβλεψη της προεκλαμψίας μέσω νευρωνικών δικτύων είναι σπάνιες. Μια προσπάθεια που έχει γίνει είναι αυτή από τους Mello G, Parretti E, Ognibene A, Mecacci F, Cioni R, Scarselli G και Messeri G που προσπάθησαν μέσω νευρωνικών δικτύων να προβλέψουν τη παρουσία υπερτασικών διαταραχών κατά την εγκυμοσύνη (PIHD - Pregnancy-induced hypertensive disorders) σε γυναίκες που θεωρούνταν ότι είχαν μεγάλη πιθανότητα να παρουσιάσουν τη νόσο. Έχοντας στη διάθεση τους 303 περιπτώσεις εγκυμονούσων γυναικών με υψηλό ρίσκο παρουσίας προεκλαμψίας χρησιμοποίησαν νευρωνικά δίκτυα και multivariate logistic regression (MLR) και στη συνέχεια σύγκριναν τα αποτελέσματα των δύο, παρατηρώντας ότι ανάμεσα στις αυτές μεθόδους τα νευρωνικά δίκτυα παρουσιάζονταν πιο αποτελεσματικά. [5]

Μια ακόμη πιο πρόσφατη προσπάθεια που έγινε χρησιμοποιώντας νευρωνικά δίκτυα για να γίνει πρόβλεψη για προεκλαμψία έγινε από τους Νεοκλέους Κ., Αναστασόπουλο Π., Νικολαΐδη Κ., Σχίζα Χ. και Νεοκλέους Κ. το 2006 [6]. Συγκεκριμένα είχαν 24 παραμέτρους για κάθε ασθενή από τις οποίες 15 μετρήσεις-παραμέτροι εισήχθησαν ως είσοδοι στο δίκτυο (Πίνακας 1.1), θεωρώντας ότι αυτές έπαιζαν πιο σημαντικό ρόλο στο κατά πόσο υπήρχε το ρίσκο-πιθανότητα να εμφανιστεί προεκλαμψία στον ασθενή.

|                                                                           |
|---------------------------------------------------------------------------|
| 1. Mean arterial pressure (MAP)                                           |
| 2. Uterine pulsatility index (UPI)                                        |
| 3. Serum marker PAPP-A                                                    |
| 4. Ethnicity                                                              |
| 5. Weight                                                                 |
| 6. Height                                                                 |
| 7. Smoking? (Y/N)                                                         |
| 8. Alcohol consumption? (Y/N)                                             |
| 9. Previous preeclampsia case?                                            |
| 10. Conception (spontaneous, ovulation drug or IVF)                       |
| 11. Medical condition of pregnant woman                                   |
| 12. Drugs taken by the pregnant woman                                     |
| 13. Gestation age (in days) when the crown rump length (CRL) was measured |
| 14. Crown rump length                                                     |
| 15. Mother had preeclampsia? (Y/N)                                        |

**Πίνακας 1.1: Οι 15 παράμετροι που χρησιμοποιήσαν για την πρόβλεψη της προεκλαμψίας**

Η βάση δεδομένων που διέθεταν ήταν 6838 περιπτώσεις ασθενών που προέρχονταν από περιοχές του Λονδίνου και γενικά από την νοτιοανατολική Αγγλία εκ των οποίων μόνο ένας αριθμός των 130 είχαν τη νόσο της προεκλαμψίας. Έχοντας αυτά προχώρησαν στη δοκιμασία διαφόρων feed-forward δομών νευρωνικών δικτύων. Μέσω διαφόρων δοκιμών που έκαναν και δομών που δοκιμάστηκαν κατέληξαν ότι τα αποτελέσματα με πολλαπλή γραμμική παλινδρόμηση (multiple linear regression) και πολλαπλή μη-γραμμικής παλινδρόμηση (multiple non-linear regression) δεν ήταν τόσο καλά όσο αυτά του νευρωνικού δικτύου ταξινομητή (neural network classifier) όπου βρήκε όλες τις περιπτώσεις με προεκλαμψία στον άγνωστο σετ δεδομένων (evaluation set) 5 από τις 5. Στο Σχήμα 1.3 φαίνεται η δομή του νευρωνικού δικτύου που χρησιμοποίησαν τελικά και είχαν τα ανάλογα αποτελέσματα.



**Σχήμα 1.3:** Το νευρωνικό δίκτυο που χρησιμοποίησαν τελικά

Καταλήγοντας έτσι στο απώτερο συμπέρασμα ότι τα νευρωνικά δίκτυα μπορούν να χρησιμοποιηθούν για αυτό το σκοπό πρόβλεψης προεκλαμψίας αλλά χρειάζεται να δοκιμαστούν εκτενέστερα με περισσότερες περιπτώσεις ασθενών πριν μπορούν να εφαρμοστούν στο μέλλον. Αφού για παράδειγμα αν και είναι γνωστό ότι περιπτώσεις έγχρωμων γυναικών είναι κάπως πιο επιρρεπείς στη πάθηση της προεκλαμψίας αυτό δεν καλύπτεται στη μελέτη τους αυτή, λόγω του μικρού αριθμού περιπτώσεων έγχρωμων γυναικών που διέθεταν.

## Κεφάλαιο 2

### Πρόβλημα προς επίλυση

---

|                                                |    |
|------------------------------------------------|----|
| 2.1 Σύντομη περιγραφή προβλήματος              | 14 |
| 2.2 Δεδομένα                                   | 15 |
| 2.2.1 Ανάλυση δεδομένων                        | 16 |
| 2.2.2 Προ-επεξεργασία/Κανονικοποίηση δεδομένων | 18 |

---

#### 2.1 Σύντομη περιγραφή προβλήματος

Βασικά το πρόβλημα που έχουμε να αντιμετωπίσουμε στα πλαίσια της διπλωματικής αυτής είναι αυτό της προεκλαμψίας σε συνδυασμό με την Υπολογιστική Νοημοσύνη (νευρωνικά δίκτυα). Δηλαδή πρέπει να βρεθεί εν κατακλείδα ένας τρόπος πρόβλεψης της εμφάνισης της νόσου της προεκλαμψίας σε κάποια εγκυμονούσα γυναίκα αφού δεν υπάρχει κάποια θεραπεία για αυτό. Με τα δεδομένα που έχουμε σήμερα η καλύτερη αντιμετώπιση είναι η γρήγορη πρόγνωση της ούτως ώστε να ληφθούν όσο καλύτερα μέτρα και να γίνουν οι κατάλληλες ενέργειες για αντιμετώπιση και αποτροπή από τα χειρότερα που ίσως προέκυπταν αν δεν γινόταν κάτι.

Εν συντομία, είναι όσο το πιο δυνατό ακριβής πρόβλεψη μέσω ενός δικτύου Υπολογιστικής Νοημοσύνης για το αν κάποια ασθενής τείνει να προσβληθεί από τη νόσο της προεκλαμψίας. Με βάση κάποιες μετρήσεις που έγιναν σε σχέση με τον ασθενή και κάποια χαρακτηριστικά του ασθενή που έχουμε στη διάθεση μας, τα οποία είναι οι παράμετροι που θα χρησιμοποιηθούν στο νευρωνικό δίκτυο που θα έχουμε, στοχεύουμε να έχουμε όσο καλύτερα ποσοστά επιτυχίας μετά από φυσικά κάποια εκπαίδευση που θα γίνει στο δίκτυο. Σημαντικό είναι να έχουμε καλά αποτελέσματα αφού μέχρι σήμερα δεν υπάρχει κάποιος ασφαλής τρόπος να πούμε αν κάποια έγκυος γυναίκα έχει τη πιθανότητα να προσληφθεί από τη νόσο αυτή της προεκλαμψίας ή και ακόμη αν έχει ήδη τη νόσο, δεν υπάρχει θεραπεία γι' αυτή. Επίσης από τη σκοπιά του

γιατρού, το δίκτυο θα πρέπει να του προσφέρει κάτι παραπάνω από ότι είχε στη διάθεση του μέχρι τώρα μέσω των κλασικών μεθόδων (στατιστικές μέθοδοι κτλ). Επομένως ποσοστά γύρω στο 50-70% που ίσως σε κάποιες άλλες περιπτώσεις θα ήταν επαρκή, εδώ δεν μας είναι αρκετά. Άρα μπορούμε να πούμε ότι ένα ποσοστό επιτυχίας πάνω από 80% θα ήταν αρκετά καλό και πάνω από 90% ιδανικό για να θεωρήσουμε το αποτέλεσμα ως απόλυτη επιτυχία του αρχικού στόχου που θέσαμε.

## 2.2 Δεδομένα

Για την εκπαίδευση ενός νευρωνικού δικτύου χρειάζονται τα ανάλογα δεδομένα-είσοδοι. Στην περίπτωση μας αυτά είναι οι μετρήσεις που πάρθηκαν από ένα αριθμό ασθενών (33602 cases) από το Harris Birthright Research Centre for Fetal Medicine του King's College Hospital Medical School που βρίσκεται στο Λονδίνο στην Αγγλία.

Οι παράμετροι που έχουμε είναι 13 για κάθε ασθενή (βλ. Πίνακα 2.1). Μερικές από αυτές τις παραμέτρους είναι αποτέλεσμα κλινικών εξετάσεων που έγιναν στους ασθενείς ενώ κάποιες είναι κοινωνικό-επιδημιολογικές (socio-epidemiologic).

|                                                        |                                                                   |
|--------------------------------------------------------|-------------------------------------------------------------------|
| <b>Race (Φυλή)</b>                                     | <b>Smoking (Κάπνισμα)</b>                                         |
| <b>Previous Pregnancies (Προηγούμενες εγκυμοσύνες)</b> | <b>Patient's mother has PE (Μητέρα ασθενούς είχε προεκλαμψία)</b> |
| <b>Conception (Σύλληψη)</b>                            | <b>Chronic Hypertension (Χρόνια υπέρταση)</b>                     |
| <b>Blood test PAPP-A</b>                               | <b>Blood test <math>\beta</math>-hCG (ορμόνη της εγκυμοσύνης)</b> |
| <b>Doppler</b>                                         | <b>Blood pressure (Αρτηριακή πίεση)</b>                           |
| <b>Height (Ύψος)</b>                                   | <b>Weight (Βάρος)</b>                                             |
| <b>Maternal Age (ηλικία της μητέρας)</b>               |                                                                   |

**Πίνακας 2.1: Δεδομένα-είσοδοι (μετρήσεις που πάρθηκαν από τους ασθενείς)**

Από το σύνολο των περιπτώσεων ασθενών που είχαμε ως δεδομένα, χαρακτηριστικό είναι ότι μόνο 752 περιπτώσεις είναι για ασθενείς που έχουν την νόσο της προεκλαμψίας (δηλαδή μόλις 2.24%). Ενώ οι υπόλοιπες 32850 περιπτώσεις είναι χωρίς προεκλαμψία. Κάτι που κάνει εμφανές πόσο δύσκολο θα είναι το έργο που έχουμε να διεκπεραιώσουμε αφού είναι εμφανές η ανισορροπία μεταξύ των δεδομένων και των δύο κατηγοριών που έχουμε (με προεκλαμψία και χωρίς προεκλαμψία), γεγονός που δείχνει το πολύ μικρό αριθμό περιπτώσεων με προεκλαμψία που θα χρησιμοποιηθούν για την εκπαίδευση του δίκτυο που έχει ως στόχο μια καλή γενίκευση.

### 2.2.1 Ανάλυση Δεδομένων

- **Race (Φυλή):** Παράμετρος που μας δείχνει από πια φυλή προέρχεται η ασθενής. Δηλαδή αν είναι χρώματος άσπρου, έγχρωμη, από την ανατολική Ασία, από την νότια Ασία ή αν προέρχεται από περισσότερες από μια από τις πιο πάνω φυλές.
- **Smoking (Κάπνισμα):** Παράμετρος που μας λέει αν η ασθενής είναι καπνίστρια ή όχι.
- **Previous Pregnancies (Προηγούμενες εγκυμοσύνες):** Υπόδειξη κατά πόσο η ασθενής έχει ή δεν έχει ξανά κυοφορήσει. Αν ναι, κατά πόσο είχε προεκλαμψία σε προηγούμενη εγκυμοσύνη.
- **Patient's mother has PE (Μητέρα ασθενούς είχε προεκλαμψία):** Υπόδειξη κατά πόσο η μητέρα της ασθενούς είχε παρουσιάσει προεκλαμψία.
- **Conception (Σύλληψη):** Παράμετρος που μας λέει κατά με πιο τρόπο η ασθενής έμεινε έγκυος. Αν με φυσικό τρόπο ή χρησιμοποίησε φάρμακα (ovulation drugs).
- **Chronic Hypertension (Χρόνια υπέρταση):** Κατά πόσο η ασθενής έχει χρόνια υπέρταση δηλαδή έχει υψηλή πίεση (και πριν την εγκυμοσύνη).
- **Blood test PAPPa:** Μέτρηση της παρουσίας πρωτεΐνης PAPPa (Pregnancy-Associated Plasma Protein A) στο αίμα. Η μέτρηση αυτή είναι μια από τους πολλούς ελέγχους αίματος που χρησιμοποιείται κυρίως για την αξιολόγηση του κινδύνου για ανάπτυξη συνδρόμου Down στο μωρό. Η δοκιμή γίνεται συνήθως μεταξύ 8 και 14 εβδομάδων της εγκυμοσύνης. Η PAPPa παρουσιάζεται σε πολύ χαμηλά επίπεδα (σε σχέση με τα κανονικά) στις περιπτώσεις αυτές.

Χρησιμοποιείται επίσης η μέτρηση αυτή όπως είναι εμφανές και στα πλαίσια της διάγνωσης για την προεκλαμψία.

- **Blood test  $\beta$ -hCG (ορμόνη της εγκυμοσύνης):** hCG (Human chorionic gonadotropin) είναι μια ορμόνη που παράγεται από τον πλακούντα της εγκύου γυναίκας. Ανιχνεύεται στο αίμα και στα ούρα εντός 10 ημερών από τη γονιμοποίηση και ως εκ τούτου αποτελεί τη βάση όλων των τεστ εγκυμοσύνης. Είναι σημαντικό να γνωρίζουμε τα επίπεδα της  $\beta$ -hCG γιατί, καθώς το έμβρυο αναπτύσσεται, το επίπεδο της hCG αυξάνεται και, ως φυσικό επακόλουθο, τα επίπεδα  $\beta$ -hCG αναμένεται να διπλασιάζονται κάθε 36 με 48 ώρες. Δραματική μείωση των επιπέδων μπορεί να υποδείξει ότι έχει γίνει αποβολή του εμβρύου ή είναι πιθανόν να γίνει, ενώ όταν επίπεδο παραμένει το ίδιο ή πέφτει αρκετά κάτω από τα φυσιολογικά όρια μπορεί να υποδείξει έκτοπη κύηση (ectopic pregnancy).  $\beta$ -hCG μπορεί επίσης να χρησιμοποιηθεί για να προσδιορίσει κυήσεις διδύμων, τριδύμων και ούτω καθεξής. Λαμβάνεται επίσης υπόψη όπως είναι εμφανές και στα πλαίσια της διάγνωσης για την προεκλαμψία.[10]
- **Doppler:** Doppler υπερηχογράφημα είναι μια πλέον εδραιωμένη τεχνική που χρησιμοποιείται για τη διάγνωση των προβλημάτων κατά τη διάρκεια της εγκυμοσύνης. Το υπερηχογράφημα Doppler είναι μια μη-επεμβατική (noninvasive) εξέταση που μπορεί να χρησιμοποιηθεί για τη μέτρηση της ροής του αίματος και την αρτηριακή πίεση χρησιμοποιώντας υψηλής συχνότητας ηχητικά κύματα (υπέρηχος) στα ερυθρά αιμοσφαίρια. Σε αντίθεση με ένα κανονικό υπερηχογράφημα που χρησιμοποιεί ηχητικά κύματα για την παραγωγή εικόνων, αλλά δεν μπορεί να δείξει τη ροή του αίματος. Ένα υπερηχογράφημα Doppler μπορεί να βοηθήσει στη διάγνωση πολλών παθήσεων, όπως θρόμβους αίματος, ελαττώματα καρδιακής βαλβίδας, φραγμένες αρτηρίες, λειτουργικές ανεπάρκειες των βαλβίδων στις φλέβες στα πόδια σας, που μπορούν να προκαλέσουν αίμα ή άλλα υγρά να μαζευτούν στα πόδια (φλεβική ανεπάρκεια), μειωμένη κυκλοφορία του αίματος στα πόδια, στένωση μιας αρτηρίας, όπως αυτές στο λαιμό (καρωτιδικής αρτηρίας).

