

ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

Δ.Π.Μ.Σ ΣΧΕΔΙΑΣΜΟΣ ΚΑΙ ΚΑΤΑΣΚΕΥΗ ΥΠΟΓΕΙΩΝ ΕΡΓΩΝ



Μεταπτυχιακή Διπλωματική Εργασία

**Πρόβλεψη του Ρυθμού Προχώρησης Μηχανών Ολομέτωπης
Κοπής (TBM) με τη χρήση Τεχνητών Νευρωνικών Δικτύων**

Σιούτας Κωνσταντίνος

Επιβλέπων: Αν. Καθηγητής Δρ. Ανδρέας Μπενάρδος

Αθήνα 2021

Ευχαριστίες

Νιώθω την ανάγκη να ευχαριστήσω τον επιβλέποντα καθηγητή Α. Μπενάρδο για την επιστημονική καθοδήγησή του καθ' όλη τη διάρκεια εκπόνησης της συγκεκριμένης διπλωματικής εργασίας και τον χρόνο που αφιέρωσε για κάθε πτυχή της. Επίσης ευχαριστώ τον MSc. Data Scientist Π. Κολόζη για τις πολύτιμες συμβουλές και διευκρινίσεις του σε θέματα που αφορούν την Μηχανική Μάθηση.

Πίνακας Περιεχομένων

Περίληψη	5
Extended Abstract	7
Introduction.....	7
Model description using Feed Forward Neural Networks	7
Results of the Feed Forward Neural Networks.....	9
The approach with Convolutional and Recurrent Neural Networks.....	11
Conclusions.....	13
Κεφάλαιο 1. Εισαγωγή	15
Κεφάλαιο 2. Μηχανές Ολομέτωπης Κοπής (TBM)	21
2.1. Είδη των TBM.....	24
2.1.1. TBM ανοιχτού τύπου (Open TBM).....	24
2.1.2. TBM μονής ασπίδας (Single Shield TBM-SS TBM).....	25
2.1.3. TBM διπλής Ασπίδας (Double Shield TBM-DS TBM)	26
2.1.4. Earth Pressure Balance TBM (EPB TBM).	27
2.1.5. Slurry Pressure Balance TBM (SPB TBM).	28
2.2 Ποσοστό αξιοποίησης, Ρυθμός προχώρησης και Ρυθμός Διείσδυσης.....	29
2.3. Μοντέλα πρόβλεψης.....	31
2.3.1 Μοντέλο πρόβλεψης απόδοσης TBM του Colorado School of Mines (CSM).....	31
2.3.2 Μοντέλο πρόβλεψης απόδοσης TBM του Norwegian University of Science and Technology (NTNU)	33
2.3.3 Μοντέλο πρόβλεψης απόδοσης TBM του Barton (2017) (Qtbm)	36
Κεφάλαιο 3. Τεχνητά Νευρωνικά δίκτυα	38
3.1 Ιστορική αναδρομή.....	38
3.2. Αρχές λειτουργίας ΤΝΔ.....	42
3.3 Τύποι Τεχνητών Νευρωνικών Δικτύων.....	45
3.3.1. Πρόσθιας τροφοδότησης (FFN-Feed Forward Networks)	45

3.3.2. Επαναλαμβανόμενα νευρωνικά δίκτυα (RNN- Recurrent Neural Networks):	46
3.3.3. Μακροπρόθεσμης / βραχυπρόθεσμης μνήμης (LSTM- Long/Short Term Memory)	48
3.3.4. Συνελκτικά νευρωνικά δίκτυα (CNN-Convolutional Neural Networks):	49
3.4. Γλώσσα Python και ΤΝΔ.....	50
3.5. Είδη Μάθησης.....	52
3.6. Χωρισμός βάσης δεδομένων.....	53
3.7. Εκπαίδευση ΤΝΔ.....	55
3.7.1. Αλγόριθμος της οπισθόδρομης διάδοσης των σφαλμάτων.....	57
3.7.2 Εκπαίδευση ΤΝΔ έλεγχος γενίκευσης.....	60
Κεφάλαιο 4. Λύσεις με την χρήση Τεχνητής Νοημοσύνης (Artificial Intelligence - A.I.)	63
4.1. Εφαρμογές πρόβλεψης ρυθμού προχώρησης και ρυθμού διείσδυσης για TBM.....	65
4.2. TBM αυτόνομης λειτουργίας.....	69
Κεφάλαιο 5. ΤΝΔ για την πρόβλεψη ρυθμού διείσδυσης TBM σηράγγων στις Άλπεις	71
5.1 Οι Άλπεις	71
5.2. Παρουσίαση των σηράγγων και δεδομένων του προβλήματος.....	71
5.2 Τρόποι προσέγγισης	74
5.3. Ανάπτυξη απλών ΤΝΔ.....	76
5.3.1 Δεδομένα, Αρχιτεκτονική, και Αλγόριθμοι	76
5.3.2. Παρουσίαση αποτελεσμάτων για την χρήση απλών ΤΝΔ.....	80
Κεφάλαιο 6. ΤΝΔ βαθιάς μάθησης (Deep learning NN) για την πρόβλεψη χρονοσειρών ..	85
6.1 Χρονοσειρές.....	85
6.2 Επιλογή σήραγγας και στοιχείων	86
6.3. Ο συνδυασμός CNN και RNN για την προσέγγιση ενός προβλήματος χρονοσειράς.	87
Κεφάλαιο 7. Αξιολόγηση των αποτελεσμάτων σε σχέση με άλλες τεχνικές πρόβλεψης.....	94
Κεφάλαιο 8. Συμπεράσματα	96
9. Βιβλιογραφία	100

Περίληψη

Η μοντελοποίηση της πρόβλεψης ρυθμού προχώρησης της (PR) μηχανών ολομέτωπης κοπής σήραγγας είναι μια σημαντική πτυχή της εσκαφής των σιηράγγων. Η δημιουργία μοντέλων που θα προσομοιάζουν αξιόπιστα τους μηχανισμούς που διέπουν τη συμπεριφορά της βραχόμαζας ή των πετρωμάτων και των αλληλεπιδράσεων που υπάρχουν μεταξύ αυτών και των τεχνικών κατασκευών είναι πάντοτε μια από τις πιο σημαντικές επιδιώξεις των ερευνητών.

Η εισαγωγή νέων μεθόδων τεχνητής νοημοσύνης, όπως αυτή των τεχνητών νευρωνικών δικτύων (ΤΝΔ), είναι σε θέση να δώσει πολλές νέες ευκαιρίες στην ανάλυση των διαφόρων εφαρμογών γεωτεχνολογίας και μηχανικής πετρωμάτων. Στη παρούσα Διπλωματική εργασία αναλύεται ο τρόπος λειτουργίας των ΤΝΔ και επιπλέον πραγματοποιούνται αναλύσεις για τον προσδιορισμό του ρυθμού προχώρησης (διείσδυσης) σιηράγγων με μηχανήματα ολομέτωπης κοπής μέσω αντίστοιχων μοντέλων, έχοντας ως δεδομένα εισαγωγής γεωτεχνικά, λιθολογικά δεδομένα και παραμέτρους λειτουργίας των μηχανημάτων διάνοιξης.

Τα μοντέλα που αναπτύχθηκαν για τη συγκεκριμένη εργασία αφορούν την κατασκευή 3 υδραυλικών σιηράγγων (Maen, Pieve και Varzo), στη Β. Ιταλία στην περιοχή των Άλπεων και υλοποιούνται μέσω της χρήσης τριών τεχνητών νευρικών δικτύων πρόσθιας τροφοδότησης (ANN-FF) που προβλέπουν τον ρυθμό προχώρησης (PR) ως συνάρτηση βασικών δεδομένων του γεωλογικού περιβάλλοντος, των γεωτεχνικών συνθηκών και των παραμέτρων του μηχανήματος TBM. Επίσης για μία από τις τρεις σιηραγγες υπήρχαν τα απαραίτητα δεδομένα ώστε να είναι δυνατή η χρήση δύο μοντέλων Βαθείας Μάθησης (συνδυασμός RNN-CNN) για την πρόβλεψη ρυθμού προχώρησης (PR). Η σιηραγγα αντιμετωπίζεται ως ένα πρόβλημα πρόβλεψης με βάση χρονοσειράς, λαμβάνοντας υπόψη δηλαδή τις προηγούμενες τιμές προχώρησης ώστε να προβλεφθούν οι μελλοντικές, είτε χωρίς είτε και με την χρήση των επιπρόσθετων δεδομένων εισαγωγής (γεωλογία, ώση, κλπ.).

Τα αποτελέσματα που προέκυψαν δείχνουν ότι τα ANN-FF αλλά και τα RNN-CNN που αναπτύχθηκαν στο πλαίσιο της εργασίας μπορούν αποτελεσματικά να γενικεύσουν, δηλαδή να κατανοήσουν και εν συνεχεία να μπορέσουν να μοντελοποιήσουν και να προβλέψουν, τη συμπεριφορά του TBM στο όσον αφορά στο ρυθμό προχώρησης που μπορεί να επιτευχθεί στο αντίστοιχο γεωτεχνικό περιβάλλον τους. Μπορούν με αυτόν τον τρόπο να δώσουν μια αξιόπιστη,

αποτελεσματική αλλά και κυριότερα συνεπή απόδοση σε όλες τις συνθήκες και παραμέτρους που έχουν εξεταστεί, φτάνοντας σε πολύ ικανοποιητικά επίπεδα ακρίβειας λαμβάνοντας υπόψιν την αβεβαιότητα του γεωλογικού μέσου. Έτσι, πλέον η χρήση τεχνικών Μηχανικής Μάθησης μπορεί να αξιοποιηθεί ώστε να παράσχει λύσεις αλλά και ανοίξει νέες δυνατότητες για την περαιτέρω αξιοποίησή της σε πολύπλοκα θέματα που σχετίζονται με το σχεδιασμό και κατασκευή υπογείων έργων αλλά και άλλων γεωτεχνικών κατασκευών.

Extended Abstract

Introduction

Modeling the penetration rate (PR) of a Tunnel Boring Machine (TBM) is an important aspect of any tunnel excavation. Creating models that will reliably simulate the mechanisms that govern the rock mass behavior and the interactions that exist between them and engineered structures is always one of the most important goals of researchers.

The introduction of new methods of artificial intelligence, such as that of artificial neural networks (ANN) are capable of providing many new opportunities in the analysis of various applications of geotechnology and rock engineering. In the present Diploma Thesis, the ANN models are analyzed and in addition, experiments are performed to determine penetration rate (PR) of TBMs through corresponding models, having as input geotechnical data, lithological data and operating parameters of TBMs

Model description using Feed Forward Neural Networks

The models developed for this Theses are for the construction of 3 hydraulic tunnels (Maen, Pieve and Varzo), in Northern Italy in the Alpines region and are implemented through the use of three feed forward artificial neural networks (FFN) that predict penetration rate (PR). Also for one of the three tunnels (Pieve), two Deep Learning models (combination of RNN-CNN) were used to predict penetration rate (PR) treating it as a time series problem.

It was chosen to build a separate NN for each tunnel, as their geological and geotechnical environment, but also the type and operation of each TBM differ. Consequently, the creation of separate models offers the possibility of performing more accurate predictions that can be used to similar projects with the same lithological formations. *Table 1* shows the total amount of data used in this project and their separation in train and test data sets for each tunnel. The NNs are created using the Python programming language. Using this language is was easier to program the neural network, adjust the architecture and the activation functions, select the training algorithm and tune the learning rate.

The accuracy of the generalization of the NNs is evaluated based on the relative error between the predicted and in the actual value of the penetration rate as shown below:

$$\Delta = \frac{PR_{actual} - PR_{predicted}}{PR_{actual}} (\%)$$

where:

PR_{actual} : actual penetration rate,

$PR_{predicted}$: penetration rate predicted from the NNs.

Table 1. Data used for the construction of the FF-NNs for the 3 tunnels

	Maen	Pieve	Varzo
Test Data	264	240	81
Train Data	66	61	21
Whole Data	330	301	102

Table 2. Results regarding the architecture, MSE, Errors and accuracy for all 3 tunnels

	Maen	Pieve	Varzo
Best NN architecture	3×40×6×1	3×10×40×4×1	3×10×30×10×2×1
Train (MSE)	0,208	0,181	0,313
Test (MSE)	0.276	0.232	0.333
Avg Train error (%)	8.146%	2,580%	4.683%
Avg Test error (%)	6,813%	20,363%	13,848%
Avg Predicting Accuracy (%)	82,70%	79.30%	72,20%

The interruption criterion of each training was twofold, either the completion of a certain number of epochs (2000), or achieving the minimum mean squared error in training (MSE) in 50 consecutive seasons. In this way, the NN also had freedom in terms of the convergence of the training algorithm, since the real convergence was achieved much earlier than the predicted number of seasons.

Results of the Feed Forward Neural Networks

It is observed that the FFNs values show a fairly consistent behavior across almost the entire range of the test subset data used. They follow the trend of the true values in a satisfactory way they show an average forecast accuracy of more than 70% for each of the projects examined (MAEN Tunnel: 82.7%, PIEVE Tunnel: 79.3%, VARZO Tunnel: 72.2%). The operation of the trained NNs is successful as observed in **Table 2** with their ability to lead to reliable predictions for the progress of the boring is proven.




Figure 1. Generalization behavior of the NN for Maen tunnel in the test dataset (**Blue: Predicted values, Orange: True values**)




Figure 2. Generalization behavior of the NN for Pieve tunnel in the test dataset (**Blue: Predicted values, Orange: True values**)




Figure 3. Generalization behavior of the NN for Varzo tunnel in the test dataset (**Blue: Predicted values, Orange: True values**)

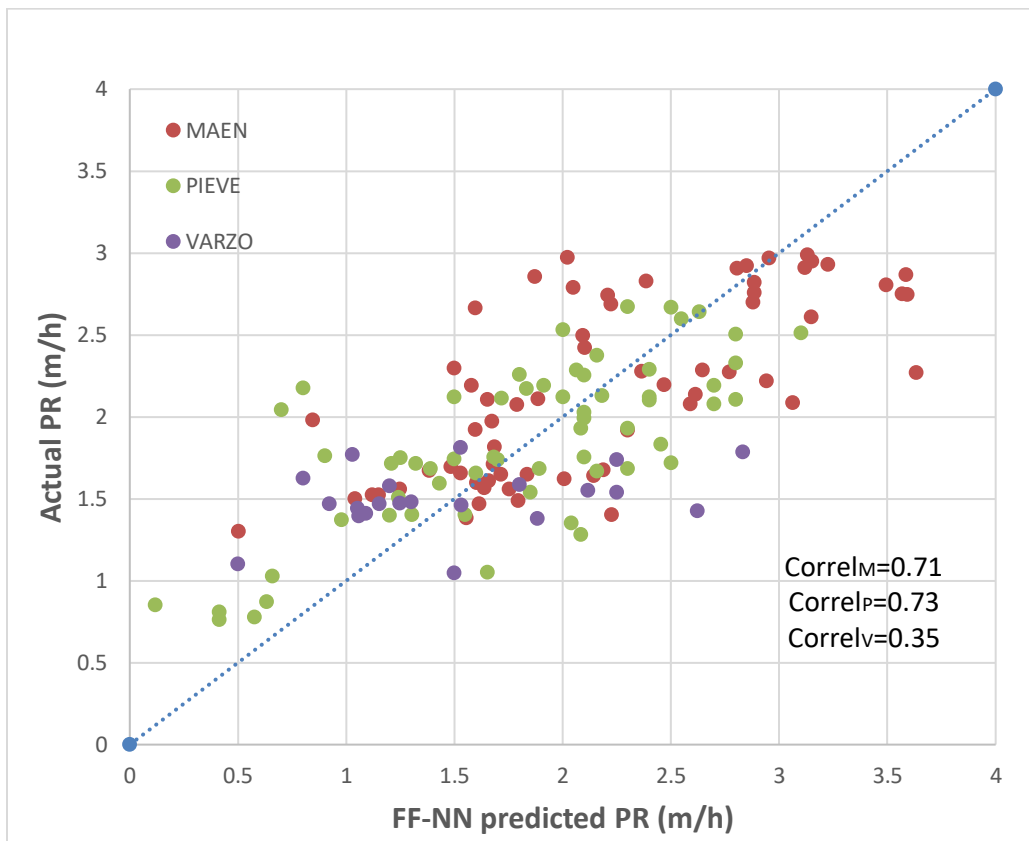


Figure 4. Cross-plot of the measured PR values against the FF-NN predictions for the 3 cases under investigation.

The approach with Convolutional and Recurrent Neural Networks

One of the tunnels that were tested (Pieve) could be examined with the time series method as we knew the position (km) in which the data for the penetration rate were collected.

In a time series problem, such as ours, sampling time may not be constant and that leads to the need of more complicated processing of the time series in order to perform the analysis. The simplest approach in this case is to define as reference time, not the actual time but the time we need to bore one kilometer. From the dataset it was observed that 40 samples consist of one kilometer, so 1km was used as a fixed time step.

With this logic in the case of RNN-CNN combination two NNs were developed consisted by a CNN layer followed by an RNN-LSTM level with 20 neurons ending in a simple layer with one output. The difference between the models was the window size. The window size is the parameter of how many previous values our model takes into consideration to predict the next one. The window size was used to determine how many of the previous PR values should our model consider before it calculates the PR+1. The results of the models were satisfying having approximately 78% forecast accuracy.

Table 3. *MSE, MAE and average accuracy of predicting values for the two CNN-RNN models*

	Pieve	
Window Size	1	5
MSE	0.242	0.260
MAE	0.370	0.390
Average Accuracy (%)	78.77%	77.77%




Figure 5. Generalization behaviour of the CNN-RNN model for Pieve tunnel in the test dataset (window size 5, PR predicted and PR actual Vs Chainage) (Blue: True values, Orange: Predicted values)




Figure 6. Generalization behaviour of the CNN-RNN model for Pieve tunnel in the test dataset (window size 1, PR predicted and PR actual Vs Chainage) (Blue: True values, Orange: Predicted values)

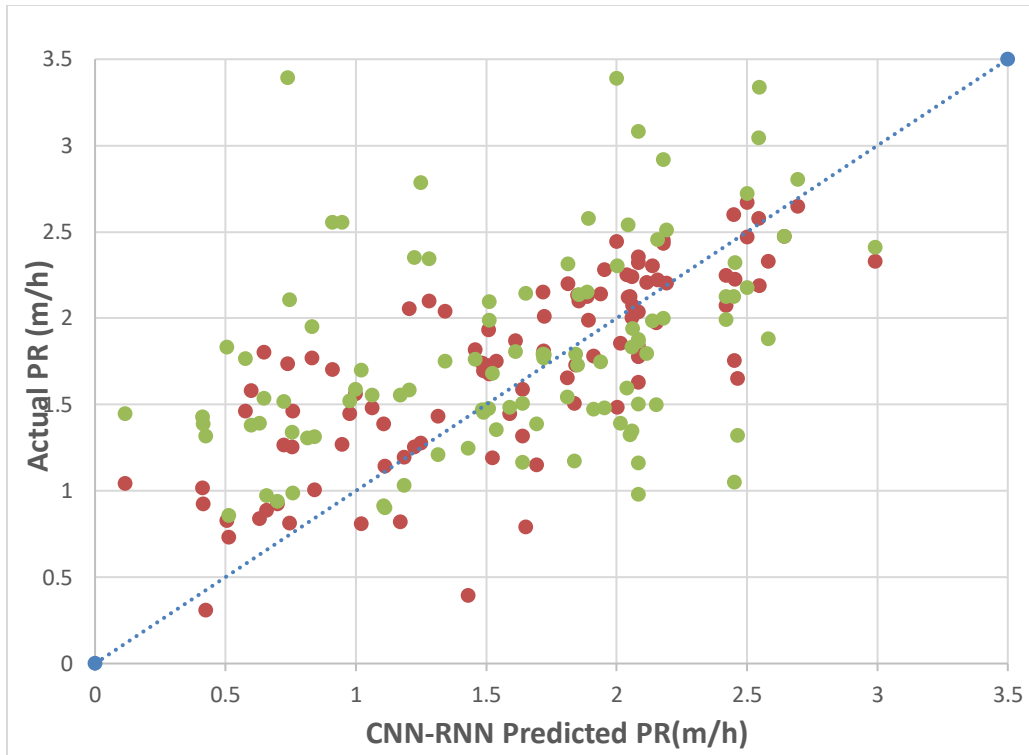


Figure 7. Cross-plot of the measured PR values against the predicted values of the combination CNN-RNN for the two model predictions.

Conclusions

Taking into account the uncertainty of the Underground Works the results of the FFN and RNN-CNN models show that they can effectively generalize the behavior of TBM in the respective geotechnical environment, having a reliable, efficient and consistent performance, reaching very good levels of accuracy.

The greatest advantage of the NNs is their ability to produce predictions which will correspond better to the truth in very specific situations. In contradiction for example of the Qtbm model they are not a generalized tool that can be used in any case but needs to be trained in every situation or site in order to produce result of high accuracy.

The use of advanced artificial intelligence methods, such as artificial neural networks in geotechnology and rock engineering problems can provide reliable solutions and contribute to the effort of the better understanding them. This was demonstrated in this article by constructing NNs which were able to give reliable results for predicting the rate of tunnel excavation using TBMs. More specifically, the advantages of the trained model are:

- It is a flexible system because it can be updated with new data easily and increase its degree of accuracy.
- It is very easy to use, even by inexperienced users. Its minimum requirements make it possible to use it in the construction environment and do not limit it to laboratory conditions only.
- NNs can produce forecasts quickly, reliably and with great accuracy.

Observing the results of the combined RNN and CNN models, we can hope that with the appropriate volume of data and data processing combined with the optimal architecture, the prediction of the penetration rate of the TBM can be turned into a multiparametric time series problem and its approach with neural network models, can prove to be very fruitful in the scientific field of Underground Works.

In addition, even during the purely construction phase, there may be an initial data flow through which neural networks will be able to be calibrated to the specific conditions of the geology and the project, providing short-term horizon estimates that will be able to meet immediate needs.

Κεφάλαιο 1. Εισαγωγή

Οι μηχανές ολομέτωπης κοπής σήραγγας (Tunnelling Boring Machines - TBM) χρησιμοποιούνται για την διάνοιξη σιηράγγων σε διάφορα είδη πετρωμάτων και εδαφών, ιδιαίτερα σε αστικές περιοχές ή για έργα που έχουν ειδικές απαιτήσεις. Υπάρχουν διάφοροι τύποι TBM που μπορούν να αντιμετωπίσουν σχεδόν όλες τις διαφορετικές γεωλογικές συνθήκες, οι οποίες μπορούν να κυμαίνονται από μαλακούς εδαφικούς σχηματισμούς έως συνεκτικά πετρώματα, ενώ την ίδια στιγμή υπάρχει η δυνατότητα διάνοιξης σιηράγγων διαμέτρου από περίπου 0,7 m έως και 20 m (*Εικόνα 1.1*).



Εικόνα 1.1. Άποψη της κατασκευασμένης σήραγγας διαμέτρου 17.5m του έργου Alaskan Way Viaduct (Seattle).

Έτσι, αυτός ο τύπος αυτοματοποιημένης εκσκαφής έχει γίνει πολύ δημοφιλής στις υπόγειες κατασκευές λόγω των πολλών πλεονεκτημάτων που προσφέρουν σε σχέση με τις συμβατικές μεθόδους εξόρυξης και την χρήση εκρηκτικών (Farrokhi, 2012). Το γεγονός αυτό


αντικατοπτρίζεται στην μεγάλη αύξηση που αναμένεται να υπάρξει στην αγορά τέτοιων μηχανημάτων σε διεθνές επίπεδο. Το 2019 το μέγεθος της παγκόσμιας αγοράς μηχανών ολομέτωπης κοπής εκτιμήθηκε στα \$US 5.476,0 εκατομμύρια σε ετήσια βάση ενώ το 2017 αναμένεται να φτάσει τα \$US 7.552,1 εκατομμύρια (Tunnel Boring Machine Market Report, 2020).

Όσον αφορά στα πλεονεκτήματα και τα μειονεκτήματα της μεθόδου κατασκευής σηράγγων με τη χρήση μηχανημάτων TBM σε σύγκριση με τη λειτουργία συμβατικής εκσκαφής και χρήσης εκρηκτικών υλών, αυτά δίνονται στον **Πίνακα 1.1**. Βασικό πλεονέκτημα της χρήση μηχανημάτων TBM είναι η δυνατότητα επίτευξης μεγάλων ρυθμών προχώρησης αλλά και η ουσιαστικά μηδενική διατάραξη της βραχώμαζας, ενώ υπάρχουν και βασικά μειονεκτήματα όπως για παράδειγμα η δυνατότητα διάνοιξης έργων μόνο κυκλικής διατομής, αλλά και η δυσκολία των μηχανημάτων να αντιπαραέλθουν συχνά μεταβαλλόμενες συνθήκες υπεδάφους.

Πίνακας 1.1. Πλεονεκτήματα και μειονεκτήματα μεθόδου εκσκαφής TBM σε σύγκριση με τη λειτουργία συμβατικής εκσκαφής και χρήσης εκρηκτικών υλών (Maidl et al., 2008).

Advantage	Disadvantage
Higher advance rate	More geological information needed
Exact excavation profile	High investment
Automated and continual work process	Longer lead time for machine designing and manufacturing
Low personnel expenditure	Specific profile (circular)
Better working conditions and safety	Limits on curve driving
Mechanization and automation of the drive	Detailed planning required
	Limits on adaptation to highly variable rock
	Limits on adaptation to high water inflow
	Limits on transportation system

Η απόφαση χρήσης ή μη ενός TBM είναι μια απόφαση που χρειάζεται να αξιολογηθεί βάσει μιας σειράς κριτηρίων. Γενικά όμως λόγω του αυξημένου κόστους κτήσης των μηχανημάτων, μικρές σε μήκος σήραγγες ευνοούν τη διάνοιξη έργων με συμβατικά μέσα. Αντίθετα έργα μεγάλου σχετικά μήκους ευνοούν τη χρήση TBM. Αυτό δίνεται χαρακτηριστικά στην **Εικόνα 1.2**, η οποία έχει ως βασικό κριτήριο επιλογής το κόστος του έργου σε σχέση με το μήκος κατασκευής.



Εικόνα 1.2. Διάγραμμα επιλογής μεθόδου εκσκαφής σύμφωνα με το κόστος και το μέγεθος του έργου.

Η διαδικασία όρυξης της σήραγγας με TBM περιλαμβάνει την συνεχή εκσκαφή στο μέτωπο, την αφαίρεση του πετρώματος και την εγκατάσταση υποστήριξης. Ο ρυθμός διείσδυσης (Rate of Penetration - ROP) και κυριότερα ο ρυθμός προχώρησης σήραγγας (Advance Rate - AR) είναι ένας κρίσιμος παράγοντας για την επιτυχή επιλογή και εφαρμογή των TBM, αλλά η ακριβής του εκτίμηση και πρόβλεψη παραμένει μια σημαντική πρόκληση για τους περισσότερους μηχανικούς και εργολάβους. Ο ρυθμός διείσδυσης (Penetration Rate - PR), ο οποίος είναι ο ίδιος με το ROP, (Farrokh, 2012), εκφράζεται συνήθως σε όρους mm / hr και είναι συνάρτηση των προδιαγραφών του μηχανήματος, των γεωλογικών παραμέτρων και των λειτουργικών παραμέτρων. Το AR είναι ο μέσος όρος του αθροιστικού υλικού που εξορύσσεται, συνήθως, ανά ημέρα, υπολογιζόμενος από το ROP και τη χρήση του μηχανήματος (U), το οποίο ορίζεται ως το τμήμα του χρόνου που εκσκάπτει το μηχάνημα στο συνολικό χρόνο. Έχουν γίνει πολλές μελέτες σχετικά με την ακριβή πρόβλεψη του ROP, με κάποια πρόοδο στη στατιστική για διάφορες γεωλογικές παραμέτρους τα τελευταία χρόνια (Rostami, 1993 και 1997, Yagiz, 2002, Ramezanzadeh 2005 και Gong 2005), αλλά το ποσοστό που εκτελούνται έρευνες στην διάρκεια χρήσης TBM, πρέπει να αυξηθεί.

