



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών
Εργαστήριο Συστημάτων Τεχνητής Νοημοσύνης και Μάθησης

**Ανάλυση και Πειραματική Εφαρμογή Καθοδήγησης μέσω
Ζευγών σε Μοντέλα Διάχυσης για Πολυμεταβλητές
Χρονοσειρές**

Διπλωματική Εργασία

του

Μπραϊμάκη Α.Αχιλλέα

Επιβλέπων: Αθανάσιος Βουλόδημος
Καθηγητής Ε.Μ.Π.

Αθήνα, Νοέμβριος 2025



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών
Εργαστήριο Συστημάτων Τεχνητής Νοημοσύνης και Μάθησης

Ανάλυση και Πειραματική Εφαρμογή Καθοδήγησης μέσω Ζευγών σε Μοντέλα Διάχυσης για Πολυμεταβλητές Χρονοσειρές

Διπλωματική Εργασία

του

Μπραϊμάκη Α.Αχιλλέα

Επιβλέπων: Αθανάσιος Βουλόδημος
Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 17^η Νοεμβρίου, 2025

.....
Αθανάσιος Βουλόδημος
Καθηγητής Ε.Μ.Π.

.....
Γ.Στάμου
Καθηγητής Ε.Μ.Π.

.....
Α. Γ. Σταφυλοπάτης
Καθηγητής Ε.Μ.Π.

Αθήνα, Νοέμβριος 2025

.....
Αχιλλέας Μπραϊμάκης

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών Ε.Μ.Π

17 Νοεμβρίου 2025

Copyright © – All rights reserved Achilles Braimakis, 2025.

Με επιφύλαξη παντός δικαιώματος.

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

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

Περίληψη

Τα μοντέλα διάχυσης αποτελούν ένα από τα πλέον ισχυρά πλαίσια στοχαστικής γένεσης, με εντυπωσιακές επιδόσεις στη σύνθεση εικόνων, ήχου και άλλων πολυδιάστατων δεδομένων. Η εφαρμογή τους στις χρονοσειρές, αν και πολλά υποσχόμενη, παραμένει ένα ενεργό πεδίο έρευνας, καθώς οι χρονικές εξαρτήσεις και οι συσχετισμοί μεταξύ χαρακτηριστικών απαιτούν εξειδικευμένες μορφές καθοδήγησης και ελέγχου της διάχυσης.

Η παρούσα εργασία εστιάζει στην ανάπτυξη και ανάλυση ενός πλαισίου καθοδήγησης πάνω στο μοντέλο CSDI (*Conditional Score-based Diffusion for Imputation*), με στόχο τη μελέτη της συμπεριφοράς του υπό στοχευμένες παρεμβάσεις μεταξύ επιλεγμένων χαρακτηριστικών. Προτείνεται ένας μηχανισμός καθοδήγησης μέσω ζευγών (*pairs-only guidance*), ο οποίος επιτρέπει την εφαρμογή ελεγχόμενων δυνάμεων έλξης ή άπωσης ανάμεσα σε ζεύγη χαρακτηριστικών, με βάρη και πολυ-βηματική διάδοση των επιδράσεων τους μέσω προϋπολογισμένων πινάκων συσχέτισης. Ο μηχανισμός αυτός δεν στοχεύει στη βελτίωση της απόδοσης του CSDI, αλλά στη διερεύνηση του τρόπου με τον οποίο η καθοδηγούμενη διάχυση μπορεί να επηρεάσει τη δομή των συσχετίσεων και τη χωρική συνοχή των παραγόμενων χρονοσειρών.

Τα πειραματικά αποτελέσματα σε συνθετικά, μουσικά και κυκλοφοριακά δεδομένα δείχνουν συνεπή και ερμηνεύσιμα μοτίβα επιλεκτικότητας, ευθυγράμμισης και διάχυσης επιρροής, επιβεβαιώνοντας ότι η καθοδήγηση ανά ζεύγη προσφέρει ένα ερμηνεύσιμο και ελεγχόμενο πλαίσιο ανάλυσης των σχέσεων μεταξύ χαρακτηριστικών. Η εργασία καταλήγει σε ένα γενικεύσιμο σχήμα διάχυσης, το οποίο μπορεί να υποστηρίξει μελλοντικά πιο σύνθετες μορφές καθοδήγησης και ελέγχου σε πολυμεταβλητές χρονοσειρές.

Λέξεις-κλειδιά: μοντέλα διάχυσης, χρονοσειρές, καθοδήγηση ζευγών, στοχαστική γένεση, συσχετίσεις, πολυ-βηματική διάδοση, CSDI.

Abstract

Diffusion models have emerged as one of the most powerful frameworks for stochastic data generation, achieving remarkable results in image, audio, and other high-dimensional domains. Their application to time series, although highly promising, remains an active field of research, as temporal dependencies and inter-feature correlations require specialized forms of diffusion guidance and control.

This work focuses on the development and analysis of a guidance framework built upon the CSDI model (Conditional Score-based Diffusion for Imputation), aiming to study its behavior under targeted interventions between selected features. A novel pair-wise guidance mechanism (pairs-only guidance) is proposed, which applies controlled attractive or repulsive forces between feature pairs, with signed weights and multi-hop propagation of their effects through precomputed correlation matrices. The mechanism is not intended to improve CSDI’s predictive performance, but rather to investigate how guided diffusion influences the correlation structure and spatial coherence of the generated time-series trajectories.

Experimental results on synthetic, musical, and traffic datasets reveal consistent and interpretable patterns of selectivity, alignment, and influence propagation, demonstrating that pair-wise guidance provides a transparent and controllable framework for analyzing relationships among features. The work concludes with a generalized diffusion scheme that can support more sophisticated forms of guidance and control in multivariate time-series models.

Keywords: diffusion models, time series, pair-wise guidance, stochastic generation, correlations, multi-hop propagation, CSDI.

Ευχαριστίες

Θα ήθελα να εκφράσω την ειλικρινή μου ευγνωμοσύνη προς τους Καθηγητές κ. Αθανάσιο Βουλοδήμο και κα. Παρασκευή Τζούβελι, καθώς και προς τον υποψήφιο διδάκτορα κ. Ηλία Μήτσουρα, για την πολύτιμη καθοδήγηση, τη συνεργασία και τη συνεχή υποστήριξή τους καθ' όλη τη διάρκεια της διπλωματικής μου εργασίας. Η επιστημονική τους καθοδήγηση, οι εύστοχες παρατηρήσεις και η διαρκής τους διαθεσιμότητα συνέβαλαν ουσιαστικά τόσο στην ερευνητική πρόοδο όσο και στη δική μου προσωπική εξέλιξη.

Τέλος, θα ήθελα να απευθύνω ένα βαθύ και ειλικρινές ευχαριστώ στην οικογένειά μου, για την αμέριστη αγάπη, υπομονή και στήριξη που μου προσέφεραν σε όλη τη διάρκεια των σπουδών μου. Χωρίς τη δική τους πίστη και συμπαράσταση, η ολοκλήρωση αυτής της προσπάθειας δεν θα ήταν δυνατή.

Μπραϊμάκης Αχιλλέας, Νοέμβριος 2025

Περιεχόμενα

Πίνακας Σχημάτων

xiii

I	Εισαγωγή	1
1	Περιγραφή Προβλήματος και Στόχοι Εργασίας	2
II	Θεωρητικό Υπόβαθρο	4
2	Βασική Θεωρία Μοντέλων Διάχυσης Diffusion Models	5
2.1	Εισαγωγή στα Μοντέλα Διάχυσης	5
2.1.1	Εμπρόσθια Διαδικασία Διάχυσης	5
2.1.2	Αντίστροφη Διαδικασία Διάχυσης	8
2.1.3	Διαδικασία Δειγματοληψίας	10
2.2	Μοντέλα Διάχυσης για Χρονοσειρές και Ανάλυση Μοντέλου CSDI	12
2.2.1	Ιδιαιτερότητες των Δεδομένων Χρονοσειρών	12
2.2.2	Θεωρητική Προσαρμογή του Πλαισίου Διάχυσης στις Χρονοσειρές	14
2.2.3	Το Μοντέλο CSDI (Conditional Score-based Diffusion for Imputation)	19
2.3	Καθοδήγηση σε Μοντέλα Διάχυσης για Χρονοσειρές	28
2.3.1	Θεμελίωση και Αναγκαιότητα της Καθοδήγησης σε Γενετικά Μοντέλα Χρονοσειρώ	28
2.3.2	Θεμελιώδεις Αρχές	30
2.3.3	Κατηγορίες Καθοδήγησης	33
2.3.4	Μορφές Δεδομένων για Καθοδήγηση	37
3	Θεωρία και Εφαρμογή του Πειραματικού Μοντέλου	41
3.1	Πειραματικό Μοντέλο Καθοδηγούμενης Διάχυσης	41
3.2	Πολυ-βηματική Διάχυση Συσχετίσεων	42
3.3	Ροή Υλοποίησης και Αλγοριθμική Περιγραφή	44
3.4	Ρυθμίσεις Καθοδήγησης και Επιλογή Παραμέτρων	46
3.5	Αναμενόμενες Συμπεριφορές και Διαγνωστικά Τεστ	47
3.6	Μετρικές Αξιολόγησης και Τεκμηρίωση Υλοποίησης	48
3.6.1	Μετρικές Καθοδήγησης και Αξιολόγησης	49
III	Πειραματικό Μέρος	51
4	Δημιουργία Συνόλων Δεδομένων	52
4.1	Δεδομένα και Αναπαραστάσεις	52
4.2	Χρονοσειρές: Προκλήσεις και Δομή	53
4.3	Πειραματικά Σύνολα Δεδομένων	54
4.3.1	Μουσική — BabySlakh (Track 1)	55
4.3.2	Συνθετικό Σύνολο Lorenz-96	57

4.3.3	Traffic – Σύνολο PEMS-SF	59
5	Πειράματα και Σχολιασμός	63
5.1	Music	63
5.2	Lorenz	72
5.3	Traffic	79
6	Μελλοντικές Επεκτάσεις	89
IV	Παράρτημα	91
7	Παράρτημα	92
8	Bibliography	115

Κατάλογος σχημάτων

1	Παράδειγμα μοντέλου διάχυσης εικόνων: η σταδιακή διαδικασία προσθήκης θορύβου [32].	5
2	Παράδειγμα αντίστροφης διαδικασίας διάχυσης (Reverse Diffusion): η σταδιακή απομάκρυνση του θορύβου και η επαναφορά της αρχικής εικόνας [12].	9
3	Διαδικασία αυτοεποπτευόμενης εκπαίδευσης του CSDI [35]. Οι πράσινες και λευκές περιοχές αντιστοιχούν σε παρατηρούμενες και ελλείπουσες τιμές, αντίστοιχα. Οι παρατηρήσεις διαχωρίζονται σε κόκκινες περιοχές στόχων συμπλήρωσης (x_0^{ta}) και μπλε υπό όρους παρατηρήσεις (x_0^{co}), οι οποίες χρησιμοποιούνται για την εκπαίδευση της συνάρτησης ε_θ . Τα χρωματισμένα τμήματα σε κάθε ορθογώνιο υποδηλώνουν την ύπαρξη διαθέσιμων τιμών.	21
4	Αρχιτεκτονική μηχανισμού προσοχής δύο διαστάσεων (2D Attention) [35]. Δεδομένου ενός τανυστή με K χαρακτηριστικά, μήκος L και C κανάλια, το Temporal Transformer layer λαμβάνει είσοδο σχήματος $(1, L, C)$ για κάθε χαρακτηριστικό και μαθαίνει χρονικές εξαρτήσεις, ενώ το Feature Transformer layer λαμβάνει είσοδο $(K, 1, C)$ για κάθε χρονική στιγμή και μαθαίνει δια-χαρακτηριστικές εξαρτήσεις. Το τελικό σχήμα εξόδου είναι (K, L, C) , ίδιο με της εισόδου.	25
5	Πλήρης αρχιτεκτονική της συνάρτησης αποθορυβοποίησης ε_θ στο CSDI για πολυμεταβλητή συμπλήρωση χρονοσειρών [35]. Το δίκτυο δέχεται ως είσοδο τα x_0^{co} , x_t^{ta} , τη μάσκα m_{co} και τις ενσωματώσεις διάχυσης, χρόνου και χαρακτηριστικών. Κάθε υπολειμματικό μπλοκ (residual layer) περιλαμβάνει ένα ζεύγος Temporal / Feature Transformer layers, ενώ οι παρακάμψεις (skip connections) συνδέουν όλα τα επίπεδα. Στην έξοδο, εφαρμόζεται η μάσκα $(1 - m_{co})$ ώστε να μηδενίζονται οι υπό όρους παρατηρήσεις.	26
6	Ροή της pairs-only καθοδήγησης μέσα στο CSDI. Από το x_t εφαρμόζονται (α) συμμετρικές ζευγαρικές ενημερώσεις στα επιλεγμένα (i, j, w_{ij}) , και (β) πολυ-βηματική διάχυση (multi-hop spill) βάσει του πίνακα συσχετίσεων W , πριν την προβολή στις γνωστές τιμές (μάσκα M) και το στοχαστικό βήμα του δειγματολήπτη.	41
7	Συνοπτική ροή της pairs-only καθοδήγησης πριν από τον αποθορυβοποιητή. Είσοδος το x_t . Στο μπλοκ <i>Update Guided Pairs</i> εφαρμόζονται οι ζευγαρικές ενημερώσεις υπό τον έλεγχο του χρονο-προγράμματος $\lambda(t)$ και της μάσκας παρατήρησης $cond_mask$, ενώ το t_embed παρέχει τον χρονικό εντοπισμό του βήματος. Στη συνέχεια υπολογίζονται οι συνολικές μεταβολές στα καθοδηγούμενα (<i>Compute Guided Deltas</i>) και διαχέονται στους υπόλοιπους κόμβους μέσω του πολυ-βηματικού πίνακα συσχετίσεων (<i>Multi-Hop Spill</i>). Το αποτέλεσμα είναι το καθοδηγούμενο δείγμα x'_t	45
8	Ακριβείς θέσεις σταθμών PEMS-SF (lat/lon) για το υποσύνολο των 10 αισθητήρων.	60
9	Συνοπτική απεικόνιση των βασικών μετρικών καθοδήγησης σε επίπεδο συνόλου.	64
10	Σταθμισμένος μέσος βαθμός ευθυγράμμισης (Weighted Alignment) μεταξύ αναμενόμενης και παρατηρούμενης μεταβολής.	65
11	Αξιολόγηση αριθμού συστάδων (K selection) βάσει μετρικών Silhouette, Calinski–Harabasz, Davies–Bouldin και WCSS. Η βέλτιστη τιμή προκύπτει στο $K = 4$, όπου συνδυάζεται υψηλή συνοχή, καθαρός διαχωρισμός και ελάχιστη ενδοσυσταδική διασπορά.	66

12	Προβολή των χαρακτηριστικών Δ στον χώρο των δύο κυριότερων συνιστωσών (PCA, $K=4$). Κάθε σημείο αντιστοιχεί σε μία σχέση μεταξύ ζευγών, ενώ το χρώμα υποδηλώνει τη cluster στην οποία ταξινομήθηκε (cluster 0 – μπλε, 1 – πορτοκαλί, 2 – πράσινο, 3 – κόκκινο). Η διάταξη αποκαλύπτει σαφή χωρικό διαχωρισμό μεταξύ των συστάδων, με το μεγαλύτερο σύμπλεγμα (cluster 0) να συγκεντρώνεται στο κέντρο και τα υπόλοιπα να κατανέμονται περιφερειακά, υποδεικνύοντας διαφορετικά μοτίβα επίδρασης.	66
13	Όλες οι σχέσεις στον χώρο alignment- $ \Delta $, χρωματισμένες ανά cluster ($K=4$). Οι διακεκομμένες γραμμές υποδεικνύουν ενδεικτικά κατώφλια (alignment ≈ 0.75 , $ \Delta \approx 0.25$) για οπτικό διαχωρισμό μεταξύ ήπιων/συμφωνημένων και ισχυρών/μη-συμφωνημένων μεταβολών.	70
14	Κατανομή τεταρτημορίων ανά weight tag για τα Clusters 00–03.	71
15	Συνοπτική απεικόνιση των βασικών μετρικών καθοδήγησης για το συνθετικό σύνολο Lorenz–96. Οι τιμές απεικονίζουν τη μέση συμπεριφορά των μεταβολών, της ενεργειακής απαίτησης, της επιλεκτικότητας και της διαρροής εκτός στόχου κατά τη διάρκεια της καθοδηγούμενης διάχυσης.	72
16	Μέσος βαθμός ευθυγράμμισης (Weighted Alignment) μεταξύ αναμενόμενης και παρατηρούμενης μεταβολής για το σύνολο Lorenz–96.	73
17	Αξιολόγηση αριθμού συστάδων (K selection) για το σύνολο Lorenz–96, βάσει των κριτηρίων GMM–BIC και GMM–AIC. Και τα δύο κριτήρια συγκλίνουν στη βέλτιστη τιμή $K = 4$, υποδεικνύοντας καλή ισορροπία μεταξύ πολυπλοκότητας μοντέλου και συνοχής συστάδων.	74
18	Προβολή των χαρακτηριστικών Δ στον χώρο των δύο κυριότερων συνιστωσών (PCA, $K=4$) για το σύνολο Lorenz–96. Κάθε σημείο αντιστοιχεί σε μία σχέση μεταξύ καθοδηγούμενων τομέων, ενώ το χρώμα υποδηλώνει τη cluster στην οποία ταξινομήθηκε (cluster 0 – μπλε, 1 – πορτοκαλί, 2 – πράσινο, 3 – κόκκινο). Η διάταξη παρουσιάζει σαφή διαχωρισμό μεταξύ των συστάδων, με το μεγαλύτερο σύμπλεγμα (cluster 1) να καταλαμβάνει το κεντρικό τμήμα του χώρου και τα μικρότερα να τοποθετούνται περιφερειακά, υποδεικνύοντας διαφορετικές κατηγορίες δυναμικής απόκρισης μεταξύ των τομέων του συστήματος.	74
19	Όλες οι σχέσεις στον χώρο alignment- $ \Delta $, χρωματισμένες ανά cluster ($K = 4$) για το Lorenz–96. Οι διακεκομμένες γραμμές υποδεικνύουν ενδεικτικά κατώφλια (alignment ≈ 0.50 , $ \Delta \approx 0.05$) για οπτικό διαχωρισμό μεταξύ ήπιων/ευθυγραμμισμένων και ισχυρών/μη ευθυγραμμισμένων μεταβολών.	78
20	Κατανομή τεταρτημορίων ανά weight tag για τα Clusters 00–03 στο Lorenz–96. Κάθε υπογράφημα εμφανίζει 16 μπάρες ($4 \text{ βάρη} \times 4 \text{ τεταρτημόρια}$).	79
21	Συνοπτική απεικόνιση των βασικών μετρικών καθοδήγησης σε επίπεδο συνόλου.	80
22	Σταθμισμένος μέσος βαθμός ευθυγράμμισης (Weighted Alignment) μεταξύ αναμενόμενης και παρατηρούμενης μεταβολής.	81
23	Αξιολόγηση του αριθμού συστάδων (K) για το κυκλοφοριακό σύνολο PEMS–SF βάσει των κριτηρίων Bayesian Information Criterion (BIC) και Akaike Information Criterion (AIC). Οι χαμηλότερες τιμές αντιστοιχούν σε καλύτερη προσαρμογή του μοντέλου, με το $K = 4$ να αναδεικνύεται ως σημείο ισορροπίας μεταξύ πολυπλοκότητας και συνοχής.	82
24	Προβολή των χαρακτηριστικών Δ στον χώρο των δύο κυριότερων συνιστωσών (PCA, $K=4$) για το κυκλοφοριακό σύνολο PEMS–SF. Κάθε σημείο αντιστοιχεί σε μία σχέση μεταξύ ζευγών αισθητήρων, ενώ το χρώμα υποδηλώνει τη cluster στην οποία ταξινομήθηκε (cluster 0 – μπλε, 1 – πορτοκαλί, 2 – πράσινο, 3 – κόκκινο). Η διάταξη αποκαλύπτει καθαρό διαχωρισμό μεταξύ των συστάδων, με το μεγαλύτερο σύμπλεγμα (cluster 0) να συγκεντρώνεται στο κεντρικό τμήμα του χώρου, ενώ τα υπόλοιπα διατάσσονται περιφερειακά. Το αποτέλεσμα υποδεικνύει διαφορετικά πρότυπα επίδρασης της καθοδήγησης, όπου ορισμένες ομάδες ακμών αντιδρούν τοπικά, ενώ άλλες παρουσιάζουν πιο έντονη χωρική διαφοροποίηση ή αντιρροπιστική συμπεριφορά.	82
25	Όλες οι σχέσεις του δικτύου στον χώρο ευθυγράμμισης–μεταβολής (alignment- $ \Delta $), χρωματισμένες ανά cluster ($K = 4$). Οι διακεκομμένες γραμμές δείχνουν ενδεικτικά κατώφλια (alignment ≈ 0.75 , $ \Delta \approx 0.25$) για την οπτική διάκριση μεταξύ ήπιων/συμφωνημένων και ισχυρών/μη-ευθυγραμμισμένων μεταβολών.	87
26	Κατανομή τεταρτημορίων ανά weight tag για τα Clusters 00–03.	88

Μέρος Ι

Εισαγωγή

Κεφάλαιο 1

Περιγραφή Προβλήματος και Στόχοι Εργασίας

Πλαίσιο και Κίνητρο

Η παρούσα εργασία τοποθετείται στο πεδίο των Time-Series Diffusion Models, μιας ταχέως αναπτυσσόμενης οικογένειας γενετικών μοντέλων που βασίζονται στη στατιστική φυσική και τη θεωρία των στοχαστικών διαφορικών εξισώσεων. Τα μοντέλα αυτά έχουν αποδείξει εξαιρετική ικανότητα στη δημιουργία σύνθετων δεδομένων, όπως εικόνες, ήχο και κείμενο, μέσω μιας διαδικασίας διάχυσης θορύβου σε δομημένες μορφές πληροφορίας.

Στο πλαίσιο των πολυμεταβλητών χρονοσειρών, η εφαρμογή της διάχυσης παρουσιάζει ιδιαίτερο ενδιαφέρον, καθώς τα δεδομένα χαρακτηρίζονται από έντονες χρονικές και διακαναλικές εξαρτήσεις. Η αναδόμηση ή η δημιουργία ρεαλιστικών χρονοσειρών απαιτεί μοντέλα που όχι μόνο μαθαίνουν τις κατανομές των μεμονωμένων χαρακτηριστικών, αλλά και τις λεπτές σχέσεις μεταξύ τους δηλαδή τον συντονισμό των μεταβλητών μέσα στο χρόνο.

Ωστόσο, η εκμάθηση τέτοιων σχέσεων αποκλειστικά από τα δεδομένα δεν επαρκεί πάντα. Σε πολλές περιπτώσεις είναι γνωστές εκ των προτέρων συγκεκριμένες συσχετίσεις ή δομές, οι οποίες εκφράζουν φυσικούς, χωρικούς ή λειτουργικούς περιορισμούς του συστήματος. Η ενσωμάτωση αυτής της γνώσης μέσα στη διαδικασία διάχυσης, με τρόπο ελεγχόμενο και διαφορίσιμο, αποτελεί το κεντρικό ζητούμενο της παρούσας μελέτης.

Ερευνητικό Πρόβλημα

Το πρόβλημα που πραγματεύεται η εργασία αυτή είναι η ανάπτυξη ενός μηχανισμού *καθοδηγούμενης διάχυσης* για πολυμεταβλητές χρονοσειρές, ο οποίος επιτρέπει τον στοχευμένο έλεγχο των διακαναλικών συσχετίσεων κατά τη δειγματοληψία. Πιο συγκεκριμένα, στόχος είναι η προσαρμογή του μοντέλου CSDI (Conditional Score-based Diffusion Model for Imputation) ώστε να υποστηρίξει έναν νέο τύπο καθοδήγησης που ονομάζεται *pairs-only guidance*.

Η προσέγγιση αυτή διαφοροποιείται από τις υπάρχουσες μεθόδους καθοδήγησης με ταξινομητή ή γράφο, καθώς δεν απαιτεί επανεκπαίδευση ή εξωτερικό δίκτυο, αλλά δρα απευθείας πάνω σε επιλεγμένα ζεύγη χαρακτηριστικών. Με τον τρόπο αυτό, μπορούμε να μελετήσουμε ποσοτικά πώς η στοχευμένη ενίσχυση ή αποδυνάμωση συγκεκριμένων συσχετίσεων επηρεάζει τη συνολική συμπεριφορά του μοντέλου διάχυσης, τη στατιστική του δομή και τη γενετική του ποικιλία.

Σκοπός και Συνεισφορά

Ο κεντρικός σκοπός της εργασίας είναι η εισαγωγή ενός ενοποιημένου πλαισίου καθοδήγησης χρονοσειρών που να επιτρέπει:

- την **παραμετρική επιβολή σχέσεων** μεταξύ επιλεγμένων χαρακτηριστικών μέσω βαρών w_{ij} ,
- την **πολυβηματική διάδοση συσχέτισης** μέσω ενός εκτός σύνδεσης τελεστή C ,
- και την **αξιολόγηση** επιλεγμένων μετρικών ώστε να μελετάται η ισορροπία μεταξύ ελέγχου και ρεαλισμού.

Πέρα από τον τεχνικό έλεγχο της διαδικασίας διάχυσης, η εργασία στοχεύει επίσης στη διερεύνηση της σχέσης μεταξύ του ήδη εκπαιδευμένου μοντέλου και της καθοδήγησης που εφαρμόζεται. Μετρώντας το βαθμό ευθυγράμ-

μισης ανάμεσα στις εσωτερικές εξαρτήσεις που το μοντέλο έχει μάθει κατά την εκπαίδευση και στις εξωτερικές συσχετίσεις που του επιβάλλουμε μέσω καθοδήγησης.

Η συνεισφορά της παρούσας μελέτης είναι διττή:

1. **Μεθοδολογική:** προτείνεται μια πρακτική, πλήρως διαφορίσιμη μέθοδος καθοδήγησης, η οποία εφαρμόζεται χωρίς να αλλοιώνει την εκπαίδευση του βασικού μοντέλου.
2. **Εμπειρική:** διεξάγονται εκτενή πειράματα σε τρία αντιπροσωπευτικά σύνολα δεδομένων (μουσική BabySlakh, συνθετικό Lorenz-96, κυκλοφορία PEMS-SF), ώστε να αξιολογηθεί η συμπεριφορά του καθοδηγούμενου μοντέλου ως προς μετρικές επιλεκτικότητας, ευθυγράμμισης και χωρικής διάχυσης, η.

Δομή του Κειμένου

Η εργασία οργανώνεται σε επτά κεφάλαια, καθένα από τα οποία αναπτύσσει διαδοχικά τη θεωρητική θεμελίωση, την αρχιτεκτονική του μοντέλου, τα δεδομένα και την πειραματική αξιολόγηση.

- **Κεφάλαιο — 2: Βασική Θεωρία Μοντέλων Διάχυσης.** Παρουσιάζεται η μαθηματική θεμελίωση των μοντέλων διάχυσης, οι έννοιες της εμπρόσθιας και αντίστροφης SDE, καθώς και ο τρόπος με τον οποίο η στοχαστική διαδικασία οδηγεί σε δειγματοληψία από πολύπλοκες κατανομές δεδομένων.
- **Κεφάλαιο — 2.2: Μοντέλα Διάχυσης για Χρονοσειρές και Ανάλυση Μοντέλου CSDI.** Επεκτείνεται η θεωρία στο πεδίο των χρονοσειρών και αναλύεται διεξοδικά το υπόδειγμα CSDI, το οποίο αποτελεί τη βάση όλων των πειραμάτων της παρούσας μελέτης.
- **Κεφάλαιο — 2.3: Καθοδήγηση σε Μοντέλα Διάχυσης για Χρονοσειρές.** Εισάγεται η έννοια της καθοδήγησης (guidance) και παρουσιάζονται οι κύριες κατηγορίες: με ταξινομητή, χωρίς ταξινομητή, αυτο-καθοδήγηση, plug-and-play και καθοδήγηση με περιορισμούς. Παράλληλα, διατυπώνεται το θεωρητικό υπόβαθρο που επιτρέπει την ενσωμάτωση καθοδήγησης στη ροή της διάχυσης.
- **Κεφάλαιο — 3: Θεωρία και Εφαρμογή του Πειραματικού Μοντέλου.** Περιγράφεται το καθοδηγούμενο υπόδειγμα που χρησιμοποιήθηκε στα πειράματα — μια προσαρμοσμένη εκδοχή του CSDI με μηχανισμό pairs-only guidance. Αναλύεται ο τρόπος ενσωμάτωσης της καθοδήγησης μέσω ζευγών, ο τελεστής εκτός σύνδεσης συσχέτισης και οι δυναμικές της καθοδηγούμενης ροής διάχυσης.
- **Κεφάλαιο — 4: Δημιουργία Συνόλων Δεδομένων και Επεξήγηση Μετρικών.** Παρουσιάζονται τα τρία σύνολα δεδομένων που χρησιμοποιήθηκαν (BabySlakh, Lorenz-96, PEMS-SF), μαζί με τις μετρικές αξιολόγησης όπως η επιλεκτικότητα (selectivity), το ποσοστό εκτός στόχου (spill-offtarget) και η ευθυγράμμιση (alignment).
- **Κεφάλαιο — 5: Πειράματα και Σχολιασμός.** Περιλαμβάνονται τα αποτελέσματα των καθοδηγούμενων και μη καθοδηγούμενων δειγματοληψιών, συγκριτικές μετρήσεις, πίνακες και ποιοτική ανάλυση των επιδράσεων καθοδήγησης στη συσχέτιση και στη δομή των παραγόμενων χρονοσειρών.
- **Κεφάλαιο — 6: Μελλοντικές Επεκτάσεις.** Συνοψίζονται τα βασικά συμπεράσματα και προτείνονται κατευθύνσεις για περαιτέρω έρευνα, όπως η γενίκευση σε πλήρως γραφοκαθοδηγούμενα μοντέλα, η ενσωμάτωση φυσικών περιορισμών και η αυτόματη εκμάθηση βαρών καθοδήγησης.
- **Κεφάλαιο — 7: Παράρτημα.**

Μέρος II

Θεωρητικό Υπόβαθρο

Κεφάλαιο 2

Βασική Θεωρία Μοντέλων Διάχυσης

Diffusion Models

2.1 Εισαγωγή στα Μοντέλα Διάχυσης


Τα diffusion models αποτελούν μία κατηγορία γενετικών μοντέλων που μαθαίνουν να προσεγγίζουν την κατανομή των δεδομένων μέσω μιας αλληλουχίας διεργασιών προσθήκης και αφαίρεσης θορύβου. Η βασική τους ιδέα είναι εμπνευσμένη από φυσικές διεργασίες διάχυσης: όπως τα μόρια ενός αερίου διαχέονται σταδιακά μέχρι να φτάσουν σε κατάσταση ισορροπίας, έτσι και ένα δείγμα δεδομένων x_0 αλλοιώνεται προοδευτικά μέσα σε θόρυβο μέσω ενός *forward process*. Στη συνέχεια, ένα νευρωνικό δίκτυο εκπαιδεύεται να μάθει την αντίστροφη ροή (reverse process), ώστε να μπορεί να ανασυνθέτει καθαρά δείγματα ξεκινώντας από τυχαίο θόρυβο.

Η διπλή αυτή διαδικασία διάχυσης και αναστροφής επιτρέπει την κατασκευή μοντέλων που δημιουργούν νέα δεδομένα με υψηλό ρεαλισμό, διατηρώντας ταυτόχρονα σταθερότητα και θεωρητική ερμηνευσιμότητα. Σε αντίθεση με τις τεχνικές τύπου GANs ή VAEs, τα μοντέλα διάχυσης ορίζουν ρητά μια στοχαστική αλυσίδα μετασχηματισμών, επιτρέποντας πλήρη έλεγχο στη ροή πληροφορίας και στον βαθμό αβεβαιότητας σε κάθε χρονικό βήμα.

Με απλά λόγια, η εκπαίδευση ενός μοντέλου διάχυσης συνίσταται στο να μάθει *πώς να αντιστρέφει* μια γνωστή διαδικασία προσθήκης θορύβου. Το πρώτο βήμα, λοιπόν, είναι να περιγράψουμε με ακρίβεια αυτήν τη διαδικασία προώθησης, γνωστή ως forward diffusion process.

2.1.1 Εμπρόσθια Διαδικασία Διάχυσης

Το βήμα forward diffusion process ορίζει έναν προκαθορισμένο και μη-εκπαιδύσιμο μηχανισμό που μετατρέπει σταδιακά ένα καθαρό δείγμα δεδομένων x_0 σε θόρυβο. Πρακτικά, η διαδικασία αυτή λειτουργεί ως μοντέλο αλλοίωσης πληροφορίας καθώς σε κάθε χρονικό βήμα, προστίθεται ένας μικρός τυχαίος θόρυβος στο προηγούμενο δείγμα, μειώνοντας προοδευτικά την ορατή δομή των δεδομένων μέχρι αυτά να προσεγγίσουν λευκό θόρυβο $N(0, I)$ [32, 12]. Η συγκεκριμένη κατανομή αποτελεί τον φυσικό τελικό στόχο της διαδικασίας, αφού είναι εύκολη στον δειγματισμό και μαθηματικά ομαλή.



Σχήμα 1: Παράδειγμα μοντέλου διάχυσης εικόνων: η σταδιακή διαδικασία προσθήκης θορύβου [32].

Για δεδομένα $x_0 \sim p_{\text{data}}(x_0)$, ορίζουμε μια στοχαστική ακολουθία κατανομών:

$$q(x_t | x_{t-1}) = \mathcal{N}(x_t; \sqrt{1 - \beta_t} x_{t-1}, \beta_t I), \quad (1)$$

όπου η παράμετρος $\beta_t \in (0, 1)$ καθορίζει το μέγεθος του προστιθέμενου θορύβου ανά βήμα και είναι γνωστή ως noise variance schedule. Η σχέση αυτή δηλώνει ότι κάθε x_t προκύπτει από το προηγούμενο x_{t-1} προσθέτοντας έναν μικρό Γκαουσιανό όρο, με αποτέλεσμα μια αλυσίδα Markov:

$$x_0 \rightarrow x_1 \rightarrow x_2 \rightarrow \dots \rightarrow x_T, \quad q(x_{1:T} | x_0) = \prod_{t=1}^T q(x_t | x_{t-1}).$$

Διαισθητικά, κάθε βήμα «ξεθωριάζει» μέρος της πληροφορίας του σήματος, έτσι ώστε μετά από αρκετά στάδια το x_T να μην περιέχει αναγνωρίσιμη δομή.

Κλειστή μορφή ως προς x_0 Η στοχαστική σχέση (1) περιγράφει τη μετάβαση από κάθε δείγμα x_{t-1} στο επόμενο x_t μέσω προσθήκης Γκαουσιανού θορύβου. Ωστόσο, επειδή η διαδικασία αυτή επαναλαμβάνεται για όλα τα χρονικά βήματα, είναι συχνά χρήσιμο να εκφράσουμε απευθείας τη μορφή της κατανομής του x_t ως συνάρτηση του αρχικού καθαρού δείγματος x_0 , χωρίς να χρειάζεται να περάσουμε από όλες τις ενδιάμεσες καταστάσεις $x_1, x_2, \dots, x_{t-1}$. Με αυτόν τον τρόπο αποκτούμε μια *κλειστή μορφή* που δείχνει ξεκάθαρα το πώς το σήμα και ο θόρυβος συνυπάρχουν σε κάθε χρονική στιγμή t .