Ένα υπερηχογράφημα Doppler μπορεί να υπολογίσει πόσο γρήγορα ρέει το αίμα από τη μέτρηση της συχνότητας αυτού. Κατά τη διάρκεια ενός υπερηχογραφήματος Doppler, μια μικρή συσκευή χειρός (αισθητήριο), περίπου στο μέγεθος ενός σαπουνιού, πιέζεται πάνω στο δέρμα πάνω από την περιοχή

του σώματός που εξετάζεται, μετακινώντας το από τη μία περιοχή σε άλλη ανάλογα με τις ανάγκες. Αυτή η εξέταση μπορεί να διεξαχθεί ως εναλλακτική λύση για περισσότερο επεμβατικές εξετάσεις, όπως η αρτηριογραφία και venography, όπου χρωστική ουσία μπαίνει στα αιμοφόρα αγγεία μέσω ένεσης, έτσι ώστε να εμφανίζονται σαφώς στην ακτινογραφία εικόνες. Μια εξέταση υπερήχου Doppler μπορεί να βοηθήσει επίσης να το γιατρό να ελέγξει για τραυματισμούς στις αρτηρίες ή για την παρακολούθηση ορισμένων φλεβών και αρτηριών στα πλαίσια κάποιας θεραπείας. Χρησιμοποιείται και για την προεκλαμψία για το λόγο ότι είναι μη-επεμβατική εξέταση κυρίως για μέτρηση της αρτηριακής πίεσης.[11, 12]

- **Blood pressure (Αρτηριακή πίεση):** Μέτρηση που μας δείχνει την αρτηριακή πίεση της ασθενούς. Η αρτηριακή πίεση πάρθηκε από αυτοματοποιημένες συσκευές και από το μπράτσο του ασθενή όπως συνηθίζεται.
- **Height (Ύψος):** Πόσο ύψος έχει η ασθενής.
- **Weight (Βάρος):** Πόσο ζυγίζει η ασθενής.
- **Maternal Age (ηλικία της μητέρας):** Η ηλικία της ασθενούς.

### 2.2.2 Προ-επεξεργασία/Κανονικοποίηση δεδομένων

Τα δεδομένα (δηλαδή οι περιπτώσεις ασθενών που έχουμε) μας έχουν δοθεί όπως φαίνεται και στο Πίνακα 2.2.

| ID Sort  | Output | MA   | Race  | Height | weight | Conception  | Smoking | Previous pregnancies            | Patients mother had PE | Chronic hypertension | Blood test PAPP | Blood test β-hCG | Doppler | Blood pressure |
|----------|--------|------|-------|--------|--------|-------------|---------|---------------------------------|------------------------|----------------------|-----------------|------------------|---------|----------------|
| 8166,2   | Normal | 32,5 | White | 154,0  | 94,0   | spontaneous | no      | Previous pregnancies without PE | No                     | No                   | 0,945           | 1,254            | 1,73    | 118,00         |
| 19053,2  | Normal | 34,4 | Black | 162,0  | 75,0   | spontaneous | no      | Previous pregnancies with PE    | Patients mother had PE | Chronic hypertension | 1,331           | 2,423            | 2,13    | 118,00         |
| 58880,1  | Normal | 35,3 | White | 167,6  | 87,0   | spontaneous | Smoker  | Previous pregnancies without PE | No                     | No                   | 0,622           | 0,881            | 2,28    | 118,17         |
| 85484,1  | Normal | 33,4 | Black | 161,0  | 85,0   | spontaneous | no      | Previous pregnancies without PE | No                     | Chronic hypertension | 0,928           | 0,532            | 2,09    | 118,33         |
| 97631,1  | Normal | 43,3 | Black | 165,1  | 98,0   | spontaneous | Smoker  | Previous pregnancies without PE | No                     | Chronic hypertension | 1,598           | 0,694            | 1,39    | 118,50         |
| 62933,1  | Normal | 44,1 | White | 175,0  | 80,0   | spontaneous | no      | No previous pregnancies         | No                     | No                   | 0,342           | 0,758            | 1,09    | 119,00         |
| 87647,2  | Normal | 25,0 | Black | 165,1  | 91,0   | spontaneous | No      | No previous pregnancies         | No                     | No                   | 0,796           | 0,687            | 2,09    | 119,33         |
| 72121,2  | Normal | 35,2 | Black | 165,1  | 67,0   | spontaneous | no      | Previous pregnancies with PE    | Patients mother had PE | Chronic hypertension | 0,828           | 0,548            | 2,47    | 120,67         |
| 60421,1  | Normal | 33,3 | White | 165,0  | 88,5   | spontaneous | no      | No previous pregnancies         | Patients mother had PE | No                   | 1,764           | 1,019            | 1,26    | 121,00         |
| 105104,1 | Normal | 36,5 | Black | 160,0  | 84,0   | spontaneous | No      | No previous pregnancies         | Patients mother had PE | Chronic hypertension | 0,850           | 1,384            | 1,21    | 121,33         |
| 58761,1  | Normal | 39,5 | Black | 169,0  | 94,0   | spontaneous | no      | Previous pregnancies with PE    | No                     | Chronic hypertension | 1,047           | 0,802            | 1,19    | 121,50         |

**Πίνακας 2.2: Μερικά από τα δεδομένα στην αρχική τους μορφή**

Όπως φαίνεται (βλ. Πίνακα 2.2) κάποιες από τις παραμέτρους για τον κάθε ασθενή μετρώνται με αριθμητικό τρόπο ενώ κάποιοι άλλοι παρουσιάζονται με φυσικό λόγο

(π.χ. στην παράμετρο κάπνισμα δείχνεται με τις λέξεις “No” για τους μη καπνιστές και “smoker” για τους καπνιστές). Στα πλαίσια των νευρωνικών δικτύων οι παράμετροι-εισόδους δεν μπορούν να εισαχθούν στο δίκτυο σε μορφή φυσικής γλώσσας αλλά πρέπει να είναι αριθμητικής μορφής ούτως ώστε να μπορούν να χρησιμοποιηθούν στις διάφορες πράξεις και εξισώσεις που θα γίνουν κατά την εκπαίδευση του νευρωνικού δικτύου. Έτσι έπρεπε να γίνει η κατάλληλη κωδικοποίηση αυτών για να μπορούν να χρησιμοποιηθούν. Οι παράμετροι που ήδη ήταν σε αριθμητική μορφή δηλαδή το MA (Maternal Age - ηλικία της μητέρας), το ύψος (height), το βάρος (weight), η Αρτηριακή πίεση (Blood pressure), το Doppler, το Blood test β-hCG και το Blood test PAPP-A παρέμειναν ως είχαν. Οι υπόλοιποι 6 παράμετροι-εισόδους αλλά και το output (παράμετρος-έξοδος) κωδικοποιήθηκαν σε αριθμητικές τιμές. Η κωδικοποίηση αυτών φαίνεται στο Πίνακα 2.3.

|                                |                             |                                     |                                  |                |           |
|--------------------------------|-----------------------------|-------------------------------------|----------------------------------|----------------|-----------|
| <b>Output:</b>                 | Normal = 1                  | PE = 2                              |                                  |                |           |
| <b>Race:</b>                   | White = 1                   | South Asian = 2                     | Black = 3                        | East Asian = 4 | Mixed = 5 |
| <b>Patients mother had PE:</b> | No = 0                      | Patients mother had PE = 1          |                                  |                |           |
| <b>Conception:</b>             | Spontaneous = 1             | Ovulation drugs = 2                 |                                  |                |           |
| <b>Previous pregnancies:</b>   | No previous pregnancies = 0 | Previous pregnancies without PE = 1 | Previous pregnancies with PE = 2 |                |           |
| <b>Chronic hypertension:</b>   | No = 0                      | Chronic hypertension = 1            |                                  |                |           |
| <b>Smoking:</b>                | No = 0                      | Smoker = 1                          |                                  |                |           |

**Πίνακας 2.3: Κωδικοποίηση παραμέτρων**

Επιπρόσθετα από τις 33602 περιπτώσεις ασθενών που είχαμε στη διάθεση μας 20064 είχαν τουλάχιστον μια από τις παραμέτρους-εισόδους ως “no test”. Δηλαδή δεν είχε γίνει η συγκεκριμένη εξέταση στους ασθενείς αυτούς. Ειδικότερα 8135 είχαν το Blood Pressure ως “no test”, 408 είχαν το Doppler ως “no test” και 11521 είχαν τόσο το Blood Pressure όσο και το Doppler ως “no test” (βλ. Πίνακα 2.4). Έτσι μετά από σκέψη, εξαιρέσαμε τις περιπτώσεις αυτές αφού δεν θα μπορούσαν να χρησιμοποιηθούν στα πλαίσια του νευρωνικού δικτύου. Αυτό γιατί οι υπόλοιπες περιπτώσεις θα είχαν 13 εισόδους ενώ αυτές θα είχαν μια ή δύο λιγότερες. Επίσης δεν μπορούσε να γίνει κανονικοποίηση των “no test” για χρησιμοποίηση στο δίκτυο αφού οι συγκεκριμένες

στήλες στις οποίες παρουσιάζονται τα “no test” οι τιμές είναι ήδη σε αριθμητική μορφή και αν γινόταν τυχόν κωδικοποίηση των “no test” σε αριθμητική τιμή το δίκτυο θα θεωρούσε ότι έχει γίνει η ανάλογη εξέταση στην πραγματικότητα και ο συγκεκριμένοι ασθενείς είχαν την τιμή (που είναι όμως απλά μια κωδικοποίηση).

Π.χ. αν άφηνα τα “no test” και έκανα τη κωδικοποίηση “no test”=0, σε κάποια ασθενή με το αρτηριακή πίεση (Blood Pressure) ως “no test” το δίκτυο θα θεωρούσε ότι έγινε η μέτρηση της αρτηριακής πίεσης της και ισούται με 0. Πράγμα που όμως δεν ισχύει αφού για την ασθενή αυτή δεν έχουμε την αρτηριακή πίεση της. Έτσι έχει μείνει πλέον ένας αριθμός 13538 περιπτώσεων στη διάθεση μας.

|          |   |     |   |     |     |   |   |   |   |   |       |       |         |         |
|----------|---|-----|---|-----|-----|---|---|---|---|---|-------|-------|---------|---------|
| 90659,1  | 1 | 1,0 | 3 | 0,0 | 1,0 | 1 | 0 | 1 | 0 | 0 | 1,000 | 1,000 | 1,00    | no test |
| 18735,2  | 1 | 1,0 | 3 | 0,0 | 1,0 | 1 | 0 | 1 | 0 | 0 | 1,000 | 1,000 | 1,00    | no test |
| 72989,2  | 1 | 1,0 | 3 | 0,0 | 1,0 | 1 | 0 | 1 | 0 | 0 | 1,000 | 1,000 | 1,00    | no test |
| 52271,2  | 1 | 1,0 | 3 | 0,0 | 1,0 | 1 | 0 | 1 | 0 | 0 | 1,000 | 1,000 | 1,00    | no test |
| 95341,1  | 1 | 1,0 | 3 | 0,0 | 1,0 | 1 | 0 | 1 | 0 | 0 | 1,000 | 1,000 | 1,00    | no test |
| 82744,1  | 1 | 1,0 | 3 | 0,0 | 1,0 | 1 | 0 | 1 | 0 | 0 | 1,000 | 1,000 | 1,00    | no test |
| 104372,1 | 1 | 1,0 | 1 | 1,0 | 1,0 | 1 | 0 | 1 | 0 | 0 | 1,000 | 0,000 | 0,00    | no test |
| 74513,1  | 1 | 1,0 | 1 | 1,0 | 1,0 | 1 | 0 | 1 | 0 | 0 | 1,000 | 0,000 | 0,00    | no test |
| 29122,2  | 1 | 1,0 | 1 | 0,0 | 1,0 | 1 | 1 | 1 | 0 | 0 | 1,000 | 0,000 | 0,00    | no test |
| 100905,1 | 1 | 1,0 | 1 | 0,0 | 0,0 | 1 | 0 | 0 | 0 | 0 | 1,000 | 0,000 | 0,00    | no test |
| 93642,1  | 1 | 1,0 | 1 | 1,0 | 1,0 | 1 | 0 | 2 | 0 | 0 | 1,000 | 0,000 | 0,00    | no test |
| 97939,1  | 1 | 1,0 | 5 | 1,0 | 1,0 | 1 | 0 | 0 | 0 | 0 | 1,000 | 1,000 | no test | 1,00    |
| 92084,1  | 1 | 1,0 | 3 | 0,0 | 1,0 | 1 | 1 | 0 | 0 | 0 | 1,000 | 1,000 | no test | 1,00    |
| 96667,1  | 1 | 1,0 | 1 | 1,0 | 1,0 | 1 | 0 | 0 | 0 | 0 | 1,000 | 1,000 | no test | 0,00    |
| 88201,1  | 1 | 1,0 | 1 | 0,0 | 1,0 | 1 | 0 | 0 | 0 | 0 | 1,000 | 1,000 | no test | 0,00    |
| 82266,1  | 1 | 1,0 | 3 | 1,0 | 1,0 | 1 | 0 | 0 | 0 | 0 | 1,000 | 1,000 | no test | 1,00    |
| 78269,1  | 1 | 1,0 | 1 | 1,0 | 1,0 | 1 | 0 | 0 | 0 | 0 | 1,000 | 1,000 | no test | 1,00    |
| 83020,1  | 1 | 1,0 | 1 | 0,0 | 1,0 | 1 | 1 | 0 | 0 | 0 | 1,000 | 1,000 | no test | 1,00    |
| 88088,1  | 1 | 1,0 | 1 | 0,0 | 1,0 | 1 | 0 | 0 | 0 | 0 | 1,000 | 1,000 | no test | 1,00    |
| 79340,1  | 1 | 1,0 | 1 | 1,0 | 1,0 | 1 | 0 | 1 | 0 | 1 | 1,000 | 1,000 | no test | no test |
| 49615,2  | 1 | 1,0 | 1 | 0,0 | 1,0 | 1 | 0 | 1 | 0 | 1 | 1,000 | 1,000 | no test | no test |
| 59480,2  | 1 | 1,0 | 1 | 1,0 | 0,0 | 1 | 0 | 1 | 0 | 1 | 0,000 | 1,000 | no test | no test |
| 73730,1  | 1 | 1,0 | 1 | 0,0 | 1,0 | 1 | 0 | 0 | 0 | 0 | 1,000 | 1,000 | no test | no test |
| 88456,1  | 1 | 1,0 | 1 | 1,0 | 1,0 | 1 | 0 | 0 | 0 | 0 | 1,000 | 1,000 | no test | no test |
| 46728,2  | 1 | 1,0 | 1 | 0,0 | 1,0 | 1 | 0 | 1 | 0 | 1 | 1,000 | 1,000 | no test | no test |
| 31959,2  | 1 | 1,0 | 1 | 1,0 | 1,0 | 1 | 0 | 1 | 0 | 1 | 1,000 | 1,000 | no test | no test |
| 72653,1  | 1 | 1,0 | 2 | 0,0 | 1,0 | 1 | 0 | 0 | 0 | 0 | 1,000 | 1,000 | no test | no test |

