



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

Σχολή Ηλεκτρολόγων Μηχανικών  
και Μηχανικών Υπολογιστών  
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών

**Πρόβλεψη τιμών δημοπρασιών online διαφημίσεων με ευφυείς τεχνικές**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ  
ΧΑΤΖΗΧΑΡΑΛΑΜΠΟΥΣ ΓΕΩΡΓΙΟΣ

**Επιβλέπων :** Ανδρέας - Γεώργιος Σταφυλοπάτης Καθηγητής Ε.Μ.Π.

**Συνεπιβλέπων :** Σιόλας Γεώργιος ΕΔΙΠ Ε.Μ.Π

Αθήνα, Ιούνιος 2019





ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

Σχολή Ηλεκτρολόγων Μηχανικών  
και Μηχανικών Υπολογιστών  
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών

**Πρόβλεψη τιμών δημοπρασιών online διαφημίσεων με ευφυείς τεχνικές**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ  
ΧΑΤΖΗΧΑΡΑΛΑΜΠΟΥΣ ΓΕΩΡΓΙΟΣ

**Επιβλέπων :** Ανδρέας - Γεώργιος Σταφυλοπάτης Καθηγητής Ε.Μ.Π.  
**Συνεπιβλέπων :** Σιόλας Γεώργιος ΕΔΙΠ Ε.Μ.Π

Εγκρίθηκε από τη τριμελή εξεταστική επιτροπή τη 10<sup>η</sup> Ιουνίου 2019.

.....

.....

.....

Ανδρέας-Γεώργιος Σταφυλοπάτης  
Καθηγητής Ε.Μ.Π

Γεώργιος Στάμου  
Αναπληρωτής Καθηγητής Ε.Μ.Π

Παναγιώτης Τσανάκας  
Καθηγητής Ε.Μ.Π

Αθήνα, Ιούνιος 2019

.....  
ΧΑΤΖΗΧΑΡΑΛΑΜΠΟΥΣ ΓΕΩΡΓΙΟΣ

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π.

Copyright © Χατζηχαραλάμπους Γεώργιος, 2019.

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου.

## Περίληψη

Τα τελευταία χρόνια με την άνοδο και κυριαρχία του διαδικτύου, οι εταιρείες έχουν αλλάξει τελείως τον τρόπο που διαφημίζουν τα προϊόντα τους. Οι διαφημίσεις πλέον γίνονται κυρίως με χρήση του διαδικτύου και πιο συγκεκριμένα, μέσω προβολής τους σε μικρά παράθυρα των ιστοσελίδων. Λόγω της εκτενούς χρήσης του διαδικτύου επήλθε μεγάλη ανάπτυξη στην ηλεκτρονική προβολή διαφημίσεων αλλά ταυτόχρονα, αποτέλεσε σημαντικό τομέα έρευνας. Ο μηχανισμός που παρέχει τις δημοπρασίες και βοηθά την αγορά και πώληση ηλεκτρονικών διαφημίσεων ονομάζεται Real Time Bidding (RTB). Περαιτέρω, καθώς ζούμε στη εποχή των Big Data, ο κλάδος του RTB επωφελείται και εκμεταλλεύεται τα πολλά δεδομένα που υπάρχουν στην αγορά για τη δημιουργία ατομικών profile, ώστε να παράγονται στοχευμένες και ουσιαστικές διαφημίσεις που ενδιαφέρουν το συγκεκριμένο χρήστη.

Παρόλη την ανάπτυξη του κλάδου αυτού, υπάρχουν πολλά προβλήματα στον ορίζοντα. Ειδικότερα, τα δεδομένα που υπάρχουν είναι ιδιαίτερα πολύπλοκα και χρειάζονται σημαντική επεξεργασία για να μπορούν να αξιοποιηθούν από τους διαφημιστές. Επίσης, η διάσταση τους είναι πολύ μεγάλη για να μπορούν οι αλγόριθμοι να τα χρησιμοποιήσουν στην αρχική τους μορφή, καθώς απαιτούν μεγάλη υπολογιστική ισχύ. Αξίζει να τονιστεί όμως, ότι τα σημαντικότερα προβλήματα εντοπίζονται στη διαδικασία της δημοπρασίας. Συγκεκριμένα, σε κάθε δημοπρασία, απαιτείται να αποφασιστεί αν θα συμμετάσχει ή όχι ο κάθε διαφημιστής και ποια θα είναι η τιμή προσφοράς της διαφήμισης. Συνάμα, απαραίτητος είναι και ο έλεγχος του προϋπολογισμού κάθε διαφημιστή, ούτως ώστε να επιτευχθούν τα καλύτερα αποτελέσματα σε βάθος χρόνου.

Σκοπός της διπλωματικής αυτής είναι η μελέτη του οικοσυστήματος του RTB σε ηλεκτρονικές διαφημίσεις και η εύρεση λύσεων στα προαναφερθέντα προβλήματα επιλογής των τιμών τους στις δημοπρασίες μέσω πρόβλεψης της απόκρισης του χρήστη. Έμφαση δίνεται στην πρόβλεψη του Click-Through Rate (CTR), που πραγματοποιείται με δύο μεθόδους. Η δημοφιλής μέθοδος των νευρωνικών δικτύων χρησιμοποιείται για την πρόβλεψη του CTR, ενώ επιπλέον μελετάται και παρουσιάζεται μια πρόσφατα δημοσιευμένη μέθοδος που τη χρησιμοποιούμε και για μείωση της διάστασης των δεδομένων σε προβλήματα μηχανικής μάθησης, που ονομάζεται μηχανή παραγοντοποίησης - Factorization Machine (FM). Εφαρμόσαμε και συγκρίναμε αυτές τις δύο μεθόδους για πρόβλεψη του CTR, χρησιμοποιώντας το σύνολο δεδομένων IPinYou. Επίσης, μερικές δοκιμές της FM έγιναν και στο σύνολο δεδομένων Criteo για πρόβλεψη CTR.

Παρατηρούμε ότι τα αποτελέσματα μας τόσο με τη FM όσο και με τα νευρωνικά δίκτυα είναι αρκετά ικανοποιητικά, και αντίστοιχης ακρίβειας με τα τελευταία τεχνολογικά μοντέλα. Τα αποτελέσματα αξιολογήθηκαν με βάση δύο διαδεδομένες μετρικές αξιολόγησης, την Area Under the Curve (AUC) και Root Mean Square Error (RMSE). Σημαντικό ρόλο στα αποτελέσματα φαίνεται να έχει το μέγεθος του διανύσματος παραγοντοποίησης κάθε χαρακτηριστικού της FM των δεδομένων μας, συνεπώς για την εκπαίδευση του μοντέλου της μηχανής παραγοντοποίησης, διερευνήσαμε διάφορα μεγέθη διανύσματος και καταλήξαμε ότι με ένα μικρό σχετικά διάνυσμα ( $k=20$ ), μπορούμε να αναπαραστήσουμε εξαιρετικά τα χαρακτηριστικά εισόδου.

Αξίζει να σημειώσουμε ότι τα δικά μας μοντέλα είναι αρκετά πιο απλά στην υλοποίηση αλλά και πιο αποδοτικά από θέμα υπολογιστικής ισχύς, σε σχέση με τα υπάρχοντα μοντέλα. Συνεπώς, αποτελεί σημαντικό πλεονέκτημα αλλά και συμπέρασμα ότι τα μοντέλα που χρησιμοποιήθηκαν σε αυτή την εργασία, παράγουν αντίστοιχης ποιότητας αποτελέσματα, αλλά με πιο απλό και αποδοτικό τρόπο. Ταυτόχρονα, καθότι τα μοντέλα είναι απλά, υπάρχει μεγάλο περιθώριο βελτίωσης με χρήση συνδυασμού μεθόδων αλλά και πιο πολύπλοκων μοντέλων, δημιουργώντας σημαντικές ευκαιρίες για μελλοντική συνέχιση αυτής της μελέτης. Τέλος, μέσω της παρούσας διπλωματικής αναδεικνύεται η δύναμη της μηχανής παραγοντοποίησης τόσο για γενική χρήση σαν αλγόριθμος μηχανικής μάθησης αλλά και για μείωση της διάστασης δεδομένων, με πολλές δυνατότητες για μεγάλο εύρος εφαρμογών.

### Λέξεις κλειδιά

Real Time Bidding (RTB), Click-Through Rate (CTR), Factorization Machine (FM), Νευρωνικά δίκτυα, Μείωση διάστασης



## Abstract

Over the past years, through the rise and dominance of the Internet, companies have changed the way they advertise their products. Nowadays, most advertisements (ads) are made using the Internet. More specifically, ads are usually shown in small areas of websites, called banners. Due to the extensive popularity of the internet, there has been a vast development and improvement in the field of online ads display, with a subsequent research interest in the field. The mechanism which provides the auctions and facilitates the sales and purchases of online ads is called Real Time Bidding (RTB). Furthermore, as we live in the era of Big Data, the field of RTB can significantly benefit from the large amounts of data that exist in the open market. Specifically, through the creation of individual user profiles, targeted and more relevant ads can be promoted to each user.

Despite significant advances in field of online ads, important problems remain. Specifically, the data available for creating user profiles are very complex and require a significant amount of preprocessing in order to be useful to advertisers. Furthermore, the data dimension is large, thus significant computational power is required for running relevant data-processing algorithms. However, it is worth mentioning that the most important problems are found in the auction process. For each auction, there are the requirements of determining whether an advertiser will join or not, and what the bidding price for the specific ad will be. Moreover, budget control for each advertiser is also a necessity, in order to achieve the best long-term results.

The purpose of this dissertation is to study the RTB ecosystem in online advertisements and to find solutions for the underlying problem of selecting the final bidding price in the auctions through the forecasting of the user response. Particular attention is given to predicting the Click-Through Rate (CTR) which is estimated using two approaches. The widely used Neural Networks method is used for CTR prediction, while this work also studies the Factorization Machine (FM) technique – a recently published method which it's also used for dimensionality reduction in machine learning problems. Both methods were applied and compared to predict CTR, using the IPinYou dataset. Furthermore, FM was tested in the Criteo dataset for CTR prediction.

Based on the abovementioned methods and simulations we can observe that our results are quite satisfactory, and of similar accuracy as the state-of-the-art models found in the literature. The accuracy of the results was assessed using two widely employed metrics, the Area Under the Curve (AUC) and the Root Mean Square Error (RMSE). Through the analysis performed, the dimension of the factorization vector of the characteristics was found to have an important effect on the results, thus several sizes were tested for the dimension during the training of the factorization machine method. It was found that a relatively small dimension of factorization vector ( $k=20$ ) is able to fully represent the input characteristics.

It is worth mentioning that the models employed in this work are much simpler in implementation and more computationally efficient compared to existing popular models. Accordingly, an important contribution of this work is the fact that sufficient accuracy can be achieved in a simpler and more computationally efficient manner, compared to state-of-the-art methods. At the same time, as the models used are simple in terms of implementation, there is significant potential for improvement, creating opportunities for future continuation of the work presented. Finally, this dissertation has highlighted the power and potential of the factorization machine method, both as a general predictor for machine learning tasks and for dimensionality reduction in data – with a wide range of possible applications. At the same time, the analysis performed emphasizes the importance of user profiling for producing targeted and more relevant ads and for achieving improved accuracy in CTR predictions.

### Keywords

Real Time Bidding (RTB), Click-Through Rate (CTR), Factorization Machine (FM), Neural networks, Dimensionality reduction





# Ευχαριστίες

Η παρούσα διπλωματική εργασία εκπονήθηκε στο πλαίσιο του προπτυχιακού προγράμματος σπουδών της Σχολής Ηλεκτρολόγων Μηχανικών & Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου και σηματοδοτεί την ολοκλήρωση των σπουδών μου ενώ συγχρόνως αποτελεί το ερέθισμα για περαιτέρω έρευνα στο συγκεκριμένο αντικείμενο.

Προτού όμως αναφερθώ στη περιγραφή της εργασίας και στα αποτελέσματα που προέκυψαν, θα ήθελα να ευχαριστήσω θερμά τους ανθρώπους οι οποίοι μέσω της συνεργασίας μας, συνέβαλαν σημαντικά στην ολοκλήρωση αυτής της εργασίας.

Αρχικά θα ήθελα να απευθύνω τις ευχαριστίες μου στον επιβλέποντα κ. Ανδρέα-Γεώργιο Σταφυλοπάτη, Καθηγητή Ε.Μ.Π ο οποίος μου προσέφερε τη δυνατότητα να εκπονήσω την διπλωματική μου σε ένα αντικείμενο ιδιαίτερα ελκυστικό και ενδιαφέρον για μένα και να διευρύνω τις επιστημονικές μου γνώσεις. Παράλληλα θα ήθελα να ευχαριστήσω τους κ.κ. Παναγιώτη Τσανάκα, Καθηγητή Ε.Μ.Π και Γεώργιο Στάμου, Αναπληρωτή Καθηγητή Ε.Μ.Π για την τιμή που μου έκαναν να είναι μέλη της επιτροπής εξέτασης της διπλωματικής εργασίας.

Επίσης οφείλω ιδιαίτερες ευχαριστίες στον συνεπιβλέποντα κ. Γεώργιο Σιόλας, ΕΔΙΠ Ε.Μ.Π για το χρόνο που αφιέρωσε και την θεμελιώδη του συνεισφορά στην εκπόνηση της συγκεκριμένης εργασίας. Η στήριξη του, επιστημονική και πνευματική, καθώς και η καθοδήγηση του σε όλη τη διάρκεια της πορείας αυτής συνέβαλαν τα μέγιστα στην επίτευξη ενός πολύ σημαντικού για εμένα στόχου. Η προθυμία του να με βοηθήσει μέσω της εμπειρίας και των γνώσεων του σε οποιαδήποτε δυσκολία συνάντησα στάθηκαν καθοριστικές και η συνεργασία μας θεωρώ πως ήταν άκρως επιτυχημένη και εποικοδομητική.

Τέλος, με εξίσου μεγάλη θερμότητα θέλω να αναφερθώ και να ευχαριστήσω την οικογένεια μου, η οποία με στήριξε όλα αυτά τα χρόνια σε όλες τις δύσκολες στιγμές, καθώς και τους φίλους και τους συμφοιτητές μου, οι οποίοι στάθηκαν δίπλα μου σε όλη τη διάρκεια της ακαδημαϊκής μου πορείας, ο καθένας με τον δικό του ξεχωριστό τρόπο.

Γεώργιος Χατζηχαραλάμπους,  
Αθήνα, 10<sup>η</sup> Ιουνίου 2019



# Περιεχόμενα

<u>Περίληψη.....</u>	<u>i</u>
<u>Abstract.....</u>	<u>iii</u>
<u>Ευχαριστίες.....</u>	<u>v</u>
<u>Κατάλογος πινάκων.....</u>	<u>ix</u>
<u>Κατάλογος σχημάτων.....</u>	<u>x</u>
<u>1. Εισαγωγή.....</u>	<u>1</u>
<u>1.1 Διαφήμιση και ιστορική αναδρομή.....</u>	<u>1</u>
<u>1.2 Ηλεκτρονική διαφήμιση.....</u>	<u>2</u>
<u>1.3 Προκλήσεις της ηλεκτρονικής διαφήμισης.....</u>	<u>4</u>
<u>2. Οικοσύστημα RTB online διαφημίσεων και τα προβλήματα που εμφανίζει.....</u>	<u>5</u>
<u>2.1 Εισαγωγικά - Παρουσίαση οικοσυστήματος RTB.....</u>	<u>5</u>
<u>2.2 Μηχανισμοί Δημοπρασιών.....</u>	<u>7</u>
<u>2.3 Προβλήματα οικοσυστήματος RTB online διαφημίσεων.....</u>	<u>8</u>
<u>2.3.1 Γενικά.....</u>	<u>8</u>
<u>2.3.2 Υπολογισμός Click-through rate (CTR).....</u>	<u>8</u>
<u>2.3.3 Bid landscape forecasting – Πρόβλεψη της κατανομής της νικητήριας τιμής.....</u>	<u>10</u>
<u>2.3.4 Στρατηγικές πονταρίσματος – Bidding strategies.....</u>	<u>11</u>
<u>2.3.5 Προσαρμοστικός έλεγχος κατανάλωσης προϋπολογισμού – Budget pacing.....</u>	<u>13</u>
<u>2.3.6 Δεδομένα για το χρήστη και τη συμπεριφορά του.....</u>	<u>16</u>
<u>3. Συγγενικά ερευνητικά θέματα.....</u>	<u>17</u>
<u>3.1 Εισαγωγικά.....</u>	<u>17</u>
<u>3.2 Πρόβλεψη τιμής αεροπορικού εισιτηρίου.....</u>	<u>17</u>
<u>3.3 Διαχείριση εφοδιαστικής αλυσίδας.....</u>	<u>18</u>
<u>3.4 Συστήματα συστάσεων.....</u>	<u>20</u>
<u>4. Συναφείς μελέτες για το CTR.....</u>	<u>22</u>
<u>4.1 Εισαγωγή.....</u>	<u>22</u>
<u>4.2 Μοντέλα παλινδρόμησης – Regression models.....</u>	<u>22</u>

4.3 Βαθιά Νευρωνικά Δίκτυα.....	23
5. Μηχανές Παραγοντοποίησης.....	27
5.1 Εισαγωγή.....	27
5.2 Μοντέλο της μηχανής παραγοντοποίησης.....	27
5.3 Αλγόριθμοι εκμάθησης μηχανών παραγοντοποίησης.....	29
5.4 Πεδιο-κεντρικές μηχανές παραγοντοποίησης - Field-aware Factorization Machines (FFM).....	29
5.5 Μορφή δεδομένων για FM και FFM.....	30
5.6 Βιβλιοθήκες για μηχανές παραγοντοποίησης.....	31
6. Σύνολα Δεδομένων και Προεπεξεργασία.....	32
6.1 Εισαγωγή.....	32
6.2 Σύνολα Δεδομένων.....	33
6.3 Προβλήματα στα σύνολα δεδομένων.....	38
7. Υλοποίηση αλγορίθμου πρόβλεψης του CTR.....	40
7.1 Εισαγωγικά.....	40
7.2 Μοντέλα – μέθοδοι υλοποίησης.....	40
7.3 Παράμετροι βελτιστοποίησης.....	42
7.4 Μετρικές αξιολόγησης αποτελεσμάτων.....	43
7.5 Προβλήματα κατά την υλοποίηση.....	44
8. Αποτελέσματα και αξιολόγηση.....	46
8.1 Γενικά.....	46
8.2 Αποτελέσματα μηχανής παραγοντοποίησης.....	46
8.3 Αποτελέσματα μηχανής παραγοντοποίησης με νευρωνικά δίκτυα – FNN.....	50
8.4 Σύγκριση με άλλα μοντέλα - μεθόδους.....	52
9. Συμπεράσματα και μελλοντικές Κατευθύνσεις.....	55
9.1 Συμπεράσματα και μελλοντικές κατευθύνσεις.....	55
Βιβλιογραφία.....	57
Παράρτημα Α – γραφικές AUC.....	64
Παράρτημα Β – γραφικές RMSE.....	65

# Κατάλογος Πινάκων

<u>Παράδειγμα δεδομένων εκπαίδευσης σε FFM.....</u>	30
<u>Ποσοστό CTR για κάθε διαφημιστή του IPinYou.....</u>	35
<u>Χαρακτηριστικά των δεδομένων του IPinYou.....</u>	36
<u>Αποτελέσματα πρόβλεψης CTR για τις δύο ομάδες χαρακτηριστικών.....</u>	49
<u>Αποτελέσματα πρόβλεψης CTR διαφόρων μοντέλων για dataset Criteo .....</u>	50
<u>Αποτελέσματα πρόβλεψης CTR διαφόρων μοντέλων.....</u>	53



# Κατάλογος σχημάτων

<u>2.1 Επικοινωνία και ροή αιτημάτων κατά τη διάρκεια μιας δημοπρασίας</u> .....	6
<u>2.2 Διάγραμμα μεριδίου προγραμματιστικών διαφημίσεων</u> .....	9
<u>2.3 Αλληλουχία ενεργειών του συστήματος ενισχυτικής μάθησης</u> .....	15
<u>2.4 Μεθόδοι ελέγχου προϋπολογισμού</u> .....	15
<u>3.1 Ενοποιημένο σύστημα εφοδιαστικής αλυσίδας</u> .....	20
<u>4.1 Νευρωνικό δίκτυο πρόσθιας τροφοδότησης</u> .....	26
<u>4.2 Μετατροπή διανύσματος σε μικρότερη διάσταση με χρήση embedding layer</u> .....	26
<u>8.1 Γραφική παράσταση AUC συναρτήση λανθάνων παραμέτρων</u> .....	47
<u>8.2 Γραφική παράσταση RMSE συναρτήση λανθάνων παραμέτρων</u> .....	48
<u>8.3 Αποτελέσματα AUC, για κάθε διαφημιστή για τις μεθόδους FM και FNN</u> .....	51
<u>8.4 Διαφορά αποτελεσμάτων ανα διαφημιστή στις μεθόδους FM και FNN</u> .....	52

# Κεφάλαιο 1

## Εισαγωγή

### 1.1 Διαφήμιση και ιστορική αναδρομή

Διαφήμιση ονομάζεται κάθε ανακοίνωση που γίνεται στο πλαίσιο εμπορικής, βιομηχανικής, βιοτεχνικής ή επαγγελματικής δραστηριότητας, με σκοπό την προώθηση της διάθεσης αγαθών ή υπηρεσιών και είναι άμεσα συνυφασμένη με την κουλτούρα ενός λαού. Οι εφημερίδες, η τηλεόραση, το ραδιόφωνο, οι ταχυδρομικές επιστολές και το διαδίκτυο θεωρούνται τα πιο γνωστά διαφημιστικά μέσα. Με τη ραγδαία ανάπτυξη του διαδικτύου και των έξυπνων κινητών - smartphones τις τελευταίες δύο δεκαετίες, οι χρήστες μπορούν εύκολα, ανώδυνα και γρήγορα να ψάχνουν για κάθε αγαθό που τους ενδιαφέρει. Μπορούν να συγκρίνουν τιμές, να παραγγέλνουν ή ακόμη και να κάνουν συναλλαγές αγοράζοντας κάθε λογής αγαθό ή υπηρεσία.

Οι ρίζες της διαφήμισης βρίσκονται χαμένες στη πάροδο του χρόνου. Στην αρχαία Ελλάδα του 6ου αιώνα η διαφήμιση ξεκίνησε με τους κήρυκες με τη μορφή μιας προφορικής αγγελίας – ανακοίνωσης. Σημαντικό να αναφέρουμε, ότι όπως και σήμερα, μαζί με το εμπόριο, άρχισε και ο ανταγωνισμός. Με τον ανταγωνισμό πρωτοεμφανίστηκε και η διαφήμιση. Η πρώτη γραπτή διαφήμιση, έγινε από ένα Άγγλο εκδότη στα τέλη του 15ου αιώνα και αναφέρεται στην έκδοση ενός εκκλησιαστικού βιβλίου. Το 20ο αιώνα υπήρξε ραγδαία ανάπτυξη στο τομέα της διαφήμισης, ως αποτέλεσμα της βιομηχανικής επανάστασης. Εκεί ξεκίνησε η διαφήμιση όπως την αντιλαμβανόμαστε σήμερα με τη χρήση της τηλεόρασης, ραδιοφώνου, εφημερίδων κλπ. Ο επόμενος μεγάλος σταθμός είναι στις αρχές αυτού του αιώνα σύμφωνα με τους [\[Wang, Zhang, & Yuan, 2016\]](#) με τη χρήση του διαδικτύου σαν διαφημιστικό μέσο. Αυτό που κάνει το διαδίκτυο τόσο σημαντικό και επαναστατικό σαν μέσο, είναι η δυνατότητα αμφίδρομης επικοινωνίας με το χρήστη - θεατή αλλά και το γεγονός ότι η επικοινωνία αυτή είναι σε πιο προσωπικό επίπεδο, έχοντας πιο στοχευμένη θεματολογία διαφήμισης. Συνάμα, πλέον είναι ένα από τα πιο φθηνά μέσα με ακτίνα διάδοσης της πληροφορίας σε πολύ μεγάλο και ευρύ κοινό.



## 1.2 Ηλεκτρονική διαφήμιση

Με τη ραγδαία ανάπτυξη του διαδικτύου και των έξυπνων κινητών - smartphones τις τελευταίες δύο δεκαετίες, οι χρήστες μπορούν εύκολα, ανώδυνα και γρήγορα να ψάχνουν για κάθε αγαθό που τους ενδιαφέρει. Μπορούν να συγκρίνουν τιμές, να παραγγέλνουν ή ακόμη και να κάνουν συναλλαγές αγοράζοντας κάθε λογής αγαθό ή υπηρεσία.

Παράλληλα, μεγάλες εταιρείες μηχανών αναζήτησης προσπαθούν να βελτιώσουν την εμπειρία περιήγησης των χρηστών στο διαδίκτυο, προσφέροντας όλο και καλύτερες και πιο εξειδικευμένες προτάσεις στο χρήστη. Λόγω της κυρίαρχης θέσης του διαδικτύου στις μέρες μας και καθώς όλο και περισσότερες επιχειρήσεις και εταιρείες λειτουργούν εξ ολοκλήρου στο διαδίκτυο, είναι λογικό επακόλουθο οι διαφημιστές πλέον να επικεντρώνουν τη στρατηγική τους σε αυτό το τομέα. Εκεί επιδιώκουν τόσο να προβάλουν τα προϊόντα τους αλλά και να βρουν νέους πελάτες.

Σαν επακόλουθο των ανωτέρω, ο τομέας που ασχολείται με τις ηλεκτρονικές διαφημίσεις είναι ένας από τους πιο αναπτυσσόμενους στη πληροφορική βιομηχανία. Κινητήριος μηχανισμός βέβαια είναι τα τεράστια χρηματικά ποσά που μπορούν οι εταιρείες να αποκτήσουν χρησιμοποιώντας πιο αναπτυγμένα και στοχευμένα συστήματα διαφήμισης.

Μερικοί τρόποι προβολής με χρήση του διαδικτύου είναι:

- Δημιουργία εταιρικών ιστοσελίδων με στόχο την προβολή της εταιρείας και την ενημέρωση γύρω από αυτή.
- Δημιουργία προωθητικών ιστοσελίδων με στόχο την προσέλκυση χρηστών που θα δημιουργήσουν σχέση με το προϊόν και θα οδηγήσουν στην αγορά του.
- Ηλεκτρονικά newsletters ή μηνύματα ηλεκτρονικού ταχυδρομείου, κυρίως ενημερωτικού χαρακτήρα.
- Διαφημιστικές καταχωρήσεις σε ιστοσελίδων που έχουν μεγάλη κίνηση ή σχετίζονται με το προωθούμενο αντικείμενο.

Με την άνοδο της ηλεκτρονικής διαφήμισης τις τελευταίες δεκαετίες αναπτύχθηκαν διάφοροι μηχανισμοί για την διευκόλυνση και προώθηση της αγοράς / πώλησης ηλεκτρονικών διαφημίσεων. Πιο συγκεκριμένα, ο μηχανισμός που επικρατεί σήμερα είναι μια μορφή πλειστηριασμού. Ονομάζεται RTB (Real Time Bidding) και παρέχει την υπηρεσία όπου διαδραματίζεται ο πλειστηριασμός. Διάφορες διαφημιστικές εταιρείες τοποθετούν 'πονταρίσματα' για το ποια θα προβάλει τη δική της διαφήμιση και σε χρόνο μικρότερο των 100ms πρέπει να βρεθεί ο νικητής και να σταλεί η νικητήρια διαφήμιση στο χρήστη - ιστοσελίδα.

Εν συντομία αναφέρουμε όλη τη διαδικασία της δημοπρασίας διαφήμισης που διαδραματίζεται, για λόγους κατανόησης και εξοικείωσης. Ο χρήστης επισκέπτεται μια ιστοσελίδα. Αυτή η ιστοσελίδα έχει ένα κομμάτι αφιερωμένο για διαφημίσεις. Μόλις την επισκεφθεί ο χρήστης, η ιστοσελίδα στέλνει ένα αίτημα μαζί με διάφορες πληροφορίες για το χρήστη (π.χ. δημογραφικά χαρακτηριστικά), προς ένα ανταλλακτήριο διαφημίσεων (ad exchange). Αυτό με τη σειρά του ενημερώνει τους διαφημιστές για το συγκεκριμένο αίτημα και αυτοί απαντάνε με την τιμή πονταρίσματος, αν θελήσουν να ποντάρουν. Έπειτα, αυτός που πόνταρε περισσότερα κερδίζει τη δημοπρασία και η διαφήμιση του αποστέλλεται στη ιστοσελίδα, όπου και βλέπει ο χρήστης. Αυτή η διαδικασία έχει χρονικό όριο 100ms, από τη στιγμή που στάλθηκε το αίτημα από την ιστοσελίδα μέχρι τη στιγμή που εμφανίζεται στο χρήστη η διαφήμιση. Τέλος, αν ενδιαφέρει τον χρήστη η διαφήμιση, κάνει κλικ, το οποίο και καταγράφεται από τον διαφημιστή. Μετά από αυτή τη αναγκαία περιγραφή της δημοπρασίας διαφημίσεων, βλέπουμε πως μεταμορφώθηκε η διαφήμιση σε αυτή που γνωρίζουμε εμείς, σήμερα.

