

Περιεχόμενα

1 Εξόρυξη Δεδομένων	1
1.1 Τί είναι Εξόρυξη Δεδομένων;	1
1.1.1 Στατιστική Μοντελοποίηση	2
1.1.2 Μηχανική Μάθηση	2
1.1.3 Υπολογιστικές Προσεγγίσεις Μοντελοποίησης	3
1.1.4 Σύνοψη	4
1.1.5 Εξαγωγή Γνωρισμάτων	4
1.2 Στατιστικά Όρια της Εξόρυξης Δεδομένων	6
1.2.1 Συνολική Επίγνωση της Πληροφορίας	6
1.2.2 Αρχή Bonferroni	7
1.2.3 Παράδειγμα της Αρχής Bonferroni	7
1.2.4 Ασκήσεις Ενότητας 1.2	9
1.3 Πράγματα χρήσιμα να γνωρίζουμε	9
1.3.1 Σπουδαιότητα των Λέξεων σε ένα Έγγραφο	10
1.3.2 Συναρτήσεις Κατακερματισμού	11
1.3.3 Κατάλογοι	13
1.3.4 Δευτερεύουσα Αποθήκευση	15
1.3.5 Βάση των Φυσικών Λογαρίθμων	16
1.3.6 Νόμος των Δυνάμεων	17
1.3.7 Ασκήσεις Ενότητας 1.3	19
1.4 Περίγραμμα Βιβλίου	20
1.5 Περιληφθή Κεφαλαίου 1	22
1.6 Αναφορές Κεφαλαίου 1	23
2 Συστήματα Αρχείων Μεγάλης Κλίμακας και Map-Reduce	25
2.1 Κατανεμημένα Συστήματα Αρχείων	26
2.1.1 Φυσική Οργάνωση Υπολογιστικών Κόμβων	26
2.1.2 Οργάνωση Συστήματος Αρχείων Ευρείας Κλίμακας	28
2.2 Map-Reduce	29
2.2.1 Εργασίες Map	30
2.2.2 Ομαδοποίηση και Συνάθροιση	31
2.2.3 Εργασίες Reduce	32
2.2.4 Συνδυαστές	32
2.2.5 Λεπτομέρειες Εκτέλεσης του Map-Reduce	33
2.2.6 Αντιμετώπιση Αποτυχιών Κόμβων	35
2.3 Αλγόριθμοι που χρησιμοποιούν Map-Reduce	35
2.3.1 Πολλαπλασιασμός Πίνακα με Διάνυσμα σε Map-Reduce	36

2.3.2	Το Διάνυσμα δεν χωρά στην Κύρια Μνήμη	37
2.3.3	Πράξεις Σχεσιακής Άλγεβρας	38
2.3.4	Υπολογισμός Επιλογών σε Map-Reduce	42
2.3.5	Υπολογισμός Προβολών σε Map-Reduce	42
2.3.6	Ένωση, Τομή και Διαφορά σε Map-Reduce	43
2.3.7	Υπολογισμός Φυσικής Σύνδεσης σε Map-Reduce	44
2.3.8	Γενίκευση Αλγορίθμου Σύνδεσης	45
2.3.9	Ομαδοποίηση και Συνάθροιση σε Map-Reduce	45
2.3.10	Πολλαπλασιασμός Πινάκων	46
2.3.11	Πολλαπλασιασμός Πινάκων σε ένα Βήμα	47
2.3.12	Ασκήσεις Ενότητας 2.3	48
2.4	Επεκτάσεις του Map-Reduce	49
2.4.1	Συστήματα Ροών Εργασίας	50
2.4.2	Αναδρομικές Επεκτάσεις στο Map-Reduce	51
2.4.3	Σύστημα Pregel	55
2.4.4	Ασκήσεις Ενότητας 2.4	56
2.5	Απόδοση Αλγορίθμων Υπολογισμού Συστοιχίας	57
2.5.1	Επικοινωνιακό Κόστος σε Υπολογισμό Συστοιχίας	57
2.5.2	Χρόνος Επικοινωνιακού Κόστους	60
2.5.3	Συνδέσεις Πολλαπλών Δρόμων	60
2.5.4	Ασκήσεις Ενότητας 2.5	65
2.6	Περίληψη Κεφαλαίου 2	66
2.7	Αναφορές Κεφαλαίου 2	69
