



Πανεπιστήμιο Πειραιώς – Τμήμα Πληροφορικής

Πρόγραμμα Μεταπτυχιακών Σπουδών

«Προηγμένα Συστήματα Πληροφορικής – Ανάπτυξη Λογισμικού
και Τεχνητής Νοημοσύνης»

Μεταπτυχιακή Διατριβή

Τίτλος Διατριβής	ΕΚΤΙΜΗΣΗ ΑΞΙΑΣ ΑΚΙΝΗΤΩΝ ΜΕ ΧΡΗΣΗ ΜΕΘΟΔΩΝ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ REAL ESTATE VALUE ESTIMATIONS USING DEEP LEARNING METHODS
Όνοματεπώνυμο Φοιτητή	ΧΑΡΑΛΑΜΠΟΣ ΛΙΟΝΗΣ
Πατρώνυμο	ΜΙΧΑΗΛ
Αριθμός Μητρώου	ΜΠΣΠ / 19029
Επιβλέπων	ΔΙΟΝΥΣΙΟΣ ΣΩΤΗΡΟΠΟΥΛΟΣ, Επίκουρος Καθηγητής

Ημερομηνία Παράδοσης **ΣΕΠΤΕΜΒΡΙΟΣ 2021**

Τριμελής Εξεταστική Επιτροπή

Διονύσιος Σωτηρόπουλος
Επικ. Καθηγητής

Ευάγγελος Σακκόπουλος
Επικ. Καθηγητής

Γεώργιος Τσιχριντζής
Καθηγητής

ΤΙΤΛΟΣ: Εκτίμηση Αξίας Ακινήτων με Χρήση Μεθόδων Βαθιάς Μάθησης

ΣΥΝΤΑΞΑΣ: Χαράλαμπος Λιονής

ΕΠΙΒΛΕΠΩΝ: Διονύσιος Σωτηρόπουλος

ΠΕΡΙΛΗΨΗ

Τα τελευταία χρόνια, έχει αναπτυχθεί στην ερευνητική κοινότητα ένα αυξημένο ενδιαφέρον για την εκτίμηση αξιών ακινήτων, με τεχνικές Deep Learning. Σε αυτή την διπλωματική εργασία παρουσιάζεται η διαδικασία σχεδίασης συνελκτικού νευρωνικού δικτύου, με σκοπό την εκτίμηση αξιών ακινήτων. Για αυτό χρησιμοποιήθηκαν δεδομένα από διάσημες διαδικτυακές πλατφόρμες στην Ελλάδα, προβολής ακινήτων. Για την δημιουργία του μοντέλου αναπτύχθηκε κώδικας στην γλώσσα Javascript και χρησιμοποιήθηκε η βιβλιοθήκη Tensorflow.

TITLE: REAL ESTATE VALUE ESTIMATIONS USING DEEP LEARNING METHODS

STUDENT: CHARALABOS LIONIS

SUPERVISOR: DIONYSIOS SOTIROPOYLOS

ABSTRACT

In recent years, the research community has developed an increased interest in real estate valuation, using Deep Learning techniques. In this work presented the process of designing a deep neural network, with the aim of estimating real estate values. For this purpose, data related to real estate from famous Greek websites were used. The software was developed in Javascript programming language and the TensorFlow framework.

ΠΙΝΑΚΑΣ ΠΕΡΙΕΧΟΜΕΝΩΝ

1	ΕΙΣΑΓΩΓΗ – ΣΥΝΤΟΜΗ ΠΕΡΙΓΡΑΦΗ ΑΝΤΙΚΕΙΜΕΝΟΥ	1
1.1	Αντικείμενο – Σκοπός	1
1.2	Εργαλεία – Μέθοδοι	1
2	ΘΕΩΡΗΤΙΚΗ ΠΕΡΙΓΡΑΦΗ ΤΟΥ ΑΝΤΙΚΕΙΜΕΝΟΥ ΠΡΟΣ ΜΕΛΕΤΗ	2
2.1	Αξία Εμπορεύματος	2
2.2	Τιμή Εμπορεύματος	2
2.3	Το Ακίνητο ως Εμπόρευμα	3
2.4	Τιμή Ακινήτου και Παράγοντες που το επηρεάζουν	3
3	ΠΕΡΙΓΡΑΦΗ ΤΩΝ ΜΕΘΟΔΩΝ ΕΚΤΙΜΗΣΗΣ ΑΞΙΩΝ ΑΚΙΝΗΤΩΝ	6
3.1	Μέθοδος Αγοραίας Αξίας ή Μέθοδος των Συγκριτικών Στοιχείων	6
3.2	Μέθοδος του Κόστους Αντικατάστασης	6
3.3	Μέθοδος της Προσόδου	7
3.4	Μέθοδος Εκτίμησης Βάσει του “Business Valuation Theory”	7
3.5	Generic Real Value Model (Jefferies)	8
3.6	DYNAMIC CAPITALIZATION MODEL (Blackadar)	9
3.7	REAL VALUE / EQUATED YIELD HYBRID MODEL (Crosby)	10
4	ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ	11
4.1	Εισαγωγή	11
4.2	Βασικές Έννοιες Μηχανικής Μάθησης	12
4.2.1	Κατηγορίες Συστημάτων Μηχανικής Μάθησης	12
4.2.2	Υποεκπαίδευση και Υπερεκπαίδευση	14
4.3	Τεχνικές Deep Learning	16
4.3.1	Καταπολέμηση της Υπερεκπαίδευσης και της Υποεκπαίδευσης	16
4.3.2	Ελαχιστοποίηση του κόστους – Αλγόριθμοι βελτιστοποίησης	16
4.3.3	Αρχικοποίηση βαρών και συναρτήσεις ενεργοποίησης	20
4.3.4	Τεχνικές regularization	22

4.4	Συνελικτικά Νευρωνικά Δίκτυα	24
4.4.1	Βασικές δομές συνελικτικών νευρωνικών δικτύων	24
4.4.2	Σημαντικότερα πλεονεκτήματα συνελικτικών νευρωνικών δικτύων	26
5	ΕΚΤΙΜΗΣΗ ΑΞΙΩΝ ΑΚΙΝΗΤΩΝ ΜΕΣΩ ΕΦΑΡΜΟΓΗΣ ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ	27
5.1	Βάση Δεδομένων	27
5.1.1	Αγγελίες Ακινήτων	27
5.1.2	Διοικητική Διαίρεση Ελλάδας	27
5.1.3	Αντικειμενικές Τιμές Ακινήτων	27
5.1.4	Πεδία της Βάσης Δεδομένων Ακινήτων	28
5.1.5	Κατανομή Τιμών Ακινήτων	29
5.2	Δημιουργία του Μοντέλου	30
5.2.1	Κανονικοποίηση Δεδομένων Βάσης Δεδομένων	30
5.2.2	Διαχωρισμός των Δεδομένων σε Train και Test	30
5.2.3	Επίπεδα (layers), Κρυμμένα Επίπεδα (hidden layers) και Παράμετροι του Compiler	31
5.3	Αποτελέσματα του Μοντέλου	32
5.3.1	Μέσω Τετραγωνικό Σφάλμα Epoch	32
5.3.2	Ποσοστό Επιτυχίας Μοντέλων	33
6	ΣΥΜΠΕΡΑΣΜΑΤΑ	35
6.1	Παράγοντες όπου Επηρεάζουν Αρνητικά την Ακρίβεια Μοντέλου	35
6.2	Παράγοντες όπου Επηρεάζουν Θετικά την Ακρίβεια του Μοντέλου	35
	ΠΕΡΙΛΗΨΗ	36
	ΒΙΒΛΙΟΓΡΑΦΙΑ	37

1 ΕΙΣΑΓΩΓΗ – ΣΥΝΤΟΜΗ ΠΕΡΙΓΡΑΦΗ ΑΝΤΙΚΕΙΜΕΝΟΥ

Οι μελέτες προσδιορισμού και μελλοντικής εκτίμησης της διακύμανσης των τιμών των ακινήτων, αλλά και γενικότερα όλων των εμπορευμάτων, είναι θεμελιώδεις για την λειτουργία κάθε οικονομίας.

Μέσω αυτών των εκτιμήσεων και των προβλέψεων:

- Προσδιορίζεται το ποσό της αγοράς – πώλησης ή μίσθωσης ενός ακινήτου,
- Αποτιμάται η ατομική περιουσία ή η περιουσία μίας επιχείρησης στην περίπτωση όπου αυτή κατέχει ακίνητα (πάγια),
- Ρυθμίζεται η ροή χρήματος από χρηματοπιστωτικούς οργανισμούς προς δανειζόμενους, αφού το μέγεθος της πίστωσης εξαρτάται κατά μεγάλο ποσοστό από την αξία των ακινήτων που υποθηκεύονται.
- Καθορίζεται η ποσότητα και το είδος μίας ιδιωτικής επένδυσης,
- Καθορίζεται η ποσότητα και το είδος μίας δημόσιας επένδυσης, στην περίπτωση όπου πρέπει να απαλλοτριωθούν ακίνητα.

1.1 Αντικείμενο – Σκοπός

Σκοπός της εργασίας είναι μέσω της αξιοποίησης της επιστήμης της πληροφορικής και συγκεκριμένα της μεθόδου της τεχνητής νοημοσύνης και μηχανικής μάθησης, να δημιουργηθεί ένα αξιόπιστο μαθηματικό μοντέλο για την εκτίμηση αξιών ακινήτων.

1.2 Εργαλεία – Μέθοδοι

Για την επίλυση του προβλήματος θα εφαρμοστούν με χρήση Η/Υ τεχνικές τεχνητής νοημοσύνης. Ο όρος τεχνητή νοημοσύνη αναφέρεται στον κλάδο της πληροφορικής ο οποίος ασχολείται με τη σχεδίαση και την υλοποίηση υπολογιστικών συστημάτων που μιμούνται στοιχεία της ανθρώπινης συμπεριφοράς τα οποία υπονοούν έστω και στοιχειώδη ευφυΐα: μάθηση, προσαρμοστικότητα, εξαγωγή συμπερασμάτων, επίλυση προβλημάτων κλπ.

Η ανάπτυξη του λογισμικού για την δημιουργία του μαθηματικού μοντέλου θα γίνει με την γλώσσα προγραμματισμού Javascript και την χρησιμοποίηση της πλατφόρμας τεχνητής νοημοσύνης και μηχανικής μάθησης Tensorflow.

2 ΘΕΩΡΗΤΙΚΗ ΠΕΡΙΓΡΑΦΗ ΤΟΥ ΑΝΤΙΚΕΙΜΕΝΟΥ ΠΡΟΣ ΜΕΛΕΤΗ

2.1 Αξία Εμπορεύματος

Στην παρούσα εργασία θα εξεταστούν τα ακίνητα ως εμπορεύματα, που ως φορείς αξίας δεν διαφέρουν σε τίποτα από τα άλλα εμπορεύματα.

Κάθε εμπόρευμα εμπρικλείει δύο μέρη. Την ανταλλακτική αξία και την αξία χρήσης.

- Ως **αξία χρήσης** νοείται η χρηστική αξία των εμπορευμάτων, δηλαδή το σύνολο των ανθρώπινων αναγκών που αυτά ικανοποιούν. Το σύνολο των αξιών χρήσης των εμπορευμάτων κάθε έθνους είναι και ο πραγματικός τους πλούτος.
- Ως **ανταλλακτική αξία** εμπορεύματος νοείται η αξία του εμπορεύματος κατά την διαδικασία ανταλλαγής με άλλα εμπορεύματα.
- Η ανταλλακτική αξία ενός εμπορεύματος καθορίζεται από το άθροισμα των ανταλλακτικών αξιών των εμπορευμάτων που χρησιμοποιήθηκαν κατά την παραγωγική διαδικασία και λόγω αυτής μεταβίβασαν μέρος της αξίας τους στο νέο εμπόρευμα.
- Ως εμπορεύματα που συμμετέχουν στην δημιουργία νέων εμπορευμάτων, είναι οι **συντελεστές παραγωγής**, δηλαδή η εργασία, τα μέσα παραγωγής και οι πρώτες ύλες.
- Το γενικό ισοδύναμο εξίσωσης των ανταλλακτικών αξιών των εμπορευμάτων είναι οι **εργατοδωρες**. Η ενέργεια που εμπρικλείουν τα εμπορεύματα ως μέσα αποθήκευσης ανθρώπινης εργασίας είναι αυτή που μεταβιβάζουν κατά την παραγωγική εργασία σε νέα εμπορεύματα.

2.2 Τιμή Εμπορεύματος

Η εμπορευματική συναλλαγή συντελείται από την στιγμή ύπαρξης του χρήματος. Το **Χρήμα** είναι εμπόρευμα όπου ο μοναδικός σκοπός της ύπαρξης του είναι η γενική εξίσωση της ανταλλακτικής αξίας όλων των εμπορευμάτων με αυτό. Το ιδιαίτερο αυτό εμπόρευμα έχει προκύψει μέσω της αφαιρετικής διαδικασίας, καθώς είναι εμπόρευμα που στερείται της αξίας χρήσης, άρα έχει μόνο ανταλλακτική αξία.

Μέσω της τεχνολογίας στην σύγχρονη μορφή του το χρήμα ολοένα και πλησιάζει την πραγματική του φύση αφού τις περισσότερες φορές στερείται της υλικής του υπόστασης, έχοντας πάρει την μορφή ψηφιακών λογιστικών εγγραφών. Η άυλη μορφή του χρήματος σε συνδυασμό με την σχεδόν εκμηδένιση της εργασίας που χρειάζεται για να παραχθεί και να κυκλοφορήσει, το μετατρέπει σε καθαρό σύμβολο αξίας.

Η **τιμή** ενός εμπορεύματος είναι η ποσότητα του χρήματος που αντανακλάται η ανταλλακτική αξία των εμπορευμάτων. Η τιμή των εμπορευμάτων επομένως εξαρτάται από την διαδικασία ύπαρξης του χρήματος δηλαδή, την γέννηση, τον τρόπο που κυκλοφορεί, και τον θάνατό του (κύκλος του χρήματος), καθώς και τους παράγοντες που επηρεάζουν την αξία του.

Σε αντίθεση με την αξία των εμπορευμάτων όπου γεννιούνται μέσω της εκ φύσεως δημιουργικότητας του ανθρώπου και τις πρώτες ύλες όπου βρίσκει στο περιβάλλον, το χρήμα είναι καθαρά ανθρώπινο δημιούργημα. Ως εκ τούτου, οι πολιτικές αποφάσεις και το δίκαιο του κάθε κράτους είναι αυτά που ρυθμίζουν την αξία και τις ροές του.

2.3 Το Ακίνητο ως Εμπόρευμα

Το ακίνητο ως πράγμα χωρίζεται σε δύο μέρη. Το υποκείμενο γήπεδο και τα επικείμενα.

- Το **υποκείμενο** γήπεδο είναι τα νοητά όρια ενός γηπέδου σε σχέση με κάποιο γεωμετρικό ή γεωγραφικό σύστημα αναφοράς.
- **Επικείμενα** σε ένα ακίνητο είναι τα πράγματα όπου υπάρχουν εντός των ορίων του υποκειμένου. Τα πράγματα αυτά μπορεί να είναι είτε τεχνητά όπως κτίρια, περίφραξη είτε φυσικά όπως δέντρα, μεταλλεύματα κτλ.

