



ΑΡΙΣΤΟΤΕΛΕΙΟ ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΟΝΙΚΗΣ

ΤΜΗΜΑ ΓΕΩΛΟΓΙΑΣ

ΤΟΜΕΑΣ ΓΕΩΦΥΣΙΚΗΣ

ΕΡΓΑΣΤΗΡΙΟ ΕΦΑΡΜΟΣΜΕΝΗΣ ΓΕΩΦΥΣΙΚΗΣ



ΣΤΕΦΑΝΟΣ ΣΥΚΙΩΤΗΣ

ΕΡΜΗΝΕΙΑ ΔΕΔΟΜΕΝΩΝ ΗΛΕΚΤΙΚΩΝ ΒΥΘΟΣΚΟΠΗΣΕΩΝ ΕΝΟΣ ΣΤΡΩΜΑΤΟΣ ΜΕ
ΤΗΝ ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ



ΘΕΣΣΑΛΟΝΙΚΗ

2021





ΣΥΚΙΩΤΗΣ ΣΤΕΦΑΝΟΣ

Φοιτητής Τμήματος Γεωλογίας, ΑΕΜ: 5737

ΕΡΜΗΝΕΙΑ ΔΕΔΟΜΕΝΩΝ ΗΛΕΚΤΙΚΩΝ ΒΥΘΟΣΚΟΠΗΣΕΩΝ ΕΝΟΣ ΣΤΡΩΜΑΤΟΣ ΜΕ
ΤΗΝ ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

Υποβλήθηκε στο Τμήμα Γεωλογίας, Τομέα Γεωφυσικής,
Εργαστήριο Εφαρμοσμένης Γεωφυσικής

Επιβλέπων

ΠΑΝΑΓΙΩΤΗΣ ΤΣΟΥΡΛΟΣ



© ΣΥΚΙΩΤΗΣ ΣΤΕΦΑΝΟΣ, Τμήμα Γεωλογίας Α.Π.Θ., Τομέας Γεωφυσικής, 2021

Με επιφύλαξη παντός δικαιώματος.

ΕΡΜΗΝΕΙΑ ΔΕΔΟΜΕΝΩΝ ΗΛΕΚΤΙΚΩΝ ΒΥΘΟΣΚΟΠΗΣΕΩΝ ΕΝΟΣ ΣΤΡΩΜΑΤΟΣ ΜΕ
ΤΗΝ ΧΡΗΣΗ ΝΕΥΡΩΝΙΚΩΝ ΔΙΚΤΥΩΝ

– Διπλωματική Εργασία

© SYKIoTIS STEFANOS, School of Geology, Dept. of Geophysics, 2021

All rights reserved.

INTERPRETATION OF ELECTRICAL SOUNDING DATA FOR SINGLE LAYERED SUB-
SURFACE MODEL USING NEURAL NETWORKS – *Bachelor Thesis*



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


Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν το συγγραφέα και δεν πρέπει να ερμηνευτεί ότι εκφράζουν τις επίσημες θέσεις του Α.Π.Θ.



ΕΥΧΑΡΙΣΤΙΕΣ

Η ολοκλήρωση της εργασίας δεν θα ήταν εφικτή χωρίς τις υποδείξεις του καθηγητή του Τομέα Γεωφυσικής του τμήματος Γεωλογίας του Αριστοτελείου Πανεπιστημίου Θεσσαλονίκης, κ. Παναγιώτη Τσούρλου. Του εκφράζω ένα μεγάλο ευχαριστώ για την βοήθεια.

Τέλος, θα ήθελα να ευχαριστήσω θερμά την οικογένεια μου και τους φίλους μου, για την συμπαράσταση και την υποστήριξη που είχα.



ΠΕΡΙΕΧΟΜΕΝΑ

ΠΕΡΙΛΗΨΗ.....	- 1 -
ABSTRACT.....	- 3 -
1. Εισαγωγή	- 4 -
2. Βασικές Αρχές	- 5 -
2.1 Ηλεκτρική Βυθοσκόπηση	- 5 -
2.2. Νευρωνικά Δίκτυα	- 8 -
3. Ερμηνεία.....	- 10 -
3.1 Ερμηνεία μέσω της Γραφικής μεθόδου	- 10 -
3.2 Ερμηνεία μέσω Αντιστροφής μοντέλου (Model Inversion)	- 11 -
4. Μεθοδολογία.....	- 12 -
5. Δομή – Αρχιτεκτονική	- 15 -
6. Κώδικας και βιβλιοθήκες.....	- 21 -
7. Αποτελέσματα.....	- 22 -
8. Συμπεράσματα	- 30 -
ΒΙΒΛΙΟΓΡΑΦΙΑ	- 32 -



ΠΕΡΙΛΗΨΗ

ΕΡΜΗΝΕΙΑ ΔΕΔΟΜΕΝΩΝ ΗΛΕΚΤΙΚΩΝ ΒΥΘΟΣΚΟΠΗΣΕΩΝ ΕΝΟΣ ΣΤΡΩΜΑΤΟΣ ΜΕ ΤΗΝ ΧΡΗΣΗ ΝΕΥΡΩΤΙΚΩΝ ΔΙΚΤΥΩΝ

ΣΥΚΙΩΤΗΣ ΣΤΕΦΑΝΟΣ

Η παρούσα διπλωματική εργασία αφορά την εφαρμογή νευρωνικών δικτύων στην ερμηνεία δεδομένων για ηλεκτρική βυθοσκόπηση σε δομή ενός στρώματος. Η ηλεκτρική βυθοσκόπηση είναι μια μέθοδος διασκόπησης κατά την οποία παράγεται μια εικόνα σε μορφή στήλης του υπεδάφους που βασίζεται στην κατακόρυφη μεταβολή της ηλεκτρικής αντίστασης κάτω από το κέντρο της διάταξης υποθέτοντας όμως ότι η γη αποτελείται από οριζόντια στρώματα. Στην παρούσα εργασία εξετάζεται η ερμηνεία δεδομένων για την απλή δομή ενός στρώματος η οποία έχει ως προϊόν τις εκτιμήσεις των τιμών ηλεκτρικής αντίστασης του ανώτερου στρώματος και του ημι-χώρου καθώς και το πάχος του στρώματος αυτού.

Στόχος της εργασίας είναι η δοκιμαστική χρήση νευρωνικών δικτύων για την ερμηνεία δεδομένων βυθοσκοπήσεων που αφορούν μοντέλα ενός στρώματος. Τα νευρωνικά δίκτυα, τα οποία τα τελευταία χρόνια συνεχώς εξελίσσονται βρίσκουν διάφορες εφαρμογές σε όλους τους τομείς, προσφέρουν ταχύτητα στην επίλυση προβλημάτων αλλά και ακρίβεια. Για το πρόβλημα που μελετήθηκε το δίκτυο εκπαιδεύτηκε με 66000 μοντέλα ενός στρώματος με μεγάλο εύρος τιμών αντιστάσεων και πάχους τα οποία κατασκευάστηκαν με κώδικα στη Python. Για την κατασκευή του δικτύου χρησιμοποιήθηκε η βιβλιοθήκη TensorFlow και Keras ενώ για την εκπαίδευση χρησιμοποιήθηκε η πλατφόρμα του Google Colaboratory – Colab. Η αρχιτεκτονική του δικτύου είναι ένας συνδυασμός μεταξύ CNN (Convolutional Neural Network) και DNN (Deep Neural Network) με 2 επίπεδα εισόδου των δεδομένων και 2 επίπεδα εξόδου από τα οποία το ένα έχει ως προϊόν τις 2 τιμές που αντιστοιχούν στις αντιστάσεις των στρωμάτων ενώ το άλλο το πάχος του στρώματος.

Ο αλγόριθμος δοκιμάστηκε σε πλήθος συνθετικών δεδομένων αλλά και πραγματικά δεδομένα. Επίσης τα αποτελέσματα συγκρίθηκαν με αυτά που παράγονται με τη μέθοδο της αντιστροφής (λογισμικό IPI2WIN) .



Σε γενικές γραμμές παρά τις σχετικές αδυναμίες η μέθοδος παρήγαγε ικανοποιητικά αποτελέσματα και αποτελεί τη βάση για την επέκταση του αλγορίθμου σε προβλήματα με περισσότερα στρώματα.



ABSTRACT

INTERPRETATION OF ELECTRICAL SOUNDING DATA FOR SINGLE LAYERED SUB-SURFACE MODEL USING NEURAL NETWORKS

SYKIOTIS STEFANOS

The present diploma thesis deals with the application of neural networks in the interpretation of vertical electrical sounding data for a single layer geoelectrical model. Electrical resistivity sounding is a geoelectrical method of surveying which produces a geoelectrical column of the subsurface based on the vertical change of electrical resistivity below the center of the electrode array assuming that the earth is composed of horizontal layers. This work examines the interpretation of data for the case of a simple layer structure i.e., seeking estimates of the electrical resistance values of the upper layer and the half-space as well as the thickness of the first layer.

The aim of this work is the experimental use of neural networks for the interpretation of vertical electrical sounding data concerning single layer models. Neural networks, which in recent years are of growing use, find various applications in all areas as they can offer speed in problem solving but also accuracy. For the studied problem the network was trained with 66000 one-layer models with a wide range of layer resistance and thicknesses values using a simple forward problem solver based on Python. The TensorFlow and Keras library was used to build the network, while the Google Colaboratory - Colab platform was used for the training. The network architecture is a combination between CNN (Convolutional Neural Network) and DNN (Deep Neural Network) with 2 data input levels and 2 output levels, one of which has as a product the two values corresponding to the layer resistances while the other includes a single value which is the thickness of the layer.