Συνοφασμένες με τις ηλεκτρονικές διαφημίσεις υπήρξαν ανέκαθεν οι ηλεκτρονικές μηχανές αναζήτησης, λόγω του ότι οι εταιρείες χρησιμοποιούσαν τις λέξεις που αναζητούσαν οι χρήστες για να βρουν τα κατάλληλα προϊόντα να τους δείξουν. Το 1998 εμφανίστηκε και ο όρος sponsored search. Με τον όρο αυτό περιγράφεται η διαδικασία κατά την οποία ένας διαφημιστής «αγοράζει» συγκεκριμένες λέξεις όπου πιθανόν να εισάγει ένας χρήστης σε μια μηχανή αναζήτησης για να του προωθήσει κάποιον προϊόν ή υπηρεσία, με τη μορφή συνήθως ενός συνδέσμου στη μηχανή αναζήτησης [[Wang, Zhang, & Yuan, 2016](#)]. Το sponsored search εξελίχθηκε στο display advertising, στο οποίο, η διαφήμιση έχει συνήθως τη μορφή είτε εικόνας είτε βίντεο και μπορεί να εμφανίζεται σε οποιαδήποτε ιστοσελίδα και όχι μόνο σε μηχανές αναζήτησης. Οι περισσότερες εταιρείες, εκμεταλλεύονται αυτή τη νέα μορφή διαφήμισης για να συλλέγουν δεδομένα για τους χρήστες τους. Πιο συγκεκριμένα, παίρνουν πληροφορίες μέσω των αναζητήσεων που κάνουν στην ιστοσελίδα της εταιρείας, τα είδη των βίντεο / εικόνων που βλέπουν ή ακόμη και αγοράζοντας έτοιμα δεδομένα από τρίτους. Με αυτά τα δεδομένα οι εταιρείες φτιάχνουν ένα profile για το χρήστη, τις προτιμήσεις και τις συνήθειες του. Σαν αποτέλεσμα, οι διαφημίσεις μπορούν να εμφανίζονται σε κάθε χρήστη ξεχωριστά, ανάλογα με το profile που έχει φτιάξει κάθε εταιρεία με τα δεδομένα που έχει συλλέξει για εκείνον, όπως αναφέρεται και στο [[Wang, Zhang, & Yuan, 2016](#)]. Αυτές οι διαφημίσεις είναι εξατομικευμένες και αντιστοιχούν στις προτιμήσεις που έχει ο χρήστης. Έτσι οι εταιρείες μπορούν να ποντάρουν ατομικά για κάθε ιστοσελίδα που βλέπει ο χρήστης, ώστε να προωθήσουν το προϊόν τους. Εδώ είναι που κρίνεται αναγκαίος ο μηχανισμός RTB.

### 1.3 Προκλήσεις της ηλεκτρονικής διαφήμισης

Βασική προϋπόθεση για μια επιτυχημένη ηλεκτρονική διαφήμιση είναι η ταχύτητα εμφάνισης της στο χρήστη. Καθώς οι χρήστες ιστοσελίδων ζητούν να φορτώνεται άμεσα η ιστοσελίδα που θέλουν να δουν, επιβάλλεται τόσο το ποντάρισμα όσο και η διαδικασία του πλειστηριασμού να γίνονται όσο το δυνατό ταχύτερα, ώστε να μειωθεί ο χρόνος απόκρισης. Παράλληλα, μια επιτυχημένη διαφήμιση στηρίζεται επίσης στην κατανόηση των αναγκών του χρήστη / πιθανού αγοραστή, που μπορεί να επιτευχθεί μέσω της χρήσης προσωπικών δεδομένων του κάθε χρήστη. Τα δεδομένα αυτά μπορούν να χρησιμοποιηθούν για τη δημιουργία μοντέλων πρόβλεψης της συμπεριφοράς του χρήστη, τα οποία θα δίνουν τη δυνατότητα δημιουργίας στοχευμένων διαφημίσεων σε ατομικό επίπεδο. Όμως, καθημερινά παράγονται όλο και περισσότερα, πολύπλοκα και πολυδιάστατα δεδομένα χρηστών, τα οποία είναι στη διάθεση των διαφημιστών. Για να μπορέσουν λοιπόν οι διαφημιστές να αξιοποιήσουν τα δεδομένα χρηστών για τη δημιουργία εξατομικευμένων διαφημίσεων, θα πρέπει να βρουν τρόπους εύκολης, γρήγορης και αποδοτικής χρήσης τους. Λαμβάνοντας υπόψη τον τεράστιο όγκο και ποικιλία δεδομένων χρηστών, καθώς και τη δυνατότητα που παρέχουν για τη δημιουργία εξατομικευμένων διαφημίσεων, είναι πλέον επιτακτική η ανάγκη δημιουργίας ενός γρήγορου, αποδοτικού και αξιόπιστου συστήματος πρόβλεψης της συμπεριφοράς του χρήστη.

## Κεφάλαιο 2

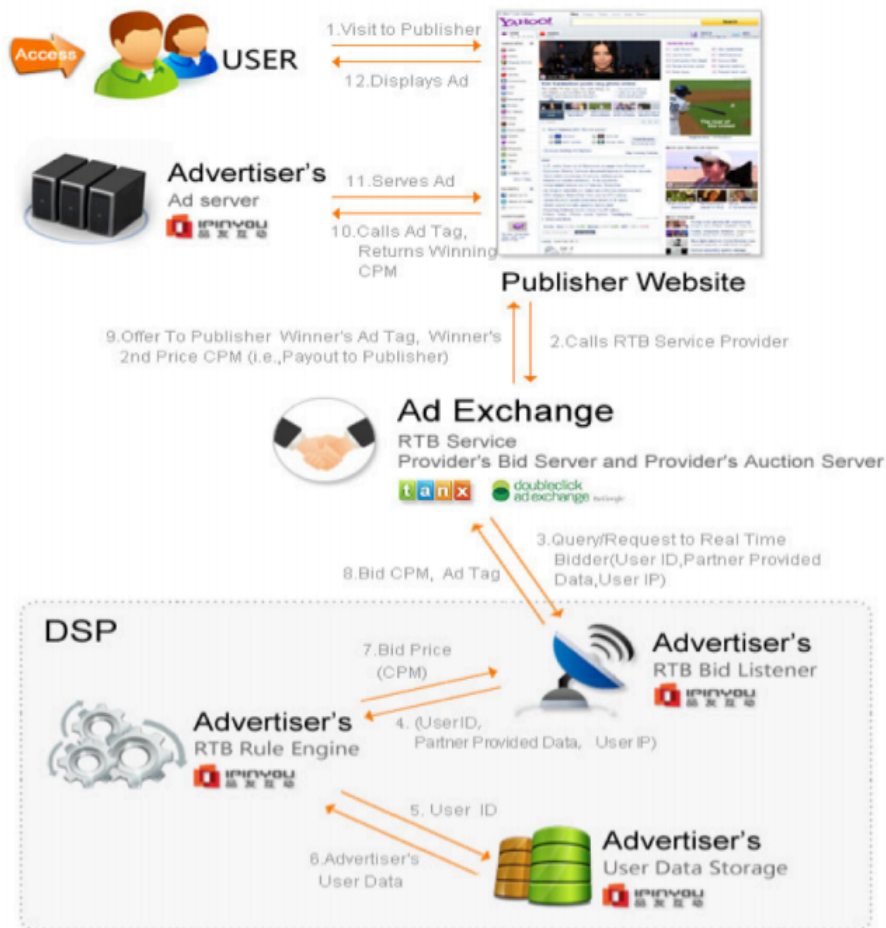
# Οικοσύστημα RTB online διαφημίσεων και τα προβλήματα που εμφανίζει

## 2.1 Εισαγωγικά - Παρουσίαση οικοσυστήματος RTB

Στο οικοσύστημα RTB διαφημίσεων υπάρχουν δύο σημαντικές οντότητες, το Ad Exchange (ADX) και το DSP (Demand Side Platform). Το Ad Exchange είναι μια ψηφιακή αγορά, όπου εκδότες και διαφημιστές συνεργάζονται για να κάνουν εμπόριο ηλεκτρονικών διαφημίσεων. Εκδότες θεωρούνται οι κάτοχοι ιστοσελίδων, online περιοδικών και ιστολογίων (blog) ή ακόμη και εφαρμογών κινητών τηλεφώνων. Στόχο έχουν μέσω του ADX, να προωθήσουν και να θέσουν προς πώληση το διαφημιστικό χώρο που κατέχουν στις ιστοσελίδες ή εφαρμογές τους. Στην αντίπερα όχθη είναι οι διαφημιστές, οι οποίοι μπορεί να είναι είτε ανεξάρτητοι έμποροι είτε διαφημιστικές εταιρείες και δίκτυα, και οι οποίοι συνδέονται σε ένα ADX με σκοπό να αγοράσουν αυτό το χώρο για να προβάλουν τις διαφημίσεις τους. Το DSP είναι μια πλατφόρμα με σκοπό να αγοράσει χώρο για τις διαφημίσεις που θέλει να προωθήσει, στη καλύτερη δυνατή τιμή και να τις εμφανίσει στους χρήστες, δεδομένου ότι τόσο οι χρήστες όσο και οι συγκεκριμένοι χώροι, πληρούν τα κριτήρια που δόθηκαν από τους διαφημιστές. Πιο συγκεκριμένα, όπως αναφέρεται στο [\[Liao et al., 2012\]](#) το ADX συγκεντρώνει τις διαφημίσεις από πολλούς διαφορετικούς εκδότες και αποστέλλει το αίτημα προσφοράς – πονταρίσματος (bid) σε διάφορα DSPs. Σε αυτό το αίτημα στέλνονται επιπρόσθετες πληροφορίες για το χώρο διαφήμισης, όπως το μέγεθος του χώρου και το url. Μπορεί επίσης να παρέχονται και πληροφορίες όπως η IP διεύθυνση του χρήστη ή γενικότερα κάποιου είδους μοναδικό αναγνωριστικό του χρήστη, όπως το cookie ID. Έπειτα το DSP, χρησιμοποιώντας αυτές τις πληροφορίες αλλά και πληροφορίες για το χρήστη, αποφασίζει αν θα ποντάρει ή όχι για αυτό το διαφημιστικό χώρο καθώς και την τιμή πονταρίσματος που θα στείλει στο ADX. Το ADX αφού μαζέψει όλες τις συμμετοχές από όλα τα DSPs, κάνει τη δημοπρασία και αποφασίζει το νικητή. Στο τέλος, η νικητήρια διαφήμιση προβάλλεται στο χρήστη μέσω ιστοσελίδας ή εφαρμογής, ανάλογα με το χώρο που αγοράστηκε. Στο [σχήμα 2.1](#) παρουσιάζεται πιο ξεκάθαρα η επικοινωνία που διαδραματίζεται μεταξύ του χρήστη, του ADX και του DSP κατά το RTB των διαφημίσεων.

Εξέχουσας σημασίας είναι το γεγονός ότι όλη αυτή η διαδικασία γίνεται αυτοματοποιημένα, μέσω προγραμμάτων - λογισμικού, και απαιτείται να έχει διάρκεια μερικών εκατοντάδων milliseconds. Ο σχεδιασμός και η βελτιστοποίηση τέτοιων λογισμικών κρίνεται αναγκαία στις μέρες μας. Αυτός είναι ο κύριος λόγος που μας ώθησε να μελετήσουμε τα προβλήματα που ενυπάρχουν σε αυτό το οικοσύστημα δημοπρασιών ηλεκτρονικών διαφημίσεων.

Σχήμα 2.1 : Παρουσιάζει την επικοινωνία και τη ροή των αιτημάτων που αποστέλλονται μεταξύ του χρήστη, του ADX και του DSP κατά τη δημοπρασία ενός χώρου που θα φιλοξενήσει μια διαφήμιση σύμφωνα με τους [Liao et al., 2012](#).



## 2.2 Μηχανισμοί Δημοπρασιών

Κάθε φορά που υπάρχει ένα αίτημα από μια ιστοσελίδα για να προβάλει μια διαφήμιση, χρειάζεται να γίνει μια δημοπρασία για να αποφασιστεί η νικητήρια διαφήμιση. Καθώς οι συγκεκριμένες δημοπρασίες αποτελούν κομβικό σημείο για το χειρισμό μεγάλων χρηματικών ποσών στην περιοχή των online ads, σημαντική έρευνα έχει γίνει για να βρεθεί η βέλτιστη στρατηγική για όλους (χρήστες, διαφημιστές κλπ).

Η κυριότερη έρευνα στον τομέα έχει τις ρίζες της στη θεωρία παιγνίων και στη στατιστική, με προσεκτική και σε βάθος μελέτη για την επιλογή της πιο συμφέρουσας απόφασης κατά τους [\[Wang, Zhang, & Yuan, 2016\]](#). Επιγραμματικά, αναφέρουμε τα πιο σημαντικά είδη δημοπρασιών και τι εν τέλη χρησιμοποιείται στο RTB διαφημίσεων.

- Δημοπρασίες πρώτης τιμής (first price auction)

Στη αυτό το είδος δημοπρασίας ο παίκτης με τη μεγαλύτερη προσφορά κερδίζει τη δημοπρασία. Το ποσό που πληρώνει είναι το ποσό της δικής του προσφοράς.

- Δημοπρασία δεύτερης τιμής (second price auction) ή αλλιώς Vickrey

Ο νικητής είναι πάλι ο παίκτης με τη υψηλότερη προσφορά αλλά τώρα πληρώνει την 2η υψηλότερη προσφορά. Δηλαδή γίνεται μια μικρή “έκπτωση” στο νικητή. Αυτός ο μηχανισμός δημοπρασίας θεωρείται φιλαλήθης, όπως αναφέρεται στο [\[Vickrey, 1961\]](#). Δηλαδή είναι κυρίαρχη στρατηγική για κάθε παίκτη να δηλώσει το πραγματικό του όφελος.

Στο οικοσύστημα των RTB ads, χρησιμοποιείται κυρίως η δημοπρασία δεύτερης τιμής. Αξίζει να σημειωθεί ότι αυτές οι δημοπρασίες είναι με ενσφράγιστες προσφορές [\[Wang, Zhang, & Yuan, 2016\]](#), δηλαδή ο κάθε παίκτης βλέπει μόνο τη δική του προσφορά. Έτσι μόνο ο διαφημιστής που έχει κερδίσει τη δημοπρασία μπορεί να δει τη νικητήρια τιμή, χωρίς οι άλλοι να γνωρίζουν πόσο κοντά ήταν η προσφορά τους στην τελική τιμή. Αυτό είναι ένα θέμα που θα μας απασχολήσει αργότερα όπου και θα δούμε τις δυσκολίες που παρουσιάζονται εξαιτίας της μορφής των δεδομένων μας.

Κάποιοι παρεμφερείς ορισμοί που αξίζει να αναφέρουμε είναι το hard price floor και το soft price floor. Το πρώτο αναφέρεται στη χαμηλότερη τιμή που είναι διατεθειμένος ένας εκδότης να πουλήσει το χώρο που παρέχει. Προσφορές κάτω από αυτή τη τιμή απευθείας αποκλείονται.

Το soft price floor είναι η τιμή που θέτει ένας εκδότης όπου εάν μια προσφορά είναι μικρότερη της αλλά μεγαλύτερη του hard floor τότε ο νικητής πληρώνει κανονικά τη τιμή της, όπως στις δημοπρασίες πρώτης τιμής. Δημιουργήθηκε για να μην χάνουν οι εκδότες ευκαιρίες που κανονικά θα ήταν χαμένες και βρίσκονται πολύ κοντά στο hard floor. Να ξεκαθαρίσουμε ότι εξαρτάται από κάθε ADX και κάθε εκδότη αν θα χρησιμοποιήσει ή όχι hard/soft price floor, όπως επίσης και ότι αυτά τα δύο δεν είναι

γνωστά στους διαφημιστές. Μάλιστα η πρόβλεψη αυτών των δύο τιμών είναι ανοικτό ερευνητικό κομμάτι καθώς προσφέρουν αρκετή πληροφορία για να προσδιοριστεί η τελική τιμή προσφοράς της διαφήμισης.

## 2.3 Προβλήματα οικοσυστήματος RTB online διαφημίσεων

### 2.3.1 Γενικά

Τα κύρια και πιο μεγάλα προβλήματα εμφανίζονται κατά τη λήψη της απόφασης ενός διαφημιστή αν θα ποντάρει για κάποια διαφήμιση και ποια τιμή είναι πρόθυμος να πληρώσει. Ο πιο διαδεδομένος τρόπος για να αποφασίσει αν αξίζει να προβληθεί μια διαφήμιση σε ένα συγκεκριμένο χρήστη, είναι γνωρίζοντας πόσο πιθανόν είναι να πατήσει πάνω (κλικ) ή γενικότερα να έχει κάποια αλληλεπίδραση μαζί της (παρακολουθώντας ένα βίντεο, ακούγοντας ένα ήχο κλπ.). Όπως είναι λογικό κάτι τέτοιο είναι αδύνατο να το γνωρίζουμε από πριν, για αυτό πρέπει να κάνουμε μια πρόβλεψη. Αυτό είναι το πιο σημαντικό πρόβλημα που αντιμετωπίζουμε στη αγορά των online διαφημίσεων αλλά και σε πολλούς τομείς του διαδικτύου π.χ. recommender systems - συστήματα συστάσεων και ονομάζεται **πρόβλεψη απόκρισης χρήστη** (user response prediction). Πιο συγκεκριμένα στην αγορά online διαφημίσεων λέγεται **Click-through rate** (CTR).

Δεύτερο πρόβλημα είναι η **εύρεση κατάλληλης τιμής πονταρίσματος**, που είναι άμεσα σχετιζόμενη με τα ζητήματα εύρεσης βέλτιστης συνάρτησης πονταρίσματος αλλά και ελέγχου του ρυθμού κατανάλωσης του προϋπολογισμού μιας εταιρείας. Όλα αυτά αναλύονται και παρουσιάζονται σε περισσότερη λεπτομέρεια παρακάτω.

### 2.3.2 Υπολογισμός Click-through rate (CTR)

Το CTR, είναι η αναλογία των χρηστών όπου έκαναν κλικ σε ένα σύνδεσμο (είτε γενικότερα αλληλεπίδρασαν με κάποιο στοιχείο μιας ιστοσελίδας/εφαρμογής), προς το συνολικό αριθμό χρηστών όπου είδαν αυτή τη σελίδα, μέγλ ή γενικότερα διαφήμιση. Είναι το πιο συχνά χρησιμοποιούμενο μέτρο για την αξιολόγηση επιτυχίας μιας διαδικτυακής διαφημιστικής καμπάνιας σε μια ιστοσελίδα όπως και την αποδοτικότητα διαφημιστικών μέγλ. Σύμφωνα με το [[Zhang et al., 2016](#)] και το [[Wang et al., 2016](#)], το user response prediction διαδραματίζει εξέχοντα ρόλο τόσο σε πολλές διαδικτυακές εφαρμογές όπως αναζήτηση στο διαδίκτυο, συστήματα συστάσεων, sponsored search όσο και στις online διαφημίσεις. Αυτό που το κάνει τόσο σημαντικό ειδικά τα τελευταία χρόνια, είναι το γεγονός ότι προσφέρει μια ποσοτικοποίηση του ενδιαφέροντος του χρήστη για ένα συγκεκριμένο γεγονός, κάτι που βοηθάει τους ενδιαφερόμενους διαφημιστές να επενδύσουν σε κατάλληλα προϊόντα. Εν ολίγοις, το προβλεπόμενο CTR εκφράζει την πιθανότητα ενός χρήστη σε ένα δεδομένο περιβάλλον να κάνει κλικ σε μια δεδομένη διαφήμιση. Η ικανότητα ατομικής στόχευσης χρηστών είναι το επίτευγμα που έδωσε ώθηση στις online διαφημίσεις έναντι των παραδοσιακών τρόπων διαφήμισης (π.χ., εφημερίδα). Όλες οι τακτικές στόχευσης χρηστών βασίζονται εξ ολοκλήρου στο να επιτύχουν ακριβή πρόβλεψη του CTR διαφημίσεων.

Πιο συγκεκριμένα, η πρόβλεψη του CTR είναι ένα πρόβλημα εύρεσης πιθανότητας, δηλαδή υπολογισμού ενός αριθμού ανάμεσα στο 0 και στο 1. Με τη χρήση μαθηματικών και στατιστικών




μεθόδων αλλά και με αλγόριθμους μηχανικής μάθησης, ερευνητές προσπαθούν να βρουν λύση σε αυτό το πρόβλημα, δημιουργώντας διάφορα μοντέλα πρόβλεψης. Ένα μεγάλο ζήτημα που αντιμετωπίζουν ειδικά, στη κοινότητα του RTB, είναι ότι παρόλο που υπάρχει πληθώρα δεδομένων από τους χρήστες π.χ. (IP address, cookies, πόλη κλπ.), τα γεγονότα (δηλαδή κλικ ή αλληλεπίδραση με τις online διαφημίσεις) είναι πολύ σπάνια. Κατά μέσο όρο το CTR είναι της τάξης του 0.01% - 0.1% ([Liao et al., 2012]) και ακόμη χαμηλότερο. Έτσι είναι πολύ δύσκολο να έχουμε καλά αποτελέσματα πρόβλεψης καθώς δεν μπορούμε να φτιάξουμε εύκολα αξιόπιστα μοντέλα λόγω ανυπαρξίας θετικών γεγονότων.

“Τα μισά χρήματα που ξοδεύω στις διαφημίσεις χάνονται. Το θέμα είναι ότι δεν ξέρω ποια μισά είναι αυτά.” Με αυτή τη χαρακτηριστική φράση, ο John Wanamaker, που από πολλούς θεωρείται ο πατέρας της σύγχρονης διαφήμισης, δηλώνει ακριβώς το πρόβλημα του CTR. Αν μπορούσαμε δηλαδή να έχουμε ένα πολύ καλό CTR, θα μπορούσαμε να κάνουμε πιο στοχευμένες και αποδοτικές διαφημίσεις, κάνοντας καλύτερη αξιοποίηση των χρημάτων που επενδύουμε.

Έχοντας υπόψη ότι το 2018 τα έσοδα από ψηφιακές διαφημίσεις έχουν ανέλθει στα 18.2 δισ. δολάρια από 3.1 δισ. το 2013, στην Αμερική και μόνο, μπορούμε να καταλάβουμε γιατί είναι σημαντικό να βελτιώσουμε το CTR. Στο [διάγραμμα 2.2](#), παρατηρούμε την ανοδική πορεία που έχει το RTB online διαφημίσεων. Πλέον, περισσότερες από τις μισές διαφημίσεις γίνονται μέσω του διαδικτύου, με καταγιστικό μάλιστα ρυθμό αύξησης, καθιστώντας πολύ σημαντική τη πρόβλεψη του CTR στο οικοσύστημα των RTB διαφημίσεων. Το αυξημένο ενδιαφέρον για πρόβλεψη του CTR φαίνεται και στην επιστημονική κοινότητα καθώς αποτελεί σημαντικό ερευνητικό τομέα στην περιοχή του RTB τα τελευταία χρόνια.

Διάγραμμα 2.2 : Παρουσιάζει το ποσοστό των διαφημίσεων που είναι τύπου RTB και την ανοδική του πορεία τα τελευταία χρόνια.<sup>1</sup>



1 Πηγή: <http://accelerateddigital.com/statistics/>



### 2.3.3 Bid landscape forecasting – Πρόβλεψη της κατανομής της νικητήριας τιμής

Το Bid landscape forecasting , έχει σαν κύριο στόχο τη πρόβλεψη της κατανομής της νικητήριας τιμής στις δημοπρασίες διαφημίσεων ([Cui et al., n.d.]). Η πρόβλεψη γίνεται δεδομένης μιας συγκεκριμένης διαφημιστικής καμπάνιας που διαδραματίζεται στην αγορά με περιορισμούς. Χρησιμοποιώντας τα δεδομένα που έχουμε με κάθε αίτημα διαφήμισης όπως και δεδομένα για το χρήστη, μοντελοποιούμε την τιμή αγοράς σαν στοχαστική διαδικασία και προβλέπουμε τη κατανομή της. Οι βασικές δυσκολίες που αντιμετωπίζουμε είναι η πρόβλεψη κατανομής σε καμπάνιες που δεν έχουμε ξαναχρησιμοποιήσει όπως επίσης και καμπάνιες που στοχεύουν σε προώθηση διαφορετικών ειδών προϊόντων. Για παράδειγμα η κατανομή τελικής τιμής για ηλεκτρικές συσκευές είναι δραστικά διαφορετική από αυτή για οικόπεδα – σπίτια. Στη δεύτερη, οι τιμές είναι αρκετά μεγάλες αλλά και η συχνότητα διαφήμισης τους πολύ πιο μικρή από ότι στις ηλεκτρικές συσκευές.

Αυτό που πρέπει να λάβουμε σοβαρά υπόψη, είναι ότι για να λειτουργούν αποδοτικά αυτές οι κατανομές πρέπει να γίνονται με βάση συγκεκριμένα αγαθά και στόχους καμπανιών. Το ιδανικό θα ήταν για κάθε είδος αγαθού ή υπηρεσίας να δημιουργούμε μια νέα κατανομή που θα προσαρμόζεται στη διαφημιστική καμπάνια που χρησιμοποιείται και υπό τους περιορισμούς που αυτή φέρει. Ο λόγος που είναι τόσο χρήσιμη η γνώση αυτής της κατανομής είναι ότι χρησιμοποιείται μαζί με το CTR για την εύρεση της τελικής τιμής πονταρίσματος στη διαφήμιση. Αν και υπάρχουν τρόποι εύρεσης αυτής της τιμής μόνο με χρήση του CTR (όπως θα αναφέρουμε πιο κάτω), έχει αποδειχθεί εμπειρικά ([Cui et al., n.d.], [Wu & Chen, 2013]) ότι η χρήση και των δύο προσφέρει ένα πιο ευρύ φάσμα γνώσης, βελτιώνοντας την ακρίβεια στη πρόβλεψη της τιμής.

Ενδεικτικά, παρουσιάζουμε μερικά μοντέλα που έχουν χρησιμοποιηθεί επιτυχώς στο bid landscape forecasting. Στο [Cui et al., n.d.] έχουν αναπτύξει ένα μείγμα log-normal κατανομής για να φθάσουν στη παραγωγή της τελικής κατανομής ανά καμπάνια. Παρόμοια μέθοδος ακολουθήθηκε στο [Wu & Chen, 2013], όπου όμως χρησιμοποιήθηκε γκαουσιανή κατανομή.

Σε αντιδιαστολή με τους προηγούμενους δύο, οι [Wang et al., 2014] χρησιμοποίησαν τα χαρακτηριστικά της δημοπρασίας (τόσο της διαφήμισης όσο και του χρήστη) χωρίς όμως να υποθέσουν κάποια συγκεκριμένη κατανομή. Για να φτιάξουν μια απευθείας απεικόνιση με τη νικητήρια τιμή πονταρίσματος, εφάρμοσαν τη μέθοδο των δέντρων αποφάσεων. Αυτή η μέθοδος θεωρείται καλύτερη καθώς δεν παίρνει σαν δεδομένη μια συγκεκριμένη κατανομή, αλλά προσπαθεί να φτιάξει τη δική της μέσω των δεδομένων.

Ένα άλλο πρόβλημα που εμφανίζεται λόγω των διαθέσιμων συνόλων δεδομένων που υπάρχουν στη κοινότητα RTB, είναι η “προκατάληψη”. Όπως έχουμε αναφέρει, στη δημοπρασία μπορεί ο καθένας να δει μόνο τη δική του προσφορά και όχι των άλλων. Αυτό ισχύει και μετά το τέλος της δημοπρασίας, καθώς ο μόνος που μαθαίνει τη νικητήρια τιμή είναι αυτός που τοποθέτησε τη ψηλότερη προσφορά. Οι υπόλοιποι, το μόνο που γνωρίζουν είναι ότι η νικητήρια τιμή είναι ψηλότερη από τη δική τους αφού έχουν χάσει. Τα σύνολα δεδομένων που υπάρχουν στην περιοχή του RTB, αφού προέρχονται από διαφημιστικές εταιρείες (π.χ. iPinYou, Criteo κλπ.) έχουν τις τελικές τιμές του

πλειστηριασμού μόνο για τις διαφημίσεις που έχουν κερδίσει. Σε μέσο όρο το ποσοστό των δεδομένων που έχουν τη νικητήρια τιμή, είναι αρκετό μικρό π.χ. στο IPinYou 23.78%, έτσι τα δεδομένα είναι προκατειλημμένα προς τις τιμές που έχουν χάσει.