Έχουν διεξαχθεί διάφορες μελέτες για τη διερεύνηση της σχέσης μεταξύ της δύναμης κοπής και των ιδιοτήτων του πετρώματος (Ozdemir, 1977, Rostami and Ozdemir, 1993, Rostami, 1997). Οι πιο δημοφιλείς ιδιότητες του άρρηκτου βράχου είναι η μονοαξονική αντοχή σε θλίψη (UCS) και η έμμεση αντοχή εφελκυσμού της δοκιμής Brazilian (BTS) για τη μέτρηση των δυνάμεων κοπής και της εκτίμησης απόδοσης του TBM. Η δυσθραυστότητα των πετρωμάτων είναι επίσης ένας σημαντικός παράγοντας που θα μπορούσε να ληφθεί μέσω διαφόρων δοκιμών ως δείκτης, αλλά δεν έχει αποκτήσει καθολική αναγνώριση. Από την άλλη, η αντοχή στη θραύση του πετρώματος έχει χρησιμοποιηθεί για την εκτίμηση των δυνάμεων κοπής από τον Sanio (1985). Ο Tarkoy (1975) χρησιμοποίησε τη ολική σκληρότητα του πετρώματος για μελέτες επιδόσεων TBM στο πεδίο, αλλά δεν έκανε εκτίμηση της δύναμης κοπής. Επίσης έχουν διεξαχθεί δοκιμές διάτρησης για να εκτιμηθεί η δυσθραυστότητα του πετρώματος για τον υπολογισμό της απόδοσης TBM (Yagiz and Ozdemir, 2001; Yagiz, 2002, 2008). Έχουν προσφερθεί αρκετοί τύποι για την εκτίμηση των δυνάμεων κοπής από τις ιδιότητες των πετρωμάτων αλλά και τη γεωμετρία κοπής (Ozdemir, 1977; Lindquist, 1984; Sanio, 1985; Rostami, 1997).

Το Colorado School of Mines (CSM) έχει αναπτύξει ένα ημι-θεωρητικό μοντέλο, που βασίζεται στις δυνάμεις κοπής σε μεμονωμένα κοπτικά (Ozdemir, 1977). Οι Rostami και Ozdemir (1993) βελτίωσαν αυτό το μοντέλο θεωρητικά εκτιμώντας τη δύναμη κοπής ως συνάρτηση της μονοαξονικής αντοχής σε θλίψη και της έμμεσης αντοχής σε εφελκυσμό από τη δοκιμή Brazilian (BTS). Επιπλέον, ο Yagiz (2002) παρουσίασε το Modified CSM, δίνοντας ακριβέστερα αποτελέσματα εκτίμησης σε κατακερματισμένες βραχώμαζες, εισάγοντας την δυσθραυστότητα και τις ιδιότητες της βραχώμαζας (δηλαδή, απόσταση μεταξύ ασυνεχειών, γωνία μεταξύ των ασυνεχειών και του άξονα της σήραγγας) στο υπάρχον μοντέλο CSM. Τα υπάρχοντα μοντέλα που χρησιμοποιούνται για την πρόγνωση επίδοσης του TBM, συμπεριλαμβανομένων των Tarkoy (1975), Nelson και O'Rourke (1983), και του νορβηγικού μοντέλου (NTNU), βασίζονται στην παρατήρηση της απόδοσης TBM επί του έργου σε διάφορες σήραγγας (Blindheim, 1979). Το πιο συχνά χρησιμοποιούμενο μοντέλο είναι το νορβηγικό μοντέλο πρόγνωσης TBM σκληρού βράχου που αναπτύχθηκε από το Νορβηγικό Πανεπιστήμιο Επιστήμης και Τεχνολογίας (NTNU) στο Trondheim (Lislerud, 1988; Bruland, 1999).

Για τη βελτίωση της προγνωστικής ικανότητας των υφιστάμενων μοντέλων, δημιουργήθηκαν βάσεις δεδομένων όπου έγιναν δοκιμές και μοντελοποιήσεις για τουλάχιστον 17 πρόσφατα

υπόγεια έργα με την χρήση TBM. Αυτά τα έργα παρείχαν λεπτομερείς πληροφορίες για την απόδοση TBM σε κάθε γεωλογική ζώνη. Η διάμετρος των TBM για αυτά τα έργα κυμαινόταν από 2,6 m έως 11,8 m. Όπως είναι αναμενόμενο, οι λειτουργικές παράμετροι των TBM και τα γεωλογικά δεδομένα διέφεραν σημαντικά από έργο σε έργο. Ο Πίνακας 1.2. παρουσιάζει συνοπτικές πληροφορίες για αυτά τα έργα, συμπεριλαμβανομένης κυρίως της περιγραφής του TBM: τύπος, διάμετρος και γεωλογία τοποθεσίας. Η δημιουργία βάσεων δεδομένων για την χρήση τους σε μοντέλα πρόβλεψης είναι μια διαδικασία η οποία λειτουργεί πάνω από 20 χρόνια. Με την εξέλιξη της τεχνολογίας, οι βάσεις δεδομένων εμπλουτίζονται με αποτέλεσμα να δίνουν καλύτερα εφόδια στα μελλοντικά μοντέλα πρόβλεψης.

Πίνακας 1.2. Πληροφορίες για τα έργα , στα οποία δημιουργήθηκαν βάσεις δεδομένων για την δημιουργία αποτελεσματικότερων μοντέλων και την ακριβέστερη πρόγνωση (Farrokh, 2012).

No.	Project Name	Tunnel Length (km)*	TBM Type	TBM Diameter (m)	Geology	Reference
1	Ghomroud (Iran)	22.8	DS	4.5	Metamorphic rocks	**
2	Karaj (Iran)	15.7	DS	4.65	Pyroclastic rocks	Hassanpour, 2009
3	Zagros (Iran)	5.3	DS	6.73	Limestone, Marl, Shale	Hassanpour, 2009
4	Golab (Iran)	0.7	DS	4.5	Diorite, Schist	**
5	Maen (Italy)	1.7	Open	4.2	Meta gabbro, Meta basite, Schist	Sapigni et al., 2002
6	Pieve (Italy)	6.3	DS	4.05	Schist, Granite, Diorite	Sapigni et al., 2002
7	Varzo (Italy)	6.2	DS	4.05	Gneiss	Sapigni et al., 2002
8	Queens (USA)	0.2	Open	7.06	Granite	Ramezanzadeh,
9	Milyang (S. Korea)	0.6	Open	2.6	Granite, Andesite	Kim, 2010
10	Manapouri (Newzealand)	1.7	Open	10.05	Gneiss	Kim, 2010
11	S. Manhattan (USA)	5.6	Open	3.84	Gneiss, Schist	**
12	KCRC D 320-First Tube (Hong Kong)	1.3	Mixed Shield	8.75	Granite	Ramezanzadeh, 2005
13	KCRC D 320-Second Tube (Hong Kong)	1.4	Mixed Shield	8.75	Granite	Ramezanzadeh, 2005
14	Frasnadello-Pilot (Italy)	1.6	Open	3.9	Dolomite, Limestone and Argillite	Barla and Pelizza, 2000
15	Antea-Pilot (Italy)	0.7	Open	3.9	Dolomite	Barla and Pelizza, 2000
16	Frasnadello-Main (Italy)	1.6	SS	11.8	Dolomite, Limestone and Argillite	Barla and Pelizza, 2000
17	Antea-Main (Italy)	0.7	SS	11.8	Dolomite	Barla and Pelizza, 2000
Total		73.6				

DS: Double Shield, SS: Single Shield

* with available data

** data from authors (Farrokh et al., 2006, 2011; Farrokh and Rostami, 2007, 2008, 2009)

Γίνεται λοιπόν αντιληπτό ότι η συνεχής προσπάθεια μοντελοποίησης και πρόβλεψης της απόδοσης ενός TBM είναι πλέον απαραίτητη στο χώρο των υπογείων έργων. Τα τελευταία χρόνια ο συνδυασμός δημιουργίας βάσεων δεδομένων στα Υπόγεια έργα και η άνοδος χρήσης στατιστικών μεθόδων ή πιο σύνθετων μεθόδων όπως τα Τεχνητά Νευρωνικά Δικτύα (ΤΝΔ), έχουν ανοίξει έναν ελπιδοφόρο δρόμο προς την ακριβέστερη πρόγνωση της απόδοσης ενός TBM.

Η συγκεκριμένη Διπλωματική εργασία με γνώμονα την σημαντικότητα της χρήσης των TBM και την βοήθεια των δυνατών εργαλείων τεχνητής νοημοσύνης μελετά τον ρυθμό διείδυσης (PR) τριών σηράγγων (Maen, Pieve, Varzo) που χτίστηκαν στις Ιταλικές Άλπεις και στην συνέχεια αξιολογεί τα αποτελέσματα συγκριτικά με άλλες μεθόδους. Η χρήση μίας γλώσσας προγραμματισμού με σκοπό την δημιουργία μοντέλων δίνει την ευκαιρία σε πολλούς επιστήμονες να την χρησιμοποιήσουν ως εργαλείο για την επίλυση προβλημάτων, ιδιαίτερος σε προβλήματα που σχετίζονται με την εκτίμηση των μηχανικών παραμέτρων των πετρωμάτων.

Η συγκεκριμένη Μεταπτυχιακή Διπλωματική Εργασία αφορά την αξιολόγηση του ρυθμού προχώρησης μηχανών ολομέτωπης κοπής. Συγκεκριμένα την μοντελοποίηση και πρόβλεψή του χρησιμοποιώντας στοιχεία που προέρχονται από την κατασκευή τριών (3) σηράγγων μεγάλου μήκους (Maen, Pieve, Varzo) οι οποίες κατασκευάστηκαν στις Άλπεις. Αυτό επιχειρείται με τη χρήση μεθόδων τεχνητής νοημοσύνης και ειδικότερα μέσω της ανάπτυξης και εκπαίδευσης απλών αλλά και πιο σύνθετων Τεχνητών Νευρωνικών Δικτύων. Η όλη διαδικασία γίνεται μέσω της γλώσσας προγραμματισμού Python, η οποία προσφέρει το υπόβαθρο για την ανάπτυξη του κώδικα αλλά και τις βιβλιοθήκες που απαιτούνται για το σκοπό αυτό.

Κεφάλαιο 2. Μηχανές Ολομέτωπης Κοπής (TBM)


Τα μηχανήματα ολομέτωπης κοπής σήραγγας (TBM) θεωρούνται ως η πιο αποτελεσματική μέθοδος εκσκαφής για μεγάλες σήραγγες λόγω της υψηλής παραγωγικότητάς τους, της προσαρμοστικότητάς τους σε διάφορες συνθήκες κάτω από την επιφάνεια και της παροχής ασφαλέστερου εργασιακού περιβάλλοντος. Ο αριθμός των TBM που χρησιμοποιήθηκαν κατά την τελευταία δεκαετία έχει αυξηθεί, γεγονός που μαρτυρά τη συνεχή επιτυχία και ευελιξία τους για εφαρμογή σε έργα διαφορετικής διαμέτρου, μήκους και εδάφους. Υπάρχουν διάφορες διαθέσιμες οδηγίες για την επιλογή TBM και για την ανάπτυξη κατάλληλων προδιαγραφών για μια μηχανή για ένα συγκεκριμένο έργο.

Προκειμένου να ξεπεραστεί η πολυπλοκότητα και η μεταβλητότητα του εδάφους, έχουν δημιουργηθεί διαφορετικοί τύποι TBM. Το εύρος εφαρμογής των TBM έχει επεκταθεί σημαντικά τα δύο τελευταία και για λόγους απλοποίησης, μπορούν αυτά να ταξινομηθούν τα σε τρία βασικά είδη σύμφωνα με τους Barla και Pelizza (2000):

- I. TBM ανοιχτού τύπου (για σκληρούς και καλής κατάστασης βραχώδης σχηματισμούς).
- II. TBM μονής ασπίδας (για ασθενείς έως πολύ ασθενείς βραχώμαζες σε σχετικά μικρές σήραγγες).
- III. TBM διπλής ασπίδας (για ασθενείς έως σκληρές βραχώμαζες σε σχετικά μεγάλες σήραγγες).

Σε αυτές τις κατηγορίες προστίθενται τα EPB (Earth Pressure Balance) Shield και τα SPB (Slurry Pressure Balance) Shield καθώς αξίζει να αναφερθεί ο ιδιαίτερος τρόπος λειτουργίας. Τα EPB και τα SPB χρησιμοποιούνται κυρίως όταν απαιτείται πίεση στο μέτωπο της σήραγγας κατά την εκσκαφή. Αυτό συμβαίνει σε πολύ ασταθείς γεωλογικούς σχηματισμούς ή σε οριακά εδαφοποιημένους σχηματισμούς. Όπως φαίνεται στο **Σχήμα 2.2**, η χρήση είτε του EPB TBM είτε του SPB TBM είναι δυνατή για ένα μεγάλο εύρος εδαφικών σχηματισμών. Συνήθως το μηχάνημα EPB έχει επιλεγεί για λεπτόκοκκα εδάφη και το SPB για χονδρόκοκκα εδάφη. Τα τελευταία χρόνια τόσο η τεχνολογική ανάπτυξη όσο και η ανάπτυξη της παραγωγικής χρήσης προσθέτων των συστημάτων έγχυσης έχουν επιτρέψει στους δύο τύπους μηχανών να μπορούν να χρησιμοποιηθούν σε ένα ευρύτερο φάσμα εδαφικών σχηματισμών (Rick, 2007)

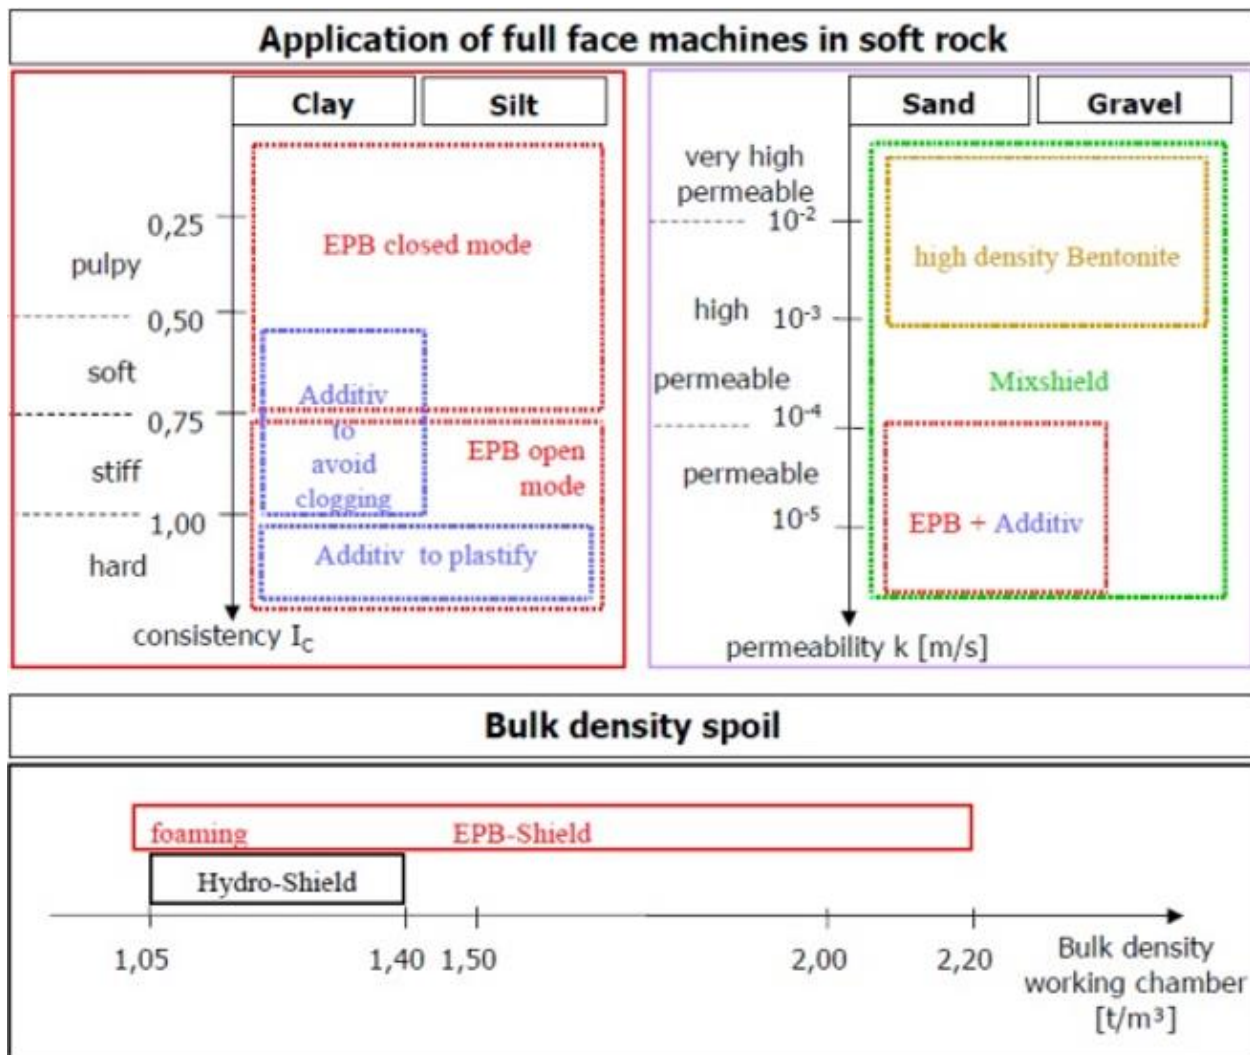
Η σταθερότητα της σήραγγας είναι ο κύριος παράγοντας για την επιλογή του τύπου TBM. Τα ανοιχτά TBM χρησιμοποιούνται βασικά σε πιο σταθερές βραχώμαζες ενώ τα θωρακισμένα TBM χρησιμοποιούνται σε ασταθείς συνθήκες βραχώμαζες με πιθανότητα κατάρρευση της σήραγγας. Το **Σχήμα 2.1.** και ο **Πίνακας 2.1** μας δείχνουν γενικά κριτήρια για την επιλογή TBM σε διαφορετικές γεωλογικές συνθήκες. Τα TBM που χρησιμοποιήθηκαν για τις σήραγγες που είναι υπό εξέταση στην παρούσα Διπλωματικής εργασία ήταν ένα TBM ανοιχτού τύπου (Maen) και 2 διαφορετικά μοντέλα TBM διπλής ασπίδας (Pieve, Varzo).



Σχήμα 2.1. Επιλογή μηχανήματος συναρτήσεϊ του συστήματος ταξινόμησης βραχώμαζας RMR (Robbins, 1995)

Πίνακας 2.1. Εμβέλεια εφαρμογής μηχανών TBM (Askilsrud , 1996)

Machine Type	Range of Diameter (m)	Rock Strength			
		Hard	Soft	Mixed	Soft Ground
Open TBM	2.5-14	■	■		
Single Shield TBM	2.5-13		■	■	
Double Shield TBM	3-12	■	■		



Σχήμα 2.2. Πεδίο εφαρμογής EPB και SPB

Η τυπική διαδικασία εξόρυξης του πετρώματος αλλά και η διαχείριση του εξορυγμένου υλικού ενός TBM συνοψίζονται ως εξής:


1. Εφαρμόζεται μια δύναμη ώθησης στην κοπτική κεφαλή και στα κοπτικά δίσκων.
2. Γίνεται διείσδυση των κοπτικών στη βραχώμαζα για να ξεκινήσει η δημιουργία ρωγμών στο πέτρωμα και η παραγωγή μικρών βραχοτεμαχίων.
3. Γίνεται η περιστροφή της κοπτικής κεφαλής για να εφαρμοστεί ροπή ώστε να αφαιρεθούν τα χαλαρά βραχοτεμάχια.
4. Μαζεύονται τα βραχοτεμάχια από τους περιφερειακούς κάδους της κοπτικής κεφαλής .

5. Μεταφορά υλικού εξόρυξης στη χοάνη της κοπτικής κεφαλής και στη συνέχεια στον μάντα μεταφοράς.
6. Από τον μάντα μεταφοράς το υλικό εξόρυξης μεταφέρεται και απομακρύνεται με το εκάστοτε σύστημα εκφόρτωσης.
7. Αποκομιδή του υλικού εξόρυξης στην είσοδο της σήραγγας

2.1. Είδη των TBM

2.1.1. TBM ανοιχτού τύπου (Open TBM)

Στην **Εικόνα 2.1**, φαίνεται ένα TBM ανοιχτού τύπου σχεδιασμένο για εκσκαφή σκληρού βράχου. Ένα ανοιχτού τύπου TBM ή αλλιώς «Gripper» TBM είναι κατάλληλο για εφαρμογή σε βραχώμαζα στην οποία δεν απαιτείται η προσωρινή υποστήριξη ή εφαρμογή πίεσης στο μέτωπο της σήραγγας. Σε περίπτωση που χρειάζεται υποστήριξη, αυτή επιτυγχάνεται με αγκυρώσεις, χαλύβδινα τόξα και εκτοξευμένο σκυρόδεμα, που εφαρμόζονται τοπικά στην οροφή της σήραγγας.




- | | |
|------------------|------------------------------|
| ① cutterhead | ⑤ anchor drill |
| ② gripper shield | ⑥ work cage with safety roof |
| ③ finger shield | ⑦ wire mesh erector |
| ④ ring erector | ⑧ gripper plates |

Εικόνα 2.1. Περιγραφή συστήματος TBM ανοιχτού τύπου (WBI, 2007)

Υπάρχουν δύο τύποι συστήματος ανοιχτού τύπου TBM, συμπεριλαμβανομένου ενός συστήματος: το μονό και το διπλό. Ένα διπλό σύστημα TBM ανοιχτού τύπου χρησιμοποιείται σε μεγαλύτερα TBM, ειδικά σε απρόβλεπτες συνθήκες όσο αφορά τις τάσεις. Η απόδοση ενός TBM ανοιχτού τύπου εξαρτάται κυρίως από το χρόνο που απαιτείται για την εγκατάσταση της υποστήριξης. Με ένα TBM ανοιχτού τύπου είναι δυνατή η εφαρμογή μέτρων υποστήριξης της βραχώμαζας (χαλύβδινα τόξα ή αγκύρια) ακριβώς πίσω από την κοπτική κεφαλή. Η συμπληρωματική υποστήριξη για τη δημιουργία του σχήματος της σήραγγας, όπως το εκτοξευόμενο σκυρόδεμα, γίνεται στην εφεδρική περιοχή.

2.1.2. TBM μονής ασπίδας (Single Shield TBM-SS TBM)

Το TBM μονής ασπίδας (Single Shield TBM) (**Εικόνα 2.2**) προορίζεται κυρίως για χρήση σε βραχώμαζες που χρειάζονται άμεσα υποστήριξη. Για την υποστήριξη του μηχανήματος και του πληρώματος, ολόκληρο το μηχάνημα προστατεύεται από μια ασπίδα, η οποία συνήθως είναι κυλινδρικής διατομής από χάλυβα.




Εικόνα 2.2. Περιγραφή συστήματος TBM μονής ασπίδας (Herrenknecht, 2010)

Η μόνιμη επένδυση της σήραγγας είναι εγκατεστημένη και έτοιμη για τοποθέτηση κάτω από την ασπίδα. Σε αντίθεση με το Open TBM, το SS TBM και οι υδραυλικοί κύλινδροι ώθησής του

σπρώχνουν τον τελευταίο δακτύλιο μόνιμης επένδυσης που έχει εγκατασταθεί για να προχωρήσει. Το σύστημα της κοπτικής κεφαλής είναι το ίδιο με αυτό του TBM ανοιχτού τύπου. Η διάμετρος εκσκαφής είναι ελαφρώς μεγαλύτερη από τη διάμετρο της εξωτερικής ασπίδας για να επιτρέπεται η υπερεκσαφή ώστε να αποφευχθεί η εμπλοκή του μηχανήματος, ειδικά σε σχηματισμούς με μεγάλες παραμορφώσεις κατά την διάρκεια εκσκαφής.

2.1.3. TBM διπλής Ασπίδας (Double Shield TBM-DS TBM)


Το TBM διπλής ασπίδας (Double Shield TBM) (*Εικόνα 2.3*) είναι τύπος TBM (*Εικόνα 2.3*) με ασπίδα που συνδυάζει τα οφέλη τόσο του Open TBM όσο και του SS TBM. Επιτρέπει έναν ταχύτερο ρυθμό προχώρησης σε πολύπλοκες γεωλογικές καταστάσεις. Από τη μία πλευρά επιτρέπεται στο μηχάνημα να προχωρήσει τόσο γρήγορα όσο ένα TBM ανοιχτού τύπου και παράλληλα η υποστήριξη τοποθετείται ανεξάρτητα κάτω από μια ξεχωριστή ασπίδα που ονομάζεται tail shield. Στην *Εικόνα 2.4* περιγράφονται τα βασικά μέρη του DS TBM.



Εικόνα 2.3. TBM διπλής ασπίδας (Herrenknecht, 2010)

Επίσης, είναι δυνατόν να χρησιμοποιηθεί η λογική του SS TBM σε μία πολύ δυσμενή και ασθενή βραχώμαζα όπου ένα TBM ανοιχτού τύπου δεν θα μπορούσε να αγκυρωθεί σωστά στα πλευρικά τοιχώματα της σήραγγας. Επομένως, έχει περισσότερα ευελιξία από το TBM ανοιχτού τύπου και

το SS TBM σε διάφορες γεωλογικές συνθήκες, ειδικά σε μεγάλες σήραγγες όπου δεν υπάρχουν οι επαρκείς και λεπτομερείς γεωλογικές πληροφορίες πριν από την έναρξη της εκσκαφής. Υπάρχουν ορισμένα μειονεκτήματα για αυτόν τον τύπο TBM σε συγκεκριμένες γεωλογικές καταστάσεις όπως η συμπίεση (squeezing) (όπου οφείλεται στο μεγάλο μήκος των ασπίδων, σε σύγκριση με το SS TBM, Το DS TBM είναι πιο πιθανό να μπλοκάρει σε μία τέτοια περίπτωση) αλλά και το γεγονός ότι αυτά τα μηχανήματα είναι πιο ακριβά.





Εικόνα 2.4. Περιγραφή συστήματος TBM διπλής ασπίδας (WBI, 2007)

2.1.4. Earth Pressure Balance TBM (EPB TBM).

Για μαλακά, συνεκτικά εδάφη τα μηχανήματα ολομέτωπης κοπής σήραγγων EPB TBM (*Εικόνα 2.5.*) με εφαρμογή πίεσης στο μέτωπο της σήραγγας είναι μια καλή επιλογή. Τα (EPB) μετατρέπουν το εκσκαπτόμενο υλικό σε πάστα εδάφους που χρησιμοποιείται ως μέσο στήριξης με πλαστική συμπεριφορά. Η διαδικασία αυτή καθιστά δυνατή την εξισορρόπηση των συνθηκών πίεσης στο μέτωπο της σήραγγας, αποφεύγοντας την ανεξέλεγκτη εισροή εδάφους μέσα στο TBM και δημιουργεί τις προϋποθέσεις για ταχεία διάνοιξη με ελάχιστες καθιζήσεις. Το ιδιαίτερο χαρακτηριστικό των EPB είναι ότι χρησιμοποιούν το ανασκαμμένο έδαφος ως μέσο στήριξης. Μία περιστρεφόμενη κοπτική κεφαλή εξοπλισμένη με εργαλεία πιέζει το μέτωπο της σήραγγας και εκσκάφει το υλικό. Το έδαφος εισέρχεται στο θάλαμο εκσκαφής μέσω ανοιγμάτων, όπου

αναμιγνύεται με μία πάστα. Η ανάμιξη της πάστας-εδάφους συμβαίνει με την βοήθεια ενός διαφράγματος μέχρι το μίγμα να έχει την απαιτούμενη υφή. Το διάφραγμα μεταφέρει την πίεση των κυλίνδρων ώθησης στην εύκαμπτη πάστα εδάφους. Όταν η πίεση του εδάφους στον θάλαμο εκσκαφής ισούται με την πίεση του περιβάλλοντος εδάφους και των υπόγειων υδάτων, έχει επιτευχθεί η απαραίτητη ισορροπία.