The algorithm was tested on several synthetic data. The results were also compared with those produced by standard inversion method (IPI2WIN software).

In general, despite the relative weaknesses, the method produced satisfactory results and is the basis for extending the algorithm to problems with more layers.



1. Εισαγωγή

Με τις μεθόδους γεωφυσικής διασκόπησης καθορίζονται οι ιδιότητες των πετρωμάτων των επιφανειακών στρωμάτων της Γης, με σκοπό την ανάλυση και την ερμηνεία της γεωλογικής δομής αυτής, στην αναζήτηση μεταλλευμάτων και γεωθερμικών πεδίων, στην υδρογεωλογία ή ακόμα και στην τεχνική γεωλογία για την ανεύρεση είτε γεωλογικού υποβάθρου είτε μητρικού πετρώματος, ανάλογα με τον στόχο κάθε έρευνας.

Στην εργασία αυτή αναλύεται η εφαρμογή των νευρωνικών δικτύων στην περίπτωση της Βυθοσκόπησης. Η Βυθοσκόπηση είναι η μέθοδος διασκόπησης με την μέτρηση της ηλεκτρικής αντίστασης. Κατά την μέθοδο αυτή τα ηλεκτρόδια δυναμικού παραμένουν σταθερά ενώ τα ηλεκτρόδια αυξάνουν την απόσταση τους σταδιακά και συμμετρικά ως προς το κέντρο της διάταξης. Η ηλεκτρική αντίσταση που καταγράφεται δεν είναι η πραγματική αλλά ένας σταθμισμένος μέσος όρος των επιμέρους αντιστάσεων ανάλογα με την συμμετοχή του κάθε στρώματος. Ανάλογα με την διάταξη υπολογίζεται η φαινόμενη ηλεκτρική αντίσταση.

Η παρούσα διπλωματική εργασία αφορά την εφαρμογή νευρωνικών δικτύων στην ερμηνεία δεδομένων για ηλεκτρική βυθοσκόπηση ενός στρώματος. Στην πτυχιακή αυτή για την επίλυση και την εξαγωγή των αποτελεσμάτων θα χρησιμοποιηθούν νευρωνικά δίκτυα και συγκεκριμένα με τη διαδικασία της εποπτευόμενης μάθησης (Supervised Learning). Σκοπός του Νευρωνικού είναι ο υπολογισμός των αντιστάσεων για το μοντέλο με ένα στρώμα (ένα ανώτερο στρώμα και ο ημιχώρος) καθώς και το βάθος αλλαγής της τιμής. Τα νευρωνικά δίκτυα επιτυγχάνουν την επίλυση προβλημάτων γρήγορα και με μεγάλη ακρίβεια.


Τυπικά, για την ερμηνεία των μετρήσεων χρησιμοποιούνται πρότυπες καμπύλες στις οποίες πρέπει το διάγραμμα της φαινόμενης αντίστασης ($\Omega \cdot m$) με την $AB/2$ (m) να ταιριάζει όσο γίνεται αλλά και η Μέθοδος της Αντιστροφής (Inversion). Στην εργασία θα γίνει σύγκριση μεταξύ των μεθόδων Αντιστροφής και του Νευρωνικού Δικτύου σε συνθετικά δεδομένα αλλά και σε πραγματικά από την περιοχή του Γαλλικού ποταμού.

2.1 Ηλεκτρική Βυθοσκόπηση

Στόχος της μεθόδου της ειδικής αντίστασης είναι να βρεθεί η γεωλογική δομή του υπεδάφους μέσω της ερμηνείας της γεωηλεκτρικής δομής που προκύπτει από τις μετρήσεις. Λόγω χαμηλού κόστους και μεγάλου εύρους εφαρμογών είναι η πιο διαδεδομένη γεωφυσική μέθοδος και χρησιμοποιείται κυρίως στην Υδρογεωλογία, στην Τεχνική Γεωλογία στην αναζήτηση μεταλλευμάτων και γεωθερμικών πεδίων, στην ανεύρεση του βάθους του μητρικού πετρώματος σε τοποθεσίες κατασκευής τεχνητών φραγμάτων, στην αρχαιομετρία κ.α. Συγκεκριμένα η μέθοδος της βυθοσκόπησης έχει ως αποτέλεσμα την εξαγωγή (μετά από κατάλληλη επεξεργασία των μετρήσεων) μιας στήλης κάτω από το κέντρο της μέτρησης η οποία αντιστοιχεί στη γεωηλεκτρική δομή του υπεδάφους για το σημείο αυτό.

Κατά την μέθοδο της γεωηλεκτρικής διασκόπησης μετράμε τη διαφορά δυναμικού που προκαλείται από την εισαγωγή ηλεκτρικού ρεύματος μέσα στη γη ενώ το βάθος διασκόπησης εξαρτάται από το μέγιστο άνοιγμα των ηλεκτροδίων που αλλάζει σε κάθε μέτρηση. Η ποσότητα που προκύπτει από τις μετρήσεις δεν είναι η ειδική ηλεκτρική αντίσταση αλλά η φαινόμενη αντίσταση αποτελεί (σε μια πρώτη προσέγγιση) ένα είδος «μέσου όρου» των ηλεκτρικών αντιστάσεων του ανομοιογενούς υπεδάφους. Άρα δεν δίνει ακριβώς την πραγματική αλλά μια «παραμορφωμένη» εικόνα της γεωηλεκτρικής δομής του υπεδάφους αποτέλεσμα της συμβολής των τιμών όλων των αντιστάσεων, από το σημείο εισαγωγής του ρεύματος μέχρι την καταγραφή. Η πραγματική αντίσταση μπορεί να βρεθεί μόνο μετά από κατάλληλη ερμηνεία και επεξεργασία.

Η διαδικασία της μέτρησης ξεκινά με την επιλογή της διάταξης βάσει της οποίας θα γίνει η τοποθέτηση των ηλεκτροδίων. Σε κάθε διάταξη συμμετέχουν 4 ηλεκτρόδια τα οποία



Σχήμα2.1: Διάταξη Schlumberger

καρφώνονται στο έδαφος. Στον εξοπλισμό των μετρήσεων περιλαμβάνεται και το όργανο μέτρησης που αποτελείται από μια πηγή, ένα βολτόμετρο και ένα αμπερόμετρο.

Η διάταξη η οποία τυπικά χρησιμοποιείται, λόγω γεωμετρίας, για την παραγωγή των δεδομένων ηλεκτρικής βυθοσκόπησης είναι η Schlumberger [Σχήμα 2.1]. Η διάταξη χαρακτηρίζεται από την αρκετά μεγαλύτερη απόσταση των ηλεκτροδίων A και B, τα οποία παρέχουν το ηλεκτρικό ρεύμα, σε σχέση με τα ηλεκτρόδια M και N τα οποία καταγράφουν το δυναμικό αλλά και την τοποθέτηση των ηλεκτροδίων M-N στο κέντρο, μεταξύ των A-B. Ο γεωμετρικός παράγοντας για την διάταξη αυτή ορίζεται ως :

$$K = \pi * \frac{L^2}{(2 * l)} \quad (1),$$

όπου $l \rightarrow$ το μισό της απόστασης μεταξύ $M - N$

$L \rightarrow$ το μισό της απόστασης μεταξύ $A - B$

Επειδή οι μετρήσεις δεν αποτελούν τις πραγματικές αντιστάσεις αλλά τις φαινόμενες, η ερμηνεία των μετρήσεων της ειδικής αντίστασης πρέπει να γίνεται με προσοχή. Για την σύγκριση των τιμών και την ερμηνεία μόνο η σχετική σύγκριση των φαινόμενων ειδικών αντιστάσεων για μια περιοχή είναι ασφαλής καθώς η μετρούμενη αντίσταση εξαρτάται από την γεωηλεκτρική δομή. Συνυπολογίζοντας άλλες μελέτες στην περιοχή όπως γεωτρήσεις, γεωλογικοί χάρτες μπορούν να εξαχθούν ασφαλή συμπεράσματα για την αντιστοιχία αντίστασης και πετρώματος.

Όπως προαναφέρθηκε, σε κάθε μέτρηση χρησιμοποιούνται 4 ηλεκτρόδια. Η απόσταση των ηλεκτροδίων ρεύματος AB ξεκινά από μερικά μέτρα και φτάνει έως και μερικές εκατοντάδες μέτρα. Η μέγιστη απόσταση, όπως προαναφέρθηκε επηρεάζει και το μέγιστο βάθος διασκόπησης το οποίο ενδεικτικά ορίζεται για την βυθοσκόπηση ως τα $1/4$ με $1/5$ της μέγιστης απόστασης των ηλεκτροδίων ρεύματος AB.