Χρησιμοποιώντας αυτά τα σύνολα δεδομένων για να εκπαιδύσουμε τα μοντέλα μας, δεν μπορούμε παρά να περιμένουμε παρόμοια αποτελέσματα, δηλαδή τιμές που δεν θα αντικατοπτρίζουν τις πραγματικές νικητήριες. Μια λύση που προτάθηκε ήταν η εκπαίδευση των μοντέλων μόνο με θετικά δεδομένα, δηλαδή δημοπρασίες που έχουν κερδηθεί από το συγκεκριμένο πάροχο των δεδομένων και άρα θα έχουν την τελική νικητήρια τιμή. Τέτοια δεδομένα όμως, αριθμητικά είναι πολύ λίγα ενώ το μοντέλο που δημιουργείται δεν είναι αξιόπιστο καθώς δεν μαθαίνει ακριβώς τη κατανομή. Οι [Wu & Chen, 2013], παίρνοντας ιδέες από Survival analysis, έφτιαξαν ένα μικτό μοντέλο παλινδρόμησης. Αυτό το μοντέλο αποτελείται από μια κατανομή μόνο από νικητήριες δημοπρασίες και μια μόνο με χαμένες. Παρόμοιες μεθόδους έχουν προταθεί και από τους [Zhang et al., 2016], [Wang et al., 2014] με καλύτερα όμως αποτελέσματα από τους προηγούμενους.

### 2.3.4 Στρατηγικές πονταρίσματος – Bidding strategies

Σύμφωνα με το [Zhang et al., n.d.], ο υπολογισμός της τιμής πονταρίσματος είναι το πιο σημαντικό πρόβλημα που αντιμετωπίζει ένα DSP. Η λύση για αυτό το πρόβλημα είναι μια στρατηγική ή συνάρτηση, πονταρίσματος. Η στρατηγική αυτή αναφέρεται στη λογική που κρύβεται πίσω από την απόφαση της τιμής πονταρίσματος. Μαζί με τη πρόβλεψη του CTR, η εύρεση μιας καλής στρατηγικής θεωρούνται τα σημαντικότερα προβλήματα σε ολόκληρο το οικοσύστημα των RTB διαφημίσεων.

Σε δημοπρασίες δεύτερης τιμής, θεωρητικά η βέλτιστη στρατηγική για τους διαφημιστές είναι να προσφέρουν όσο νομίζουν ότι είναι η πραγματική αξία / όφελος για αυτή τη διαφήμιση, να είναι δηλαδή φιλαλήθης. Η πραγματική αξία είναι βέβαια άμεσα συνυφασμένη με το CTR. Πιο αναλυτικά, αν ένας χρήστης έχει μεγάλη πιθανότητα CTR, δηλαδή προβλέπουμε ότι θα κάνει κλικ σε αυτή τη διαφήμιση με μεγάλη πιθανότητα που είναι το επιθυμητό αποτέλεσμα για το διαφημιστή, είναι λογικό να αξίζει περισσότερο για αυτόν. Για παράδειγμα μια τέτοια στρατηγική θα ήταν να ποντάραμε γραμμικά σε αναλογία με το CTR. Όπως προαναφέρθηκε, θεωρητικά αυτή είναι η βέλτιστη στρατηγική δεδομένου ότι δεν υπήρχαν περιορισμοί στη καμπάνια του διαφημιστή. Αν όμως υπάρχουν περιορισμοί όπως προϋπολογισμός και εναπομένοντας χρόνος λήξης της διαφημιστικής καμπάνιας, το πρόβλημα γίνεται αρκετά πιο σύνθετο.

Αυτοί οι παράγοντες ώθησαν τα DSP, στο να ψάξουν μαθηματικές λύσεις ώστε να βελτιστοποιήσουν τις στρατηγικές τους και να έχουν καλύτερη απόδοση σε μια καμπάνια λαμβάνοντας υπόψη κάθε είδους περιορισμούς. Περιορισμοί μπορεί να εισάγονται και από τον τελικό στόχο της κάθε καμπάνιας. Λόγω της πληθώρας τόσο των ειδών διαφήμισης αλλά και των διαφημιστικών εταιρειών, κάθε καμπάνια μπορεί να έχει διαφορετικό τελικό στόχο. Παραδείγματα τελικών στόχων είναι τα πολλά κλικ, οι πολλές αγορές αγαθών ή τα πολλά καθαρά κέρδη από πώληση αγαθών σαν τελικό αποτέλεσμα. Μετρικές σαν αυτές είναι γνωστές και σαν βασικοί δείκτες απόδοσης (KPI - Key Performance Indicator). Συνήθως κάθε καμπάνια χρησιμοποιεί ένα τέτοιο δείκτη για να κρίνει αν ήταν επιτυχημένη ή όχι. Η εισαγωγή τέτοιων περιορισμών στο μαθηματικό πρόβλημα εύρεσης βέλτιστης στρατηγικής, το μετασχηματίζει σε πρόβλημα βελτιστοποίησης κάτω υπό περιορισμούς.

Πιο κάτω παρουσιάζεται συνοπτικά ένα τέτοιο πρόβλημα για σκοπούς κατανόησης. Ως δείκτη απόδοσης χρησιμοποιείται το αν έγινε κλικ σε μια διαφήμιση ή όχι, ούτως ώστε να χρησιμοποιηθεί το CTR και για την πρόβλεψη της απόκριση του χρήστη.

Μαθηματικά η βέλτιστη συνάρτηση - στρατηγική για αυτό το πρόβλημα περιγράφεται [Zhang et al., n.d.] όπως πιο κάτω :

$$b_{RTB}() = \underset{b(\cdot)}{\operatorname{argmax}} N \int_x \theta(x) * w(b(\theta(x), x), x) * p_x(x) dx \quad (2.1)$$

$$\text{υπό τον περιορισμό} \quad N \int_x b(\theta(x), x) * w(b(\theta(x), x), x) * p_x(x) dx \leq B \quad (2.2)$$

Όπου  $b(\theta(x), x)$  είναι η συνάρτηση πονταρίσματος που θέλουμε να βρούμε, το  $x$  είναι το διάνυσμα όλων των χαρακτηριστικών,  $\theta(x)$  είναι το προβλεπόμενο CTR,  $w(b(\theta(x), x), x)$  το προβλεπόμενο ποσοστό νίκης δεδομένης μιας τιμής πονταρίσματος  $b$  και ενός διανύσματος χαρακτηριστικών  $x$ , το  $N$  ο προβλεπόμενος αριθμός αιτημάτων για πονταρίσματα για όλη τη καμπάνια μέχρι να τελειώσει ο προϋπολογισμός  $B$  και η  $p_x(x)$  συνάρτηση πυκνότητας πιθανότητας του  $x$ .

Δύο λύσεις για αυτό το πρόβλημα που έλυσε ο [Zhang et al., n.d.] και που δοκιμάστηκαν με επιτυχία σε πραγματικά δεδομένα, είναι οι εξής:

$$b_{RTB1}(\theta) = \sqrt{\frac{c}{\lambda} \theta + \theta^2} - c \quad (2.3)$$

$$b_{RTB2}(\theta) = c * \left[ \left( \frac{\theta + \sqrt{c^2 * \lambda^2 + \theta^2}}{c * \lambda} \right)^{\frac{1}{3}} - \left( \frac{c * \lambda}{\theta + \sqrt{c^2 * \lambda^2 + \theta^2}} \right)^{\frac{1}{3}} \right] \quad (2.4)$$

όπου  $\lambda$  είναι ο Λαγκρασσιανός πολλαπλασιαστής και  $c$  μια παράμετρος που προσδιορίζεται κατά τη προσομοίωση.

Για λόγους πληρότητας αναφέρουμε και τη συνάρτηση που χρησιμοποιήθηκε σαν φιλαλήθης και η οποία ήταν γραμμική ως προς το CTR.

$$b_{Lin}(\theta) = \frac{\theta}{\theta_0} * b_0 \quad (2.5)$$

Όπου  $\theta_0$  είναι ο μέσος όρος του CTR,  $b_0$  η βασική τιμή πονταρίσματος (αριθμοί που προκύπτουν από τα δεδομένα) και  $\theta$  είναι το προβλεπόμενο CTR.

Όπως δείχνει στο [Zhang et al., n.d.], η χρήση των συναρτήσεων (2.3) και (2.4) που προέκυψαν από τη λύση του προβλήματος υπό περιορισμούς έφεραν βελτίωση στα αποτελέσματα συγκριτικά με την απλή γραμμική συνάρτηση ως προς το CTR, όπως αναμενόταν. Το ίδιο πρόβλημα επιλύθηκε και με διαφορετικό KPI (αριθμός κλικ σε διαφημίσεις + αριθμός αγορών αγαθών από τις διαφημίσεις αυτές), με παρόμοια αποτελέσματα. Περαιτέρω ανάλυση παρέχεται στο [Zhang & Wang, n.d.], όπου γίνεται βελτιστοποίηση ως προς το συνολικό καθαρό κέρδος (δείκτης απόδοσης), με 32% βελτίωση συγκριτικά με τη βασική συνάρτηση σύγκρισης.

Καταλήγοντας το πρόβλημα εύρεσης μιας καλής στρατηγικής πονταρίσματος, εξαρτάται τόσο από τους περιορισμούς που επιβάλλει η καμπάνια αλλά και από την επιλογή του KPI της. Δεν υπάρχει μια βέλτιστη στρατηγική για όλες τις περιπτώσεις, αντίθετα κάθε φορά πρέπει να λύνουμε το πρόβλημα βελτιστοποίησης για να έχουμε τα καλύτερα δυνατά αποτελέσματα.

Αν συνδυάσουμε όμως την προαναφερθείσα μαθηματική μέθοδο με σύγχρονες μεθόδους μηχανικής μάθησης μπορούμε να φτιάξουμε ακόμη καλύτερα συστήματα, με μεγαλύτερη ευκολία διαχείρισης τους αλλά και όποιους περιορισμούς επιθυμούμε. Ο λόγος για τη ενισχυτική μάθηση(Reinforcement learning – RL), την οποία θα δούμε στη συνέχεια στο πρόβλημα του ελέγχου κατανάλωσης του προϋπολογισμού μιας καμπάνιας.

### **2.3.5 Προσαρμοστικός έλεγχος κατανάλωσης προϋπολογισμού – Budget pacing**

Προτού μιλήσουμε για το θέμα ελέγχου του προϋπολογισμού ας εξετάσουμε τι ακριβώς είναι μια καμπάνια και πως τα δύο αυτά συνδέονται. Μια καμπάνια είναι ένα σύνολο από διαφημίσεις όλων των ειδών που στήνει ένας διαφημιστής, η οποία έχει συγκεκριμένα χαρακτηριστικά. Αυτά τα χαρακτηριστικά είναι τέτοια με στόχο να προωθήσουν αγαθά ή υπηρεσίες και να προσελκύσουν συγκεκριμένο κοινό. Συνήθως περιέχει κατάλληλο κείμενο και εικόνα - animation για να τραβήξει άτομα που ενδιαφέρονται για το προϊόν αυτό. Μερικά από τα χαρακτηριστικά που μπορούμε να ρυθμίσουμε είναι ο προϋπολογισμός, η γλώσσα, η τοποθεσία κ.α. Εδώ είναι που βρίσκεται η σύνδεση μεταξύ προϋπολογισμού και καμπάνιας. Κατά τη διάρκεια μιας καμπάνιας, για τις διαφημίσεις που αγοράζουμε ξοδεύουμε χρήματα, τα οποία αφαιρούνται από ένα συνολικό ποσό που διατίθεται προς χρήση, το οποίο λέγεται προϋπολογισμός. Εν ολίγοις ο προϋπολογισμός είναι τα χρήματα που είναι διατεθειμένοι να ξοδέψουν για τη προώθηση των αγαθών – υπηρεσιών, οι διαφημιστές.

Σύμφωνα με όσα είπαμε πριν, κάθε καμπάνια έχει ένα ειδικό δείκτη απόδοσης, ο οποίος θέλουμε να μεγιστοποιείται. Αυτός όμως είναι άμεσα εξαρτώμενος από το προϋπολογισμό της κάθε καμπάνιας και πως αυτός θα ξοδευτεί. Αν απλά αγοράζαμε τη μια διαφήμιση μετά την άλλη χωρίς να λαμβάνουμε υπόψη τα εναπομείναντα χρήματα, πιθανό να χάναμε κάποιες μελλοντικές καλές διαφημίσεις που δεν θα μπορούμε να αγοράσουμε οι οποίες θα ήταν πολύ πιο προσοδοφόρες. Άλλο ζήτημα που θα αντιμετωπίζαμε είναι η περίπτωση της κατανάλωσης του προϋπολογισμού πολύ νωρίς σε δαπανηρές διαφημίσεις που όμως δεν προσφέρουν το ανάλογο κέρδος. Πέρα από αυτά έχει βρεθεί

([\[Lee, Jalali, & Dasdan, 2013\]](#)) ότι η κατανάλωση των χρημάτων καθόλη τη διάρκεια της ημέρας παρά σε ένα συγκεκριμένο χρονικό περιθώριο, προωθεί το προϊόν σε πιο ευρύ κοινό, έχοντας έτσι μεγαλύτερη απήχηση. Στο [\[Zhang et al., n.d.\]](#) έχουν βρει ότι μια βέλτιστη στρατηγική πονταρίσματος θα πρέπει να ποντάρει σε περισσότερες διαφημίσεις παρά να συγκεντρώνεται σε ένα μικρό σύνολο ακριβών, καθώς στη τρέχουσα αγορά, οι πιο φθηνές διαφημίσεις είναι πιο κερδοφόρες και εκτός αυτού, έχουμε πιο μεγάλες πιθανότητες να τις πάρουμε. Πρέπει να έχει γίνει ξεκάθαρο ότι ο έλεγχος κατανάλωσης του προϋπολογισμού είναι άμεσα συνυφασμένος με την εύρεση κατάλληλης συνάρτησης και τιμής πονταρίσματος. Το ερώτημα λοιπόν που καλούμαστε να απαντήσουμε πρακτικά, είναι αν υπάρχει ένας έξυπνος τρόπος να βρούμε ποιες διαφημίσεις αξίζει να ξοδεύουμε τα χρήματά μας, δεδομένων των στόχων μιας διαφημιστικής καμπάνιας.

Έχουν προταθεί διάφοροι τρόποι για ρύθμιση της κατανάλωσης του προϋπολογισμού. Οι δύο κύριες μέθοδοι [\[Xu, Lee, Li, Qi, & Lu, 2015\]](#) είναι είτε κρατώντας ένα σταθερό ρυθμό κατανάλωσης ανά χρονική περίοδο (Probabilistic throttling) είτε τροποποιώντας τη τιμή πονταρίσματος ανάλογα με το υπόλοιπο χρημάτων του προϋπολογισμού (Bid modification). Στο [σχήμα 2.4](#) φαίνονται ξεκάθαρα οι αλληλεπιδράσεις που γίνονται σε κάθε δημοπρασία για κάθε μέθοδο. Οι συναρτήσεις πονταρίσματος που παρουσιάσαμε πριν, φέρουν στοιχεία από Bid modification καθώς εισάγοντας το σχετικό περιορισμό για το προϋπολογισμό, λαμβάνεται απευθείας υπόψη στη εύρεση της τιμής πονταρίσματος.


Μια πιο σύγχρονη τεχνική που έχει γίνει de facto σύστημα για χρήση σε έλεγχο προϋπολογισμού, είναι η ενισχυτική μάθηση. Εν ολίγοις το σύστημα μάθησης προσπαθεί να μάθει μέσα από την αλληλεπίδραση με το περιβάλλον του, να διαλέγει τις καλές – αποδοτικές διαφημίσεις και να ξοδεύει το προϋπολογισμό σε βάθος χρόνου για να επιτελεί τους στόχους της καμπάνιας. Μοιάζει με ένα βρόγχο ανάδρασης όπου παίρνοντας τα κατάλληλα σήματα και ερεθίσματα, μαθαίνει μόνο του τι επιλογές να κάνει για να βελτιστοποιήσει το KPI κάθε καμπάνιας. Για να είμαστε πιο ακριβείς, κάθε τέτοιο πρόβλημα έχει μια κατάσταση όπου είναι η αναπαράσταση του τωρινού περιβάλλοντος, μια ενέργεια όπου είναι η δράση που κάνει το σύστημα δεδομένου του περιβάλλοντος – κατάστασης και μια ανταμοιβή όπου το σύστημα λαμβάνει σαν αποτέλεσμα της ενέργειας του.

Στο [\[Du et al. 2017\]](#) και στο [\[Cai et al. n.d.\]](#), μοντελοποιούν τη διαδικασία πονταρίσματος σαν μια Μαρκοβιανή διαδικασία αποφάσεων με περιορισμούς (Constrained Markov Decision Process ) που βασίζεται στη ενισχυτική μάθηση. Το μοντέλο χρησιμοποιεί το προβλεπόμενο CTR σαν κατάσταση, τη τιμή πονταρίσματος σαν τη δράση και σαν επιβράβευση τα κλικ στις διαφημίσεις. Στο [σχήμα 2.3](#) γίνεται πιο κατανοητή η αλληλουχία των ενεργειών που γίνονται κατά τη διάρκεια μιας δημοπρασίας χρησιμοποιώντας ενισχυτική μάθηση. Οι [\[Zhang, Rong, Wang, Zhu, & Wang, 2016\]](#), χρησιμοποίησαν ένα μοντέλο ελέγχου με ανάδραση, όπου έχει σαν κύριο στόχο τον έλεγχο και βελτιστοποίηση του KPI κάθε καμπάνιας. Σαν λογική μοιάζει πολύ με την ενισχυτική μάθηση που μόλις περιγράψαμε. Έχοντας κατά νου ότι μια διαφημιστική εταιρεία μπορεί να έχει πολλούς διαφημιστές και αυτοί πολλές διαφορετικές ή και ίδιες καμπάνιες μεταξύ τους, οι [\[Jin et al. 2018\]](#) πήραν το πρόβλημα ένα βήμα παραπέρα. Προσπάθησαν πάλι με ενισχυτική μάθηση να φτιάξουν ένα πολυεπίπεδο σύστημα ενισχυτικής μάθησης για να εξυπηρετούν πλήθος από διαφημιστές.

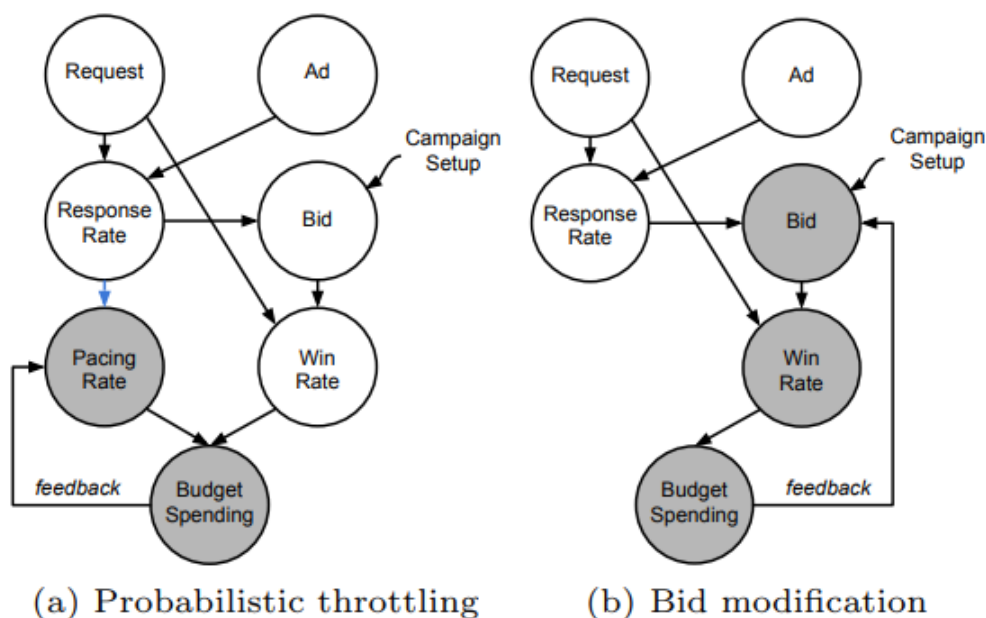
Κλείνοντας θέλω να καταλήξω, ότι η σύγχρονη λύση τόσο για τον έλεγχο του προϋπολογισμού όσο και για την εύρεση της κατάλληλης τιμής πονταρίσματος είναι τα συστήματα ενισχυτικής μάθησης. Πλέον χρησιμοποιείται σχεδόν επι το πλείστο σε τέτοιου είδους προβλήματα, ιδιαίτερα καθώς πολλοί

θεωρούν αυτά τα δύο σαν ένα μεγαλύτερο πρόβλημα πονταρίσματος. Τα αποτελέσματα που έχουμε σήμερα είναι αρκετά καλά και χάρη της υπολογιστικής δύναμης που έχουμε στο κόσμο τώρα αλλά και στη πληθώρα δεδομένων, θεωρούμε ότι μπορούν μόνο να βελτιώνονται.

Σχήμα 2.3 : Διάγραμμα της αλληλουχίας ενεργειών που χρησιμοποιεί το σύστημα ενισχυτικής μάθησης τόσο για εύρεσης τιμής πονταρίσματος αλλά και για έλεγχο κατανάλωσης των χρημάτων.<sup>2</sup>



Σχήμα 2.4 : Αλληλεπιδράσεις που γίνονται στους μηχανισμούς μιας δημοπρασίας στις δύο μεθόδους ελέγχου του προϋπολογισμού.<sup>3</sup>



2 Πηγή: [Cai et al. n.d.].

3 Πηγή: [Xu, Lee, Li, Qi, & Lu, 2015].



## 2.3.6 Δεδομένα για το χρήστη και τη συμπεριφορά του

Με την ύπαρξη αυτού του καινούργιου τρόπου διαφήμισης - RTB (όπου πρώτα η ιστοσελίδα/εφαρμογή που επισκέπτεται ο χρήστης στέλνει αίτημα για να δείξει μια διαφήμιση) οι διαφημιστές μπορούν χρησιμοποιώντας παλαιότερα δεδομένα των χρηστών να κάνουν καλύτερες προωθήσεις προϊόντων και πιο σχετικές με το κάθε χρήστη. Αυτό είναι εφικτό καθώς με τις πληροφορίες που έχουν οι εταιρείες για κάθε χρήστη, μπορούν να σκιαγραφήσουν ένα προσωπίο για αυτόν. Μπορούν είτε μελετώντας παλαιότερη συμπεριφορά είτε συνδέοντας τα διαδικτυακά του ίχνη να καταλάβουν τι πράγματα του αρέσουν, τι άνθρωπος είναι, αν αγοράζει συχνά αντικείμενα ή όχι και έτσι να του προτείνουν αγαθά ή υπηρεσίες που ούτε ο ίδιος ήξερε ότι ήθελε.

Το κύριο ελάττωμα είναι ότι αυτά τα δεδομένα δεν αποκτώνται εύκολα. Ένας τρόπος για να τα αποκτήσεις είναι προσφέροντας στο χρήστη υπηρεσίες όπου μέσω τους σου δίνει χωρίς να το καταλαβαίνει κύριες πληροφορίες για εκείνον. Ένα παράδειγμα είναι το λεγόμενο ηλεκτρονικό καρότσι, όπου θεωρείται άμεσος τρόπος για να πάρεις δεδομένα. Σε αυτό το καρότσι ο χρήστης μπορεί να φυλάξει διάφορα προϊόντα που τον ενδιαφέρουν για να τα αγοράσει. Σε περίπτωση που ο χρήστης δεν τα αγοράσει, οι εταιρείες παίρνουν εκείνα τα προϊόντα και τον βομβαρδίζουν με διαφημίσεις για αυτά ή παρόμοια. Το πιο τρανταχτό παράδειγμα όμως είναι γενικότερα το browsing σε ιστοσελίδες, όπου και καταγράφεται η κάθε κίνηση που κάνεις, τα κλικ και ακόμη οι λέξεις που ψάχνεις. Βέβαια για να μπορείς να κάνεις κάτι τέτοιο πρέπει να υπάρχει ένας τρόπος να αναγνωρίζεις το κάθε χρήστη μοναδικά. Κάτι τέτοιο μπορεί να θεωρηθεί η διεύθυνση IP ή ακόμη καλύτερα κάποιο αναγνωριστικό τύπου cookie ID. Με αυτό το αναγνωριστικό συλλέγουν δεδομένα για το χρήστη, τα οποία αργότερα δέχονται στατιστική επεξεργασία για να προκύψει ένα profile για τις ανάγκες, τις προτιμήσεις του κτλ. Μια μόδα-τάση που έκανε τελευταία την εμφάνιση της είναι η αγορά “έτοιμων” δεδομένων από εταιρείες όπου σαρώνουν το διαδίκτυο για να τα αποκτήσουν.

Παρόλα αυτά με όποιο τρόπο και αν αποκτούνται αυτά τα δεδομένα η ύπαρξη τους έδωσε μεγάλη ώθηση στις διαφημιστικές εταιρείες αλλά και στην ανάπτυξη του τρόπου διαφήμισης. Πλέον μπορούμε να κάνουμε ατομική διαφήμιση, αυτοματοποιημένα στο κάθε χρήστη ανάλογα με τα δικά του ενδιαφέροντα. Έτσι οι διαφημιστές κάνουν πιο στοχευμένες προωθήσεις προϊόντων αλλά και οι καταναλωτές δέχονται διαφημίσεις που όντως τους ενδιαφέρουν χωρίς να καταντά κουραστικό.

# Κεφάλαιο 3

## Συγγενικά ερευνητικά θέματα

### 3.1 Εισαγωγικά

Η περιοχή των RTB διαφημίσεων εκτός ότι η ίδια είναι ήδη πολύ μεγάλη, υπάγεται σε μια ακόμη μεγαλύτερη ερευνητική περιοχή. Αυτή η περιοχή νοείται σαν πρόβλεψη γενικότερα, αλλά και πιο συγκεκριμένα πρόβλεψη τιμών, για κάθε είδους αγαθού και υπηρεσίας. Από την αρχή αυτού του αιώνα είχαμε μια ραγδαία εξέλιξη της τεχνολογίας, που έφερε αυτοματισμούς σε πολλά πράγματα αλλά συνάμα και πολυπλοκότητα, καθώς οι άνθρωποι ζητούσαν ολοένα και καλύτερα, γρηγορότερα και πιο αξιόπιστα συστήματα. Αυτός ο αυτοματισμός μπήκε και στις αγοραπωλησίες προϊόντων, τόσο στο καθορισμό των τιμών τους, στην αγορά και πώληση αλλά και στη δημιουργία μαθηματικών μοντέλων για πόσο εμπόρευμα πρέπει να έχουν ανά ημέρα του χρόνου, πότε πρέπει να βγάλουν κάποια προϊόντα σε εκπτώσεις κτλ. Αναφέρουμε ενδεικτικά μερικά από αυτά τα θέματα που θα μπορούσαν να εφαρμοστούν άμεσα αρκετές λύσεις που προτάθηκαν για τα προβλήματα της RTB κοινότητας και αποτελούν παραπλήσιο ερευνητικό ενδιαφέρον.

### 3.2 Πρόβλεψη τιμής αεροπορικού εισιτηρίου

Αρχίζουμε με αυτό καθώς κατά τη γνώμη μου είναι το πιο ενδιαφέρον, αφού είναι ένα θέμα που παιδεύει όλο το κόσμο. Όλοι μας κάποια στιγμή, αναρωτηθήκαμε πως ακριβώς αποφασίζονται οι τιμές των αεροπορικών εισιτηρίων και πότε είναι η καταλληλότερη περίοδος να τα κλείσουμε. Αν κάποιος παρατηρήσει τις τιμές για μεγάλο χρονικό διάστημα, θα καταλήξει ότι είναι πολύ δύσκολο να προβλέψει τη σωστή περίοδο για να αγοράσει το φθηνότερο εισιτήριο. Αυτό γιατί, ένα τέτοιο πρόβλημα είναι πολύ πιο πολύπλοκο από όσο νομίζουμε. Οικονομικοί, εμπορικοί αλλά και κοινωνικοί παράγοντες λαμβάνονται όλοι μαζί υπόψη για να δημιουργήσουν την τελική τιμή του εισιτηρίου. Διαθεσιμότητα θέσεων, ανταγωνισμός στην αγορά, εποχή ή γιορτές (Χριστούγεννα) [\[Vu et al., 2018\]](#),



είναι μόνο μερικά από τα χαρακτηριστικά που επιδρούν στην αλλαγή της τιμής. Επιπλέον οι αεροπορικές εταιρείες χρησιμοποιούν περίπλοκες στρατηγικές και μεθόδους για να υπολογίσουν τις τιμές των εισιτηρίων τους με δυναμικό τρόπο [Tziridis et al., 2017]. Πιο συγκεκριμένα το yield management [Vu et al., 2018], είναι η πιο γνωστή στρατηγική που χρησιμοποιείται από τις εταιρείες που σαν βασικό στόχο έχει τη μεγιστοποίηση του κέρδους.

