



ΠΑΝΕΠΙΣΤΗΜΙΟ ΠΕΙΡΑΙΩΣ

ΣΧΟΛΗ ΤΕΧΝΟΛΟΓΙΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ ΚΑΙ ΕΠΙΚΟΙΝΩΝΙΩΝ

ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ

Πτυχιακή Εργασία

Τίτλος Πτυχιακής Εργασίας	Χρήση Ευφυών Τεχνικών για την Ανάπτυξη ενός Συστήματος Συστάσεων Use of Intelligent Techniques for the Development of a Recommendation System
Ονοματεπώνυμο Φοιτητή	Αλέξιος Ρούτσης
Πατρώνυμο	Αλφρέντ
Αριθμός Μητρώου	Π21145
Επιβλέπων	Κωνσταντίνος Λιαγκούρας, Επ. Καθηγητής

Ημερομηνία Παράδοσης **Σεπτέμβριος 2026**

Copyright ©

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.

Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν αποκλειστικά τον συγγραφέα και δεν αντιπροσωπεύουν τις επίσημες θέσεις του Πανεπιστημίου Πειραιώς.

Ως συγγραφέας της παρούσας εργασίας δηλώνω πως η παρούσα εργασία δεν αποτελεί προϊόν λογοκλοπής και δεν περιέχει υλικό από μη αναφερόμενες πηγές.

Ευχαριστίες

Φτάνοντας στο τέλος αυτής της προσπάθειας, θα ήθελα να σταθώ για λίγο σε όσους τη διευκόλυναν με τον δικό τους τρόπο.

Ευχαριστώ τον επιβλέποντα καθηγητή μου, κ. Κωνσταντίνο Λιαγκούρα, για την ανάθεση ενός θέματος που με κέντρισε πραγματικά, αλλά και για τις παρατηρήσεις του, οι οποίες με βοήθησαν να δω το αντικείμενο σε μεγαλύτερο βάθος.

Οφείλω επίσης ένα ευχαριστώ στους διδάσκοντες του Τμήματος Πληροφορικής του Πανεπιστημίου Πειραιώς· χωρίς τις γνώσεις που απέκτησα στα χρόνια των σπουδών μου, μια τέτοια εργασία δεν θα ήταν εφικτή.

Πάνω απ' όλα, ευχαριστώ τους δικούς μου ανθρώπους για την υπομονή και τη στήριξή τους σε όλη αυτή τη διαδρομή.

Περίληψη

Η ραγδαία ανάπτυξη του διαδικτύου και του ηλεκτρονικού εμπορίου έχει οδηγήσει σε μια πρωτοφανή αύξηση του όγκου των διαθέσιμων προϊόντων και πληροφοριών, δημιουργώντας το πρόβλημα της υπερπληροφόρησης. Τα συστήματα συστάσεων (recommender systems) αποτελούν μια από τις σημαντικότερες τεχνολογίες αντιμετώπισης του προβλήματος αυτού, καθώς προβλέπουν τις προτιμήσεις των χρηστών και παρέχουν εξατομικευμένες προτάσεις.

Στην παρούσα εργασία μελετάται η χρήση ευφυών τεχνικών για την ανάπτυξη συστημάτων συστάσεων. Παρουσιάζονται αναλυτικά, με το αντίστοιχο μαθηματικό υπόβαθρο, οι βασικές κατηγορίες τεχνικών: το συνεργατικό φιλτράρισμα (μνήμης και μοντέλου), το φιλτράρισμα βάσει περιεχομένου, οι μέθοδοι παραγοντοποίησης πινάκων (matrix factorization) και οι σύγχρονες προσεγγίσεις βαθιάς μάθησης. Για κάθε τεχνική δίνονται οι μαθηματικοί τύποι, οι αλγόριθμοι και ο ψευδοκώδικας λειτουργίας τους, καθώς και οι μετρικές αξιολόγησης (RMSE, MAE, Precision@k, Recall@k, NDCG).

Η εργασία ακολουθεί θεωρητική και αναλυτική προσέγγιση, εστιάζοντας στη συγκριτική μελέτη των ευφυών τεχνικών, στη μαθηματική τους θεμελίωση και στα κριτήρια αξιολόγησής τους. Ολοκληρώνεται με τη συζήτηση των σύγχρονων τάσεων, των περιορισμών και των μελλοντικών κατευθύνσεων, όπως η πειραματική επικύρωση των μεθόδων σε πραγματικά σύνολα δεδομένων.

Λέξεις-κλειδιά: συστήματα συστάσεων, ευφυείς τεχνικές, συνεργατικό φιλτράρισμα, παραγοντοποίηση πινάκων, μηχανική μάθηση, ηλεκτρονικό εμπόριο.

Αφιερώσεις

Στους ανθρώπους που στέκονται δίπλα μου — σιωπηλά αλλά σταθερά.

Περιεχόμενα

Copyright ©	2
Ευχαριστίες.....	3
Περίληψη.....	4
Αφιερώσεις.....	5
Περιεχόμενα	6
ΚΕΦΑΛΑΙΟ 1: Εισαγωγή	10
ΚΕΦΑΛΑΙΟ 2: Θεωρητικό Υπόβαθρο των Συστημάτων Συστάσεων	14
2.1 Ορισμός και βασικές έννοιες των συστημάτων συστάσεων	14
2.2 Ιστορική εξέλιξη και σημασία τους στην ψηφιακή εποχή	16
2.3 Βασικές κατηγορίες συστημάτων συστάσεων	19
2.4 Πλεονεκτήματα, προκλήσεις και περιορισμοί	22
ΚΕΦΑΛΑΙΟ 3: Ευφυείς Τεχνικές και Μέθοδοι Τεχνητής Νοημοσύνης	26
3.1 Μηχανική μάθηση και εφαρμογές της	26
3.2 Νευρωνικά δίκτυα και βαθιά μάθηση	29
3.3 Ασαφής λογική και εξελικτικοί αλγόριθμοι.....	32
3.4 Εξόρυξη δεδομένων και ανακάλυψη προτύπων	35
3.5 Μαθηματική διατύπωση του προβλήματος σύστασης	37
3.6 Συνεργατικό φιλτράρισμα βασισμένο στη μνήμη (Memory-based Collaborative Filtering)	38
3.6.1 Μέτρα ομοιότητας	39
3.6.2 Πρόβλεψη user-based και item-based	40
3.6.3 Αλγόριθμος k-Nearest Neighbors για σύσταση	40
3.7 Μοντέλα παραγοντοποίησης πινάκων (Matrix Factorization)	41
3.7.1 Συνάρτηση σφάλματος και κανονικοποίηση	41
3.7.2 Βελτιστοποίηση με στοχαστική κατάβαση κλίσης (SGD)	42
3.7.3 Εναλλασσόμενα ελάχιστα τετράγωνα (ALS)	42
3.8 Φιλτράρισμα βασισμένο στο περιεχόμενο (Content-based Filtering)	43
3.9 Προηγμένες ευφυείς τεχνικές	44

3.9.1 Νευρωνικό συνεργατικό φιλτράρισμα (Neural Collaborative Filtering)	44
3.9.2 Κανόνες συσχέτισης (Association Rules)	44
3.9.3 Ομαδοποίηση χρηστών με k-means.....	45
3.9.4 Ασαφής λογική και εξελικτικοί αλγόριθμοι.....	45
3.10 Υβριδικές μέθοδοι σύστασης.....	45
3.11 Βιβλιογραφική αποτίμηση.....	46
ΚΕΦΑΛΑΙΟ 4: Εφαρμογή Ευφυών Τεχνικών στα Συστήματα Συστάσεων	47
4.1 Συστήματα συστάσεων βασισμένα σε περιεχόμενο	47
4.2 Συνεργατικά συστήματα συστάσεων.....	50
4.3 Υβριδικά συστήματα συστάσεων	53
4.4 Εξατομίκευση και προσαρμοστικότητα προτάσεων.....	57
4.5 Αρχιτεκτονική και ροή ενός συστήματος συστάσεων	60
4.6 Αλγόριθμος παραγωγής Top-N συστάσεων (συνεργατικό φιλτράρισμα)	62
4.7 Υβριδικός αλγόριθμος και αντιμετώπιση ψυχρής εκκίνησης	62
4.8 Υπολογιστική πολυπλοκότητα και κλιμάκωση	64
4.9 Βιβλιογραφική αποτίμηση	64
ΚΕΦΑΛΑΙΟ 5: Αξιολόγηση και Σύγκριση Ευφυών Προσεγγίσεων	65
5.1 Κριτήρια αξιολόγησης αποτελεσματικότητας	65
5.2 Μετρικές ποιότητας των συστάσεων.....	68
5.3 Συγκριτική ανάλυση διαφορετικών τεχνικών.....	71
5.4 Περιορισμοί και τεχνικές βελτίωσης.....	75
5.5 Μαθηματικοί ορισμοί των μετρικών αξιολόγησης.....	78
5.5.1 Μετρικές ακρίβειας πρόβλεψης	78
5.5.2 Μετρικές ποιότητας κατάταξης	79
5.5.3 Κανονικοποιημένο σωρευτικό κέρδος (NDCG).....	80
5.5.4 Μετρικές πέραν της ακρίβειας	80
5.5.5 Παράδειγμα υπολογισμού.....	81
5.6 Βιβλιογραφική αποτίμηση	81

ΚΕΦΑΛΑΙΟ 6: Σύγχρονες Τάσεις και Μελλοντικές Κατευθύνσεις	82
6.1 Χρήση βαθιάς μάθησης στα σύγχρονα συστήματα συστάσεων	82
6.2 Επεξηγήσιμα συστήματα συστάσεων	85
6.3 Ζητήματα ιδιωτικότητας και ηθικής στη χρήση δεδομένων	88
6.4 Μελλοντικές ερευνητικές προοπτικές	91
ΚΕΦΑΛΑΙΟ 7: Συμπεράσματα	95
Βιβλιογραφία.....	98
Άρθρα σε επιστημονικά περιοδικά (Journals).....	98
Πρακτικά συνεδρίων (Conference proceedings).....	100
Βιβλία και κεφάλαια βιβλίων (Books & book chapters)	102
Διαδικτυακές πηγές, σύνολα δεδομένων και εργαλεία	102

Χρήση ευφυών τεχνικών για την ανάπτυξη ενός συστήματος συστάσεων.

ΚΕΦΑΛΑΙΟ 1: Εισαγωγή

Η σύγχρονη ψηφιακή εποχή χαρακτηρίζεται από τη συνεχή παραγωγή, διάχυση και κατανάλωση τεράστιων ποσοτήτων πληροφορίας. Η ραγδαία ανάπτυξη του διαδικτύου, των κοινωνικών δικτύων, του ηλεκτρονικού εμπορίου και των ψηφιακών υπηρεσιών έχει δημιουργήσει ένα περιβάλλον στο οποίο οι χρήστες έρχονται καθημερινά αντιμέτωποι με έναν πρωτοφανή όγκο διαθέσιμων δεδομένων, προϊόντων και επιλογών. Παρότι η αυξημένη πρόσβαση στην πληροφορία αποτελεί σημαντικό πλεονέκτημα της ψηφιακής κοινωνίας, ταυτόχρονα δημιουργεί ένα σοβαρό πρόβλημα υπερπληροφόρησης, καθώς η αναζήτηση του πραγματικά χρήσιμου και σχετικού περιεχομένου καθίσταται ολοένα και δυσκολότερη. Σε αυτό το πλαίσιο, τα συστήματα συστάσεων έχουν αναδειχθεί ως μία από τις σημαντικότερες τεχνολογίες υποστήριξης αποφάσεων, επιτρέποντας την αποτελεσματική διαχείριση της πληροφορίας και τη διαμόρφωση εξατομικευμένων εμπειριών χρήσης.

Η ανάγκη ανάπτυξης μηχανισμών που θα μπορούσαν να φιλτράρουν πληροφορίες και να υποστηρίξουν τους χρήστες στην επιλογή περιεχομένου είχε ήδη αναγνωριστεί από τις αρχές της δεκαετίας του 1990. Η Maes (1994) υποστήριξε ότι η αυξανόμενη πληροφοριακή πολυπλοκότητα καθιστά αναγκαία την ύπαρξη ευφύων ψηφιακών βοηθών, ικανών να λειτουργούν ως ενδιάμεσοι μεταξύ του χρήστη και του διαθέσιμου όγκου πληροφοριών. Η προσέγγιση αυτή αποτέλεσε τη βάση για την ανάπτυξη ευφύων πρακτόρων και μετέπειτα συστημάτων συστάσεων, τα οποία εξελίχθηκαν σταδιακά από απλά εργαλεία φιλτραρίσματος σε σύνθετα συστήματα τεχνητής νοημοσύνης. Οι Genesereth και Ketchpel (1994) καθώς και οι Wooldridge και Jennings (1995) περιέγραψαν τους ευφυείς πράκτορες ως αυτόνομα υπολογιστικά συστήματα που διαθέτουν την ικανότητα να αντιλαμβάνονται το περιβάλλον τους, να λαμβάνουν αποφάσεις και να ενεργούν προς όφελος του χρήστη. Οι αρχές αυτές εξακολουθούν να αποτελούν βασικά θεωρητικά θεμέλια για τη λειτουργία των σύγχρονων συστημάτων συστάσεων. Τα συστήματα συστάσεων αποτελούν σήμερα μία από τις πλέον διαδεδομένες εφαρμογές της τεχνητής νοημοσύνης. Στόχος τους είναι η πρόβλεψη των προτιμήσεων ενός χρήστη και η παροχή εξατομικευμένων προτάσεων που ανταποκρίνονται στις ανάγκες και τα ενδιαφέροντά του. Σύμφωνα με τους Adomavicius και Tuzhilin (2005), τα συστήματα συστάσεων αποτελούν εξειδικευμένα συστήματα φιλτραρίσματος πληροφοριών που επιδιώκουν να υποστηρίξουν τη διαδικασία λήψης αποφάσεων μέσω της παροχής εξατομικευμένου περιεχομένου. Η σημασία τους είναι ιδιαίτερα εμφανής σε περιβάλλοντα όπου οι διαθέσιμες επιλογές είναι τόσο πολλές ώστε η χειροκίνητη αξιολόγησή τους καθίσταται πρακτικά αδύνατη. Εφαρμογές όπως οι πλατφόρμες ηλεκτρονικού εμπορίου, οι υπηρεσίες συνεχούς ροής

πολυμέσων, τα κοινωνικά δίκτυα, οι μηχανές αναζήτησης, οι ψηφιακές βιβλιοθήκες και οι εκπαιδευτικές πλατφόρμες βασίζονται πλέον σε προηγμένα συστήματα συστάσεων προκειμένου να βελτιώσουν την εμπειρία των χρηστών και να ενισχύσουν την αποτελεσματικότητα των υπηρεσιών τους.

Η ιστορική εξέλιξη των συστημάτων συστάσεων ακολούθησε παράλληλη πορεία με την πρόοδο της τεχνητής νοημοσύνης και της μηχανικής μάθησης. Οι πρώτες προσεγγίσεις βασίστηκαν στο συνεργατικό φιλτράρισμα, όπου οι προτιμήσεις και οι αξιολογήσεις μιας κοινότητας χρηστών αξιοποιούνται για την πρόβλεψη των προτιμήσεων άλλων χρηστών. Οι εργασίες των Goldberg et al. (1992) και Resnick et al. (1994) αποτέλεσαν ορόσημο για την ανάπτυξη του πεδίου, καθώς απέδειξαν ότι η συλλογική συμπεριφορά των χρηστών μπορεί να χρησιμοποιηθεί ως αξιόπιστη πηγή γνώσης για την παραγωγή εξατομικευμένων προτάσεων. Στη συνέχεια, η ανάπτυξη τεχνικών συνεργατικού φιλτραρίσματος βασισμένων σε αντικείμενα και η εφαρμογή τους σε μεγάλης κλίμακας εμπορικά περιβάλλοντα, όπως στην Amazon, κατέδειξαν τη σημαντική επιχειρησιακή αξία των συστημάτων συστάσεων (Sarwar et al., 2001; Linden et al., 2003). Η επόμενη σημαντική φάση στην εξέλιξη των recommender systems συνδέθηκε με την ανάπτυξη τεχνικών μηχανικής μάθησης και εξόρυξης δεδομένων. Η δυνατότητα ανάλυσης μεγάλων συνόλων δεδομένων επέτρεψε τη δημιουργία πιο εξελιγμένων μοντέλων πρόβλεψης, τα οποία μπορούσαν να αναγνωρίζουν σύνθετα πρότυπα συμπεριφοράς χρηστών. Ιδιαίτερη σημασία απέκτησαν οι μέθοδοι παραγοντοποίησης πινάκων, οι οποίες επέτρεψαν την ανακάλυψη λανθανόντων σχέσεων μεταξύ χρηστών και αντικειμένων, βελτιώνοντας σημαντικά την ακρίβεια των συστάσεων (Koren et al., 2009). Συμπληρωματικά, η αξιοποίηση έμμεσης ανατροφοδότησης μέσω δεδομένων συμπεριφοράς, όπως τα κλικ, οι προβολές και οι αγορές, διέυρυνε τις δυνατότητες μάθησης των συστημάτων συστάσεων σε πραγματικά περιβάλλοντα εφαρμογής (Hu et al., 2008; Rendle et al., 2009).

Τα τελευταία χρόνια, η ενσωμάτωση τεχνικών βαθιάς μάθησης έχει μετασχηματίσει ριζικά το πεδίο των συστημάτων συστάσεων. Τα βαθιά νευρωνικά δίκτυα έχουν τη δυνατότητα να επεξεργάζονται μεγάλες ποσότητες ετερογενών δεδομένων και να αποκαλύπτουν πολύπλοκες μη γραμμικές σχέσεις που δεν μπορούν να ανιχνευθούν από παραδοσιακές μεθόδους. Εργασίες όπως αυτές των Covington et al. (2016), Cheng et al. (2016) και He et al. (2017) απέδειξαν ότι τα μοντέλα βαθιάς μάθησης μπορούν να επιτύχουν εντυπωσιακές βελτιώσεις στην ποιότητα των συστάσεων, ιδιαίτερα σε περιβάλλοντα μεγάλης κλίμακας. Σύμφωνα με τους Zhang et al. (2019) και Zhou et al. (2023), η βαθιά μάθηση αποτελεί πλέον μία από τις σημαντικότερες τεχνολογικές κατευθύνσεις στην ανάπτυξη συστημάτων συστάσεων, προσφέροντας νέες δυνατότητες εξατομίκευσης, προσαρμοστικότητας και κατανόησης της ανθρώπινης συμπεριφοράς.

Η αυξανόμενη πολυπλοκότητα των ψηφιακών οικοσυστημάτων έχει καταστήσει αναγκαία την αξιοποίηση ολοένα και πιο προηγμένων ευφυών τεχνικών. Η μηχανική μάθηση, τα νευρωνικά δίκτυα, η βαθιά μάθηση, η εξόρυξη δεδομένων, οι εξελικτικοί αλγόριθμοι, η ασαφής λογική και η ενισχυτική μάθηση αποτελούν σήμερα βασικά εργαλεία για την ανάπτυξη σύγχρονων συστημάτων συστάσεων. Οι τεχνικές αυτές επιτρέπουν όχι μόνο την ακριβέστερη πρόβλεψη προτιμήσεων αλλά και την προσαρμογή των συστάσεων στις μεταβαλλόμενες ανάγκες των χρηστών. Ιδιαίτερα η ενισχυτική μάθηση έχει προσελκύσει έντονο ερευνητικό ενδιαφέρον, καθώς επιτρέπει στα συστήματα να μαθαίνουν μέσα από συνεχή αλληλεπίδραση με το περιβάλλον και να βελτιστοποιούν τη μακροχρόνια εμπειρία των χρηστών (Chen et al., 2021). Παρά τη σημαντική πρόοδο που έχει σημειωθεί, τα συστήματα συστάσεων εξακολουθούν να αντιμετωπίζουν σημαντικές προκλήσεις. Προβλήματα όπως η ψυχρή εκκίνηση, η αραιότητα των δεδομένων, η υπερ-εξειδίκευση, η έλλειψη διαφάνειας και η δυσκολία ερμηνείας των προτάσεων εξακολουθούν να απασχολούν την ερευνητική κοινότητα. Εντωμεταξύ, η αυξανόμενη χρήση προσωπικών δεδομένων έχει αναδείξει σημαντικά ζητήματα ιδιωτικότητας, ασφάλειας και ηθικής. Η εμπιστοσύνη των χρηστών αναδεικνύεται πλέον ως κρίσιμος παράγοντας για την επιτυχία των συστημάτων συστάσεων, καθώς η αποτελεσματικότητα ενός αλγορίθμου δεν αρκεί από μόνη της εάν οι χρήστες δεν αντιλαμβάνονται το σύστημα ως αξιόπιστο και δίκαιο (Akdim et al., 2025). Επιπλέον, η ανάγκη ανάπτυξης επεξηγήσιμων συστημάτων συστάσεων έχει αποκτήσει ιδιαίτερη σημασία, καθώς οι χρήστες επιθυμούν να κατανοούν τους λόγους για τους οποίους λαμβάνουν συγκεκριμένες προτάσεις (Zhang & Chen, 2020).

Η παρούσα διπλωματική εργασία επικεντρώνεται στη μελέτη της χρήσης ευφυών τεχνικών για την ανάπτυξη συστημάτων συστάσεων. Η επιλογή του συγκεκριμένου θέματος βασίζεται τόσο στη θεωρητική όσο και στην πρακτική του σημασία. Από επιστημονική άποψη, τα συστήματα συστάσεων αποτελούν ένα από τα πλέον ενεργά ερευνητικά πεδία της τεχνητής νοημοσύνης, συγκεντρώνοντας σημαντικό ενδιαφέρον από την ακαδημαϊκή κοινότητα. Από πρακτική άποψη, η εφαρμογή τους επηρεάζει άμεσα την καθημερινότητα εκατομμυρίων χρηστών και τη λειτουργία επιχειρήσεων και οργανισμών σε παγκόσμιο επίπεδο. Η κατανόηση των τεχνικών που χρησιμοποιούνται για την ανάπτυξή τους και η αξιολόγηση της αποτελεσματικότητάς τους αποτελούν επομένως σημαντικά ζητήματα τόσο για την έρευνα όσο και για την πράξη.

Σκοπός της εργασίας είναι η διερεύνηση των βασικών κατηγοριών συστημάτων συστάσεων και η ανάλυση των ευφυών τεχνικών που χρησιμοποιούνται για τη βελτίωση της λειτουργίας τους. Ιδιαίτερη έμφαση δίνεται στις τεχνικές μηχανικής μάθησης και βαθιάς μάθησης, στις μεθόδους εξατομίκευσης και προσαρμοστικότητας, καθώς και στις σύγχρονες προκλήσεις που σχετίζονται με την αξιολόγηση, την επεξηγησιμότητα, την ιδιωτικότητα και την εμπιστοσύνη. Συγχρόνως,

εξετάζονται οι κυριότερες μετρικές αξιολόγησης, οι περιορισμοί των υφιστάμενων προσεγγίσεων και οι μελλοντικές ερευνητικές κατευθύνσεις του πεδίου.

Η δομή της εργασίας ακολουθεί μία λογική πορεία από τη θεωρητική θεμελίωση προς την ανάλυση των σύγχρονων τεχνικών και τάσεων. Αρχικά παρουσιάζονται οι βασικές έννοιες, η ιστορική εξέλιξη και οι κατηγορίες των συστημάτων συστάσεων. Στη συνέχεια αναλύονται οι κυριότερες ευφυείς τεχνικές της τεχνητής νοημοσύνης που χρησιμοποιούνται για την ανάπτυξή τους. Ακολουθεί η διερεύνηση των διαφορετικών προσεγγίσεων συστάσεων, η αξιολόγηση της αποτελεσματικότητάς τους και η συγκριτική ανάλυση των διαθέσιμων τεχνικών. Τέλος, εξετάζονται οι σύγχρονες εξελίξεις που σχετίζονται με τη βαθιά μάθηση, τα επεξηγήσιμα συστήματα συστάσεων, τα ζητήματα ιδιωτικότητας και τις μελλοντικές ερευνητικές προοπτικές.

ΚΕΦΑΛΑΙΟ 2: Θεωρητικό Υπόβαθρο των Συστημάτων Συστάσεων

2.1 Ορισμός και βασικές έννοιες των συστημάτων συστάσεων

Τα συστήματα συστάσεων αποτελούν μία από τις σημαντικότερες εφαρμογές της τεχνητής νοημοσύνης και της επιστήμης δεδομένων στη σύγχρονη ψηφιακή εποχή, καθώς σχεδιάζονται με σκοπό να υποστηρίζουν τους χρήστες στη διαδικασία λήψης αποφάσεων, προτείνοντας προϊόντα, υπηρεσίες ή πληροφορίες που είναι πιθανό να ανταποκρίνονται στις προτιμήσεις και τις ανάγκες τους. Η ανάπτυξη των συστημάτων αυτών συνδέεται άμεσα με την εκρηκτική αύξηση του διαθέσιμου ψηφιακού περιεχομένου και την ανάγκη αποτελεσματικής διαχείρισης της υπερπληροφόρησης, ένα φαινόμενο που καθιστά ολοένα και δυσκολότερη την εύρεση ουσιαστικά σχετικής πληροφορίας από τον τελικό χρήστη. Ήδη από τη δεκαετία του 1990 είχε επισημανθεί ότι η αυξανόμενη διαθεσιμότητα πληροφοριών στα υπολογιστικά συστήματα δημιουργούσε την ανάγκη ανάπτυξης ευφυών μηχανισμών φιλτραρίσματος, οι οποίοι θα μπορούσαν να μειώσουν τον γνωστικό φόρτο του χρήστη και να αυτοματοποιήσουν τη διαδικασία εντοπισμού χρήσιμου περιεχομένου (Maes, 1994). Μέσα σε αυτό το πλαίσιο, τα συστήματα συστάσεων εξελίχθηκαν από απλά εργαλεία φιλτραρίσματος σε πολύπλοκα ευφυή συστήματα λήψης αποφάσεων που ενσωματώνουν τεχνικές μηχανικής μάθησης, εξόρυξης δεδομένων, ανάλυσης συμπεριφοράς χρηστών και, πιο πρόσφατα, βαθιάς μάθησης. Σε θεωρητικό επίπεδο, ένα σύστημα συστάσεων μπορεί να οριστεί ως ένα πληροφοριακό σύστημα το οποίο συλλέγει, αναλύει και επεξεργάζεται δεδομένα σχετικά με τους χρήστες και τα διαθέσιμα αντικείμενα ενός συστήματος, προκειμένου να προβλέψει ποια από αυτά τα αντικείμενα παρουσιάζουν υψηλή πιθανότητα ενδιαφέροντος για κάθε συγκεκριμένο χρήστη. Σύμφωνα με τους Adomavicius και Tuzhilin (2005), τα συστήματα συστάσεων αποτελούν ειδική κατηγορία συστημάτων φιλτραρίσματος πληροφοριών, με κύριο στόχο την εξατομίκευση της πληροφορίας και την προσαρμογή της στις ιδιαίτερες προτιμήσεις του εκάστοτε ατόμου. Η έννοια της εξατομίκευσης αποτελεί βασικό πυλώνα της λειτουργίας τους, καθώς διαφοροποιεί τα συστήματα συστάσεων από τις παραδοσιακές μηχανές αναζήτησης ή τα στατικά πληροφοριακά συστήματα, τα οποία συνήθως παρέχουν το ίδιο αποτέλεσμα σε όλους τους χρήστες ανεξαρτήτως προφίλ, ιστορικού ή συμπεριφοράς.

Η θεμελιώδης λογική λειτουργίας ενός συστήματος συστάσεων βασίζεται στην υπόθεση ότι είναι δυνατό να εξαχθούν χρήσιμα συμπεράσματα για τις μελλοντικές προτιμήσεις ενός χρήστη μέσα από την ανάλυση προηγούμενων αλληλεπιδράσεών του με το σύστημα, αλλά και μέσα από την παρατήρηση της συμπεριφοράς άλλων χρηστών με παρόμοια χαρακτηριστικά ή προτιμήσεις. Οι πρώτες σημαντικές εφαρμογές αυτής της λογικής εμφανίστηκαν μέσα από την έννοια του

συνεργατικού φιλτραρίσματος, όπου οι προτιμήσεις μιας ομάδας χρηστών χρησιμοποιούνται ως βάση για την παραγωγή εξατομικευμένων προτάσεων. Η εργασία των Goldberg et al. (1992) θεωρείται μία από τις πρώτες ουσιαστικές υλοποιήσεις αυτής της προσέγγισης, παρουσιάζοντας ένα σύστημα το οποίο αξιοποιούσε αξιολογήσεις χρηστών για την αυτόματη επιλογή σχετικού περιεχομένου. Λίγα χρόνια αργότερα, το σύστημα GroupLens εισήγαγε μια πιο οργανωμένη αρχιτεκτονική συνεργατικού φιλτραρίσματος, αποδεικνύοντας ότι η συλλογική ανθρώπινη εμπειρία μπορεί να μετατραπεί σε υπολογιστικό μηχανισμό πρόβλεψης προτιμήσεων (Resnick et al., 1994). Η ιδέα αυτή εξακολουθεί να αποτελεί μέχρι σήμερα μία από τις βασικότερες θεωρητικές βάσεις των σύγχρονων recommender systems.

Κεντρική έννοια στη μελέτη των συστημάτων συστάσεων είναι το προφίλ χρήστη. Το προφίλ αυτό συνιστά μια υπολογιστική αναπαράσταση των ενδιαφερόντων, των προτιμήσεων, των συνηθειών και της συμπεριφοράς ενός ατόμου μέσα σε ένα πληροφοριακό περιβάλλον. Η δημιουργία του μπορεί να βασίζεται είτε σε ρητά δεδομένα, όπως αξιολογήσεις, σχόλια ή δηλωμένες προτιμήσεις, είτε σε έμμεσα δεδομένα, όπως ιστορικό περιήγησης, χρόνος παραμονής σε συγκεκριμένο περιεχόμενο, συχνότητα αλληλεπίδρασης ή προηγούμενες αγορές. Η έννοια του ευφυούς προσωπικού βοηθού, ο οποίος μαθαίνει προοδευτικά τις προτιμήσεις του χρήστη και λειτουργεί ως ενδιάμεσος μεταξύ αυτού και του διαθέσιμου πληροφοριακού όγκου, είχε ήδη παρουσιαστεί από τους Mitchell et al. (1994), οι οποίοι ανέδειξαν τη σημασία της προσαρμοστικής μάθησης στην ανάπτυξη εξατομικευμένων ψηφιακών υπηρεσιών. Η προσέγγιση αυτή συνδέει άμεσα τα συστήματα συστάσεων με τη γενικότερη φιλοσοφία των ευφυών πρακτόρων, δηλαδή αυτόνομων λογισμικών οντοτήτων που δρουν με σκοπό την υποστήριξη του χρήστη, προσαρμόζοντας τη συμπεριφορά τους με βάση τις μεταβαλλόμενες ανάγκες του (Genesereth & Ketchpel, 1994; Wooldridge & Jennings, 1995). Μία ακόμη βασική έννοια είναι η πρόβλεψη προτίμησης, δηλαδή η υπολογιστική εκτίμηση του βαθμού στον οποίο ένας χρήστης είναι πιθανό να ενδιαφερθεί για ένα συγκεκριμένο αντικείμενο. Η πρόβλεψη αυτή συχνά εκφράζεται με τη μορφή βαθμολογίας, πιθανότητας επιλογής ή σχετικού βαθμού συνάφειας. Στη σύγχρονη βιβλιογραφία, η διαδικασία αυτή έχει εξελιχθεί σημαντικά, με την εισαγωγή τεχνικών παραγοντοποίησης πινάκων, οι οποίες επιτρέπουν την ανακάλυψη λανθανόντων προτύπων στις σχέσεις χρηστών και αντικειμένων. Οι Koren, Bell και Volinsky (2009) ανέδειξαν ότι τέτοιες μέθοδοι μπορούν να αποτυπώσουν αφανή χαρακτηριστικά προτίμησης και να οδηγήσουν σε σημαντικά ακριβέστερες προβλέψεις. Ταυτοχρόνως, η μελέτη της χρονικής διάστασης των προτιμήσεων απέδειξε ότι οι επιλογές των χρηστών δεν είναι στατικές, αλλά μεταβάλλονται με την πάροδο του χρόνου, γεγονός που καθιστά αναγκαία την ενσωμάτωση δυναμικών μοντέλων μάθησης στα recommender systems (Koren, 2010).

Επιπροσθέτως, η έννοια της συνάφειας δεν περιορίζεται αποκλειστικά στην ακρίβεια πρόβλεψης. Ένα σύγχρονο σύστημα συστάσεων καλείται να προσφέρει προτάσεις που είναι όχι μόνο σχετικές, αλλά και ποικίλες, καινοτόμες, κατανοητές και αξιόπιστες. Η εξηγησιμότητα των συστάσεων αποτελεί πλέον σημαντικό ερευνητικό πεδίο, καθώς οι χρήστες τείνουν να εμπιστεύονται περισσότερο ένα σύστημα όταν κατανοούν τη λογική πίσω από τις προτάσεις που λαμβάνουν (Zhang & Chen, 2020). Ταυτοχρόνως, η έννοια της εμπιστοσύνης αναδεικνύεται ως κρίσιμος παράγοντας για τη μακροχρόνια αποδοχή των συστημάτων αυτών, ειδικά σε περιβάλλοντα όπου οι προτάσεις επηρεάζουν σημαντικές αποφάσεις, όπως η εκπαίδευση, η υγεία ή οι χρηματοοικονομικές υπηρεσίες (Akdim et al., 2025). Στη σύγχρονη εποχή, τα συστήματα συστάσεων έχουν εξελιχθεί σε πολύπλοκα οικοσυστήματα ευφυούς λήψης αποφάσεων, ενσωματώνοντας βαθιά νευρωνικά δίκτυα, μοντέλα ενισχυτικής μάθησης και τεχνικές πολυκριτηριακής βελτιστοποίησης. Η βιβλιογραφία δείχνει ότι οι νεότερες αρχιτεκτονικές επιτρέπουν την καλύτερη κατανόηση της ανθρώπινης συμπεριφοράς και τη δημιουργία ιδιαίτερα ακριβών, προσαρμοστικών και δυναμικών προτάσεων (Zhang et al., 2019; Chen et al., 2021; Li et al., 2023). Ωστόσο, παρά την τεχνολογική πρόοδο, ο βασικός θεωρητικός πυρήνας των συστημάτων συστάσεων παραμένει αμετάβλητος: η αξιοποίηση δεδομένων, γνώσης και ευφύων αλγορίθμων για την παροχή προσωποποιημένης πληροφορίας στο σωστό χρήστη, τη σωστή χρονική στιγμή. Υπό αυτό το πρίσμα, τα συστήματα συστάσεων δεν αποτελούν απλώς τεχνολογικά εργαλεία φιλτραρίσματος περιεχομένου, αλλά ολοκληρωμένα ευφυή συστήματα υποστήριξης αποφάσεων, με κεντρικό στόχο τη βελτίωση της εμπειρίας του χρήστη και την αποτελεσματικότερη διαχείριση της πληροφορίας στο σύγχρονο ψηφιακό περιβάλλον.

2.2 Ιστορική εξέλιξη και σημασία τους στην ψηφιακή εποχή

Η ιστορική εξέλιξη των συστημάτων συστάσεων είναι στενά συνδεδεμένη με τη γενικότερη πρόοδο της επιστήμης των υπολογιστών, της τεχνητής νοημοσύνης και των πληροφοριακών συστημάτων, καθώς και με τη διαρκώς αυξανόμενη ανάγκη αποτελεσματικής διαχείρισης της ψηφιακής πληροφορίας. Η ανάγκη για μηχανισμούς οι οποίοι θα μπορούσαν να φιλτράρουν, να οργανώνουν και να προσαρμόζουν την πληροφορία στις ιδιαίτερες ανάγκες του κάθε χρήστη άρχισε να διαμορφώνεται ήδη από τις τελευταίες δεκαετίες του 20ού αιώνα, όταν η διάδοση των υπολογιστικών συστημάτων και η ανάπτυξη του διαδικτύου οδήγησαν σε ραγδαία αύξηση του διαθέσιμου περιεχομένου. Μέχρι εκείνη την περίοδο, η πρόσβαση στην πληροφορία βασιζόταν κυρίως σε στατικά πληροφοριακά συστήματα και σε μηχανισμούς αναζήτησης που λειτουργούσαν με γενικά κριτήρια ταξινόμησης, χωρίς να λαμβάνουν υπόψη τα ιδιαίτερα χαρακτηριστικά, τις προτιμήσεις ή το ιστορικό αλληλεπίδρασης κάθε χρήστη. Όμως, η σταδιακή

μετάβαση σε ένα περιβάλλον έντονης πληροφορικής πολυπλοκότητας ανέδειξε την ανάγκη για περισσότερο προσωποποιημένες και ευφυείς λύσεις, ικανές να λειτουργούν ως φίλτρα γνώσης μέσα σε έναν συνεχώς διογκούμενο ψηφιακό κόσμο.

Σημαντικό θεωρητικό υπόβαθρο για τη μετέπειτα ανάπτυξη των συστημάτων συστάσεων αποτέλεσε η έννοια των ευφύων πρακτόρων. Κατά τη δεκαετία του 1990, η βιβλιογραφία της τεχνητής νοημοσύνης άρχισε να εξετάζει την προοπτική ανάπτυξης αυτόνομων λογισμικών οντοτήτων που θα μπορούσαν να ενεργούν για λογαριασμό του χρήστη, να μαθαίνουν από τη συμπεριφορά του και να προσαρμόζουν δυναμικά τις λειτουργίες τους στις ανάγκες του. Οι Genesereth και Ketchpel (1994) περιέγραψαν τους λογισμικούς πράκτορες ως υπολογιστικά συστήματα με σχετική αυτονομία, ικανά να αλληλεπιδρούν με το περιβάλλον τους και να επιδιώκουν συγκεκριμένους στόχους προς όφελος του χρήστη. Αντίστοιχα, οι Wooldridge και Jennings (1995) υπογράμμισαν ότι η έννοια της αυτονομίας, της προσαρμοστικότητας και της ευφυούς συμπεριφοράς αποτελεί βασικό στοιχείο στην ανάπτυξη σύγχρονων πληροφοριακών εφαρμογών. Οι ιδέες αυτές λειτούργησαν ως θεωρητική γέφυρα μεταξύ της παραδοσιακής τεχνητής νοημοσύνης και των πρώτων συστημάτων προσωποποιημένης σύστασης, καθώς εισήγαγαν την αντίληψη ότι ένα λογισμικό σύστημα μπορεί να λειτουργεί ενεργά υπέρ του χρήστη, αναλαμβάνοντας μέρος της διαδικασίας επιλογής πληροφορίας.

Μία από τις πρώτες ουσιαστικές αναφορές στην ανάγκη ανάπτυξης τέτοιων ευφύων ψηφιακών βοηθών προήλθε από την εργασία της Maes (1994), η οποία ανέδειξε ότι ο αυξανόμενος όγκος πληροφοριών δημιουργεί γνωστική επιβάρυνση στους χρήστες και καθιστά αναγκαία την ύπαρξη υπολογιστικών μηχανισμών που θα μειώνουν τον φόρτο αναζήτησης, επιλογής και αξιολόγησης πληροφορίας. Η Maes πρότεινε ότι ευφυείς πράκτορες θα μπορούσαν να λειτουργούν ως προσωπικοί βοηθοί, μαθαίνοντας σταδιακά τις προτιμήσεις και τις συνήθειες του χρήστη, ώστε να προτείνουν σχετικό περιεχόμενο χωρίς να απαιτείται συνεχής ρητή αναζήτηση. Η προσέγγιση αυτή αποτέλεσε μία από τις πρώτες διατυπώσεις της βασικής φιλοσοφίας που διέπει τα σημερινά recommender systems. Λίγα χρόνια αργότερα, η ίδια ερευνήτρια επέκτεινε αυτή τη σκέψη, παρουσιάζοντας ένα όραμα για έναν πιο «ανθρώπινο» ψηφιακό κόσμο, στον οποίο οι υπολογιστές θα λειτουργούν ως προσαρμοστικοί συνεργάτες του ανθρώπου και όχι απλώς ως εργαλεία εκτέλεσης εντολών (Maes, 1997). Η μετάβαση αυτή από την παθητική στην ενεργητική υπολογιστική υποστήριξη αποτέλεσε κομβικό σημείο στην ιστορική εξέλιξη των συστημάτων συστάσεων.

Σε επίπεδο πρακτικών εφαρμογών, η δεκαετία του 1990 αποτέλεσε την περίοδο κατά την οποία εμφανίστηκαν οι πρώτες ουσιαστικές υλοποιήσεις μηχανισμών συστάσεων. Η εργασία των

Goldberg et al. (1992) θεωρείται ιστορικής σημασίας, καθώς εισήγαγε μία από τις πρώτες μορφές συνεργατικού φιλτραρίσματος, βασισμένη στην ιδέα ότι οι αξιολογήσεις και οι προτιμήσεις μιας κοινότητας χρηστών μπορούν να αξιοποιηθούν για την πρόβλεψη των ενδιαφερόντων άλλων χρηστών. Η προσέγγιση αυτή εγκαινίασε μια νέα φιλοσοφία στη διαχείριση πληροφορίας, όπου η συλλογική εμπειρία μετατράπηκε σε μηχανισμό υπολογιστικής μάθησης. Λίγο αργότερα, το σύστημα GroupLens των Resnick et al. (1994) καθιέρωσε το συνεργατικό φιλτράρισμα ως βασικό ερευνητικό και εφαρμοσμένο πεδίο, παρουσιάζοντας μια αρχιτεκτονική που μπορούσε να επεξεργάζεται αξιολογήσεις χρηστών και να δημιουργεί εξατομικευμένες προτάσεις περιεχομένου σε μεγάλης κλίμακας περιβάλλοντα. Οι εφαρμογές αυτές απέδειξαν στην πράξη ότι οι υπολογιστές μπορούν να μάθουν πρότυπα ανθρώπινης προτίμησης και να υποστηρίξουν τη διαδικασία λήψης αποφάσεων. Κατά τη δεκαετία του 2000, η ανάπτυξη του ηλεκτρονικού εμπορίου και η μαζική διάδοση διαδικτυακών υπηρεσιών επιτάχυναν σημαντικά την εξέλιξη των συστημάτων συστάσεων. Η αυξανόμενη ανάγκη των επιχειρήσεων να κατανοήσουν καλύτερα τις προτιμήσεις των πελατών τους και να προσφέρουν προσωποποιημένες εμπειρίες οδήγησε στην ενσωμάτωση recommender systems σε εμπορικές πλατφόρμες μεγάλης κλίμακας. Χαρακτηριστικό παράδειγμα αποτελεί η αρχιτεκτονική προτάσεων της Amazon, η οποία βασίστηκε σε αλγορίθμους item-to-item collaborative filtering και επέτρεψε την άμεση παραγωγή προσωποποιημένων προτάσεων σε εκατομμύρια χρήστες με υψηλή αποδοτικότητα (Linden et al., 2003). Η συγκεκριμένη εξέλιξη κατέδειξε ότι τα συστήματα συστάσεων δεν αποτελούν μόνο ερευνητικό αντικείμενο, αλλά κρίσιμη επιχειρησιακή τεχνολογία με σημαντική εμπορική αξία. Την ίδια στιγμή, η συστηματική μελέτη των Adomavicius και Tuzhilin (2005) αποτύπωσε τη μετάβαση από τα απλά μοντέλα φιλτραρίσματος προς περισσότερο σύνθετα συστήματα, τα οποία ενσωματώνουν συμφραζόμενα δεδομένα, πολυδιάστατες προτιμήσεις και πιο προηγμένες τεχνικές υπολογιστικής μάθησης.