Το καταγραφικό συνδέεται με τα ηλεκτρόδια μέσω καλωδίων το οποίο διαβιβάζει συνεχές ρεύμα έντασης από μερικά milli Ampere έως μερικά Ampere στα ηλεκτρόδια A και B. Το δυναμικό μετράται σε διάφορες θέσεις από τα ηλεκτρόδια M και N. Λόγω της ανομοιογένειας της γης η οποία κατά επέκταση την καθιστά και γεωηλεκτρικά ανομοιογενή, οι μετρήσεις είναι συνάρτηση της γεωηλεκτρικής δομής του υπεδάφους καθώς και της γεωμετρίας της μέτρησης. Άρα η τιμή




που καταγράφεται είναι η φαινόμενη ειδική ηλεκτρική αντίσταση. Επομένως η φαινόμενη ειδική ηλεκτρική αντίσταση ορίζεται ως:

$$\rho = R * K = \left(\frac{VMN}{IAB} \right) * K, (2) \quad K \rightarrow \text{Γεωμετρικός παραγοντας που εξαρτάται από διαταξη,}$$
$$VMN \rightarrow \text{Δυναμικό (Volts), } IAB \rightarrow \text{Ένταση ρεύματος (Ampere),}$$
$$\rho \rightarrow \text{Φαινόμενη Ειδική ηλεκτρική αντίσταση (Ohm * m),}$$
$$R \rightarrow \text{Ηλεκτρική Αντίσταση (Ohm)}$$

2.2. Νευρωνικά Δίκτυα

Τα τεχνητά Νευρωνικά Δίκτυα λειτουργούν όπως τα οργανικά νευρωνικά δίκτυα. Τα δίκτυα αυτά έχουν νευρώνες οι οποίοι συνδέονται μεταξύ τους και σε συνδυασμό με συναρτήσεις ενεργοποίησης και τον τρόπο σύνδεσης μεταξύ τους παρομοιάζουν την δομή των οργανικών.




Σχήμα 2.2: Σχεδιάγραμμα Νευρωνικού Δικτύου

Το νευρωνικό δίκτυο αποτελείται από νευρώνες στους οποίους γίνεται όλη η επεξεργασία των δεδομένων που εισέρχονται σε αυτό. Σε κάθε νευρώνα υπάρχει ένα σύνολο από τιμές βαρών που μπορούν να αλλάζουν. Τα βάρη αυτά εφαρμόζονται στις τιμές που εισέρχεται στο νευρώνα και στο τέλος προκύπτει η τιμή της ιδιότητας η οποία είναι το προϊόν του νευρώνα.

Στα αποτελέσματα ενός ή πολλών νευρώνων (επίπεδα) εφαρμόζεται η συνάρτηση ενεργοποίησης (activation function) η οποία και επηρεάζει τα αποτελέσματα με βάση τις ίδιες τις τιμές τους ώστε να βρει περίπλοκες σχέσεις μεταξύ των τιμών εισόδου και των τιμών εξόδου [Σχήμα 2.3].

Υπάρχουν διάφοροι τύποι νευρώνων οι οποίοι πραγματοποιούν συγκεκριμένες πράξεις μεταξύ των τιμών εισόδου και των βαρών. Ως επίπεδο (layer) χαρακτηρίζεται το σύνολο των νευρώνων (nodes-neurons) με κοινά χαρακτηριστικά. Τα ενδιάμεσα επίπεδα μεταξύ του επιπέδου εισόδου και εξόδου λέγονται κρυφά επίπεδα (hidden layer). Στο τέλος γίνεται εκτίμηση των αποτελεσμάτων του υπολογισμού και υπολογίζεται η ακρίβεια των υπολογισμών με βάση κάποια συνάρτηση (loss function). Με βάση την απόκλιση αυτή βλέπουμε πόσο καλά «μαθαίνει» το δίκτυο αλλά και με βάση αυτήν την τιμή, η διαδικασία βελτιστοποίησης (optimizer) προσαρμόζει τις παραμέτρους ώστε να γίνει καλύτερο.




Σχήμα 2.3: Εσωτερική δομή νευρωνικού δικτύου

3. Ερμηνεία

3.1 Ερμηνεία μέσω της Γραφικής μεθόδου

Η ερμηνεία των δεδομένων βασίζεται στην χρήση πρότυπων καμπυλών 2 στρωμάτων [Σχήμα 3.1]. Οι πρότυπες καμπύλες έχουν προκύψει από χαρτογράφηση σε λογαριθμικούς άξονες διάφορους λόγους ρ_2/ρ_1 με άξονα X, $AB/2$ και άξονα Y, ρ_2/ρ_1 . Για την ερμηνεία των μετρήσεων θα πρέπει να γίνει η προβολή τους σε ένα διάγραμμα με λογαριθμικούς άξονες με άξονα X τις τιμές $AB/2$ και με άξονα Y τις τιμές των φαινόμενων αντιστάσεων που μετρήθηκαν. Μετά την προβολή στο διάγραμμα θα πρέπει να γίνει η ταύτιση μεταξύ των πρότυπων καμπύλων και της καμπύλης από τις μετρήσεις. Κάθε



Σχήμα 3.1: Πρότυπες καμπύλες

καμπύλη στο διάγραμμα των πρότυπων αντιστοιχεί σε μια αναλογία αντιστάσεων. Έτσι γνωρίζοντας την αντίσταση του ανώτερου μπορούμε να βρούμε να βρούμε μέσω της τιμής της καμπύλης. Η εκτίμηση του βάθους γίνεται με βάση την θέση του σημείου (1,1) μετά την ταύτιση των καμπύλων. Με την ταύτιση των καμπύλων, σημειώνεται η θέση του σημείου (1,1) από το διάγραμμα καμπύλων στο διάγραμμα των μετρήσεων. Η τιμή Y αντιστοιχεί στην αντίσταση του ανώτερου (P1) ενώ η τιμή X στην τιμή $AB/2$. Ξέροντας τις τιμές αυτές τότε μέσω των σχέσεων :

$$\frac{AB}{2Z} = 1 \quad (3) \quad \left| \quad \frac{P_2}{P_1} = \mu \quad (4) \right. , \mu \rightarrow \text{η τιμή της πρότυπης καμπύλης}$$

υπολογίζονται από τις σχέσεις αυτές το Z (το βάθος αλλαγής) και το P2.

3.2 Ερμηνεία μέσω Αντιστροφής μοντέλου (Model Inversion)

Η διαδικασία της Αντιστροφής είναι μία έμμεση μέθοδος προσδιορισμού ενός πιθανού μοντέλου δομής της γης από το οποίο μπορούν να προκύψουν μετρήσεις (Προβλεπόμενες μετρήσεις) που να είναι όμως παρόμοιες με τις παρατηρούμενες. Είναι το αντίστροφο της διαδικασίας επίλυσης του ευθέως προβλήματος (εύρεση της απόκρισης του μοντέλου). Στην αντιστροφή, εισάγονται τα παρατηρούμενα δεδομένα και η έξοδος είναι ένα μοντέλο του οποίου τα δεδομένα μετρήσεων ταιριάζουν στα δεδομένα που εισάχθηκαν. Η διαδικασία της Αντιστροφής ξεκινά με την δημιουργία ενός αρχικού μοντέλου για την δομή. Στην συνέχεια, από το μοντέλο παράγονται μέσω της επίλυσης του ευθέως προβλήματος οι συνθετικές μετρήσεις (προβλεπόμενες). Μέσω της σύγκρισης των πραγματικών μετρήσεων με τις προβλεπόμενες υπολογίζεται το σφάλμα το οποίο και χρησιμοποιείται ως δείκτης για το βαθμό που οι συνθετικές μετρήσεις πλησιάζουν στις πραγματικές. Η διαδικασία αυτή επαναλαμβάνεται μέχρι το σφάλμα μεταξύ των πραγματικών και συνθετικών δεδομένων να μην βελτιώνεται άλλο. Το μοντέλο της δομής για το οποίο τα συνθετικά έχουν το μικρότερο σφάλμα σε σχέση με τα παρατηρούμενα (πραγματικά) δεδομένα θεωρείται και η λύση της διαδικασίας της αντιστροφής. Για την αντιστροφή χρησιμοποιήθηκε το λογισμικό IPI2WIN (το οποίο για την μοντελοποίηση χρησιμοποιεί τον αλγόριθμο γραμμικού φιλτραρίσματος ενώ η αντιστροφή γίνεται βάσει της μεθόδου του Occam. Η μέθοδος του Occam αποσκοπεί στην αναζήτηση του πιο ομαλού (smooth) γεωηλεκτρικού μοντέλου το οποίο συγχρόνως ελαχιστοποιεί το σφάλμα μεταξύ των πραγματικών και συνθετικών δεδομένων.

4. Μεθοδολογία

Σκοπός της μελέτης είναι η εύρεση της γεωηλεκτρικής δομής μέσω βυθοσκόπησης με μετρήσεις ηλεκτρικής αντίστασης με τη διάταξη Schlumberger και τη χρήση Νευρωνικών δικτύων. Ο τύπος εκπαίδευσης του Νευρωνικού δικτύου είναι με επιβλεπόμενη μάθηση (Supervised Learning), δηλαδή οι τιμές που εισέρχονται στο δίκτυο συγκρίνονται με κάποιες πρότυπες τιμές με σκοπό το δίκτυο να βρει κάποια σχέση μεταξύ τους αλλά και να την γενικεύσει.

Στα πλαίσια της πτυχιακής, η εφαρμογή των Νευρωνικών δικτύων έγινε με σκοπό να ερμηνεύσει μετρήσεις για γεωηλεκτρική δομή ενός στρώματος. Τα δεδομένα που κατασκευάστηκαν για την εκπαίδευση περιλάμβαναν 15 τιμές φαινόμενων αντιστάσεων (οι μετρήσεις) με αυξανόμενες αποστάσεις AB και σταθερά MN για τις μετρήσεις που αντιστοιχούν σε μοντέλα ηλεκτρικών αντιστάσεων με εύρος (10, 40500) Ohm-m για κάθε μοντέλο γεωηλεκτρικής δομής (για ένα στρώμα) του υπεδάφους,

Άρα τα δεδομένα που είναι διαθέσιμα είναι οι μετρήσεις της φαινόμενης αντίστασης και οι αποστάσεις AB/2 που είναι οι τιμές της απόστασης των ηλεκτροδίων ρεύματος από το κέντρο της διάταξης ενώ η τιμή MN δηλαδή τις αποστάσεις των ηλεκτροδίων που καταγραφούν την διαφορά δυναμικού διατηρείται σταθερή.