Τα εμπράγματα δικαιώματα στα ακίνητα γεννιούνται καταρχήν από την νομή και κατοχή από τους ιδιοκτήτες τους. Όμως με την ένταξη του ακινήτου και της δραστηριότητας εντός ορίων αυτού στην επικράτεια ενός κράτος δικαίου, τότε τα εμπράγματα δικαιώματα υφίστανται υπό τη μορφή τίτλου ιδιοκτησίας, όπου μέσω αυτού ορίζεται:

- α) Τα όρια και το γεωμετρικό μέγεθος του ακινήτου, καθώς και τα επικείμενα επί αυτού.
- β) Ο ιδιοκτήτης και το είδος του εμπράγματος δικαιώματος επί του ακινήτου.

Απαραίτητη προϋπόθεση προκειμένου ένα ακίνητο εντός κράτος δικαίου να είναι εμπόρευμα είναι να υπάρχουν για αυτό τίτλοι ιδιοκτησίας.

Πέραν των τίτλων ιδιοκτησία, εντός ενός κράτους υπάρχουν διοικητικές πράξεις που καθορίζουν τις χρήσεις γης των γηπέδων, καθώς και διοικητικές πράξεις που μεταβάλουν τα όρια και τους ιδιοκτήτες των ακινήτων.


Συνοψίζοντας, τα χαρακτηριστικά των ακινήτων ως εμπόρευμα είναι:

- Ο τίτλος ιδιοκτησίας, δηλαδή όρια και είδος εμπράγματος δικαιώματος
- Οι επιτρεπόμενες χρήσεις γης του ακινήτου
- Τα χαρακτηριστικά των επικειμένων του ακινήτου καθώς και τα εμπράγματα δικαιώματα επί αυτών

2.4 Τιμή Ακινήτου και Παράγοντες που το επηρεάζουν

Κατά την αγοροπωλησία ακινήτων, όπως και κάθε εμπορεύματος, μέσω της τέχνης της επικοινωνίας και της διαπραγμάτευσης, ο αγοραστής και ο πωλητής προσπαθεί να διεκδικήσει καλύτερη συμφέρουσα τιμή προς το μέρος του. Ο αγοραστής προσπαθεί να αγοράσει κατά το δυνατόν φθηνότερα και ο πωλητής προσπαθεί να πωλήσει κατά το δυνατόν ακριβότερα. Η συμφωνηθείσα και στη συνέχεια υλοποιηθείσα συναλλαγή είναι η τιμή του εμπορεύματος.

Αν θεωρήσουμε ότι η κίνηση και αποθήκευση του χρήματος σε μία οικονομία είναι ένας γράφος $G(v, e)$ όπου οι κόμβοι V του γράφου είναι πρόσωπα που συμμετέχουν στον οικονομικό γίγνεσθαι και ως ακμές E του γράφου είναι η κίνηση του χρήματος μεταξύ προσώπων. Τότε μία μεμονωμένη εμπορική συναλλαγή περιγράφεται στο παρακάτω σχήμα.



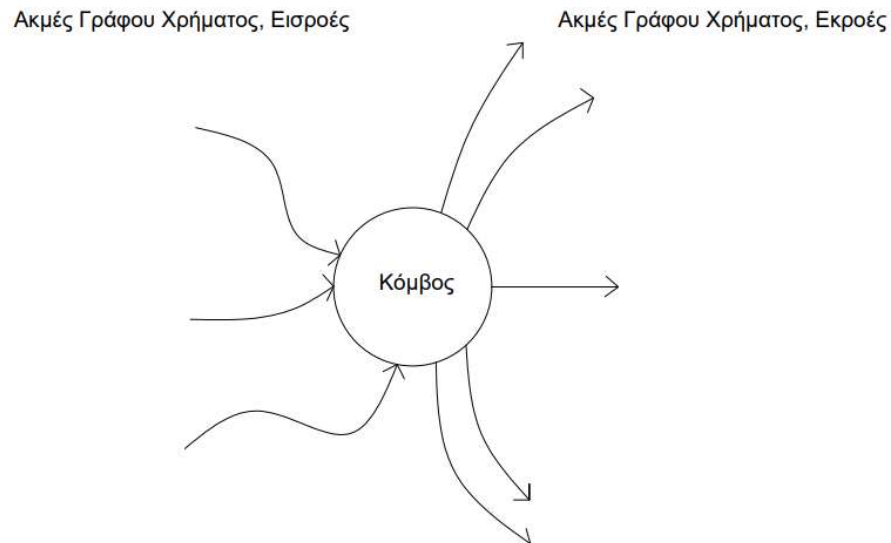
Σχήμα 2.1

Σκοπός μας είναι να ερευνήσουμε τα ποσοτικά και ποιοτικά στοιχεία αυτού του γράφου, προκειμένου να ταξινομήσουμε τους κόμβους και τις σχέσεις μεταξύ τους, για την δημιουργία οικονομικών μοντέλων. Η επιτυχία και η ορθότητα των εκτιμήσεων για την τιμή των εμπορευμάτων εξαρτάται από την ποιότητα της μοντελοποίησης του παραπάνω γράφου.

Παρακάτω περιγράφονται δείκτες που επηρεάζουν την τιμή των εμπορευμάτων και που χρησιμοποιούνται για την ταξινόμηση του γραφήματος.

- Για κάθε κόμβο στο γράφημα, σε ένα δεδομένο χρονικό διάστημα, συντελείται ένα πλήθος εισροών και εκροών χρήματος. Ως χρήμα αποθηκευμένο σε κάθε κόμβο ορίζεται το άθροισμα των εισροών μείον το άθροισμα των εκροών συν το προηγούμενο υπόλοιπο χρήματος.

$$\text{Αποθηκευμένο Χρήμα} = \Sigma \text{εισροές} - \Sigma \text{εκροές} + \text{προηγούμενο υπόλοιπο}$$



Σχήμα 2.2

- Το σύνολο του αποθηκευμένου σε όλους τους κόμβους χρήμα μία δεδομένη στιγμή είναι το σύνολο του χρήματος που υπάρχει στην οικονομία και το συμβολίζουμε με ΣX κόμβου.
- Σε μία δεδομένη στιγμή του γράφου, το σύνολο του χρήματος που είναι αποθηκευμένο στο σύνολο των κόμβων είναι η συνολική ποσότητα του χρήματος που υπάρχει στην οικονομία και το συμβολίζουμε με ΣX .
- Σε μία δεδομένη χρονική περίοδο το άθροισμα των ακμών του αφορούν όλες τις συναλλαγές στην οικονομία, ονομάζεται συνολικός τζίρος και το συμβολίζουμε με Σe
- Σε μία δεδομένη χρονική περίοδο το άθροισμα των ακμών που αφορούν συναλλαγές ακινήτων είναι ο συνολικός τζίρος αγοροπωλησίας ακινήτων και το συμβολίζουμε με Σe ακινήτων.

$$\Sigma \text{ συναλλαγών} = \Sigma \text{ συναλλαγών ακινήτων} + \Sigma \text{ λοιπών συναλλαγών}$$

- Το % ποσοστό του $\Sigma e / \Sigma e$ ακινήτων μας δείχνει το ποσοστό που διεκδικούν στον συνολικό οικονομικό κύκλο η αγοροπωλησίες ακινήτων.

Εάν τώρα συμπεριλάβουμε στην ανάλυση μας ότι οι συναλλαγές συντελούνται στα πλαίσια ενός χώρου υπό την κυριαρχία κρατών, τότε ο παραπάνω γράφος έχει ουσιαστικές ποιοτικές και ποσοτικές διαφορές από χώρα σε χώρα. Πρέπει να συμπεριλάβουμε στην ανάλυση το σύνολο των εισροών και εκροών χρήματος από και προς κάθε χώρα, σε σχέση πάλι με το πλήθος των συναλλαγών, το πλήθος του χρήματος, του πλήθους των συναλλαγών μεταξύ διαφορετικών κατηγοριών εμπορευμάτων (πχ % συναλλαγών ακινήτων). Ακόμα πρέπει να λάβουμε υπόψιν στις διεθνείς συναλλαγές την διαφορετική αξία χρήματος από κράτος σε κράτος.

3 ΠΕΡΙΓΡΑΦΗ ΤΩΝ ΜΕΘΟΔΩΝ ΕΚΤΙΜΗΣΗΣ ΑΞΙΩΝ ΑΚΙΝΗΤΩΝ

Το κυριότερο πρόβλημα στις εκτιμήσεις αξιών ακινήτων είναι η πρόσβαση σε σωστές πληροφορίες που αφορούν αγοροπωλησίες ακινήτων, αλλά και γενικότερα αγοροπωλησίες εμπορευμάτων.

Η αιτία πρωτίστως της απόκρυψης των πληροφοριών αυτών από τους αγοραστές και πωλητές, είναι να μειωθούν τα έξοδα μεταβίβασης ακινήτου. Όσα λιγότερα χρήματα δηλωθούν, τόσο λιγότερα έξοδα μεταβίβασης χρειάζονται. Κατ' επέκταση, για τον ίδιο λόγο δεν υπάρχουν απολύτως αξιόπιστοι μακροοικονομικοί δείκτες στην οικονομία.

Επιπλέον, υπάρχει συμφέρον για την μη αποκάλυψη της σωστής πληροφορίας από τους γνώστες της, διότι η σωστή πληροφορία και η διαχείρισή της είναι αυτή που καθορίζει εν τέλει την τιμή του κάθε εμπορεύματος, αφού όπως αναφέραμε και παραπάνω η τιμή κάθε εμπορεύματος είναι θέμα επικοινωνιακής τέχνης και διαπραγματεύσεως. Η γνώση σωστής πληροφορίας φέρνει σε πλεονεκτική θέση τον διαπραγματευτή για να πετύχει καλύτερη συμφέρουσα τιμή προς το μέρος του.

Ακόμα, για την εκτίμηση των μελλοντικών αξιών ακινήτων, είναι απαραίτητη η πρόσβαση σε πληροφορίες για μελλοντικές διοικητικές πράξεις που καθορίζουν τις αξίες ειδικά των ακινήτων. Για παράδειγμα η απόφαση της διοίκησης για αλλαγές χρήσεις γης σε μία περιοχή ή μία επέκταση σχεδίου πόλης, μπορεί να μεταβάλει ολόκληρο τον χαρακτήρα μίας περιοχής και να μεταβάλει κατά πολύ τις αξίες της. Επίσης η μεταβολή στην φορολογία ακινήτων ή οι μεταβολές στον φόρο μεταβίβασης, επίσης μεταβάλει την αξία των ακινήτων.

Παρακάτω γίνεται περιγραφή των επικρατέστερων μεθόδων εκτίμησης αξιών ακινήτων.

3.1 Μέθοδος Αγοραίας Αξίας ή Μέθοδος των Συγκριτικών Στοιχείων

Η συγκεκριμένη μέθοδος αποτελεί την παλαιότερη προσέγγιση αξίας ακινήτων που χρησιμοποιείται στην Ελληνική Κτηματαγορά. Ανήκει στις παραδοσιακές μεθόδους εκτίμησης ακινήτων και χρησιμοποιείται ευρύτατα για τον υπολογισμό της αξίας κατοικιών. Σύμφωνα με τη μέθοδο αυτή, η αγοραία αξία ενός ακινήτου μπορεί να εκτιμηθεί με σύγκριση των αξιών άλλων παρόμοιων ακινήτων που έχουν αποτελέσει αντικείμενο συναλλαγής. Η συγκεκριμένη μέθοδος θα εφαρμοστεί σε αυτή την εργασία.

Τα μαθηματικά που εφαρμόζονται για την μοντελοποίηση ποικίλουν. Στην συγκεκριμένη εργασία θα εφαρμοστούν αλγόριθμοι Τεχνητής Νοημοσύνης και Βαθιάς Μηχανικής Μάθησης για την επεξεργασία των δεδομένων. Οι τεχνικές αυτές θα αναλυθούν σε επόμενο κεφάλαιο.

3.2 Μέθοδος του Κόστους Αντικατάστασης

Για την εκτίμηση της αξίας του ακινήτου (γης και κτιρίου), με τη μέθοδο του κόστους αντικατάστασης, θεωρούμε ένα σενάριο κατασκευής ενός νέου κτιρίου, που θα έχει την ίδια χρήση και θα είναι παρόμοιο με το προς εκτίμηση υπάρχον κτίριο σε ένα οικόπεδο.

Σύμφωνα με τη μέθοδο αυτή, η αξία ενός ακινήτου προκύπτει αν στο συνολικό κόστος κατασκευής του νέου κτιρίου σε τρέχουσες τιμές, στο οποίο συμπεριλαμβάνεται και το εργολαβικό και επιχειρηματικό όφελος, δηλ. το κέρδος, προσθέσουμε την αξία γης (αυξημένη κατά την υπεραξία λόγω ύπαρξης του κτίσματος) και στη συνέχεια αφαιρέσουμε τη συνολική απαξίωση (υποτίμηση) που

υπέστη το υπάρχον προς εκτίμηση κτίριο, λόγω λειτουργικής παλαιότητας, ζημιών, φθορών λόγω χρήσης, ανεπαρκών συντηρήσεων και άλλων ελλείψεων σε σχέση με το νέο θεωρητικό κτίριο.

3.3 Μέθοδος της Προσόδου

Η μέθοδος αυτή χρησιμοποιείται στην αποτίμηση ακινήτων που αποτελούν αντικείμενο ιδιοκτησίας με κύριο σκοπό την αποκόμιση μισθωμάτων σε ετήσια βάση, δηλαδή τα επενδυτικά ακίνητα. Τα ακίνητα αυτά προορίζονται για την κεφαλαιακή ενίσχυση του ιδιοκτήτη τους και όχι για λειτουργική χρήση (π.χ. ξενοδοχεία, εστιατόρια, γραφεία κ.λπ.). Βασικό στοιχείο της μεθόδου αυτής είναι ότι στηρίζομαστε σε προσδοκίες. Η διάσταση του μελλοντικού χρόνου παίζει σημαντικό ρόλο στην εκτίμηση. Η αξία του ακινήτου ορίζεται σαν η Παρούσα Αξία των αναμενόμενων εισροών που θα ληφθούν κατά τη διάρκεια ζωής του ακινήτου.

Η συγκεκριμένη μεθοδολογία παρουσιάζει ενοποιημένα τις ταμειακές ροές, δηλ. τα ετήσια καθαρά μισθώματα (Net Operating Income N.O.I. ή Net Cash Flows N.C.F.) και την αξία πώλησης του ακινήτου στη λήξη της παρούσας μίσθωσης (Sales price S.P.). Συνεπώς, δημιουργείται μία σειρά μελλοντικών ταμειακών ροών, οι οποίες στη συνέχεια προεξοφλούνται βάσει του προεξοφλητικού επιτοκίου (discount rate) για τον υπολογισμό της συνολικής παρούσας αξίας του ακινήτου.

Κατά την εκτίμηση του ακινήτου, τα σημεία που χρήζουν ιδιαίτερης προσοχής είναι τα εξής:

- Το αρχικό ετήσιο μίσθωμα υπολογίζεται σε επίπεδο αντίστοιχο με το ετήσιο μίσθωμα ομοειδών ακινήτων που ήδη μισθώνονται στην αγορά. Προκειμένου να εκτιμηθούν τα μισθώματα ανά έτος στο μέλλον, χρησιμοποιείται ο ρυθμός ανάπτυξης της οικονομίας (ετήσιο ποσοστό αύξησης του Α.Ε.Π.).
- Το προεξοφλητικό επιτόκιο (discount rate) είναι συνήθως το risk-free rate, και το επιλέγουμε ανάλογα με την πορεία της οικονομίας.

Η μέθοδος της προσόδου διακρίνεται σε άμεση και έμμεση. Εμπλέκονται οι έννοιες της προεξόφλησης και της κεφαλαιοποίησης μιας ροής εισοδήματος. Οι μεταβλητές, όπως για παράδειγμα, το καθαρό λειτουργικό εισόδημα (N.O.I.) ή οι ταμειακές ροές (N.C.F.), χρησιμοποιούνται για να δείξουν το όφελος που αποκομίζει ο ιδιοκτήτης από τη χρήση του ακινήτου.