Η επόμενη μεγάλη φάση στην ιστορική εξέλιξη των συστημάτων συστάσεων ήρθε μέσα από την αξιοποίηση προηγμένων μεθόδων μηχανικής μάθησης. Η παραγοντοποίηση πινάκων αποτέλεσε σημείο καμπής, καθώς επέτρεψε την αποκάλυψη λανθανόντων προτύπων στις σχέσεις χρηστών και αντικειμένων και βελτίωσε δραστικά την ακρίβεια των προβλέψεων (Koren et al., 2009). Η εξέλιξη αυτή ενίσχυσε τη δυνατότητα δημιουργίας περισσότερο εξατομικευμένων και ακριβών προτάσεων, ενώ η εισαγωγή χρονικών δυναμικών στις προτιμήσεις των χρηστών ανέδειξε τη σημασία της προσαρμοστικότητας και της συνεχούς μάθησης (Koren, 2010). Στη συνέχεια, η εμφάνιση της βαθιάς μάθησης μεταμόρφωσε εκ νέου το πεδίο. Νευρωνικά δίκτυα υψηλής πολυπλοκότητας κατέστησαν δυνατή την επεξεργασία ετερογενών μορφών δεδομένων, όπως κείμενο, εικόνα, ήχος και πολύπλοκες ακολουθίες αλληλεπιδράσεων, επιτρέποντας στα

recommender systems να κατανοούν βαθύτερα τη συμπεριφορά των χρηστών (He et al., 2017; Covington et al., 2016; Cheng et al., 2016). Στη σημερινή ψηφιακή εποχή, η σημασία των συστημάτων συστάσεων είναι καθοριστική. Βρίσκονται στον πυρήνα σχεδόν κάθε μεγάλης ψηφιακής πλατφόρμας, από ηλεκτρονικά καταστήματα και υπηρεσίες συνεχούς ροής πολυμέσων έως κοινωνικά δίκτυα, ειδησεογραφικές εφαρμογές και εκπαιδευτικά περιβάλλοντα. Δεν περιορίζονται πλέον στην απλή πρόταση προϊόντων ή περιεχομένου, αλλά λειτουργούν ως μηχανισμοί διαμόρφωσης εμπειρίας, επηρεάζοντας ουσιαστικά τις επιλογές, τη συμπεριφορά και πολλές φορές ακόμη και τη γνώση των χρηστών. Η σύγχρονη βιβλιογραφία επισημαίνει ότι τα recommender systems αποτελούν πλέον πολυδιάστατα συστήματα λήψης αποφάσεων, τα οποία πρέπει να συνδυάζουν ακρίβεια, διαφάνεια, αξιοπιστία, πολυκριτηριακή βελτιστοποίηση και εμπιστοσύνη (Jannach et al., 2023; Akdim et al., 2025). Ακόμη, νέες προσεγγίσεις που βασίζονται στην ενισχυτική μάθηση και σε εξελιγμένα μοντέλα βαθιάς μάθησης επιτρέπουν τη δημιουργία δυναμικών συστημάτων που αλληλεπιδρούν συνεχώς με τον χρήστη και προσαρμόζονται σε πραγματικό χρόνο στις μεταβαλλόμενες ανάγκες του (Chen et al., 2021; Zhou et al., 2023; Li et al., 2023).

2.3 Βασικές κατηγορίες συστημάτων συστάσεων

Η κατηγοριοποίηση των συστημάτων συστάσεων αποτελεί θεμελιώδες ζήτημα στη σχετική βιβλιογραφία, καθώς επιτρέπει την κατανόηση των διαφορετικών μεθοδολογικών προσεγγίσεων που έχουν αναπτυχθεί για την παραγωγή εξατομικευμένων προτάσεων. Παρά τη μεγάλη ποικιλία αλγορίθμων και τεχνικών που χρησιμοποιούνται στη σύγχρονη εποχή, η βασική αρχή λειτουργίας όλων των συστημάτων συστάσεων παραμένει κοινή: η αξιοποίηση διαθέσιμων δεδομένων προκειμένου να προβλεφθεί με όσο το δυνατόν μεγαλύτερη ακρίβεια ποιο περιεχόμενο, ποιο προϊόν ή ποια πληροφορία είναι περισσότερο σχετική με τις ανάγκες, τα ενδιαφέροντα και τις προτιμήσεις ενός συγκεκριμένου χρήστη. Πάραυτα, οι διαφορετικοί τρόποι με τους οποίους τα δεδομένα αυτά συλλέγονται, αναλύονται και αξιοποιούνται έχουν οδηγήσει στη διαμόρφωση διακριτών κατηγοριών συστημάτων συστάσεων, καθεμία από τις οποίες βασίζεται σε διαφορετικές θεωρητικές παραδοχές και παρουσιάζει διαφορετικά πλεονεκτήματα και περιορισμούς. Σύμφωνα με τους Adomavicius και Tuzhilin (2005), η κατανόηση των κύριων κατηγοριών αποτελεί απαραίτητη προϋπόθεση για την ορθή μελέτη και αξιολόγηση των συστημάτων συστάσεων, καθώς η επιλογή της κατάλληλης προσέγγισης εξαρτάται σε μεγάλο βαθμό από τη φύση των διαθέσιμων δεδομένων, τα χαρακτηριστικά του πεδίου εφαρμογής και τους στόχους της εξατομίκευσης.

Η πρώτη και ιστορικά σημαντικότερη κατηγορία είναι τα συνεργατικά συστήματα συστάσεων, τα οποία βασίζονται στη θεμελιώδη υπόθεση ότι χρήστες με παρόμοιες προτιμήσεις στο παρελθόν είναι πιθανό να εμφανίσουν παρόμοιες προτιμήσεις και στο μέλλον. Η προσέγγιση αυτή δεν εξετάζει άμεσα τα χαρακτηριστικά των αντικειμένων που προτείνονται, αλλά επικεντρώνεται στη συλλογική συμπεριφορά των χρηστών, αξιοποιώντας μοτίβα αλληλεπίδρασης, αξιολογήσεις, ιστορικά επιλογών ή άλλες μορφές συμπεριφορικών δεδομένων. Οι πρώτες πρακτικές εφαρμογές αυτής της λογικής εμφανίστηκαν μέσα από την εργασία των Goldberg et al. (1992), οι οποίοι εισήγαγαν την ιδέα της συλλογικής αξιοποίησης προτιμήσεων για το φιλτράρισμα πληροφορίας. Στη συνέχεια, το GroupLens των Resnick et al. (1994) εδραίωσε το συνεργατικό φιλτράρισμα ως βασική αρχιτεκτονική recommendation, αποδεικνύοντας ότι η ανάλυση αξιολογήσεων χρηστών μπορεί να χρησιμοποιηθεί αποτελεσματικά για την παραγωγή εξατομικευμένων προτάσεων μεγάλης κλίμακας. Η περαιτέρω εξέλιξη αυτής της κατηγορίας οδήγησε στην ανάπτυξη item-based collaborative filtering, όπου η σύσταση βασίζεται όχι μόνο στην ομοιότητα μεταξύ χρηστών αλλά και στην ομοιότητα μεταξύ αντικειμένων, μια προσέγγιση που αποδείχθηκε ιδιαίτερα αποδοτική σε εμπορικά περιβάλλοντα μεγάλης κλίμακας (Sarwar et al., 2001). Η εφαρμογή αντίστοιχων τεχνικών στην Amazon επιβεβαίωσε τη χρηστικότητα της προσέγγισης, καθώς το item-to-item collaborative filtering επέτρεψε τη δημιουργία γρήγορων και υψηλής ποιότητας προσωποποιημένων προτάσεων για εκατομμύρια χρήστες (Linden et al., 2003). Μία δεύτερη βασική κατηγορία είναι τα συστήματα συστάσεων βασισμένα στο περιεχόμενο, τα οποία λειτουργούν με διαφορετική λογική. Αντί να βασίζονται στις προτιμήσεις άλλων χρηστών, εξετάζουν τα χαρακτηριστικά των αντικειμένων που ένας χρήστης έχει ήδη δείξει ότι προτιμά, προκειμένου να προτείνουν παρόμοια αντικείμενα στο μέλλον. Η βασική θεωρητική παραδοχή αυτής της προσέγγισης είναι ότι η προηγούμενη συμπεριφορά του ίδιου του χρήστη αποτελεί τον πιο αξιόπιστο δείκτη των μελλοντικών επιλογών του. Εδώ, κρίσιμο ρόλο παίζει η αναπαράσταση των αντικειμένων μέσα από χαρακτηριστικά γνωρίσματα, όπως λέξεις-κλειδιά, κατηγορίες, μεταδεδομένα ή πιο σύνθετες σημασιολογικές αναπαραστάσεις. Συγχρόνως, δημιουργείται ένα δυναμικό προφίλ χρήστη, το οποίο εμπλουτίζεται διαρκώς μέσα από τη συνεχή αλληλεπίδραση με το σύστημα. Η προσέγγιση αυτή συνδέεται εννοιολογικά με τη φιλοσοφία των ευφύων πρακτόρων, όπως περιγράφηκε από τους Genesereth και Ketchpel (1994), καθώς το σύστημα λειτουργεί ως ένας προσαρμοστικός ψηφιακός βοηθός που μαθαίνει σταδιακά τις ατομικές προτιμήσεις και προσαρμόζει τη συμπεριφορά του ανάλογα. Παρόμοιες ιδέες είχαν αναπτυχθεί και από τους Mitchell et al. (1994), οι οποίοι περιέγραψαν τη λειτουργία ενός προσωπικού βοηθού μάθησης ικανού να παρακολουθεί και να κατανοεί τα ενδιαφέροντα του χρήστη με σκοπό την παροχή προσωποποιημένων υπηρεσιών. Αν και τα content-based systems προσφέρουν υψηλό βαθμό εξατομικεύσης, συχνά περιορίζονται στη δημιουργία

προτάσεων που παραμένουν κοντά στις ήδη γνωστές προτιμήσεις του χρήστη, περιορίζοντας την ανακάλυψη νέου ή διαφορετικού περιεχομένου.

Η τρίτη σημαντική κατηγορία είναι τα συστήματα βασισμένα στη γνώση, τα οποία αξιοποιούν ρητή γνώση σχετικά με τις ανάγκες του χρήστη, τα χαρακτηριστικά των αντικειμένων και τους κανόνες αντιστοίχισης μεταξύ τους. Σε αντίθεση με τα collaborative ή content-based συστήματα, εδώ η παραγωγή συστάσεων δεν εξαρτάται αποκλειστικά από ιστορικά δεδομένα ή μοτίβα συμπεριφοράς, αλλά βασίζεται σε μοντέλα γνώσης, κανόνες λογικής και συστήματα αναπαράστασης σχέσεων μεταξύ χαρακτηριστικών. Αυτή η κατηγορία είναι ιδιαίτερα χρήσιμη σε περιβάλλοντα όπου οι αποφάσεις είναι πιο σύνθετες, οι αγορές σπανιότερες ή τα διαθέσιμα ιστορικά δεδομένα περιορισμένα. Παρότι στη σύγχρονη βιβλιογραφία η συγκεκριμένη προσέγγιση συχνά συνδυάζεται με άλλες μεθόδους, εξακολουθεί να αποτελεί σημαντική θεωρητική κατηγορία, ιδιαίτερα σε τομείς όπως η εκπαίδευση, η υγεία και οι επαγγελματικές υπηρεσίες. Η λογική αυτή βρίσκεται κοντά στη θεώρηση των ευφύων πρακτόρων ως λογισμικών οντοτήτων που διαθέτουν εσωτερικά μοντέλα γνώσης και λειτουργούν με βάση στόχους, περιορισμούς και κανόνες απόφασης (Wooldridge & Jennings, 1995; Nwana & Ndumu, 1998).

Η εξέλιξη των πληροφοριακών συστημάτων και η αυξανόμενη πολυπλοκότητα των ψηφιακών οικοσυστημάτων οδήγησαν στη δημιουργία υβριδικών συστημάτων συστάσεων, τα οποία συνδυάζουν περισσότερες από μία τεχνικές προκειμένου να αξιοποιήσουν τα πλεονεκτήματα κάθε προσέγγισης και να μειώσουν τις αδυναμίες τους. Η ανάπτυξη αυτής της κατηγορίας αποτέλεσε ουσιαστικό σημείο καμπής στη βιβλιογραφία των recommender systems, καθώς αναγνωρίστηκε ότι καμία μεμονωμένη μέθοδος δεν μπορεί να ανταποκριθεί απόλυτα στις απαιτήσεις πραγματικών εφαρμογών. Τα υβριδικά συστήματα συνδυάζουν συχνά συνεργατικό φιλτράρισμα, ανάλυση περιεχομένου, σημασιολογική γνώση και μηχανική μάθηση σε ένα ενιαίο πλαίσιο πρόβλεψης. Σύμφωνα με τους Adomavicius και Tuzhilin (2005), η υβριδική προσέγγιση αποτελεί τη φυσική εξέλιξη του πεδίου, καθώς προσφέρει μεγαλύτερη ευελιξία, καλύτερη προσαρμοστικότητα και πιο ισορροπημένες προτάσεις. Η τάση αυτή ενισχύθηκε ακόμη περισσότερο με την είσοδο των τεχνικών παραγοντοποίησης πινάκων, οι οποίες εισήγαγαν μια νέα διάσταση στη μοντελοποίηση προτιμήσεων, αξιοποιώντας λανθάνοντες παράγοντες για τη βαθύτερη κατανόηση της σχέσης χρήστη-αντικειμένου (Koren et al., 2009). Συγχρόνως, η αξιοποίηση έμμεσης ανατροφοδότησης από τη συμπεριφορά των χρηστών, όπως προβολές, κλικ ή διάρκεια αλληλεπίδρασης, επέκτεινε σημαντικά τη δυνατότητα μάθησης των recommender systems σε περιβάλλοντα όπου οι ρητές αξιολογήσεις είναι περιορισμένες (Hu et al., 2008).

Στη σύγχρονη εποχή, η κατηγοριοποίηση των συστημάτων συστάσεων έχει επεκταθεί ακόμη περισσότερο, καθώς η ενσωμάτωση βαθιάς μάθησης δημιούργησε νέες υποκατηγορίες ευφυών recommendation architectures. Η νευρωνική συνεργατική φιλτραριστική προσέγγιση αντικαθιστά ή εμπλουτίζει τις παραδοσιακές τεχνικές ομοιότητας με βαθιά νευρωνικά δίκτυα, ικανά να συλλαμβάνουν πολύπλοκες, μη γραμμικές σχέσεις μεταξύ χρηστών και αντικειμένων (He et al., 2017). Επιπρόσθετα, αρχιτεκτονικές όπως τα deep neural recommendation models επέτρεψαν την αξιοποίηση πολλαπλών πηγών δεδομένων, συμπεριλαμβανομένων δημογραφικών στοιχείων, ιστορικού συμπεριφοράς, συμφραζομένων δεδομένων και πολυμεσικού περιεχομένου, βελτιώνοντας σημαντικά την ακρίβεια και τη δυναμική προσαρμογή των προτάσεων (Covington et al., 2016; Cheng et al., 2016). Η βιβλιογραφία των τελευταίων ετών δείχνει ότι η βαθιά μάθηση δεν αποτελεί απλώς μια νέα τεχνική, αλλά μια νέα γενιά recommendation systems, η οποία επιτρέπει τη δημιουργία πολυδιάστατων, ευφυών και ιδιαίτερα προσαρμοστικών μηχανισμών εξατομίκευσης (Zhang et al., 2019; Zhou et al., 2023).

Αξίζει επίσης να σημειωθεί πως, έχουν εμφανιστεί εξειδικευμένες κατηγορίες, όπως context-aware συστήματα που λαμβάνουν υπόψη το πλαίσιο χρήσης, multi-objective recommender systems που βελτιστοποιούν πολλαπλά κριτήρια ταυτόχρονα, explainable recommender systems που στοχεύουν στη διαφάνεια των προτάσεων και reinforcement learning-based systems που μαθαίνουν δυναμικά μέσα από συνεχή αλληλεπίδραση με τον χρήστη (Zhang & Chen, 2020; Chen et al., 2021; Jannach et al., 2023). Η ύπαρξη αυτών των σύγχρονων κατηγοριών αποδεικνύει ότι τα recommender systems έχουν εξελιχθεί από απλούς μηχανισμούς πρόβλεψης σε σύνθετα ευφυή συστήματα λήψης αποφάσεων, με υψηλό βαθμό προσαρμοστικότητας, αυτονομίας και εξατομίκευσης.

2.4 Πλεονεκτήματα, προκλήσεις και περιορισμοί

Τα συστήματα συστάσεων αποτελούν σήμερα αναπόσπαστο μέρος της σύγχρονης ψηφιακής εμπειρίας, έχοντας καθιερωθεί ως βασικός μηχανισμός διαχείρισης πληροφορίας, υποστήριξης λήψης αποφάσεων και εξατομίκευσης υπηρεσιών σε ένα ευρύ φάσμα εφαρμογών. Η εκτεταμένη υιοθέτησή τους από ηλεκτρονικές πλατφόρμες, υπηρεσίες ψηφιακού περιεχομένου, κοινωνικά δίκτυα, εκπαιδευτικά συστήματα και επαγγελματικά πληροφοριακά περιβάλλοντα δεν είναι τυχαία, αλλά απορρέει από τα σημαντικά πλεονεκτήματα που προσφέρουν τόσο στους τελικούς χρήστες όσο και στους οργανισμούς που τα αξιοποιούν. Περαιτέρω, η αυξανόμενη πολυπλοκότητα των ψηφιακών οικοσυστημάτων, η διαρκής μεταβολή της ανθρώπινης συμπεριφοράς και οι νέες απαιτήσεις σε επίπεδο διαφάνειας, εμπιστοσύνης και ηθικής χρήσης δεδομένων έχουν αναδείξει ένα σύνολο σημαντικών προκλήσεων και περιορισμών, οι οποίοι

επηρεάζουν ουσιαστικά τη σχεδίαση, την απόδοση και την κοινωνική αποδοχή των συστημάτων αυτών. Ως αποτέλεσμα, η επιστημονική μελέτη των recommender systems δεν περιορίζεται πλέον στην ανάπτυξη ακριβέστερων αλγορίθμων πρόβλεψης, αλλά επεκτείνεται στην αναζήτηση ισορροπίας ανάμεσα στην αποτελεσματικότητα, τη χρηστικότητα, την αξιοπιστία και τη δίκαιη λειτουργία τους.

Ένα από τα σημαντικότερα πλεονεκτήματα των συστημάτων συστάσεων είναι η δυνατότητα αντιμετώπισης του φαινομένου της υπερπληροφόρησης. Στη σύγχρονη ψηφιακή εποχή, ο όγκος της διαθέσιμης πληροφορίας έχει αυξηθεί σε τέτοιο βαθμό ώστε η διαδικασία επιλογής να καθίσταται συχνά ιδιαίτερα δύσκολη για τον χρήστη. Η αφθονία προϊόντων, υπηρεσιών και ψηφιακού περιεχομένου, αντί να διευκολύνει τη λήψη αποφάσεων, πολλές φορές οδηγεί σε γνωστική υπερφόρτωση, αβεβαιότητα και καθυστέρηση στην επιλογή. Ήδη από τη δεκαετία του 1990, η Maes (1994) είχε επισημάνει ότι η πληροφοριακή υπερφόρτωση αποτελεί ένα από τα βασικά προβλήματα της ψηφιακής κοινωνίας και υποστήριξε ότι ευφυείς υπολογιστικοί πράκτορες μπορούν να λειτουργήσουν ως φίλτρα πληροφορίας, αναλαμβάνοντας μέρος της γνωστικής επεξεργασίας για λογαριασμό του χρήστη. Η προσέγγιση αυτή αποτέλεσε θεμελιώδη ιδέα για τη μετέπειτα εξέλιξη των recommender systems, τα οποία σήμερα λειτουργούν ακριβώς ως μηχανισμοί μείωσης της πληροφοριακής πολυπλοκότητας, προσφέροντας στοχευμένες και σχετικές προτάσεις που εξοικονομούν χρόνο, μειώνουν την αβεβαιότητα και βελτιώνουν τη συνολική εμπειρία χρήσης.

Εξίσου σημαντικό πλεονέκτημα είναι η δυνατότητα εξατομίκευσης της εμπειρίας του χρήστη. Σε αντίθεση με τα παραδοσιακά πληροφοριακά συστήματα, τα οποία παρέχουν ομοιόμορφο περιεχόμενο σε όλους, τα συστήματα συστάσεων προσαρμόζουν δυναμικά την παρεχόμενη πληροφορία με βάση το προφίλ, τη συμπεριφορά, τις προτιμήσεις και το ιστορικό αλληλεπίδρασης κάθε χρήστη. Η εξατομίκευση αυτή δημιουργεί μεγαλύτερη αίσθηση συνάφειας, αυξάνει την ικανοποίηση και ενισχύει τη μακροχρόνια δέσμευση του χρήστη με την πλατφόρμα. Οι Mitchell et al. (1994) είχαν ήδη αναδείξει τη σημασία των ευφύων προσωπικών βοηθών που μαθαίνουν σταδιακά τις προτιμήσεις του χρήστη και προσαρμόζουν τη συμπεριφορά τους ανάλογα, ενώ οι Genesereth και Ketchpel (1994) καθώς και οι Wooldridge και Jennings (1995) ενίσχυσαν θεωρητικά την ιδέα αυτή μέσα από το πλαίσιο των ευφύων πρακτόρων, δηλαδή αυτόνομων λογισμικών οντοτήτων που δρουν προς όφελος του χρήστη. Στη σύγχρονη εποχή, η προσωποποίηση έχει εξελιχθεί σε στρατηγικό πυλώνα των ψηφιακών υπηρεσιών, καθώς οι πλατφόρμες αξιοποιούν πολύπλοκες μεθόδους μηχανικής μάθησης και βαθιάς μάθησης για να κατανοήσουν βαθύτερα τη συμπεριφορά των χρηστών και να προσφέρουν όλο και πιο ακριβείς και δυναμικές προτάσεις (Zhang et al., 2019; Li et al., 2023).

Από επιχειρησιακή σκοπιά, τα συστήματα συστάσεων προσφέρουν σημαντικά οφέλη σε οργανισμούς και επιχειρήσεις, καθώς ενισχύουν τη διατήρηση χρηστών, αυξάνουν την κατανάλωση περιεχομένου και βελτιώνουν τη μετατροπή επισκέψεων σε αγορές ή άλλες επιθυμητές ενέργειες. Η εφαρμογή recommendation τεχνολογιών από μεγάλες ψηφιακές πλατφόρμες απέδειξε ότι η σωστή εξατομίκευση μπορεί να αποτελέσει κρίσιμο ανταγωνιστικό πλεονέκτημα. Το παράδειγμα της Amazon είναι χαρακτηριστικό, καθώς η υιοθέτηση item-to-item collaborative filtering επέτρεψε την ανάπτυξη μιας εξαιρετικά αποδοτικής μηχανής προτάσεων μεγάλης κλίμακας, η οποία βελτίωσε σημαντικά τη σχετικότητα των προτεινόμενων προϊόντων και ενίσχυσε την εμπορική αποτελεσματικότητα της πλατφόρμας (Linden et al., 2003). Αντίστοιχα, η αξιοποίηση βαθιών νευρωνικών δικτύων για recommendation σε πλατφόρμες μαζικής χρήσης επέτρεψε την κατανόηση πολυδιάστατων μοτίβων συμπεριφοράς και την παραγωγή περισσότερο προσαρμοστικών και στοχευμένων προτάσεων (Covington et al., 2016; Cheng et al., 2016).

Παρά τα σημαντικά αυτά πλεονεκτήματα, τα συστήματα συστάσεων αντιμετωπίζουν σοβαρές τεχνικές προκλήσεις. Μία από τις πιο γνωστές είναι το πρόβλημα της ψυχρής εκκίνησης, το οποίο εμφανίζεται όταν ένα σύστημα διαθέτει ελάχιστα ή καθόλου δεδομένα για έναν νέο χρήστη ή ένα νέο αντικείμενο. Σε τέτοιες περιπτώσεις, η παραγωγή αξιόπιστων προτάσεων καθίσταται εξαιρετικά δύσκολη, ιδιαίτερα για collaborative approaches που βασίζονται σε ιστορικά δεδομένα αλληλεπίδρασης. Συναφές είναι και το πρόβλημα της αραιότητας δεδομένων, καθώς σε μεγάλης κλίμακας συστήματα ο πίνακας αλληλεπίδρασης χρηστών–αντικειμένων είναι συνήθως εξαιρετικά αραιός, με αποτέλεσμα να υπάρχουν περιορισμένες άμεσες ενδείξεις προτίμησης για την εκπαίδευση αλγορίθμων. Οι τεχνικές παραγοντοποίησης πινάκων αποτέλεσαν σημαντική πρόοδο στην αντιμετώπιση αυτού του προβλήματος, καθώς επέτρεψαν την ανακάλυψη λανθανόντων σχέσεων ακόμη και σε εξαιρετικά αραιά σύνολα δεδομένων (Koren et al., 2009). Επίσης, η αξιοποίηση έμμεσης ανατροφοδότησης, όπως προβολές, κλικ και χρόνος αλληλεπίδρασης, διεύρυνε σημαντικά τη δυνατότητα μάθησης σε περιβάλλοντα περιορισμένων ρητών αξιολογήσεων (Hu et al., 2008; Rendle et al., 2009).

Ένας ακόμη σημαντικός περιορισμός αφορά τον κίνδυνο υπερ-εξειδίκευσης και δημιουργίας πληροφοριακών «φούσκων». Όταν ένα recommender system εστιάζει υπερβολικά στις ήδη γνωστές προτιμήσεις του χρήστη, υπάρχει ο κίνδυνος να περιορίσει την έκθεσή του σε νέες ιδέες, διαφορετικά προϊόντα ή εναλλακτικές οπτικές. Το αποτέλεσμα είναι η δημιουργία ενός κλειστού κύκλου προτάσεων που ενισχύει υφιστάμενες προτιμήσεις χωρίς να προάγει την ανακάλυψη νέου περιεχομένου. Αυτό όχι μόνο μειώνει την ποικιλία των προτάσεων αλλά ενδέχεται να έχει και ευρύτερες κοινωνικές συνέπειες, ιδιαίτερα όταν τα recommendation

systems επηρεάζουν την ενημέρωση, την πολιτισμική κατανάλωση ή την κοινωνική αλληλεπίδραση. Για τον λόγο αυτό, η σύγχρονη βιβλιογραφία δίνει ιδιαίτερη έμφαση στη βελτιστοποίηση πολλαπλών στόχων, έτσι ώστε τα συστήματα να ισορροπούν ανάμεσα στην ακρίβεια, την ποικιλία, τη δικαιοσύνη και την καινοτομία των προτάσεων (Jannach et al., 2023). Εξίσου σημαντική είναι η πρόκληση της διαφάνειας και της εξηγησιμότητας. Καθώς οι recommendation αλγόριθμοι γίνονται ολοένα πιο σύνθετοι, ιδιαίτερα με την εισαγωγή βαθιών νευρωνικών δικτύων, η εσωτερική λογική παραγωγής προτάσεων γίνεται δυσκολότερο να κατανοηθεί τόσο από τους χρήστες όσο και από τους ίδιους τους σχεδιαστές των συστημάτων. Η αδιαφάνεια αυτή ενδέχεται να μειώσει την εμπιστοσύνη, να ενισχύσει προκαταλήψεις ή να οδηγήσει σε μη αναμενόμενες συμπεριφορές του συστήματος. Η ανάγκη για explainable recommender systems έχει αναδειχθεί έντονα τα τελευταία χρόνια, με στόχο τη δημιουργία μηχανισμών που όχι μόνο προτείνουν, αλλά και αιτιολογούν με σαφήνεια τις προτάσεις τους, ενισχύοντας την κατανόηση, την εμπιστοσύνη και την αποδοχή από τον χρήστη (Zhang & Chen, 2020).

Τέλος, η συνεχής συλλογή και επεξεργασία μεγάλου όγκου προσωπικών δεδομένων εγείρει σοβαρά ζητήματα ιδιωτικότητας, ηθικής χρήσης δεδομένων και εμπιστοσύνης. Η ακριβής προσωποποίηση απαιτεί συχνά λεπτομερή γνώση της συμπεριφοράς, των προτιμήσεων και των μοτίβων αλληλεπίδρασης των χρηστών, γεγονός που μπορεί να δημιουργήσει ανησυχίες σχετικά με την ιδιωτικότητα, την επιτήρηση και την πιθανή κατάχρηση δεδομένων. Επίσης, οι αλγόριθμοι ενδέχεται να αναπαράγουν ή να ενισχύσουν υφιστάμενες κοινωνικές προκαταλήψεις που υπάρχουν στα δεδομένα εκπαίδευσης, οδηγώντας σε μεροληπτικές ή άδικες προτάσεις. Η εμπιστοσύνη, επομένως, αναδεικνύεται ως κεντρική διάσταση της επιτυχίας ενός recommender system, όχι μόνο από τεχνική αλλά και από κοινωνικο-ηθική σκοπιά (Akdim et al., 2025).

ΚΕΦΑΛΑΙΟ 3: Ευφυείς Τεχνικές και Μέθοδοι Τεχνητής Νοημοσύνης

3.1 Μηχανική μάθηση και εφαρμογές της

Η μηχανική μάθηση αποτελεί έναν από τους σημαντικότερους κλάδους της τεχνητής νοημοσύνης και συνιστά τη βασική τεχνολογική υποδομή πάνω στην οποία στηρίζεται μεγάλο μέρος των σύγχρονων ευφύων πληροφοριακών συστημάτων. Ως επιστημονικό πεδίο, η μηχανική μάθηση επικεντρώνεται στην ανάπτυξη υπολογιστικών μεθόδων που επιτρέπουν σε ένα σύστημα να μαθαίνει από δεδομένα, να αναγνωρίζει πρότυπα, να προσαρμόζει τη συμπεριφορά του βάσει εμπειρίας και να βελτιώνει την απόδοσή του χωρίς να απαιτείται ρητός προγραμματισμός για κάθε πιθανή περίπτωση λειτουργίας. Η βασική φιλοσοφία της μηχανικής μάθησης έγκειται στην ιδέα ότι οι υπολογιστές μπορούν να αποκτήσουν λειτουργική γνώση μέσω της παρατήρησης δεδομένων και της συνεχούς προσαρμογής των εσωτερικών μοντέλων τους, γεγονός που τους επιτρέπει να αντιμετωπίζουν σύνθετα προβλήματα πρόβλεψης, ταξινόμησης, λήψης αποφάσεων και εξατομίκευσης. Στο πλαίσιο των συστημάτων συστάσεων, η μηχανική μάθηση έχει αποκτήσει κομβική σημασία, καθώς επιτρέπει τη μετατροπή μεγάλου όγκου δεδομένων χρήστη σε αξιοποιήσιμη γνώση σχετικά με προτιμήσεις, μοτίβα συμπεριφοράς και πιθανές μελλοντικές επιλογές, καθιστώντας δυνατή τη δημιουργία δυναμικών και ιδιαίτερα ακριβών μηχανισμών πρότασης περιεχομένου.

Η σύνδεση της μηχανικής μάθησης με την έννοια της ευφυούς υπολογιστικής συμπεριφοράς εμφανίζεται ήδη στις πρώτες θεωρητικές προσεγγίσεις των λογισμικών πρακτόρων. Οι Genesereth και Ketchpel (1994) περιέγραψαν τους software agents ως αυτόνομα λογισμικά συστήματα που ενεργούν για λογαριασμό του χρήστη μέσα σε ένα υπολογιστικό περιβάλλον, προσαρμόζοντας τη συμπεριφορά τους ανάλογα με τους στόχους και τις μεταβαλλόμενες συνθήκες λειτουργίας. Η αυτονομία αυτή προϋποθέτει μηχανισμούς μάθησης, καθώς ένα σύστημα δεν μπορεί να λειτουργήσει πραγματικά προσαρμοστικά αν δεν έχει τη δυνατότητα να επεξεργάζεται εμπειρικά δεδομένα και να αναπροσαρμόζει τη στρατηγική του βάσει προηγούμενων αλληλεπιδράσεων. Παρόμοια, οι Wooldridge και Jennings (1995) υπογράμμισαν ότι η ευφυΐα ενός πράκτορα σχετίζεται άμεσα με την ικανότητά του να αντιλαμβάνεται το περιβάλλον, να αξιολογεί εναλλακτικές επιλογές και να λαμβάνει αποφάσεις υπό συνθήκες αβεβαιότητας, στοιχεία τα οποία αποτελούν βασικές λειτουργικές εκφάνσεις της μηχανικής μάθησης στα σύγχρονα πληροφοριακά συστήματα. Η έννοια αυτή αποκτά ιδιαίτερη σημασία στα

recommender systems, όπου το σύστημα καλείται να «κατανοήσει» τον χρήστη, να προβλέψει τη συμπεριφορά του και να προσαρμόζεται συνεχώς στις αλλαγές των προτιμήσεών του.

Η εφαρμογή της μηχανικής μάθησης στα συστήματα συστάσεων αναδείχθηκε ιδιαίτερα μέσα από την εξέλιξη των συνεργατικών μεθόδων φιλτραρίσματος. Οι πρώτες προσεγγίσεις recommendation βασίζονταν κυρίως σε σχετικά απλές στατιστικές τεχνικές ομοιότητας μεταξύ χρηστών ή αντικειμένων, όπου οι προτιμήσεις ενός χρήστη εκτιμώνταν βάσει της συμπεριφοράς άλλων χρηστών με παρόμοιο ιστορικό αλληλεπίδρασης. Οι Goldberg et al. (1992) εισήγαγαν την ιδέα ότι οι συλλογικές προτιμήσεις μιας κοινότητας χρηστών μπορούν να λειτουργήσουν ως πηγή γνώσης για τη δημιουργία εξατομικευμένων προτάσεων, εγκαινιάζοντας ουσιαστικά την υπολογιστική λογική του collaborative filtering. Το GroupLens των Resnick et al. (1994) επέκτεινε αυτή τη θεώρηση, εισάγοντας αρχιτεκτονικές ικανές να επεξεργάζονται μεγάλης κλίμακας δεδομένα αξιολογήσεων και να παράγουν δυναμικές προβλέψεις προτίμησης. Αν και οι πρώτες αυτές εφαρμογές δεν αξιοποιούσαν εξελιγμένα μοντέλα μάθησης όπως αυτά που χρησιμοποιούνται σήμερα, έθεσαν τα θεμέλια για την αντίληψη ότι οι προτιμήσεις των χρηστών μπορούν να μαθευτούν υπολογιστικά μέσα από δεδομένα, μια βασική αρχή της μηχανικής μάθησης.

Η ουσιαστική μετάβαση προς περισσότερο προηγμένα μοντέλα μηχανικής μάθησης πραγματοποιήθηκε με την αξιοποίηση τεχνικών λανθανουσών αναπαραστάσεων και παραγοντοποίησης πινάκων. Οι Koren, Bell και Volinsky (2009) έδειξαν ότι οι παραδοσιακές μέθοδοι ομοιότητας μπορούν να αντικατασταθούν από υπολογιστικά μοντέλα που μαθαίνουν αφανείς παράγοντες προτίμησης, δηλαδή βαθύτερα μοτίβα που δεν είναι άμεσα ορατά στα αρχικά δεδομένα αλλά αποτυπώνουν ουσιαστικές σχέσεις μεταξύ χρηστών και αντικειμένων. Η καινοτομία αυτή αποτελεί χαρακτηριστικό παράδειγμα εφαρμογής μηχανικής μάθησης, καθώς το σύστημα δεν βασίζεται σε προκαθορισμένους κανόνες, αλλά «εκπαιδεύεται» πάνω σε δεδομένα και ανακαλύπτει μόνο του τις υποκείμενες δομές που καθορίζουν τη συμπεριφορά. Επίσης φαίνεται πως, η εισαγωγή χρονικών δυναμικών στις προβλέψεις επέτρεψε στα recommendation systems να κατανοούν ότι οι ανθρώπινες προτιμήσεις δεν είναι στατικές αλλά μεταβάλλονται με την πάροδο του χρόνου, γεγονός που καθιστά απαραίτητη τη συνεχή μάθηση και αναπροσαρμογή των μοντέλων πρόβλεψης (Koren, 2010). Αυτή η δυνατότητα προσαρμοστικότητας αποτελεί βασικό χαρακτηριστικό κάθε σύγχρονου συστήματος μηχανικής μάθησης.

Η μηχανική μάθηση στα recommender systems επεκτάθηκε σημαντικά και μέσα από την αξιοποίηση έμμεσης ανατροφοδότησης. Σε πολλά πραγματικά περιβάλλοντα, οι χρήστες δεν

παρέχουν ρητές αξιολογήσεις για κάθε αντικείμενο, γεγονός που περιορίζει τη διαθέσιμη πληροφορία για την εκπαίδευση αλγορίθμων. Παραταύτα, η συμπεριφορά τους αφήνει έμμεσα ίχνη ενδιαφέροντος, όπως κλικ, προβολές, χρόνος αλληλεπίδρασης, επαναλαμβανόμενες επισκέψεις ή αγοραστικές επιλογές. Οι Hu, Koren και Volinsky (2008) ανέδειξαν ότι η αξιοποίηση αυτής της έμμεσης πληροφορίας μπορεί να αποτελέσει ιδιαίτερα ισχυρή πηγή μάθησης για recommendation μοντέλα, επιτρέποντας στο σύστημα να εκπαιδεύεται σε πολύ μεγαλύτερη κλίμακα δεδομένων. Αντίστοιχα, οι Rendle et al. (2009) παρουσίασαν τη Bayesian Personalized Ranking προσέγγιση, η οποία εισήγαγε ένα πλαίσιο μάθησης προσανατολισμένο στην κατάταξη αντικειμένων βάσει πιθανής προτίμησης, βελτιώνοντας σημαντικά την ικανότητα των συστημάτων να προβλέπουν σχετικές επιλογές ακόμη και σε περιβάλλοντα με περιορισμένη άμεση ανατροφοδότηση. Οι προσεγγίσεις αυτές αποδεικνύουν ότι η μηχανική μάθηση δεν αφορά μόνο την πρόβλεψη, αλλά και τη δημιουργία πιο ρεαλιστικών υπολογιστικών μοντέλων ανθρώπινης συμπεριφοράς.

Η περαιτέρω πρόοδος της μηχανικής μάθησης οδήγησε στην είσοδο της βαθιάς μάθησης στα συστήματα συστάσεων, μεταβάλλοντας ουσιαστικά το τοπίο της υπολογιστικής εξατομίκευσης. Η βαθιά μάθηση επιτρέπει την ανάπτυξη πολυεπίπεδων μοντέλων που μαθαίνουν σύνθετες, μη γραμμικές αναπαραστάσεις δεδομένων, συλλαμβάνοντας σχέσεις που οι παραδοσιακές μέθοδοι δυσκολεύονται να εντοπίσουν. Η Neural Collaborative Filtering αρχιτεκτονική των He et al. (2017) αποτέλεσε χαρακτηριστικό παράδειγμα αυτής της μετάβασης, καθώς αντικατέστησε τις γραμμικές μαθηματικές σχέσεις των παραδοσιακών recommendation models με βαθιά νευρωνικά δίκτυα ικανά να μοντελοποιούν πολύπλοκες αλληλεπιδράσεις χρήστη-αντικειμένου. Ακόμη, οι Covington, Adams και Sargin (2016) απέδειξαν ότι η αξιοποίηση βαθιών νευρωνικών μοντέλων σε recommendation περιβάλλοντα πολύ μεγάλης κλίμακας μπορεί να οδηγήσει σε εξαιρετικά ακριβείς και δυναμικές προτάσεις, ενώ οι Cheng et al. (2016) παρουσίασαν υβριδικά μοντέλα που συνδυάζουν μνήμη, γενίκευση και βαθιά μάθηση για τη δημιουργία περισσότερο ολοκληρωμένων recommendation architectures. Η εξέλιξη αυτή κατέστησε σαφές ότι η μηχανική μάθηση δεν αποτελεί πλέον απλώς εργαλείο ανάλυσης δεδομένων, αλλά τον πυρήνα της λειτουργικής νοημοσύνης των σύγχρονων πληροφοριακών συστημάτων.

Η σημασία της μηχανικής μάθησης επεκτείνεται επίσης στη δυνατότητα ανάπτυξης recommendation συστημάτων που βελτιστοποιούν πολλαπλούς στόχους ταυτόχρονα, όπως ακρίβεια, ποικιλία, διαφάνεια, εμπιστοσύνη και μακροχρόνια ικανοποίηση χρήστη. Η σύγχρονη βιβλιογραφία δείχνει ότι τα recommender systems εξελίσσονται σε πολυδιάστατα συστήματα λήψης αποφάσεων, στα οποία η μάθηση δεν περιορίζεται σε απλή πρόβλεψη προτίμησης αλλά επεκτείνεται στη συνολική κατανόηση της αλληλεπίδρασης ανθρώπου-συστήματος (Jannach et

al., 2023). Συγχρόνως, η ενισχυτική μάθηση έχει εισαγάγει νέα μοντέλα στα οποία το σύστημα μαθαίνει μέσα από συνεχή αλληλεπίδραση με τον χρήστη, λαμβάνοντας αποφάσεις που δεν στοχεύουν μόνο στη βραχυπρόθεσμη συνάφεια αλλά στη μακροπρόθεσμη βελτιστοποίηση της εμπειρίας χρήσης (Chen et al., 2021). Η εξέλιξη αυτή φέρνει τα recommendation systems ακόμη πιο κοντά στη λογική των ευφυών πρακτόρων που περιέγραψαν οι Maes (1997) και Sycara (1995), δηλαδή αυτόνομων, προσαρμοστικών και μαθησιακών υπολογιστικών οντοτήτων που λειτουργούν ως ευφυείς μεσολαβητές ανάμεσα στον άνθρωπο και στην πληροφορία.

3.2 Νευρωνικά δίκτυα και βαθιά μάθηση

Τα νευρωνικά δίκτυα και η βαθιά μάθηση αποτελούν μία από τις πλέον σημαντικές και ραγδαία εξελισσόμενες περιοχές της τεχνητής νοημοσύνης, έχοντας μετασχηματίσει ουσιαστικά τον τρόπο με τον οποίο τα σύγχρονα πληροφοριακά συστήματα επεξεργάζονται δεδομένα, αναγνωρίζουν πρότυπα και λαμβάνουν αποφάσεις. Ως υπολογιστικά μοντέλα, τα τεχνητά νευρωνικά δίκτυα εμπνέονται από τη λειτουργία του ανθρώπινου εγκεφάλου και βασίζονται στη διασύνδεση μεγάλου αριθμού τεχνητών νευρώνων, οι οποίοι συνεργάζονται για την επεξεργασία πληροφορίας μέσω σταδιακής μάθησης από δεδομένα. Η βασική αρχή λειτουργίας τους έγκειται στη δυνατότητα προσαρμογής των εσωτερικών βαρών σύνδεσης μεταξύ των νευρώνων, έτσι ώστε το σύστημα να μπορεί να αναγνωρίζει πολύπλοκες σχέσεις εισόδου–εξόδου, να εξάγει λανθάνοντα πρότυπα και να βελτιώνει την απόδοσή του όσο αυξάνεται η εμπειρία του μέσω εκπαίδευσης. Η βαθιά μάθηση αποτελεί ουσιαστικά την εξέλιξη αυτής της προσέγγισης, αξιοποιώντας πολυεπίπεδες αρχιτεκτονικές νευρωνικών δικτύων που διαθέτουν πολλαπλά κρυφά επίπεδα επεξεργασίας, επιτρέποντας έτσι την ιεραρχική μάθηση πολύπλοκων αναπαραστάσεων δεδομένων. Στο πλαίσιο των συστημάτων συστάσεων, η εμφάνιση των νευρωνικών δικτύων και της βαθιάς μάθησης σηματοδότησε μία ουσιαστική μετάβαση από τις παραδοσιακές στατιστικές και γραμμικές μεθόδους πρόβλεψης προς ευφυή συστήματα ικανά να κατανοούν βαθύτερα και με μεγαλύτερη ακρίβεια τη συμπεριφορά των χρηστών.

Η σύνδεση των νευρωνικών δικτύων με την εξέλιξη των recommender systems προέκυψε από τους περιορισμούς των παραδοσιακών μοντέλων συνεργατικού φιλτραρίσματος. Οι πρώτες γενιές recommendation αλγορίθμων βασίζονταν κυρίως σε μεθόδους υπολογισμού ομοιότητας μεταξύ χρηστών ή αντικειμένων, αξιοποιώντας ρητές ή έμμεσες αξιολογήσεις για την πρόβλεψη προτιμήσεων. Παρότι οι προσεγγίσεις αυτές απέδωσαν σημαντικά αποτελέσματα και διαμόρφωσαν τη θεωρητική βάση του πεδίου (Goldberg et al., 1992; Resnick et al., 1994), παρουσίαζαν σημαντικούς περιορισμούς ως προς την ικανότητα κατανόησης σύνθετων, μη γραμμικών σχέσεων μεταξύ δεδομένων. Η ανάπτυξη τεχνικών παραγοντοποίησης πινάκων

αποτελέσσε ένα σημαντικό βήμα προς πιο εξελιγμένες μορφές υπολογιστικής μάθησης, καθώς επέτρεψε την αναπαράσταση χρηστών και αντικειμένων σε λανθάνοντες διανυσματικούς χώρους, όπου μπορούσαν να αποτυπωθούν πιο αφηρημένες σχέσεις προτίμησης (Koren et al., 2009). Παρόλα αυτά, ακόμη και αυτά τα μοντέλα παρέμεναν σε μεγάλο βαθμό περιορισμένα από γραμμικές μαθηματικές υποθέσεις, γεγονός που καθιστούσε δύσκολη την αποτύπωση της πραγματικής πολυπλοκότητας της ανθρώπινης συμπεριφοράς.