Επιπλέον τα δεδομένα εισόδου έχουν «ανακατευτεί» ώστε να εμποδιστεί η τάση του δικτύου για απομνημόνευση των δεδομένων σε βάρος της εκμάθησης.

Για να έχουμε περισσότερες τιμές φαινόμενων αντιστάσεων και οι τιμές αυτές να ισαπέχουν μεταξύ τους από τις αρχικές μετρήσεις (για τιμές AB/2=4, 6, 8, 10, 12, 15, 18, 20, 24, 30, 40, 50, 65, 80, 100), μέσω παρεμβολής υπολογίστηκαν συνολικά 200 τιμές.

Οι τιμές του μοντέλου (γεωηλεκτρική δομή της γης για ένα στρώμα) τις οποίες και προσπαθούμε να βρούμε είναι τρεις και σχετίζονται με την αντίσταση και του πάχους του στρώματος καθώς και με την ηλεκτρική αντίσταση του ημιχώρου. Με βάση αυτές τις τρεις παραμέτρους του μοντέλου (δυο ειδικές ηλεκτρικές αντιστάσεις και το πάχος) εκπαιδεύτηκε το δίκτυο για διαφορετικά μοντέλα και υπολογίστηκαν συνθετικές μετρήσεις.

Το πρόβλημα περιλαμβάνει 2 τύπους δεδομένων με διαφορετικά φυσικά μεγέθη: αποστάσεις ηλεκτροδίων AB από τη μία και φαινόμενες αντιστάσεις (δηλαδή οι μετρήσεις) από την άλλη

που δε συνδέονται μεταξύ τους άμεσα. Έτσι έγινε η επιλογή κατασκευής του δικτύου με δύο εισόδους για τους δυο διαφορετικούς τύπους δεδομένων.

Όσο αναφορά τις εισόδους, η πρώτη είσοδος αντιστοιχεί στις μετρήσεις της φαινόμενης αντίστασης ενώ η δεύτερη είσοδος αντιστοιχεί στις αποστάσεις $AB/2$. Επιπλέον, μέσα στο δίκτυο αυτές οι τιμές συνδυάζονται και τελικά χρησιμοποιούνται για τον υπολογισμό της λύσης η οποία γίνεται και αυτή σε δυο κλάδους από τους οποίους ο ένας θα δώσει τις τιμές της ειδ. ηλεκτρικής αντίστασης (στρώμα και ημιχώρος) ενώ ο άλλος θα δώσει την τιμή του πάχους του στρώματος (δλδ. το βάθος της αλλαγής).


Και στους δύο κλάδους έχει εφαρμοστεί μία δομή «λαιμού μπουκαλιού» (Bottleneck) η οποία αρχικά συμπιέζει και μετά αποσυμπιέζει τα δεδομένα με σκοπό να «μάθει» το δίκτυο να αναπαράγει τα δεδομένα με τα κύρια χαρακτηριστικά τους. Επίσης να σημειωθεί ότι σε όλες οι τιμές είτε των φαινόμενων αντιστάσεων, είτε των μοντέλων έχει εφαρμοστεί κανονικοποίηση ώστε να είναι εντός του διαστήματος $[0, 1]$ καθώς έτσι η εκπαίδευση είναι καλύτερη και γρηγορότερη. Η κανονικοποίηση έγινε με βάση την εξής συνάρτηση:

$$y' = \frac{\ln(y)}{20} \quad (15), \quad \text{όπου } y \rightarrow \text{η τιμή της παραμέτρου}$$

Εντός του δικτύου χρησιμοποιήθηκαν ενδιάμεσα πυκνά (dense) επίπεδα, όπου σε αυτά γίνεται το άθροισμα των εσωτερικών γινομένων των ανυσμάτων (vectors) των βαρών (W_i) με τις τιμές εισόδου (X_i), καθώς και επίπεδα Συνέλιξης (1D Convolutional Layers) και δειγματοληψίας (Pooling) [Σχήμα 4.1]. Με την χρήση των επιπέδων συνέλιξης επιτυγχάνεται ο υπολογισμός των χαρακτηριστικών που συνδέουν τα δεδομένα με τις τιμές της λύσης.

Τα Νευρωνικά δίκτυα που εμπεριέχουν μέσα επίπεδα συνέλιξης ονομάζονται Νευρωνικά Δίκτυα Συνέλιξης

(Convolutional Neural Networks - CNN) και στην συγκεκριμένη περίπτωση εφαρμόζονται στην πρώτη είσοδο δηλαδή στα δεδομένα της φαινόμενης ηλεκτρικής αντίστασης ώστε να βρούμε,



Σχήμα 4.1: Σχεδιάγραμμα λειτουργίας Συνέλιξης

όπως προαναφέραμε, κάποιο χαρακτηριστικό - ιδιότητα που στην συγκεκριμένη περίπτωση είναι οι τιμές του μοντέλου ενός στρώματος. Αντίθετα, για την άλλη είσοδο χρησιμοποιήθηκαν πυκνά (Dense) επίπεδα ενώ στην συνέχεια γίνεται ο συνδυασμός των δύο εισόδων με την χρήση πολλαπλασιασμού των δύο ανυσμάτων (αφού έρθουν στις ίδιες διαστάσεις).


Για τον υπολογισμό της ποιότητας της λύσης χρησιμοποιήθηκε η Μέση Απόλυτη Απόκλιση (Mean Absolute Error-MAE) που υπολογίζει την απόκλιση της απόκρισης της λύσης, δηλαδή συγκρίνει τις συνθετικές μετρήσεις φαινόμενης αντίστασης που αντιστοιχούν σε ένα υποψήφιο μοντέλο με τα αρχικά δεδομένα δηλαδή τις μετρήσεις μας. Για την ελαχιστοποίηση της απόκλισης χρησιμοποιείται βελτιστοποίηση μέσω του αλγορίθμου Gradient Descent ο οποίος ψάχνει το σημείο με την ελάχιστη απόκλιση μέσω αλλαγών στα βάρη.

Ο αλγόριθμος έχει ως παράμετρο τον ρυθμό εκμάθησης (Learning Rate) ο οποίος ελέγχει πως θα μεταβάλλονται τα βάρη ανά επανάληψη. Όταν η παράμετρος έχει πολύ υψηλή η τιμή τότε δεν θα φτάσει στο σωστό ελάχιστο σημείο και ίσως το «περάσει» ενώ όταν η τιμή της είναι πολύ μικρή δεν θα φτάσει στο σημείο αυτό.

Εκτός από το ρυθμό εκμάθησης μια άλλη παράμετρος που λαμβάνεται υπόψη είναι το μέγεθος των πακέτων δεδομένων-μοντέλων (batch size) που θα χρησιμοποιηθούν ταυτόχρονα κατά την εκπαίδευση. Στο δίκτυο που δημιουργήθηκε χρησιμοποιήθηκαν 8 πακέτα (batch size) για 15 στάδια (Epochs). Σε κάθε στάδιο γίνεται ο υπολογισμός της απόκλισης και οι αλλαγές στα βάρη μέσω της βελτιστοποίησης ενώ η επανάληψη (iteration) ορίζεται ως το στάδιο για κάθε ένα από τα 8 πακέτα δεδομένων. Τέλος από τα 66000 μοντέλα που κατασκευάστηκαν για την εκπαίδευση, το 25% χρησιμοποιήθηκε για την αξιολόγηση του ώστε να μελετηθεί και η συμπεριφορά και σε «ανεξάρτητα» δεδομένα.

5. Δομή – Αρχιτεκτονική

Στην παράγραφο αυτή θα παρουσιαστεί η αρχιτεκτονική του Νευρωνικού Δικτύου που κατασκευάστηκε και θα συγκριθεί με άλλα δύο δίκτυα με την ίδια δομή αλλά και με κάποιες αλλαγές στις παραμέτρους των επιπέδων. Όπως προαναφέρθηκε το δίκτυο έχει δύο εισόδους για δεδομένα ενώ στην έξοδο χωρίζεται σε δύο κλάδους για κάθε μέγεθος. Επίσης εμπεριέχει επίπεδα συνέλιξης τα οποία αποσκοπούν στην εμφάνιση χαρακτηριστικών μεταξύ των δεδομένων.



Σχήμα 5.1: Οι 2 κύριες δομές του Νευρωνικού δικτύου. A] είναι η δομή με τιμή bottleneck 32 κόμβων ενώ B] η δομή με bottleneck 64 κόμβων


Όμως όπως φαίνεται και από το Σχήμα 5.1 χρησιμοποιήθηκε η δομή με πολλαπλά πυκνά επίπεδα. Το μεγαλύτερο πρόβλημα που συναντήθηκε ήταν η εκτίμηση του πάχους του στρώματος ενώ στις εκτιμήσεις των αντιστάσεων υπήρχε μια καλή ακρίβεια. Έτσι η κύρια αλλαγή για την βελτίωση του δικτύου επικεντρώθηκε στον κλάδο του βάθους. Στους κλάδους, όπως θα παρουσιαστεί παρακάτω, έχει εφαρμοστεί μία δομή «λαιμού μπουκαλιού» (Bottleneck). Η επέμβαση που προαναφέραμε αλλάζει στον κλάδο του βάθους τον αριθμό των κόμβων-νευρώνων αλλάζοντας έτσι τον βαθμό συμπίεσης. Με βάση την αλλαγή, οι κύριες δομές που ελέγχθηκαν χωρίζονται σε 2 κατηγορίες [Σχήμα 5.1]. Στην συνέχεια ορίστηκαν τα αρχικά βάρη στο δίκτυο ώστε να μην είναι τυχαία βοηθώντας έτσι στην ταχύτητα της εκπαίδευσης και την ποιότητα της.