Εικόνα 2.5. EPB TBM (Herrenknecht)

2.1.5. Slurry Pressure Balance TBM (SPB TBM).

Τα Slurry Pressure Balance TBM (SPB) (*Εικόνα 2.6.*) είναι εφοδιασμένα με κοπτική κεφαλή που παρέχει πίεση στο μέτωπο της σήραγγας εισπιέζοντας διατρητικό υγρό μέσα στο θάλαμο κοπής. Αυτά τα TBM είναι κατάλληλα για σήραγγες που βρίσκονται μέσα σε ασταθής σχηματισμούς που υπόκεινται σε υψηλή πίεση υπόγειων υδάτων ή υπάρχει κάποια εισροή νερού που πρέπει να σταματήσει στηρίζοντας το μέτωπο με ένα διατρητικό υγρό που εισπιέζεται. Η κοπτική κεφαλή λειτουργεί ως μέσο εκσκαφής, ενώ η στήριξη του μετώπου παρέχεται από την αντίθετη πίεση μέσω του πολφού, δηλαδή ενός εναιωρήματος μπεντονίτη ή ενός μείγματος αργίλου και νερού.

Αυτό το εναιώρημα αντλείται στον θάλαμο εκσκαφής όπου φτάνει στο μέτωπο και διεισδύει στο έδαφος σχηματίζοντας ένα αδιαπέραστο διάφραγμα (λεπτόκοκκο έδαφος) ή μία εμποτισμένη ζώνη (χονδρόκοκκο έδαφος) μέσω των οποίων μεταφέρεται επιτυχώς η αντίθετη πίεση στο μέτωπο της σήραγγας. Το μείγμα πολφού-εδάφους αντλείται (υδραυλική απορρόφηση) από τον θάλαμο εκσκαφής σε μια μονάδα διαχωρισμού που βρίσκεται στην επιφάνεια και επιτρέπει την ανακύκλωση του πολφού για επαναχρησιμοποίηση.



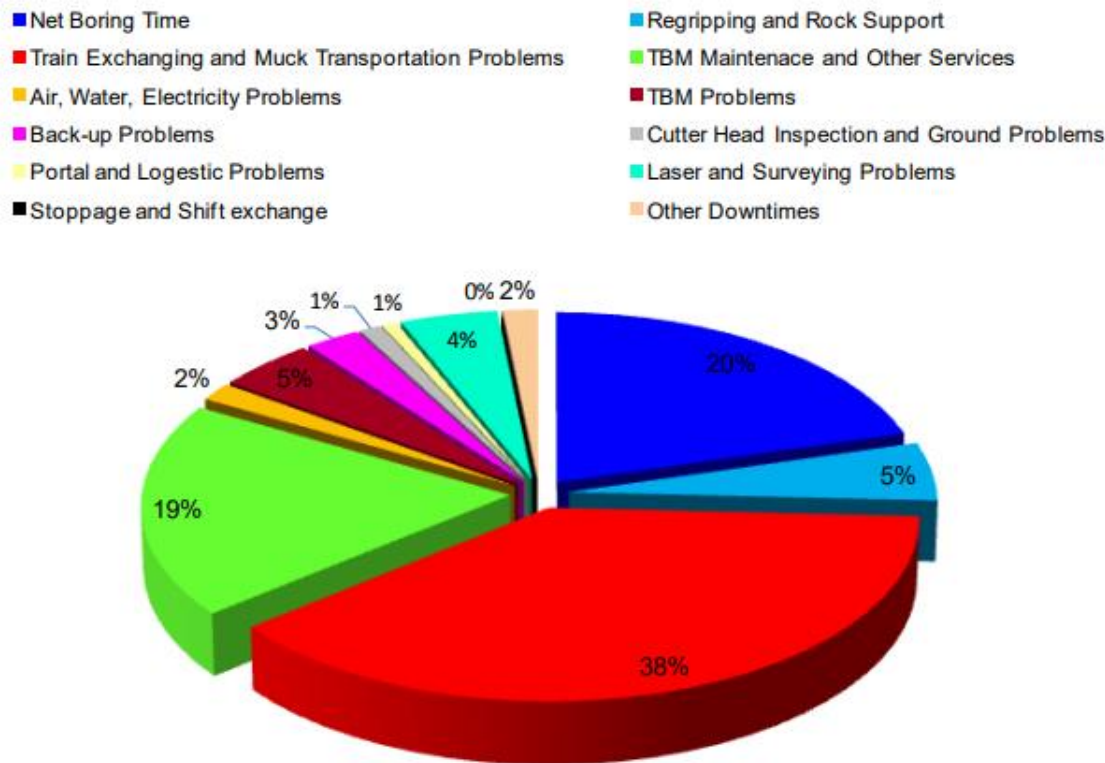
Εικόνα 2.6. SPB TMB (Herrenknecht)

2.2 Ποσοστό αξιοποίησης, Ρυθμός προχώρησης και Ρυθμός Διείσδυσης

Η αξιοποίηση του TBM ελέγχεται από διάφορους παράγοντες, συμπεριλαμβανομένων τον τύπο του πετρώματος και των συνθηκών της βραχώμαζας, των λειτουργικών παραμέτρων TBM, της κλίσης και των στροφών κατά μήκος της ευθυγράμμισης, των λειτουργικών περιορισμών, των ειδικών συνθηκών αναλόγως την τοποθεσία, και της εμπειρίας των εργολάβων. Η αποτυχία πρόβλεψης του ποσοστού αξιοποίησης του TBM μπορεί να προκαλέσει προβλήματα στην

ανάπτυξη ενός ρεαλιστικού σχεδίου για μια λειτουργική σήραγγα, το οποίο θα μπορεί λάβει προληπτικών μέτρων για την αποτελεσματική λειτουργία που με την σειρά της θα επιφέρει υψηλούς ρυθμούς προχώρησης.

Το ποσοστό αξιοποίησης του TBM έχει άμεσο αντίκτυπο στο ρυθμό προχώρησης και στο κόστος του έργου. Η σχέση μεταξύ ROP, AR και U μπορεί απλώς να δηλωθεί ως: $AR = ROP \times U \times T$ όπου, το T αντιπροσωπεύει τις ώρες εργασίας της ημέρας. Ο τύπος αυτός μας δείχνει ότι οποιαδήποτε αύξηση στη αξιοποίηση μπορεί να επηρεάσει άμεσα το ρυθμό προχώρησης. Μας δείχνει επίσης ότι ακόμη και σε περιπτώσεις όπου μπορεί να επιτευχθεί υψηλό ROP, ο ρυθμός προχώρησης της σήραγγας θα μπορούσε ακόμη να βρίσκεται υπό των προσδοκιών εάν η χρήση-αξιοποίηση του μηχανήματος είναι χαμηλή. Στην πράξη, η χρήση TBM μπορεί κανονικά να κυμαίνεται από <10% έως 50% (*Εικόνα 2.7*). Αυτό δείχνει ότι στις περισσότερες εκσκαφές, το μέρος του χρόνου που δαπανάται στην ίδια την εκσκαφή είναι μικρότερο από το χρόνο που αφιερώνεται σε διάφορες μορφές καθυστερήσεων ή των επονομαζόμενων χρόνων διακοπής. Στο παρακάτω σχήμα μπορούμε να παρατηρήσουμε ότι για μία σήραγγα (Ghomroud tunnel) ο καθαρός μηνιαίος χρόνος εξόρυξης είναι μόλις 20%.



Εικόνα 2.7. Τυπική μηνιαία κατανομή ποσοστών εργασιών στο Ghomroud tunnel (Farrokh, 2012)

Ο σχεδιασμός μιας σήραγγας με την χρήση TBM όσο αφορά τον απαιτούμενο χρόνο και κόστος για την ολοκλήρωση της εξαρτάται σε μεγάλο βαθμό από τις παραμέτρους απόδοσης TBM, κυρίως την αξιοποίηση και το ρυθμό προχώρησης. Ενώ αυτές οι δύο παράμετροι είναι οι πιο σημαντικές παράμετροι απόδοσης, έχουν πραγματοποιηθεί πολλές μελέτες για την ανάπτυξη σχέσεων για το ρυθμό διείδυσης. Ένας λόγος είναι ότι ο ρυθμός διείδυσης επηρεάζεται κυρίως από τα χαρακτηριστικά της βραχώμαζας και του TBM και μπορεί να εκτιμηθεί πιο εύκολα με έναν σχετικά υψηλό βαθμό ακρίβειας.

Με την πρόοδο λοιπόν της τεχνολογίας, η πρόβλεψη του ποσοστού προόδου TBM είναι ένα πολύ σημαντικό ζήτημα, καθώς επηρεάζει σημαντικά τη διάρκεια και το κόστος του έργου. Η συνολική απόδοση του TBM αναφέρεται σε ρυθμό διείδυσης (PR), συντελεστή χρησιμοποίησης (U) και ρυθμό προχώρησης (AR). Συγκεκριμένα, το AR είναι η πραγματική απόσταση που εξορύσσεται διαιρούμενη με το συνολικό χρόνο των λειτουργιών και περιλαμβάνει τους χρόνους διακοπής λειτουργίας για συντήρηση TBM, την αστοχία της σήραγγας, την βλάβη του μηχανήματος. Ο παράγοντας αξιοποίησης είναι μία από τις βασικές παραμέτρους απόδοσης που συνδέουν το AR και το PR. Τα περισσότερα από τα διαθέσιμα μοντέλα πρόβλεψης έχουν επικεντρωθεί μόνο στην εκτίμηση του ρυθμού διείδυσης. Ωστόσο, τα μοντέλα, όπως CSM, NTNU και Qtbm, προσφέρουν κάποιες σχέσεις και διαγράμματα για την εκτίμηση του συντελεστή χρήσης (U). Αυτά τα μοντέλα έχουν αναπτυχθεί από τις αρχές της δεκαετίας του 1960 και οι ικανότητές τους έχουν βελτιωθεί λόγω της προόδου που έχει σημειωθεί σε κατασκευές σιράγγων με τη χρήση TBM. Τα μηχανήματα ολομέτωπης εκσκαφής εισάγονται σε ολοένα και πιο προκλητικές συνθήκες εδάφους προσφέροντας νέες πληροφορίες και δεδομένα.

2.3. Μοντέλα πρόβλεψης

2.3.1 Μοντέλο πρόβλεψης απόδοσης TBM του Colorado School of Mines (CSM)

Το Earth Mechanics Institute (EMI) ανέπτυξε το μοντέλο CSM για πρόβλεψη απόδοσης TBM σε διάρκεια 25 ετών. Για να δημιουργήσει τη λεπτομερή βάση δεδομένων για την ανάπτυξη μοντέλου, το EMI έχει συλλέξει εκτεταμένο αριθμό εργοταξιακών δεδομένων και διεξήγαγε εργαστηριακές δοκιμές κοπής πραγματικής κλίμακας για να χρησιμεύσουν ως βάση για την ανάπτυξη και την επικύρωση του μοντέλου. Αυτή η προσπάθεια συλλογής δεδομένων συμπληρώθηκε από εκτεταμένη θεωρητική ανάλυση της αστοχίας της βραχώμαζας. Έχει

αναπτυχθεί μια βάση δεδομένων μετρούμενων δυνάμεων κοπής που χρησιμοποιούν κοπτικά δίσκων σε διαφορετικούς τύπους βραχόμαζας και ενημερώνεται συνεχώς στο EMI. Για την δημιουργία αυτής της βάσης δεδομένων χρησιμοποιήθηκε η δοκιμή πραγματικής κλίμακας Linear Cutting Machine (LCM) για μια ποικιλία πετρωμάτων. Οι δοκιμές LCM συνοδεύτηκαν από δοκιμές για τον προσδιορισμό των φυσικών ιδιοτήτων του πετρώματος, δηλαδή τον υπολογισμό της μονοαξονικής θλιπτικής αντοχής και της αντοχής σε εφελκυσμό μέσω της δοκιμής Brazilian. Η βάση δεδομένων χρησιμοποιήθηκε αρχικά για την παραγωγή τύπων όσο αφορά τις δυνάμεις κοπής. Τα δεδομένα συλλέχθηκαν συμπεριλαμβανομένης της απόστασης μεταξύ των κοπτικών, του ρυθμού διείδυσης, της διαμέτρου και του πλάτους ακμής των κοπτικών, την θλιπτική και εφελκυστική αντοχή της βραχόμαζας με στόχο τον υπολογισμό του φορτίου κοπής ενός κοπτικού. Έτσι, υπολογίστηκε η δύναμη που ενεργούσε στην επιφάνεια του πετρώματος. Έπειτα πραγματοποιήθηκε πολλαπλή γραμμική παλινδρόμηση για την ανάλυση ώστε να βρεθεί ο καλύτερος συνδυασμός παραμέτρων για την ανάπτυξη σχέσης μεταξύ του φορτίου κοπής και τις παραμέτρους εισόδου.

Ως αποτέλεσμα των ευρημάτων, οι τύποι της πρόβλεψης απόδοσης TBM στο μοντέλο έχουν ως εξής:

$$F_n = 8.76 T^{0.8} * R^{0.79} * \varphi^{0.6} S^{0.28} * \sigma_c^{0.63} * \sigma_t^{0.2}$$

$$\varphi = \text{Cos}^{-1} * ((R-p) / R)$$

$$P^0 = C * T^{-1/6} * R^{-1/6} * \varphi^{-1/3} * S^{1/3} * \sigma_c^{2/3} * \sigma_t^{1/3}$$

$$F_n = (T * R * P^0) / \varphi * (1 - \text{Cos} \varphi)$$

$$F_r = (T * R * P^0) / \varphi * (1 - \text{Sin} \varphi)$$

$$T_h = \Sigma F_n * n$$

$$T_r = \Sigma F_r * R = 0.3 * D_c * F_r$$

όπου:

F_n: είναι η δύναμη σε lb,

S: είναι η απόσταση μεταξύ των κοπτικών σε in,

p: είναι η διείδυση σε in,

P⁰: είναι η βασική πίεση στη θρυμματισμένη ζώνη κάτω από το σημείο κοπής,

σ_t και **σ_c**: είναι η αντοχή σε εφελκυσμό της δοκιμής Brazilian και η μονοαξονική θλιπτική αντοχή σε λίβρες ανά τετραγωνική ίντσα αντίστοιχα ,

T: είναι το πλάτος του άκρου του κοπτικού,

D_c: είναι η διάμετρος του κοπτικού και το

R: είναι η ακτίνα κοπής σε in.

Μετά από αυτό, ο υπολογισμός της μέγιστης ταχύτητας περιστροφής (RPM) διέπεται από τη διάμετρο του κοπτικού και την απαιτούμενη ισχύ (P_c) της κοπτικής κεφαλής ως εξής:

$$\mathbf{RPM} = (\mathbf{V}_{\max} / \pi * \mathbf{D}_c)$$

$$\mathbf{P}_c = \mathbf{T}_r * \mathbf{RPM}$$

2.3.2 Μοντέλο πρόβλεψης απόδοσης TBM του Norwegian University of Science and Technology (NTNU)

Η φιλοσοφία του μοντέλου πρόβλεψης NTNU είναι ο συνδυασμός των καθοριστικών ιδιοτήτων του πετρώματος και τις σχετικές παραμέτρους του μηχανήματος. Αρκετά βήματα εμπλέκονται στο μοντέλο πρόβλεψης NTNU για TBM σκληρών πετρωμάτων για την εκτίμηση του χρόνου και του κόστους για την εκσκαφή της σήραγγας.

- Καθαρός Ρυθμός διείσδυσης
- Διάρκεια ζωής κοπτικών
- Ρυθμός προχώρησης
- Κόστος εκσκαφής

Ο παράγοντας για τις παραμέτρους του πετρώματος είναι ο ισοδύναμος συντελεστής θραύσης (**k_{ekv}**):

$$\mathbf{k}_{ekv} = \mathbf{k}_{s-tot} * \mathbf{k}_{DRI} * \mathbf{k}_{por}$$

όπου:

k_{s-tot} είναι ο συντελεστής της ολικής θραύση της βραχώμαζας

k_{DRI} είναι ο διορθωτικός συντελεστής για το DRI της βραχώμαζας (Ο δείκτης ρυθμού γεώτρησης (DRI) εκφράζει την ικανότητα διάτρησης ή την ικανότητα εκσκαφής του άρρηκτου βράχου. Το DRI αξιολογείται βάσει δύο εργαστηριακές δοκιμές, τη δοκιμή Brittleness Value (S20) και τη δοκιμή Sievers 'J-Value (SJ) με μικροσκοπικό τρυπάνι.),

k_{por} είναι ο συντελεστής διόρθωσης για το πορώδες της βραχώμαζας

Ο παράγοντας για τις παραμέτρους TBM είναι το ισοδύναμο παράγοντας της ώσης των κοπτικών (M_{ekv}) σε kN /κοπτικό:

$$M_{ekv} = M_B * k_d * k_a$$

όπου:

M_B είναι η μέση ώση των κοπτικών (Η ώση που θα χρησιμοποιηθεί),

k_d είναι ο διορθωτικός συντελεστής για τη διάμετρο των κοπτικών

k_a είναι ο συντελεστής διόρθωσης για τη μέση απόσταση μεταξύ των κοπτικών.

Το μοντέλο εκτίμησης του ποσοστού διείδυσης είναι βασισμένο σε κανονικοποιημένες καμπύλες διείδυσης σύμφωνα με τον Bruland (1998). Οι καμπύλες διείδυσης προκύπτουν από δοκιμές διείδυσης που πραγματοποιήθηκαν με TBM κατά τη διάρκεια εκσκαφών. Το **Σχήμα 2.3** δείχνει μια γενική μορφή της καμπύλη διείδυσης:

Η παρακάτω εξίσωση σχετίζεται με την την καμπύλη διείδυσης του Bruland (1998).

$$i_o = (M_{ekv}/M_I)^b$$


όπου:

i_o είναι ο βασικός ρυθμός διείδυσης (mm / rev),

M_{ekv} είναι ο ισοδύναμος παράγοντας ώσης των κοπτικών (kN / cutter),

M_I είναι η κρίσιμη ώση κοπτικών kN / κοπτικό (Είναι η απαραίτητη ώση για την επίτευξη 1 mm/ rev)

b είναι ο συντελεστής διείδυσης



General progress of a penetration curve
(Bruland, 1998)

Σχήμα 2.3. Γενική πορεία της καμπύλης διείσδυσης (Bruland, 1998)

Η κρίσιμη ώση κοπής (M_1) και ο συντελεστής διείσδυσης (b) έχουν σχέση με το ισοδύναμο συντελεστή θραύσης (k_{ekv}) (Bruland (1998).

Ο βασικός καθαρός ρυθμός διείσδυσης (I_o) για μια συστηματικά σπασμένη βραχώμαζα ορίζεται ως μετρητές μέτρα εκσκαφής ανά ώρα. Το I_o είναι σε συνάρτηση του βασικού ρυθμού διείσδυσης και των περιστροφών ανά λεπτό της κεφαλής:

$$I_o = i_o * \text{RPM} * 60 / 1000$$

όπου το I_o είναι σε m / h.

Σε περίπτωση παρουσίας «επισημασμένων μεμονομένων ασυνεχειών») χρησιμοποιείται ένας συντελεστής διόρθωσης αυτών k_{esp} . Σε αυτή την περίπτωση ο βασικός καθαρός ρυθμός διείσδυσης (I_o) εμπλουτίζεται ως εξής:

$$I_{esp} = I_o * k_{esp}$$

Έχοντας υπόψιν τα προηγούμενα οι παράμετροι εξόδου του NTNU είναι:

- Καθαρός ρυθμός διείσδυσης (m / h)
- Διάρκεια κοπής (h / κοπτικό, $\text{sm}^3/\text{κοπτικό}$)

- Χρήση του μηχανήματος (%)
- Εβδομαδιαίος ρυθμός προχώρησης (m / εβδομάδα)
- Έξοδα εκσκαφής (NOK / m)
- Έξοδα εκσκαφής (NOK / m)

2.3.3 Μοντέλο πρόβλεψης απόδοσης TBM του Barton (2017) (Q_{TBM})

Το 2017 ο Nick Ryland Barton δημοσίευσε μία νέα μέθοδο για την εκτίμηση του PR και του AR βασισμένη στην ταξινόμηση βραχώμαζας Q εισάγοντας έναν καινούριο όρο Q_{TBM} .

Σύμφωνα με αυτό, η πρόβλεψη των τιμών του ρυθμού προχώρησης (AR) και του ρυθμού εκσκαφής (PR), γίνεται μέσω του δείκτη Q_{TBM} (Σχήμα 2.4). Ο συγκεκριμένος δείκτης αποτελεί μια αναπτυγμένη μορφή του δείκτη ποιότητας βραχώμαζας Q (Q-system), η οποία συμπεριλαμβάνει επιπλέον στοιχεία για την αλληλεπίδραση μηχανήματος – βραχώμαζας, σύμφωνα με τον τύπο:

$$Q_{TBM} = \frac{RQD_0}{J_n} \cdot \frac{J_r}{J_\alpha} \cdot \frac{J_w}{SFR} \cdot \frac{SIGMA}{F^{10}/20^9} \cdot \frac{20}{CLI} \cdot \frac{q}{20} \cdot \frac{\sigma_\theta}{5}$$

όπου:

RQD_0 : Η τιμή RQD που μετρείται κατά τη διεύθυνση όρυξης.

J_n : Αριθμός οικογενειών ασυνεχειών

J_r : Συντελεστής τραχύτητας ασυνεχειών της οικογένειας που επιδρά περισσότερο στην όρυξη

J_w : Συντελεστής κατάστασης υπόγειων υδάτων

SFR : Συντελεστής μείωσης τάσεων

SIGMA : Αντοχή βραχώμαζας (MPa)

F : Μέση τιμή φορτίου κοπτήρα (tnf)


CLI : Cutter Life Index

q : περιεκτικότητα σε χαλαζία (%)

σ_θ : μέση τάση που ασκείται στο μέτωπο εκσκαφής (MPa)

Σύμφωνα με τον Barton, μια καλή προσέγγιση μεταξύ του ρυθμού εκσκαφής (PR) και του δείκτη QTBM, δίνεται από τη σχέση:

$$PR \approx 5 \cdot (Q_{TBM})^{-0.2}$$



Σχήμα 2.4. Η μέθοδος QTBM στην ολοκληρωμένη της μορφή. Οι καμπυλές PR και AR είναι από ένα παράδειγμα του Barton, 2000. Ο μέγιστος υποτιθέμενων ωρών εργασίας μίας ημέρας, εβδομάδας και μήνα είναι μεγέθη που προσαρμόζονται αν υπάρχουν αλλαγές στις βάρδιες εργασίας.

Κεφάλαιο 3. Τεχνητά Νευρωνικά δίκτυα

Η ανάπτυξη των τεχνητών νευρωνικών δικτύων (ΤΝΔ), ξεκίνησε ως μια προσπάθεια κατανόησης του ανθρώπινου εγκεφάλου και μίμησης των δυνατοτήτων του, δηλαδή της ικανότητας να λαμβάνει αποφάσεις κάτω από συνθήκες έλλειψης ή ανεπάρκειας δεδομένων, απρόβλεπτων παραγόντων και αβεβαιότητας και να αντιμετωπίζει με επιτυχία ακόμα και καταστάσεις, οι οποίες είναι τελείως άγνωστες σε αυτόν.


Ουσιαστικά τα νευρωνικά δίκτυα είναι απλουστευμένα μαθηματικά μοντέλα που αποτελούνται από πολλές απλές μονάδες επεξεργασίας, τους νευρώνες (neurons), οι οποίοι είναι διασυνδεδεμένοι μεταξύ τους με μια, προσδιορισμένη κάθε φορά, μορφή τοπολογίας. Βασικό χαρακτηριστικό τους είναι η δυνατότητα μαζικής παράλληλης επεξεργασίας των ερεθισμάτων (δεδομένων) που λαμβάνουν, σε αντίθεση με τα συνήθη μοντέλα τα οποία στηρίζονται στη σειριακή εκτέλεση μαθηματικών και λογικών πράξεων.

Τα νευρωνικά δίκτυα επιδεικνύουν μια σειρά από πλεονεκτήματα σε σχέση με άλλες μεθόδους (αριθμητικές και μη), γεγονός που τα καθιστά σημαντικά εργαλεία για την αντιμετώπιση μιας πληθώρας προβλημάτων. Στον κλασικό προγραμματισμό, το πρόβλημα και ο τρόπος επίλυσής του πρέπει να περιγράφουν ρητά μέσω αναλυτικών μαθηματικών σχέσεων. Στα νευρωνικά δίκτυα, το μόνο που χρειάζεται να γίνει, είναι η συλλογή δεδομένων που θα έχουν τη μορφή αιτίου – αποτελέσματος και τα οποία θα εισαχθούν στο νευρωνικό δίκτυο για να γίνει η εκπαίδευσή του. Από τη στιγμή εκείνη, το νευρωνικό δίκτυο είναι σε θέση να “ανακαλύψει” τις συσχετίσεις που υπάρχουν στα δεδομένα και να τις “μάθει”, με την κατάλληλη μεταβολή των συντελεστών βαρύτητάς του. Έτσι, είναι σε θέση να εκπαιδευτεί με βάση τα υπάρχοντα δεδομένα και στη συνέχεια να κάνει προβλέψεις.


3.1 Ιστορική αναδρομή

Η χρήση τεχνητών νευρωνικών δικτύων – ΤΝΔ (artificial neural networks – ANN) έχει ρίζες από τις αρχές του 1940. Το πρώτο κύμα ονομαζόταν “Cybernetics” (1940-1960) όπου το σκεπτικό ήταν να φτιαχτεί ένας υπολογιστής ο οποίος θα πλησίαζε τον τρόπο με τον οποίο σκέφτεται ο άνθρωπος. Η έμπνευση αυτή ήταν και ο λόγος που επικράτησε η ονομασία “νευρωνικό δίκτυο” από τον επιστημονικό κλάδο της βιολογίας του ανθρώπου. Δηλαδή ο υπολογιστής καλείται να αντιμετωπίσει προβλήματα με τον ίδιο τρόπο που αντιμετωπίζει ο άνθρωπος τα καθημερινά του

προβλήματα. Έτσι το 1943 φτιάχτηκε το πρώτο νευρωνικό δίκτυο (**Σχήμα 3.1.**) από τους McCulloch-Pitts. Ουσιαστικά μιλάμε για έναν νευρώνα όπου υπήρχαν τρεις είσοδοι (x_1, x_2, x_3) και τα βάρη (w_1, w_2, w_3) δινόντουσαν με το χέρι αναλόγως με το πρόβλημα που έπρεπε να λυθεί λαμβάνοντας τις τιμές -1 και 1 ώστε τελικά να πάρουμε μία έξοδο. Αργότερα το 1958 δημιουργήθηκε ο νευρώνας "Perceptron" ή Αντίληπτρο όπου ήταν το πρώτο μοντέλο το οποίο "μάθαινε" τα βάρη. Σε αυτό το μοντέλο (**Σχήμα 3.2.**) δινόταν ως είσοδος κάποια χαρακτηριστικά από x_1 έως x_n και μία σταθερά (constant=1) και εν συνεχεία υπήρχαν συγκεκριμένες παράμετροι που καθόριζαν πόσο σημαντικό είναι το κάθε χαρακτηριστικό και πόσο σημαντική είναι η σταθερά. Δηλαδή όπως φαίνεται στο **Σχήμα 3.1.** το w_0 "ζύγισε" την σταθερά, το w_1 "ζύγισε" το x_1 κ.ο.κ καταλήγοντας έτσι σε ένα ζυγισμένο άθροισμα. Έπειτα μέσω μίας συνάρτησης "σκαλοπάτι" έδινε μία έξοδο μεταξύ 0 και 1. Το συγκεκριμένο μοντέλο χρησιμοποιείται σήμερα με πολύ πιο σύνθετη μορφή (MLP-Multi Layer Perceptron). Η μορφή που είχε τότε όμως δεν το είχε καταστήσει ούτε εύχρηστο ούτε έμπιστο οπότε σε εκείνο το σημείο τελείωσε το πρώτο κύμα.



Σχήμα 3.1. Το πρώτο νευρωνικό δίκτυο από τους McCulloch-Pitts (1943)




Σχήμα 3.2. Ο νευρώνας "Perceptron" ή Αντίληπτρο (1958).