**Πίνακας 2.4.: Μερικά από τα δεδομένα με “no test”**

# Κεφάλαιο 3

## Μεθοδολογία

---

|                                                    |    |
|----------------------------------------------------|----|
| 3.1 Αλγόριθμοι/Αρχιτεκτονικές που χρησιμοποιήθηκαν | 21 |
| 3.1.1 Back-propagation                             | 22 |
| 3.1.1.1 Backpropagation - Standard Connections     | 22 |
| 3.1.1.2 Backpropagation - Jump Connections         | 23 |
| 3.1.1.3 Backpropagation - Ward Networks            | 24 |
| 3.1.2 General Regression Neural Network (GRNN)     | 25 |
| 3.2 Διαδικασία που ακολουθήθηκε                    | 25 |
| 3.2.1 Προσπάθειες με 13538 περιπτώσεις ασθενών     | 27 |
| 3.2.2 Προσπάθειες με ισορροπημένη εκπαίδευση       | 29 |
| 3.2.2.1 Προσπάθειες με 860 περιπτώσεις ασθενών     | 30 |
| 3.2.2.2 Προσπάθεια με 3346 περιπτώσεις ασθενών     | 31 |

---

### 3.1 Αλγόριθμοι/Αρχιτεκτονικές που χρησιμοποιήθηκαν

Στα πλαίσια της διπλωματικής αυτής εργασίας χρησιμοποιήθηκε το πρόγραμμα Neuroshell 2. Το πρόγραμμα αυτό δίνει τη δυνατότητα να δοκιμαστούν ένας αριθμός αρχιτεκτονικών για το πρόβλημα που επιθυμεί ο χρήστης. Οι αρχιτεκτονικές που προσφέρονται είναι η Back-propagation με διάφορες παραλλαγές της (standard connections, jump connections, ward nets, recurrent networks), η Kohonen (Self Organizing Map), τα Probabilistic Neural Networks και τα General Regression Neural Networks [9]. Από αυτές χρησιμοποιήθηκαν αυτές που θεωρήσαμε καλύτερες με βάση τις γνώσεις που κατείχαμε μέχρι τώρα για το πρόβλημα της προεκλαμψίας σε συνδυασμό με τα νευρωνικά δίκτυα, και θα αναλυθούν πιο κάτω.

### 3.1.1 Back-propagation


Back-propagation είναι μια κοινή μέθοδος διδασκαλίας τεχνητών νευρωνικών δικτύων για το πώς να εκτελέσει μια συγκεκριμένη εργασία. Αρχικά αναφέρεται για αυτή ο Arthur E. Bryson και Yu-Chi Ho το 1969, αλλά δεν κέρδισαν την αναγνώριση που ξέρουμε και σήμερα μέχρι και το 1974, όπου μέσα από το έργο των P.Werbos, David E. Rumelhart, Geoffrey E. Hinton και Ronald J. Williams, αναδείχθηκαν και οδήγησαν σε μια επανάσταση στον τομέα της έρευνας των τεχνητών νευρωνικών δικτύων. Πρόκειται για μια επιβλεπόμενη μέθοδο μάθησης, και μια γενίκευση του delta rule. Απαιτεί έναν δάσκαλο που γνωρίζει, ή μπορεί να υπολογίσει, το επιθυμητό αποτέλεσμα για κάθε πιθανή είσοδο στα πλαίσια της εκπαίδευσης (training). Είναι ιδιαίτερα χρήσιμη για τα λεγόμενα feed-forward δίκτυα (δηλαδή δίκτυα που δεν έχουν συνδέσεις που οδηγούν σε βρόχους) . Τα back-propagation δίκτυα είναι γνωστά για την ικανότητά τους να γενικεύουν καλά σε μια ευρεία ποικιλία προβλημάτων. Ανάλογα με τον αριθμό των προτύπων, η εκπαίδευση μπορεί να είναι πιο αργή σε σχέση με άλλες περιπτώσεις. Τα back-propagation δίκτυα χρησιμοποιούνται για τη συντριπτική πλειοψηφία των υπάρχοντων νευρωνικών δικτυακών εφαρμογών, επειδή τείνουν να γενικεύουν καλά.

Στα δίκτυα back-propagation, ο αριθμός των κρυφών νευρώνων καθορίζει το πόσο καλά το πρόβλημα μπορεί να μαθευτεί από το δίκτυο. Εάν χρησιμοποιηθούν πάρα πολλοί, το δίκτυο θα τείνει να προσπαθεί να απομνημονεύσει το πρόβλημα, και έτσι δεν θα γενικεύει καλά αργότερα που θα δοκιμαστεί με άγνωστα δεδομένα. Αν όμως χρησιμοποιηθούν πολύ λίγοι νευρώνες, το δίκτυο θα γενικεύει μεν καλά, αλλά δεν θα έχει αρκετή "δύναμη" για να μάθει τα πρότυπα κατά την εκπαίδευση καλά. Για να βρεθεί ο σωστός αριθμός κρυφών νευρώνων δεν υπάρχει κάποιος καθορισμένος τρόπος ή μέθοδος, μπορεί να γίνει μόνο με συνεχές δοκιμή και υπολογισμό του λάθους που προκύπτει κάθε φορά (trial & error).

#### 3.1.1.1 Backpropagation - Standard Connections

Αυτός είναι ο απλός τύπος του δικτύου back-propagation στον οποίο κάθε στρώμα είναι συνδεδεμένο με το αμέσως προηγούμενο στρώμα. Έτσι μπορούν να δημιουργηθούν δίκτυα αποτελούμενα από πολλά στρώματα. Έχει διαπιστωθεί ότι ένα δίκτυο back-propagation με τρία στρώματα (με standard connections) είναι κατάλληλο για την


επίλυση σχεδόν όλων των προβλημάτων, φτάνει να χρησιμοποιείται και ο κατάλληλος αριθμός κρυμμένων νευρώνων.



**Σχήμα 3.1: Απλό Ν.Α. Back-propagation 3 στρωμάτων (με standard connections)**

### 3.1.1.2 Backpropagation - Jump Connections


Αυτό είναι ένα είδος δικτύου back-propagation στο οποίο κάθε στρώμα είναι συνδεδεμένο με κάθε προηγούμενο στρώμα, σε αντίθεση με του απλού τύπου συνδέσεις (standard connections) που συνδέουν κάποιο νευρώνα μόνο με τους νευρώνες του αμέσως προηγούμενου στρώματος.



**Σχήμα 3.2: Ν.Α. Back-propagation 3 στρωμάτων (με jump connections)**

### 3.1.1.3 Backpropagation – Ward networks

Τα κρυφά στρώματα σε ένα νευρωνικό δίκτυο είναι γνωστά και ως ανιχνευτές χαρακτηριστικών (features detectors). Ως αποτέλεσμα αυτού η Ward Systems Group ανακάλυψε τρεις διαφορετικές αρχιτεκτονικές δικτύων back-propagation με πολλαπλά κρυμμένα στρώματα. Διαφορετικά activation functions εφαρμόζονται στους νευρώνες των κρυφών στρωμάτων ανιχνεύοντας έτσι διάφορα χαρακτηριστικά σε ένα πρότυπο που περνά μέσα από το δίκτυο. Για παράδειγμα, ένα δίκτυο μπορεί να χρησιμοποιεί Gaussian συνάρτηση σε μια κρυφή πλάκα (ένα σύνολο από νευρώνες) και να χρησιμοποιεί Linear συνάρτηση σε κάποια άλλη κρυφή πλάκα. Έτσι, το στρώμα εξόδου θα πάρει διαφορετικές "απόψεις για τα δεδομένα." Συνδυάζοντας τις διαφορετικές αυτές απόψεις για τα δεδομένα το στρώμα εξόδου μπορεί να οδηγήσει σε μια καλύτερη πρόγνωση. Υπάρχουν τρεις διαφορετικοί τύποι Ward networks αυτό με 2 Hidden Slabs with Different Activation Functions, με 3 Hidden Slabs with Different Activation Functions και με 2 Hidden Slabs, Different Activation Functions+Jump connection.



**Σχήμα 3.3: Ward net - με 2 Hidden Slabs with Different Activation Functions**

### 3.1.2 General Regression Neural Network (GRNN)

Τα GRNN δίκτυα (Νευρωνικά Δίκτυα Γενικής Παλινδρόμησης) είναι γνωστά για την ικανότητά τους να εκπαιδεύσουν γρήγορα σε αραιά σύνολα δεδομένων. GRNN είναι ένα είδος δικτύου με επιβλεπόμενη μάθηση (supervised network). Πιστεύεται ότι τα GRNN ανταποκρίνονται πολύ καλύτερα από ότι τα back-propagation δίκτυα σε πολλούς τύπους προβλημάτων (αλλά όχι όλους). Τα GRNN μπορούν να έχουν πολυδιάστατη είσοδο, και μπορούν να περάσουν πολυδιάστατες επιφάνειες μέσω των δεδομένων.

GRNN είναι βασικά ένα δίκτυο τριών επιπέδων, όπου πρέπει να υπάρχει ένα κρυφός νευρώνας για κάθε πρότυπο στην εκπαίδευση (training pattern). Δεν υπάρχουν παράμετροι εκπαίδευσης, όπως ρυθμός μάθησης και ορμή όπως στο back-propagation, αλλά υπάρχει ένας παράγοντας εξομάλυνσης (smoothing factor), που εφαρμόζεται μετά που το δίκτυο είναι εκπαιδευμένο.

### 3.2 Διαδικασία που ακολουθήθηκε

Ένας αριθμός από αρχιτεκτονικές/αλγόριθμους δοκιμάστηκαν συστηματικά για την εύρεση της καλύτερης πρόβλεψης.

Τα νευρωνικά δίκτυα (αρχιτεκτονικές) που δοκιμάστηκαν είναι αυτά που αναφέρονται στο υποκεφάλαιο 3.1. Για την εύρεση των αποτελεσμάτων χρησιμοποιήθηκαν κάποιοι βασικοί παράμετροι των αρχιτεκτονικών του συστήματος κατά την εκπαίδευση. Οι παράμετροι αυτοί αλλάζονταν κατά τη διάρκεια της όλης φάσης που δοκιμάζονταν οι αρχιτεκτονικές για να βρεθεί η καλύτερη αρχιτεκτονική για το πρόβλημα αυτό και ταυτόχρονα να υπάρχει η δυνατότητα για μια ευρύτερη αναζήτηση στο πολυδιάστατο χώρο για καλύτερα αποτελέσματα. Ακολουθεί μια σύντομη εξήγηση των βασικών αυτών παραμέτρων.

- **Hidden Slabs (1, 2, 3):** Ο αριθμός των κρυφών πλακών που χρησιμοποιούνται στα δίκτυα. Ο αριθμός των νευρώνων και το activation function ορίζονται επίσης στα πλαίσια αυτής της παραμέτρου.
- **Learning rate:** Κάθε φορά που ένα πρότυπο (pattern) παρουσιάζεται στο δίκτυο, τα βάρη που οδηγούν σε κόμβο εξόδου τροποποιούνται ελαφρώς κατά τη διάρκεια της μάθησης σύμφωνα με ένα "σφάλμα" που προκύπτει αναλόγως. Η αναπροσαρμογή των βαρών είναι βασικά μια συνάρτηση του ποσοστού

μάθησης (learning rate) και του σφάλματος (error). Εδώ η τιμή μένει σταθερή στο 0.1.

- **Initial weights:** Καθώς οι νευρώνες περνούν τιμές από ένα στρώμα του δικτύου στο άλλο στρώμα σε δίκτυα, οι τιμές τροποποιούνται από μια τιμή βάρους στο σύνδεσμο που μας δείχνει πόσο ισχυρή είναι μια σύνδεση μεταξύ των νευρώνων. Τα βάρη (weights) αρχικά σε μια αρχιτεκτονική θέτονται τυχαία αφού αλλάζουν στη πορεία εκπαίδευσης. Εδώ αρχικοποιούνται πάντα με 0.3 ως προκαθορισμένη τιμή.
- **Momentum (Ορμή):** Μεγάλα ποσοστά μάθησης συχνά οδηγούν σε διακυμάνσεις (oscillations) των αλλαγών στα βάρη και η μάθηση ποτέ δεν ολοκληρώνεται όπως πρέπει, ή καταλήγουμε σε λύση που δεν είναι η καλύτερη που μπορεί να βρεθεί. Ένας τρόπος για να γίνει γρηγορότερη μάθηση χωρίς διακυμάνσεις είναι να ληφθεί υπόψη και να χρησιμοποιηθεί ο παράγοντας της ορμής που λαμβάνει υπόψη του το ποσοστό αλλαγών των βαρών σε κάθε βήμα της διαδικασίας της εκπαίδευσης. Εδώ η τιμή μένει σταθερή στο 0.2.
- **Stop criteria:** Τα κριτήρια που χρησιμοποιούνται για το πότε θα σταματήσει την εκπαίδευση το δίκτυο. (π.χ. αριθμός εποχών που θα περάσουν). Εδώ χρησιμοποιείται σε όλα ως κριτήριο, οι 2000 εποχές .

| hidden_slab1 | hidden_slab2 | hidden_slab3 | stop criteria           |
|--------------|--------------|--------------|-------------------------|
| 100_Gaussian | 100_Gaussian |              | trainSet<br>epochs=2000 |

**Πίνακας 3.1: Παράδειγμα των βασικών παραμέτρων που χρησιμοποιούνται κατά τη διάρκεια της εκπαίδευσης**

Για την αξιολόγηση των επιδόσεων κάθε αρχιτεκτονικής των νευρωνικών δικτύων που χρησιμοποιήθηκε κατά τη διάρκεια της εκπαίδευσης, θεώρησα τους ακόλουθους παράγοντες:

- **Tr\_min.aver.error:** Η χαμηλότερη τιμή για τον μέσο σφάλμα που το δίκτυο πέτυχε κατά τη διάρκεια της εκπαίδευσης των δεδομένων στον training set.