Πολλές μέθοδοι έχουν δοκιμαστεί, ταυτόχρονα με βοήθεια στατιστικής ανάλυσης και η κάθε μια προσφέρει όλο και περισσότερη γνώση και φως σε αυτό το θέμα. Μερικά μοντέλα μηχανικής μάθησης που έχουν δείξει αξιολογικά αποτελέσματα είναι η παλινδρόμηση (regression) [Chawla & Kaur, 2017], [Tziridis et al., 2017], η ομαδοποίηση [Chawla & Kaur, 2017], [Wohlfarth et al., 2011], τα νευρωνικά δίκτυα [Vu et al., 2018], [Tziridis et al., 2017], η ενισχυτική μάθηση [Etzioni et al. 2003], SVM [Vu et al., 2018], [Tziridis et al., 2017] κ.α.

Μερικές σημαντικές παρατηρήσεις έχουν γίνει αναφορικά με τα δεδομένα που ανακτήθηκαν. Σύμφωνα με το [Wohlfarth et al., 2011] και το [Etzioni et al. 2003], ο διαθέσιμος αριθμός θέσεων σε μια πτήση είναι το κλειδί για να βρεις ποια είναι η καλύτερη τιμή εισιτηρίου. Αντίστοιχα στο [Vu et al., 2018], πιστεύουν ότι η περίοδος από τη μέρα αναχώρησης μέχρι τη μέρα αγοράς έχει τη μεγαλύτερη επίδραση στην αλλαγή της τιμής. Επιβεβαιώνοντας αυτό που όλοι γνωρίζαμε, οι [Tziridis et al., 2017], έδειξαν ότι η ώρα αναχώρησης και άφιξης επηρεάζουν σημαντικά την τιμή του εισιτηρίου. Παρατηρούμε γενικότερα ότι αυτές οι παρατηρήσεις επαληθεύουν τα χαρακτηριστικά που και εμείς οι ίδιοι κοιτάμε συνήθως για να κλείσουμε κάποιο εισιτήριο.

Παρόλο που έχουμε καλά αποτελέσματα με χρήση συγκεκριμένων μοντέλων και δεδομένων, δεν μπορούμε να πούμε κάτι απόλυτο, καθώς στη διεθνή κοινότητα δεν υπάρχει σημείο αναφοράς (benchmark) για να μπορούμε να συγκρίνουμε τις μεθόδους. Σχεδόν όλοι οι ερευνητές ([Tziridis et al., 2017], [Vu et al., 2018], [Chawla & Kaur, 2017], [Wohlfarth et al., 2011] και [Etzioni et al. 2003]) αναγκάζονται να φτιάξουν λογισμικό για να μαζέψουν αυτόματα δεδομένα από ιστοσελίδες αεροπορικών εταιρειών λόγω της έλλειψης δημόσιων συνόλων δεδομένων (datasets). Αυτό κάνει τη δουλειά δυσκολότερη και έτσι πολλοί αποφεύγουν την έρευνα σε αυτό το τομέα με μικρή έτσι πρόοδο. Περαιτέρω υπάρχουν χαρακτηριστικά των πτήσεων όπως ο διαθέσιμος αριθμός θέσεων ή το μοντέλο του αεροπλάνου [Etzioni et al. 2003], που ενώ είναι πολύ σημαντικές πληροφορίες είναι αδύνατο να βρεθούν μέσω των ιστοσελίδων.

Κλείνοντας να πούμε ότι ακριβώς η ίδια λογική τόσο προβλήματος όσο και λύσεων, παρουσιάζεται σχεδόν αυτούσια στις αγορές δωματίων ξενοδοχείων, ενοικιάσεις αυτοκινήτων κτλ. όπως αναφέρει ο [Etzioni et al. 2003], που είναι πολύ ενδιαφέρον καθώς αποτελούν και αυτά συχνά προβλήματα της σημερινής κοινωνίας.

### 3.3 Διαχείριση εφοδιαστικής αλυσίδας

Η διαχείριση εφοδιαστικής αλυσίδας αναφέρεται στο σχεδιασμό, την εκτέλεση, τον έλεγχο και παρακολούθηση των δραστηριοτήτων εφοδιαστικής αλυσίδας με απώτερο στόχο τη δημιουργία

καθαρού κέρδους. Μέσα σε όλα αυτά συμπεριλαμβάνεται ο συγχρονισμός της παροχής με τη ζήτηση αγαθών ή υπηρεσιών και είναι το κομμάτι που μας ενδιαφέρει ιδιαίτερω. Τυπικά αυτό που προσπαθεί να κάνει είναι να ελέγξει κεντρικά τη παραγωγή, αποστολή και κατανάλωση των αγαθών για να παράξει κέρδος.

Με τη χρήση των υπολογιστικών και μαθηματικών μεθόδων που συζητήσαμε υπάρχει μεγάλο περιθώριο για βελτίωση της κερδοφορίας ενός οργανισμού. Το κόστος παραγωγής μπορεί να μειωθεί, οι αγορές – πωλήσεις μπορούν να προβλέπονται με μεγαλύτερη ακρίβεια, μειώνοντας έτσι το κόστος δημιουργίας ή απόκτησης αγαθών που δεν θα πωληθούν. Η χρήση αλγόριθμων μηχανικής μάθησης μπορεί να βελτιώσει τη παραγωγικότητα του οργανισμού και να βοηθήσει σε λήψεις αποφάσεων [Bousqaoui et al., 2018], βρίσκοντας μοτίβα που διαφορετικά θα παρέμεναν κρυμμένα.

Για να δείξουμε πόσο χρήσιμα είναι αυτά τα μοντέλα θα αναφέρουμε μερικά προβλήματα που αντιμετωπίζονται στη εφοδιαστική αλυσίδα. Τα πιο γνωστά ([Carbonneau et al., 2008]), είναι η πρόβλεψη της προσφοράς και της ζήτησης αγαθών όπως αναφέραμε και πριν. Χρησιμοποιώντας νευρωνικά δίκτυα, SVM και RBF καταλήγουν στα πιο καλά αποτελέσματα αν και υπάρχουν πολλές εξίσου καλές μέθοδοι. Η επιλογή και αποτίμηση ενός προμηθευτή ([Bousqaoui et al., 2018]), εάν δηλαδή είναι καλός, εάν τα προϊόντα του είναι φθηνά και αξιόπιστα αποτελεί άλλο ένα θέμα. Μπορεί να γίνει πλέον εύκολα και γρήγορα, κάνοντας χρήση κυρίως νευρωνικών δικτύων με ασαφής λογικές. Περαιτέρω, για να αποφεύγονται τυχών καθυστερήσεις παράδοσης αγαθών σε πελάτες, ο χρόνος παραγωγής τους μπορεί να προβλεφθεί. Τα SVM, νευρωνικά δίκτυα και μοντέλα παλινδρόμησης είναι οι συχνότερες επιλογές για τη λύση τέτοιων προβλημάτων.

Ειδικότερα στη σημερινή εποχή, όπου μπορούμε με μικρούς μηχανισμούς – αισθητήρες να παρακολουθούμε τις κινήσεις των πελατών και ποια προϊόντα τους ενδιαφέρουν περισσότερο, οι προβλέψεις μας μπορούν να αποκτήσουν μεγαλύτερη ακρίβεια. Στην [εικόνα 3.1](#), βλέπουμε ένα κομμάτι της εφοδιαστικής αλυσίδας και πως με διάφορους αισθητήρες αλλά και συστήματα – αλγόριθμους μηχανικής μάθησης, όλα τα προβλήματα που ενυπάρχουν μπορούν να λυθούν. Για παράδειγμα, μια κάμερα, ελέγχει με χρήση τεχνητής νοημοσύνης και όρασης υπολογιστών, τη ποιότητα των αγαθών που παράγει το εργοστάσιο και τη ταξινόμηση τους, ανάλογα με το είδος τους. Επιπλέον, η καταγραφή των αποθεμάτων και η διαχείριση τους, γίνεται με παρόμοιο τρόπο, με χρήση δηλαδή συστήματος όρασης υπολογιστών. Έτσι, εκτός ότι κάνει όλα τη διαδικασία καταγραφής αυτόματα, άμεσα και φθηνά, αντικαθιστά πλήρως το άτομο που κανονικά έλεγε το αποθεματικό κάνοντας τη φυσική του παρουσία μη απαραίτητη. Μια τέτοια δουλειά πλέον ανάγεται στη εργασία της επίβλεψης του συστήματος και των αποτελεσμάτων που αυτό φέρνει.

Στην [εικόνα 3.1](#), μπορεί να δείτε ακόμη περισσότερα παραδείγματα χρήσης αυτοματοποιημένων μεθόδων σε συνεργασία με αλγόριθμους μηχανικής μάθησης και υπολογιστικής νοημοσύνης για το πλήρη έλεγχο και λειτουργία της εφοδιαστικής αλυσίδας. Όπως καταλαβαίνει κανείς οι προοπτικές είναι ατελειώτες, με τελικό στόχο τη πλήρη αυτοματοποίηση όλων των λειτουργιών. Αβίαστα, λοιπόν, συνάγεται το συμπέρασμα ότι η χρήση μεθόδων μηχανικής μάθησης κρίνεται σχεδόν επιτακτική στη περιοχή της διαχείρισης της εφοδιαστικής αλυσίδας.

Σχήμα 3.1 : Παρουσιάζεται ένα ενοποιημένο και αυτοποιημένο σύστημα ελέγχου της εφοδιαστικής αλυσίδας με χρήση υπολογιστής νοημοσύνης και αλγορίθμων μηχανικής μάθησης.<sup>4</sup>

#### SEEING, SPEAKING & THINKING LOGISTICS OPERATIONS



### 3.4 Συστήματα συστάσεων

Τα συστήματα συστάσεων θεωρούνται από τις πιο σημαντικές αλλά και ευρέως χρησιμοποιημένες, εφαρμογές των αλγορίθμων μηχανικής μάθησης. Αυτός είναι ο κύριος λόγος που το παρουσιάζουμε εδώ αν και δεν εμπίπτει ακριβώς στα προβλήματα πρόβλεψης τιμών αλλά στα προβλήματα πρόβλεψης γενικότερα. Τα συστήματα συστάσεων είναι ένα εργαλείο όπου φιλτράρει πληροφορίες με στόχο να προβλέψει την αξιολόγηση ή προτίμηση του χρήστη σε κάποιο προϊόν ή υπηρεσία όπως αναφέρουν και οι [Stalidis & Kardaras, 2015]. Αυτό το πρόβλημα έγινε ιδιαίτερο εμφανές, στις αρχές αυτού του αιώνα με τη μεγάλη εξάπλωση του διαδικτύου και τη μεγάλη παραγωγή δεδομένων, τόσο από μεριάς επιχειρήσεων αλλά και από πελατών – χρηστών. Τόσο οι πελάτες θέλουν να βρουν τα

4 Πηγή: <https://blogs-images.forbes.com/louiscolombus/files/2018/06/contextual-intelligence.jpg>

καταλληλότερα αγαθά για τους ίδιους, αλλά και οι επιχειρήσεις θέλουν να τους προσφέρουν – προωθούν αυτά που είναι κοντά στις αρεσκείες τους, με τελικό στόχο να τα αγοράσουν.

Εδώ είναι όπου η μηχανική μάθηση κρίνεται απαραίτητη. Οι αλγόριθμοι αυτοί είναι οι καταλληλότεροι για να αναλύσουν τα χαρακτηριστικά των χρηστών και των προϊόντων μαζί με άλλες πληροφορίες και έτσι να εξάγουν μοτίβα που υπάρχουν κρυμένα στα δεδομένα αυτά. Εν τέλη αυτό που προσπαθεί να κάνει το σύστημα συστάσεων είναι να προβλέψει με μεγάλη ακρίβεια τις ανάγκες και επιθυμίες του χρήστη και να προτείνει το καταλληλότερο αγαθό για αυτόν. Πολλές τεχνικές έχουν αναπτυχθεί που δεν απαιτούν τη χρήση αλγόριθμων μηχανικής μάθησης με πολύ καλά αποτελέσματα. Δύο από αυτές είναι το Collaborative-Filtering και το Content-based Filtering. Η πρώτη προσπαθεί να βρει κοινές προτιμήσεις μεταξύ χρηστών και να προτείνει προϊόντα που έχει ο ένας και ο άλλος όχι, δεδομένου ότι έχουν κοινές προτιμήσεις. Η δεύτερη τεχνική προσπαθεί να βρει ομοιότητες και κοινά χαρακτηριστικά μεταξύ των διάφορων αντικειμένων και με βάση το προφίλ αλλά και προηγούμενες αγορές του χρήστη, να του κάνει την καλύτερη πρόταση.

Η χρήση αλγορίθμων μηχανικής μάθησης, προσφέρει μεγαλύτερο φάσμα γνώσης αλλά και τη δυνατότητα να εξάγει τόσο πληροφορίες αλλά και μοτίβα που με τις τωρινές μεθόδους δεν ήταν δυνατό να βρεθούν. Η διαφορά έγκειται στο ότι αυτές οι μέθοδοι, μπορούν να εξάγουν καινούργια χαρακτηριστικά από δεδομένα που οι άλλες δύο μέθοδοι βρίσκουν αχρείαστα. Επιπλέον, λόγω των υψηλών τάξης αλληλεπιδράσεων που μπορούν να δημιουργήσουν, μπορούν να αναπτυχθούν πιο πολύπλοκες και κρίσιμες πληροφορίες. Ένα άλλο πρόβλημα που λύνεται σε κάποιο βαθμό, είναι το πρόβλημα της ψυχρής εκκίνησης (cold start). Το πρόβλημα αυτό οφείλεται στο γεγονός ότι εάν έρθει ένας νέος χρήστης, δεν έχουμε ιδιαίτερα πολλά δεδομένα για αυτόν και έτσι καμία από τις δύο μεθόδους δεν μπορεί να βγάλει ασφαλή συμπεράσματα και προβλέψεις.

Κλείνοντας να αναφέρουμε ότι οι μηχανές παραγοντοποίησης που παρουσιάζουμε και χρησιμοποιούμε πιο κάτω, θεωρούνται σαν ένα από τα τελευταία τεχνολογικά συστήματα μηχανικής μάθησης που βρίσκουν εφαρμογή στα συστήματα συστάσεων. Μάλιστα, έχουν σημειώσει ιδιαίτερη επιτυχία, καθώς μπορούν τόσο να επεξεργαστούν μεγάλα σε διάσταση και αραία δεδομένα εύκολα αλλά και να εξάγουν αλληλεπιδράσεις υψηλών τάξεων. Καταλήγουμε ότι ειδικά σε προβλήματα όπου υπάρχουν πολλά και πολύπλοκα δεδομένα, οι αλγόριθμοι μηχανικής μάθησης κρίνονται επιτακτικοί, προσφέροντας μάλιστα πολύ καλά αποτελέσματα.



# Κεφάλαιο 4

## Συναφείς μελέτες για το CTR

### 4.1 Εισαγωγή

Σε αυτό το κεφάλαιο θα επεκτείνουμε τους συλλογισμούς μας, γύρω από το πρόβλημα της πρόβλεψης του CTR διαφημίσεων. Είναι χρήσιμο να τονιστεί ότι δεν έχουμε αναφέρει λύσεις σε αυτό το πρόβλημα όπως στα υπόλοιπα του οικοσυστήματος RTB, καθώς είναι το κύριο πρόβλημα που ασχολείται η διπλωματική και θα παρουσιαστούν εδώ πιο αναλυτικά. Υπενθυμίζουμε, ότι το CTR είναι η πιθανότητα ο χρήστης να αλληλεπιδράσει με κάτι στην ιστοσελίδα/εφαρμογή όπως τονίζεται στο [\[Wang, Zhang, & Yuan, 2016\]](#). Για παράδειγμα κάνοντας κλικ σε διαφήμιση, διαβάζοντας ή βλέποντας ένα βίντεο ή ακόμη και αγοράζοντας ένα προϊόν.

### 4.2 Μοντέλα παλινδρόμησης – Regression models

Τα πρώτα μοντέλα που χρησιμοποιήθηκαν για αυτό το πρόβλημα είναι τα μοντέλα παλινδρόμησης. Θεωρητικά είναι τα πιο ταιριαστά για τη λύση ενός τέτοιου προβλήματος καθώς έχουν την επιλογή - ιδιότητα να προβλέπουν τιμές ανάμεσα στο 0 και στο 1 ακριβώς σαν πιθανότητες σύμφωνα με τους [\[Richardson et al., 2007\]](#). Επιπλέον είναι γνωστό ότι είναι πολύ γρήγορα μοντέλα και ότι δεν χρειάζεται ιδιαίτερη προεπεξεργασία των δεδομένων για να εκπαιδευτούν.

Ενδεικτικά μερικά μοντέλα παλινδρόμησης που χρησιμοποιούνται είναι η λογιστική (Logistic Regression - LR), τα μοντέλα δέντρων κ.α. Η λογιστική παλινδρόμηση θεωρείται γραμμικό μοντέλο [\[Zhang et al., 2014\]](#) και είναι το πιο δημοφιλές λόγω της απλότητας και μικρού χρόνου εκπαίδευσης που χρειάζεται. Λόγω αυτής όμως της απλότητας δεν μπορεί να “καταλάβει” αλληλεπιδράσεις μεταξύ χαρακτηριστικών ανώτερης τάξης. Το Gradient Boosting Regression Tree (GBRT) είναι ένα μη γραμμικό μοντέλο παλινδρόμησης. Συγκριτικά με το LR, έχει το πλεονέκτημα να μαθαίνει μη γραμμικά χαρακτηριστικά όπως αναφέρει το [\[Zhang et al., 2014\]](#).

Στο σημείο αυτό είναι απαραίτητο να πούμε ότι η συνάρτηση σφάλματος που θέλουμε να ελαχιστοποιήσουμε είναι η διασταυρούμενη εντροπία (cross-entropy), μεταξύ της πρόβλεψης του CTR

και του πραγματικού αποτελέσματος ([Zhang et al., 2014],[Szwabe et al., 2017]). Επιπρόσθετα, προστέθηκε και L2 κανονικοποίηση σε προσπάθεια να αποφευχθεί το overfitting των δεδομένων στο μοντέλο [Szwabe et al., 2017]. Το μοντέλο εκπαιδεύεται χρησιμοποιώντας τη μέθοδο στοχαστικής καθόδου κλίσης (stochastic gradient descent - SGD).

Σαν αποτέλεσμα της πρόβλεψης του CTR, χρησιμοποιώντας αυτό το μοντέλο παίρνουμε :

$$\hat{y} = P(y=1|x) = \sigma(w^T x) = \frac{1}{1 + e^{-w^T x}} \quad (4.1)$$

Όπου σαν  $x$  συμβολίζεται το διάνυσμα χαρακτηριστικών μετά την προεπεξεργασία που έχει δεχτεί και μετατραπεί σε δυαδικές τιμές. Το  $w$  αποτελεί το διάνυσμα βαρών του μοντέλου, όπου και βρίσκεται μέσω της εκπαίδευσης.

Σαν συνάρτηση σφάλματος η διασταυρούμενη εντροπία :

$$L(y, \hat{y}) = -y \log \hat{y} - (1 - y) \log (1 - \hat{y}) \quad (4.2)$$

και για την L2 κανονικοποίηση που προσθέτουμε στη συνάρτηση σφάλματος :

$$g^{L2}(w) = \frac{\sum_{i=1} w_i^2 * \lambda}{2} \quad (4.3)$$

με το λάμδα -  $\lambda$ , παράμετρος που ορίζουμε εμείς.

## 4.3 Βαθιά Νευρωνικά Δίκτυα

Νευρωνικό δίκτυο ονομάζεται ένα δίκτυο που αποτελείται από απλούς υπολογιστικούς κόμβους, που λέγονται νευρώνες και οι οποίοι είναι διασυνδεδεμένοι μεταξύ τους, σύμφωνα με τα [Schmidhuber, 2015], [McCulloch & Pitts, 1943]. Ο νευρώνας είναι εμπνευσμένος από το μοντέλο του βιολογικού νευρώνα, όπου και πήρε το όνομα του. Αντίστοιχα ένα νευρωνικό δίκτυο είναι εμπνευσμένο από το κεντρικό νευρικό σύστημα. Ο νευρώνας θεωρείται το βασικό συστατικό του δικτύου. Ενώνοντας μεταξύ τους πολλούς τέτοιους νευρώνες και οργανώνοντας τους σε αλληλοσυνδεδεμένα επίπεδα, φτιάχνουμε ένα νευρωνικό δίκτυο. Οι νευρώνες εισόδου ενεργοποιούνται από αισθητήρες του περιβάλλοντος (είσοδοι δεδομένων) ενώ άλλοι ενεργοποιούνται μέσω των συνδέσεων - συνάψεων (με βάρη) που υπάρχουν από προηγούμενους νευρώνες.

Μαθηματικά μιλώντας, κάθε τέτοιος νευρώνας, δέχεται ένα σύνολο αριθμητικών εισόδων από διαφορετικές πηγές και με βάση αυτές, επιτελεί ένα υπολογισμό, παράγοντας έτσι μια έξοδο κατά το [McCulloch & Pitts, 1943]. Η έξοδος αυτή είτε είναι το τελικό αποτέλεσμα είτε ενδιάμεσο στάδιο που τροφοδοτείται σαν είσοδος σε νευρώνα επόμενου επιπέδου. Σημαντικό να αναφέρουμε ότι το

διάνυσμα εισόδου δεδομένων, ονομάζεται και επίπεδο εισόδου (input layer) και τροφοδοτεί τους νευρώνες του πρώτου κρυφού επιπέδου (hidden layer). Το επίπεδο εξόδου μετά τη διάδοση όλων των σημάτων στα ενδιάμεσα επίπεδα, μας δίνει τις τελικές εξόδους του δικτύου. Γενικότερα, κρυφά επίπεδα λέγονται όλα τα επίπεδα ανάμεσα στο επίπεδο εισόδου και εξόδου. Όπως αναφέρει και ο [\[Bishop, 1996\]](#), πολλά διαδοχικά τέτοια επίπεδα μπορούν να φτιάξουν πιο γενικές συναρτήσεις. Μπορείτε να δείτε στο [σχήμα 4.1](#) πιο παραστατικά αυτές τις έννοιες.

Δεν υπάρχει αμφιβολία ότι τα νευρωνικά δίκτυα έχουν μπει για τα καλά στη ζωή μας ιδιαίτερα την τελευταία δεκαετία. Συνήθως τέτοιοι αλγόριθμοι - μέθοδοι, είναι υπολογιστικά πολύ δαπανηροί, για αυτό ενώ έχει χρόνια που υπήρχαν σαν θεωρία, δεν είχαν δοκιμαστεί στη πράξη μέχρι τελευταία. Τα βαθύτερα αίτια αυτής της ξαφνικής ανόδου, βρίσκονται στην ανάπτυξη και διάδοσης της ωμής υπολογιστικής δύναμης. Ειδικότερα η υπολογιστική ισχύς έχει γίνει πλέον προσιτή τόσο σε θέματα τιμής όσο και ευκολίας χρήσης για όλους. Για παράδειγμα με τη χρήση GPU και TPU, ο χρόνος εκπαίδευσης ενός αλγορίθμου μηχανικής μάθησης, μειώνεται δραστικά, λύνοντας τα κάποτε χρονοβόρα προβλήματα σε χρόνο ρεκόρ.

Είναι κοινά παραδεκτό ότι με την εμφάνιση της φθηνής υπολογιστικής δύναμης, έκαναν την εμφάνιση τους και τα βαθιά νευρωνικά δίκτυα. Αναλυτικότερα, σε αντίθεση με τα απλά τεχνητά νευρωνικά, τα βαθιά έχουν περισσότερα επίπεδα το ένα μετά το άλλο, με αποτέλεσμα να δίνεται η ευκαιρία για εξαγωγή πιο υψηλού επιπέδου γνώσης όπως αναφέρει το [\[\[Wang et al., 2016\]\]](#). Παράλληλα, με τη χρήση πολυεπίπεδων δικτύων μπορούμε να εξερευνήσουμε αλληλεπιδράσεις υψηλότερης τάξης μεταξύ των χαρακτηριστικών ([\[Wang et al., 2016\]](#)). Όλα αυτά κάνουν τα βαθιά νευρωνικά την κατάλληλη μέθοδο για να ανακαλύψουμε τα κρυμμένα μοτίβα που υπάρχουν στα δεδομένα μας, ώστε να κατασκευάσουμε ένα καλό εργαλείο πρόβλεψης για CTR.

Παρόλα αυτά, λόγω της μορφής των δεδομένων δεν μπορούμε να τα χρησιμοποιήσουμε απευθείας σε νευρωνικό δίκτυο. Ο λόγος πίσω από αυτό έγκειται ότι στο δίκτυο μας, θέλουμε να έχουμε διάνυσμα εισόδου σταθερού μήκους. Απεναντίας λόγω των δεδομένων που έχουμε, δεν μπορούμε να δημιουργήσουμε εύκολα, διάνυσμα σταθερού μήκους. Για να γίνει κάτι τέτοιο χρειάζεται σημαντική προεπεξεργασία, με αποτέλεσμα ίσως να χαθεί μάλιστα πολύτιμη πληροφορία. Συνάμα, το μέγεθος των δεδομένων αποτελεί ένα σημαντικό θέμα. Είναι πολύ δύσκολο να εκπαιδύσουμε ένα νευρωνικό δίκτυο, με δεδομένα που περιέχουν περίπου 950 χιλιάδες χαρακτηριστικά (αναφερόμενοι στο σύνολο δεδομένων IPinYou). Θα ήταν πολύ ακριβό υπολογιστικά αλλά και χρονικά, καθώς θα χρειαζόμασταν αρκετό διάστημα για να γίνουν οι προσομοιώσεις. Θα αναφερθούμε πιο αναλυτικά στη μορφή και τα προβλήματα των δεδομένων στο επόμενο κεφάλαιο.

Είναι φανερό ότι πρέπει να βρεθεί ένα άλλο ενδιάμεσο στάδιο για να μετασχηματίσουμε τα δεδομένα μας σε μορφή όπου μπορεί το νευρωνικό δίκτυο να λάβει. Όπως αναφέρεται στο [\[Wang et al., 2016\]](#), μερικές τέτοιες μέθοδοι είναι το Factorisation machine (FM), η περιορισμένη μηχανή Boltzmann (restricted Boltzmann machine - RBM) και ο αυτοκωδικοποιητής αποθορυβοποίησης (denoising auto-encoders – DAEs). Αυτές οι μέθοδοι είναι γνωστές ως embeddings layers και είναι υπεύθυνες για να μετατρέψουν μια διακριτή μεταβλητή σε ένα συνεχές διάνυσμα χαμηλότερης όμως διάστασης. Συνάμα, τα διανύσματα που είναι πιο κοντά στο πλαίσιο του προβλήματος μας εννοιολογικά, τοποθετούνται πιο κοντά και στο χώρο του embedding όπως λένε στο [Guo & Berkahn,](#)

2016]. Στο [σχήμα 4.2](#) γίνεται πιο αντιληπτή η μετατροπή των δεδομένων με τη χρήση των embedding layers.

Κρίνεται αναγκαίο να αναφερθούμε και στα είδη νευρωνικών δικτύων που υπάρχουν και έχουν χρησιμοποιηθεί για τη πρόβλεψη του CTR από διάφορους ερευνητές. Επίσης, ας μην ξεχνάμε ότι σε όσα χρειάζονται, έχει προηγηθεί πρώτα ένα embedding επίπεδο για μετατροπή των δεδομένων. Το πρώτο είδος που χρησιμοποιείται ως επί το πλείστο είναι τα απλά βαθιά νευρωνικά. Για τη πρόβλεψη CTR διαφημίσεων, πρώτα χρησιμοποιήθηκαν από τους [\[Wang et al., 2016\]](#).

Έπειτα, προχωράμε σε πιο σύνθετα δίκτυα, όπως τα ανατροφοδοτούμενα νευρωνικά δίκτυα (Recurrent neural network - RNN). Η βασική διαφορά τους με τα απλά δίκτυα, είναι ότι μπορούν να έχουν συνδέσεις – συνάψεις που ξεκινούν από την έξοδο ενός στρώματος και καταλήγουν στην είσοδο του ίδιου ή ενός προηγούμενου στρώματος ([\[Sak, Senior, & Beaufays, 2014\]](#)). Όπως αναφέρουν και οι [\[Graves et al., 2009\]](#), τα δίκτυα αυτά μπορούν να παρουσιάσουν ιδιότητες παρόμοιες με της ανθρώπινης μνήμης, καθώς η τωρινή έξοδος μπορεί να εξαρτάται από τις εξόδους του παρελθόντος. Έτσι, οι [\[Y. Zhang et al., 2014\]](#) έχουν υλοποιήσει επιτυχώς ένα τέτοιο RNN μοντέλο, προσπαθώντας να εκμεταλλευτούν την ιδέα της ύπαρξης μνήμης στο δίκτυο.

Παίρνοντας ιδέες από τον τρόπο λειτουργίας των κυττάρων του εγκεφάλου κατά την όραση, όπου παρομοιάζεται με τη χρήση γραμμικού φίλτρου δημιουργήθηκαν τα συνελικτικά νευρωνικά δίκτυα (convolutional neural network - CNN). Αυτή η χρήση φίλτρου, μαθηματικά γίνεται με τη πράξη της συνέλιξης στους νευρώνες αντί με τον πολλαπλασιασμό πινάκων που γινόταν κανονικά. Έχει χρησιμοποιηθεί στο μοντέλο που έφτιαξαν οι [\[Liu et al., 2016\]](#), με καλά αποτελέσματα.