Το δεύτερο κύμα (Connectionism) ήρθε πολύ αργότερα στις δεκαετίες του 1980 και 1990 όπου η ιδέα εδώ ήταν: Αν δημιουργηθεί ένα δίκτυο από πολλές απλές υπολογιστικές μονάδες μπορεί τελικά να έχει μία ευφυής συμπεριφορά. Σε αυτό το κύμα για πρώτη φορά χρησιμοποιήθηκε η κατανεμημένη αναπαράσταση. Δηλαδή αν έχουμε N νευρώνες για να αναπαραστήσουμε χρώματα και M νευρώνες για να αναπαραστήσουμε τα αντικείμενα μπορούμε να τους ενώσουμε και να αναπαραστήσουμε $N \cdot M$ χρωματιστά αντικείμενα.

Επίσης, σε αυτό το κύμα είναι η πρώτη φορά που εισήχθη η έννοια της "οπισθοδιάδοσης" (**backpropagation**), δηλαδή πως εμείς ενημερώνουμε τα βάρη, βάση του πόσο λάθος κάνουμε πάνω σε αυτό που προσπαθούμε να προβλέψουμε κατά την διάρκεια της εκπαίδευσης. Το συγκεκριμένο κύμα μπορούμε να πούμε ότι μπήκε σε χειμερία νάρκη επειδή υπήρχαν μη ρεαλιστικοί ισχυρισμοί από τους ερευνητές αλλά όλη η γνώση συντηρήθηκε στο Καναδά και συνέχισε να γίνεται έρευνα μέχρι που ωρίμασαν οι συνθήκες για να φτάσουμε στην εποχή μας όπου η χρήση τεχνητών νευρωνικών δικτύων για την ανάλυση προβλημάτων έχει σημαντική εξάπλωση σε διάφορες εφαρμογές.

Για να γίνει κατανοητό το πόσο περίπου δημοφιλές ήταν κάθε κύμα μπορούμε να δούμε το **Σχήμα 3.3.** (Goodfellow, 2016). Στο κατακόρυφο άξονα βλέπουμε την συχνότητα της εμφάνισης της

ονομασίας των δύο κυμάτων (cybernetics και connectionism + neural networks) στις ερευνητικές δημοσιεύσεις που γίνοντουσαν στα εκάστοτε συνέδρια, συναρτήσει του χρόνου στον οριζόντιο άξονα (έως το 2000).



Σχήμα 3.3. Δημοφιλία των δύο κυμάτων (cybernetics και connectionism + neural networks) (Goodfellow,2016).

Στην εποχή μας, οι γλώσσες προγραμματισμού δίνουν την ευκαιρία σε πολλούς επιστήμονες να χρησιμοποιήσουν αλγόριθμους ως εργαλεία για την επίλυση προβλημάτων αλλά και την αξιολόγηση των αποτελεσμάτων τους συγκριτικά με άλλες μεθόδους. Οι αλγόριθμοι αυτοί που μπορούν να “μάθουν” μέσα από δεδομένα παρατήρησης και να κάνουν προβλέψεις βάσει των δεδομένων αποτελούν αυτό που αποκαλούμε στις μέρες μας “Μηχανική Μάθηση” (Machine Learning). Οι τεχνικές της Μηχανικής Μάθησης μπορούν να εκφραστούν πολύ απλά όπως μία γραμμική παλινδρόμηση αλλά και πιο σύνθετα όπως ένα νευρωνικό δίκτυο. Το μεγάλο ερώτημα είναι αν οι αλγόριθμοι αυτοί πλησιάζουν πραγματικά τον τρόπο με τον οποίο λειτουργεί ο ανθρώπινος εγκέφαλος.

Τα νευρωνικά δίκτυα παρουσιάζουν ιδιαίτερη ικανότητα στην επίλυση ζητημάτων, όπου οι εμπλεκόμενες παράμετροι που επιδρούν είτε είναι μεγάλες σε αριθμό, είτε δεν είναι πλήρως κατανοητός ο τρόπος επίδρασής τους είτε, τέλος, δεν υπάρχουν συγκεκριμένοι γενικευμένοι κανόνες που να μοντελοποιούν με ακρίβεια την συμπεριφορά τους στο τελικό αποτέλεσμα.

Προβλήματα των οποίων η επίλυση αρχικά φαίνεται να βρίσκεται σε μια πολλαπλή γραμμική παλινδρόμηση μπορούν να εμφανίσουν πολύ γρήγορα αδύναμα σημεία όπως η πολυσυγγραμμικότητα, η οποία συναντάται λόγω της αλληλεπίδρασης μεταξύ των αυξημένων, για το εν λόγω πρόβλημα, ανεξάρτητων παραμέτρων. Το βασικό στοιχείο των νευρωνικών δικτύων είναι ότι υπάρχει διαθέσιμο ένα πλήθος δεδομένων, μέσα στο οποίο πραγματώνονται και μπορούν να αναζητηθούν, μέσω των κατάλληλων εργαλείων, νόμοι που διέπουν την έκβαση του φαινομένου.

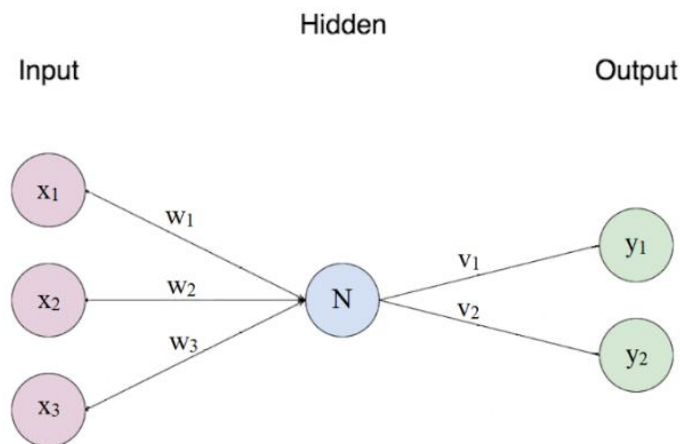
3.2. Αρχές λειτουργίας ΤΝΔ

Η λειτουργία των ΤΝΔ στηρίζεται στις παρακάτω παραδοχές:

- Η επεξεργασία της πληροφορίας γίνεται σε ένα πλήθος νευρώνων, οι οποίοι έχουν εισόδους και εξόδους των σημάτων.
- Η ένωση των νευρώνων γίνεται μέσω συνδέσεων (connection links), κάθε μια από τις οποίες έχει αντιστοιχισμένο ένα συντελεστή βαρύτητας (weight), ο οποίος πολλαπλασιάζει το σήμα.
- Κάθε νευρώνας εφαρμόζει μια συνάρτηση στο σήμα που λαμβάνει, για να καθορίσει το σήμα που θα εκπέμψει. Η συνάρτηση αυτή, ονομάζεται συνάρτηση ενεργοποίησης (activation function) και είναι συνήθως μη γραμμική, συνηθέστερα σιγμοειδής.

Στην ουσία, οι συντελεστές βαρύτητας είναι τα σημεία στα οποία αποθηκεύονται οι πληροφορίες που χρησιμοποιεί το ΤΝΔ, για να περιγράψει και να λύσει το πρόβλημα που του τίθεται. Όπως ισχύει και στο βιολογικό ανάλογο, στο οποίο η "βαρύτητα" κάθε σύναψης διαφέρει και μπορεί να μεταβληθεί, αντίστοιχα συμβαίνει και για τους συντελεστές βαρύτητας των ΤΝΔ.

Στο **Σχήμα 3.4** παρουσιάζεται ένα πολύ απλό νευρωνικό δίκτυο. Οι νευρώνες είναι τοποθετημένοι σε τρία επίπεδα (denses), στο επίπεδο εισόδου (input layer), στο επίπεδο εξόδου (output layer) και σε ένα ενδιάμεσο επίπεδο, το οποίο ονομάζεται κρυμμένο επίπεδο (hidden layer).



Σχήμα 3.4. Σχηματική απεικόνιση απλού νευρωνικού δικτύου

Αναλύοντας περισσότερο τη δομή, παρατηρείται ότι οι νευρώνες στο επίπεδο εισόδου είναι οι X_1 , X_2 και X_3 , υπάρχει ένας νευρώνας N στο κρυμμένο επίπεδο και δύο νευρώνες y_1 , y_2 στο επίπεδο εξόδου. Τέλος, w_1 , w_2 , w_3 είναι οι συντελεστές βαρύτητας των συνδέσεων μεταξύ των νευρώνων X_1 , X_2 , X_3 και του N αντίστοιχα και v_1 , v_2 εκείνοι των συνδέσεων μεταξύ του νευρώνα N και των y_1 , y_2 .

Το σήμα στην είσοδο του νευρώνα N , ισούται με το άθροισμα των σταθμισμένων σημάτων που προέρχονται από τους νευρώνες X_1 , X_2 και X_3 :

$$y_{in} = w_1 \cdot x_1 + w_2 \cdot x_2 + w_3 \cdot x_3$$

Το αποτέλεσμα αυτό εισάγεται στη συνάρτηση ενεργοποίησης του νευρώνα N και το αποτέλεσμα εκπέμπεται προς τους νευρώνες y_1 , y_2 σε μια μορφή: $y = f(y_{in})$. Παρά το γεγονός ότι το εκπεμπόμενο σήμα είναι αρχικά το ίδιο και προς τους δύο νευρώνες εξόδου, οι τιμές των σημάτων που φτάνουν στην είσοδο του καθένα από αυτούς είναι διαφορετικές, λόγω των διαφορετικών συντελεστών βαρύτητας.

Όπως αναφέρθηκε παραπάνω η συνάρτηση ενεργοποίησης (activation function) και είναι συνήθως μη γραμμική, συνηθέστερα σιγμοειδής. Αυτό σημαίνει το εξής: ο υπολογισμός των συντελεστών βαρύτητας μπορεί να είναι ένας οποιοσδήποτε αριθμός. Αυτό που θέλουμε εμείς είναι οι ενεργοποιήσεις των νευρώνων να βρίσκονται μεταξύ των τιμών 0 και 1. Οπότε το σύνθημα είναι


να τροφοδοτούμε το άθροισμα των βαρών $y_{in} = w_1 \cdot x_1 + w_2 \cdot x_2 + w_3 \cdot x_3$ σε μία συνάρτηση η οποία συμπιέζει αυτήν την αριθμοσειρά στο διάστημα τιμών μεταξύ 0 και 1. Μια κοινή συνάρτηση η οποία το πετυχαίνει αυτό είναι η σιγμοειδής συνάρτηση (σ). Οι πολύ αρνητικές εισοδοι καταλήγουν κοντά στο μηδέν ενώ οι πολύ θετικές εισοδοι καταλήγουν κοντά στο 1 (**Σχήμα 15**). Οπότε ουσιαστικά η ενεργοποίηση ενός νευρώνα είναι μία μέτρηση του πόσο θετικό είναι το σχετικό άθροισμα των συντελεστών βαρύτητας. Για παράδειγμα στην παρακάτω συνάρτηση πόσο θετικό είναι το " $w_2 \cdot x_2$ ":

$$\sigma(w_1 \cdot x_1 + w_2 \cdot x_2 + w_3 \cdot x_3).$$

Σε περίπτωση που δεν θέλουμε ο νευρώνας να ενεργοποιηθεί για μία τιμή η οποία είναι απλά μεγαλύτερη του 0, αλλά για μία που είναι μεγαλύτερη από έναν συγκεκριμένο αριθμό τότε στο τέλος του παραπάνω αθροίσματος προσθέτουμε μία παράμετρο η οποία ονομάζεται bias. Την παράμετρο αυτή μπορούμε να τη ονομάσουμε παράμετρο αδράνειας καθώς αν το άθροισμά μας δεν ξεπερνάει την τιμή της παραμέτρου αυτής, προτού εισέλθει στην σιγμοειδή συνάρτηση, τότε ο νευρώνας θα παραμείνει ανενεργός. Έτσι η παραπάνω εξίσωση ολοκληρώνεται ως εξής:

$$\sigma(w_1 \cdot x_1 + w_2 \cdot x_2 + w_3 \cdot x_3 + bias).$$

Πλέον η σιγμοειδής συνάρτηση (σ) έχει αντικατασταθεί επί το πλείστον στο προγραμματισμό με συναρτήσεις όπως η ReLU ή η Tanh οποίες όμως κρατάνε την ίδια αρχή λειτουργίας (**Σχήμα 3.5**).



Σχήμα 3.5. Οι τρεις δημοφιλέστερες συναρτήσεις ενεργοποίησης.

Όπως γίνεται φανερό κάθε νευρωνικό δίκτυο χαρακτηρίζεται από τρία βασικά στοιχεία :

- Τον τρόπο με τον οποίο συνδέονται οι νευρώνες μεταξύ τους, ο οποίος ονομάζεται αρχιτεκτονική του δικτύου (network architecture). Αποτελεί ίσως το πιο σημαντικό γνώρισμα ενός ΤΝΔ γιατί ανάλογα με αυτόν, καθορίζονται και οι δυνατότητές του.

- Τη μέθοδο που χρησιμοποιείται για να καθορίζονται οι τιμές των συντελεστών βαρύτητας στις συνδέσεις, η οποία ονομάζεται αλγόριθμος εκπαίδευσης (training algorithm).
- Τον τύπο της συνάρτησης ενεργοποίησης.

Υπάρχουν πολλές άλλες λεπτομέρειες στην κατασκευή του μοντέλου που ενδεχομένως να λάβουν σημαντικό ρόλο στην εκπαίδευση, όπως το βήμα εκμάθησης του μοντέλου μέσα από τον αλγόριθμο βελτιστοποίησης, αλλά τα παραπάνω τρία βασικά χαρακτηριστικά αποτελούν το κορμό του νευρωνικού δικτύου.

Με βάση τα χαρακτηριστικά αυτά και ιδιαίτερα με τα δύο πρώτα, έχουν δημιουργηθεί διαφορετικά είδη ΤΝΔ, κάθε ένα από τα οποία μπορεί να αντιμετωπίσει και διαφορετικά είδη προβλημάτων. Τα ευρύτερα διαδεδομένα και χρησιμοποιούμενα ΤΝΔ είναι αυτά της πρόσθιας τροφοδότησης (feedforward neural networks). Εφαρμόζονται κυρίως σε προβλήματα που απαιτούν την αντιστοίχιση μιας ομάδας διανυσμάτων εισόδου, σε μια άλλη, καθορισμένη ομάδα διανυσμάτων εξόδου. Ο στόχος είναι να εκπαιδευθεί το ΤΝΔ, έτσι ώστε να επιτευχθεί μια ισορροπία ανάμεσα στην ικανότητά του να αποκρίνεται σωστά στα διανύσματα εισόδου (απομνημόνευση, memorization) και σε αυτή που θα του επιτρέπει να δίνει ικανοποιητικές αποκρίσεις σε διανύσματα που είναι παρόμοια, αλλά όχι ίδια (γενίκευση, generalization), με αυτά που χρησιμοποιήθηκαν κατά τη φάση της εκπαίδευσης.


3.3 Τύποι Τεχνητών Νευρωνικών Δικτύων

Στην εποχή μας υπάρχουν πάρα πολλοί τύποι ΤΝΔ ακριβώς επειδή τα αποτελέσματά τους είναι εντυπωσιακά. Ο αυξημένος αριθμός τύπων ΤΝΔ υπάρχει καθώς κάθε ένα από αυτά εξυπηρετεί συγκεκριμένους τύπους προβλημάτων. Οι δημοφιλέστεροι και πιο βασικοί τύποι ΤΝΔ είναι περίπου 30. Στην συγκεκριμένη διπλωματική εργασία θα εξηγήσουμε με λίγα λόγια 5 από αυτούς καθώς πάνω σε αυτούς έγινε και το πειραματικό κομμάτι.

3.3.1. Πρόσθιας τροφοδότησης (FFN-Feed Forward Networks)

Ένα νευρικό δίκτυο πρόσθιας τροφοδότησης (**Σχήμα 3.6.**) είναι ένα τεχνητό νευρωνικό δίκτυο στο οποίο οι κόμβοι δεν σχηματίζουν ποτέ κύκλο. Σε αυτό το νευρωνικό δίκτυο, όλα οι νευρώνες

είναι διατεταγμένοι σε στρώματα όπου το επίπεδο εισόδου εισάγει δεδομένα και το επίπεδο εξόδου εξάγει δεδομένα. Τα κρυμμένα επίπεδα δεν έχουν καμία σχέση με τον εξωτερικό κόσμο, γι' αυτό και ονομάζονται κρυμμένα. Σε ένα νευρωνικό δίκτυο πρόσθιας τροφοδότησης, κάθε νευρώνας σε ένα επίπεδο συνδέεται με κάθε νευρώνα του επόμενου επιπέδου. Επομένως, όλοι οι νευρώνες είναι πλήρως συνδεδεμένοι. Κάτι άλλο που πρέπει να παρατηρήσουμε είναι ότι δεν υπάρχει ορατή ή αόρατη σύνδεση μεταξύ των νευρώνων στο ίδιο επίπεδο. Ως εκ τούτου, για να ελαχιστοποιήσουμε το σφάλμα στην πρόβλεψη, χρησιμοποιούμε γενικά τον αλγόριθμο backpropagation για να ενημερώσουμε τις τιμές των βαρών. Εφαρμόζονται κυρίως για συμπίεση δεδομένων, αναγνώριση μοτίβου, αναγνώριση στόχου Sonar, αναγνώρισης ομιλίας και αναγνώριση χειρόγραφων χαρακτήρων.




Σχήμα 3.6. Το μοντέλο FFN-Feed Forward Network

3.3.2. Επαναλαμβανόμενα νευρωνικά δίκτυα (RNN- Recurrent Neural Networks):

Τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN) (Σχήμα 3.7.) είναι μια παραλλαγή στα δίκτυα πρόσθιας τροφοδότησης (FF). Σε αυτόν τον τύπο, καθένας από τους νευρώνες σε κρυμμένα επίπεδα λαμβάνει μια είσοδο με συγκεκριμένη καθυστέρηση στο χρόνο. Αυτός ο τύπος νευρωνικού δικτύου χρησιμοποιείται όπου πρέπει να έχουμε πρόσβαση σε προηγούμενες πληροφορίες σε τρέχουσες επαναλήψεις. Για παράδειγμα, όταν προσπαθούμε να προβλέψουμε

την επόμενη λέξη σε μια πρόταση, πρέπει πρώτα να γνωρίζουμε τις λέξεις που χρησιμοποιήθηκαν προηγουμένως.

Τα RNN μπορούν να επεξεργαστούν εισόδους και να μοιραστούν τυχόν μήκη και βάρη με την πάροδο του χρόνου. Το μέγεθος του μοντέλου δεν αυξάνεται με το μέγεθος των δεδομένων εισαγωγής και οι υπολογισμοί σε αυτό το μοντέλο λαμβάνουν υπόψη τις ιστορικές πληροφορίες. Ένα άλλο διακριτικό χαρακτηριστικό των επαναλαμβανόμενων νευρωνικών δικτύων είναι ότι μοιράζονται παραμέτρους σε κάθε επίπεδο του δικτύου. Ενώ τα πρόσθια τροφοδότησης δίκτυα έχουν διαφορετικά βάρη σε κάθε κόμβο, τα επαναλαμβανόμενα νευρωνικά δίκτυα μοιράζονται την ίδια παράμετρο βάρους σε κάθε επίπεδο του δικτύου. Τούτου λεχθέντος, αυτά τα βάρη εξακολουθούν να προσαρμόζονται μέσω των διαδικασιών του backpropagation και της κατάβασης κλίσης για να διευκολυνθεί η εκμάθηση ενίσχυσης.



Σχήμα 3.7. Το μοντέλο RNN- Recurrent Neural Network


Τα επαναλαμβανόμενα νευρικά δίκτυα αξιοποιούν τον αλγόριθμο backpropagation μέσω του χρόνου (BPTT- backpropagation through time) για τον προσδιορισμό των βαρών, ο οποίος είναι ελαφρώς διαφορετικός από τον παραδοσιακό αλγόριθμο backpropagation καθώς είναι συγκεκριμένος για τα δεδομένα αλληλουχίας. Οι αρχές του BPTT είναι οι ίδιες με τον παραδοσιακό αλγόριθμο backpropagation, όπου το μοντέλο εκπαιδεύεται υπολογίζοντας τα σφάλματα από το επίπεδο εξόδου στο επίπεδο εισόδου του. Αυτοί οι υπολογισμοί μας επιτρέπουν να προσαρμόζουμε και να προσαρμόζουμε κατάλληλα τις παραμέτρους του μοντέλου. Το BPTT διαφέρει από την παραδοσιακή προσέγγιση στο ότι το BPTT αθροίζει τα σφάλματα σε κάθε

χρονικό βήμα, ενώ τα δίκτυα τροφοδοσίας δεν χρειάζεται να αθροίζουν σφάλματα καθώς δεν μοιράζονται παραμέτρους σε κάθε επίπεδο.

Βασικό πρόβλημα με αυτόν τον τύπο νευρωνικού δικτύου είναι η αργή υπολογιστική ταχύτητα. Επιπλέον, δεν μπορεί να εξετάσει μελλοντικά στοιχεία για την τρέχουσα κατάσταση και δεν "θυμάται" πληροφορίες που μπορεί να έχουν προηγηθεί αρκετά νωρίτερα. Εφαρμόζονται κυρίως σε μηχανική μετάφραση, πρόβλεψη χρονοσειρών, αναγνώριση ομιλίας, σύνθεση ομιλίας, ανίχνευση ανωμαλίας χρονοσειρών, εκμάθηση ρυθμού, μουσική σύνθεση.

3.3.3. Μακροπρόθεσμης / βραχυπρόθεσμης μνήμης (LSTM- Long/Short Term Memory)

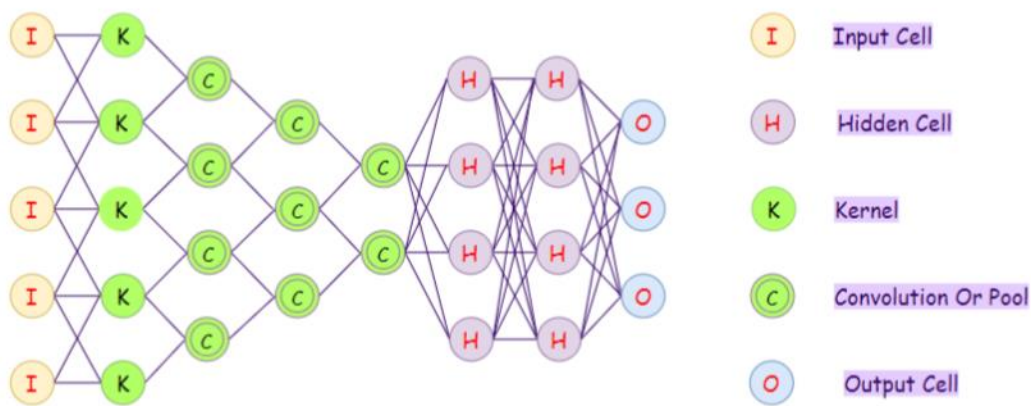
Πρόκειται για μια δημοφιλή αρχιτεκτονική RNN, η οποία εισήχθη από τους **Sepp Hochreiter** και **Juergen Schmidhuber** ως λύση στο πρόβλημα της εξάλειψης της κλίσης (gradient). Στην εργασία τους εργάστηκαν για την αντιμετώπιση του προβλήματος των μακροπρόθεσμων εξαρτήσεων. Τα δίκτυα LSTM (**Σχήμα 3.8.**) εισάγουν ένα νευρώνα μνήμης. Μπορούν να επεξεργαστούν δεδομένα με κενά μνήμης. Στο παρακάτω σχήμα, μπορούμε να παρατηρήσουμε ότι μπορούμε να εξετάσουμε τη χρονική καθυστέρηση στα RNN, αλλά εάν το RNN μας αποτύχει όταν έχουμε μεγάλο αριθμό σχετικών δεδομένων και θέλουμε να μάθουμε αυτά τα σχετικά δεδομένα από αυτό, τότε τα LSTM είναι ο τρόπος να το κάνουμε. Επίσης, τα RNN δεν μπορούν να θυμούνται δεδομένα που μπορεί να έχουν προηγηθεί αρκετά νωρίτερα, σε αντίθεση με τα LSTM που μπορούν. Εφαρμόζονται κυρίως για αναγνώρισης ομιλίας και αναγνώριση γραφής.



Σχήμα 3.8. Το μοντέλο LSTM- Long/Short Term Memory

3.3.4. Συνελκτικὰ νευρωνικά δίκτυα (CNN-Convolutional Neural Networks):

Τα Convolutional Neural Networks (**Σχήμα 3.9.**) είναι νευρωνικά δίκτυα που χρησιμοποιούνται κυρίως για την ταξινόμηση των εικόνων, τη συγκέντρωση εικόνων και την αναγνώριση αντικειμένων. Τα CNN επιτρέπουν την μη εποπτευόμενη κατασκευή ιεραρχικών αναπαραστάσεων εικόνας. Μια συνέλιξη είναι η απλή εφαρμογή ενός φίλτρου σε μια είσοδο που οδηγεί σε ενεργοποίηση. Η επαναλαμβανόμενη εφαρμογή του ίδιου φίλτρου σε μια είσοδο οδηγεί σε έναν χάρτη ενεργοποιήσεων που ονομάζεται χάρτης δυνατοτήτων, υποδεικνύοντας τις θέσεις και τη δύναμη ενός ανιχνευμένου χαρακτηριστικού σε μια είσοδο, όπως μια εικόνα. Η καινοτομία των συνελκτικών νευρωνικών δικτύων είναι η ικανότητα αυτόματης εκμάθησης ενός μεγάλου αριθμού φίλτρων παράλληλα ειδικά για ένα σύνολο δεδομένων εκπαίδευσης υπό τους περιορισμούς ενός συγκεκριμένου προβλήματος προγνωστικής μοντελοποίησης, όπως η ταξινόμηση εικόνας.



Σχήμα 3.9. Το μοντέλο CNN-Convolutional Neural Network

Το αποτέλεσμα είναι εξαιρετικά συγκεκριμένες δυνατότητες που μπορούν να εντοπιστούν οπουδήποτε στις εικόνες εισόδου.

- Τα συνελκτικὰ νευρωνικά δίκτυα εφαρμόζουν ένα φίλτρο σε μια είσοδο για τη δημιουργία ενός χάρτη δυνατοτήτων που συνοψίζει την παρουσία των εντοπισμένων χαρακτηριστικών στην είσοδο.

- Τα φίλτρα μπορούν να κατασκευαστούν χειροποίητα, όπως ανιχνευτές γραμμής, αλλά η καινοτομία των συνελκτικών νευρωνικών δικτύων είναι η εκμάθηση των φίλτρων κατά την προπόνηση στο πλαίσιο ενός συγκεκριμένου προβλήματος πρόβλεψης.

3.4. Γλώσσα Python και ΤΝΔ

Η Python είναι διερμηνευόμενη (interpreted), γενικού σκοπού (general-purpose) και υψηλού επιπέδου, γλώσσα προγραμματισμού. Ανήκει στις γλώσσες προστακτικού προγραμματισμού (Imperative programming) και υποστηρίζει τόσο το διαδικαστικό (procedural programming) όσο και το αντικειμενοστραφές (object-oriented programming) προγραμματιστικό υπόδειγμα. Δημιουργήθηκε από τον Ολλανδό Γκίντο βαν Ρόσσουμ (Guido van Rossum) στο ερευνητικό κέντρο Centrum Wiskunde & Informatica (CWI) το 1989 και κυκλοφόρησε για πρώτη φορά το 1991. Ο κύριος στόχος της είναι η αναγνωσιμότητα του κώδικά της και η ευκολία χρήσης της. Το συντακτικό της επιτρέπει στους προγραμματιστές να εκφράσουν έννοιες σε λιγότερες γραμμές κώδικα από ότι θα ήταν δυνατόν σε γλώσσες όπως η C++ ή η Java. Διακρίνεται λόγω του ότι έχει πολλές βιβλιοθήκες που διευκολύνουν ιδιαίτερα αρκετές συνηθισμένες εργασίες και για την ταχύτητα εκμάθησής της. Μειονεκτεί στο ότι επειδή είναι διερμηνευόμενη είναι πιο αργή από τις μεταγλωττιζόμενες (compiled) γλώσσες όπως η C και η C++. Για αυτόν τον λόγο δεν είναι κατάλληλη για γραφή λειτουργικών συστημάτων. Οι διερμηνευτές της Python είναι διαθέσιμοι για εγκατάσταση σε πολλά λειτουργικά συστήματα, επιτρέποντας στην Python την εκτέλεση κώδικα σε ευρεία γκάμα συστημάτων. Η Python αναπτύσσεται ως ανοιχτό λογισμικό (open source) και η διαχείρισή της γίνεται από τον μη κερδοσκοπικό οργανισμό Python Software Foundation.