- **Test\_min.aver.error:** Η χαμηλότερη τιμή για τον μέσο σφάλμα που το δίκτυο πέτυχε κατά τη διάρκεια της εκπαίδευσης των δεδομένων στον testing set.
- **Percentage of correct prediction:** Παρουσιάζει τον αριθμό των σωστών προβλέψεων σε σχέση με το συνολικό αριθμό των περιπτώσεων σε κάθε κατάσταση (normal και abnormal) μαζί με τα υπολογιζόμενα συνολικά ποσοστά των επιτυχών προβλέψεων για το evaluation/production set και το training set.
- **Mean sq. error:** Μέσο σφάλμα που προκύπτει από όλες τις περιπτώσεις από το evaluation set που δοκιμάζεται.

|                   |                     |                | Percentage of correct prediction (%) |              |                |                |
|-------------------|---------------------|----------------|--------------------------------------|--------------|----------------|----------------|
| tr_min.aver.error | test_min.aver.error | mean sq. error | TRAINING SET                         | TRAINING SET | EVALUATION SET | EVALUATION SET |
|                   |                     |                | Normal                               | Abnormal     | Normal         | Abnormal       |
|                   |                     |                | 7710/7874                            | 120/250      | 48/85          | 2005/2622      |
| ,0060669          | 0,0147811           | 0,153          | 97,9%                                | 48%          | 56,47%         | 76,43%         |


**Πίνακας 3.2: Παράδειγμα των παραγόντων που χρησιμοποιούνται για την αξιολόγηση του δικτύου**

Το test set το οποίο χρησιμοποιείται κατά τη διάρκεια της εκπαίδευσης βασικά εφαρμόζεται στο τέλος κάθε εποχής (epoch) για να γίνει κάποιος έλεγχος της προόδου που έχει το training. Αν τα αποτελέσματα κατά το testing σε κάποιο χρονικό σημείο  $t$  ήταν καλύτερα από ό,τι στο χρονικό σημείο  $t-1$ , τότε τα βάρη φυλάσσονται ως αυτά του καλύτερου σετ. Στο τέλος της διαδικασίας αυτής (της όλης εκπαίδευσης) το σύνολο των καλύτερων βαρών φυλάσσεται για να χρησιμοποιηθεί στη πρόβλεψη.

### 3.2.1 Προσπάθειες με 13538 περιπτώσεις ασθενών

Αρχικά πήραμε τις 13538 πλήρεις περιπτώσεις που έμειναν μετά την προ-επεξεργασία των δεδομένων. Για τους σκοπούς χρήσης αυτών σε νευρωνικά δίκτυα τα διαχώρισα σε training set (60%), test set (20%) και production/evaluation set (20%). Τα training και test sets χρησιμοποιήθηκαν βασικά στα πλαίσια της εκπαίδευσης του ανάλογου νευρωνικού δικτύου ενώ το production/evaluation set είναι οι περιπτώσεις που


αφέθηκαν άγνωστες προς το εκπαιδευμένο δίκτυο για να ελέγξω την αποτελεσματικότητα αυτού μετά. Η επιλογή των σετ έγινε με τυχαίο τρόπο. Ο διαχωρισμός φαίνεται στο Σχήμα 3.4.



**Σχήμα 3.4: Διαχωρισμός δεδομένων σε training, test και production/evaluation sets (13538 περιπτώσεις)**

Στη συνέχεια λαμβάνοντας υπόψη συνεχώς τα αποτελέσματα που έπαιρνα μέσω των συστηματικών δοκιμών που έγιναν με διάφορα νευρωνικά δίκτυα επιλέχτηκε το καλύτερο από αυτά. Η επιλογή του καλύτερου δικτύου γινόταν λαμβάνοντας φυσικά με βάση το ολικό ποσοστό επιτυχίας του δικτύου (δηλαδή σωστές προβλέψεις True Positive ή True Negative), αλλά κυρίως δινόταν προσοχή στο ποσοστό επιτυχίας πρόβλεψης των περιπτώσεων που παρουσίασαν προεκλαμψία (True Positive) αφού προτιμότερο και πιο σημαντικό είναι να προβλεφτεί σωστά αν κάποια ασθενής θα παρουσιάσει προεκλαμψία ούτως ώστε οι γιατροί να κινηθούν κατάλληλα και να προλάβουν τα χειρότερα που ίσως ακολουθήσουν. Οι συνέπειες θα είναι σαφέστατα πιο μεγάλες αν κάποια ασθενής που θα εμφανίσει προεκλαμψία δεν έχει προβλεφτεί σωστά από το δίκτυο (False Negative), παρά από το αν κάποια ασθενής που εν κατακλείδι δεν παρουσιάσει προεκλαμψία βρεθεί από το δίκτυο θετική στη πιθανότητα να εμφανίσει προεκλαμψία (False Positive). Στη 2<sup>η</sup> περίπτωση το πιο πιθανό το μόνο που θα γίνει είναι ότι στη συγκεκριμένη ασθενή που βρέθηκε False Positive θα γίνουν εκτενέστερες εξετάσεις και οι γιατροί θα είναι πιο προσεκτικοί με αυτή, ενώ σε περίπτωση False

Negative μπορεί η ασθενής ακόμη και να πεθάνει αν δεν αντιμετωπιστεί κατάλληλα η ασθένεια.



**Σχήμα 3.5: Γενική δομή νευρωνικού δικτύου με τις 13 εισόδους που χρησιμοποιώ και την ανάλογη έξοδο-πρόβλεψη**

### 3.2.2 Προσπάθειες με ισορροπημένη εκπαίδευση


Στη συνέχεια αφού δεν λάβαμε τα αναμενόμενα αποτελέσματα στις προηγούμενες προσπάθειες με όλα τα δεδομένα, δοκιμάσαμε μια νέα ανορθόδοξη ιδέα που δεν συνηθίζεται να γίνεται. Αφού οι προσπάθειες ως τώρα δεν είχαν όπως ανάφερα “καλά” αποτελέσματα, σκεφτήκαμε να δοκιμάσουμε να μειώσουμε τα δεδομένα και συγκεκριμένα τον αριθμό των normal περιπτώσεων. Η διαίρεση του μεγάλου συνόλου normal δεδομένων πρέπει να γίνει με έναν τρόπο που τα μικρότερα υποσύνολα να

συμπεριλαμβάνουν όλες τις πιθανές ομάδες φυσιολογικές περιπτώσεις, με αποτέλεσμα να χρειάζεται περαιτέρω προ-επεξεργασία αλγοριθμικών δεδομένων (δηλαδή η μείωση να γίνει με σωστό και μεθοδικό τρόπο). Όμως στη προσπάθεια αυτή παρουσιάστηκε πρόβλημα στη μείωση αφού κάθε περίπτωση ασθενή συνήθως παρουσιάζοταν να έχει τις δικές της ιδιαιτερότητες. Αποτέλεσμα αυτού ήταν να μην μπορέσουμε να αφαιρέσουμε ουσιαστικά και ορθά έναν αριθμό normal περιπτώσεων που ήταν ο συγκεκριμένος στόχος τη δεδομένη στιγμή.

Παρόλα αυτά για να εξεταστεί αυτή την υπόθεση, αποφασίσαμε να πειραματιστούμε με μια μάλλον ανορθόδοξη διαδικασία, όπου πρόκειται να γίνει τυχαία επιλογή των περιπτώσεων χωρίς προεκλαμψία ώστε να φτάσουν σε παρόμοιο αριθμό με τον αριθμό των περιπτώσεων με προεκλαμψία. Παρά το ότι η διαίρεση του μεγάλου συνόλου στοιχείων, όπως αναφέρεται, πρέπει να γίνει με προσεκτική εξέταση αυτό το τεστ θα μπορούσε να μας δώσει κάποιες πρώτες ενδείξεις για την αποτελεσματικότητα αυτής της προσέγγισης. Αν πάρουμε καλά αποτελέσματα θα δοκιμάσουμε με διαφορετικά σετ. Με το τρόπο αυτό θα δούμε αν το δίκτυο μπορεί να μάθει και της abnormal περιπτώσεις και αν η μέχρι στιγμής αποτυχία οφείλεται στη μη ισορροπία ανάμεσα στις περιπτώσεις.

### **3.2.2.1 Προσπάθειες με 860 περιπτώσεις**

Έτσι δοκιμάσαμε με ένα αριθμό 860 περιπτώσεων εκ των οποίων 440 ήταν normal και 420 abnormal. Που είναι καθαρά ένα πιο ισορροπημένο σετ δεδομένων σε σχέση με πριν ( $13118 \text{ normal} > 420 \text{ abnormal}$ ). Οι abnormal περιπτώσεις έμειναν ως είχαν λόγω του πολύ μικρού αριθμού αυτών ενώ διαλέχτηκαν με κάποιο τυχαίο τρόπο οι normal περιπτώσεις που θα συμπλήρωναν τις abnormal στη ολοκλήρωση του ισορροπημένου σετ.




**Σχήμα 3.6: Διαχωρισμός δεδομένων σε training, test και production/evaluation sets (860 περιπτώσεις)**

Αφού δοκιμάσαμε αρκετές αρχιτεκτονικές και ελέγχοντας τις με ένα σετ που δημιουργήθηκε, προσέξαμε ότι στις περισσότερες από τις αρχιτεκτονικές που δοκιμάστηκαν, κάποιες περιπτώσεις ασθενών αν και στη πραγματικότητα είναι normal (δηλαδή χωρίς προεκλαμψία) παρουσιάζονταν από τα δίκτυα αυτά ως abnormal (με προεκλαμψία). Έτσι αφαιρέσαμε αυτές από το evaluation set που είχαμε και τις αντικαταστήσαμε με άλλες normal περιπτώσεις ασθενών από τα δεδομένα που δεν χρησιμοποιήθηκαν (δεν περιλαμβάνονταν μέσα στα 860). Επίσης δοκιμάσαμε και άλλα εντελώς καινούργια σετ (τα ονόμασα balanced3, balanced4, balanced5) με πάλι τυχαία επιλογή περιπτώσεων normal ασθενών από το σύνολο αυτών.

### 3.2.2.2 Προσπάθεια με 3346 περιπτώσεις ασθενών

Ακολούθως αφού τελειώσαμε με τις προσπάθειες με τα ισορροπημένα δεδομένα (balanced1, balanced2, balanced3, balanced4, balanced5 sets) θα δοκιμάσουμε αφήνοντας τα training και test sets ως έχουν με το ισορροπημένο τρόπο εκπαίδευσης, ένα μεγαλύτερο evaluation/production set όπου τα normal δεδομένα θα είναι περισσότερα από τα abnormal. Έτσι θα δούμε με ακόμη ένα τρόπο αν ισχύει η υπόθεση που έχουμε κάνει και ακολουθήσαμε βασιζόμενη σε μια ισορροπημένη εκπαίδευση. Η επιλογή των normal περιπτώσεων έγινε με τυχαίο τρόπο (βλ. Σχήμα 3.7).



**Σχήμα 3.7: Διαχωρισμός δεδομένων σε training, test και production/evaluation sets**

## Κεφάλαιο 4

### Αποτελέσματα

---

|                                                           |    |
|-----------------------------------------------------------|----|
| 4.1 Αποτελέσματα προσπαθειών με 13538 περιπτώσεις ασθενών | 34 |
| 4.1.1 Σχολιασμός αποτελεσμάτων (με 13538 περιπτώσεις)     | 39 |
| 4.2 Αποτελέσματα προσπαθειών με 860 περιπτώσεις ασθενών   | 40 |
| 4.2.1 Αποτελέσματα με το balanced1 set                    | 40 |
| 4.2.2 Αποτελέσματα με το balanced2/balanced3 sets         | 43 |
| 4.3 Αποτελέσματα προσπαθειών με 3346 περιπτώσεις ασθενών  | 46 |

---


Κατά την διάρκεια αυτής της διπλωματικής εργασίας, μετά την υλοποίηση των νευρωνικών δικτύων που αναλύσαμε στο προηγούμενο κεφάλαιο, παράχθηκαν αρκετά αποτελέσματα, εκ των οποίων κάποια από αυτά ήταν ικανοποιητικά και άλλα δεν ήταν. Η διαδικασία παραγωγής των αποτελεσμάτων είναι μια πολύ χρονοβόρα διαδικασία και ο χρόνος που αφιερώθηκε για την εξαγωγή τους ήταν αρκετά μεγάλος. Ο λόγος είναι ότι για την ολοκλήρωση μιας σωστής εκπαίδευσης σε κάποια από τα δίκτυα που δοκιμάστηκαν χρειάστηκε αρκετός χρόνος. Συγκεκριμένα στα αρχικά δίκτυα που δοκιμάστηκαν με τα 13538 περιπτώσεις και κυρίως σε αυτά με μεγάλων αριθμών νευρώνων στα κρυφά επίπεδα. Επίσης η ίδια η διαδικασία της εκπαίδευσης είναι πολύ ευαίσθητη στις διάφορες παραμέτρους που θα της δώσουμε. Ακόμα και μια μικρή αλλαγή στις παραμέτρους μπορεί να επηρεάσει σημαντικά, είτε αρνητικά, είτε θετικά τα αποτελέσματα μας. Όπως αλλαγή του activation function.

Τα αποτελέσματα που πάρθηκαν, θα τα παρουσιάσω περιεκτικά και με τρόπο ξεκάθαρο, όπου θα φαίνονται μεταξύ άλλων η επιτυχία πρόβλεψης στο evaluation set που ήταν τα άγνωστα δεδομένα για το ανάλογο εκπαιδευμένο δίκτυο (αλλά και στο training set), οι τιμές των λαθών (errors) στα training και test sets που προέκυψαν από την εκπαίδευση και οι ανάλογοι παράμετροι που χρησιμοποιήθηκαν για την εκπαίδευση κάθε δικτύου.

#### 4.1 Αποτελέσματα προσπαθειών με 13538 περιπτώσεις ασθενών

Αρχικά όπως ανέφερα και στο προηγούμενο κεφάλαιο δοκιμάσαμε όπως είναι φυσικό με όλες τις 13538 πλήρεις περιπτώσεις ασθενών που είχαμε στη διάθεση μας.


Αρχή έγινε με την αρχιτεκτονική standard back-propagation (Σχήμα 4.1) με ένα κρυμμένο επίπεδο (σύνολο 3 επίπεδα). Για την εκπαίδευση αυτής χρησιμοποιήσαμε Gaussian activation function, learning rate ίσο με 0.1, ορμή (momentum) ίσο με 0.2 και κριτήριο για τέλος της εκπαίδευσης έθεσα τις 2000 εποχές στο training set.



**Σχήμα 4.1: Backpropagation Architecture - Standard Connections (3 Layers)**

Εφαρμόζοντας το training set (Σχήμα 4.2) προσέξαμε ότι κατά τη εκπαίδευση έμαθε 7710 από τις 7874 normal περιπτώσεις (97.9%) και 120 από τις 250 abnormal περιπτώσεις (48%). Όπως φαίνεται και στο Σχήμα 4.2 η πρόοδος της εκπαίδευσης δεν ήταν και η καλύτερη βλέποντας τη μείωση του error. Στο evaluation set που ήταν το άγνωστο για το δίκτυο αφού το έτρεξα στο πλέον εκπαιδευμένο δίκτυο προσέξαμε ότι έβρισκε 48 από τις 85 abnormal περιπτώσεις (56.47%) και 2005 από τις 2622 normal περιπτώσεις (76.43%). Γενικά στο evaluation το συγκεκριμένο δίκτυο βρήκε 75.84% (συνολικά σωστές προβλέψεις) και 24.16% (συνολικά λανθασμένες προβλέψεις).