Οι πυρήνες αρχικοποίηση (Kernel initializers) που χρησιμοποιήθηκε ήταν ο LeCun normal ο οποίος θεωρεί μία κανονική κατανομή με κέντρο το 0 και τυπική απόκλιση που δίνεται από την παρακάτω σχέση:

$$\text{Τυπική απόκλιση} = \sqrt{\frac{1}{n_{inputs}}} \quad (16) , \quad \text{όπου } n_{inputs} \text{ είναι το πλήθος των δεδομένων που εισέρχονται}$$

Να σημειωθεί ότι ο LeCun Normal, βοηθά στην γρήγορη σύγκλιση του δικτύου καθώς στην ισορροπη προσέγγιση στη σωστή λύση.

Μία πάρα πολύ σημαντική παράμετρος στους κόμβους των επιπέδων- layers, είναι η συνάρτηση ενεργοποίησης (activation function). Η συνάρτηση ενεργοποίησης έχει ως μεταβλητή την τιμή από την έξοδο του κόμβου-νευρώνα και ουσιαστικά αλλάζει τη τιμή αυτή ακόμα και μη γραμμικά ώστε να λύσει περίπλοκα προβλήματα. Στο δίκτυο χρησιμοποιήθηκε σε όλες τις δομές, ως συνάρτηση ενεργοποίησης η SELU (Scaled Exponential Linear Unit) με την παρακάτω εξίσωση:



Σχήμα 5.2: Γραφική παράσταση των τιμών της συνάρτησης ενεργοποίησης SELU

$$SELU(x) = \lambda * \begin{cases} x, & \text{για } x > 0 \\ \alpha * e^{(x)} - \alpha, & \text{για } x \leq 0 \end{cases} \quad (18)$$

Η τιμές για τις δύο παραμέτρους είναι:

$$\alpha \approx 1.67326$$


$$\lambda \approx 1.05071$$

ενώ το διάγραμμα της συνάρτησης παρουσιάζεται στο Σχήμα 5.2.

Ως συνάρτηση υπολογισμού του σφάλματος (loss function), όπως προαναφέρθηκε χρησιμοποιήθηκε η Μέση Απόλυτη Απόκλιση (Mean Absolute Error-MAE) ενώ ως επιπλέον δείκτης για την εκπαίδευση χρησιμοποιήθηκε το Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error – MSE). Ως βελτιστοποιητής (Optimizer) για την ελαχιστοποίηση της απόκλισης, χρησιμοποιείται NADAM για τους λόγους που προαναφέρθηκαν. Οι περιπτώσεις δικτύων που εξετάστηκαν ήταν τρεις:


- I. Με δομή bottleneck με 32 κόμβους και LeCun normal ως kernel initializer
- II. Με δομή bottleneck με 64 κόμβους και LeCun normal ως kernel initializer
- III. Με δομή bottleneck με 64 κόμβους και Glorot uniform ως kernel initializer

Οι αρχιτεκτονικές και οι δομές αυτές είναι οι καλύτερες που προέκυψαν κατά την μελέτη αυτή και φυσικά με τις υπολογιστικές δυνατότητες που προσφέρει δωρεάν το Google Colaboratory. Όπως θα φανεί παρακάτω αυτή που ξεχωρίζει είναι το μοντέλο με δομή bottleneck με 32 κόμβους και LeCun Normal για τον υπολογισμό των αρχικών τιμών.



Σχήμα 5.3: Διαγράμματα από το TensorBoard για την σύγκριση της απόκλισης και του MSE κατά την εκπαίδευση. Δίνεται και το υπόμνημα

Για την σύγκριση των παραπάνω μοντέλων χρησιμοποιήθηκε το TensorBoard που προσφέρει η open source πλατφόρμα, TensorFlow. Το TensorBoard δίνει την δυνατότητα να συγκριθούν η απόκλιση, το Μέσο Τετραγωνικό Σφάλμα (Mean Squared Error – MSE) καθώς και άλλοι δείκτες, ανά epoch ή/και iteration. Όπως φαίνεται από τα διαγράμματα της εκπαίδευσης (Σχήμα 5.3), η αρχιτεκτονική I. ξεκινά απότομα ενώ μετά το 2ο στάδιο (epoch) παρατηρείται η ταύτιση της απόκλισης και του MSE. Στο τέλος καταλήγουν στην ίδια τιμή και για την MSE και για την απόκλιση (loss).



Σχήμα 5.4: διαγράμματα από το TensorBoard για την σύγκριση της απόκλισης και του MSE κατά την αξιολόγηση (evaluation). Δίνεται και το υπόμνημα

Σε αυτό το σημείο θα πρέπει να σημειωθεί ότι ένα από τα προβλήματα και φόβος κατά τον σχεδιασμό του δικτύου είναι το πρόβλημα της υπερταύτισης (overfitting) δηλαδή την μάθηση από το δίκτυο όχι της εσωτερικής δομής των δεδομένων αλλά την απομνημόνευση των ίδιων των δεδομένων. Το πρόβλημα αυτό εντοπίζεται στα διαγράμματα της αξιολόγησης, όπου για δεδομένα που το δίκτυο δεν έχει ξαναδεί αστοχεί (έχει μεγάλη απόκλιση) ενώ κατά την εκπαίδευση επιτυγχάνεται η μείωση της απόκλισης και της τιμής οποιουδήποτε άλλου δείκτη. Έτσι, ένα μέρος των δεδομένων χρησιμοποιείται για την αξιολόγηση του δικτύου. Στην μελέτη αυτή το 1/4 , χρησιμοποιείται για την αξιολόγηση.


	LECUN NORMAL 32 UNITS BOTTLENECK	LECUN NORMAL 64 UNITS BOTTLENECK	GLOT UNIFORM 64 UNITS BOTTLENECK
ΜΕΓΙΣΤΗ ΔΙΑΦΟΡΑ ΣΤΗΝ ΗΛΕΚΤΡΙΚΗ ΑΝΤΙΣΤΑΣΗ 1	0.13	0.09	0.11
ΜΕΓΙΣΤΗ ΔΙΑΦΟΡΑ ΣΤΗΝ ΗΛΕΚΤΡΙΚΗ ΑΝΤΙΣΤΑΣΗ 2	0.104	0.110	0.105
ΜΕΓΙΣΤΗ ΔΙΑΦΟΡΑ ΣΤΟ ΒΑΘΟΣ	0.205	0.194	0.205
ΕΛΑΧΙΣΤΗ ΔΙΑΦΟΡΑ ΣΤΗΝ ΗΛΕΚΤΡΙΚΗ ΑΝΤΙΣΤΑΣΗ 1	9.13E-08	1.41-07	7.19E-08
ΕΛΑΧΙΣΤΗ ΔΙΑΦΟΡΑ ΣΤΗΝ ΗΛΕΚΤΡΙΚΗ ΑΝΤΙΣΤΑΣΗ 2	8.85E-10	9.99E-08	9.17E-08
ΕΛΑΧΙΣΤΗ ΔΙΑΦΟΡΑ ΣΤΟ ΒΑΘΟΣ	1.44E-07	2.44E-07	1.44E-07
ΠΛΗΘΟΣ ΤΙΜΩΝ ΜΕ ΔΙΑΦΟΡΑ ΣΤΗΝ ΤΙΜΗ ΤΟΥ ΒΑΘΟΥΣ > 0.01	6694	7250	7598

Πίνακας 5.1: Παρουσίαση τιμών για την μέγιστη και ελάχιστη διαφορά της ηλεκτρικής αντίστασης για κάθε στρώμα μεταξύ μοντέλου και της παραγόμενης τιμής από κάθε νευρωνικό δίκτυο, την μέγιστη και ελάχιστη διαφορά του βάθους μεταξύ μοντέλου και της παραγόμενης τιμής από κάθε νευρωνικό δίκτυο καθώς και το πλήθος των τιμών με διαφορά της τιμής του βάθους > 0.01 ($\approx 1m$)

Από την αξιολόγηση (Σχήμα 5.4) προκύπτει ότι η δομή Glorot με units παρουσιάζει μια διακύμανση κατά την αξιολόγηση με κάποιες έντονες κορυφές το οποίο δηλώνει αστάθεια.

Να σημειωθεί ότι την μικρότερη απόκλιση στις τιμές παρουσιάζουν τα I και II που έχουν ως kernel initializer το LeCun. Η παρατήρηση αυτή επιβεβαιώνει τις προτάσεις περί εφαρμογής LeCun

Normal ως Initializer. Παρόλα αυτά οι τελικές τιμές, γενικά είναι αρκετά καλές συγκριτικά με την εκπαίδευση όπως φαίνεται από τον Πίνακα 5.1 Επιπρόσθετα στα διαγράμματα με τις τιμές των



Σχήμα 5.5: διαγράμματα από το TensorBoard για την σύγκριση της απόκλισης και του MSE κατά την αξιολόγηση ανά iteration. Δίνεται και το υπόμνημα

δεικτών ανά επανάληψη (iteration) (Σχήμα 5.5) φάνηκε έντονα η διαφορά στην ικανότητα εκμάθησης μεταξύ των δομών που δοκιμάσαμε. Στα διαγράμματα αυτά η δομή 'I' έχει τις μικρότερες διακυμάνσεις και μια ξεκάθαρη τάση μείωσης των σφαλμάτων.