Ακόμη, υπάρχουν διάφορες παραλλαγές των νευρωνικών δικτύων. Ένα παράδειγμα, είναι τα λεγόμενα PNN - product based neural networks. Σε αντίθεση με τα απλά νευρωνικά, χρησιμοποιούν διάφορες λειτουργίες γινομένου στη θέση της λειτουργία της πρόσθεσης στα κανονικά δίκτυα. Πιο συγκεκριμένα, οι [\[Qu et al., 2017\]](#) μετά την εφαρμογή ενός embedding layer, κάνουν χρήση εσωτερικού και εξωτερικού γινομένου στα διανύσματα για κάθε χαρακτηριστικό που υπολόγισε το embedding layer. Το συγκεκριμένο μοντέλο, έχει από τα καλύτερα αποτελέσματα στο πρόβλημα πρόβλεψης του CTR.

Είναι απαραίτητο να αναφερθούν και μερικά μοντέλα όπου είτε είναι συνδυασμός πολλών μικρότερων είτε χρησιμοποιούν μικρές παραλλαγές τους αλλά έχουν αξιοσημείωτα αποτελέσματα. Για παράδειγμα, στο [\[Guo et al. 2017\]](#) χρησιμοποιούν πιο εξελιγμένα μοντέλα, κάνοντας συνδυασμό διαφορετικών μοντέλων. Επίσης, ένα τροποποιημένο - επαυξημένο μοντέλο των factorization machine, όπου λέγεται Field-aware Factorization Machines-FFM, έχει προταθεί ([\[Juan, Lefortier, & Chapelle, 2017\]](#), [\[Juan et al., 2016\]](#)) που φαίνεται να δίνει πολύ καλά αποτελέσματα, κερδίζοντας δύο διαγωνισμούς στο Kaggle. Μεγάλη ανάλυση περί αυτών και πολλών άλλων μοντέλων παρουσιάζεται στο [\[Qu, Fang, et al., 2017\]](#), μαζί με την αναγκαία θεωρία και μαθηματικές αποδείξεις.

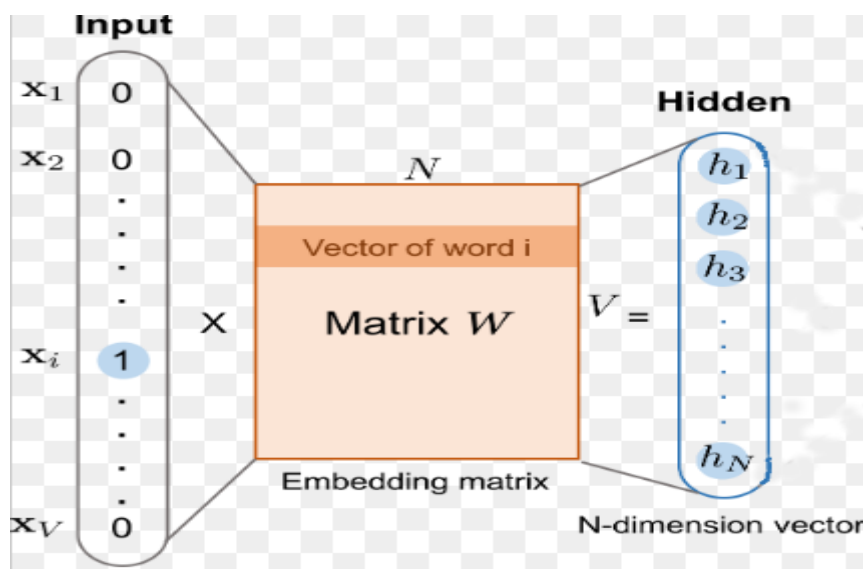
Κλείνοντας να αναφέρουμε ότι υπάρχει μια τάση να δημιουργούνται όλο και πιο μεγάλα και πολύπλοκα μοντέλα. Με την τεχνολογία που αναπτύσσεται σήμερα (GPU, TPU) και τις ευριστικές μεθόδους για καταπολέμηση της υπερπροσαρμογής στα δεδομένα, μπορούμε να συνεχίσουμε αυτή τη ανάπτυξη τους, παράγοντας όλο και καλύτερα αποτελέσματα.



Σχήμα 4.1 : Νευρωνικό δίκτυο πρόσθιας τροφοδότησης, με δύο κρυφά επίπεδα και δύο εξόδους.<sup>5</sup>



Σχήμα 4.2 : Φαίνεται η μετατροπή του αρχικού διακριτού διανύσματος (συνήθως τέτοια δεδομένα εισόδου, είναι αυτά που προέρχονται από one hot encoding), σε συνεχές διάνυσμα μικρότερης όμως διάστασης.<sup>6</sup>



5 Πηγή: <https://www.intechopen.com/media/chapter/39071/media/f2.jpg>

6 Πηγή: <https://www.kisspng.com/png-word2vec-euclidean-vector-bidirectional-recurrent-6778347/preview.html>

# Κεφάλαιο 5

## Μηχανές Παραγοντοποίησης

### 5.1 Εισαγωγή

Οι μηχανές παραγοντοποίησης ή factorization machines - FM όπως λέγονται στα Αγγλικά, είναι γενικά εργαλεία πρόβλεψης όπου μπορούν να δουλέψουν με οποιοδήποτε διάνυσμα πραγματικών αριθμών σύμφωνα με τον [\[Rendle, 2010\]](#). Εκτός από εργαλεία πρόβλεψης όλων των ειδών, μπορούν να χρησιμοποιηθούν και για μείωση διάστασης των διανυσμάτων δεδομένων όπως αναφέραμε και πριν. Αυτή η μέθοδος είναι σχετικά καινούργια, καθώς δημοσιεύτηκε για πρώτη φορά το 2010 από τον [\[Rendle, 2010\]](#). Το κύριο χαρακτηριστικό της, είναι ότι μοντελοποιεί τις αλληλεπιδράσεις μεταξύ όλων των χαρακτηριστικών / μεταβλητών των δεδομένων, χωρίς κανένα πρόβλημα ακόμη και για δεδομένα που είναι πολύ αραιά π.χ. προερχόμενα από one hot encoding. Αυτό το κάνει χρησιμοποιώντας λανθάνουσες παραμέτρους για κάθε χαρακτηριστικό, οι οποίοι μαθαίνονται από τα δεδομένα. Συνάμα σημαντικό, να πούμε ότι οι εξισώσεις του μοντέλου του μπορούν να υπολογιστούν σε γραμμικό χρόνο, κάτι που το κάνει σχετικά γρήγορο. Κλείνοντας να αναφέρουμε, ότι ένας επιπρόσθετος λόγος για τη δημοτικότητα τους είναι ότι μπορούν να μιμηθούν τα περισσότερα μοντέλα παραγοντοποίησης απλά με επεξεργασία των χαρακτηριστικών όπως αναφέρεται και στο [\[Rendle, 2012\]](#).

### 5.2 Μοντέλο της μηχανής παραγοντοποίησης

Αρχικά να πούμε ότι η μηχανή παραγοντοποίησης μπορεί να μοντελοποιήσει όλες τις εμφωλευμένες αλληλεπιδράσεις μέχρι τάξης έστω  $d$ , μεταξύ των  $p$  μεταβλητών εισόδου του διανύσματος εισόδου  $x \in \mathbb{R}^p$  [\[Rendle, 2010\]](#). Για λόγους ευκολίας, θα παρουσιάσουμε το μοντέλο τάξης  $d=2$ , όπου μοντελοποιεί όλες τις αλληλεπιδράσεις μεταξύ δύο χαρακτηριστικών / μεταβλητών.

Έχοντας ένα διάνυσμα εισόδου,  $x \in \mathbb{R}^p$  με αριθμό λανθανόντων παραμέτρων για κάθε μεταβλητή,  $k$ , το μοντέλο είναι:

$$\hat{y}(x) = w_0 + \sum_{i=1}^p w_i x_i + \sum_{i=1}^p \sum_{j=i+1}^p \langle v_i, v_j \rangle x_i x_j \quad (5.1)$$

όπου  $\hat{y}(x)$  εκτίμηση του FM για το πρόβλημα με είσοδο το διάνυσμα  $x$ , η  $w_0 \in \mathbb{R}$  πόλωση που πρέπει να “μαθευτεί”,  $w \in \mathbb{R}^p$  τα βάρη σύνδεσης των μεταβλητών που αντικατοπτρίζουν τη δύναμη κάθε μεταβλητής και ο πίνακας  $V \in \mathbb{R}^{p \times k}$ , περιγράφει τους παραμέτρους που μαθαίνονται για κάθε μεταβλητή - χαρακτηριστικό.

Ακόμη, ο συμβολισμός  $\langle \cdot, \cdot \rangle$  είναι το εσωτερικό γινόμενο μεταξύ δύο διανυσμάτων μεγέθους  $k$ .

$$\text{Δηλαδή, } \langle v_i, v_j \rangle = \sum_{f=1}^k v_{i,f} v_{j,f} \quad (5.2)$$

Πιο συγκεκριμένα, μια γραμμή έστω  $v_i$  του  $V$ , περιγράφει την  $i$ -οστή μεταβλητή με  $k$  παράγοντες, όπου  $k \in \mathbb{N}_0^+$  είναι η υπερπαράμετρος που περιγράψαμε πριν και χαρακτηρίζει τη διάσταση της παραγοντοποίησης. Σε αραιά δεδομένα, περιορίζοντας το  $k$  και άρα έτσι την εκφραστικότητα του FM, οδηγούμαστε σε καλύτερες γενικεύσεις [Rendle, 2010]. Όπως λέει και στο [Rendle, 2012], το  $w$ , μοντελοποιεί τις αλληλεπιδράσεις κάθε μεταβλητής με το στόχο, ακριβώς όπως και στο μοντέλο γραμμικής παλινδρόμησης. Όσο αφορά την μοντελοποίηση των αλληλεπιδράσεων τάξης  $d=2$ , μεταξύ όλων τα μεταβλητών, διαφέρουν από το τρόπο της πολυωνυμικής παλινδρόμησης, καθώς χρησιμοποιούν παραγοντοποιημένη παραμετροποίηση αντί για ανεξάρτητες παραμέτρους.

Όπως παρατηρούμε από το μοντέλο που μόλις περιγράψαμε ο ευθύς υπολογισμός του, απαιτεί χρόνο της τάξης του  $O(kn^2)$ . Πειράζοντας όμως λίγο τη μαθηματική φόρμουλα σύμφωνα με το [Rendle, 2010] μπορεί να γραφτεί σαν :

$$\hat{y}(x) = w_0 + \sum_{i=1}^p w_i x_i + \frac{1}{2} \sum_{f=1}^k \left( \left( \sum_{i=1}^p v_{i,f} x_i \right)^2 - \sum_{i=1}^p v_{i,f}^2 x_i^2 \right) \quad (5.3)$$

Η οποία, μπορεί να υπολογιστεί σε χρόνο  $O(kn)$ . Όπου συνήθως το  $k$  είναι μικρό σε τάξη, άρα ο χρόνος γίνεται γραμμικός ως προς το  $n$ . Περαιτέρω, καθώς πολλές φορές ο χώρος δεδομένων είναι πολύ αραιός, δηλαδή τα περισσότερα στοιχεία είναι 0, τα αθροίσματα χρειάζεται να υπολογιστούν μόνο στα μη-μηδενικά στοιχεία. Έτσι ο υπολογισμός γίνεται σε  $O(k \bar{m}_D)$ , όπου  $\bar{m}_D$  μέσος όρος των μη-μηδενικών στοιχείων όλων των διανυσμάτων  $x \in D$ , με  $D$  το σύνολο δεδομένων εκπαίδευσης.

Όπως αναφέραμε και πριν το μοντέλο του FM, μπορεί να μοντελοποιήσει αλληλεπιδράσεις μεταξύ των μεταβλητών μέχρι τάξης  $d$ . Ο ευθύς υπολογισμός του μοντέλου τάξεως  $d$ , δίνει  $O(k_d n^d)$ . Όμως με τις ίδιες αλλαγές με πριν μπορεί να υπολογιστεί πάλι σε γραμμικό χρόνο όπως αναφέρει και ο [Rendle, 2010].

Για τους ενδιαφερόμενους στο [Rendle, 2010], υπάρχει εκτενής σύγκριση με τα μοντέλα SVM αλλά και άλλα μοντέλα παραγοντοποίησης, αλλά και πως το FM, μπορεί να τα μιμηθεί.

## 5.3 Αλγόριθμοι εκμάθησης μηχανών παραγοντοποίησης

Αρχικά τρεις μέθοδοι έχουν προταθεί για την εκμάθηση των παραγόντων των διανυσμάτων του FM. Αυτές είναι η στοχαστική κάθοδος κλίσης (stochastic gradient descent – SGD), τα εναλλάσσοντα ελάχιστα τετράγωνα (alternating least-squares – ALS) και οι Μαρκοβιανές αλυσίδες Μόντε Κάρλο (Markov Chain Monte Carlo -MCMC). Παράλληλα μερικές συναρτήσεις σφάλματος που έχουν χρησιμοποιηθεί είναι τα ελάχιστα τετράγωνα, η λογιστική ([Ta, 2015]) και η hinge.

Θα αποτελούσε παράληψη αν δεν αναφέραμε ότι πολλές φορές κρίνεται απαραίτητα και η χρήση κανονικοποίησης. Ειδικότερα, αν διαλέξουμε το  $k$  αρκετά μεγάλο, το μοντέλο θα έχει πολλούς παραμέτρους, πράγμα που το κάνει επιρρεπή στην υπερπροσαρμογή. Για να αντιμετωπιστεί αυτό, συνήθως L2 κανονικοποίηση χρησιμοποιείται, όπως αναφέρει και ο [Rendle, 2012].

## 5.4 Πεδιο-κεντρικές μηχανές παραγοντοποίησης - Field-aware Factorization Machines (FFM)

Αρχίζουμε ξεκαθαρίζοντας ότι οι μηχανές FFM, αποτελούν, μια μετεξέλιξη-παραλλαγή των απλών μηχανών παραγοντοποίησης. Στις FM, κάθε χαρακτηριστικό έχει ένα λανθάνων διάνυσμα για να μάθει την αλληλεπίδραση του, με όλα τα άλλα χαρακτηριστικά. Κάθε χαρακτηριστικό ανήκει σε κάποιο συγκεκριμένο πεδίο. Σαν πεδίο νοείται μια πιο ευρύς κατηγορία, που περιέχει πολλά χαρακτηριστικά. Για παράδειγμα, το πεδίο φύλο, περιέχει τα χαρακτηριστικά γυναίκα και άντρας. Αντίθετα, στις FFM όπως αναφέρει και το [Juan et al., 2016], κάθε χαρακτηριστικό έχει πολλά λανθάνων διανύσματα για να μάθει την αλληλεπίδραση του με τα άλλα χαρακτηριστικά, με κάθε διάνυσμα να αντιστοιχεί σε ένα συγκεκριμένο πεδίο. Αυτή είναι η κύρια διαφορά μεταξύ των δύο παραλλαγών μηχανών παραγοντοποίησης.

Για να καταλάβουμε καλύτερα τη χρησιμότητα αυτών των επιπλέον λανθανόντων διανυσμάτων ας δούμε ένα παράδειγμα. Έστω ότι θέλουμε να μάθουμε το διάνυσμα για το χαρακτηριστικό StarTV. Στις FM, έχουμε ένα διάνυσμα για να μάθουμε τόσο την αλληλεπίδραση μεταξύ StarTV με CoffeeIsland ( $v_{StarTV} \cdot v_{CoffeeIsland}$ ) όσο και μεταξύ StarTV με Άρρεν ( $v_{StarTV} \cdot v_{Άρρεν}$ ). Όμως αυτά τα δύο αφού ανήκουν σε διαφορετικά πεδία, λογικά θα έχουν διαφορετικές αλληλεπιδράσεις με το StarTV. Ωστόσο αυτό δεν μπορεί να συλληφθεί από τις FM, καθώς θα χρησιμοποιήσει το ίδιο διάνυσμα και στις δύο περιπτώσεις. Δε συμβαίνει όμως το ίδιο με τις FFM, καθώς έχουν για κάθε πεδίο ένα λανθάνων διάνυσμα και μπορούν έτσι να εκλάβουν καλύτερα τις αλληλεπιδράσεις των χαρακτηριστικών σύμφωνα με τους [Juan et al., 2016]. Για τα δεδομένα του πίνακα 1, θα είχαμε 3 λανθάνοντα διανύσματα για κάθε χαρακτηριστικό. Για το StarTV, οι αλληλεπιδράσεις θα αναπαραστούσαν από το

$$v_{StarTV, \Delta} \cdot v_{CoffeeIsland, E} \text{ και το } v_{StarTV, \Phi} \cdot v_{Άρρεν, E} .$$

Πίνακας 1 : Παράδειγμα δεδομένων εκπαίδευσης σε FFM

Έκαναν κλικ	Εκδότης (Ε)	Διαφημιστής (Δ)	Φύλο (Φ)
Ναι	StarTV	CoffeeIsland	Άρρεν

Μαθηματικά το μοντέλο των FFM γράφεται σαν :

$$\hat{y}(x) = w_0 + \sum_{i=1}^p w_i x_i + \sum_{i=1}^p \sum_{j=i+1}^p \langle v_{i,f2}, v_{j,f1} \rangle x_i x_j \quad (5.4)$$

Με μόνη διαφορά από πριν τους δείκτες f1,f2 στα λανθάνοντα διανύσματα, που αντιστοιχούν στα πεδία των i, j αντίστοιχα.

Χρήσιμο να τονιστεί ότι ο συγγραφέας του [\[Juan et al., 2016\]](#), διατυπώνει την άποψη ότι στα FFM αφού κάθε διάνυσμα πρέπει να μάθει μόνο την αλληλεπίδραση ενός πεδίου, το  $k_{FFM} \ll k_{FM}$  .

## 5.5 Μορφή δεδομένων για FM και FFM

Οι πλείστες βιβλιοθήκες έτοιμων υλοποιήσεων μηχανών παραγοντοποίησης, θέλουν τα δεδομένα εισόδου σε μια συγκεκριμένη μορφή. Αυτή η μορφή λέγεται libSVM μορφοποίηση. Τα δεδομένα τόσο εκπαίδευσης όσο και δοκιμής πρέπει να είναι σε αυτή τη μορφή.

Μορφή για FM (όπως αναφέρεται στις επίσημες σελίδες των βιβλιοθηκών για FM):

<label> <index\_feature\_1>:<value\_1> <index\_feature\_2>:<value\_2> ...

Label είναι ο στόχος-y κάθε διανύσματος εισόδου x, index\_feature ο δείκτης κάθε χαρακτηριστικού αρχίζοντας από 0 και value, η τιμή του αντίστοιχου χαρακτηριστικού. Σημαντικό να υπενθυμίσουμε ότι μόνο τα μη-μηδενικά χαρακτηριστικά τοποθετούνται σε αυτή τη μορφή.

Μορφή για FFM :

<label> <index\_field\_1>:<index\_feature\_1>:<value\_1>  
<index\_field\_2>:<index\_feature\_2>:<value\_2> ...

Όπου index\_field είναι ο δείκτης για το πεδίο του συγκεκριμένου χαρακτηριστικού. Τα υπόλοιπα είναι όπως και στη μορφή του FM.

## 5.6 Βιβλιοθήκες για μηχανές παραγοντοποίησης

Αρχικά με τη πρώτη επίσημη εμφάνιση τους, ο [\[Rendle, 2010\]](#), δημιούργησε μια υλοποίηση για τις μηχανές παραγοντοποίησης και στη συνέχεια την ενσωμάτωσε σε βιβλιοθήκη, που λέγεται LibFM και είναι γραμμένη σε c++. Παρόμοιας λογικής αλλά για πεδίο-κεντρικές μηχανές (FFM), είναι η βιβλιοθήκη LIBFFM, όπου είναι πάλι γραμμένη σε c++ και υλοποιήθηκε από τους [\[Juan et al., 2016\]](#). Στο [\[Bayer, 2015\]](#), έχουν κάνει μια προσπάθεια για βιβλιοθήκη όπου συνάδει με το api scikit-learn της python, φτιάχνοντας την fastFM, χωρίς να έχει λάβει ιδιαίτερα καλή κριτική.

Η βιβλιοθήκη που χρησιμοποιούμε εμείς είναι η xLearn. Αυτό καθώς είναι εύχρηστη, κλιμακώνεται εύκολα καθώς έχει δυνατότητα για κατανεμημένη μάθηση αλλά και επειδή υποστηρίζει out-of-core εκτέλεση. Συνάμα, σύμφωνα με κάποια ανεπίσημα στατιστικά είναι αρκετά πιο γρήγορη από τις άλλες. Επίσης, έχουν φτιάξει api που μπορείς να το εγκαταστήσεις εύκολα μέσω του μάνατζερ πακέτων της python (pip). Κλείνοντας ένα επιπλέον χαρακτηριστικό που μας έκανε να την διαλέξουμε, είναι ότι υποστηρίζει τόσο απλές μηχανές παραγοντοποίησης (FM) όσο και πεδίο-κεντρικές (FFM), κάτι πολύ χρήσιμο για κάποιον που θέλει εύκολα να εξερευνήσει και τις δύο μεθόδους.

Αναλυτικότερα, η βιβλιοθήκη xLearn προσφέρει μερικά άλλα χαρακτηριστικά που την κάνουν να ξεχωρίζει από τις άλλες. Αρχίζοντας να τονίσουμε ότι το μοντέλο αποθηκεύεται αυτόματα είτε σε δυαδική (binary) μορφή είτε σαν αρχείο κειμένου. Με τη χρήση μόνο του binary αρχείου του μοντέλου, μπορεί να υποστηρίξει online learning, το οποίο μπορεί να εκπαιδεύσει νέα δεδομένα, με βάση το παλιό ήδη εκπαιδευμένο μοντέλο. Επιπλέον από την υλοποίηση απλών και πεδίο-κεντρικών, μηχανών παραγοντοποίησης, υπάρχει και υλοποίηση γενικευμένων γραμμικών μοντέλων (generalized linear model – GLM), που είναι μια γενίκευση της γραμμικής παλινδρόμησης. Ακόμη υπάρχει η δυνατότητα χρήσης cross-validation, τεχνική που επιτρέπει την αξιολόγηση των αποτελεσμάτων. Είναι πολύ χρήσιμη σε περιπτώσεις όπου το σύνολο δεδομένων μας είναι πολύ μικρό.

Παρέχεται επίσης η χρήση τριών μεθόδων βελτιστοποίησης. Αυτές είναι, η στοχαστική κάθοδος κλίσης (sgd), η adagrad, όπου συγκριτικά με τη sgd, προσαρμόζει το ρυθμό μάθησης με τους παραμέτρους και η (Follow-the-Regularized-Leader – FTRL) όπου όμως απαιτεί τη ρύθμιση περισσότερων υπερπαραμέτρων. Ταυτόχρονα, αν επιλέξουμε να χρησιμοποιήσουμε δεδομένα επαλήθευσης (validation data), το xLearn θα εκτελέσει αυτόματα, “πρόωρη διακοπή” (early stopping), μια μέθοδος που προστατεύει το μοντέλο από υπερπροσαρμογή στα δεδομένα. Αυτή η μέθοδος, διακόπτει τη διαδικασία εκπαίδευσης όταν πέσει η απόδοση του μοντέλου, στα δεδομένα επαλήθευσης. Η βιβλιοθήκη έχει και άλλα χαρακτηριστικά όπου όμως θεωρούνται αρκετά εξελιγμένα για να τα αναφέρουμε.

Συμπερασματικά, η xLearn είναι μια πολύ καλή και πλούσια βιβλιοθήκη για FM, που προσφέρει όλες τις βασικές λειτουργίες που ένας χρήστης απαιτεί, για χρήση σε προβλήματα μηχανικής μάθησης.

## Κεφάλαιο 6

# Σύνολα Δεδομένων και Προεπεξεργασία

### 6.1 Εισαγωγή

Βρισκόμαστε στην εποχή όπου τα δεδομένα είναι το μαγικό κλειδί για την αλλαγή του κόσμου. Τα δεδομένα είναι μια συλλογή από γεγονότα. Μπορεί να είναι αριθμοί, λέξεις, μετρήσεις ή παρατηρήσεις και τα οποία θέλουμε να μεταφράσουμε σε μορφές όπου ο υπολογιστής μπορεί να καταλάβει και επεξεργαστεί. Τα δεδομένα έχουν γίνει πλέον το εμπόρευμα του μέλλοντος, καθώς όποιος τα κατέχει, κατέχει και μεγάλη δύναμη - γνώση.

Η ανάπτυξη της μηχανικής μάθησης τις τελευταίες δεκαετίες, έχει φέρει και την αντίστοιχη ανάπτυξη στα δεδομένα. Όπως είναι κοινά γνωστό η μηχανική μάθηση αποτελεί το πεδίο μελέτης και εξόρυξης γνώσης από δεδομένα. Είναι φανερό, ότι τα δεδομένα μπορούν να παρομοιαστούν σαν τα καύσιμα του μηχανισμού της μηχανικής μάθησης. Έχουν πλέον γίνει το συνάλλαγμα των επιχειρήσεων και η περαιτέρω ανάπτυξη τους, παίρνει πρωταγωνιστικό ρόλο στην ανάπτυξη των ίδιων των επιχειρήσεων. Αυτός είναι και ο λόγος που ο όγκος των δεδομένων που παράγονται αυξάνεται με εκθετικούς ρυθμούς. Αξιοσημείωτο, ότι 90% όλων των δεδομένων, έχουν δημιουργηθεί τα τελευταία δύο χρόνια. Με όλη αυτή τη ακατέργαστη γνώση να υπάρχει εκεί έξω, η ευθύνη μένει στα χέρια μας για να τα επεξεργαστούμε, μελετήσουμε και ερμηνεύσουμε για να δαμάσουμε τη δύναμη που αυτά μπορούν να προσφέρουν.

Δεν υπάρχει αμφιβολία, ότι τα δεδομένα έχουν φέρει την αλλαγή και στην κοινότητα των RTB διαφημίσεων. Ο [\[Zhang et al., 2014\]](#), αναφέρει ότι οι μελετητές σε αυτό το τομέα είχαν μεγάλο πρόβλημα λόγω της απουσίας δημόσιων συνόλων δεδομένων, αφού οι διαφημιστικές εταιρείες δεν ήθελαν να μοιραστούν με το κοινό, τέτοια πολύτιμα δεδομένα. Αυτό άλλαξε το 2014, όπου έκανε την εμφάνιση του, το dataset IPinYou ([\[Liao et al., 2012\]](#)). Το 2013, η IpinYou, εταιρεία που προσφέρει DSP συστήματα και θεωρείται από τις κορυφαίες στη Κίνα, διοργάνωσε ένα παγκόσμιο διαγωνισμό για αλγόριθμους RTB. Μετά το πέρας του διαγωνισμού, η εταιρεία δημοσίευσε τα σύνολα δεδομένων που χρησιμοποιήθηκαν για τη διαδικασία του διαγωνισμού. Αυτά ήταν και τα πρώτα δημόσια δεδομένα που αφορούσαν RTB διαφημίσεων. Στα επόμενα χρόνια, έγιναν και άλλοι τέτοιοι διαγωνισμοί με αποτέλεσμα να έχουμε και άλλα dataset διαθέσιμα. Παρόλα αυτά, το IPinYou, θεωρείται το πιο πλήρες.



Στα επόμενα κομμάτια, γίνεται αναλυτική παρουσίαση των συνόλων δεδομένων που χρησιμοποιήσαμε και τη προεπεξεργασία που αυτά χρειάστηκαν για να μπορούν οι αλγόριθμοι μηχανικής μάθησης να χρησιμοποιήσουν.

## 6.2 Σύνολα Δεδομένων

**IPinYou:** Αυτό το σύνολο δεδομένων έκανε την εμφάνιση του το 2014. Περιέχει τρεις season, με κάθε εποχή να έχει διαφορετικά δεδομένα – χαρακτηριστικά, τα οποία όλα προέρχονται από αληθινές διαφημιστικές καμπάνιες της εταιρείας. Πιο συγκεκριμένα, το σύνολο αυτό περιέχει αρχεία καταγραφής πονταρισμάτων διαφημίσεων (bidding log), τα χαρακτηριστικά τους (impression log), εάν έκαναν ή όχι κλικ (click log) και περιπτώσεις που τελικά αγοράστηκε το προϊόν (μετατροπή - conversion log). Το μέγεθος τους, αγγίζει περίπου τα 35GB αριθμώντας 19.5 εκατομμύρια εγγραφές οι οποίες περιέχουν συνολικά 937,748 δυαδικά χαρακτηριστικά. Σημαντικό να αναφέρουμε ότι η εταιρεία είχε θέσει δικό της KPI στο διαγωνισμό, όπου οι ομάδες έπρεπε να βελτιστοποιήσουν και είναι το εξής:

$\max \quad \#click+N * \#μετατροπών$   
που υπόκειται σε σταθερό προϋπολογισμό.