Η αναδρομική εφαρμογή της (1) οδηγεί στη σχέση:

$$q(x_t | x_0) = \mathcal{N}(x_t; \sqrt{\bar{\alpha}_t} x_0, (1 - \bar{\alpha}_t)I), \quad (2)$$

όπου

$$\bar{\alpha}_t = \prod_{s=1}^t (1 - \beta_s) \quad (3)$$

είναι η εξίσωση που περιγράφει το συνολική αναλογία διατήρησης σήματος (cumulative signal fraction) [12].

Η μορφή αυτή καθιστά σαφές ότι κάθε x_t αποτελεί ένα σταδιακό μίγμα του αρχικού σήματος x_0 και ενός ανεξάρτητου θορύβου. Ο μέσος όρος $\sqrt{\bar{\alpha}_t} x_0$ αντιπροσωπεύει το μέρος του σήματος που έχει διατηρηθεί έως το βήμα t , ενώ η διασπορά $(1 - \bar{\alpha}_t)I$ εκφράζει το ποσοστό θορύβου που έχει προστεθεί. Όσο αυξάνεται το t , η ποσότητα $\bar{\alpha}_t$ μειώνεται μονοτονικά, πράγμα που σημαίνει ότι η πληροφορία του σήματος εξασθενεί και τελικά χάνεται, ενώ ο θόρυβος κυριαρχεί. Στα άκρα, έχουμε $\bar{\alpha}_0 = 1$ (όλο σήμα και καθόλου θόρυβος), ενώ για μεγάλα t η $\bar{\alpha}_t \downarrow 0$, οδηγώντας σε καθαρό λευκό θόρυβο.

Διαισθητικά, μπορούμε να θεωρήσουμε ότι το x_t είναι ένα ρυθμισμένο μίγμα που περιέχει ποσοστό σήματος $\sqrt{\bar{\alpha}_t}$ από το αρχικό δείγμα x_0 και ποσοστό θορύβου με ισχύ $1 - \bar{\alpha}_t$. Η αναλογία αυτών των δύο συστατικών ελέγχεται αποκλειστικά από το χρονοδιάγραμμα θορύβου $\{\beta_t\}$, το οποίο καθορίζει πόσο γρήγορα η πληροφορία του σήματος θα εξαφανιστεί. Αυτή η διατύπωση είναι ιδιαίτερα χρήσιμη, καθώς επιτρέπει τη δειγματοληψία ενός x_t απευθείας από το x_0 χωρίς να απαιτείται η προσομοίωση ολόκληρης της αλυσίδας βημάτων, απλοποιώντας σημαντικά τη μαθηματική ανάλυση και την υλοποίηση του forward process.

Χρονοδιάγραμμα Θορύβου και Παραμετροποιήσεις Αφού κάθε ενδιάμεσο δείγμα x_t μπορεί να θεωρηθεί ως ένα μίγμα καθαρού σήματος και προστιθέμενου θορύβου, είναι προφανές ότι ο τρόπος με τον οποίο αυξάνεται ο θόρυβος στο χρόνο παίζει καθοριστικό ρόλο στη συμπεριφορά του μοντέλου. Η ακολουθία των παραμέτρων $\{\beta_t\}$ καθορίζει τον ρυθμό με τον οποίο το αρχικό σήμα αποσυντίθεται σε θόρυβο και επηρεάζει καθοριστικά τόσο την ποιότητα όσο και τη σταθερότητα της αντίστροφης διαδικασίας. Στην ουσία, το noise schedule ρυθμίζει πόσο γρήγορα μειώνεται η πληροφορία του σήματος καθώς αυξάνεται το t , καθορίζοντας τη δυσκολία του προβλήματος που καλείται να μάθει το δίκτυο αποθορυβοποίησης. Διαφορετικά χρονοδιαγράμματα κατανέμουν την ένταση της θορυβοποίησης σε διαφορετικά τμήματα του χρόνου, με αποτέλεσμα να παράγουν διαφορετική στατιστική συμπεριφορά για τα ενδιάμεσα δείγματα x_t .

Ένα κατάλληλο χρονοδιάγραμμα θορύβου πρέπει να επιτυγχάνει ομαλή αποδόμηση του σήματος, έτσι ώστε το μοντέλο κατά την αντίστροφη διαδικασία να μη χρειάζεται να διορθώνει απότομα μεγάλα σφάλματα μέσα σε λίγα βήματα. Παράλληλα, πρέπει να αποφεύγει ακραίες τιμές του λόγου σήματος προς θόρυβο (SNR), οι οποίες οδηγούν σε αριθμητικές αστάθειες, και να προσαρμόζεται στο είδος των δεδομένων. Για παράδειγμα, σε χρονοσειρές

με ομαλή χρονική δομή, είναι επιθυμητό το σήμα να φθείρεται με ήπιους ρυθμούς, ώστε να διατηρείται η πληροφορία των συσχετίσεων για περισσότερα χρονικά βήματα. Αντίθετα, ένα υπερβολικά επιθετικό χρονοδιάγραμμα θα οδηγούσε σε ταχεία απώλεια πληροφορίας και δυσκολότερη εκπαίδευση.

Αν και οι εξισώσεις της προώθησης (1) και της κλειστής μορφής (2) παραμένουν ίδιες, η συγκεκριμένη επιλογή του β_t επηρεάζει άμεσα το πώς το μοντέλο «αντιλαμβάνεται» τα ενδιάμεσα στάδια της θορυβώδους ακολουθίας. Στην πράξη, ένα ισορροπημένο χρονοδιάγραμμα πρέπει να επιτρέπει στο δίκτυο να βλέπει δείγματα όπου η πληροφορία είναι μερικώς αλλοιωμένη αλλά όχι εντελώς χαμένη· μόνο έτσι το δίκτυο μπορεί να μάθει σταθερά και προοδευτικά τη διαδικασία αποθορυβοποίησης.

Cosine schedule. Μία από τις πιο διαδεδομένες και σταθερές επιλογές αποτελεί η cosine παραμετροποίηση [27], η οποία εξασφαλίζει ομαλή και φυσική φθορά του σήματος στο χρόνο. Η βασική ιδέα είναι να επιτρέψουμε αργή απώλεια πληροφορίας στα αρχικά στάδια —όπου η δομή του σήματος είναι ακόμη πλούσια— και σταδιακή επιτάχυνση προς το τέλος, έτσι ώστε η κατανομή να συγκλίνει ομαλά στη Γκαουσιανή $N(0, I)$. Η σωρευτική αναλογία διατήρησης σήματος ορίζεται ως:

$$\bar{\alpha}(t) = \frac{\cos^2\left(\frac{\pi}{2} \frac{t+s}{1+s}\right)}{\cos^2\left(\frac{\pi}{2} \frac{s}{1+s}\right)}, \quad s \in [0, 0.008], \quad (4)$$

ενώ για διακριτά βήματα $t = 1, \dots, T$ ορίζουμε $u = t/T$ και λαμβάνουμε:

$$\beta_t = 1 - \frac{\bar{\alpha}_t}{\bar{\alpha}_{t-1}}, \quad \bar{\alpha}_0 := 1. \quad (5)$$

Η συγκεκριμένη μορφή έχει το πλεονέκτημα ότι κατανέμει την ενέργεια του σήματος με τρόπο που μιμείται φυσικές διαδικασίες φθοράς: στα πρώτα βήματα, η πληροφορία παραμένει σε μεγάλο βαθμό ανέπαφη, επιτρέποντας στο δίκτυο να αναγνωρίσει και να μάθει τα βασικά δομικά μοτίβα, ενώ στα τελευταία βήματα, όπου η $\bar{\alpha}_t$ τείνει στο μηδέν, το σήμα έχει πλήρως θορυβοποιηθεί και η διαδικασία συγκλίνει στην επιθυμητή κατανομή λευκού θορύβου. Αυτό εξηγεί γιατί η cosine schedule οδηγεί σε σταθερότερη εκπαίδευση και σε πιο ρεαλιστικά δείγματα σε σύγκριση με γραμμικά ή εκθετικά χρονοδιαγράμματα.

logSNR παραμετροποίηση. Μια εναλλακτική και συχνά πιο διαφανής θεώρηση είναι η παραμετροποίηση μέσω της μεταβλητής log-SNR [19]. Αντί να εργαζόμαστε απευθείας με τις ποσότητες α_t ή $\bar{\alpha}_t$, ορίζουμε

$$\lambda_t = \log \frac{\bar{\alpha}_t}{1 - \bar{\alpha}_t}, \quad \text{SNR}(t) = \frac{\bar{\alpha}_t}{1 - \bar{\alpha}_t}, \quad (6)$$

με αντίστροφη σχέση

$$\bar{\alpha}_t = \sigma(\lambda_t) = \frac{1}{1 + e^{-\lambda_t}}, \quad 1 - \bar{\alpha}_t = \sigma(-\lambda_t). \quad (7)$$

Η μεταβλητή λ_t αποτυπώνει τη σχετική ισορροπία σήματος και θορύβου σε λογαριθμική κλίμακα, μεγάλωνοντας την αριθμητική σταθερότητα και επιτρέποντας πιο ομαλή κατανομή των δειγμάτων κατά την εκπαίδευση. Η προσέγγιση αυτή καθιστά ευκολότερη τη σχεδίαση χρονοδιαγραμμάτων και σταθμίσεων, καθώς το λ_t μπορεί να θεωρηθεί ως συνεχής δείκτης καθαρότητας του δείγματος. Για παράδειγμα, σε μικρές τιμές λ_t (χαμηλό SNR) το δείγμα είναι σχεδόν καθαρός θόρυβος, ενώ σε μεγάλες τιμές κυριαρχεί το σήμα. Αυτό το ενιαίο μέτρο καθιστά δυνατή την ομοιογενή βαθμονόμηση ανάμεσα στα timesteps και οδηγεί σε πιο σταθερή εκπαίδευση σε όλα τα t .

Συνολικά, τόσο η cosine schedule όσο και η log-SNR parameterization δεν αλλάζουν τη βασική θεωρία της διάχυσης, αλλά επηρεάζουν τη δυναμική της μάθησης. Η πρώτη ορίζει ένα πρακτικά βελτιστοποιημένο προφίλ αποδόμησης σήματος, ενώ η δεύτερη παρέχει ένα συνεχές και αριθμητικά σταθερό πλαίσιο για τη διαχείριση του λόγου σήματος προς θόρυβο. Οι δύο αυτές επιλογές χρησιμοποιούνται ευρέως σε σύγχρονες υλοποιήσεις, είτε σε απλά DDPM είτε σε πιο προχωρημένα μοντέλα όπως τα Variational Diffusion Models (VDM) [19].

Επαναπροσδιόριση Παραμέτρων Η κλειστή μορφή της εξίσωσης (2) μπορεί να εκφραστεί με έναν ιδιαίτερα πρακτικό τρόπο, γνωστό ως reparameterization form. Η αναπαράσταση αυτή γράφεται ως:

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, \quad \epsilon \sim \mathcal{N}(0, I). \quad (8)$$

Η εξίσωση δείχνει ότι κάθε θορυβώδες δείγμα x_t μπορεί να θεωρηθεί ως γραμμικός συνδυασμός δύο συνιστωσών: ενός καθαρού όρου signal που διατηρείται από το αρχικό δείγμα x_0 και ενός τυχαίου όρου noise που εκφράζεται μέσω του ϵ . Η ποσότητα $\bar{\alpha}_t$ ρυθμίζει το ποσοστό συμμετοχής κάθε όρου, όταν το t είναι μικρό, η $\bar{\alpha}_t$ είναι κοντά στο 1 και το δείγμα παραμένει σχεδόν καθαρό, ενώ για μεγάλα t η $\bar{\alpha}_t$ προσεγγίζει το μηδέν και το x_t μετατρέπεται σε καθαρό θόρυβο. Έτσι, η εξίσωση λειτουργεί ως ένας συνεχής συνδυασμός μεταξύ του αρχικού σήματος και του θορύβου, ελέγχοντας το βαθμό αλλοίωσης μέσω του χρόνου.

Αυτή η μορφή είναι εξαιρετικά χρήσιμη στην πράξη, καθώς επιτρέπει την παραγωγή ενός δείγματος x_t απευθείας από το x_0 χωρίς την ανάγκη να προσομοιωθούν όλα τα ενδιάμεσα βήματα της αλυσίδας. Μια απλή κλήση παραγωγής Γκαουσιανού θορύβου αρκεί για να δημιουργήσει το επιθυμητό επίπεδο αλλοίωσης, γεγονός που κάνει την εξίσωση ιδανική για υλοποιήσεις σε κώδικα. Επιπλέον, προσφέρει έναν καθαρό διαχωρισμό μεταξύ του deterministic component (το μέρος που προέρχεται από το αρχικό σήμα) και του stochastic component (το μέρος που εισάγεται τυχαία μέσω του θορύβου), κάτι που βοηθά τόσο στην ανάλυση όσο και στη σταθερότητα των πειραμάτων. Η διαδικασία είναι επίσης επαναλήψιμη: με σταθερό seed για τη μεταβλητή ϵ , παράγονται ακριβώς τα ίδια θορυβώδη δείγματα, γεγονός ιδιαίτερα χρήσιμο για συγκρίσεις και αναπαραγωγές αποτελεσμάτων.

Τέλος, η μορφή αυτή συνδέεται άμεσα με τη στατιστική περιγραφή της (2), καθώς προκύπτει εύκολα ότι $\mathbb{E}[x_t | x_0] = \sqrt{\bar{\alpha}_t} x_0$ και $\text{Var}(x_t | x_0) = (1 - \bar{\alpha}_t)I$, επιβεβαιώνοντας ότι η reparameterization form αποτελεί ακριβή αναπαράσταση της στοχαστικής διεργασίας διάχυσης.

Ερμηνεία Μεταβλητών

Σύμβολο	Έννοια	Τυπική Τιμή / Εύρος
x_0	Καθαρό δείγμα δεδομένων	Από p_{data}
x_t	Θορυβώδες δείγμα μετά από t βήματα	Ενδιάμεση κατάσταση
β_t	Διασπορά προστιθέμενου θορύβου	$10^{-4} \rightarrow 10^{-2}$
$\alpha_t = 1 - \beta_t$	Αναλογία διατήρησης σήματος	Κοντά στο 1
$\bar{\alpha}_t = \prod_{s=1}^t \alpha_s$	Σωρευτική αναλογία	Μειώνεται με t


Κάθε βήμα λοιπόν λειτουργεί ως ένας μικρός μηχανισμός αποδόμησης: το αρχικό σήμα χάνει σταδιακά την ταυτότητά του, ενώ το θορυβώδες στοιχείο ενισχύεται. Μετά από αρκετά βήματα, η κατανομή του τελικού δείγματος προσεγγίζει την κανονική:

$$x_T \approx \mathcal{N}(0, I), \quad (9)$$

η οποία θα αποτελέσει το σημείο εκκίνησης της αντίστροφης διαδικασίας που μαθαίνει το μοντέλο.

2.1.2 Αντίστροφη Διαδικασία Διάχυσης

Η διεργασία αντιστροφής (reverse diffusion process) είναι το βασικότερο στάδιο στη λειτουργία των diffusion models, καθώς καθορίζει πώς ένα δείγμα καθαρού θορύβου μπορεί να μετατραπεί ξανά σε συνεκτικά και ρεαλιστικά δεδομένα. Ενώ το forward process είναι πλήρως προκαθορισμένο και μη εκπαιδύσιμο, η αντίστροφη διαδικασία πρέπει να *εκτιμηθεί* από το μοντέλο, καθώς η ακριβής κατανομή των πραγματικών δεδομένων είναι άγνωστη. Κατά την εκπαίδευση, το μοντέλο μαθαίνει να προσεγγίζει τη στατιστική σχέση ανάμεσα στα ενδιάμεσα θορυβώδη δείγματα x_t και στα καθαρά δείγματα x_0 , ώστε κατά τη δειγματοληψία να μπορεί να ανασυνθέτει τη διαδικασία αυτή βήμα προς βήμα.



Σχήμα 2: Παράδειγμα αντίστροφης διαδικασίας διάχυσης (Reverse Diffusion): η σταδιακή απομάκρυνση του θορύβου και η επαναφορά της αρχικής εικόνας [12].

Η μαθηματική θεμελίωση του reverse process μπορεί να διατυπωθεί με τρεις κύριες προσεγγίσεις: την διακριτή πιθανοθεωρητική μορφή των DDPM, την ντετερμινιστική παραλλαγή των DDIM, και τη συνεχή στοχαστική θεώρηση των score-based SDE models. Κάθε μία από αυτές ορίζει διαφορετικό τρόπο με τον οποίο πραγματοποιείται η αντίστροφη διάχυση, διατηρώντας ωστόσο κοινή θεωρητική βάση.

Denoising Diffusion Probabilistic Models(DDPM) Η πρώτη μορφή, γνωστή ως Denoising Diffusion Probabilistic Model (DDPM) [12], προσεγγίζει την αντίστροφη διαδικασία ως μια ακολουθία διακριτών Γκαουσιανών μεταβάσεων. Η θεωρητική μορφή του ιδανικού βήματος προκύπτει από τον κανόνα του Bayes:

$$q(x_{t-1} | x_t, x_0) \propto q(x_t | x_{t-1}) q(x_{t-1} | x_0), \quad (10)$$

και οδηγεί στην κατανομή

$$q(x_{t-1} | x_t, x_0) = \mathcal{N}(x_{t-1}; \tilde{\mu}_t(x_t, x_0), \tilde{\beta}_t I), \quad (11)$$

όπου η μέση τιμή $\tilde{\mu}_t(x_t, x_0)$ και η διασπορά $\tilde{\beta}_t$ υπολογίζονται αναλυτικά με βάση τα γνωστά α_t και $\bar{\alpha}_t$ του forward process. Κατά τη δειγματοληψία, όμως, το x_0 είναι άγνωστο, επομένως χρειάζεται ένα μοντέλο που να μπορεί να το εκτιμήσει ή να προβλέπει τον θόρυβο που το αντικαθιστά.

Για τον σκοπό αυτό, εισάγεται ένα παραμετρικό δίκτυο $p_\theta(x_{t-1} | x_t)$ το οποίο προσεγγίζει την ιδανική αντίστροφη προβλέποντας το πρόσθετο θορυβώδες στοιχείο:

$$p_\theta(x_{t-1} | x_t) = \mathcal{N}(x_{t-1}; \mu_\theta(x_t, t), \tilde{\beta}_t I), \quad (12)$$

όπου η μέση τιμή δίνεται από

$$\mu_\theta(x_t, t) = \frac{1}{\sqrt{\alpha_t}} \left(x_t - \frac{1 - \alpha_t}{\sqrt{1 - \alpha_t}} \epsilon_\theta(x_t, t) \right). \quad (13)$$

Το δίκτυο μαθαίνει να προβλέπει τον θόρυβο $\epsilon_\theta(x_t, t)$ μέσω μιας απλής απώλειας mean squared error:

$$\mathcal{L}_{\text{simple}}(\theta) = \mathbb{E}_{x_0, \epsilon, t} [\|\epsilon - \epsilon_\theta(x_t, t)\|_2^2], \quad x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon. \quad (14)$$

Αυτή η διατύπωση έχει το πλεονέκτημα ότι είναι σταθερή αριθμητικά, εύκολη στην υλοποίηση και επαρκώς εκφραστική για πολύπλοκες κατανομές. Η αντίστροφη πραγματοποιείται δειγματοληπτικά, καθώς σε κάθε βήμα t προστίθεται ένα νέο δείγμα θορύβου από $\mathcal{N}(0, \beta_t I)$, γεγονός που καθιστά τη διαδικασία στοχαστική και ποικιλόμορφη. Η μέθοδος αυτή είναι η βάση σχεδόν όλων των σύγχρονων diffusion frameworks.

Denoising Diffusion Implicit Models(DDIM) Η μέθοδος Denoising Diffusion Implicit Model (DDIM) [33] προτείνει μια εναλλακτική, πιο ντετερμινιστική εκδοχή της αντίστροφης διαδικασίας. Ενώ τα DDPM εισάγουν νέο θόρυβο σε κάθε βήμα, τα DDIM ορίζουν μια αντιστοιχία όπου το x_t μετασχηματίζεται στο x_{t-1} χωρίς νέα τυχαία δειγματοληψία. Η μορφή αυτή επιτρέπει στον χρήστη να ελέγχει τη σχέση μεταξύ στοχαστικότητας και συνέπειας, παράγοντας πιο ρεαλιστικά και συνεπή δείγματα.

Η βασική εξίσωση δίνεται από

$$x_{t-1} = \sqrt{\bar{\alpha}_{t-1}} \hat{x}_0(x_t, t) + \sqrt{1 - \bar{\alpha}_{t-1}} \epsilon_\theta(x_t, t), \quad (15)$$

όπου $\hat{x}_0(x_t, t) = \frac{x_t - \sqrt{1 - \bar{\alpha}_t} \epsilon_\theta(x_t, t)}{\sqrt{\bar{\alpha}_t}}$ είναι η εκτίμηση του καθαρού σήματος. Αν η στοχαστικότητα καταργηθεί εντελώς, η αντιστροφή γίνεται ντετερμινιστική, προσφέροντας έναν πιο ελεγχόμενο τρόπο παραγωγής δεδομένων.

Η λογική πίσω από τα DDIM είναι ότι η αντιστροφή μπορεί να ιδωθεί ως *implicit ODE*, δηλαδή ως ντετερμινιστική εξίσωση διαφορών, που συνδέει ομαλά το x_T με το x_0 χωρίς τη συνεχή εισαγωγή τυχαίων όρων. Αυτό έχει δύο βασικά αποτελέσματα: τα δείγματα είναι πιο συνεπή μεταξύ τους για ίδιο seed, και ο αριθμός των απαιτούμενων βημάτων μπορεί να μειωθεί σημαντικά χωρίς σοβαρή απώλεια ποιότητας. Η μέθοδος αυτή είναι ιδιαίτερα χρήσιμη σε περιπτώσεις όπου επιθυμείται ταχύτητα δειγματοληψίας ή έλεγχος του ρυθμού αποθορυβοποίησης, όπως σε diffusion-based text-to-image συστήματα.

Score-based Generative Modeling μέσω SDEs Η τρίτη και πιο γενική θεώρηση της αντίστροφης διάχυσης είναι η συνεχής στοχαστική εκδοχή των score-based SDE models [34]. Αντί για διακριτά βήματα, η διαδικασία περιγράφεται από μια στοχαστική διαφορική εξίσωση του τύπου

$$dx = [f(x, t) - g(t)^2 \nabla_x \log p_t(x)] dt + g(t) d\bar{w}, \quad (16)$$

όπου $f(x, t)$ και $g(t)$ είναι οι συντελεστές του forward SDE, και η συνάρτηση $\nabla_x \log p_t(x)$, γνωστή ως score function, εκτιμάται από το μοντέλο. Η τελευταία συνδέεται με το παραμετρικό δίκτυο μέσω της σχέσης

$$\nabla_x \log p_t(x) \simeq -\frac{1}{\sqrt{1 - \bar{\alpha}_t}} \epsilon_\theta(x_t, t). \quad (17)$$

Η συνεχή αυτή μορφή έχει το πλεονέκτημα ότι ενώνει τη θεωρία των diffusion probabilistic models με τα score matching μοντέλα. Η αντιστροφή υλοποιείται μέσω αριθμητικής ολοκλήρωσης μιας reverse SDE ή του αντίστοιχου deterministic ODE (γνωστού ως probability flow ODE), παρέχοντας ευελιξία ως προς το επίπεδο στοχαστικότητας και τον ρυθμό αποθορυβοποίησης. Η θεώρηση αυτή είναι πιο γενική και έχει επιτρέψει σημαντικές προεκτάσεις, όπως adaptive sampling, continuous-time training, και unified score-based frameworks που περιλαμβάνουν τόσο τα DDPM όσο και τα DDIM ως ειδικές περιπτώσεις.

Αρχιτεκτονικές και πρακτικές υλοποιήσεις Η υλοποίηση του παραμετρικού μοντέλου $\epsilon_\theta(x_t, t)$ εξαρτάται από τον τύπο των δεδομένων και τη φύση του conditioning. Για εικόνες, τα περισσότερα συστήματα χρησιμοποιούν ένα UNet με πολυκλιμακωτή ανάλυση και skip connections, όπου το χρονικό embedding t εισάγεται σε κάθε επίπεδο μέσω FiLM ή sinusoidal embeddings. Σε πιο πρόσφατες προσεγγίσεις, οι Diffusion Transformers (DiT) αντικαθιστούν τα convolutional layers με self-attention μηχανισμούς, επιτυγχάνοντας καλύτερη παγκόσμια συνέπεια. Σε μοντέλα latent diffusion, η διάχυση εφαρμόζεται σε συμπιεσμένο latent χώρο, επιτρέποντας παραγωγή υψηλής ανάλυσης με μειωμένο υπολογιστικό κόστος.

Για χρονοσειρές και δεδομένα χρόνου, χρησιμοποιούνται temporal UNet, Temporal Convolutional Networks (TCN) και Transformers με time embeddings και cross-attention. Σε χωροχρονικά δεδομένα, όπως κυκλοφορία ή αισθητήρες, υβριδικές αρχιτεκτονικές που συνδυάζουν Graph Neural Networks (GNNs) με attention μηχανισμούς αξιοποιούν τη χωρική συσχέτιση μεταξύ κόμβων. Το βασικό ζητούμενο σε κάθε περίπτωση είναι η εκτίμηση μιας συνάρτησης $\epsilon_\theta(x_t, t, \text{cond})$ που να προβλέπει τον θόρυβο σε κάθε χρονικό βήμα και να επιτρέπει τη σταθερή αντιστροφή της διάχυσης.

2.1.3 Διαδικασία Δειγματοληψίας

Αφού περιγράψαμε πώς η εμπρόσθια διαδικασία διάχυσης μετατρέπει σταδιακά το καθαρό δείγμα x_0 σε θόρυβο μέσω της προσθήκης των βημάτων $\{\beta_t\}$, το επόμενο στάδιο είναι να αντιστρέψουμε αυτή τη διαδικασία, ώστε να παραχθούν νέα δείγματα από θόρυβο προς δεδομένα. Η διαδικασία αυτή ονομάζεται *δειγματοληψία* και αποτελεί το ουσιαστικό γενετικό σκέλος του μοντέλου διάχυσης. Αφού το δίκτυο έχει εκπαιδευτεί να προβλέπει τον προστιθέμενο θόρυβο $\epsilon_\theta(x_t, t)$, όπως ορίζεται στην απώλεια (14), μπορούμε να χρησιμοποιήσουμε αυτή τη γνώση για να αναδομήσουμε προοδευτικά το αρχικό σήμα. Με αυτόν τον τρόπο, το μοντέλο αντιστρέφει τη διάχυση: ξεκινά από καθαρό Γκαουσιανό θόρυβο και εφαρμόζει διαδοχικά τα αντίστροφα βήματα που έχει μάθει, παράγοντας στο

τέλος ένα ρεαλιστικό δείγμα x_0 που ακολουθεί την κατανομή των πραγματικών δεδομένων. Η διαδικασία αυτή μπορεί να θεωρηθεί ως μια generative trajectory στον χώρο των θορυβωμένων μεταβλητών, η οποία μετατρέπει σταδιακά τον τυχαίο θόρυβο σε δομημένα δεδομένα.

Αρχικοποίηση και στόχος της δειγματοληψίας Η δειγματοληψία ξεκινά με την τυχαία αρχικοποίηση ενός δείγματος από την κανονική κατανομή, όπως φαίνεται στην (1) για το $t = T$:

$$x_T \sim \mathcal{N}(0, I),$$

όπου T είναι ο συνολικός αριθμός βημάτων διάχυσης. Στόχος είναι, μέσω μιας ακολουθίας αντιστροφών $t = T, T-1, \dots, 1$, να ανακατασκευαστεί η μη θορυβώδης εκδοχή x_0 . Σε κάθε βήμα, το δίκτυο εκτιμά ποιο μέρος του x_t προέρχεται από το καθαρό σήμα και ποιο από τον θόρυβο, εφαρμόζοντας τον μηχανισμό αποθορυβοποίησης που έμαθε κατά την εκπαίδευση.

Αντίστροφο βήμα και υπολογισμός μέσης τιμής Από το εμπρόσθιο βήμα της (1) προκύπτει ότι η αληθής αντίστροφη κατανομή είναι επίσης Γκαουσιανή, όπως ορίστηκε στην (11). Κατά τη δειγματοληψία, όμως, το x_0 δεν είναι γνωστό και επομένως χρησιμοποιούμε την εκτίμηση του μοντέλου μέσω της πρόβλεψης θορύβου $\epsilon_\theta(x_t, t)$. Η αντίστοιχη εκτίμηση του καθαρού δείγματος δίνεται από:

$$\hat{x}_0(x_t, t) = \frac{1}{\sqrt{\bar{\alpha}_t}} (x_t - \sqrt{1 - \bar{\alpha}_t} \epsilon_\theta(x_t, t)).$$

, ενώ η μέση τιμή υπολογίζεται με την (13). Με αυτές τις σχέσεις, η δειγματοληψία αποκτά την πλήρη μορφή της και μπορεί να υλοποιηθεί είτε στοχαστικά είτε αποφασιστικά, ανάλογα με τη μέθοδο που χρησιμοποιείται.

Δειγματοληψία με DDPM Η κλασική μέθοδος δειγματοληψίας των DDPM [12] θεωρεί ότι κάθε αντίστροφο βήμα είναι μια στοχαστική μετάβαση της μορφής:

$$x_{t-1} = \mu_\theta(x_t, t) + \sigma_t z, \quad z \sim \mathcal{N}(0, I). \quad (18)$$

Σε κάθε στάδιο, το δίκτυο υπολογίζει τη μέση τιμή $\mu_\theta(x_t, t)$, ενώ ο όρος $\sigma_t z$ προσθέτει ελεγχόμενη στοχαστικότητα, επιτρέποντας τη δημιουργία πολλών διαφορετικών δειγμάτων για ίδια αρχική συνθήκη. Η διαδικασία είναι προοδευτική και αργή, καθώς απαιτεί εκατοντάδες ή και χιλιάδες βήματα, όμως εγγυάται δείγματα που ακολουθούν πιστά την πραγματική κατανομή των δεδομένων.

Διαισθητικά, κάθε βήμα αφαιρεί ένα λεπτό στρώμα θορύβου, επανεισάγοντας σταδιακά τη δομή που υπήρχε στο αρχικό δείγμα. Ο μηχανισμός μοιάζει με διαδοχικές φάσεις καθαρισμού του σήματος, όπου το μοντέλο λειτουργεί ως φίλτρο που γνωρίζει το στατιστικό προφίλ του θορύβου.

Δειγματοληψία με DDIM Η μέθοδος Denoising Diffusion Implicit Model (DDIM) [33] προτείνει μια παραλλαγή όπου τα αντίστροφα βήματα δεν περιλαμβάνουν νέα τυχαία δειγματοληψία. Αντίθετα, η διαδικασία ορίζεται ντετερμινιστικά, παράγοντας κάθε x_{t-1} ως συνάρτηση του προηγούμενου x_t και της εκτίμησης του καθαρού σήματος όπως στην (??):

$$x_{t-1} = \sqrt{\bar{\alpha}_{t-1}} \hat{x}_0(x_t, t) + \sqrt{1 - \bar{\alpha}_{t-1}} \epsilon_\theta(x_t, t). \quad (19)$$

Η σχέση αυτή οδηγεί σε πιο ομαλή και ελεγχόμενη τροχιά στον λανθάνοντα χώρο, η οποία διατηρεί τις σωστές οριακές κατανομές αλλά μειώνει τη στοχαστικότητα. Έτσι, τα DDIM είναι κατάλληλα για ταχύτερη δειγματοληψία με λιγότερα βήματα, χωρίς σημαντική απώλεια ποιότητας, κάτι ιδιαίτερα χρήσιμο σε εφαρμογές πραγματικού χρόνου.

Η απουσία τυχαίου όρου σημαίνει ότι για κάθε αρχικό seed το αποτέλεσμα είναι αναπαραγώγιμο. Η μέθοδος, αν και πιο άκαμπτη στα παραγόμενα δείγματα, προσφέρει μεγαλύτερο έλεγχο στη συμπεριφορά του μοντέλου και μπορεί να θεωρηθεί ως ειδική περίπτωση της ντετερμινιστικής probability flow ODE.

Συνεχής δειγματοληψία και θεωρητική ενοποίηση Στο όριο συνεχούς χρόνου, οι διακριτές μέθοδοι DDPM και DDIM αντιστοιχούν σε διαφορετικές ολοκληρώσεις της αντίστροφης stochastic differential equation (SDE) της (16):

$$dx = [f(x, t) - g(t)^2 \nabla_x \log p_t(x)] dt + g(t) d\bar{w}. \quad (20)$$

Αν αφαιρέσουμε τον στοχαστικό όρο $g(t) d\bar{w}$, προκύπτει η ντετερμινιστική probability flow ODE, η οποία συνδέει άμεσα τα DDIM με τα score-based SDE models [34]. Με αυτή τη θεώρηση, η δειγματοληψία δεν είναι απλώς μια σειρά διακριτών βημάτων, αλλά μια συνεχής ροή στον χώρο των πιθανοτήτων, η οποία μεταφέρει την κατανομή $p_T(x_T) = \mathcal{N}(0, I)$ προς το $p_0(x_0)$ των πραγματικών δεδομένων.

Αριθμητικά, η ολοκλήρωση της εξίσωσης μπορεί να γίνει με σχήματα Euler–Maruyama ή με κλασικούς ODE solvers για τις ντετερμινιστικές εκδοχές. Η επιλογή του solver, του αριθμού βημάτων και του χρονοδιαγράμματος θορύβου επιτρέπει έναν άμεσο συμβιβασμό ανάμεσα στην ποιότητα, την ταχύτητα και τη στοχαστικότητα της παραγωγής.

Οι μέθοδοι δειγματοληψίας των diffusion models αποτελούν τη γέφυρα ανάμεσα στη θεωρία και την πράξη. Η DDPM προσφέρει πιστή πιθανοτική ανακατασκευή με υψηλή ποικιλία, η DDIM παρέχει ελεγχόμενη και ταχύτερη παραγωγή, ενώ η συνεχής SDE θεώρηση ενοποιεί θεωρητικά τις δύο και επιτρέπει ευέλικτες προσαρμογές στα μοντέλα και στα datasets. Σε όλες τις περιπτώσεις, η επιτυχία της διαδικασίας εξαρτάται από την ποιότητα της εκτίμησης του θορύβου ϵ_θ , την ομαλότητα του χρονοδιαγράμματος $\{\beta_t\}$ και τη σταθερότητα του solver που χρησιμοποιείται για την ολοκλήρωση της αντίστροφης ροής.

2.2 Μοντέλα Διάχυσης για Χρονοσειρές και Ανάλυση Μοντέλου CSDI

Η πρόσφατη εξέλιξη των diffusion models έχει αναδείξει μια εντυπωσιακά ευέλικτη κατηγορία γενετικών μοντέλων, ικανών να μάθουν περίπλοκες πολυδιάστατες κατανομές χωρίς να απαιτούν ρητές παραδοχές για το σχήμα των δεδομένων. Από την πρώτη θεμελίωση μέσω θερμοδυναμικών αναλογιών [32] έως τα καθιερωμένα πλαίσια DDPM [12] και Score-based SDEs [34], η θεωρία της διάχυσης έχει αποδείξει ότι μπορεί να αναπαράγει υψηλής πιστότητας κατανομές σε εικόνες, ήχο, βίντεο και κείμενο, με τρόπο σταθερό και ελεγχόμενο.