3	Αναζήτηση Όμοιων Αντικειμένων	73
3.1	Εφαρμογές Αναζήτησης Κοντινότερου Γείτονα	74
3.1.1	Μετρική Jaccard για την Ομοιότητα Συνόλων	74
3.1.2	Ομοιότητα Εγγράφων	74
3.1.3	Η Συνεργατική Διήθηση ως Πρόβλημα Ομοιότητας	76
3.1.4	Ασκήσεις Ενότητας 3.1	78
3.2	Θρυμματοποίηση Εγγράφων	78
3.2.1	k-θρύμμα	79
3.2.2	Επιλογή Μεγέθους Θρύμματος	79
3.2.3	Κατακερματισμός Θρυμμάτων	80
3.2.4	Κατασκευή Θρυμμάτων από Λέξεις	81
3.2.5	Ασκήσεις Ενότητας 3.2	82
3.3	Συνόψεις που διατηρούν την Ομοιότητα	82
3.3.1	Αναπαράσταση Πινάκων για Σύνολα	83
3.3.2	Minhashing	84
3.3.3	Minhashing και Ομοιότητα Jaccard	85
3.3.4	Τυπογραφές Minhash	86
3.3.5	Υπολογισμός Τυπογραφών Minhash	86
3.3.6	Ασκήσεις Ενότητας 3.3	90
3.4	Κατακερματισμός Διατήρησης Τοπικότητας για Έγγραφα	91
3.4.1	LSH για Τυπογραφές Minhash	92
3.4.2	Ανάλυση της Τεχνικής Λωριδοποίησης	94
3.4.3	Συνδυασμός των Τεχνικών	96
3.4.4	Ασκήσεις Ενότητας 3.4	97
3.5	Μετρικές Απόστασης	98
3.5.1	Ορισμός Μετρικής Απόστασης	98

3.5.2	Ευκλειδεία Απόσταση	99
3.5.3	Απόσταση Jaccard	100
3.5.4	Απόσταση Συνημιτόνου	101
3.5.5	Απόσταση Διόρθωσης	102
3.5.6	Απόσταση Hamming	104
3.5.7	Ασκήσεις Ενότητας 3.5	104
3.6	Θεωρία Συναρτήσεων Διατήρησης Τοπικότητας	106
3.6.1	Συναρτήσεις Διατήρησης της Τοπικότητας	107
3.6.2	Οικογένειες Συναρτήσεων Διατήρησης Τοπικότητας για Απόσταση Jaccard	109
3.6.3	Ενίσχυση Πιθανότητας μίας Οικογένειας Συναρτήσεων Διατήρησης Τοπικότητας	109
3.6.4	Ασκήσεις Ενότητας 3.6	112
3.7	Οικογένειες Συναρτήσεων LSH για Άλλες Μετρικές Απόστασης	113
3.7.1	Συναρτήσεις LSH για Απόσταση Hamming	113
3.7.2	Τυχαία Υπερεπίπεδα και Απόσταση Συνημιτόνου	114
3.7.3	Σκίτσα	116
3.7.4	Συναρτήσεις LSH για Ευκλειδεία Απόσταση	117
3.7.5	Άλλες Οικογένειες Συναρτήσεων LSH για Ευκλειδεία Απόσταση	118
3.7.6	Ασκήσεις Ενότητας 3.7	119
3.8	Εφαρμογές Κατακερματισμού με Διατήρηση Τοπικότητας	121
3.8.1	Καθορισμός Οντότητας	121
3.8.2	Παράδειγμα Καθορισμού Οντότητας	122
3.8.3	Επαλγήθευση Ταιριάσματος Εγγραφών	123
3.8.4	Ταιριασμα Δωκτυλικών Αποτυπωμάτων	125
3.8.5	Μία Οικογένεια LSH για Ταιριασμα Δωκτυλικών Αποτυπωμάτων	126
3.8.6	Όμοια Άρθρα Εφημερίδων	128
3.8.7	Ασκήσεις Ενότητας 3.8	130
3.9	Μέθοδοι για Ύψηλό Βαθμό Ομοιότητας	131
3.9.1	Εύρεση Τοιων Αντικειμένων	131