Στα μέσα της δεκαετίας του 2000, υπήρξε μια εκθετική αύξηση του όγκου δεδομένων που οι εταιρείες αποθήκευαν, παρακολουθούσαν και διαχειριζόντουσαν. Επιπλέον, από το 2005 και μετά, οι εταιρείες κοινωνικών μέσων δικτύωσης όπως το Facebook, το Instagram, το YouTube και το Twitter είχαν επίσης γίνει δημοφιλείς. Λόγω της ευκολίας χρήσης της Python, αυτές οι νέες εταιρείες την βρήκαν ως την πιο οικονομική λύση για την πρόωμη ανάπτυξη, με αποτέλεσμα να γίνει η γλώσσα επιλογής για τη διαχείριση δεδομένων κοινωνικών μέσων δικτύωσης. Μετά την οικονομική κρίση του 2008, , αυτές οι εταιρείες επέλεξαν να αντικαταστήσουν στοιχεία της «ανθρώπινης» παρέμβασης στις ροές εργασίας τους με ισοδύναμα τεχνητής νοημοσύνης, με

αποτέλεσμα καθαρότερους τρόπους για τη διαχείριση των τεράστιων όγκων δεδομένων που παράγει καθημερινά ο χρηματοοικονομικός κόσμος.

Με τα δεδομένα να πολλαπλασιάζονται, η μηχανική μάθηση και η επιστήμη των δεδομένων έγινε σύντομα η νέα «καυτή» καριέρα για προγραμματιστές. Μαζί με αυτήν τη μετατόπιση της ζήτησης από τον προγραμματισμό λογισμικού στην επιστήμη των δεδομένων προέκυψε η ανάγκη ενοποίησης εργαλείων. Την προσπάθεια που ξεκίνησε στην έρευνα και τη χρηματοδότηση υπερασπίστηκαν μεγάλες εταιρείες τεχνολογίας όπως η Google και το Facebook, συμπεριλαμβανομένων των παρακάτω 3 βιβλιοθηκών Python:

Pandas: ένα έργο που ξεκίνησε από τον Wes McKinney το 2008 για την εκτέλεση ποσοτικής ανάλυσης με οικονομικά δεδομένα.

Scikit-learn: ξεκίνησε το 2007 από τον David Courvapeau, που επιτρέπει στους προγραμματιστές να χρησιμοποιούν αλγόριθμους μηχανικής μάθησης και επιστήμης δεδομένων.

Matplotlib: ξεκίνησε το 2008 από τον John D. Hunter για να μεταφέρει πολλές από τις λειτουργίες γραφικών παραστάσεων της MATLAB στην Python.

Αναπτύχθηκαν εργαλεία, συμβάσεις κωδικοποίησης, βέλτιστες πρακτικές, αλγόριθμοι και κλιμακωτές λύσεις χρησιμοποιώντας το Python, συμπεριλαμβανομένων των παρακάτω παραδειγμάτων:

TensorFlow: ένα έργο που ξεκίνησε η Google το 2015 για να επιτρέψει καλύτερη οπτικοποίηση δεδομένων στη ροή εργασίας της επιστήμης δεδομένων και της μηχανικής μάθησης.

Seaborn: ξεκίνησε από τον Michael Waskom το 2012 για να βελτιώσει τα εργαλεία οπτικοποίησης δεδομένων στην επιστημονική κοινότητα υπολογιστών.

Με την Python τώρα τη γλώσσα επιλογής στη μηχανική μάθηση και την επιστήμη δεδομένων, οι προγραμματιστές άρχισαν να συνεργάζονται στενά με επιστήμονες δεδομένων, μηχανικούς μηχανικής μάθησης και ερευνητές για την ανάπτυξη πιο εξελιγμένων εφαρμογών AI. Στην συγκεκριμένη Διπλωματική εργασία χρησιμοποιούνται όλα τα παραπάνω εργαλεία όπως επίσης οι βιβλιοθήκες του Keras για την μοντελοποίηση ΤΝΔ.

3.5. Είδη Μάθησης

Όσο αφορά την ανακάλυψη των συσχετίσεων που υπάρχουν στα δεδομένα, ο τύπος Μηχανικής Μάθησης που χρησιμοποιείται είναι η ανεπιτήρητη μάθηση (unsupervised learning). Στον συγκεκριμένο τύπο μάθησης δεν δίνουμε στο νευρωνικό δίκτυο κάποια απάντηση μέσω της βάσης δεδομένων, απλά του την παρουσιάζουμε και το αφήνουμε να κάνει αυτό τις συσχετίσεις που καταλαβαίνει. Για παράδειγμα δίνοντας στο νευρωνικό δίκτυο ως είσοδο κάποια χρωματιστά σχήματα ποικίλου μεγέθους και χρησιμοποιώντας έναν αλγόριθμο για την κατηγοριοποίηση αυτών των χρωματιστών σχημάτων με κάποιο κριτήριο ομοιότητας, δίχως να του παρέχουμε την πληροφορία σε ποια κατηγορία ανήκει κάθε χρωματιστό σχήμα ώστε να "εκπαιδευτεί" πάνω σε αυτό, εκείνο θα προσπαθήσει να δημιουργήσει δικά του κριτήρια για την κατηγοριοποίηση αυτή. Δηλαδή η κατηγοριοποίηση που μπορεί να δημιουργήσει το νευρωνικό δίκτυο μπορεί να αφορά το σχήμα, το χρώμα, το μέγεθος. Με αυτόν τον τρόπο βρίσκεται θέση να "ανακαλύψει" συσχετίσεις που υπάρχουν στα δεδομένα που διαφορετικά εμείς δεν θα μπορούσαμε να παρατηρήσουμε (latent variables). Από την άλλη μεριά έχουμε το δεύτερο είδος Μηχανικής Μάθησης, την επιβλεπόμενη μάθηση (supervised learning), όπου σε αυτήν την περίπτωση έχουμε ένα σύνολο απαντήσεων στη βάση δεδομένων από τις οποίες το μοντέλο μπορεί να εκπαιδευτεί. Δηλαδή δίνουμε στο νευρωνικό δίκτυο ένα μεγάλο κομμάτι (60%-80%) της βάσης δεδομένων παρατήρησης που την ονομάζουμε "σύνολο δεδομένων εκπαίδευσης" με σκοπό να θεμελιώσει σχέσεις μεταξύ των παραμέτρων και των ζητούμενων που θέλουμε. Έπειτα εισάγουμε στο νευρωνικό δίκτυο δεδομένα από την ίδια βάση δεδομένων παρατήρησης τα οποία δεν έχει ξανασυναντήσει (σύνολο δεδομένων ελέγχου $\approx 20\%$) με σκοπό να προσπαθήσει να προβλέψει την πληροφορία που αναζητάμε βάση της "εκπαίδευσης" που προηγήθηκε. Με αυτόν τον τρόπο μπορούμε να αξιολογήσουμε τις προβλέψεις του νευρωνικού δικτύου καθώς γνωρίζουμε τις σωστές απαντήσεις ήδη. Στην περίπτωση που το μοντέλο μας λειτουργεί με ένα σεβαστό ποσοστό επιτυχίας πρόβλεψης, το οποίο ποικίλει αναλόγως τον επιστημονικό τομέα που εφαρμόζεται το μοντέλο, τότε μπορούμε να θεωρήσουμε ότι θα καταφέρει να προβλέψει το ζητούμενο το ίδιο καλά από μελλοντικές βάσεις δεδομένων παρατήρησης που έχουν τα ίδια χαρακτηριστικά. Στη παρούσα Διπλωματική εργασία ο τύπος Μηχανικής Μάθησης που χρησιμοποιήθηκε είναι αυτός της επιβλεπόμενης μάθησης (supervised learning).

3.6. Χωρισμός βάσης δεδομένων


Όσο αφορά τον χωρισμό της βάσης δεδομένων παρατήρησης θα πρέπει να είμαστε προσεκτικοί. Το σύνολο δεδομένων εκπαίδευσης (*Εικόνα 3.1.*) και το σύνολο δεδομένων ελέγχου (*Εικόνα 3.2.*) πρέπει να είναι αρκετά μεγάλα σε μέγεθος ώστε να είναι αντιπροσωπευτικά δείγματα της συνολικής βάσης δεδομένων παρατήρησης. Δηλαδή να περιλαμβάνουν και οι δύο βάσεις όλες τις πληροφορίες που θέλουμε. Ο χωρισμός πρέπει να είναι τυχαίος αλλά και κατανομημένος καθώς θέλουμε να διατηρήσουμε τα μοτίβα της βάσης δεδομένων ανέπαφα (*Εικόνα 3.3. και Εικόνα 3.4.*). Με αυτόν το τρόπο προστατεύουμε το μοντέλο μας από το φαινόμενο της υπερβολικής απομνημόνευσης των δεδομένων (overfitting). Δηλαδή αν το μοντέλο μας προσπαθεί να επικεντρωθεί στο να προβλέψει, εκτός από τις συμβατικές, όλες τις ακραίες τιμές στη συγκεκριμένη βάση δεδομένων πολύ πιθανόν να καταλήξει σε υπερβολική απομνημόνευση και να μην ανταπεξέλθει σε καινούρια δεδομένα που δεν έχει ξανασυναντήσει.

	Lithology	Lithology.1	Lithology.2	Lithology.3	Lithology.4	Lithology.5	RMR	Thrust (kN)	category
304	0	0	0	0	1	0	64.0	6735.344828	4
260	0	0	0	0	1	0	78.0	6983.536585	4
72	0	0	0	1	0	0	61.0	6025.000000	3
154	0	0	1	0	0	0	36.0	3095.967742	2
307	0	1	0	0	0	0	55.0	5453.977273	1
...
70	0	0	0	1	0	0	79.0	5557.352941	3
135	0	0	0	0	1	0	70.0	7163.157895	4
64	0	1	0	0	0	0	52.0	5692.708333	1
248	0	0	0	0	1	0	68.0	5650.000000	4
216	0	1	0	0	0	0	35.0	5975.000000	1


Εικόνα 3.1. Σύνολο δεδομένων εκπαίδευσης στην συγκεκριμένη Διπλωματική Εργασία

	Lithology	Lithology.1	Lithology.2	Lithology.3	Lithology.4	Lithology.5	RMR	Thrust (kN)	category
193	0	0	0	0	0	1	0.750000	0.838345	5
158	1	0	0	0	0	0	0.572917	0.569335	0
140	0	0	0	0	1	0	0.697917	0.781085	4
206	0	0	0	0	0	1	0.875000	0.926075	5
147	0	0	0	0	1	0	0.572917	0.789443	4
...
37	1	0	0	0	0	0	0.562500	0.482221	0
183	1	0	0	0	0	0	0.812500	0.533316	0
194	0	0	0	0	0	1	0.750000	0.713497	5
129	0	0	0	0	1	0	0.885417	0.824319	4
94	0	0	1	0	0	0	0.489583	0.440434	2

Εικόνα 3.2. Σύνολο δεδομένων ελέγχου στην συγκεκριμένη Διπλωματική Εργασία






Εικόνα 3.3. Ιστόγραμμα ποσοστών των κατηγοριών των πετρωμάτων στη βάση δεδομένων εκπαίδευσης στην συγκεκριμένη Διπλωματική Εργασία



Εικόνα 3.4. Ιστόγραμμα ποσοστών των κατηγοριών των πετρωμάτων στη βάση δεδομένων ελέγχου στην συγκεκριμένη Διπλωματική Εργασία

3.7. Εκπαίδευση ΤΝΔ

Όπως αναφέρθηκε και προηγουμένως κοιτώντας έναν νευρώνα σε ένα κρυφό επίπεδο θα δούμε ότι συνδέεται με όλους τους υπόλοιπους νευρώνες του προηγούμενου επιπέδου. Τα βάρη στο άθροισμα των συντελεστών μαζί με την παράμετρο bias αποφασίζουν αν θα ενεργοποιηθεί ή όχι. Στην ουσία αυτό το “ζυγισμένο” άθροισμα δείχνει το πόσο δυνατές είναι οι συνδέσεις του νευρώνα αυτού με το προηγούμενο επίπεδο. Οπότε καταλαβαίνουμε ότι ξεκινώντας την εκπαίδευση ενός νευρωνικού δικτύου πρέπει να γίνει τυχαία αρχικοποίηση των βαρών και των παραμέτρων bias ώστε να μην ανακατευτούμε εμμέσως στην εκπαίδευση. Η ελάχιστη τιμή της συνάρτησης κόστους, ακόμα και αν αυτή η συνάρτηση είναι απλή, δεν είναι κάτι το οποίο υπολογίζεται εύκολα. Ένα πέρασμα από όλα τα ζευγάρια διανυσμάτων εκπαίδευσης εισόδου και διανυσμάτων στόχων εξόδου, ονομάζεται εποχή (epochs) ή κύκλος επανάληψης. Σχεδόν πάντα χρειάζεται ένας μεγάλος αριθμός εποχών (επαναλήψεων) για την εκπαίδευση ενός ΤΝΔ πρόσθιας τροφοδότησης, δηλαδή να επιτευχθεί η σύγκλιση του σφάλματος κάτω από ένα προκαθορισμένο επίπεδο. Το σφάλμα είναι μια συνάρτηση κόστους με μεταβλητές τους συντελεστές βαρύτητας και στόχος είναι η ελαχιστοποίησή του, μεταβάλλοντας τις τιμές των συντελεστών. Με έναν μεγάλο αριθμό εκπαιδεύσεων μπορούμε ίσως να μάθουμε αν βρισκόμαστε σε τοπικό ή ολικό ελάχιστο της συνάρτησης. Για να μπορέσουμε να το κάνουμε εικόνα μπορούμε να φανταστούμε τις τυχαίες αρχικοποιήσεις των παραμέτρων ως μπάλες που βρίσκονται πάνω στην συνάρτηση. Ανάλογα με την τυχαία αρχικοποίηση που έχει γίνει οι “κοιλιάδες” στις οποίες μπορούν να καταλήξουν οι μπάλες αυτές ποικίλλουν χωρίς να ξέρουμε με σιγουριά αν βρισκόμαστε στο ολικό ελάχιστο της συνάρτησης άρα και στην ελάχιστη τιμή της (**Εικόνα 3.5**.) Αν το ξέραμε η εκπαίδευση του συγκεκριμένου μοντέλου θεωρείται ολοκληρωμένη και δεν μπορεί με τα συγκεκριμένα χαρακτηριστικά να εκπαιδευτεί περαιτέρω. Η αποτελεσματική και γρήγορη μείωση τις τιμές της συνάρτησης του κόστους γίνεται μέσω της στοχαστικής κλίσης καθόδου από τα μαθηματικά (SGD-Stochastic Gradient Descent). Το ανάδελτα της συνάρτησης δείχνει την κατεύθυνση της κλίσης με την οποία η συνάρτηση θα αυξηθεί γρηγορότερα και, όπως είναι φυσικό η αρνητική τιμή του ανάδελτα είναι η κλίση η οποία πρέπει να ακολουθηθεί ώστε να μειωθεί με τον ταχύτερο τρόπο η τιμή της συνάρτησης κόστους.



Εικόνα 3.5. Τυχαία αρχικοποίηση δεδομένων και σταδιακή κάθοδος σε τοπικά ελάχιστα ή στο ολικό ελάχιστο της συνάρτησης.

Το ΤΝΔ θα ξεκινήσει τη μάθηση του και εμείς παρακολουθούμε την εκπαίδευση με μαθηματικούς τρόπους. Προσθέτοντας τα τετράγωνα των διαφορών μεταξύ των πραγματικών τιμών και των τιμών που προβλέπει το νευρωνικό δίκτυο διαμορφώνουμε μία συνάρτηση κόστους για το ΤΝΔ. Όπως είναι λογικό το άθροισμα αυτό θα είναι μικρό όσο το ΤΝΔ προβλέπει σχετικά σωστά τις τιμές αλλά μεγάλο όταν δεν καταλαβαίνει αυτό που πρέπει να κάνει. Αυτός είναι ο κύκλος ενός παραδείγματος εκπαίδευσης. Στην συνέχεια υπολογίζοντας τη μέση τιμή αυτής της συνάρτησης κόστους όλων των παραδειγμάτων εκπαίδευσης (MSE-Mean Squared Error) μπορούμε να καταλάβουμε πόσο καλή είναι η επίδοση του συγκεκριμένου ΤΝΔ.

Για παράδειγμα αν a_k είναι η πραγματική τιμή ελέγχου και t_k η αντίστοιχη τιμή που υπολογίζεται από το ΤΝΔ, τότε το MSE δίνεται από τον ακόλουθο τύπο:


$$MSE = \frac{1}{q} \sum_{k=1}^q e_k^2 = \frac{1}{q} \sum_{k=1}^q (t_k - a_k)^2, \text{ για } k=1, \dots, q.$$

3.7.1. Αλγόριθμος της οπισθόδρομης διάδοσης των σφαλμάτων

Ο βασικός αλγόριθμος για τον πολύπλοκο υπολογισμό του ανάδελτα της συνάρτησης κόστους είναι ο αλγόριθμος της οπισθόδρομης διάδοσης των σφαλμάτων (backpropagation of error). Εφόσον μιλάμε για το βασικό γρανάζι της εκπαίδευσης θα εξηγήσουμε με μαθηματικό τρόπο την λειτουργία του. Σε περίπτωση που πρέπει να αυξηθεί το πόσο ενεργοποιείται ένας νευρώνας υπάρχουν τρεις τρόποι με τους οποίους θα προσπαθήσει το νευρωνικό να το επιτύχει:


1. Να αυξηθεί η παράμετρος του bias.
2. Να αυξηθούν τα βάρη που συνδέουν τον νευρώνα με τους νευρώνες του προηγούμενου επιπέδου.
3. Να αλλάξουμε την συνάρτηση ενεργοποίησης από το προηγούμενο επίπεδο στο υποκείμενο επίπεδο που βρίσκεται ο συγκεκριμένος νευρώνας.

Για να κρατήσουμε τους μαθηματικούς τύπους σε απλό επίπεδο θα πάρουμε ένα παράδειγμα ενός ΤΝΔ με δύο κρυφά επίπεδα και έναν νευρώνα σε κάθε επίπεδο (**Εικόνα 3.6**). Σκοπός μας είναι να δούμε πόσο ευαίσθητη είναι αυτή η συνάρτηση στις παραμέτρους από τις οποίες αποτελείται. Με αυτόν το τρόπο μπορούμε και εμείς να καταλάβουμε ποια αλλαγή θα είναι αυτή που θα έχει την μεγαλύτερη επιρροή στην μείωση της συνάρτησης κόστους.



Εικόνα 3.6. ΤΝΔ με δύο κρυφά επίπεδα και έναν νευρώνα σε κάθε επίπεδο

Για να απλοποιήσουμε ακόμα περισσότερο το επίπεδο των μαθηματικών και να μπορέσουμε να καταλάβουμε το νόημα του αλγορίθμου θα επικεντρωθούμε στη σύνδεση των τελευταίων 2 νευρώνων (**Εικόνα 3.7.**).



Εικόνα 3.7. Αναπαράσταση εξισώσεων τελευταίων 2 νευρώνων

Ονομάζουμε την ενεργοποίηση του τελευταίου νευρώνα ($\alpha^{(L)}$) και την ενεργοποίηση του νευρώνα στο ακριβώς προηγούμενο επίπεδο $\alpha^{(L-1)}$. Ονομάζουμε y (0 ή 1) την επιθυμητή έξοδο που θέλουμε το ΤΝΔ να δώσει για ένα συγκεκριμένο αριθμό παραδειγμάτων. Η συνάρτηση κόστους αυτού του απλού ΤΝΔ για ένα συγκεκριμένο παράδειγμα εκπαίδευσης ορίζεται ως:

$$C_0(\dots) = (\alpha^{(L)} - y)^2$$

Η τελευταία ενεργοποίηση του νευρώνα ($\alpha^{(L)}$) διαμορφώνεται από ένα βάρος ($b^{(L)}$), την ενεργοποίηση του προηγούμενου νευρώνα ($\alpha^{(L-1)}$), και το bias ($b^{(L)}$) ως εξής:

$$z^{(L)} = w^{(L)} * \alpha^{(L-1)} + b^{(L)}$$

$\alpha^{(L)} = \sigma(z^{(L)})$, όπου σ , η σιγμοειδής συνάρτηση.

Εφόσον θέσαμε τους τύπους, θα πρέπει να έχουμε υπόψιν ότι μιλάμε για αριθμούς. Οπότε μπορούμε να φανταστούμε ότι αυτές οι παράμετροι ανήκουν πάνω σε αριθμογραμμές. Ο πρώτος μας στόχος είναι να βρούμε πόσο ευαίσθητη είναι η αριθμογραμμή της συνάρτησης κόστους (C_0) σε μία μικρή αλλαγή στην αριθμογραμμή του βάρους ($w^{(L)}$). Πιο συγκεκριμένα ποια είναι παράγωγος της συνάρτησης κόστους (C_0) συναρτήσει του βάρους ($w^{(L)}$):

$$dC_0 / dw^{(L)}$$

Εφόσον οι παραπάνω διαμορφωμένες σχέσεις είναι αλυσιδωτές, καταλήγουμε εύκολα ότι το ποσοστό αλλαγής στην συνάρτηση κόστους συναρτήσει του βάρους διαμορφώνεται ως εξής:

$$dC_0 / dw^{(L)} = dz^{(L)} / dw^{(L)} * d\alpha^{(L)} / dz^{(L)} * dC_0 / d\alpha^{(L)}$$

όπου:

$$dC_0 / d\alpha^{(L)} = 2 * (\alpha^{(L)} - y),$$

$$d\alpha^{(L)} / dz^{(L)} = \sigma'(z^{(L)}),$$

$$dz^{(L)} / dw^{(L)} = \alpha^{(L-1)}$$

Κοιτώντας την περίπτωση της τελευταίας παραγώγου καταλαβαίνουμε αυτή η μικρή αλλαγή στην αριθμογραμμή του βάρους ($w^{(L)}$) επηρεάζει τον τελευταίο νευρώνα βάσει του βαθμού ενεργοποίησης του προηγούμενου νευρώνα.

Όλα τα παραπάνω αποτελούν τον υπολογισμό της παραγώγου της συνάρτησης κόστους (C_0) συναρτήσει του βάρους ($w^{(L)}$) για ένα παράδειγμα εκπαίδευσης. Ο υπολογισμός για όλα τα παραδείγματα n υπολογίζεται ως εξής:

$$dC / dw^{(L)} = 1/n * \sum_{k=0}^{n-1} dC_k / dw^{(L)}$$

Στο συγκεκριμένο παράδειγμα πηγαίνοντας με μικρά βήματα και απομονώνοντας 2 νευρώνες, εξετάσαμε την παράγωγο της συνάρτησης κόστους (C_0) συναρτήσει του βάρους ($w^{(L)}$). Με τον ίδιο τρόπο θα υπολογίζαμε και τη παράγωγο της συνάρτησης κόστους (C_0) συναρτήσει του bias

(b^L) κ.ο.κ. Και σαφώς η επανάληψη της διαδικασίας συνεχίζεται στους νευρώνες που προηγούνται των 2 επιπέδων που διαλέξαμε στο παράδειγμά μας.

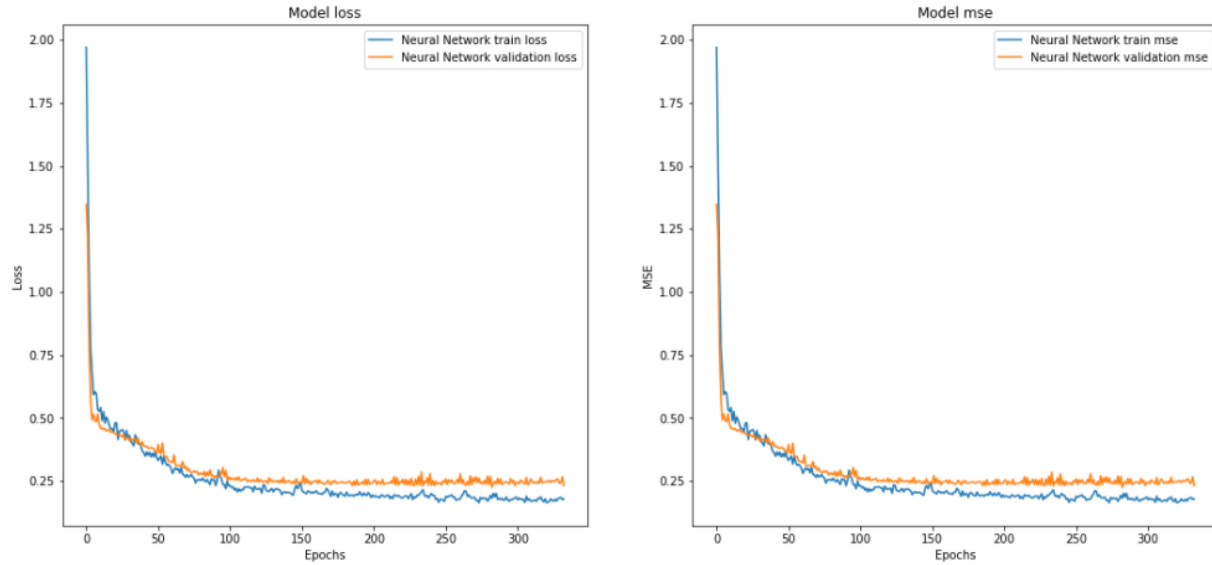
3.7.2 Εκπαίδευση ΤΝΔ έλεγχος γενίκευσης

Το κυριότερο πρόβλημα που αντιμετωπίζεται σε εκπαιδευμένα ΤΝΔ, είναι το φαινόμενο της υπερβολικής απομνημόνευσης των δεδομένων (overfitting). Στις συγκεκριμένες περιπτώσεις, το μοντέλο έχει την ικανότητα να μαθαίνει τα δεδομένα εκπαίδευσης με σφάλμα που τείνει στο μηδέν, αλλά το σφάλμα γενίκευσής του είναι πάρα πολύ μεγάλο. Αυτό σημαίνει ότι η μάθηση αφορά στα συγκεκριμένα δεδομένα εκπαίδευσης και μόνο σε αυτά, γεγονός που καθιστά το μοντέλο ανεπαρκές για να χρησιμοποιηθεί για προβλέψεις με βάση άλλα δεδομένα εισαγωγής. Η εμφάνιση του γεγονότος αυτού οφείλεται, τις περισσότερες φορές, στη χρήση αρκετά πολύπλοκων αρχιτεκτονικών με μεγάλο αριθμό νευρώνων. Δυστυχώς, δεν υπάρχουν κανόνες που να υπαγορεύουν το πλήθος των κρυμμένων επιπέδων και του πλήθους των νευρώνων που κάθε ένα από αυτά πρέπει να περιέχει.

Το γεγονός αυτό, επιβαρύνεται και από το ότι δεν υπάρχει μονοσήμαντη αντιστοιχία ανάμεσα στο εξεταζόμενο πρόβλημα και στη δομή της αρχιτεκτονικής του μοντέλου ΤΝΔ δηλαδή, μπορεί να υπάρχουν περισσότερα από ένα μοντέλα με διαφορετική αρχιτεκτονική το καθένα που να αποδίδουν το ίδιο καλά. Η σχέση που συνδέει τη δομή ενός ΤΝΔ και την πολυπλοκότητα του εξεταζόμενου προβλήματος είναι πολύ δύσκολο να περιγράψει γιατί εξαρτάται από ένα πολύ μεγάλο πλήθος παραγόντων. Ενδεικτικά και μόνο αναφέρονται, η χρήση δυαδικών ή δεκαδικών τιμών στις εισόδους, η ύπαρξη ή όχι θορύβου στα δεδομένα εκπαίδευσης και το είδος των χρησιμοποιούμενων συναρτήσεων ενεργοποίησης. Γενικά πάντως, ισχύει ότι όσο πολυπλοκότερη είναι η συνάρτηση κόστους που πρέπει να προσεγγιστεί (ύπαρξη πολλών διαφορετικών τοπικών ακροτάτων, αλλαγών καμπυλότητας, ασυνεχειών, κ.λ.π.) τόσο μεγαλύτερο πρέπει να είναι και το μέγεθος του ΤΝΔ, έτσι ώστε να είναι δυνατή η μοντελοποίηση αυτών των μη-γραμμικοτήτων.