Η επέκταση αυτής της θεωρίας στις χρονοσειρές αποτελεί φυσικό αλλά ταυτόχρονα μη τετριμμένο βήμα. Σε πλήθος εφαρμογών — όπως η πρόβλεψη μετεωρολογικών, ενεργειακών ή χρηματοοικονομικών μεγεθών, η ανάλυση ιατρικών σημάτων και η ανακατασκευή αισθητηριακών μετρήσεων — τα δεδομένα έχουν σαφή χρονική δομή και ενσωματώνουν εξαρτήσεις μεγάλης διάρκειας. Οι κλασικές στοχαστικές ή νευρωνικές προσεγγίσεις (π.χ. RNNs, VAEs, GANs) δυσκολεύονται να αποτυπώσουν επαρκώς την αβεβαιότητα και τη μη γραμμικότητα των πραγματικών διαδικασιών, ενώ τα diffusion models προσφέρουν έναν συνεπή μηχανισμό που περιγράφει την παραγωγή δεδομένων ως σταδιακή αποθρυβοποίηση ενός θορυβώδους συστήματος.

Η βασική ιδέα παραμένει ίδια με την κλασική θεωρία: ένα προωθητικό στάδιο (forward process) που σταδιακά προσθέτει θόρυβο σε ένα καθαρό σήμα, και ένα αντίστροφο στάδιο (reverse process) που μαθαίνεται από το μοντέλο για να ανακτήσει την αρχική δομή. Ωστόσο, όταν το σήμα εξελίσσεται στο χρόνο, η ίδια διαδικασία πρέπει να προσαρμοστεί ώστε να διατηρεί τη χρονική αιτιότητα και τις συσχετίσεις μεταξύ χαρακτηριστικών. Η άμεση εφαρμογή των εξισώσεων (1)–(16) σε τέτοια δεδομένα θα κατέστρεφε τις χρονικές εξαρτήσεις και θα οδηγούσε σε μη ρεαλιστικές προσομοιώσεις.

Για τον λόγο αυτό, τα *μοντέλα διάχυσης για χρονοσειρές* (Time-Series Diffusion Models) εισάγουν ειδική συνθηκοποίηση (conditional diffusion), μάσκες παρατήρησης και αρχιτεκτονικές που ενσωματώνουν τη χρονική πληροφορία. Η παρούσα ενότητα παρουσιάζει το θεωρητικό υπόβαθρο αυτής της προσαρμογής, ξεκινώντας με την ανάλυση των χαρακτηριστικών των δεδομένων χρονοσειρών και καταλήγοντας στο βασικό μοντέλο αναφοράς CSDI [35], το οποίο αποτελεί το θεμέλιο για όλες τις επόμενες μελέτες και επεκτάσεις που θα παρουσιαστούν σε επόμενα κεφάλαια.

2.2.1 Ιδιαιτερότητες των Δεδομένων Χρονοσειρών

Η εφαρμογή των μοντέλων διάχυσης σε χρονοσειρές δεν είναι άμεση, καθώς το είδος αυτό των δεδομένων διαθέτει δομές και περιορισμούς που απουσιάζουν από τα στατικά σήματα ή τις εικόνες. Σε αντίθεση με τις ανεξάρτητες δισδιάστατες τομές μιας εικόνας ή τις απλές κυματομορφές ήχου, οι χρονοσειρές περιγράφουν εξελίξεις στο χρόνο δηλαδή ακολουθίες τιμών που φέρουν σαφή *χρονική αιτιότητα*, *διαδοχή* και συχνά *αβεβαιότητα παρατήρησης*. Κάθε

τιμή δεν είναι απλώς ένα δείγμα αλλά μέρος μιας συνεχούς διαδικασίας, της οποίας η εξέλιξη εξαρτάται από το παρελθόν και επηρεάζει το μέλλον.

Η θεωρία των μοντέλων διάχυσης, όπως αναπτύχθηκε στα προηγούμενα κεφάλαια, παρέχει ένα γενικό πλαίσιο στοχαστικής προώθησης και αντιστροφής αποθορυβοποίησης. Ωστόσο, αυτό το πλαίσιο έχει αρχικά σχεδιαστεί για δεδομένα *χωρικά στατικά* ή *ανεξάρτητα δειγματοληπτικά*: στις χρονοσειρές, η ίδια διαδικασία θορυβοποίησης μπορεί να καταστρέψει κρίσιμες χρονικές εξαρτήσεις, καθιστώντας την απλή εφαρμογή των εξισώσεων (1)–(16) ανεπαρκή για τη σωστή μοντελοποίηση. Η διατήρηση της χρονικής συνοχής, της αιτιότητας και των συσχετίσεων μεταξύ καναλιών απαιτεί συνεπώς τροποποιήσεις τόσο στον forward όσο και στον reverse μηχανισμό, καθώς και ειδική παραμετροποίηση του δικτύου $\epsilon_\theta(x_t, t)$ ώστε να γνωρίζει τη θέση κάθε δείγματος στο χρόνο και ποιες τιμές είναι διαθέσιμες ή ελλείπουσες.

Πρακτικά, αυτό σημαίνει ότι το μοντέλο διάχυσης για χρονοσειρές πρέπει να λειτουργεί σε ένα *συνθηκοποιημένο πλαίσιο* (conditional setting), όπου ορισμένες χρονικές στιγμές είναι γνωστές και άλλες άγνωστες και πρέπει να παραχθούν. Η διάχυση επομένως μετατρέπεται από ένα απλό generative πρόβλημα σε ένα *καθοδηγούμενο πρόβλημα αποκατάστασης*, με ρητή γνώση για τη μάσκα παρατήρησης, τις χρονικές εξαρτήσεις και τις αλληλεπιδράσεις μεταξύ χαρακτηριστικών.

Επιπλέον, οι χρονοσειρές είναι συχνά *πολυμεταβλητές, μη στασιμές* και παρουσιάζουν μακροχρόνιες εξαρτήσεις. Αυτές οι ιδιότητες καθιστούν την εκπαίδευση του μοντέλου πιο απαιτητική, καθώς η στοχαστική διαδικασία πρέπει να μάθει να ισορροπεί ανάμεσα στην τοπική δυναμική και τη συνολική τάση του συστήματος. Για τον λόγο αυτό, τα μοντέλα διάχυσης για χρονοσειρές (Time-Series Diffusion Models) υιοθετούν συνήθως *mask-aware score networks*, ειδικά χρονοδιαγράμματα θορύβου και αρχιτεκτονικές με *temporal embeddings* ή *causal attention*.

Στις παραγράφους που ακολουθούν παρουσιάζονται αναλυτικά οι βασικές ιδιαιτερότητες των δεδομένων χρονοσειρών που καθορίζουν αυτές τις προσαρμογές και θέτουν τα θεμέλια για την εξειδικευμένη θεωρία των time-series diffusion models.

Αιτιότητα και χρονική εξάρτηση Σε αντίθεση με τα ανεξάρτητα εικονοστοιχεία μιας εικόνας, κάθε σημείο μιας χρονοσειράς εξαρτάται αιτιακά από τα προηγούμενα. Αυτό σημαίνει ότι η διαδικασία διάχυσης πρέπει να διατηρεί τη χρονική κατεύθυνση: κατά την αποθορυβοποίηση, το μοντέλο δεν πρέπει να χρησιμοποιεί μελλοντικές τιμές για την πρόβλεψη του παρελθόντος. Η απαίτηση αυτή οδηγεί στη χρήση *mask-aware* μηχανισμών, όπου η πληροφορία διαρρέει μόνο από το παρελθόν προς το μέλλον, καθώς και στη σχεδίαση χρονικών ενσωματώσεων (temporal embeddings) που αποτυπώνουν τη θέση κάθε δείγματος στον χρόνο.

Ανομοιομορφία και ελλείψεις παρατηρήσεις Πολλές πραγματικές χρονοσειρές περιλαμβάνουν ακανόνιστη δειγματοληψία ή ελλείποντα δεδομένα. Η διάχυση, όντας ορισμένη σε συνεχή στοχαστική ροή, δεν μπορεί να υποθέσει ομοιόμορφα χρονικά διαστήματα. Για τον λόγο αυτό εισάγονται *μάσκες παρατήρησης* $M \in \{0, 1\}^{K \times L}$ που δηλώνουν ποια σημεία είναι γνωστά και ποια πρέπει να παραχθούν. Η πληροφορία αυτή περνά στο μοντέλο ως συνθήκη (conditioning), επιτρέποντας στο δίκτυο να γνωρίζει ποια τμήματα της ακολουθίας είναι έγκυρα και ποια υπόκεινται σε στοχαστική αναδόμηση. Η ιδέα αυτή αποτελεί θεμελιώδες στοιχείο των Conditional Score-based Diffusion Models (CSDI) [35].

Πολυμεταβλητότητα και συσχετίσεις καναλιών Οι περισσότερες χρονοσειρές είναι πολυδιάστατες, με κανάλια που συσχετίζονται ισχυρά μεταξύ τους. Η διάχυση πρέπει επομένως να λειτουργεί σε επίπεδο συνόλου χαρακτηριστικών, ώστε να μπορεί να ανακατασκευάζει ταυτόχρονα τα K κανάλια λαμβάνοντας υπόψη τη μεταξύ τους αλληλεξάρτηση. Αυτό οδηγεί σε αρχιτεκτονικές με *cross-channel attention*, γραφικές αναπαραστάσεις ή μηχανισμούς καθοδήγησης (guidance) που επιβάλλουν συσχετισμένες σχέσεις.

Μη στασιμότητα Οι πραγματικές χρονικές διαδικασίες δεν είναι σταθερές στο χρόνο· η κατανομή των παρατηρήσεων μπορεί να μεταβάλλεται λόγω εποχικότητας, αλλαγής περιβάλλοντος ή εξωτερικών γεγονότων. Αυτό σημαίνει ότι η εκπαίδευση πρέπει να λαμβάνει υπόψη τη δυναμική φύση των στατιστικών ιδιοτήτων, είτε με χρονικά εξαρτώμενα embeddings είτε με adaptive noise schedules. Η μη στασιμότητα καθιστά επίσης σημαντική την ύπαρξη conditional priors, ώστε η διαδικασία αποθορυβοποίησης να μην υπερπροσαρμόζεται σε συγκεκριμένα υποσύνολα.

Μακροχρόνιες εξαρτήσεις Οι χρονοσειρές εμφανίζουν εξαρτήσεις σε μεγάλο χρονικό εύρος, όπου γεγονότα στο μακρινό παρελθόν μπορούν να επηρεάσουν το παρόν. Η μοντελοποίηση τέτοιων σχέσεων είναι δύσκολη, καθώς η διάχυση βασίζεται σε σταδιακή προσθήκη και αφαίρεση θορύβου που τείνει να αποσυνδέει μακρινές χρονικές θέσεις. Για την αντιμετώπιση αυτού, σύγχρονες προσεγγίσεις χρησιμοποιούν transformer-based αρχιτεκτονικές με long-range attention ή state-space models [10, 9], που επιτρέπουν στο $\epsilon_\theta(x_t, t)$ να λαμβάνει υπόψη ευρύτερα χρονικά μοτίβα.

Ερμηνευσιμότητα και αβεβαιότητα Τέλος, η χρήση των diffusion models στις χρονοσειρές συνδέεται με την ανάγκη ελέγχου της αβεβαιότητας. Επειδή το μοντέλο παράγει κατανομές πιθανών ακολουθιών, η ερμηνεία των αποτελεσμάτων απαιτεί κατάλληλα μέτρα όπως το CRPS ή την ποσοστιαία αξιολόγηση προβλέψεων [8, 28]. Αυτό διαφοροποιεί τη διάχυση σε χρονοσειρές από τη γενετική χρήση σε εικόνες: ο στόχος δεν είναι μόνο η ρεαλιστική παραγωγή αλλά και η αξιόπιστη αποτύπωση της πιθανότητας.

Οι παραπάνω ιδιαιτερότητες δείχνουν ότι η προσαρμογή των μοντέλων διάχυσης σε χρονοσειρές δεν αποτελεί απλή μεταφορά ενός υπάρχοντος πλαισίου, αλλά θεμελιώδη αναδιατύπωση της στοχαστικής διαδικασίας, ώστε να σέβεται τη χρονική δομή, την ετερογένεια και την αβεβαιότητα των δεδομένων. Στις επόμενες ενότητες θα παρουσιαστεί πώς αυτή η αναδιατύπωση υλοποιείται θεωρητικά μέσω *προσαρμοσμένων forward–reverse διεργασιών* και *συνθηκοποιημένων score δικτύων*, τα οποία αποτελούν τον πυρήνα των Time-Series Diffusion Models.

2.2.2 Θεωρητική Προσαρμογή του Πλαισίου Διάχυσης στις Χρονοσειρές

Η μετάβαση από τα στατικά δεδομένα στις χρονοσειρές απαιτεί την προσεκτική ενσωμάτωση της χρονικής δομής και της αιτιότητας μέσα στο στοχαστικό πλαίσιο της διάχυσης. Αν και οι εξισώσεις προώθησης και αντιστροφής ((1)–(16)) παραμένουν θεμελιωδώς ίδιες, η πρακτική εφαρμογή τους σε δεδομένα που εξελίσσονται στο χρόνο εισάγει τρεις κρίσιμες προσαρμογές: (α) συνθηκοποίηση με βάση τις παρατηρήσεις, (β) χρήση μάσκας παρατήρησης που διαχωρίζει γνωστά και άγνωστα στοιχεία, και (γ) αρχιτεκτονικές που διατηρούν χρονική και διακαναλική συνοχή.

Διάχυση υπό Συνθήκη Η κλασική θεωρία διάχυσης υποθέτει ότι κάθε δείγμα δεδομένων x_0 είναι πλήρες και παρατηρείται ολόκληρο κατά την εκπαίδευση. Στις χρονοσειρές, ωστόσο, η πραγματικότητα είναι διαφορετική: τα δεδομένα είναι συχνά *μερικώς παρατηρημένα*, με ελλείπουσες τιμές, ακανόνιστα χρονικά διαστήματα ή τμήματα που λείπουν εντελώς. Για να μπορέσει ένα μοντέλο διάχυσης να λειτουργήσει σε ένα τέτοιο περιβάλλον, χρειάζεται να επεκταθεί από την απλή μη-συνθηκοποιημένη μορφή σε μια *συνθηκοποιημένη εκδοχή* (conditional diffusion), όπου η διαδικασία θορυβοποίησης και αποθορυβοποίησης λαμβάνει υπόψη ποια στοιχεία του σήματος είναι γνωστά και ποια πρέπει να εκτιμηθούν.

Ας θεωρήσουμε μια πολυμεταβλητή χρονοσειρά

$$x_0 \in \mathbb{R}^{K \times L},$$

όπου K είναι τα χαρακτηριστικά (κανάλια) και L ο αριθμός των χρονικών στιγμών. Σε ένα πραγματικό σενάριο μέτρησης, για κάθε σημείο (i, j) γνωρίζουμε αν η τιμή του είναι διαθέσιμη ή όχι. Αυτό εκφράζεται μέσω μιας *μάσκας παρατήρησης*

$$M \in \{0, 1\}^{K \times L},$$

όπου $M_{ij} = 1$ σημαίνει ότι η τιμή x_{ij} είναι παρατηρημένη (γνωστή), ενώ $M_{ij} = 0$ δηλώνει ελλιπή ή άγνωστη τιμή. Η μάσκα αυτή χωρίζει το δείγμα σε δύο συμπληρωματικά μέρη:

$$x_{\text{obs}} = M \odot x_0, \quad x_{\text{unobs}} = (1 - M) \odot x_0.$$

Στόχος του μοντέλου δεν είναι να αναπαράγει ολόκληρο το x_0 , αλλά να μάθει την υπό συνθήκη κατανομή

$$p_\theta(x_{\text{unobs}} \mid x_{\text{obs}}),$$

δηλαδή να συμπληρώνει τις άγνωστες περιοχές του σήματος με τρόπο συνεπή προς τα παρατηρούμενα δεδομένα.

Η παραπάνω κατανομή είναι η καρδιά της συνθηκοποιημένης διάχυσης. Στην πράξη, το μοντέλο πρέπει να μάθει έναν μηχανισμό που εκτελεί αποθορυβοποίηση μόνο στα μη παρατηρούμενα στοιχεία, ενώ τα γνωστά παραμένουν αναλλοίωτα καθ' όλη τη διάρκεια των βημάτων. Αυτό επιτυγχάνεται τροποποιώντας τη διαδικασία προώθησης (forward process) έτσι ώστε ο θόρυβος να προστίθεται μόνο στις θέσεις όπου $M_{ij} = 0$.

Η στοχαστική σχέση θορυβοποίησης, όμοια με την εξίσωση (1), προσαρμόζεται ώστε να λαμβάνει υπόψη τη μάσκα:

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, \quad \epsilon \sim \mathcal{N}(0, I), \quad (21)$$

όπου η θορυβοποίηση εφαρμόζεται επιλεκτικά μέσω της μάσκας:

$$x_t \leftarrow M \odot x_0 + (1 - M) \odot (\sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon).$$

Με αυτόν τον τρόπο, οι γνωστές τιμές του σήματος διατηρούνται σταθερές καθ' όλη τη διάρκεια της προώθησης, ενώ οι άγνωστες ακολουθούν το στοχαστικό μονοπάτι της διάχυσης. Η ίδια αρχή θα εφαρμοστεί και στην αντίστροφη διαδικασία, όπου το δίκτυο θα κληθεί να μάθει πώς να καθαρίζει μόνο τα τμήματα που είναι πραγματικά αβέβαια.

Αυτή η συνθηκοποιημένη προσέγγιση είναι κρίσιμη για να μπορέσουν τα μοντέλα διάχυσης να χειριστούν πραγματικές χρονοσειρές. Σε αντίθεση με τις εικόνες ή τα κείμενα, εδώ τα δεδομένα διαθέτουν χρονική εξάρτηση καθώς κάθε τιμή εξαρτάται από προηγούμενες και επόμενες στιγμές, και η έλλειψη μιας μεμονωμένης παρατήρησης μπορεί να αλλοιώσει ολόκληρη την τοπική δυναμική. Η εισαγωγή της μάσκας M διασφαλίζει ότι το μοντέλο έχει επίγνωση αυτής της δομής, ώστε να μαθαίνει να εξομαλύνει και να συμπληρώνει τις ελλείψεις με τρόπο που διατηρεί τη χρονική συνέχεια και τη συσχέτιση μεταξύ χαρακτηριστικών.

Συνοψίζοντας, η διάχυση με συνθήκη μετατρέπει το καθολικό πρόβλημα γενετικής μοντελοποίησης σε μια πιο ρεαλιστική και εφαρμοσμένη εκδοχή καθώς το μοντέλο δεν προσπαθεί να ανακατασκευάσει εξ ολοκλήρου τον κόσμο των δεδομένων, αλλά να αναδομήσει συνεπώς εκείνα τα τμήματα του χρόνου που δεν έχουν ποτέ παρατηρηθεί, λαμβάνοντας υπόψη όλα όσα γνωρίζει για τη χρονική και στατιστική δομή του συστήματος.

Τροποποιημένη Εμπρόσθια Διαδικασία Διάχυσης

Ο προωθητικός μηχανισμός (forward process) στις χρονοσειρές διατηρεί τη γενική του θεωρητική μορφή, όπως ορίστηκε στην εξίσωση (1), αλλά προσαρμόζεται ώστε να λαμβάνει υπόψη την παρουσία ελλειπών ή μη παρατηρούμενων τιμών. Η βασική ιδέα είναι ότι η στοχαστική θορυβοποίηση εφαρμόζεται επιλεκτικά δηλαδή μόνο στις θέσεις όπου το σήμα είναι άγνωστο, ενώ οι γνωστές τιμές παραμένουν αμετάβλητες καθ' όλη τη διάρκεια των βημάτων της προώθησης.

Αν υποθέσουμε ότι σε κάθε χρονική στιγμή έχουμε διαθέσιμη τη μάσκα παρατήρησης $M \in \{0, 1\}^{K \times L}$, τότε η προωθητική διαδικασία περιγράφεται από τη Γκαουσιανή κατανομή

$$q(x_t | x_{t-1}, M) = \mathcal{N}(x_t; \sqrt{1 - \beta_t} x_{t-1}, \beta_t I),$$

όπως και στο κλασικό μοντέλο διάχυσης. Η διαφορά έγκειται στον τρόπο που εφαρμόζεται: για τα στοιχεία όπου $M_{ij} = 1$ (δηλαδή γνωστά), κρατάμε την τιμή του σήματος σταθερή και δεν προσθέτουμε θόρυβο, ενώ για τα στοιχεία με $M_{ij} = 0$ προστίθεται θόρυβος σύμφωνα με τη στοχαστική εξίσωση.

Στην πράξη, το προωθητικό βήμα υλοποιείται ως εξής:

$$x_t = M \odot x_0 + (1 - M) \odot (\sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon), \quad \epsilon \sim \mathcal{N}(0, I). \quad (22)$$

Η εξίσωση (22) διατηρεί την ίδια στατιστική δομή με την εξίσωση (2), αλλά περιορίζει τη θορυβοποίηση στα σημεία όπου τα δεδομένα είναι άγνωστα. Έτσι, η διαδικασία της διάχυσης παραμένει πλήρως συμβατή με την αρχική θεωρία, χωρίς να αλλοιώνει τις πληροφορίες που προέρχονται από πραγματικές παρατηρήσεις.

Η συγκεκριμένη παραλλαγή έχει ιδιαίτερη σημασία για τις χρονοσειρές, καθώς διασφαλίζει ότι το μοντέλο εκπαιδεύεται σε ρεαλιστικές συνθήκες ελλειπών δεδομένων. Κατά την εκπαίδευση, το δίκτυο παρατηρεί τόσο καθαρές όσο και θορυβώδεις εκδοχές των ίδιων σημείων, αλλά μόνο εκεί όπου υπάρχει αβεβαιότητα. Αυτό επιτρέπει στο μοντέλο να εστιάσει στο να μάθει πώς εξελίσσεται ο θόρυβος και η συσχέτιση στο χρόνο μόνο στις περιοχές που πραγματικά το χρειάζονται.

Διαισθητικά, ο προσαρμοσμένος προωθητικός μηχανισμός λειτουργεί ως ένα ελεγχόμενο πείραμα θορυβοποίησης καθώς κρατά σταθερές τις παρατηρημένες πληροφορίες ως σταθερούς κόμβους και επιτρέπει στο στοχαστικό

μέρος της διάχυσης να δρα αποκλειστικά στα άγνωστα τμήματα του σήματος. Αυτό εξασφαλίζει ότι, σε μεταγενέστερα βήματα της αντίστροφης διαδικασίας, το μοντέλο θα διαθέτει ένα σαφές πλαίσιο αναφοράς για το πώς ο θόρυβος επιδρά μόνο εκεί όπου υπάρχει αβεβαιότητα. Με τον τρόπο αυτό, η προώθηση παραμένει στατιστικά συνεπής με τη θεωρία της διάχυσης, αλλά αποκτά ικανότητα χειρισμού των μερικώς παρατηρούμενων χρονοσειρών.

Τροποποιημένη Αντίστροφη Διαδικασία Διάχυσης

Αφού ο προωθητικός μηχανισμός (forward process) έχει ορίσει πώς τα δεδομένα μετατρέπονται σταδιακά σε θόρυβο, το ζητούμενο για το μοντέλο είναι να μάθει την αντίστροφη πορεία: πώς να ανακτήσει τη δομή του αρχικού σήματος από μια θορυβώδη εκδοχή του, λαμβάνοντας υπόψη ποιες τιμές είναι γνωστές και ποιες όχι.

Στο ιδανικό θεωρητικό πλαίσιο, η αντίστροφη διαδικασία θα περιγραφόταν από την αληθή κατανομή

$$q(x_{t-1} \mid x_t, x_{\text{obs}}),$$

η οποία εκφράζει το πώς κατανέμεται το προηγούμενο βήμα x_{t-1} δεδομένου του τρέχοντος δείγματος x_t και των παρατηρήσεων. Ωστόσο, η κατανομή αυτή είναι άγνωστη και υπολογιστικά απρόσιτη· γι' αυτό χρησιμοποιούμε ένα παραμετρικό μοντέλο, το οποίο προσεγγίζει αυτήν τη σχέση μέσω εκμάθησης.

Το μοντέλο, επομένως, ορίζεται ως

$$p_\theta(x_{t-1} \mid x_t, M, x_{\text{obs}}),$$

όπου τα παραμετρικά βάρη θ αντιπροσωπεύουν τα εκπαιδευσιμα στοιχεία ενός νευρωνικού δικτύου, και η συνάρτηση p_θ μαθαίνει να αντιστρέφει το θορυβοποιημένο βήμα. Η εξάρτηση από τη μάσκα M και τις παρατηρήσεις x_{obs} διασφαλίζει ότι το δίκτυο γνωρίζει ποια σημεία πρέπει να καθαρίσει και ποια να διατηρήσει ως σταθερές αναφορές.

Από άποψη εισόδων, το δίκτυο λαμβάνει τέσσερις θεμελιώδεις πληροφορίες:

1. το τρέχον θορυβωμένο δείγμα x_t ,
2. τη μάσκα παρατήρησης M ,
3. τις γνωστές τιμές x_{obs} ,
4. και το χρονικό βήμα t (ως χρονική ενσωμάτωση ή time embedding).

Ο συνδυασμός αυτών των εισόδων επιτρέπει στο μοντέλο να καταλάβει όχι μόνο την ένταση του θορύβου σε κάθε στάδιο, αλλά και το πού ακριβώς πρέπει να δράσει.

Η έξοδος του δικτύου είναι μια εκτίμηση του θορύβου που είχε προστεθεί στο στάδιο t , η οποία συμβολίζεται ως

$$\epsilon_\theta(x_t, M, x_{\text{obs}}, t).$$

Από τη στιγμή που το μοντέλο μάθει να προβλέπει σωστά αυτόν τον θόρυβο, μπορούμε να ανακατασκευάσουμε το καθαρό σήμα που αντιστοιχεί στο βήμα x_0 μέσω της αντίστροφης παραμετροποίησης:

$$\hat{x}_0(x_t, M, x_{\text{obs}}, t) = \frac{x_t - \sqrt{1 - \bar{\alpha}_t} \epsilon_\theta(x_t, M, x_{\text{obs}}, t)}{\sqrt{\bar{\alpha}_t}}. \quad (23)$$

Η εξίσωση (23) αποτελεί την *conditional reparameterization form* και εκφράζει τον τρόπο με τον οποίο η εκτίμηση του θορύβου μεταφράζεται σε ανακατασκευή της καθαρής χρονοσειράς. Στην πράξη, αυτή η σχέση χρησιμοποιείται επαναληπτικά, ξεκινώντας από το πλήρως θορυβώδες x_T και προοδευτικά δημιουργώντας $x_{T-1}, x_{T-2}, \dots, x_0$.

Η διαδικασία αυτή μπορεί να ερμηνευτεί ως μια αλληλουχία προβλέψεων και διορθώσεων: σε κάθε βήμα, το δίκτυο προβλέπει ποιο μέρος του σήματος είναι θόρυβος, αφαιρεί αυτόν τον εκτιμώμενο θόρυβο, και προχωρά ένα βήμα πιο κοντά στην πραγματική, καθαρή ακολουθία. Εφόσον η πληροφορία για τις γνωστές τιμές παραμένει σταθερή σε όλα τα στάδια, το μοντέλο σταδιακά «γεμίζει» τα κενά, δημιουργώντας ένα χρονολογικά συνεπές και στατιστικά έγκυρο σήμα.

Διαισθητικά, η συνθηκοποιημένη αντίστροφη διαδικασία μπορεί να θεωρηθεί ως ένας μηχανισμός εξομάλυνσης με μνήμη: σε κάθε βήμα, το μοντέλο αξιοποιεί τόσο τη γνώση του παρελθόντος (μέσω του x_t) όσο και τη σταθερή πληροφορία του x_{obs} , ώστε να διαμορφώνει μια πιθανοτική εκτίμηση για το πώς θα μπορούσε να είναι το καθαρό, πλήρες σήμα. Με τον τρόπο αυτό, η διάχυση στις χρονοσειρές μετατρέπεται από ένα στατικό πρόβλημα αποθορυβοποίησης σε μια δυναμική διαδικασία μάθησης που αναδομεί χρονικές εξαρτήσεις βήμα προς βήμα.

Υπό Όρους Εκμάθησης Score για Ελλιπή Δεδομένα

Η εκπαίδευση του μοντέλου διάχυσης για χρονοσειρές ακολουθεί την ίδια θεμελιώδη αρχή με τα κλασικά DDPM, όπως ορίστηκε στην απώλεια (14), με τη διαφορά ότι η βελτιστοποίηση περιορίζεται αποκλειστικά στα μη παρατηρούμενα σημεία του σήματος. Η στοχαστική φύση του προβλήματος και η ύπαρξη ελλείψεων καθιστούν αναγκαία την εκμάθηση ενός *conditional score function*, δηλαδή μιας παραμετρικής συνάρτησης που εκτιμά τον βαθμό μεταβολής (score) της λογαριθμικής πυκνότητας μόνο για τις περιοχές αβεβαιότητας.

Η βασική ιδέα είναι ότι το δίκτυο πρέπει να μάθει να προβλέπει τον προστιθέμενο θόρυβο ϵ σε κάθε στάδιο t , αλλά μόνο για τα σημεία όπου η πραγματική τιμή του x_0 δεν είναι γνωστή. Αυτό επιτυγχάνεται μέσω μιας τροποποιημένης συνάρτησης απώλειας, η οποία σταθμίζει επιλεκτικά τη συνεισφορά κάθε στοιχείου ανάλογα με τη μάσκα παρατήρησης M . Η μάσκα εξασφαλίζει ότι η εκπαίδευση επικεντρώνεται εκεί όπου υπάρχει αβεβαιότητα και αγνοεί τα γνωστά δεδομένα, τα οποία δεν χρειάζεται να ανακατασκευαστούν.

Η μαθηματική διατύπωση της απώλειας δίνεται ως:

$$\mathcal{L}_{\text{CSDI}} = \mathbb{E}_{x_0, \epsilon, t, M} [\| (1-M) \odot (\epsilon - \epsilon_\theta(x_t, M, x_{\text{obs}}, t)) \|_2^2], \quad (24)$$

όπου το σύμβολο $\odot$ δηλώνει το στοιχειώδες γινόμενο. Η μάσκα $(1-M)$ λειτουργεί ως φίλτρο που επιτρέπει τη ροή πληροφορίας μόνο στα σημεία που πρέπει να εκτιμηθούν, απομονώνοντας το τμήμα του σήματος που περιέχει ελλείπουσες τιμές. Η συνάρτηση απώλειας λοιπόν ελαχιστοποιεί τη διαφορά μεταξύ του πραγματικού θορύβου ϵ και της εκτίμησης του μοντέλου ϵ_θ , μόνο για τα μη παρατηρούμενα στοιχεία.

Από στατιστικής άποψης, η παραπάνω σχέση ισοδυναμεί με την προσέγγιση του score matching σε ένα υποσύνολο του χώρου δεδομένων που καθορίζεται από τη μάσκα M . Εκεί, το δίκτυο μαθαίνει να υπολογίζει το διάνυσμα βαθμίδας της λογαριθμικής πυκνότητας $p_t(x)$ σε κάθε βήμα διάχυσης, αλλά υπό συνθήκη ως προς τις παρατηρήσεις x_{obs} . Με αυτόν τον τρόπο, η εκμάθηση επικεντρώνεται στο *conditional score function*

$$s_\theta(x_t, M, x_{\text{obs}}, t) \simeq \nabla_{x_t} \log p_t(x_t | x_{\text{obs}}),$$

το οποίο περιγράφει την κατεύθυνση της μέγιστης πιθανότητας μόνο για τις περιοχές που χρειάζονται ανακατασκευή.

Η σημασία αυτής της απώλειας είναι διττή. Πρώτον, παρέχει μια μαθησιακή αρχή πλήρως συμβατή με το θεωρητικό υπόβαθρο των diffusion models, χωρίς να απαιτεί την ανακατασκευή ολόκληρου του δείγματος. Δεύτερον, εισάγει έναν φυσικό μηχανισμό μάθησης για την αναπλήρωση ελλειπόντων δεδομένων, καθώς η βελτιστοποίηση της (28) οδηγεί το μοντέλο να εκτιμά με ακρίβεια τη στοχαστική κατανομή των άγνωστων τιμών υπό το πλαίσιο των γνωστών. Η διατύπωση αυτή βρίσκεται στο επίκεντρο των *Conditional Score-based Diffusion Models (CSDI)* [35], τα οποία αποτέλεσαν τη βάση για τη μοντελοποίηση χρονοσειρών με ελλείπουσες παρατηρήσεις.

Η λογική πίσω από τη συνθηκοποιημένη διάχυση είναι απλή: το μοντέλο δεν χρειάζεται να «ανακαλύψει» πληροφορίες που είναι ήδη γνωστές, αλλά να εστιάσει στη στατιστική ανακατασκευή των αγνώστων με βάση το παρελθόν και τα συσχετισμένα χαρακτηριστικά. Σε κάθε βήμα της αντίστροφης διαδικασίας, η γνώση του x_{obs} και της μάσκας M κατευθύνει το δίκτυο ώστε να συμπληρώνει τις ελλείψεις, προσαρμόζοντας τη δυναμική του θορύβου σύμφωνα με τη δομή του χρονικού συστήματος. Έτσι, η διάχυση μετατρέπεται σε μια μάθηση *καθαρής χρονικής συνέπειας* και *πιθανοτικής εξομάλυνσης* ανάμεσα σε γνωστές και άγνωστες τιμές.

Αρχιτεκτονική Ενσωμάτωσης Χρονικής Πληροφορίας

Η επιτυχία των Time-Series Diffusion Models εξαρτάται καθοριστικά από το πώς ενσωματώνεται και αξιοποιείται η χρονική πληροφορία μέσα στο νευρωνικό δίκτυο. Σε αντίθεση με τις εικόνες ή τα λανθάνοντα διανύσματα, όπου η χωρική δομή είναι στατική, οι χρονοσειρές απαιτούν την κατανόηση της ακολουθίας γεγονότων στον χρόνο, την αναγνώριση μακροπρόθεσμων εξαρτήσεων και τη διατήρηση αιτιώδους συνέπειας. Για τον λόγο αυτό, τα μοντέλα διάχυσης για χρονοσειρές ενσωματώνουν εξειδικευμένα συστατικά που επιτρέπουν στο δίκτυο να αντιλαμβάνεται τον χρόνο και ποιες τιμές είναι παρατηρημένες και να συνδέει τα διάφορα χαρακτηριστικά μεταξύ τους.

Temporal Embedding. Κάθε χρονικό βήμα t μετατρέπεται σε συνεχές διάνυσμα χαρακτηριστικών, ώστε το μοντέλο να κατανοεί τη σχετική του θέση μέσα στην ακολουθία. Η πιο συνηθισμένη προσέγγιση βασίζεται στις

ημιτονοειδείς κωδικοποιήσεις θέσης (sine-cosine positional encodings), όπως εκείνες που χρησιμοποιούνται στους Transformers, ενώ εναλλακτικά μπορούν να χρησιμοποιηθούν learnable time embeddings, όπου οι παράμετροι εκπαιδεύονται απευθείας μαζί με το υπόλοιπο δίκτυο. Οι χρονικές ενσωματώσεις συνήθως προστίθενται ή συνενώνονται με τις ενσωματώσεις των χαρακτηριστικών εισόδου, δίνοντας στο δίκτυο τη δυνατότητα να διαφοροποιεί τις προβλέψεις ανάλογα με το χρονικό πλαίσιο. Η χρονική κωδικοποίηση επομένως δρα ως «ρολόι» του μοντέλου, επιτρέποντάς του να οργανώνει τη στοχαστική διάχυση με χρονική συνοχή.