Κλείνοντας την παράγραφο, θα πρέπει να επισημανθεί ότι με βάση τα παραπάνω διαγράμματα παρατηρούμε ποια μοντέλα είναι ευσταθή και με μικρό σφάλμα και προσανατολίζουν προς κάποια διεύθυνση, την διερεύνηση όλο και καλύτερου μοντέλου. Στην περίπτωση αυτή, παρατηρείται ότι το Bottleneck με 32 κόμβους είναι καλύτερο και μάλιστα με initializer LeCun Normal και επομένως αν διατηρηθεί η δομή θα πρέπει να εξεταστούν περιπτώσεις με μικρότερο αριθμό κόμβων ή ακόμα και προστεθούν σε σειρά και άλλα bottlenecks.

6. Κώδικας και βιβλιοθήκες

Για το προγραμματιστικό μέρος της εργασίας, χρησιμοποιήθηκε η γλώσσα Python v.3.7.10. Η Python προσφέρει την δυνατότητα εύκολης διαχείρισης και γρήγορης επεξεργασίας δεδομένων είτε μέσω της βιβλιοθήκης της NumPy (Numerical Python) είτε μέσω Pandas. Την χρησιμότητα της στην ανάλυση δεδομένων έρχεται και συμπληρώνει η πλατφόρμα TensorFlow η οποία προσθέτει τα απαραίτητα εργαλεία για την κατασκευή ενός Νευρωνικού Δικτύου αλλά ακόμα και αν δεν χρησιμοποιήσει κάποιος τις προαναφερμένες βιβλιοθήκες, η TensorFlow μαζί με την Keras εμπεριέχει και αυτά τα εργαλεία για την προετοιμασία και επεξεργασία των δεδομένων. Στην κατασκευή του δικτύου που παρουσιάστηκε παραπάνω χρησιμοποιήθηκαν για την επεξεργασία η βιβλιοθήκη NumPy, για τον σχεδιασμό του χρησιμοποιήθηκε η TensorFlow και Keras ενώ για τις γραφικές παραστάσεις των δεδομένων χρησιμοποιήθηκε η Matplotlib.

Όπως προαναφέρθηκε, αξιοποιήθηκαν οι υποδομές που προσφέρει η Google μέσω Google Colaboratory για την όλη διαδικασία της επεξεργασίας και του σχεδιασμού του Νευρωνικού Δικτύου. Το Google Colaboratory προσφέρει δωρεάν GPU, CPU και TPU καθώς και περίπου 13GB RAM τα οποία σε συνδυασμό με το Google Drive βοηθάν στην γρήγορη επεξεργασία και πρόσβαση στα δεδομένα. Το αρνητικό στην περίπτωση είναι ο περιορισμός στον χρόνο χρήσης ανά Session. Το προγραμματιστικό περιβάλλον μέσω του οποίου αξιοποιούνται οι υποδομές αυτές είναι ένα Jupyter Notebook. Οι υποδομές που προσφέρει είναι 2 CPUs Intel Xeon 2.20GHz ενώ η GPU είναι NVIDIA TESLA K80. Το Colab φυσικά δίνει την δυνατότητα σύνδεσης σε τοπικό σύστημα σε περίπτωση που υποδομές που προσφέρει δεν ικανοποιούν τον χρήστη.

```
#RES MODEL
res_input = Input(shape=(200, 1), name='RES_INPUT', dtype='float64')
res = Conv2D(32, kernel_size=2, strides=1, padding='valid', activation='selu', kernel_initializer='glorot_uniform', dtype='float64', name='res_conv_1')(res_input)
res = MaxPooling2D(pool_size=2, strides=1, dtype='float64', name='res_maxpooling')(res)
res_output = Flatten(dtype='float64', name='res_flatten')(res)
res_output = Dense(128, activation='selu', name='res_dense', kernel_initializer='glorot_uniform', dtype='float64')(res_output)

#DEPTH MODEL
depth_input = Input(shape=(200, 1), name='DEPTH_INPUT', dtype='float64')
depth_output = Dense(128, activation='selu', name='DEPTH_DENSE', kernel_initializer='glorot_uniform', dtype='float64')(depth_input)

#SOUNDING
sounding_in = Multiply()(res_output, depth_output)

#RES MODEL_V1
sounding = Dense(128, activation='selu', kernel_initializer='glorot_uniform', dtype='float64')(sounding_in)
sounding = Dense(128, activation='selu', kernel_initializer='glorot_uniform', dtype='float64')(sounding)
sounding = Dense(128, activation='selu', kernel_initializer='glorot_uniform', dtype='float64')(sounding)
sounding_res_output = Dense(2, activation='selu', kernel_initializer='glorot_uniform', name='OUTPUT_RES', dtype='float64')(sounding)

#DEPTH MODEL
sounding_dep = Dense(32, activation='selu', kernel_initializer='glorot_uniform', dtype='float64')(sounding_in)
sounding_dep = Dense(32, activation='selu', kernel_initializer='glorot_uniform', dtype='float64')(sounding_dep)
sounding_depth_output = Dense(1, activation='selu', kernel_initializer='glorot_uniform', name='OUTPUT_DEPTH', dtype='float64')(sounding_dep)

model_2_input = [res_input, depth_input], outputs = [sounding_res_output, sounding_depth_output]
model_2_input.summary()
keras.utils.plot_model(model_2_input, show_shapes=True)

model_2_input.compile(optimizer='adam', loss=['OUTPUT_RES': 'mae', 'OUTPUT_DEPTH': 'mae'], metrics=['OUTPUT_RES': ['mean_squared_error'], 'OUTPUT_DEPTH': ['mean_squared_error']])
model_2_input.fit({'RES_INPUT': DENSE_processed_w_data_training, 'DEPTH_INPUT': DEPTH_input_data }, {'OUTPUT_RES': res_model_training, 'OUTPUT_DEPTH': depth_model_training},
                epochs = 15,
                batch_size = 8,
                validation_split = 0.25,
                callbacks=[tensorboard_callback])
```

Σχήμα 6.1: Δομή ενός από τα μοντέλα γραμμένο σε Python χρησιμοποιώντας την πλατφόρμα TensorFlow στο περιβάλλον του Google Colab.

7. Αποτελέσματα

Σε αυτήν την παράγραφο θα γίνει η σύγκριση μεταξύ των αρχικών μοντέλων και των μοντέλων που προκύπτουν από το Νευρωνικό δίκτυο που αναπτύχθηκε και παρουσιάστηκε προηγουμένως. Στην σύγκριση επίσης θα συμμετέχει και τα αποτελέσματα από την εφαρμογή της μεθόδου αντιστροφής με τη χρήση του λογισμικού IPI2WIN. Στην συνέχεια θα γίνει και η σύγκριση μεταξύ των αποτελεσμάτων για τις παραμέτρους για κάθε ένα από τα 11 μοντέλα που δοκιμάστηκαν καθώς και των παραγόμενων μετρήσεων από τις παραμέτρους της λύσης μέσω της επίλυσης του ευθέως προβλήματος.

	MODEL_0			MODEL_1			MODEL_2			MODEL_3		
	Real	IPI2WIN (Inversion)	NN	Real	IPI2WIN (Inversion)	NN	Real	IPI2WIN (Inversion)	NN	Real	IPI2WIN (Inversion)	NN
Resistivity layer 1	20	19.99	15.99	20	19.99	13.17	1000	1000	1015.21	100	100.1	74.31
Resistivity layer 2	30	30.17	27.29	400	396.2	193.44	2000	1932	2441.43	30	32.62	16.71
DEPTH	50	50.6	36.42	50	50.1	50.1	50	48.24	54.87	50	48.42	55.21
	MODEL_4			MODEL_5			MODEL_6			MODEL_7		
	Real	IPI2WIN (Inversion)	NN	Real	IPI2WIN (Inversion)	NN	Real	IPI2WIN (Inversion)	NN	Real	IPI2WIN (Inversion)	NN
Resistivity layer 1	100	99.94	78.76	100	99.99	77.93	500	500.3	518.81	500	500.1	506.51
Resistivity layer 2	400	398.3	368.41	2000	1577	875.94	30	44.3	45.46	400	407.4	391.32
DEPTH	50	49.86	50.64	50	49.1	51.75	50	48.6	45.2	50	47.73	58.19
	MODEL_8			MODEL_9			MODEL_10					
	Real	IPI2WIN (Inversion)	NN	Real	IPI2WIN (Inversion)	NN	Real	IPI2WIN (Inversion)	NN			
Resistivity layer 1	500	500.1	481.03	1000	1000	1035	1000	1001	1051.63			
Resistivity layer 2	2000	2018	2587.75	30	55.07	76.99	400	424.5	369.69			
DEPTH	50	50.21	53.2	50	48.84	44.28	50	48.81	51.88			


Πίνακας 7.1: Σύγκριση αποτελεσμάτων μεταξύ πραγματικών-IPI2WIN-Nδ για 11 μοντέλα, άγνωστα στο Νευρωνικό δίκτυο

Η σύγκριση των παραμέτρων εισόδου και λύσης παρουσιάζεται στον πίνακα 7.1 για τη λύση με τα νευρωνικά δίκτυα και με την αντιστροφή. Παρατηρείται ότι με την αντιστροφή, οι εκτιμήσεις των παραμέτρων έχουν πολύ καλή ακρίβεια. Οι τιμές που προκύπτουν από το νευρωνικό δίκτυο σε κάποια μοντέλα παρουσιάζει ικανοποιητική ακρίβεια ενώ σε κάποια αστοχεί στην αντίσταση του ημιχώρου – δεύτερου στρώματος όπως στα μοντέλα 2, 5, 8, 9 (MODEL_2 , MODEL_5, MODEL_8, MODEL_9).