Στο **Σχήμα 3.10**, φαίνονται τα γραφήματα εκπαίδευσης μίας από τις υπό εξέταση σήραγγες (Pieve) όπου στα αριστερά παρατηρούμε την πορεία της συνάρτησης απώλειας κατά την εκπαίδευση. Η συνάρτηση που προσπαθούμε να μεγιστοποιήσουμε ή να ελαχιστοποιήσουμε σε μία ανάλυση ονομάζεται συνάρτηση στόχου (objective function) ή κριτήριο. Όταν λοιπόν προσπαθούμε να την ελαχιστοποιήσουμε, όπως στην περίπτωσή μας, ονομάζεται συνάρτηση κόστους ή συνάρτηση

απόλειας ή συνάρτηση σφάλματος. Την ίδια πορεία του μετρούμενου σφάλματος MSE παρατηρούμε στα δεξιά.



Σχήμα 3.10. Παράδειγμα της εκπαίδευσης του τελικού μοντέλου της σήραγγας Pieve. Αριστερά βλέπουμε την συνάρτηση απόλειας και δεξιά το MSE.

Οι εκπαίδευση των μοντέλων όπως αναφέραμε και παραπάνω είναι μία διαδικασία δοκιμής και επανάληψης. Για το κάθε μοντέλο ΤΝΔ των υπό εξέταση σηράγγων εκτελέστηκαν τουλάχιστον 60 δοκιμές που αναφερόντουσαν στην αρχιτεκτονική τους, το ρυθμό μάθησης, τον αριθμό εισαγωγής δεδομένων σε κάθε επανάληψη αλλά και τα κριτήρια ολοκλήρωσης της εκπαίδευσης. Στο **Σχήμα 3.11.** παρουσιάζεται μία συμπεριφορά της γενίκευσης του ΤΝΔ για τη σήραγγα Varzo, στο σύνολο των δεδομένων ελέγχου που απορρίφθηκε καθώς ξεκάθαρα μπορούμε να παρατηρήσουμε ότι το νευρώτικο δίκτυο για οποιονδήποτε πιθανό λόγο δεν καταλαβαίνει τι πρέπει να υπολογίσει/προβλέψει και καταλήγει να εμφανίζει μία τιμή (μέσο όρο των τιμών ελέγχου).




Σχήμα 3.11. Συμπεριφορά της γενίκευσης του TNΔ για τη σήραγγα Varzo, στο σύνολο των δεδομένων ελέγχου που απορρίφθηκε

Κεφάλαιο 4. Λύσεις με την χρήση Τεχνητής Νοημοσύνης (Artificial Intelligence - A.I.)


Τα μηχανήματα ολομέτωπης κοπής για την όρυξη σηράγγων έχουν τύχει ευρείας αποδοχής όταν πρόκειται για την κατασκευή σηράγγων μεγάλου μήκους. Παρά το γεγονός ότι μπορούν να επιτύχουν αρκετά μεγάλες ταχύτητες προχώρησης, συχνά υπάρχουν προβλήματα της διατήρησης του αρχικά προβλεφθέντος ρυθμού εκσκαφής (Barla et al., 2000), γεγονός που έχει άμεση επίδραση στο τελικό κόστος του έργου (Alber, 2000). Γίνεται επομένως αναγκαία η δημιουργία συστημάτων, τα οποία με ακρίβεια θα δίνουν προβλέψεις για τον ρυθμό εκσκαφής και προχώρησης του έργου.

Στο παρελθόν έχουν γίνει προσπάθειες για την κατασκευή μοντέλων με τη χρήση της Μηχανικής μάθησης για την πρόγνωση επίδοσης του TBM είτε με πολλαπλή γραμμική παλινδρόμηση (Jamshidi 2018) (**Σχήμα 4.1.**) είτε με χρήση TND (Benardos 2004) (**Σχήμα 4.2.**), (Benardos 2008), (Yagiz, 2009) είτε με άλλες μεθόδους όπως η fuzzy logic (Ghasemi et. al., 2014) (**Σχήμα 4.3.**), όπου όλες παρουσίασαν πολύ θετικά αποτελέσματα. Αυτό μας δείχνει ότι όλη η πρότερη γνώση που έχουμε για την πρόβλεψη της προχώρησης TBM σε μία σήραγγα, παρόλο την αβεβαιότητα που διέπει το έργο, μπορεί να χρησιμοποιηθεί για την κατασκευή μοντέλων που εφαρμόζονται είτε κατά περίπτωση αλλά είτε και πιο γενικευμένα.

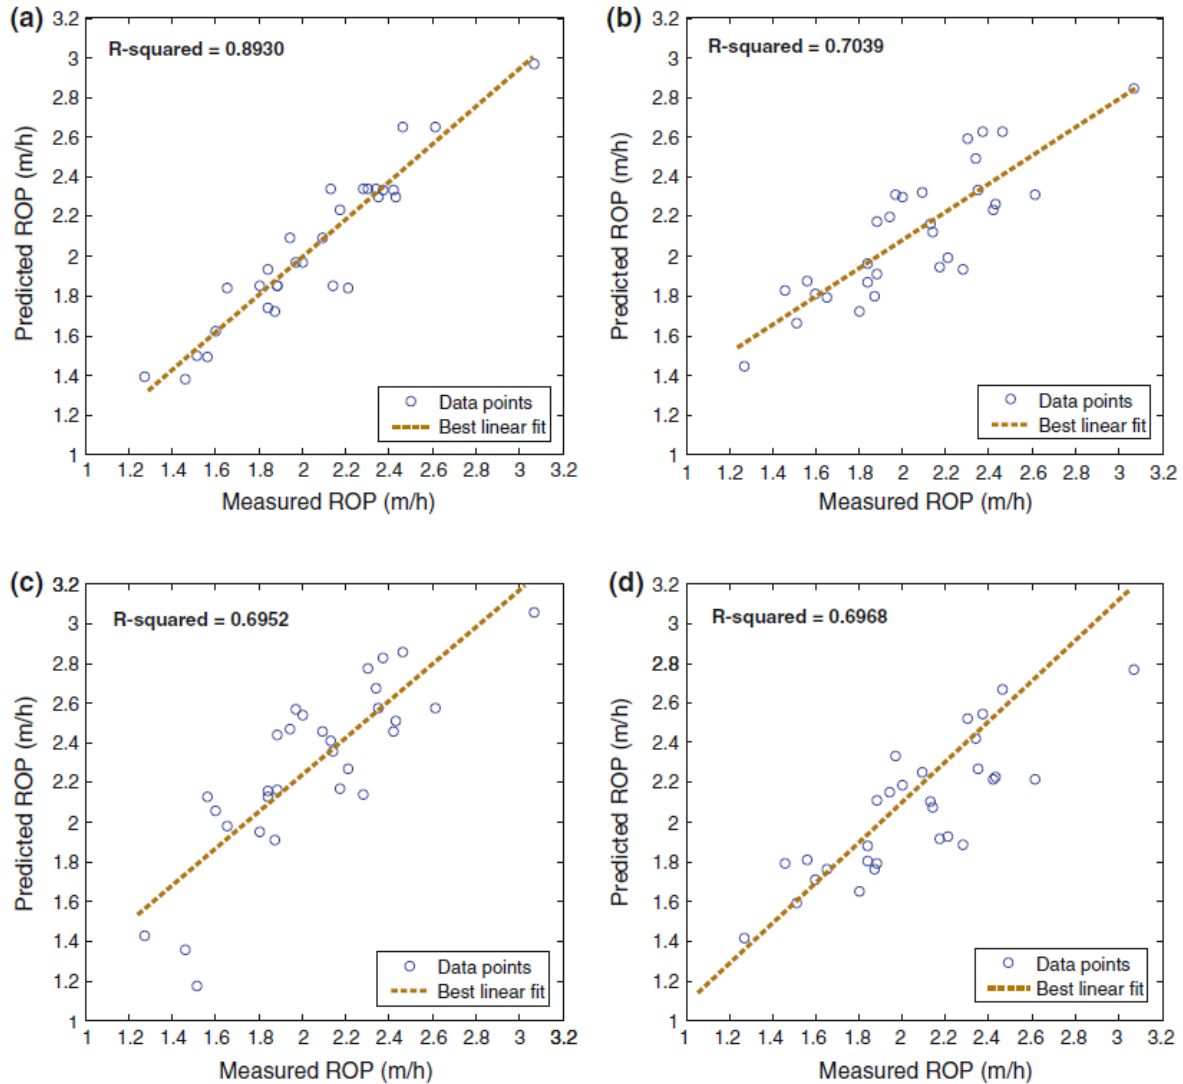
Η συλλογή δεδομένων από πραγματικές κατασκευές σηράγγων ήταν πάντα αναγκαία. Πλέον η συλλογή δεδομένων από κατασκευές σηράγγων με τη χρήση μηχανικών μέσων είναι η τροφή για τα μοντέλα τα οποία θα μπορέσουν να παραμετροποιηθούν όλο και περισσότερο φθάνοντας σε ακόμη πιο ακριβής προβλέψεις.



Σχήμα 4.1. Πραγματικές τιμές του PR από την μελέτη *Bilgin et al. (1993)* και οι τιμές πρόβλεψης του (*A. Jamshidi 2018*) από 2 διαφορετικές εξισώσεις (*M1* αριστερά και *M2* δεξιά) πολλαπλής γραμμικής παλινδρόμησης



Σχήμα 4.2. Παράδειγμα για αναμενόμενες τιμές του AR σε συνάρτηση με το RMR και το UCS για μία συγκεκριμένη τιμή του RQD του πετρώματος (*Benardos 2004*)



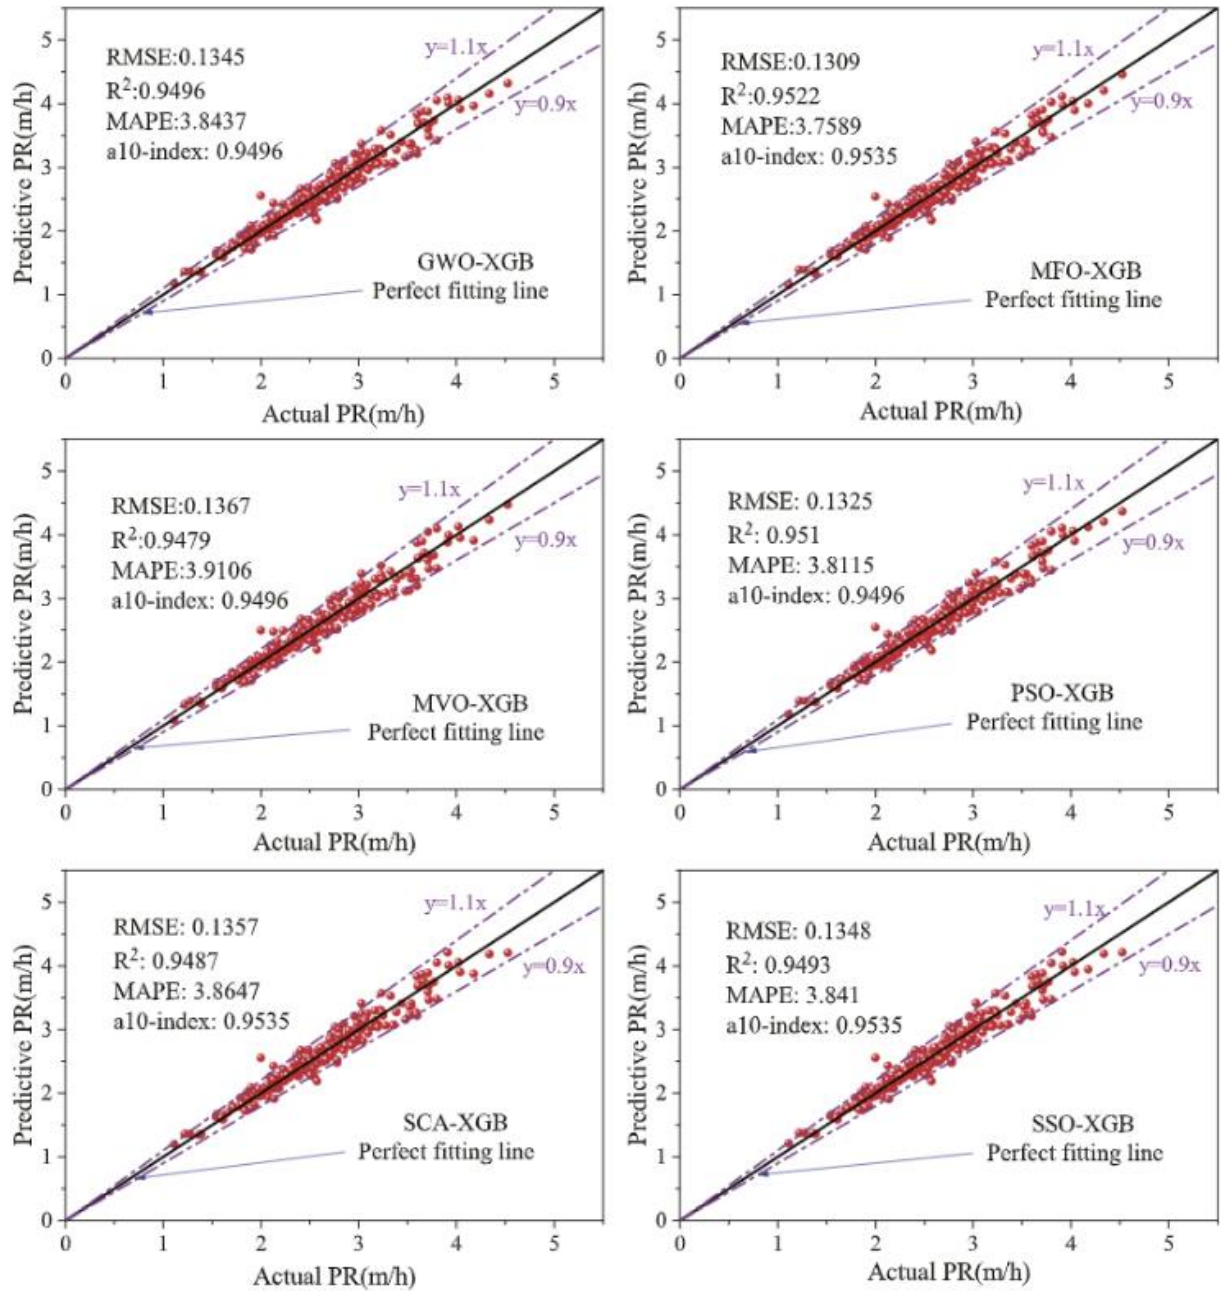
Σχήμα 4.3. Σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων τεσσάρων μοντέλων (Ghasemi et. Al., 2014)

4.1. Εφαρμογές πρόβλεψης ρυθμού προχώρησης και ρυθμού διείδυσης για TBM


Εκτός από τις εμπειρικές και θεωρητικές έρευνες, πολλοί ερευνητές έχουν εφαρμόσει διάφορες τεχνικές τεχνητής νοημοσύνης (AI) για την πρόβλεψη απόδοσης TBM. Για παράδειγμα, οι Grima, Bruines και Verhoef (2000) πρότειναν τη νευρο-ασαφή μέθοδο για να μοντελοποιήσουν την απόδοση των TBM για 640 TBM έργα. Οι Zhao, Gong, Zhang και Zhao (2007) εφάρμοσαν ένα μοντέλο πρόβλεψης απόδοσης TBM χρησιμοποιώντας σύνολο νευρωνικών δικτύων με 47 σύνολα δεδομένων. Σε μια άλλη έρευνα, οι Yagiz και Karahan (2011) εφάρμοσαν μια τεχνική

βελτιστοποίησης σωματιδίων (PSO) για την πρόβλεψη του ρυθμού διεισδυσής (PR) TBM σε σκληρό πετρώματα. Πρόσφατα, οι Armaghani et al. (2019) ανέπτυξε δύο υβριδικές τεχνικές βελτιστοποίησης με βάση το PSO και έναν αλγόριθμο (ICA) για την πρόβλεψη του AR του TBM σε διαφορετικές επιφανειακές καταστάσεις γρανίτη. Τα προαναφερθέντα μοντέλα έχουν τόσο πλεονεκτήματα όσο και μειονεκτήματα, και έχουν καταβληθεί προσπάθειες για την ενίσχυση της ακρίβειας αυτών των μοντέλων και για την ελαχιστοποίηση των αδυναμιών τους. Η κατανόηση και η πρόβλεψη της απόδοσης του TBM εξακολουθεί να αποτελεί σημαντική πρόκληση για την εκσκαφή με TBM.


Οι Chen και Guestrin (2016) προτείνουν τον ισχυρό αλγόριθμο εκμάθησης συνόλου που βασίζεται σε ένα σύστημα ενίσχυσης διαβάθμισης που ονομάζεται Extreme gradient boosting (XGBoost). Πιο συγκεκριμένα, το XGBoost είναι ένα ισχυρό εργαλείο εξόρυξης δεδομένων που έχει χρησιμοποιηθεί ευρέως και έχει αποδειχθεί αποτελεσματικό σε πολλά προβλήματα παλινδρόμησης και ταξινόμησης. Επιπλέον, ο συντονισμός των υπερ-παραμέτρων των μοντέλων XGBoost για σύνολα δεδομένων TBM είναι επίσης χρήσιμος. Για τη βελτιστοποίηση των υπερ-παραμέτρων του XGBoost χρησιμοποιείται ο αλγόριθμος Bayesian optimization (BO). Πρόκειται για ένα καινοτόμο έργο, καθώς η πρόβλεψη ρυθμού προχώρησης TBM με τους (Jian Zhou et. al., 2020) να επιτυγχάνουν εντυπωσιακά αποτελέσματα για τη πρόβλεψη ρυθμού προχώρησης (AR) (Σχήμα 4.4. και Σχήμα 4.5.).




Σχήμα 4.4. Σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων με την χρήση των αλγορίθμων υβριδικών τεχνικών βελτιστοποίησης με βάση το PSO και έναν αλγόριθμο (ICA) (Armaghani et al., 2019)



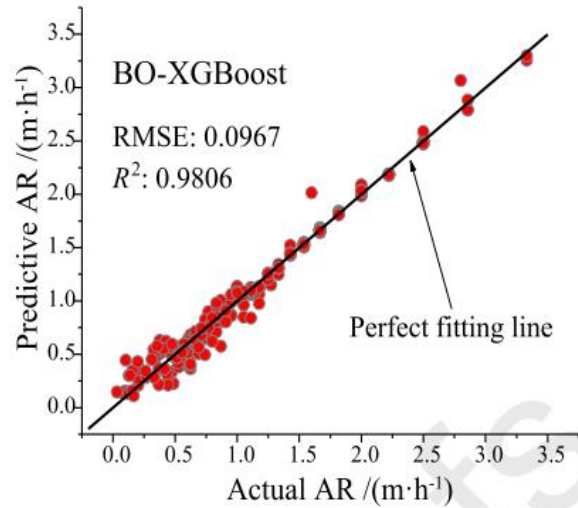
(a) XGB(training set)



(b) XGB(testing set)



(c) BO-XGBoost (training set)



(d) BO-XGBoost (testing set)

Σχήμα 4.5. Σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων σε βάσεις δεδομένων εκπαίδευσης και ελέγχου με την χρήση των αλγορίθμων XGBoost και BO-XGBoost από τους (Jian Zhou et. al., 2020)


4.2. TBM αυτόνομης λειτουργίας

Τα πλήρως αυτοματοποιημένα TBM μπορεί να είναι αρκετά μακριά, αλλά η πραγματικότητα της αυτόνομης λειτουργίας TBM έχει ήδη τεθεί σε λειτουργία. Το σύστημα τους βασίζεται σε προσαρμοσμένους αλγόριθμους τεχνητής νοημοσύνης που αναλύουν δεδομένα μηχανών σε πραγματικό χρόνο και αναλαμβάνουν τον έλεγχο των διαφόρων λειτουργικών υποσυστημάτων του TBM με ελάχιστη ανθρώπινη παρέμβαση.

Αναπτύχθηκε από μια ομάδα νέων μηχανικών και τεχνικών στην Κουάλα Λουμπόρ της Μαλαισίας, και το αυτόνομο λειτουργικό σύστημα TBM είναι κάτι περισσότερο από μια θεωρητική ιδέα ή ένα εργαστηριακό πρωτότυπο. Η ομάδα ανάπτυξης έχει εφαρμόσει το σύστημα σε 10 από τα 12 TBM που εξορύσσουν επί του παρόντος 13,5 χιλιόμετρα δίδυμων σηράγγων κάτω από το κέντρο της πόλης της πρωτεύουσας της Μαλαισίας. Τα 10 TBM διαφόρων χρήσεων, που παρέχονται από τον Γερμανό κατασκευαστή Herrenknecht, είχαν έναν ξεχωριστό βιομηχανικό υπολογιστή που προστέθηκε ο καθένας στα plcs τους (προγραμματιζόμενοι λογικοί ελεγκτές) για να παρέχει αυτόνομη λειτουργία με ανθρώπινη επίβλεψη και όχι έλεγχο.

Ενώ υπάρχει το θέμα που αφορά τις ευρύτερες νομικές ευθύνες και τις ευθύνες συνέπειας ενός συστήματος που μεταφέρει την ευθύνη από έναν ανθρώπινο χειριστή σε ένα μηχάνημα, οι προγραμματιστές υποστηρίζουν ότι η αποδεδειγμένη επιτυχία των TBM σε αυτόνομη λειτουργία είναι αυτό που προτιμάται και απαιτείται όταν τα μηχανήματα αυτά λειτουργούν υπό τις πιο ευαίσθητες συνθήκες, δηλαδή όταν οι κίνδυνοι ανθρώπινου σφάλματος ή ακανόνιστης λειτουργίας του μηχανήματος θα προκαλούσαν τις πιο καταστροφικές πιθανές συνέπειες. Ένα μηχάνημα εξοπλισμένο με το συγκεκριμένο σύστημα θα ανταποκρίνεται πιο γρήγορα και με μεγαλύτερη ευαισθησία από έναν ανθρώπινο χειριστή όταν, για παράδειγμα πρέπει να γίνει διόρθωση πορείας και επιπέδου για να κατευθυνθεί το μηχάνημα, προσαρμογή της πίεσης που εφαρμόζεται στο μέτωπο, τον έλεγχο της απώλειας εδάφους, τον έλεγχο του ρυθμού προχώρησης, την διαχείριση της κυκλοφορίας πολφού και άλλες μηχανικές λειτουργίες και συστήματα. Η δυνατότητα αυτόνομου ελέγχου αυτών των λειτουργιών ήταν διαθέσιμη στο παρελθόν. Η διαφορά που προσφέρει η ομάδα στη Μαλαισία είναι η συλλογή τεράστιων όγκων δεδομένων από αισθητήρες παρακολούθησης, προσθέτοντας στις δυνατότητες των σύγχρονων υπολογιστών και των μεγάλων συστημάτων διαχείρισης δεδομένων, ώστε αυτά να εφαρμοστούν στη μηχανική μάθηση και την ανάπτυξη της τεχνητής νοημοσύνης, και εγκατάσταση της ανεπτυγμένης τεχνολογίας σε πραγματικές εργασίες των TBM (Σχήμα 4.6.).

Drastic Stability Improvements



Σχήμα 4.6. Σύγκριση της ακρίβειας πλοήγησης μεταξύ ανθρώπινου δυναμικού και Αυτόνομου Συστήματος TBM

Κεφάλαιο 5. ΤΝΔ για την πρόβλεψη ρυθμού διείδυσης ΤΒΜ σηράγγων στις Άλπεις


5.1 Οι Άλπεις

Οι Άλπεις είναι σύστημα οροσειρών στην Ευρώπη και εκτείνονται από την Αυστρία και την Σλοβενία στα ανατολικά, μέσω της Ιταλίας, της Ελβετίας, του Λίχτενσταϊν και της Γερμανίας έως την Γαλλία στα δυτικά. Η λέξη Άλπεις σημαίνει βουνά. Η ψηλότερη κορυφή των Άλπεων είναι τα Λευκά Όρη (Mont Blanc) με 4.810 μέτρα στα Γαλλοϊταλικά σύνορα. Το σύστημα δημιουργήθηκε σε δεκάδες εκατομμύρια χρόνια από τη σύγκρουση της Ευρωπαϊκής με την Αφρικανική τεκτονική πλάκα, η οποία δημιούργησε τις Αλπικές πτυχώσεις και οδήγησε στο σχηματισμό του συστήματος. Οι Άλπεις, με τους εξαιρετικούς βραχώδεις σχηματισμούς, αντιπροσωπεύουν ένα θαυμάσιο φυσικό εργαστήριο για πολλές γεωλογικές διεργασίες και έχουν διαδραματίσει καθοριστικό ρόλο στην ιστορία της γεωλογίας. Ξεκινάνε από το προ-τριασικό κρυσταλλικό υπόβαθρο, ακολουθούμενο από ιζηματογενείς προσχλωσιγενή πετρώματα Παλαιόζωικης, Μεσοζωικής και Κενοζοϊκής εποχής. Η κατανόηση της εξέλιξης των Άλπεων ως οροσειράς συνεπάγεται με την αποκάλυψη της μεταμορφικής ιστορίας των Άλπεων για να αποκαλυφθεί η πολυπλοκότητα και ο συγχρονισμός της ορογένεσης.


5.2. Παρουσίαση των σηράγγων και δεδομένων του προβλήματος

Στο παράδειγμα εφαρμογής που ακολουθεί, πραγματοποιείται η κατασκευή και η κατάλληλη εκπαίδευση ΤΝΔ με στόχο την πρόβλεψη του ρυθμού εκσκαφής μηχανήματος ολομέτωπης κοπής. Τα δεδομένα που λαμβάνονται υπ' όψη στη παρούσα εργασία, διατέθηκαν από τους ερευνητές του Πανεπιστημίου της Μπολόνια και προέρχονται από την κατασκευή 3 υδραυλικών σηράγγων (Maen, Pieve και Varzo), στη Β. Ιταλία στην περιοχή των Άλπεων. Το συνολικό μήκος των σηράγγων φτάνει τα 18 km περίπου, ενώ το μήκος για το οποίο υπάρχουν πλήρη δεδομένα και για το οποίο πραγματοποιείται η ανάλυση φτάνει τα 14 km. Η λήψη των δεδομένων γίνονταν είτε σε ημερήσια βάση (Pieve, Varzo), είτε ανά συγκεκριμένο μήκος όρυξης 5 m (Maen). Για την κατασκευή των σηράγγων χρησιμοποιήθηκαν δύο τύποι ΤΒΜ, ανοικτού τύπου και διπλής ασπίδας (Sapigni et al., 2002). Τα αναλυτικά στοιχεία για τα συγκεκριμένα έργα, καθώς και τα χαρακτηριστικά των μηχανημάτων δίνονται στον **Πίνακα 5.1**.


Γεωλογικά, η ευρύτερη περιοχή δομείται κυρίως από μεταμορφωσιγενή πετρώματα, όπως, σερπεντινίτες, ασβεστιτικοί, μαρμαρυγιακοί και ταλκικοί σχιστόλιθοι, μεταβασίτες, μεταμορφωμένοι γάββροι, γνεύσιοι, μεταγρανίτες, μεταμορφωμένοι διορίτες και γρανοδιορίτες. Τα συγκεντρωτικά στοιχεία για τους γεωλογικούς σχηματισμούς που συναντήθηκαν κατά τη διάρκεια της όρυξης, καθώς και για τις μηχανικές ιδιότητές τους δίνονται στον **Πίνακα 5.2**.



Εικόνα 5.1. Γεωλογική τομή σήραγγας Maen (Sapigni et al., 2002)



Εικόνα 5.2. Γεωλογική τομή σήραγγας Pieve (Sapigni et al., 2002)



Εικόνα 5.3. Γεωλογική τομή σήραγγας Varzo (Sapigni et al., 2002)

Πίνακας 5.1. Κατασκευαστικά δεδομένα για τα υπό εξέταση έργα (Sapigni et al., 2002).