3.9.2	Αναπαράσταση Συνόλων με Αλφαριθμητικά	132
3.9.3	Φιλτράρισμα με Βάση το Μήκος	133
3.9.4	Δεικτοδότηση Προθέματος	134
3.9.5	Χρήση της Πληροφορίας Θέσης	136
3.9.6	Χρήση Θέσης και Μήκους για Δεικτοδότηση	137
3.9.7	Ασκήσεις Ενότητας 3.9	140
3.10	Περίληψη Κεφαλαίου 3	142
3.11	Αναφορές Κεφαλαίου 3	145
4	Εξόρυξη από Ροές Δεδομένων	149
4.1	Μοντέλο Δεδομένων Ροής	150
4.1.1	Συστήματα Διαχείρισης Ροών Δεδομένων	150
4.1.2	Πηγές Ροών Δεδομένων	151
4.1.3	Ερωτήματα Ροών	152
4.1.4	Βασικά Θέματα Επεξεργασίας Ροών	154
4.2	Δειγματοληψία σε Ροή Δεδομένων	155
4.2.1	Ενδεικτικό Παράδειγμα	155
4.2.2	Θεώρηση ενός Αντιπροσωπευτικού Δείγματος	157
4.2.3	Γενικό Πρόβλημα της Δειγματοληψίας	157
4.2.4	Μεταβολή του Μεγέθους Δείγματος	158

4.2.5 Ασκήσεις Ενότητας 4.2	159
4.3 Φιλτράρισμα Ροής	159
4.3.1 Ενδεικτικό Παράδειγμα	159
4.3.2 Φίλτρο Bloom	161
4.3.3 Ανάλυση Φίλτρου Bloom	161
4.3.4 Ασκήσεις Ενότητας 4.3	163
4.4 Μέτρηση Διακριτών Στοιχείων Ροής	164
4.4.1 Πρόβλημα της Μέτρησης Διακριτών Στοιχείων	164
4.4.2 Αλγόριθμος Flajolet-Martin	165
4.4.3 Συνδυασμός Εκτιμήσεων	166
4.4.4 Απαιτήσεις Χώρου	167
4.4.5 Ασκήσεις Ενότητας 4.4	168
4.5 Εκτίμηση Ροπών	168
4.5.1 Ορισμός Ροπών	168
4.5.2 Αλγόριθμος Alon-Matias-Szegedy για Ροπές Δεύτερης Τάξης	169
4.5.3 Γιατί Δουλεύει ο Αλγόριθμος Alon-Matias-Szegedy	171
4.5.4 Ροπές Υψηλότερης Τάξης	172
4.5.5 Αντιμετώπιση Άπειρων Ροών	172
4.5.6 Ασκήσεις Ενότητας 4.5	174
4.6 Μέτρηση Άσσων σε Παράθυρο	175
4.6.1 Κόστος Επανχριστούς Μέτρησης	175
4.6.2 Αλγόριθμος Datar-Gionis-Indyk-Motwani (DGIM)	176
4.6.3 Απαιτήσεις Χώρου Αλγορίθμου DGIM	178
4.6.4 Απάντηση Ερωτημάτων με τον Αλγόριθμο DGIM	178
4.6.5 Διατήρηση των Κανόνων DGIM	180
4.6.6 Περιορισμός Σφράλματος	181
4.6.7 Επεκτάσεις στη Μέτρηση Άσσων	182
4.6.8 Ασκήσεις Ενότητας 4.6	183
4.7 Φθίνοντα Παράθυρα	183
4.7.1 Πρόβλημα των πιο Κοινών Στοιχείων	184
4.7.2 Ορισμός Φθίνοντος Παραθύρου	184
4.7.3 Εύρεση Δημοφιλέστερων Στοιχείων	186
4.8 Περίληψη Κεφαλαίου 4	187
4.9 Αναφορές Κεφαλαίου 4	189
5 Ανάλυση Συνδέσμων	191
5.1 Ο Αλγόριθμος PageRank	192
5.1.1 Πρώιμες Μηχανές και Ανεπιθύμητοι Όροι	192
5.1.2 Ορισμός του PageRank	194
5.1.3 Δομή του Παγκόσμιου Ιστού	198
5.1.4 Αποφυγή Αδιεξόδων	200