Η βαθιά μάθηση ήρθε να αντιμετωπίσει ακριβώς αυτό το πρόβλημα, εισάγοντας μοντέλα ικανά να μαθαίνουν μη γραμμικές, πολυδιάστατες και ιδιαίτερα σύνθετες αναπαραστάσεις των δεδομένων. Σε αντίθεση με τις παραδοσιακές μεθόδους, όπου η εξαγωγή χαρακτηριστικών απαιτούσε συχνά ανθρώπινη παρέμβαση και χειροκίνητη επιλογή παραμέτρων, τα βαθιά νευρωνικά δίκτυα διαθέτουν τη δυνατότητα αυτόματης εξαγωγής χαρακτηριστικών μέσα από τα ίδια τα δεδομένα εκπαίδευσης. Αυτό σημαίνει ότι μπορούν να εντοπίζουν υποκείμενες δομές, συσχετίσεις και αφανή μοτίβα που δύσκολα αναγνωρίζονται με συμβατικές τεχνικές. Σύμφωνα με τους Zhang, Yao, Sun και Tay (2019), η βαθιά μάθηση επέτρεψε στα recommender systems να μεταβούν από τη μοντελοποίηση απλών αλληλεπιδράσεων χρηστών–αντικειμένων στη βαθύτερη κατανόηση της συνολικής συμπεριφοράς, λαμβάνοντας υπόψη ετερογενή δεδομένα, συμφραζόμενα στοιχεία και πολυδιάστατες αναπαραστάσεις ενδιαφερόντων.

Μία από τις σημαντικότερες εφαρμογές νευρωνικών δικτύων στα συστήματα συστάσεων ήταν η ανάπτυξη της προσέγγισης Neural Collaborative Filtering. Οι He et al. (2017) πρότειναν μια νέα αρχιτεκτονική recommendation, στην οποία οι παραδοσιακές μαθηματικές συναρτήσεις συσχέτισης χρηστών και αντικειμένων αντικαθίστανται από βαθιά νευρωνικά δίκτυα. Μέσα από τη χρήση πολλαπλών επιπέδων επεξεργασίας, το σύστημα αποκτά τη δυνατότητα να μαθαίνει πολύ πιο σύνθετες σχέσεις μεταξύ των προτιμήσεων των χρηστών και των χαρακτηριστικών των αντικειμένων, οδηγώντας σε σημαντική βελτίωση της ακρίβειας πρόβλεψης. Η προσέγγιση αυτή θεωρείται ιδιαίτερα σημαντική, καθώς κατέδειξε ότι τα recommendation systems μπορούν να επωφεληθούν από τις ίδιες αρχές βαθιάς μάθησης που είχαν ήδη οδηγήσει σε επαναστατικές εξελίξεις σε πεδία όπως η αναγνώριση εικόνας, η επεξεργασία φυσικής γλώσσας και η αυτόνομη λήψη αποφάσεων.

Η πρακτική σημασία των βαθιών νευρωνικών μοντέλων έγινε ακόμη πιο εμφανής μέσα από εφαρμογές μεγάλης κλίμακας. Οι Covington, Adams και Sargin (2016) παρουσίασαν ένα recommendation σύστημα βασισμένο σε βαθιά νευρωνικά δίκτυα, σχεδιασμένο για περιβάλλοντα εξαιρετικά υψηλού όγκου δεδομένων και συνεχούς αλληλεπίδρασης χρηστών. Η προσέγγιση αυτή απέδειξε ότι τα νευρωνικά δίκτυα μπορούν να αξιοποιήσουν ιστορικά

δεδομένα παρακολούθησης, ακολουθίες αλληλεπίδρασης, συμφραζόμενα δεδομένα και πολυδιάστατα χαρακτηριστικά χρηστών για να δημιουργήσουν ιδιαίτερα προσωποποιημένες προτάσεις υψηλής ακρίβειας. Αντίστοιχα, οι Cheng et al. (2016) παρουσίασαν μια υβριδική αρχιτεκτονική που συνδυάζει βαθιά μάθηση με μηχανισμούς γενίκευσης και μνήμης, επιτρέποντας στα recommendation συστήματα όχι μόνο να μαθαίνουν από προηγούμενα δεδομένα αλλά και να γενικεύουν τη γνώση αυτή σε νέες περιπτώσεις. Αυτή η δυνατότητα είναι κρίσιμη για την αντιμετώπιση προβλημάτων όπως η ψυχρή εκκίνηση, η περιορισμένη πληροφορία για νέους χρήστες ή νέα αντικείμενα και η ανάγκη ταχείας προσαρμογής σε μεταβαλλόμενα πρότυπα συμπεριφοράς.

Ένα ακόμη σημαντικό πλεονέκτημα της βαθιάς μάθησης είναι η ικανότητά της να αξιοποιεί πολλαπλές μορφές δεδομένων ταυτόχρονα. Τα σύγχρονα recommender systems δεν βασίζονται αποκλειστικά σε αξιολογήσεις ή ιστορικό επιλογών, αλλά επεξεργάζονται επίσης κείμενο, εικόνες, ήχο, δημογραφικά στοιχεία, κοινωνικές σχέσεις, συμφραζόμενα δεδομένα και ακολουθίες χρονικής συμπεριφοράς. Η βαθιά μάθηση επιτρέπει την ενοποίηση όλων αυτών των ετερογενών πηγών πληροφορίας σε ενιαία υπολογιστικά μοντέλα, δημιουργώντας πολύ πιο ολοκληρωμένες και ακριβείς αναπαραστάσεις των χρηστών και των ενδιαφερόντων τους (Zhou et al., 2023). Επιπλέον, η δυνατότητα ιεραρχικής μάθησης χαρακτηριστικών σημαίνει ότι τα βαθιά μοντέλα μπορούν να κατανοήσουν όχι μόνο τι επιλέγει ένας χρήστης, αλλά και γιατί το επιλέγει, προσεγγίζοντας περισσότερο τις βαθύτερες γνωστικές και συμπεριφορικές διαστάσεις της ανθρώπινης απόφασης. Ακόμη, η εξέλιξη της βαθιάς μάθησης έχει επηρεάσει και τη γενικότερη αντίληψη περί ευφύων πληροφοριακών συστημάτων. Η Maes (1997) είχε περιγράψει ένα όραμα όπου οι υπολογιστές θα λειτουργούν ως ενεργοί συνεργάτες του ανθρώπου, μαθαίνοντας συνεχώς από τις αλληλεπιδράσεις τους και αναλαμβάνοντας πιο σύνθετους ρόλους στην υποστήριξη λήψης αποφάσεων. Η βαθιά μάθηση αποτελεί ίσως την πιο κοντινή τεχνολογική υλοποίηση αυτού του οράματος, καθώς προσφέρει στα σύγχρονα συστήματα τη δυνατότητα συνεχούς μάθησης, προσαρμογής και βελτίωσης μέσα από τεράστιο όγκο εμπειρικών δεδομένων. Επίσης, η ενσωμάτωση ενισχυτικής μάθησης σε βαθιά recommendation architectures επιτρέπει στα συστήματα να μαθαίνουν δυναμικά μέσα από συνεχή αλληλεπίδραση με τον χρήστη, λαμβάνοντας αποφάσεις που βελτιστοποιούν όχι μόνο τη βραχυπρόθεσμη συνάφεια αλλά και τη μακροχρόνια εμπειρία χρήσης (Chen et al., 2021). Εκτός των πλεονεκτημάτων, η αξιοποίηση νευρωνικών δικτύων συνοδεύεται και από προκλήσεις. Η μεγάλη υπολογιστική πολυπλοκότητα, η ανάγκη για τεράστιο όγκο δεδομένων εκπαίδευσης, η δυσκολία ερμηνείας των αποφάσεων και ο κίνδυνος αλγοριθμικής μεροληψίας αποτελούν ουσιαστικά ζητήματα για τη μελλοντική εξέλιξη των βαθιών recommendation systems. Η ανάγκη

ανάπτυξης περισσότερο διαφανών και εξηγήσιμων μοντέλων είναι ιδιαίτερα έντονη, καθώς η αυξανόμενη πολυπλοκότητα των βαθιών αρχιτεκτονικών μπορεί να μειώσει την εμπιστοσύνη των χρηστών όταν οι προτάσεις δεν συνοδεύονται από σαφή αιτιολόγηση (Zhang & Chen, 2020). Τέλος, η συνεχής επεξεργασία μεγάλου όγκου προσωπικών δεδομένων εγείρει ζητήματα ιδιωτικότητας και αξιοπιστίας, τα οποία σχετίζονται άμεσα με τη μακροχρόνια κοινωνική αποδοχή αυτών των τεχνολογιών (Akdim et al., 2025).

3.3 Ασαφής λογική και εξελικτικοί αλγόριθμοι

Η ανάπτυξη των ευφυών πληροφοριακών συστημάτων δεν βασίστηκε αποκλειστικά στη μηχανική μάθηση και στα νευρωνικά δίκτυα, αλλά επηρεάστηκε σημαντικά και από άλλες υπολογιστικές προσεγγίσεις που επιδιώκουν να προσομοιώσουν διαφορετικές πτυχές της ανθρώπινης νοημοσύνης και της προσαρμοστικής συμπεριφοράς. Ανάμεσα σε αυτές, η ασαφής λογική και οι εξελικτικοί αλγόριθμοι κατέχουν ιδιαίτερη θέση, καθώς προσφέρουν εναλλακτικά θεωρητικά και πρακτικά πλαίσια για την αντιμετώπιση προβλημάτων αβεβαιότητας, πολυπλοκότητας και βελτιστοποίησης σε δυναμικά περιβάλλοντα. Παρότι οι δύο αυτές προσεγγίσεις στηρίζονται σε διαφορετικές επιστημονικές αρχές, παρουσιάζουν ένα κοινό χαρακτηριστικό: επιχειρούν να υπερβούν τους περιορισμούς των αυστηρά ντετερμινιστικών και δυαδικών υπολογιστικών μοντέλων, προσεγγίζοντας περισσότερο τη φυσική ανθρώπινη διαδικασία σκέψης, προσαρμογής και λήψης αποφάσεων. Στο πλαίσιο των συστημάτων συστάσεων, η συμβολή τους υπήρξε σημαντική, ιδιαίτερα σε ζητήματα μοντελοποίησης ασαφών προτιμήσεων χρηστών, αντιμετώπισης πολυκριτηριακών προβλημάτων σύστασης και αναζήτησης βέλτιστων λύσεων μέσα σε εξαιρετικά πολύπλοκους χώρους πιθανών επιλογών.

Η ασαφής λογική αναπτύχθηκε ως απάντηση στους περιορισμούς της κλασικής δυαδικής λογικής, η οποία αντιμετωπίζει κάθε πρόταση ως απολύτως αληθή ή απολύτως ψευδή. Στην πραγματικότητα, ωστόσο, η ανθρώπινη σκέψη και οι διαδικασίες αξιολόγησης χαρακτηρίζονται συχνά από αβεβαιότητα, βαθμιαίες εκτιμήσεις και ενδιάμεσες καταστάσεις. Έννοιες όπως «αρκετά καλό», «πολύ σχετικό», «μέτρια ενδιαφέρον» ή «πιθανώς κατάλληλο» δεν μπορούν να αποτυπωθούν αποτελεσματικά μέσα από αυστηρά δυαδικά σχήματα αναπαράστασης. Η ασαφής λογική επιτρέπει ακριβώς αυτή τη βαθμιαία αναπαράσταση της γνώσης, δίνοντας τη δυνατότητα σε ένα σύστημα να χειρίζεται ασαφείς ή μερικώς καθορισμένες πληροφορίες με τρόπο περισσότερο κοντά στη φυσική ανθρώπινη αξιολόγηση. Η σημασία αυτής της προσέγγισης για τα ευφυή πληροφοριακά συστήματα συνδέεται άμεσα με τη γενικότερη επιδίωξη ανάπτυξης λογισμικών οντοτήτων που λειτουργούν πιο ευέλικτα, προσαρμοστικά και γνωστικά. Οι Wooldridge και Jennings (1995) τόνισαν ότι η έννοια της ευφυΐας στα υπολογιστικά συστήματα

δεν περιορίζεται στην εκτέλεση σαφώς καθορισμένων κανόνων, αλλά περιλαμβάνει την ικανότητα λήψης αποφάσεων υπό αβεβαιότητα, την αξιολόγηση εναλλακτικών σε ασαφή περιβάλλοντα και την προσαρμογή σε μεταβαλλόμενες συνθήκες. Η ασαφής λογική αποτέλεσε ένα από τα πρώτα θεωρητικά εργαλεία που έδωσαν πρακτική υπόσταση σε αυτή τη θεώρηση.

Στα συστήματα συστάσεων, η ασαφής λογική αξιοποιείται κυρίως για τη μοντελοποίηση προτιμήσεων που δεν εκφράζονται με απόλυτο τρόπο. Οι ανθρώπινες επιλογές σπάνια βασίζονται σε απόλυτα κριτήρια. Ένας χρήστης μπορεί να θεωρεί μια ταινία «αρκετά ενδιαφέρουσα», ένα προϊόν «σχετικά οικονομικό» ή μια υπηρεσία «πολύ πιθανό να είναι χρήσιμη», χωρίς αυτές οι αξιολογήσεις να αντιστοιχούν σε ακριβείς αριθμητικές τιμές. Τα ασαφή μοντέλα επιτρέπουν τη μετατροπή τέτοιων ποιοτικών και βαθμιαίων κρίσεων σε υπολογιστικά διαχειρίσιμη γνώση, δημιουργώντας recommendation μηχανισμούς που μπορούν να λειτουργούν πιο κοντά στη φυσική γνωστική διαδικασία του ανθρώπου. Αυτή η προσέγγιση συνδέεται και με τη λογική των ευφύων πρακτόρων, όπως περιγράφηκε από τους Genesereth και Ketchpel (1994), οι οποίοι υποστήριξαν ότι ένα πραγματικά ευφυές πληροφοριακό σύστημα πρέπει να διαθέτει μηχανισμούς κατανόησης ατελούς πληροφορίας και ικανότητα λειτουργίας σε περιβάλλοντα αβεβαιότητας. Η ασαφής λογική παρέχει ακριβώς αυτή τη δυνατότητα, επιτρέποντας σε recommendation συστήματα να λαμβάνουν αποφάσεις όχι μόνο βάσει απόλυτων μετρήσεων αλλά και βάσει ασαφών, σταδιακών ή εννοιολογικών εκτιμήσεων.

Επιπροσθέτως, η ασαφής λογική προσφέρει σημαντικά πλεονεκτήματα σε περιπτώσεις πολυκριτηριακής αξιολόγησης. Τα σύγχρονα συστήματα συστάσεων δεν αξιολογούν πλέον τα αντικείμενα μόνο με βάση ένα κριτήριο συνάφειας, αλλά καλούνται να ισορροπήσουν ανάμεσα σε πολλαπλές διαστάσεις όπως ποιότητα, κόστος, αξιοπιστία, πρωτοτυπία, ποικιλία, επεξηγησιμότητα και εμπιστοσύνη. Οι Jannach, Bauer και Jugovac (2023) επισημαίνουν ότι η σύγχρονη recommendation έρευνα στρέφεται ολοένα περισσότερο σε multi-objective optimization frameworks, όπου το ζητούμενο δεν είναι η απλή μεγιστοποίηση της ακρίβειας πρόβλεψης αλλά η ταυτόχρονη ικανοποίηση πολλαπλών συχνά αντικρουόμενων στόχων. Η ασαφής λογική είναι ιδιαίτερα κατάλληλη για τέτοια προβλήματα, καθώς επιτρέπει τη βαθμιαία αξιολόγηση διαφορετικών κριτηρίων και τη συνδυαστική λήψη αποφάσεων χωρίς να απαιτούνται απόλυτα κατώφλια ή αυστηροί δυαδικοί διαχωρισμοί.

Συμπληρωματικά προς την ασαφή λογική, οι εξελικτικοί αλγόριθμοι αποτελούν μία ακόμη σημαντική ευφυή τεχνική που έχει αξιοποιηθεί εκτενώς σε προβλήματα τεχνητής νοημοσύνης και recommendation systems. Οι εξελικτικοί αλγόριθμοι βασίζονται σε αρχές εμπνευσμένες από τη βιολογική εξέλιξη, όπως η επιλογή, η προσαρμογή, η διασταύρωση και η μετάλλαξη, με στόχο

τη σταδιακή αναζήτηση βέλτιστων ή σχεδόν βέλτιστων λύσεων μέσα σε πολύπλοκους χώρους αναζήτησης. Σε αντίθεση με κλασικές μεθόδους βελτιστοποίησης, οι εξελικτικές προσεγγίσεις δεν απαιτούν πλήρη γνώση της δομής του προβλήματος, ούτε προϋποθέτουν ομαλές μαθηματικές συναρτήσεις στόχου. Αντίθετα, επιτρέπουν την εξερεύνηση μεγάλων, μη γραμμικών και δυναμικών χώρων λύσεων, καθιστώντας τις ιδιαίτερα χρήσιμες σε recommendation προβλήματα όπου υπάρχουν πολλοί παράγοντες, αβεβαιότητα και ανάγκη ταυτόχρονης βελτιστοποίησης πολλαπλών στόχων.

Η σχέση των εξελικτικών αλγορίθμων με τη γενικότερη θεωρία των ευφυών πρακτόρων είναι εμφανής. Οι Maes (1994) και Sycara (1995) περιέγραψαν ευφυή πληροφοριακά συστήματα ως προσαρμοστικές υπολογιστικές οντότητες που λειτουργούν σε πολύπλοκα περιβάλλοντα, μαθαίνουν συνεχώς από την εμπειρία και τροποποιούν δυναμικά τη στρατηγική τους. Αυτή η λογική προσαρμογής είναι ιδιαίτερα κοντά στη φιλοσοφία των εξελικτικών αλγορίθμων, όπου ένα σύνολο πιθανών λύσεων εξελίσσεται σταδιακά μέσω επαναληπτικής αξιολόγησης και επιλογής, οδηγώντας σε ολοένα καλύτερες υπολογιστικές στρατηγικές. Στα recommendation systems, αυτό μπορεί να μεταφραστεί σε βελτιστοποίηση παραμέτρων πρόβλεψης, δυναμική προσαρμογή weighting schemes μεταξύ διαφορετικών recommendation modules, επιλογή κατάλληλων χαρακτηριστικών για user modeling ή ακόμη και διαρκή αναζήτηση της βέλτιστης ισορροπίας μεταξύ ακρίβειας, ποικιλίας και αξιοπιστίας των προτάσεων.

Η σύγχρονη εξέλιξη της μηχανικής μάθησης και της βαθιάς μάθησης δεν έχει περιορίσει τη σημασία αυτών των τεχνικών· αντίθετα, έχει ενισχύσει τον ρόλο τους ως συμπληρωματικών ευφυών εργαλείων. Η βιβλιογραφία δείχνει ότι τα πιο σύγχρονα recommendation architectures τείνουν να υιοθετούν υβριδικές προσεγγίσεις, όπου βαθιά νευρωνικά δίκτυα, ασαφή μοντέλα, εξελικτικοί μηχανισμοί βελτιστοποίησης και ενισχυτική μάθηση συνεργάζονται μέσα σε πολυεπίπεδα συστήματα λήψης αποφάσεων (Li et al., 2023; Zhou et al., 2023). Εκτός αυτού, η ανάπτυξη explainable recommendation systems έχει αναδείξει εκ νέου τη σημασία ασαφών λογικών μοντέλων, καθώς η βαθμιαία αναπαράσταση σχέσεων και η χρήση γλωσσικών κανόνων διευκολύνει τη δημιουργία περισσότερο κατανοητών και ερμηνεύσιμων προτάσεων (Zhang & Chen, 2020). Αντίστοιχα, η ανάγκη για trustworthy recommendation systems, τα οποία θα είναι αξιόπιστα, δίκαια και ανθεκτικά σε αβεβαιότητες ή αλλαγές συμπεριφοράς, καθιστά ιδιαίτερα σημαντική τη χρήση προσαρμοστικών και εξελικτικών μηχανισμών βελτιστοποίησης (Akdim et al., 2025).

3.4 Εξόρυξη δεδομένων και ανακάλυψη προτύπων

Η εξόρυξη δεδομένων αποτελεί μία από τις σημαντικότερες ευφυείς τεχνικές της σύγχρονης τεχνητής νοημοσύνης και της επιστήμης δεδομένων, καθώς εστιάζει στην ανακάλυψη χρήσιμης γνώσης, κρυφών σχέσεων, επαναλαμβανόμενων μοτίβων και σημαντικών κανονικοτήτων μέσα από μεγάλους όγκους δεδομένων. Σε ένα ψηφιακό περιβάλλον όπου η πληροφορία παράγεται με εκθετικό ρυθμό, η απλή αποθήκευση δεδομένων δεν είναι από μόνη της αρκετή για τη δημιουργία επιχειρησιακής ή επιστημονικής αξίας. Η πραγματική αξιοποίηση των δεδομένων προκύπτει μέσα από την ικανότητα ανάλυσης και ερμηνείας τους, δηλαδή μέσα από διαδικασίες που επιτρέπουν τη μετατροπή της ακατέργαστης πληροφορίας σε γνώση. Σε αυτό ακριβώς το σημείο παρεμβαίνει η εξόρυξη δεδομένων, λειτουργώντας ως ο μηχανισμός μέσω του οποίου τα πληροφοριακά συστήματα μπορούν να εντοπίσουν δομές που δεν είναι άμεσα ορατές, να αναγνωρίσουν πρότυπα συμπεριφοράς και να δημιουργήσουν προβλεπτικά μοντέλα που ενισχύουν τη λήψη αποφάσεων. Στο πλαίσιο των συστημάτων συστάσεων, η εξόρυξη δεδομένων δεν αποτελεί απλώς μία βοηθητική τεχνική, αλλά τον θεμελιώδη μηχανισμό μέσω του οποίου συλλέγονται, οργανώνονται και ερμηνεύονται οι πληροφορίες που οδηγούν στη δημιουργία εξατομικευμένων προτάσεων.

Η θεωρητική σύνδεση της εξόρυξης δεδομένων με τα recommender systems βασίζεται στην παρατήρηση ότι κάθε αλληλεπίδραση ενός χρήστη με ένα πληροφοριακό σύστημα αφήνει πίσω της ένα σύνολο δεδομένων, το οποίο μπορεί να αξιοποιηθεί για την αναγνώριση μοτίβων προτίμησης. Κλικ, προβολές, αξιολογήσεις, χρόνος αλληλεπίδρασης, αγοραστικές επιλογές, σειρές περιήγησης και επαναλαμβανόμενες συμπεριφορές συνθέτουν ένα πολύπλοκο πληροφοριακό αποτύπωμα, το οποίο εμπεριέχει σημαντική γνώση σχετικά με τις ανάγκες, τις προτιμήσεις και τις πιθανές μελλοντικές επιλογές ενός χρήστη. Η εξόρυξη δεδομένων επιτρέπει την επεξεργασία αυτού του αποτυπώματος με τρόπο συστηματικό, αποκαλύπτοντας σχέσεις που δεν μπορούν να εντοπιστούν εύκολα με συμβατικές μεθόδους στατιστικής ανάλυσης. Σύμφωνα με τους Adomavicius και Tuzhilin (2005), η εξέλιξη των συστημάτων συστάσεων προς περισσότερο προηγμένα και αποτελεσματικά recommendation frameworks συνδέεται άμεσα με την ικανότητά τους να αξιοποιούν ολοένα μεγαλύτερους όγκους δεδομένων και να εξάγουν από αυτούς ουσιαστική γνώση για τη συμπεριφορά των χρηστών. Η παρατήρηση αυτή καθιστά σαφές ότι η εξόρυξη δεδομένων βρίσκεται στον πυρήνα της σύγχρονης υπολογιστικής εξατομίκευσης.

Η ανακάλυψη προτύπων αποτελεί τη σημαντικότερη λειτουργία της εξόρυξης δεδομένων στα συστήματα συστάσεων. Τα πρότυπα αυτά μπορεί να αφορούν επαναλαμβανόμενες σχέσεις

μεταξύ αντικειμένων, ομοιότητες συμπεριφοράς μεταξύ χρηστών, χρονικές ακολουθίες επιλογών ή ακόμη και πολυδιάστατες συσχετίσεις που συνδέουν χαρακτηριστικά χρηστών με συγκεκριμένες μορφές ενδιαφέροντος. Η αναγνώριση τέτοιων μοτίβων επιτρέπει σε ένα recommender system να προβλέψει με μεγαλύτερη ακρίβεια ποιο αντικείμενο έχει αυξημένη πιθανότητα να ενδιαφέρει έναν χρήστη. Η αξία αυτής της προσέγγισης αναδείχθηκε ιδιαίτερα μέσα από την ανάπτυξη item-based recommendation models, όπου η βασική ιδέα είναι ότι αντικείμενα που επιλέγονται συχνά μαζί ή παρουσιάζουν σταθερά κοινά μοτίβα κατανάλωσης μπορούν να συνδεθούν μεταξύ τους υπολογιστικά. Οι Sarwar, Karypis, Konstan και Riedl (2001) έδειξαν ότι η ανάλυση ομοιότητας μεταξύ αντικειμένων αποτελεί εξαιρετικά αποτελεσματικό μηχανισμό recommendation, καθώς επιτρέπει την εξαγωγή σταθερών δομών συσχέτισης μέσα από μεγάλα ιστορικά δεδομένα. Η προσέγγιση αυτή αποτελεί χαρακτηριστικό παράδειγμα εξόρυξης προτύπων, καθώς το σύστημα δεν βασίζεται σε χειροκίνητα ορισμένες σχέσεις αλλά τις ανακαλύπτει αυτόνομα μέσα από τη μελέτη επαναλαμβανόμενων αλληλεπιδράσεων.

Η πρακτική σημασία της εξόρυξης δεδομένων έγινε ακόμη πιο εμφανής μέσα από την ενσωμάτωσή της σε μεγάλης κλίμακας ψηφιακές πλατφόρμες. Οι Linden, Smith και York (2003) παρουσίασαν ένα recommendation μοντέλο στο οποίο η ανάλυση τεράστιου όγκου δεδομένων αλληλεπίδρασης χρηστών αξιοποιείται για την ανακάλυψη σχέσεων μεταξύ αντικειμένων και τη δημιουργία προσωποποιημένων προτάσεων σε πραγματικό χρόνο. Η λογική αυτή βασίζεται ουσιαστικά στη συνεχή εξόρυξη γνώσης από ιστορικά δεδομένα χρήσης, όπου κάθε νέα αλληλεπίδραση ενισχύει ή αναδιαμορφώνει τα υπάρχοντα υπολογιστικά πρότυπα. Έτσι, το recommender system λειτουργεί ως ένας δυναμικός μηχανισμός μάθησης, ο οποίος εξελίσσεται συνεχώς καθώς αυξάνεται η διαθέσιμη πληροφορία. Αυτή η διαρκής ανατροφοδότηση αποτελεί βασικό χαρακτηριστικό των σύγχρονων ευφυών συστημάτων, καθώς επιτρέπει την προσαρμογή σε νέες συνθήκες, νέες προτιμήσεις και νέες μορφές συμπεριφοράς χωρίς να απαιτείται επανασχεδιασμός του συστήματος.

Εξίσου σημαντική διάσταση της εξόρυξης δεδομένων είναι η δυνατότητα ομαδοποίησης και τμηματοποίησης χρηστών ή αντικειμένων με βάση κοινά χαρακτηριστικά. Η διαδικασία αυτή επιτρέπει τον εντοπισμό κοινοτήτων χρηστών με παρόμοια ενδιαφέροντα ή τη δημιουργία κατηγοριών αντικειμένων που παρουσιάζουν παρόμοια μοτίβα κατανάλωσης. Η γνώση αυτή έχει ιδιαίτερη αξία για recommendation συστήματα, καθώς επιτρέπει τη δημιουργία περισσότερο στοχευμένων προτάσεων και την καλύτερη κατανόηση της εσωτερικής δομής των δεδομένων. Οι Ekstrand, Riedl και Konstan (2011) επισημαίνουν ότι η αποτελεσματικότητα των σύγχρονων collaborative filtering models εξαρτάται σε μεγάλο βαθμό από την ικανότητα ανάλυσης των σχέσεων που αναπτύσσονται μέσα στα δεδομένα αλληλεπίδρασης, υπογραμμίζοντας έτσι τον

κεντρικό ρόλο της ανακάλυψης προτύπων στη recommendation διαδικασία. Η ανάλυση αυτή δεν περιορίζεται σε απλές ομοιότητες, αλλά επεκτείνεται στη χαρτογράφηση λανθανόντων δομών συμπεριφοράς, οι οποίες μπορούν να χρησιμοποιηθούν για πιο ουσιαστική και βαθιά κατανόηση των αναγκών του χρήστη.

Συμπληρωματικά, η εξόρυξη δεδομένων διαδραματίζει σημαντικό ρόλο στην αντιμετώπιση της πολυπλοκότητας που χαρακτηρίζει τα σύγχρονα recommendation οικοσυστήματα. Τα δεδομένα που συλλέγονται σήμερα δεν είναι μόνο μεγάλα σε όγκο, αλλά και εξαιρετικά ετερογενή, καθώς περιλαμβάνουν δομημένα δεδομένα, κείμενο, εικόνα, χρονικές ακολουθίες, συμφραζόμενα στοιχεία και σύνθετες αλληλεπιδράσεις μεταξύ χρηστών και πλατφορμών. Η ανακάλυψη χρήσιμων προτύπων μέσα σε ένα τέτοιο πολυδιάστατο περιβάλλον απαιτεί προηγμένες τεχνικές επεξεργασίας, φιλτραρίσματος και εννοιολογικής αναπαράστασης. Οι Adomavicius και Tuzhilin (2005) είχαν ήδη επισημάνει ότι η επόμενη γενιά συστημάτων συστάσεων θα βασίζεται σε recommendation frameworks που δεν αξιοποιούν μόνο άμεσες αξιολογήσεις, αλλά ενσωματώνουν πολυδιάστατα συμφραζόμενα δεδομένα και σύνθετες μορφές γνώσης. Η πρόβλεψη αυτή επιβεβαιώθηκε πλήρως από τη σύγχρονη εξέλιξη της επιστήμης δεδομένων, όπου η εξόρυξη προτύπων επεκτείνεται πλέον από απλές συσχετίσεις προς πολύπλοκες δομές γνώσης που υποστηρίζουν δυναμική εξατομίκευση.

Η σχέση της εξόρυξης δεδομένων με την τεχνητή νοημοσύνη είναι επίσης βαθύτερη, καθώς συνδέεται με τη γενικότερη φιλοσοφία ανάπτυξης ευφυών πληροφοριακών οντοτήτων που αποκτούν γνώση από την εμπειρία. Οι Nwana και Ndumu (1998) περιέγραψαν τα ευφυή πληροφοριακά συστήματα ως προσαρμοστικές λογισμικές οντότητες που αντιλαμβάνονται το περιβάλλον τους, επεξεργάζονται διαθέσιμες πληροφορίες και τροποποιούν τη συμπεριφορά τους βάσει νέας γνώσης. Η εξόρυξη δεδομένων αποτελεί ακριβώς τον μηχανισμό μέσω του οποίου αποκτάται αυτή η γνώση. Μέσα από τη συνεχή ανάλυση δεδομένων, τα πληροφοριακά συστήματα δεν περιορίζονται στην παθητική επεξεργασία εισόδων αλλά αναπτύσσουν ενεργητική κατανόηση του περιβάλλοντος λειτουργίας τους, αναγνωρίζουν τάσεις, προβλέπουν εξελίξεις και προσαρμόζουν τις αποφάσεις τους με τρόπο περισσότερο ευφυή και δυναμικό.

3.5 Μαθηματική διατύπωση του προβλήματος σύστασης

Πριν παρουσιαστούν οι επιμέρους ευφυείς τεχνικές, είναι απαραίτητη η τυπική μαθηματική διατύπωση του προβλήματος. Έστω ένα σύνολο χρηστών $U = \{u_1, u_2, \dots, u_m\}$ με πληθάριθμο $|U| = m$ και ένα σύνολο αντικειμένων (προϊόντων) $I = \{i_1, i_2, \dots, i_n\}$ με $|I| = n$. Η αλληλεπίδραση των χρηστών με τα αντικείμενα αναπαρίσταται από έναν πίνακα αξιολογήσεων (rating matrix) R

διαστάσεων $m \times n$, όπου κάθε στοιχείο r_{ui} δηλώνει την προτίμηση του χρήστη u για το αντικείμενο i .

$$R = [r_{ui}] \in \mathbb{R}^{m \times n}, \quad u = 1, \dots, m, \quad i = 1, \dots, n$$

Ο πίνακας R είναι κατά κανόνα εξαιρετικά αραιός (sparse), καθώς κάθε χρήστης έχει αξιολογήσει ή αγοράσει μόνο ένα πολύ μικρό υποσύνολο των διαθέσιμων προϊόντων. Το ποσοστό αραιότητας ορίζεται ως:

$$\text{sparsity}(R) = 1 - \frac{|\{(u, i) : r_{ui} \text{ is known}\}|}{m \cdot n}$$

Σε πραγματικά συστήματα ηλεκτρονικού εμπορίου η αραιότητα ξεπερνά συχνά το 99%. Στόχος ενός συστήματος συστάσεων είναι η εκτίμηση των άγνωστων τιμών του πίνακα, δηλαδή η εκμάθηση μιας συνάρτησης χρησιμότητας (utility function) f που αντιστοιχίζει κάθε ζεύγος χρήστη–αντικειμένου σε μια προβλεπόμενη βαθμολογία προτίμησης:

$$f: U \times I \rightarrow \mathbb{R}, \quad \hat{r}_{ui} = f(u, i)$$

όπου $\hat{r}_{ui}$ είναι η προβλεπόμενη προτίμηση του χρήστη u για το αντικείμενο i .

Με βάση τις εκτιμήσεις αυτές, το σύστημα επιλέγει για κάθε χρήστη u το σύνολο των Top-N αντικειμένων με τη μεγαλύτερη προβλεπόμενη προτίμηση, τα οποία ο χρήστης δεν έχει ήδη αξιολογήσει:

$$\text{TopN}(u) = \{i_{(1)}, \dots, i_{(N)}\} \subseteq I \setminus I_u, \quad \hat{r}_{u, i_{(1)}} \geq \dots \geq \hat{r}_{u, i_{(N)}}$$

όπου I_u το σύνολο των αντικειμένων που έχει ήδη αξιολογήσει ο χρήστης u .

Το πρόβλημα διακρίνεται σε δύο βασικές παραλλαγές: την πρόβλεψη βαθμολογίας (rating prediction), όπου ζητείται η ακριβής αριθμητική τιμή $\hat{r}_{ui}$, και την κατάταξη Top-N (ranking), όπου ζητείται η σωστή σειρά προτεραιότητας των αντικειμένων. Οι ευφυείς τεχνικές που ακολουθούν προσεγγίζουν το πρόβλημα αυτό με διαφορετικό μαθηματικό υπόβαθρο.

3.6 Συνεργατικό φιλτράρισμα βασισμένο στη μνήμη (Memory-based Collaborative Filtering)

Το συνεργατικό φιλτράρισμα βασισμένο στη μνήμη υπολογίζει προβλέψεις αξιοποιώντας απευθείας τις ομοιότητες μεταξύ χρηστών ή μεταξύ αντικειμένων, χωρίς την εκμάθηση ενός

ρητού παραμετρικού μοντέλου. Διακρίνεται σε δύο προσεγγίσεις: το user-based και το item-based φιλτράρισμα.

3.6.1 Μέτρα ομοιότητας

Το κρίσιμο βήμα είναι ο υπολογισμός της ομοιότητας. Η ομοιότητα συνημιτόνου (cosine similarity) μεταξύ δύο χρηστών u και v , με βάση τα κοινά αξιολογημένα αντικείμενα I_{uv} , ορίζεται ως:

$$\text{sim}_{\cos}(u, v) = \frac{\sum_{i \in I_{uv}} r_{ui} r_{vi}}{\sqrt{\sum_{i \in I_{uv}} r_{ui}^2} \sqrt{\sum_{i \in I_{uv}} r_{vi}^2}}$$

Η ομοιότητα συνημιτόνου δεν λαμβάνει υπόψη τις διαφορετικές τάσεις βαθμολόγησης των χρηστών (άλλοι βαθμολογούν συστηματικά υψηλά, άλλοι χαμηλά). Το πρόβλημα αυτό αντιμετωπίζει ο συντελεστής συσχέτισης Pearson, ο οποίος αφαιρεί τον μέσο όρο βαθμολογιών κάθε χρήστη:

$$\text{sim}_{\text{pearson}}(u, v) = \frac{\sum_{i \in I_{uv}} (r_{ui} - \bar{r}_u)(r_{vi} - \bar{r}_v)}{\sqrt{\sum_{i \in I_{uv}} (r_{ui} - \bar{r}_u)^2} \sqrt{\sum_{i \in I_{uv}} (r_{vi} - \bar{r}_v)^2}}$$

όπου $\bar{r}_u$ και $\bar{r}_v$ οι μέσες βαθμολογίες των χρηστών u και v αντίστοιχα.

Στο item-based φιλτράρισμα χρησιμοποιείται συχνά η προσαρμοσμένη ομοιότητα συνημιτόνου (adjusted cosine similarity), η οποία αφαιρεί τον μέσο όρο ανά χρήστη ώστε να εξουδετερώνονται οι διαφορές κλίμακας μεταξύ χρηστών:

$$\text{sim}(i, j) = \frac{\sum_{u \in U_{ij}} (r_{ui} - \bar{r}_u)(r_{uj} - \bar{r}_u)}{\sqrt{\sum_{u \in U_{ij}} (r_{ui} - \bar{r}_u)^2} \sqrt{\sum_{u \in U_{ij}} (r_{uj} - \bar{r}_u)^2}}$$

όπου U_{ij} το σύνολο των χρηστών που έχουν αξιολογήσει και τα δύο αντικείμενα i και j .

3.6.2 Πρόβλεψη user-based και item-based

Στο user-based φιλτράρισμα, η προβλεπόμενη βαθμολογία του χρήστη u για το αντικείμενο i προκύπτει ως σταθμισμένος μέσος όρος των βαθμολογιών των «γειτόνων» του χρήστη, δηλαδή του συνόλου $N(u)$ των πλέον όμοιων χρηστών που έχουν αξιολογήσει το i :

$$\hat{r}_{ui} = \bar{r}_u + \frac{\sum_{v \in N(u)} \text{sim}(u, v) (r_{vi} - \bar{r}_v)}{\sum_{v \in N(u)} |\text{sim}(u, v)|}$$

Αντίστοιχα, στο item-based φιλτράρισμα η πρόβλεψη βασίζεται στην ομοιότητα του αντικειμένου-στόχου i με τα υπόλοιπα αντικείμενα που έχει αξιολογήσει ο χρήστης:

$$\hat{r}_{ui} = \frac{\sum_{j \in N(i)} \text{sim}(i, j) r_{uj}}{\sum_{j \in N(i)} |\text{sim}(i, j)|}$$

Το item-based φιλτράρισμα προτιμάται συχνά σε συστήματα ηλεκτρονικού εμπορίου μεγάλης κλίμακας, όπως το Amazon, διότι οι ομοιότητες μεταξύ προϊόντων είναι πιο σταθερές στον χρόνο από τις ομοιότητες μεταξύ χρηστών και μπορούν να προϋπολογιστούν εκτός σύνδεσης (offline).

3.6.3 Αλγόριθμος k-Nearest Neighbors για σύσταση

Η επιλογή των γειτόνων γίνεται με τον αλγόριθμο k πλησιέστερων γειτόνων (k -NN): για κάθε πρόβλεψη επιλέγονται οι k χρήστες (ή αντικείμενα) με τη μεγαλύτερη ομοιότητα. Ο παρακάτω ψευδοκώδικας περιγράφει τη διαδικασία για item-based σύσταση.

Αλγόριθμος 3.1: Item-based k-NN πρόβλεψη

```

Είσοδος: πίνακας  $R$ , χρήστης  $u$ , αντικείμενο-στόχος  $i$ , πλήθος γειτόνων  $k$ 
Εξοδος: προβλεπόμενη βαθμολογία  $\hat{r}_{ui}$ 
1:  $S \leftarrow \{\}$  // λίστα (αντικείμενο, ομοιότητα)
2: για κάθε  $j \in I_u$  (αντικείμενα που αξιολόγησε ο  $u$ ):
3:    $s \leftarrow \text{sim}(i, j)$  // adjusted cosine
4:    $S \leftarrow S \cup \{(j, s)\}$ 
5:  $N(i) \leftarrow$  τα  $k$  αντικείμενα του  $S$  με τη μεγαλύτερη  $|s|$ 
6: αριθμητής  $\leftarrow \sum_{j \in N(i)} \text{sim}(i, j) \cdot r_{uj}$ 
7: παρονομαστής  $\leftarrow \sum_{j \in N(i)} |\text{sim}(i, j)|$ 
8: αν παρονομαστής = 0: επίστρεψε τον μέσο όρο του αντικειμένου  $i$ 
9:  $\hat{r}_{ui} \leftarrow$  αριθμητής / παρονομαστής
10: επίστρεψε  $\hat{r}_{ui}$ 

```

Η υπολογιστική πολυπλοκότητα του naive item-based k -NN για τον υπολογισμό όλων των ομοιοτήτων είναι $O(n^2 \cdot m)$ στη χειρότερη περίπτωση, γεγονός που καθιστά απαραίτητες τεχνικές

επιτάχυνσης (π.χ. αποθήκευση αραιών πινάκων, προϋπολογισμός γειτονιάς, locality-sensitive hashing) σε συστήματα μεγάλης κλίμακας.

3.7 Μοντέλα παραγοντοποίησης πινάκων (Matrix Factorization)

Τα μοντέλα παραγοντοποίησης πινάκων αποτελούν την πλέον διαδεδομένη κατηγορία μεθόδων μοντέλου (model-based) και αναδείχθηκαν ιδιαίτερα μετά τον διαγωνισμό Netflix Prize. Η βασική ιδέα είναι η αναπαράσταση χρηστών και αντικειμένων σε έναν κοινό λανθάνοντα χώρο (latent factor space) διάστασης k , όπου κάθε χρήστης u αντιστοιχεί σε ένα διάνυσμα p_u και κάθε αντικείμενο i σε ένα διάνυσμα q_i .

$$p_u \in \mathbb{R}^k, \quad q_i \in \mathbb{R}^k, \quad k \ll \min(m, n)$$

Η προβλεπόμενη βαθμολογία προκύπτει από το εσωτερικό γινόμενο των δύο διανυσμάτων, το οποίο εκφράζει τον βαθμό στον οποίο τα ενδιαφέροντα του χρήστη ευθυγραμμίζονται με τα χαρακτηριστικά του αντικειμένου:

$$\hat{r}_{ui} = p_u^T q_i = \sum_{f=1}^k p_{uf} q_{if}$$

3.7.1 Συνάρτηση σφάλματος και κανονικοποίηση

Η εκμάθηση των λανθανόντων διανυσμάτων γίνεται με ελαχιστοποίηση του τετραγωνικού σφάλματος πρόβλεψης πάνω στο σύνολο K των γνωστών βαθμολογιών, με προσθήκη όρου κανονικοποίησης (regularization) L_2 για την αποφυγή υπερπροσαρμογής (overfitting):

$$\min_{p^*, q^*} \sum_{(u, i) \in K} (r_{ui} - p_u^T q_i)^2 + \lambda (\|p_u\|^2 + \|q_i\|^2)$$

όπου $\lambda \geq 0$ η παράμετρος κανονικοποίησης που ελέγχει το μέγεθος των παραμέτρων.

Η ενσωμάτωση όρων μεροληψίας (bias terms) βελτιώνει σημαντικά την ακρίβεια, καθώς μοντελοποιεί τις συστηματικές αποκλίσεις χρηστών και αντικειμένων από τον γενικό μέσο όρο μ :

$$\hat{r}_{ui} = \mu + b_u + b_i + p_u^T q_i$$

όπου μ ο συνολικός μέσος όρος όλων των βαθμολογιών, b_u η μεροληψία του χρήστη u και b_i η μεροληψία του αντικειμένου i .