Όπου μετατροπή εννοούμε την αγορά κάποιου προϊόντος από ένα χρήστη και N, είναι ο αριθμός που δείχνει πόσο σημαντική είναι η κάθε μετατροπή.

Αναφορικά με τα αρχεία δεδομένων, σε κάθε γραμμή στο αρχείο πονταρίσματος (bidding log), η πρώτη στήλη είναι το Bid ID, το οποίο είναι το μοναδικό αναγνωριστικό κάθε εγγραφής που αντιστοιχεί σε κάθε δημοπρασία διαφήμισης. Περαιτέρω, αυτό χρησιμοποιείται και στα αρχεία χαρακτηριστικών και κλικ (impression και click logs) για να μπορούμε να τα συνδυάσουμε μοναδικά σε μία δημοπρασία και το αποτέλεσμα της.

Όπως παρουσιάζεται και στο [\[Zhang et al., 2014\]](#), κάθε εγγραφή έχει τρία είδη πληροφορίας. Αρχικά, τα χαρακτηριστικά για τη δημοπρασία και τη διαφήμιση, τα οποία αποστέλλονται στο αίτημα, για να γίνει το ποντάρισμα. Έπειτα είναι η νικητήρια τιμή, δεδομένου ότι το DSP νίκησε τη δημοπρασία και τέλος, η αντίδραση του χρήστη, εάν δηλαδή έκανε κλικ ή όχι και εάν αγόρασε το προϊόν. Στο πίνακα 2 παρουσιάζεται μια ανάλυση των χαρακτηριστικών μιας εγγραφής, όπως πάρθηκαν από το [\[Zhang et al., 2014\]](#).

Είναι κοινά αποδεκτό ότι το IPinYou, είναι από τα πιο διαδεδομένα σύνολα δεδομένων για το χώρο του RTB. Σκοπός της δημιουργίας του από την IPinYou, ήταν για να βρεθούν μέσω του διαγωνισμού καινούργιες μέθοδοι για τη λύση όλων των προβλημάτων του RTB. Δηλαδή ήθελαν να βρεθεί καινούργιος αλγόριθμος για υπολογισμό του CTR, αλλά και βέλτιστη στρατηγική πονταρίσματος και



συνάρτησης υπολογισμού της τιμής, με ότι άλλο αυτά τα προβλήματα περιέχουν π.χ. έλεγχο προϋπολογισμού. Για το λόγο αυτό τα δεδομένα αυτά θεωρούνται τα πιο πλήρη που υπάρχουν στο χώρο καθώς προσφέρονται για ανάπτυξη, έλεγχο και λύση όλων των παραπάνω προβλημάτων. Ενημερωτικά αναφέρουμε, ότι τα πλείστα σύνολα δεδομένων που υπάρχουν στην RTB κοινότητα, αφορούν μόνο τη πρόβλεψη CTR, αφού είναι και το πιο κρίσιμο και δημοφιλές πρόβλημα.

Περαιτέρω, λόγω αυτής της πληρότητας των δεδομένων του αλλά και επειδή ήταν το πρώτο που εμφανίστηκε, η περισσότερη μελέτη και χρήση στη κοινότητα, γίνεται με βάση αυτό. Έτσι έχουμε τόσο θεωρία αλλά και ιδέες που μπορούμε να αναπτύξουμε και ταυτόχρονα αποτελέσματα για να μπορούμε να συγκρίνουμε με τα δικά μας μοντέλα. Ειδικότερα το τελευταίο κομμάτι, θεωρείται πολύ σημαντικό, καθώς στο τομέα της μηχανικής μάθησης είναι κρίσιμο να μπορείς να συγκρίνεις και να ξέρεις ότι ο αλγόριθμος σου πάει καλά συγκριτικά με κάποιους άλλους που έχεις σαν βάση.

Σε αυτό βοήθησαν ιδιαίτερα οι [\[Zhang et al., 2014\]](#), καθώς είχαν κάνει κάποια benchmarks για πρόβλεψη CTR αλλά και για στρατηγικές πονταρίσματος, χρησιμοποιώντας όμως απλές σχετικές μεθόδους. Ταυτόχρονα, παρουσίασαν και στατιστική ανάλυση διαφόρων παραγόντων του συνόλου δεδομένων, όπως π.χ. το CTR κάθε διαφημιστή που υπήρχε στα δεδομένα. Οι ίδιοι ([\[Zhang et al., 2014\]](#)), είχαν κάνει επίσης και τη προεπεξεργασία δεδομένων και δημοσίευσαν τους κώδικες στο κοινό, για να μπορεί το θέμα να ερευνηθεί πιο εύκολα και με πιο τυποποιημένο τρόπο. Αυτή τη προεπεξεργασία χρησιμοποιήσαμε και εμείς στο συγκεκριμένο dataset.

Κλείνοντας, να πούμε όμως ότι καθώς στη πρώτη season δεδομένων, δεν δίνεται το μοναδικό αναγνωριστικό των διαφημιστών και έχοντας στο μυαλό μας ότι η ποικιλία διαφημιστών κάνει τα δεδομένα πιο ενδιαφέροντα ([\[Zhang et al., 2014\]](#)), αποφασίσαμε να μην την χρησιμοποιήσουμε. Για να είμαστε πιο ξεκάθαροι, πρακτικά χωρίζουμε τις εγγραφές της δεύτερης και τρίτης season, κατά το διαφημιστή. Υπάρχουν συνολικά 9 διαφημιστές. Θεωρούμε ότι κάθε διαφημιστής αντιστοιχεί σε μια συγκεκριμένη καμπάνια. Έτσι, λύνουμε το πρόβλημα της πρόβλεψης CTR, ξεχωριστά για κάθε διαφημιστή για να έχουμε καλύτερη ανάλυση αλλά και επίδοση. Ένας επιπλέον λόγος για τη χρήση μόνο της δεύτερης και τρίτης season, είναι ότι στη πρώτη season δεν υπάρχουν user tags, πράγμα που κάνει τη μοντελοποίηση λιγότερο ενδιαφέρουσα, δεδομένου ότι θεωρούνται πολύ σημαντικά χαρακτηριστικά.

Ένα ενδιαφέρον στατιστικό που προέκυψε από την ανάλυση των [\[Zhang et al., 2014\]](#), είναι ότι ενώ όλοι οι διαφημιστές είχαν CTR λιγότερο από 0.1% στα δεδομένα εκπαίδευσης ο διαφημιστής 2997 είχε 0.444%. Ο λόγος πίσω από αυτό είναι ότι ο διαφημιστής αυτός συνδέεται με περιβάλλον διαφήμισης σε κινητά τηλέφωνα σύμφωνα με τους [\[Zhang et al., 2014\]](#), όπου εκεί τα κλικ γίνονται πιο εύκολα (χάρη π.χ. στο φαινόμενο του χοντρού δακτύλου, κατά το οποίο ο χρήστης καταλάθος πατάει σε διάφορα σημεία της οθόνης και άρα γίνονται κλικ σε διαφημίσεις).

Πίνακας 6.1 : Παρουσιάζει τα ποσοστά CTR, που υπάρχουν στα δεδομένα του dataset IPinYou, στη δεύτερη και τρίτη season. Βλέπουμε ότι όλα τα ποσοστά είναι πολύ χαμηλά.

Διαφημιστές	CTR (δεδομένα εκπαίδευσης)	CTR (δεδομένα δοκιμής)
1458	0.080%	0.088%
2259	0.034%	0.031%
2261	0.030%	0.028%
2821	0.064%	0.060%
2997	<b>0.444%</b>	<b>0.342%</b>
3358	0.078%	0.113%
3386	0.073%	0.091%
3427	0.074%	0.074%
3476	0.052%	0.058%

Μερικά από τα user tags που χρησιμοποιούνται κατά τις season 2 και 3, αφορούν γεωγραφικά, δημογραφικά στοιχεία του χρήστη, μακροχρόνια ενδιαφέροντα του και συγκεκριμένα είδη αγαθών/υπηρεσιών που τον ενδιαφέρουν.

Ακολουθούν μερικά παραδείγματα:

- Μακροχρόνια ενδιαφέροντα είναι οι ειδήσεις, η μάθηση και η μόδα.
- Είδη αγαθών/υπηρεσιών που ενδιαφέρουν το χρήστη είναι ο ρουχισμός, τα αθλητικά είδη και τα ταξίδια.
- Δημογραφική ετικέτα, υπάρχει μόνο το φύλο ενός χρήστη, άντρας/γυναίκα.
- Γεωγραφικά η περιοχή και η πόλη του χρήστη, όπως το Πεκίνο.

Μια ακόμη ενδιαφέρουσα παρατήρηση είναι ότι η IPinYou, δεν έδωσε στην δημοσιότητα όλες τις ετικέτες χρήστη που έχει, παρά ένα κομμάτι τους.

Να αναφέρουμε ότι οι διαφημιστές 1458, 3358, 3386, 3427, 3476 ανήκουν στη season 2 ενώ οι υπόλοιποι (2259, 2261, 2821, 2997) ανήκουν στη season 3 του dataset IPinYou.

Αν παρατηρήσει κανείς το [πίνακα 6.1](#), θα δει ότι το CTR των διαφημιστών της season 2, είναι ψηλότερο από αυτό της season 3. Οι τεχνικοί της IPinYou, εξήγησαν ([\[Zhang et al., 2014\]](#)) ότι αυτό οφείλεται στα διαφορετικά συστήματα που χρησιμοποιήθηκαν για διαχωρισμό των χρηστών μεταξύ

της season 2 και 3. Με λίγα λόγια μπορεί να είχαν χωρίσει τους χρήστες ανα διαφορετικό δημογραφικό χαρακτηριστικό σε κάθε season και έτσι κατέληξαν σε διαφορετικά αποτελέσματα. Να αναφέρουμε, ότι η παρατήρηση αυτή, παρουσιάζεται ακριβώς και στα αποτελέσματα πρόβλεψης του CTR που κάνουμε, κάτι το οποίο θα δούμε παρακάτω σε πιο μεγάλη ανάλυση.

**Πίνακας 2 :** Λεπτομερής παρουσίαση των χαρακτηριστικών όλων των αρχείων. Οι στήλες με \* εμφανίζονται μόνο στα impression/click/conversion log αλλά όχι στο bidding log.

<b>Στήλη</b>	<b>Περιγραφή</b>	<b>Παράδειγμα</b>
1	Bid ID	015300008...3f5a4f5121
2	Χρονική σφραγίδα	20130218001203638
*3	Log type	1
4	iPinYou ID	35605620124122340227135
5	User-Agent	Mozilla/5.0 (compatible; MSIE 9.0; Windows NT 6.1; WOW64; Trident/5.0)
6	IP	118.81.189.*
7	Region - Περιοχή	15
8	City - Πόλη	16
9	Ad exchange	2
10	Domain	e80f4ec7...c01cd1a049
11	URL	hz55b00000...3d6f275121
12	Anonymous URL ID	Null
13	Ad Slot ID	2147689 8764813
14	Ad Slot width - Μήκος διαφήμισης	300
15	Ad Slot height - Ύψος διαφήμισης	250
16	Ad Slot visibility	SecondView
17	Ad Slot format	Fixed
18	Ad Slot floor price	0
19	Creative ID	e39e178ffd...1ee56bcd
20	Bidding price	753
*21	Paying price	15
*22	Key page URL	a8be178ffd...1ee56bcd
23	Advertiser ID - Αναγνωριστικό διαφημιστή	2345

24	User Tags - Ετικέτες χρήστη	123,5678,3456
----	-----------------------------	---------------

- (c01) Το Bid ID, που είναι το μοναδικό αναγνωριστικό κάθε εγγραφής.
- (c02) Χρονική σφραγίδα της δημοπρασίας, στη μορφή: yyyyMMddHHmmssSSS 3 .
- (c03) Ο τύπος του αρχείου, όπου μπορεί να είναι: 1 (impression), 2 (click), και 3 (conversion).
- (c04) Το εσωτερικό αναγνωριστικό χρήστη που έδωσε το iPinYou.
- (c05) Αυτό το χαρακτηριστικό περιγράφει τη συσκευή, λειτουργικό της σύστημα και φυλλομετρητή(browser) του χρήστη.
- (c10) Το domain της ιστοσελίδας όπου θα πήγαινε η διαφήμιση.
- (c11) Το URL της ιστοσελίδας όπου θα πήγαινε η διαφήμιση.
- (c12) Όταν το URL, δεν είναι διαθέσιμο, χρησιμοποιείται αυτό στη θέση του.
- (c16) Περιγράφει τη θέση της διαφήμισης, που μπορεί να είναι : (“FirstView”) ή (“SecondView” μέχρι “TenthView”), ή άγνωστη (“Na”).
- (c17) Η μορφή της διαφήμισης, που μπορεί να είναι: “Fixed” (σταθερή θέση και μέγεθος), “Pop” (pop-up window), “Background”, “Float” και άγνωστη (“Na”).
- (c18) Floor price για τη συγκεκριμένη διαφήμιση.
- (c20) Η τιμή πονταρίσματος του iPinYou, για αυτή τη διαφήμιση.
- (c21) Η τιμή πληρωμής, είναι η ψηλότερη τιμή πονταρίσματος από τους ανταγωνιστές. Αν αυτή η τιμή είναι πιο ψηλή από τη νικητήρια τιμή της δημοπρασίας τότε θα εμφανιστεί η εγγραφή αυτή στο impression log.
- (c24) User tags που έχει φτιάξει η iPinYou, για να περιγράψει τις πληροφορίες χρηστών.

**Criteo:** Η Criteo, είναι και αυτή μια τεράστια διαφημιστική εταιρεία που προσφέρει υπηρεσίες από όλο το οικοσύστημα του RTB. Μέσω το Kaggle (διαδικτυακή κοινότητα – πλατφόρμα, μηχανικών δεδομένων, που φιλοξενεί και διαγωνισμούς μηχανικής μάθησης), η Criteo, διοργάνωσε διαγωνισμό για αλγόριθμους πρόβλεψης CTR το 2014. Παρόμοια με την iPinYou, μετά το τέλος του διαγωνισμού, δημοσίευσε το dataset της στο ευρύ κοινό.

Τα δεδομένα του συγκεκριμένου dataset, περιλαμβάνουν το αποτέλεσμα - label, 13 χαρακτηριστικά που είναι ακέραιοι αριθμοί και 26 χαρακτηριστικά που είναι κατηγορικά. Να ξεκαθαρίσουμε ότι δεν ξέρουμε πληροφορίες για το τι είναι το κάθε χαρακτηριστικό όπως στο iPinYou, καθώς δεν δημοσιεύτηκαν. Αυτό αποτελεί και ένα μειονέκτημα του συγκεκριμένου συνόλου, καθώς θα μπορούσε να γίνει καλύτερη ανάλυση και προεπεξεργασία των δεδομένων αν ξέραμε ακριβώς τι είναι κάθε χαρακτηριστικό.

Ενδιαφέρον να αναφέρουμε ότι, η ομάδα που νίκησε το διαγωνισμό ([\[Juan et al., 2016\]](#)), είναι τα ίδια άτομα όπου έγραψαν την βιβλιοθήκη για FFM (libFFM) και αυτή η μέθοδος είναι ο λόγος που νίκησαν το συγκεκριμένο διαγωνισμό.

Κάνουμε χρήση και αυτού του dataset , για λόγους περαιτέρω σύγκρισης αποτελεσμάτων. Η προεπεξεργασία που ακολουθούμε είναι αυτή που ανακοίνωσαν οι νικητές του διαγωνισμού. Να σημειώσουμε ότι οι δοκιμές σε αυτό το dataset περιορίζονται μόνο στη μηχανή παραγοντοποίησης κυρίως για να δείξουμε τη αποτελεσματικότητα της και την ευκολία στη χρήση της.

Για εκπαιδευτικούς λόγους αλλά και για πληρότητα, αναφέρουμε επιπρόσθετα dataset που υπάρχουν αλλά δεν χρησιμοποιήθηκαν στη παρούσα διπλωματική εργασία για πρόβλεψη CTR και αποτελούν πιθανά dataset για επεκτάσεις – δοκιμές των αλγορίθμων μας

**Avazu:** Διαφημιστική εταιρεία, όπου μέσω διαγωνισμού στο Kaggle έβγαλε το dataset. Το συγκεκριμένο αφορά μόνο διαφημίσεις κινητών τηλεφώνων (mobile ads).

**Outbrain :** Διαφημιστική εταιρεία που δημιούργησε διαγωνισμό μέσω Kaggle όπως πριν. Αφορά διαφημίσεις όλων των ειδών.

**Criteo Conversion Logs :** Η ίδια εταιρεία με πριν, Criteo, πρώτα δημοσίευσε αυτά τα αρχεία όπου, αντιπροσωπεύουν ένα κομμάτι της κίνησης σε διαφημίσεις που είχε. Συγκεκριμένα, τα αρχεία περιέχουν δεδομένα για μετατροπές – conversion αγαθών/υπηρεσιών.

**YOYI:** Η YOYI, είναι διαφημιστική εταιρεία στην Κίνα που τρέχει διαφημίσεις για όλες τις συσκευές. Να τονίσουμε, ότι το dataset που έδωσε στο κοινό, όπως το dataset της IPinYou, είναι πλήρες και μπορεί να χρησιμοποιηθεί για προσομοίωση όλων τα σταδίων του RTB διαφημίσεων.

## 6.3 Προβλήματα στα σύνολα δεδομένων

Τα συγκεκριμένα datasets που χρησιμοποιούμε, έχουν μερικά προβλήματα που επηρέασαν την εργασία μας. Αρχίζοντας, το IPinYou, έχει ελλιπή δεδομένα. Για παράδειγμα τα user tags, υπάρχουν μόνο σε μερικές εγγραφές δεδομένων. Πράγμα που μας αποτρέπει από το να φτιάξουμε ένα ενιαίο μοντέλο ή και να χρησιμοποιήσουμε όλες τις εγγραφές για εκπαίδευση των μοντέλων, όπως θα εξηγήσουμε στο επόμενο κεφάλαιο. Ένας πιθανός λόγος πίσω από την απουσία αυτών των δεδομένων σε μερικές εγγραφές, είναι ότι δεν είχε γίνει profile για αυτό το χρήστη από το IPinYou.

Άλλο ένα θέμα που αντιμετωπίζουμε στο dataset του IPinYou αλλά και γενικότερα σε τέτοια δεδομένα (για πρόβλεψη CTR) είναι ο μικρός αριθμός θετικών στιγμιότυπων, δηλαδή εγγραφών, όπου το αποτέλεσμα να είναι κλικ. Όπως αναφέραμε και πριν, δημιουργώντας μοντέλα με τέτοια δεδομένα, παράγονται και τα ανάλογα αποτελέσματα. Δηλαδή, αποτελέσματα που είναι προκατειλημμένα προς το να μην γίνει κλικ. Μερικοί μέθοδοι έχουν προταθεί ([Wu & Chen, 2013],[Zhang et al., 2016] ) για να λυθεί αυτό το πρόβλημα αλλά το ιδανικό θα ήταν να είχαμε σωστότερα δεδομένα, δηλαδή ισοζυγισμένο dataset. Στο dataset του Criteo, οι [Qu, Fang, et al., 2017] λόγω του τεράστιου όγκου δεδομένων και του μικρού αριθμού θετικών στιγμιότυπων (3%), έκαναν υποδειγματοληψία

(undersampling). Έτσι κράτησαν το ποσοστό των θετικών στιγμιότυπων κοντά στο 50% και άρα αντιμετωπίστηκε το θέμα αυτό.

Ένα θέμα που υπάρχει με τα δεδομένα του Criteo, είναι ότι τα χαρακτηριστικά που μας δίνουν είναι ανώνυμα. Εν ολίγοις, απλά αναφέρεται ότι είναι 13 στήλες από ακέραιους αριθμούς και 26 στήλες, από κατηγορικά χαρακτηριστικά, χωρίς να μας λένε περισσότερες πληροφορίες για αυτά. Γνωρίζοντας όμως, τι είναι ακριβώς κάθε χαρακτηριστικό μπορείς να οργανώσεις καλύτερα το μοντέλο και σε μερικά να δώσεις είτε περισσότερο είτε λιγότερο ή και καθόλου βάρος, εάν δεν είναι χρήσιμα. Το πιο πιθανό, αυτό να το κάνουν για λόγους ανωνυμίας αλλά και για να κρατήσουν τον ανταγωνισμό στο σκοτάδι. Δεν δημοσιεύουν τα δεδομένα που χρησιμοποιούν για τη δημιουργία των μοντέλων τους, για να μπορούν να ξεπερνούν έτσι τον ανταγωνισμό.

Όλοι συμφωνούμε, ότι είναι λογικό να μην μπορούμε να βρούμε τέλεια δεδομένα δωρεάν στο διαδίκτυο. Όπως αναφέραμε και πριν, στη σημερινή εποχή τα δεδομένα είναι δύναμη και η δύναμη δεν παρέχεται σε κανέναν φθηνά.

## Κεφάλαιο 7

# Υλοποίηση αλγορίθμου πρόβλεψης του CTR

## 7.1 Εισαγωγικά

Είναι γνωστό ότι υπάρχουν πλέον πολλοί τρόποι να λύσουμε το πρόβλημα πρόβλεψης του CTR μιας διαφήμισης, όπως και έχουμε αναφέρει πριν. Διαλέξαμε να λύσουμε το πρόβλημα αυτό, χρησιμοποιώντας δύο μεθόδους που περιλαμβάνουν και οι δύο τις μηχανές παραγοντοποίησης (FM). Ο κύριος λόγος πίσω από αυτό είναι για να παρουσιάσουμε την αποδοτικότητα τους, την ευκολία χρήσης τους αλλά και για να αναδείξουμε τη σπουδαιότητα και δύναμη που φέρουν. Συνάμα, θέλουμε να τις προωθήσουμε σαν μια μέθοδο που έχει πολλά να προσφέρει στην επιστημονική και μη κοινότητα της μηχανικής μάθησης. Αναφέρουμε ενδεικτικά ότι αυτή η μέθοδος έχει ήδη χρησιμοποιηθεί αλλά με μια ελαφριά και όχι ολοκληρωμένη, υλοποίηση του αλγορίθμου. Εμείς κάνουμε χρήση του πλήρως υλοποιημένου αλγορίθμου μέσω της βιβλιοθήκης μηχανών παραγοντοποίησης, xLearn, για python.

## 7.2 Μοντέλα – μέθοδοι υλοποίησης

Η πρώτη μέθοδος αποτελείται εξ ολοκλήρου από τη μηχανή παραγοντοποίησης. Δηλαδή, αφού φέρουμε τα δεδομένα στη σωστή μορφή (libSVM), μέσω της προεπεξεργασίας, τα τροφοδοτούμε στο FM και παίρνουμε τα αποτελέσματα του CTR.

Να υπενθυμίσουμε ότι όσο αφορά το dataset IPinYou, πρακτικά το χωρίζουμε σε μικρότερα dataset για μελέτη, που το καθένα αντιστοιχεί σε ένα διαφημιστή. Συνολικά έχουμε 9 διαφημιστές, όπου για καθένα θα δημιουργήσουμε διαφορετικό μοντέλο πρόβλεψης CTR. Ο λόγος πίσω από αυτό το διαχωρισμό είναι ότι διαφημίσεις διαφορετικών εννοιολογικών πεδίων, έχουν σημαντική διαφορά στη συμπεριφορά απόκρισης του χρήστη. Αν φτιάχναμε ένα ενιαίο μοντέλο το πιο πιθανό είναι ότι θα είχαμε απλά μέτρια αποτελέσματα σε όλους τους διαφημιστές, καθώς το μοντέλο θα μάθαινε από τα δεδομένα όλων. Αντίθετα, με αυτό το τρόπο, φτιάχνουμε μοντέλα πιο εύχρηστα, πιο στοχευμένα προς τις ανάγκες των χρηστών αλλά και ανθεκτικά σε λάθη. Αναφέρουμε επίσης για να είμαστε πλήρως ξεκάθαροι, ότι η μηχανή παραγοντοποίησης κατασκευάζει ένα  $k$ -διάστατο διάνυσμα για κάθε χαρακτηριστικό και με τη χρήση των μεθόδων μάθησης, το προσαρμόζει στα δεδομένα όπως αναφέραμε πριν.



Για να πάρουμε το τελικό αποτέλεσμα της πρόβλεψης χρησιμοποιούμε το τύπο (5.1), δηλαδή :

$$\hat{y}(x) = w_0 + \sum_{i=1}^p w_i x_i + \sum_{i=1}^p \sum_{j=i+1}^p \langle v_i, v_j \rangle x_i x_j$$

Για λόγους που θα γίνουν κατανοητοί αργότερα, θα χωρίσουμε τα δεδομένα μας σε δύο ομάδες. Η διαφορά των δύο ομάδων είναι ότι η μία, δεν θα έχει στα χαρακτηριστικά εκπαίδευσης τα user tags. Πέρα από αυτό, θα κάνουμε όλη τη διαδικασία που περιγράψαμε πριν και στις δύο ομάδες. Λογικά περιμένουμε να δούμε διαφορετικά αποτελέσματα για κάθε ομάδα, με την ομάδα με user tags, να έχει καλύτερα. Αυτό είναι λογικό επόμενο, δεδομένης της ατομικής στόχευσης που έχουμε αναφέρει. Αρκεί να επαληθευτεί και πειραματικά.

Η δεύτερη μέθοδος είναι εξέλιξη της πρώτης, με τη χρήση νευρωνικών δικτύων. Όπως είπαμε, λόγω της διάστασης των δεδομένων και των χαρακτηριστικών (937,748 διαφορετικά χαρακτηριστικά) είναι σχεδόν αδύνατο να τα εισάγουμε απευθείας σε νευρωνικό δίκτυο. Για το λόγο αυτό χρησιμοποιήσαμε ένα embedding layer, που στη περίπτωση μας είναι η μηχανή παραγοντοποίησης. Έτσι παρακάμπτουμε το πρόβλημα της μεγάλης διάστασης των δεδομένων. Αυτά τα επίπεδα, πέρα από τη μείωση διάστασης συνήθως αποτελούν και μια καλή αρχικοποίηση των εισόδων του νευρωνικού.

Η χρήση νευρωνικού δικτύου, κρίνεται επιτακτική καθώς η μηχανή παραγοντοποίησης που χρησιμοποιούμε δεν μπορεί να υπολογίσει αλληλεπιδράσεις μεταξύ περισσότερων από δύο χαρακτηριστικών-μεταβλητών. Η βιβλιοθήκη που έχουμε διαλέξει αλλά και οι υπόλοιπες υπάρχουσες, δεν έχουν υλοποιήσει το μοντέλο για αλληλεπιδράσεις υψηλότερων τάξεων. Αυτό δεν είναι καθόλου τυχαίο, καθώς αν και το μοντέλο θεωρητικά μπορεί να υπολογιστεί σε γραμμικό χρόνο, οι αλληλεπιδράσεις αυτές, ειδικά σε αραιό χώρο δεδομένων είναι δύσκολο να υπολογιστούν. Ακόμη ένα πρόβλημα, είναι ότι λόγω της μικρής - χαμηλής εκφραστικότητας τους, οι FM, δε μπορούν να μοντελοποιήσουν πολύπλοκα μοτίβα που τα δεδομένα μπορεί να κρύβουν. Εδώ είναι όπου τα βαθιά νευρωνικά μπορούν να βοηθήσουν. Τα βαθιά νευρωνικά έχουν την ικανότητα να ανακαλύπτουν νέα και όλο και πιο περίπλοκα μοτίβα από τα δεδομένα μας. Ταυτόχρονα μπορούν να εξάγουν αλληλεπιδράσεις μεταξύ των χαρακτηριστικών υψηλών τάξεων. Όλα αυτά κάνουν το συνδυασμό αυτών των δύο μεθόδων, ικανό για τη μελέτη των πολύπλοκων σχέσεων που ενυπάρχουν στα δεδομένα, για πρόβλεψη του CTR διαφημίσεων.

Σε αντίθεση με τη χρήση δύο ομάδων δεδομένων πριν, τώρα θα χρησιμοποιήσουμε μόνο αυτή χωρίς τα user tags. Αρχικά να πούμε ότι στο νευρωνικό που φτιάχνουμε χρειαζόμαστε διάνυσμα εισόδου σταθερού μήκους. Ο λόγος που δεν μπορούμε να φτιάξουμε είσοδο σταθερού μήκους με τη χρήση στα δεδομένα και των user tags, είναι τα ελλιπή δεδομένα. Ο τρόπος που κατασκευάζεται αυτό το διάνυσμα, είναι συνθέτοντας τα χαρακτηριστικά μιας εγγραφής. Από τη μηχανή παραγοντοποίησης, έχουμε ήδη υπολογίσει ένα διάνυσμα για κάθε χαρακτηριστικό. Έτσι, κοιτάζοντας τι χαρακτηριστικά έχει κάθε εγγραφή, μπορούμε ενώνοντας το διάνυσμα κάθε χαρακτηριστικού να φτιάξουμε ένα μεγαλύτερο διάνυσμα που αντιστοιχεί στην εγγραφή αυτή. Για να γίνουμε πιο κατανοητοί, να πούμε ότι όσα χαρακτηριστικά χρησιμοποιούνται για να συνθέσουμε το διάνυσμα εισόδου του νευρωνικού, πρέπει να υπάρχουν σίγουρα σε κάθε εγγραφή. Όμως τα χαρακτηριστικά που αντιστοιχούν σε user



tags, δεν εμφανίζονται τόσο συχνά στις εγγραφές και άρα δεν μπορούμε να τα υιοθετήσουμε μόνιμα στο διάγραμμα εισόδου.