Όσο αναφορά την αντίσταση του πρώτου στρώματος, το νευρωνικό δίκτυο καταφέρνει να υπολογίζει ακριβοί αποτελέσματα όπως και για το βάθος εκτός από κάποια μοντέλα στα οποία η απόκλιση είναι σημαντική.. Να σημειωθεί ότι στο μοντέλο 7 (MODEL_7) η αντιστροφή εμφανίζει απόκλιση στο πάχος 3 μέτρα η οποία είναι και η μεγαλύτερη για αυτή την μέθοδο και μάλλον η δυσκολία να οφείλεται στο γεγονός ότι οι τιμές των αντιστάσεων του στρώματος και του ημιχώρου για το αρχικό μοντέλο είναι κοντινές (500 και 400). Επομένως προκύπτει ότι το νευρωνικό δίκτυο που σχεδιάστηκε παρουσιάζει μέτριο προς καλό βαθμό ακρίβειας σε αυτό το επίπεδο.

Όσο αναφορά την σύγκριση των μετρήσεων που προκύπτουν από τις εκτιμήσεις των παραμέτρων των μοντέλων από το Νευρωνικό δίκτυο και το IPI2WIN εφαρμόζοντας Forward μοντελοποίηση, για το IPI2WIN οι μετρήσεις για κάθε μοντέλο παρουσιάζονται στο Σχήμα 7.1 με το σφάλμα για κάθε εκτίμηση να παρουσιάζεται στο Σχήμα 7.2. Παράλληλα, στο Σχήμα 7.3 παρουσιάζονται οι προβλεπόμενες μετρήσεις που αντιστοιχούν στο μοντέλο που υπολογίστηκε από το Νευρωνικό Δίκτυο, που υπολογίστηκαν με την επίλυση του ευθέως προβλήματος.

Όσο αναφορά τις προβλεπόμενες μετρήσεις από την Αντιστροφή χρησιμοποιώντας το IPI2WIN, φαίνεται ότι προκύπτουν μετρήσεις που ταυτίζονται με τις μετρήσεις που εισήχθησαν. Αντίθετα οι παραγόμενες μετρήσεις για κάθε μοντέλο του οποίου οι παράμετροι υπολογίστηκαν από το Νευρωνικό δίκτυο, φαίνεται, βάση του Σχήματος 7.3, να παρουσιάζουν μια σχεδόν συστηματική διαφορά (σαν παράλληλη μετατόπιση) αλλά με πολύ καλό προσδιορισμό της μορφής της καμπύλης (σημείο αλλαγής της κλίσης της καμπύλης). Από το Σχήμα 7.3 οι εκτιμήσεις οι οποίες παρουσιάζουν προφανή απόκλιση είναι τα MODEL_0, MODEL_3, MODEL_4, MODEL_5.



Σχήμα 7.1: Διαγράμματα αντίστασης προς $AB/2$. Με κόκκινο οι μετρήσεις από το μοντέλο της Αντιστροφής ενώ με μαύρο οι πραγματικές μετρήσεις. Με μπλε είναι το μοντέλο από την αντιστροφή

MODEL_0

Error = 0.0897%

N	p	h	d	Alt
1	19.99	50.6	50.6	-50.598
2	30.17			

MODEL_1

Error = 0.0371%

N	p	h	d	Alt
1	19.99	50.01	50.01	-50.014
2	396.2			

MODEL_2

Error = 0.192%

N	p	h	d	Alt
1	1000	48.24	48.24	-48.244
2	1932			

MODEL_3

Error = 0.0946%

N	p	h	d	Alt
1	100.1	48.42	48.42	-48.416
2	32.62			

MODEL_4

Error = 0.127%

N	p	h	d	Alt
1	99.94	49.86	49.86	-49.859
2	398.3			

MODEL_5

Error = 0.173%

N	p	h	d	Alt
1	99.99	49.1	49.1	-49.096
2	1577			

MODEL_6

Error = 0.119%

N	p	h	d	Alt
1	500.3	48.6	48.6	-48.599
2	44.3			

MODEL_7

Error = 0.048%

N	p	h	d	Alt
1	500.1	47.73	47.73	-47.734
2	407.4			

MODEL_8

Error = 0.0665%

N	p	h	d	Alt
1	500.1	50.21	50.21	-50.213
2	2018			

MODEL_9

Error = 0.101%












N	p	h	d	Alt
1	1000	48.84	48.84	-48.837
2	55.07			

MODEL_10

Error = 0.0752%

N	p	h	d	Alt
1	1001	48.41	48.41	-48.412
2	424.5			

Σχήμα 7.2: Πίνακες με το μοντέλο και το σφάλμα των μοντέλων που προέκυψαν από την αντιστροφή και παρουσιάζονται στο Σχήμα 7.1



Σχήμα 7.3: Διαγράμματα μετρήσεων για κάθε μοντέλο όπου με μπλε είναι οι πραγματικές ενώ με κόκκινο εκείνες που προέκυψαν από Forward μοντελοποίηση βάση των παραμέτρων για κάθε μοντέλο που παράχθηκαν από το Νευρωνικό δίκτυο

Εφαρμογή σε πραγματικά δεδομένα


Κλείνοντας θα παρουσιαστεί η εφαρμογή της μεθόδου της Αντιστροφής και του Νευρωνικού δικτύου σε πραγματικές μετρήσεις από την περιοχή του Γαλλικού ποταμού όπου εκτελέστηκε βυθοσκόπηση με τη διάταξη Schlumberger ενώ στην περιοχή είναι γνωστό ότι υπάρχει επιφανειακό στρώμα μεγάλου πάχους (>50m) με άμμο-χαλίκια-κροκάλες. Τα στοιχεία από την εφαρμογή αυτή πάρθηκαν από το φυλλάδιο ασκήσεων του εργαστηρίου του μαθήματος ΗΛΕΚΤΡΟΜΑΓΝΗΤΙΚΕΣ ΜΕΘΟΔΟΙ ΓΕΩΦΥΣΙΚΗΣ ΔΙΑΣΚΟΠΗΣΗΣ του τμήματος. Στον πίνακα 7.2 παρουσιάζονται οι τιμές των μετρήσεων. Όπως φαίνεται παρουσιάζεται μια ιδιαιτερότητα στα δεδομένα AB/2 καθώς όπως είχαμε προαναφέρει τα μοντέλα με τα οποία έγινε η εκπαίδευση το Νευρωνικό δίκτυο είχαν συγκεκριμένο εύρος τιμών και συγκεκριμένα [4, 100]. Στην εφαρμογή το εύρος τιμών είναι [3.2, 50]. Με την πρώτη εικόνα των μετρήσεων φαίνεται μια απότομη μείωση των τιμών ενώ στην αρχή και το τέλος μικρή διακύμανση. Όπως και στην εκπαίδευση έτσι και εδώ, η τιμή της MN διατηρείται σταθερή και ίση με 1m. Με βάση τα αποτελέσματα που παρουσιάζονται στον Πίνακα 7.3, φαίνεται ότι και με τις δύο μεθόδους έγινε μια παρόμοια εκτίμηση του μοντέλου.

(MN=1m)	
AB/2(m)	ΦΑΙΝ. ΑΝΤΙΣΤΑΣΗ(Ohm-m)
3.2	1106
4	1111
5.	1005
6.4	760
8.0	637
10	479
13	317
16	235
20	183
32	151
40	143
50	145


Πίνακας 7.2: πίνακας μετρήσεων με AB/2 και τις τιμές της ηλεκτρικής αντίστασης. Η τιμή της MN παραμένει σταθερή με τιμή 1m

	NN	IPI2WIN (Inversion)
RESISTIVITY L.1	1502.96	1211
RESISTIVITY L.2	177.08	141.85
DEPTH	7.55	4.02

Πίνακας 7.3: Οι εκτιμήσεις των παραμέτρων του μοντέλου για τον Γαλλικό ποταμό μέσω Νευρωνικού δικτύου (NN) και Αντιστροφής.



Σχήμα 7.4: Διάγραμμα μετρήσεων για την εφαρμογή στον Γαλλικό Ποταμό όπου με μπλε είναι οι πραγματικές ενώ με κόκκινο εκείνες που προέκυψαν από Forward μοντελοποίηση βάση των παραμέτρων που παράχθηκαν από το Νευρωνικό δίκτυο



Σχήμα 7.5: Διάγραμμα μετρήσεων για την εφαρμογή στον Γαλλικό Ποταμό όπου με μαύρο είναι οι πραγματικές ενώ με κόκκινο εκείνες που προέκυψαν από Forward μοντελοποίηση μέσα από το IPI2WIN

με εξαίρεση στην τιμή της αντίστασης του πρώτου στρώματος όπου παρατηρείται εμφανής διαφορά μεταξύ τους. Τέλος, έγινε η παραγωγή των αντίστοιχων μετρήσεων βάση των παραμέτρων για το μοντέλο που εκτίμησαν το Νευρωνικό Δίκτυο και η μέθοδος της Αντιστροφής δίκτυο οι οποίες παρουσιάζονται στο διάγραμμα 7.4 και 7.5 αντίστοιχα. Όπως φαίνεται η αντιστροφή έχει την καλύτερη ταύτιση αλλά και το Νευρωνικό δίκτυο δεν παρουσιάζει άσχημα αποτελέσματα καθώς η κλίση είναι παρόμοια αλλά υπάρχει μια διαφορά όσο αναφορά το σημείο αλλαγής της κλίσης και η διαφορά μεταξύ τους είναι μικρότερη από 400 ohm-m. Δεδομένου όλων των παραπάνω στοιχείων θεωρείται ότι το Νευρωνικό δίκτυο τα πήγε πολύ καλά αλλά φυσικά είναι αισθητές οι διαφορές και κατά επέκταση τα περιθώρια βελτίωσης.