Mask Embedding. Η μάσκα $M \in \{0, 1\}^{K \times L}$ παίζει θεμελιώδη ρόλο, καθώς υποδεικνύει ποιες τιμές είναι γνωστές και ποιες λείπουν. Για να αξιοποιηθεί αυτή η πληροφορία αποτελεσματικά, η μάσκα δεν τροφοδοτείται απλώς ως δυαδικός πίνακας, αλλά προβάλλεται σε συνεχές διάστημα μέσω ενός mask embedding layer. Αυτό επιτρέπει στο δίκτυο να «αντιλαμβάνεται» την πυκνότητα των παρατηρήσεων, να διαφοροποιεί τη συμπεριφορά του ανάλογα με το ποσοστό ελλειπόντων τιμών, και να μαθαίνει πώς να συνδυάζει τις γνωστές τιμές ως σταθερά σημεία αναφοράς στη διαδικασία αποθρυβοποίησης. Η πληροφορία της μάσκας ενσωματώνεται συνήθως μέσω προσθετικής σύνδεσης στα χαρακτηριστικά εισόδου, ή μέσω cross-attention μηχανισμών, ώστε να κατευθύνει τη ροή πληροφορίας μόνο προς τις θέσεις που χρειάζονται ανακατασκευή.

Cross-Feature Attention. Οι χρονοσειρές είναι πολυμεταβλητές, και οι συσχετίσεις μεταξύ των καναλιών (π.χ. αισθητήρες, φυσικές μεταβλητές, οικονομικοί δείκτες) αποτελούν κρίσιμο στοιχείο για την ποιότητα των προβλέψεων. Η διακαναλική προσοχή επιτρέπει στο δίκτυο να εξετάζει ρητά τις σχέσεις μεταξύ διαφορετικών χαρακτηριστικών, εστιάζοντας σε εκείνα που είναι πιο σχετιζόμενα με την τρέχουσα χρονική στιγμή. Μέσω μηχανισμών multi-head attention, το μοντέλο μπορεί να μάθει πολύπλοκα μοτίβα αλληλεπίδρασης, να μεταδίδει πληροφορία μεταξύ καναλιών με παρόμοια συμπεριφορά, και να βελτιώνει την εκτίμηση του θορύβου ή του score σε κάθε βήμα.

Υλοποιήσεις και αρχιτεκτονικές. Στην πράξη, οι παραπάνω μηχανισμοί υλοποιούνται μέσω δύο κύριων κατηγοριών αρχιτεκτονικών: (α) τα Temporal Transformers, που βασίζονται σε στρώματα αυτοπροσοχής και προσφέρουν μεγάλη ικανότητα για μακροχρόνια εξάρτηση, και (β) τα Temporal U-Nets, τα οποία επεκτείνουν τη δομή του κλασικού U-Net σε μονοδιάστατο ή διδιάστατο χρόνο, προσφέροντας λεπτομερή τοπική κατανόηση σε συνδυασμό με ιεραρχική κλιμάκωση χαρακτηριστικών. Συχνά, οι πιο αποτελεσματικές εκδόσεις συνδυάζουν τα δύο — χρησιμοποιώντας Transformer blocks μέσα στο πλαίσιο ενός U-Net για να επιτύχουν ισορροπία ανάμεσα στη χρονική λεπτομέρεια και τη μακροσκοπική συνέπεια.

Συνολικά, η ενσωμάτωση της χρονικότητας δεν αποτελεί απλώς μηχανιστική λεπτομέρεια, αλλά τον ακρογωνιαίο λίθο των Time-Series Diffusion Models. Η χρονική, μασκοποιημένη και διακαναλική ενσωμάτωση επιτρέπει στο δίκτυο να κατανοεί τη δυναμική εξέλιξη των δεδομένων και να μαθαίνει πώς να συνθέτει συνεκτικές, αιτιωδώς έγκυρες χρονικές ακολουθίες.

Συνολική Επισκόπηση Με τις προηγούμενες προσαρμογές, το θεωρητικό πλαίσιο των μοντέλων διάχυσης επεκτείνεται επιτυχώς στον άξονα του χρόνου. Η στοχαστική διαδικασία παραμένει δομικά ίδια με εκείνη των κλασικών μοντέλων διάχυσης, όμως αποκτά πλέον συνειδητή γνώση για το ποιες πληροφορίες είναι διαθέσιμες και ποιες πρέπει να παραχθούν. Η μάσκα παρατήρησης M λειτουργεί ως πυρήνας αυτής της προσαρμογής: επιτρέπει στο μοντέλο να διαχωρίζει δυναμικά τα παρατηρούμενα από τα μη παρατηρούμενα σημεία και να εφαρμόζει θορυβοποίηση και αποθρυβοποίηση επιλεκτικά, μόνο όπου υπάρχει αβεβαιότητα.

Η εκπαίδευση βασίζεται πλέον στη μάθηση ενός *conditional score function*, το οποίο εκτιμά την κλίση της λογαριθμικής πυκνότητας $p_t(x_t | x_{\text{obs}})$ υπό την παρουσία γνωστών παρατηρήσεων. Με αυτόν τον τρόπο, το δίκτυο δεν χρειάζεται να μοντελοποιήσει ολόκληρη την κατανομή των δεδομένων, αλλά μόνο τη στοχαστική συμπεριφορά των ελλειπόντων σημείων μέσα στο πλαίσιο των παρατηρούμενων. Η απώλεια εκπαίδευσης (28) καθοδηγεί το μοντέλο να προβλέπει με συνέπεια τον προστιθέμενο θόρυβο και να ανακατασκευάζει τη χρονική δομή του σήματος βήμα προς βήμα.

Από αρχιτεκτονικής πλευράς, τα time-series diffusion models οφείλουν να διατηρούν δύο κρίσιμες ιδιότητες: *χρονική συνέπεια* και *στατιστική πληρότητα*. Η χρονική συνέπεια εξασφαλίζει ότι οι προβλέψεις σε διαφορετικά χρονικά βήματα παραμένουν ομαλές και αιτιωδώς συνδεδεμένες, ενώ η στατιστική πληρότητα εγγυάται ότι η τελική ανακατασκευή του x_0 αντιπροσωπεύει μια έγκυρη δειγματοληψία από την υπό όρους κατανομή $p(x_0 | x_{\text{obs}})$.

Η επέκταση αυτή καθιστά τη διάχυση κατάλληλη όχι μόνο για στατικά σήματα, αλλά και για ακολουθίες με χρονική εξάρτηση, ελλείψεις ή μη σταθερή δειγματοληψία. Στην πράξη, το πλαίσιο αυτό προσφέρει έναν ενιαίο

τρόπο να πραγματοποιούνται εργασίες αποκατάστασης (imputation), πρόβλεψης (forecasting) και δημιουργίας (generation) χρονοσειρών μέσα από ένα ενιαίο πιθανοτικό μοντέλο.

2.2.3 Το Μοντέλο CSDI (Conditional Score-based Diffusion for Imputation)

Το Conditional Score-based Diffusion Model for Imputation (CSDI) [35] αποτελεί το πρώτο πλήρως λειτουργικό πλαίσιο που εφαρμόζει τη θεωρία των score-based diffusion models σε χρονοσειρές με ελλείπουσες ή μερικώς παρατηρούμενες τιμές. Εισάγει έναν ενιαίο μηχανισμό που μαθαίνει να ανακατασκευάζει χρονικά δεδομένα υπό συνθήκη, συνδυάζοντας στοχαστική διάχυση, μάσκες παρατήρησης και ενσωμάτωση χρονικότητας μέσα σε ένα νευρωνικό δίκτυο τύπου Transformer. Το CSDI δεν επιδιώκει απλώς την πρόβλεψη ελλειπόντων τιμών, αλλά την εκμάθηση μιας πλήρους υπό όρους κατανομής

$$p_{\theta}(x_0 \mid x_{\text{obs}}),$$

η οποία επιτρέπει πολλαπλές συνεπείς δειγματοληψίες του ίδιου σήματος, παρέχοντας εκτίμηση αβεβαιότητας και εύρος πιθανών εξελίξεων.

Η θεωρητική του βάση προέρχεται άμεσα από το συνθηκοποιημένο πλαίσιο διάχυσης που αναπτύχθηκε στις προηγούμενες ενότητες· το CSDI ουσιαστικά υλοποιεί στην πράξη την εξίσωση εκπαίδευσης (28) και τον αντίστροφο μηχανισμό

$$p_{\theta}(x_{t-1} \mid x_t, M, x_{\text{obs}}) = \mathcal{N}(x_{t-1}; \mu_{\theta}(x_t, M, x_{\text{obs}}, t), \tilde{\beta}_t I),$$

όπου η μέση τιμή υπολογίζεται από την εκτίμηση του θορύβου $\epsilon_{\theta}(x_t, M, x_{\text{obs}}, t)$ με την ίδια λογική που ορίστηκε στα κλασικά μοντέλα διάχυσης. Με αυτόν τον τρόπο, η διαδικασία αποθρομβοποίησης ενσωματώνει ρητά τη γνώση των παρατηρούμενων σημείων, ενώ τα μη παρατηρούμενα συμπληρώνονται σταδιακά μέσα από τη στοχαστική ροή της αντίστροφης διάχυσης.

Το CSDI σχεδιάστηκε πρωτίστως για καθήκοντα *imputation*, όμως το ίδιο πλαίσιο μπορεί να χρησιμοποιηθεί και για πρόβλεψη (forecasting) ή παραγωγή (generation) χρονοσειρών, καθώς η αρχιτεκτονική και ο μηχανισμός μάθησης είναι γενικοί και εξαρτώνται μόνο από τη μορφή της μάσκας M και τη χρονική περιοχή που τίθεται ως άγνωστη.

Επισκόπηση και Στόχοι του Μοντέλου

Ο κύριος στόχος του CSDI είναι η εκμάθηση μιας στοχαστικής συνάρτησης αποκατάστασης που χαρτογραφεί θορυβώμενες και μερικώς παρατηρούμενες εισόδους σε συνεπείς χρονικές ανακατασκευές. Κατά τη διάρκεια της εκπαίδευσης, το δίκτυο μαθαίνει να εκτιμά τον προστιθέμενο θόρυβο $\epsilon_{\theta}(x_t, M, x_{\text{obs}}, t)$ για κάθε χρονικό βήμα της διάχυσης, ενώ τα γνωστά σημεία της μάσκας παραμένουν αμετάβλητα. Αυτό το καθιστά ικανό να απομονώνει το στοχαστικό μέρος της ακολουθίας και να μαθαίνει τις υποκείμενες σχέσεις που τη διέπουν.

Σε αντίθεση με κλασικές μεθόδους παρεμβολής ή πρόβλεψης, το CSDI δεν παράγει μία μοναδική εκτίμηση για τα ελλείποντα σημεία, αλλά έναν ολόκληρο κατανεμημένο χώρο πιθανών λύσεων. Κάθε δειγματοληψία από το $p_{\theta}(x_0 \mid x_{\text{obs}})$ αντιστοιχεί σε μια διαφορετική, αλλά στατιστικά έγκυρη ανακατασκευή, αντικατοπτρίζοντας τη φυσική αβεβαιότητα που ενυπάρχει στα χρονικά δεδομένα.

Η προσέγγιση αυτή προσφέρει τρία βασικά πλεονεκτήματα: πρώτον, τη δυνατότητα ποσοτικοποίησης της αβεβαιότητας· δεύτερον, την αποκατάσταση πολύπλοκων μη γραμμικών εξαρτήσεων που οι κλασικές μέθοδοι δεν μπορούν να εκφράσουν· και τρίτον, τη γενίκευση σε διάφορες εργασίες χρονοσειρών μέσα από ένα ενιαίο πιθανοτικό πλαίσιο. Στις επόμενες υποενότητες θα παρουσιαστεί η εσωτερική αρχιτεκτονική του μοντέλου, η διαδικασία εκπαίδευσης και η στρατηγική δειγματοληψίας που επιτρέπουν την πρακτική του λειτουργία.

Υπό Όρους Παραμετροποίηση του Μοντέλου Διάχυσης Η αρχιτεκτονική του μοντέλου επεκτείνει το πρότυπο DDPM σε μια υπό όρους παραμετροποίηση. Ορίζεται μια αποθρομβοποιητική συνάρτηση:

$$\epsilon_{\theta}(x_t^{\text{ta}}, t \mid x_0^{\text{co}}), \quad (25)$$

η οποία λαμβάνει ως είσοδο τις παρατηρημένες τιμές x_0^{co} και επιστρέφει μια εκτίμηση του θορύβου στις ελλείπουσες συνιστώσες x_t^{ta} .

Με βάση αυτή τη συνάρτηση, η μέση τιμή και η διασπορά του αντίστροφου βήματος διάχυσης ορίζονται ως:

$$\mu_{\theta}(x_t^{\text{ta}}, t \mid x_0^{\text{co}}) = \mu_{\text{DDPM}}(x_t^{\text{ta}}, t, \epsilon_{\theta}(x_t^{\text{ta}}, t \mid x_0^{\text{co}})), \quad \sigma_{\theta}(x_t^{\text{ta}}, t \mid x_0^{\text{co}}) = \sigma_{\text{DDPM}}(x_t^{\text{ta}}, t) \quad (26)$$

όπου οι συναρτήσεις μ_{DDPM} και σ_{DDPM} προέρχονται από τη γενική μορφή του στοχαστικού μοντέλου διάχυσης.

Η διαδικασία δειγματοληψίας πραγματοποιείται με την αντίστροφη διάχυση, όπου οι παρατηρημένες τιμές x_0^{co} παραμένουν σταθερές και λειτουργούν ως συνθήκες, ενώ οι άγνωστες τιμές x_0^{ta} συμπληρώνονται σταδιακά σε κάθε χρονικό βήμα. Έτσι, το δίκτυο μαθαίνει να εκμεταλλεύεται τη διαθέσιμη πληροφορία κατά μήκος του χρόνου και να προσαρμόζει την αποθορυβοποίηση σε συμφωνία με το πλαίσιο των παρατηρήσεων.

Τέλος, αξίζει να σημειωθεί ότι το υπό όρους αυτό σχήμα ανάγεται στο κλασικό, μη-υπό όρους μοντέλο διάχυσης όταν δεν υπάρχουν παρατηρημένες τιμές. Συνεπώς, το ίδιο πλαίσιο μπορεί να χρησιμοποιηθεί όχι μόνο για συμπλήρωση (imputation), αλλά και για παραγωγή (generation) ή πρόβλεψη (forecasting) δεδομένων, καθιστώντας το CSDI ένα ενιαίο και ευέλικτο εργαλείο για τη μοντελοποίηση χρονοσειρών με ελλείπουσες πληροφορίες.

Εκπαίδευση του CSDI

Η εκπαίδευση του CSDI βασίζεται άμεσα στις αρχές της στοχαστικής διάχυσης, αλλά προσαρμόζεται έτσι ώστε να λαμβάνει υπόψη τη μάσκα παρατήρησης και τη χρονική δομή των δεδομένων. Σε κάθε βήμα εκπαίδευσης, το μοντέλο λαμβάνει μια μερικώς παρατηρούμενη χρονοσειρά, προσθέτει προοδευτικά θόρυβο στα ελλείποντα σημεία, και μαθαίνει να εκτιμά το θορυβώδες μέρος της κατανομής, ώστε να μπορεί να το αφαιρέσει στην αντίστροφη φάση. Η διαδικασία αυτή αντικατοπτρίζει μια μορφή εκμάθησης υπό όρους (conditional score matching), όπως ορίζεται στη θεμελιώδη απώλεια της Εξ. (28).

Η βασική ιδέα παραμένει ίδια με τα κλασικά DDPM: το δίκτυο μαθαίνει να προβλέπει τον θόρυβο που προστέθηκε στο δείγμα, και όχι το ίδιο το καθαρό σήμα. Ωστόσο, το CSDI ενσωματώνει τη γνώση των παρατηρούμενων σημείων μέσω της μάσκας M , μαθαίνοντας να αποκαθιστά επιλεκτικά μόνο τα μη παρατηρούμενα στοιχεία.

Στάδιο θορυβοποίησης. Αρχικά, για κάθε δείγμα x_0 και αντίστοιχη μάσκα M , επιλέγεται ένα χρονικό βήμα διάχυσης t και παράγεται το θορυβωμένο δείγμα:

$$x_t = \sqrt{\alpha_t} x_0 + \sqrt{1 - \alpha_t} \varepsilon, \quad \varepsilon \sim \mathcal{N}(0, I). \quad (27)$$

Η διαδικασία αυτή εφαρμόζεται μόνο στις θέσεις όπου $M = 0$, δηλαδή στα ελλείποντα σημεία, ενώ οι παρατηρούμενες τιμές ($M = 1$) παραμένουν σταθερές. Με αυτόν τον τρόπο, το δίκτυο μαθαίνει να γεμίζει τα άγνωστα τμήματα της χρονοσειράς, χρησιμοποιώντας ως αναφορά τα διαθέσιμα δεδομένα.

Πρόβλεψη του θορύβου. Το νευρωνικό δίκτυο λαμβάνει ως είσοδο το ζεύγος (x_t, M) , τις παρατηρούμενες τιμές x_{obs} και το χρονικό ενσωμάτωμα (temporal embedding) t . Ο στόχος του είναι να εκτιμήσει τον θόρυβο $\varepsilon_{\theta}(x_t, M, x_{\text{obs}}, t)$, ο οποίος συγκρίνεται με τον πραγματικό θόρυβο ε μέσω ενός τετραγωνικού σφάλματος, υπολογισμένου αποκλειστικά στα μη παρατηρούμενα σημεία. Ο σκοπός του μοντέλου δεν είναι να αναπαράγει απευθείας το x_0 , αλλά να μάθει τον τρόπο με τον οποίο ο θόρυβος μεταβάλλει τα ελλείποντα στοιχεία, ώστε να μπορεί να τον αντιστρέψει στη φάση δειγματοληψίας.

Αντικειμενική συνάρτηση εκπαίδευσης. Η εκπαίδευση πραγματοποιείται μέσω της ελαχιστοποίησης μιας συνάρτησης κόστους που αποτυπώνει την απόκλιση μεταξύ του πραγματικού και του εκτιμώμενου θορύβου:

$$\mathcal{L}_{\text{CSDI}} = \mathbb{E}_{x_0, \varepsilon, t, M} [\|(1 - M) \odot (\varepsilon - \varepsilon_{\theta}(x_t, M, x_{\text{obs}}, t))\|_2^2], \quad (28)$$


όπου ο τελεστής $(1 - M)$ εξασφαλίζει ότι το σφάλμα υπολογίζεται μόνο στα σημεία που πρέπει να συμπληρωθούν. Η απώλεια αυτή συνδέεται άμεσα με τον κλασικό στόχο του DDPM, αλλά επεκτείνεται ώστε να λαμβάνει υπόψη τη χωρική επιλεκτικότητα και την ύπαρξη ελλειπών δεδομένων. Σε ορισμένες παραλλαγές, χρησιμοποιούνται επιπλέον συντελεστές στάθμισης ανά χρονικό βήμα ή χαρακτηριστικό, ώστε να δοθεί μεγαλύτερη έμφαση σε περιοχές με υψηλή διακύμανση ή αυξημένη σημασία πρόβλεψης.

Αυτοεποπτευόμενη στρατηγική εκπαίδευσης. Στην πράξη, το πρόβλημα είναι ότι στα πραγματικά δεδομένα δεν γνωρίζουμε εκ των προτέρων ποιες τιμές είναι ελλείπουσες. Για να ξεπεραστεί αυτό, το CSDI χρησιμοποιεί μια αυτοεποπτευόμενη στρατηγική (self-supervised training) εμπνευσμένη από masked language modeling. Από κάθε δείγμα x_0 , ένα υποσύνολο των παρατηρούμενων τιμών αποκρύπτεται τεχνητά και ορίζεται ως στόχοι συμπλήρωσης x_0^{ta} , ενώ οι υπόλοιπες τιμές διατηρούνται ως υπό όρους παρατηρήσεις x_0^{co} . Το μοντέλο εκπαιδεύεται

να ανακατασκευάζει τις αποκρυμμένες τιμές, μιμούμενο την πραγματική διαδικασία συμπλήρωσης ελλειπόντων δεδομένων.

Πίνακας 1: Καθορισμός στόχων συμπλήρωσης (x_0^{ta}) και υπό όρους παρατηρήσεων (x_0^{co}) στο CSDI.

Διαδικασία	Στόχοι συμπλήρωσης x_0^{ta}	Υπό όρους παρατηρήσεις x_0^{co}
Sampling (imputation)	Όλες οι ελλείπουσες τιμές	Όλες οι παρατηρημένες τιμές
Training (self-supervised)	Υποσύνολο των παρατηρήσεων (με μάσκα)	Οι υπόλοιπες παρατηρήσεις



Σχήμα 3: Διαδικασία αυτοεποπτευόμενης εκπαίδευσης του CSDI [35]. Οι πράσινες και λευκές περιοχές αντιστοιχούν σε παρατηρούμενες και ελλείπουσες τιμές, αντίστοιχα. Οι παρατηρήσεις διαχωρίζονται σε κόκκινες περιοχές στόχων συμπλήρωσης (x_0^{ta}) και μπλε υπό όρους παρατηρήσεις (x_0^{co}), οι οποίες χρησιμοποιούνται για την εκπαίδευση της συνάρτησης ϵ_θ . Τα χρωματισμένα τμήματα σε κάθε ορθογώνιο υποδηλώνουν την ύπαρξη διαθέσιμων τιμών.

Αλγοριθμική περιγραφή της εκπαίδευσης. Η διαδικασία μπορεί να αποδοθεί βηματικά ως εξής:

Πίνακας 2: Εκπαίδευση CSDI (αυτοεποπτευόμενη μάθηση με μάσκα).

Είσοδος: κατανομή εκπαίδευσης $q(x_0)$, στρατηγική στόχων T , πλήθος επαναλήψεων N_{iter} , ακολουθία θορύβου $\{\alpha_t\}$.
Εξοδος: εκπαιδευμένη αποθορυβοποιητική συνάρτηση ϵ_θ .

for $i = 1..N_{iter}$ **do**

Δειγμάτισε $t \sim \text{Uniform}(\{1, \dots, T\})$, $x_0 \sim q(x_0)$.

Διαχωρισμός στόχων: χώρισε τις παρατηρήσεις του x_0 σε **υπό όρους** x_0^{co} και **στόχους** x_0^{ta} με βάση τη στρατηγική T (βλ. Ενότητα ??).

Δειγμάτισε θόρυβο $\epsilon \sim \mathcal{N}(0, I)$ με διαστάσεις ίδιες με του x_0^{ta} .

Θορυβοποίηση στόχων: $x_t^{ta} \leftarrow \sqrt{\alpha_t} x_0^{ta} + \sqrt{1 - \alpha_t} \epsilon$.

Βήμα εκπαίδευσης: ελαχιστοποίησε $\|\epsilon - \epsilon_\theta(x_t^{ta}, t | x_0^{co})\|_2^2$ (βλ. Εξ. (28)).

end for

Διαχείριση ελλείψεων στο *training* (προσαρμοσμένη απώλεια). Στην πράξη, τα δεδομένα εκπαίδευσης για χρονοσειρές συχνά περιλαμβάνουν ήδη ελλείψεις, γεγονός που περιπλέκει τη διαδικασία εκμάθησης της συνάρτησης score. Αν η απώλεια υπολογιζόταν αδιακρίτως σε όλες τις θέσεις, το δίκτυο θα «τιμωρούσε» τον εαυτό του και για τιμές που δεν υπάρχουν πραγματικά στο δείγμα, δημιουργώντας παραπλανητική εκπαίδευση. Για τον λόγο

αυτό, το CSDI εισάγει μια προσαρμοσμένη μορφή εκπαίδευσης με **ψευδοτιμές** (dummy values) και **μάσκες παρατήρησης** (observation masks), ώστε να αγνοούνται οι αγνώστες περιοχές του σήματος κατά τον υπολογισμό της απώλειας.

Έστω ότι έχουμε ένα δείγμα x_0 μεγέθους $K \times L$ (π.χ. K χαρακτηριστικά, L χρονικά βήματα), το οποίο περιέχει ελλείψεις. Ορίζουμε μια δυαδική μάσκα $m \in \{0, 1\}^{K \times L}$ με:

$$m_{ij} = \begin{cases} 1, & \text{αν η τιμή } x_{0,ij} \text{ είναι παρατηρημένη,} \\ 0, & \text{αν η τιμή } x_{0,ij} \text{ είναι ελλείπουσα.} \end{cases}$$

Κατόπιν, αντικαθιστούμε τις ελλείπουσες τιμές του x_0 με μηδενικά (ή άλλες ουδέτερες τιμές) δημιουργώντας το x_0^b . Οι μηδενικές αυτές «ψευδοτιμές» δεν μεταφέρουν πληροφορία, αλλά επιτρέπουν να εφαρμοστεί η ίδια θορυβοποίηση σε όλο το δείγμα, διατηρώντας συνεπή διαστάσεις και δομή εισόδου.

Κατά το στάδιο θορυβοποίησης, δημιουργούμε:

$$x_t^b = \sqrt{\alpha_t} x_0^b + \sqrt{1 - \alpha_t} \varepsilon, \quad \varepsilon \sim \mathcal{N}(0, I),$$

και υπολογίζουμε την απώλεια μόνο στις θέσεις όπου $m = 1$, δηλαδή στα σημεία για τα οποία υπάρχει πραγματικό σήμα. Η προσαρμοσμένη απώλεια γράφεται:

$$\mathcal{L}(\theta) = \mathbb{E}_{x_0, \varepsilon, t} \left[\|(\varepsilon - \varepsilon_\theta(\sqrt{\alpha_t} x_0^b + \sqrt{1 - \alpha_t} \varepsilon, t)) \odot m\|_2^2 \right], \quad (29)$$

όπου ο τελεστής Hadamard $\odot$ εξασφαλίζει ότι η συνεισφορά στο σφάλμα προέρχεται μόνο από τις παρατηρούμενες τιμές. Με αυτό τον τρόπο, το μοντέλο «μαθαίνει» το score μόνο εκεί όπου υπάρχει πραγματικό έδαφος αναφοράς, αποφεύγοντας να παράγει αυθαίρετους υπολογισμούς στα κενά.

Η λογική αυτής της μάσκας είναι διττή:

- **Πρώτον**, εξασφαλίζει ότι η εκπαίδευση δεν επιβαρύνεται με ανύπαρκτες πληροφορίες. Οι μηδενικές τιμές χρησιμοποιούνται απλώς για να διατηρήσουν το σχήμα εισόδου, χωρίς να «παρεμβαίνουν» στην εκτίμηση της απώλειας.
- **Δεύτερον**, παρέχει μια ομαλή μετάβαση από τα πλήρως παρατηρούμενα δεδομένα στα μερικώς παρατηρούμενα, καθιστώντας το δίκτυο ανθεκτικό σε ποικίλους τύπους μάσκας.

Σε πιο σύνθετα σενάρια, το CSDI διαφοροποιεί τις μάσκες μεταξύ *υπό όρους παρατηρήσεων* και *στόχων συμπλήρωσης*, εισάγοντας δύο επιπλέον πίνακες: m_{co} για τις παρατηρήσεις και m_{ta} για τους στόχους. Αυτό επιτρέπει στο δίκτυο να γνωρίζει όχι μόνο ποιες τιμές είναι διαθέσιμες, αλλά και ποιες αποτελούν το αντικείμενο πρόβλεψης στο εκάστοτε βήμα εκπαίδευσης.

Με αυτή τη ρητή διάκριση, η απώλεια παίρνει την πιο γενική μορφή:

$$\min_{\theta} \mathbb{E}_{x_0, \varepsilon, t} \left[\|(\varepsilon - \varepsilon_\theta(x_t^{\text{tab}}, t \mid x_0^{\text{co}}, m_{co})) \odot m_{ta}\|_2^2 \right], \quad (30)$$

όπου x_t^{tab} είναι το θορυβωμένο δείγμα που προκύπτει από το x_0 μετά τη συμπλήρωση μηδενικών στις ελλείπουσες θέσεις. Ο πίνακας m_{co} καθορίζει ποιες τιμές αποτελούν γνωστή πληροφορία (conditional observations), ενώ ο m_{ta} ελέγχει σε ποιες θέσεις θα υπολογιστεί το σφάλμα — δηλαδή, σε ποια σημεία το δίκτυο καλείται να μάθει την αποθορυβοποίηση.

Το **masking του θορύβου** (masked noise) διαδραματίζει επίσης κρίσιμο ρόλο. Ο θόρυβος ε περιορίζεται με τον ίδιο τρόπο μέσω των μασκών, ώστε το δίκτυο να μη λαμβάνει λανθασμένες ενδείξεις στις περιοχές όπου δεν υπάρχει πραγματική πληροφορία. Σχηματικά, αυτό ισοδυναμεί με την παραγωγή ενός «θορυβώδους δείγματος» μόνο στα ενεργά κανάλια, κρατώντας τις υπόλοιπες θέσεις ουδέτερες.

Η προσέγγιση αυτή έχει σημαντικά πλεονεκτήματα:

- Επιτρέπει την εκπαίδευση του μοντέλου ακόμα και σε περιβάλλοντα όπου δεν υπάρχουν πλήρως παρατηρούμενα δείγματα.
- Προλαμβάνει την παραμόρφωση της εκτίμησης score στα μηδενικά ή αυθαίρετα δεδομένα.
- Δημιουργεί ένα ενοποιημένο πλαίσιο που καλύπτει τόσο τις υπό όρους (conditional) όσο και τις μη-υπό όρους (unconditional) εκδοχές διάχυσης.

Συνολικά, η προσαρμοσμένη αυτή απώλεια επιτρέπει στο CSDI να εκπαιδεύεται με ασφάλεια σε πραγματικές χρονοσειρές που περιέχουν ατελή, ακανόνιστα ή σποραδικά ελλείποντα δεδομένα, διατηρώντας τη μαθηματική συνέπεια του πλαισίου διάχυσης. Έτσι, το δίκτυο μαθαίνει όχι μόνο να αποθορυβοποιεί σημεία με γνωστή αναφορά, αλλά και να αναγνωρίζει τις περιοχές όπου η πληροφορία είναι ανεπαρκής — θεμελιώδες χαρακτηριστικό για την επιτυχία της συμπλήρωσης (imputation) σε πραγματικά δεδομένα.

unconditional προσέγγιση imputation. Σε πειράματα όπου χρησιμοποιείται μη-υπό όρους διάχυση για imputation, η υπό όρους αντίστροφη διαδικασία $p_\theta(x_{t-1}^{ta} | x_t^{ta}, x_0^{co})$ προσεγγίζεται με την μη-υπό όρους $p_\theta(x_{t-1} | x_t)$, τροφοδοτώντας ως είσοδο $x_t = [x_t^{co}; x_t^{ta}]$ με $x_t^{co} := \sqrt{\alpha_t} x_0^{co} + \sqrt{1 - \alpha_t} \epsilon$. Έτσι, μπορούμε να δειγματοληπτούμε x_{t-1} , να εξάγουμε τους στόχους x_{t-1}^{ta} και να επαναλάβουμε μέχρι το $t=1$, παράγοντας το x_0^{ta} . Η προσέγγιση αυτή είναι χρήσιμη ως γραμμική βάση, αλλά το πλήρες CSDI επιτυγχάνει ακριβέστερη υπό όρους μοντελοποίηση.

Τεχνικές σταθεροποίησης. Για αριθμητική σταθερότητα και καλύτερη γενίκευση, το CSDI υιοθετεί πρακτικές όπως self-conditioning (χρήση της $\hat{x}_0$ προηγούμενου βήματος ως πρόσθετης εισόδου) και dynamic thresholding για να περιορίζονται οι προβλέψεις στο ρεαλιστικό δυναμικό εύρος των δεδομένων.

Διαδικασία εκπαίδευσης στην πράξη. Η εκπαίδευση εκτελείται σε mini-batches τυχαία δειγματοσιμμένων χρονοσειρών. Για κάθε batch, επιλέγεται τυχαίο t , δημιουργείται το x_t σύμφωνα με (27), υπολογίζεται η απώλεια (28) (ή οι παραλλαγές (29), (30) ανά περίπτωση), και οι παράμετροι ενημερώνονται με AdamW. Η τυχαία επιλογή του t καλύπτει ομοιόμορφα όλα τα στάδια θορυβοποίησης· η εκπαίδευση ολοκληρώνεται όταν η μέση απώλεια σταθεροποιείται σε χαμηλές τιμές, υποδηλώνοντας συνεπή προσέγγιση του score.

Συνολικά, η εκπαίδευση του CSDI ενοποιεί τη θεωρία των score-based diffusion models με έναν ρεαλιστικό μηχανισμό μάθησης για δεδομένα με ελλείψεις. Κάθε επανάληψη μιμείται τη στοχαστική διαδικασία που αργότερα θα αντιστραφεί στη δειγματοληψία, οδηγώντας σε ένα μοντέλο που όχι μόνο συμπληρώνει τα κενά, αλλά μαθαίνει την κατανομή των πιθανών χρονικών εξελίξεων.

Επιλογή Στόχων Συμπλήρωσης στην Αυτοεποπτευόμενη Μάθηση Ένα κρίσιμο στοιχείο της αυτοεποπτευόμενης εκπαίδευσης του CSDI είναι ο τρόπος με τον οποίο επιλέγονται οι στόχοι συμπλήρωσης (imputation targets) κατά τη φάση εκπαίδευσης. Η επιλογή αυτών των στόχων καθορίζει ποια σημεία του σήματος θα αποκρυφθούν τεχνητά και ποια θα χρησιμοποιηθούν ως υπό όρους παρατηρήσεις για να καθοδηγήσουν το δίκτυο. Αν η διαδικασία αυτή γίνει ακατάλληλα, το μοντέλο είτε θα μάθει υπερβολικά συγκεκριμένα μοτίβα απώλειας (οπότε θα υπερπροσαρμοστεί στα δεδομένα εκπαίδευσης), είτε θα αδυνατεί να συλλάβει τη δομή των πραγματικών ελλείψεων που συναντά κατά τη δειγματοληψία.

Για να αντιμετωπιστεί αυτό το πρόβλημα, το CSDI προτείνει τέσσερις διαφορετικές στρατηγικές επιλογής στόχων, ανάλογα με το αν και σε ποιο βαθμό είναι γνωστά τα μοτίβα ελλειπόντων τιμών στα δεδομένα ελέγχου (test set). Κάθε στρατηγική αντανακλά ένα διαφορετικό σενάριο γνώσης και δομής των δεδομένων.

(1) Τυχαία στρατηγική Η πιο βασική στρατηγική εφαρμόζεται όταν δεν υπάρχει καμία πληροφορία σχετικά με τα μοτίβα των ελλείψεων στο σύνολο ελέγχου. Σε αυτή την περίπτωση, ένα τυχαίο ποσοστό των παρατηρούμενων τιμών αποκρύπτεται και χρησιμοποιείται ως στόχοι συμπλήρωσης. Το ποσοστό αυτό δειγματοληπτείται από το διάστημα $[0\%, 100\%]$, ώστε το μοντέλο να εκτεθεί σε πλήθος διαφορετικών ποσοστών απώλειας κατά την εκπαίδευση. Με αυτόν τον τρόπο, το CSDI αποκτά τη δυνατότητα να προσαρμόζεται σε ποικίλα επίπεδα πληρότητας δεδομένων, από πλήρως παρατηρημένα μέχρι και σχεδόν πλήρως ελλιπή σήματα. Αυτή η τυχαία μάσκα λειτουργεί ως μηχανισμός κανονικοποίησης, προάγοντας τη γενίκευση του μοντέλου και αποτρέποντας την εξάρτηση από συγκεκριμένες χωροχρονικές θέσεις απώλειας.