3.4 Μέθοδος Εκτίμησης Βάσει του “Business Valuation Theory”

Το “Business Valuation Theory”, βάσει της μελέτης του Jenkins (2006) [4] αναγνωρίζει τρεις μεθόδους αποτίμησης της αξίας των ακινήτων:

α) Income capitalization approach: Για την αποτίμηση της αξίας, χρησιμοποιείται σαν βάση το μελλοντικό εισόδημα που θα αποφέρει το περιουσιακό στοιχείο.

β) Asset – based data approach: Εστιάζει στον προσδιορισμό της συνολικής αξίας των περιουσιακών στοιχείων ενός ατόμου. Στην περίπτωση των εταιρειών διαχείρισης ακινήτων, για να καταλήξουμε στην καθαρή παρούσα αξία του ακινήτου, θα πρέπει να έχουμε τα στοιχεία του Ενεργητικού και του Παθητικού της εταιρείας σε τρέχουσες τιμές, είτε ένα – ένα (discrete valuation), είτε όλα μαζί (collective valuation). Λόγω της δυσκολίας του να αποτιμηθούν όλα τα στοιχεία του Παγίου Ενεργητικού της εταιρείας (κτίρια, μηχανήματα κ.λπ.) ένα – ένα και λόγω των διαφορετικών συνθηκών της αγοράς κάθε φορά που εκτιμώνται τα ακίνητα, είναι πολλές φορές αναγκαία η εκτίμηση από ειδικούς εκτιμητές.

γ) Market approach: Είναι προϊόν των δύο παραπάνω μεθόδων αποτίμησης της αξίας. Καθένα από αυτά τα μοντέλα προσδιορίζει ένα μέρος της λειτουργίας για τον προσδιορισμό της αξίας ενός ακινήτου ή μιας εταιρείας διαχείρισης ακινήτων. Η προσέγγιση αυτή είναι μια υβριδική τεχνική που συνδυάζει και τις δύο μεθόδους. Μπορεί να θεωρηθεί καλύτερο μοντέλο αποτίμησης της αξίας των ακινήτων, καθώς και πιο αποτελεσματικό γιατί χρησιμοποιεί τα θετικά στοιχεία από κάθε μία από τις δύο αυτές προσεγγίσεις.

Τα βασικά σημεία στα οποία πρέπει να εστιάσουμε για να κατανοήσουμε την αποτελεσματικότητα της υβριδικής προσέγγισης είναι τα εξής:

- Η εκτίμηση της αξίας βασίζεται σε συλλογική εκτίμηση δεδομένων και για το εισόδημα αλλά και για περιουσιακά στοιχεία.
- Τα υβριδικά μοντέλα υπερέχουν, όσον αφορά την ακρίβεια στην εκτίμηση της αξίας, καθώς και σε άλλα οικονομικά μεγέθη.
- Χρησιμοποιούνται ταυτόχρονα πληροφορίες που περιέχονται σε δεδομένα για: α) εισόδημα και β) περιουσιακά στοιχεία.

Αν έχουμε τα στοιχεία συγκεντρωτικά, οι δύο μέθοδοι δίνουν πιο ακριβή αποτελέσματα και η ανάλυση είναι πιο αποδοτική. Αυτό είναι το πλεονέκτημα της υβριδικής προσέγγισης για τον υπολογισμό της αξίας, από το να χρησιμοποιούσαμε την κάθε μέθοδο ξεχωριστά.

3.5 Generic Real Value Model (Jefferies)

Η επίδραση του πληθωρισμού και η αλληλεπίδρασή του με την ανάπτυξη της οικονομίας σε πραγματικά αντί σε ονομαστικά μεγέθη ήταν ένα πρόβλημα που απασχόλησε τον Jefferies το 1977, όταν αρχικά ανέπτυξε το υπόδειγμά του στη Νέα Ζηλανδία διότι τα παραδοσιακά υποδείγματα εκτίμησης δε γνώριζαν πώς να συμπεριλάβουν τους όρους αυτούς στη εκτίμηση των ακινήτων με ένα ορθολογιστικό και παράλληλα τεχνικό τρόπο.

Κατά τη διάρκεια του συγγραφικού του έργου, ο Jefferies διέσπειρε τεχνικές κεφαλαιοποίησης, οι οποίες στη συνέχεια υιοθετήθηκαν και χρησιμοποιούνται ακόμα στη Νέα Ζηλανδία ως "Η Βίβλος της Εκτιμητικής" (Jefferies, 2009) [5]. Το 1997, εφάρμοσε για πρώτη φορά τις τεχνικές του για την εκτίμηση ακινήτων, κάτι το οποίο βέβαια δεν ήταν πρωτόγνωρο για την εποχή. Ήδη στο Ηνωμένο Βασίλειο υπήρχαν τα μοντέλα του Dr. Neil Crosby και του Dr. Earnest Wood, καθώς και στις Η.Π.Α. το μοντέλο του Gordon Blackadar. Το νέο αυτό μοντέλο διαφέρει από τα μοντέλα που αναπτύχθηκαν στο Ηνωμένο Βασίλειο και στις Η.Π.Α. από την άποψη ότι είναι πιο απλό και εύχρηστο για τον εκτιμητή. Ο Jefferies πίστευε ότι το μοντέλο του θα γινόταν αποδεκτό και δε θα είχε την ίδια τύχη με τα μοντέλα του Ηνωμένου Βασιλείου και των Η.Π.Α.

Το μοντέλο του Jefferies στηρίζεται στο μοντέλο Προεξόφλησης Χρηματοροών (D.C.F.), όπου οι χρηματοροές στηρίζονται σε ετήσιες προβλέψεις και χρειάζονταν συχνά αναπροσαρμογές στα ποσά των ενοικίων, στα έξοδα, στους δείκτες επιτοκίων που χρησιμοποιούνταν, κ.λπ. με αποτέλεσμα να απαιτούνται αλλαγές στα κελιά της φόρμουλας. Ο Jefferies πιστεύει ότι οι χρηματοροές μπορούν να εκφραστούν πιο απλά και σε πραγματικά μεγέθη. Αναφέρεται στο μοντέλο του λέγοντας τα εξής: «...μεταχειρίζεται το γνωστό εισόδημα από ενοίκια, σαν μια κανονική ράντα προεξοφλημένη με ένα συντελεστή απόδοσης ο οποίος συμπεριλαμβάνει την αύξηση της απόδοσης των επενδύσεων.», και συνεχίζει αναφέροντας ότι: «Το μοντέλο εκτίμησης της αξίας των ακινήτων βασίζεται στο ότι προβλέπει το αναθεωρημένο εισόδημα από ενοίκια και την επαναφορά των ενοικίων στη λήξη, σε πραγματικούς όρους, προεξοφλώντας τα με συντελεστή απόδοσης των επενδύσεων "καθαρό από πληθωρισμό και ανάπτυξη"».

Η βασική ιδέα του μοντέλου είναι ότι «Οι τρέχουσες ονομαστικές αξίες είναι και οι πραγματικές ή αγοραίες αξίες, βάσει των όρων που αναγράφουν, τα συμβόλαια μίσθωσης και οι μελλοντικές αξίες σε πραγματικά μεγέθη, μπορούν να εκφραστούν στις τρέχουσες ονομαστικές αξίες, αφού προεξοφληθούν, λόγω του κινδύνου αθέτησης πληρωμής των υποχρεώσεων.» (Jefferies, 2009)

Για να προκύψει η παρούσα αξία του ακινήτου, γίνεται προεξόφληση των ποσών των ενοικίων που αναγράφονται στα συμβόλαια μίσθωσης, καθώς και των εξόδων, μέχρι την ημερομηνία της επόμενης επανεξέτασης. Προσθέτουμε στην παρούσα αξία των ενοικίων, την παρούσα αξία της τελικής αξίας του ακινήτου (terminal value / reversion value), που έχει υπολογισθεί βάσει της ανάπτυξης της οικονομίας. Ο πληθωρισμός δεν υπολογίζεται σαν ξεχωριστό μέγεθος, αλλά λαμβάνεται υπόψη μέσα στο ρυθμό οικονομικής ανάπτυξης.

3.6 DYNAMIC CAPITALIZATION MODEL (Blackadar)

Το πιο κατανοητό μοντέλο εκτίμησης ακινήτων που αναπτύχθηκε στις Ηνωμένες Πολιτείες Αμερικής είναι το μοντέλο «Δυναμικής Κεφαλαιοποίησης». Αναπτύχθηκε τη δεκαετία του 1980 από τον Blackadar (1986) [1]. Η συμβολή του Blackadar στον τομέα της εκτίμησης ακινήτων γίνεται εμφανής από τη μελέτη του, αν λάβουμε υπόψη ότι εκδόθηκε αρχικά το 1984, σε μία έκδοση, η οποία είναι η μόνη πλήρως αναπτυγμένη έκδοση που αναφέρεται σε ένα μοντέλο εκτίμησης ακινήτων και υπάρχει στη διεθνή βιβλιογραφία. Αναφέρεται στην εκτίμηση των ακινήτων λέγοντας ότι είναι “μια προσέγγιση εισοδήματος σε πραγματικό επιτόκιο σε δολάρια”. Ενδιαφέρον παρουσιάζει και η αναφορά του Blackadar στον Έλληνα Μαθηματικό Ευκλείδη (300 π.Χ.), στον οποίο θεωρεί ότι βασίζεται η προεξόφληση των επιτοκίων.

Το μοντέλο του Blackadar εστιάζει στην επίδραση του πληθωρισμού στις αξίες των περιουσιακών στοιχείων ανεξάρτητα από την επίδραση της ανάπτυξης της οικονομίας, θεωρώντας ότι έτσι το αποτέλεσμα της εκτίμησης είναι πιο ακριβές. Θα έπρεπε, ωστόσο, το μοντέλο να συνδεθεί με κάποια μέθοδο εκτίμησης που υπήρχε τότε, για παράδειγμα με τη μέθοδο κεφαλαιοποίησης χρηματοροών. Δημιούργησε, λοιπόν, ο Blackadar μια ράντα, της οποίας τα στοιχεία μεταβάλλονται κατά τη διάρκεια ζωής του ακινήτου. Συγκριτικά με τα υπόλοιπα μοντέλα εκτίμησης ακινήτων, εδώ δεν υπάρχει επιτόκιο κεφαλαιοποίησης, αλλά ένας πολλαπλασιαστής εισοδήματος, που αναφέρεται στα ακαθάριστα έσοδα. Τα έξοδα δεν αφαιρούνται, αλλά ενσωματώνονται στον πολλαπλασιαστή εισοδήματος, ο οποίος μεταβάλλεται κατά περίπτωση.

Η παρούσα αξία του ακινήτου προκύπτει από την παρούσα αξία μιας ράντας, στην οποία υπάρχει ένας πολλαπλασιαστής των χρηματοροών ακαθάριστου εισοδήματος που βοηθάει στην αναγωγή στην παρούσα αξία. Επίσης, απαιτείται πρόβλεψη των μελλοντικών χρηματοροών βάσει του πληθωρισμού, της ανάπτυξης της οικονομίας και άλλων χαρακτηριστικών που εξαρτώνται απ’ το εκάστοτε ακίνητο. Παρ’ όλα αυτά, τα σύμβολα που χρησιμοποιεί ο Blackadar στο μοντέλο του, καθώς και οι πολύπλοκες μαθηματικές πράξεις, έχουν σαν αποτέλεσμα να μη γίνει αποδεκτό το μοντέλο απ’ τους εκτιμητές και τους ακαδημαϊκούς. Ο Blackadar εφαρμόζει τις ιδέες του και προσεγγίζει την ανάλυση των χρηματοροών με μια περίπλοκη φόρμουλα, η οποία όμως δίνει ακριβή αποτελέσματα. Η ιδιαιτερότητα του μοντέλου αυτού είναι ότι εφαρμόζεται μόνο σε ακίνητα που είναι υπό κατασκευή και θεωρούμε ότι τώρα ξεκινά η ζωή του ακινήτου, δηλ. βρισκόμαστε σε χρόνο $t = 0$. Επίσης, ο εκτιμητής υποθέτει ότι το 100% του ακινήτου προορίζεται για ενοικίαση και όχι για ιδιοχρηση.

Η αυξημένη χρήση πιο ευέλικτων και εύχρηστων μοντέλων προεξόφλησης χρηματοροών, συνέβαλε στην εξαφάνιση των υπολοίπων μοντέλων που αναπτύχθηκαν στις Η.Π.Α. Το ίδιο συνέβη και με το «Μοντέλο Δυναμικής Κεφαλαιοποίησης του Blackadar, δεδομένου ότι οι εκτιμητές προτιμούσαν πιο εύχρηστα μοντέλα για τις εκτιμήσεις που έκαναν σε καθημερινή βάση.

3.7 REAL VALUE / EQUATED YIELD HYBRID MODEL (Crosby)

Ο Neil Crosby, προκάλεσε την κοινή γνώμη που επικρατούσε στον τομέα της εκτίμησης ακινήτων, υποστηρίζοντας ότι «οι συμβατικές αυτές τεχνικές αποτίμησης είναι επαρκείς για τον υπολογισμό της αγοραίας αξίας των επενδύσεων». Υποστήριζε επίσης ότι τα μοντέλα εκτίμησης της απόδοσης που χρησιμοποιούσαν στο Ηνωμένο Βασίλειο είναι “πιο αναλυτικά όσον αφορά τις αλλαγές στο μελλοντικό εισόδημα, αλλά η φόρμουλα που περιλαμβάνουν είναι πιο περίπλοκη από αυτή στην πραγματική τεχνική εκτίμησης της αξίας”. Επίσης, σημειώνει ότι “η προσέγγιση της πραγματικής αξίας δίνει βάση στο εισόδημα, στα πλαίσια της αγοραστικής του δύναμης” (Crosby, 1983, 1986) [2][3].

4 ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

4.1 Εισαγωγή

Η τεχνητή νοημοσύνη αποτελεί μία από τις μεγαλύτερες τάσεις στο χώρο των ψηφιακών τεχνολογιών. Με τον όρο τεχνητή νοημοσύνη εννοούμε τον τομέα της επιστήμης των υπολογιστών ο οποίος ασχολείται με τη σχεδίαση και υλοποίηση προγραμμάτων που μπορούν να μιμηθούν τις ανθρώπινες γνωστικές ικανότητες.