Η αντίστοιχη συνάρτηση κόστους με μεροληψίες γίνεται:

$$J = \sum_{(u,i) \in K} (r_{ui} - \mu - b_u - b_i - p_u^T q_i)^2 + \lambda (\|p_u\|^2 + \|q_i\|^2 + b_u^2 + b_i^2)$$

3.7.2 Βελτιστοποίηση με στοχαστική κατάβαση κλίσης (SGD)

Μία από τις πιο αποδοτικές μεθόδους ελαχιστοποίησης είναι η στοχαστική κατάβαση κλίσης (Stochastic Gradient Descent, SGD). Για κάθε γνωστή βαθμολογία υπολογίζεται το σφάλμα πρόβλεψης:

$$e_{ui} = r_{ui} - \hat{r}_{ui}$$

και οι παράμετροι ενημερώνονται προς την αντίθετη κατεύθυνση της κλίσης, με ρυθμό μάθησης γ :

$$p_u \leftarrow p_u + \gamma (e_{ui} q_i - \lambda p_u)$$

$$q_i \leftarrow q_i + \gamma (e_{ui} p_u - \lambda q_i)$$

$$b_u \leftarrow b_u + \gamma (e_{ui} - \lambda b_u), \quad b_i \leftarrow b_i + \gamma (e_{ui} - \lambda b_i)$$

Αλγόριθμος 3.2: Εκπαίδευση Matrix Factorization με SGD

Είσοδος: γνωστές βαθμολογίες K , διάσταση k , ρυθμός γ , κανονικ. λ , εποχές T
 Έξοδος: παράμετροι p, q, b_u, b_i, μ

- 1: $\mu \leftarrow$ μέσος όρος όλων των r_{ui} στο K
- 2: αρχικοποίησε p_u, q_i με μικρές τυχαίες τιμές. $b_u, b_i \leftarrow 0$
- 3: για epoch = 1 έως T :
- 4: ανακάτεψε (shuffle) τις $(u,i) \in K$
- 5: για κάθε $(u,i) \in K$:
- 6: $\hat{r}_{ui} \leftarrow \mu + b_u + b_i + p_u \cdot q_i$
- 7: $e_{ui} \leftarrow r_{ui} - \hat{r}_{ui}$
- 8: $b_u \leftarrow b_u + \gamma (e_{ui} - \lambda \cdot b_u)$
- 9: $b_i \leftarrow b_i + \gamma (e_{ui} - \lambda \cdot b_i)$
- 10: $p_u \leftarrow p_u + \gamma (e_{ui} \cdot q_i - \lambda \cdot p_u)$
- 11: $q_i \leftarrow q_i + \gamma (e_{ui} \cdot p_u - \lambda \cdot q_i)$
- 12: (προαιρετικά) υπολόγισε RMSE στο validation και έλεγξε σύγκλιση
- 13: επέστρεψε p, q, b_u, b_i, μ

3.7.3 Εναλλασσόμενα ελάχιστα τετράγωνα (ALS)

Μια εναλλακτική μέθοδος βελτιστοποίησης είναι τα Εναλλασσόμενα Ελάχιστα Τετράγωνα (Alternating Least Squares, ALS). Επειδή η συνάρτηση κόστους δεν είναι κυρτή ως προς p και q ταυτόχρονα, αλλά γίνεται κυρτή αν σταθεροποιηθεί το ένα εκ των δύο, η ALS εναλλάσσει: κρατά

σταθερά τα q_i και λύνει ως προς r_u , και αντίστροφα. Για σταθερά q_i , η βέλτιστη λύση για κάθε χρήστη προκύπτει αναλυτικά:

$$p_u = (Q_{I_u}^T Q_{I_u} + \lambda \mathbf{I})^{-1} Q_{I_u}^T r_u$$

όπου Q_{I_u} ο πίνακας των διανυσμάτων των αντικειμένων που αξιολόγησε ο u , $\mathbf{I}$ ο μοναδιαίος πίνακας $k \times k$ και r_u το διάνυσμα των βαθμολογιών του u .

Η ALS παραλληλοποιείται εύκολα (κάθε r_u υπολογίζεται ανεξάρτητα) και είναι ιδιαίτερα κατάλληλη για δεδομένα έμμεσης ανάδρασης (implicit feedback) μεγάλης κλίμακας, όπως κλικ, προβολές και αγορές σε πλατφόρμες e-commerce.

3.8 Φιλτράρισμα βασισμένο στο περιεχόμενο (Content-based Filtering)

Το φιλτράρισμα βάσει περιεχομένου συστήνει αντικείμενα όμοια με εκείνα που άρεσαν στο παρελθόν στον χρήστη, με βάση τα χαρακτηριστικά (features) των αντικειμένων. Κάθε αντικείμενο i αναπαρίσταται ως διάνυσμα χαρακτηριστικών. Για κείμενα (π.χ. περιγραφές προϊόντων) χρησιμοποιείται η στάθμιση TF-IDF, η οποία αποδίδει σε κάθε όρο t βάρος ανάλογο της συχνότητάς του στο έγγραφο και αντιστρόφως ανάλογο της συχνότητάς του στη συλλογή:

$$\text{tfidf}(t, d) = \text{tf}(t, d) \cdot \log \frac{N}{\text{df}(t)}$$

όπου $\text{tf}(t, d)$ η συχνότητα του όρου t στο έγγραφο d , N το πλήθος των εγγράφων και $\text{df}(t)$ το πλήθος των εγγράφων που περιέχουν τον όρο t .

Το προφίλ κάθε χρήστη υπολογίζεται ως ο σταθμισμένος μέσος όρος των διανυσμάτων των αντικειμένων που έχει αξιολογήσει θετικά:

$$\text{profile}(u) = \frac{1}{|I_u|} \sum_{i \in I_u} r_{ui} \cdot \mathbf{v}_i$$

όπου $\mathbf{v}_i$ το διάνυσμα χαρακτηριστικών (π.χ. TF-IDF) του αντικειμένου i .

Η καταλληλότητα ενός νέου αντικειμένου εκτιμάται από την ομοιότητα συνημιτόνου μεταξύ του προφίλ του χρήστη και του διανύσματος του αντικειμένου:

$$\hat{r}_{ui} = \cos(\text{profile}(u), \mathbf{v}_i) = \frac{\text{profile}(u)^T \mathbf{v}_i}{\|\text{profile}(u)\| \|\mathbf{v}_i\|}$$

Το βασικό πλεονέκτημα της μεθόδου είναι η αντιμετώπιση του προβλήματος του «νέου αντικειμένου» (new item cold start), αφού δεν απαιτούνται προηγούμενες αξιολογήσεις άλλων χρηστών· βασικό μειονέκτημα είναι η υπερεξειδίκευση (overspecialization) και η αδυναμία ανακάλυψης απρόσμενων, ποικίλων προτάσεων.

3.9 Προηγμένες ευφυείς τεχνικές

3.9.1 Νευρωνικό συνεργατικό φιλτράρισμα (Neural Collaborative Filtering)

Το Neural Collaborative Filtering (NCF) γενικεύει την παραγοντοποίηση πινάκων αντικαθιστώντας το εσωτερικό γινόμενο με ένα μη γραμμικό νευρωνικό δίκτυο. Οι χρήστες και τα αντικείμενα απεικονίζονται σε διανύσματα ενσωμάτωσης (embeddings) και η αλληλεπίδρασή τους μαθαίνεται μέσω πολυεπίπεδου perceptron:

$$\hat{r}_{ui} = \sigma(h^T \phi(p_u, q_i))$$

όπου ϕ η συνάρτηση αλληλεπίδρασης του δικτύου, h το διάνυσμα βαρών του τελικού επιπέδου και σ η σιγμοειδής συνάρτηση ενεργοποίησης.

$$\sigma(x) = \frac{1}{1 + e^{-x}}$$

Η εκπαίδευση για implicit δεδομένα γίνεται με ελαχιστοποίηση της δυαδικής διασταυρούμενης εντροπίας (binary cross-entropy) μεταξύ των πραγματικών αλληλεπιδράσεων και των προβλέψεων.

3.9.2 Κανόνες συσχέτισης (Association Rules)

Η εξόρυξη κανόνων συσχέτισης εντοπίζει μοτίβα της μορφής «όσοι αγόρασαν το X αγόρασαν και το Y» και αξιοποιείται ευρέως στο ηλεκτρονικό εμπόριο (market basket analysis). Ένας κανόνας $X \Rightarrow Y$ αξιολογείται με τρεις βασικές μετρικές. Η υποστήριξη (support) εκφράζει τη συχνότητα εμφάνισης του συνόλου στις συναλλαγές:

$$\text{support}(X \Rightarrow Y) = \frac{|\{T : X \cup Y \subseteq T\}|}{|D|}$$

Η εμπιστοσύνη (confidence) εκφράζει την υπό συνθήκη πιθανότητα εμφάνισης του Y δεδομένου του X:

$$\text{confidence}(X \Rightarrow Y) = \frac{\text{support}(X \cup Y)}{\text{support}(X)}$$

Η ανύψωση (lift) μετρά πόσο ισχυρότερη είναι η συσχέτιση σε σχέση με την τυχαιότητα· τιμές > 1 δηλώνουν θετική συσχέτιση:

$$\text{lift}(X \Rightarrow Y) = \frac{\text{confidence}(X \Rightarrow Y)}{\text{support}(Y)}$$

3.9.3 Ομαδοποίηση χρηστών με k-means

Η ομαδοποίηση (clustering) χρησιμοποιείται για την τμηματοποίηση χρηστών σε ομάδες με παρόμοιες προτιμήσεις, μειώνοντας την πολυπλοκότητα των συστάσεων. Ο αλγόριθμος k-means ελαχιστοποιεί το άθροισμα των τετραγωνικών αποστάσεων των σημείων από τα κέντρα των ομάδων:

$$J = \sum_{j=1}^k \sum_{x \in C_j} \|x - \mu_j\|^2$$

όπου C_j η j -οστή ομάδα και μ_j το κέντρο (centroid) της.

3.9.4 Ασαφής λογική και εξελικτικοί αλγόριθμοι

Η ασαφής λογική (fuzzy logic) επιτρέπει τη μοντελοποίηση αβέβαιων ή ασαφών προτιμήσεων, αντιστοιχίζοντας κάθε χρήστη σε μια κατηγορία με βαθμό συμμετοχής (membership degree) στο διάστημα $[0,1]$ αντί για δυαδική ένταξη:

$$\mu_A : X \rightarrow [0, 1], \quad \mu_A(x) \in [0, 1]$$

Οι εξελικτικοί (γενετικοί) αλγόριθμοι αξιοποιούνται για τη βελτιστοποίηση υπερπαραμέτρων ή τον συνδυασμό μεθόδων σε υβριδικά συστήματα, καθοδηγούμενοι από μια συνάρτηση καταλληλότητας (fitness) που αντικατοπτρίζει την ποιότητα των συστάσεων (π.χ. την ακρίβεια Top-N).

3.10 Υβριδικές μέθοδοι σύστασης

Οι υβριδικές μέθοδοι συνδυάζουν δύο ή περισσότερες τεχνικές ώστε να αντισταθμίζονται τα μειονεκτήματα της καθεμιάς (π.χ. το πρόβλημα cold-start του συνεργατικού φιλτραρίσματος με

τη δυνατότητα του content-based). Στη σταθμισμένη (weighted) υβριδική προσέγγιση, η τελική πρόβλεψη είναι γραμμικός συνδυασμός των επιμέρους προβλέψεων:

$$\hat{r}_{ui} = \sum_{s=1}^S \alpha_s \hat{r}_{ui}^{(s)}, \quad \sum_{s=1}^S \alpha_s = 1, \quad \alpha_s \geq 0$$

όπου $\hat{r}^{(s)}$ η πρόβλεψη της s -οστής μεθόδου και α_s το αντίστοιχο βάρος της.

Άλλες στρατηγικές περιλαμβάνουν τη μεταγωγή (switching), όπου το σύστημα επιλέγει δυναμικά μέθοδο ανάλογα με το πλαίσιο (π.χ. content-based για νέους χρήστες, collaborative για έμπειρους), και τη μεικτή (mixed) προσέγγιση, όπου παρουσιάζονται ταυτόχρονα προτάσεις από πολλαπλές μεθόδους. Η σταθμισμένη υβριδική μέθοδος συγκαταλέγεται στις πλέον αποτελεσματικές προσεγγίσεις της πράξης και αποτελεί συχνά τη βάση σύγχρονων εμπορικών συστημάτων συστάσεων.

3.11 Βιβλιογραφική αποτίμηση

Η μαθηματική θεμελίωση που παρουσιάστηκε στο παρόν κεφάλαιο αντλεί από τα θεμελιώδη έργα του πεδίου. Το συνεργατικό φιλτράρισμα βασισμένο στη μνήμη τυποποιήθηκε από τους Resnick et al. (1994) και Sarwar et al. (2001), ενώ η παραγοντοποίηση πινάκων και οι όροι μεροληψίας από τους Koren et al. (2009) και Koren (2010). Οι μέθοδοι για implicit feedback και ALS προέρχονται από τους Hu et al. (2008) και Rendle et al. (2009), το νευρωνικό συνεργατικό φιλτράρισμα από τους He et al. (2017) και οι κανόνες συσχέτισης από την κλασική εργασία εξόρυξης δεδομένων. Η σύγκλιση όλων αυτών των προσεγγίσεων καταδεικνύει ότι το πρόβλημα της σύστασης είναι, στον πυρήνα του, ένα πρόβλημα μαθηματικής βελτιστοποίησης πάνω σε αραιά δεδομένα.

ΚΕΦΑΛΑΙΟ 4: Εφαρμογή Ευφυών Τεχνικών στα Συστήματα Συστάσεων

4.1 Συστήματα συστάσεων βασισμένα σε περιεχόμενο

Τα συστήματα συστάσεων βασισμένα σε περιεχόμενο (content-based recommender systems) αποτελούν μία από τις θεμελιώδεις κατηγορίες συστημάτων συστάσεων και βασίζονται στην αρχή ότι οι χρήστες τείνουν να προτιμούν αντικείμενα με χαρακτηριστικά παρόμοια με εκείνα που έχουν εκτιμήσει θετικά στο παρελθόν. Η βασική λειτουργία τους στηρίζεται στην ανάλυση των ιδιοτήτων των αντικειμένων και στη δημιουργία ενός προφίλ προτιμήσεων για κάθε χρήστη, το οποίο χρησιμοποιείται για την πρόβλεψη του βαθμού ενδιαφέροντος απέναντι σε νέα αντικείμενα. Η προσέγγιση αυτή διαφοροποιείται από τα συνεργατικά συστήματα συστάσεων, καθώς δεν απαιτεί πληροφορίες από άλλους χρήστες αλλά επικεντρώνεται αποκλειστικά στη σχέση μεταξύ του χρήστη και των χαρακτηριστικών του περιεχομένου των αντικειμένων (Adomavicius & Tuzhilin, 2005).

Η ανάπτυξη των συστημάτων συστάσεων βασισμένων σε περιεχόμενο συνδέεται άμεσα με την ανάγκη διαχείρισης της υπερφόρτωσης πληροφορίας που προέκυψε από τη ραγδαία αύξηση του διαθέσιμου ψηφιακού περιεχομένου. Σε περιβάλλοντα όπου οι χρήστες έρχονται αντιμέτωποι με τεράστιο όγκο πληροφοριών, η δυνατότητα αυτόματης φιλτραρίσματος και εξατομίκευσης του περιεχομένου καθίσταται κρίσιμη. Οι πρώτες εφαρμογές τέτοιων συστημάτων εμφανίστηκαν σε συστήματα διαχείρισης ειδήσεων, ηλεκτρονικής αλληλογραφίας και προσωπικών βοηθών λογισμικού, όπου χρησιμοποιούνταν τεχνικές μηχανικής μάθησης για την ανάλυση των προτιμήσεων των χρηστών και την παροχή εξατομικευμένων προτάσεων (Mitchell et al., 1994). Αξίζει επίσης να σημειωθεί πως, η έρευνα στον τομέα των ευφυών πρακτόρων συνέβαλε σημαντικά στη διαμόρφωση των θεωρητικών βάσεων των content-based συστημάτων, καθώς οι πράκτορες αυτοί είχαν τη δυνατότητα να παρακολουθούν τη συμπεριφορά των χρηστών, να μαθαίνουν από τις αλληλεπιδράσεις τους και να προσαρμόζουν δυναμικά τις προτάσεις τους (Maes, 1994; Maes, 1997; Genesereth & Ketchpel, 1994).

Η λειτουργία ενός συστήματος βασισμένου σε περιεχόμενο προϋποθέτει την ύπαρξη περιγραφικών χαρακτηριστικών για κάθε αντικείμενο. Τα χαρακτηριστικά αυτά μπορεί να είναι λέξεις-κλειδιά, κατηγορίες, μεταδεδομένα, ετικέτες ή άλλες ιδιότητες που επιτρέπουν την αναπαράσταση του περιεχομένου σε κατάλληλη μορφή. Στην περίπτωση των άρθρων ειδήσεων, για παράδειγμα, χρησιμοποιούνται συχνά όροι που εξάγονται από το κείμενο, ενώ στις εφαρμογές μουσικής και κινηματογράφου αξιοποιούνται πληροφορίες όπως το είδος, οι

δημιουργοί, οι ηθοποιοί ή άλλες θεματικές κατηγορίες. Το προφίλ του χρήστη δημιουργείται μέσω της ανάλυσης των αντικειμένων με τα οποία έχει αλληλεπιδράσει θετικά και αποτυπώνει τις προτιμήσεις του σε ένα πολυδιάστατο χώρο χαρακτηριστικών. Στη συνέχεια, η ομοιότητα μεταξύ του προφίλ του χρήστη και των διαθέσιμων αντικειμένων υπολογίζεται με διάφορες μεθόδους, επιτρέποντας την επιλογή των πλέον σχετικών προτάσεων (Adomavicius & Tuzhilin, 2005). Η εισαγωγή τεχνικών μηχανικής μάθησης συνέβαλε καθοριστικά στη βελτίωση της αποτελεσματικότητας των content-based συστημάτων. Οι αλγόριθμοι αυτοί είναι σε θέση να αναγνωρίζουν πρότυπα στις προτιμήσεις των χρηστών και να ενημερώνουν δυναμικά τα προφίλ τους καθώς προκύπτουν νέες αλληλεπιδράσεις. Με αυτόν τον τρόπο, οι συστάσεις δεν βασίζονται αποκλειστικά σε στατικά χαρακτηριστικά αλλά προσαρμόζονται συνεχώς στις μεταβαλλόμενες ανάγκες και ενδιαφέροντα των χρηστών. Η δυνατότητα μάθησης από την εμπειρία αποτελεί βασικό στοιχείο των ευφυών συστημάτων και συνδέεται με τη γενικότερη φιλοσοφία των πρακτόρων λογισμικού, οι οποίοι διαθέτουν αυτονομία, προσαρμοστικότητα και ικανότητα λήψης αποφάσεων (Wooldridge & Jennings, 1995; Sycara, 1995; Nwana & Ndumu, 1998).

Ένα από τα σημαντικότερα πλεονεκτήματα των συστημάτων συστάσεων βασισμένων σε περιεχόμενο είναι η ανεξαρτησία τους από τις αξιολογήσεις άλλων χρηστών. Σε αντίθεση με το συνεργατικό φιλτράρισμα, το οποίο απαιτεί μεγάλο όγκο δεδομένων αλληλεπίδρασης μεταξύ πολλών χρηστών, τα content-based συστήματα μπορούν να λειτουργήσουν ακόμη και όταν οι πληροφορίες αυτές είναι περιορισμένες. Το χαρακτηριστικό αυτό τα καθιστά ιδιαίτερα χρήσιμα σε περιβάλλοντα όπου οι χρήστες διαθέτουν εξειδικευμένα ενδιαφέροντα ή όταν το σύστημα εξυπηρετεί σχετικά μικρό αριθμό ατόμων. Ακόμη, προσφέρουν υψηλό βαθμό εξατομίκευσης, καθώς οι προτάσεις βασίζονται αποκλειστικά στο προσωπικό ιστορικό κάθε χρήστη και όχι στις προτιμήσεις της ευρύτερης κοινότητας (Adomavicius & Tuzhilin, 2005). Ένα ακόμη σημαντικό πλεονέκτημα αφορά την ερμηνευσιμότητα των προτάσεων. Επειδή οι συστάσεις προκύπτουν από συγκεκριμένα χαρακτηριστικά των αντικειμένων, είναι σχετικά εύκολο να εξηγηθεί στον χρήστη γιατί προτάθηκε ένα συγκεκριμένο στοιχείο. Η δυνατότητα παροχής εξηγήσεων αποτελεί σημαντικό παράγοντα για την ενίσχυση της διαφάνειας, της εμπιστοσύνης και της αποδοχής των συστημάτων συστάσεων. Σύμφωνα με τη σύγχρονη βιβλιογραφία, η ερμηνευσιμότητα αποτελεί πλέον βασική απαίτηση για τα ευφυή συστήματα, καθώς οι χρήστες επιθυμούν να κατανοούν τη λογική πίσω από τις προτάσεις που λαμβάνουν (Zhang & Chen, 2020). Ακόμη, η εμπιστοσύνη έχει αναδειχθεί σε κρίσιμο παράγοντα επιτυχίας των συστημάτων συστάσεων, καθώς επηρεάζει άμεσα την πρόθεση των χρηστών να ακολουθήσουν τις προτεινόμενες επιλογές και να συνεχίσουν να χρησιμοποιούν την πλατφόρμα (Akdim et al., 2025).

Παρά όλα τα θετικά τους, τα συστήματα βασισμένα σε περιεχόμενο παρουσιάζουν και ορισμένους περιορισμούς. Ένα από τα σημαντικότερα προβλήματα είναι η υπερεξειδίκευση των προτάσεων. Επειδή το σύστημα βασίζεται αποκλειστικά στις προηγούμενες προτιμήσεις του χρήστη, τείνει να προτείνει αντικείμενα παρόμοια με εκείνα που έχει ήδη επιλέξει, περιορίζοντας έτσι την ανακάλυψη νέου περιεχομένου. Το φαινόμενο αυτό μπορεί να οδηγήσει στη δημιουργία ενός στενού φάσματος προτάσεων και να μειώσει τη συνολική εμπειρία του χρήστη. Η πρόκληση της ισορροπίας μεταξύ ακρίβειας και ποικιλίας αποτελεί ένα από τα βασικά ερευνητικά ζητήματα στον χώρο των συστημάτων συστάσεων και έχει οδηγήσει στην ανάπτυξη πολυκριτηριακών και πολυστοχικών προσεγγίσεων που λαμβάνουν υπόψη πολλαπλούς στόχους κατά τη διαδικασία σύστασης (Jannach et al., 2023).

Ένας ακόμη περιορισμός αφορά την ανάγκη ύπαρξης πλούσιων και ποιοτικών περιγραφικών χαρακτηριστικών για κάθε αντικείμενο. Η αποτελεσματικότητα του συστήματος εξαρτάται σε μεγάλο βαθμό από την πληρότητα και την ακρίβεια των διαθέσιμων μεταδεδομένων. Σε περιπτώσεις όπου τα αντικείμενα δεν διαθέτουν επαρκή χαρακτηριστικά ή όταν η αναπαράσταση του περιεχομένου είναι ελλιπής, η ποιότητα των συστάσεων ενδέχεται να μειωθεί σημαντικά. Επίσης, η δημιουργία και συντήρηση των μεταδεδομένων μπορεί να απαιτεί σημαντικό κόστος και υπολογιστικούς πόρους, ιδιαίτερα σε εφαρμογές μεγάλης κλίμακας όπου ο αριθμός των διαθέσιμων αντικειμένων αυξάνεται συνεχώς (Li et al., 2023). Η εξέλιξη των τεχνικών βαθιάς μάθησης έχει μεταμορφώσει ουσιαστικά τον τρόπο με τον οποίο υλοποιούνται τα σύγχρονα content-based συστήματα συστάσεων. Οι παραδοσιακές μέθοδοι αναπαράστασης χαρακτηριστικών αντικαθίστανται πλέον από νευρωνικά δίκτυα τα οποία είναι σε θέση να εξαγάγουν αυτόματα σύνθετες και υψηλού επιπέδου αναπαραστάσεις από μη δομημένα δεδομένα, όπως κείμενο, εικόνες, ήχο και βίντεο. Μέσω αυτής της διαδικασίας, το σύστημα μπορεί να κατανοήσει βαθύτερες σημασιολογικές σχέσεις μεταξύ των αντικειμένων και να παράγει πιο ακριβείς και προσωποποιημένες συστάσεις. Η αξιοποίηση βαθιών νευρωνικών δικτύων έχει οδηγήσει σε σημαντική βελτίωση της απόδοσης των συστημάτων συστάσεων σε πολλές εφαρμογές του πραγματικού κόσμου, ιδίως σε πλατφόρμες ψηφιακού περιεχομένου μεγάλης κλίμακας (Zhang et al., 2019; Zhou et al., 2023).

Χαρακτηριστικό παράδειγμα φαίνεται να αποτελεί η χρήση αρχιτεκτονικών βαθιάς μάθησης σε συστήματα όπως το YouTube, όπου τα νευρωνικά δίκτυα χρησιμοποιούνται για την επεξεργασία μεγάλου όγκου πληροφοριών σχετικά με το περιεχόμενο και τη συμπεριφορά των χρηστών, επιτρέποντας την παροχή εξαιρετικά εξατομικευμένων προτάσεων σε πραγματικό χρόνο (Covington et al., 2016). Παρόμοια, η προσέγγιση Wide & Deep συνδυάζει τη δυνατότητα απομνημόνευσης γνωστών συσχετίσεων με τη γενίκευση νέων μοτίβων, προσφέροντας

βελτιωμένη ακρίβεια και αποτελεσματικότητα στις διαδικασίες σύστασης (Cheng et al., 2016). Οι εξελίξεις αυτές καταδεικνύουν τον τρόπο με τον οποίο οι ευφυείς τεχνικές έχουν επεκτείνει σημαντικά τις δυνατότητες των παραδοσιακών content-based συστημάτων.

Συγχρόνως, η σύγχρονη έρευνα εξετάζει τη συνδυαστική αξιοποίηση διαφορετικών πηγών πληροφορίας και τεχνικών μάθησης με στόχο την αντιμετώπιση των αδυναμιών των κλασικών content-based προσεγγίσεων. Τα συστήματα βαθιάς μάθησης μπορούν να ενσωματώνουν δεδομένα περιεχομένου, ιστορικό αλληλεπιδράσεων και πληροφορίες περιβάλλοντος, δημιουργώντας πιο ολοκληρωμένα μοντέλα προτιμήσεων. Εκτός αυτού, η ενσωμάτωση τεχνικών ενισχυτικής μάθησης επιτρέπει στα συστήματα να βελτιστοποιούν δυναμικά τις προτάσεις τους με βάση τη διαδοχική συμπεριφορά των χρηστών και τους μακροπρόθεσμους στόχους αλληλεπίδρασης (Chen et al., 2021).

4.2 Συνεργατικά συστήματα συστάσεων

Τα συνεργατικά συστήματα συστάσεων (collaborative recommender systems) αποτελούν μία από τις πλέον διαδεδομένες και επιτυχημένες προσεγγίσεις στον χώρο των συστημάτων συστάσεων, καθώς βασίζονται στην αξιοποίηση των προτιμήσεων και της συμπεριφοράς πολλών χρηστών για την παραγωγή εξατομικευμένων προτάσεων. Σε αντίθεση με τα συστήματα που βασίζονται στο περιεχόμενο, τα συνεργατικά συστήματα δεν απαιτούν λεπτομερή γνώση των χαρακτηριστικών των αντικειμένων, αλλά στηρίζονται στην υπόθεση ότι χρήστες με παρόμοιες προτιμήσεις στο παρελθόν είναι πιθανό να παρουσιάσουν παρόμοια συμπεριφορά και στο μέλλον. Η βασική αυτή αρχή έχει καταστήσει τα συνεργατικά συστήματα θεμελιώδη τεχνολογία σε εφαρμογές ηλεκτρονικού εμπορίου, υπηρεσίες ψυχαγωγίας, πλατφόρμες κοινωνικής δικτύωσης και γενικότερα σε κάθε περιβάλλον όπου απαιτείται η εξατομίκευση της εμπειρίας του χρήστη (Adomavicius & Tuzhilin, 2005). Η ιστορική εξέλιξη των συνεργατικών συστημάτων συστάσεων συνδέεται άμεσα με τις πρώτες προσπάθειες αξιοποίησης της συλλογικής γνώσης και εμπειρίας των χρηστών για τη διαχείριση της αυξανόμενης ποσότητας ψηφιακής πληροφορίας. Οι πρώτες σημαντικές εφαρμογές εμφανίστηκαν στις αρχές της δεκαετίας του 1990 με τα συστήματα Tapestry και GroupLens, τα οποία αξιοποιούσαν τις αξιολογήσεις και τις προτιμήσεις των χρηστών για την παροχή προσωποποιημένων προτάσεων σε περιβάλλοντα ανταλλαγής πληροφοριών και ειδήσεων (Goldberg et al., 1992; Resnick et al., 1994). Τα συστήματα αυτά απέδειξαν ότι οι συλλογικές προτιμήσεις μπορούν να αποτελέσουν ισχυρή πηγή γνώσης για τη δημιουργία αποτελεσματικών μηχανισμών φιλτραρίσματος και σύστασης, θέτοντας τα θεμέλια για την ανάπτυξη των σύγχρονων συνεργατικών προσεγγίσεων.

Η βασική λειτουργία των συνεργατικών συστημάτων στηρίζεται στη συλλογή και ανάλυση δεδομένων αλληλεπίδρασης μεταξύ χρηστών και αντικειμένων. Τα δεδομένα αυτά μπορεί να προέρχονται από ρητές αξιολογήσεις, όπως βαθμολογίες και κριτικές, ή από έμμεσες ενδείξεις ενδιαφέροντος, όπως αγορές, προβολές, κλικ, χρόνος παραμονής ή ιστορικό πλοήγησης. Με βάση αυτές τις πληροφορίες, το σύστημα προσπαθεί να εντοπίσει πρότυπα ομοιότητας είτε μεταξύ χρηστών είτε μεταξύ αντικειμένων, προκειμένου να προβλέψει ποιες επιλογές είναι πιθανό να ενδιαφέρουν έναν συγκεκριμένο χρήστη. Η διαδικασία αυτή επιτρέπει την παραγωγή συστάσεων χωρίς να απαιτείται γνώση των πραγματικών χαρακτηριστικών των αντικειμένων, γεγονός που καθιστά τη μέθοδο ιδιαίτερα ευέλικτη και εφαρμόσιμη σε διαφορετικά πεδία (Ekstrand et al., 2011). Οι παραδοσιακές συνεργατικές μέθοδοι διακρίνονται συνήθως σε προσεγγίσεις βασισμένες στους χρήστες και σε προσεγγίσεις βασισμένες στα αντικείμενα. Στην πρώτη περίπτωση, το σύστημα εντοπίζει χρήστες με παρόμοιο ιστορικό προτιμήσεων και χρησιμοποιεί τις επιλογές τους για να προβλέψει τις μελλοντικές προτιμήσεις ενός χρήστη. Στη δεύτερη περίπτωση, η ανάλυση επικεντρώνεται στις σχέσεις μεταξύ αντικειμένων και προτείνονται στοιχεία που εμφανίζουν υψηλό βαθμό συσχέτισης με εκείνα που έχει ήδη επιλέξει ο χρήστης. Οι αλγόριθμοι αυτοί αποτέλεσαν για πολλά χρόνια τον πυρήνα των συνεργατικών συστημάτων συστάσεων και χρησιμοποιήθηκαν ευρέως σε εμπορικές εφαρμογές μεγάλης κλίμακας (Sarwar et al., 2001).

Ιδιαίτερα σημαντική υπήρξε η ανάπτυξη των αλγορίθμων συνεργατικού φιλτραρίσματος βασισμένων σε αντικείμενα, οι οποίοι προσέφεραν υψηλή υπολογιστική αποδοτικότητα και δυνατότητα κλιμάκωσης σε περιβάλλοντα με εκατομμύρια χρήστες και προϊόντα. Χαρακτηριστικό παράδειγμα αποτελεί το σύστημα προτάσεων της Amazon, το οποίο αξιοποίησε τη λογική των συσχετίσεων μεταξύ προϊόντων για την παραγωγή συστάσεων σε πραγματικό χρόνο. Η επιτυχία αυτής της προσέγγισης απέδειξε ότι οι συνεργατικές τεχνικές μπορούν να λειτουργήσουν αποτελεσματικά ακόμη και σε περιβάλλοντα με εξαιρετικά μεγάλο όγκο δεδομένων και υψηλές απαιτήσεις απόδοσης (Linden et al., 2003).

Πέρα από τα σχετικά πλεονεκτήματά τους, τα παραδοσιακά συνεργατικά συστήματα αντιμετώπισαν από νωρίς ορισμένες σημαντικές προκλήσεις. Ένα από τα πιο γνωστά προβλήματα είναι η αραιότητα των δεδομένων, καθώς οι περισσότεροι χρήστες αλληλεπιδρούν μόνο με ένα μικρό ποσοστό των διαθέσιμων αντικειμένων. Ως αποτέλεσμα, οι πίνακες αξιολογήσεων περιέχουν μεγάλο αριθμό κενών τιμών, γεγονός που δυσκολεύει τον εντοπισμό αξιόπιστων προτύπων ομοιότητας. Επίσης, τα προβλήματα της ψυχρής εκκίνησης (cold start) για νέους χρήστες και νέα αντικείμενα περιορίζουν την αποτελεσματικότητα των συστημάτων όταν δεν υπάρχουν επαρκή ιστορικά δεδομένα αλληλεπίδρασης (Adomavicius & Tuzhilin, 2005;

Ekstrand et al., 2011). Για την αντιμετώπιση αυτών των περιορισμών αναπτύχθηκαν πιο προηγμένες μέθοδοι βασισμένες στην παραγοντοποίηση πινάκων (matrix factorization). Οι τεχνικές αυτές επιδιώκουν να ανακαλύψουν λανθάνοντες παράγοντες που εξηγούν τις προτιμήσεις των χρηστών και τα χαρακτηριστικά των αντικειμένων μέσα από τη μαθηματική ανάλυση των διαθέσιμων δεδομένων. Αντί να βασίζονται αποκλειστικά σε άμεσες ομοιότητες, οι μέθοδοι παραγοντοποίησης είναι σε θέση να αποκαλύπτουν κρυφές σχέσεις και πρότυπα που δεν είναι εμφανή στις αρχικές αξιολογήσεις. Η προσέγγιση αυτή οδήγησε σε σημαντική βελτίωση της ακρίβειας των συστάσεων και αποτέλεσε τη βάση πολλών επιτυχημένων συστημάτων που αναπτύχθηκαν τα τελευταία χρόνια (Koren et al., 2009).

Η σημασία των τεχνικών παραγοντοποίησης ενισχύθηκε περαιτέρω με την εισαγωγή μοντέλων που λαμβάνουν υπόψη τη χρονική διάσταση των προτιμήσεων των χρηστών. Οι προτιμήσεις δεν παραμένουν σταθερές αλλά μεταβάλλονται με την πάροδο του χρόνου, επηρεαζόμενες από προσωπικές ανάγκες, κοινωνικές τάσεις και μεταβαλλόμενα ενδιαφέροντα. Η ενσωμάτωση χρονικών δυναμικών στα συνεργατικά μοντέλα επέτρεψε τη δημιουργία πιο ρεαλιστικών και προσαρμοστικών συστημάτων, τα οποία μπορούν να ανταποκρίνονται αποτελεσματικότερα στις αλλαγές της συμπεριφοράς των χρηστών (Koren, 2010).

Εκτός αυτού, η αυξανόμενη διαθεσιμότητα δεδομένων έμμεσης ανατροφοδότησης οδήγησε στην ανάπτυξη νέων μεθόδων συνεργατικού φιλτραρίσματος. Σε πολλές σύγχρονες εφαρμογές οι χρήστες δεν παρέχουν ρητές αξιολογήσεις, αλλά αλληλεπιδρούν με το περιεχόμενο μέσω προβολών, αγορών ή άλλων ενεργειών. Η αξιοποίηση αυτών των δεδομένων απαιτεί εξειδικευμένες τεχνικές επεξεργασίας, καθώς η απουσία μιας ενέργειας δεν σημαίνει απαραίτητα αρνητική προτίμηση. Οι μέθοδοι που σχεδιάστηκαν για δεδομένα έμμεσης ανατροφοδότησης επέτρεψαν την αποτελεσματική αξιοποίηση τέτοιων πληροφοριών και βελτίωσαν σημαντικά την απόδοση των συστημάτων συστάσεων σε πραγματικές συνθήκες λειτουργίας (Hu et al., 2008). Μία ακόμη σημαντική εξέλιξη υπήρξε η ανάπτυξη αλγορίθμων κατάταξης που επικεντρώνονται στη σχετική προτίμηση των χρηστών μεταξύ διαφορετικών αντικειμένων. Αντί να επιχειρούν την ακριβή πρόβλεψη μιας βαθμολογίας, οι μέθοδοι αυτές στοχεύουν στη δημιουργία μιας σειράς αντικειμένων ταξινομημένων με βάση την πιθανότητα ενδιαφέροντος για τον χρήστη. Η προσέγγιση αυτή ανταποκρίνεται καλύτερα στις ανάγκες των σύγχρονων εφαρμογών, όπου η ποιότητα της τελικής λίστας προτάσεων είναι σημαντικότερη από την ακριβή εκτίμηση μιας αριθμητικής αξιολόγησης (Rendle et al., 2009). Η εμφάνιση της βαθιάς μάθησης σηματοδότησε μία νέα εποχή για τα συνεργατικά συστήματα συστάσεων. Τα βαθιά νευρωνικά δίκτυα προσφέρουν τη δυνατότητα μοντελοποίησης πολύπλοκων και μη γραμμικών σχέσεων μεταξύ χρηστών και αντικειμένων, ξεπερνώντας τους περιορισμούς των

παραδοσιακών μεθόδων. Μέσω της εκμάθησης σύνθετων αναπαραστάσεων των δεδομένων, τα συστήματα μπορούν να εντοπίζουν βαθύτερα πρότυπα συμπεριφοράς και να παράγουν πιο ακριβείς και προσωποποιημένες προτάσεις. Η ενσωμάτωση νευρωνικών αρχιτεκτονικών στα συνεργατικά συστήματα έχει αποτελέσει ένα από τα πιο ενεργά ερευνητικά πεδία της τελευταίας δεκαετίας (Zhang et al., 2019; Zhou et al., 2023).

Ένα από τα πιο χαρακτηριστικά παραδείγματα αυτής της εξέλιξης είναι το Neural Collaborative Filtering, το οποίο αντικαθιστά τα γραμμικά μοντέλα παραγοντοποίησης με νευρωνικά δίκτυα ικανά να μαθαίνουν σύνθετες συναρτήσεις αλληλεπίδρασης μεταξύ χρηστών και αντικειμένων. Η προσέγγιση αυτή έχει αποδειχθεί ιδιαίτερα αποτελεσματική στην αξιοποίηση μεγάλων και πολύπλοκων συνόλων δεδομένων, βελτιώνοντας σημαντικά την ποιότητα των παραγόμενων συστάσεων (He et al., 2017). Παράλληλα, προηγμένες αρχιτεκτονικές βαθιάς μάθησης, όπως τα μοντέλα Wide & Deep, συνδυάζουν τη δυνατότητα απομνημόνευσης γνωστών σχέσεων με την ικανότητα γενίκευσης νέων προτύπων, ενισχύοντας περαιτέρω την αποτελεσματικότητα των συστημάτων συστάσεων (Cheng et al., 2016). Η εξέλιξη των συνεργατικών συστημάτων επηρεάστηκε επίσης από την ανάπτυξη τεχνικών ενισχυτικής μάθησης. Οι τεχνικές αυτές αντιμετωπίζουν τη διαδικασία σύστασης ως μία ακολουθία αποφάσεων, όπου το σύστημα μαθαίνει σταδιακά ποιες προτάσεις οδηγούν στα καλύτερα αποτελέσματα μακροπρόθεσμα. Αντί να επικεντρώνεται αποκλειστικά στις άμεσες αντιδράσεις των χρηστών, το σύστημα επιδιώκει να μεγιστοποιήσει τη συνολική εμπειρία και τη διαχρονική ικανοποίηση του χρήστη. Η προσέγγιση αυτή θεωρείται ιδιαίτερα υποσχόμενη για τις επόμενες γενιές ευφυών συστημάτων συστάσεων (Chen et al., 2021).

Μαζί με τη βελτίωση της ακρίβειας, η σύγχρονη έρευνα δίνει αυξημένη έμφαση σε ζητήματα διαφάνειας, εμπιστοσύνης και πολυκριτηριακής βελτιστοποίησης. Οι χρήστες επιθυμούν όχι μόνο ακριβείς προτάσεις αλλά και συστάσεις που να είναι κατανοητές, αξιόπιστες και δίκαιες. Η παροχή επεξηγήσεων για τις προτάσεις και η ενίσχυση της εμπιστοσύνης αποτελούν πλέον βασικούς στόχους των σύγχρονων συστημάτων συστάσεων (Zhang & Chen, 2020; Akdim et al., 2025). Επιπλέον, τα σύγχρονα συνεργατικά συστήματα καλούνται να ισορροπήσουν μεταξύ πολλαπλών αντικρουόμενων στόχων, όπως η ακρίβεια, η ποικιλία, η καινοτομία και η ικανοποίηση του χρήστη, γεγονός που έχει οδηγήσει στην ανάπτυξη πολυστοχικών προσεγγίσεων σύστασης (Jannach et al., 2023).

4.3 Υβριδικά συστήματα συστάσεων

Τα υβριδικά συστήματα συστάσεων (hybrid recommender systems) αποτελούν μία από τις σημαντικότερες εξελίξεις στον χώρο των συστημάτων συστάσεων, καθώς συνδυάζουν

διαφορετικές τεχνικές και πηγές πληροφορίας με στόχο τη βελτίωση της ποιότητας, της αξιοπιστίας και της αποτελεσματικότητας των προτάσεων. Η ανάπτυξή τους προέκυψε από την ανάγκη αντιμετώπισης των περιορισμών που εμφανίζουν οι επιμέρους προσεγγίσεις, όπως τα συστήματα βασισμένα σε περιεχόμενο και τα συνεργατικά συστήματα συστάσεων. Ενώ κάθε μία από αυτές τις κατηγορίες παρουσιάζει σημαντικά πλεονεκτήματα, εμφανίζει ταυτόχρονα αδυναμίες που περιορίζουν την απόδοσή της σε συγκεκριμένες συνθήκες. Τα υβριδικά συστήματα επιδιώκουν να αξιοποιήσουν τα ισχυρά σημεία πολλαπλών μεθόδων και να περιορίσουν τις αδυναμίες τους, προσφέροντας πιο ακριβείς, ευέλικτες και αξιόπιστες συστάσεις (Adomavicius & Tuzhilin, 2005). Η βασική φιλοσοφία των υβριδικών συστημάτων στηρίζεται στην παραδοχή ότι καμία μεμονωμένη τεχνική δεν είναι επαρκής για να αντιμετωπίσει όλες τις προκλήσεις που χαρακτηρίζουν τα σύγχρονα περιβάλλοντα συστάσεων. Τα συστήματα βασισμένα σε περιεχόμενο είναι ιδιαίτερα αποτελεσματικά στην εξατομίκευση και στην ερμηνευσιμότητα των προτάσεων, αλλά συχνά περιορίζονται από το φαινόμενο της υπερεξειδίκευσης και από την ανάγκη ύπαρξης πλούσιων μεταδεδομένων. Αντίστοιχα, τα συνεργατικά συστήματα εκμεταλλεύονται τη συλλογική γνώση των χρηστών και μπορούν να ανακαλύπτουν ενδιαφέρουσες συσχετίσεις μεταξύ αντικειμένων, όμως αντιμετωπίζουν προβλήματα όπως η αραιότητα των δεδομένων και η ψυχρή εκκίνηση νέων χρηστών ή αντικειμένων. Ο συνδυασμός αυτών των προσεγγίσεων επιτρέπει τη δημιουργία πιο ολοκληρωμένων μοντέλων προτίμησης, τα οποία αξιοποιούν τόσο τα χαρακτηριστικά των αντικειμένων όσο και τις συλλογικές συμπεριφορές των χρηστών (Adomavicius & Tuzhilin, 2005; Li et al., 2023).