	Maen	Pieve	Varzo
Συνολικό μήκος (m)	1750	9600	6600
Μήκος εξέτασης (m)	1750	6400	5800
Συνολικός χρόνος εκσκαφής (ημερ.)	413	809	468
Διάμετρος εκσκαφής (m)	4,20	4,05	4,05
Κλίση σήραγγας (°)	24–35	≈0	≈0
Μοντέλο TBM	Wirth 340/420 E	Robbins 1111-234/3	Robbins 1214-240/1
Τύπος TBM	Ανοικτού τύπου	Διπλής ασπίδας	Διπλής ασπίδας
Αριθμός κοπτικών	36	27	27
Απόσταση κοπτικών (mm)	66	75	75
Διάμετρος κοπτικών (in)	17''	17''	17''
Μέγιστη ώση (kN)	7920	4602	8827
Διαδρομή εμβόλου (m)	1,5	0,63	0,63
Ρυθμός περιστροφής κεφαλής (rpm)	5,5–11	11,3	4,5–8,9

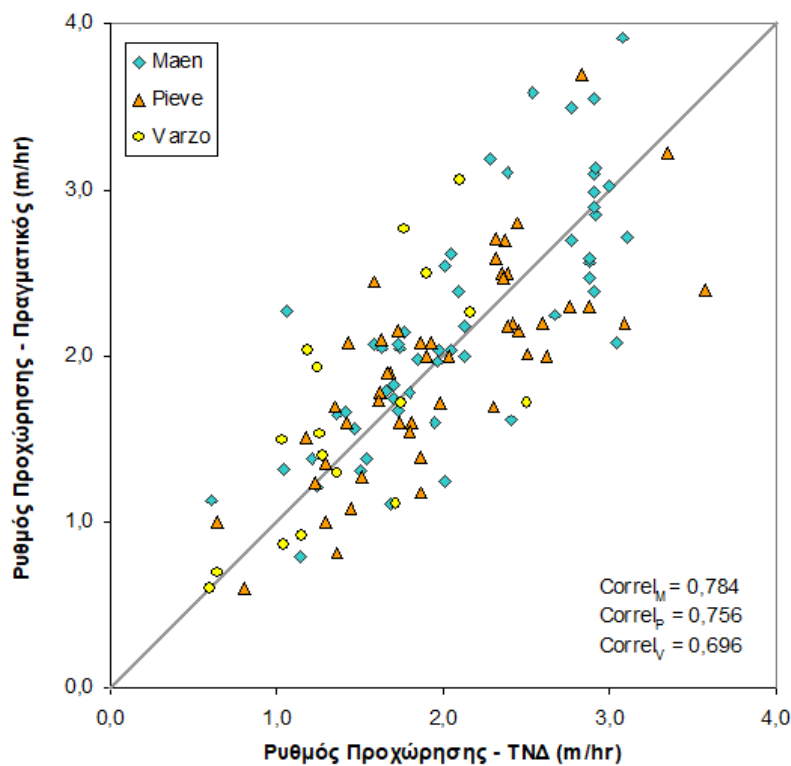
Πίνακας 5.2 Στοιχεία γεωλογικών σχηματισμών και των ιδιοτήτων τους στα υπό εξέταση έργα (Sapigni et al., 2002).

Έργο	Πέτρωμα	Αντοχή σε μονοαξονική θλίψη (MPa)	Αντοχή σε εφελκυσμό (MPa)	Μέση σκληρότητα Mohs	Cutter Life Index	Μέτρο Ελαστικότητας (GPa)
Maen	Σερπεντινίτης	124 (64–174)	—	3,6	30–70	—
	Μεταβασίτης	180 (104–289)	15 (9–29)	6,2	10–20	65 (37–94)
	Χλωριτικός – Ταλκικός σχιστόλιθος	17 (0.9–39)	—	2,8	60–90	—
	Μεταμ. Γάββρος	138 (113–163)	10–12	6	15–25	39
	Ασβεστιτικός σχιστόλιθος	75 (29–134)	—	3,6	30–70	—
Pieve	Μαρμαρυγιακός σχιστόλιθος	124–215	5–9	4,1	15–70	28
	Μεταδιορίτης	171–221	8–13	5,1	15–40	46–100
	Μεταγρανодиορίτης	160–210	—	5,4	15–40	—
	Μέτα-χαλαζιακός διορίτης	160–210	—	6,4	15	—
	Μεταγρανίτης	146–296	0.7–7	6,6	10	24–38
Varzo	Γνεύσιος ⊥ σχιστότητας	161 (90–260)	9	5,8	15–25	—
	// σχιστότητας	115 (82–217)	(6–13)	5,8	15–25	—

5.2 Τρόποι προσέγγισης

Στην μελέτη του, *TBM performance estimation using rock mass classifications*, ο Sapigni κάνει ανάλυση της διακύμανσης των κυρίαρχων πετρωμάτων που συναντήθηκαν στις τρεις σήραγγες με 2 μεθόδους ταξινόμησης RMR και Q. Στην μελέτη του παρατηρεί ότι γενικά, ο ρυθμός διείδυσης (PR) αυξάνεται με τη μείωση της ποιότητας της βραχόμαζας έως τις τιμές RMR περίπου 50–70. Η πτώση της απόδοσης κάτω από αυτό το εύρος αντικατοπτρίζει κακή ικανότητα εκσκαφής σε δυσμενής συνθήκες βραχόμαζας, όπου προβλήματα όπως η αστάθεια μετώπου μειώνουν το δυνητικά υψηλό ρυθμός διείδυσης. Αντίθετα, καταγράφηκε χαμηλό PR σε πολύ καλές βραχόμαζες (RMR > 80-90) λόγω της υψηλής αντοχής του άρρηκτου βράχου και από τη χαμηλή συχνότητα ασυνεχειών, τα οποία μειώνουν την κοπτική ικανότητα των κοπτικών και επηρεάζουν το σχήμα των τεμαχίων που αποκολλούνται λόγω του μηχανισμού αστοχίας.

Παρατηρείται μία περισσότερο ή λιγότερο τετραγωνική σχέση μεταξύ του ρυθμού διείδυσης και του RMR παρά τη σταθερή γραμμική αύξηση της ώσης του TBM, γεγονός που δείχνει ότι η παρατηρούμενη τάση δεν προκύπτει από μίμηση της εφαρμοζόμενης δύναμης αλλά είναι το αποτέλεσμα της αλληλεπίδρασης TBM-βραχώμαζας. Ο Sapigni λοιπόν στην ανάλυση του συσχέτισε το ρυθμό διείδυσης με το RMR, το οποίο RMR είχε τον κυρίαρχο λόγο στα “δεδομένα εισόδου”. Ο Benardos το 2008 προσεγγίζει το πρόβλημα με TND με εργαλείο την Matlab πετυχαίνοντας πολύ καλά ποσοστά ακρίβειας πρόβλεψης και με μικρά σφάλματα ελέγχου γενίκευσης (Σχήμα 5.1).



Σχήμα 5.1. Σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων των TND για τις σήραγγες Maen, Pieve, Varzo (Benardos, 2008)

Υπάρχουν όμως δεδομένα για την ώση, την λιθολογία και το RMR μπορούμε να εξερευνήσουμε το θέμα λίγο πιο αναλυτικά χρησιμοποιώντας όλες τις παραμέτρους ως εισόδους του προβλήματος Έχοντας λοιπόν ένα πολυπαραμετρικό πρόβλημα οι τόποι προσέγγισης ποικίλλουν. Η πολυσυγγραμμικότητα (multicollinearity), δηλαδή η εκτεταμένη αλληλεπίδραση μεταξύ των ανεξάρτητων παραμέτρων ενός προβλήματος μπορεί ενδεχομένως να οδηγήσει μια γραμμική

παλινδρόμηση σε αδιέξοδο. Και οι ανεξάρτητες παράμετροι του συγκεκριμένου προβλήματος είναι άρρηκτα συνδεδεμένοι. Αυτό όμως δεν είναι πρόβλημα για τα νευρωνικά δίκτυα λόγω του τρόπου λειτουργίας τους. Τα βάρη είναι αυτά που καθορίζουν τις σχέσεις των παραμέτρων μας, αφήνοντας εμάς να ασχοληθούμε κυρίως με την υπερβολική απομνημόνευση (overfitting).

5.3. Ανάπτυξη απλών ΤΝΔ

Στο πρώτο κομμάτι των πειραμάτων δημιουργήθηκαν τρία μοντέλα απλών ΤΝΔ πρόσθιας τροφοδότησης στα οποία έγιναν δοκιμές όσο αφορά την αρχιτεκτονική (επίπεδα, νευρώνες), τον ρυθμό μάθησης, τον αριθμό εισαγωγής δεδομένων για κάθε επανάληψη (εποχή), τον αριθμό εποχών και του ελέγχους εκπαίδευσης και γενίκευσης.

5.3.1 Δεδομένα, Αρχιτεκτονική, και Αλγόριθμοι

Για την εκτίμηση του ρυθμού εκσκαφής (penetration rate – PR) των υπό εξέταση σήραγγων κατασκευάστηκαν ΤΝΔ, τα οποία είχαν ως δεδομένα εισαγωγής:

- τη λιθολογία που συναντήθηκε κατά μήκος της σήραγγας
- τη γεωμηχανική κατάταξη της βραχώμαζας, όπως εκφράζεται από το δείκτη RMR
- την ώση του μηχανήματος κατά τη διάρκεια της όρυξης.

Σημειώνεται ότι ανάλογα με το πλήθος λιθολογικών σχηματισμών που συναντήθηκαν κατά τη διάρκεια της όρυξης έγινε και η αντίστοιχη ομαδοποίηση των δεδομένων εισαγωγής για την κατηγορία “λιθολογία”. Υπήρξε δηλαδή διαφοροποίηση του αριθμού των κατηγοριών για κάθε σήραγγα. Έτσι για την εξέταση της σήραγγας Maen υπήρξαν 3 νευρώνες εισόδου (RMR, Ώση (Thrust (kN))), και κατηγορία πετρώματος από 0 έως 5), για τη σήραγγα Pieve υπήρξαν 3 νευρώνες εισόδου (RMR, Ώση (Thrust (kN))), και κατηγορία πετρώματος από 0 έως 4), ενώ για τη σήραγγα Varzo επειδή υπήρξε μόνο ένας λιθολογικός σχηματισμός χωρίστηκαν κατηγορίες βάση της κατάταξης RMR του ίδιου του πετρώματος καταλήγοντας σε 3 νευρώνες εισόδου (RMR, Ώση (Thrust (kN))), και κατηγορία πετρώματος βάση του RMR από 1 έως 5).

Τα δεδομένα για την κάθε περίπτωση χωρίστηκαν σε 2 υποσύνολα, εφαρμόζοντας τυχαία δειγματοληψία με τη βιβλιοθήκη stratify της Python. Αυτός ήταν και ο σκοπός της δημιουργίας κατηγοριών. Δημιουργούνται κατηγορίες και θέτονται αυτές τις κατηγορίες ως τη βάση με την

οποία θα γίνει το χώρισμα των δεδομένων σε 2 υποσύνολα. Το πρώτο υποσύνολο περιλαμβάνει το 80% του συνόλου των δεδομένων και χρησιμοποιείται για την εκπαίδευση του ΤΝΔ. Το δεύτερο υποσύνολο περιέχει το υπόλοιπο 20% των δεδομένων και χρησιμοποιείται για τον έλεγχο της ικανότητας γενίκευσης (πρόβλεψης) του εκπαιδευμένου μοντέλου. Έτσι επιτυγχάνεται η διατήρηση σχεδόν ίδιου ποσοστού κάθε λιθολογίας στα δεδομένα εκπαίδευσης και δεδομένα ελέγχου γενίκευσης. Σημειώνεται ότι τα δεδομένα εισόδου κανονικοποιήθηκαν βάση της μέγιστης τιμής η οποία συναντήθηκε στα δεδομένα εκπαίδευσης όπως είθισται στην Μηχανική Μάθηση και αυτή η μέγιστη τιμή συναντάται στα δεδομένα εκπαίδευσης και όχι στα δεδομένα ελέγχου γενίκευσης. Και αυτό γιατί σημειώνεται επίσης, ότι τα δεδομένα του υποσυνόλου ελέγχου, είναι στην ουσία άγνωστα δεδομένα για το μοντέλο αφού δεν χρησιμοποιούνται για την εκπαίδευσή του (*Πίνακας 5.3*).

Πίνακας 5.3. Δεδομένα που χρησιμοποιούνται για την κατασκευή των εκπαιδευμένων ΤΝΔ για τα υπό εξέταση έργα.

	Maen	Pieve	Varzo
Δεδομένα εκπαίδευσης	264	240	81
Δεδομένα ελέγχου γενίκευσης	66	61	21
Σύνολο δεδομένων	330	301	102

Επιλέχθηκε να κατασκευαστεί ΤΝΔ για κάθε σήραγγα ξεχωριστά, καθώς το γεωλογικό και γεωτεχνικό περιβάλλον τους, αλλά και ο τύπος και η λειτουργία του κάθε μηχανήματος διαφέρουν. Κατά συνέπεια, η δημιουργία των ξεχωριστών μοντέλων προσφέρει τη δυνατότητα εκτέλεσης ακριβέστερων προβλέψεων που μπορούν να χρησιμοποιηθούν για την όρυξη έργων σε αντιστοίχους σχηματισμούς.

Τα ΤΝΔ δημιουργούνται με τη χρήση της γλώσσας προγραμματισμού Python. Με τη χρήση της συγκεκριμένης γλώσσας, γίνεται ο προγραμματισμός του κώδικα των νευρωνικών δικτύων, επιλέγεται η αρχιτεκτονική που θα ακολουθηθεί, οι συναρτήσεις ενεργοποίησης καθώς και ο αλγόριθμος εκπαίδευσης.

Το κριτήριο διακοπής της κάθε εκπαίδευσης ήταν διπλό, είτε η συμπλήρωση ορισμένου αριθμού εποχών (2000 εποχές), είτε η επίτευξη του ελάχιστου σφάλματος εκπαίδευσης (MSE) αν σε 50 συνεχόμενες εποχές δεν έχει υπάρξει μεγαλύτερο ελάχιστο από το ήδη υπάρχον. Με αυτόν τον τρόπο, το ΤΝΔ είχε ελευθερία και ως προς τη σύγκλιση του αλγόριθμου εκπαίδευσης, αφού η πραγματική σύγκλιση επιτυγχανόταν πολύ νωρίτερα από τον προβλεπόμενο αριθμό εποχών αλλά και ως προς το τελικό σφάλμα. Η ακρίβεια των γενικεύσεων του εκπαιδευμένου ΤΝΔ, αξιολογείται με βάση το σχετικό σφάλμα ανάμεσα στην προβλεπόμενη και στην πραγματική τιμή του ρυθμού εκσκαφής, σύμφωνα με τον τύπο:

$$\Delta = \frac{PR_{actual} - PR_{predicted}}{PR_{actual}} (\%), \text{ όπου:}$$

PR_{actual} : πραγματική τιμή ρυθμού εκσκαφής,

$PR_{predicted}$: τιμή ρυθμού εκσκαφής όπως υπολογίζεται από το ΤΝΔ.

Το συγκεκριμένο κριτήριο, δίνει μια άμεση εικόνα της συμπεριφοράς του μοντέλου και παράλληλα κάνει δυνατή τη σύγκριση μεταξύ των αποτελεσμάτων του ΤΝΔ και άλλων μεθόδων ή θεωρητικών μοντέλων.

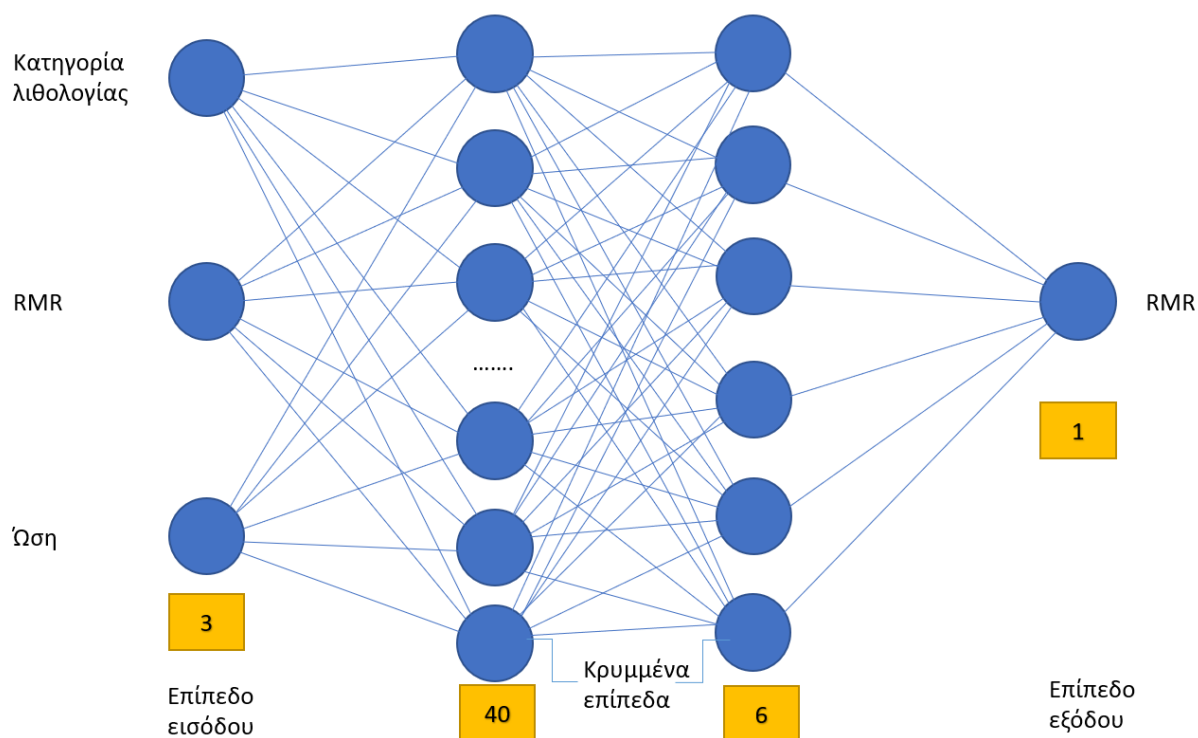
Αν και έγιναν προσπάθειες να υπάρξει μια αρκετά απλή δομή αρχιτεκτονικής, εντούτοις, αποδείχτηκε ότι κάτι τέτοιο δεν μπορούσε να οδηγήσει σε ακριβή αποτελέσματα. Έτσι, οι δοκιμές συνεχίστηκαν, αυξάνοντας τον αριθμό των κρυμμένων επιπέδων, σε μια προσπάθεια να βρεθεί ο συνδυασμός που θα έδινε τα βέλτιστα αποτελέσματα. Κάθε σήραγγα απαιτούσε είτε διαφορετικό αριθμό νευρώνων σε κάθε ένα από τα κρυμμένα επίπεδα, είτε διαφορετικό αριθμό κρυμμένων επιπέδων. Αυτό επιβεβαιώνει το γεγονός ότι κάθε νευρωνικό δίκτυο είναι διαφορετικό και η αρχιτεκτονική του επηρεάζεται αναλόγως την ποσότητα των δεδομένων που υπάρχουν και η ίδια προσδιορίζεται με δοκιμή και επανάληψη και όχι μέσω κάποιου κανόνα.

Στον **Πίνακα 5.4**, παρουσιάζονται οι τελικές δομές αρχιτεκτονικής που επιλέχθηκαν σε κάθε περίπτωση, τα μεγέθη των σφαλμάτων (MSE) που υπήρξαν κατά τη διάρκεια της εκπαίδευσης και της γενίκευσης των ΤΝΔ, τη τελική μέση τιμή των σχετικών απόλυτων σφαλμάτων γενίκευσης (%) των δικτύων καθώς και η μέση ακρίβεια πρόβλεψης τιμών (%).

Πίνακας 5.4. Αρχιτεκτονική, MSE, Μέσο σχετικό σφάλμα και ακρίβεια πρόβλεψης των ΤΝΔ που χρησιμοποιήθηκαν σε κάθε περίπτωση.

	Maen	Pieve	Varzo
Βέλτιστη αρχιτεκτονική ΤΝΔ	3×40×6×1	3×10×40×4×1	3×10×30×10×2×1
Λάθος εκπαίδευσης (MSE)	0,208	0,181	0,313
Λάθος γενίκευσης (MSE)	0.276	0.232	0.333
Μέσο σχετικό σφάλμα εκπαίδευσης (%)	8.146%	2,580%	4.683%
Μέσο σχετικό σφάλμα γενίκευσης (%)	6,813%	20,363%	13,848%
Μέση ακρίβεια πρόβλεψης τιμών (%)	82,70%	79.30%	72,20%

Την πιο καλή συμπεριφορά παρουσιάζει το ΤΝΔ που κατασκευάστηκε για την περίπτωση της σήραγγας Maen, έχοντας αρχιτεκτονική 3×40×6×1 (Σχήμα 5.2.) δηλαδή δομείται από 3 νευρώνες εισόδου, έχοντας 2 κρυμμένα επίπεδα με 40 και 6 νευρώνες αντίστοιχα και τέλος 1 νευρώνα εξόδου.




Σχήμα 5.2. Δομή της αρχιτεκτονικής του ΤΝΔ για τη σήραγγα Maen (3x40x6x1).

Σε αυτό το σημείο θα αναφερθεί ότι σε όλα τα μοντέλα και για τις 3 σήραγγες όσο αφορά τη συνάρτηση ενεργοποίησης χρησιμοποιήθηκε η ReLU και για το τον νευρώνα εξόδου αναγκαστικά η γραμμική συνάρτηση. Επίσης σε κάποια κρυμμένα επίπεδα χρησιμοποιήθηκε η εντολή Dropout. Η εντολή Dropout δίνει στο χρήστη τη δυνατότητα να "αχρηστεύσει" ένα ποσοστό νευρώνων σε κάποιο επίπεδο (π.χ. 10%) ωθώντας έτσι τους υπόλοιπους νευρώνες του επιπέδου να δουλέψουν με μεγαλύτερη πίεση. Η συνάρτηση βελτιστοποίησης που χρησιμοποιήθηκε ήταν η Adam με τον προεπιλεγμένο ρυθμό μάθησης. Και τα άλλα δύο όμως ΤΝΔ, παρουσιάζουν καλή σχετικά απόκριση με επίπεδα σφάλματος που θεωρούνται ικανοποιητικά.


5.3.2. Παρουσίαση αποτελεσμάτων για την χρήση απλών ΤΝΔ

Πέρα από την παρουσίαση των μέσων τιμών των σφαλμάτων γενίκευσης, είναι σημαντικό να εξεταστεί και η συνολικότερη συμπεριφορά της απόκρισης των ΤΝΔ. Ο συγκεκριμένος έλεγχος θα εξασφαλίσει ότι η ικανότητα των εκπαιδευμένων μοντέλων να προσφέρουν αξιόπιστες προβλέψεις, διαχέεται σε όλο το εύρος των τιμών και δεν εστιάζεται μόνο σε συγκεκριμένα τμήματα. Κάτι τέτοιο γίνεται στα παρακάτω **Σχήματα 5.3, 5.4 και 5.5**, στα οποία παρουσιάζονται οι πραγματικές τιμές του ρυθμού προχώρησης, προερχόμενες από το υποσύνολο ελέγχου, σε σχέση με τις τιμές που προέρχονται από τις προβλέψεις του ΤΝΔ. Στο **Σχήμα 5.6** γίνεται σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων των ΤΝΔ για τις υπό εξέταση περιπτώσεις.


Παρατηρείται ότι οι τιμές απόκρισης των ΤΝΔ παρουσιάζουν μια αρκετά συνεπή συμπεριφορά σε όλο σχεδόν το φάσμα των δεδομένων του υποσυνόλου ελέγχου που χρησιμοποιήθηκε. Ακολουθούν με ικανοποιητική ακρίβεια τις μεταβολές που υπάρχουν στις πραγματικές τιμές του ρυθμού προχώρησης των ΤΒΜ και τελικά εμφανίζουν μία μέση ακρίβεια πρόβλεψης μεγαλύτερη από 70% για κάθε ένα από τα έργα που εξετάστηκαν (**Σήραγγα MAEN: 82.7%, Σήραγγα PIVE: 79.3%, Σήραγγα VARZO: 72.2%**). Με τον τρόπο αυτό, επιβεβαιώνεται η καλή λειτουργία των εκπαιδευμένων ΤΝΔ, ενώ αποδεικνύεται επίσης και η ικανότητά τους να οδηγήσουν σε αξιόπιστες προβλέψεις για το ρυθμό προχώρησης της όρυξης.




*Σχήμα 5.3. Συμπεριφορά της γενίκευσης του TNΔ για τη σήραγγα Μαση, στο σύνολο των δεδομένων ελέγχου.
(Μπλέ: Τιμές πρόβλεψης, Πορτοκαλί: Πραγματικές τιμές)*



*Σχήμα 5.4. Συμπεριφορά της γενίκευσης του ΤΝΔ για τη σήραγγα Pieve, στο σύνολο των δεδομένων ελέγχου.
(Μπλέ: Τιμές πρόβλεψης, Πορτοκαλί: Πραγματικές τιμές)*



*Σχήμα 5.5. Συμπεριφορά της γενίκευσης του ΤΝΔ για τη σήραγγα Ριενε, στο σύνολο των δεδομένων ελέγχου.
(Μπλέ: Τιμές πρόβλεψης, Πορτοκαλί: Πραγματικές τιμές)*



Σχήμα 5.6. Σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων των ΤΝΔ για τις υπό εξέταση περιπτώσεις.

Κεφάλαιο 6. ΤΝΔ βαθιάς μάθησης (Deep learning NN) για την πρόβλεψη χρονοσειρών

Πρακτικά, η Βαθεία Μάθηση είναι ένα υποσύνολο της Μηχανικής Μάθησης που επιτυγχάνει μεγάλη δύναμη και ευελιξία μαθαίνοντας να εκπροσωπεί τον κόσμο ως ένθετη ιεραρχία σεναρίων, με κάθε σενάριο να ορίζεται με απλούστερες έννοιες όπου τα περισσότερα αφηρημένα σενάρια υπολογίζονται περισσότερο από ότι τα λιγότερα αφηρημένα. Μια τεχνική βαθιάς μάθησης μαθαίνει κατηγορίες σταδιακά μέσω της αρχιτεκτονικής κρυφών επιπέδων. Για παράδειγμα στην αναγνώριση μίας πρότασης ορίζονται κατηγορίες χαμηλού επιπέδου όπως γράμματα πρώτα και κατηγορίες υψηλότερου επιπέδου όπως λέξεις. Στη συνέχεια ορίζονται κατηγορίες ακόμη υψηλότερου επιπέδου όπως οι προτάσεις. Στο παράδειγμα της αναγνώρισης εικόνας, η πρώτη διαδικασία είναι ο προσδιορισμός φωτεινών / σκοτεινών περιοχών πριν την κατηγοριοποίηση γραμμών και στη συνέχεια σχημάτων που επιτρέπουν την αναγνώριση προσώπου. Κάθε νευρώνας ή κόμβος στο δίκτυο αντιπροσωπεύει μια όψη του συνόλου και όλα μαζί παρέχουν μια πλήρη αναπαράσταση της εικόνας. Κάθε κόμβος ή κρυφό στρώμα έχει ένα βάρος που αντιπροσωπεύει τη δύναμη της σχέσης του με την έξοδο και καθώς το μοντέλο αναπτύσσεται, τα βάρη προσαρμόζονται. Τα RNN και τα CNN που αναλύθηκαν στο κεφάλαιο 4.2 αποτελούν σημαντικό κομμάτι των ΤΝΔ βαθιάς μάθησης και χρησιμοποιούνται πολύ συχνά στις μέρες μας, εκτός των άλλων εφαρμογών τους, για την επίλυση χρονοσειρών.