(2) Ιστορική στρατηγική. Σε περιπτώσεις όπου υπάρχουν διαθέσιμες πληροφορίες για τα μοτίβα των ελλείψεων στα δεδομένα εκπαίδευσης, μπορεί να αξιοποιηθεί μια πιο δομημένη προσέγγιση. Η ιστορική στρατηγική (Historical) στηρίζεται στην υπόθεση ότι οι ελλείψεις στα πραγματικά δεδομένα δεν εμφανίζονται τυχαία, αλλά ακολουθούν συχνά επαναλαμβανόμενες δομές — για παράδειγμα, διαδοχικά χρονικά διαστήματα χωρίς καταγραφή ή αισθητήρες που αποτυγχάνουν περιοδικά. Η διαδικασία λειτουργεί ως εξής: για κάθε δείγμα εκπαίδευσης x_0 , επιλέγεται τυχαία ένα δεύτερο δείγμα $\tilde{x}_0$ από το ίδιο σύνολο δεδομένων. Οι δείκτες που είναι παρατηρημένοι στο x_0 και ταυτόχρονα ελλείποντες στο $\tilde{x}_0$ ορίζονται ως νέοι στόχοι συμπλήρωσης x_0^{ta} . Με αυτό τον τρόπο, το μοντέλο

μαθαίνει να αναγνωρίζει και να συμπληρώνει ελλείψεις που ακολουθούν ρεαλιστικά, χρονικά συσχετισμένα μοτίβα, όμοια με αυτά που συναντώνται στον πραγματικό κόσμο. Όταν τα μοτίβα απώλειας μεταξύ εκπαίδευσης και ελέγχου είναι όμοια ή συσχετισμένα, αυτή η στρατηγική μπορεί να βελτιώσει σημαντικά την ποιότητα της υπό όρους κατανομής που μαθαίνει το δίκτυο.

(3) Μικτή στρατηγική Αν και η ιστορική στρατηγική αποτυπώνει ρεαλιστικά μοτίβα ελλείψεων, ενέχει τον κίνδυνο υπερπροσαρμογής, καθώς το μοντέλο μπορεί να μάθει να προβλέπει συγκεκριμένα πρότυπα απώλειας που υπάρχουν μόνο στα δεδομένα εκπαίδευσης. Για να αντιμετωπιστεί αυτή η αδυναμία, προτείνεται η μικτή στρατηγική (Mix strategy), η οποία συνδυάζει τις δύο προηγούμενες μεθόδους. Στην πράξη, ένα μέρος των στόχων επιλέγεται τυχαία (όπως στη Random), ενώ ένα άλλο μέρος καθορίζεται βάσει της ιστορικής σχέσης μεταξύ δειγμάτων (όπως στη Historical). Αυτός ο συνδυασμός επιτρέπει στο μοντέλο να διατηρεί την ικανότητα γενίκευσης σε νέες περιπτώσεις, χωρίς να χάνει την προσαρμοστικότητα σε ρεαλιστικά μοτίβα απώλειας. Είναι μια ισορροπημένη επιλογή που εξυπηρετεί εφαρμογές όπου η δομή των ελλείψεων είναι εν μέρει γνωστή, αλλά όχι σταθερή ή απόλυτα επαναλαμβανόμενη.

(4) Στρατηγική ελέγχου προτύπων Η τελευταία στρατηγική εφαρμόζεται όταν τα μοτίβα των ελλείψεων στο σύνολο ελέγχου είναι εκ των προτέρων γνωστά. Σε αυτή την περίπτωση, η εκπαίδευση μπορεί να εξειδικευθεί πλήρως στις ίδιες μάσκες που θα εμφανιστούν στη φάση δειγματοληψίας. Χαρακτηριστικό παράδειγμα είναι η πρόβλεψη χρονοσειρών (forecasting), όπου τα «ελλείποντα» σημεία αντιστοιχούν στα μελλοντικά χρονικά βήματα που θέλουμε να προβλέψουμε. Εφόσον οι χρονικές θέσεις αυτών των σημείων είναι εκ των προτέρων γνωστές, η μάσκα μπορεί να οριστεί εξ αρχής, επιτρέποντας στο μοντέλο να μάθει να προβλέπει ακριβώς τα χρονικά διαστήματα ενδιαφέροντος. Η στρατηγική αυτή έχει τον πιο στοχευμένο χαρακτήρα και συνήθως προσφέρει τις καλύτερες επιδόσεις, όταν οι συνθήκες μεταξύ εκπαίδευσης και ελέγχου είναι πλήρως εναρμονισμένες.

Συνοψίζοντας, οι παραπάνω στρατηγικές σχηματίζουν μια ιεραρχία μεταξύ τυχαιότητας και δομής: η Random μεγιστοποιεί τη γενίκευση, η Historical ενσωματώνει ρεαλιστικά μοτίβα, η Mix εξισορροπεί τα δύο, και η Test pattern εξειδικεύει την εκπαίδευση για συγκεκριμένες συνθήκες. Η ευελιξία αυτή καθιστά το CSDI ικανό να προσαρμόζεται σε διαφορετικούς τύπους δεδομένων και σενάρια, από πλήρως τυχαίες ελλείψεις μέχρι προβλέψεις προκαθορισμένων χρονικών παραθύρων.

Αρχιτεκτονική του CSDI

Η αρχιτεκτονική του CSDI έχει σχεδιαστεί ώστε να επεκτείνει το γενικό πλαίσιο των score-based diffusion models σε δεδομένα χρονοσειρών με ελλείψεις, λαμβάνοντας ρητά υπόψη τόσο τη χρονική εξάρτηση όσο και τη συσχέτιση μεταξύ χαρακτηριστικών. Για να επιτευχθεί αυτό, η συνάρτηση αποθορυβοποίησης ε_θ πρέπει να μπορεί να δέχεται ως είσοδο μερικώς παρατηρούμενες χρονοσειρές, να χειρίζεται μάσκες παρατήρησης και να μαθαίνει αλληλεπιδράσεις κατά μήκος του χρόνου και των χαρακτηριστικών.

Δομή εισόδων και μάσκες. Κάθε δείγμα χρονοσειράς αναπαρίσταται ως τριάδα $\{X, M, s\}$, όπου $X \in \mathbb{R}^{K \times L}$ είναι η πολυμεταβλητή ακολουθία με K χαρακτηριστικά και L χρονικά βήματα, $M \in \{0, 1\}^{K \times L}$ είναι η μάσκα παρατήρησης που δηλώνει ποιες τιμές είναι διαθέσιμες, και $s = \{s_1, \dots, s_L\}$ το διανυσματικό χρονικό στίγμα κάθε δείγματος.

Η συνάρτηση ε_θ , όπως ορίστηκε προηγουμένως, δέχεται ως είσοδο τα μερικώς θορυβοποιημένα δείγματα x_t^{ta} και τις υπό όρους παρατηρήσεις x_0^{co} . Ωστόσο, οι δύο αυτές μεταβλητές δεν έχουν σταθερό σχήμα — καταλαμβάνουν υποσύνολα του χώρου X . Για να μπορεί το δίκτυο να επεξεργαστεί τα δεδομένα σε ένα συνεκτικό χώρο, όλες οι είσοδοι προσαρμόζονται στο ίδιο σταθερό σχήμα $K \times L$ μέσω μηδενικής συμπλήρωσης (zero padding). Με αυτό τον τρόπο, οι θέσεις που δεν περιέχουν πραγματικές τιμές (λευκές περιοχές στο Σχ. 3) συμπληρώνονται με μηδενικά.

Για να υποδειχθούν οι θέσεις που περιέχουν έγκυρη πληροφορία, εισάγεται η μάσκα $m_{\text{co}} \in \{0, 1\}^{K \times L}$, η οποία έχει τιμή 1 στις θέσεις των υπό όρους παρατηρήσεων. Έτσι, η αποθορυβοποιητική συνάρτηση αποκτά τη γενική μορφή:

$$\varepsilon_\theta : (\mathbb{R}^{K \times L} \times \mathbb{R} \mid \mathbb{R}^{K \times L} \times \{0, 1\}^{K \times L}) \longrightarrow \mathbb{R}^{K \times L},$$

και γράφεται $\varepsilon_\theta(x_t^{\text{ta}}, t \mid x_0^{\text{co}}, m_{\text{co}})$.

Κατά τη δειγματοληψία, το m_{co} ισούται με τη μάσκα M των παρατηρούμενων τιμών, ενώ τα στοιχεία του x_0^{co} λαμβάνονται ως $x_0^{co} = m_{co} \odot X$. Αντίθετα, στην εκπαίδευση, όπου ο διαχωρισμός γίνεται βάσει της στρατηγικής επιλογής στόχων, ορίζουμε:

$$x_0^{co} = m_{co} \odot X, \quad x_0^{ta} = (M - m_{co}) \odot X,$$

εξασφαλίζοντας συνεπή είσοδο τόσο για τα πραγματικά όσο και για τα τεχνητά ελλείποντα σημεία.


Βασική αρχιτεκτονική. Το CSDI υιοθετεί ως βάση την αρχιτεκτονική του DiffWave [20], η οποία αποτελείται από πολλαπλά **υπολειμματικά στρώματα** (residual layers) με C υπολειμματικά κανάλια. Κάθε στρώμα ενσωματώνει μηχανισμούς κανονικοποίησης και συνδέσεις παράκαμψης (skip connections), επιτρέποντας την προοδευτική μεταφορά πληροφορίας μεταξύ των επιπέδων διάχυσης. Η συνολική διαδικασία εκτελείται για $T = 50$ βήματα διάχυσης.

Παρά το ότι το DiffWave βασίζεται σε συνελκτικά φίλτρα (convolutions), το CSDI αντικαθιστά πλήρως αυτά τα μπλοκ με **μηχανισμούς προσοχής δύο διαστάσεων** (2D attention), ώστε να συλλάβει ταυτόχρονα τη χρονική και δια-χαρακτηριστική συσχέτιση.

Διπλός μηχανισμός προσοχής. Κάθε υπολειμματικό στρώμα του CSDI περιλαμβάνει δύο διαδοχικούς μηχανισμούς προσοχής τύπου Transformer encoder:

- έναν **χρονικό Transformer layer**, που δέχεται ως είσοδο το υποσύνολο $X_{:,1:L}$ για κάθε χαρακτηριστικό, και μαθαίνει τη χρονική εξάρτηση (π.χ. επαναλαμβανόμενα μοτίβα, φθίνουσες συσχετίσεις),
- έναν **δια-χαρακτηριστικό Transformer layer**, που δέχεται ως είσοδο τα $X_{1:K,l}$ για κάθε χρονικό βήμα, και μαθαίνει τις αλληλεπιδράσεις μεταξύ των χαρακτηριστικών.

Κάθε ένα από τα δύο αυτά στρώματα αποτελεί έναν TransformerEncoder μιας επανάληψης (1-layer), με multi-head attention, πλήρως συνδεδεμένα επίπεδα και κανονικοποίηση επιπέδου (LayerNorm). Ο διπλός αυτός σχεδιασμός επιτρέπει στο δίκτυο να μοντελοποιεί συσχετίσεις τόσο στον χρόνο όσο και μεταξύ των καναλιών, χωρίς να χρειάζεται σταθερό μήκος ακολουθίας — το μήκος L μπορεί να μεταβάλλεται ανά δείγμα, και για τη συνεκτική εκπαίδευση γίνεται μηδενική συμπλήρωση (padding) στο μέγιστο μήκος της παρτίδας.



Σχήμα 4: Αρχιτεκτονική μηχανισμού προσοχής δύο διαστάσεων (2D Attention) [35]. Δεδομένου ενός ταυστή με K χαρακτηριστικά, μήκος L και C κανάλια, το Temporal Transformer layer λαμβάνει είσοδο σχήματος $(1, L, C)$ για κάθε χαρακτηριστικό και μαθαίνει χρονικές εξαρτήσεις, ενώ το Feature Transformer layer λαμβάνει είσοδο $(K, 1, C)$ για κάθε χρονική στιγμή και μαθαίνει δια-χαρακτηριστικές εξαρτήσεις. Το τελικό σχήμα εξόδου είναι (K, L, C) , ίδιο με της εισόδου.

Ενσωμάτωση χρονικών και κατηγορικών πληροφοριών. Για να αποδοθεί στο δίκτυο γνώση της χρονικής τοποθέτησης κάθε βήματος, χρησιμοποιούνται **χρονικές ενσωματώσεις** (temporal embeddings) $s_{\text{embedding}}(s_l)$ 128 διαστάσεων, όμοιες με τις sinusoidal positional encodings των Transformers [37]. Για κάθε χρονική στιγμή s_l :

$$s_{\text{embedding}}(s_l) = [\sin(s_l/\tau^{0/64}), \dots, \sin(s_l/\tau^{63/64}), \cos(s_l/\tau^{0/64}), \dots, \cos(s_l/\tau^{63/64})], \quad (31)$$


όπου $\tau = 10000$.

Επιπλέον, κάθε χαρακτηριστικό k αποκτά μια **κατηγορική ενσωμάτωση** 16 διαστάσεων, ώστε το μοντέλο να διακρίνει διαφορετικές φυσικές ή σημασιολογικές πηγές (π.χ. αισθητήρας, όργανο, κανάλι). Οι ενσωματώσεις αυτές προσαρτώνται (concatenate) στα χρονικά embeddings και επαναλαμβάνονται σε όλα τα χρονικά βήματα, δημιουργώντας έναν ενιαίο πίνακα πλευρικής πληροφορίας (side information) που εισάγεται στο δίκτυο μαζί με τα κύρια δεδομένα εισόδου.

Ενσωμάτωση του βήματος διάχυσης. Το χρονικό βήμα διάχυσης t εισέρχεται στο δίκτυο μέσω ενός 128-διάστατου **diffusion step embedding**:

$$t_{\text{embedding}}(t) = [\sin(100^{0/63}t), \dots, \sin(100^{63/63}t), \cos(100^{0/63}t), \dots, \cos(100^{63/63}t)], \quad (32)$$

το οποίο ακολουθεί την ίδια περιοδική μορφή με αυτή των DiffWave και DDPM, επιτρέποντας στο μοντέλο να κατανοεί τη θέση κάθε βήματος στο στοχαστικό μονοπάτι της διάχυσης.



Σχήμα 5: Πλήρης αρχιτεκτονική της συνάρτησης αποθρομβοποίησης ε_θ στο CSDI για πολυμεταβλητή συμπλήρωση χρονοσειρών [35]. Το δίκτυο δέχεται ως είσοδο τα $x_0^{\text{co}}, x_t^{\text{ta}}$, τη μάσκα m_{co} και τις ενσωματώσεις διάχυσης, χρόνου και χαρακτηριστικών. Κάθε υπολειμματικό μπλοκ (residual layer) περιλαμβάνει ένα ζεύγος Temporal / Feature Transformer layers, ενώ οι παρακάμψεις (skip connections) συνδέουν όλα τα επίπεδα. Στην έξοδο, εφαρμόζεται η μάσκα $(1 - m_{\text{co}})$ ώστε να μηδενίζονται οι υπό όρους παρατηρήσεις.

Συνδυασμός εισόδων και εξόδων. Στην είσοδο του δικτύου συνενώνονται τα εξής:

$$\{x_t^{\text{ta}}, x_0^{\text{co}}, m_{\text{co}}, t_{\text{embedding}}, s_{\text{embedding}}, \text{feature embeddings}\},$$

δημιουργώντας έναν πολυδιάστατο πίνακα χαρακτηριστικών που περιλαμβάνει πληροφορία για τον χρόνο, το χαρακτηριστικό και τη φάση της διάχυσης. Στην έξοδο, εφαρμόζεται μάσκα $(1 - m_{\text{co}})$ ώστε να μηδενίζονται οι προβλέψεις στις υπό όρους παρατηρήσεις — το δίκτυο προβλέπει μόνο στα σημεία όπου χρειάζεται αποθρομβοποίηση.

Διαφορές από το DiffWave. Σε αντίθεση με το αρχικό DiffWave, το CSDI:

- αντικαθιστά τις συνεκτικές δομές με μηχανισμούς προσοχής δύο αξόνων (temporal και feature transformers);
- ενσωματώνει μάσκες παρατήρησης m_{co} και μηδενική συμπλήρωση ώστε να χειρίζεται δυναμικά ελλείψεις και διαφορετικά μήκη ακολουθιών·
- χρησιμοποιεί πολλαπλά κανάλια υπολειμματικής ροής (residual channels) προσαρμοσμένα σε δεδομένα χρονοσειρών·
- εφαρμόζει πολλαπλές ενσωματώσεις πλευρικής πληροφορίας (diffusion step, temporal και feature embeddings).

Υπολογιστική βελτιστοποίηση. Για πειράματα πρόβλεψης με μεγάλα K ή L , χρησιμοποιείται η αποδοτική παραλλαγή linear attention transformer [17], η οποία υπολογίζει την προσοχή με πολυπλοκότητα $O(N)$ αντί $O(N^2)$, διατηρώντας υψηλή απόδοση χωρίς απώλεια ακρίβειας. Μόνο για καθήκοντα forecasting ενεργοποιείται η *global attention* εκδοχή, ενώ για imputation χρησιμοποιούνται πλήρεις μηχανισμοί προσοχής.

Συνολικά, η αρχιτεκτονική του CSDI συνδυάζει:

- υπό όρους διάχυση (conditioned reverse process),
- διπλή προσοχή σε χρόνο και χαρακτηριστικά,
- πολλαπλές ενσωματώσεις πλευρικής πληροφορίας, και
- μασκωμένη έξοδο για ελεγχόμενη αποθορυβοποίηση.

Αυτός ο σχεδιασμός καθιστά το CSDI ικανό να μαθαίνει εξαρτήσεις πολλών επιπέδων σε πολύπλοκες, ελλειπείς χρονοσειρές, συνδυάζοντας την ευελιξία των Transformers με τη στοχαστική ακρίβεια των diffusion models.

Δειγματοληψία και Ανακατασκευή Χρονοσειρών

Αφού ολοκληρωθεί η εκπαίδευση, το CSDI μπορεί να χρησιμοποιηθεί για τη δημιουργία πλήρων χρονοσειρών από μερικές μόνο παρατηρήσεις. Στην ουσία, η διαδικασία δειγματοληψίας αποτελεί την αντίστροφη προσομοίωση του στοχαστικού μηχανισμού που περιγράφηκε στο forward βήμα (1) και στη συνθηκοποιημένη εκδοχή του (28). Η θεωρητική αρχή παραμένει ίδια: το μοντέλο μαθαίνει να αφαιρεί θόρυβο από το x_t , επιδιώκοντας να ανακτήσει το καθαρό σήμα x_0 , αλλά πλέον η διαδικασία πραγματοποιείται υπό συνθήκη ως προς τη μάσκα παρατήρησης M και τις γνωστές τιμές x_{obs} .

Αρχικοποίηση. Η αντίστροφη διαδικασία ξεκινά από το μέγιστο επίπεδο αβεβαιότητας, δηλαδή από ένα δείγμα x_T που ακολουθεί την τυπική κανονική κατανομή $\mathcal{N}(0, I)$, όπως έχει οριστεί και στο γενικό πλαίσιο της διάχυσης. Σε αυτό το στάδιο, καμία χρονική πληροφορία δεν είναι παρούσα: όλα τα ελλείποντα σημεία είναι καθαρός θόρυβος, ενώ τα παρατηρούμενα διατηρούνται σταθερά μέσω της μάσκας M , ώστε να παραμένουν αναλλοίωτα καθ' όλη τη διαδικασία.

Αντίστροφα βήματα διάχυσης. Ξεκινώντας από το x_T , το μοντέλο εκτελεί T αντίστροφα βήματα, επαναφέροντας σταδιακά την πληροφορία που είχε χαθεί στη θορυβοποίηση. Σε κάθε στάδιο t , η πρόβλεψη του καθαρού δείγματος υπολογίζεται μέσω της *conditional reparameterization form* (8), όπου η εκτίμηση του μοντέλου για τον θόρυβο ϵ_θ υποκαθιστά τον πραγματικό θόρυβο ϵ :

$$\hat{x}_0(x_t, M, x_{\text{obs}}, t) = \frac{x_t - \sqrt{1 - \bar{\alpha}_t} \epsilon_\theta(x_t, M, x_{\text{obs}}, t)}{\sqrt{\bar{\alpha}_t}}. \quad (33)$$

Η παραπάνω εξίσωση, ταυτόσημη με την αντίστοιχη του κλασικού DDPM [12], προσαρμόζεται εδώ ώστε η πρόβλεψη να εξαρτάται ρητά από τη μάσκα παρατήρησης. Με αυτόν τον τρόπο, το μοντέλο γνωρίζει ποιες τιμές είναι αξιόπιστες και ποιες χρειάζονται αποκατάσταση.

Στη συνέχεια, το προηγούμενο στάδιο x_{t-1} προκύπτει από τη Γκαουσιανή μορφή της αντίστροφης διαδικασίας (11):

$$x_{t-1} = \sqrt{\bar{\alpha}_{t-1}} \hat{x}_0 + \sqrt{1 - \bar{\alpha}_{t-1}} z, \quad z \sim \mathcal{N}(0, I). \quad (34)$$

Ο θόρυβος z εισάγει στοχαστικότητα στο δείγμα, επιτρέποντας στο μοντέλο να παράγει πολλαπλές εναλλακτικές λύσεις. Σε κάθε βήμα, οι γνωστές τιμές επαναφέρονται:

$$x_{t-1} \leftarrow M \odot x_{\text{obs}} + (1 - M) \odot x_{t-1}, \quad (35)$$

ώστε η διαδικασία να παραμένει συνεπής με τα δεδομένα εισόδου.

Υπό όρους δειγματοληψία και αβεβαιότητα. Επαναλαμβάνοντας τα βήματα (33)–(35) μέχρι το $t = 1$, παράγεται μία πλήρης εκδοχή της χρονοσειράς x_0 . Επειδή η διαδικασία είναι στοχαστική, μπορούν να παραχθούν πολλαπλές ανακατασκευές $x_0^{(1)}, x_0^{(2)}, \dots, x_0^{(N)}$, οι οποίες σχηματίζουν μια εκτίμηση της υπό όρους κατανομής $p_\theta(x_0 | x_{\text{obs}})$. Η διασπορά αυτών των δειγμάτων παρέχει μέτρο αβεβαιότητας, αντανakλώντας το πόσο βέβαιο είναι το μοντέλο για κάθε σημείο της ακολουθίας.

Αν και το CSDI χρησιμοποιεί κατά βάση την τυπική διαδικασία ancestral sampling, είναι επίσης συμβατό με την απλούστερη και ταχύτερη DDIM parameterization [33], όπου η στοχαστικότητα z μπορεί να παραληφθεί. Αυτό επιτρέπει την παραγωγή καθοριστικών (deterministic) ανακατασκευών, χρήσιμων όταν προέχει η σταθερότητα ή η ακρίβεια σε πραγματικού χρόνου εφαρμογές. Η επιλογή μεθόδου επομένως εξαρτάται από το ζητούμενο: η πλήρης στοχαστική δειγματοληψία προσφέρει πλουσιότερη εκτίμηση αβεβαιότητας, ενώ η ντετερμινιστική εκδοχή παρέχει ταχύτερη και προβλέψιμη συμπλήρωση.

Η διαδικασία δειγματοληψίας του CSDI δεν είναι μια απλή αναστροφή του θορύβου, αλλά μια *στοχαστική αναδόμηση υπό συνθήκη*, όπου το μοντέλο αξιοποιεί τις γνωστές τιμές για να καθοδηγήσει την αποθορυβοποίηση των ελλειπόντων. Με αυτόν τον τρόπο, επεκτείνεται η θεωρία των score-based diffusion models σε προβλήματα πραγματικών χρονοσειρών, όπου η αβεβαιότητα και η αιτιότητα παίζουν κεντρικό ρόλο. Το αποτέλεσμα είναι όχι μόνο η ανακατασκευή ενός πιθανού σεναρίου, αλλά ενός πλήρους πιθανοτικού πεδίου χρονικών εξελίξεων, το οποίο αποτυπώνει ρεαλιστικά τη στοχαστική φύση του χρόνου και των μετρήσεων.

Πίνακας 3: Δειγματοληψία / Συμπλήρωση (imputation) με CSDI.

Είσοδος: δείγμα x_0 με παρατηρούμενες τιμές x_0^{co} , εκπαιδευμένη ε_θ .
Έξοδος: συμπληρωμένες τιμές x_0^{ta} .

Αρχικοποίηση: $x_T^{\text{ta}} \sim \mathcal{N}(0, I)$ με διαστάσεις ίδιες με των ελλειπόντων δεικτών του x_0 .
for $t = T, T-1, \dots, 1$ **do**
 Αντίστροφο βήμα:
 Υπολόγισε $\mu_\theta(x_t^{\text{ta}}, t \mid x_0^{\text{co}})$ και $\sigma_\theta(x_t^{\text{ta}}, t \mid x_0^{\text{co}})$ όπως στην (26).
 Δειγμάτισε x_{t-1}^{ta} από την κατανομή του αντίστροφου βήματος (Εξ. (5),(6)).
end for
Έξοδος: x_0^{ta} .

2.3 Καθοδήγηση σε Μοντέλα Διάχυσης για Χρονοσειρές

2.3.1 Θεμελίωση και Αναγκαιότητα της Καθοδήγησης σε Γενετικά Μοντέλα Χρονοσειρών

Τα μοντέλα διάχυσης (diffusion models) αποτελούν ένα ισχυρό πλαίσιο για τη γένεση πολύπλοκων κατανομών δεδομένων, με βάση την αντιστροφή μιας στοχαστικής διαδικασίας διαφθοράς [32, 12, 34, 1]. Κατά την εκπαίδευση, το μοντέλο μαθαίνει πώς να αφαιρεί προοδευτικά τον θόρυβο από παραμορφωμένα δείγματα, ενώ κατά τη δειγματοληψία επαναλαμβάνει αυτή την αντίστροφη διαδικασία για να ανασυνθέσει ρεαλιστικά δεδομένα. Ωστόσο, η μη καθοδηγούμενη διάχυση λειτουργεί αποκλειστικά με βάση τα στατιστικά των δεδομένων εκπαίδευσης, χωρίς τη δυνατότητα να ελέγχει την κατεύθυνση ή το περιεχόμενο της γενετικής διαδικασίας.

Στο πεδίο των χρονοσειρών, όπου η χρονική εξάρτηση και η αιτιότητα διαδραματίζουν καθοριστικό ρόλο, η απουσία ελέγχου περιορίζει σημαντικά τη χρησιμότητα των μοντέλων διάχυσης. Εφαρμογές όπως η πρόβλεψη μελλοντικών τιμών, η αποκατάσταση ελλειπόν παρατηρήσεων (imputation), ή η παραγωγή ρεαλιστικών σεναρίων υπό εξωτερικούς περιορισμούς, απαιτούν μηχανισμούς που μπορούν να κατευθύνουν τη στοχαστική διαδικασία προς συγκεκριμένους στόχους. Η έννοια της *καθοδήγησης* (guidance) προκύπτει ακριβώς για να ικανοποιήσει αυτή την ανάγκη: να επιτρέψει στον χρήστη να διαμορφώνει τη γενετική συμπεριφορά του μοντέλου με τρόπο που παραμένει συμβατός με τη βασική πιθανοτική αρχιτεκτονική της διάχυσης.

Η ανάγκη για καθοδήγηση αναδύεται από τρεις αλληλένδετες διαστάσεις:

Controllability Η δυνατότητα καθοδήγησης επιτρέπει τη στοχευμένη παραγωγή δεδομένων που συμμορφώνονται με επιθυμητούς χρονικούς ή δομικούς περιορισμούς. Για παράδειγμα, το μοντέλο μπορεί να εξαναγκαστεί ώστε οι παραγόμενες τροχιές να παραμένουν συνεπείς με το πρόσφατο παρελθόν, ή ώστε τα πολυμεταβλητά κανάλια να υπακούουν σε γνωστές συσχετίσεις, ιεραρχίες ή τοπολογίες γράφων [7, 2, 23]. Η καθοδήγηση μετατρέπει έτσι τη διάχυση από μη ελεγχόμενο γενετικό μηχανισμό σε εργαλείο με ρητή κατεύθυνση και εφαρμοστικό σκοπό.

Guided Realism Η μη καθοδηγούμενη διάχυση παράγει συνήθως «μέσες» ή ομαλοποιημένες εκδοχές των χρονοσειρών, οι οποίες αν και στατιστικά συνεπείς, συχνά στερούνται εντοπισμένων χρονικών προτύπων ή ενισχυμένων αιτιωδών σχέσεων. Η καθοδήγηση εισάγει ρητούς όρους που τροποποιούν τη βαθμίδα της αντίστροφης διαδικασίας, προκαλώντας τη διάχυση να κινηθεί προς περιοχές του λανθάνοντος χώρου που αντιστοιχούν σε δομές με ενισχυμένο σημασιολογικό περιεχόμενο — π.χ. τονισμό περιοδικοτήτων, αιχμών ή συσχετισμένων καναλιών [7, 13].

Interpretability και Alignment Η εισαγωγή καθοδηγητικών όρων, όπως βαθμίδων ταξινομητών ή φυσικών περιορισμών, επιτρέπει τη μελέτη του τρόπου με τον οποίο το μοντέλο ανταποκρίνεται σε εξωτερικές επιρροές. Η αντίστροφη διαδικασία καθίσταται πλέον *διαφανής*, καθώς μπορούμε να παρατηρήσουμε πώς η καθοδήγηση επηρεάζει τις μερικές παραγώγους της βαθμίδας, και να εξαγάγουμε συμπεράσματα για τη δυναμική της γένεσης [2, 23, 18]. Έτσι, η καθοδήγηση δεν είναι μόνο εργαλείο ελέγχου, αλλά και μέσο ερμηνείας της εσωτερικής λειτουργίας των diffusion models.

Στο πλαίσιο των χρονοσειρών, τα παραπάνω κίνητρα αποκτούν ιδιαίτερη σημασία. Η παραγωγή χρονικών δεδομένων απαιτεί ταυτόχρονα *αιτιώδη συνέπεια*, *πολυμεταβλητή συνοχή* και *πιθανοκρατική ποικιλία*. Η καθοδήγηση λειτουργεί ως γέφυρα ανάμεσα σε αυτές τις απαιτήσεις, επιτρέποντας στο μοντέλο να παραμένει πιστό στα δεδομένα, να ενισχύει τις σχέσεις που καθορίζονται από τη δομή ή τη φυσική του φαινομένου, και να διατηρεί το εγγενές στοχαστικό του εύρος. Με αυτόν τον τρόπο, η καθοδήγηση μεταμορφώνει τη διάχυση από ένα γενικό πλαίσιο παραγωγής δεδομένων σε μια δυναμική, ελεγχόμενη διαδικασία χρονικής μοντελοποίησης θεμελιώνοντας το πεδίο των *καθοδηγούμενων μοντέλων διάχυσης για χρονοσειρές*.

Εννοιολογική Διαφορά μεταξύ Conditioning και Guidance Παρότι οι όροι conditioning και guidance συχνά χρησιμοποιούνται εναλλακτικά στη βιβλιογραφία, αντιπροσωπεύουν δύο διαφορετικούς τρόπους ελέγχου της διαδικασίας διάχυσης [23, 2]. Η διάκριση τους δεν είναι απλώς τεχνική· σχετίζεται άμεσα με το στάδιο στο οποίο εφαρμόζεται η πληροφορία (εκπαίδευση ή δειγματοληψία) και με το είδος της τροποποίησης που εφαρμόζεται.

Στο conditioning, το μοντέλο *εκπαιδύεται εξ αρχής* ώστε να ενσωματώνει κάποια γνωστή πληροφορία C , όπως μάσκες παρατήρησης, εξωγενείς μεταβλητές ή σημασιολογικά χαρακτηριστικά. Η συνθήκη αυτή γίνεται μέρος της εκπαίδευσης και μεταβάλλει την ίδια την κατανομή που μαθαίνει το μοντέλο — δηλαδή το $p_\theta(x|C)$.

Αντίθετα, η καθοδήγηση (guidance) *επιδρά εκ των υστέρων*, κατά τη διαδικασία δειγματοληψίας, προσθέτοντας έναν εξωτερικό βαθμιδωτό όρο που κατευθύνει τη ροή της αντίστροφης διάχυσης. Έτσι, το μοντέλο δεν επανεκπαιδεύεται, αλλά ωθείται να εξερευνήσει περιοχές στον latent space που μεγιστοποιούν μια επιθυμητή δεσμευμένη πιθανότητα ή κάποιον δομικό περιορισμό.

Πτυχή	Conditioning	Καθοδήγηση (Guidance)
Ορισμός	Ενσωμάτωση γνωστής πληροφορίας C απευθείας στο μοντέλο διάχυσης (π.χ. $s_\theta(x_t, C, t)$).	Μεταγενέστερη τροποποίηση της αντίστροφης δυναμικής με χρήση εξωτερικής βαθμίδας ή όρου προκατάληψης.
Μηχανισμός	Μαθαίνεται κατά την εκπαίδευση — το μοντέλο προσαρμόζεται στο C .	Εφαρμόζεται κατά τη δειγματοληψία — τροποποιεί το πεδίο SDE/ODE.
Εξίσωση	$dX_t = [f(X_t, t) - g^2(t) s_\theta(X_t, C, t)] dt + g(t) dW_t$	$dX_t = [f(X_t, t) - g^2(t) (s_\theta(X_t, t) + \lambda \nabla_{x_t} \log p_t(C))] dt + g(t) dW_t$
Παραδείγματα	Αποκατάσταση υπό μάσκα, προγνωστική διάχυση.	Καθοδήγηση από ταξινομητή, καθοδήγηση χωρίς ταξινομητή (classifier-free), αυτοκαθοδήγηση, καθοδήγηση μέσω συσχέτισης ή γράφων.
Κόστος Εκπαίδευσης	Απαιτεί σύνολο δεδομένων με συνθήκες ή μάσκες.	Επαναχρησιμοποιεί το μη καθοδηγούμενο μοντέλο· απαιτεί εκτίμηση εξωτερικής βαθμίδας.
Ερμηνεία	Μεταβάλλει την κατανομή $p_\theta(x C)$ που μαθαίνει το μοντέλο.	Μεταβάλλει τη δειγματοληψία διατηρώντας το ίδιο εκπαιδευμένο μοντέλο.

Πίνακας 4: Εννοιολογική διάκριση μεταξύ conditioning και καθοδήγησης στα μοντέλα διάχυσης [35, 7, 13, 23].

Συνοψίζοντας, το conditioning καθορίζει *τι μαθαίνει* το μοντέλο κατά την εκπαίδευση, ενώ η καθοδήγηση ρυθμίζει *πώς δειγματοληπτεί* κατά την παραγωγή. Η δεύτερη λειτουργεί ως στοχαστική διόρθωση της αντίστροφης διαδικασίας, μετατοπίζοντας το πεδίο της SDE/ODE προς περιοχές υψηλότερης δεσμευμένης πιθανότητας, χωρίς να αλλάζει τα βάρη του νευρωνικού δικτύου [2, 23]. Με αυτό τον τρόπο, η καθοδήγηση επιτρέπει την εκ των υστέρων επιβολή περιορισμών, προσφέροντας ένα ευέλικτο εργαλείο ελέγχου πάνω στην ίδια στοχαστική γεωμετρία της διάχυσης.