Η υλοποίηση ενός υβριδικού συστήματος μπορεί να πραγματοποιηθεί με διάφορους τρόπους, ανάλογα με τις απαιτήσεις της εφαρμογής και τα διαθέσιμα δεδομένα. Μία συνηθισμένη προσέγγιση είναι ο συνδυασμός των αποτελεσμάτων που παράγονται από διαφορετικούς αλγόριθμους, όπου οι επιμέρους προτάσεις συγχωνεύονται και κατατάσσονται με βάση συγκεκριμένα κριτήρια. Μια άλλη προσέγγιση περιλαμβάνει την ενσωμάτωση χαρακτηριστικών περιεχομένου σε συνεργατικά μοντέλα ή αντίστροφα, δημιουργώντας ενιαία μοντέλα που αξιοποιούν ταυτόχρονα πολλαπλές πηγές πληροφορίας. Η ευελιξία αυτή καθιστά τα υβριδικά συστήματα ιδιαίτερα προσαρμοστικά σε διαφορετικά περιβάλλοντα και εφαρμογές, από ηλεκτρονικά καταστήματα και υπηρεσίες ψυχαγωγίας έως εκπαιδευτικές και επαγγελματικές πλατφόρμες (Li et al., 2023).

Η ανάγκη ανάπτυξης υβριδικών προσεγγίσεων έγινε ιδιαίτερα εμφανής με την εξάπλωση των διαδικτυακών υπηρεσιών μεγάλης κλίμακας. Οι σύγχρονες πλατφόρμες καλούνται να διαχειριστούν τεράστιους όγκους δεδομένων, διαφορετικούς τύπους περιεχομένου και

εκατομμύρια χρήστες με ετερογενείς προτιμήσεις. Σε αυτό το πλαίσιο, η αξιοποίηση μίας μόνο τεχνικής συχνά δεν επαρκεί για την παροχή ποιοτικών προτάσεων. Τα υβριδικά συστήματα προσφέρουν τη δυνατότητα συνδυασμού πληροφοριών από πολλαπλές πηγές, επιτρέποντας τη δημιουργία πιο ακριβών μοντέλων χρηστών και την παραγωγή προτάσεων υψηλότερης ποιότητας. Η προσέγγιση αυτή θεωρείται σήμερα μία από τις πιο αποτελεσματικές στρατηγικές στον σχεδιασμό συστημάτων συστάσεων (Zhou et al., 2023). Σημαντικό πλεονέκτημα των υβριδικών συστημάτων αποτελεί η αποτελεσματικότερη αντιμετώπιση του προβλήματος της ψυχρής εκκίνησης. Στα συνεργατικά συστήματα, η απουσία ιστορικών δεδομένων καθιστά δύσκολη τη δημιουργία αξιόπιστων προτάσεων για νέους χρήστες ή νέα αντικείμενα. Παρόλα αυτά, όταν συνδυάζονται δεδομένα περιεχομένου με συνεργατικά πρότυπα, το σύστημα μπορεί να αξιοποιήσει τα διαθέσιμα χαρακτηριστικά των αντικειμένων ή τις αρχικές προτιμήσεις των χρηστών για να δημιουργήσει ικανοποιητικές συστάσεις ακόμη και σε συνθήκες περιορισμένης πληροφορίας. Η δυνατότητα αυτή βελτιώνει σημαντικά τη λειτουργικότητα και την αποτελεσματικότητα του συστήματος κατά τα πρώτα στάδια χρήσης του (Adomavicius & Tuzhilin, 2005).

Ταυτοχρόνως, τα υβριδικά συστήματα συμβάλλουν στη μείωση του προβλήματος της υπερεξειδίκευσης που συναντάται συχνά στις content-based προσεγγίσεις. Ενώ τα συστήματα βασισμένα αποκλειστικά στο περιεχόμενο τείνουν να προτείνουν αντικείμενα παρόμοια με εκείνα που έχει ήδη επιλέξει ο χρήστης, η ενσωμάτωση συνεργατικών πληροφοριών επιτρέπει την ανακάλυψη νέων και ενδεχομένως απρόβλεπτων επιλογών. Ως αποτέλεσμα, οι προτάσεις γίνονται πιο ποικίλες και ενδιαφέρουσες, ενισχύοντας τη συνολική εμπειρία του χρήστη και αποτρέποντας τη δημιουργία περιορισμένων «φούσκων πληροφορίας» (Jannach et al., 2023). Η ανάπτυξη των τεχνικών παραγοντοποίησης πινάκων και λανθανόντων παραγόντων συνέβαλε καθοριστικά στην εξέλιξη των υβριδικών συστημάτων. Μέσω αυτών των τεχνικών κατέστη δυνατός ο συνδυασμός πληροφοριών προερχόμενων από διαφορετικές πηγές σε ενιαία μαθηματικά μοντέλα. Οι μέθοδοι παραγοντοποίησης επιτρέπουν την ανακάλυψη κρυφών σχέσεων μεταξύ χρηστών και αντικειμένων, ενώ ταυτόχρονα μπορούν να ενσωματώνουν χαρακτηριστικά περιεχομένου, κοινωνικές πληροφορίες ή άλλα συμφραζόμενα δεδομένα. Η προσέγγιση αυτή έχει οδηγήσει σε σημαντική βελτίωση της ακρίβειας των συστάσεων και αποτελεί βασικό στοιχείο πολλών σύγχρονων υβριδικών εφαρμογών (Koren et al., 2009). Η ενσωμάτωση της βαθιάς μάθησης έχει προσδώσει νέα δυναμική στα υβριδικά συστήματα συστάσεων. Τα νευρωνικά δίκτυα είναι σε θέση να επεξεργάζονται ταυτόχρονα δεδομένα διαφορετικών μορφών, όπως κείμενο, εικόνες, μεταδεδομένα και ιστορικά αλληλεπιδράσεων, δημιουργώντας σύνθετες και υψηλού επιπέδου αναπαραστάσεις των χρηστών και των

αντικειμένων. Η δυνατότητα αυτή επιτρέπει τη βαθύτερη κατανόηση των προτιμήσεων των χρηστών και τη δημιουργία περισσότερο εξατομικευμένων προτάσεων. Σύμφωνα με τη σύγχρονη βιβλιογραφία, η βαθιά μάθηση έχει αναδειχθεί σε βασικό πυλώνα ανάπτυξης των υβριδικών συστημάτων, προσφέροντας σημαντικές βελτιώσεις τόσο στην ακρίβεια όσο και στην προσαρμοστικότητα των μοντέλων (Zhang et al., 2019; Zhou et al., 2023).

Χαρακτηριστικό παράδειγμα αυτής της εξέλιξης αποτελεί η αρχιτεκτονική Wide & Deep, η οποία συνδυάζει γραμμικά μοντέλα με βαθιά νευρωνικά δίκτυα. Το γραμμικό τμήμα του μοντέλου επιτρέπει την απομνημόνευση γνωστών σχέσεων μεταξύ χρηστών και αντικειμένων, ενώ το βαθύ τμήμα αναλαμβάνει τη γενίκευση και την ανακάλυψη νέων συσχετίσεων. Η συνδυαστική αυτή λειτουργία προσφέρει υψηλότερη ακρίβεια και καλύτερη δυνατότητα προσαρμογής σε νέα δεδομένα, αποτελώντας χαρακτηριστικό παράδειγμα υβριδικής προσέγγισης που αξιοποιεί διαφορετικές τεχνικές μάθησης σε ένα ενιαίο πλαίσιο (Cheng et al., 2016). Παρόμοια φιλοσοφία ακολουθείται και στα σύγχρονα συστήματα προτάσεων βίντεο και ψηφιακού περιεχομένου μεγάλης κλίμακας. Στην περίπτωση του YouTube, για παράδειγμα, τα νευρωνικά δίκτυα συνδυάζουν πληροφορίες σχετικά με τα χαρακτηριστικά του περιεχομένου, το ιστορικό προβολών, τις προηγούμενες αλληλεπιδράσεις και πλήθος επιπλέον παραμέτρων, δημιουργώντας ένα εξαιρετικά πολύπλοκο υβριδικό μοντέλο συστάσεων. Η επιτυχία αυτών των εφαρμογών αποδεικνύει ότι η αξιοποίηση πολλαπλών πηγών δεδομένων μπορεί να οδηγήσει σε σημαντική βελτίωση της ποιότητας των προτάσεων και της ικανοποίησης των χρηστών (Covington et al., 2016).

Η εξέλιξη των υβριδικών συστημάτων συνδέεται επίσης με την ανάπτυξη νευρωνικών συνεργατικών μοντέλων. Τα μοντέλα αυτά αξιοποιούν τόσο τις παραδοσιακές πληροφορίες αλληλεπίδρασης όσο και πρόσθετα χαρακτηριστικά περιεχομένου, επιτρέποντας τη δημιουργία πλουσιότερων αναπαραστάσεων των χρηστών και των αντικειμένων. Μέσω της βαθιάς μάθησης, οι σύνθετες σχέσεις μεταξύ διαφορετικών πηγών δεδομένων μπορούν να μοντελοποιηθούν αποτελεσματικότερα από ό,τι στις κλασικές μεθόδους, οδηγώντας σε βελτιωμένη απόδοση και μεγαλύτερη ευελιξία (He et al., 2017). Είναι επίσης σημαντικό να σημειωθεί πως, οι τεχνικές ενισχυτικής μάθησης έχουν αρχίσει να ενσωματώνονται στα υβριδικά συστήματα, επιτρέποντας τη συνεχή προσαρμογή των προτάσεων με βάση τη συμπεριφορά των χρηστών σε πραγματικό χρόνο. Σε αυτές τις περιπτώσεις, το σύστημα δεν βασίζεται μόνο σε ιστορικά δεδομένα αλλά μαθαίνει διαρκώς από τις αλληλεπιδράσεις του χρήστη, επιδιώκοντας τη μεγιστοποίηση της μακροχρόνιας ικανοποίησής του. Η προσέγγιση αυτή θεωρείται ιδιαίτερα σημαντική για εφαρμογές όπου οι προτιμήσεις μεταβάλλονται συχνά και η δυναμική προσαρμογή των προτάσεων αποτελεί κρίσιμο παράγοντα επιτυχίας (Chen et al., 2021).

Ένα ακόμη σημαντικό χαρακτηριστικό των σύγχρονων υβριδικών συστημάτων είναι η έμφαση που δίνεται στην ερμηνευσιμότητα και στην εμπιστοσύνη των χρηστών. Καθώς τα μοντέλα γίνονται ολοένα πιο πολύπλοκα, η δυνατότητα κατανόησης της διαδικασίας λήψης αποφάσεων αποκτά ιδιαίτερη σημασία. Η παροχή επεξηγήσεων σχετικά με τους λόγους που οδήγησαν σε μία πρόταση συμβάλλει στην αύξηση της διαφάνειας και της αποδοχής των συστάσεων. Παράλληλα, η ενίσχυση της εμπιστοσύνης θεωρείται κρίσιμος παράγοντας για τη μακροχρόνια επιτυχία ενός συστήματος συστάσεων, ιδιαίτερα σε περιβάλλοντα όπου οι αποφάσεις των χρηστών επηρεάζονται σημαντικά από τις παρεχόμενες προτάσεις (Zhang & Chen, 2020; Akdim et al., 2025).

Η σύγχρονη έρευνα προσανατολίζεται επίσης προς την ανάπτυξη πολυστοχικών υβριδικών συστημάτων, τα οποία επιδιώκουν την ταυτόχρονη βελτιστοποίηση πολλαπλών παραμέτρων, όπως η ακρίβεια, η ποικιλία, η καινοτομία, η δικαιοσύνη και η ικανοποίηση των χρηστών. Η προσέγγιση αυτή αντανακλά την αυξανόμενη πολυπλοκότητα των απαιτήσεων των σύγχρονων ψηφιακών οικοσυστημάτων και αναδεικνύει τον πολυδιάστατο χαρακτήρα της διαδικασίας σύστασης (Jannach et al., 2023).

4.4 Εξατομίκευση και προσαρμοστικότητα προτάσεων

Η εξατομίκευση αποτελεί μία από τις σημαντικότερες λειτουργίες των σύγχρονων συστημάτων συστάσεων και συνιστά βασικό παράγοντα της επιτυχίας τους σε ένα περιβάλλον όπου ο όγκος της διαθέσιμης πληροφορίας αυξάνεται συνεχώς. Στόχος της εξατομίκευσης είναι η προσαρμογή των παρεχόμενων προτάσεων στις ιδιαίτερες ανάγκες, προτιμήσεις, συμπεριφορές και ενδιαφέροντα κάθε χρήστη, με τρόπο που να μεγιστοποιεί τη χρησιμότητα και τη συνάφεια των προτεινόμενων αντικειμένων. Η δυνατότητα αυτή διαφοροποιεί τα συστήματα συστάσεων από τις παραδοσιακές μεθόδους αναζήτησης και ανάκτησης πληροφορίας, καθώς επιτρέπει την ενεργητική παροχή περιεχομένου προσαρμοσμένου στις ανάγκες του εκάστοτε ατόμου χωρίς να απαιτείται η συνεχής διατύπωση ερωτημάτων από τον χρήστη (Adomavicius & Tuzhilin, 2005).

Η έννοια της εξατομίκευσης συνδέεται στενά με τη δυνατότητα των ευφύων συστημάτων να αναγνωρίζουν πρότυπα συμπεριφοράς και να μαθαίνουν από τις αλληλεπιδράσεις των χρηστών. Μέσω της ανάλυσης δεδομένων όπως οι αξιολογήσεις, οι αγορές, οι προβολές, οι αναζητήσεις και ο χρόνος αλληλεπίδρασης με συγκεκριμένα αντικείμενα, τα συστήματα δημιουργούν δυναμικά προφίλ χρηστών τα οποία αποτυπώνουν τις προτιμήσεις και τα ενδιαφέροντά τους. Τα προφίλ αυτά αποτελούν τη βάση για τη λήψη αποφάσεων σχετικά με το ποιο περιεχόμενο θα προταθεί σε κάθε χρήστη, επιτρέποντας την παροχή εξατομικευμένων εμπειριών που ανταποκρίνονται στις ιδιαίτερες ανάγκες του (Li et al., 2023). Η προσαρμοστικότητα των

προτάσεων αναφέρεται στην ικανότητα του συστήματος να αναθεωρεί και να ενημερώνει συνεχώς τα μοντέλα χρηστών με βάση νέα δεδομένα και μεταβαλλόμενες συνθήκες. Οι προτιμήσεις των ανθρώπων δεν παραμένουν σταθερές αλλά μεταβάλλονται με την πάροδο του χρόνου, επηρεαζόμενες από προσωπικούς, κοινωνικούς και περιβαλλοντικούς παράγοντες. Ένα αποτελεσματικό σύστημα συστάσεων οφείλει να αναγνωρίζει αυτές τις μεταβολές και να προσαρμόζει ανάλογα τις προτάσεις του, ώστε να διατηρεί υψηλό επίπεδο συνάφειας και χρησιμότητας. Η ανάγκη ενσωμάτωσης χρονικών δυναμικών στις διαδικασίες σύστασης έχει αναγνωριστεί ως ιδιαίτερα σημαντική για τη βελτίωση της απόδοσης των συστημάτων σε πραγματικές συνθήκες λειτουργίας (Koren, 2010).

Η εφαρμογή ευφυών τεχνικών έχει διαδραματίσει καθοριστικό ρόλο στην ανάπτυξη προηγμένων μηχανισμών εξατομίκευσης. Οι αλγόριθμοι μηχανικής μάθησης είναι σε θέση να αναλύουν μεγάλες ποσότητες δεδομένων και να ανακαλύπτουν σύνθετες σχέσεις μεταξύ χρηστών και αντικειμένων, οι οποίες δεν είναι άμεσα ορατές μέσω παραδοσιακών στατιστικών μεθόδων. Μέσα από επαναλαμβανόμενες διαδικασίες μάθησης, τα συστήματα βελτιώνουν συνεχώς την κατανόηση των προτιμήσεων των χρηστών και παράγουν ολοένα πιο ακριβείς και εξατομικευμένες συστάσεις. Η δυνατότητα αυτή αποτελεί ένα από τα σημαντικότερα χαρακτηριστικά των σύγχρονων ευφυών συστημάτων συστάσεων (Zhang et al., 2019). Η έννοια της εξατομίκευσης δεν περιορίζεται μόνο στην ανάλυση ιστορικών δεδομένων, αλλά επεκτείνεται και στη διαχείριση συμφραζομένων πληροφοριών που περιγράφουν το περιβάλλον χρήσης. Παράγοντες όπως η χρονική στιγμή, η τοποθεσία, η συσκευή πρόσβασης ή ακόμη και η τρέχουσα δραστηριότητα του χρήστη μπορούν να επηρεάσουν σημαντικά τις προτιμήσεις του. Η αξιοποίηση τέτοιων δεδομένων επιτρέπει τη δημιουργία περισσότερο ευέλικτων και προσαρμοστικών συστημάτων που ανταποκρίνονται αποτελεσματικότερα στις πραγματικές συνθήκες χρήσης. Η τάση αυτή έχει ενισχυθεί σημαντικά τα τελευταία χρόνια λόγω της ευρείας διάδοσης κινητών συσκευών και εφαρμογών που παράγουν συνεχώς δεδομένα συμφραζομένων (Li et al., 2023).

Η σημασία της εξατομίκευσης γίνεται ιδιαίτερα εμφανής σε περιβάλλοντα ηλεκτρονικού εμπορίου και ψηφιακού περιεχομένου. Οι χρήστες αναμένουν πλέον από τις πλατφόρμες να κατανοούν τις ανάγκες τους και να τους προτείνουν προϊόντα, υπηρεσίες ή πληροφορίες που ανταποκρίνονται στα ενδιαφέροντά τους. Η δυνατότητα παροχής προσωποποιημένων εμπειριών συμβάλλει στην αύξηση της ικανοποίησης των χρηστών, στη βελτίωση της εμπλοκής τους με την πλατφόρμα και στην ενίσχυση της πιστότητας προς την υπηρεσία. Για τον λόγο αυτό, η εξατομίκευση έχει εξελιχθεί σε βασικό στρατηγικό στόχο για τις περισσότερες ψηφιακές επιχειρήσεις και οργανισμούς (Adomavicius & Tuzhilin, 2005). Η ανάπτυξη των τεχνικών βαθιάς

μάθησης έχει ενισχύσει σημαντικά τις δυνατότητες εξατομίκευσης των συστημάτων συστάσεων. Τα βαθιά νευρωνικά δίκτυα είναι σε θέση να επεξεργάζονται δεδομένα υψηλής πολυπλοκότητας και να δημιουργούν πολυδιάστατες αναπαραστάσεις των χρηστών και των αντικειμένων. Σε αντίθεση με τις παραδοσιακές μεθόδους που βασίζονται σε χειροκίνητα καθορισμένα χαρακτηριστικά, τα μοντέλα βαθιάς μάθησης μαθαίνουν αυτόματα τις πιο σημαντικές αναπαραστάσεις από τα δεδομένα, επιτρέποντας την αναγνώριση πολύπλοκων και μη γραμμικών σχέσεων. Ως αποτέλεσμα, τα συστήματα αποκτούν τη δυνατότητα να παρέχουν περισσότερο ακριβείς και εξατομικευμένες προτάσεις ακόμη και σε ιδιαίτερα σύνθετα περιβάλλοντα δεδομένων (Zhang et al., 2019; Zhou et al., 2023).

Η εφαρμογή βαθιών νευρωνικών δικτύων σε πλατφόρμες μεγάλης κλίμακας έχει αποδείξει την αποτελεσματικότητα αυτής της προσέγγισης. Συστήματα όπως εκείνα που χρησιμοποιούνται για την προώθηση βίντεο, προϊόντων ή ψηφιακού περιεχομένου αξιοποιούν πολύπλοκες αρχιτεκτονικές οι οποίες συνδυάζουν ιστορικά δεδομένα χρήσης, χαρακτηριστικά περιεχομένου και πληροφορίες συμφραζομένων για τη δημιουργία εξατομικευμένων εμπειριών σε πραγματικό χρόνο. Η δυνατότητα συνεχούς ενημέρωσης των μοντέλων και επεξεργασίας τεράστιων ποσοτήτων δεδομένων επιτρέπει την παροχή προτάσεων υψηλής ποιότητας ακόμη και σε περιβάλλοντα με εκατομμύρια χρήστες (Covington et al., 2016). Σημαντική συμβολή στην ενίσχυση της προσαρμοστικότητας των συστημάτων συστάσεων έχει επίσης η αρχιτεκτονική Wide & Deep. Η συγκεκριμένη προσέγγιση συνδυάζει την αποθήκευση γνωστών προτύπων συμπεριφοράς με την ικανότητα γενίκευσης και ανακάλυψης νέων σχέσεων. Με τον τρόπο αυτό, το σύστημα μπορεί να αξιοποιεί τόσο την υπάρχουσα γνώση όσο και νέα δεδομένα που προκύπτουν από τις αλληλεπιδράσεις των χρηστών, βελτιώνοντας συνεχώς την ποιότητα των προτάσεων και την προσαρμοστικότητά τους σε μεταβαλλόμενα περιβάλλοντα (Cheng et al., 2016).

Η εξέλιξη της εξατομίκευσης συνδέεται επίσης με την ανάπτυξη νευρωνικών συνεργατικών μοντέλων, τα οποία αξιοποιούν πολύπλοκες αλληλεπιδράσεις μεταξύ χρηστών και αντικειμένων. Μέσω της χρήσης βαθιών νευρωνικών δικτύων, τα μοντέλα αυτά μπορούν να αναπαριστούν με μεγαλύτερη ακρίβεια τις προτιμήσεις των χρηστών και να προσαρμόζουν δυναμικά τις συστάσεις τους καθώς προκύπτουν νέες πληροφορίες. Η προσέγγιση αυτή έχει αποδειχθεί ιδιαίτερα αποτελεσματική σε περιβάλλοντα όπου οι προτιμήσεις των χρηστών μεταβάλλονται συχνά και η ανάγκη για εξατομικευμένες προτάσεις είναι ιδιαίτερα έντονη (He et al., 2017). Επιπρόσθετα, οι τεχνικές ενισχυτικής μάθησης έχουν δημιουργήσει νέες δυνατότητες όσον αφορά τη δυναμική προσαρμογή των προτάσεων. Σε αντίθεση με τα παραδοσιακά μοντέλα που βασίζονται κυρίως σε ιστορικά δεδομένα, η ενισχυτική μάθηση επιτρέπει στο σύστημα να μαθαίνει μέσα από τη

συνεχή αλληλεπίδραση με τον χρήστη. Οι προτάσεις αντιμετωπίζονται ως διαδοχικές αποφάσεις και το σύστημα επιδιώκει να μεγιστοποιήσει τη μακροχρόνια ικανοποίηση του χρήστη μέσω συνεχούς ανατροφοδότησης. Η δυνατότητα αυτή θεωρείται ιδιαίτερα σημαντική για εφαρμογές όπου οι ανάγκες και οι προτιμήσεις μεταβάλλονται διαρκώς, όπως οι υπηρεσίες ψυχαγωγίας, τα κοινωνικά δίκτυα και οι πλατφόρμες ηλεκτρονικού εμπορίου (Chen et al., 2021).


Η εξατομίκευση συνδέεται άμεσα και με το ζήτημα της εμπιστοσύνης των χρηστών προς τα συστήματα συστάσεων. Όσο πιο αποτελεσματικά και συνεπή είναι τα συστήματα στην παροχή σχετικών προτάσεων, τόσο μεγαλύτερη είναι η πιθανότητα οι χρήστες να τα εμπιστευθούν και να ακολουθήσουν τις συστάσεις τους. Η εμπιστοσύνη αποτελεί κρίσιμο παράγοντα για τη διατήρηση της μακροχρόνιας χρήσης μιας πλατφόρμας, καθώς επηρεάζει τόσο την αποδοχή των προτάσεων όσο και τη συνολική εμπειρία του χρήστη. Σύμφωνα με τη σύγχρονη βιβλιογραφία, η καλλιέργεια εμπιστοσύνης θεωρείται πλέον αναπόσπαστο στοιχείο του σχεδιασμού των συστημάτων εξατομίκευσης (Akdim et al., 2025). Ταυτόχρονα, η ανάγκη για διαφάνεια και επεξηγησιμότητα έχει αποκτήσει ιδιαίτερη σημασία. Οι χρήστες δεν ενδιαφέρονται μόνο για την ακρίβεια των προτάσεων αλλά και για την κατανόηση των λόγων που οδήγησαν στην εμφάνισή τους. Τα επεξηγήσιμα συστήματα συστάσεων επιτρέπουν την παροχή σαφών αιτιολογήσεων σχετικά με τις προτάσεις, ενισχύοντας την κατανόηση, την αποδοχή και την εμπιστοσύνη των χρηστών. Η ερμηνευσιμότητα αποτελεί σήμερα βασική διάσταση της εξατομίκευσης και αναμένεται να διαδραματίσει ακόμη σημαντικότερο ρόλο στις μελλοντικές εφαρμογές της τεχνητής νοημοσύνης (Zhang & Chen, 2020).

Εκτός την πρόοδο που έχει επιτευχθεί, η εξατομίκευση συνοδεύεται από αξιοσημείωτες δυσκολίες. Η διατήρηση της ισορροπίας μεταξύ ακρίβειας και ποικιλίας παραμένει ένα από τα βασικά ζητήματα, καθώς η υπερβολική εστίαση στις προηγούμενες προτιμήσεις μπορεί να περιορίσει την έκθεση των χρηστών σε νέο περιεχόμενο. Εκτός αυτού, η ανάγκη ταυτόχρονης βελτιστοποίησης πολλαπλών στόχων, όπως η ακρίβεια, η καινοτομία, η ποικιλία, η δικαιοσύνη και η ικανοποίηση των χρηστών, καθιστά τη διαδικασία σύστασης ιδιαίτερα σύνθετη. Για τον λόγο αυτό, η ανάπτυξη πολυστοχικών συστημάτων συστάσεων αποτελεί μία από τις σημαντικότερες σύγχρονες ερευνητικές κατευθύνσεις (Jannach et al., 2023).

4.5 Αρχιτεκτονική και ροή ενός συστήματος συστάσεων

Η πρακτική υλοποίηση ενός συστήματος συστάσεων οργανώνεται τυπικά σε δύο φάσεις: τη φάση εκτός σύνδεσης (offline), όπου εκπαιδεύεται το μοντέλο πάνω στα ιστορικά δεδομένα αλληλεπίδρασης, και τη φάση σε σύνδεση (online), όπου παράγονται σε πραγματικό χρόνο οι εξατομικευμένες προτάσεις για κάθε χρήστη. Ο διαχωρισμός αυτός είναι κρίσιμος για την

κλιμάκωση, καθώς οι υπολογιστικά δαπανηρές διαδικασίες (εκπαίδευση, υπολογισμός ομοιοτήτων) εκτελούνται offline, ενώ η online φάση περιορίζεται στην ταχεία κατάταξη και επιλογή Top-N. Το Σχήμα 4.1 αποτυπώνει τη συνολική ροή δεδομένων.



Σχήμα 4.1: Αρχιτεκτονική και ροή δεδομένων ενός συστήματος συστάσεων (offline εκπαίδευση – online σύσταση – αξιολόγηση).

4.6 Αλγόριθμος παραγωγής Top-N συστάσεων (συνεργατικό φιλτράρισμα)

Ο παρακάτω αλγόριθμος περιγράφει τον πλήρη αγωγό παραγωγής των N κορυφαίων συστάσεων για έναν χρήστη με χρήση user-based συνεργατικού φιλτραρίσματος. Συνδυάζει τον υπολογισμό ομοιοτήτων, την επιλογή γειτονιάς, την πρόβλεψη βαθμολογιών και την τελική κατάταξη.

Αλγόριθμος 4.1: Παραγωγή Top-N συστάσεων (user-based CF)

```


Είσοδος: πίνακας  $R$ , χρήστης-στόχος  $u$ , μέγεθος γειτονιάς  $k$ , πλήθος  $N$ 
Έξοδος: λίστα  $L$  των  $N$  συνιστώμενων αντικειμένων
1: για κάθε χρήστη  $v \neq u$  με κοινά αντικείμενα με τον  $u$ :
2:    $\text{sim}[v] \leftarrow \text{Pearson}(u, v)$ 
3:  $N(u) \leftarrow$  οι  $k$  χρήστες με τη μεγαλύτερη  $\text{sim}[v] > 0$ 
4: υποψήφια  $\leftarrow \{ i : i \text{ αξιολογήθηκε από κάποιον } v \in N(u) \text{ και } i \notin I_u \}$ 
5: για κάθε  $i \in$  υποψήφια:
6:    $r_{ui} \leftarrow r_u + ( \sum_{v \in N(u)} \text{sim}[v] \cdot (r_{vi} - r_v) ) / ( \sum_{v \in N(u)} |\text{sim}[v]| )$ 
7: ταξινόμησε τα  $i$  κατά φθίνον  $r_{ui}$ 
8:  $L \leftarrow$  τα πρώτα  $N$  αντικείμενα
9: επίστρεψε  $L$ 

```

Το βήμα ταξινόμησης (γραμμή 7) έχει πολυπλοκότητα $O(|\text{υποψήφια}| \cdot \log |\text{υποψήφια}|)$, ενώ ο υπολογισμός των ομοιοτήτων κυριαρχεί στο συνολικό κόστος και προϋπολογίζεται offline.

4.7 Υβριδικός αλγόριθμος και αντιμετώπιση ψυχρής εκκίνησης

Το βασικότερο πρακτικό πρόβλημα των συστημάτων συστάσεων είναι η ψυχρή εκκίνηση (cold-start): για νέους χρήστες ή νέα προϊόντα δεν υπάρχουν επαρκή δεδομένα αλληλεπίδρασης ώστε το συνεργατικό φιλτράρισμα να λειτουργήσει αξιόπιστα. Η υβριδική προσέγγιση αντιμετωπίζει το πρόβλημα συνδυάζοντας δυναμικά το συνεργατικό φιλτράρισμα με το φιλτράρισμα βάσει περιεχομένου, όπως φαίνεται στο Σχήμα 4.2.



Σχήμα 4.2: Λογική απόφασης υβριδικού συστήματος με μεταγωγή (switching) για την αντιμετώπιση της ψυχρής εκκίνησης.

Ο αντίστοιχος αλγόριθμος υλοποιεί τη σταθμισμένη υβριδική στρατηγική με προσαρμογή στο πλαίσιο του χρήστη και του αντικειμένου:

Αλγόριθμος 4.2: Υβριδική πρόβλεψη με μεταγωγή

Είσοδος: χρήστης u , αντικείμενο i , βάρος $\alpha \in [0,1]$, κατώφλια θ_u, θ_i
 Έξοδος: προβλεπόμενη βαθμολογία $\hat{r}_{ui}$

```

1: αν  $|I_u| < \theta_u$ : // νέος χρήστης
2:   επίστρεψε  $\hat{r}_{CB}(u, i)$  // content-based
3: αν  $|U_i| < \theta_i$ : // αραιό/νέο αντικείμενο
4:   επίστρεψε  $\hat{r}_{CB}(u, i)$ 
5:  $\hat{r}_{CF} \leftarrow \text{CollaborativeFiltering}(u, i)$ 
6:  $\hat{r}_{CB} \leftarrow \text{ContentBased}(u, i)$ 
7:  $\hat{r}_{ui} \leftarrow \alpha \cdot \hat{r}_{CF} + (1 - \alpha) \cdot \hat{r}_{CB}$ 
8: επίστρεψε  $\hat{r}_{ui}$ 
  
```

Το βάρος α ρυθμίζεται πειραματικά (π.χ. με αναζήτηση πλέγματος στο σύνολο επικύρωσης) ώστε να μεγιστοποιείται μια μετρική κατάταξης όπως το $NDCG@k$. Η στρατηγική αυτή αποτελεί καθιερωμένη πρακτική στα σύγχρονα υβριδικά συστήματα συστάσεων.

4.8 Υπολογιστική πολυπλοκότητα και κλιμάκωση

Ο παρακάτω πίνακας συνοψίζει την υπολογιστική πολυπλοκότητα των κυριότερων μεθόδων, όπου m το πλήθος χρηστών, n το πλήθος αντικειμένων, k η διάσταση των λανθανόντων παραγόντων και $|K|$ το πλήθος των γνωστών βαθμολογιών.

Μέθοδος	Εκπαίδευση (offline)	Πρόβλεψη (online)
User-based kNN	$O(m^2 \cdot n)$	$O(m \cdot n)$
Item-based kNN	$O(n^2 \cdot m)$	$O(k_{\text{geit}})$
Matrix Factorization (SGD)	$O(K \cdot k \cdot T)$	$O(k)$
Content-based	$O(n \cdot d)$	$O(d)$
Υβριδικό (weighted)	άθροισμα επιμέρους	$O(k + d)$

Πίνακας 4.3: Υπολογιστική πολυπλοκότητα μεθόδων σύστασης

Είναι εμφανές ότι η παραγοντοποίηση πινάκων προσφέρει το καλύτερο προφίλ κλιμάκωσης στην online φάση (σταθερός χρόνος $O(k)$ ανά πρόβλεψη), γεγονός που εξηγεί την ευρεία υιοθέτησή της σε συστήματα παραγωγής μεγάλης κλίμακας.

4.9 Βιβλιογραφική αποτίμηση

Η αρχιτεκτονική offline/online και οι αλγόριθμοι που παρουσιάστηκαν βασίζονται στις καθιερωμένες υλοποιήσεις item-based φιλτραρίσματος των Sarwar et al. (2001) και Linden et al. (2003), οι οποίοι περιέγραψαν το σύστημα του Amazon. Οι υβριδικές στρατηγικές αντλούν από την ταξινομία του Burke για τα υβριδικά συστήματα, ενώ η αντιμετώπιση της ψυχρής εκκίνησης αποτελεί διαρκές αντικείμενο έρευνας (Adomavicius & Tuzhilin, 2005). Η ανάλυση πολυπλοκότητας επιβεβαιώνει τη θεωρητική υπεροχή των μεθόδων μοντέλου έναντι των μεθόδων μνήμης σε περιβάλλοντα μεγάλης κλίμακας.

ΚΕΦΑΛΑΙΟ 5: Αξιολόγηση και Σύγκριση Ευφύων Προσεγγίσεων

5.1 Κριτήρια αξιολόγησης αποτελεσματικότητας

Η αξιολόγηση της αποτελεσματικότητας των συστημάτων συστάσεων αποτελεί μία από τις σημαντικότερες διαδικασίες στον σχεδιασμό και την ανάπτυξή τους, καθώς επιτρέπει την εκτίμηση της ποιότητας των παραγόμενων προτάσεων και τη σύγκριση διαφορετικών μεθοδολογικών προσεγγίσεων. Καθώς τα συστήματα συστάσεων έχουν εξελιχθεί σε βασικό εργαλείο διαχείρισης πληροφορίας και εξατομίκευσης σε ψηφιακά περιβάλλοντα, η ανάγκη για αξιόπιστες και ολοκληρωμένες μεθόδους αξιολόγησης έχει αποκτήσει ιδιαίτερη σημασία. Η αποτελεσματικότητα ενός συστήματος δεν περιορίζεται μόνο στην ακρίβεια των προβλέψεων που παράγει, αλλά περιλαμβάνει ένα ευρύτερο σύνολο παραγόντων που σχετίζονται με την εμπειρία του χρήστη, τη χρησιμότητα των προτάσεων, την αξιοπιστία του συστήματος και την επίτευξη των επιχειρησιακών στόχων της εφαρμογής (Adomavicius & Tuzhilin, 2005). Κατά τα πρώτα στάδια ανάπτυξης των συστημάτων συστάσεων, η αξιολόγηση επικεντρωνόταν κυρίως στη μέτρηση της ακρίβειας των προβλέψεων. Η βασική λογική ήταν ότι όσο πιο ακριβώς ένα σύστημα μπορεί να προβλέψει τις προτιμήσεις των χρηστών, τόσο καλύτερη θεωρείται η συνολική του απόδοση. Για τον λόγο αυτό, οι πρώτες ερευνητικές προσπάθειες εστίασαν στην ανάπτυξη μετρικών που συγκρίνουν τις πραγματικές αξιολογήσεις των χρηστών με τις προβλέψεις που παράγει το σύστημα. Η ακρίβεια παρέμεινε για πολλά χρόνια το κυρίαρχο κριτήριο αξιολόγησης, καθώς συνδέεται άμεσα με την ικανότητα ενός αλγορίθμου να μοντελοποιεί τις προτιμήσεις των χρηστών και να παρέχει σχετικές προτάσεις (Ekstrand et al., 2011).

Πάραυτα, η συνεχής εξέλιξη των συστημάτων συστάσεων κατέδειξε ότι η ακρίβεια από μόνη της δεν επαρκεί για την πλήρη αποτίμηση της ποιότητας ενός συστήματος. Ένα σύστημα μπορεί να παρουσιάζει υψηλή ακρίβεια στις προβλέψεις του, αλλά ταυτόχρονα να παράγει επαναλαμβανόμενες ή υπερβολικά προβλέψιμες προτάσεις που δεν προσφέρουν πραγματική αξία στον χρήστη. Ως αποτέλεσμα, η σύγχρονη έρευνα έχει διευρύνει σημαντικά το πλαίσιο αξιολόγησης, ενσωματώνοντας πρόσθετες διαστάσεις όπως η ποικιλία, η καινοτομία, η κάλυψη, η ερμηνευσιμότητα, η εμπιστοσύνη και η συνολική ικανοποίηση των χρηστών (Jannach et al., 2023). Η ακρίβεια εξακολουθεί να αποτελεί βασικό κριτήριο αξιολόγησης, καθώς αποτυπώνει τον βαθμό στον οποίο οι προτάσεις ανταποκρίνονται στις πραγματικές προτιμήσεις των χρηστών. Στα συστήματα που βασίζονται σε ρητές αξιολογήσεις, η ακρίβεια συχνά εκφράζεται μέσω της απόκλισης μεταξύ των προβλεπόμενων και των πραγματικών βαθμολογιών. Σε συστήματα που αξιοποιούν έμμεση ανατροφοδότηση, όπως κλικ ή αγορές, η αξιολόγηση επικεντρώνεται

περισσότερο στην ικανότητα του συστήματος να εντοπίζει τα αντικείμενα που παρουσιάζουν υψηλή πιθανότητα ενδιαφέροντος για τον χρήστη. Η βελτίωση της ακρίβειας παραμένει διαχρονικός στόχος των ερευνητών, καθώς συνδέεται άμεσα με τη χρηστικότητα και την αποδοχή των συστημάτων συστάσεων (Koren et al., 2009; Hu et al., 2008).

Ιδιαίτερη σημασία έχει επίσης η αξιολόγηση της ικανότητας κατάταξης των αντικειμένων. Στις περισσότερες πραγματικές εφαρμογές, ο χρήστης δεν ενδιαφέρεται για την ακριβή πρόβλεψη μιας βαθμολογίας αλλά για τη λήψη μιας λίστας με τις πιο σχετικές προτάσεις. Για τον λόγο αυτό, η ποιότητα της τελικής κατάταξης θεωρείται κρίσιμο στοιχείο της αξιολόγησης. Η ανάπτυξη αλγορίθμων που βελτιστοποιούν τη σειρά εμφάνισης των αντικειμένων αποτέλεσε σημαντική κατεύθυνση της έρευνας, ιδιαίτερα σε περιβάλλοντα όπου τα δεδομένα προέρχονται από έμμεσες αλληλεπιδράσεις και όχι από ρητές αξιολογήσεις (Rendle et al., 2009). Πέρα από την ακρίβεια, η ποικιλία των προτάσεων έχει αναδειχθεί σε σημαντικό κριτήριο αξιολόγησης. Ένα σύστημα που προτείνει συνεχώς παρόμοια αντικείμενα μπορεί να επιτυγχάνει υψηλή ακρίβεια, αλλά ενδέχεται να περιορίζει την εμπειρία του χρήστη και να μειώνει τις δυνατότητες ανακάλυψης νέου περιεχομένου. Η ποικιλία συμβάλλει στη διεύρυνση των επιλογών του χρήστη και στη μείωση του φαινομένου της υπερεξειδίκευσης που συχνά εμφανίζεται σε συστήματα βασισμένα αποκλειστικά σε προηγούμενες προτιμήσεις. Ως αποτέλεσμα, η ποικιλία θεωρείται πλέον αναπόσπαστο στοιχείο της συνολικής ποιότητας ενός συστήματος συστάσεων (Jannach et al., 2023).

Στενά συνδεδεμένη με την ποικιλία είναι και η έννοια της καινοτομίας ή ανακάλυψης νέου περιεχομένου. Η αποτελεσματικότητα ενός συστήματος δεν εξαρτάται μόνο από την ικανότητά του να προτείνει αντικείμενα που είναι ήδη γνωστά ή αναμενόμενα από τον χρήστη, αλλά και από την ικανότητά του να αναδεικνύει ενδιαφέρουσες επιλογές που διαφορετικά δεν θα ανακαλύπτονταν. Η διάσταση αυτή αποκτά ιδιαίτερη σημασία σε περιβάλλοντα με μεγάλο αριθμό διαθέσιμων αντικειμένων, όπου η ανακάλυψη νέου περιεχομένου αποτελεί βασικό στόχο των συστημάτων συστάσεων (Adomavicius & Tuzhilin, 2005). Ένα ακόμη σημαντικό κριτήριο αξιολόγησης είναι η κάλυψη του συστήματος. Η κάλυψη αναφέρεται στον βαθμό στον οποίο το σύστημα είναι σε θέση να παράγει προτάσεις για διαφορετικούς χρήστες και αντικείμενα. Ένα σύστημα μπορεί να εμφανίζει υψηλή ακρίβεια μόνο για συγκεκριμένες κατηγορίες χρηστών ή προϊόντων, αποτυγχάνοντας να εξυπηρετήσει αποτελεσματικά το σύνολο του πληθυσμού. Η δυνατότητα παροχής χρήσιμων προτάσεων σε ευρύ φάσμα περιπτώσεων θεωρείται κρίσιμη για την επιτυχή λειτουργία των συστημάτων συστάσεων σε πραγματικά περιβάλλοντα χρήσης (Ekstrand et al., 2011). Η αξιολόγηση της προσαρμοστικότητας αποτελεί επίσης βασικό στοιχείο της αποτελεσματικότητας των ευφυών προσεγγίσεων. Τα σύγχρονα

συστήματα λειτουργούν σε δυναμικά περιβάλλοντα όπου οι προτιμήσεις των χρηστών μεταβάλλονται συνεχώς. Επομένως, ένα αποτελεσματικό σύστημα πρέπει να είναι σε θέση να αναγνωρίζει και να ενσωματώνει αυτές τις αλλαγές, προσαρμόζοντας κατάλληλα τις προτάσεις του. Η δυνατότητα διαχείρισης χρονικών μεταβολών και εξελισσόμενων προτύπων συμπεριφοράς αποτελεί σημαντικό κριτήριο αξιολόγησης, ιδιαίτερα στις σύγχρονες εφαρμογές μεγάλης κλίμακας (Koren, 2010).

Η ανάπτυξη τεχνικών βαθιάς μάθησης έχει επηρεάσει σημαντικά και τις διαδικασίες αξιολόγησης. Τα νευρωνικά δίκτυα επιτυγχάνουν συχνά υψηλότερη ακρίβεια σε σχέση με τις παραδοσιακές μεθόδους, γεγονός που απαιτεί τη χρήση πιο σύνθετων πλαισίων αξιολόγησης που λαμβάνουν υπόψη πολλαπλές διαστάσεις απόδοσης. Η ικανότητα των μοντέλων βαθιάς μάθησης να επεξεργάζονται ετερογενή δεδομένα και να ανακαλύπτουν σύνθετες σχέσεις μεταξύ χρηστών και αντικειμένων έχει οδηγήσει σε σημαντικές βελτιώσεις στην ποιότητα των συστάσεων, αλλά ταυτόχρονα έχει αναδείξει νέες προκλήσεις όσον αφορά την ερμηνευσιμότητα και τη διαφάνεια των αποτελεσμάτων (Zhang et al., 2019; Zhou et al., 2023).

Η ερμηνευσιμότητα αποτελεί πλέον ένα από τα σημαντικότερα κριτήρια αξιολόγησης των συστημάτων συστάσεων. Οι χρήστες δεν ενδιαφέρονται μόνο για το αν μία πρόταση είναι σωστή, αλλά και για το πώς προέκυψε. Η δυνατότητα παροχής κατανοητών εξηγήσεων σχετικά με τους λόγους που οδήγησαν σε μία πρόταση ενισχύει την κατανόηση, τη διαφάνεια και την αποδοχή του συστήματος. Ως εκ τούτου, η αξιολόγηση των μηχανισμών επεξήγησης αποτελεί πλέον αναπόσπαστο μέρος της συνολικής αξιολόγησης των ευφυών συστημάτων συστάσεων (Zhang & Chen, 2020). Άμεσα συνδεδεμένη με την ερμηνευσιμότητα είναι και η έννοια της εμπιστοσύνης. Η εμπιστοσύνη αναφέρεται στον βαθμό στον οποίο οι χρήστες θεωρούν ότι οι προτάσεις που λαμβάνουν είναι αξιόπιστες, χρήσιμες και ευθυγραμμισμένες με τα συμφέροντά τους. Ένα σύστημα μπορεί να εμφανίζει υψηλή τεχνική απόδοση αλλά να αποτυγχάνει να κερδίσει την εμπιστοσύνη των χρηστών, περιορίζοντας έτσι την πραγματική του αποτελεσματικότητα. Η αξιολόγηση της εμπιστοσύνης έχει αναδειχθεί σε σημαντική ερευνητική κατεύθυνση, ιδιαίτερα καθώς τα συστήματα συστάσεων επηρεάζουν ολοένα και περισσότερο σημαντικές αποφάσεις των χρηστών (Akdin et al., 2025).