6.1 Χρονοσειρές

Το πρόβλημα στην ανάλυση χρονοσειρών είναι να εκτιμήσουμε το σύστημα που παράγει τη χρονοσειρά και ενδεχομένως να κάνουμε προβλέψεις μελλοντικών τιμών του μεγέθους που παρατηρούμε. Τα κυριότερα χαρακτηριστικά που θα πρέπει να μελετήσουμε πριν προχωρήσουμε να προσαρμόσουμε κάποιο μοντέλο στη χρονοσειρά είναι :

1. Στασιμότητα (Stationarity): Απλά αυτό σημαίνει ότι οι διακυμάνσεις των τιμών της χρονοσειράς δε διαφοροποιούνται με το χρόνο. Μια μη στάσιμη χρονοσειρά μπορεί να έχει τάσεις (trends), δηλαδή (αργές) αλλαγές στη μέση τιμή της με το χρόνο

2. Αιτιοκρατία (determinism) και στοχαστικότητα (stochasticity): Όλες οι χρονοσειρές από πραγματικά μμεγέθη περιέχουν θόρυβο και με αυτήν την έννοια όλες οι πραγματικές χρονοσειρές είναι στοχαστικές. Η μεγαλύτερη πρόκληση στην ανάλυση πραγματικών χρονοσειρών είναι η διερεύνηση και ταύτιση ή εντοπισμός του αιτιοκρατικού μέρους του συστήματος που παράγει τη χρονοσειρά.

3. Γραμμικότητα (linearity) και μη-γραμμικότητα (nonlinearity): Σύμφωνα με τα παραπάνω φαίνεται αυτές οι δύο έννοιες να σχετίζονται με την αιτιοκρατία και στοχαστικότητα αλλά γενικά μπορούν να ορισθούν ανεξάρτητα από αυτές. Η γραμμικότητα του συστήματος σημαίνει πως οι μεταβλητές του συστήματος (που μπορεί να μην έχουμε τη δυνατότητα να τις παρατηρήσουμε) αλληλο-επιδρούν γραμμικά, δηλαδή αν θα εκφράζαμε το σύστημα με αναλυτική μορφή όλοι οι όροι θα ήταν γραμμικοί ως προς τις μεταβλητές του συστήματος. Σε αντίθετη περίπτωση το σύστημα είναι μη-γραμμικό. Για τη χρονοσειρά αυτό σημαίνει πως για ένα γραμμικό σύστημα ορίζουμε την εξέλιξη της χρονοσειράς ως γραμμικό συνδυασμό των προηγούμενων παρατηρήσεων της χρονοσειράς, ενώ για ένα μη-γραμμικό σύστημα μπορούμε να ορίσουμε την εξέλιξη της χρονοσειράς με μεγαλύτερη ακρίβεια αν θεωρήσουμε και τη συνδυασμένη επίδραση των προηγούμενων παρατηρήσεων σε διαφορετικές χρονικές στιγμές ή τις ίδιες.

6.2 Επιλογή σήραγγας και στοιχείων

Μία από τις υπό εξέταση σήραγγες (Pieve) μπορούσαμε να την εξετάσουμε με την μέθοδο χρονοσειρών καθώς γνωρίζαμε τη χιλιομετρική θέση στην οποία γινόντουσαν οι μετρήσεις για τον ρυθμό προχώρησης.

Μπορούμε να το αντιμετωπίσουμε σαν ένα πρόβλημα όπου ένα μέγεθος αλλάζει τιμές με το χρόνο και μπορούμε μελετήσουμε την εξάρτηση του μεγέθους X σε κάποια χρονική στιγμή t , x_t , από το ίδιο μέγεθος σε προηγούμενες χρονικές στιγμές, x_{t-1} , x_{t-2} , ... περιλαμβάνοντας και όλους τους υπόλοιπους παράγοντες όπως στα προηγούμενα μοντέλα (Πέτρωμα, Δύναμη Ωσης, RMR). Σε κάποια προβλήματα, όπως και στο δικό μας χρόνος δειγματοληψίας (sampling time) μπορεί να μην είναι σταθερός και τότε χρειάζεται ειδικότερη επεξεργασία της χρονοσειράς για να γίνει η ανάλυση. Η πιο απλή προσέγγιση σε αυτήν την περίπτωση είναι να ορίσουμε ως χρόνο αναφοράς όχι το φυσικό χρόνο αλλά τον χρόνο που κάνουμε να προχωρήσουμε ένα χιλιόμετρο και να θεωρήσουμε σταθερό χρονικό βήμα τις 40 μετρήσεις όπου αποτελούν ένα χιλιόμετρο. Στη


συνέχεια θα θεωρούμε το χρόνο δειγματοληψίας σταθερό που είναι και η τυπική περίπτωση στην ανάλυση μιας χρονοσειράς.

6.3. Ο συνδυασμός CNN και RNN για την προσέγγιση ενός προβλήματος χρονοσειράς.


Για να προσεγγίσουμε την μεθοδολογία της επίλυσης μίας χρονοσειράς με την Μηχανική Μάθηση και πιο συγκεκριμένα με ΤΝΔ που ανήκουν στην βαθιά μάθηση μπορούμε να χρησιμοποιήσουμε τα επαναλαμβανόμενα νευρωνικά δίκτυα (Recurrent neural networks-RNN).

Στην περίπτωση του συγκεκριμένου προβλήματος μετά από αρκετές δοκιμές παρατηρήθηκε ότι η αρχιτεκτονική RNN που ταιριάζει είναι μέσω των LSTM.

Αρχικά κατασκευάστηκαν 4 μοντέλα απλής πρόβλεψης (forecast models) και 1 μοντέλο με την χρήση ΤΝΔ-RNN τα οποία είχαν μοναδική είσοδο τον ρυθμό προχώρησης και μοναδική έξοδο επίσης τον ρυθμό προχώρησης. Σέ κάθε μία από τις περιπτώσεις των απλών μοντέλων υπήρχε διαφορετικός αριθμός εισόδων προηγούμενων τιμών (window size). Τα μοντέλα δηλαδή λαμβάνουν υπόψιν αντίστοιχα 1, 3, 5 και 10 προηγούμενες τιμές ρυθμού προχώρησης (PR) για να προβλέψουν την επόμενη (PR_{+1}). Το μοντέλο RNN λαμβάνει υπόψιν 20 προηγούμενες τιμές προχώρησης και αποτελείται από ένα επίπεδο εισόδου, 2 κρυμμένα επίπεδα RNN, και ένα επίπεδο εξόδου.




Εικόνα 6.1. Μοντέλα απλής πρόβλεψης (forecast models) με αριθμό εισόδων προηγούμενων τιμών (window size) 1 (αριστερά) και 3 (δεξιά). (Μπλέ: Πραγματικές τιμές, Πορτοκαλί: Τιμές πρόβλεψης)



Εικόνα 6.2. Μοντέλα απλής πρόβλεψης (forecast models) με αριθμό εισόδων προηγούμενων τιμών (window size) 5 (αριστερά) και 10 (δεξιά). (Μπλέ: Πραγματικές τιμές, Πορτοκαλί: Τιμές πρόβλεψης)

Και τα 5 μοντέλα είχαν μέση ακρίβεια πρόβλεψη τιμών από 80% και πάνω ενώ το MSE ήταν σε όλα της τάξης του 0,2 και το MAE της τάξης του 0,3. Το **Σχήμα 6.1.** βλέπουμε τη σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων για τα 5 μοντέλα. Με αυτόν τον τρόπο ήταν δυνατό να παρατηρήσουμε ότι το μοντέλο RNN είναι στη σωστή κατεύθυνση και μπορούμε να εισάγουμε και τις υπόλοιπες παραμέτρους.




Σχήμα 6.1. Σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων των 5 μοντέλων. (Pieve)

Στην συνέχεια έγινε ο συνδυασμός των CNN και RNN νευρωνικών δικτύων. Δημιουργήθηκαν 2 μοντέλα όπου στο ένα λαμβάνονται υπόψιν οι 5 προηγούμενες τιμές για τον υπολογισμό του PR_{+1} και στο άλλο υπόψιν 1 προηγούμενη τιμή. Οι εισοδοι στα νευρωνικά δίκτυα ήταν ο τύπος του πετρώματος, η δύναμη ώσης, το RMR και ο ρυθμός διείδυσης PR ενώ η έξοδος ήταν ο ρυθμός διείδυσης PR_{+1} . Ο λόγος που χρησιμοποιήθηκαν τα CNN είναι λόγω των φίλτρων. Τα CNN έχουν μεγάλη φήμη, ευχρηστία και επιτυχία στην αναγνώριση εικόνων. Η εικόνα ως είσοδος αντιμετωπίζεται από τα CNN ως πίνακας. Καταφέρνουν και βρίσκουν τις διαφορές σε κοντινά σημεία π.χ. το περίγραμμα ενός αντικειμένου στο "object recognition". Με αντίστοιχο τρόπο μπορούν να εντοπίσουν τις κοντινές κινήσεις που κάνει η χρονοσειρά βοηθώντας έτσι σημαντικά στην εύρεση του PR_{+1} . Με αυτήν τη λογική στην περίπτωση π.χ. του μοντέλου που λαμβάνει


υπόψιν τις 5 προηγούμενες τιμές έχουμε έναν πίνακα εισόδου με 4 στήλες (Λιθολογία, Ώση, RMR, PR) και 5 γραμμές. Αυτός ο πίνακας λοιπόν μπορεί να αντιμετωπίσει από τα φίλτρα του επιπέδου CNN όπως θα αντιμετώπιζε μια εικόνα. Ύστερα από το επίπεδο CNN ακολουθεί ένα επίπεδο RNN-LSTM με 20 νευρώνες καταλήγοντας σε ένα απλό επίπεδο με μία έξοδο. Τα αποτελέσματα των μοντέλων παρατίθενται στον **Πίνακα 6.1.** , ενώ στα **Σχήματα 6.2. και 6.3.** βλέπουμε την του ρυθμού προχώρησης TNΔ και των πραγματικών σε σύγκριση με την προχώρηση της σήραγγας και τέλος στο **Σχήμα 6.4.** βλέπουμε την σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων για τα δύο μοντέλα. Το μοντέλο που λαμβάνει υπόψιν 5 προηγούμενες τιμές δεδομένων για προβλέψει το PR_{+1} δείχνει συνολικά καλύτερη συμπεριφορά με τις τιμές πρόβλεψης να είναι κοντινότερα στην διαγώνιο. Το μοντέλο που λαμβάνει υπόψιν 1 προηγούμενη τιμή μπορούμε να δούμε στο σχήμα ότι αργεί να εκπαιδευτεί καθώς οι αρχικές τιμές βρίσκονται αρκετά μακριά από την αλήθεια και συγκλίνουν σε αυτήν αργότερα.

Πίνακας 6.1. Αποτελέσματα των TNΔ που χρησιμοποιήθηκαν.


Window Size	Pieve	
	1	5
MSE	0.242	0.260
MAE	0.370	0.390
Μέση ακρίβεια πρόβλεψης τιμών (%)	78.77%	77.77%



Σχήμα 6.2. Συμπεριφορά του ρυθμού προχώρησης ΤΝΔ και των πραγματικών σε σύγκριση με την προχώρηση της σήραγγας (*window size 5, PR predicted and PR actual Vs Chainage*). (Μπλέ: Πραγματικές τιμές, Πορτοκαλί: Τιμές πρόβλεψης)



Σχήμα 6.3. Συμπεριφορά του ρυθμού προχώρησης ΤΝΔ και των πραγματικών σε σύγκριση με την προχώρηση της σήραγγας (window size 1, PR predicted and PR actual Vs Chainage). (Μπλε: Πραγματικές τιμές, Πορτοκαλί: Τιμές πρόβλεψης)




Σχήμα 28. Σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων για τα δύο μοντέλα.

Κεφάλαιο 7. Αξιολόγηση των αποτελεσμάτων σε σχέση με άλλες τεχνικές πρόβλεψης

Η αξιολόγηση των αποτελεσμάτων που προέκυψαν από τα ΤΝΔ, γίνεται ακόμα πιο ολοκληρωμένη με την αντιπαραβολή τους, σε σχέση με τα αποτελέσματα που προκύπτουν από την εφαρμογή άλλων τεχνικών πρόβλεψης. Υπάρχουν αρκετά τέτοια μοντέλα πρόβλεψης που έχουν στόχο να συνδέουν τις παραμέτρους της βραχόμαζας και τα χαρακτηριστικά των μηχανημάτων με την ταχύτητα εκσκαφής, είτε μέσω εμπειρικών τύπων είτε μέσω θεωριών κοπής (McFeat-Smith et al., 1979; Nelson, 1993; Lislerud, 1998; Bruland, 1999;). Ένα αρκετά διαδεδομένο μοντέλο το οποίο έχει προταθεί από τον Barton (2000). Σύμφωνα με αυτό, του ρυθμού εκσκαφής (PR), γίνεται μέσω του δείκτη Q_{TBM} . Ο συγκεκριμένος δείκτης αποτελεί μια αναπτυγμένη μορφή του δείκτη ποιότητας βραχόμαζας Q (Q-system), η οποία συμπεριλαμβάνει επιπλέον στοιχεία για την αλληλεπίδραση μηχανήματος – βραχόμαζας.


Το σημαντικότερο πλεονέκτημα των εκπαιδευμένων ΤΝΔ είναι η ικανότητά τους να μπορούν να προσφέρουν προβλέψεις, οι οποίες θα ανταποκρίνονται ακριβέστερα σε πολύ συγκεκριμένες συνθήκες. Επιπλέον, αυτό γίνεται με τη χρήση πιο απλών και πιο εύκολα μετρήσιμων δεδομένων, γεγονός που αυξάνει την ευχρηστία τους. Σε αντίθεση για παράδειγμα με το μοντέλο του Q_{TBM} όμως, δεν είναι ένα γενικό εργαλείο που μπορεί να χρησιμοποιηθεί σε κάθε περίπτωση, αλλά χρειάζεται να βαθμονομηθεί (εκπαιδευτεί), σε κάθε εφαρμογή ή περιοχή ξεχωριστά, προκειμένου να δώσει αποτελέσματα υψηλής αξιοπιστίας.

Η εφαρμογή του μοντέλου Barton έγινε στις υπό εξέταση περιπτώσεις από τους Sapigni et al. (2002), και τα αποτελέσματά του δίνονται γραφικά στο **Σχήμα 7.1**. Εκεί παρουσιάζονται οι πραγματικές τιμές προχώρησης σε σχέση με τον εκάστοτε δείκτη Q_{TBM} που υπολογίστηκε, παράλληλα με τη θεωρητική τιμή της προχώρησης, όπως προκύπτει από την αντίστοιχη εξίσωση.



Σχήμα 7.1. Πρόβλεψη του ρυθμού προχώρησης των TBM μέσω του δείκτη Q_{TBM} αριστερά στη σήραγγα Maen και δεξιά. στις σήραγγες Pieve και Varzo (Sapigni et al., 2002).

Μια πρώτη παρατήρηση είναι ότι το συγκεκριμένο μοντέλο μπορεί να προσφέρει μια εικόνα της προχώρησης, η οποία γενικά συμβαδίζει με το μέσο όρο των τιμών. Η πιο καλή προσέγγιση δίνεται για τη σήραγγα Varzo, ενώ για τις άλλες δύο φαίνεται να δίνει αποτελέσματα που ελαφρώς υποεκτιμούν τους πραγματικούς ρυθμούς προχώρησης (Benardos 2008). Στο **Σχήμα 7.2.** βλέπουμε ακόμη ένα διάγραμμα από τους Sapigni et al., 2002 που δείχνει ένα μεγάλο εύρος τιμών του PR σε σχέση με το RMR γεγονός που δείχνει περιορισμένες ικανότητες πρόβλεψης του μοντέλου, κάνοντάς το περισσότερο ικανό για να εκφράσει τη γενικότερη τάση, αλλά όχι αρκετά ακριβές ώστε να δώσει προβλέψεις συγκεκριμένων τιμών όπως τα Τεχνητά Νευρωνικά Δίκτυα.



Σχήμα 7.2. Εύρος τιμών του PR σε σχέση με το RMR και για τις 3 σήραγγες (Sapigni et al., 2002).

Κεφάλαιο 8. Συμπεράσματα

Η χρήση εξελιγμένων μεθόδων τεχνητής νοημοσύνης, όπως τα τεχνητά νευρωνικά δίκτυα σε προβλήματα γεωτεχνολογίας και μηχανικής πετρωμάτων μπορεί να δώσει αξιόπιστες λύσεις και να συμβάλει στην προσπάθεια της καλύτερης κατανόησής τους. Αυτό αποδείχτηκε στο παρόν άρθρο με την κατασκευή ΤΝΔ τα οποία μπόρεσαν να δώσουν αξιόπιστα αποτελέσματα για την πρόβλεψη του ρυθμού εκσκαφής σηράγγων με τη χρήση μηχανημάτων ολομέτωπης κοπής.

Πιο αναλυτικά, τα πλεονεκτήματα που διαθέτει το εκπαιδευμένο μοντέλο είναι :

- Αποτελεί ένα ευέλικτο σύστημα γιατί μπορεί να ενημερώνεται με καινούρια στοιχεία εύκολα και να αυξάνει το βαθμό ακρίβειάς του.
- Είναι πολύ εύκολο στη χρήση του, ακόμα και από άπειρους χρήστες. Οι ελάχιστες απαιτήσεις του καθιστούν εφικτή τη χρησιμοποίησή του στο κατασκευαστικό περιβάλλον και δεν την περιορίζουν σε εργαστηριακές συνθήκες μόνο.
- Το ΤΝΔ μπορεί να παράγει προβλέψεις ταχύτατα, αξιόπιστα και με μεγάλη ακρίβεια.
- Βασισμένο στο θεωρητικό υπόβαθρο της αναπτυχθείσας μεθοδολογίας κατάφερε να συνδυάσει τις παραμέτρους μοντελοποίησης με πειραματικά δεδομένα και να συσχετίσει την ποιοτική εκτίμηση της τρωτότητας του γεωλογικού μέσου, με μια ποσοτική εκτίμηση του ρυθμού προχώρησης.
- Παρατηρώντας τα αποτελέσματα των συνδυαστικών μοντέλων RNN και CNN εκτιμούμε ότι με τον κατάλληλο όγκο και επεξεργασία δεδομένων σε συνδυασμό με την βέλτιστη αρχιτεκτονική, η συνδυαστική προσέγγιση μέσω της χρήσης των βασικών δεδομένων εισαγωγής αλλά και των χρονικών δεδομένων εκσκαφής (χρήση χρονοσειράς) μπορεί να δώσει αρκετά καλά αποτελέσματα, που μπορούν να βοηθήσουν αποφασιστικά στην μοντελοποίηση του φαινομένου και συνεπώς στην βελτίωση της πρόβλεψής του.

Στον **Πίνακα 8.1.** παρουσιάζονται συγκεντρωμένα τα αποτελέσματα από τις 2 μεθόδους προσέγγισης που πραγματοποιήθηκαν σε αυτή τη Διπλωματική εργασία. Παρόλο που χρησιμοποιήθηκαν και στις δύο τα ΤΝΔ και τα αποτελέσματα είναι αριθμητικά κοντά, οι μέθοδοι αυτές δεν είναι συγκρίσιμες ακριβώς για τον λόγο προσέγγισης του προβλήματος.

Πίνακας 8.1. Παρουσίαση συγκεντρωτικού πίνακα αποτελεσμάτων από τις 2 μεθόδους προσέγγισης


	FF-NN		
	Maen	Pieve	Varzo
Βέλτιστη αρχιτεκτονική ΤΝΔ	3×40×6×1	3×10×40×4×1	3×10×30×10×2×1
Λάθος εκπαίδευσης (MSE)	0,208	0,181	0,313
Λάθος γενίκευσης (MSE)	0.276	0.232	0.333
Μέσο σχετικό σφάλμα εκπαίδευσης (%)	8.146%	2,580%	4.683%
Μέσο σχετικό σφάλμα γενίκευσης (%)	6,813%	20,363%	13,848%
Μέση ακρίβεια πρόβλεψης τιμών (%)	82,70%	79.30%	72,20%
	CNN -RNN		
	Pieve		
Window Size	1	5	
MSE	0.242	0.260	
MAE	0.370	0.390	
Μέση ακρίβεια πρόβλεψης τιμών (%)	78,77%	77,77%	

Αντίστοιχα, στο **Σχήμα 8.1.** παρουσιάζονται συγκεντρωτικά οι συγκρίσεις μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων των απλών ΤΝΔ πρόσθιας τροφοδότησης ενώ στο **Σχήμα 8.2.** παρουσιάζονται οι συγκρίσεις μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων για την σήραγγα Pieve του ΤΝΔ πρόσθιας τροφοδότησης (FF-ANN) και του ΤΝΔ με χρήση CNN-RNN. Όσο αφορά το τελευταίο διάγραμμα παρατηρείται μία παρόμοια συμπεριφορά μεταξύ των δύο μοντέλων. Οι χαμηλές τιμές του PR βρίσκονται σε απόσταση από τη διαγώνιο ενώ οι μεγαλύτερες συγκλίνουν προς αυτήν. Ενώ οι προσεγγίσεις είναι τελείως διαφορετικές τα ΤΝΔ έχουν παρόμοια συμπεριφορά κάτι το οποίο μπορεί να εξηγηθεί λόγω του ρυθμού μάθησης (learning rate) των μοντέλων. Και οι δύο μέθοδοι δίνουν αξιολογικά αποτελέσματα γεγονός που παρουσιάζει μία ευελιξία για την περαιτέρω διερεύνηση της προσέγγισης του προβλήματος.


Επιπρόσθετα, ακόμη και κατά τη διάρκεια της αμιγώς κατασκευαστικής φάσης, είναι δυνατόν να υπάρξει μια αρχική ροή δεδομένων μέσω των οποίων θα καταστεί δυνατή η βαθμονόμηση των νευρωνικών δικτύων στις ιδιαίτερες συνθήκες του συστήματος γεωλογίας – έργου, παρέχοντας εκτιμήσεις βραχυπρόθεσμου ορίζοντα που θα είναι σε θέση να καλύπτουν τις άμεσες ανάγκες.

Οι μετρήσεις για την διαμόρφωση βάσεων δεδομένων στα τεχνικά έργα έως τώρα γινόντουσαν με βάση κάποιο ορόσημο π.χ. βήμα εκσκαφής. Η αύξηση της χρήσης των τεχνητών νευρωνικών

δικτύων σε συνδυασμό με την συνεχόμενη εξέλιξη της επιστήμης των δεδομένων (Data engineering και Big data) μπορεί να εισέλθει ενδεχομένως πιο ενεργά στην κατασκευή των Υπογείων Έργων κάνοντας δυνατό το γεγονός για περισσότερες μετρήσεις ακόμα συχνότερα οδηγώντας έτσι την επιστημονική κοινότητα στην κατασκευή ακριβέστερων μοντέλων.



Σχήμα 8.1. Σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων των ΤΝΔ για τις υπό εξέταση περιπτώσεις.



Σχήμα 8.2. Σύγκριση μεταξύ των πραγματικών τιμών προχώρησης και των προβλέψεων της σήραγγας Pieve του μοντέλου FF-ANN και CNN-RNN.

Ο συνδυασμός της Μηχανικής Μάθησης που εξελίσσεται συνεχώς και η αυξανόμενη χρήση των TBM είναι το αναπόφευκτο μέλλον. Η σημαντικότητα της πρόβλεψης δύο πολύ σημαντικών παραμέτρων ενός Υπογείου Έργου όπως το κόστος και ο χρόνος τα οποία είναι άρρηκτα συνδεδεμένα με παραμέτρους απόδοσης του TBM (U, AR, PR), σε συνδυασμό με την αβεβαιότητα που διέπει την φύση των Υπογείων Έργων, είναι αδιαμφισβήτητη. Άρα η ανάγκη πρόβλεψης των παραμέτρων απόδοσης του TBM έχει απεύθυνση στην επιστημονική κοινότητα και τα εργαλεία της Μηχανικής και Βαθείας Μάθησης που δίνονται για την επιτευξή τους, ήδη παρουσιάζουν εντυπωσιακά αποτελέσματα κατά τον κόσμο.

9. Βιβλιογραφία

- A. Jamshidi (1973) «Prediction of TBM penetration rate from brittleness indexes using multiple regression analysis», *Modeling Earth Systems and Environment*, (2018) **4**, pp. 383–394.
- Ghasemi et. al., «Predicting penetration rate of hard rock tunnel boring machine using fuzzy logic», *Article in Bulletin of Engineering Geology and the Environment*, February 2014
- Andreas Benardos (2008) «Artificial intelligence in underground development: A study of TBM Performance», *Conference Paper*, August 2008
- A.G. Benardos, D.C. Kaliampakos, (2004), «Modelling TBM performance with artificial neural networks», *Tunnelling and Underground Space Technology* **19**, pp. 597–605
- S. Yagiz et. al., (2009), «Application of two non-linear prediction tools to the estimation of tunnel boring machine performance», *Engineering Applications of Artificial Intelligence* **22**, pp. 808–814
- Nick Ryland Barton, (1999), TBM performance in rock using QTBM. *Article January 1999*
- Saffet Yagiz, *Development of rock fracture and brittleness indices to quantify the effect of rock mass features and toughness in the CSM model basic penetration for hard rock tunneling machines*, Thesis, Colorado School of Mines 2002.
- M. Sapigni, et. al., (2002), «TBM performance estimation using rock mass classifications», *International Journal of Rock Mechanics & Mining Sciences*, **39**, pp.771–788
- Saffet Yagiz, (2001), «Geotechnical parameters influencing the TBM performance in various rocks», *44th Annual Meeting of Association of Engineering Geologists*, Saint Louis, MO USA, **Technical Session 10**, Engineering Geology for Construction Practices p79.
- Tarkoy P.J. , Hendron. A.J., (1975-9), «Rock Hardness Index Properties and Geotechnical Parameters For Predicting Tunnel Boring Machine Performance», University of Illinois, Urbana-Champaign Department of Civil and Environmental Engineering, p. 347
- Giovanni Barla, «Tunnelling mechanics Tunnelling under squeezing rock conditions», In book: *Tunneling Mechanics - Advances in Geotechnical Engineering and Tunneling*, Chapter: 3

- McFeat-Smith I, Fowell RJ, (1977), «Correlation of rock properties and the cutting performance of tunneling machines», *Proceedings of a conference on rock engineering*, CORE-UK, The University of Newcastle upon Tyne, pp. 581–602
- Michael Alber, (2000), «Advance Rates of Hard Rock TBM's and Their Effects on Project Economics», *Tunnelling and Underground Space Technology*, **15**(1), pp. 55-64
- Arne Lislrud, (1988), «Hard rock tunnel boring: Prognosis and costs», *Tunnelling and Underground Space Technology Volume 3, Issue 1*, pp. 9-17
- Amund Bruland, (2000), *Hard Rock Tunnel Boring Vol. 3 - Advance Rate and Cutter Wear*, Thesis for: Dr.ing. (PhD), NTNU
- Priscilla P Nelson et. al., (1995), «Probabilistic prediction of tunnel boring machine performance», *Book Research Transformed into Practice: Implementation of NSF*, pp.283-294
- J. Rostami, L. Ozdemir, D. M. Neil., (1994), «Performance prediction: a key issue in mechanical hard rock mining», *International Journal of Rock Mechanics and Mining Sciences and Geomechanics*, Abstracts
- Ozdemir, L., (1977), *Development of theoretical equation for predicting tunnel boreability*, PhD thesis, Colorado School of Mines
- Jamal I. Rostami, (1997), *DEVELOPMENT OF A FORCE ESTIMATION MODEL FOR ROCK FRAGMENTATION WITH DISC CUTTERS THROUGH THEORETICAL MODELING AND PHYSICAL MEASUREMENT OF CRUSHED ZONE PRESSURE*, Thesis for: PhD, Colorado School of Mines
- Ian Goodfellow et. al., (2016) «*Deep learning*» Book in preparation for MIT Press.
- TunnelTalk, (2019), “Award-winning autonomous TBM operations”, <https://www.tunneltalk.com/Accolades-and-Awards-11Dec2019-Autonomous-TBM-operation-takes-highest-industry-accolades.php>
- Ebrahim Farrokh, (2012), Study of utilization factor and advance rate of hard rock TBMs, Thesis, Pennsylvania State University
- Jian Zhou et. Al., (2020), «Estimating TBM advance rate in hard rock condition using XGBoost and Bayesian optimization», *Underground Space Journal*