Επιπλέον κατά τη διαδικασία εκπαίδευσης των βαρών των συνδέσεων, επανεκπαιδευόμε και τα διανύσματα κάθε χαρακτηριστικού, που προέκυψαν από τη μηχανή παραγοντοποίησης. Ένας λόγος για αυτή την επανεκπαίδευση, είναι ότι τα συγκεκριμένα διανύσματα είχαν τέτοιες τιμές ώστε να είναι κατάλληλα για το μοντέλο του FM και όχι του νευρωνικού. Πρακτικά, τα τροποποιούμε για να αντιδρούν κατάλληλα στο μοντέλο - συνδέσεις, του νευρωνικού δικτύου.

Είναι γεγονός, ότι αυτός δεν ήταν ο μόνος λόγος που μας ώθησε να φτιάξουμε δύο ομάδες δεδομένων για χρήση στη μηχανή παραγοντοποίησης. Ειδικότερα, αυτή η προσέγγιση μας επιτρέπει να κάνουμε καλύτερη σύγκριση με άλλους αλγόριθμους, έχοντας μια πιο γενική γνώση των επιδόσεων στα αποτελέσματα μας. Παράλληλα, μπορούμε να παρατηρήσουμε τη σπουδαιότητα και δύναμη που κρύβουν τα συγκεκριμένα χαρακτηριστικά - user tags. Ειδικά στο συγκεκριμένο πρόβλημα, όπου η δημιουργία ατομικών profile για κάθε χρήστη και η στόχευση στα ενδιαφέροντα τους είναι κρίσιμο συστατικό για ένα καλό εργαλείο πρόβλεψης CTR.

Σαν τελική σημείωση, να πούμε ότι οι [Ta, 2015], χρησιμοποίησαν μόνο τους παράγοντες αλληλεπιδράσεις  $V$  για να πάρουν τις προβλέψεις για ένα διάνυσμα εισόδου. Στη πράξη ωστόσο, είδαμε ότι προσθέτοντας και τις αλληλεπιδράσεις με την είσοδο κάθε μεταβλητής,  $w$ , είχαμε καλύτερη απόδοση στα νευρωνικά και έτσι διαλέξαμε αυτό το μοντέλο.

## 7.3 Παράμετροι βελτιστοποίησης

Οι παράμετροι βελτιστοποίησης που είχαμε ήταν πέντε. Οι δύο είναι ίδιοι τόσο για τη μηχανή παραγοντοποίησης αλλά και για το νευρωνικό δίκτυο. Πιο συγκεκριμένα, το πρώτο, είναι ο ρυθμός μάθησης των βαρών τόσο του νευρωνικού και του FM αλλά και των λανθανόντων παραγόντων του FM. Το δεύτερο κοινό, είναι ο αριθμός των εποχών εκπαίδευσης κάθε μοντέλου. Η τρίτη παράμετρος, που χρησιμοποιείται μόνο στη βελτιστοποίηση της μηχανής παραγοντοποίησης, είναι ο αριθμός των λανθανόντων παραγόντων του διανύσματος χαρακτηριστικού, όπου είχαμε ορίσει προηγουμένως. Επίσης πάλι μόνο στο FM, έχουμε τη παράμετρο κανονικοποίησης λάμδα της νόρμας L2. Στο νευρωνικό αν και θα μπορούσαμε να κάνουμε χρήση της ίδιας κανονικοποίησης L2, σύμφωνα με το [Wang et al., 2016], η χρήση του dropout - περιορισμός ενεργοποίησης, δίνει καλύτερα αποτελέσματα και έτσι αυτή επιλέξαμε.

Ο ρυθμός μάθησης  $\eta$ , καθορίζει το πόσο μεγάλες ή μικρές θα είναι οι διακυμάνσεις στις τιμές των βαρών ή λανθάνων παραγόντων. Συνήθεις τιμές είναι κοντά στο 0.1 . Η κανονικοποίηση L2, όπως εξηγήσαμε, χρησιμοποιείται στη προσπάθειά μας να αποφύγουμε την υπερπροσαρμογή του μοντέλου μας στα δεδομένα εκπαίδευσης. Η παράμετρος λάμδα συγκεκριμένα, καθορίζει την ισχύ της επίδρασης του όρου της κανονικοποίησης στις τιμές των αντίστοιχων παραμέτρων. Αντίστοιχα, αυτό που κάνει το dropout, είναι να απενεργοποιεί τυχαία κάποιους νευρώνες του δικτύου και μαζί κάθε εξερχόμενη/εισερχόμενη σύνδεση, με πιθανότητα  $p$ , όπου είναι και η παράμετρος προς

βελτιστοποίηση. Αυτός ο τρόπος αποτρέπει τις συνδέσεις - βάρη των νευρώνων να υπερπροσαρμόζονται όπως αναφέρει το [\[Sutskever et al., 2014\]](#).

Για τη βελτιστοποίηση των παραμέτρων, στη μηχανή παραγοντοποίησης, κάναμε εκτενή προσπάθεια και έρευνα σε μεγάλο εύρος τιμών. Συγκεκριμένα, για το ρυθμό μάθησης, κινηθήκαμε από  $\eta=0.00001$  μέχρι  $\eta=1$ , για τη παράμετρο κανονικοποίησης λάμδα, από  $\lambda=0.0001$  μέχρι  $\lambda=0.5$  και για τον αριθμό λανθάνων παραγόντων, αρχίσαμε από  $k=20$  και φτάσαμε μέχρι  $k=200$ . Μετά το όριο των 200 παραγόντων ανά διάνυσμα, το μοντέλο γινόταν υπερβολικά μεγάλο και η εκπαίδευση δεν ήταν βατή. Επιπλέον, ο στόχος της χρήσης της μηχανής παραγοντοποίησης είναι η αναπαράσταση των δεδομένων σε ένα χώρο χαμηλής διάστασης, κρίνοντας τέτοια μοντέλα με τόσο μεγάλο αριθμό απαγορευτικά.

Όσο αφορά, τη βελτιστοποίηση των παραμέτρων του νευρωνικού δικτύου, λόγω περιορισμών υπολογιστικών πόρων και χρονικών ορίων, δεν έγιναν δοκιμές σε όλους τους διαφημιστές και όλο το εύρος. Βελτιστοποίηση έγινε στους μισούς διαφημιστές του IpinYou (1458, 2259, 2261, 2997, 3358, 3476) , για να ελέγξουμε αν όντως η βελτιστοποίηση επιφέρει σημαντική βελτίωση στα αποτελέσματα πρόβλεψης του CTR. Πιο συγκεκριμένα, δοκιμάστηκαν ρυθμοί μάθησης από  $\eta=0.0001$  μέχρι  $\eta=0.1$ . Αυτή είναι μια σημαντική παράλειψη, που ίσως μελλοντικά, επιφυλάσσει καλύτερα αποτελέσματα από αυτά που έχουμε τώρα, όσο αφορά τους διαφημιστές του IPinYou που δεν βελτιστοποιήσαμε. Αυτό ισχύει, καθώς δεν έχουμε ψάξει σε όλο το χώρο λύσεων για τη βέλτιστη επιλογή παραμέτρων και κάπου μπορεί να υπάρχει μια μαγική τομή όπου βελτιώνει κατά πολύ τα αποτελέσματα. Το ίδιο έγινε και για τη παράμετρο του dropout, όπου ορίστηκε, όπως προτείνεται στο  $p=0.5$  για τους διαφημιστές που δεν βελτιστοποιήσαμε. Για τους υπόλοιπους, δοκιμάσαμε από  $p=0.4$  έως  $p=0.6$ . Περαιτέρω, να αναφέρουμε για λόγους πληρότητας ότι σαν συνάρτηση ενεργοποίησης των νευρώνων του δικτύου, χρησιμοποιήθηκε η υπερβολική εφαιπτομένη-tanh, καθώς κρίθηκε σαν η καταλληλότερη από τους [\[Wang et al., 2016\]](#) και [\[Qu, Fang, et al., 2017\]](#). Κλείνοντας, να πούμε ότι χρησιμοποιήθηκαν 3 κρυφά επίπεδα, με μεγέθη (200,300,100) όπως και στο [\[Wang et al., 2016\]](#) καθώς βρήκαν ότι είναι ο βέλτιστος συνδυασμός για αυτό το πρόβλημα.

Αν και στη πραγματικότητα ο αριθμός των εποχών εκπαίδευσης θεωρείται σαν παράμετρος προς βελτιστοποίηση, δεν έχουμε δώσει ιδιαίτερη σημασία. Αυτό, καθώς χρησιμοποιούμε early stopping-πρόωρη διακοπή, στην εκπαίδευση του μοντέλου και αν διαλέξουμε ένα ικανοποιητικά μεγάλο αριθμό εποχών, θα εφαρμοστεί το early stopping σίγουρα. Ένας τέτοιος αριθμός είναι π.χ. epochs=200. Γενικότερα, η μέθοδος αυτή, ρυθμίζει αποτελεσματικά τον αριθμό των εποχών εκπαίδευσης.

## 7.4 Μετρικές αξιολόγησης αποτελεσμάτων

Κάνουμε χρήση δύο μετρικών για αξιολόγηση των αποτελεσμάτων μας αλλά και για να συγκρίνουμε με άλλους. Αυτές οι δύο είναι η AUROC-AUC και το μέσο τετραγωνικό σφάλμα - MSE. Η πρώτη δηλαδή, η περιοχή κάτω από τη καμπύλη χαρακτηριστικών - Area Under the Receiver

Operating Characteristics (AUROC), είναι η πιο συνηθισμένη μετρική για την αξιολόγηση της πρόβλεψης CTR διαφημίσεων.

Η AUROC, δείχνει την ικανότητα του μοντέλου να διακρίνει σωστά μεταξύ θετικών και αρνητικών παρατηρήσεων. Πιο συγκεκριμένα η περιοχή αυτή αναπαριστά το βαθμό διαχωρισιμότητας των κλάσεων, δηλαδή πόσο καλά το μοντέλο μπορεί να ξεχωρίσει τη κάθε κλάση(στη περίπτωση μας κλικ ή όχι κλικ). Όσο πιο ψηλό είναι το AUC, τόσο καλύτερα το μοντέλο ξεχωρίζει τις κλάσεις. Όταν η AUC, είναι κοντά στο 1, σημαίνει ότι το μοντέλο είναι σχεδόν τέλειο, ενώ όταν είναι κοντά στο 0.5 δεν μπορεί να ξεχωρίσει σε ποια κλάση ανήκει - επιλέγει σχεδόν τυχαία δηλαδή.

Το μέσο τετραγωνικό σφάλμα (Mean Squared Error) είναι και αυτό μια πολύ δημοφιλής μετρική. Αυτό που κάνει είναι να μετράει τη μέση απόκλιση των προβλέψεων μας. Για κάθε πρόβλεψη, βρίσκει τη τετραγωνική διαφορά μεταξύ της πρόβλεψης και του στόχου. Έπειτα, αθροίζει σε όλες τις προβλέψεις και βγάζει το μέσο όρο τους. Μια άλλη μετρική που βασικά είναι η ίδια είναι η RMSE, δηλαδή η τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος. Στη πράξη, αυτή τη μετρική αντί της MSE, χρησιμοποιούμε για τα αποτελέσματα μας. Ο τύπος της είναι :

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2} = \sqrt{MSE} \quad (7.1)$$

## 7.5 Προβλήματα κατά την υλοποίηση

Ένα από τα πιο σοβαρά προβλήματα που είχαμε είναι η έλλειψη υπολογιστικής δύναμης. Επίσης, τα σύνολα δεδομένων μας είναι μεγάλα (IPinYou 35GB), κάνοντας τη διαδικασία αυτή ακόμη πιο δύσκολη. Όχι μόνο τέτοια μεγέθη δεδομένων είναι δύσκολο να τα διαχειριστούμε αλλά και οι μέθοδοι που χρησιμοποιούμε είναι αρκετά πολύπλοκες και δαπανηρές από άποψη υπολογιστικής ισχύς. Για παράδειγμα η εκπαίδευση του νευρωνικού δικτύου είναι μια πολύπλοκη διαδικασία που περιέχει τις φάσεις τόσο εμπρόσθιας αλλά και οπίσθια διάδοσης σφάλματος (back propagation), υπολογιστικά δαπανηρές.

Να αναφέρουμε ότι οι πλείστες προσομοιώσεις, έγιναν σε υπολογιστή με 6GB μνήμης RAM με 4 πυρήνες. Επίσης, οι προσομοιώσεις για βελτιστοποίηση που ήταν πιο υπολογιστικά δαπανηρές έγιναν στο server του εργαστηρίου με 64GB RAM και 16 πυρήνες. Λόγω του ότι δεν είχαμε συνεχή πρόσβαση στο μηχάνημα του εργαστηρίου, δεν βελτιστοποιήσαμε όλες τις παραμέτρους. Για λόγους σύγκρισης, να πούμε ότι οι νικητές του διαγωνισμού του Criteo στο Kaggle, είπαν ότι χρειάζεσαι τουλάχιστον 40GB, για να τρέξεις ένα FFM μοντέλο σε αυτά τα δεδομένα, οπότε καταλαβαίνεται τις δυσκολίες που είχαμε να αντιμετωπίσουμε. Τα δεδομένα για την εκπαίδευση ήταν πολλές φορές περισσότερα από αυτά που χωρούσε η RAM και έτσι μεγάλος υπολογιστικός χρόνος αναλωνόταν στη είσοδο/έξοδο δεδομένων από και προς τη RAM, αντί να κάνει χρήσιμους υπολογισμούς. Για αυτούς

τους λόγους, δεν ήταν δυνατή η πλήρης βελτιστοποίηση των παραμέτρων των νευρωνικών δικτύων για όλα τα δεδομένα μας, καθώς μόνο και μόνο μια επανάληψη όλης της διαδικασίας εκπαίδευσης του αλγορίθμου μπορούσε να κρατήσει μέχρι και μέρες.

Για καλή μας τύχη, τα δεδομένα του IPinYou, μπορούσαμε να τα χωρίσουμε σε διαφημιστές και έτσι να φτιάξουμε μικρότερα σύνολα δεδομένων που βγάζουν νόημα. Αυτό μας βοήθησε εν μέρη στην εκπαίδευση. Απεναντίας, στο Criteo, καθώς κάτι τέτοιο δεν μπορούσαμε να κάνουμε, είχαμε ένα τεράστιο σύνολο και εκπαίδευσης και δοκιμής. Ήταν αδύνατο να κτίσουμε τη μηχανή παραγοντοποίησης με αυτό το σύνολο εκπαίδευσης και έτσι απλά σπάσαμε το σύνολο δεδομένων σε μικρότερα κομμάτια των 2-3 GB δεδομένων. Έπειτα για να εκπαιδεύσουμε το μοντέλο, χρησιμοποιήσαμε το online learning, που παρέχει η βιβλιοθήκη xLearn και έτσι χρησιμοποιώντας όλα τα δεδομένα εκπαιδεύσαμε τελικά το μοντέλο. Αντίστοιχα, για να μπορέσουμε να ελέγξουμε όλα τα δεδομένα δοκιμής, τα σπάσαμε σε μικρά κομμάτια και κάναμε τις προβλέψεις ξεχωριστά και μετά ανασυνθέσαμε τα αποτελέσματα. Για τους ίδιους λόγους δεν δημιουργήσαμε καν μοντέλο για νευρωνικά δίκτυα, καθώς η εκπαίδευση του δεν ήταν υπολογιστικά βατή. Σε μελλοντικές προσπάθειες ελπίζουμε να ξεπεράσουμε τα προβλήματα αυτά.

# Κεφάλαιο 8

## Αποτελέσματα και αξιολόγηση

### 8.1 Γενικά

Έχουμε εξηγήσει, αναλύσει και δικαιολογήσει όλες τις σχεδιαστικές επιλογές που έχουμε κάνει. Σε αυτό το κεφάλαιο παρουσιάζουμε τα αποτελέσματα από τις προσομοιώσεις για όλα τα μοντέλα που έχουμε υλοποιήσει και τα σύνολα δεδομένων που χρησιμοποιούμε. Συνάμα, παρουσιάζουμε αποτελέσματα και άλλων μεθόδων για να έχουμε κάποια βάση να συγκρίνουμε αλλά και να δούμε πόσο καλά είναι τα δικά μας αποτελέσματα, σε σχέση με τις τελευταίες εξελίξεις στο τομέα του RTB.

Όπως αναφέραμε, οι μετρικές που χρησιμοποιούμε για αξιολόγηση είναι η AUROC και το RMSE. Παρόλα αυτά θα δώσουμε περισσότερη βαρύτητα στην πρώτη. Ο λόγος πίσω από αυτό κρύβεται στην μεγάλη ανισορροπία θετικών και αρνητικών στιγμιότυπων των δεδομένων. Τα αρνητικά στιγμιότυπα, μπορούμε να πούμε ότι σπρώχνουν την πρόβλεψη κοντά στο 0, και έτσι το RMSE έχει πολύ μικρή τιμή. Λόγω αυτής της μικρής τιμής, ακόμη μικρότερες θα είναι και οι αλλαγές που θα βλέπουμε στα αποτελέσματα.



### 8.2 Αποτελέσματα μηχανής παραγοντοποίησης

Πρώτα θα κάνουμε μια ανάλυση συγκριτικά με τον αριθμό των λανθανόντων παραμέτρων στο διάλυμα της μηχανής παραγοντοποίησης. Θα εξετάσουμε αν χρησιμοποιώντας μεγαλύτερο αριθμό, παίρνουμε και την ανάλογη βελτίωση στη απόδοση. Στα πιο κάτω σχεδιαγράμματα, παρουσιάζονται γραφικές για όλους τους διαφημιστές, τόσο με μετρική τη AUC ([σχήμα 8.1](#)) όσο και με την RMSE ([σχήμα 8.2](#)), σε σχέση με τον αριθμό λανθανόντων παραμέτρων  $k$ .



Ξεκινήσαμε τις μετρήσεις μας, με το  $k$ , να ξεκινά από 20 και να φτάνει μέχρι 200. Πιο συγκεκριμένα, πήραμε αποτελέσματα για τις μετρικές, για  $k=\{20,40,60,100,200\}$ . Υπενθυμίζουμε, ότι για τη μετρική AUC, θέλουμε να είναι όσο πιο κοντά στο 1, ενώ για τη RMSE όσο πιο μικρή γίνεται. Όπως παρατηρούμε δεν υπάρχει κάποια σαφής ένδειξη ότι αυξάνοντας τον αριθμό των παραμέτρων, έχουμε και καλύτερα αποτελέσματα. Αντιθέτως βλέπουμε ότι είναι σχεδόν τυχαίο, αν το μοντέλο είναι καλύτερο ή χειρότερο σε σχέση το  $k$ . Το αποτέλεσμα αυτό, μας προϊδεάζει ότι έχουμε περάσει το όριο των παραγόντων όπου το μοντέλο βελτιώνεται με την αύξηση των παραγόντων. Πιο συγκεκριμένα, με  $k=20$ , έχουμε αρκετά καλά αποτελέσματα και άρα το μοντέλο δεν χρειάζεται μεγαλύτερο αριθμό για να μάθει την αναπαράσταση της εισόδου. Άρα στη περίπτωση μας, αφού μετά από  $k=20$ , η αύξηση του αριθμού των παραγόντων δεν επιφέρει ιδιαίτερη έως καθόλου βελτίωση, δεν χρειάζονται περισσότεροι

παράγοντες. Για αυτό το λόγο για τη βελτιστοποίηση του νευρωνικού δικτύου κρατάμε τα μοντέλα όλων των διαφημιστών με  $k=20$ . Εκτός από το γεγονός ότι η αύξηση των παραγόντων δεν επιφέρει βελτίωση να μην ξεχνάμε ότι έτσι φτιάχνουμε μοντέλα μικρότερου μεγέθους. Κρατώντας χαμηλό  $k$ , οι προσομοιώσεις μας δεν θα είναι πολύ δαπανηρές, γλιτώνοντας τόσο υπολογιστική ισχύ αλλά και χρόνο.

Σχήμα 8.1: Εδώ φαίνονται μερικά από τα αποτελέσματα για τη μετρική AUC, των προσομοιώσεων για κάθε διαφημιστή σε σχέση με τον αριθμό των λανθάνων παραμέτρων του IriπYou, όπου παρατηρείται μια σχετική βελτίωση. Όλες οι γραφικές για την AUC, βρίσκονται στο [παράρτημα Α](#).



Σχήμα 8.2 : Εδώ φαίνονται μερικά από τα αποτελέσματα για τη μετρική  $RMSE$ , των προσομοιώσεων για κάθε διαφημιστή του  $IPinYou$ , σε σχέση με τον αριθμό των λανθάνων παραγόντων της  $FM$ . Οι υπόλοιπες γραφικές για τους διαφημιστές, βρίσκονται στο [παράρτημα Β](#).



Παίρνοντας σαν δεδομένο, ότι με  $k=20$ , η μηχανή παραγοντοποίησης μαθαίνει όλη τη πληροφορία που μπορεί από τα δεδομένα που κατέχουμε, συνεχίζουμε με τις προσομοιώσεις μας. Όπως αναφέραμε, για το IPinYou dataset, χωρίσαμε τα δεδομένα σε δύο ομάδες. Η μια ομάδα περιείχε στα χαρακτηριστικά της και τα user tags, ενώ η άλλη όχι. Στο [πίνακα 8.1](#) φαίνονται τα αποτελέσματα των δύο ομάδων. Όπως παρατηρούμε, τα αποτελέσματα της ομάδας με τα user tags, είναι πολύ καλύτερα από αυτής χωρίς. Πιο συγκεκριμένα, στους διαφημιστές 1458, 3358, 3427 και 3476 υπάρχει μια αύξηση τις τάξης του 20% στις τιμές της AUC. Στους υπόλοιπους διαφημιστές, τα αποτελέσματα παραμένουν περίπου στην ίδια κλίμακα, χωρίς σημαντικές αποκλίσεις. Παρόμοια είναι τα αποτελέσματα και για τη μετρική RMSE. Στους ίδιους διαφημιστές υπήρξε σχετικά, “σημαντική” μείωση ενώ οι υπόλοιποι διατηρήθηκαν στα ίδια επίπεδα.

Μέσω αυτής της σύγκρισης, γίνεται ξεκάθαρη η δύναμη που κρύβουν αυτά τα χαρακτηριστικά. Όπως προβλέψαμε, αποτελούν πολύ σημαντικά στοιχεία για τη πρόβλεψη του CTR. Ειδικά στο συγκεκριμένο πρόβλημα, η κατοχή και χρήση τέτοιων πληροφοριών είναι ζωτικής σημασίας για τη δημιουργία profile των χρηστών. Αυτά τα χαρακτηριστικά θα μας αναδείξουν το χαρακτήρα του χρήστη και τις ανάγκες που έχει. Ας μη ξεχνάμε, ότι εάν σε ένα χρήστη έρθει μια διαφήμιση για κάτι που όντως χρειάζεται, είναι λογικό να κάνει κλικ. Έτσι όσο πιο εξατομικευμένες και στοχευμένες στο κάθε χρήστη, είναι οι διαφημίσεις που μπορούμε να κάνουμε τόσο περισσότερα κλικ μπορούμε να αποκτήσουμε.

*Πίνακας 8.1 : Αποτελέσματα προσομοίωσης για τις δύο ομάδες χαρακτηριστικών, με  $k=20$ . Με έντονο-**bold**, συμβολίζονται οι μεγάλες αυξήσεις τάξης ~20% στο AUC.*

Διαφημιστές	Ομάδα χωρίς user tags		Ομάδα με user tags	
	AUC	RMSE	AUC	RMSE
1458	0.7021	0.02892	<b>0.982</b>	0.028513
2259	0.6945	0.017664	0.690	0.017654
2261	0.6474	0.016894	0.651	0.016818
2821	0.624	0.023891	0.632	0.023885
2997	0.613	0.058163	0.613	0.058166
3358	0.8046	0.029334	<b>0.980</b>	0.029079
3386	0.7923	0.028507	0.780	0.028505
3427	0.7456	0.026081	<b>0.966</b>	0.025965
3476	0.687	0.023393	<b>0.964</b>	0.023362



Για το σύνολο δεδομένων του Criteo, καθώς δεν υπήρχαν καθόλου θετικά γεγονότα στο σύνολο ελέγχου του, αποφασίσαμε να χρησιμοποιήσουμε και ένα κομμάτι του συνόλου εκπαίδευσης για να υπάρχει καλύτερη ισορροπία. Για το λόγο αυτό τα αποτελέσματά μας, δεν είναι τόσο καλά όσο των υπολοίπων όπου έχουν κάνει υποδειγματοληψία για να είναι ισορροπημένο το dataset.

Πίνακας 8.2 : Αποτελέσματα προσομοίωσης πολλών μοντέλων για σύγκριση με το δικό μας FM (xLearn) για το dataset Criteo <sup>7</sup>

Μοντέλο	FM (xLearn)	FM ([Wang et al., 2016])	LR	FNN ([Wang et al., 2016])	CCPM	IPNN	OPNN
AUC	0.7366	0.7220	0.7148	.7566	0.7671	0.7779	0.7754

Το μοντέλο CCPM έχουν φτιάξει οι [Liu et al., 2016] και τα IPNN (εσωτερικό γινόμενο), OPNN (εξωτερικό γινόμενο) αποτελούντα μοντέλα γινομένων αντί πρόσθεσης των [Qu et al., 2017], που αναφέραμε και προηγουμένως.

### 8.3 Αποτελέσματα μηχανής παραγοντοποίησης με νευρωνικά δίκτυα – FNN

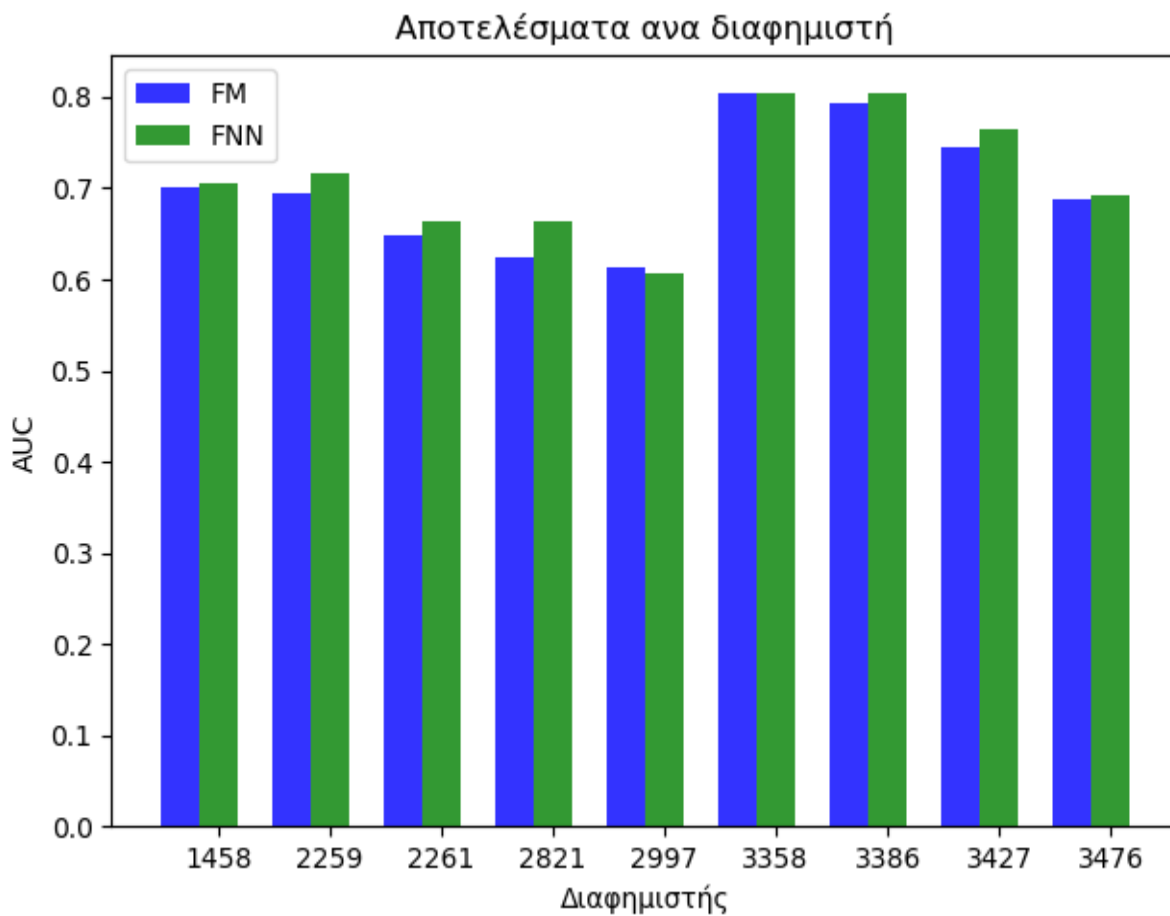
Στη συνέχεια, παρουσιάζουμε τα αποτελέσματα, της ενοποιημένης μεθόδου της μηχανής παραγοντοποίησης με το νευρωνικό δίκτυο. Η μέθοδος αυτή θα αναφέρεται ως FNN (από το Factorization machine-FM και neural networks - NN), όπως είναι γνωστή στη κοινότητα του RTB. Η σύγκριση μεταξύ FNN και απλής μηχανής παραγοντοποίησης, φαίνεται στο [σχήμα 8.3](#). Όπως βλέπουμε, η μέθοδος αυτή έχει καλύτερα αποτελέσματα από τη μηχανή παραγοντοποίησης. Ωστόσο, αυτό που περιμέναμε, ήταν να είχε αρκετά καλύτερα αποτελέσματα από τα συγκεκριμένα που πήραμε.