Επιπροσθέτως, η σύγχρονη έρευνα δίνει αυξημένη έμφαση στην αξιολόγηση της συνολικής εμπειρίας του χρήστη. Η αποτελεσματικότητα ενός συστήματος δεν μπορεί να αποτιμηθεί αποκλειστικά μέσω τεχνικών μετρικών αλλά απαιτεί και την εξέταση της αντίληψης των χρηστών σχετικά με τη χρησιμότητα, την ευχρηστία και την ικανοποίησή τους από τις παρεχόμενες προτάσεις. Οι παράγοντες αυτοί επηρεάζουν άμεσα τη μακροχρόνια χρήση μιας πλατφόρμας και

αποτελούν κρίσιμα στοιχεία για την επιτυχία των συστημάτων συστάσεων σε πραγματικά περιβάλλοντα λειτουργίας (Adomavicius & Tuzhilin, 2005). Η ανάγκη ταυτόχρονης βελτιστοποίησης πολλαπλών κριτηρίων έχει οδηγήσει στην ανάπτυξη πολυστοχικών προσεγγίσεων αξιολόγησης. Αντί να εξετάζεται μόνο μία διάσταση απόδοσης, όπως η ακρίβεια, τα σύγχρονα πλαίσια αξιολόγησης επιχειρούν να συνδυάσουν διαφορετικούς στόχους, συμπεριλαμβανομένων της ποικιλίας, της καινοτομίας, της δικαιοσύνης, της ερμηνευσιμότητας και της ικανοποίησης των χρηστών. Η προσέγγιση αυτή αντανακλά τη σύνθετη φύση των σύγχρονων συστημάτων συστάσεων και τις αυξανόμενες απαιτήσεις των χρηστών και των οργανισμών που τα αξιοποιούν (Jannach et al., 2023).

5.2 Μετρικές ποιότητας των συστάσεων

Η αξιολόγηση των συστημάτων συστάσεων βασίζεται σε ένα σύνολο μετρικών που επιτρέπουν τη μέτρηση της ποιότητας των παραγόμενων προτάσεων και την αντικειμενική σύγκριση διαφορετικών αλγοριθμικών προσεγγίσεων. Καθώς τα συστήματα συστάσεων έχουν εξελιχθεί σημαντικά τις τελευταίες δεκαετίες, η έννοια της ποιότητας έχει αποκτήσει πολυδιάστατο χαρακτήρα και δεν περιορίζεται αποκλειστικά στην ακρίβεια των προβλέψεων. Οι σύγχρονες εφαρμογές απαιτούν συστήματα που όχι μόνο προτείνουν σχετικά αντικείμενα αλλά ταυτόχρονα εξασφαλίζουν ποικιλία, καινοτομία, διαφάνεια, εμπιστοσύνη και υψηλό επίπεδο ικανοποίησης των χρηστών. Ως αποτέλεσμα, η αξιολόγηση των συστάσεων πραγματοποιείται μέσω ενός ευρύτερου συνόλου μετρικών που αποτυπώνουν διαφορετικές πτυχές της απόδοσης των συστημάτων (Adomavicius & Tuzhilin, 2005).

Οι πρώτες ερευνητικές προσπάθειες στον τομέα των συστημάτων συστάσεων επικεντρώθηκαν κυρίως στη μέτρηση της ακρίβειας των προβλέψεων. Η ακρίβεια θεωρήθηκε για μεγάλο χρονικό διάστημα το βασικότερο κριτήριο ποιότητας, καθώς αποτυπώνει τον βαθμό στον οποίο οι προτεινόμενες επιλογές ανταποκρίνονται στις πραγματικές προτιμήσεις των χρηστών. Στα συστήματα που βασίζονται σε ρητές αξιολογήσεις, η ποιότητα εκτιμάται μέσω της σύγκρισης μεταξύ των προβλεπόμενων και των πραγματικών βαθμολογιών. Όσο μικρότερη είναι η απόκλιση μεταξύ αυτών των τιμών, τόσο αποτελεσματικότερο θεωρείται το σύστημα. Η συγκεκριμένη προσέγγιση αποτέλεσε τη βάση για την αξιολόγηση των πρώτων συνεργατικών και content-based συστημάτων συστάσεων (Ekstrand et al., 2011). Η σημασία της ακρίβειας παραμένει ιδιαίτερα μεγάλη και στα σύγχρονα συστήματα. Οι τεχνικές παραγοντοποίησης πινάκων, οι οποίες αναδείχθηκαν ως μία από τις σημαντικότερες εξελίξεις στον χώρο των συστημάτων συστάσεων, αξιολογούνται συχνά με βάση την ικανότητά τους να βελτιώνουν την ακρίβεια των προβλέψεων. Μέσω της ανακάλυψης λανθανόντων παραγόντων που περιγράφουν

τις προτιμήσεις των χρηστών και τα χαρακτηριστικά των αντικειμένων, οι μέθοδοι αυτές επιτυγχάνουν σημαντική μείωση των σφαλμάτων πρόβλεψης και υψηλότερη ποιότητα συστάσεων σε σύγκριση με παλαιότερες τεχνικές συνεργατικού φιλτραρίσματος (Koren et al., 2009).

Θα πρέπει επίσης να σημειωθεί πως, η αξιοποίηση δεδομένων έμμεσης ανατροφοδότησης δημιούργησε την ανάγκη ανάπτυξης νέων μετρικών αξιολόγησης. Σε πολλές πραγματικές εφαρμογές οι χρήστες δεν παρέχουν άμεσες αξιολογήσεις αλλά αλληλεπιδρούν με τα αντικείμενα μέσω προβολών, αγορών, κλικ ή άλλων ενεργειών. Σε αυτές τις περιπτώσεις, η ποιότητα των συστάσεων αξιολογείται κυρίως μέσω της ικανότητας του συστήματος να αναγνωρίζει τα αντικείμενα που παρουσιάζουν μεγαλύτερη πιθανότητα ενδιαφέροντος για τον χρήστη. Η προσέγγιση αυτή απαιτεί διαφορετικές στρατηγικές αξιολόγησης σε σχέση με τα παραδοσιακά συστήματα που βασίζονται αποκλειστικά σε ρητές βαθμολογίες (Hu et al., 2008).

Ιδιαίτερη σημασία έχουν οι μετρικές που σχετίζονται με την ποιότητα της κατάταξης των προτεινόμενων αντικειμένων. Στην πράξη, οι χρήστες έρχονται συνήθως σε επαφή με μία περιορισμένη λίστα προτάσεων και όχι με το σύνολο των διαθέσιμων αντικειμένων. Για τον λόγο αυτό, η σωστή σειρά εμφάνισης των αντικειμένων αποτελεί κρίσιμο παράγοντα της συνολικής εμπειρίας. Οι μέθοδοι κατάταξης επιδιώκουν να τοποθετούν στις πρώτες θέσεις τα αντικείμενα με τη μεγαλύτερη πιθανότητα να ενδιαφέρουν τον χρήστη, μεγιστοποιώντας έτσι τη χρησιμότητα της λίστας προτάσεων. Η ανάπτυξη αλγορίθμων που βελτιστοποιούν την ποιότητα της κατάταξης έχει αποτελέσει σημαντική ερευνητική κατεύθυνση, ιδιαίτερα στα συστήματα που βασίζονται σε έμμεση ανατροφοδότηση (Rendle et al., 2009). Παρότι η ακρίβεια και η ποιότητα της κατάταξης παραμένουν θεμελιώδεις δείκτες απόδοσης, η σύγχρονη έρευνα έχει αναδείξει τη σημασία της ποικιλίας ως κρίσιμης διάστασης της ποιότητας των συστάσεων. Ένα σύστημα που προτείνει συνεχώς παρόμοια αντικείμενα μπορεί να επιτυγχάνει υψηλή ακρίβεια, όμως ενδέχεται να περιορίζει τις δυνατότητες εξερεύνησης και ανακάλυψης νέου περιεχομένου από τον χρήστη. Η ποικιλία συμβάλλει στη δημιουργία μιας πιο πλούσιας και ενδιαφέρουσας εμπειρίας χρήσης, επιτρέποντας την έκθεση σε διαφορετικές κατηγορίες αντικειμένων και τη διεύρυνση των επιλογών του χρήστη (Jannach et al., 2023). Στενά συνδεδεμένη με την ποικιλία είναι η έννοια της καινοτομίας. Η καινοτομία αναφέρεται στον βαθμό στον οποίο οι προτεινόμενες επιλογές είναι νέες ή απρόσμενες για τον χρήστη. Ένα σύστημα υψηλής ποιότητας δεν περιορίζεται στην αναπαραγωγή ήδη γνωστών επιλογών αλλά συμβάλλει στην ανακάλυψη αντικειμένων που ο χρήστης ενδέχεται να μην είχε εντοπίσει μόνος του. Η δυνατότητα αυτή αποτελεί σημαντικό πλεονέκτημα των συστημάτων συστάσεων και συνδέεται άμεσα με τη συνολική αξία που προσφέρουν στους χρήστες και στους παρόχους υπηρεσιών (Adomavicius & Tuzhilin, 2005).

Ένας ακόμη σημαντικός δείκτης ποιότητας είναι η κάλυψη. Η κάλυψη αφορά τον βαθμό στον οποίο το σύστημα είναι ικανό να παράγει συστάσεις για το σύνολο των χρηστών και των διαθέσιμων αντικειμένων. Ένα σύστημα μπορεί να παρουσιάζει υψηλή ακρίβεια για συγκεκριμένες κατηγορίες χρηστών ή προϊόντων, αλλά να αδυνατεί να εξυπηρετήσει αποτελεσματικά άλλες περιπτώσεις. Η υψηλή κάλυψη θεωρείται ιδιαίτερα σημαντική σε εφαρμογές μεγάλης κλίμακας, όπου η ετερογένεια των χρηστών και των αντικειμένων είναι ιδιαίτερα αυξημένη (Ekstrand et al., 2011). Η προσαρμοστικότητα των συστημάτων αποτελεί επίσης σημαντικό παράγοντα ποιότητας. Οι προτιμήσεις των χρηστών εξελίσσονται διαρκώς, γεγονός που καθιστά απαραίτητη την ικανότητα του συστήματος να ανανεώνει τα μοντέλα του και να προσαρμόζει τις συστάσεις του σε νέες συνθήκες. Οι τεχνικές που ενσωματώνουν χρονικές δυναμικές έχουν αναδείξει τη σημασία αυτής της διάστασης, καθώς επιτρέπουν την αποτελεσματικότερη παρακολούθηση των μεταβαλλόμενων ενδιαφερόντων των χρηστών και την παροχή περισσότερο σχετικών προτάσεων (Koren, 2010).

Η εμφάνιση της βαθιάς μάθησης δημιούργησε νέες δυνατότητες όσον αφορά τη βελτίωση των μετρικών ποιότητας. Τα βαθιά νευρωνικά δίκτυα έχουν αποδειχθεί ιδιαίτερα αποτελεσματικά στην αναγνώριση πολύπλοκων σχέσεων μεταξύ χρηστών και αντικειμένων, οδηγώντας σε σημαντική βελτίωση της ακρίβειας και της ποιότητας των συστάσεων. Μέσω της εκμάθησης πολυδιάστατων αναπαραστάσεων, τα συστήματα βαθιάς μάθησης μπορούν να αξιοποιούν αποτελεσματικότερα τα διαθέσιμα δεδομένα και να παράγουν πιο εξατομικευμένες προτάσεις σε σχέση με τις παραδοσιακές προσεγγίσεις (Zhang et al., 2019; Zhou et al., 2023). Χαρακτηριστικό παράδειγμα αποτελεί η χρήση βαθιών νευρωνικών δικτύων σε πλατφόρμες μεγάλης κλίμακας όπως το YouTube. Τα συστήματα αυτά αξιολογούνται όχι μόνο ως προς την ακρίβεια των προτάσεων αλλά και ως προς την ικανότητά τους να αυξάνουν την εμπλοκή των χρηστών, τον χρόνο αλληλεπίδρασης και τη συνολική ικανοποίηση από την υπηρεσία. Η ποιότητα των συστάσεων συνδέεται επομένως άμεσα με επιχειρησιακούς δείκτες που αντικατοπτρίζουν την πραγματική αξία του συστήματος σε συνθήκες λειτουργίας (Covington et al., 2016).

Η αρχιτεκτονική Wide & Deep αποτελεί ένα ακόμη παράδειγμα προσέγγισης που επιδιώκει τη βελτίωση πολλαπλών διαστάσεων ποιότητας. Μέσω του συνδυασμού γραμμικών μοντέλων και βαθιών νευρωνικών δικτύων, το σύστημα επιτυγχάνει υψηλότερη ακρίβεια και καλύτερη γενίκευση σε νέα δεδομένα, βελτιώνοντας τη συνολική αποτελεσματικότητα των προτάσεων. Η αξιολόγηση τέτοιων μοντέλων απαιτεί τη συνεκτίμηση διαφορετικών δεικτών ποιότητας, καθώς η απόδοσή τους εκτείνεται πέρα από την απλή πρόβλεψη αξιολογήσεων (Cheng et al., 2016). Τα τελευταία χρόνια, η ερμηνευσιμότητα έχει αναδειχθεί σε ιδιαίτερα σημαντική μετρική

ποιότητας. Οι χρήστες επιθυμούν να γνωρίζουν γιατί τους προτάθηκε ένα συγκεκριμένο αντικείμενο και να κατανοούν τη λογική πίσω από τις αποφάσεις του συστήματος. Η δυνατότητα παροχής επεξηγήσεων ενισχύει τη διαφάνεια και βελτιώνει την αποδοχή των προτάσεων. Ως εκ τούτου, η αξιολόγηση των μηχανισμών επεξήγησης αποτελεί πλέον αναπόσπαστο μέρος της αξιολόγησης των σύγχρονων συστημάτων συστάσεων (Zhang & Chen, 2020).

Άμεσα συνδεδεμένη με την ερμηνευσιμότητα είναι και η εμπιστοσύνη των χρηστών. Η εμπιστοσύνη θεωρείται σήμερα μία από τις σημαντικότερες ποιοτικές διαστάσεις των συστημάτων συστάσεων, καθώς επηρεάζει άμεσα την πιθανότητα αποδοχής των προτάσεων και τη μακροχρόνια χρήση της πλατφόρμας. Ένα σύστημα μπορεί να εμφανίζει υψηλή τεχνική απόδοση, αλλά αν οι χρήστες δεν το θεωρούν αξιόπιστο, η πραγματική του αποτελεσματικότητα περιορίζεται σημαντικά. Για τον λόγο αυτό, η αξιολόγηση της εμπιστοσύνης αποτελεί πλέον βασικό αντικείμενο έρευνας στον χώρο των ευφυών συστημάτων συστάσεων (Akdim et al., 2025). Η ανάπτυξη πολυστοχικών συστημάτων συστάσεων έχει επηρεάσει σημαντικά και τον τρόπο με τον οποίο ορίζεται η ποιότητα των συστάσεων. Στις σύγχρονες εφαρμογές δεν αρκεί η βελτιστοποίηση ενός μόνο κριτηρίου, όπως η ακρίβεια, αλλά απαιτείται η ταυτόχρονη επίτευξη πολλαπλών στόχων. Η ποιότητα αξιολογείται πλέον ως αποτέλεσμα της ισορροπίας μεταξύ ακρίβειας, ποικιλίας, καινοτομίας, δικαιοσύνης, ερμηνευσιμότητας και ικανοποίησης των χρηστών. Η πολυδιάστατη αυτή θεώρηση αντανακλά την αυξανόμενη πολυπλοκότητα των σύγχρονων ψηφιακών οικοσυστημάτων και των απαιτήσεων που αυτά επιβάλλουν (Jannach et al., 2023).

5.3 Συγκριτική ανάλυση διαφορετικών τεχνικών

Η συνεχής εξέλιξη των συστημάτων συστάσεων έχει οδηγήσει στην ανάπτυξη ενός μεγάλου αριθμού τεχνικών και αλγοριθμικών προσεγγίσεων, καθεμία από τις οποίες παρουσιάζει διαφορετικά χαρακτηριστικά, πλεονεκτήματα και περιορισμούς. Η συγκριτική ανάλυση των τεχνικών αυτών αποτελεί βασικό στοιχείο της έρευνας στον τομέα των συστημάτων συστάσεων, καθώς επιτρέπει την κατανόηση της αποτελεσματικότητάς τους σε διαφορετικά περιβάλλοντα εφαρμογής και συμβάλλει στην επιλογή της καταλληλότερης μεθόδου ανάλογα με τις απαιτήσεις κάθε περίπτωσης. Η αξιολόγηση δεν περιορίζεται αποκλειστικά στην ακρίβεια των προβλέψεων αλλά επεκτείνεται σε ένα ευρύτερο σύνολο παραμέτρων που περιλαμβάνει την προσαρμοστικότητα, την υπολογιστική αποδοτικότητα, την ερμηνευσιμότητα, την ποικιλία των προτάσεων και τη συνολική εμπειρία των χρηστών (Adomavicius & Tuzhilin, 2005). Οι πρώτες εφαρμογές συστημάτων συστάσεων βασίστηκαν κυρίως σε συνεργατικές τεχνικές φιλτραρίσματος, οι οποίες αξιοποιούσαν τις συλλογικές προτιμήσεις των χρηστών για την

παραγωγή προτάσεων. Οι μέθοδοι αυτές απέκτησαν μεγάλη δημοτικότητα λόγω της ικανότητάς τους να εντοπίζουν σχέσεις μεταξύ χρηστών και αντικειμένων χωρίς να απαιτείται γνώση των χαρακτηριστικών του περιεχομένου. Συστήματα όπως το GroupLens και άλλες πρώιμες εφαρμογές συνεργατικού φιλτραρίσματος απέδειξαν ότι οι συλλογικές αξιολογήσεις μπορούν να αξιοποιηθούν αποτελεσματικά για την παραγωγή εξατομικευμένων συστάσεων (Resnick et al., 1994; Goldberg et al., 1992). Όμως, οι μέθοδοι αυτές παρουσίαζαν σημαντικούς περιορισμούς, κυρίως λόγω της αραιότητας των δεδομένων και του προβλήματος της ψυχρής εκκίνησης, γεγονός που οδήγησε στην αναζήτηση εναλλακτικών ή συμπληρωματικών προσεγγίσεων.

Τα συστήματα συστάσεων βασισμένα σε περιεχόμενο αποτέλεσαν μία από τις σημαντικότερες εναλλακτικές λύσεις. Σε αντίθεση με τις συνεργατικές τεχνικές, τα content-based συστήματα αξιοποιούν τα χαρακτηριστικά των αντικειμένων και το ιστορικό προτιμήσεων κάθε χρήστη για την παραγωγή συστάσεων. Το βασικό τους πλεονέκτημα είναι ότι μπορούν να λειτουργήσουν αποτελεσματικά ακόμη και όταν δεν υπάρχουν επαρκή δεδομένα από άλλους χρήστες, ενώ ταυτόχρονα προσφέρουν υψηλό βαθμό εξατομίκευσης και καλύτερη δυνατότητα ερμηνείας των προτάσεων. Παρόλα αυτά, συχνά εμφανίζουν το πρόβλημα της υπερεξειδίκευσης, καθώς τείνουν να προτείνουν αντικείμενα παρόμοια με εκείνα που έχει ήδη επιλέξει ο χρήστης, περιορίζοντας τις δυνατότητες ανακάλυψης νέου περιεχομένου (Adomavicius & Tuzhilin, 2005). Η συγκριτική αξιολόγηση μεταξύ content-based και collaborative συστημάτων έχει δείξει ότι καμία από τις δύο προσεγγίσεις δεν υπερτερεί απόλυτα σε όλες τις περιπτώσεις. Τα συνεργατικά συστήματα εμφανίζουν συνήθως καλύτερη ικανότητα ανακάλυψης νέων αντικειμένων και αξιοποίησης της συλλογικής γνώσης, ενώ τα content-based συστήματα προσφέρουν μεγαλύτερη ανεξαρτησία από εξωτερικά δεδομένα και καλύτερη λειτουργία σε περιπτώσεις περιορισμένης πληροφορίας. Η επιλογή μεταξύ των δύο προσεγγίσεων εξαρτάται σε μεγάλο βαθμό από τα χαρακτηριστικά της εφαρμογής, τη διαθεσιμότητα δεδομένων και τους στόχους του συστήματος (Ekstrand et al., 2011). Η ανάγκη αντιμετώπισης των αδυναμιών των επιμέρους προσεγγίσεων οδήγησε στην ανάπτυξη υβριδικών συστημάτων συστάσεων. Τα υβριδικά μοντέλα συνδυάζουν διαφορετικές τεχνικές προκειμένου να αξιοποιήσουν τα πλεονεκτήματα κάθε προσέγγισης και να περιορίσουν τους αντίστοιχους περιορισμούς. Η συγκριτική ανάλυση έχει δείξει ότι τα υβριδικά συστήματα εμφανίζουν συνήθως υψηλότερη ακρίβεια, καλύτερη διαχείριση του προβλήματος της ψυχρής εκκίνησης και αυξημένη ποικιλία προτάσεων σε σχέση με τις αμιγείς μεθόδους. Για τον λόγο αυτό, αποτελούν σήμερα μία από τις κυρίαρχες προσεγγίσεις στις εμπορικές εφαρμογές και στη σύγχρονη ερευνητική δραστηριότητα (Adomavicius & Tuzhilin, 2005; Li et al., 2023). Σημαντικό σταθμό στην εξέλιξη των συστημάτων συστάσεων αποτέλεσε η εισαγωγή των τεχνικών παραγοντοποίησης πινάκων. Οι μέθοδοι αυτές επέτρεψαν την ανακάλυψη λανθάνοντων

παραγόντων που περιγράφουν τις προτιμήσεις των χρηστών και τα χαρακτηριστικά των αντικειμένων, προσφέροντας σημαντικές βελτιώσεις στην ακρίβεια των προβλέψεων. Σε συγκριτικές μελέτες, οι τεχνικές παραγοντοποίησης απέδωσαν καλύτερα από τους παραδοσιακούς αλγορίθμους συνεργατικού φιλτραρίσματος, ιδιαίτερα σε μεγάλα και αραιά σύνολα δεδομένων. Η δυνατότητα αναπαράστασης σύνθετων σχέσεων μεταξύ χρηστών και αντικειμένων κατέστησε τις μεθόδους αυτές ιδιαίτερα δημοφιλείς τόσο στην ακαδημαϊκή έρευνα όσο και στις εφαρμογές του πραγματικού κόσμου (Koren et al., 2009).

Η περαιτέρω ανάπτυξη μοντέλων που λαμβάνουν υπόψη τη χρονική εξέλιξη των προτιμήσεων οδήγησε σε νέες βελτιώσεις των επιδόσεων. Η συγκριτική ανάλυση έδειξε ότι τα μοντέλα που ενσωματώνουν χρονικές δυναμικές παρουσιάζουν μεγαλύτερη προσαρμοστικότητα και είναι σε θέση να αποτυπώνουν αποτελεσματικότερα τις μεταβαλλόμενες ανάγκες των χρηστών. Σε περιβάλλοντα όπου οι προτιμήσεις εξελίσσονται διαρκώς, τα χρονικά μοντέλα υπερτερούν των στατικών προσεγγίσεων ως προς τη διατήρηση υψηλής ποιότητας συστάσεων σε βάθος χρόνου (Koren, 2010).

Η αξιοποίηση δεδομένων έμμεσης ανατροφοδότησης αποτέλεσε επίσης αντικείμενο εκτεταμένων συγκριτικών αναλύσεων. Σε πολλές σύγχρονες εφαρμογές, οι χρήστες δεν παρέχουν ρητές αξιολογήσεις αλλά εκφράζουν τις προτιμήσεις τους μέσω έμμεσων ενεργειών όπως αγορές, προβολές ή κλικ. Οι εξειδικευμένες μέθοδοι που σχεδιάστηκαν για τη διαχείριση τέτοιων δεδομένων αποδείχθηκαν περισσότερο αποτελεσματικές από τα παραδοσιακά μοντέλα που βασίζονται αποκλειστικά σε βαθμολογίες, καθώς αξιοποιούν καλύτερα τις διαθέσιμες πληροφορίες και ανταποκρίνονται πληρέστερα στις πραγματικές συνθήκες λειτουργίας των σύγχρονων συστημάτων συστάσεων (Hu et al., 2008).

Μία ακόμη σημαντική κατηγορία συγκριτικών μελετών αφορά τους αλγορίθμους κατάταξης. Οι τεχνικές αυτές δεν επικεντρώνονται στην πρόβλεψη συγκεκριμένων βαθμολογιών αλλά στην παραγωγή βέλτιστων λιστών προτάσεων. Η σύγκριση με παραδοσιακές μεθόδους πρόβλεψης έχει δείξει ότι οι αλγόριθμοι κατάταξης συχνά προσφέρουν καλύτερη εμπειρία χρήστη, καθώς ανταποκρίνονται πιο αποτελεσματικά στον τρόπο με τον οποίο οι χρήστες αλληλεπιδρούν με τα αποτελέσματα ενός συστήματος συστάσεων. Η σημασία τους έχει αυξηθεί ιδιαίτερα στις εφαρμογές ηλεκτρονικού εμπορίου και ψηφιακού περιεχομένου, όπου η ποιότητα της τελικής λίστας προτάσεων είναι καθοριστική για την επιτυχία του συστήματος (Rendle et al., 2009). Η εμφάνιση της βαθιάς μάθησης δημιούργησε ένα νέο πεδίο συγκριτικής αξιολόγησης. Τα συστήματα που βασίζονται σε βαθιά νευρωνικά δίκτυα εμφανίζουν σημαντικές διαφορές σε σχέση με τις παραδοσιακές μεθόδους συνεργατικού φιλτραρίσματος και παραγοντοποίησης

πινάκων. Η βασική τους υπεροχή έγκειται στην ικανότητα αναγνώρισης πολύπλοκων και μη γραμμικών σχέσεων μεταξύ χρηστών και αντικειμένων, καθώς και στην αξιοποίηση ετερογενών μορφών δεδομένων όπως κείμενο, εικόνες και μεταδεδομένα. Πολλές συγκριτικές μελέτες έχουν δείξει ότι τα μοντέλα βαθιάς μάθησης επιτυγχάνουν υψηλότερη ακρίβεια και καλύτερη εξατομίκευση σε σχέση με τις παραδοσιακές προσεγγίσεις, ιδιαίτερα σε περιβάλλοντα μεγάλης κλίμακας (Zhang et al., 2019; Zhou et al., 2023).

Σχετικό παράδειγμα αποτελεί το Neural Collaborative Filtering, το οποίο συγκρίθηκε με παραδοσιακές τεχνικές παραγοντοποίησης και απέδειξε ότι τα νευρωνικά μοντέλα μπορούν να αναπαριστούν αποτελεσματικότερα τις αλληλεπιδράσεις μεταξύ χρηστών και αντικειμένων. Μέσω της χρήσης πολυεπίπεδων νευρωνικών δικτύων, η προσέγγιση αυτή επιτυγχάνει μεγαλύτερη ευελιξία και καλύτερη προσαρμογή στα δεδομένα, προσφέροντας βελτιωμένες επιδόσεις σε πολλές εφαρμογές συστάσεων (He et al., 2017). Περαιτέρω, προηγμένες αρχιτεκτονικές όπως το Wide & Deep απέδειξαν ότι ο συνδυασμός διαφορετικών τεχνικών μάθησης μπορεί να προσφέρει καλύτερα αποτελέσματα από την αποκλειστική χρήση μίας μόνο προσέγγισης. Η συγκριτική αξιολόγηση έδειξε ότι τα υβριδικά νευρωνικά μοντέλα είναι σε θέση να συνδυάζουν αποτελεσματικά την απομνημόνευση γνωστών σχέσεων με τη δυνατότητα γενίκευσης νέων προτύπων, οδηγώντας σε υψηλότερη ακρίβεια και μεγαλύτερη προσαρμοστικότητα (Cheng et al., 2016).

Οι σύγχρονες εφαρμογές μεγάλης κλίμακας, όπως το YouTube, προσφέρουν επίσης σημαντικά συμπεράσματα σχετικά με τη συγκριτική αποτελεσματικότητα διαφορετικών τεχνικών. Η χρήση βαθιών νευρωνικών δικτύων σε συνδυασμό με πολλαπλές πηγές δεδομένων έχει αποδειχθεί ιδιαίτερα αποτελεσματική στη βελτίωση της εμπειρίας των χρηστών και στην αύξηση της εμπλοκής τους με το περιεχόμενο. Τα αποτελέσματα αυτά επιβεβαιώνουν την υπεροχή των προηγμένων υβριδικών και νευρωνικών προσεγγίσεων σε περιβάλλοντα που χαρακτηρίζονται από μεγάλο όγκο δεδομένων και υψηλή πολυπλοκότητα (Covington et al., 2016). Εκτός από τις βελτιώσεις που προσφέρουν οι τεχνικές βαθιάς μάθησης, η συγκριτική αξιολόγηση έχει αναδείξει και ορισμένες προκλήσεις. Τα μοντέλα αυτά απαιτούν μεγάλες ποσότητες δεδομένων και αυξημένους υπολογιστικούς πόρους, ενώ συχνά παρουσιάζουν περιορισμένη ερμηνευσιμότητα σε σχέση με πιο απλές προσεγγίσεις. Ως αποτέλεσμα, η επιλογή της κατάλληλης τεχνικής δεν βασίζεται αποκλειστικά στην ακρίβεια αλλά και σε παράγοντες όπως το κόστος υλοποίησης, η διαφάνεια και οι απαιτήσεις της εφαρμογής (Zhang & Chen, 2020).

Η σύγχρονη έρευνα μετατοπίζει σταδιακά το ενδιαφέρον της από τη μονοδιάστατη αξιολόγηση της ακρίβειας προς τη σύγκριση πολυστοχικών συστημάτων συστάσεων. Οι νέες προσεγγίσεις

επιδιώκουν την ταυτόχρονη βελτιστοποίηση πολλαπλών κριτηρίων, όπως η ακρίβεια, η ποικιλία, η καινοτομία, η δικαιοσύνη, η εμπιστοσύνη και η ικανοποίηση των χρηστών. Η συγκριτική ανάλυση των συστημάτων αυτών δείχνει ότι η βέλτιστη λύση συχνά προκύπτει από την ισορροπία μεταξύ διαφορετικών στόχων και όχι από τη μεγιστοποίηση μίας μόνο μετρικής απόδοσης (Jannach et al., 2023). Επιπλέον, η εμπιστοσύνη των χρηστών έχει αναδειχθεί σε σημαντικό παράγοντα συγκριτικής αξιολόγησης. Τα συστήματα που παρέχουν διαφανείς και κατανοητές συστάσεις τείνουν να επιτυγχάνουν υψηλότερα επίπεδα αποδοχής και μακροχρόνιας χρήσης, ακόμη και όταν η τεχνική τους απόδοση δεν είναι πάντοτε η υψηλότερη. Η παρατήρηση αυτή υπογραμμίζει τη σημασία της ανθρωποκεντρικής προσέγγισης στην αξιολόγηση των συστημάτων συστάσεων και αναδεικνύει την ανάγκη συνδυασμού τεχνικών και ποιοτικών κριτηρίων αξιολόγησης (Akdin et al., 2025).

5.4 Περιορισμοί και τεχνικές βελτίωσης

Αρχικά, φαίνεται πως παρά τη σημαντική πρόοδο που έχει σημειωθεί στον τομέα των συστημάτων συστάσεων και την ευρεία υιοθέτησή τους σε ένα μεγάλο εύρος εφαρμογών, οι υπάρχουσες τεχνικές εξακολουθούν να αντιμετωπίζουν σημαντικούς περιορισμούς που επηρεάζουν την αποτελεσματικότητα, την αξιοπιστία και τη συνολική εμπειρία των χρηστών. Οι περιορισμοί αυτοί σχετίζονται τόσο με τη φύση των διαθέσιμων δεδομένων όσο και με τις αδυναμίες των αλγοριθμικών προσεγγίσεων που χρησιμοποιούνται για τη δημιουργία εξατομικευμένων προτάσεων. Ως αποτέλεσμα, η ανάπτυξη τεχνικών βελτίωσης αποτελεί διαχρονικά βασικό αντικείμενο έρευνας, με στόχο τη δημιουργία συστημάτων που να είναι περισσότερο ακριβή, προσαρμοστικά, αξιόπιστα και αποτελεσματικά σε σύνθετα περιβάλλοντα λειτουργίας (Adomavicius & Tuzhilin, 2005).

Ένας από τους σημαντικότερους περιορισμούς των συστημάτων συστάσεων είναι το πρόβλημα της ψυχρής εκκίνησης (cold start). Το πρόβλημα αυτό εμφανίζεται όταν το σύστημα καλείται να παράγει προτάσεις για νέους χρήστες ή νέα αντικείμενα για τα οποία δεν υπάρχουν επαρκή ιστορικά δεδομένα αλληλεπίδρασης. Στα συνεργατικά συστήματα συστάσεων, η απουσία προηγούμενων αξιολογήσεων δυσκολεύει τον εντοπισμό προτύπων ομοιότητας και περιορίζει σημαντικά την ακρίβεια των προτάσεων. Η συγκεκριμένη πρόκληση αποτελεί ένα από τα πλέον μελετημένα προβλήματα στη βιβλιογραφία, καθώς επηρεάζει άμεσα τη λειτουργικότητα των συστημάτων κατά τα πρώτα στάδια χρήσης τους (Adomavicius & Tuzhilin, 2005; Ekstrand et al., 2011).

Για την αντιμετώπιση του προβλήματος της ψυχρής εκκίνησης έχουν αναπτυχθεί διάφορες τεχνικές βελτίωσης, με κυριότερη τη χρήση υβριδικών προσεγγίσεων που συνδυάζουν

πληροφορίες περιεχομένου και συνεργατικά δεδομένα. Μέσω της αξιοποίησης χαρακτηριστικών των αντικειμένων και πρόσθετων πληροφοριών σχετικά με τους χρήστες, τα υβριδικά συστήματα μπορούν να παράγουν χρήσιμες προτάσεις ακόμη και όταν τα διαθέσιμα δεδομένα είναι περιορισμένα. Η ενσωμάτωση πολλαπλών πηγών γνώσης έχει αποδειχθεί ιδιαίτερα αποτελεσματική στη μείωση των επιπτώσεων του προβλήματος και αποτελεί μία από τις κυρίαρχες κατευθύνσεις βελτίωσης των σύγχρονων συστημάτων συστάσεων (Li et al., 2023). Ένας ακόμη σημαντικός περιορισμός αφορά την αραιότητα των δεδομένων. Στα περισσότερα συστήματα συστάσεων, οι χρήστες αλληλεπιδρούν μόνο με ένα μικρό ποσοστό των διαθέσιμων αντικειμένων, με αποτέλεσμα οι πίνακες αξιολογήσεων να περιέχουν μεγάλο αριθμό κενών τιμών. Η έλλειψη επαρκών δεδομένων δυσχεραίνει την εξαγωγή αξιόπιστων συμπερασμάτων και μειώνει την αποτελεσματικότητα πολλών αλγορίθμων συνεργατικού φιλτραρίσματος. Το πρόβλημα αυτό γίνεται ακόμη πιο έντονο σε εφαρμογές μεγάλης κλίμακας όπου ο αριθμός των χρηστών και των αντικειμένων αυξάνεται συνεχώς (Ekstrand et al., 2011).

Οι τεχνικές παραγοντοποίησης πινάκων αναπτύχθηκαν σε μεγάλο βαθμό ως απάντηση στο πρόβλημα της αραιότητας. Μέσω της ανακάλυψης λανθανόντων παραγόντων που περιγράφουν τις προτιμήσεις των χρηστών και τα χαρακτηριστικά των αντικειμένων, οι μέθοδοι αυτές επιτρέπουν την εκτίμηση μη παρατηρήσιμων σχέσεων και τη δημιουργία ακριβέστερων προβλέψεων ακόμη και όταν τα διαθέσιμα δεδομένα είναι περιορισμένα. Η επιτυχία των τεχνικών παραγοντοποίησης έχει αναγνωριστεί ευρέως στη βιβλιογραφία και αποτελεί έναν από τους βασικούς λόγους για τους οποίους οι μέθοδοι αυτές χρησιμοποιούνται εκτενώς σε σύγχρονες εφαρμογές συστάσεων (Koren et al., 2009). Ένας άλλος σημαντικός περιορισμός αφορά το φαινόμενο της υπερεξειδίκευσης (overspecialization), το οποίο εμφανίζεται κυρίως στα συστήματα που βασίζονται σε περιεχόμενο. Επειδή οι προτάσεις βασίζονται στις προηγούμενες επιλογές του χρήστη, το σύστημα τείνει να προτείνει αντικείμενα με πολύ παρόμοια χαρακτηριστικά, περιορίζοντας έτσι την έκθεση σε νέο και διαφορετικό περιεχόμενο. Το αποτέλεσμα είναι η δημιουργία ενός στενού φάσματος προτάσεων που μπορεί να μειώσει το ενδιαφέρον και την ικανοποίηση του χρήστη. Η αντιμετώπιση αυτού του προβλήματος απαιτεί την εισαγωγή μηχανισμών που ενισχύουν την ποικιλία και την ανακάλυψη νέων αντικειμένων (Jannach et al., 2023).

Η ενσωμάτωση πολυστοχικών τεχνικών σύστασης αποτελεί μία από τις σημαντικότερες στρατηγικές για τη βελτίωση της ποικιλίας των προτάσεων. Τα σύγχρονα συστήματα δεν επιδιώκουν πλέον αποκλειστικά τη μεγιστοποίηση της ακρίβειας, αλλά λαμβάνουν υπόψη και άλλους παράγοντες, όπως η καινοτομία, η ποικιλία, η δικαιοσύνη και η ικανοποίηση των χρηστών. Η πολυστοχική βελτιστοποίηση επιτρέπει την επίτευξη ισορροπίας μεταξύ

αντικρουόμενων στόχων και συμβάλλει στη δημιουργία περισσότερο ολοκληρωμένων και ποιοτικών συστάσεων (Jannach et al., 2023). Σημαντικό πρόβλημα αποτελεί επίσης η αδυναμία πολλών συστημάτων να προσαρμόζονται αποτελεσματικά στις μεταβαλλόμενες προτιμήσεις των χρηστών. Οι περισσότεροι άνθρωποι μεταβάλλουν τα ενδιαφέροντά τους με την πάροδο του χρόνου, επηρεαζόμενοι από νέες εμπειρίες, κοινωνικές τάσεις και προσωπικές ανάγκες. Τα στατικά μοντέλα δυσκολεύονται να αποτυπώσουν αυτές τις μεταβολές, γεγονός που μπορεί να οδηγήσει στη μείωση της ποιότητας των προτάσεων. Για τον λόγο αυτό, η ενσωμάτωση χρονικών δυναμικών αποτελεί σημαντική τεχνική βελτίωσης των συστημάτων συστάσεων (Koren, 2010).

Την ίδια στιγμή, η αξιοποίηση δεδομένων έμμεσης ανατροφοδότησης έχει συμβάλει ουσιαστικά στη βελτίωση της προσαρμοστικότητας των συστημάτων. Σε πολλές περιπτώσεις οι χρήστες δεν παρέχουν ρητές αξιολογήσεις, αλλά η συμπεριφορά τους καταγράφεται μέσω κλικ, προβολών, αγορών ή άλλων μορφών αλληλεπίδρασης. Η ανάπτυξη εξειδικευμένων αλγορίθμων για την αξιοποίηση τέτοιων δεδομένων επιτρέπει τη δημιουργία πλουσιότερων μοντέλων χρηστών και οδηγεί σε πιο ακριβείς και δυναμικές προτάσεις (Hu et al., 2008).

Η περιορισμένη δυνατότητα ερμηνείας των αποτελεσμάτων αποτελεί έναν ακόμη σημαντικό περιορισμό, ιδιαίτερα στις σύγχρονες εφαρμογές που βασίζονται σε σύνθετα μοντέλα βαθιάς μάθησης. Αν και τα νευρωνικά δίκτυα προσφέρουν υψηλή ακρίβεια, η διαδικασία λήψης αποφάσεων συχνά παραμένει αδιαφανής για τους χρήστες και τους διαχειριστές των συστημάτων. Η έλλειψη επεξηγησιμότητας μπορεί να μειώσει την εμπιστοσύνη των χρηστών και να περιορίσει την αποδοχή των προτάσεων, ακόμη και όταν αυτές είναι τεχνικά ορθές (Zhang & Chen, 2020). Η ανάπτυξη επεξηγήσιμων συστημάτων συστάσεων αποτελεί μία από τις σημαντικότερες σύγχρονες τεχνικές βελτίωσης. Τα συστήματα αυτά παρέχουν πληροφορίες σχετικά με τους λόγους που οδήγησαν σε μία συγκεκριμένη πρόταση, επιτρέποντας στους χρήστες να κατανοούν καλύτερα τη λειτουργία του αλγορίθμου. Η αυξημένη διαφάνεια ενισχύει την αποδοχή των συστάσεων και συμβάλλει στη δημιουργία σχέσεων εμπιστοσύνης μεταξύ χρηστών και συστήματος (Zhang & Chen, 2020).

Η εμπιστοσύνη αποτελεί γενικότερα μία κρίσιμη πρόκληση για τα σύγχρονα συστήματα συστάσεων. Οι χρήστες είναι περισσότερο πιθανό να ακολουθήσουν τις προτάσεις ενός συστήματος όταν το θεωρούν αξιόπιστο, δίκαιο και συνεπές. Παρόλα αυτά, παράγοντες όπως η έλλειψη διαφάνειας, οι προκαταλήψεις των δεδομένων και οι ακατάλληλες προτάσεις μπορούν να μειώσουν σημαντικά το επίπεδο εμπιστοσύνης. Η σύγχρονη έρευνα επικεντρώνεται στην ανάπτυξη τεχνικών που ενισχύουν την αξιοπιστία και την κοινωνική αποδοχή των συστημάτων συστάσεων (Akdim et al., 2025). Η εμφάνιση της βαθιάς μάθησης έχει προσφέρει νέες

δυνατότητες αντιμετώπισης πολλών από τους παραπάνω περιορισμούς. Τα βαθιά νευρωνικά δίκτυα μπορούν να επεξεργάζονται μεγάλους όγκους ετερογενών δεδομένων και να ανακαλύπτουν σύνθετα πρότυπα συμπεριφοράς που δεν είναι εύκολα ανιχνεύσιμα από παραδοσιακές μεθόδους. Η δυνατότητα αξιοποίησης δεδομένων κειμένου, εικόνας, ήχου και μεταδεδομένων οδηγεί σε πλουσιότερες αναπαραστάσεις χρηστών και αντικειμένων, βελτιώνοντας την ακρίβεια και την προσαρμοστικότητα των συστημάτων (Zhang et al., 2019; Zhou et al., 2023). Ιδιαίτερα σημαντική θεωρείται η ανάπτυξη νευρωνικών συνεργατικών μοντέλων, τα οποία αξιοποιούν τις δυνατότητες της βαθιάς μάθησης για τη μοντελοποίηση πολύπλοκων αλληλεπιδράσεων μεταξύ χρηστών και αντικειμένων. Συγκριτικές μελέτες έχουν δείξει ότι τα μοντέλα αυτά υπερτερούν συχνά των παραδοσιακών τεχνικών ως προς την ακρίβεια και τη δυνατότητα προσαρμογής σε μεγάλα και σύνθετα σύνολα δεδομένων (He et al., 2017).