Παρόλο το όχι και τόσο άσχημο ποσοστό ορθών προβλέψεων (75.84%), οι περιπτώσεις των abnormal ασθενών έχουν μόλις πάνω από το 50% σωστές προβλέψεις που δεν είναι καθόλου καλό αφού αυτό είναι το σημαντικότερο ποσοστό πρόβλεψης (πιο σημαντική η ορθή πρόβλεψη των abnormal περιπτώσεων).




**Σχήμα 4.2: Πρόοδος της εκπαίδευσης: Training set average error vs. Epochs**

Με αντίστοιχο τρόπο δοκιμάστηκαν και άλλες αρχιτεκτονικές όπως οι Backpropagation Architecture - Standard Connections (4 Layers), Backpropagation Architecture - Standard Connections (5 Layers), Backpropagation Architecture - Jump Connections (3 Layers), Backpropagation Architecture - Jump Connections (4 Layers), General Regression Neural Networks (genetic adaptive), Backpropagation Architecture - Ward Networks (2 Hidden Slabs with Different Activation Functions), Backpropagation Architecture - Ward Networks (3 Hidden Slabs with Different Activation Functions), Backpropagation Architecture - Ward Networks (2 Hidden Slabs, Different Activation Functions + Jump Connection)...

Ενδεικτικά στην αρχιτεκτονική Backpropagation - Ward Networks (2 Hidden Slabs, Different Activation Functions + Jump Connection) που δοκίμασα με Gaussian

activation function, learning rate ίσο με 0.1, ορμή (momentum) ίσο με 0.2 και κριτήριο για τέλος της εκπαίδευσης έθεσα τις 1200 εποχές στο training set. (Σχήμα 4.3)



**Σχήμα 4.3: Ward Networks (2 Hidden Slabs, Different Activation Functions + Jump Connection)**

Στο training set παρατηρήθηκαν ποσοστά 99,6% για τις normal περιπτώσεις και 40.8% για τις abnormal περιπτώσεις ενώ στο evaluation set που ήταν το άγνωστο για το δίκτυο αφού τρέξαμε στο πλέον εκπαιδευμένο δίκτυο παρατηρήθηκε ότι έβρισκε 24 από τις 85 abnormal περιπτώσεις (28.23%) και 2480 από τις 2622 normal περιπτώσεις (94.50%). Γενικά στο evaluation το συγκεκριμένο δίκτυο βρήκε 92.50% (συνολικά σωστές προβλέψεις) και μόλις 7.50% (συνολικά λανθασμένες προβλέψεις). Παρόλο το πολύ καλό ποσοστό ορθών προβλέψεων (92.50%), οι περιπτώσεις των abnormal ασθενών έχουν μόλις πάνω από το 28.23% σωστές προβλέψεις που δεν είναι καθόλου καλό (πιο σημαντική η ορθή πρόβλεψη των abnormal περιπτώσεων). Ομοίως ισχύει και για το training. Το πολύ καλό ποσοστό που βγήκε συνολικά οφείλεται επί το πλείστο στο γεγονός ότι προβλέφθηκαν ορθά σχεδόν όλες οι normal περιπτώσεις. Αυτό όμως αν και θετικό από μια άποψη έχει ως κύριο αρνητικό στοιχείο του ότι λόγω του μεγάλου αριθμού normal περιπτώσεων σε σχέση με τα abnormal, το δίκτυο είχε το φαινόμενο

της υπέρ-μάθησης αφού μάθαινε πολύ καλά τις περιπτώσεις των ασθενών χωρίς προεκλαμψία που ήταν σαφώς περισσότερες και δεν γενίκευε όσο καλά θέλαμε. Αποτέλεσμα αυτού ήταν να δείχνει πολλές περιπτώσεις abnormal ασθενών ως normal. (π.χ. αν μια περίπτωση ασθενή με προεκλαμψία είχε κάποιες από τις παραμέτρους εισόδου της παρόμοιες με αυτές ασθενών που δεν έχουν παρουσιάσει προεκλαμψία, το δίκτυο έχοντας δει κατά την εκπαίδευση επί το πλείστο περιπτώσεις normal είναι φυσικό κατά κάποιο τρόπο να κατανέμει και την προαναφερθείσα ως normal). Αυτό μας δείχνει ότι δεν έγινε καλή γενίκευση από το δίκτυο.

Τα αποτελέσματα που πήραμε από simulations που έγιναν με 13538 δεδομένα φαίνονται στο Πίνακα 4.1.

| Architecture                   |              |                   |              |               |               |                     |                | Percentage of correct prediction |                      |                         |                     |
|--------------------------------|--------------|-------------------|--------------|---------------|---------------|---------------------|----------------|----------------------------------|----------------------|-------------------------|---------------------|
|                                |              |                   |              |               |               |                     |                | TRAINING SET                     | TRAINING SET         | EVALUATION SET          | EVALUATION SET      |
| <b>3-layers standard:</b>      | hidden_slab1 | hidden_slab2      | hidden_slab3 | stop criteria | tr_min.aver.e | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal                  | Abnormal            |
|                                | 100_Gaussian |                   |              | epochs=2000-1 | 0,0060669     | 0,0147811           | 0,153          | 7710/7874 <b>97,9%</b>           | 120/250 <b>48%</b>   | 2005/2622 <b>76,43%</b> | 48/85 <b>56,47%</b> |
|                                | 75_Gaussian  |                   |              | epochs=2000-1 | 0,0066187     | 0,0150148           | 0,062          | 7854/7874 <b>99,7%</b>           | 59/250 <b>23,6%</b>  | 2503/2622 <b>95,46%</b> | 18/85 <b>21,17%</b> |
|                                | 50_Gaussian  |                   |              | epochs=2000-1 | 0,0074805     | 0,0152044           | 0,041          | 7842/7874 <b>99,59%</b>          | 45/250 <b>18%</b>    | 2576/2622 <b>98,2%</b>  | 12/85 <b>14,11%</b> |
|                                | 120_Gaussian |                   |              | epochs=2000-1 | 0,0067833     | 0,015048            | 0,041          | 7851/7874 <b>99,7%</b>           | 45/250 <b>18%</b>    | 2575/2622 <b>98,2%</b>  | 16/85 <b>18,8%</b>  |
|                                | 50_linear    |                   |              | epochs=2000-1 | 0,0165442     | 0,0158193           | 0,039          | 7837/7874 <b>99,5%</b>           | 17/250 <b>6,8%</b>   | 2586/2622 <b>98,6%</b>  | 7/85 <b>8,23%</b>   |
|                                | 50_tanh      |                   |              | epochs=2000-1 | 0,0106141     | 0,0156155           | 0,039          | 7841/7874 <b>99,58%</b>          | 36/250 <b>14,4%</b>  | 2575/2622 <b>98,2%</b>  | 9/85 <b>10,58%</b>  |
| <b>4-layers standard:</b>      | hidden_slab1 | hidden_slab2      | hidden_slab3 | stop criteria | tr_min.aver.e | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal                  | Abnormal            |
|                                | 100_Gaussian | 100_Gaussian      |              | epochs=2000-1 | 0,0006856     | 0,0148645           | 0,049          | 7797/7874 <b>99%</b>             | 45/250 <b>18%</b>    | 2536/2622 <b>96,68%</b> | 16/85 <b>18,8%</b>  |
| <b>5-layers standard:</b>      | hidden_slab1 | hidden_slab2      | hidden_slab3 | stop criteria | tr_min.aver.e | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal                  | Abnormal            |
|                                | 50_Gaussian  | 50_Gaussian       | 50_Gaussian  | epochs=2000-1 | 0,0006627     | 0,0147189           | 0,068          | 7817/7874 <b>99,27%</b>          | 90/250 <b>36%</b>    | 2459/2622 <b>93,7%</b>  | 20/85 <b>23,52%</b> |
| <b>3rd Ward net:</b>           | hidden_slab1 | hidden_slab2      | hidden_slab3 | stop criteria | tr_min.aver.e | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal                  | Abnormal            |
|                                | 100_Gaussian | 100_Gaussian      |              | epochs=2000-1 | 0,0127107     | 0,0149725           | 0,06           | 7845/7874 <b>99,6%</b>           | 102/250 <b>40,8%</b> | 2480/2622 <b>94,5%</b>  | 24/85 <b>28,23%</b> |
|                                | 50_Gaussian  | 50_Gaussian comp. |              | epochs=2000-1 | 0,0070737     | 0,0149674           | 0,053          | 7845/7874 <b>99,6%</b>           | 65/250 <b>26%</b>    | 2523/2622 <b>96,22%</b> | 19/85 <b>22,35%</b> |
|                                | 50_linear    | 50_tanh15         |              | epochs=2000-1 | 0,0174638     | 0,0156054           | 0,04           | 7852/7874 <b>99,7%</b>           | 23/250 <b>9,2%</b>   | 2591/2622 <b>98,8%</b>  | 8/85 <b>9,4%</b>    |
| <b>2nd Ward net:</b>           | hidden_slab1 | hidden_slab2      | hidden_slab3 | stop criteria | tr_min.aver.e | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal                  | Abnormal            |
|                                | 32_Gaussian  | 32_Gaussian       | 32_Gaussian  | epochs=2000-1 | 0,0075486     | 0,0126018           | 0,166          | 7849/7874 <b>99,68%</b>          | 83/250 <b>33,2%</b>  | 1957/2622 <b>74,6%</b>  | 38/85 <b>44,7%</b>  |
|                                | 100_Gaussian | 100_Gaussian      | 100_Gaussian | epochs=2000-1 | 0,0197424     | 0,0149515           | 0,042          | 7837/7874 <b>99,5%</b>           | 44/250 <b>17,6%</b>  | 2582/2622 <b>98,4%</b>  | 12/85 <b>14,11%</b> |
| <b>1st Ward net:</b>           | hidden_slab1 | hidden_slab2      | hidden_slab3 | stop criteria | tr_min.aver.e | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal                  | Abnormal            |
|                                | 100_Gaussian | 100_Gaussian      |              | epochs=2000-1 | 0,0132661     | 0,0153112           | 0,036          | 7694/7874 <b>97,7%</b>           | 83/250 <b>33,2%</b>  | 2598/2622 <b>99,04%</b> | 10/85 <b>11,76%</b> |
|                                | 100_Gaussian | 100_tanh          |              | epochs=2000-1 | 0,0130622     | 0,0146076           | 0,122          | 7787/7874 <b>98,89%</b>          | 89/250 <b>35,6%</b>  | 2135/2622 <b>81,42%</b> | 33/85 <b>38,82%</b> |
| <b>1st Jump-Connect</b>        | hidden_slab1 | hidden_slab2      | hidden_slab3 | stop criteria | tr_min.aver.e | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal                  | Abnormal            |
|                                | 100_Gaussian |                   |              | epochs=2000-1 | 0,0091055     | 0,0152935           | 0,037          | 7854/7874 <b>99,7%</b>           | 35/250 <b>14%</b>    | 2590/2622 <b>98,7%</b>  | 7/85 <b>8,23%</b>   |
|                                | 100_logistic |                   |              | epochs=2000-1 | 0,0146165     | 0,0152426           | 0,036          | 7856/7874 <b>99,77%</b>          | 20/250 <b>8%</b>     | 2603/2622 <b>99,27%</b> | 8/85 <b>9,4%</b>    |
| <b>2nd Jump-Connect</b>        | hidden_slab1 | hidden_slab2      | hidden_slab3 | stop criteria | tr_min.aver.e | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal                  | Abnormal            |
|                                | 48_Gaussian  | 48_Gaussian       |              | epochs=2000-1 | 0,0082072     | 0,014669            | 0,051          | 7850/7874 <b>99,69%</b>          | 34/250 <b>13,6%</b>  | 2543-2622 <b>96,95%</b> | 21/85 <b>24,7%</b>  |
|                                | 100_Gaussian | 100_Gaussian      |              | epochs=2000-1 | 0,0013209     | 0,0148596           | 0,049          | 7813/7874 <b>99,22%</b>          | 58/250 <b>23,2%</b>  | 2525/2622 <b>96,26%</b> | 17/85 <b>20%</b>    |
| <b>GRNN, genetic adaptive:</b> |              |                   |              |               |               |                     | mean sq. error | Normal                           | Abnormal             | Normal                  | Abnormal            |
|                                |              |                   |              |               |               |                     | 0,037          | 7874/7874 <b>100%</b>            | 50/250 <b>20%</b>    | 2597/2622 <b>99%</b>    | 6/85 <b>7,05%</b>   |
|                                |              |                   |              |               |               |                     |                |                                  |                      |                         |                     |

Πίνακας 4.1: Αποτελέσματα πρόγνωσης προεκλαμψίας νευρωνικών Δικτύων

#### 4.1.1 Σχολιασμός αποτελεσμάτων (με 13538 περιπτώσεις)

Όπως φαίνεται και στο Πίνακα 4.1 στις πλείστες αρχιτεκτονικές που δοκιμάστηκαν, τα ποσοστά στο training αλλά και evaluation set όσον αφορά τις σωστές προβλέψεις για τους normal ασθενείς (χωρίς προεκλαμψία) είναι πολύ καλά. Δηλαδή κυμαίνονται στο 99% για το training set και περίπου από 75% μέχρι και 99% στο evaluation set (True Negative). Παρόλα αυτά ο στόχος δεν ήταν μόνο αυτός, αλλά μια συνολική καλή απόδοση έχοντας καλά ποσοστά και στις abnormal περιπτώσεις (κυρίως σε αυτές). Στα ποσοστά σωστών προβλέψεων -στο evaluation set- για τις abnormal περιπτώσεις (True Positive) παρατηρείται ότι οι αριθμοί που παρουσιάζονται δεν είναι και τόσο καλοί αφού καλύτερο ποσοστό που εξάγεται είναι μόλις 48% στο training και 56.47% στο evaluation set και χειρότερο ένα ποσοστό της τάξης του 6.8% στο training set (μόλις 17 από τις 85 abnormal βρέθηκαν σωστά). Γι' αυτό ίσως δοκιμάστηκαν και αρχιτεκτονικές με μεγαλύτερη πολυπλοκότητα από κάποιες άλλες με τη σκέψη ότι ίσως βοηθήσουν για να φτάσουμε στη λύση του προβλήματος. Για παράδειγμα δοκιμάστηκε και η backpropagation με 3 κρυμμένα επίπεδα παρόλο που πιστεύεται (Kolmogorov's theorem) ότι με το πολύ 2 κρυμμένα επίπεδα στην συγκεκριμένη αρχιτεκτονική μπορούν να λυθούν τα πλείστα προβλήματα. Άρα ίσως η λύση θα μπορούσε να βρεθεί με δύο κρυμμένα επίπεδα, και αύξηση της πολυπλοκότητας των νευρώνων. Να σημειωθεί ότι επί το πλείστο οι αρχιτεκτονικές δοκιμάζονταν με κριτήριο για να σταματήσει η εκπαίδευση 2000 εποχές κατά το training set.