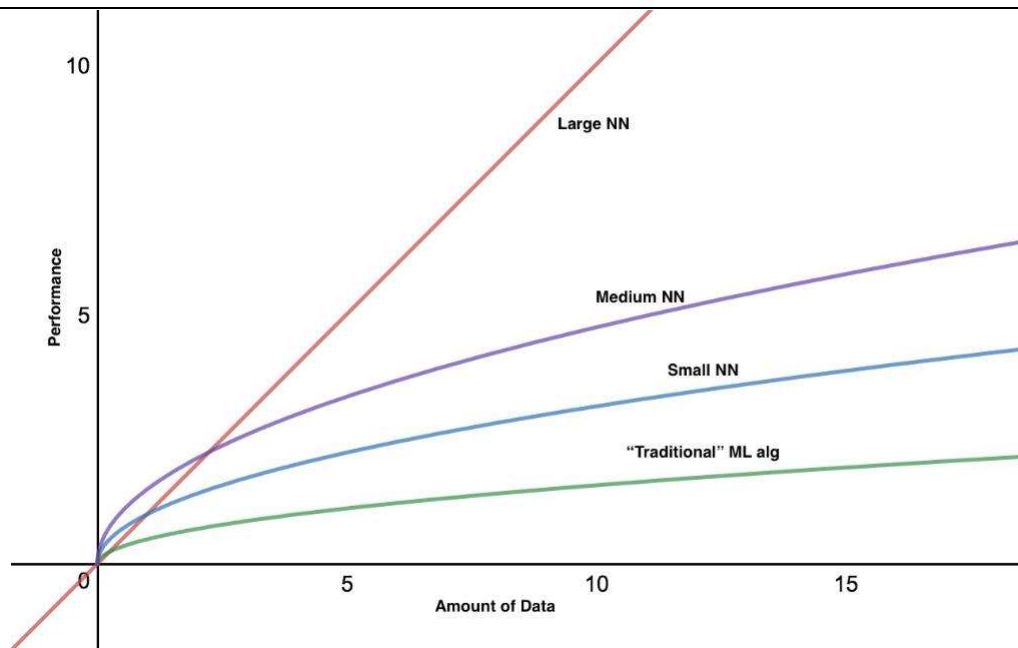
Τα τελευταία χρόνια παρατηρείται ένα τεράστιο ενδιαφέρον για το ερευνητικό πεδίο της Μηχανικής Μάθησης και ιδιαίτερα για τον περίφημο κλάδο της, το Deep Learning. Το ενδιαφέρον αυτό δεν περιορίζεται στις ερευνητικές κοινότητες των Επιστημόνων Υπολογιστών αλλά έχει επεκταθεί σε κάθε επιστημονικό πεδίο, στο οποίο το Deep Learning οδήγησε τα τελευταία χρόνια σε επαναστατικά αποτελέσματα.

Το Deep Learning και γενικότερα τα νευρωνικά δίκτυα δεν αποτελούν κάποια πρόσφατη εφεύρεση. Η πρώτη προσπάθεια για τη μαθηματική μοντελοποίηση της λειτουργικής μονάδας του νευρικού συστήματος, δηλαδή του νευρώνα, έγινε το 1943 από τον νευροφυσιολόγο Warren McCulloch και τον μαθηματικό Walter Pitts, όπου παρουσίασαν ένα απλοποιημένο μαθηματικό μοντέλο του βιολογικού νευρώνα, με το οποίο μπορούσαν να εκτελεστούν υπολογισμοί με προτασιακή λογική. Με σκοπό να εξηγήσουν πως λειτουργεί ο εγκέφαλος, μοντελοποίησαν ένα απλό νευρωνικό δίκτυο με ηλεκτρικά κυκλώματα.

Τα τελευταία χρόνια, τα τεχνητά νευρωνικά δίκτυα βρίσκονται και πάλι στο κέντρο του επιστημονικού ενδιαφέροντος. Μερικοί λόγοι είναι οι εξής:

- Η αύξηση του αριθμού των διαθέσιμων δεδομένων εκπαίδευσης.
- Η συνεχής αύξηση της υπολογιστικής ισχύος.
- Η βελτίωση των αλγορίθμων εκπαίδευσης των νευρωνικών δικτύων.

Ίσως ο σημαντικότερος λόγος που οδήγησε τελικά στη διάδοση των νευρωνικών δικτύων, και ειδικότερα του Deep Learning, ήταν η συγκέντρωση μεγάλου όγκου δεδομένων σε μεγάλες βάσεις, καθώς, όπως φαίνεται και στην εικόνα 4.1, το Deep Learning αποδίδει πολύ καλύτερα όσο αυξάνονται τα διαθέσιμα δεδομένα εκπαίδευσης. Τα μεγαλύτερα επιτεύγματα στον χώρο της Τεχνητής Νοημοσύνης συντελέστηκαν πολλά χρόνια μετά από την ανακάλυψη του αλγορίθμου που τα καθιστούσε δυνατά. Αυτό που τελικά φαίνεται να καθόρισε την επιτυχία των αλγορίθμων ήταν η ανάπτυξη μεγάλων βάσεων δεδομένων.



Σχήμα 4.1 Απόδοση Deep Learning συγκριτικά με το πλήθος των διαθέσιμων δεδομένων

Πολλοί σηματοδοτούν το 2006 ως τη χρονιά κατά την οποία και πάλι ξεκίνησε το έντονο ερευνητικό ενδιαφέρον για το Deep Learning, όταν δημοσιεύτηκε μία εργασία από τους Geoffrey Hinton et al. [7], στην οποία παρουσιαζόταν λεπτομερώς η διαδικασία εκπαίδευσης ενός βαθύς νευρωνικού δικτύου, το οποίο μπορούσε να αναγνωρίζει χειρόγραφα ψηφία με ακρίβεια μεγαλύτερη του 98%. Αυτό ήταν το γεγονός που καθόρισε το μέλλον της έρευνας πάνω στα νευρωνικά δίκτυα, για τα οποία είχε χαθεί το ενδιαφέρον ήδη από το 1990. Φτάνοντας στο σήμερα, το Deep Learning χρησιμοποιείται σε όλο και περισσότερες εφαρμογές, από την αναγνώριση ομιλίας σε ένα απλό κινητό μέχρι την καθοδήγηση ενός αυτοκινούμενου οχήματος σε ένα δρόμο με κίνηση. Οι δυνατότητες είναι πραγματικά αναρίθμητες και τα αποτελέσματα δεν παύουν να εκπλήσσουν.

4.2 Βασικές Έννοιες Μηχανικής Μάθησης

Ένας πολύ δημοφιλής ορισμός της Μηχανικής Μάθησης, ο οποίος χρησιμοποιείται ακόμη και σήμερα, δόθηκε από τον περίφημο Tom Mitchell το 1997 όπου λέει:

A computer programme is said to learn from experience E with respect to some task T and some performance measure P , if its performance on T , as measured by P , improves with experience E .

4.2.1 Κατηγορίες Συστημάτων Μηχανικής Μάθησης

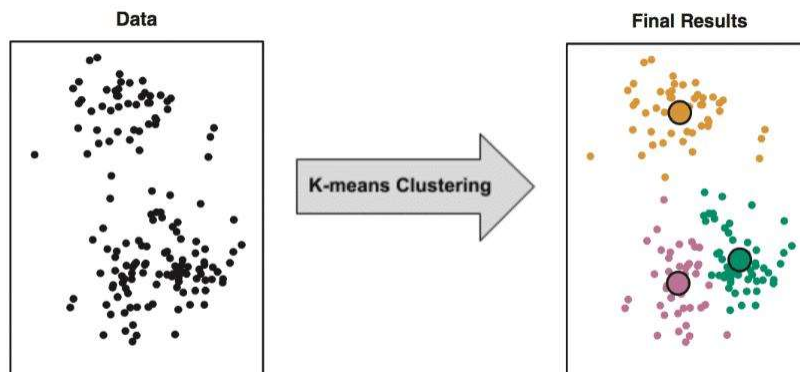
Γενικά, το σε τι ακριβώς αντιστοιχεί κάθε μία από τις έννοιες E , T και P , είναι κάτι που εξαρτάται αρκετά από την τεχνική Μηχανικής Μάθησης που χρησιμοποιείται. Οι πιο βασικές κατηγορίες Μηχανικής Μάθησης είναι:

- **Supervised Learning:** Στα προβλήματα supervised learning, τα δεδομένα που χρησιμοποιούνται για την εκπαίδευση του μοντέλου περιέχουν και ως πληροφορία το επιθυμητό αποτέλεσμα που θα πρέπει το μοντέλο μετά την εκπαίδευση να μπορεί εξαγάγει από την

πληροφορία της εισόδου. Μερικά κλασσικά μοντέλα Μηχανικής Μάθησης αυτής της κατηγορίας είναι:

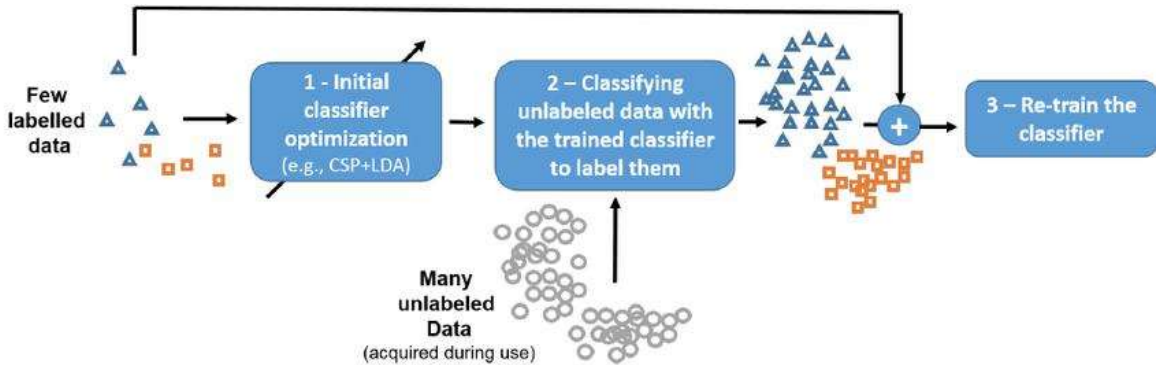
- Linear/Logistic Regression
 - SVMs
 - Decision Trees
 - Neural Networks
- **Unsupervised Learning:** Σε αυτήν την κατηγορία Μηχανικής Μάθησης προφανώς χρησιμοποιούνται κατά την εκπαίδευση δεδομένα στα οποία δεν περιέχεται η πληροφορία του επιθυμητού αποτελέσματος. Αυτός είναι και ο λόγος για τον οποίο με την κατηγορία αυτή λύνονται προβλήματα όπως:
 - Clustering
 - Association
 - Dimensionality Reduction

Στην εικόνα 4.2 φαίνεται ένα παράδειγμα clustering με K-means.



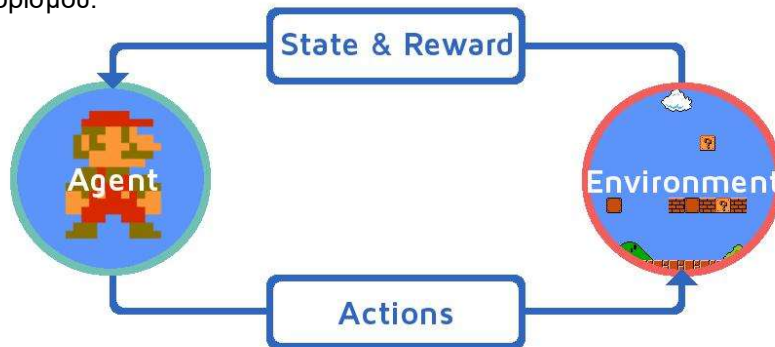
Εικόνα 4.2: Παράδειγμα unsupervised learning

- **Semi-supervised Learning:** Σε αυτήν την κατηγορία χρησιμοποιείται συνδυασμός γνωστών και αγνώστων δεδομένων για την εκπαίδευση των μοντέλων της. Αυτός είναι και ο λόγος για τον οποίο εφαρμόζονται συνδυασμοί αλγορίθμων τόσο από την πρώτη όσο και από την δεύτερη κατηγορία. Παράδειγμα τέτοιου μοντέλου είναι τα Deep Belief Networks. Στην εικόνα 4.3 φαίνεται η διαδικασία που ακολουθείται στα προβλήματα semi-supervised learning, κατά την οποία έχοντας λίγα δεδομένα ταξινομημένα, ένα μοντέλο εκπαιδεύεται με αυτά και βάσει του εκπαιδευμένου μοντέλου ταξινομούνται τα άγνωστα δεδομένα. Τέλος, με το σύνολο των ταξινομημένων δεδομένων το μοντέλο εκπαιδεύεται και πάλι.



Εικόνα 4.3: Διαδικασία semi-supervised learning

- Reinforcement Learning:** Αυτή η κατηγορία Μηχανικής Μάθησης διαφέρει ριζικά από τις υπόλοιπες τρεις καθώς αντί τα μοντέλα της να εκπαιδεύονται από ένα συγκεκριμένο πλήθος δεδομένων, ένας πράκτορας αλληλεπιδρά με το περιβάλλον, ούτως ώστε να εξαγάγει ιδιότητες από αυτό και τέλος να μπορέσει να προσδιορίσει τις δράσεις που πρέπει να εκτελέσει για να επιβραβευτεί όσο το δυνατόν περισσότερο. Ακολουθεί επομένως τη μέθοδο του συμπεριφορισμού.




Εικόνα 4.4: Διαδικασία reinforcement learning

4.2.2 Υποεκπαίδευση και Υπερεκπαίδευση

Προσπάθεια αποφυγής, τόσο της υποεκπαίδευσης, όσο και της υπερεκπαίδευσης είναι ίσως ο πυρήνας της επίλυσης κάθε προβλήματος Μηχανικής Μάθησης. Τα μοντέλα Μηχανικής Μάθησης εκπαιδεύονται με τη χρήση ενός πλήθους διαθέσιμων δεδομένων και ο σκοπός είναι η εξαγωγή ιδιοτήτων από τα δεδομένα αυτά. Η εκπαίδευση όμως πρέπει να γίνει σε τέτοιο βαθμό, που το μοντέλο να μπορεί μετά την εκπαίδευση να αναγνωρίζει τις ιδιότητες αυτές και σε δεδομένα τα οποία θα δει για πρώτη φορά. Εάν λοιπόν ένα μοντέλο δεν εκπαιδευτεί αρκετά, δεν θα μπορέσει να διακρίνει τις απαραίτητες ιδιότητες στα δεδομένα της εκπαίδευσης. Αυτό μπορεί να συμβεί όταν δεν υπάρχουν αρκετά δεδομένα διαθέσιμα και όταν τα δεδομένα που θα χρησιμοποιηθούν στην εκπαίδευση είναι χαμηλής ποιότητας. Αντίθετα, εάν το μοντέλο εκπαιδευτεί περισσότερο από ό,τι πρέπει, θα αρχίσει να θεωρεί ως χρήσιμη πληροφορία των θόρυβο των δεδομένων. Αυτό συμβαίνει, είτε επειδή το μοντέλο διαθέτει αδικαιολόγητα μεγάλο αριθμό εκπαιδευσιμων παραμέτρων, είτε επειδή το μοντέλο έχει εκπαιδευτεί πολλές φορές με τα ίδια δεδομένα.

Στην εικόνα 4.5 φαίνονται τρία πολύ διαδεδομένα διαγράμματα, που περιγράφουν άριστα τα δύο φαινόμενα που μόλις περιεγραφήκαν, καθώς και την επιθυμητή κατάσταση που επιδιώκουμε με την εκπαίδευση ενός μοντέλου Μηχανικής Μάθησης. Στο συγκεκριμένο πρόβλημα, ένα μοντέλο χρειάζεται να εκπαιδευτεί για την πρόβλεψη δισδιάστατων δειγμάτων τιμών. Επομένως, το μοντέλο θα πρέπει να περιγράψει μία συνάρτηση, κοντά στην οποία αναμένεται να κινούνται οι τιμές του προβλήματος.