Ακόμη, οι τεχνικές ενισχυτικής μάθησης προσφέρουν μία νέα προσέγγιση για τη βελτίωση των συστημάτων συστάσεων. Αντί να βασίζονται αποκλειστικά σε ιστορικά δεδομένα, τα συστήματα αυτά μαθαίνουν μέσα από τη συνεχή αλληλεπίδραση με τους χρήστες και προσαρμόζουν δυναμικά τη στρατηγική τους. Η δυνατότητα βελτιστοποίησης μακροπρόθεσμων στόχων επιτρέπει τη δημιουργία πιο ευφύων και προσαρμοστικών μηχανισμών σύστασης, οι οποίοι ανταποκρίνονται καλύτερα στις μεταβαλλόμενες ανάγκες των χρηστών (Chen et al., 2021). Σημαντική τεχνική βελτίωσης αποτελεί επίσης η αξιοποίηση σύνθετων υβριδικών αρχιτεκτονικών. Συστήματα όπως το Wide & Deep συνδυάζουν διαφορετικές μεθόδους μάθησης σε ένα ενιαίο πλαίσιο, επιτρέποντας την ταυτόχρονη αξιοποίηση γνωστών σχέσεων και την ανακάλυψη νέων προτύπων. Η προσέγγιση αυτή συμβάλλει στη βελτίωση της ακρίβειας, της γενίκευσης και της προσαρμοστικότητας των προτάσεων, αποτελώντας χαρακτηριστικό παράδειγμα σύγχρονης τεχνικής βελτίωσης (Cheng et al., 2016).

5.5 Μαθηματικοί ορισμοί των μετρικών αξιολόγησης

Η αξιολόγηση ενός συστήματος συστάσεων απαιτεί την τυπική μαθηματική διατύπωση των μετρικών. Οι μετρικές διακρίνονται σε τρεις κατηγορίες: μετρικές ακρίβειας πρόβλεψης βαθμολογίας, μετρικές ποιότητας κατάταξης (Top-N) και μετρικές πέραν της ακρίβειας (κάλυψη, ποικιλία, καινοτομία).

5.5.1 Μετρικές ακρίβειας πρόβλεψης

Το μέσο απόλυτο σφάλμα (MAE) και η ρίζα του μέσου τετραγωνικού σφάλματος (RMSE) μετρούν την απόκλιση των προβλεπόμενων από τις πραγματικές βαθμολογίες στο σύνολο ελέγχου:

$$\text{MAE} = \frac{1}{|K_{\text{test}}|} \sum_{(u,i) \in K_{\text{test}}} |r_{ui} - \hat{r}_{ui}|$$

$$\text{RMSE} = \sqrt{\frac{1}{|K_{\text{test}}|} \sum_{(u,i) \in K_{\text{test}}} (r_{ui} - \hat{r}_{ui})^2}$$

Η RMSE τιμωρεί εντονότερα τα μεγάλα σφάλματα λόγω της ύψωσης στο τετράγωνο και αποτέλεσε την επίσημη μετρική του διαγωνισμού Netflix Prize.

5.5.2 Μετρικές ποιότητας κατάταξης

Για την αξιολόγηση της λίστας Top-N, ορίζουμε ως R_u το σύνολο των πραγματικά σχετικών αντικειμένων για τον χρήστη u και ως $T_u(k)$ τα k κορυφαία συνιστώμενα αντικείμενα. Η ακρίβεια ($\text{Precision}@k$) και η ανάκληση ($\text{Recall}@k$) ορίζονται ως:

$$\text{Precision}@k = \frac{|R_u \cap T_u^{(k)}|}{k}$$

$$\text{Recall}@k = \frac{|R_u \cap T_u^{(k)}|}{|R_u|}$$

Ο συνδυασμός τους μέσω του αρμονικού μέσου δίνει το $F1@k$:

$$F1@k = \frac{2 \cdot \text{Precision}@k \cdot \text{Recall}@k}{\text{Precision}@k + \text{Recall}@k}$$

Η μέση ακρίβεια (Average Precision) λαμβάνει υπόψη τη θέση των σχετικών αντικειμένων στην κατάταξη, ενώ η μέση μέση ακρίβεια (MAP) μέσο όρο για όλους τους χρήστες:

$$\text{AP}@k = \frac{1}{|R_u|} \sum_{n=1}^k \text{Precision}@n \cdot \text{rel}(n)$$

$$\text{MAP}@k = \frac{1}{|U|} \sum_{u \in U} \text{AP}@k(u)$$

όπου $\text{rel}(n) = 1$ αν το αντικείμενο στη θέση n είναι σχετικό, αλλιώς 0.

Ο μέσος αντίστροφος βαθμός (Mean Reciprocal Rank) εστιάζει στη θέση του πρώτου σχετικού αντικειμένου:

$$\text{MRR} = \frac{1}{|U|} \sum_{u \in U} \frac{1}{\text{rank}_u}$$

5.5.3 Κανονικοποιημένο σωρευτικό κέρδος (NDCG)

Το NDCG είναι η πλέον διαδεδομένη μετρική κατάταξης, καθώς αποδίδει μεγαλύτερο βάρος στα σχετικά αντικείμενα που εμφανίζονται σε υψηλότερες θέσεις, μέσω λογαριθμικής μείωσης. Το σωρευτικό κέρδος με έκπτωση (DCG) ορίζεται ως:

$$\text{DCG}@k = \sum_{n=1}^k \frac{2^{\text{rel}_n} - 1}{\log_2(n+1)}$$

και κανονικοποιείται ως προς το ιδανικό DCG (IDCG), δηλαδή το DCG της τέλει κατάταξης:

$$\text{NDCG}@k = \frac{\text{DCG}@k}{\text{IDCG}@k} \in [0, 1]$$

5.5.4 Μετρικές πέραν της ακρίβειας

Η κάλυψη καταλόγου (catalog coverage) μετρά το ποσοστό των αντικειμένων που το σύστημα είναι ικανό να προτείνει:

$$\text{Coverage} = \frac{|\bigcup_{u \in U} T_u^{(k)}|}{|I|}$$

Η ενδο-λίστα ποικιλία (intra-list diversity) εκφράζει πόσο διαφορετικά μεταξύ τους είναι τα προτεινόμενα αντικείμενα:

$$\text{ILD}(L) = \frac{2}{|L|(|L|-1)} \sum_{i \in L} \sum_{j \in L, j \neq i} (1 - \text{sim}(i, j))$$

Η καινοτομία (novelty) επιβραβεύει τη σύσταση λιγότερο δημοφιλών αντικειμένων, με βάση την αυτοπληροφορία τους:

$$\text{Novelty}(L) = -\frac{1}{|L|} \sum_{i \in L} \log_2 p(i)$$

όπου $p(i)$ η πιθανότητα (δημοφιλία) του αντικειμένου i .

5.5.5 Παράδειγμα υπολογισμού

Έστω ότι για έναν χρήστη το σύστημα επιστρέφει λίστα Top-5 και τα πραγματικά σχετικά αντικείμενα βρίσκονται στις θέσεις 1, 2 και 4 (μοτίβο σχετικότητας: 1,1,0,1,0), με συνολικά $|Ru| = 3$ σχετικά. Τότε: $\text{Precision@5} = 3/5 = 0,60$ και $\text{Recall@5} = 3/3 = 1,00$. Για το $\text{DCG@5} = 1/\log_2(2) + 1/\log_2(3) + 0 + 1/\log_2(5) + 0 = 1 + 0,631 + 0,431 = 2,062$. Η ιδανική κατάταξη (1,1,1,0,0) δίνει $\text{IDCG@5} = 1 + 0,631 + 0,500 = 2,131$, οπότε $\text{NDCG@5} = 2,062 / 2,131 = 0,968$. Οι υψηλές τιμές υποδεικνύουν ότι τα σχετικά αντικείμενα κατατάχθηκαν κοντά στην κορυφή.

5.6 Βιβλιογραφική αποτίμηση

Οι μετρικές που παρουσιάστηκαν αποτελούν το καθιερωμένο πλαίσιο αξιολόγησης της βιβλιογραφίας. Οι μετρικές ακρίβειας (MAE, RMSE) κυριάρχησαν στην εποχή του Netflix Prize (Koren et al., 2009), ενώ η στροφή προς μετρικές κατάταξης (Precision@k , MAP, NDCG) αντανακλά τη συνειδητοποίηση ότι η πραγματική αξία ενός συστήματος έγκειται στην ποιότητα της Top-N λίστας και όχι στην ακριβή πρόβλεψη βαθμολογίας (Herlocker et al., 2004). Οι μετρικές πέραν της ακρίβειας αναδείχθηκαν πιο πρόσφατα, καθώς αναγνωρίστηκε ότι η υπερβολική εστίαση στην ακρίβεια οδηγεί σε ομοιόμορφες, προβλέψιμες συστάσεις εις βάρος της ικανοποίησης του χρήστη.

ΚΕΦΑΛΑΙΟ 6: Σύγχρονες Τάσεις και Μελλοντικές Κατευθύνσεις

6.1 Χρήση βαθιάς μάθησης στα σύγχρονα συστήματα συστάσεων

Η βαθιά μάθηση αποτελεί μία από τις σημαντικότερες σύγχρονες τάσεις στον τομέα των συστημάτων συστάσεων, καθώς έχει μεταβάλει ουσιαστικά τον τρόπο με τον οποίο αναπαρίστανται οι χρήστες, τα αντικείμενα και οι μεταξύ τους αλληλεπιδράσεις. Σε αντίθεση με τις παραδοσιακές τεχνικές, οι οποίες βασίζονται συχνά σε γραμμικές συσχετίσεις ή σε χειροκίνητα καθορισμένα χαρακτηριστικά, τα μοντέλα βαθιάς μάθησης μπορούν να μαθαίνουν αυτόματα σύνθετες, μη γραμμικές και πολυεπίπεδες αναπαραστάσεις από μεγάλα σύνολα δεδομένων. Η δυνατότητα αυτή είναι ιδιαίτερα σημαντική για τα σύγχρονα ψηφιακά περιβάλλοντα, όπου οι χρήστες αλληλεπιδρούν συνεχώς με διαφορετικούς τύπους περιεχομένου, όπως κείμενο, εικόνες, βίντεο, μουσική, προϊόντα και κοινωνικές πληροφορίες (Zhang et al., 2019). Η χρήση βαθιάς μάθησης στα συστήματα συστάσεων συνδέεται άμεσα με την ανάγκη αντιμετώπισης της πολυπλοκότητας και της ετερογένειας των σύγχρονων δεδομένων. Οι παραδοσιακές μέθοδοι συνεργατικού φιλτραρίσματος και παραγοντοποίησης πινάκων υπήρξαν ιδιαίτερα αποτελεσματικές, όμως συχνά δυσκολεύονται να αποτυπώσουν πολύπλοκες σχέσεις μεταξύ χρηστών και αντικειμένων. Οι προτιμήσεις των χρηστών δεν είναι πάντοτε γραμμικές ή σταθερές, αλλά εξαρτώνται από πολλούς παράγοντες, όπως το ιστορικό συμπεριφοράς, το περιεχόμενο των αντικειμένων, το πλαίσιο χρήσης και οι χρονικές μεταβολές. Τα βαθιά νευρωνικά δίκτυα προσφέρουν τη δυνατότητα μοντελοποίησης αυτών των σύνθετων σχέσεων, βελτιώνοντας την ακρίβεια και την εξατομίκευση των προτάσεων (Koren et al., 2009; Zhou et al., 2023).

Ένα από τα βασικά πλεονεκτήματα της βαθιάς μάθησης είναι η ικανότητα αυτόματης εξαγωγής χαρακτηριστικών. Στα συστήματα βασισμένα σε περιεχόμενο, η ποιότητα των προτάσεων εξαρτάται σε μεγάλο βαθμό από την ποιότητα των διαθέσιμων μεταδεδομένων και των χαρακτηριστικών που περιγράφουν τα αντικείμενα. Με τη χρήση βαθιών νευρωνικών δικτύων, το σύστημα μπορεί να εξάγει μόνο του χρήσιμες αναπαραστάσεις από μη δομημένα δεδομένα, όπως κείμενο, εικόνες και βίντεο. Αυτό μειώνει την ανάγκη χειροκίνητης επεξεργασίας χαρακτηριστικών και επιτρέπει την αξιοποίηση πλουσιότερων μορφών πληροφορίας, ενισχύοντας την αποτελεσματικότητα των συστάσεων σε σύνθετα περιβάλλοντα (Zhang et al., 2019; Li et al., 2023). Η εφαρμογή της βαθιάς μάθησης έχει επηρεάσει ιδιαίτερα τα συνεργατικά συστήματα συστάσεων. Παραδοσιακά, το συνεργατικό φιλτράρισμα βασιζόταν στον εντοπισμό ομοιοτήτων μεταξύ χρηστών ή αντικειμένων, ενώ οι τεχνικές παραγοντοποίησης πινάκων επιδίωκαν να ανακαλύψουν λανθάνοντες παράγοντες που εξηγούν τις αξιολογήσεις. Αν και οι

τεχνικές αυτές παραμένουν σημαντικές, τα νευρωνικά μοντέλα επιτρέπουν την εκμάθηση πιο σύνθετων αλληλεπιδράσεων. Το Neural Collaborative Filtering αποτελεί χαρακτηριστικό παράδειγμα αυτής της μετάβασης, καθώς αντικαθιστά τη γραμμική αλληλεπίδραση χρήστη-αντικειμένου με νευρωνικά δίκτυα που μπορούν να μοντελοποιήσουν μη γραμμικές σχέσεις και να βελτιώσουν την ποιότητα των προβλέψεων (He et al., 2017).

Η βαθιά μάθηση έχει επίσης συμβάλει καθοριστικά στην ανάπτυξη υβριδικών συστημάτων συστάσεων. Τα υβριδικά μοντέλα μπορούν να συνδυάζουν συνεργατικά δεδομένα, χαρακτηριστικά περιεχομένου, συμφραζόμενες πληροφορίες και ιστορικά αλληλεπιδράσεων μέσα σε ένα ενιαίο πλαίσιο μάθησης. Με αυτόν τον τρόπο, επιτυγχάνεται καλύτερη αξιοποίηση της διαθέσιμης πληροφορίας και μειώνονται προβλήματα όπως η ψυχρή εκκίνηση και η αραιότητα των δεδομένων. Η δυνατότητα συνδυασμού πολλαπλών πηγών δεδομένων αποτελεί βασικό λόγο για τον οποίο τα μοντέλα βαθιάς μάθησης έχουν κυριαρχήσει σε πολλές σύγχρονες εφαρμογές συστάσεων (Zhang et al., 2019; Zhou et al., 2023). Ιδιαίτερο ενδιαφέρον παρουσιάζει η αρχιτεκτονική Wide & Deep, η οποία αποτελεί χαρακτηριστικό παράδειγμα συνδυασμού παραδοσιακών και βαθιών τεχνικών μάθησης. Το «wide» μέρος του μοντέλου επιτρέπει την απομνημόνευση γνωστών συσχετίσεων, ενώ το «deep» μέρος επιτρέπει τη γενίκευση και την ανακάλυψη νέων προτύπων. Η συγκεκριμένη προσέγγιση είναι ιδιαίτερα χρήσιμη στα συστήματα συστάσεων, καθώς οι προτάσεις απαιτούν ταυτόχρονα αξιοποίηση προηγούμενης γνώσης και προσαρμογή σε νέες περιπτώσεις. Με αυτόν τον τρόπο, τα συστήματα μπορούν να επιτυγχάνουν υψηλή ακρίβεια χωρίς να χάνουν τη δυνατότητα γενίκευσης σε νέους χρήστες ή αντικείμενα (Cheng et al., 2016).

Η χρήση βαθιάς μάθησης σε πλατφόρμες μεγάλης κλίμακας έχει αναδείξει την πρακτική αξία αυτών των τεχνικών. Στο YouTube, για παράδειγμα, τα βαθιά νευρωνικά δίκτυα αξιοποιούνται για την επιλογή και κατάταξη βίντεο μέσα από τεράστιο όγκο διαθέσιμου περιεχομένου. Το σύστημα πρέπει να λαμβάνει υπόψη το ιστορικό προβολών, τις αλληλεπιδράσεις των χρηστών, τα χαρακτηριστικά των βίντεο και τις μεταβαλλόμενες προτιμήσεις, παράγοντας εξατομικευμένες συστάσεις σε πραγματικό χρόνο. Η εφαρμογή αυτή δείχνει ότι η βαθιά μάθηση δεν αποτελεί μόνο θεωρητική πρόοδο, αλλά πρακτική λύση για συστήματα με πολύ υψηλές απαιτήσεις κλιμάκωσης και απόδοσης (Covington et al., 2016). Ένα ακόμη θετικό των βαθιών μοντέλων είναι η δυνατότητα βελτίωσης της εξατομίκευσης. Μέσω της εκμάθησης σύνθετων αναπαραστάσεων, τα συστήματα μπορούν να κατανοούν καλύτερα τις ιδιαίτερες προτιμήσεις κάθε χρήστη και να παράγουν προτάσεις που ανταποκρίνονται σε πιο λεπτές διαφοροποιήσεις ενδιαφερόντων. Αυτό είναι ιδιαίτερα σημαντικό σε περιβάλλοντα όπου οι χρήστες έχουν διαφορετικά μοτίβα συμπεριφοράς και όπου η απλή σύγκριση αξιολογήσεων δεν επαρκεί για

την κατανόηση των αναγκών τους. Η βαθιά μάθηση επιτρέπει στα συστήματα να προσαρμόζονται καλύτερα σε αυτές τις διαφοροποιήσεις και να παρέχουν πιο ακριβείς προτάσεις (Zhang et al., 2019; Li et al., 2023).

Εκτός των ανωτέρω, τα βαθιά μοντέλα μπορούν να αξιοποιήσουν δεδομένα έμμεσης ανατροφοδότησης, τα οποία κυριαρχούν στις σύγχρονες εφαρμογές. Οι χρήστες συχνά δεν παρέχουν ρητές αξιολογήσεις, αλλά αφήνουν ίχνη συμπεριφοράς μέσα από κλικ, προβολές, αγορές και χρόνο παραμονής. Η βαθιά μάθηση επιτρέπει την ανάλυση αυτών των σημάτων και τη μετατροπή τους σε χρήσιμες αναπαραστάσεις προτιμήσεων. Με τον τρόπο αυτό, τα συστήματα μπορούν να μαθαίνουν συνεχώς από την πραγματική συμπεριφορά των χρηστών και να βελτιώνουν δυναμικά τις συστάσεις τους (Hu et al., 2008; Zhou et al., 2023). Η ενσωμάτωση βαθιάς μάθησης συνδέεται επίσης με την ανάπτυξη πιο προσαρμοστικών συστημάτων. Οι προτιμήσεις των χρηστών μεταβάλλονται με την πάροδο του χρόνου και τα σύγχρονα συστήματα πρέπει να ανταποκρίνονται γρήγορα σε αυτές τις αλλαγές. Τα βαθιά μοντέλα μπορούν να ενημερώνονται με νέα δεδομένα και να προσαρμόζουν τις αναπαραστάσεις τους, ενώ σε συνδυασμό με τεχνικές χρονικής μοντελοποίησης μπορούν να αποτυπώνουν καλύτερα τις μεταβολές στη συμπεριφορά των χρηστών. Η ανάγκη αυτή είναι ιδιαίτερα εμφανής σε εφαρμογές ψυχαγωγίας και ηλεκτρονικού εμπορίου, όπου τα ενδιαφέροντα των χρηστών μπορεί να αλλάζουν γρήγορα (Koren, 2010; Chen et al., 2021).

Η ενισχυτική μάθηση αποτελεί μία επιπλέον κατεύθυνση που συνδέεται με τα σύγχρονα βαθιά συστήματα συστάσεων. Μέσω της βαθιάς ενισχυτικής μάθησης, η διαδικασία σύστασης μπορεί να αντιμετωπιστεί ως ακολουθία αποφάσεων, όπου το σύστημα μαθαίνει ποιες προτάσεις οδηγούν σε καλύτερα αποτελέσματα σε βάθος χρόνου. Αντί να επικεντρώνεται μόνο στην άμεση πιθανότητα κλικ ή αγοράς, το σύστημα μπορεί να επιδιώκει τη μακροχρόνια ικανοποίηση και εμπλοκή του χρήστη. Η προσέγγιση αυτή θεωρείται ιδιαίτερα σημαντική για το μέλλον των συστημάτων συστάσεων, καθώς επιτρέπει πιο δυναμική και στρατηγική προσαρμογή των προτάσεων (Chen et al., 2021). Θα πρέπει όμως να ληφθεί υπόψη πως η χρήση βαθιάς μάθησης στα συστήματα συστάσεων συνοδεύεται και από σημαντικές προκλήσεις. Τα βαθιά μοντέλα απαιτούν συνήθως μεγάλο όγκο δεδομένων και υψηλή υπολογιστική ισχύ, γεγονός που μπορεί να περιορίσει την εφαρμογή τους σε μικρότερα συστήματα ή οργανισμούς με περιορισμένους πόρους. Περαιτέρω, η πολυπλοκότητά τους καθιστά δυσκολότερη την κατανόηση του τρόπου με τον οποίο παράγονται οι προτάσεις. Η περιορισμένη ερμηνευσιμότητα αποτελεί σημαντικό ζήτημα, καθώς οι χρήστες και οι διαχειριστές συστημάτων συχνά χρειάζονται σαφείς εξηγήσεις για τους λόγους που ένα αντικείμενο προτείνεται (Zhang & Chen, 2020).

Η ανάγκη για διαφάνεια και εμπιστοσύνη είναι ιδιαίτερα σημαντική στα σύγχρονα συστήματα που βασίζονται σε βαθιά μάθηση. Η υψηλή ακρίβεια δεν αρκεί από μόνη της για την επιτυχία ενός συστήματος, εάν οι χρήστες δεν εμπιστεύονται τις προτάσεις που λαμβάνουν. Για τον λόγο αυτό, η ανάπτυξη επεξηγήσιμων μοντέλων και μηχανισμών αιτιολόγησης αποτελεί βασική μελλοντική κατεύθυνση. Τα συστήματα πρέπει να μπορούν να παρέχουν όχι μόνο σωστές αλλά και κατανοητές προτάσεις, ενισχύοντας τη διαφάνεια, την αποδοχή και τη μακροχρόνια χρήση τους (Zhang & Chen, 2020; Akdim et al., 2025).

Ένα ακόμη ζήτημα αφορά την ισορροπία μεταξύ ακρίβειας και άλλων ποιοτικών στόχων. Τα βαθιά μοντέλα συχνά βελτιστοποιούνται με βάση δείκτες ακρίβειας ή εμπλοκής, όμως τα σύγχρονα συστήματα συστάσεων πρέπει να λαμβάνουν υπόψη και άλλες διαστάσεις, όπως η ποικιλία, η καινοτομία, η δικαιοσύνη και η ικανοποίηση των χρηστών. Η ανάπτυξη πολυστοχικών προσεγγίσεων που ενσωματώνουν βαθιά μάθηση αποτελεί σημαντική ερευνητική τάση, καθώς επιτρέπει την παραγωγή συστάσεων που είναι όχι μόνο ακριβείς αλλά και πιο χρήσιμες, ισορροπημένες και ανθρωποκεντρικές (Jannach et al., 2023).

6.2 Επεξηγήσιμα συστήματα συστάσεων

Η ραγδαία ανάπτυξη των συστημάτων συστάσεων τα τελευταία χρόνια έχει οδηγήσει στη δημιουργία ολοένα και πιο σύνθετων αλγοριθμικών μοντέλων, τα οποία είναι σε θέση να παράγουν εξαιρετικά ακριβείς και εξατομικευμένες προτάσεις. Όμως, η αυξανόμενη πολυπλοκότητα αυτών των συστημάτων έχει δημιουργήσει σημαντικές προκλήσεις όσον αφορά την κατανόηση του τρόπου με τον οποίο λαμβάνονται οι αποφάσεις τους. Πολλά σύγχρονα μοντέλα, ιδιαίτερα εκείνα που βασίζονται στη βαθιά μάθηση, λειτουργούν ως «μαύρα κουτιά», γεγονός που δυσκολεύει τόσο τους χρήστες όσο και τους σχεδιαστές των συστημάτων να κατανοήσουν τους λόγους για τους οποίους προτείνεται ένα συγκεκριμένο αντικείμενο. Η ανάγκη αντιμετώπισης αυτού του προβλήματος οδήγησε στην ανάπτυξη των επεξηγήσιμων συστημάτων συστάσεων (Explainable Recommender Systems – XRS), τα οποία επιδιώκουν να συνδυάσουν την αποτελεσματικότητα των σύγχρονων αλγορίθμων με τη δυνατότητα παροχής κατανοητών και διαφανών εξηγήσεων προς τους χρήστες (Zhang & Chen, 2020). Η βασική φιλοσοφία των επεξηγήσιμων συστημάτων συστάσεων στηρίζεται στην παραδοχή ότι οι χρήστες δεν ενδιαφέρονται μόνο για το αποτέλεσμα μιας σύστασης αλλά και για τη διαδικασία που οδήγησε σε αυτήν. Όταν ένα σύστημα προτείνει ένα προϊόν, μια ταινία, ένα βιβλίο ή ένα βίντεο, οι χρήστες συχνά επιθυμούν να γνωρίζουν ποια χαρακτηριστικά, προτιμήσεις ή προηγούμενες αλληλεπιδράσεις συνέβαλαν στη συγκεκριμένη πρόταση. Η παροχή τέτοιων πληροφοριών

επιτρέπει την καλύτερη κατανόηση της λειτουργίας του συστήματος και ενισχύει την αίσθηση ελέγχου του χρήστη κατά τη διαδικασία λήψης αποφάσεων (Zhang & Chen, 2020).

Η σημασία των επεξηγήσεων συνδέεται άμεσα με τη διαφάνεια των ευφυών συστημάτων. Καθώς οι αλγόριθμοι τεχνητής νοημοσύνης επηρεάζουν ολοένα και περισσότερο τις επιλογές των χρηστών σε διάφορους τομείς της καθημερινής ζωής, η ανάγκη για διαφανείς και κατανοητές διαδικασίες λήψης αποφάσεων γίνεται ολοένα πιο επιτακτική. Τα συστήματα συστάσεων δεν αποτελούν εξαίρεση, καθώς επηρεάζουν σημαντικά την κατανάλωση πληροφοριών, τις αγορές προϊόντων, την επιλογή ψυχαγωγικού περιεχομένου και πλήθος άλλων δραστηριοτήτων. Η δυνατότητα κατανόησης των συστάσεων συμβάλλει στην αποδοχή των αποτελεσμάτων και μειώνει την αβεβαιότητα που μπορεί να δημιουργεί η λειτουργία σύνθετων αλγοριθμικών μοντέλων (Akdim et al., 2025). Ένα από τα σημαντικότερα οφέλη των επεξηγήσιμων συστημάτων είναι η ενίσχυση της εμπιστοσύνης των χρηστών. Η εμπιστοσύνη αποτελεί κρίσιμο παράγοντα για την επιτυχία κάθε συστήματος συστάσεων, καθώς επηρεάζει άμεσα την πιθανότητα οι χρήστες να ακολουθήσουν τις παρεχόμενες προτάσεις και να συνεχίσουν να χρησιμοποιούν την πλατφόρμα. Όταν οι χρήστες κατανοούν τους λόγους που οδήγησαν σε μία σύσταση, είναι περισσότερο πιθανό να θεωρήσουν το σύστημα αξιόπιστο και να αποδεχθούν τις προτάσεις του. Αντίθετα, η έλλειψη διαφάνειας μπορεί να δημιουργήσει αμφιβολίες και να μειώσει την αποτελεσματικότητα ακόμη και ενός τεχνικά άρτιου συστήματος (Akdim et al., 2025).

Οι πρώτες μορφές επεξήγησης εμφανίστηκαν στα παραδοσιακά συστήματα συστάσεων που βασίζονταν σε συνεργατικό φιλτράρισμα ή σε χαρακτηριστικά περιεχομένου. Στα συστήματα αυτά, οι εξηγήσεις μπορούσαν να βασιστούν σε σχετικά απλούς μηχανισμούς, όπως η αναφορά παρόμοιων χρηστών ή κοινών χαρακτηριστικών μεταξύ αντικειμένων. Για παράδειγμα, ένα σύστημα μπορούσε να ενημερώνει τον χρήστη ότι ένα προϊόν προτείνεται επειδή χρήστες με παρόμοιες προτιμήσεις το αξιολόγησαν θετικά ή επειδή παρουσιάζει χαρακτηριστικά αντίστοιχα με αντικείμενα που έχει επιλέξει στο παρελθόν. Οι εξηγήσεις αυτές ήταν σχετικά εύκολες στην κατανόηση και συνέβαλαν στη βελτίωση της διαφάνειας των συστημάτων (Adomavicius & Tuzhilin, 2005). Παρόλα αυτά, η μετάβαση προς πιο σύνθετες τεχνικές, όπως οι μέθοδοι παραγοντοποίησης πινάκων και τα βαθιά νευρωνικά δίκτυα, δημιούργησε νέες προκλήσεις. Οι τεχνικές αυτές βασίζονται σε λανθάνοντες παράγοντες και πολύπλοκες μαθηματικές αναπαραστάσεις που δεν είναι εύκολα ερμηνεύσιμες από τον άνθρωπο. Παρότι προσφέρουν σημαντικές βελτιώσεις στην ακρίβεια των προτάσεων, η κατανόηση του τρόπου με τον οποίο παράγονται οι συστάσεις καθίσταται δυσκολότερη. Ως αποτέλεσμα, η ανάγκη ανάπτυξης νέων

μεθόδων επεξήγησης έχει αναδειχθεί σε μία από τις σημαντικότερες ερευνητικές κατευθύνσεις στον χώρο των συστημάτων συστάσεων (Zhang & Chen, 2020).

Η βαθιά μάθηση αποτελεί χαρακτηριστικό παράδειγμα της σύγκρουσης μεταξύ απόδοσης και ερμηνευσιμότητας. Τα βαθιά νευρωνικά δίκτυα έχουν αποδειχθεί ιδιαίτερα αποτελεσματικά στην αναγνώριση σύνθετων προτύπων και στην παραγωγή εξατομικευμένων προτάσεων, ωστόσο η εσωτερική τους λειτουργία είναι συχνά δύσκολο να ερμηνευθεί. Οι αναπαραστάσεις που δημιουργούνται στα πολλαπλά επίπεδα των νευρωνικών δικτύων δεν αντιστοιχούν πάντοτε σε έννοιες κατανοητές από τον άνθρωπο, γεγονός που περιορίζει τη δυνατότητα παροχής σαφών εξηγήσεων. Η αντιμετώπιση αυτής της πρόκλησης αποτελεί βασικό αντικείμενο της σύγχρονης έρευνας στην τεχνητή νοημοσύνη και στα συστήματα συστάσεων (Zhang et al., 2019; Zhou et al., 2023). Παρά τις δυσκολίες αυτές, έχουν αναπτυχθεί διάφορες τεχνικές που επιτρέπουν τη δημιουργία επεξηγήσεων ακόμη και σε περιβάλλοντα βαθιάς μάθησης. Οι προσεγγίσεις αυτές επιχειρούν να συνδέσουν τις εσωτερικές αναπαραστάσεις των μοντέλων με χαρακτηριστικά που μπορούν να γίνουν κατανοητά από τους χρήστες. Μέσω της ανάλυσης των σημαντικότερων παραγόντων που επηρεάζουν μία πρόβλεψη, τα συστήματα μπορούν να παρέχουν πληροφορίες σχετικά με τα χαρακτηριστικά των αντικειμένων, τα πρότυπα συμπεριφοράς ή τις προηγούμενες αλληλεπιδράσεις που συνέβαλαν στην παραγωγή της πρότασης. Με αυτόν τον τρόπο, επιτυγχάνεται ένας βαθμός διαφάνειας χωρίς σημαντική απώλεια της απόδοσης των μοντέλων (Zhang & Chen, 2020). Η ανάπτυξη επεξηγήσιμων συστημάτων συνδέεται επίσης με την ανάγκη ενίσχυσης της δικαιοσύνης και της λογοδοσίας των αλγοριθμικών συστημάτων. Καθώς οι συστάσεις επηρεάζουν ολοένα και περισσότερο σημαντικές αποφάσεις των χρηστών, η δυνατότητα ελέγχου και αξιολόγησης των αλγοριθμικών διαδικασιών αποκτά ιδιαίτερη σημασία. Οι επεξηγήσεις επιτρέπουν την ανίχνευση πιθανών προκαταλήψεων ή ανεπιθύμητων συμπεριφορών των συστημάτων και συμβάλλουν στη δημιουργία περισσότερο υπεύθυνων εφαρμογών τεχνητής νοημοσύνης (Akdin et al., 2025).

Επίσης, η παροχή εξηγήσεων μπορεί να βελτιώσει την αλληλεπίδραση μεταξύ χρήστη και συστήματος. Όταν οι χρήστες κατανοούν καλύτερα τον τρόπο λειτουργίας ενός συστήματος, είναι περισσότερο πιθανό να παρέχουν χρήσιμη ανατροφοδότηση και να αλληλεπιδρούν πιο ενεργά με τις προτάσεις που λαμβάνουν. Η διαδικασία αυτή δημιουργεί έναν θετικό κύκλο μάθησης, καθώς το σύστημα αποκτά πρόσθετες πληροφορίες για τις προτιμήσεις των χρηστών και μπορεί να βελτιώνει διαρκώς τις συστάσεις του (Zhang & Chen, 2020).

Η σημασία των επεξηγήσιμων συστημάτων γίνεται ιδιαίτερα εμφανής σε εφαρμογές όπου οι προτάσεις σχετίζονται με σημαντικές αποφάσεις ή ευαίσθητα δεδομένα. Σε τέτοια

περιβάλλοντα, οι χρήστες απαιτούν υψηλότερο επίπεδο διαφάνειας και λογοδοσίας σε σχέση με εφαρμογές ψυχαγωγίας ή γενικής κατανάλωσης περιεχομένου. Η δυνατότητα παροχής τεκμηριωμένων και κατανοητών εξηγήσεων θεωρείται κρίσιμη για τη διατήρηση της εμπιστοσύνης και της αποδοχής των συστημάτων τεχνητής νοημοσύνης από την κοινωνία (Akdim et al., 2025). Η σύγχρονη έρευνα προσανατολίζεται προς την ανάπτυξη συστημάτων που επιτυγχάνουν ισορροπία μεταξύ ακρίβειας και ερμηνευσιμότητας. Για πολλά χρόνια, οι δύο αυτοί στόχοι θεωρούνταν αντικρουόμενοι, καθώς τα πιο σύνθετα μοντέλα παρείχαν καλύτερες επιδόσεις αλλά μικρότερη δυνατότητα επεξήγησης. Σήμερα, όμως, αναπτύσσονται νέες προσεγγίσεις που επιχειρούν να συνδυάσουν τα πλεονεκτήματα των προηγμένων τεχνικών μάθησης με αποτελεσματικούς μηχανισμούς επεξήγησης, επιτρέποντας τη δημιουργία συστημάτων που είναι ταυτόχρονα ακριβή και διαφανή (Zhang & Chen, 2020).

Τέλος, η ενσωμάτωση πολυστοχικών κριτηρίων αξιολόγησης έχει ενισχύσει το ενδιαφέρον για τις επεξηγήσεις. Τα σύγχρονα συστήματα δεν αξιολογούνται πλέον αποκλειστικά με βάση την ακρίβεια, αλλά και σύμφωνα με παράγοντες όπως η εμπιστοσύνη, η δικαιοσύνη, η ποικιλία και η ικανοποίηση των χρηστών. Η επεξηγησιμότητα αποτελεί πλέον βασική διάσταση της συνολικής ποιότητας ενός συστήματος συστάσεων και αναμένεται να διαδραματίσει ακόμη σημαντικότερο ρόλο στις μελλοντικές εφαρμογές τεχνητής νοημοσύνης (Jannach et al., 2023).

6.3 Ζητήματα ιδιωτικότητας και ηθικής στη χρήση δεδομένων

Η ραγδαία ανάπτυξη των συστημάτων συστάσεων και η αυξανόμενη ενσωμάτωσή τους σε ψηφιακές πλατφόρμες έχουν δημιουργήσει σημαντικά οφέλη τόσο για τους χρήστες όσο και για τους οργανισμούς που τα αξιοποιούν. Μέσω της ανάλυσης μεγάλων όγκων δεδομένων, τα συστήματα αυτά είναι σε θέση να παρέχουν εξατομικευμένες προτάσεις, να βελτιώνουν την εμπειρία των χρηστών και να διευκολύνουν τη λήψη αποφάσεων σε ένα περιβάλλον έντονου πληροφοριακού φόρτου. Ωστόσο, η αποτελεσματικότητά τους βασίζεται σε μεγάλο βαθμό στη συλλογή, αποθήκευση και επεξεργασία προσωπικών δεδομένων, γεγονός που δημιουργεί σημαντικά ζητήματα ιδιωτικότητας, διαφάνειας και ηθικής. Καθώς οι τεχνικές τεχνητής νοημοσύνης γίνονται ολοένα πιο ισχυρές και οι δυνατότητες ανάλυσης δεδομένων αυξάνονται, οι προβληματισμοί σχετικά με τη χρήση προσωπικών πληροφοριών αποκτούν κεντρική θέση στη σύγχρονη έρευνα και πρακτική των συστημάτων συστάσεων (Akdim et al., 2025).

Η λειτουργία των συστημάτων συστάσεων προϋποθέτει συνήθως τη συλλογή μεγάλου όγκου πληροφοριών σχετικά με τους χρήστες. Τα δεδομένα αυτά μπορεί να περιλαμβάνουν αξιολογήσεις, ιστορικό αγορών, αναζητήσεις, προτιμήσεις περιεχομένου, τοποθεσία, δημογραφικά χαρακτηριστικά και πλήθος άλλων μορφών αλληλεπίδρασης. Μέσω της ανάλυσης

αυτών των πληροφοριών δημιουργούνται λεπτομερή προφίλ χρηστών, τα οποία επιτρέπουν την παραγωγή εξατομικευμένων προτάσεων. Παρότι η διαδικασία αυτή συμβάλλει σημαντικά στη βελτίωση της ποιότητας των συστάσεων, ταυτόχρονα δημιουργεί ανησυχίες σχετικά με το εύρος και τον τρόπο χρήσης των προσωπικών δεδομένων (Adomavicius & Tuzhilin, 2005). Η ιδιωτικότητα αποτελεί θεμελιώδες δικαίωμα των χρηστών και βασική προϋπόθεση για την ασφαλή χρήση ψηφιακών υπηρεσιών. Στο πλαίσιο των συστημάτων συστάσεων, η προστασία της ιδιωτικότητας συνδέεται με την ανάγκη διασφάλισης ότι οι προσωπικές πληροφορίες συλλέγονται και χρησιμοποιούνται με διαφανή, νόμιμο και υπεύθυνο τρόπο. Οι χρήστες συχνά δεν γνωρίζουν την έκταση των δεδομένων που καταγράφονται ούτε τον τρόπο με τον οποίο αυτά αξιοποιούνται για τη δημιουργία προφίλ και την παραγωγή συστάσεων. Η έλλειψη αυτής της γνώσης μπορεί να οδηγήσει σε μειωμένη εμπιστοσύνη προς τις ψηφιακές πλατφόρμες και να επηρεάσει αρνητικά την αποδοχή των συστημάτων συστάσεων (Akdim et al., 2025).

Ένα από τα σημαντικότερα ζητήματα αφορά τον κίνδυνο αποκάλυψης ευαίσθητων πληροφοριών μέσω της ανάλυσης δεδομένων. Ακόμη και όταν οι χρήστες δεν παρέχουν άμεσα συγκεκριμένα προσωπικά στοιχεία, οι αλγόριθμοι μπορούν συχνά να εξαγάγουν συμπεράσματα σχετικά με τις προτιμήσεις, τις συνήθειες, τις πολιτικές απόψεις ή άλλες προσωπικές πτυχές της ζωής τους. Η δυνατότητα αυτή ενισχύεται ιδιαίτερα από τις σύγχρονες τεχνικές μηχανικής μάθησης και βαθιάς μάθησης, οι οποίες είναι σε θέση να αναγνωρίζουν σύνθετα πρότυπα και κρυφές συσχετίσεις μέσα σε μεγάλα σύνολα δεδομένων (Zhang et al., 2019; Zhou et al., 2023). Η αυξανόμενη χρήση δεδομένων έμμεσης ανατροφοδότησης έχει εντείνει περαιτέρω τους προβληματισμούς σχετικά με την ιδιωτικότητα. Στις περισσότερες σύγχρονες εφαρμογές, οι χρήστες δεν παρέχουν μόνο ρητές αξιολογήσεις αλλά δημιουργούν συνεχώς ψηφιακά ίχνη μέσω των κλικ, των προβολών, των αγορών, του χρόνου παραμονής σε μία σελίδα και άλλων μορφών αλληλεπίδρασης. Τα δεδομένα αυτά θεωρούνται ιδιαίτερα πολύτιμα για τη βελτίωση της ακρίβειας των συστημάτων συστάσεων, καθώς αποτυπώνουν τη φυσική συμπεριφορά των χρηστών. Θα πρέπει πάραυτα να σημειωθεί πως, η συνεχής συλλογή τους δημιουργεί ανησυχίες σχετικά με τον βαθμό παρακολούθησης και επιτήρησης που υφίστανται οι χρήστες κατά τη χρήση ψηφιακών υπηρεσιών (Hu et al., 2008).

Ένα ακόμη σημαντικό ηθικό ζήτημα αφορά τη διαφάνεια των αλγορίθμων. Πολλά σύγχρονα συστήματα συστάσεων βασίζονται σε σύνθετα μοντέλα βαθιάς μάθησης, τα οποία συχνά λειτουργούν ως «μαύρα κουτιά». Οι χρήστες ενδέχεται να μην γνωρίζουν γιατί τους προτείνεται συγκεκριμένο περιεχόμενο ή πώς οι προηγούμενες ενέργειές τους επηρεάζουν τις μελλοντικές συστάσεις. Η έλλειψη διαφάνειας μπορεί να δημιουργήσει αίσθημα αβεβαιότητας και να περιορίσει την εμπιστοσύνη προς το σύστημα, ιδιαίτερα όταν οι συστάσεις επηρεάζουν

σημαντικές αποφάσεις (Zhang & Chen, 2020). Η ανάπτυξη επεξηγήσιμων συστημάτων συστάσεων έχει αναδειχθεί ως μία από τις βασικές στρατηγικές αντιμετώπισης αυτού του προβλήματος. Μέσω της παροχής κατανοητών εξηγήσεων σχετικά με τους λόγους που οδήγησαν σε μία σύσταση, τα συστήματα μπορούν να ενισχύσουν τη διαφάνεια και να προσφέρουν στους χρήστες μεγαλύτερο έλεγχο επί των δεδομένων και των αποφάσεων που τους αφορούν. Η δυνατότητα κατανόησης της λειτουργίας ενός συστήματος θεωρείται πλέον βασικό στοιχείο της ηθικής και υπεύθυνης χρήσης της τεχνητής νοημοσύνης (Zhang & Chen, 2020).

Ιδιαίτερη σημασία παρουσιάζει επίσης το ζήτημα της αλγοριθμικής προκατάληψης. Τα συστήματα συστάσεων εκπαιδεύονται πάνω σε ιστορικά δεδομένα που συχνά αντανακλούν κοινωνικές, πολιτισμικές ή οικονομικές ανισότητες. Ως αποτέλεσμα, οι αλγόριθμοι μπορεί να αναπαράγουν ή ακόμη και να ενισχύουν υφιστάμενες προκαταλήψεις, οδηγώντας σε άνιση μεταχείριση συγκεκριμένων ομάδων χρηστών ή αντικειμένων. Η πρόκληση αυτή έχει αποκτήσει ιδιαίτερη σημασία καθώς τα συστήματα συστάσεων χρησιμοποιούνται ολοένα και περισσότερο σε κρίσιμους τομείς όπου η δικαιοσύνη και η ισότιμη πρόσβαση αποτελούν βασικές απαιτήσεις (Jannach et al., 2023). Σχετικό με το παραπάνω είναι και το φαινόμενο των «φουσκών πληροφορίας» (filter bubbles), το οποίο προκύπτει όταν τα συστήματα προτείνουν συνεχώς περιεχόμενο που ευθυγραμμίζεται με τις ήδη υπάρχουσες προτιμήσεις των χρηστών. Παρότι η εξατομίκευση αυξάνει τη συνάφεια των προτάσεων, ενδέχεται να περιορίζει την έκθεση σε εναλλακτικές απόψεις, διαφορετικά προϊόντα ή νέο περιεχόμενο. Η κατάσταση αυτή μπορεί να επηρεάσει αρνητικά την πολυφωνία της πληροφόρησης και να περιορίσει τις δυνατότητες ανακάλυψης νέων επιλογών από τους χρήστες (Adomavicius & Tuzhilin, 2005).