Τέλος, η ερμηνεία και των δύο μοντέλων δείχνει ένα υλικό με υψηλή αντίσταση της τάξης $1.2 - 1.5 \cdot 10^3$ Ohm-m το οποίο σε βάθος 4-7 μέτρα γίνεται απότομη αλλαγή της αντίστασης στην τάξη των $1.4 - 1.7 \cdot 10^2$ Ohm-m το οποίο δείχνει την παρουσία νερού καθώς το υλικό που μελετάται είναι πορώδες και στην περιοχή ο υδροφόρος αναμένεται να βρεθεί σε χαμηλό βάθος αφού υπάρχει ποταμός.

8. Συμπεράσματα

Σκοπός της πτυχιακής είναι η επίδειξη της εφαρμογής ενός Νευρωνικού δικτύου στην ανάλυση της γεωηλεκτρικής δομής του υπεδάφους με τον σχεδιασμό από την αρχή ενός δικτύου και η επίδειξη της εφαρμογής του. Σχεδιάστηκε ένα δίκτυο πολλαπλών εισόδων και εξόδων το οποίο χρησιμοποιεί επίπεδα Συνέλιξης (Convolutional Layer) καθώς και δομές «λαιμού μπουκαλιού» (Bottleneck) οι οποίες βοηθάν στην καλύτερη εκμάθηση.

Από τις δομές και οι αρχιτεκτονικές που σχεδιάστηκαν και δοκιμάστηκαν, παρατηρήθηκε ότι από τις 3 καλύτερες που προέκυψαν, η δομή με bottleneck με 32 κόμβους και LeCun normal ως kernel initializer [δομή I] ήταν η καλύτερη παρόλο που και οι τρεις είχαν παρόμοιες τελικές τιμές σε όλους τους δείκτες. Στα μόνα διαγράμματα που φάνηκε η διαφορά στην ικανότητα εκμάθησης ήταν στα διαγράμματα με τις τιμές των δεικτών ανά επανάληψη (iteration). Σε αυτά τα διαγράμματα η δομή του 'I' είχε τις μικρότερες διακυμάνσεις και μια ξεκάθαρη τάση μείωσης των αποκλίσεων.

Στην συνέχεια έγινε η σύγκριση με την Μέθοδο της Αντιστροφής για την εφαρμογή της οποίας χρησιμοποιήθηκε το λογισμικό IPI2WIN. Στα 7 μοντέλα ενός στρώματος που δοκιμάστηκαν παρατηρείται ότι με την αντιστροφή όπως αναμενόταν, οι εκτιμήσεις των παραμέτρων έχουν πολύ καλή ακρίβεια. Οι τιμές που προκύπτουν από το νευρωνικό δίκτυο σε κάποια μοντέλα παρουσιάζουν ικανοποιητική ακρίβεια ενώ σε κάποια άλλα ο υπολογισμός κάποιων παραμέτρων δεν είναι ικανοποιητικός. Παρόμοια εικόνα προέκυψε από τη σύγκριση των αρχικών δεδομένων φαινόμενης αντίστασης με την απόκριση των μοντέλων. Ο αλγόριθμος δοκιμάστηκε και σε πραγματικά δεδομένα και παρήγαγε μοντέλο που είναι αρκετά κοντά με αυτό που προέκυψε από την αντιστροφή.

Κλείνοντας, δεδομένου του στόχου της εργασίας και όλων των παραπάνω στοιχείων θεωρείται ότι ο αλγόριθμος που αναπτύχθηκε και παρουσιάστηκε αποτελεί ένα ικανοποιητικό πρώτο βήμα, ως δοκιμή, για την ανάπτυξη αλγόριθμων ερμηνείας δεδομένων ηλεκτρικών βυθοσκοπήσεων που βασίζονται στα νευρωνικά δίκτυα. Τα αποτελέσματα που προέκυψαν στις δοκιμές εξακρίβωσης είναι σχετικά ικανοποιητικά, αλλά φυσικά είναι αισθητές οι διαφορές και οι αποκλίσεις σε σχέση με τον κλασικό αλγόριθμο ερμηνείας (αντιστροφή).

Υπάρχουν σαφώς πολλά περιθώρια βελτίωσης που μπορούν να εξερευνηθούν με περισσότερες υπολογιστικές υποδομές και χωρίς περιορισμούς καθώς με καλύτερες υποδομές



επιτυγχάνεται πιο γρήγορη εκπαίδευση και κατά επέκταση, δίνεται η δυνατότητα να δοκιμαστούν περισσότεροι συνδυασμοί παραμέτρων.



A. Kurniawan (2009). *Manual for IPI2WIN* - Moscow State University, Geological Faculty, Department of Geophysics

C. Caldero n-Macias, Mr.K. Sen, P.L. Stoffa (2000) *Artificial neural networks for parameter estimation in geophysics*

C. Darken, J. Chang, & J. Moody (1992). *Learning rate schedules for faster stochastic gradient search. Neural Networks for Signal Processing II Proceedings of the 1992 IEEE Workshop, (September), 1–11.* <http://doi.org/10.1109/NNSP.1992.253713>

D. Stut (2014). "Introduction to Neural Networks", RWTH Aachen University

D.P. Kingma, & J.L. Ba (2015). *Adam: A Method for Stochastic Optimization. International Conference on Learning Representations*

G. Klambauer, T. Unterthiner, A. Mayr, & S. Hochreiter. (2017). *Self-Normalizing Neural Networks. In Advances in Neural Information Processing Systems (NIPS)*

H. Kinsley & D. Kukiela. *Neural Networks from Scratch (NNFS)* <https://nnfs.io>


L. Bottou, F. E. Curtis, J. Nocedal (2018) *Optimization Methods for Large-Scale Machine Learning.* arXiv:1606.04838

M. Abadi, A. Agarwal, P. Barham, Eu. Brevdo, Zh. Chen, Cr. Citro, Gr. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, R. Jozefowicz, Y. Jia, L. Kaiser, M. Kudlur, J. Levenberg, D. Mané, M. Schuster, R. Monga, Sh. Moore, D. Murray, Chr. Olah, J. Shlens, B. Steiner, Il. Sutskever, K. Talwar, P. Tucker, V.t Vanhoucke, V. Vasudevan, F. Viégas, Or. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, and X. Zheng. (2015) *TensorFlow: Large-scale machine learning on heterogeneous systems, 2015. Software available from tensorflow.org.*

M. Van der Baan and C. Jutten (2000) *Neural networks in geophysical applications. Geophysics, 65 (4). pp. 1032-1047. ISSN 0016-8033* <https://doi.org/10.1190/1.1444797>

P. Suriyapor (2020). *1-D Vertical Electrical Sounding (VES) Inversion with a lateral constraint – MAHIDOL UNIVERSITY*

S. Ruder (2016). *An overview of gradient descent optimisation algorithms. arXiv preprint arXiv:1609.04747.*



T. Dozat (2015). *Incorporating Nesterov Momentum into Adam*

Y. Nesterov, (1983). *A method for unconstrained convex minimization problem with the rate of convergence $O(1/k^2)$* . Doklady ANSSSR (translated as Soviet.Math.Docl.), vol. 269, pp. 543– 547.

Y.L. Ekinici, A. Demirci (2008). *A Damped Least-Squares Inversion Program for the Interpretation of Schlumberger Sounding Curves - Çanakkale Onsekiz Mart Üniversitesi-Department of Geophysical Engineering*

A. ΠΑΠΑΔΟΠΟΥΛΟΣ (2016). *ΣΥΝΕΛΙΚΤΙΚΑ ΝΕΥΡΩΝΙΚΑ ΔΙΚΤΥΑ ΣΤΗΝ ΥΠΟΛΟΓΙΣΤΙΚΗ ΟΡΑΣΗ. ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΑΤΡΩΝ -ΤΜΗΜΑ ΦΥΣΙΚΗΣ -Α.Π.Μ.Σ.*

A. ΤΣΕΛΕΝΤΗΣ, Π.ΠΑΡΑΣΚΕΥΟΠΟΥΛΟΣ (2013). *‘ΕΦΑΡΜΟΣΜΕΝΗ ΓΕΩΦΥΣΙΚΗ’, ΕΚΔΟΣΕΙΣ LIBERAL BOOKS*

B. K. ΠΑΠΑΖΑΧΟΥ (1996). *‘ΕΙΣΑΓΩΓΗ ΣΤΗΝ ΕΦΑΡΜΟΣΜΕΝΗ ΓΕΩΦΥΣΙΚΗ’ ΕΚΔΟΣΕΙΣ ΖΗΤΗ*

Γ. ΒΑΡΓΕΜΕΖΗΣ, Π. ΤΣΟΥΡΛΟΣ (2020-2021). *Φυλλάδιο Ασκήσεων εργαστηρίου του μαθήματος ΗΛΕΚΤΡΟΜΑΓΝΗΤΙΚΕΣ ΜΕΘΟΔΟΙ ΓΕΩΦΥΣΙΚΗΣ ΔΙΑΣΚΟΠΗΣΗΣ - ΑΡΙΣΤΟΤΕΛΕΙΟ ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΟΝΙΚΗΣ ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ ΤΜΗΜΑ ΓΕΩΛΟΓΙΑΣ ΤΟΜΕΑΣ ΓΕΩΦΥΣΙΚΗΣ*