5.1.5 Αραχνοπαγίδες και Φορολόγηση	204
5.1.6 Χρήση του PageRank σε Μηχανές Αναζήτησης	207
5.1.7 Ασκήσεις Ενότητας 5.1	207
5.2 Αποδοτικός Υπολογισμός του PageRank	209
5.2.1 Αναπαράσταση Πίνακων Μετάβασης	210
5.2.2 Επανάληψη του Pagerank με Χρήση Map-Reduce	211
5.2.3 Χρήση Συνδυαστών για τον Υπολογισμό Διανύσματος	212
5.2.4 Αναπαράσταση Τμημάτων του Πίνακα Μεταβάσεων	213
5.2.5 Άλλες Τεχνικές για τις Επαναλήψεις του PageRank	214

5.2.6	Ασκήσεις Ενότητας 5.2	216
5.3	PageRank με Βάση το Θέμα	217
5.3.1	Κίνητρο	217
5.3.2	Μεροληπτικοί Τυχαίοι Περίπατοι	218
5.3.3	Χρήση της Μεθόδου	220
5.3.4	Εξαγωγή Θεμάτων από Όρους	221
5.3.5	Ασκήσεις Ενότητας 5.3	222
5.4	Ανεπιθύμητοι Συνδέσμοι	222
5.4.1	Φάρμα Ανεπιθύμητων Ιστοσελίδων	223
5.4.2	Ανάλυση της Φάρμας Ανεπιθύμητων Σελίδων	224
5.4.3	Καταπολέμηση της Επιδρασης Ανεπιθύμητων Συνδέσμων	225
5.4.4	TrustRank	226
5.4.5	Ανεπιθύμητη Μάζα	227
5.4.6	Ασκήσεις Ενότητας 5.4	228
5.5	Κέντρα και Αυθεντίες	229
5.5.1	Διαίσθηση πίσω από τον HITS	229
5.5.2	Υπολογισμός Βαθμολογιών Κέντρου και Αυθεντίας	230
5.5.3	Ασκήσεις Ενότητας 5.5	234
5.6	Περίληψη Κεφαλαίου 5	234
5.7	Αναφορές Κεφαλαίου 5	238
6	Συχνά Στοιχειοσύνολα	241
6.1	Μοντέλο Καλαθιού Αγορών	242
6.1.1	Ορισμός Συχνών Στοιχειοσυνόλων	242
6.1.2	Εφαρμογές Συχνών Στοιχειοσυνόλων	244
6.1.3	Κανόνες Συσχέτισης	247
6.1.4	Εύρεση Κανόνων Συσχέτισης με Υψηλή Εμπιστοσύνη	248
6.1.5	Ασκήσεις Ενότητας 6.1	249
6.2	Καλάθια Αγορών και Αλγόριθμος A-Priori	251
6.2.1	Αναπαράσταση Δεδομένων Καλαθιών Αγορών	251
6.2.2	Χρήση Κύριας Μνήμης για την Καταμέτρηση Στοιχειοσυνόλων	252
6.2.3	Μονοτονικότητα Στοιχειοσυνόλων	255
6.2.4	Τυραννία της Καταμέτρησης Ζευγών	256
6.2.5	Αλγόριθμος A-Priori	256
6.2.6	A-Priori για Όλα τα Συχνά Στοιχειοσύνολα	259
6.2.7	Ασκήσεις Ενότητας 6.2	261
6.3	Διαχείριση Μεγάλων Συνόλων Δεδομένων στην Κύρια Μνήμη	262
6.3.1	Αλγόριθμος των Park, Chen και Yu	263
6.3.2	Αλγόριθμος Multistage	266
6.3.3	Αλγόριθμος Multihash	268
6.3.4	Ασκήσεις Ενότητας 6.3	270
6.4	Αλγόριθμοι Περιορισμένων Περασμάτων	273
6.4.1	Απλός Τυχαιοποιημένος Αλγόριθμος	273
6.4.2	Αποφυγή Σφαλμάτων στους Αλγόριθμους Δειγματοληψίας	275
6.4.3	Αλγόριθμος των Savasere, Omiecinski και Navathe	276
6.4.4	Αλγόριθμος SON και Map-Reduce	277