Η ανάπτυξη πολυστοχικών συστημάτων συστάσεων επιχειρεί να αντιμετωπίσει τέτοιου είδους προβλήματα μέσω της ενσωμάτωσης επιπλέον κριτηρίων πέρα από την ακρίβεια. Παράγοντες όπως η ποικιλία, η καινοτομία, η δικαιοσύνη και η ισορροπημένη έκθεση σε διαφορετικές επιλογές λαμβάνονται ολοένα περισσότερο υπόψη κατά τον σχεδιασμό των αλγορίθμων. Η προσέγγιση αυτή αντανακλά τη σύγχρονη αντίληψη ότι η ποιότητα ενός συστήματος συστάσεων δεν καθορίζεται μόνο από την ακρίβεια των προβλέψεών του αλλά και από τις ευρύτερες κοινωνικές και ηθικές συνέπειες της λειτουργίας του (Jannach et al., 2023). Πρέπει ωστόσο να σημειωθεί πως, η εμπιστοσύνη αποτελεί μία από τις σημαντικότερες διαστάσεις της ηθικής χρήσης δεδομένων. Οι χρήστες είναι περισσότερο πρόθυμοι να μοιραστούν προσωπικές πληροφορίες όταν θεωρούν ότι αυτές θα χρησιμοποιηθούν με υπεύθυνο και ασφαλή τρόπο. Αντίθετα, περιστατικά κατάχρησης δεδομένων ή αδιαφανών πρακτικών μπορούν να υπονομεύσουν σοβαρά τη σχέση εμπιστοσύνης μεταξύ χρηστών και ψηφιακών πλατφορμών. Η δημιουργία αξιόπιστων μηχανισμών προστασίας δεδομένων και η σαφής ενημέρωση των

χρηστών σχετικά με τις διαδικασίες επεξεργασίας αποτελούν βασικές προϋποθέσεις για τη διατήρηση αυτής της εμπιστοσύνης (Akdim et al., 2025).

Η χρήση βαθιάς μάθησης ενισχύει ακόμη περισσότερο τη σημασία των ζητημάτων ιδιωτικότητας και ηθικής. Τα βαθιά νευρωνικά δίκτυα έχουν τη δυνατότητα να αξιοποιούν τεράστιες ποσότητες δεδομένων και να εξάγουν πολύπλοκα πρότυπα συμπεριφοράς, γεγονός που βελτιώνει σημαντικά την ακρίβεια των συστάσεων. Παρόλα αυτά, η αυξημένη αυτή ικανότητα ανάλυσης ενδέχεται να οδηγήσει σε μεγαλύτερη συγκέντρωση προσωπικών πληροφοριών και σε δυσκολότερο έλεγχο της διαδικασίας λήψης αποφάσεων. Ως αποτέλεσμα, η ανάπτυξη μηχανισμών που συνδυάζουν υψηλή απόδοση με σεβασμό της ιδιωτικότητας αποτελεί βασική πρόκληση για τα μελλοντικά συστήματα συστάσεων (Zhang et al., 2019; Zhou et al., 2023). Η σύγχρονη έρευνα προσανατολίζεται προς την ανάπτυξη περισσότερο ανθρωποκεντρικών και υπεύθυνων συστημάτων συστάσεων. Οι νέες προσεγγίσεις δεν επικεντρώνονται αποκλειστικά στη βελτίωση της ακρίβειας, αλλά λαμβάνουν υπόψη παράγοντες όπως η διαφάνεια, η λογοδοσία, η προστασία της ιδιωτικότητας, η δικαιοσύνη και η ενίσχυση της εμπιστοσύνης. Η τάση αυτή αντανακλά τη γενικότερη στροφή της τεχνητής νοημοσύνης προς πιο ηθικές και κοινωνικά αποδεκτές μορφές ανάπτυξης και εφαρμογής (Akdim et al., 2025; Jannach et al., 2023).

6.4 Μελλοντικές ερευνητικές προοπτικές

Η συνεχής εξέλιξη των συστημάτων συστάσεων και η αυξανόμενη σημασία τους στα σύγχρονα ψηφιακά οικοσυστήματα δημιουργούν νέες προκλήσεις και ταυτόχρονα νέες ερευνητικές ευκαιρίες. Τα τελευταία χρόνια, οι σημαντικές πρόοδοι στην τεχνητή νοημοσύνη, τη μηχανική μάθηση και την ανάλυση μεγάλων δεδομένων έχουν βελτιώσει σημαντικά την αποτελεσματικότητα των συστημάτων συστάσεων, επιτρέποντας την παροχή ολοένα και πιο εξατομικευμένων και ακριβών προτάσεων. Παρά τη σημαντική αυτή πρόοδο, εξακολουθούν να υπάρχουν περιορισμοί που σχετίζονται με την ακρίβεια, την ερμηνευσιμότητα, την ιδιωτικότητα, τη δικαιοσύνη και την προσαρμοστικότητα των συστημάτων. Ως αποτέλεσμα, η σύγχρονη έρευνα επικεντρώνεται στην ανάπτυξη νέων προσεγγίσεων που θα επιτρέψουν τη δημιουργία περισσότερο ευφύων, αξιόπιστων και ανθρωποκεντρικών συστημάτων συστάσεων (Li et al., 2023).

Μία από τις σημαντικότερες μελλοντικές κατευθύνσεις αφορά την περαιτέρω αξιοποίηση της βαθιάς μάθησης. Τα βαθιά νευρωνικά δίκτυα έχουν ήδη μετασχηματίσει τον τρόπο με τον οποίο αναπαρίστανται οι χρήστες και τα αντικείμενα, επιτρέποντας την ανάλυση πολύπλοκων και ετερογενών δεδομένων. Ωστόσο, η έρευνα συνεχίζει να αναζητά νέες αρχιτεκτονικές που θα

μπορούν να εκμεταλλεύονται αποτελεσματικότερα τις διαθέσιμες πληροφορίες, να απαιτούν λιγότερα δεδομένα εκπαίδευσης και να προσαρμόζονται ταχύτερα σε μεταβαλλόμενα περιβάλλοντα. Η ανάπτυξη πιο αποδοτικών και ευέλικτων μοντέλων βαθιάς μάθησης αναμένεται να αποτελέσει βασικό πεδίο έρευνας τα επόμενα χρόνια (Zhang et al., 2019; Zhou et al., 2023). Επιπρόσθετα, ιδιαίτερο ενδιαφέρον παρουσιάζει η ενσωμάτωση πολυτροπικών δεδομένων στα συστήματα συστάσεων. Οι σύγχρονες ψηφιακές πλατφόρμες παράγουν δεδομένα διαφορετικών μορφών, όπως κείμενα, εικόνες, βίντεο, ήχο, κοινωνικές αλληλεπιδράσεις και δεδομένα συμφραζομένων. Η αξιοποίηση όλων αυτών των πηγών πληροφορίας σε ενιαία μοντέλα μπορεί να οδηγήσει σε βαθύτερη κατανόηση των προτιμήσεων των χρηστών και σε σημαντική βελτίωση της ποιότητας των προτάσεων. Η ανάπτυξη τεχνικών που επιτρέπουν την αποτελεσματική ενοποίηση και επεξεργασία πολυτροπικών δεδομένων αποτελεί μία από τις πλέον υποσχόμενες κατευθύνσεις της σύγχρονης έρευνας (Zhang et al., 2019; Zhou et al., 2023).

Ιδιαίτερη έμφαση δίνεται επίσης στη δυναμική προσαρμογή των συστημάτων σε πραγματικό χρόνο. Οι προτιμήσεις των χρηστών μεταβάλλονται συνεχώς και επηρεάζονται από το περιβάλλον, τη χρονική στιγμή και τις τρέχουσες ανάγκες τους. Η ανάπτυξη μοντέλων που μπορούν να προσαρμόζονται άμεσα στις νέες πληροφορίες και να ενημερώνουν δυναμικά τις συστάσεις τους αποτελεί σημαντική πρόκληση. Η δυνατότητα συνεχούς μάθησης και άμεσης προσαρμογής θεωρείται απαραίτητη για την επόμενη γενιά συστημάτων συστάσεων, ιδιαίτερα σε περιβάλλοντα υψηλής αλληλεπίδρασης και ταχείας μεταβολής των δεδομένων (Koren, 2010). Στο πλαίσιο αυτό, η ενισχυτική μάθηση αναμένεται να διαδραματίσει ολοένα σημαντικότερο ρόλο. Σε αντίθεση με τα παραδοσιακά μοντέλα που βασίζονται κυρίως σε ιστορικά δεδομένα, η ενισχυτική μάθηση επιτρέπει στα συστήματα να μαθαίνουν μέσα από τη συνεχή αλληλεπίδραση με τους χρήστες και να προσαρμόζουν τη στρατηγική τους ανάλογα με τα αποτελέσματα των προηγούμενων αποφάσεων. Η προσέγγιση αυτή δίνει τη δυνατότητα βελτιστοποίησης της μακροχρόνιας εμπειρίας των χρηστών και όχι μόνο της άμεσης απόκρισης σε μία συγκεκριμένη σύσταση. Η σύνδεση της βαθιάς μάθησης με την ενισχυτική μάθηση θεωρείται μία από τις σημαντικότερες μελλοντικές εξελίξεις στον τομέα των συστημάτων συστάσεων (Chen et al., 2021). Συμπληρωματικά, η έρευνα στρέφεται ολοένα περισσότερο προς την ανάπτυξη πολυστοχικών συστημάτων συστάσεων. Για πολλά χρόνια, η αξιολόγηση των συστημάτων βασιζόταν κυρίως στην ακρίβεια των προβλέψεων. Σήμερα, όμως, αναγνωρίζεται ότι η ποιότητα των συστάσεων εξαρτάται και από άλλους παράγοντες, όπως η ποικιλία, η καινοτομία, η δικαιοσύνη, η εμπιστοσύνη και η συνολική ικανοποίηση των χρηστών. Η μελλοντική έρευνα αναμένεται να επικεντρωθεί στην ανάπτυξη μοντέλων που θα μπορούν να βελτιστοποιούν

ταυτόχρονα πολλαπλούς και συχνά αντικρουόμενους στόχους, δημιουργώντας πιο ισορροπημένες και αποτελεσματικές προτάσεις (Jannach et al., 2023).

Μία ακόμη σημαντική ερευνητική κατεύθυνση αφορά τη βελτίωση της ερμηνευσιμότητας των συστημάτων συστάσεων. Η αυξανόμενη χρήση σύνθετων μοντέλων βαθιάς μάθησης έχει οδηγήσει σε σημαντικές βελτιώσεις της ακρίβειας, αλλά παράλληλα έχει δημιουργήσει προβλήματα διαφάνειας. Οι χρήστες επιθυμούν να γνωρίζουν γιατί τους προτείνεται ένα συγκεκριμένο αντικείμενο και να κατανοούν τη λογική πίσω από τις αποφάσεις του συστήματος. Ως αποτέλεσμα, η ανάπτυξη επεξηγήσιμων συστημάτων συστάσεων αναμένεται να αποτελέσει μία από τις κυρίαρχες ερευνητικές κατευθύνσεις των επόμενων ετών, καθώς συνδέεται άμεσα με την εμπιστοσύνη και την αποδοχή των αλγοριθμικών συστημάτων (Zhang & Chen, 2020). Η ενίσχυση της εμπιστοσύνης των χρηστών αποτελεί επίσης κεντρικό θέμα της μελλοντικής έρευνας. Η επιτυχία ενός συστήματος συστάσεων δεν εξαρτάται αποκλειστικά από την τεχνική του απόδοση αλλά και από τον βαθμό στον οποίο οι χρήστες το θεωρούν αξιόπιστο και δίκαιο. Η ανάπτυξη μηχανισμών που ενισχύουν τη διαφάνεια, την ερμηνευσιμότητα και τη λογοδοσία των συστημάτων αναμένεται να συμβάλει σημαντικά στη βελτίωση της εμπιστοσύνης και της αποδοχής τους από τους χρήστες (Akdin et al., 2025).

Τα ζητήματα ιδιωτικότητας και προστασίας προσωπικών δεδομένων αποτελούν μία ακόμη κρίσιμη ερευνητική πρόκληση. Καθώς τα συστήματα συστάσεων βασίζονται σε μεγάλους όγκους προσωπικών πληροφοριών, η ανάγκη ανάπτυξης τεχνικών που διασφαλίζουν την προστασία της ιδιωτικότητας γίνεται ολοένα πιο επιτακτική. Η μελλοντική έρευνα αναμένεται να επικεντρωθεί στη δημιουργία μεθόδων που επιτρέπουν την αξιοποίηση των δεδομένων χωρίς να τίθεται σε κίνδυνο η ασφάλεια και η ιδιωτική ζωή των χρηστών. Η ισορροπία μεταξύ εξατομίκευσης και προστασίας προσωπικών δεδομένων θεωρείται ένα από τα σημαντικότερα ζητήματα που θα απασχολήσουν τα συστήματα συστάσεων στο μέλλον (Akdin et al., 2025). Επίσης, η αντιμετώπιση της αλγοριθμικής προκατάληψης και η διασφάλιση της δικαιοσύνης αποτελούν αναδυόμενα πεδία έρευνας. Τα δεδομένα που χρησιμοποιούνται για την εκπαίδευση των αλγορίθμων συχνά περιλαμβάνουν κοινωνικές ή πολιτισμικές προκαταλήψεις, οι οποίες μπορούν να επηρεάσουν τις παραγόμενες προτάσεις. Η ανάπτυξη συστημάτων που λαμβάνουν υπόψη ζητήματα ισότητας και δικαιοσύνης αναμένεται να αποκτήσει ακόμη μεγαλύτερη σημασία καθώς οι συστάσεις επηρεάζουν ολοένα περισσότερες πτυχές της καθημερινής ζωής των χρηστών (Jannach et al., 2023).

Μία ιδιαίτερα ενδιαφέρουσα κατεύθυνση αφορά την περαιτέρω ανάπτυξη υβριδικών αρχιτεκτονικών. Οι υβριδικές προσεγγίσεις έχουν ήδη αποδείξει την αποτελεσματικότητά τους

συνδυάζοντας διαφορετικές τεχνικές μάθησης και πηγές δεδομένων. Στο μέλλον αναμένεται να αναπτυχθούν ακόμη πιο σύνθετα μοντέλα που θα ενσωματώνουν βαθιά μάθηση, συνεργατικό φιλτράρισμα, δεδομένα περιεχομένου, κοινωνικά δίκτυα και πληροφορίες συμφραζομένων μέσα σε ενιαία πλαίσια μάθησης. Η τάση αυτή αναμένεται να βελτιώσει περαιτέρω την ακρίβεια και την προσαρμοστικότητα των συστημάτων συστάσεων (Li et al., 2023). Η αυξανόμενη διάδοση ευφυών πρακτόρων και αυτόνομων συστημάτων δημιουργεί επίσης νέες προοπτικές για τα συστήματα συστάσεων. Οι ευφυείς πράκτορες μπορούν να λειτουργούν ως προσωπικοί βοηθοί που κατανοούν τις ανάγκες των χρηστών, αλληλεπιδρούν μαζί τους και λαμβάνουν πρωτοβουλίες για την παροχή εξατομικευμένων προτάσεων. Η σύνδεση των συστημάτων συστάσεων με τεχνολογίες ευφυών πρακτόρων αναμένεται να οδηγήσει σε πιο διαδραστικές και προσωποποιημένες εμπειρίες χρήσης (Maes, 1994; Maes, 1997; Wooldridge & Jennings, 1995).

Επιπλέον, η εξέλιξη των μεγάλων γλωσσικών μοντέλων και των συστημάτων γενετικής τεχνητής νοημοσύνης δημιουργεί νέες δυνατότητες για την παραγωγή πιο φυσικών και διαδραστικών συστάσεων. Τα μοντέλα αυτά μπορούν να κατανοούν καλύτερα τη γλώσσα των χρηστών, να ερμηνεύουν σύνθετες ανάγκες και να παράγουν εξατομικευμένες προτάσεις συνοδευόμενες από αναλυτικές εξηγήσεις. Αν και η συγκεκριμένη κατεύθυνση βρίσκεται ακόμη σε πρώιμο στάδιο ανάπτυξης, θεωρείται ιδιαίτερα υποσχόμενη για το μέλλον των συστημάτων συστάσεων και της αλληλεπίδρασης ανθρώπου-υπολογιστή (Li et al., 2023; Zhou et al., 2023). Η μελλοντική έρευνα αναμένεται επίσης να επικεντρωθεί στη βελτίωση της δυνατότητας γενίκευσης των συστημάτων σε διαφορετικά πεδία εφαρμογής. Τα περισσότερα σύγχρονα μοντέλα σχεδιάζονται για συγκεκριμένες κατηγορίες δεδομένων ή εφαρμογών, γεγονός που περιορίζει τη μεταφορά γνώσης μεταξύ διαφορετικών περιβαλλόντων. Η ανάπτυξη περισσότερο ευέλικτων και γενικεύσιμων συστημάτων θα επιτρέψει τη δημιουργία εφαρμογών που μπορούν να προσαρμόζονται αποτελεσματικά σε νέες συνθήκες με περιορισμένες απαιτήσεις εκπαίδευσης (Zhou et al., 2023).

ΚΕΦΑΛΑΙΟ 7: Συμπεράσματα

Η παρούσα εργασία εξέτασε τη χρήση ευφυών τεχνικών για την ανάπτυξη συστημάτων συστάσεων, αναδεικνύοντας τον καθοριστικό ρόλο που διαδραματίζουν οι τεχνολογίες τεχνητής νοημοσύνης στη σύγχρονη ψηφιακή εποχή. Τα συστήματα συστάσεων έχουν εξελιχθεί από απλούς μηχανισμούς φιλτραρίσματος πληροφορίας σε σύνθετα ευφυή συστήματα υποστήριξης αποφάσεων, τα οποία αξιοποιούν δεδομένα χρηστών, χαρακτηριστικά αντικειμένων και προηγμένους αλγορίθμους μάθησης για την παραγωγή εξατομικευμένων προτάσεων. Η σημασία τους είναι ιδιαίτερα έντονη σε περιβάλλοντα όπου ο όγκος της διαθέσιμης πληροφορίας είναι εξαιρετικά μεγάλος και η επιλογή σχετικού περιεχομένου καθίσταται δύσκολη για τον χρήστη. Μέσα σε αυτό το πλαίσιο, τα συστήματα συστάσεων συμβάλλουν ουσιαστικά στη μείωση της υπερπληροφόρησης, στη βελτίωση της εμπειρίας χρήσης και στην αποτελεσματικότερη διαχείριση των ψηφιακών επιλογών.

Από τη θεωρητική ανάλυση προέκυψε ότι τα συστήματα συστάσεων βασίζονται στη δυνατότητα συλλογής, επεξεργασίας και ερμηνείας δεδομένων που σχετίζονται με τις προτιμήσεις και τη συμπεριφορά των χρηστών. Οι βασικές κατηγορίες τους, όπως τα συστήματα βασισμένα σε περιεχόμενο, τα συνεργατικά συστήματα και τα υβριδικά συστήματα, παρουσιάζουν διαφορετικά πλεονεκτήματα και περιορισμούς. Τα content-based συστήματα προσφέρουν υψηλό βαθμό εξατομίκευσης και δυνατότητα ερμηνείας των προτάσεων, ενώ τα συνεργατικά συστήματα αξιοποιούν τη συλλογική γνώση των χρηστών για την ανακάλυψη προτύπων συμπεριφοράς. Τα υβριδικά συστήματα, συνδυάζοντας διαφορετικές πηγές πληροφορίας και τεχνικές, αποτελούν μία από τις πλέον αποτελεσματικές σύγχρονες προσεγγίσεις, καθώς μπορούν να μειώσουν προβλήματα όπως η ψυχρή εκκίνηση, η αραιότητα δεδομένων και η υπερεξειδίκευση των προτάσεων (Adomavicius & Tuzhilin, 2005; Li et al., 2023). Η μελέτη ανέδειξε επίσης ότι οι ευφυείς τεχνικές αποτελούν τον βασικό μηχανισμό εξέλιξης των συστημάτων συστάσεων. Η μηχανική μάθηση επιτρέπει στα συστήματα να μαθαίνουν από τα δεδομένα και να βελτιώνουν τις προβλέψεις τους με την πάροδο του χρόνου, ενώ η εξόρυξη δεδομένων συμβάλλει στην ανακάλυψη χρήσιμων προτύπων μέσα σε μεγάλα σύνολα πληροφοριών. Οι τεχνικές παραγοντοποίησης πινάκων και η αξιοποίηση έμμεσης ανατροφοδότησης έχουν ενισχύσει σημαντικά την ακρίβεια των συνεργατικών συστημάτων, επιτρέποντας την αποτελεσματικότερη ανάλυση σύνθετων σχέσεων μεταξύ χρηστών και αντικειμένων (Hu et al., 2008; Koren et al., 2009; Rendle et al., 2009). Ιδιαίτερη σημασία αποδόθηκε στη βαθιά μάθηση, η οποία έχει μετασχηματίσει ουσιαστικά τα σύγχρονα συστήματα συστάσεων. Τα βαθιά νευρωνικά δίκτυα επιτρέπουν την επεξεργασία ετερογενών δεδομένων,

όπως κείμενο, εικόνες, βίντεο και συμπεριφορικά δεδομένα, δημιουργώντας πιο σύνθετες και ακριβείς αναπαραστάσεις χρηστών και αντικειμένων. Προσεγγίσεις όπως το Neural Collaborative Filtering και τα μοντέλα Wide & Deep δείχνουν ότι η βαθιά μάθηση μπορεί να βελτιώσει σημαντικά την ακρίβεια, την προσαρμοστικότητα και τη δυνατότητα γενίκευσης των συστάσεων (Cheng et al., 2016; He et al., 2017; Zhang et al., 2019; Zhou et al., 2023).

Η αξιολόγηση των συστημάτων συστάσεων αποδείχθηκε ιδιαίτερα σύνθετη διαδικασία. Η ακρίβεια παραμένει βασικό κριτήριο, ωστόσο δεν επαρκεί από μόνη της για την πλήρη αποτίμηση της ποιότητας ενός συστήματος. Η ποικιλία, η καινοτομία, η κάλυψη, η προσαρμοστικότητα, η ερμηνευσιμότητα, η εμπιστοσύνη και η συνολική εμπειρία του χρήστη αποτελούν πλέον εξίσου σημαντικές διαστάσεις αξιολόγησης. Η σύγχρονη έρευνα στρέφεται προς πολυστοχικές προσεγγίσεις, οι οποίες επιδιώκουν την ισορροπία μεταξύ διαφορετικών και συχνά αντικρουόμενων στόχων, ώστε οι συστάσεις να είναι όχι μόνο ακριβείς αλλά και χρήσιμες, δίκαιες και αποδεκτές από τους χρήστες (Jannach et al., 2023). Παρά την πρόοδο που έχει επιτευχθεί, η εργασία ανέδειξε και σημαντικούς περιορισμούς. Το πρόβλημα της ψυχρής εκκίνησης εξακολουθεί να δυσκολεύει την παραγωγή προτάσεων για νέους χρήστες ή νέα αντικείμενα, ενώ η αραιότητα των δεδομένων περιορίζει την αποτελεσματικότητα πολλών συνεργατικών τεχνικών. Επιπροσθέτως, η υπερεξειδίκευση των προτάσεων μπορεί να περιορίσει την έκθεση των χρηστών σε νέο περιεχόμενο, δημιουργώντας στενούς κύκλους πληροφόρησης. Η αντιμετώπιση αυτών των περιορισμών απαιτεί τη συνδυαστική αξιοποίηση διαφορετικών τεχνικών, την ενσωμάτωση περισσότερων πηγών δεδομένων και την ανάπτυξη μοντέλων που λαμβάνουν υπόψη όχι μόνο τις προηγούμενες προτιμήσεις αλλά και τις μεταβαλλόμενες ανάγκες των χρηστών.

Ένα από τα μεγαλύτερα συμπεράσματα της εργασίας είναι ότι η αποτελεσματικότητα των συστημάτων συστάσεων δεν μπορεί να εξεταστεί αποκλειστικά με τεχνικούς όρους. Η εμπιστοσύνη, η διαφάνεια, η ερμηνευσιμότητα και η ηθική χρήση των δεδομένων αποτελούν πλέον κεντρικά ζητήματα. Οι χρήστες είναι περισσότερο πιθανό να αποδεχθούν και να αξιοποιήσουν τις προτάσεις ενός συστήματος όταν κατανοούν τη λογική πίσω από αυτές και όταν αισθάνονται ότι τα προσωπικά τους δεδομένα χρησιμοποιούνται με υπεύθυνο τρόπο. Για τον λόγο αυτό, τα επεξηγήσιμα συστήματα συστάσεων και οι ανθρωποκεντρικές προσεγγίσεις αναμένεται να διαδραματίσουν καθοριστικό ρόλο στη μελλοντική εξέλιξη του πεδίου (Zhang & Chen, 2020; Akdim et al., 2025). Τα ζητήματα ιδιωτικότητας και ηθικής στη χρήση δεδομένων αναδείχθηκαν επίσης ως βασικές προκλήσεις. Η υψηλή ποιότητα των συστάσεων εξαρτάται σε μεγάλο βαθμό από τη συλλογή και ανάλυση δεδομένων χρηστών, γεγονός που δημιουργεί ανάγκη για αυξημένη διαφάνεια, προστασία προσωπικών πληροφοριών και λογοδοσία των

αλγοριθμικών συστημάτων. Επίσης, η πιθανότητα αλγοριθμικών προκαταλήψεων και άνισης μεταχείρισης χρηστών ή αντικειμένων καθιστά απαραίτητη την ανάπτυξη πιο δίκαιων και υπεύθυνων συστημάτων. Η τεχνολογική πρόοδος, επομένως, πρέπει να συνοδεύεται από κοινωνική και ηθική υπευθυνότητα.

Συνολικά, η εργασία κατέληξε στο συμπέρασμα ότι τα συστήματα συστάσεων αποτελούν έναν από τους σημαντικότερους τομείς εφαρμογής των ευφυών τεχνικών στη σύγχρονη πληροφορική. Η συμβολή τους δεν περιορίζεται στην πρόταση προϊόντων ή περιεχομένου, αλλά επεκτείνεται στη διαμόρφωση της ψηφιακής εμπειρίας, στην υποστήριξη αποφάσεων και στη διαχείριση της γνώσης. Η μελλοντική τους εξέλιξη αναμένεται να βασιστεί στη σύγκλιση της βαθιάς μάθησης, της ενισχυτικής μάθησης, των υβριδικών μοντέλων, των επεξηγήσιμων τεχνικών και των πολυστοχικών προσεγγίσεων. Η πρόκληση για την επόμενη γενιά συστημάτων συστάσεων δεν είναι μόνο να παράγουν πιο ακριβείς προτάσεις, αλλά να είναι ταυτόχρονα προσαρμοστικά, διαφανή, αξιόπιστα, ηθικά και ανθρωποκεντρικά.

Καταληκτικά, η χρήση ευφυών τεχνικών για την ανάπτυξη συστημάτων συστάσεων αποτελεί ένα πεδίο με ιδιαίτερη επιστημονική και πρακτική αξία. Η συνεχής αύξηση των δεδομένων, η ανάγκη εξατομίκευσης και η πρόοδος της τεχνητής νοημοσύνης καθιστούν τα recommender systems αναπόσπαστο στοιχείο των σύγχρονων ψηφιακών υπηρεσιών. Τέλος, οι τεχνικές και κοινωνικές προκλήσεις που τα συνοδεύουν καθιστούν αναγκαία τη συνεχή έρευνα και βελτίωσή τους. Η επιτυχία των μελλοντικών συστημάτων δεν θα εξαρτηθεί μόνο από την αλγοριθμική τους ισχύ, αλλά και από την ικανότητά τους να υπηρετούν ουσιαστικά τις ανάγκες των χρηστών, να ενισχύουν την εμπιστοσύνη και να συμβάλλουν σε ένα πιο υπεύθυνο και αποτελεσματικό ψηφιακό περιβάλλον.

Βιβλιογραφία

Η βιβλιογραφία οργανώνεται σε κατηγορίες: άρθρα σε επιστημονικά περιοδικά, πρακτικά συνεδρίων, βιβλία και κεφάλαια βιβλίων, καθώς και διαδικτυακές πηγές, σύνολα δεδομένων και εργαλεία λογισμικού.

Άρθρα σε επιστημονικά περιοδικά (Journals)

- Adomavicius, G., & Tuzhilin, A. (2005). Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 17(6), 734–749.
- Adomavicius, G., & Kwon, Y. (2012). Improving aggregate recommendation diversity using ranking-based techniques. *IEEE Transactions on Knowledge and Data Engineering*, 24(5), 896–911.
- Bobadilla, J., Ortega, F., Hernando, A., & Bernal, J. (2012). A collaborative filtering approach to mitigate the new user cold start problem. *Knowledge-Based Systems*, 26, 225–238.
- Portugal, I., Alencar, P., & Cowan, D. (2018). The use of machine learning algorithms in recommender systems: A systematic review. *Expert Systems with Applications*, 97, 205–227.
- Zhang, Q., Lu, J., & Jin, Y. (2021). Artificial intelligence in recommender systems. *Complex & Intelligent Systems*, 7(1), 439–457.
- Akdim, I., El Boussaidi, G., & Saadi, R. (2025). Trust in recommender systems: A survey. *Expert Systems with Applications*, 287, 128835.
- Batmaz, Z., Yurekli, A., Bilge, A., & Kaleli, C. (2019). A review on deep learning for recommender systems: Challenges and remedies. *Artificial Intelligence Review*, 52(1), 1–37.
- Bell, R. M., & Koren, Y. (2007). Lessons from the Netflix prize challenge. *ACM SIGKDD Explorations Newsletter*, 9(2), 75–79.
- Bobadilla, J., Ortega, F., Hernando, A., & Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-Based Systems*, 46, 109–132.
- Breese, J. S., Heckerman, D., & Kadie, C. (1998). Empirical analysis of predictive algorithms for collaborative filtering. *Uncertainty in Artificial Intelligence*, 43–52.
- Burke, R. (2002). Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, 12(4), 331–370.
- Chen, X., Yao, L., McAuley, J., Zhou, G., & Wang, X. (2021). A survey of deep reinforcement learning in recommender systems. *ACM Computing Surveys*, 54(6), 1–38.
- Deshpande, M., & Karypis, G. (2004). Item-based Top-N recommendation algorithms. *ACM Transactions on Information Systems*, 22(1), 143–177.
- Ekstrand, M. D., Riedl, J. T., & Konstan, J. A. (2011). Collaborative filtering recommender systems. *Foundations and Trends in Human-Computer Interaction*, 4(2), 81–173.
- Goldberg, D., Nichols, D., Oki, B. M., & Terry, D. (1992). Using collaborative filtering to weave an information tapestry. *Communications of the ACM*, 35(12), 61–70.
- Gomez-Urbe, C. A., & Hunt, N. (2015). The Netflix recommender system: Algorithms, business value, and innovation. *ACM Transactions on Management Information Systems*, 6(4), 1–19.

- Harper, F. M., & Konstan, J. A. (2015). The MovieLens datasets: History and context. *ACM Transactions on Interactive Intelligent Systems*, 5(4), 1–19.
- Herlocker, J. L., Konstan, J. A., Terveen, L. G., & Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems*, 22(1), 5–53.
- Jannach, D., Bauer, C., & Jugovac, M. (2023). A survey on multi-objective recommender systems. *Frontiers in Big Data*, 6, Article 1157899.
- Koren, Y. (2010). Collaborative filtering with temporal dynamics. *Communications of the ACM*, 53(4), 89–97.
- Koren, Y., Bell, R., & Volinsky, C. (2009). Matrix factorization techniques for recommender systems. *Computer*, 42(8), 30–37.
- Kunaver, M., & Požrl, T. (2017). Diversity in recommender systems – A survey. *Knowledge-Based Systems*, 123, 154–162.
- Li, Y., Liu, K., Satapathy, R., Wang, S., & Cambria, E. (2023). Recent developments in recommender systems: A survey. *IEEE Computational Intelligence Magazine*, 18(3), 78–95.
- Linden, G., Smith, B., & York, J. (2003). Amazon.com recommendations: Item-to-item collaborative filtering. *IEEE Internet Computing*, 7(1), 76–80.
- Maes, P. (1994). Agents that reduce work and information overload. *Communications of the ACM*, 37(7), 31–40.
- Maes, P. (1997). Humanizing the global computer. *IEEE Internet Computing*, 1(4), 10–19.
- Mitchell, T., Caruana, R., Freitag, D., McDermott, J., & Zabowski, D. (1994). Experience with a learning personal assistant. *Communications of the ACM*, 37(7), 81–91.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... Duchesnay, É. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
- Quadrana, M., Cremonesi, P., & Jannach, D. (2018). Sequence-aware recommender systems. *ACM Computing Surveys*, 51(4), 1–36.
- Su, X., & Khoshgoftaar, T. M. (2009). A survey of collaborative filtering techniques. *Advances in Artificial Intelligence*, 2009, Article 421425.
- Wooldridge, M. J., & Jennings, N. R. (1995). Intelligent agents: Theory and practice. *The Knowledge Engineering Review*, 10(2), 115–152.
- Wu, S., Sun, F., Zhang, W., Xie, X., & Cui, B. (2022). Graph neural networks in recommender systems: A survey. *ACM Computing Surveys*, 55(5), 1–37.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338–353.
- Zhang, S., Yao, L., Sun, A., & Tay, Y. (2019). Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys*, 52(1), 1–38.
- Zhang, Y., & Chen, X. (2020). Explainable recommendation: A survey and new perspectives. *Foundations and Trends in Information Retrieval*, 14(1), 1–101.
- Zhou, H., Xu, J., Zheng, Z., Zhu, Z., Bu, J., Wang, W., & Yu, P. S. (2023). A comprehensive survey of recommender systems based on deep learning. *Applied Sciences*, 13(20), 11378.
- Hunter, J. D. (2007). Matplotlib: A 2D graphics environment. *Computing in Science & Engineering*, 9(3), 90–95.
- Harris, C. R., Millman, K. J., van der Walt, S. J., Gommers, R., Virtanen, P., Cournapeau, D., ... Oliphant, T. E. (2020). Array programming with NumPy. *Nature*, 585, 357–362.
- Nwana, H. S. (1996). Software agents: An overview. *The Knowledge Engineering Review*, 11(3), 205–244.

Πρακτικά συνεδρίων (Conference proceedings)

- Cheng, H.-T., Koc, L., Harmsen, J., Shaked, T., Chandra, T., Aradhye, H., ... Shah, H. (2016). Wide & deep learning for recommender systems. *Proceedings of the 1st Workshop on Deep Learning for Recommender Systems*, 7–10.
- Covington, P., Adams, J., & Sargin, E. (2016). Deep neural networks for YouTube recommendations. *Proceedings of the 10th ACM Conference on Recommender Systems*, 191–198.
- Cremonesi, P., Koren, Y., & Turrin, R. (2010). Performance of recommender algorithms on Top-N recommendation tasks. *Proceedings of the 4th ACM Conference on Recommender Systems*, 39–46.
- Das, A. S., Datar, M., Garg, A., & Rajaram, S. (2007). Google news personalization: Scalable online collaborative filtering. *Proceedings of the 16th International Conference on World Wide Web*, 271–280.
- Guo, H., Tang, R., Ye, Y., Li, Z., & He, X. (2017). DeepFM: A factorization-machine based neural network for CTR prediction. *Proceedings of the 26th International Joint Conference on Artificial Intelligence*, 1725–1731.
- He, X., Deng, K., Wang, X., Li, Y., Zhang, Y., & Wang, M. (2020). LightGCN: Simplifying and powering graph convolution network for recommendation. *Proceedings of the 43rd International ACM SIGIR Conference*, 639–648.
- He, X., Liao, L., Zhang, H., Nie, L., Hu, X., & Chua, T.-S. (2017). Neural collaborative filtering. *Proceedings of the 26th International Conference on World Wide Web*, 173–182.
- He, R., & McAuley, J. (2016). VBPR: Visual Bayesian personalized ranking from implicit feedback. *Proceedings of the 30th AAAI Conference on Artificial Intelligence*, 144–150.
- Hidasi, B., Karatzoglou, A., Baltrunas, L., & Tikk, D. (2016). Session-based recommendations with recurrent neural networks. *Proceedings of the 4th International Conference on Learning Representations (ICLR)*.
- Hu, Y., Koren, Y., & Volinsky, C. (2008). Collaborative filtering for implicit feedback datasets. *Proceedings of the 8th IEEE International Conference on Data Mining*, 263–272.
- Kabbur, S., Ning, X., & Karypis, G. (2013). FISM: Factored item similarity models for Top-N recommender systems. *Proceedings of the 19th ACM SIGKDD Conference*, 659–667.
- Kang, W.-C., & McAuley, J. (2018). Self-attentive sequential recommendation. *Proceedings of the 2018 IEEE International Conference on Data Mining*, 197–206.
- Koren, Y. (2008). Factorization meets the neighborhood: A multifaceted collaborative filtering model. *Proceedings of the 14th ACM SIGKDD Conference*, 426–434.
- Liang, D., Krishnan, R. G., Hoffman, M. D., & Jebara, T. (2018). Variational autoencoders for collaborative filtering. *Proceedings of the 2018 World Wide Web Conference*, 689–698.
- McAuley, J., Targett, C., Shi, Q., & van den Hengel, A. (2015). Image-based recommendations on styles and substitutes. *Proceedings of the 38th International ACM SIGIR Conference*, 43–52.
- Mnih, A., & Salakhutdinov, R. (2008). Probabilistic matrix factorization. *Advances in Neural Information Processing Systems*, 20, 1257–1264.
- Ning, X., & Karypis, G. (2011). SLIM: Sparse linear methods for Top-N recommender systems. *Proceedings of the 11th IEEE International Conference on Data Mining*, 497–506.

- Paszke, A., Gross, S., Massa, F., Lerer, A., Bradbury, J., Chanan, G., ... Chintala, S. (2019). PyTorch: An imperative style, high-performance deep learning library. *Advances in Neural Information Processing Systems*, 32, 8024–8035.
- Rendle, S. (2010). Factorization machines. *Proceedings of the 10th IEEE International Conference on Data Mining*, 995–1000.
- Rendle, S., Freudenthaler, C., Gantner, Z., & Schmidt-Thieme, L. (2009). BPR: Bayesian personalized ranking from implicit feedback. *Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence*, 452–461.
- Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., & Riedl, J. (1994). GroupLens: An open architecture for collaborative filtering of netnews. *Proceedings of the ACM Conference on Computer Supported Cooperative Work*, 175–186.
- Salakhutdinov, R., Mnih, A., & Hinton, G. (2007). Restricted Boltzmann machines for collaborative filtering. *Proceedings of the 24th International Conference on Machine Learning*, 791–798.
- Sarwar, B., Karypis, G., Konstan, J., & Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. *Proceedings of the 10th International Conference on World Wide Web*, 285–295.
- Schafer, J. B., Konstan, J., & Riedl, J. (1999). Recommender systems in e-commerce. *Proceedings of the 1st ACM Conference on Electronic Commerce*, 158–166.
- Sedhain, S., Menon, A. K., Sanner, S., & Xie, L. (2015). AutoRec: Autoencoders meet collaborative filtering. *Proceedings of the 24th International Conference on World Wide Web*, 111–112.
- Sun, F., Liu, J., Wu, J., Pei, C., Lin, X., Ou, W., & Jiang, P. (2019). BERT4Rec: Sequential recommendation with bidirectional encoder representations from transformer. *Proceedings of the 28th ACM CIKM Conference*, 1441–1450.
- Wang, H., Wang, N., & Yeung, D.-Y. (2015). Collaborative deep learning for recommender systems. *Proceedings of the 21st ACM SIGKDD Conference*, 1235–1244.
- Wang, X., He, X., Wang, M., Feng, F., & Chua, T.-S. (2019). Neural graph collaborative filtering. *Proceedings of the 42nd International ACM SIGIR Conference*, 165–174.
- Zhou, G., Zhu, X., Song, C., Fan, Y., Zhu, H., Ma, X., ... Gai, K. (2018). Deep interest network for click-through rate prediction. *Proceedings of the 24th ACM SIGKDD Conference*, 1059–1068.
- Zhang, F., Yuan, N. J., Lian, D., Xie, X., & Ma, W.-Y. (2016). Collaborative knowledge base embedding for recommender systems. *Proceedings of the 22nd ACM SIGKDD Conference*, 353–362.
- Tang, J., & Wang, K. (2018). Personalized Top-N sequential recommendation via convolutional sequence embedding. *Proceedings of the 11th ACM International Conference on Web Search and Data Mining*, 565–573.
- Wu, C.-Y., Ahmed, A., Beutel, A., Smola, A. J., & Jing, H. (2017). Recurrent recommender networks. *Proceedings of the 10th ACM International Conference on Web Search and Data Mining*, 495–503.
- Barkan, O., & Koenigstein, N. (2016). Item2Vec: Neural item embedding for collaborative filtering. *Proceedings of the IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP)*, 1–6.
- Sycara, K. (1995). Intelligent agents and the information revolution. *UNICOM Seminar on Intelligent Agents and Their Business Applications*, 143–159.
- Genesereth, M. R., & Ketchpel, S. P. (1994). Software agents. *Communications of the ACM*, 37(7), 48–53.

Βιβλία και κεφάλαια βιβλίων (Books & book chapters)

- Aggarwal, C. C. (2016). Recommender systems: The textbook. Springer.
- Bishop, C. M. (2006). Pattern recognition and machine learning. Springer.
- Falk, K. (2019). Practical recommender systems. Manning Publications.
- Goldberg, D. E. (1989). Genetic algorithms in search, optimization, and machine learning. Addison-Wesley.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press.
- Han, J., Kamber, M., & Pei, J. (2011). Data mining: Concepts and techniques (3rd ed.). Morgan Kaufmann.
- Jannach, D., Zanker, M., Felfernig, A., & Friedrich, G. (2010). Recommender systems: An introduction. Cambridge University Press.
- Lops, P., de Gemmis, M., & Semeraro, G. (2011). Content-based recommender systems: State of the art and trends. In F. Ricci, L. Rokach, B. Shapira, & P. B. Kantor (Eds.), Recommender systems handbook (pp. 73–105). Springer.
- Manning, C. D., Raghavan, P., & Schütze, H. (2008). Introduction to information retrieval. Cambridge University Press.
- Mitchell, T. M. (1997). Machine learning. McGraw-Hill.
- Pazzani, M. J., & Billsus, D. (2007). Content-based recommendation systems. In P. Brusilovsky, A. Kobsa, & W. Nejdl (Eds.), The adaptive web (LNCS 4321, pp. 325–341). Springer.
- Ricci, F., Rokach, L., & Shapira, B. (Eds.). (2015). Recommender systems handbook (2nd ed.). Springer.
- Ricci, F., Rokach, L., & Shapira, B. (2011). Introduction to recommender systems handbook. In Recommender systems handbook (pp. 1–35). Springer.
- Shani, G., & Gunawardana, A. (2011). Evaluating recommendation systems. In Recommender systems handbook (pp. 257–297). Springer.
- Russell, S., & Norvig, P. (2021). Artificial intelligence: A modern approach (4th ed.). Pearson.
- Koren, Y., & Bell, R. (2015). Advances in collaborative filtering. In F. Ricci, L. Rokach, & B. Shapira (Eds.), Recommender systems handbook (2nd ed., pp. 77–118). Springer.
- Desrosiers, C., & Karypis, G. (2011). A comprehensive survey of neighborhood-based recommendation methods. In Recommender systems handbook (pp. 107–144). Springer.
- Nwana, H. S., & Ndumu, D. T. (1998). A brief introduction to software agent technology. In N. R. Jennings & M. J. Wooldridge (Eds.), Agent technology: Foundations, applications, and markets (pp. 29–47). Springer.

Διαδικτυακές πηγές, σύνολα δεδομένων και εργαλεία

- Funk, S. (2006). Netflix update: Try this at home. Ανακτήθηκε από <https://sifter.org/~simon/journal/20061211.html>
- Hug, N. (2020). Surprise: A Python library for recommender systems. Journal of Open Source Software, 5(52), 2174.
- McAuley, J. (2018). Amazon product review data. Ανακτήθηκε από <https://jmcauley.ucsd.edu/data/amazon/>
- GroupLens Research. (2021). MovieLens datasets. University of Minnesota. Ανακτήθηκε από <https://grouplens.org/datasets/movielens/>

- McKinney, W. (2010). Data structures for statistical computing in Python. Proceedings of the 9th Python in Science Conference, 56–61.
- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... Zheng, X. (2016). TensorFlow: A system for large-scale machine learning. Proceedings of the 12th USENIX Symposium on Operating Systems Design and Implementation, 265–283.
- Virtanen, P., Gommers, R., Oliphant, T. E., Haberland, M., Reddy, T., Cournapeau, D., ... van Mulbregt, P. (2020). SciPy 1.0: Fundamental algorithms for scientific computing in Python. Nature Methods, 17, 261–272.
- Konstan, J. A., & Riedl, J. (2012). Recommender systems: From algorithms to user experience. User Modeling and User-Adapted Interaction, 22(1–2), 101–123.