Άρα από τα πιο πάνω είναι εμφανές ότι παρουσιάζονται δυσκολίες στην εύρεση μιας αρχιτεκτονικής/δομής νευρωνικού δικτύου που να ικανοποιεί τον αρχικό στόχο, ένα δίκτυο με καλές προβλέψεις χρησιμοποιώντας τα δεδομένα ως έχουν.

Αυτό σε ένα πολύ μεγάλο βαθμό οφείλεται στο ότι ο αριθμός των περιπτώσεων χωρίς προεκλαμψία είναι πολύ πιο μεγάλος από τον αριθμό των περιπτώσεων που έχουμε στην διάθεση μας και παρουσιάζουν προεκλαμψία. Έτσι ως αποτέλεσμα αυτής της μη ισορροπίας μεταξύ των δύο κατηγοριών των δεδομένων, τα δίκτυα που δοκιμάστηκαν δεν γενίκευαν όπως θα έπρεπε και συγκλείνανε προς τις περιπτώσεις χωρίς προεκλαμψία που είναι και οι πλείστες. Δηλαδή μάθαιναν περισσότερο για αυτές στα πλαίσια της εκπαίδευσης. Τα ποσοστά έτσι των περιπτώσεων ασθενών με προεκλαμψία δεν ήταν καθόλου καλά (δεν είχε τη δυνατότητα να μάθει στο βαθμό που έπρεπε τις abnormal περιπτώσεις). Αυτό ίσως είναι και λόγω του φαινομένου overlap όπου πολλές

περιπτώσεις από τις normal μοιάζουν με κάποιες από τα abnormal με αποτέλεσμα το δίκτυο να τις κατατάσσει στα normal μη μπορώντας να τις ξεχωρίσει. Υπό κανονικές συνθήκες ένα δίκτυο για να μάθει σωστά θα ήταν ιδανικό να υπήρχε μια ισορροπία μεταξύ των δεδομένων (στη περίπτωση μας ισορροπία normal-abnormal).

## **4.2 Αποτελέσματα των προσπαθειών με 860 περιπτώσεις**

Ως επακόλουθο το μη καλών αποτελεσμάτων μέχρι στιγμής, αποφασίσαμε μετά από κάποιες άλλες προσπάθειες που έγιναν σχετικά με τα δεδομένα (βλ. Κεφάλαιο 3) να ακολουθήσουμε μια και όχι τόσο συνηθισμένη πορεία. Να δημιουργήσουμε σετ δεδομένων που ο αριθμός των περιπτώσεων με προεκλαμψία και χωρίς, θα ήταν πιο ισορροπημένος.

### **4.2.1 Αποτελέσματα με το balanced1 set**


Αρχικά δημιουργήσαμε το πρώτο ισορροπημένο σετ (balanced1) διαλέγοντας ένα αριθμό περιπτώσεων ασθενών από το σύνολο αυτών. Όπως έχω ήδη αναφέρει οι abnormal περιπτώσεις έμειναν ως είχαν λόγω του πολύ μικρού αριθμού αυτών ενώ διαλέχτηκαν με τυχαίο τρόπο οι normal περιπτώσεις που θα συμπλήρωναν τις abnormal στη ολοκλήρωση του ισορροπημένου σετ. Τα αποτελέσματα από τα simulations που έγιναν με το balanced1 σετ των 860 δεδομένων φαίνονται στο Πίνακα 4.2

| Architecture                   |              |                    |                    |                 |                     |                | Percentage of correct prediction |                      |                     |                     |
|--------------------------------|--------------|--------------------|--------------------|-----------------|---------------------|----------------|----------------------------------|----------------------|---------------------|---------------------|
|                                |              |                    |                    |                 |                     |                | TRAINING SET                     | TRAINING SET         | EVALUATION SET      | EVALUATION SET      |
| <b>3-layers standard:</b>      | hiddenSlab1  | hiddenSlab2        | hiddenSlab3        | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced1                      | 100_linear   |                    |                    | 0,0040833       | 0,131595            | 0,198          | 202/263 <b>76,8%</b>             | 198/250 <b>79,2%</b> | 73/88 <b>82,07%</b> | 67/85 <b>78,8%</b>  |
| balanced1                      | 100_Gaussian |                    |                    | 0,0018898       | 0,0917052           | 0,177          | 191/263 <b>72,6%</b>             | 234/250 <b>93,6%</b> | 58/88 <b>65,16%</b> | 72/85 <b>84,7%</b>  |
| <b>4-layers standard:</b>      | hiddenSlab1  | hiddenSlab2        | hiddenSlab3        | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced1                      | 100_Gaussian | 100_Gaussian       |                    | 0,0000061       | 0,0303021           | 0,101          | 208/263 <b>79,08%</b>            | 234/250 <b>93,6%</b> | 74/88 <b>83,1%</b>  | 78/85 <b>91,7%</b>  |
| balanced1                      | 100_Gaussian | 100_Gaussian comp. |                    | 0,0000035       | 0,0307952           | 0,118          | 189/263 <b>71,8%</b>             | 241/250 <b>96,4%</b> | 66/88 <b>74,15%</b> | 83/85 <b>97,64%</b> |
| balanced1                      | 100_linear   | 100_linear         |                    | 0,004452        | 0,1449674           | 0,286          | 35/263 <b>13,3%</b>              | 239/250 <b>95,6%</b> | 64/88 <b>71,9%</b>  | 45/85 <b>52,9%</b>  |
| balanced1                      | 100_Gaussian | 100_tanh           |                    | 0,0000055       | 0,036015            | 0,094          | 198/263 <b>75,28%</b>            | 223/250 <b>89,2%</b> | 72/88 <b>81%</b>    | 80/85 <b>94%</b>    |
| <b>5-layers standard:</b>      | hiddenSlab1  | hiddenSlab2        | hiddenSlab3        | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced1                      | 100_Gaussian | 100_Gaussian       | 100_Gaussian       | 0,0000021       | 0,0265422           | 0,095          | 201/263 <b>76,4%</b>             | 228/250 <b>91,2%</b> | 74/88 <b>83,1%</b>  | 80/85 <b>94,1%</b>  |
| balanced1                      | 100_Gaussian | 100_Gaussian comp. | 100_Gaussian comp. | 0,0841449       | 0,0309388           | 0,107          | 206/263 <b>78,3%</b>             | 225/250 <b>90%</b>   | 73/88 <b>82%</b>    | 78/85 <b>91,7%</b>  |
| <b>1st Ward net:</b>           | hiddenSlab1  | hiddenSlab2        | hiddenSlab3        | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced1                      | 100_Gaussian | 100_Gaussian comp. |                    | 0,0002354       | 0,0420303           | 0,105          | 199/263 <b>75,6%</b>             | 225/250 <b>90%</b>   | 45/88 <b>50,56%</b> | 49/85 <b>57,6%</b>  |
| <b>2nd Ward net:</b>           | hiddenSlab1  | hiddenSlab2        | hiddenSlab3        | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced1                      | 32_Gaussian  | 32_Gaussian        | 32_Gaussian        | 0,0003072       | 0,0448786           | 0,103          | 210/263 <b>79,8%</b>             | 209/250 <b>83,6%</b> | 76/88 <b>85,39%</b> | 75/85 <b>88,2%</b>  |
| balanced1                      | 100_Gaussian | 100_Gaussian       | 100_Gaussian       | 0,0003172       | 0,0383109           | 0,105          | 200/263 <b>76%</b>               | 232/250 <b>92,8%</b> | 74/88 <b>83,14%</b> | 79/85 <b>92,94%</b> |
| balanced1                      | 100_Gaussian | 100_linear         | 100_Gaussian comp. | 0,0016871       | 0,1522932           | 0,26           | 209/263 <b>79,46%</b>            | 213/250 <b>85,2%</b> | 69/88 <b>77,5%</b>  | 17/85 <b>20%</b>    |
| <b>3rd Ward net:</b>           | hiddenSlab1  | hiddenSlab2        | hiddenSlab3        | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced1                      | 100_Gaussian | 100_Gaussian comp. |                    | 0,0002827       | 0,0430944           | 0,113          | 190/263 <b>72,24%</b>            | 229/250 <b>91,6%</b> | 71/88 <b>79,7%</b>  | 78/85 <b>91,7%</b>  |
| balanced1                      | 100_Gaussian | 100_linear         |                    | 0,0015708       | 0,1325204           | 0,234          | 176/263 <b>66,92%</b>            | 228/250 <b>91,2%</b> | 73/88 <b>82%</b>    | 30/85 <b>35,3%</b>  |
| balanced1                      | 100_Gaussian | 100_Gaussian       |                    | 0,0003746       | 0,040881            | 0,099          | 197/263 <b>74,9%</b>             | 221/250 <b>88,4%</b> | 72/88 <b>81%</b>    | 80/85 <b>94%</b>    |
| balanced1                      | 100_Gaussian | 100_tanh           |                    | 0,0004337       | 0,0443456           | 0,115          | 188/263 <b>71,48%</b>            | 233/250 <b>93,2%</b> | 67/88 <b>76,13%</b> | 78/85 <b>91,7%</b>  |
| <b>1st Jump-Connect:</b>       | hiddenSlab1  | hiddenSlab2        | hiddenSlab3        | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced1                      | 100_Gaussian |                    |                    | 0,0003562       | 0,0412888           | 0,103          | 198/263 <b>75,28%</b>            | 232/250 <b>92,8%</b> | 73/88 <b>82%</b>    | 78/85 <b>91,7%</b>  |
| <b>2nd Jump-Connect:</b>       | hiddenSlab1  | hiddenSlab2        | hiddenSlab3        | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced1                      | 100_Gaussian | 100_Gaussian       |                    | 0               | 0,0393584           | 0,102          | 196/263 <b>74,5%</b>             | 234/250 <b>93,6%</b> | 71/88 <b>79,77%</b> | 80/85 <b>94,11%</b> |
| <b>3rd Jump-Connect:</b>       | hiddenSlab1  | hiddenSlab2        | hiddenSlab3        | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced1                      | 100_Gaussian | 100_Gaussian       | 100_Gaussian       | 0               | 0,0382414           | 0,103          | 200/263 <b>76%</b>               | 231/250 <b>92,4%</b> | 72/88 <b>80,89%</b> | 78/85 <b>91,7%</b>  |
| <b>GRNN, genetic adaptive:</b> |              |                    |                    |                 |                     | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced1                      |              |                    |                    |                 |                     | 0,127          | 241/263 <b>91,6%</b>             | 229/250 <b>91,6%</b> | 71/88 <b>79,77%</b> | 74/85 <b>87,05%</b> |

Πίνακας 4.2: Αποτελέσματα πρόγνωσης προεκλαμψίας νευρωνικών Δικτύων (balanced1)

Είναι εμφανές ότι τα αποτελέσματα είναι βελτιωμένα. Πλέον με των ισορροπημένο αριθμό δεδομένων τα ποσοστά για τις ορθές προβλέψεις περιπτώσεις με προεκλαμψία (True Positive) είναι πολύ καλύτερα. Τα ποσοστά κυμαίνονται επί το πλείστο γύρω στο 90 % στο training και από περίπου 20% έως 97% στο evaluation set.

Καλύτερο δίκτυο μπορώ να πω ότι είναι το standard back-propagation με δυο κρυμμένα επίπεδα (σύνολο 4 επίπεδα) με activation function την Gaussian στο πρώτο κρυμμένο επίπεδο και την Gaussian comp. στο δεύτερο κρυμμένο επίπεδο. Ενώ υπάρχουν 100 νευρώνες στο κάθε κρυμμένο επίπεδο (με κίτρινο στο Πίνακα 4.2). Ο κύριος λόγος που υποδεικνύω αυτό το δίκτυο ως το καλύτερο παρόλο που υπάρχουν και άλλα ε υψηλά ποσοστά είναι γιατί έχει το υψηλότερο ποσοστό στα abnormal (τομέας που είχαμε πρόβλημα προηγουμένως). Στο δίκτυο αυτό παρατηρείται ότι στα άγνωστα δεδομένα (evaluation set) βρίσκει 83 από τις 85 abnormal περιπτώσεις (97.64%) και 66 από τις 88 normal περιπτώσεις (74.15%). Στο Σχήμα 4.4 φαίνεται η πρόοδος του δικτύου αυτού κατά την εκπαίδευση (Training set average error - Epochs).



**Σχήμα 4.4: Πρόοδος της εκπαίδευσης: Training set average error vs. Epochs**

Άρα κατά κάποιο τρόπο παρατηρείται ότι τώρα μαθαίνει και τις περιπτώσεις με προεκλαμψία που είναι μείζων σημείο (αν όχι το σημαντικότερο). Όσον αφορά τις περιπτώσεις χωρίς προεκλαμψία το ποσοστό των σωστών προβλέψεων πέφτει αφού όπως έχω αναφέρει η επιλογή των περιπτώσεων έγινε τυχαία ανάμεσα από τις 13118 περιπτώσεις που έχουμε στη διάθεση μας. Αποτέλεσμα αυτού είναι ίσως κάποιες περιπτώσεις που βρίσκονται στο evaluation set να μην καλύπτονται από αυτά που έχει μάθει το δίκτυο αφού είναι φυσικό κάθε περίπτωση ασθενή να είναι μοναδική. Δεν παρουσιάζουν όλοι τα ίδια αποτελέσματα στις εξετάσεις/μετρήσεις που τους έχουν γίνει από τους γιατρούς (ύψος, βάρος, χρόνια υπέρταση, αρτηριακή πίεση).

#### **4.2.2 Αποτελέσματα με τα balanced2/3/4/5 sets**

Στη συνέχεια αφού παρατηρήσαμε ότι με το 1<sup>ο</sup> ισορροπημένο σετ δεδομένων το δίκτυο μάθαινε και κατά συνέπεια προέβλεπε τις abnormal περιπτώσεις καλά, αφήσαμε τα training και testing sets που έχουμε για την εκπαίδευση και δοκιμάσαμε νέο evaluation σετ (κυρίως με τις καλύτερες αρχιτεκτονικές όπως βγήκαν από το balanced1 σετ). Στο λεγόμενο balanced2 σετ αφαιρέσαμε ορισμένες περιπτώσεις normal περιπτώσεων που τα πλείστα δίκτυα τα έβρισκαν ως abnormal (False Positive) και τις αντικαταστήσαμε με άλλες τυχαίες επιλεγμένες περιπτώσεις από τα υπόλοιπα δεδομένα. Το γεγονός ότι οι συγκεκριμένες περιπτώσεις προβλέπονταν λανθασμένα μπορεί βασικά να οφείλεται σε δύο παράγοντες. Πρώτο στο ότι ίσως οι μετρήσεις κάποιων ασθενών είναι λανθασμένες, γεγονός που μπορεί να οφείλεται σε λάθος των γιατρών ή και ακόμα και σε τυπογραφικό λάθος των δεδομένων όπως μας δόθηκαν. Σε αυτή τη περίπτωση θα αναφερθούν στους γιατρούς οι αριθμοί (ID) των συγκεκριμένων ασθενών για να ελεγχθεί αν πράγματι έχει κάποιο λάθος στις μετρήσεις. Ο άλλος πιθανός παράγοντας που οι συγκεκριμένες περιπτώσεις ασθενών βγαίνουν False Positive είναι ότι ίσως οι μετρήσεις αυτών να είναι παρόμοιες με αυτές ασθενών που έχουν προεκλαμψία με αποτέλεσμα το δίκτυο να τις κατατάσσει στην κατηγορία των ασθενών με προεκλαμψία.