6.4.5	Αλγόριθμος Toivonen	278
6.4.6	Γιατί Δουλεύει ο Αλγόριθμος Toivonen	280
6.4.7	Ασκήσεις Ενότητας 6.4	280
6.5	Μέτρηση Συχνών Αντικειμένων σε μία Ροή Δεδομένων	281

6.5.1	Μέθοδοι Δειγματοληψίας για Ροές	282
6.5.2	Συχνά Στοιχειοσύνολα σε Φθίνοντα Παράθυρα	283
6.5.3	Τύπωση Μέθοδοι	284
6.5.4	Ασκήσεις Ενότητας 6.5	286
6.6	Περίληψη Κεφαλαίου 6	286
6.7	Αναφορές Κεφαλαίου 6	289
7	Ομαδοποίηση	291
7.1	Εισαγωγή στις Τεχνικές Ομαδοποίησης	291
7.1.1	Σημεία, Χώροι και Αποστάσεις	292
7.1.2	Στρατηγικές Ομαδοποίησης	293
7.1.3	Κατάρα της Διαστασιμότητας	294
7.1.4	Ασκήσεις Ενότητας 7.1	296
7.2	Ιεραρχική Ομαδοποίηση	297
7.2.1	Ιεραρχική Ομαδοποίηση σε Ευκλείδειο Χώρο	297
7.2.2	Αποδοτικότητα της Ιεραρχικής Ομαδοποίησης	302
7.2.3	Εναλλακτικοί Κανόνες Ελέγχου Ιεραρχικής Ομαδοποίησης	303
7.2.4	Ιεραρχική Ομαδοποίηση σε μη Ευκλείδειους Χώρους	305
7.2.5	Ασκήσεις Ενότητας 7.2	307
7.3	Αλγόριθμοι <i>K</i> -Μέσων	308
7.3.1	Τα βασικά των <i>K</i> -Μέσων	308
7.3.2	Αρχικοποίηση Ομάδων στους <i>K</i> -Μέσους	309
7.3.3	Επιλογή Σωστής Τιμής του <i>k</i>	310
7.3.4	Αλγόριθμος των Bradley, Fayyad και Reina	312
7.3.5	Επεξεργασία Δεδομένων στον Αλγόριθμο BFR	314
7.3.6	Ασκήσεις Ενότητας 7.3	317
7.4	Αλγόριθμος CURE	318
7.4.1	Αρχικοποίηση του CURE	319
7.4.2	Ολοκλήρωση Αλγόριθμου CURE	321
7.4.3	Ασκήσεις Ενότητας 7.4	322
7.5	Ομαδοποίηση σε Μη Ευκλείδειους Χώρους	322
7.5.1	Αναπαράσταση Ομάδων στον Αλγόριθμο GRGPF	323
7.5.2	Αρχικοποίηση του Δένδρου Ομάδων	324
7.5.3	Πρόσθεση Σημείων στον Αλγόριθμο GRGPF	324
7.5.4	Διάσπαση και Συγχώνευση Ομάδων	326
7.5.5	Ασκήσεις Ενότητας 7.5	328
7.6	Ομαδοποίηση για Ροές και Παραλληλισμό	328
7.6.1	Μοντέλο Υπολογισμού Ροών	329
7.6.2	Αλγόριθμος Ομαδοποίησης Ροών	329
7.6.3	Αρχικοποίηση Κάδων	330
7.6.4	Συγχώνευση Κάδων	331
7.6.5	Απάντηση Ερωτημάτων	334
7.6.6	Ομαδοποίηση σε Παραλλήλο Περιβάλλον	335
7.6.7	Ασκήσεις Ενότητας 7.6	335
7.7	Περίληψη Κεφαλαίου 7	336
7.8	Αναφορές Κεφαλαίου 7	340
8	Διαφήμιση στο Διαδίκτυο	343
8.1	Θέματα Διαδίκτυων Διαφήμισης	344
8.1.1	Ευκαρπίες Διαφήμισης	344

8.1.2	Άμεση Τοποθέτηση Διαφημίσεων	345
8.1.3	Θέματα Εμφάνισης Διαφημίσεων	346
8.2	Αλγόριθμοι Άμεσης Επεξεργασίας	347
8.2.1	Αλγόριθμοι Άμεσης και Ολικής Επεξεργασίας	348