Γιατί η Καθοδήγηση Είναι Απαραίτητη για Ελεγχόμενη Χρονική Γένεση Στο πεδίο των χρονοσειρών, η καθοδήγηση αποκτά ιδιαίτερη σημασία, καθώς τα δεδομένα δεν είναι απλές στατικές δομές αλλά χρονικά εξαρτημένα σήματα με αιτιακές σχέσεις. Ένα μη καθοδηγούμενο μοντέλο διάχυσης μπορεί να παράγει στατιστικά έγκυρες αλλά συχνά «μέσες» ή αποπροσανατολισμένες δυναμικές, παραγνωρίζοντας τη χρονική κατεύθυνση, τις εξαρτήσεις μεταξύ καναλιών και τα εξωγενή συμφραζόμενα [35]. Η καθοδήγηση επιτρέπει την ενεργό παρέμβαση σε αυτή τη διαδικασία, ώστε η γένεση να παραμένει συνεπής με την πραγματική δομή του χρόνου και του φαινομένου.

Οι κύριες διαστάσεις ελέγχου που καθιστούν την καθοδήγηση αναγκαία είναι οι εξής:

Χρονική συνέπεια (Temporal Consistency). Χωρίς καθοδήγηση, τα παραγόμενα δείγματα μπορεί να αποσυνδεθούν από το πρόσφατο παρελθόν ή να εμφανίσουν μη ρεαλιστικές μεταβάσεις. Η καθοδήγηση εισάγει βαθμιδωτούς όρους που εξασφαλίζουν συνέχεια και ομαλότητα ανάμεσα στο γνωστό και στο προβλεπόμενο τμήμα της ακολουθίας [35, 23].

Αιτιακή κατεύθυνση (Causal Directionality). Η ενσωμάτωση πληροφοριών που αντικατοπτρίζουν γνωστές αιτιακές σχέσεις — όπως φυσικούς νόμους, λειτουργικά μοντέλα ή δομές εξάρτησης — καθιστά την εξέλιξη της διάχυσης αιτιωδώς ευθυγραμμισμένη με το χρόνο [7, 18].

Διακαναλική συνοχή (Cross-Channel Coherence). Σε πολυμεταβλητές χρονοσειρές, τα κανάλια δεν είναι ανεξάρτητα· αντιπροσωπεύουν αλληλεπιδρώντα υποσυστήματα. Η καθοδήγηση με βάση γράφους ή συσχετίσεις επιτρέπει στο μοντέλο να διατηρεί τη φυσική ή στατιστική συνάφεια μεταξύ των καναλιών κατά την αποθορυβοποίηση [18, 2].

Εξωγενείς και πολυτροπικές συνθήκες (Exogenous and Multi-Modal Constraints). Πολλές πραγματικές εφαρμογές περιλαμβάνουν εξωτερικές μορφές πληροφορίας, όπως μεταδεδομένα αισθητήρων, χωρικές ενδείξεις ή κειμενικές περιγραφές. Η καθοδήγηση επιτρέπει την αξιοποίησή τους ακόμη κι αν δεν συμπεριλαμβάνονταν ρητά στην εκπαίδευση, παρέχοντας ένα γενικό πλαίσιο πολυτροπικής ενσωμάτωσης [23].

Ισορροπία εξερεύνησης-εκμετάλλευσης (Exploration-Exploitation Balance). Η ισχύς της καθοδήγησης ρυθμίζεται μέσω του παράγοντα λ , ο οποίος καθορίζει τον βαθμό απόκλισης από την ελεύθερη διάχυση. Μικρές τιμές επιτρέπουν ευρεία στοχαστική εξερεύνηση αλλά χαμηλή πιστότητα, ενώ μεγάλες τιμές οδηγούν σε σχεδόν ντετερμινιστική σύγκλιση [7, 13, 2].

Η καθοδηγούμενη αντίστροφη δυναμική, σύμφωνα με το γενικευμένο σχήμα των score-based SDEs [34, 1], παίρνει τη μορφή:

$$dX_t = [f(X_t, t) - g^2(t) (s_\theta(X_t, t) + \lambda \nabla_{x_t} \log p_t(C|X_t))] dt + g(t) d\bar{W}_t, \quad (36)$$

όπου η βαθμίδα $\nabla_{x_t} \log p_t(C|X_t)$ εκφράζει την εξωτερική καθοδήγηση — π.χ. από ταξινομητή, φυσικό περιορισμό ή συσχετιστική δομή. Το σχήμα αυτό ενώνει σε ένα ενιαίο πλαίσιο τις προσεγγίσεις classifier guidance, classifier-free guidance και τις πιο πρόσφατες correlation-aware ή graph-based μεθόδους [7, 13, 2, 23].

Η καθοδήγηση μεταμορφώνει τα μοντέλα διάχυσης χρονοσειρών από παθητικούς αναπαραγωγείς της εκπαίδευσης σε ενεργούς, ελεγχόμενους μηχανισμούς στοχαστικής γένεσης. Επιτρέπει την επιβολή χρονικών, δομικών και σημασιολογικών περιορισμών χωρίς επανεκπαίδευση, ενοποιώντας τις έννοιες της πιθανοκρατικής μάθησης, της αιτιότητας και της πολυμεταβλητής συνέπειας. Με αυτόν τον τρόπο, τα καθοδηγούμενα μοντέλα διάχυσης αποτελούν τη φυσική συνέχεια των conditional diffusion models, επεκτείνοντας τη δυνατότητα ελέγχου και ερμηνείας στη φάση της δειγματοληψίας [23, 2, 18].

2.3.2 Θεμελιώδεις Αρχές

Η καθοδήγηση (guidance) δεν αποτελεί εξωτερικό πρόσθετο μηχανισμό, αλλά προκύπτει απευθείας από τη θεωρία των δεσμευμένων πιθανοτήτων. Στα βασικά diffusion models, η διαδικασία δειγματοληψίας βασίζεται στην οριακή κατανομή $p_t(X_t)$, η οποία περιγράφει τη δυναμική της αντίστροφης SDE, βλ. (16)). Όταν όμως επιθυμούμε τα δείγματα να είναι συμβατά με μια συγκεκριμένη συνθήκη C (π.χ. με ένα γνωστό ιστορικό τμήμα ή με έναν δομικό περιορισμό), ο στόχος μετασχηματίζεται από την $p_t(X_t)$ στη δεσμευμένη $p_t(X_t | C)$. Η μετάβαση αυτή απαιτεί τροποποίηση της αντίστροφης δυναμικής μέσω ενός πρόσθετου όρου, ο οποίος κατευθύνει την εξέλιξη

προς περιοχές του χώρου καταστάσεων όπου η δεσμευμένη πιθανότητα $\log p_t(C | X_t)$ αυξάνεται. Κατά συνέπεια, η καθοδήγηση μπορεί να αντιμετωπιστεί ως η φυσική προέκταση της δειγματοληψίας στο δεσμευμένο πεδίο όπου η ροή εμπλουτίζεται με τον κατάλληλο καθοδηγητικό όρο που υλοποιεί τη μετάβαση από p_t σε $p_t(\cdot | C)$.

Πιθανοθεωρητική Θεμελίωση της Καθοδηγούμενης Διάχυσης

Η πιθανοτική ερμηνεία της καθοδήγησης βασίζεται στην αρχή ότι η στοχαστική διαδικασία της διάχυσης μπορεί να περιγραφεί πλήρως μέσω της κατανομής πιθανότητας που εξελίσσεται με το χρόνο. Στο βασικό πλαίσιο, η εμπρόσθια SDE διαχέει τα δεδομένα $X_0 \sim p_{\text{data}}$ σε σταδιακά πιο θορυβώδεις εκδοχές X_t , ενώ η αντίστροφη SDE ((16)) επιχειρεί να αντιστρέψει αυτή τη διαδικασία, ανακτώντας τη δομή των πραγματικών δεδομένων από καθαρό θόρυβο.

Όταν όμως θέλουμε η γένεση να εξαρτάται από κάποια γνωστή πληροφορία ή συνθήκη C — όπως μια μάσκα παρατήρησης, ένα κλάσμα ιστορικών τιμών ή μια επιθυμητή δομή συσχέτισης — τότε ο στόχος μας αλλάζει. Δεν επιδιώκουμε πλέον την οριακή κατανομή $p_t(X_t)$, αλλά τη δεσμευμένη $p_t(X_t | C)$, δηλαδή τη πιθανότητα των καταστάσεων X_t υπό τον όρο ότι η συνθήκη C ισχύει. Η μετάβαση από την οριακή στην δεσμευμένη κατανομή αποτελεί το θεμέλιο της καθοδήγησης, καθώς επιβάλλει τη ροή της διάχυσης να κατευθύνεται προς τροχιές που συμφωνούν με το C .

Από τις βασικές ταυτότητες των πιθανοτήτων προκύπτει η σχέση μεταξύ των δύο αυτών πυκνοτήτων μέσω της conditional score identity [34]:

$$\nabla_{x_t} \log p_t(X_t | C) = \nabla_{x_t} \log p_t(X_t) + \nabla_{x_t} \log p_t(C | X_t). \quad (37)$$

Η εξίσωση αυτή έχει θεμελιώδη σημασία: δηλώνει ότι ο βαθμός (score) της δεσμευμένης κατανομής, δηλαδή η κατεύθυνση που αυξάνει τη δεσμευμένη πιθανότητα $p_t(X_t | C)$, αποτελεί το άθροισμα δύο όρων του αρχικού βαθμού της οριακής κατανομής $p_t(X_t)$, τον οποίο ήδη έχει μάθει το μοντέλο, και ενός επιπλέον όρου που εξαρτάται από τη συνθήκη C και εκφράζει τη διορθωτική πληροφορία $\nabla_{x_t} \log p_t(C | X_t)$.

Αν αντικαταστήσουμε τη σχέση αυτή στη γνωστή αντίστροφη SDE ((16)), προκύπτει η νέα, καθοδηγούμενη μορφή της δυναμικής:

$$dX_t = \left[f(X_t, t) - g^2(t)(s_\theta(X_t, t) + \lambda \nabla_{x_t} \log p_t(C | X_t)) \right] dt + g(t) d\bar{W}_t, \quad (38)$$

όπου το $s_\theta(X_t, t)$ είναι ο εκτιμητής του score που έχει μάθει το νευρωνικό δίκτυο, και ο παράγοντας $\lambda > 0$ ρυθμίζει την ένταση με την οποία επιβάλλεται ο καθοδηγητικός όρος.

Η εξίσωση (38) φανερώνει ότι η καθοδήγηση δεν αλλάζει το ίδιο το εκπαιδευμένο μοντέλο, αλλά τροποποιεί τον τρόπο με τον οποίο αυτό χρησιμοποιείται κατά τη δειγματοληψία. Ο πρόσθετος βαθμιδωτός όρος $\nabla_{x_t} \log p_t(C | X_t)$ λειτουργεί σαν δύναμη που ωθεί τα δείγματα να κινηθούν προς περιοχές του χώρου καταστάσεων όπου η συνθήκη C είναι πιο πιθανή. Αντίθετα, αν η καθοδήγηση απενεργοποιηθεί ($\lambda = 0$), η διαδικασία επανέρχεται στην κλασική, μη δεσμευμένη διάχυση.

Αυτή η πιθανοτική θεώρηση δίνει μία ενιαία μαθηματική ερμηνεία για όλες τις γνωστές μορφές καθοδήγησης είτε προέρχεται από ταξινομητή (classifier guidance), είτε από συνδυασμό δεσμευμένου και αδέσμευτου score (classifier-free guidance), είτε από ενεργειακούς ή δομικούς περιορισμούς (energy-based guidance). Σε όλες τις περιπτώσεις, ο μηχανισμός είναι ο ίδιος: η εισαγωγή ενός βαθμιδωτού όρου που μετατοπίζει τη ροή της αντίστροφης διάχυσης προς περιοχές υψηλότερης δεσμευμένης πιθανότητας, επιτυγχάνοντας ελεγχόμενη και ερμηνεύσιμη γένεση.

Τροποποίηση του Drift στην Αντίστροφη SDE

Αφού είδαμε ότι η καθοδήγηση μπορεί να προκύψει από τη δεσμευμένη πιθανοτική θεώρηση (§2.3.2), είναι χρήσιμο τώρα να εξετάσουμε πώς αυτή η θεωρητική ιδέα εκδηλώνεται στο επίπεδο της ίδιας της δυναμικής ροής. Η αντίστροφη διαδικασία διάχυσης όπως ορίστηκε στην εξίσωση (16) περιγράφεται από ένα πεδίο, το οποίο καθορίζει προς ποια κατεύθυνση μεταβάλλονται τα δείγματα X_t όταν αντιστρέφουμε το θόρυβο. Το πεδίο αυτό ονομάζεται drift και συμβολίζεται με $b_\theta(X_t, t)$.

Χωρίς καθοδήγηση, ο ονομαστικός drift έχει τη μορφή:

$$b_\theta(X_t, t) := f(X_t, t) - g^2(t) s_\theta(X_t, t), \quad (39)$$

όπου ο πρώτος όρος $f(X_t, t)$ εκφράζει τη δυναμική της διάχυσης, ενώ ο δεύτερος όρος $-g^2(t) s_\theta(X_t, t)$ διορθώνει αυτή τη ροή με βάση το score function που έχει μάθει το δίκτυο. Μαθηματικά, το b_θ είναι εκείνο που μεταφέρει τα δείγματα από καθαρό θόρυβο προς τις περιοχές της πυκνότητας δεδομένων, ακολουθώντας την κατεύθυνση όπου αυξάνεται η $\log p_t(X_t)$.

Η καθοδήγηση τροποποιεί αυτό το πεδίο, προσθέτοντας ένα νέο όρο που αντανακλά τη συνθήκη C . Ουσιαστικά, εισάγουμε μια έλξη προς περιοχές του χώρου καταστάσεων όπου η πιθανότητα $p_t(C | X_t)$ είναι μεγαλύτερη. Η νέα, καθοδηγούμενη μορφή του drift γράφεται:

$$\tilde{b}_\theta(X_t, t; C) = b_\theta(X_t, t) - \lambda g^2(t) \nabla_{x_t} \log p_t(C | X_t), \quad (40)$$

όπου ο συντελεστής λ ελέγχει το πόσο ισχυρή είναι αυτή η έλξη. Για μικρές τιμές λ η διαδικασία παραμένει κοντά στην αρχική διάχυση, ενώ για μεγαλύτερες τιμές, η δυναμική στρέφεται έντονα προς τις περιοχές που ικανοποιούν το C .

Η φυσική ερμηνεία της (40) είναι ότι το καθοδηγούμενο πεδίο $\tilde{b}_\theta$ παραμορφώνει τη ροή της διάχυσης έτσι ώστε οι τροχιές που παράγονται να περνούν από περιοχές του χώρου, σύμφωνα με τη δεσμευμένη πιθανοφάνεια $p_t(C | X_t)$. Με ολοκλήρωση της εξίσωσης από $t = T$ έως $t = 0$, οι τελικές καταστάσεις X_0 που προκύπτουν αντιστοιχούν σε δείγματα τα οποία ικανοποιούν στατιστικά τη συνθήκη C .

Στην πράξη, ο καθοδηγητικός όρος $\nabla_{x_t} \log p_t(C | X_t)$ μπορεί να υλοποιηθεί με διάφορους τρόπους:

- μέσω ενός διακριτού ταξινομητή $p_\phi(C | X_t)$, όπως στα classifier-guided diffusion models [7],
- μέσω της διαφοράς δεσμευμένου και αδέσμευτου score, στα classifier-free methods [13, 23],
- ή μέσω διαφορίσιμης ενέργειας περιορισμού ή γράφου, στην energy/structure-based καθοδήγηση [2].

Παρά τις επιμέρους διαφορές, όλες αυτές οι εκδοχές υπάγονται στο ενιαίο σχήμα της (40): τροποποιούν το drift με βάση μια εξωτερική πληροφορία που ενισχύει συγκεκριμένες στατιστικές ιδιότητες των δειγμάτων.

Η καθοδήγηση μπορεί να διατυπωθεί επίσης στη ντετερμινιστική μορφή της λεγόμενης probability-flow ODE [34], όπου η στοχαστικότητα απαλείφεται και η διάχυση περιγράφεται ως συνεχής ροή στο χώρο καταστάσεων:

$$\frac{dX_t}{dt} = f(X_t, t) - \frac{1}{2} g^2(t) \left[s_\theta(X_t, t) + \lambda \nabla_{x_t} \log p_t(C | X_t) \right]. \quad (41)$$

Η μορφή αυτή αναδεικνύει ότι η καθοδήγηση δεν προσθέτει νέο θόρυβο στη διαδικασία, αλλά *παραμορφώνει* το ντετερμινιστικό drift, οδηγώντας τα δείγματα προς περιοχές μεγαλύτερης πιθανοφάνειας υπό τη συνθήκη C . Με αυτόν τον τρόπο, η καθοδήγηση αποκτά μια καθαρή γεωμετρική ερμηνεία δηλαδή είναι η μετατόπιση της ροής της διάχυσης προς κατευθύνσεις που αυξάνουν τη δεσμευμένη πιθανότητα.

Η τροποποίηση του drift συνιστά την πιο θεμελιώδη μαθηματική περιγραφή της καθοδήγησης. Δεν αλλάζει τη φύση της διάχυσης, αλλά τον τρόπο με τον οποίο εξελίσσεται η ροή στο χώρο καταστάσεων. Με έναν απλό βαθμιδωτό όρο, το μοντέλο μετατρέπεται από μη ελεγχόμενο γενετικό δειγματολήπτη σε ένα στοχαστικό σύστημα που μπορεί να κατευθύνεται προς συγκεκριμένες χρονικές ή δομικές συνθήκες μια προοπτική που θα συνδεθεί άμεσα με τις energy-based και posterior reweighting ερμηνείες στην επόμενη ενότητα.

Στάθμιση της εκ των υστέρων κατανομής και Ενεργειακά Μοντέλα

Η καθοδήγηση μπορεί να ιδωθεί και από μια εναλλακτική, αλλά απολύτως συνεπή, πιθανοτική οπτική: προκύπτει ως *reweighted posterior* επάνω στις τροχιές της διάχυσης. Με άλλα λόγια, αντί να αλλάξουμε το ίδιο το μοντέλο, αλλάζουμε το πώς βαθμολογούνται οι τροχιές του, δίνοντας μεγαλύτερο βάρος σε εκείνες που ικανοποιούν μια συνθήκη C .

Αν $p_\theta(X_{0:T})$ είναι η μη καθοδηγούμενη κατανομή πάνω στις τροχιές (όπως προκύπτει από την αντίστροφη SDE) και $p(C | X_{0:T})$ εκφράζει το πόσο συμβατή είναι κάθε τροχιά με τον περιορισμό C , τότε το δεσμευμένο posterior γράφεται:

$$p_\theta(X_{0:T} | C) \propto p_\theta(X_{0:T}) p(C | X_{0:T}). \quad (42)$$

Η σχέση αυτή δείχνει ότι οι ίδιες τροχιές του μοντέλου μπορούν να ξαναβαθμολογηθούν ανάλογα με τη συμβατότητά τους με το C . Παραγωγίζοντας ως προς X_t , και υποθέτοντας Μαρκοβιακή ανεξαρτησία ώστε $p(C | X_{0:T}) \approx$

$p(C \mid X_t)$, ανακτούμε ακριβώς τον διορθωτικό βαθμιδωτό όρο της (40). Έτσι, η καθοδήγηση ισοδυναμεί με τροποποίηση του posterior: οι πιθανότητες επανασταθμίζονται έτσι ώστε η ροή της διάχυσης να μετακινείται προς περιοχές του χώρου όπου η συνθήκη C είναι πιο πιθανή.

Αν δούμε το ίδιο φαινόμενο στο επίπεδο των οριακών πυκνοτήτων, η επαναβαθμισμένη δεσμευμένη πυκνότητα γράφεται:

$$\tilde{p}_t(X_t \mid C) \propto p_t(X_t) [p_t(C \mid X_t)]^\lambda, \quad (43)$$

όπου ο εκθέτης λ ελέγχει το πόσο ισχυρά επηρεάζεται η ροή από τη συνθήκη. Όταν $\lambda = 0$, επανερχόμαστε στην απλή, μη καθοδηγούμενη διάχυση, ενώ όσο αυξάνεται η λ , οι πιθανότητες συγκεντρώνονται γύρω από καταστάσεις που μεγιστοποιούν το $p_t(C \mid X_t)$. Παραγωγίζοντας τη (43) ως προς X_t , παίρνουμε τον νέο επαναβαθμισμένο βαθμό:

$$\nabla_{x_t} \log \tilde{p}_t(X_t \mid C) = \nabla_{x_t} \log p_t(X_t) + \lambda \nabla_{x_t} \log p_t(C \mid X_t), \quad (44)$$

δηλαδή η καθοδήγηση ισοδυναμεί με την προσθήκη μιας επιπλέον βαθμίδας που οδηγεί τη ροή προς τη δεσμευμένη πυκνότητα. Από την (44) γίνεται αντιληπτός ο τρόπος με τον οποίο εμπλουτίζεται το score του μοντέλου.

Η ίδια ιδέα μπορεί να ερμηνευθεί και μέσα από την οπτική των energy-based models. Αν θεωρήσουμε ότι η στοχαστική διάχυση ελαχιστοποιεί μια ενέργεια $E_\theta(X_t, t) = -\log p_t(X_t)$, τότε η καθοδήγηση αντιστοιχεί στην προσθήκη μιας βοηθητικής ενέργειας που σχετίζεται με τη συνθήκη:

$$E_{\text{guid}}(X_t; C) = -\log p_t(C \mid X_t). \quad (45)$$

Η ολική ενέργεια του συστήματος γίνεται:

$$E_{\text{total}}(X_t, t; C) = E_\theta(X_t, t) + \lambda E_{\text{guid}}(X_t; C), \quad (46)$$

και η αντίστοιχη βαθμιδωτή ροή ακολουθεί τη φυσική κατεύθυνση μείωσης αυτής της ενέργειας:

$$dX_t = -g^2(t) \nabla_{x_t} E_{\text{total}}(X_t, t; C) dt + g(t) dW_t.$$

Έτσι, η καθοδήγηση μπορεί να θεωρηθεί είτε ως *reweighted posterior* που αυξάνει τη δεσμευμένη πιθανότητα, είτε ως *εμπλουτισμένο ενεργειακό τοπίο* όπου η ροή ακολουθεί τη συνδυασμένη ελαχιστοποίηση E_{total} .

Οπτική	Κύρια Εξίσωση	Ερμηνεία
Πιθανοτική	$\tilde{p}_t(X_t \mid C) \propto p_t(X_t) [p_t(C \mid X_t)]^\lambda$	Δεσμευμένη πυκνότητα
Τροποποίηση Drift	$\tilde{b}_\theta = b_\theta - \lambda g^2 \nabla_{x_t} \log p_t(C \mid X_t)$	Καθοδηγούμενος ρυθμιστής
Energy-Based Posterior Rew.	$E_{\text{total}} = E_\theta + \lambda E_{\text{guid}}$ $\nabla \log \tilde{p}_t = \nabla \log p_t + \lambda \nabla \log p_t(C \mid X_t)$	Αυξημένη ενέργεια Επαναβαθμισμένος βαθμός
Πρακτική Θέαση	$s_\theta^{\text{guided}} = s_\theta + \lambda \nabla_{x_t} \log p_t(C \mid X_t)$	Διόρθωση score

Πίνακας 5: Ισοδύναμες οπτικές της καθοδήγησης σε μοντέλα διάχυσης [34, 2, 23].

Οι τρεις οπτικές **πιθανοτική**, **drift-based**, και **energy-based** οδηγούν στο συμπέρασμα ότι η καθοδήγηση εισάγει ένα ελεγχόμενο, ρυθμιζόμενο με λ , βαθμιδωτό σήμα που μετατοπίζει τη ροή της διάχυσης προς τροχιές συμβατές με το C . Αυτό το σήμα δρα σαν εσωτερικός οδηγός που συνδυάζει τη μάθηση του μοντέλου με τη γνώση του πεδίου, προσφέροντας έναν μηχανισμό *ελέγχου χωρίς επανεκπαίδευση* και ταυτόχρονα υψηλή *ερμηνευσιμότητα*.

2.3.3 Κατηγορίες Καθοδήγησης

Η καθοδήγηση στα μοντέλα διάχυσης περιλαμβάνει μια οικογένεια τεχνικών που τροποποιούν την αντίστροφη διαδικασία διάχυσης ώστε να ευνοούνται δείγματα συμβατά με βοηθητική πληροφορία ή περιορισμούς. Αν και οι πιθανοτικές και energy-based διατυπώσεις παρέχουν ενοποιημένη θεμελίωση [2, 23], οι πρακτικές υλοποιήσεις διαφέρουν ανάλογα με το πώς εκτιμάται και εφαρμόζεται το διάνυσμα βαθμίδας $\nabla_{x_t} \log p_t(C \mid X_t)$. Στην ενότητα αυτή παρουσιάζεται ταξινομία βασικών μηχανισμών καθοδήγησης, καθένας με ξεχωριστή πηγή πληροφορίας και διαφορετικό συμβιβασμό μεταξύ ελέγχου, κόστους εκπαίδευσης και ποικιλίας δειγμάτων.

Καθοδήγηση με Ταξινομητή

Έννοια. Εισαγόμενη από τους Dhariwal & Nichol (2021), η καθοδήγηση με ταξινομητή χρησιμοποιεί ξεχωριστά εκπαιδευμένο, διαφορισίμο ταξινομητή $p_\phi(C | x_t)$ για να κατευθύνει τη δειγματοληψία [7]. Ο ταξινομητής παρέχει εκτίμηση του δεσμευμένου βαθμού:

$$\nabla_{x_t} \log p_t(C | x_t) = \nabla_{x_t} \log p_\phi(C | x_t). \quad (47)$$

Η βαθμίδα αυτή προστίθεται στο drift της αντίστροφης SDE:

$$dX_t = \left[f(X_t, t) - g^2(t)(s_\theta(X_t, t) + \lambda \nabla_{x_t} \log p_\phi(C | X_t)) \right] dt + g(t) d\bar{W}_t. \quad (48)$$

Ο ταξινομητής δρα ως δυναμικό που διαμορφώνει το πιθανοτικό τοπίο προς περιοχές με υψηλό $p_\phi(C | x_t)$, ενισχύοντας τις καταστάσεις που συμφωνούν με την επιθυμητή κατηγορία ή συνθήκη C . Στις χρονοσειρές, το C μπορεί να αντιπροσωπεύει καθεστώς, καταστάσεις ανωμαλίας ή χαρακτηριστικά πρότυπα κυματομορφής. Η μέθοδος αυτή προσφέρει υψηλή ελεγχσιμότητα και ερμηνευσιμότητα καθώς ο ταξινομητής μπορεί να εκπαιδευτεί ανεξάρτητα σε ετερογενή βοηθητικά δεδομένα. Ωστόσο, απαιτεί επισημασμένο σύνολο για το C , το οποίο συνεπάγεται πρόσθετο κόστος εκπαίδευσης και ενδέχεται να οδηγήσει σε ασυμφωνία μεταξύ του ταξινομητή και του μοντέλου διάχυσης, καθώς και σε ευαισθησία σε θορυβώδεις ή ασταθείς βαθμίδες. Ενδεικτικές εφαρμογές περιλαμβάνουν καθοδήγηση προς φυσιολογικές καταστάσεις σε βιοϊατρικά σήματα, προς καθεστώτα μεταβλητότητας σε οικονομικές χρονοσειρές, ή προς κατηγοριοποιημένες συνθήκες σε δεδομένα κυκλοφορίας και ενέργειας [7].

Καθοδήγηση Χωρίς Ταξινομητή

Η classifier-free guidance (Ho & Salimans, 2022) προτάθηκε για να αποφευχθεί η εξάρτηση από εξωτερικό ταξινομητή, ο οποίος συχνά εισάγει θόρυβο βαθμίδας και απαιτεί πρόσθετη εκπαίδευση. Η ιδέα είναι να μάθουμε ένα ενιαίο δίκτυο που να μπορεί να λειτουργεί τόσο υπό συνθήκη όσο και χωρίς συνθήκη, επιτρέποντας τη σύνθεση των δύο εκτιμήσεων κατά τη δειγματοληψία.

Μαθαίνονται δύο συναρτήσεις score, $s_\theta(x_t, t | C)$ και $s_\theta(x_t, t | \emptyset)$, και κατά τη δειγματοληψία σχηματίζεται ο καθοδηγούμενος βαθμός:

$$s_\theta^{\text{guided}}(x_t, t | C) = (1 + \lambda) s_\theta(x_t, t | C) - \lambda s_\theta(x_t, t | \emptyset). \quad (49)$$

Η σχέση (49) είναι μια πρακτική προσεγγιστική υλοποίηση της γενικής μορφής καθοδήγησης

$$\nabla_{x_t} \log p(x_t | g) = \nabla_{x_t} \log p(x_t) + \lambda \nabla_{x_t} \log p(g | x_t),$$

όπου ο δεύτερος όρος προσεγγίζεται μέσω της διαφοράς μεταξύ των δύο scores. Έτσι επιτυγχάνεται επίδραση όμοια με την προσθήκη κλιμακωμένης βαθμίδας, χωρίς να χρειάζεται ρητός ταξινομητής.

Η καθοδήγηση χωρίς ταξινομητή αναβαθμίζει τη δεσμευμένη εκτίμηση έναντι της αδέσμευτης, ενισχύοντας την πιστότητα της παραγόμενης κατανομής ως προς την επιθυμητή συνθήκη C . Η μέθοδος απλοποιεί την εκπαίδευση, μειώνει τον αριθμό παραμέτρων και παρουσιάζει ανθεκτικότητα σε θόρυβο βαθμίδας. Επιπλέον, ταιριάζει φυσικά σε δεσμευμένα (conditional) μοντέλα χρονοσειρών, όπου η συνθήκη C ενσωματώνεται απευθείας στα δεδομένα εισόδου ή στις μάσκες παρατήρησης [13, 35].

Εξίσωση στη SDE. Στο συνεχές πλαίσιο, η τροποποιημένη SDE γράφεται:

$$dX_t = [f(X_t, t) - g^2(t) s_\theta^{\text{guided}}(X_t, t | C)] dt + g(t) d\bar{W}_t. \quad (50)$$

Η παράμετρος λ ρυθμίζει την ισορροπία μεταξύ πιστότητας (υψηλή λ) και ποικιλίας (χαμηλή λ), καθορίζοντας έτσι τον βαθμό επιρροής της καθοδήγησης στο παραγόμενο δείγμα. Στην πράξη, χρησιμοποιούνται *προγράμματα καθοδήγησης* $\lambda(t)$ που αυξάνουν σταδιακά τη δύναμη καθοδήγησης στα τελευταία βήματα της αντίστροφης διάχυσης, όταν η δομή του σήματος έχει πλέον σταθεροποιηθεί. Η πρακτική αυτή βελτιώνει τόσο τη σταθερότητα όσο και την ποικιλία των παραγόμενων δειγμάτων. Ενδεικτικές εφαρμογές περιλαμβάνουν αποκατάσταση υπό μάσκα και δεσμευμένη πρόβλεψη χωρίς ρητούς ταξινομητές, όπως παρουσιάζεται στο [35].

Αυτο-Καθοδήγηση

Η *αυτο-καθοδήγηση* (self-guidance / self-conditioning) αποτελεί μια εσωτερική μορφή καθοδήγησης, κατά την οποία το ίδιο το μοντέλο χρησιμοποιεί τις προηγούμενες προβλέψεις του ως πρόσθετες πληροφορίες εισόδου για τα επόμενα βήματα της αντίστροφης διάχυσης. Δεν εισάγει εξωτερικό σήμα g , αλλά αντλεί πληροφορία από τις ίδιες τις εκτιμήσεις του, λειτουργώντας ως *ενδογενής ανάδραση* (feedback control) που σταθεροποιεί τη διαδικασία.

Αν $\hat{x}^0(t+1)$ είναι η εκτίμηση της καθαρής ανακατασκευής στο βήμα $t+1$, τότε στο επόμενο βήμα η πρόβλεψη του θορύβου εξαρτάται ρητά και από αυτή:

$$\epsilon_\theta(t) = \epsilon_\theta(x_t, \hat{x}^0(t+1), t). \quad (51)$$

Εναλλακτικά, στο επίπεδο του score function, η διαδικασία μπορεί να θεωρηθεί ως εκτίμηση υπό εσωτερική συνθήκη:

$$s_\theta^{\text{self}}(x_t, t) = \mathbb{E}[\nabla_{x_t} \log p_t(x_t | \hat{x}^0(t+1))], \quad (52)$$

όπου το $\hat{x}^0(t+1)$ δρα ως *εσωτερική συνθήκη* που μεταφέρει πληροφορία μεταξύ διαδοχικών χρονικών βημάτων.

Η αντίστοιχη αντίστροφη ενημέρωση γράφεται:

$$x_{t-1} = F_t(x_t) + \lambda_{\text{self}}(t) \nabla_{x_t} \log p_t(x_t | \hat{x}^0(t+1)) + \sigma_t z, \quad z \sim \mathcal{N}(0, I), \quad (53)$$

όπου η παράμετρος $\lambda_{\text{self}}(t)$ ελέγχει τη δύναμη της αυτο-καθοδήγησης. Η ενημέρωση αυτή διασφαλίζει χρονική συνέπεια και μειώνει τις διακυμάνσεις μεταξύ διαδοχικών εκτιμήσεων.

Η αυτο-καθοδήγηση επιβάλλει *εσωτερική συνέπεια* στις προβλέψεις, εξαναγκάζοντας τη ροή διάχυσης να εξελίσσεται ομαλά. Βελτιώνει την ομαλότητα και τη σταθερότητα της αποθορυβοποίησης, ειδικά σε δεδομένα με ισχυρή χρονική συσχέτιση (όπως χρονοσειρές ή σήματα ήχου) [23]. Ωστόσο, υπερβολική εξάρτηση από προηγούμενες εκτιμήσεις μπορεί να προκαλέσει *υπερ-εξομάλυνση* και απώλεια ποικιλίας φαινόμενο που αντιμετωπίζεται με ρυθμιζόμενο βάρος $\lambda_{\text{self}}(t)$ ή με τυχαία απόρριψη (dropout) της συνθήκης $\hat{x}^0$ κατά την εκπαίδευση. Η αυτο-καθοδήγηση χρησιμοποιείται σε μοντέλα όπως CSDI, DiffWave, και TimeGrad, όπου εξασφαλίζει σταθερή αναδόμηση κατά την επαναληπτική αποθορυβοποίηση, χωρίς να απαιτεί εξωτερικό οδηγό ή ταξινομητή.