Για να εξεταστεί περαιτέρω η εγκυρότητα αυτής της υπόθεσης που ακολουθήσαμε, δημιουργήσαμε και άλλα σετ με ισορροπημένο αριθμό δεδομένων και τα δοκιμάσαμε εκ νέου με τα καλύτερα δίκτυα όπως βγήκαν έως τώρα (και επιπλέον κάποια άλλα).

Με το τρόπο αυτό θα δούμε αν η επιτυχία της πρόβλεψης στο `balanced1` ήταν τυχαία και αν η ανορθόδοξη αυτή διαδικασία που ακολουθήσαμε μπορεί να μας βοηθήσει στο μέλλον. Στο Πίνακα 4.3 φαίνονται τα αποτελέσματα από τα simulations με τα `balanced2`, `balanced3`, `balanced4`, `balanced5` sets.

| Architecture              |              |                    |              |                 |                     |                | Percentage of correct prediction |                      |                     |                     |
|---------------------------|--------------|--------------------|--------------|-----------------|---------------------|----------------|----------------------------------|----------------------|---------------------|---------------------|
|                           |              |                    |              |                 |                     |                | TRAINING SET                     | TRAINING SET         | EVALUATION SET      | EVALUATION SET      |
| <b>4-layers standard:</b> | hiddenSlab1  | hiddenSlab2        | hiddenSlab3  | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced2                 | 100_Gaussian | 100_Gaussian comp. |              | 0,0000009       | 0,0317589           | 0,17           | 164/263 <b>62,35%</b>            | 241/250 <b>96,4%</b> | 49/88 <b>55,05%</b> | 83/85 <b>97,64%</b> |
| balanced2                 | 100_Gaussian | 100_Gaussian       |              | 0,0000051       | 0,030228            | 0,122          | 224/263 <b>85,17%</b>            | 241/250 <b>96,4%</b> | 69/88 <b>78,4%</b>  | 75/85 <b>88,23%</b> |
| balanced3                 | 100_Gaussian | 100_Gaussian comp. |              | 0,0000076       | 0,0354788           | 0,117          | 197/263 <b>74,9%</b>             | 229/250 <b>91,6%</b> | 72/88 <b>81,81%</b> | 79/85 <b>92,94%</b> |
| balanced4                 | 100_Gaussian | 100_Gaussian comp. |              | 0,0002321       | 0,0402189           | 0,143          | 184/263 <b>69,96%</b>            | 224/250 <b>89,6%</b> | 65/88 <b>73,86%</b> | 80/85 <b>94,11%</b> |
| balanced5                 | 100_Gaussian | 100_Gaussian comp. |              | 0,1339183       | 0,0914203           | 0,192          | 197/263 <b>74,9%</b>             | 180/250 <b>72%</b>   | 55/88 <b>62,5%</b>  | 68/85 <b>80%</b>    |
| balanced5                 | 100_Gaussian | 100_Gaussian       |              | 0               | 0,0836062           | 0,205          | 202/263 <b>76,8%</b>             | 176/250 <b>70,4%</b> | 49/88 <b>54,5%</b>  | 69/85 <b>81,1%</b>  |
| <b>5-layers standard:</b> | hiddenSlab1  | hiddenSlab2        | hiddenSlab3  | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced2                 | 100_Gaussian | 100_Gaussian       | 100_Gaussian | 0,0000021       | 0,0197597           | 0,091          | 187/263 <b>71,1%</b>             | 241/250 <b>96,4%</b> | 73/88 <b>82%</b>    | 83/85 <b>97,64%</b> |
| balanced3                 | 100_Gaussian | 100_Gaussian       | 100_Gaussian | 0,0000034       | 0,0320767           | 0,148          | 194/263 <b>73,76%</b>            | 231/250 <b>92,4%</b> | 62/88 <b>70,45%</b> | 77/85 <b>90,58%</b> |
| balanced4                 | 100_Gaussian | 100_Gaussian       | 100_Gaussian | 0,0000072       | 0,0469228           | 0,163          | 217/263 <b>82,5%</b>             | 229/250 <b>91,6%</b> | 63/88 <b>71,59%</b> | 77/85 <b>90,58%</b> |
| <b>3rd Ward net:</b>      | hiddenSlab1  | hiddenSlab2        | hiddenSlab3  | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced2                 | 100_Gaussian | 100_Gaussian comp. |              | 0,0004576       | 0,0394522           | 0,074          | 214/263 <b>81,36%</b>            | 223/250 <b>89,2%</b> | 81/88 <b>92,04%</b> | 76/85 <b>89,41%</b> |
| balanced3                 | 100_Gaussian | 100_Gaussian comp. |              | 0,0003185       | 0,0410426           | 0,1            | 203/263 <b>76,89%</b>            | 224/250 <b>89,6%</b> | 74/88 <b>84,09%</b> | 78/85 <b>91,76%</b> |
| <b>1st Jump-Connect</b>   | hiddenSlab1  | hiddenSlab2        | hiddenSlab3  | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced3                 | 30_Gaussian  |                    |              | 0,0009288       | 0,0364525           | 0,1            | 197/263 <b>74,9%</b>             | 228/250 <b>91,2%</b> | 70/88 <b>79,54%</b> | 80/85 <b>94,11%</b> |
| balanced3                 | 30_tanh15    |                    |              | 0,0031667       | 0,0372114           | 0,102          | 203/263 <b>77,18%</b>            | 233/250 <b>93,2%</b> | 68/88 <b>77,27%</b> | 81/85 <b>95,29%</b> |
| <b>2nd Jump-Connect</b>   | hiddenSlab1  | hiddenSlab2        | hiddenSlab3  | tr_min.aver.err | test_min.aver.error | mean sq. error | Normal                           | Abnormal             | Normal              | Abnormal            |
| balanced2                 | 100_Gaussian | 100_Gaussian       |              | 0,0000001       | 0,0369339           | 0,068          | 197/263 <b>74,9%</b>             | 221/250 <b>88,4%</b> | 80/88 <b>90,9%</b>  | 80/85 <b>94,11%</b> |
| balanced2                 | 100_Gaussian | 100_Gaussian comp. |              | 0,0000001       | 0,036943            | 0,074          | 190/263 <b>72,24%</b>            | 225/250 <b>90%</b>   | 77/88 <b>87,5%</b>  | 80/85 <b>94,11%</b> |
| balanced3                 | 100_Gaussian | 100_Gaussian comp. |              | 0,0000012       | 0,0379759           | 0,105          | 198/263 <b>75,28%</b>            | 229/250 <b>91,6%</b> | 71/88 <b>80,68%</b> | 77/85 <b>90,58%</b> |
|                           |              |                    |              |                 |                     |                |                                  |                      |                     |                     |

**Πίνακας 4.3: Αποτελέσματα πρόγνωσης προεκλαμψίας νευρωνικών Δικτύων (balanced sets 2, 3, 4, 5)**

Από τα αποτελέσματα που φαίνονται και στο πιο πάνω Πίνακα 4.3 σε σχέση και με αυτά από το Πίνακα 4.2 παρατηρείται ότι τα ποσοστά για τις σωστές προβλέψεις των περιπτώσεων με προεκλαμψία (True Positive) παραμένουν υψηλά. Φυσικά το γεγονός ότι τα ποσοστά επιτυχίας για τις περιπτώσεις normal αν και παραμένουν σε αρκετά υψηλά επίπεδα, σε κάποιες περιπτώσεις δικτύων βλέπουμε να πέφτουν κάπως. Αυτό είναι φυσιολογικό αφού η επιλογή των normal περιπτώσεων έγινε όπως προανέφερα με τυχαίο τρόπο και ίσως σε κάποιες περιπτώσεις δεν καλύπτεται όλο το φάσμα των φυσιολογικών ασθενών κατά την εκπαίδευση-μάθηση.

#### 4.3 Αποτελέσματα των προσπαθειών με 3346 περιπτώσεις ασθενών

Λόγο των καλών αποτελεσμάτων που είχαμε σε αυτές τις τελευταίες προσπάθειες που έγιναν αποφασίσαμε να δοκιμάσουμε με ένα μεγαλύτερο evaluation set 2660 περιπτώσεων εκ των οποίων τα 85 είναι abnormal όπως και στα προηγούμενα evaluation sets και τα υπόλοιπα 2575 είναι τυχαία normal που δεν χρησιμοποιούνται στα αντίστοιχα training και test sets. Εδώ δοκιμάστηκε απλά μια από τις καλύτερες αρχιτεκτονικές όπως προέκυψε από τα προηγούμενα δίκτυα που δοκιμάστηκαν (standard back-propagation με δυο κρυμμένα επίπεδα με Gaussian και Gaussian comp. activation functions για τα κρυμμένα επίπεδα αντίστοιχα).

| Architecture      | Percentage of correct prediction |                    |                  |                |
|-------------------|----------------------------------|--------------------|------------------|----------------|
|                   | TRAINING SET                     | TRAINING SET       | EVALUATION SET   | EVALUATION SET |
| 4-layers standard | hiddenSlab1                      | hiddenSlab2        | hiddenSlab3      |                |
|                   | 100_Gaussian                     | 100_Gaussian comp. | Normal           | Abnormal       |
|                   |                                  |                    | 189/263 71,8%    | 241/250 96,4%  |
|                   |                                  |                    | 1495/2575 58,05% | 81/85 95,29%   |

**Πίνακας 4.4: Αποτέλεσμα πρόγνωσης προεκλαμψίας νευρωνικού Δικτύου - standard back-propagation με δυο κρυμμένα επίπεδα (3346 περιπτώσεις ασθενών )**

Βλέπουμε εδώ ότι το ποσοστό των abnormal κατά το training είναι 96.4% ενώ και στα άγνωστα δεδομένα όσον αφορά τις abnormal περιπτώσεις ασθενών παραμένει υψηλό (95.29%) που ήταν και ο βασικός στόχος. Αντίθετα το γεγονός ότι το ποσοστό των normal άγνωστων περιπτώσεων προς το δίκτυο έχει πέσει (58.05%) οφείλεται πολύ πιθανόν στο ότι η τυχαία επιλογή του συνόλου των normal περιπτώσεων που

χρησιμοποιεί το δίκτυο στην εκπαίδευση του δεν καλύπτει όλες τις πιθανές περιπτώσεις ασθενών χωρίς προεκλαμψία με αποτέλεσμα να μην κατατάσσει εκεί που πρέπει αρκετές περιπτώσεις από τις άγνωστες (evaluation set) αφού δεν έχει δει κατά τη μάθηση του κάποια παρόμοια. Επιπρόσθετα όμως αυτό ίσως οφείλεται σε overlap όπου το δίκτυο αν και μαθαίνει σωστά πλέον τα abnormal, αρκετά από τα normal τα κατατάσσει ως abnormal αφού αρκετές normal με abnormal περιπτώσεις μοιάζουν μεταξύ τους.

# Κεφάλαιο 5

## Συμπεράσματα

|                         |    |
|-------------------------|----|
| 4.1 Γενικά συμπεράσματα | 48 |
| 4.2 Μελλοντική εργασία  | 51 |

### 4.1 Γενικά συμπεράσματα

Μετά την ανάλυση των αποτελεσμάτων που λήφθηκαν από τη όλη διαδικασία που ακολουθήθηκε, καταλήξαμε σε ορισμένα συμπεράσματα. Κάποια από τα συμπεράσματα ήταν αναμενόμενα από την αρχή της εργασίας, όμως προέκυψαν και μερικά άλλα που δεν αναμέναμε. Αυτό όμως που προσπαθήσαμε να αποδείξουμε με την παρούσα εργασία όπως αρχικά σχεδιάστηκε, λόγο κάποιων ενδιάμεσων πορισμάτων που προέκυψαν κατά την εργασία δεν έγινε κατά γράμμα. Δηλαδή δεν πετύχαμε το ποσοστό επιτυχίας πάνω από τουλάχιστον 80% πάνω στον αρχικό στόχο που είχε αποφασισθεί. Κάτι που προσωπικά ανέμενα κατά κάποιο τρόπο αφού στο τομέα αυτό της υπολογιστικής νοημοσύνης και των νευρωνικών δικτύων αλλά και στα πλαίσια μιας μελέτης πάντα υπάρχουν και τα αναπάντεχα. Λόγο των λεγόμενων ενδιάμεσων συμπερασμάτων/πορισμάτων που συναντήσαμε προσπαθήσαμε να δείξουμε ότι εν κατακλείδι μπορεί να βρεθεί λύση στο πρόβλημα που έχουμε να αντιμετωπίσουμε αναφορικά με την πρόβλεψη της προεκλαμψίας θέτοντας τις βάσεις για τυχόν μελλοντική εργασία.

Καταρχάς όπως αναφέρετε και σε προηγούμενα κεφάλαια αρχικά χρησιμοποιήσαμε 13538 περιπτώσεις ασθενών στο σύνολο χωρίζοντας τις στα ανάλογα σαι (training, test, evaluation/production). Από τα αποτελέσματα που πάρθηκαν και την ανάλυση αυτών προσέξαμε ότι τα διάφορα δίκτυα δεν είχαν καλά ποσοστά πρόβλεψης όσον αφορά τους ασθενείς με προεκλαμψία κάτι που είναι ίσως το σημαντικότερο κομμάτι

στην επίτευξη του απώτερου στόχου. Αυτό οφειλόταν κατά πασά πιθανότητα στο ότι οι περιπτώσεις των ασθενών χωρίς προεκλαμψία ήταν σαφέστατα πολύ περισσότερες από τις θετικές σε προεκλαμψία περιπτώσεις. Περίπου μόνο το 3% από τις 13538 ήταν θετικές σε προεκλαμψία. Αποτέλεσμα αυτού ήταν να καταλήξουμε στο συμπέρασμα ότι με τέτοια ανισορροπία στα δεδομένα το δίκτυο πολύ δύσκολα θα μαθαίνει να γενικεύει και δεν θα βρίσκει σωστά τις περιπτώσεις με προεκλαμψία αφού θα συγκλίνει προς αυτές που δεν έχουν προεκλαμψία τις οποίες ξέρει επί το πλείστο από την εκπαίδευση του. Κάτι που υπήρχε μεγάλη πιθανότητα να συμβεί αφού για να γίνει σωστά η εκπαίδευση ενός νευρωνικού δικτύου είναι προτιμότερο να υπάρχουν ανάλογος αριθμός περιπτώσεων δεδομένων μεταξύ των κατηγοριών που καλείται να προβλέψει. (δηλαδή στη περίπτωση της εργασίας αυτής πιο ισορροπημένος αριθμός ασθενών θετικών στη προεκλαμψία και ασθενών αρνητικών σε αυτή).

Από εκεί και πέρα όπως αναφέρεται και στο κεφάλαιο της μεθοδολογίας προσπαθήσαμε να ακολουθήσουμε την αρχή αυτή και να δοκιμάσουμε να εκπαιδεύσουμε τα υπό δοκιμασία δίκτυα με ένα πιο συμμετρικό αριθμό περιπτώσεων (προσπάθειες με 860 περιπτώσεις). Από τα αποτελέσματα της προσπάθειας αυτής είδαμε ότι πράγματι ένα δίκτυο μπορεί να μάθει και της περιπτώσεις με προεκλαμψία. Παρουσιάστηκε ένα ποσοστό της τάξης του 97% για ορθή πρόβλεψη των True Positive (περιπτώσεις με προεκλαμψία). Το ποσοστό αυτό μας ώθησε προς τη κατεύθυνση ότι πράγματι ένα πιο συμμετρικός αριθμός περιπτώσεων θα βοηθήσει το δίκτυο στο να μάθει να γενικεύει καλύτερα. Όμως αυτό δεν ήταν αρκετό αφού έπρεπε να βεβαιωθούμε όσο το πιο δυνατό για το πόρισμα αυτό.