Εικόνα 4.5: Διαγράμματα υποεκπαίδευσης, επιθυμητής εκπαίδευσης και υπερεκπαίδευσης

Στο πρώτο διάγραμμα της εικόνας 4.5, παρουσιάζεται το φαινόμενο της υποεκπαίδευσης. Ενώ το ανθρώπινο μάτι εύκολα μπορεί να καταλάβει πως τα δεδομένα κινούνται πολύ κοντά σε μία συνάρτηση δευτέρου βαθμού, το μοντέλο, επειδή ακριβώς δεν έχει εκπαιδευτεί επαρκώς, θεωρεί πως καλύτερα περιγράφεται η συμπεριφορά των δεδομένων από μία ευθεία γραμμή. Στο μεσαίο διάγραμμα, έχει σχεδιαστεί μία γραμμή ικανοποιητική για την περιγραφή των δισδιάστατων δεδομένων. Τέλος, στο τρίτο διάγραμμα της εικόνας, εμφανίζεται το φαινόμενο της υπερεκπαίδευσης. Το μοντέλο σε αυτήν την περίπτωση έχει εκπαιδευτεί τόσο πολύ, που ουσιαστικά έχει «αποστηθίσει» τα δεδομένα της εκπαίδευσης και τα περιγράφει τέλεια. Αυτό προφανώς δεν είναι επιθυμητό, καθώς εύκολα παρατηρείται πως ένα πιθανό μελλοντικό δείγμα μάλλον θα ακολουθήσει την γραμμή του δευτέρου διαγράμματος και άρα το μοντέλο δεν θα προέβλεπε τη νέα τιμή. Εν γένει, θα μπορούσε να ειπωθεί, πως, τόσο η υπερεκπαίδευση, όσο και η υποεκπαίδευση, οδηγούν στην απώλεια της ικανότητας ενός μοντέλου να γενικεύει.

Στο Deep Learning, το πρόβλημα που μόλις περιεγράφηκε γίνεται αρκετά πιο περίπλοκο. Κατ' αρχάς, το Deep Learning χρησιμοποιείται σε περιπτώσεις που τα δεδομένα είναι αρκετά σύνθετα, κι άρα η εξαγωγή ιδιοτήτων είναι μία εξαιρετικά δύσκολη υπόθεση. Αυτό προκύπτει από το γεγονός ότι συνήθως τα δεδομένα με τα οποία γίνεται η εκπαίδευση είναι πολυδιάστατα κι άρα δεν είναι δυνατόν να τα ελέγξουμε εύκολα, όπως στην εικόνα 4.5, εάν το μοντέλο μπορεί να γενικεύει. Το δεύτερο και πολύ σημαντικό πρόβλημα του Deep Learning προκύπτει από το γεγονός ότι τα βαθιά νευρωνικά δίκτυα διαθέτουν ένα τεράστιο πλήθος εκπαιδευσιμων παραμέτρων. Αυτό, ναι μεν μπορεί να οδηγήσει στην επίλυση δύσκολων προβλημάτων μέσα από την εξαγωγή πολλών ιδιοτήτων, εύκολα μπορεί όμως να οδηγήσει και στην περιγραφή περίπλοκων συναρτήσεων, σαν αυτή που βλέπουμε στο τρίτο διάγραμμα της εικόνας 4.5.

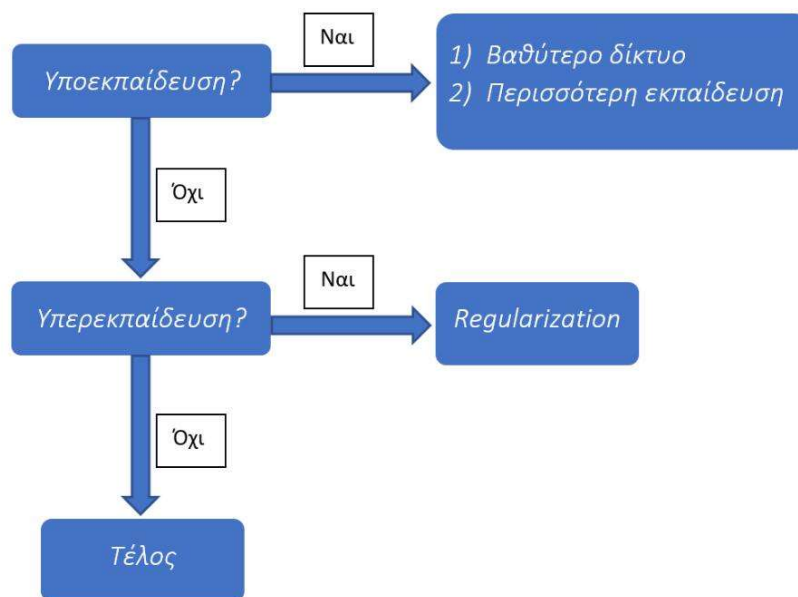
Στα περισσότερα προβλήματα της Μηχανικής Μάθησης είναι απαραίτητο να είναι δυνατή η παρατήρηση της συμπεριφοράς των μοντέλων κατά τη διάρκεια της εκπαίδευσής τους, ούτως ώστε να αποφευχθεί τόσο η υπερεκπαίδευση όσο και η υποεκπαίδευση. Για το σκοπό αυτό, μία συνήθης πρακτική είναι ο διαχωρισμός των διαθέσιμων δεδομένων σε τρεις ομάδες. Η πρώτη ομάδα, που ονομάζεται training set και περιέχει το μεγαλύτερο ποσοστό των δεδομένων, χρησιμοποιείται για την εκπαίδευση. Η δεύτερη ομάδα, γνωστή ως validation set, χρησιμοποιείται κατά τη διάρκεια της εκπαίδευσης για να παρατηρείται η συμπεριφορά της. Τέλος, τα υπόλοιπα δεδομένα

χρησιμοποιούνται μετά την εκπαίδευση του μοντέλου και πάλι με σκοπό του ελέγχου της ικανότητας γενίκευσης. Η ομάδα αυτή, έχει το όνομα testing set.

4.3 Τεχνικές Deep Learning

4.3.1 Καταπολέμηση της Υπερεκπαίδευσης και της Υποεκπαίδευσης

Το διάγραμμα της εικόνας 4.6 παρουσιάζει τη βασική μεθοδολογία που ακολουθείται για την καταπολέμηση της υποεκπαίδευσης και της υπερεκπαίδευσης στα βαθιά νευρωνικά δίκτυα.



Εικόνα 4.6: Διαδικασία καταπολέμησης υπερεκπαίδευσης και υποεκπαίδευσης

Όπως φαίνεται στην εικόνα 4.6, η διαδικασία ξεκινάει με έναν έλεγχο σχετικά με το αν το μοντέλο έχει υποεκπαιδευτεί. Εάν αυτό πράγματι ισχύει, τότε πρέπει να αυξήσουμε τον αριθμό των εκπαιδευσίμων παραμέτρων και να δημιουργήσουμε ένα πιο βαθύ δίκτυο, καθώς έτσι, πιθανώς να εξαχθούν περισσότερες ιδιότητες από τα δεδομένα. Αντιθέτως, εάν το δίκτυο έχει υπερεκπαιδευτεί, θα πρέπει να δοκιμάσουμε στην επόμενη εκπαίδευση να εφαρμόσουμε κάποια τεχνική regularization, στις οποίες θα αναφερθούμε με λεπτομέρεια αργότερα στο σύγγραμμα. Μία ακόμη μέθοδος για την καταπολέμηση της υπερεκπαίδευσης είναι προφανώς και η συλλογή περισσότερων δεδομένων, αυτό όμως δεν είναι πάντοτε δυνατό. Η διαδικασία της εικόνας 4.6 επαναλαμβάνεται μέχρις ότου το μοντέλο θα έχει εκπαιδευτεί σωστά.


4.3.2 Ελαχιστοποίηση του κόστους – Αλγόριθμοι βελτιστοποίησης

Οι αλγόριθμοι βελτιστοποίησης αποτελούν ένα πολύ σημαντικό κομμάτι της εκπαίδευσης των νευρωνικών δικτύων, καθώς χρησιμοποιούνται κατά την εκπαίδευση ενός μοντέλου για την ανανέωση των παραμέτρων του. Οι παράμετροι ανανεώνονται πάντα με τέτοιο τρόπο, ώστε βάσει

του αλγορίθμου να ελαχιστοποιείται η συνάρτηση κόστους. Στην συνέχεια θα γίνει αναφορά σε μερικούς από τους πιο σημαντικούς αλγορίθμους βελτιστοποίησης:


- Gradient Descent

Ίσως ο πιο σημαντικός αλγόριθμος βελτιστοποίησης στη Μηχανική Μάθηση, αφού αποτελεί τη βάση όλων των σύγχρονων μεθόδων βελτιστοποίησης, είναι ο gradient descent. Σε αυτόν, υπολογίζεται σε κάθε βήμα προς την εύρεση του ελαχίστου της συνάρτησης κόστους, η παράγωγός της ως προς κάθε παράμετρο. Έτσι, οι παράμετροι του δικτύου w και b ανανεώνονται προς την κατεύθυνση που θα οδηγήσει στη μείωση της κλίσης της συνάρτησης. Το μέγεθος του βήματος εξαρτάται από μία υπερπαράμετρο, το learning rate. Όσο πιο κοντά φτάνουμε στον μηδενισμό της παραγώγου, κι άρα σε ένα ελάχιστο της συνάρτησης, τόσο πιο αργά μεταβάλλονται οι τιμές των w και b . Το γεγονός αυτό είναι πολύ σημαντικό, καθώς ο αλγόριθμος θα είναι πιο ακριβής στην περιοχή κοντά στο ελάχιστο και πιο ταχύς μακριά από αυτό. Στην εικόνα 4.7 φαίνεται ένα παράδειγμα επιτυχούς εφαρμογής του αλγορίθμου gradient descent.




Εικόνα 4.7: Επιτυχής gradient descent

Ο τρόπος με τον οποίο επιλέγουμε το learning rate είναι πολύ σημαντικός καθώς η επιλογή μίας πολύ μικρής τιμής θα καθυστερήσει πολύ την σύγκλιση του αλγορίθμου. Αντιθέτως, η επιλογή μίας πολύ μεγάλης τιμής είναι πιθανό να οδηγήσει τον αλγόριθμο στο να αστοχήσει και να χάσει το ελάχιστο της συνάρτησης. Στην εικόνα 4.8 φαίνεται ένα παράδειγμα εφαρμογής του gradient descent με μικρό learning rate, όπου τελικά τα βήματα γίνονται τόσο μικρά που ο αλγόριθμος δεν φτάνει στο ελάχιστο. Αντίθετα στην εικόνα 4.9 παρουσιάζεται ένα παράδειγμα χρήσης μεγάλου learning rate, όπου και φαίνεται πως ο αλγόριθμος προσπερνάει το ελάχιστο πάρα πολλές φορές.



Εικόνα 4.8: Παράδειγμα gradient descent με πολύ μικρό learning rate



Εικόνα 4.9: Παράδειγμα gradient descent με πολύ μεγάλο learning rate


Στο παράδειγμα με τα learning rates παρουσιάστηκε ο τρόπος λειτουργίας του Gradient Descent για την ελαχιστοποίηση μίας μονοδιάστατης συνάρτησης. Εν γένει μία συνάρτηση κόστους στη Μηχανική Μάθηση εξαρτάται από ένα διάνυσμα παραμέτρων = [1, 2, ...,].

Ειδικά στο Deep Learning, το πλήθος των δεδομένων που χρησιμοποιείται στην εκπαίδευση είναι τεράστιο. Για πολλά δεδομένα επομένως, το υπολογιστικό κόστος θα είναι πολύ μεγάλο. Ο αλγόριθμος αυτός έχει λάβει το όνομα Batch Gradient Descent, αφού χρησιμοποιεί το σύνολο (batch) των δεδομένων εκπαίδευσης, προτού ανανεώσει τις εκπαιδευσιμες παραμέτρους. Η λύση στο πρόβλημα αυτό είναι οι εκπαιδευσιμες παράμετροι να ανανεώνονται χωρίς ο αλγόριθμος να έχει χρησιμοποιήσει το σύνολο των δεδομένων. Έτσι καταλήγουμε σε 3 διαφορετικές περιπτώσεις:

- A. Batch Gradient Descent: Ανανέωση των εκπαιδευσιμων παραμέτρων λαμβάνοντας υπόψιν το σύνολο των διαθέσιμων δεδομένων.
- B. Stochastic Gradient Descent: Ανανέωση των εκπαιδευσιμων παραμέτρων σε κάθε βήμα χρησιμοποιώντας κάθε φορά ένα τυχαίο παράδειγμα από το σύνολο των δεδομένων.
- C. mini-batch Gradient Descent: Ανανέωση των εκπαιδευσιμων παραμέτρων λαμβάνοντας υπόψιν ένα μικρό υποσύνολο των δεδομένων κάθε φορά.

Οι περιπτώσεις A και B είναι οι ακραίες και παρουσιάζουν ορισμένα πολύ σημαντικά προβλήματα. Στην περίπτωση A, παρ' ό,τι είναι σίγουρο πως μετά από κάθε ανανέωση των παραμέτρων ο αλγόριθμος θα έχει οδηγήσει πιο κοντά στην εύρεση του ελαχίστου, κι άρα σε σύγκλιση, αυτό θα γίνει μετά από πολύ χρόνο, ειδικά εάν χρησιμοποιούνται πολλά δεδομένα. Βέβαια,

αξίζει να αναφερθεί πως ο αλγόριθμος δεν εγγυάται τη σύγκλιση στην βέλτιστη τιμή ενώ ταυτόχρονα απαιτεί την παρουσία όλων των δεδομένων στη μνήμη. Ο αλγόριθμος B από την άλλη, προφανώς είναι ταχύτερος. Παρ' όλ' αυτά, η διαδρομή του προς την ελάχιστη τιμή της συνάρτησης κόστους είναι εξαιρετικά ενθόρυβη και δεν εγγυάται σύγκλιση. Προφανώς, η περίπτωση C είναι μία μέση λύση που συνδυάζει τα θετικά των A και B και στην πράξη προτιμάται. Στην εικόνα 4.10 απεικονίζεται η συμπεριφορά αυτών των τριών περιπτώσεων.




Εικόνα 4.10: Σύγκριση των τριών αλγορίθμων που βασίζονται στον gradient descent

Σημειώνεται, πως σήμερα με τον όρο Stochastic Gradient Descent συνήθως εννοείται ο αλγόριθμος mini-batch Gradient Descent.

- **Gradient Descent with Momentum [8]**

Ο κλασικός αλγόριθμος Gradient Descent δε λαμβάνει υπόψιν τις τιμές που έλαβε η παράγωγος σε προηγούμενα βήματα. Αντίθετα, ενδιαφέρεται μόνο για την τιμή της παραγώγου της συναρτήσεως κόστους, ως προς κάθε εκπαιδευσιμη μεταβλητή που λαμβάνει, σε κάθε βήμα. Αυτό βέβαια μπορεί να οδηγήσει σε φαινόμενα όπως αυτό της εικόνας 4.11, στο οποίο ο αλγόριθμος αδυνατεί να αντιληφθεί την ταλάντωση γύρω από τον άξονα που τελικά οδηγεί προς το ελάχιστο. Θα μπορούσαμε να πούμε, πως το πρόβλημα αυτό είναι προϊόν της χρήσης της παραγώγου ως ανάλογο της ταχύτητας και όχι της επιτάχυνσης. Πιο συγκεκριμένα, πρέπει ο αλγόριθμος να μπορεί να καταλάβει τότε κατά μέσο όρο σε έναν άξονα οι παράγωγοι είναι κοντά στο μηδέν.



Εικόνα 4.11: Χρήση momentum στον αλγόριθμο stochastic gradient descent

Στην εικόνα 4.11 φαίνεται πως αποφεύγεται η ταλάντωση, κάτι που επιταχύνει δραματικά την διαδικασία εκπαίδευσης. Συνήθως, το β λαμβάνει την τιμή 0.9.