Plug-and-Play Καθοδήγηση

Η plug-and-play καθοδήγηση επεκτείνει τη λογική του ταξινομητή επιτρέποντας την αξιοποίηση οποιουδήποτε διαφορίσιμου, προεκπαιδευμένου δικτύου ως πηγής καθοδήγησης. Η βασική ιδέα είναι ότι, αντί να επανεκπαιδεύουμε το μοντέλο διάχυσης για κάθε νέο στόχο, μπορούμε να συνδέουμε (plug in) ένα ήδη προεκπαιδευμένο και παγωμένο δίκτυο F_ϕ , το οποίο δεν ενημερώνεται αλλά χρησιμοποιείται για να υπολογίζει βαθμίδες καθοδήγησης κατά τη δειγματοληψία. Συγκεκριμένα, από την απώλεια $L(F_\phi(x_t), C)$ ως προς την επιθυμητή συνθήκη C , εξάγεται η παράγωγος

$$\nabla_{x_t} L(F_\phi(x_t), C),$$

η οποία δείχνει προς την κατεύθυνση που πρέπει να μεταβληθεί το δείγμα x_t ώστε να πλησιάσει τον στόχο C . Αυτή η βαθμίδα προστίθεται ως όρος καθοδήγησης στο drift της αντίστροφης διαδικασίας διάχυσης, επιτρέποντας στο μοντέλο να προσαρμόζεται σε νέες ιδιότητες ή περιορισμούς χωρίς επιπλέον εκπαίδευση.

Αν $F_\phi(X_t)$ είναι το προεκπαιδευμένο μοντέλο και $L(F_\phi(X_t), C)$ μια διαφορίσιμη απώλεια ως προς την επιθυμητή συνθήκη C , τότε το καθοδηγούμενο αντίστροφο SDE γράφεται [11]:

$$dX_t = \left[f(X_t, t) - g^2(t) \left(s_\theta(X_t, t) + \lambda \nabla_{x_t} L(F_\phi(X_t), C) \right) \right] dt + g(t) d\bar{W}_t. \quad (54)$$

Ο πρόσθετος όρος βαθμίδας $\nabla_{x_t} L(F_\phi(X_t), C)$ εκφράζει την επίδραση του παγωμένου δικτύου ως εξωτερικής ενέργειας:

$$\mathcal{E}_{\text{pnp}}(x_t) = L(F_\phi(x_t), C), \quad \Gamma_{\text{pnp}}(x_t) = -\nabla_{x_t} \mathcal{E}_{\text{pnp}}(x_t),$$

ώστε η καθοδήγηση να ενοποιείται θεωρητικά με την ενεργειακή μορφή που έχει αναλυθεί.

Στη διακριτή εκδοχή, το αντίστροφο βήμα διάχυσης διαμορφώνεται ως:

$$x_{t-1} = F_t(x_t) + \lambda(t) \Gamma_{\text{np}}(x_t) + \sigma_t z, \quad z \sim \mathcal{N}(0, I), \quad (55)$$

όπου $\Gamma_{\text{np}}(x_t)$ παρέχει στοχευμένη διόρθωση βάσει των βαθμίδων του εξωτερικού δικτύου.

Η μέθοδος plug-and-play επιτρέπει την ενσωμάτωση εξειδικευμένης γνώσης χωρίς να απαιτείται επανεκπαίδευση του μοντέλου διάχυσης, παρέχοντας έναν ευέλικτο μηχανισμό καθοδήγησης που ενισχύει την εκφραστικότητα και τη μεταφερσιμότητα του συστήματος. Μπορεί να αξιοποιηθεί για φυσική καθοδήγηση μέσω μοντέλων φυσικών περιορισμών ή εξισώσεων ισορροπίας, για πολυτροπική καθοδήγηση με χρήση δικτύων που χαρτογραφούν χρονοσειρές σε κείμενο, εικόνα ή ήχο, καθώς και για τομεακή προσαρμογή μέσω προεκπαιδευμένων μοντέλων πρόγνωσης, ανίχνευσης ανωμαλιών ή ταξινόμησης, τα οποία κατευθύνουν τη δειγματοληψία προς έγκυρες χρονικές δομές. Παρά τα πλεονεκτήματά της, η μέθοδος απαιτεί προσεκτική κανονικοποίηση των βαθμίδων του F_ϕ ώστε να αποφευχθεί αριθμητική αστάθεια, καθώς και μέριμνα για την υπολογιστική αποδοτικότητα, ειδικά όταν το F_ϕ είναι μεγάλο ή πολύπλοκο.

Διόρθωση Score ή Περιορισμοί

Η καθοδήγηση με περιορισμούς επιτρέπει την ενσωμάτωση προτέρων γνώσεων ή φυσικών νόμων στη διαδικασία διάχυσης, χωρίς να απαιτείται επανεκπαίδευση. Σκοπός είναι να διασφαλιστεί ότι τα παραγόμενα δείγματα υπακούν σε γνωστές ιδιότητες του συστήματος όπως ομαλότητα, ενεργειακή διατήρηση ή συσχετισμοί μεταξύ μεταβλητών που τα καθαρά δεδομένα ενδέχεται να μην εκφράζουν επαρκώς. Η ιδέα είναι να εισαχθεί ένας διαφορισμός όρος ποινής $R(X_t)$, ο οποίος επιβραβεύει δυναμικές που πλησιάζουν γνωστούς περιορισμούς.

Η αντίστοιχη καθοδηγούμενη SDE παίρνει τη μορφή:

$$dX_t = \left[f(X_t, t) - g^2(t)(s_\theta(X_t, t) + \lambda \nabla_{x_t} R(X_t)) \right] dt + g(t) d\bar{W}_t. \quad (56)$$

Ο πρόσθετος όρος $\nabla_{x_t} R(X_t)$ αντιστοιχεί σε *βαθμίδα ποινής* ή *ενεργειακό περιορισμό* που ωθεί τη διαδικασία προς δομές που ικανοποιούν τον περιορισμό. Η διατύπωση αυτή ισοδυναμεί με την προσθήκη ενός όρου ενέργειας

$$\mathcal{E}_{\text{total}}(x_t) = \mathcal{E}_\theta(x_t) + \lambda R(x_t),$$

οπότε η καθοδήγηση μπορεί να θεωρηθεί ως ενεργειακή διόρθωση της αρχικής πυκνότητας διάχυσης.

Στη διακριτή εκδοχή, το καθοδηγούμενο αντίστροφο βήμα γράφεται:

$$x_{t-1} = F_t(x_t) + \lambda(t) \Gamma_R(x_t) + \sigma_t z, \quad \Gamma_R(x_t) = -\nabla_{x_t} R(x_t), \quad z \sim \mathcal{N}(0, I). \quad (57)$$

Η συνάρτηση $R(x_t)$ δρα ως *πεδίο περιορισμού* που ωθεί τη διαδικασία αποθρομβοποίησης προς ενεργειακά έγκυρες περιοχές.

Παραδείγματα Τυπικών Περιορισμών. Στα μοντέλα διάχυσης χρονοσειρών, τα $R(x_t)$ συχνά λαμβάνουν τη μορφή:

- **Ποινές Συσχέτισης:** $R_{\text{corr}}(x_t) = \|C(x_t) - C_{\text{target}}\|_2^2$, ώστε οι παραγόμενες συσχετίσεις να πλησιάζουν γνωστά ή επιθυμητά μοτίβα.
- **Ποινές Ομαλότητας:** $R_{\text{smooth}}(x_t) = \|\nabla_t x_t\|_2^2$, προάγοντας συνεχή και μη θορυβώδη σήματα.
- **Ποινές Διατήρησης:** $R_{\text{phys}}(x_t) = \|\mathcal{F}(x_t)\|_2^2$, όπου $\mathcal{F}(x_t)$ εκφράζει παραβίαση φυσικού νόμου (π.χ. διατήρηση ενέργειας/μάζας).
- **Ποινές Δομής Γράφου:** $R_{\text{graph}}(x_t) = \|Lx_t\|_2^2$, με L τον graph Laplacian, ώστε να ενισχύεται η τοπική συσχέτιση και πολυάλμα διάχυση.

Η καθοδήγηση μέσω περιορισμών επιτρέπει στο μοντέλο διάχυσης να υπακούει σε γνωστές φυσικές ή δομικές αρχές χωρίς την ανάγκη πρόσθετων δεδομένων ή ετικετών [2, 23]. Η ισορροπία μεταξύ πιστότητας και ποικιλίας ελέγχεται από το βάρος λ : μεγαλύτερες τιμές οδηγούν σε ακριβέστερη συμμόρφωση προς τους περιορισμούς αλλά μειωμένη στοχαστικότητα των δειγμάτων. Για λόγους αριθμητικής σταθερότητας, οι βαθμίδες $\nabla_{x_t} R$ κανονικοποιούνται συνήθως ως

$$\Gamma_R^{\text{norm}}(x_t) = \frac{\Gamma_R(x_t)}{\|\Gamma_R(x_t)\|_2 + \epsilon} \|\epsilon_\theta(x_t, t)\|_2,$$

ώστε να διατηρείται η σχετική κλίμακα με τον αρχικό score και να αποφεύγονται εκρήξεις μεγέθους. Η προσέγγιση αυτή προσφέρει υψηλό βαθμό ελέγχου και ερμηνευσιμότητας, ιδανική για συστήματα που υπακούουν σε φυσικούς νόμους ή γραφικές δομές. Ωστόσο, η αποτελεσματικότητά της εξαρτάται από τη διαφορισμότητα και την ορθή κλιμάκωση των ποινών, καθώς και από τη σωστή επιλογή της παραμέτρου λ , ώστε να μην περιορίζεται υπερβολικά η ποικιλία των παραγόμενων δειγμάτων.

Τύπος	Πηγή Βαθμίδας	Extra Training.	Ισχύς Ελέγχου	Σύνηθη Χρήση
Ταξινομητής	$\nabla_{x_t} \log p_\phi(C \mid x_t)$	Ναι	Υψηλή	Σηματολογικός/καθεστώς έλεγχος
Χωρίς ταξινομητή	Παρεμβολή δεσμ./αδέσμ. scores	Όχι	Μεσαία–Υψηλή	Δεσμευμένη γένεση, imputation
Αυτο-καθοδήγηση	Προβλέψεις του ίδιου μοντέλου	Όχι	Μεσαία	Ομαλότητα, σταθερότητα
Plug-and-Play	$\nabla_{x_t} L(F_\phi(X_t), C)$	Όχι (προεκπ.)	Ευέλικτη	Φυσική/στόχοι εργασίας
Περιορισμοί	$\nabla_{x_t} R(X_t)$ (αναλυτικό)	Όχι	Ρυθμιζόμενη με λ	Δομή, φυσική, συσχέτιση

Πίνακας 6: Μηχανισμοί καθοδήγησης: πηγές, συμβιβασμοί και συνήθεις χρήσεις [7, 13, 11, 2, 23, 35].

Σύνοψη. Όλοι οι μηχανισμοί καθοδήγησης μπορούν να ιδωθούν ως διαφορετικοί εκτιμητές του βαθμού $\nabla_{x_t} \log p_t(C \mid X_t)$, δηλαδή ως εναλλακτικοί τρόποι υπολογισμού της κατεύθυνσης που ενισχύει την πιθανότητα του επιθυμητού συμβάντος C . Ο ταξινομητής παρέχει ρητό βαθμό πιθανοφάνειας μέσω ενός εποπτευόμενου μοντέλου [7], ενώ η καθοδήγηση χωρίς ταξινομητή εκτιμά έμμεσα τη βαθμίδα μέσω παρεμβολής μεταξύ δεσμευμένων και αδέσμευτων scores [13]. Η αυτο-καθοδήγηση βασίζεται στη συνοχή με παρελθούσες προβλέψεις του ίδιου μοντέλου [23], ενώ η plug-and-play καθοδήγηση αντλεί τη βαθμίδα από εξωτερικούς διαφορίσιμους πρότερους ή βοηθητικά μοντέλα [11]. Τέλος, οι καθοδηγήσεις μέσω περιορισμών ή φυσικών αρχών αξιοποιούν αναλυτικές βαθμίδες που προέρχονται από ποινές ή ενεργειακές συναρτήσεις [2]. Το φάσμα αυτό εκτείνεται από καθαρά δεδομένο-κεντρικές μεθόδους έως φυσικά και δομικά ενημερωμένες προσεγγίσεις, θεμελιώνοντας προηγμένες μορφές καθοδήγησης βασισμένες σε γράφους και συσχετίσεις για δεδομένα χρονοσειρών.

2.3.4 Μορφές Δεδομένων για Καθοδήγηση

Η καθοδήγηση στη διάχυση χρονοσειρών δεν περιορίζεται σε αριθμητικές συνθήκες ή ετικέτες. Κάθε πληροφορία που ορίζει διαφορίσιμο ή συμβολικό περιορισμό στην παραγόμενη ακολουθία μπορεί να λειτουργήσει ως σήμα καθοδήγησης. Οι τρόποι δεδομένων διαφέρουν ως προς την αναπαράσταση, τη μαθηματική διατύπωση και το μονοπάτι ενσωμάτωσης στο πλαίσιο της διάχυσης. Στην ενότητα αυτή κατηγοριοποιούμε τους κύριους τρόπους καθοδήγησης που είναι σχετικοί με γενετική μοντελοποίηση στο χρόνο [35, 5, 2].

Καθοδήγηση βάσει Γράφου — Πίνακες Συσχέτισης, Πρότεροι Γειτνίασης, Ζευγαρωτή Σύζευξη

Πολλές πολυμεταβλητές χρονοσειρές εμφανίζουν δομημένες αλληλεξαρτήσεις μεταξύ μεταβλητών (αισθητήρες, όργανα, πράκτορες). Ένας γράφος $G = (V, E, W)$ κωδικοποιεί αυτές τις εξαρτήσεις, με γειτνίαση W_{ij} που

αποτυπώνει συνδεσιμότητα ή ισχύ συσχέτισης. Η καθοδήγηση βάσει γράφου εγγεί αυτή τη σχεσιακή δομή στη διάχυση είτε ως σταθερό πρότερο είτε ως χρονικά μεταβαλλόμενο περιορισμό [18, 5].

Έστω $C \in \mathbb{R}^{K \times K}$ πίνακας συσχέτισης ή γειτνίασης. Κατά τη δειγματοληψία, προστίθεται βαθμίδα που τιμωρεί απόκλιση από το C :

$$\nabla_{x_t} \log p_t(C | X_t) \propto -\frac{\partial}{\partial X_t} \|\hat{C}(X_t) - C\|_2^2, \quad (58)$$

όπου $\hat{C}(X_t)$ είναι η στιγμιαία συσχέτιση των παραγόμενων χαρακτηριστικών. Ισοδύναμα, η ανάστροφη SDE γίνεται

$$dX_t = \left[f(X_t, t) - g^2(t)(s_\theta(X_t, t) + \lambda \nabla_{x_t} R_C(X_t)) \right] dt + g(t) d\bar{W}_t, \quad (59)$$

που ερμηνεύεται ως *energy-based* διόρθωση με R_C να δρα ως πρόσθετη ενέργεια δομής [2].

Η προσέγγιση αυτή επιβάλλει ρεαλιστικές διακαναλικές εξαρτήσεις και ευθυγραμμίζει τη δυναμική διάχυσης με την τοπολογία του δικτύου ή τη φυσική δομή του συστήματος, υποστηρίζοντας φυσικά σχήματα πολλαπλών αλμάτων και ζευγαρωτής σύζευξης [18]. Εφαρμόζεται σε προβλήματα φόρτου δικτύου ηλεκτρικής ενέργειας, κυκλοφορίας, κλιματικών δεδομένων και δικτύων αισθητήρων, όπου οι χωρικές ή λειτουργικές σχέσεις μεταξύ μεταβλητών παίζουν κρίσιμο ρόλο. Τα *pairs-only* και τα *graph-guided multi-hop* πειράματά σας αποτελούν άμεσες και χαρακτηριστικές υλοποιήσεις αυτής της κατηγορίας καθοδήγησης.

Κειμενική / Συμβολική Καθοδήγηση — Περιγραφές Καθεστώτων ή Γεγονότων

Έννοια. Σε πολυτροπικά σενάρια, κειμενικοί ή συμβολικοί περιγραφείς (π.χ. «ημέρα υψηλής ζήτησης», «βλάβη εξοπλισμού», «καταιγίδα») παρέχουν ποιοτικούς περιορισμούς στη χρονοσειρά. Ένας κωδικοποιητής γλώσσας E_{text} χαρτογραφεί το κείμενο σε λανθάνον διάνυσμα z_C , το οποίο δεσμεύει το score της διάχυσης [22].

Ο καθοδηγούμενος score γράφεται

$$s_\theta^{\text{guided}}(x_t, t, z_C) = s_\theta(x_t, t) + w_t \nabla_{x_t} \log p_t(z_C | x_t), \quad (60)$$

όπου το $p_t(z_C | x_t)$ προσεγγίζεται από cross-encoder κειμένου-χρονοσειράς ή αντιθετικό (contrastive) μοντέλο [22].

Με αυτόν τον τρόπο παρέχεται σημασιολογικός και γεγονотоκεντρικός έλεγχος ο οποίος απαιτεί ευθυγραμμισμένους γλωσσικούς κωδικοποιητές, χρήσιμος για προσομοίωση καθεστώτων σε οικονομικά/κλίμα, σχολιασμένα βιοϊατρικά σήματα κ.ά. [22].

Ηχητική / Φασματική Καθοδήγηση

Πολλές χρονοσειρές έχουν χαρακτηριστικές φασματικές υπογραφές. Η καθοδήγηση μπορεί να δράσει στο πεδίο συχνοτήτων επιβάλλοντας φασματική ενέργεια ή ρυθμική δομή [2].

Ορίζουμε φασματική απώλεια:

$$R_{\text{spec}}(X_t) = \|F(X_t) - F(X_{\text{target}})\|_2^2, \quad (61)$$

όπου F είναι μετασχηματισμός Fourier ή κυματίων. Η βαθμίδα καθοδήγησης είναι

$$\nabla_{x_t} R_{\text{spec}}(X_t) = 2 F^{-1}(F(X_t) - F(X_{\text{target}})), \quad (62)$$

και ενσωματώνεται ως όρος διόρθωσης στο drift [2].

Με αυτόν τον τρόπο επιβάλλεται ρυθμικός και ταλαντωτικός έλεγχος, χρήσιμος για περιοδικά και ημι-περιοδικά ή μουσικά σήματα, μηχανικές δονήσεις, φυσιολογικούς ρυθμούς (ECG, EEG).

Εικόνα / Χωρική Καθοδήγηση

Έννοια. Για χωροχρονικά δεδομένα (δορυφορικά, ραντάρ, ιατρική απεικόνιση), κάθε χρονικό βήμα είναι χωρικός χάρτης. Η καθοδήγηση εικόνας εισάγει 2-D/3-D χωρικούς προτέρους στη χρονική διάχυση [5].

Έστω $X_t \in \mathbb{R}^{H \times W \times T}$. Ένας χωρικός κωδικοποιητής δίνει $z_s = \Phi(X_t)$ και επιβάλλουμε χωρική συνέπεια:

$$R_{\text{spatial}}(X_t) = \|\nabla_{xy} X_t - \nabla_{xy} X_{\text{target}}\|_2^2, \quad (63)$$

της οποίας η βαθμίδα τιμωρεί μη ρεαλιστικές ασυνέχειες και επιβάλλει λείες χωρικές δομές [5].

Πιθανές εφαρμογές είναι η γένεση ακολουθιών ραντάρ καιρού, χωροχρονική ρύπανση/κλίμα, ιατρικές ακολουθίες (fMRI, υπέρηχου).

Πινάκες — Εξωγενείς Συνδιακυμάνσεις και Μεταδεδομένα

Πολλά προβλήματα χρονοσειρών εξαρτώνται από εξωγενείς μεταβλητές ή μεταδεδομένα όπως ημερολογιακές πληροφορίες, κατηγορίες αισθητήρων, γεωγραφικά ή οικονομικά χαρακτηριστικά. Η απλή διάχυση σε x_t αγνοεί συχνά αυτές τις πηγές πληροφορίας, οδηγώντας σε απώλεια συμφραζομένων και μειωμένη γενίκευση. Η *καθοδήγηση μέσω πινάκων* (tabular or context guidance) αντιμετωπίζει το ζήτημα εισάγοντας εξωτερικές συνδιακυμάνσεις $u_t \in \mathbb{R}^d$ που τροποποιούν τη δυναμική του μοντέλου διάχυσης.

Η πληροφορία πίνακα μετασχηματίζεται μέσω ενσωμάτωσης $\psi(u_t)$ και επιδρά πολλαπλασιαστικά ή προσθετικά στις εσωτερικές καταστάσεις του μοντέλου μέσω Feature-wise Linear Modulation (FiLM) [35]:

$$h_t = \text{FiLM}(h_t, \psi(u_t)) = \gamma(u_t) \odot h_t + \beta(u_t), \quad \psi(u_t) = \text{MLP}(u_t), \quad (64)$$

όπου $\gamma(u_t)$ και $\beta(u_t)$ αποτελούν παραμέτρους επανακλιμάκωσης και μετατόπισης που προκύπτουν από ένα μικρό δίκτυο MLP. Η ενσωμάτωση αυτή δρα ως soft καθοδήγηση προσαρμόζοντας τη ροή διάχυσης στις εξωτερικές συνθήκες χωρίς ρητό περιορισμό.

Ισοδύναμα, η καθοδήγηση μπορεί να θεωρηθεί ως προσθετική διόρθωση στο score:

$$s_\theta(x_t, t \mid u_t) = s_\theta(x_t, t) + \Gamma_u(x_t, t), \quad \Gamma_u(x_t, t) = \nabla_{x_t} \log p_\theta(u_t \mid x_t), \quad (65)$$

όπου ο όρος Γ_u εκφράζει την επίδραση των συμφραζομένων πάνω στο δυναμικό της διάχυσης.

Η καθοδήγηση μέσω πινάκων δεν επιβάλλει αυστηρούς περιορισμούς, αλλά *επαναζυγίζει* τις εσωτερικές αναπαραστάσεις του μοντέλου ανάλογα με εξωτερικά συμφραζόμενα, όπως ημερομηνία, εποχή, τύπο αισθητήρα ή άλλες συνθήκες λειτουργίας. Στην πράξη, μπορεί να εφαρμοστεί είτε μέσω ενσωμάτωσης στο δίκτυο, με στρώματα τύπου FiLM ή adaptive normalization σε κάθε επίπεδο του U-Net, είτε μέσω συνένωσης εισόδου, προσθέτοντας τα ενσωματώματα u_t στα χρονικά embeddings ή απευθείας στις παρατηρήσεις (x_t, t, u_t) . Και στις δύο περιπτώσεις, η καθοδήγηση λειτουργεί με soft τρόπο, προσανατολίζοντας στατιστικά το μοντέλο προς ρεαλιστικά σενάρια. Ενδεικτικές εφαρμογές περιλαμβάνουν πρόγνωση ζήτησης με ημερολογιακές και μετεωρολογικές μεταβλητές που βελτιώνουν τη διακύμανση ενέργειας ή κατανάλωσης [35], βιομηχανική τηλεμετρία όπου τα μεταδεδομένα μηχανών ή αισθητήρων παρέχουν context για ανωμαλίες και διακοπές λειτουργίας, καθώς και οικονομικά και μεταφορικά δεδομένα, όπου εξωγενείς δείκτες ή κυκλοφοριακοί παράγοντες καθοδηγούν τη διάχυση προς εύλογες μακροοικονομικές ή εποχικές κατανομές [5].

Φυσικοί Νόμοι

Τα μοντέλα διάχυσης που μαθαίνουν αποκλειστικά από δεδομένα συχνά παράγουν χρονικές τροχιές που παραβιάζουν γνωστούς φυσικούς νόμους όπως τη διατήρηση ενέργειας, μάζας ή ορμής. Η *καθοδήγηση βάσει φυσικής* (physics-informed guidance) στοχεύει να επαναφέρει τη φυσική συνέπεια, επιβάλλοντας διαφορισμούς περιορισμούς που προέρχονται από γνωστές δυναμικές ή εξισώσεις εξέλιξης [30, 2]. Αντί να βασίζεται αποκλειστικά σε στατιστική εκμάθηση, ενσωματώνει ρητά τους μηχανισμούς του συστήματος ως ενεργειακούς όρους ή απώλειες ποινής.

Αν οι πραγματικές δυναμικές του συστήματος περιγράφονται από διαφορική εξίσωση

$$\dot{x} = F(x, t),$$

ορίζουμε έναν διαφορισμό όρο ποινής που μετρά την απόκλιση των παραγόμενων τροχιών από τους γνωστούς νόμους:

$$R_{\text{phys}}(X_t) = \|\dot{X}_t - F(X_t, t)\|_2^2 + \sum_j \eta_j [C_j(X_t) - c_j]^2, \quad (66)$$

όπου $C_j(X_t) = c_j$ εκφράζουν περιορισμούς διατήρησης και οι η_j είναι βάρη εξισορρόπησης. Ο αντίστοιχος ενεργειακός όρος καθοδήγησης είναι

$$\mathcal{E}_{\text{phys}}(x_t) = R_{\text{phys}}(x_t), \quad \Gamma_{\text{phys}}(x_t) = -\nabla_{x_t} R_{\text{phys}}(x_t),$$

ώστε η φυσική καθοδήγηση να εντάσσεται στο ενιαίο ενεργειακό πλαίσιο των εξισώσεων καθοδήγησης.

Η αντίστοιχη καθοδηγούμενη SDE γράφεται:

$$dX_t = \left[f(X_t, t) - g^2(t)(s_\theta(X_t, t) + \lambda \nabla_{x_t} R_{\text{phys}}(X_t)) \right] dt + g(t) d\bar{W}_t. \quad (67)$$

Στη διακριτή μορφή, η ενημέρωση της κατάστασης γίνεται:

$$x_{t-1} = F_t(x_t) + \lambda(t) \Gamma_{\text{phys}}(x_t) + \sigma_t z, \quad z \sim \mathcal{N}(0, I), \quad (68)$$

όπου ο φυσικός όρος $\Gamma_{\text{phys}}(x_t)$ δρα ως βαθμίδα διόρθωσης προς δυναμικά έγκυρες τροχιές.

Η φυσική καθοδήγηση μπορεί να θεωρηθεί ως επιβολή νόμων διατήρησης, χωρίς να περιορίζει πλήρως τη στοχαστικότητα της διάχυσης. Καθώς το μοντέλο παράγει δείγματα, οι βαθμίδες $-\nabla_{x_t} R_{\text{phys}}(X_t)$ λειτουργούν ως επαναφορά προς επιτρεπτές περιοχές του χώρου καταστάσεων, διατηρώντας σταθερότητα και φυσικό ρεαλισμό.

Οι περιορισμοί που χρησιμοποιούνται στην καθοδήγηση μέσω φυσικών ή δομικών αρχών μπορούν να λάβουν διάφορες μορφές. Περιλαμβάνουν δυναμικούς περιορισμούς, νόμους διατήρησης, περιορισμούς σταθερότητας και ομαλότητας, καθώς και υβριδικά μοντέλα όπου εξισώσεις φυσικής συνδυάζονται με εμπειρικά μοντέλα διάχυσης και η φυσική καθοδήγηση λειτουργεί ως regularizer. Η προσέγγιση αυτή έχει αποδειχθεί αποτελεσματική σε πλήθος εφαρμογών, όπως ρευστοδυναμική και πρόβλεψη κλιματικών πεδίων, συνθετικά χαοτικά συστήματα (Lorenz-96, Kuramoto-Sivashinsky), καθώς και ελεγχόμενα συστήματα όπου απαιτείται γένεση χρονικών τροχιών υπό ενεργειακούς ή δομικούς περιορισμούς.

Η καθοδήγηση βάσει φυσικής παρέχει φυσικά ρεαλιστικές, ερμηνεύσιμες τροχιές και μειώνει την ανάγκη για μεγάλα σύνολα δεδομένων. Ωστόσο, απαιτεί υπολογισμό παραγώγων $\dot{X}_t$ και διαφορίσιμους εκτιμητές $F(X_t, t)$, που μπορεί να αυξήσουν το κόστος υπολογισμού. Η επιλογή του βάρους λ καθορίζει την ισορροπία μεταξύ πιστότητας και ελευθερίας: μεγάλα λ οδηγούν σε φυσική ακρίβεια αλλά περιορισμένη ποικιλία δειγμάτων.


Σύνοψη Οι διαφορετικοί τρόποι καθοδήγησης αντανακλούν συμπληρωματικές μορφές πληροφορίας: ο γράφος επιβάλλει σχεσιακή σύζευξη· το κείμενο συνδέει σημασιολογία με τη γενετική δυναμική· το φάσμα συλλαμβάνει ρυθμικούς προτέρους· η εικόνα επιβάλλει χωροχρονική συνοχή· οι πίνακες ενσωματώνουν ετερογενείς συνδιακυμάνσεις· η φυσική επιβάλλει μηχανιστικό ρεαλισμό. Στη διάχυση χρονοσειρών, οι τρόποι αυτοί συνδυάζονται (π.χ. γράφος+φυσική για συζευγμένα δυναμικά συστήματα ή συμφραζόμενα+φάσμα για μουσικές ακολουθίες), οδηγώντας σε πολυτροπικά πλαίσια καθοδήγησης που γεφυρώνουν τη στατιστική μοντελοποίηση με γνώση πεδίου [5, 30].

Κεφάλαιο 3

Θεωρία και Εφαρμογή του Πειραματικού Μοντέλου

3.1 Πειραματικό Μοντέλο Καθοδηγούμενης Διάχυσης

Η μελέτη των μοντέλων διάχυσης για χρονοσειρές αποκαλύπτει ένα ουσιαστικό ερώτημα: πέρα από την επιφανειακή αναπαραγωγή των στατιστικών προτύπων, ποιοι είναι οι εσωτερικοί μηχανισμοί που ρυθμίζουν τις συσχετίσεις μεταξύ χαρακτηριστικών; Το CSDI (*Conditional Score-based Diffusion for Imputation*) μαθαίνει πολύπλοκες αλληλεξαρτήσεις, όμως ο τρόπος με τον οποίο τις εκφράζει κατά τη διάχυση παραμένει σε μεγάλο βαθμό αδιαφανής. Η ανάγκη για ελεγχόμενη και ερμηνεύσιμη παρέμβαση μέσα στη διαδικασία αυτή οδήγησε στην ανάπτυξη του παρόντος πειραματικού μοντέλου καθοδηγούμενης διάχυσης. Πιο συγκεκριμένα αντί να επανεκπαιδεύσουμε το δίκτυο ή να αλλάξουμε τη στοχαστική του φύση, εισάγουμε μια εξωτερική καθοδήγηση που δρα μόνο σε επιλεγμένα ζεύγη χαρακτηριστικών (i, j) με βάρη w_{ij} . Η παρέμβαση αυτή, γνωστή ως *pairs-only guidance*, εφαρμόζεται κατά τη φάση του *inference* και μπορεί να επεκταθεί σε γειτονικά χαρακτηριστικά μέσω ενός πολυ-βηματικού πίνακα συσχέτισης W . Έτσι, χωρίς να αλλοιώνεται ο εκπαιδευμένος μηχανισμός του CSDI, μπορούμε να κατευθύνουμε τη διάχυση προς επιθυμητές συσχετίσεις και να παρατηρούμε πώς αντιδρά το μοντέλο.



Σχήμα 6: Ροή της pairs-only καθοδήγησης μέσα στο CSDI. Από το x_t εφαρμόζονται (α) συμμετρικές ζευγαρικές ενημερώσεις στα επιλεγμένα (i, j, w_{ij}) , και (β) πολυ-βηματική διάχυση (multi-hop spill) βάσει του πίνακα συσχετίσεων W , πριν την προβολή στις γνωστές τιμές (μάσκα M) και το στοχαστικό βήμα του δειγματολήπτη.

Σημείο παρέμβασης στη διάχυση. Στο Σχήμα 6 απεικονίζεται το σημείο στο οποίο παρεμβαίνει ο μηχανισμός καθοδήγησης μέσα στη ροή του CSDI. Κάθε χρονικό βήμα της αντίστροφης διάχυσης ξεκινά από το x_t , ένα ενδιάμεσο δείγμα που περιέχει ακόμη υπολείμματα θορύβου. Πριν το δείγμα αυτό εισέλθει στον αποθορυβοποιητή f_θ , διέρχεται από τη συνάρτηση καθοδήγησης *conf_fn*. Εκεί συμβαίνουν δύο πράγματα:

1. **Παρέμβαση Ζευγαριού.** Για κάθε επιλεγμένο ζεύγος χαρακτηριστικών (i, j) με βάρος w_{ij} , τα δύο στοιχεία έλκονται ή απωθούνται μεταξύ τους, ανάλογα με το πρόσημο και το μέγεθος του βάρους. Η διαδικασία αυτή είναι συμμετρική: καμία μεταβλητή δεν κυριαρχεί στην άλλη, απλώς συγκλίνουν ή αποκλίνουν κατά

ένα μικρό ποσοστό που ελέγχεται από έναν συντελεστή έντασης $\lambda(t)$. Ο συντελεστής αυτός ακολουθεί ένα *late-ramp* χρονοπρόγραμμα, δηλαδή αυξάνεται προς τα τελευταία βήματα της διάχυσης, όταν το δείγμα πλησιάζει στην καθαρή ανακατασκευή. Με αυτό τον τρόπο, η καθοδήγηση αποφεύγει να διαταράξει τα πρώιμα, πιο θορυβώδη στάδια.

2. **Διάχυση πολλαπλών βημάτων.** Εκτός από τα ίδια τα καθοδηγούμενα ζεύγη, επιτρέπουμε η επίδρασή τους να μεταφερθεί και σε γειτονικά χαρακτηριστικά, με βάση τον πίνακα πολυ-βηματικής συσχέτισης W . Ο πίνακας αυτός λειτουργεί σαν ένας χάρτης επιρροής: αν δύο χαρακτηριστικά έχουν ισχυρή συσχέτιση στο αρχικό σύνολο δεδομένων, ένα μέρος της καθοδήγησης μεταφέρεται κι εκεί. Έτσι, το σύστημα δεν περιορίζεται σε μεμονωμένα ζεύγη, αλλά προσομοιώνει τη φυσική διάδοση αλληλεπιδράσεων μέσα σε ένα πλέγμα σχέσεων.

Η έξοδος της συνάρτησης καθοδήγησης είναι το x'_t , δηλαδή μια ήπια προσαρμοσμένη εκδοχή του αρχικού δείγματος. Στο Σχήμα 6 απεικονίζεται αυτή η ροή καθώς το x_t περνά μέσα από το μπλοκ Pairs-only Guidance, δέχεται τις στοχευμένες ενημερώσεις και, αν έχει ενεργοποιηθεί, το multi-hop spill, και στη συνέχεια προωθείται προς τον αποθορυβοποιητή του CSDI.

Ενσωμάτωση στον βρόχο του CSDI. Μετά την εφαρμογή της καθοδήγησης, το δείγμα x'_t εισέρχεται στον αποθορυβοποιητή f_θ , ο οποίος προβλέπει τον θόρυβο που πρέπει να αφαιρεθεί. Η πρόβλεψη αυτή οδηγεί το μοντέλο να υπολογίσει το επόμενο βήμα x_{t-1} . Σε κάθε βήμα εφαρμόζεται επίσης η μάσκα M_{cond} , η οποία διασφαλίζει ότι οι παρατηρημένες τιμές παραμένουν αμετάβλητες και μόνο οι άγνωστες ενημερώνονται.

Συνοπτικά, η διαδικασία έχει την εξής μορφή:

$$x_t \xrightarrow{\text{pairs-only / multi-hop}} x'_t \xrightarrow{\text{denoiser } f_\theta} x_{t-1}^{\text{raw}} \xrightarrow{\text{mask } M_{\text{cond}}} x_{t-1}.$$

Η παραπάνω αλληλουχία, που αποτυπώνεται στο διάγραμμα του Σχήματος 6, δείχνει καθαρά ότι η καθοδήγηση λειτουργεί ως ένα πρόσθετο, ντετερμινιστικό στρώμα ελέγχου, ενώ η στοχαστική φύση της διάχυσης παραμένει ανέπαφη. Η παρέμβαση είναι ήπια, τοπική και πλήρως αναστρέψιμη, επιτρέποντάς μας να εξετάζουμε την αντίδραση του μοντέλου σε συγκεκριμένες τροποποιήσεις χωρίς επανεκπαίδευση.