Έτσι δοκιμάσαμε με νέα σετ δεδομένων (balanced2, balanced3, balanced4, balanced5) για να δούμε αν το ποσοστό που πήραμε θα παρέμενε σε αυτά τα υψηλά επίπεδα. Το ποσοστό πράγματι παράμεινε σε αυτά τα επίπεδα. Παρόλο που παρατηρήθηκε κάποια μείωση στη τελευταία προσπάθεια (balanced5) δεν σήμαινε αυτό κάτι το αρνητικό αφού τα δεδομένα για τις περιπτώσεις χωρίς προεκλαμψία διαλέχτηκαν τυχαία για τα ισορροπημένα αυτά σετ δεδομένων και σίγουρα δεν κάλυπταν όλες τις πιθανές περιπτώσεις ασθενών που είχαμε στη βάση δεδομένων μας. Για το λόγο αυτό οφειλόταν και το γεγονός ότι στη πρόβλεψη των ασθενών χωρίς προεκλαμψία (True Negative) τα ποσοστά κυμαίνονταν περίπου σε επίπεδα 70-80% στα περισσότερα δίκτυα που δοκιμάστηκαν με τα σετ που είχαν ισορροπημένα δεδομένα. Ποσοστά που σε σχέση με

αυτά που παρουσιάστηκαν για τα True Negative στην αρχή με όλα τα δεδομένα είναι κάπως χαμηλότερα. Με όλες τις περιπτώσεις παρουσιάστηκε μέχρι και 99% για τα True Negative. Φυσικά αυτό οφείλεται όπως προανέφερα στην ασυμμετρία μεταξύ των περιπτώσεων με προεκλαμψία και αυτών χωρίς. Τα συμπεράσματα από τις προσπάθειες αυτές ήταν ότι υπάρχει βάση στη πορεία που ακολουθήσαμε με τα λεγόμενα “ισορροπημένα σετ δεδομένων” και μπορεί με μια καλή και σωστή εκπαίδευση το δίκτυο να μάθει όπως πρέπει.

Η προσπάθεια μας όμως δεν σταμάτησε εδώ αφού θέλαμε να σιγουρευτούμε ακόμη περισσότερο για τα μέχρι στιγμής ευρήματά μας και τα συμπεράσματα που εξάχθηκαν. Με τη σκέψη αυτή δοκιμάσαμε το καλύτερο δίκτυο όπως βγήκε από τα προηγούμενα αφήνοντας τα σετ (training set, test set) που εμπλέκονταν στην εκπαίδευση του δικτύου ως είχαν, (δηλαδή έχοντας ισορροπία μεταξύ των θετικών και αρνητικών ασθενών ως προς τη προεκλαμψία κατά την εκπαίδευση) και δημιουργήσαμε πιο μεγάλο evaluation σετ με περισσότερες περιπτώσεις ασθενών χωρίς προεκλαμψία (2926 έναντι 420 με προεκλαμψία). Το ποσοστό των True Positive παρέμεινε ψηλό (γύρω στο 95%), ενώ το αντίστοιχο για τα True Negative έπεσε στο 58.09%. Αυτό ήταν κάτι που ενίσχυσε κατά κάποιο τρόπο ότι μπορεί να δουλέψει η λεγόμενη “ισορροπημένη εκπαίδευση” όπως την ονομάσαμε αφού το δίκτυο μαθαίνει τις περιπτώσεις με προεκλαμψία, ενώ από την άλλη τόνισε αυτό που ανέφερα και προηγουμένως ότι δεν καλύπτεται όλο το φάσμα των περιπτώσεων χωρίς προεκλαμψία στην εκπαίδευση λόγω της τυχαίας επιλογής αυτών από τη βάση δεδομένων. Ίσως όμως το γεγονός του χαμηλού ποσοστού στις περιπτώσεις ασθενών χωρίς προεκλαμψία να οφείλεται σε πιθανό overlap.

Εν κατακλείδι, το συμπέρασμα που καταλήξαμε στα πλαίσια της προσπάθειας που έγινε κατά την εργασία αυτή ότι μπορούν να χρησιμοποιηθούν τα νευρωνικά δίκτυα για αυτό το σκοπό πρόβλεψης προεκλαμψίας. Και από τις δοκιμές που έγιναν είδαμε ότι χρειάζεται να γίνει εκπαίδευση του δικτύου με ένα ισορροπημένο σετ δεδομένων (“ισορροπημένη εκπαίδευση”). Αυτό όμως πρέπει να γίνει με σωστό και μεθοδικό τρόπο ούτως ώστε να καλύπτονται όλες οι περιπτώσεις των ασθενών που έχουμε στη βάση δεδομένων που διαθέτουμε, αφού κάθε ασθενής είναι ξεχωριστός και σπάνια θα βρεθούν περιπτώσεις ασθενών με ακριβώς τις ίδιες μετρήσεις στις σχετικές εξετάσεις που τους γίνονται. Συνήθως κάτι πάντα διαφέρει σε κάποια μέτρηση που ίσως παίζει

σημαντικό ρόλο. Και σίγουρα στο μέλλον θα εμφανιστούν και περιπτώσεις ασθενών πρωτοφανείς. Επίσης ίσως οι παράμετροι που έχουμε να μην είναι επαρκής για την πρόβλεψη της προεκλαμψίας και αν είχαμε και κάποιες άλλες μετρήσεις να μπορούσαμε με πιο εύκολο τρόπο να υλοποιήσουμε ένα σύστημα πρόβλεψης της προεκλαμψίας. Αυτό φαίνεται και από το γεγονός ότι τόσο στις προσπάθειες με όλα τα δεδομένα αλλά και στα balanced sets παρουσιάζεται το φαινόμενο του overlap. Όπου αρχικά μαθαίνει μεν τα normal αλλά κατατάσσει πολλά abnormal ως normal ενώ αργότερα με τα balanced sets συμβαίνει το αντίθετο.

## **4.2 Μελλοντική εργασία**

Όπως φαίνεται και γίνεται αντιληπτό η υλοποίηση ενός συστήματος που θα βοηθά στη πρόβλεψη της νόσου που ονομάζεται προεκλαμψία είναι αρκετά σημαντικό αφού η θεραπεία για αυτή δεν έχει βρεθεί ακόμη έχοντας ως συνέπεια τραγικές καταλήξεις για πολλές εγκύους γυναίκες και τα έμβρυα (χειρότερο αποτέλεσμα αυτού ο θάνατος). Αν επιτευχθεί η δημιουργία ενός τέτοιου συστήματος που θα βοηθά τους γιατρούς στην έγκαιρη διάγνωση και πρόβλεψη της νόσου, να σωθούν χιλιάδες ζωές και να αποτραπούν δυσάρεστες συνέπειες για γυναίκες σε όλο το κόσμο. Επιπρόσθετα αν επιτευχθεί το σύστημα αυτό θα ανοίξει το δρόμο για εύρεση κι άλλων συστημάτων για πρόβλεψη παθήσεων που ίσως έχουν παρόμοιες παραμέτρους με αυτές τις προεκλαμψίας. Επομένως, πιστεύω ότι είναι πολύ σημαντικό να συνεχιστούν οι έρευνες για το σκοπό αυτό. Δεν είναι κάτι που λυθεί από τη μια μέρα στην άλλη αφού η δυσκολίες που μπορεί να παρουσιαστούν είναι πολλές αλλά μπορούν να ξεπεραστούν αν υπάρξει η ανάλογη προσπάθεια. Τελειώνοντας λοιπόν, και λαμβάνοντας υπόψη τις εμπειρίες τις οποίες που αποκόμισα στην όλη προσπάθεια που έγινε όσον αφορά το συγκεκριμένο πρόβλημα θα αναφέρω κάποιες προτάσεις που πιστεύω ότι αξίζει να εξεταστούν έτσι ώστε να δοθεί μια συνέχεια στην δουλειά που έχει ήδη γίνει.

Μια πρώτη προσπάθεια για μελλοντική εργασία που μπορεί να γίνει είναι ουσιαστικά η συνέχεια της εργασίας αυτής με την “ισορροπημένη εκπαίδευση”. Κατ’ ακρίβεια μπορεί να γίνει όπως ανέφερα μια σωστή κατανομή και επιλογή δεδομένων ώστε η εκπαίδευση που να περνά το νευρωνικό δίκτυο να καλύπτει όλο το φάσμα των περιπτώσεων των ασθενών χωρίς προεκλαμψία. Κάτι που όπως υποδεικνύεται και πιο

πάνω μπορεί να έχει θετικά αποτελέσματα. Ίσως η χρήση μια μεθόδου σαν το Principal Component Analysis να βοηθήσει στη μείωση των δεδομένων.

Ακόμη θα μπορούσε να ακολουθηθεί μια διαφορετική οδός πέρα από αυτή της μείωσης των δεδομένων και να δοκιμαστούν περισσότερες αρχιτεκτονικές/δομές νευρωνικών δικτύων που δεν είχα το χρόνο να δοκιμάσω.

Επίσης θα μπορούσαν να ελεγχθούν εκτενέστερα οι μετρήσεις/παραμέτροι που έχουμε για τον κάθε ασθενή και να διαφοροποιηθούν οι εισοδοί για το πρόβλημα ή και να δοκιμαστούν περισσότεροι εισοδοί στο δίκτυο για κάθε ασθενή. Όπως για παράδειγμα στην προσπάθεια που έγινε από Νεοκλέους Κ., Αναστασόπουλο Π., Νικολαΐδη Κ., Σχίζα Χ. και Νεοκλέους Κ [5] (βλέπε Κεφάλαιο 1) είχαν 24 παραμέτρους για κάθε ασθενή εκ των οποίων χρησιμοποιήθηκαν 15 παράμετροι με βάση υποδείξεις των γιατρών. Στην εργασία αυτή χρησιμοποιήθηκαν μόλις 13 παραμέτρους για κάθε ασθενή. Για παράδειγμα σε σχέση με τις 15 εισόδους που είχαν οι προαναφερθέντες εδώ δεν είχαμε μέτρηση για το Crown Rump Length, ούτε κατά πόσο η ασθενής ήταν αλκοολική. Παράμετροι που ίσως τελικά παίζουν σημαντικότερο ρόλο από ότι πιστεύεται και ίσως αλλάζουν τα αποτελέσματα ενός τέτοιου συστήματος προς στο καλύτερο. Αυτά μπορεί να συζητηθούν και με τους γιατρούς ακόμη περισσότερο για να διευκρινιστεί το θέμα των εισόδων στο δίκτυο.

Τέλος, θα μπορούσε ακόμη να δοκιμαστεί κάτι ελαφρώς διαφορετικό στο μέλλον, συνδυάζοντας νευρωνικά δίκτυα με γενετικούς αλγόριθμους. Δηλαδή θα μπορούσαν να χρησιμοποιηθούν οι γενετικοί αλγόριθμοι για βελτιστοποίηση των παραμέτρων και στη συνέχεια να χρησιμοποιηθούν τα νευρωνικά δίκτυα λαμβάνοντας τους βελτιστοποιημένους αυτούς παραμέτρους που θα βοηθήσουν ακόμη περισσότερο στην επίλυση του προβλήματος μας. Επίσης θα μπορούσαν να χρησιμοποιηθούν οι γενετικοί αλγόριθμοι για βελτιστοποίηση των αρχιτεκτονικών των νευρωνικών δικτύων.

Υπάρχουν πολλά που μπορούν να γίνουν και να μελετηθούν μέσα από τα οποία μπορούν να αποδειχτούν σημαντικά συμπεράσματα. Η υπολογιστική νοημοσύνη είναι ένας τομέας που συνεχώς νέα πράγματα ανακαλύπτονται. Και μέχρι που ο εγκέφαλος παραμένει μια περιοχή που δεν έχει εξερευνηθεί και κατανοηθεί πλήρως υπάρχουν πολλά αναπάντητα ερωτήματα. Όλα αυτά επηρεάζουν αν όχι άμεσα, σίγουρα έμμεσα

την προσπάθεια για εύρεση ενός συστήματος πρόβλεψης της προεκλαμψίας. Κατά τη γνώμη μου το θέμα αυτό είναι πολύ ενδιαφέρον γιατί αν επιλυθεί θα επηρεάσει τις ζωές πολλών ανθρώπων και θα βοηθήσει στο τομέα της Ιατρικής.

## Βιβλιογραφία

- [1] Υλικό Διαλέξεων Συστήματα Υπολογιστικής Νοημοσύνης (ΕΠΛ 444), Τμήμα Πληροφορικής Τμήμα Πληροφορικής, Πανεπιστήμιο Κύπρου, Χρίστος Σχίζας
- [2] Υλικό Διαλέξεων Πληροφοριακών Συστημάτων Μάθησης (ΕΠΛ 442), Τμήμα Πληροφορικής, Πανεπιστήμιο Κύπρου, Χρίστος Χριστοδούλου
- [3] Włodzisław Duch, “What is Computational Intelligence and what could it become?”, Department of Informatics, Nicolaus Copernicus University, 2007
- [4] B. Eskenazi, L. Fenster, and S. Sidney, “A multivariate analysis of risk factors for preeclampsia”, *J. Am. Med Association*, vol. 266, 1991, pp.237-241.
- [5] Mello G., Parretti E., Ognibene A., Mecacci F., Cioni R., Scarselli G. και Messeri G., “Prediction of the development of pregnancy-induced hypertensive disorders in high-risk pregnant women by artificial neural networks”, *Clinical Chemistry and Laboratory Medicine*, vol. 39(9), 2001, pp. A25-A86.
- [6] Νεοκλέους Κ., Αναστασόπουλο Π., Νικολαΐδη Κ., Σχίζα Χ. και Νεοκλέους Κ., “Neural networks to estimate the risk for preeclampsia occurrence”
- [7] Preeclampsia Foundation, <http://www.preeclampsia.org/>
- [8] Action on Preeclampsia, <http://www.apec.org.uk/>
- [9] Ward Systems Group, Inc. *NeuroShell 2 Help*, <http://www.wardsystems.com/manuals/neuroshell2/index.html>
- [10] BabyHoper.com, “What is hCG?”, <http://www.babyhopes.com/articles/hcg.html>

[11] Government of Western Australia, Department of Health, “Doppler Ultrasound”,  
<http://www.imagingpathways.health.wa.gov.au/includes/index.html>

[12] Mayo Clinic, “Doppler ultrasound: What is it used for?”,  
<http://www.mayoclinic.com/health/doppler-ultrasound/AN00511>

[13] James P. Neilson, “Pre-eclampsia and eclampsia”, *Maternal Mortality*, 2009, ch. 3,  
pp. 79-85

[14] Christos Stergiou and Dimitrios Siganos, “Neural Networks”, *SURPRISE 96  
Journal*, vol.4, Imperial College London