- RMSProp [9]

Ένας άλλος πολύ σημαντικός αλγόριθμος βελτιστοποίησης είναι ο RMSProp. Στην περίπτωση αυτή, για την ανανέωση των εκπαιδευσιμων παραμέτρων, χρησιμοποιείται το τετράγωνο των μερικών παραγώγων, ούτως ώστε, μεγάλες μεταβολές να οδηγούν σε μεγάλες τιμές της μεταβλητής st . Έτσι, επειδή αυτή χρησιμοποιείται στον παρονομαστή της συνάρτησης ανανέωσης των εκπαιδευσιμων παραμέτρων, όσο πιο μεγάλη παράγωγος, τόσο πιο μικρή και η μεταβολή τους. Το αντίθετο προφανώς ισχύει για τις μικρές παραγώγους. Αυτή η διαδικασία εξομαλύνει τις μεγάλες ταλαντώσεις. Ο αλγόριθμος αυτός, ανήκει στην κατηγορία των adaptive learning rate algorithms, οι οποίοι μειώνουν το learning rate ταχύτητα για τις παραγώγους που λαμβάνουν μεγάλες τιμές και αργά για μικρές παραγώγους.

- Adam [9]


Ο αλγόριθμος Adam συνδυάζει τους αλγορίθμους Stochastic Gradient Descent with Momentum και RMSProp. Αυτό σημαίνει πως ταυτόχρονα παρατηρεί το exponentially decaying average τόσο των προηγούμενων παραγώγων όσο και των τετραγώνων τους.

4.3.3 Αρχικοποίηση βαρών και συναρτήσεις ενεργοποίησης

Στον αλγόριθμο Backpropagation, υπολογίζεται η μερική παράγωγος της συνάρτησης κόστους ως προς κάθε μία από τις παραμέτρους του νευρωνικού δικτύου, ξεκινώντας από την έξοδο του δικτύου και ολοκληρώνοντας στην είσοδο. Το πρόβλημα που παρατηρήθηκε, ειδικά στα βαθιά νευρωνικά δίκτυα, είναι πως πολλές φορές, καθώς ο αλγόριθμος οπισθοδρομεί προς την είσοδο του δικτύου, οι παράγωγοι γίνονται όλο και πιο μικρές. Από τη στιγμή λοιπόν που η ανανέωση των εκπαιδευσιμων εξαρτάται από τις τιμές των παραγώγων, είναι προφανές πως η συνεχής εξασθένηση τους οδηγεί στην αμελητέα μεταβολή των παραμέτρων. Ειδικά στα αναδρομικά νευρωνικά δίκτυα, δύναται να παρατηρηθεί και το αντίστροφο φαινόμενο, δηλαδή, σε ορισμένα επίπεδα του δικτύου, οι παράγωγοι μπορεί να λάβουν τεράστιες τιμές, με αποτέλεσμα τα επίπεδα αυτά να ανανεώνουν τόσο δραστικά τα βάρη τους, που ο αλγόριθμος τελικά αποκλίνει. Αυτό το φαινόμενο ονομάζεται exploding gradient descent.

Οι λόγοι που προκαλούσαν το φαινόμενο αυτό εντοπίστηκαν και δημοσιεύτηκαν από τους Xavier Glorot και Yoshua Bengio [6]. Το πρώτο πρόβλημα ήταν η μέθοδος αρχικοποίησης των εκπαιδευσιμων παραμέτρων του δικτύου. Τότε, ο πιο συνήθης τρόπος αρχικοποίησης ήταν η τυχαία απόδοση τιμών, οι οποίες ακολουθούσαν κανονική κατανομή με μέσο όρο μηδέν και τυπική απόκλιση ένα. Αυτό όμως οδηγούσε στη διασπορά της εξόδου κάθε επιπέδου να είναι μεγαλύτερη από την διασπορά της εισόδου. Αυτό συνέβαινε επειδή η είσοδος στη συνάρτηση ενεργοποίησης ενός νευρώνα είναι το άθροισμα των γινομένων κάθε εξόδου του προηγούμενου επιπέδου με το αντίστοιχο βάρος. Εάν χάριν απλότητας θεωρήσουμε πως η είσοδος ενός επιπέδου είναι ένα διάνυσμα με μονάδες, τότε η είσοδος στη συνάρτηση ενεργοποίησης θα είναι απλώς το άθροισμα των βαρών. Αυτό οδηγεί στο ότι το άθροισμα αυτό, να μην θα ακολουθεί κανονική κατανομή με μέση τιμή μηδέν, αλλά η τυπική του απόκλιση θα έχει αλλάξει. Αυτό διότι, η διασπορά του αθροίσματος ενός συνόλου τυχαίων και ανεξάρτητων αριθμών ισούται με το άθροισμα των διασπορών αυτών των αριθμών. Επομένως, αφού η διασπορά κάθε αριθμού είναι ένα, τότε η συνολική διασπορά θα είναι ίση με το πλήθος των νευρώνων του προηγούμενου επιπέδου. Αυτή η διαισθητική προσέγγιση εξηγεί γιατί σε κάθε επίπεδο ενός δικτύου με μεγάλο πλήθος νευρώνων η διασπορά, και άρα η τυπική απόκλιση, αυξάνεται κατά πολύ. Έτσι, αφού η τυπική απόκλιση θα είναι σημαντικά μεγαλύτερη του ένα, η είσοδος της συνάρτησης ενεργοποίησης θα είναι πιο πιθανό να λάβει τιμές μεγαλύτερες του ένα. Εάν η συνάρτηση ενεργοποίησης είναι σιγμοειδής, τότε σε λίγα μόνο επίπεδα η έξοδος θα έχει φτάσει σε

κορεσμό. Η σιγμοειδής συνάρτηση φαίνεται στην εικόνα 4.12 και υπήρξε μία από τις πιο διαδεδομένες συναρτήσεις ενεργοποίησης των νευρωνικών δικτύων για αρκετό καιρό.

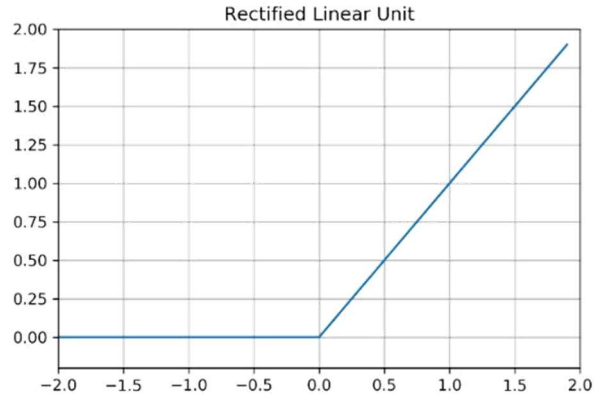


Εικόνα 4.12: Σιγμοειδής συνάρτηση


Αυτή η διαισθητική προσέγγιση οδηγεί στο συμπέρασμα που κατέληξαν οι Xavier και Bengio, ότι δηλαδή, η διασπορά των βαρών κατά την αρχικοποίηση, πρέπει να εξαρτάται από το πλήθος όχι μόνο των εισόδων ενός επιπέδου αλλά και των εξόδων, ούτως ώστε το σήμα εισόδου να διατηρεί, όσο το δυνατόν, την διασπορά του σταθερή, τόσο στην ευθεία προσπέλαση του δικτύου όσο και στην οπισθοδρόμηση.

Όπως αναφέρθηκε, το πρόβλημα της αύξησης της διασποράς προκαλεί προβλήματα στην εκπαίδευση ενός δικτύου όταν χρησιμοποιούνται συναρτήσεις ενεργοποίησης οι οποίες επιτρέπουν τον κορεσμό, όπως είναι η σιγμοειδής και η υπερβολική εφαιπτομένη. Έτσι, για την περαιτέρω καταπολέμηση του προβλήματος έπρεπε να σχεδιαστούν νέες συναρτήσεις, οι οποίες δεν επιτρέπουν τον κορεσμό. Ως τότε, η επιστημονική κοινότητα έδειχνε προτίμηση στην σιγμοειδή, καθώς παρατηρήθηκε πως οι άκρες των βιολογικών νευρώνων παρουσίαζαν αντίστοιχη συμπεριφορά.

Μερικώς η λύση δόθηκε από την ReLU (Rectified Linear Unit), η οποία μάλιστα επιτρέπει ταχύτατους υπολογισμούς και φαίνεται στην εικόνα 4.13. Δυστυχώς, κι αυτή εμφανίζει μερικά αρνητικά φαινόμενα, όπως το φαινόμενο dying ReLU, κατά το οποίο πολύ νευρώνες νεκρώνονται, δηλαδή, βγάζουν ως έξοδο μόνο μηδέν. Μία παραλλαγή της, η Leaky ReLU, αντιμετωπίζει σ' ένα βαθμό το πρόβλημα καθώς οι νευρώνες δεν νεκρώνονται. Αντίθετα εισέρχονται σε μία κωματώδη κατάσταση από την οποία μπορεί να ξυπνήσουν. Η συνάρτηση αυτή φαίνεται στην εικόνα 4.14.



Εικόνα 4.13: ReLU




Εικόνα 4.14: Leaky ReLU

4.3.4 Τεχνικές regularization

Όπως προαναφέρθηκε στο σύγγραμμα, με τις τεχνικές regularization είναι δυνατόν να αποτραπεί η υπερεκπαίδευση του νευρωνικού. Μερικές πολύ συνήθεις πρακτικές είναι:

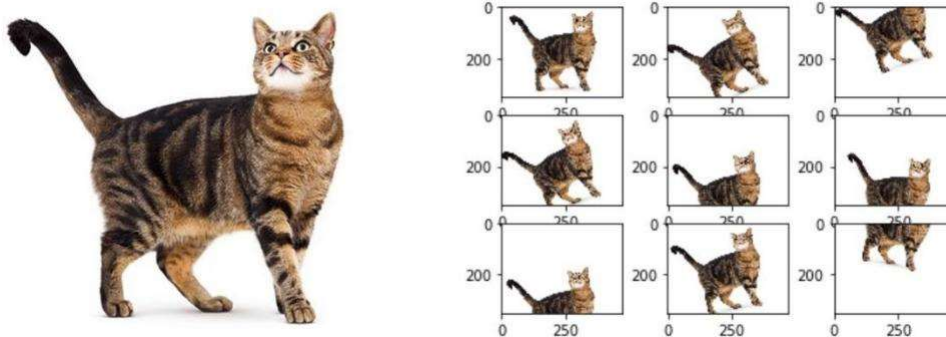
- i. **L2 Regularization:** Ίσως η πιο κλασική τεχνική regularization, η οποία επεμβαίνει κατευθείαν στη συνάρτηση κόστους, με την πρόσθεση ενός ακόμη όρου. Ουσιαστικά, ο αλγόριθμος βελτιστοποίησης θα πρέπει για να ελαχιστοποιήσει το κόστος να λάβει υπόψιν και το νέο προστιθέμενο όρο. Διαισθητικά μπορεί να γίνει αντιληπτό, πως η επιλογή μίας πολύ μεγάλης τιμής για το λ θα οδηγήσει τα βάρη w σε τιμές πολύ κοντά στο μηδέν. Επομένως, ένα πολύ μεγάλο δίκτυο που υπερεκπαιδεύεται λόγω του μεγάλου πλήθους των παραμέτρων του, θα προσεγγίσει με την εξασθένηση των βαρών τη συμπεριφορά ενός μικρότερου δικτύου. Μένει λοιπόν να επιλεχθεί μία τιμή για το λ , η οποία θα οδηγήσει στην ιδανική εκπαίδευση.
- ii. **Dropout:** Μία πανίσχυρη τεχνική regularization είναι το dropout, η οποία προτάθηκε το 2012 από τους G. Hinton [7]. Σε αυτή, ορίζεται πριν την εκπαίδευση ενός δικτύου μία τιμή πιθανότητας p , βάσει της οποίας, σε κάθε βήμα εκπαίδευσης ένας νευρώνας του δικτύου θα συμμετέχει ή όχι στην διαδικασία. Και σε αυτήν την περίπτωση, καταπολεμάται η υπερεκπαίδευση του δικτύου, στην οποία και πάλι οδηγεί το τεράστιο πλήθος των εκπαιδευσίμων παραμέτρων. Αυτό είναι πολύ σημαντικό, καθώς έτσι, οι διπλανοί νευρώνες

καταφέρνουν να εξειδικευτούν καλύτερα, κάτι που τελικά αυξάνει και την ακρίβεια του νευρωνικού δικτύου. Στην εικόνα 4.15 φαίνεται ένα νευρωνικό δίκτυο, στο οποίο εφαρμόζεται dropout, σε ένα τυχαίο βήμα εκπαίδευσης.



Εικόνα 4.15: Εφαρμογή Dropout σε ένα νευρωνικό δίκτυο

iii. **Data augmentation:** Μία μέθοδος που θα οδηγούσε στην καταπολέμηση του overfitting θα ήταν η χρήση περισσότερων δεδομένων στην εκπαίδευση. Αυτό βέβαια είναι δύσκολο, αφού συνήθως χρησιμοποιούνται εξ αρχής όλα τα διαθέσιμα δεδομένα. Κάτι που εν μέρει μπορεί να λύσει αυτό το πρόβλημα είναι η τεχνική data augmentation. Βάσει αυτής, τα δεδομένα χρησιμοποιούνται περισσότερες από μία φορές αλλά τροποποιημένα. Το ανθρώπινο μάτι, σε μία φωτογραφία μίας γάτας, αναγνωρίζει εύκολα τη γάτα ακόμη κι αν η φωτογραφία περιστραφεί, μεγεθυνθεί κτλ. Το νευρωνικό δίκτυο όμως αντιλαμβάνεται πίνακες τιμών και θα πρέπει να εκπαιδευτεί τόσο καλά, που να μπορεί να εντοπίζει τις απαραίτητες ιδιότητες σε μία φωτογραφία, σε κάθε πιθανή της κατάσταση. Επομένως, μία φωτογραφία τροποποιημένη προσφέρει χρήσιμη πληροφορία σε ένα νευρωνικό δίκτυο κατά την εκπαίδευση. Στην εικόνα 4.16 φαίνονται μερικές πιθανές τροποποιήσεις που δύναται να εφαρμοστούν σε μία εικόνα με σκοπό την αύξηση του πλήθους των δεδομένων.




Εικόνα 4.16: Εφαρμογή Data Augmentation

4.4 Συνελικτικά Νευρωνικά Δίκτυα

Τα συνελικτικά νευρωνικά δίκτυα είναι μία ειδική κατηγορία νευρωνικών δικτύων και έμπνευση για την εφεύρεσή τους ξεκίνησε από μερικά πολύ σημαντικά πειράματα που διεξήχθησαν τη δεκαετία του '60 από τους επιστήμονες David H. Hubel και Torsten Wiesel [10]. Αυτοί μελέτησαν τον οπτικό φλοιό μέσα από πειράματα που εκτέλεσαν σε γάτες, και κατάφεραν έτσι να καταλάβουν πολύ σημαντικές πληροφορίες για τη δομή του. Πιο συγκεκριμένα, παρατήρησαν πως οι νευρώνες του οπτικού φλοιού αντιδρούν σε μικρές περιοχές της εικόνας που αντιλαμβάνεται ο οφθαλμός. Μάλιστα, ομάδες νευρώνων παρατηρήθηκε πως διεγείρονται από συγκεκριμένα μόνο ερεθίσματα, όπως επί παραδείγματι οριζόντιες γραμμές.

Αυτές οι παρατηρήσεις οδήγησαν στην σχεδίαση του neocognitron, το οποίο ήταν ουσιαστικά ο πρόδρομος των συνελικτικών νευρωνικών δικτύων. Το πιο σημαντικό βήμα όμως προς την εξέλιξη των συνελικτικών νευρωνικών δικτύων έγινε από τους ερευνητές Yann LeCun, Leon Bottou, Yoshua Bengio και Patrick Haffner [11], οι οποίοι και σχεδίασαν την περίφημη αρχιτεκτονική LeNet-5. Αυτή η αρχιτεκτονική χρησιμοποιήθηκε κατά κόρον για την αναγνώριση χειρόγραφων ψηφίων σε επιταγές και ενσωμάτωσε ένα νέο τύπο επιπέδου νευρωνικού δικτύου, το συνελικτικό.