Θα αναφέρουμε μερικούς λόγους που μπορεί να εξηγούν γιατί δεν ήταν ακόμη καλύτερα τα αποτελέσματά μας. Να αρχίσουμε λέγοντας, ότι τα αποτελέσματα δεν θεωρούνται κακά. Στη τελική, αθροιστικά μιλώντας, έχουμε βελτίωση της πρόβλεψης του CTR στους περισσότερους διαφημιστές (7/9 παρουσιάζουν αύξηση στο AUC). Το θέμα είναι ότι περιμέναμε να ήταν πολύ καλύτερα, καθώς θεωρητικά μπορούν να εξαγάγουν αλληλεπιδράσεις ανώτερης τάξης από του FM αλλά και γενικά να συλλάβουν πολύπλοκα μοτίβα στα δεδομένα. Πρώτα να υπενθυμίσουμε, ότι αυτά τα αποτελέσματα,


<sup>7</sup> Έγινε μόνο η προσομοίωση για τη δική μας FM, τα υπόλοιπα αποτελέσματα πάρθηκαν από το [Qu et al., 2017].

πιθανότατα να μην είναι τα καλύτερα που μπορούμε να πάρουμε με τη χρήση του νευρωνικού. Όπως αναφέραμε, δεν είχαμε τους υπολογιστικούς πόρους για να βελτιστοποιήσουμε πλήρως τις παραμέτρους εκπαίδευσης του νευρωνικού π.χ. ρυθμός μάθησης, για όλους τους διαφημιστές. Αυτή η βελτιστοποίηση, μπορεί να κρύβει αρκετή βελτίωση στα αποτελέσματα. Περαιτέρω, λόγω ότι δεν χρησιμοποιήσαμε τα user tags, σίγουρα περιορίσαμε το μοντέλο, καθώς όπως είδαμε, δίνουν σημαντική ώθηση στη πρόβλεψη του CTR. Συγκεκριμένα, οι αλληλεπιδράσεις αυτές μεταξύ των ετικετών του χρήστη, είναι που πιθανόν να δίνουν αυτή την ώθηση. Άρα η μη χρήση τους σε αυτό το μοντέλο, διαδραμάτισε εξαιρετικό ρόλο στα αποτελέσματα μας.

Σχήμα 8.3 : Αποτελέσματα AUC, για κάθε διαφημιστή για τις μεθόδους FM και FNN.



Σχήμα 8.4: Διαφορά αποτελεσμάτων ανά διαφημιστή στις μεθόδους FM και FNN. Η θετική διαφορά σημαίνει καλύτερο αποτέλεσμα από το FNN και αντίστοιχα χειρότερο η αρνητική.



Να αναφέρουμε ξανά εδώ ότι τόσο στα αποτελέσματα της μηχανής παραγοντοποίησης όσο και του βαθιού νευρωνικού δικτύου, παρατηρούμε ότι η πρόβλεψη του CTR στους διαφημιστές της season 2 είναι μεγαλύτερη από αυτής της season 3. Αυτό οφείλεται λόγω του διαφορετικού τρόπου διαχωρισμού των χρηστών από το IPinYou.

## 8.4 Σύγκριση με άλλα μοντέλα - μεθόδους

Αρχίζουμε λέγοντας ότι στη επιστημονική κοινότητα υπήρξε και υπάρχει εκτενής έρευνα στο πρόβλημα πρόβλεψης του CTR. Ιδιαίτερη ώθηση, έδωσαν οι μεγάλες διαφημιστικές εταιρείες (IPinYou, Criteo και Avazu) δημιουργώντας διαγωνισμούς και δημοσιεύοντας τα σύνολα δεδομένων τους.

Η σημερινή εποχή με την άνοδο της μηχανικής μάθησης και την ευρεία χρήση μεγάλων υπολογιστικών μονάδων, βοήθησε στην ανάπτυξη μεγάλων, πολύπλοκων και δαπανηρών μοντέλων

που παλιά ήταν αδύνατο να υλοποιηθούν. Αυτή είναι και η τάση που κυριαρχεί σήμερα όχι μόνο στη πρόβλεψη για CTR, αλλά γενικά σε πολλά προβλήματα. Παράλληλα, η χρήση πολλών μεθόδων ταυτόχρονα αποτελεί άλλη μια τάση τώρα.

Στην ανάλυση μας, θα παρουσιάσουμε μερικά μοντέλα που εκτελέσαμε μόνοι μας αλλά και αποτελέσματα από άλλα που πήραμε έτοιμα.

Πίνακας 8.3: Αποτελέσματα πρόβλεψης CTR διαφόρων μοντέλων για μετρική AUC

Με έντονο-*bold* είναι τα καλύτερα αποτελέσματα για κάθε διαφημιστή.

Μέθοδος πρόβλεψης	FNN (xLearn)	FM(με usertags-xLearn)	LR	FM( <a href="#">[Wang et al., 2016]</a> )	FNN ( <a href="#">[Wang et al., 2016]</a> )	LR-KMMP ( <a href="#">[Zhang et al., 2016]</a> )	CCPM	IPNN	OPNN
Διαφημιστές									
1458	0.705	0.982	0.988	0.702	0.707	<b>0.991</b>	0.687	0.702	0.695
2259	<b>0.7166</b>	0.690	0.687	0.651	0.709	0.620	0.663	0.673	0.671
2261	<b>0.664</b>	0.651	0.614	0.596	0.634	0.590	0.564	0.622	0.625
2821	<b>0.664</b>	0.632	0.641	0.592	0.660	0.603	0.590	0.640	0.621
2997	0.607	<b>0.613</b>	0.599	0.606	0.611	0.608	0.556	0.601	0.601
3358	0.8036	<b>0.980</b>	0.975	0.751	0.805	0.970	0.801	0.818	0.813
3386	0.805	0.780	0.790	0.761	<b>0.807</b>	0.742	0.784	0.796	0.791
3427	0.764	0.966	<b>0.973</b>	0.709	0.756	0.968	0.730	0.745	0.740
3476	0.692	<b>0.964</b>	0.962	0.577	0.701	0.922	0.654	0.653	0.658

Παρατηρούμε ότι τα αποτελέσματα μας είναι πολύ καλά. Περίπου κυμαίνονται στα ίδια επίπεδα με τα τελευταία τεχνολογικά μοντέλα που θεωρούνται μάλιστα και πιο πολύπλοκα. Καταρχάς να αναφέρουμε ότι στα μοντέλα που δεν είναι δικά μας, δεν έχει γίνει πλήρης βελτιστοποίηση και άρα θεωρητικά τα αποτελέσματα τους μπορούν να βελτιωθούν. Βέβαια και με αυτή τη βελτίωση, κάποιος μπορεί να δει ότι περίπου τα αποτελέσματα που θα βγάλουν θα είναι πολύ κοντά με τα δικά μας. Έτσι υπολογίζουμε ότι περίπου είναι ισάξια. Ενδιαφέρον να δούμε ότι στο μοντέλο του FM που φτιάξαμε, όπου είναι και το μοναδικό μοντέλο που χρησιμοποιεί στα δεδομένα τα user - tags, έχουμε τα πιο καλά αποτελέσματα. Αυτό δεν είναι καθόλου τυχαίο καθώς αναδύκνυει τη σημαντική θέση που κατέχουν τα

συγκεκριμένα χαρακτηριστικά στη πρόβλεψη του CTR. Ακόμη μια σημαντική παρατήρηση, είναι ότι παρά την απλότητα του μοντέλου τόσο της FM όσο και της γραμμικής παλινδρόμησης έχουν και τα δύο εξαιρετικά αποτελέσματα. Έτσι όσο αφορά θέματα υπολογιστικής δαπάνης σίγουρα υπερέχουν. Αντιθέτως, τα μοντέλα που κάνουν χρήση νευρωνικών δικτύων όχι μόνο είναι πολύπλοκα στη κατασκευή και εκπαίδευση αλλά και πολύ δαπανηρά τόσο σε υπολογιστική ισχύ και χρόνο. Ειδικότερα, αν σκεφτεί κανείς ότι μια δημοπρασία πρέπει να διαρκεί περίπου 100ms, για να είναι ευχαριστημένος ο χρήστης, τα οικονομικότερα και απλότερα μοντέλα φέρνουν αρκετά καλές επιδόσεις για τέτοιες χρήσεις. Κλείνοντας, να πούμε ότι προφανώς αν υπάρχει η υπολογιστική δύναμη και επιστημονική γνώση, τα πιο πολύπλοκα μοντέλα και μάλιστα συνδυασμένα, θα μας δώσουν τα πιο καλά αποτελέσματα πρόβλεψης.

## Κεφάλαιο 9

# Συμπεράσματα και μελλοντικές Κατευθύνσεις

### 9.1 Συμπεράσματα και μελλοντικές κατευθύνσεις

Στη διπλωματική αυτή, μελετήσαμε το πρόβλημα της πρόβλεψης του CTR διαφημίσεων και τη χρήση των μηχανών παραγοντοποίησης τόσο σαν γενικού εργαλείου πρόβλεψη όσο και σαν ενδιάμεσου βήματος για μείωση της διάστασης των δεδομένων.

Έχουμε δει ενθαρρυντικά αποτελέσματα που μας εισηγούνται, ότι η μηχανή παραγοντοποίησης κρύβει αρκετή δύναμη. Ταυτόχρονα, η προσπάθεια μας να λύσουμε το πρόβλημα του CTR, μας βοήθησε να αντιληφθούμε καλύτερα σημαντικές πτυχές του προβλήματος όπως η χρήση σωστών και ολοκληρωμένων δεδομένων. Είδαμε επίσης, το σημαντικό ρόλο που διαδραματίζουν τα δεδομένα χρήστη σε τέτοια προβλήματα. Πιο συγκεκριμένα, η χρήση των user - tags, έφερε μεγάλη βελτίωση σε μερικούς διαφημιστές. Σημαντικό να αναφερθεί ότι με την ανάλυση των αποτελεσμάτων συνειδητοποιήσαμε ότι τα μοντέλα που φτιάξαμε παράγουν παρόμοια ακρίβειας αποτελέσματα σε σχέση με τα καλύτερα της αγοράς, ενώ είναι πολύ πιο απλά στην υλοποίηση αλλά και πιο αποδοτικά από άποψη υπολογιστικής ισχύος. Όλα αυτά μας ενθαρρύνουν και μας δίνουν ιδέες για να συνεχίσουμε να ασχολούμαστε με το RTB και τα παρακλάδια του.

Μια προφανής πρώτη επέκταση της παρούσας μελέτης, αφορά στην επίλυση μικροπροβλημάτων που αντιμετωπίσαμε, είτε λόγω των δεδομένων που χρησιμοποιήσαμε είτε λόγω της συγκεκριμένης υλοποίησης μας. Πιο συγκεκριμένα, το βασικό στοιχείο που χρειάζεται να βελτιωθεί, είναι τα ίδια τα δεδομένα. Όπως αναφέραμε, τα σύνολα δεδομένων που έχουμε έχουν διάφορα μικρά προβλήματα που μπορεί να μας κοστίζουν όμως ακριβά όσον αφορά στην απόδοση. Ειδικότερα, τα δεδομένα μας παρουσιάζουν ανισορροπία θετικών και αρνητικών γεγονότων όσο αφορά στα κλικ αλλά και στην προκατάληψη των δεδομένων προς τις τιμές που έχουν χάσει, αναφορικά με το πρόβλημα του Bid landscape forecasting. Επιπλέον, σημαντικό θα ήταν να είχαμε γενικά πιο ολοκληρωμένα δεδομένα όπως περιγραφή του κάθε χαρακτηριστικού για το dataset Criteo αλλά και χαρακτηριστικά user tags, σε όλες τις εγγραφές του IPinYou. Όλα αυτά μπορούν να λυθούν εύκολα με τη δημιουργία ενός πιο πλήρους συνόλου δεδομένων.

Στη συνέχεια, πέρα από τη μελέτη των συναφών προβλημάτων του RTB, θα θέλαμε να κάνουμε κάποια εκτενή πειράματα για βελτιστοποίηση όλων των μοντέλων που χρησιμοποιήσαμε αλλά και

χρήση άλλων μεθόδων για υπολογισμό του CTR. Για παράδειγμα πολλά μοντέλα έχουν προταθεί που αποτελούν συνδυασμό μεθόδων (για παράδειγμα το deerFM χρησιμοποιεί πλατιά επίπεδα με μεγάλο βάθος και συνδυάζει τους παράγοντες τόσο του FM όσο και των βαθιών νευρωνικών δικτύων για να κάνει τη πρόβλεψη) και έχουν καλά αποτελέσματα ( [\[Guo et al. 2017\]](#) ), κάτι που μπορούμε να εξερευνήσουμε και εμείς. Επιπλέον, όπως αναφέραμε, έχουν προταθεί και άλλες μέθοδοι για μείωση της διάστασης, καθώς ο τομέας παρουσιάζει μεγάλο ερευνητικό ενδιαφέρον. Συνεπώς, η μελέτη διάφορων μεθόδων, ή συνδυασμού μεθόδων ή και τροποποιήσεων υπάρχουσων μεθόδων, θα μπορούσε να αποτελέσει συνέχεια της παρούσας διπλωματικής.

Τέλος, με την κατανόηση, μελέτη και λύση του προβλήματος του CTR μέσω της παρούσας διπλωματικής, έχουμε αποκτήσει μια δυνατή βάση για να μπορέσουμε να λύσουμε και συναφή προβλήματα της RTB κοινότητας. Ειδικότερα αφού έχουμε ήδη μια πρόβλεψη για το CTR, η εύρεση τόσο στρατηγικής αλλά και συνάρτησης για ποντάρισμα αποτελεί τον επόμενο στόχο μας. Συνάμα, η λειτουργία των προαναφερθέντων σε ένα περιβάλλον όπου παρέχεται και έλεγχος του προϋπολογισμού, αποτελεί λύση ολόκληρου του προβλήματος του RTB διαφημίσεων. Η λύση αυτών των προβλημάτων μας ενδιαφέρει άμεσα για την πλήρη μελέτη όλου του RTB διαφημίσεων αλλά και βελτιστοποίηση κάθε μεριάς αυτού.

## **Βιβλιογραφία**

- [Bayer, 2015] Bayer, I. (2015). fastfm: A library for factorization machines. arXiv preprint arXiv:1505.00641.
- [Bishop 1996] Bishop, C. M. (1995). Neural networks for pattern recognition. Oxford university press.
- [Bousqaoui et al., 2018] Bousqaoui, H., Achchab, S., & Tikito, K. (2017, October). Machine learning applications in supply chains: An emphasis on neural network applications. In 2017 3rd International Conference of Cloud Computing Technologies and Applications (CloudTech) (pp. 1-7). IEEE.
- [Cai et al. n.d.] Cai, H., Ren, K., Zhang, W., Malialis, K., Wang, J., Yu, Y., & Guo, D. (2017, February). Real-time bidding by reinforcement learning in display advertising. In Proceedings of the Tenth ACM International Conference on Web Search and Data Mining (pp. 661-670). ACM.
- [Carbonneau et al., 2008] Carbonneau, R., Laframboise, K., & Vahidov, R. (2008). Application of machine learning techniques for supply chain demand forecasting. European Journal of Operational Research, 184(3), 1140-1154.
- [Chawla & Kaur, 2017] Bhavuk, C., & Kaur, M. C. (2017). Airfare Analysis And Prediction Using Data Mining And Machine Learning. International Journal of Engineering Science Invention, 6(11), 10-17.
- [Cui et al., n.d.] Cui, Y., Zhang, R., Li, W., & Mao, J. (2011, August). Bid landscape forecasting in online ad exchange marketplace. In Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining (pp. 265-273). ACM.
- [Du et al. 2017] Du, M., Sassioui, R., Varisteas, G., Brorsson, M., & Cherkaoui, O. (2017, November). Improving real-time bidding using a constrained markov decision



process. In International Conference on Advanced Data Mining and Applications (pp. 711-726). Springer, Cham.

[Etzioni et al., 2003] Etzioni, O., Tuchinda, R., Knoblock, C. A., & Yates, A. (2003, August). To buy or not to buy: mining airfare data to minimize ticket purchase price. In Proceedings of the ninth ACM SIGKDD international conference on Knowledge discovery and data mining (pp. 119-128). ACM.

[Graves et al., 2009] Graves, A., Liwicki, M., Fernández, S., Bertolami, R., Bunke, H., & Schmidhuber, J. (2008). A novel connectionist system for unconstrained handwriting recognition. *IEEE transactions on pattern analysis and machine intelligence*, 31(5), 855-868.

[Guo et al. 2017] Guo, H., Tang, R., Ye, Y., Li, Z., & He, X. (2017). DeepFM: a factorization-machine based neural network for CTR prediction. arXiv preprint arXiv:1703.04247.

[Guo & Berkahn, 2016] Guo, C., & Berkahn, F. (2016). Entity embeddings of categorical variables. arXiv preprint arXiv:1604.06737.

[Jin et al. 2018] Jin, J., Song, C., Li, H., Gai, K., Wang, J., & Zhang, W. (2018, October). Real-time bidding with multi-agent reinforcement learning in display advertising. In Proceedings of the 27th ACM International Conference on Information and Knowledge Management (pp. 2193-2201). ACM.

[Juan et al., 2016] Juan, Y., Zhuang, Y., Chin, W. S., & Lin, C. J. (2016, September). Field-aware factorization machines for CTR prediction. In Proceedings of the 10th ACM Conference on Recommender Systems (pp. 43-50). ACM.

[Juan, Lefortier, & Chapelle, 2017] Juan, Y., Lefortier, D., & Chapelle, O. (2017, April). Field-aware factorization machines in a real-world online advertising system. In Proceedings of the 26th International Conference on World Wide Web Companion (pp. 680-688). International World Wide Web Conferences Steering Committee.

- [Lee, Jalali, & Dasdan, 2013] Lee, K. C., Jalali, A., & Dasdan, A. (2013, August). Real time bid optimization with smooth budget delivery in online advertising. In Proceedings of the Seventh International Workshop on Data Mining for Online Advertising (p. 1). ACM.
- [Liao et al., 2012] Liao, H., Peng, L., Liu, Z., & Shen, X. (2014, August). iPinYou global rtb bidding algorithm competition dataset. In Proceedings of the Eighth International Workshop on Data Mining for Online Advertising (pp. 1-6). ACM.
- [Liu et al., 2016] Liu, Q., Yu, F., Wu, S., & Wang, L. (2015, October). A convolutional click prediction model. In Proceedings of the 24th ACM International on Conference on Information and Knowledge Management (pp. 1743-1746). ACM.
- [McCulloch & Pitts, 1943] McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- [Qu et al., 2017] Qu, Y., Cai, H., Ren, K., Zhang, W., Yu, Y., Wen, Y., & Wang, J. (2016, December). Product-based neural networks for user response prediction. In 2016 IEEE 16th International Conference on Data Mining (ICDM) (pp. 1149-1154). IEEE.
- [Qu, Fang, et al., 2017] Qu, Y., Fang, B., Zhang, W., Tang, R., Niu, M., Guo, H., ... & He, X. (2018). Product-Based Neural Networks for User Response Prediction over Multi-Field Categorical Data. *ACM Transactions on Information Systems (TOIS)*, 37(1), 5.
- [Rendle, 2010] Rendle, S. (2010, December). Factorization machines. In 2010 IEEE International Conference on Data Mining (pp. 995-1000). IEEE.
- [Rendle, 2012] Rendle, S. (2012). Factorization machines with libfm. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 3(3), 57.
- [Richardson et al., 2007] Richardson, M., Dominowska, E., & Rago, R. (2007, May). Predicting clicks: estimating the click-through rate for new ads. In Proceedings of the 16th international conference on World Wide Web (pp. 521-530). ACM.

- [Sak, Senior, & Beaufays, 2014] Sak, H., Senior, A., & Beaufays, F. (2014). Long short-term memory recurrent neural network architectures for large scale acoustic modeling. In Fifteenth annual conference of the international speech communication association.
- [Schmidhuber, 2015] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- [Stalidis & Kardaras, 2015] Stalidis, G., Kardaras, D., Σταλίδης, Γ., & Καρδαράς, Δ. (2015). Συστήματα συστάσεων (Recommender systems).
- [Sutskever et al., 2014] Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*, 15(1), 1929-1958.
- [Szwabe et al., 2017] Szwabe, A., Misiorek, P., & Ciesielczyk, M. (2017, February). Logistic regression setup for RTB CTR estimation. In *Proceedings of the 9th International Conference on Machine Learning and Computing* (pp. 61-70). ACM.
- [Ta, 2015] Ta, A. P. (2015, October). Factorization machines with follow-the-regularized-leader for CTR prediction in display advertising. In *2015 IEEE International Conference on Big Data (Big Data)* (pp. 2889-2891). IEEE.
- [Tziridis et al., 2017] Tziridis, K., Kalampokas, T., Papakostas, G. A., & Diamantaras, K. I. (2017, August). Airfare prices prediction using machine learning techniques. In *2017 25th European Signal Processing Conference (EUSIPCO)* (pp. 1036-1039). IEEE.
- [Vickrey, 1961] Vickrey, W. (1961). Counterspeculation, auctions, and competitive sealed tenders. *The Journal of finance*, 16(1), 8-37.
- [Vu et al., 2018] Vu, V. H., Minh, Q. T., & Phung, P. H. (2018, January). An airfare prediction model for developing markets. In *2018 International Conference on Information Networking (ICOIN)*(pp. 765-770). IEEE.

[Wang et al., 2014] Wang, Y., Ren, K., Zhang, W., Wang, J., & Yu, Y. (2016, September). Functional bid landscape forecasting for display advertising. In Joint European Conference on Machine Learning and Knowledge Discovery in Databases (pp. 115-131). Springer, Cham.

[Wang et al., 2016] Zhang, W., Du, T., & Wang, J. (2016, March). Deep learning over multi-field categorical data. In European conference on information retrieval (pp. 45-57). Springer, Cham.

[Wang, Zhang, & Yuan, 2016] Wang, J., Zhang, W., & Yuan, S. (2017). Display advertising with real-time bidding (RTB) and behavioural targeting. *Foundations and Trends® in Information Retrieval*, 11(4-5), 297-435.

[Wohlfarth et al., 2011] Wohlfarth, T., Cléménçon, S., Roueff, F., & Casellato, X. (2011, December). A data-mining approach to travel price forecasting. In 2011 10th International Conference on Machine Learning and Applications and Workshops (Vol. 1, pp. 84-89). IEEE.

[Wu & Chen, 2013] Wu, W. C. H., Yeh, M. Y., & Chen, M. S. (2015, August). Predicting winning price in real time bidding with censored data. In Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 1305-1314). ACM.

[Xu, Lee, Li, Qi, & Lu, 2015] Xu, J., Lee, K. C., Li, W., Qi, H., & Lu, Q. (2015, August). Smart pacing for effective online ad campaign optimization. In Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 2217-2226). ACM.

[Y. Zhang et al., 2014] Zhang, Y., Dai, H., Xu, C., Feng, J., Wang, T., Bian, J., ... & Liu, T. Y. (2014, June). Sequential click prediction for sponsored search with recurrent neural networks. In Twenty-Eighth AAAI Conference on Artificial Intelligence.

[Zhang et al., 2014] Zhang, W., Yuan, S., Wang, J., & Shen, X. (2014). Real-time bidding benchmarking with ipinyou dataset. arXiv preprint arXiv:1407.7073.

[Zhang et al., 2016] Zhang, W., Zhou, T., Wang, J., & Xu, J. (2016, August). Bid-aware gradient descent for unbiased learning with censored data in display advertising. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 665-674). ACM.

[Zhang, Rong, Wang, Zhu, & Wang, 2016] Zhang, W., Rong, Y., Wang, J., Zhu, T., & Wang, X. (2016, February). Feedback control of real-time display advertising. In Proceedings of the Ninth ACM International Conference on Web Search and Data Mining (pp. 407-416). ACM.

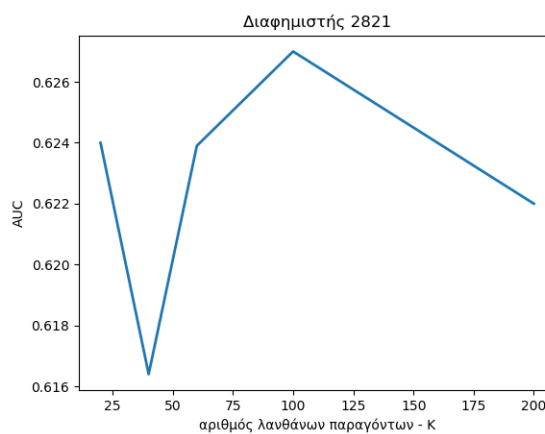


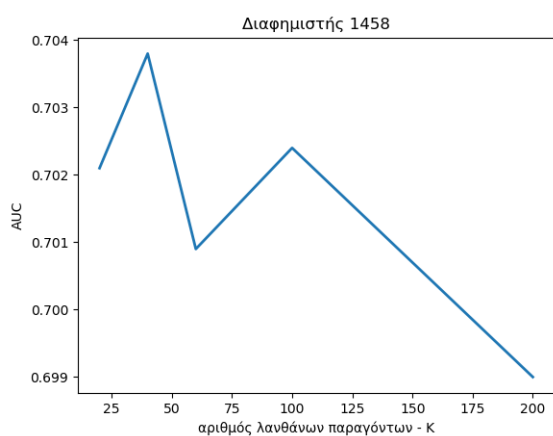
[Zhang et al., n.d.] Zhang, W., Yuan, S., & Wang, J. (2014, August). Optimal real-time bidding for display advertising. In Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining (pp. 1077-1086). ACM.



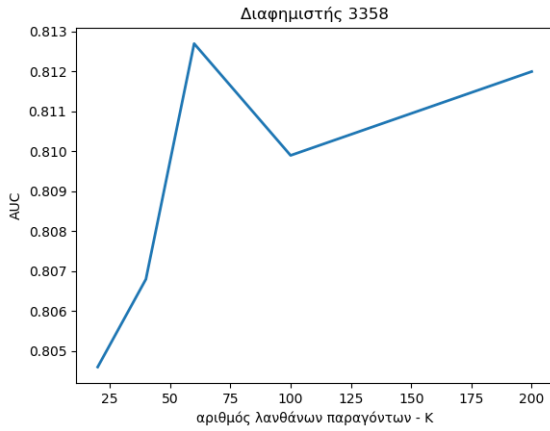
[Zhang & Wang, n.d.] Zhang, W., & Wang, J. (2015, August). Statistical arbitrage mining for display advertising. In Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 1465-1474). ACM.



## Παράρτημα Α – γραφικές AUC



Όπως παρατηρούμε δεν υπάρχει κάποιο συγκεκριμένο μοτίβο στις γραφικές, με την αύξηση του  $k$  όπως επίσης οι αλλαγές που παρατηρούνται είναι μηδαμινές. Άρα δεν αξίζει να επιλέξουμε μοντέλο με μεγάλο αριθμό λανθάνων παραμέτρων. Οι λόγοι πίσω από αυτό είναι ότι δεν κερδίζουμε τίποτα σε απόδοση αλλά και ότι με μεγάλο  $k$ , αυξάνεται η πολυπλοκότητα και το μέγεθος του μοντέλου, κάτι που μας κοστίζει ακριβώς σε θέματα υπολογιστικής ισχύς και χρόνου εκπαίδευσης.






## Παράρτημα Β – γραφικές RMSE

Όπως παρατηρούμε για τη μετρική RMSE, υπάρχει σχεδόν απειροστή διαφορά με την αύξηση του  $k$ . Πιο συγκεκριμένα μάλιστα μετρική σε μερικούς διαφημιστές μάλιστα αυξάνεται, έστω ελάχιστα, υποδηλώνοντας ότι το μοντέλο χειροτερεύει αντί να βελτιώνεται.






Διαφημιστής 2261



Διαφημιστής 2821



Διαφημιστής 2997