8.2.2	Άπληστοι Αλγόριθμοι	350
8.2.3	Ανταγωνιστικός Λόγος	350
8.2.4	Ασκήσεις Ενότητας 8.2	351
8.3	Το Πρόβλημα του Ταιριάσματος	352
8.3.1	Ταιριάσματα και Τέλεια Ταιριάσματα	352
8.3.2	Άπληστος Αλγόριθμος Μέγιστου Ταιριάσματος	353
8.3.3	Ανταγωνιστικός Λόγος για Άπληστο Ταιριάσμα	354
8.3.4	Ασκήσεις Ενότητας 8.3	355
8.4	Το Πρόβλημα Adwords	356
8.4.1	Ιστορία της Διαφήμισης με Αναζήτηση	356
8.4.2	Ορισμός του Προβλήματος Adwords	357
8.4.3	Άπληστη Μέθοδος για το Πρόβλημα Adwords	358
8.4.4	Αλγόριθμος Ισορροπίας	359
8.4.5	Κάτω Φράγμα Ανταγωνιστικού Λόγου Αλγόριθμου Ισορροπίας	361
8.4.6	Αλγόριθμος Ισορροπίας για Πολλούς Ανταγωνιστές	364
8.4.7	Γενικευμένος Αλγόριθμος Ισορροπίας	366
8.4.8	Μερικές Τελικές Παρατηρήσεις για το Πρόβλημα Adwords	367
8.4.9	Ασκήσεις Ενότητας 8.4	368
8.5	Τλοποίηση του Προβλήματος Adwords	369
8.5.1	Τάιριασμα Προσφορών και Ερωτήσεων Αναζήτησης	369
8.5.2	Πιο Πολύπλοκα Προβλήματα Ταιριάσματος	370
8.5.3	Αλγόριθμος Ταιριάσματος για Έγγραφα και Προσφορές	371
8.6	Περιληφτή Κεφαλαίου 8	374
8.7	Αναφορές Κεφαλαίου 8	377
9	Συστήματα Συστάσεων	379
9.1	Ένα Μοντέλο Συστημάτων Συστάσεων	380
9.1.1	Πίνακας Ωφελείας	380
9.1.2	Η Μακριά Ουρά	382
9.1.3	Εφαρμογές Συστημάτων Συστάσεων	382
9.1.4	Σύμπλήρωση του Πίνακα Ωφελείας	384
9.2	Συστάσεις Βασισμένες στο Περιεχόμενο	385
9.2.1	Προφίλ Στοιχείων	385
9.2.2	Ανακαλύπτοντας Γνωρίσματα Εγγράφων	386
9.2.3	Απόκτηση Γνωρισμάτων Στοιχείων από Επισημειώσεις	388
9.2.4	Αναπαριστώντας Προφίλ Στοιχείων	389
9.2.5	Προφίλ Χρηστών	391
9.2.6	Συστήνοντας Στοιχεία σε Χρήστες με Βάση το Περιεχόμενο	392
9.2.7	Αλγόριθμοι Κατηγοριοποίησης	393
9.2.8	Ασκήσεις Ενότητας 9.2	396
9.3	Συνεργατική Διήθηση	398
9.3.1	Μέτρηση Ομοιότητας	398
9.3.2	Δυαδικότητα της Ομοιότητας	401
9.3.3	Ομαδοποίηση Χρηστών και Στοιχείων	403
9.3.4	Ασκήσεις Ενότητας 9.3	405
9.4	Μείωση Διαστάσεων	406

9.4.1	Αποσύνθεση-UV	407
9.4.2	Λάθος Μέσης Τετραγωνικής Ρίζας	408
9.4.3	Τυπολογιστική Αύξηση της Αποσύνθεσης-UV	409
9.4.4	Βελτιστοποιώντας ένα Αυθαίρετο Στοιχείο	412
9.4.5	Δημιουργία Ολοκληρωμένου Αλγορίθμου Αποσύνθεσης-UV . .	414
9.4.6	Ασκήσεις Ενότητας 9.4	417
9.5	Η Πρόκληση του NetFlix	418
9.6	Περιληφή Κεφαλαίου 9	419
9.7	Αναφορές Κεφαλαίου 9	422