Τα συνελικτικά επίπεδα, εμπνευσμένα από την μελέτη του οπτικού φλοιού, χρησιμοποιούν από το προηγούμενο επίπεδο του νευρωνικού δικτύου ένα μικρό μόνο μέρος της πληροφορίας, το οποίο ονομάζεται *receptive field*. Έτσι, το δίκτυο στα χαμηλά επίπεδα εκπαιδεύεται για να αναγνωρίζει βασικές δομές, τις οποίες στα ανώτερα επίπεδα συνθέτει με σκοπό την εξαγωγή πιο σύνθετων ιδιοτήτων, κάτι που σχηματικά παρουσιάζεται στην εικόνα 4.17.



Εικόνα 4.17: Εξαγωγή ιδιοτήτων στα συνελικτικά νευρωνικά δίκτυα ανά επίπεδο

4.4.1 Βασικές δομές συνελικτικών νευρωνικών δικτύων

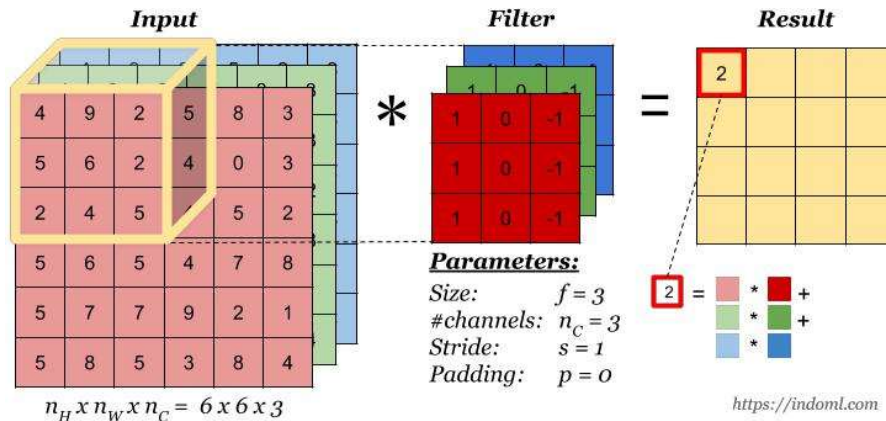
Η βασικότερη δομή ενός συνελικτικού νευρωνικού δικτύου είναι προφανώς το συνελικτικό επίπεδο. Το επίπεδο αυτό αποτελείται από φίλτρα τα οποία συνελίσσονται με την είσοδο του επιπέδου. Στην εικόνα 4.18 παρουσιάζεται η διαδικασία της δυσδιάστατης συνέλιξης, όπως αυτή εκτελείται στα συνελικτικά επίπεδα.



Εικόνα 4.18: Συνέλιξη μεταξύ μία εικόνας I και ενός φίλτρου K

Όπως φαίνεται και στην εικόνα 4.18, συνελίσσοντας μία εικόνα διαστάσεων $N \times N$ με ένα φίλτρο διαστάσεων $F \times F$, παράγεται ένα νέο σήμα με διαστάσεις $(N-F+1) \times (N-F+1)$.


Είναι εξαιρετικά σύνθητες η είσοδος στο δίκτυο να αποτελείται από περισσότερα από ένα κανάλια. Επί παραδείγματι, μία εικόνα RGB διαθέτει τρία κανάλια. Έτσι, σε τέτοιες περιπτώσεις, θα πρέπει η συνέλιξη να γίνει ταυτόχρονα σε όλα τα κανάλια. Για αυτό το λόγο, τα φίλτρα πρέπει να έχουν αριθμό καναλιών ίσο με αυτόν της εικόνας εισόδου. Το τελικό αποτέλεσμα μίας τέτοιας συνέλιξης είναι το άθροισμα των αποτελεσμάτων των συνελιξεων κάθε καναλιού, όπως ακριβώς φαίνεται στο παράδειγμα της εικόνας 4.19.



Εικόνα 4.19: Παράδειγμα συνέλιξης εικόνας με περισσότερα του ενός κανάλια

Η δεύτερη σημαντικότερη δομή στα συνελικτικά νευρωνικά δίκτυα είναι τα επίπεδα υποδειγματοληψίας, γνωστά στη διεθνή ορολογία ως pooling layers. Εν γένει, μία πολύ βασική αρχή που ακολουθείται στα νευρωνικά δίκτυα είναι πως, καθώς η πληροφορία ρέει προς την έξοδο και το δίκτυο εξαγεί ιδιότητες από αυτή, θα πρέπει να μειώνεται η ποσότητα της. Αυτή η διαδικασία ελαττώνει εξαιρετικά τον χρόνο υπολογισμών και ταυτόχρονα μειώνει τις απαιτήσεις μεγάλης μνήμης RAM του συστήματος. Η συνέλιξη είναι από μόνη της μία διαδικασία που μειώνει τις διαστάσεις της εικόνας εισόδου. Παρόλα αυτά, στα συνελικτικά δίκτυα συνήθως χρησιμοποιείται η μέθοδος zero-padding, μέσω της οποίας το φαινόμενο αυτό αναστέλλεται. Ο λόγος είναι, πως οι διαδοχικές συνέλιξεις μειώνουν πολύ γρήγορα το μέγεθος της εικόνας. Αντίθετα, με τα επίπεδα pooling, είναι δυνατόν κατά βούληση να μειώσουμε σε κάποιο στάδιο της αρχιτεκτονικής τον όγκο της πληροφορίας, διατηρώντας όμως το χρήσιμο μέρος της. Στο παράδειγμα της εικόνας 4.20 φαίνεται το

αποτέλεσμα των επιπέδων υποδειγματοληψίας max-pooling και average-pooling. Όπως είναι εμφανές, το max-pooling επιτυγχάνει πολύ καλύτερα να διατηρήσει την χρήσιμη πληροφορία μία ακμής μειώνοντας όμως κατά το ένα τέταρτο το μέγεθος της εικόνας.



Εικόνα 4.20: Παράδειγμα επιπέδων υποδειγματοληψίας

4.4.2 Σημαντικότερα πλεονεκτήματα συνελκτικών νευρωνικών δικτύων

Σε αυτό το σημείο αξίζει να σχολιαστεί πως η χρήση συνελκτικών επιπέδων μειώνει σημαντικά τον αριθμό των εκπαιδευσιμων παραμέτρων, κάτι που με τη σειρά του ελαττώνει την πιθανότητα υπερεκπαίδευσης αλλά και επιταχύνει τους υπολογισμούς. Έστω επί παραδείγματι, πως μία μικρή εικόνα, διαστάσεων $32 \times 32 \times 3$, εισέρχεται σε ένα συνελκτικό επίπεδο με έξι φίλτρα διαστάσεων 5×5 . Η εικόνα, που έχει στο σύνολο 3072 τιμές, εισέρχεται σε ένα επίπεδο με 156 παραμέτρους και το αποτέλεσμα στην έξοδο θα έχει διαστάσεις $28 \times 28 \times 6$, δηλαδή, 4704 τιμές. Έστω, ότι το ίδιο παράδειγμα θέλαμε να το εκτελέσουμε χρησιμοποιώντας fully connected επίπεδα. Τότε, θα έπρεπε από ένα επίπεδο εισόδου με 3072 νευρώνες να συνδέσουμε κάθε νευρώνα με 4704 νευρώνες του επομένου επιπέδου. Αυτό προφανώς σημαίνει πως θα χρειαζόμασταν 14 εκατομμύρια περίπου εκπαιδευσιμες παραμέτρους.

Πέρα από το πολύ σημαντικό γεγονός ότι τα συνελκτικά νευρωνικά δίκτυα χρειάζονται πολύ μικρότερο αριθμό εκπαιδευσιμων παραμέτρων, οι αρχιτεκτονικές που χρησιμοποιούν συνελκτικά επίπεδα παρουσιάζουν ακόμη ένα πολύ σημαντικό προτέρημα. Αυτό είναι πως η εκπαίδευση των φίλτρων του συνελκτικού νευρωνικού δικτύου εκπαιδεύονται με σκοπό την εξαγωγή ιδιοτήτων από μία εικόνα εισόδου. Οι ιδιότητες αυτές όμως μπορεί να βρίσκονται οπουδήποτε στην εικόνα και μάλιστα να εμφανίζονται αρκετές φορές. Επί παραδείγματι, ένα φίλτρο που εντοπίζει κάθετες γραμμές εκτελεί σημαντικό έργο σε ολόκληρο το εύρος της εικόνας.

5 ΕΚΤΙΜΗΣΗ ΑΞΙΩΝ ΑΚΙΝΗΤΩΝ ΜΕΣΩ ΕΦΑΡΜΟΓΗΣ ΑΛΓΟΡΙΘΜΩΝ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ

Σε αυτήν την ενότητα θα παρουσιαστεί η ερευνητική διαδικασία μέσω της οποίας αναπτύχθηκε το μοντέλο εκτίμησης αξιών ακινήτων, μέσω του οποίου γίνονται αποτιμήσεις και εκτιμήσεις αξιών ακινήτων.

5.1 Βάση Δεδομένων

5.1.1 Αγγελίες Ακινήτων

Ως βάση δεδομένων ακινήτων χρησιμοποιήθηκαν αγγελίες από τα δημοφιλέστερα website προβολής αγγελιών ακινήτων στην Ελλάδα, δηλαδή την XE.gr και spitogatos.gr.

Παρακάτω αναφέρονται τα φίλτρα που εφαρμόστηκαν στα δεδομένα, προκειμένου να αποκλειστεί πληροφορία χαμηλής ποιότητας όπου θα επηρεάσει αρνητικά την ποιότητα του μοντέλου που θα κατασκευαστεί στη συνέχεια.

- Από αυτή την βάση δεδομένων χρησιμοποιήθηκαν τα ακίνητα μόνο προς πώληση και με χρήση κατοικία την χρονική περίοδο 2013 έως 2019. Ο συνολικός αριθμός των κατοικιών προς πώληση είναι 662.012 αγγελίες
- Απορρίφθηκαν αγγελίες κατοικιών όπου οι τιμές τους ήταν χαμηλότερη των 30.000 ευρώ και υψηλότερη των 800.000 ευρώ. Τα ακίνητα με τιμή χαμηλότερη των 30.000 ευρώ σε αρκετές περιπτώσεις είναι ψευδείς, ενώ τα ακίνητα όπου ξεπερνά η τιμή τους τα 800.000 ευρώ θεωρούνται ακίνητα όπου με ιδιαίτερα χαρακτηριστικά όπου χρειάζεται ειδική μελέτη και μοντελοποίηση.
- Χρησιμοποιήθηκαν αγγελίες που ήταν γεωαναφερμένες και μόνο αυτές όπου η τοποθεσία τους ήταν εντός της ηπειρωτικής Ελλάδος. Οι εναπομείναντες αγγελίες είναι 604.939
- Από αυτές χρησιμοποιήθηκαν αγγελίες όπου το εμβαδόν των κατοικιών είναι μεγαλύτερο από 10 μ² και μικρότερο των 3000 μ².
- Τέλος χρησιμοποιήθηκαν ακίνητα με χρήση μη επαγγελματική. Οι εναπομείναντες αγγελίες είναι **599.912**

5.1.2 Διοικητική Διαίρεση Ελλάδας

Η πηγή της διοικητικής διαίρεσης της Ελλάδας είναι η ανοιχτή γεωχωρική βάση δεδομένων open street map. Χρησιμοποιήθηκε για να εντοπιστούν ποια ακίνητα γεωαναφέρονται εντός του Ελληνικού ηπειρωτικού χώρου.

5.1.3 Αντικειμενικές Τιμές Ακινήτων

Από τις 28-06-2021 μέσω της εφαρμογής <https://maps.gsis.gr/valuemaps/> έγιναν διαθέσιμες στο κοινό, επίσημα από το υπουργείο οικονομικών, γεωαναφερμένες οι ζώνες αντικειμενικών αξιών ακινήτων. Οι πληροφορίες αυτές είναι δύο ειδών: Πολυγωνικές και γραμμικές. Για την μοντελοποίηση θα αξιοποιηθεί η πολυγωνική πληροφορία. Κάθε ακίνητο όπου βρίσκεται εντός του πολυγώνου, η αντικειμενική του αξία παίρνει την τιμή που έχει το πολύγωνο. Η γραμμική πληροφορία δεν αξιοποιήθηκε γιατί χρειάζεται μεγάλη ακρίβεια στον γεωγραφικό εντοπισμό του κάθε ακινήτου για να αξιοποιηθεί.

Οι περιοχές της Ελλάδος που δεν υπάρχει πολυγωνική πληροφορία, παίρνει βάσει νόμου ως αντικειμενική τιμή την μικρότερη που υπάρχει εντός Δήμου. Για την παραγωγή της πληροφορίας αυτής χρησιμοποιήθηκαν τα διοικητικά όρια της Ελλάδας (5.2.1).

5.1.4 Πεδία της Βάσης Δεδομένων Ακινήτων

Τα πεδία του πίνακα των ακινήτων παρουσιάζονται παρακάτω:

- Τιμή (ευρώ)
- Εμβαδόν (μ²)
- Αντικειμενική τιμή (ευρώ/μ²)
- Τύπος ακινήτου (πχ διαμέρισμα, μονοκατοικία, ρετιρέ κτλ)
- Γεωγραφικές συντεταγμένες Φ και Λ
- Το έτος προβολής της αγγελίας
- Το έτος κατασκευής του ακινήτου
- Αν έχει σύστημα θέρμανσης
- Σε ποιο όροφο βρίσκεται
- Αν έχει parking
- Αν έχει αποθήκη και πόσα τετραγωνικά μέτρα είναι αυτή
- Αν έχει wc και τον αριθμό αυτών
- Πόσες κρεβατοκάμαρες
- Αν έχει τζάκι
- Τι τύπο δαπέδου έχει
- Αν έχει κλιματιστικό
- Αν έχει κήπο
- Αν έχει βεράντα
- Σε τι είδος δρόμου έχει πρόσωπο το ακίνητο
- Αν είναι γωνιακό
- Τι ενεργειακής κλάσης είναι το σπίτι
- Αν έχει πόρτα ασφαλείας
- Αν έχει συναγερμό
- Το ύψος των κοινοχρήστων σε ευρώ
- Αν έχει ανελκυστήρα
- Αν είναι επιπλωμένο
- Αν έχει κουφώματα
- Αν έχει διπλά τζάμια στα κουφώματα

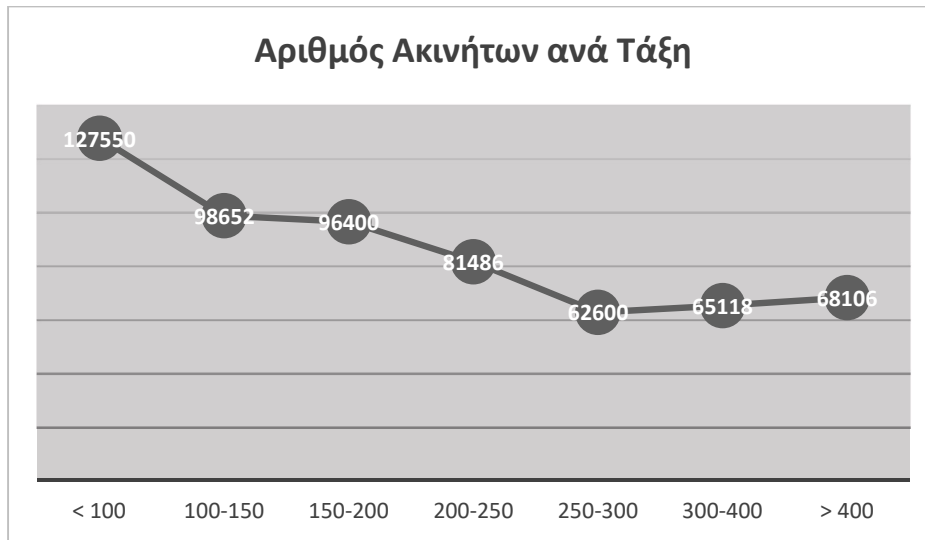
- Αν έχει ηλιακό θερμοσίφωνα
- Αν έχει πισίνα
- Αν είναι κοντά σε θάλασσα
- Αν είναι διαμπερές
- Το τελευταίο έτος ανακαίνισης
- Αν έχει πρόσβαση ΑΜΕΑ
- Αν χρήζει ανακαίνισης
- Αν έχει playroom
- Αν είναι ημιτελές
- Αν είναι νεοκλασικό
- Αν έχει σοφίτα
- Αν είναι διατηρητέο

5.1.5 Κατανομή Τιμών Ακινήτων

Η κατανομή των ακινήτων ανά τάξη παρουσιάζεται στον παρακάτω πίνακα και γράφημα.

Τάξεις Τιμών Ακινήτων (σε χιλιάδες ευρώ)	Αριθμός Ακινήτων	Ποσοστό %
< 100	127550	21
100-150	98652	16
150-200	96400	16
200-250	81486	14
250-300	62600	10
300-400	65118	11
> 400	68106	11

Πίνακας 5.1: Κατανομή Τιμών Ακινήτων



Γράφημα 5.2: Κατανομή Τιμών Ακινήτων

5.2 Δημιουργία του Μοντέλου

Για την δημιουργία των μοντέλων χρησιμοποιήθηκε η βιβλιοθήκη Tensorflow.

5.2.1 Κανονικοποίηση Δεδομένων Βάσης Δεδομένων

Για την δημιουργία του μοντέλου, θα πρέπει τα δεδομένα που θα εισαχθούν στον αλγόριθμο, να είναι κανονικοποιημένα, δηλαδή οι τιμές σε κάθε πεδίο να έχει την τιμή από 0 έως 1. Αυτό επιτυγχάνεται μέσω της εφαρμογής της συνάρτησης $ValueNormal = (Value - ValueMin) / (ValueMax - ValueMin)$.

5.2.2 Διαχωρισμός των Δεδομένων σε Train και Test

Για την εκπαίδευση, επαλήθευση και ποιοτική αξιολόγηση του μοντέλου που θα δημιουργήσουμε, θα εφαρμοστεί η μέθοδος 10-fold cross validation. Τα δεδομένα θα χωριστούν σε Train και Test. Με τα δεδομένα Train που αποτελούν το 90% των συνολικών δεδομένων θα γίνει η εκπαίδευση του μοντέλου και με τα δεδομένα Test που αποτελούν το υπόλοιπο 10% θα γίνει επαλήθευση της ορθότητας του μοντέλου που δημιουργήθηκε. Παρακάτω παρουσιάζεται ο διαχωρισμός των δεδομένων:

ΒΗΜΑ	TEST (%)	TRAIN (%)
1	0-10	10-90
2	10-20	0-10 & 20-100
3	20-30	0-20 & 30-100
4	30-40	0-30 & 40-100
5	40-50	0-40 & 50-100
6	50-60	0-50 & 60-100
7	60-70	0-60 & 70-100
8	70-80	0-70 & 80-100
9	80-90	0-80 & 90-100
10	90-100	0-90

Πίνακας 5.3: Διαχωρισμός Δεδομένων σε Train και Test

Σε κάθε βήμα τα Test δεδομένα είναι περίπου 60.000 σε αριθμό ενώ τα Train περίπου 540.000

5.2.3 Επίπεδα (layers), Κρυμμένα Επίπεδα (hidden layers) και Παράμετροι του Compiler

Τα επίπεδα και κρυμμένα επίπεδα που χρησιμοποιήθηκαν για την δημιουργία του μοντέλου φαίνονται στον παρακάτω πίνακα:

Αριθμός Κόμβων	Activation
16	Sigmoid
8	Sigmoid
4	Sigmoid
1	Linear

Πίνακας 5.4: Χαρακτηριστικά Layers

Οι παράμετροι για τον Compiler είναι:

- Optimizer → Adam
- Losses → Mean Squared Error

Προκειμένου να δημιουργηθεί το μοντέλο για κάθε σύνολο δεδομένων, ο αλγόριθμος εκτελέστηκε σε 25 epochs.

5.3 Αποτελέσματα του Μοντέλου

5.3.1 Μέσω Τετραγωνικό Σφάλμα Epoch

Το μέσο τετραγωνικό σφάλμα για κάθε epoch, και για τα 10 μοντέλα, παρουσιάζεται στον παρακάτω πίνακα:

ΔΕΔΟΜΕΝΑ		EPOCHS Mean Square Error							
ΒΗΜΑ	TRAIN (%)	1	2	3	5	10	15	20	25
1	10-90	0.0231	0.0164	0.0156	0.0151	0.0146	0.0144	0.0143	0.0142
2	0-10 & 20-100	0.1429	0.0167	0.0160	0.0153	0.0145	0.0143	0.0141	0.0140
3	0-20 & 30-100	0.0170	0.0154	0.0146	0.0141	0.0137	0.0136	0.0135	0.0134
4	0-30 & 40-100	0.0174	0.0159	0.0150	0.0144	0.0139	0.0137	0.0136	0.0135
5	0-40 & 50-100	0.0330	0.0140	0.0132	0.0127	0.0122	0.0121	0.0120	0.0119
6	0-50 & 60-100	0.0745	0.0141	0.0132	0.0126	0.0122	0.0121	0.0119	0.0119
7	0-60 & 70-100	0.0214	0.0159	0.0151	0.0146	0.0140	0.0138	0.0136	0.0135
8	0-70 & 80-100	0.5420	0.0158	0.0148	0.0142	0.0137	0.0135	0.0134	0.0133
9	0-80 & 90-100	0.3468	0.0141	0.0134	0.0130	0.0126	0.0123	0.0122	0.0121
10	0-90	0.0960	0.0146	0.0138	0.0133	0.0128	0.0126	0.0125	0.0124

Πίνακας 5.5 Μέσω τετραγωνικό σφάλμα ανά epoch ανά βήμα

5.3.2 Ποσοστό Επιτυχίας Μοντέλων

Το ποσοστό επιτυχίας του κάθε μοντέλου υπολογίστηκε στα test δεδομένα σε κάθε βήμα. Τα κριτήρια για το επιτυχές της πρόβλεψης είναι:

- Το κατά ποσοστό σφάλμα της τιμής πρόβλεψης από την πραγματική τιμή να μην υπερβαίνει σε απόλυτο αριθμό το 30%
- Το σφάλμα να μην υπερβαίνει σε απόλυτο αριθμό τα 30.000 ευρώ

Στον παρακάτω πίνακα παρουσιάζονται τα αποτελέσματα του σφάλματος σε κάθε βήμα:

ΔΕΔΟΜΕΝΑ		ΠΟΣΟΣΤΟ ΕΠΙΤΥΧΙΑΣ %
ΒΗΜΑ	TRAIN (%)	
1	10-90	58.66
2	0-10 & 20-100	69.83
3	0-20 & 30-100	62.00
4	0-30 & 40-100	63.26
5	0-40 & 50-100	62.53
6	0-50 & 60-100	62.51
7	0-60 & 70-100	56.77
8	0-70 & 80-100	64.27
9	0-80 & 90-100	51.09
10	0-90	51.23


Πίνακας 5.6 Ποσοστό επιτυχίας μοντέλου ανά βήμα

Ο μέσος όρος σφάλματος για όλα τα μοντέλα είναι 60.22%

Παρακάτω παρουσιάζεται το κατά ποσοστό σφάλμα του μοντέλου ανά τάξη και ανά βήμα.

Τάξεις Τιμών Ακινήτων (σε χιλιάδες ευρώ)	% Ποσοστό Σφάλματος ανά Βήμα										
	ΒΗΜΑ	1	2	3	4	5	6	7	8	9	10
< 100	48.68	56.56	25.73	11.34	11.83	14.97	6.80	47.18	35.47	46.27	30.48
100-150	85.20	81.00	51.93	44.92	33.50	37.03	35.84	63.57	53.67	49.38	53.60
150-200	75.92	84.34	76.88	71.81	56.02	48.93	65.20	77.24	57.50	50.37	66.42
200-250	47.73	61.40	85.18	85.90	64.50	62.11	83.95	77.31	59.65	52.34	68.01
250-300	17.99	27.71	82.43	85.77	69.26	70.87	85.12	66.43	61.15	55.32	62.21
300-400	0.54	3.19	70.16	75.08	75.79	74.29	77.05	53.94	64.84	58.15	55.30
> 400	1.88	0.00	27.98	27.53	64.53	69.51	35.74	28.79	52.91	56.42	36.53
0-800	58.66	69.83	62.00	63.26	62.53	62.51	56.77	64.27	51.09	51.23	60.22

Πίνακας 5.7 Ποσοστό επιτυχίας μοντέλου ανά βήμα – ανά τιμή



Πίνακας 5.8 Μέσω συνολικό ποσοστό επιτυχίας ανά τιμή

6 ΣΥΜΠΕΡΑΣΜΑΤΑ

6.1 Παράγοντες όπου Επηρεάζουν Αρνητικά την Ακρίβεια του Μοντέλου

Α) Τα δεδομένα που χρησιμοποιήθηκαν είναι αγγελίες ακινήτων και όχι πραγματοποιηθείσες συναλλαγές. Αυτό επηρεάζει σημαντικά την ακρίβεια, καθώς η τελική τιμή μπορεί να αποκλίνει σημαντικά από την τιμή αρχικής προσφοράς, πάντα προς κάτω. Ακόμα κάποιες αγγελίες είναι ψευδείς, με σκοπό να δημιουργήσουν εντυπώσεις στους καταναλωτές ή να προσελκύσουν πελάτες. Δεν υπάρχει τρόπος να φιλτραριστούν οι αγγελίες αυτές από ψευδείς πληροφορίες.

Β) Οι αγγελίες δεν περιέχουν πάντα πραγματικά στοιχεία για τα ακίνητα για τον ίδιο λόγο με παραπάνω. Κυρίως όμως αυτό που δεν αναφέρεται σκοπίμως με ακρίβεια είναι η θέση του ακινήτου. Η γεωγραφική θέση του ακινήτου είναι το σημαντικότερο στοιχείο του που του προσδίδει αξία. Μέσω αυτής μπορούμε να ξέρουμε με βεβαιότητα από πληροφορία δημόσια, την τιμή ζώνης που βρίσκεται το ακίνητο, το οικοδομικό τετράγωνο με τον συντελεστή δόμησης και τις χρήσεις γης και την γεωμετρία του οικοπέδου ή γεωτεμαχίου που υπόκειται του ακινήτου.

Γ) Ο δεύτερος σημαντικότερος παράγοντας που επηρεάζει την τιμή ενός ακινήτου, είναι το ιδιοκτησιακό καθεστώς. Τα δεδομένα αυτά όμως θα γίνουν γνωστά μετά την ολοκλήρωση του έργου του Εθνικού Κτηματολογίου. Ακόμα όμως και να ολοκληρωθεί πολλά από αυτά τα δεδομένα είναι προσωπικά, χωρίς να μπορούν να γίνουν γνωστά στο ευρύ κοινό, οπότε πάντα λόγω αυτού του προβλήματος θα υπάρχει αβεβαιότητα στις εκτιμήσεις αξιών ακινήτων.

6.2 Παράγοντες όπου Επηρεάζουν Θετικά την Ακρίβεια του Μοντέλου

Ο παράγοντας που επηρεάζει θετικά την ακρίβεια του μοντέλου είναι η πληροφορία της αντικειμενικής τιμής ζώνης. Η τιμή ζώνης χρησιμοποιείται ως οδηγός για την εκτίμηση αξιών ακινήτων, αφού είναι μία ταξινόμηση στις αξίες ακινήτων όπου ήδη έχει γίνει χονδρικά, από το υπουργείο οικονομικών.

ΠΕΡΙΛΗΨΗ

Τα τελευταία χρόνια, έχει αναπτυχθεί στην ερευνητική κοινότητα ένα αυξημένο ενδιαφέρον για την εκτίμηση αξιών ακινήτων, με τεχνικές Deep Learning. Σε αυτή την διπλωματική εργασία παρουσιάζεται η διαδικασία σχεδίασης συνελκτικού νευρωνικού δικτύου, με σκοπό την εκτίμηση αξιών ακινήτων.

Για αυτό χρησιμοποιήθηκαν και συνδυάστηκαν δεδομένα από

- Διαδικτυακές πλατφόρμες στην Ελλάδα προβολής αγγελιών ακινήτων.
- Δημόσια δεδομένα από το υπουργείο οικονομικών σχετικά με τις αντικειμενικές αξίες ακινήτων.
- Δεδομένα από το openstreet map για την διοικητική διαίρεση της Ελλάδος.

Το αποτέλεσμα ήταν η δημιουργία μαθηματικού μοντέλου όπου προβλέπει την αξία ενός ακινήτου βάση των χαρακτηριστικών του με επιτυχία περίπου 60%. Το αποτέλεσμα κρίνεται ικανοποιητικό, αφού τα δεδομένα που χρησιμοποιήθηκαν ήταν αγγελίες από ακίνητα προς πώληση, άρα υπάρχει μεγάλη αβεβαιότητα στην ορθότητα των στοιχείων. Η ακρίβεια μπορεί να βελτιωθεί αισθητά μέσω της αξιοποίησης μιας βάσης δεδομένων ακινήτων όπου θα περιέχει αξιόπιστα και ακριβή δεδομένα.

ΒΙΒΛΙΟΓΡΑΦΙΑ

ΟΙΚΟΝΟΜΙΚΗ ΕΠΙΣΤΗΜΗ

- [1] Blackadar, C. (1986), "Dynamic Capitalization: An income approach in Real Dollars at Real Interest"
- [2] Crosby, N. (1983), "The investment method of valuation: A real value approach"
- [3] Crosby, N. (1986), "Real value, rational model, D.C.F.: A reply"
- [4] Jenkins, David S. (2006), "The benefits of hybrid valuation models"
- [5] Jefferies, Rodney L. (2009), "A brief history and development of 'Real Value' Valuation Models"

ΕΠΙΣΤΗΜΗ ΤΗΣ ΠΛΗΡΟΦΟΡΙΚΗΣ

- [6] Ian Goodfellow and Yoshua Bengio and Aaron Courville (2016), "Deep Learning" MIT Press
- [7] D. E. Rumelhart, G. E. Hinton and a. R. J. Williams (1988), "Learning internal representations by error propagation". MIT Press, Cambridge
- [8] B. Polyak (1964), "Some methods of speeding up the convergence of iteration methods," Ussr Computational Mathematics and Mathematical Physics.
- [9] A. Geron [2017], Hands-On Machine Learning with Scikit-Learn & TensorFlow, O'reilly.
- [10] D. Hubel and a. T. Wiesel (1959), "Receptive Fields of Single Neurones in the Cat's Striate Cortex"
- [11] Y. LeCun, L. Bottou, Y. Bengio and a. P. Haffner (1998), "Gradient-Based Learning Applied to Document Recognition"