Το αποτέλεσμα είναι ένας πλήρης βρόχος καθοδηγούμενης διάχυσης, όπου κάθε μεταβολή στο x_t είναι ταυτόχρονα προϊόν μάθησης και ελέγχου, μια προγραμματισμένη παρέμβαση που μας επιτρέπει να παρατηρήσουμε τι πραγματικά έχει μάθει το μοντέλο για τις σχέσεις μεταξύ των χαρακτηριστικών του.

Η ενοποίηση αυτής της καθοδήγησης μέσα στη διάχυση επιτρέπει όχι μόνο την άμεση ποιοτική παρέμβαση, αλλά και την ποσοτική ανάλυση της συμπεριφοράς του μοντέλου μέσω των μετρικών Δ , *alignment*, και *selectivity*. Στις επόμενες σελίδες αναλύεται διεξοδικά ο εσωτερικός μηχανισμός της pairs-only καθοδήγησης (§??), η πολυ-βηματική διάχυση συσχετίσεων μέσω του πίνακα W (§3.2), και η σύνδεση με τον πίνακα *expectedness* E που χρησιμοποιείται για την αξιολόγηση της ευθυγράμμισης.

3.2 Πολυ-βηματική Διάχυση Συσχετίσεων

Η καθοδήγηση μέσω ζευγών δρα άμεσα μεταξύ συγκεκριμένων χαρακτηριστικών, όμως σε πολυμεταβλητά συστήματα οι αλληλεπιδράσεις σπάνια παραμένουν περιορισμένες μόνο σε ένα ζεύγος. Η μεταβολή που υφίσταται ένα χαρακτηριστικό τείνει να επηρεάζει και άλλα, μέσω έμμεσων σχέσεων. Για να αποτυπωθεί αυτή η *διάχυση επιρροής*, το προτεινόμενο μοντέλο εισάγει έναν μηχανισμό πολυ-βηματικής διάχυσης συσχετίσεων, ο οποίος βασίζεται σε έναν πίνακα $C \in \mathbb{R}^{K \times K}$ που περιγράφει τις συσχετίσεις πρώτης τάξης μεταξύ των χαρακτηριστικών.

Υπολογισμός του πίνακα συσχετίσεων. Πριν κατασκευαστεί ο πολυ-βηματικός πίνακας W , απαιτείται μια αξιόπιστη εκτίμηση των άμεσων σχέσεων μεταξύ όλων των χαρακτηριστικών. Αυτό επιτυγχάνεται μέσω του δείκτη συσχέτισης Pearson, ο οποίος αποτυπώνει τον βαθμό γραμμικής εξάρτησης μεταξύ δύο κανονικοποιημένων χρονοσειρών.

Για δύο χαρακτηριστικά $a, b \in \{1, \dots, K\}$, έστω $x_a, x_b \in \mathbb{R}^T$ οι κανονικοποιημένες χρονοσειρές και T_{ab} το σύνολο των χρονικών δεικτών όπου και οι δύο τιμές είναι παρατηρημένες. Οι μέσες τιμές στα κοινά αυτά δείγματα

συμβολίζονται ως $\bar{x}_a$ και $\bar{x}_b$. Η συσχέτιση Pearson ορίζεται ως:

$$C_{ab}^{(P)} = \frac{\sum_{t \in T_{ab}} (x_a(t) - \bar{x}_a)(x_b(t) - \bar{x}_b)}{\sqrt{\sum_{t \in T_{ab}} (x_a(t) - \bar{x}_a)^2} \sqrt{\sum_{t \in T_{ab}} (x_b(t) - \bar{x}_b)^2}}. \quad (69)$$

Η εξίσωση (69) αποδίδει τιμές στο διάστημα $[-1, 1]$: θετικές τιμές δηλώνουν ταυτόχρονη αυξομείωση των δύο χαρακτηριστικών, ενώ αρνητικές τιμές υποδεικνύουν αντίθετη πορεία. Με τον τρόπο αυτό, ο πίνακας $C^{(P)}$ λειτουργεί ως «αποτύπωμα» των γραμμικών αλληλεπιδράσεων που χαρακτηρίζουν το σύστημα.

Ωστόσο, για να διασφαλιστεί ότι κάθε εκτίμηση είναι στατιστικά αξιόπιστη, λαμβάνεται υπόψη μόνο το υπο-σύνολο των δειγμάτων όπου τα δύο χαρακτηριστικά συνυπάρχουν χρονικά. Αν ο αριθμός αυτών των κοινών δειγμάτων $|T_{ab}|$ είναι μικρότερος από ένα κατώφλι $\min_samples$, ή αν κάποιος από τα δύο χαρακτηριστικά έχει πολύ μικρή διακύμανση ($\text{std}(x_k) < \varepsilon$), η αντίστοιχη εκτίμηση C_{ab} θεωρείται μη αξιόπιστη και τίθεται ίση με μηδέν. Η παράμετρος $\min_samples$ ρυθμίζει τον ελάχιστο αριθμό ταυτόχρονων παρατηρήσεων που απαιτούνται για σταθερή εκτίμηση· τυπικές τιμές κυμαίνονται στο διάστημα $[8, 20]$, ανάλογα με το μήκος της χρονοσειράς και το ποσοστό ελλειπόντων δεδομένων.

Αντιμετώπιση NaN και εκφυλισμένων περιπτώσεων. Η διαδικασία υπολογισμού του πίνακα C συνοδεύεται από μια σειρά ελέγχων ποιότητας, ώστε να αποφευχθούν εκφυλισμένες ή θορυβώδεις περιπτώσεις. Αρχικά, ελέγχεται κάθε χαρακτηριστικό x_k : αν η διακύμανσή του είναι μικρότερη από ε ή αν ο αριθμός έγκυρων δειγμάτων του είναι κάτω από $\min_samples$, τότε το χαρακτηριστικό θεωρείται μη έγκυρο και αποκλείεται από τον υπολογισμό. Ο πίνακας συσχετίσεων υπολογίζεται στο έγκυρο υποσύνολο $V \subseteq \{1, \dots, K\}$ και στη συνέχεια «επανατοποθετείται» στο πλήρες σχήμα $(K \times K)$, όπου οι μη έγκυρες γραμμές και στήλες αντικαθίστανται με μηδενικά.

Τέλος, για να αποφευχθεί οποιαδήποτε μορφή αυτοδιάχυσης, η διαγώνιος του πίνακα μηδενίζεται:

$$\text{diag}(C) = 0.$$

Το τελικό αποτέλεσμα είναι ένας συμμετρικός πίνακας C που ικανοποιεί $C_{ab} \in [-1, 1]$ και λειτουργεί ως σταθερή βάση πάνω στην οποία εφαρμόζεται στη συνέχεια η πολυ-βηματική διάχυση συσχετίσεων. Με άλλα λόγια, ο πίνακας C αντιπροσωπεύει την πρώτη ύλη της καθοδήγησης καθώς αποδίδει την συσχέτιση των χαρακτηριστικών πριν αρχίσει η εξάπλωση των επιδράσεων μέσω του πίνακα W .

Από τον πίνακα C μπορούμε να παραγάγουμε πληροφορία για έμμεσες σχέσεις μεταξύ χαρακτηριστικών μέσω της ύψωσής του σε διαδοχικές δυνάμεις. Η k -οστή δύναμη C^k εκφράζει τη «διάδοση» επιρροής κατά μήκος αλυσίδων μήκους k . Συνδυάζοντας αυτά τα επίπεδα, σχηματίζεται ο πολυ-βηματικός πίνακας W :

$$W = \sum_{h=1}^{H_{\max}} \alpha^{h-1} \mathcal{N}(C^h), \quad (70)$$

όπου:

- $H_{\max}$ είναι ο μέγιστος αριθμός βημάτων που επιτρέπεται να διαδοθεί η επίδραση,
- $\alpha \in (0, 1)$ είναι ο παράγοντας που μειώνει τη συμβολή κάθε επιπλέον βήματος,
- $\mathcal{N}(\cdot)$ δηλώνει κανονικοποίηση (π.χ. ως προς μέγιστη τιμή ή ℓ_1 -νόρμα).

Η εξίσωση (70) αποτελεί τη γενική μορφή του μηχανισμού· στην πράξη υπάρχουν διαφορετικοί τρόποι υλοποίησης ανάλογα με τον τρόπο διάδοσης.

Εναλλακτικές μέθοδοι διάδοσης. Στην παρούσα εργασία εξετάζονται τρεις κύριες μορφές πολυ-βηματικής διάχυσης, οι οποίες αντιστοιχούν σε διαφορετικού τύπου εξομάλυνση του πίνακα C :

1. Πολυωνυμική διάδοση (polynomial propagation):

$$W_{\text{poly}} = C + \alpha C^2 + \alpha^2 C^3 + \dots + \alpha^{H_{\max}-1} C^{H_{\max}}.$$

Πρόκειται για απλή επέκταση κατά δυνάμεις του C . Είναι εύκολη υπολογιστικά και διατηρεί την ερμηνευσιμότητα του πίνακα όπου κάθε όρος αντιστοιχεί σε συσχετίσεις 1, 2, 3 βαθμού. Η προσέγγιση αυτή χρησιμοποιείται συχνά σε graph diffusion kernels.

2. Εκθετική διάδοση (exponential propagation):

$$W_{\text{exp}} = \exp(\alpha C) - I = \sum_{h=1}^{\infty} \frac{\alpha^h C^h}{h!}.$$

Η μορφή αυτή λαμβάνει υπόψη άπειρα βήματα με σταδιακά μειούμενο βάρος. Παρέχει ομαλότερη και πιο συνεχόμενη εξασθένιση της επίδρασης και εξασφαλίζει ότι οι τιμές του W παραμένουν εντός σταθερού εύρους. Στο πειραματικό μας μοντέλο επιλέχθηκε η εκθετική μορφή γιατί προσφέρει πιο σταθερή διάδοση, αποφεύγοντας τις απότομες ενισχύσεις που μπορεί να προκαλέσουν οι υψηλές δυνάμεις του C στην πολυωνυμική εκδοχή.

3. **Διάδοση μέσω γειτονιάς** Στην προσέγγιση αυτή υπολογίζονται διαδοχικά προϊόντα $C, C^2, C^3, \dots$ και κάθε βήμα κανονικοποιείται ξεχωριστά:

$$W_{\text{neigh}} = \sum_{h=1}^{H_{\max}} \alpha^{h-1} \mathcal{N}(C^h),$$

δίνοντας μεγαλύτερο έλεγχο στην ένταση κάθε επιπέδου. Εφαρμόζεται συχνά όταν το C αντιστοιχεί σε γράφημα με αραιές συνδέσεις ή ανομοιόμορφα βάρη.

Επιλογή παραμέτρων. Για τις πειραματικές δοκιμές επιλέχθηκαν:

$$H_{\max} = 3, \quad \alpha = 0.7, \quad \text{μέθοδος: εκθετική.}$$

Η τιμή $\alpha = 0.7$ επιτρέπει μέτρια διάχυση χωρίς υπερβολική εξάπλωση, ενώ τρία βήματα (3-hop) επαρκούν για να συλλάβουν τις κυριότερες έμμεσες επιρροές χωρίς να χαθεί η τοπικότητα της καθοδήγησης. Η εκθετική μέθοδος διασφαλίζει αριθμητική σταθερότητα και φυσική ομαλότητα στη μετάδοση των επιδράσεων.

Ενσωμάτωση στη ροή της διάχυσης. Στην πράξη, ο πίνακας W εφαρμόζεται μετά την ενημέρωση των καθοδηγούμενων ζευγών. Οι μεταβολές που επιβλήθηκαν στα καθοδηγούμενα χαρακτηριστικά πολλαπλασιάζονται με W^T ώστε να διαχυθούν και στα υπόλοιπα:

$$\Delta_{\text{spill}} = \alpha_{\text{spill}} (\Delta_G W^T),$$

όπου α_{spill} είναι ο *συντελεστής διαρροής*. Η τιμή του ελέγχει το ποσοστό ενέργειας που μεταφέρεται από τα καθοδηγούμενα στα μη καθοδηγούμενα χαρακτηριστικά· στην παρούσα εργασία χρησιμοποιείται τυπικά $\alpha_{\text{spill}} = 0.2$, ώστε η διαρροή να είναι αισθητή αλλά να μην υπερκαλύπτει την αρχική καθοδήγηση.


Η διαδικασία αυτή φαίνεται στο Σχήμα 6: μετά τις ζευγαρικές ενημερώσεις, το multi-hop spill διαχέει τις επιδράσεις σε χαρακτηριστικά που συνδέονται έμμεσα, προσδίδοντας στο μοντέλο μια πιο φυσική και ρεαλιστική δυναμική.

Σύνοψη Μεθόδων

Μέθοδος	Τύπος	Αποτυπώνει	Κόστος	Σταθερότητα	Τυπική Χρήση
Polynomial	$\sum_{h=1}^H \gamma^{h-1} C^h$	Πεπερασμένα άλματα	$\mathcal{O}(HK^3)$	Υψηλός έλεγχος	Γενική χρήση
Exponential	$\exp(\gamma C) - I$	Άπειρα άλματα (παραγοντική απόσβεση)	$\mathcal{O}(K^3)$	Σταθερή για μικρή γ	Συνοπτική πυκνή σύζευξη
Neighbors	Ρητή άθροιση ανά άλμα	hop-wise συγκέντρωση	$\mathcal{O}(HK^3)$	Ανθεκτική με επανακλ.	Εμπειρικά σε γραφήματα

3.3 Ροή Υλοποίησης και Αλγοριθμική Περιγραφή

Αφού περιγράψαμε τα θεωρητικά συστατικά της καθοδήγησης, μπορούμε να εξετάσουμε τώρα πώς ενσωματώνονται βήμα προς βήμα στην εκτελεστική ροή του πειραματικού μοντέλου. Η διαδικασία αυτή υλοποιείται μέσω μιας συνάρτησης υπό όρους, της `conf_fn_pairs_only`, η οποία εφαρμόζεται σε κάθε βήμα της αντίστροφης διάχυσης πριν το δείγμα περάσει από τον αποθρομβοποιητή f_θ .



Σχήμα 7: Συνοπτική ροή της pairs-only καθοδήγησης πριν από τον αποθορυβοποιητή. Είσοδος το x_t . Στο μπλοκ *Update Guided Pairs* εφαρμόζονται οι ζευγαρικές ενημερώσεις υπό τον έλεγχο του χρονοπρογράμματος $\lambda(t)$ και της μάσκας παρατήρησης cond_mask , ενώ το t_embed παρέχει τον χρονικό εντοπισμό του βήματος. Στη συνέχεια υπολογίζονται οι συνολικές μεταβολές στα καθοδηγούμενα (*Compute Guided Deltas*) και διαχέονται στους υπόλοιπους κόμβους μέσω του πολυ-βηματικού πίνακα συσχετίσεων (*Multi-Hop Spill*). Το αποτέλεσμα είναι το καθοδηγημένο δείγμα x'_t .

Για να διευκολυνθεί η κατανόηση της εσωτερικής λειτουργίας της συνάρτησης `conf_fn_pairs_only`, το Σχήμα 7 παρουσιάζει μια συμπυκνωμένη εκδοχή της ροής που λαμβάνει χώρα μέσα σε κάθε βήμα διάχυσης. Το διάγραμμα λειτουργεί ως οπτικός οδηγός για τα επιμέρους στάδια που περιγράφηκαν προηγουμένως και για τον ψευδοκώδικα που ακολουθεί.

Αντιστοίχιση μπλοκ σε λειτουργίες. Με βάση το Σχήμα 7, κάθε στοιχείο και είσοδος αντιστοιχεί άμεσα σε υποσυνάρτηση του μηχανισμού καθοδήγησης:

- **Είσοδοι και αρχικοποίηση.** Ξεκινάμε με το τρέχον δείγμα x_t της αντίστροφης διάχυσης, το οποίο συνοδεύεται από τη μάσκα παρατήρησης cond_mask και το χρονικό ενσωμάτωμα t_embed . Το x_t περιέχει όλα τα κανάλια της χρονοσειράς, ενώ η μάσκα cond_mask (1 = παρατηρημένο, 0 = μη παρατηρημένο) περιορίζει τις ενημερώσεις μόνο στα ελλείποντα σημεία. Το t_embed παρέχει χρονικό πλαίσιο στο δίκτυο, συγχρονίζοντας τη δυναμική καθοδήγηση με το στάδιο της διάχυσης.
- **Χρονοπρογραμματισμός $\lambda(t)$.** Μέσω του *scheduler* $\lambda(t)$, που ελέγχουμε την ένταση της καθοδήγησης. Ανάλογα με τη μορφή του (late-ramp ή SNR gate), ενεργοποιεί σταδιακά το βάρος της επίδρασης στα τελευταία βήματα, όταν η διάχυση είναι πλέον πιο σταθερή. Με τον τρόπο αυτό, εξασφαλίζεται ότι οι παρεμβάσεις γίνονται ομαλά και χωρίς να αποσταθεροποιούν τα πρώιμα στάδια.
- **Ενημέρωση καθοδηγούμενων ζευγών (Update Guided Pairs).** Σε αυτό το βήμα εφαρμόζονται οι συμμετρικές ενημερώσεις για κάθε επιλεγμένο ζεύγος $(i, j, w_{ij}) \in \mathcal{G}$:

$$x_i \leftarrow x_i + \lambda(t)w_{ij}(x_j - x_i), \quad x_j \leftarrow x_j + \lambda(t)w_{ij}(x_i - x_j),$$

μόνο σε θέσεις όπου $\text{cond_mask} = 0$. Πρόκειται για τον πυρήνα της *Pairs-only Guidance*, όπου η καθοδήγηση επιβάλλει αμφίδρομη προσαρμογή μεταξύ καναλιών με βάση το βάρος w_{ij} . Η εφαρμογή του $\lambda(t)$ προσφέρει χρονικά ελεγχόμενη “ευαισθησία” στη μεταξύ τους επίδραση.

- **Υπολογισμός καθοδηγούμενων μεταβολών (Compute Guided Deltas).** Μετά την ενημέρωση, υπολογίζονται οι καθαρές μεταβολές που προκάλεσαν οι ζευγαρικές παρεμβάσεις:

$$\Delta_G = (x - x_0)_{\text{guided}},$$

οι οποίες εκφράζουν τη συνιστώσα της αλλαγής που οφείλεται αποκλειστικά στην καθοδήγηση. Αυτές οι μεταβολές λειτουργούν ως πηγή ενέργειας που θα διαχυθεί μέσω του πίνακα συσχετίσεων στο επόμενο στάδιο.

- **Πολυ-βηματική διάχυση (Multi-Hop Spill).** Οι μεταβολές Δ_G προβάλλονται στον πολυ-βηματικό πίνακα $W = f(C_{\text{offline}})$, όπου $f(\cdot)$ μπορεί να είναι εκθετική, πολυωνυμική ή γειτονική συνάρτηση διάδοσης. Υπολογίζεται το συνολικό σήμα διάχυσης

$$\Delta_{\text{all}} = \Delta_G W^T,$$

και εφαρμόζεται στο δείγμα:

$$x \leftarrow x + \alpha_{\text{spill}} \cdot \Delta_{\text{all}}.$$

Το αποτέλεσμα είναι η μεταφορά των καθοδηγούμενων επιδράσεων και σε μη καθοδηγούμενα χαρακτηριστικά, διατηρώντας τη συνοχή της πολυμεταβλητής δομής. Οι επιλογές `multi_hop_apply_to_guided` και `spill_center` καθορίζουν εάν επηρεάζονται και τα ίδια τα ζευγάρια-πηγές.

- Έξοδος x'_t . Στο τέλος της διαδικασίας παράγεται το x'_t , δηλαδή το αποτέλεσμα της ζευγαρικής και πολυ-βηματικής καθοδήγησης. Το x'_t περνάει στη συνάρτηση αποθορυβοποίησης f_θ για τον υπολογισμό του επόμενου χρονικού βήματος x_{t+1} .

Μέσω αυτής της ακολουθίας περιγράφεται με ακρίβεια η εσωτερική ροή του μηχανισμού `conf_fn_pairs_only`. Το Σχήμα 7 επομένως λειτουργεί ως οδηγός που αποτυπώνει τη διαδοχή των επιμέρους ενεργειών, από την είσοδο x_t και τη ζευγαρική ενημέρωση έως την πολυ-βηματική διάχυση και την παραγωγή του καθοδηγημένου δείγματος x'_t .

3.4 Ρυθμίσεις Καθοδήγησης και Επιλογή Παραμέτρων

Η επιλογή των υπερπαραμέτρων του μηχανισμού καθοδήγησης αποτελεί κρίσιμο βήμα για τη σταθερότητα και την ερμηνευσιμότητα του μοντέλου. Στόχος δεν είναι η βελτιστοποίηση απόδοσης, αλλά η διαμόρφωση ενός *ρεαλιστικού και ελεγχόμενου πεδίου επιρροών* που να επιτρέπει τη μελέτη της συμπεριφοράς του συστήματος χωρίς να διαταράσσεται η στοχαστική φύση της διάχυσης. Οι τελικές ρυθμίσεις προέκυψαν ύστερα από ανάλυση σταθερότητας και εμπειρικούς ελέγχους σε τρία αντιπροσωπευτικά σύνολα: BabySlakh (music), Lorenz-96 (synthetic), και PEMS-SF (traffic). Η φιλοσοφία ήταν να επιλεγούν *συντηρητικές αλλά αποδοτικές* τιμές, που εξασφαλίζουν σταθερότητα, επιλεκτικότητα και ρεαλισμό του καθοδηγημένου σήματος.

(α) Δειγματοληψία και Αξιολόγηση

Η δειγματοληψία πραγματοποιήθηκε με `--nsample 20` και `--eval_batch_size 1`. Η επιλογή $N_{\text{sample}} = 20$ επιτρέπει αξιόπιστη εκτίμηση της πιθανοκρατικής αβεβαιότητας (μέσω ποσοστιαίων 5–95% και CRPS) χωρίς υπερβολικό υπολογιστικό κόστος. Η εκτέλεση σε παρτίδες μεγέθους 1 διευκολύνει την αποθήκευση πλήρων χρονικών τροχιών και την άμεση αντιστοίχιση κάθε καθοδηγούμενης εκτέλεσης με τη μη καθοδηγούμενη βάση αναφοράς.

(β) Βασική Ισχύς Καθοδήγησης

Ο συντελεστής λ_g καθορίζει τη βασική ένταση της καθοδήγησης. Η τιμή `--lambda_g 0.10` προέκυψε από σάρωση τιμών στο διάστημα $[0.05, 0.30]$. Για $\lambda_g > 0.15$ παρατηρήθηκαν υπερβολικές αποκλίσεις και απώλεια ποικιλίας, ενώ για $\lambda_g < 0.05$ το σήμα καθοδήγησης γινόταν ανεπαίσθητο. Η επιλογή 0.10 αντιπροσωπεύει μια σταθερή ισορροπία: η καθοδήγηση παραμένει σαφώς ανιχνεύσιμη, αλλά χωρίς να διαταράσσει την εγγενή στοχαστικότητα του μοντέλου. Σε όρους δυναμικής, η τιμή αυτή διατηρεί τη «σύσπαση» του πεδίου χωρίς υπερβολική συμπίεση του χώρου καταστάσεων.

(γ) Χρονοπρογραμματισμός Ενεργοποίησης

Η καθοδήγηση ενεργοποιείται σύμφωνα με το σχήμα `--guidance_schedule late90` και τη συνθήκη `--snr_gate 0.5`. Το χρονοπρόγραμμα *late90* σημαίνει ότι η καθοδήγηση εφαρμόζεται μόνο στο τελευταίο $\sim 10\%$ των βημάτων της διάχυσης, όταν ο λόγος σήματος-προς-θόρυβο (SNR) είναι υψηλός και η εκτίμηση s_θ πιο αξιόπιστη. Στα πρώιμα στάδια, όπου η διαδικασία κυριαρχείται από τυχαίο θόρυβο, μια ισχυρή καθοδήγηση θα μπορούσε να οδηγήσει σε αποσταθεροποίηση. Η πύλη $\text{SNR} \geq 0.5$ δρα ως μηχανισμός ασφάλειας, επιτρέποντας τη δράση της καθοδήγησης μόνο όταν το δείγμα περιέχει επαρκή πληροφορία σήματος.

(δ) Ελεγχόμενη Διάχυση μέσω Spill

Η παράμετρος `--unguided_spill_mode corr` ενεργοποιεί τη διάχυση βασισμένη στις πραγματικές συσχετίσεις των δεδομένων. Έτσι, οι μη καθοδηγούμενοι κόμβοι επηρεάζονται μόνο από στατιστικά συναφή χαρακτηριστικά. Ο συντελεστής `--unguided_spill_alpha 0.10` ελέγχει την ένταση της διάχυσης: χαμηλή τιμή (0.1) διασφαλίζει ότι η

διαδικασία λειτουργεί ως ήπια εξομάλυνση και όχι ως δεύτερη καθοδήγηση. Η επιλογή αυτή αποτρέπει υπερβολική εξάπλωση επιρροών και διατηρεί την τοπικότητα των αλληλεπιδράσεων.

Ο πίνακας συσχετίσεων C υψώνεται σε δύναμη $p = 1.0$ (`--corr_power 1.0`), ώστε να διατηρηθεί γραμμική σχέση με τις εκτιμημένες συσχετίσεις χωρίς τεχνητή ενίσχυση ή αποδυνάμωση. Η κανονικοποίηση `--corr_norm colmax` επιλέχθηκε επειδή παρέχει σταθερό φράγμα ανά στήλη ($\|C: b\|_\infty = 1$) και διατηρεί ισορροπημένα τοπικά βάρη. Η επιλογή `--unguided_spill_center` εξασφαλίζει μηδενική συνολική μετατόπιση του x_t , αφαιρώντας τη διάμεσο από το διαχυθέν σήμα. Αυτό είναι σημαντικό σε κανονικοποιημένα δεδομένα, όπου το μέσο επίπεδο πρέπει να παραμένει κοντά στο μηδέν.

(ε) Πολυ-Βηματική Διάδοση

Η παράμετρος `--multi_hop_enabled` ενεργοποιεί την πολυ-βηματική διάχυση, η οποία είναι ιδιαίτερα σημαντική για δεδομένα με πλούσιες συζεύξεις όπως τα `traffic sensors`. Επιλέχθηκε εκθετική μέθοδος διάδοσης (`--multi_hop_method exponential`) λόγω της ομαλής και φυσικά αποσβεστικής συμπεριφοράς της:

$$\Phi_{\text{exp}}(C) = e^{\gamma C} - I,$$

όπου η παράμετρος `--multi_hop_decay 0.3` ρυθμίζει τον ρυθμό απόσβεσης, ενώ `--multi_hop_max_hops 4` περιορίζει την επέκταση σε τέσσερα βήματα, καλύπτοντας τοπικές και δευτερεύουσες επιδράσεις χωρίς υπερβολικό θόρυβο. Η επιλογή `--multi_hop_normalize` εξασφαλίζει αριθμητική σταθερότητα ανά άλμα και αποτρέπει τη σωρευτική ενίσχυση σε μεγάλα βάθη διάχυσης.

(στ) Δομική Στάθμιση και Παραγόμενα Δεδομένα

Η ρύθμιση `--structure_by_pair_weight` ενσωματώνει τα πρόσσημα των βαρών w_{ij} στην πολυάλμα διάχυση, επιτρέποντας τη διατήρηση ελκτικών ($w > 0$) ή απωστικών ($w < 0$) σχέσεων. Έτσι, το τελικό ενεργειακό τοπίο του συστήματος αντικατοπτρίζει την επιθυμητή πολικότητα συσχέτισης. Τέλος, η επιλογή `--keep_only_generated` διατηρεί μόνο τα παραγόμενα x_U (τιμές σε μη παρατηρημένα σημεία), μειώνοντας το κόστος αποθήκευσης και επιτρέποντας άμεση αξιολόγηση μέσω πινάκων συσχέτισης και μετρικών ευθυγράμμισης.

Οι παραπάνω ρυθμίσεις αντιπροσωπεύουν έναν ισορροπημένο συμβιβασμό μεταξύ θεωρητικής σταθερότητας και πρακτικής επιλεκτικότητας. Η χαμηλή ένταση καθοδήγησης ($\lambda_g = 0.1$), η περιορισμένη διάχυση ($\alpha_{\text{spill}} = 0.1$), η καθυστερημένη ενεργοποίηση (`late90`) και η εκθετική πολυάλμα διάδοση ($H = 4$, $\gamma = 0.3$) εξασφαλίζουν ήπια αλλά ουσιαστική μεταβολή των επιλεγμένων ζευγών με ρεαλιστική εξάπλωση επιρροών στον χώρο χαρακτηριστικών του μοντέλου.

3.5 Αναμενόμενες Συμπεριφορές και Διαγνωστικά Τεστ

Για να αξιολογηθεί η λειτουργία του μηχανισμού καθοδήγησης, πέρα από τα καθιερωμένα τεστ επαναληψιμότητας και σταθερότητας που εφαρμόζονται στα μοντέλα διάχυσης, πραγματοποιούνται και ειδικοί έλεγχοι λογικής και συνέπειας με στόχο να επαληθευτεί ότι η `pairs-only` καθοδήγηση παράγει αιτιολογικά αναμενόμενες συμπεριφορές. Οι έλεγχοι αυτοί δεν στοχεύουν στη βελτίωση απόδοσης, αλλά στη διασφάλιση ότι το σύστημα αποκρίνεται με τρόπο συνεπή προς τις θεωρητικές του αρχές.

Έλεγχοι Λογικής με Συνθετικές Συζεύξεις

Η βασική ιδέα αυτών των τεστ είναι να απομονωθούν απλές συνθήκες ώστε να ελεγχθεί αν η καθοδήγηση συμπεριφέρεται με σωστο τρόπο. Κάθε τεστ ξετάζει μια συγκεκριμένη πτυχή της εσωτερικής λογικής του μηχανισμού:

- **Αναστροφή ελέγχου (sign reversal).** Όταν ένα ζεύγος καθοδηγείται με θετικό βάρος $w_{ij} > 0$, η συσχέτιση ρ_{ij} στο παραγόμενο δείγμα πρέπει να αυξάνεται· αν το βάρος αντιστραφεί ($w_{ij} < 0$), η συσχέτιση πρέπει να μειώνεται ή να αλλάζει πρόσημο. Η συμπεριφορά αυτή ελέγχει τη συνεκτικότητα της γραμμικής απόκρισης ως προς το πρόσημο της καθοδήγησης.

- **Μηδενικό βάρος (null equivalence).** Όταν $w_{ij} = 0$, η εκτέλεση πρέπει να ταυτίζεται με την *μη καθοδηγούμενη* περίπτωση. Επομένως, ο μηχανισμός δεν πρέπει να εισάγει καμία συστηματική μεταβολή στη συσχέτιση ή στο φάσμα του σήματος. Το τεστ αυτό επιβεβαιώνει ότι η καθοδήγηση είναι απολύτως παθητική όταν δεν της δίνεται ενεργό σήμα.
- **Συμμετρία (pair symmetry).** Για συμμετρικά βάρη $w_{ij} = w_{ji}$, η απόκριση πρέπει να είναι συμμετρική ως προς τα δύο χαρακτηριστικά, δηλαδή $\Delta\rho_{ij} = \Delta\rho_{ji}$. Η ασυμμετρία θα υποδήλωνε αριθμητική αστάθεια ή σφάλμα εφαρμογής της μάσκας M .
- **Πολυ-άλμα διάχυση (multi-hop spill test).** Όταν ενεργοποιείται η πολυ-βηματική διάχυση, τα μη καθοδηγούμενα χαρακτηριστικά που συνδέονται με υψηλές τιμές στον πίνακα W πρέπει να παρουσιάζουν συντονισμένες μεταβολές στη συσχέτισή τους με τα καθοδηγούμενα. Η παρουσία τέτοιων *δευτερευουσών επιδράσεων* επιβεβαιώνει ότι η συνάρτηση $\Phi(C)$ εφαρμόζεται σωστά και ότι η πληροφορία διαχέεται μέσω του γράφου.

Έλεγχος Αποτελέσματος και Ποιοτική Ανάλυση Παραμέτρων

Για να μελετηθεί η συμπεριφορά του μοντέλου υπό διαφορετικές ρυθμίσεις, ορίστηκαν άξονες ελέγχου που συνδέουν κάθε βασική παράμετρο με το αναμενόμενο αποτέλεσμα. Οι τάσεις που καταγράφονται στον Πίνακα 7 προκύπτουν από συστηματικούς πειραματικούς ελέγχους με συνθετικά και πραγματικά δεδομένα.

Πίνακας 7: Αναμενόμενες τάσεις και ποιοτικές συμπεριφορές παραμέτρων καθοδήγησης.

Άξονας	Περιγραφή	Αναμενόμενη Τάση / Ερμηνεία
$\pm w_{ij}$	Πρόσημο και ένταση καθοδήγησης στα ζεύγη	Αναστροφή πρόσημου συσχέτισης: $w > 0 \rightarrow$ έλξη, $w < 0 \rightarrow$ άπωθηση.
$H_{\max}$	Πλήθος αλμάτων στη διάχυση	Μεγαλύτερο $H \Rightarrow$ αυξημένη εμβέλεια επιρροής αλλά μικρότερη επιλεκτικότητα· τα δευτερεύοντα χαρακτηριστικά επηρεάζονται ισχυρότερα.
γ	Συντελεστής απόσβεσης ανά άλμα	Μεγαλύτερη γ (ισχυρότερη φθίση) $\Rightarrow$ πιο ομαλή, καθολική διάδοση· μικρότερη $\gamma \Rightarrow$ πιο τοπική και έντονη επίδραση.
Κανονικοποίηση	Τύπος κανονικοποίησης πίνακα συσχέτισης (colmax, ℓ_1)	colmax διατηρεί φραγμένες κορυφές (σταθερές αναλογίες), ενώ ℓ_1 εξισορροπεί τις στήλες αναδιανέμοντας τη μάζα των επιρροών.
Ισχύς p	Εξόρυξη μη γραμμικής οξύτητας στη συσχέτιση	Μεγαλύτερο p τονίζει τις ισχυρές σχέσεις και αραιώνει το υπόλοιπο πεδίο· πιο εκλεκτική και τοπική διάχυση.
Απόλυτο ή υπογεγραμμένο C	Χρήση απόλυτων ή υπογεγραμμένων συσχετίσεων	Η χρήση υπογεγραμμένου C διατηρεί ανταγωνιστικές σχέσεις (π.χ. θετικές έναντι αρνητικών αλληλεξαρτήσεων), ενώ το απόλυτο $ C $ ενισχύει γενικά την ευθυγράμμιση.

3.6 Μετρικές Αξιολόγησης και Τεκμηρίωση Υλοποίησης

Η αξιολόγηση του μηχανισμού καθοδήγησης βασίζεται σε ένα σύνολο μετρικών που αποτυπώνουν διαφορετικές πτυχές της επίδρασής του πάνω στη δυναμική και στη δομή συσχετίσεων του συστήματος. Οι μετρικές αυτές επιτρέπουν την ποσοτικοποίηση τόσο της *έντασης* των αλλαγών που προκαλούνται, όσο και της *εστίασης* και της *συνέπειάς* τους σε σχέση με την αναμενόμενη συμπεριφορά. Οι βασικές μετρικές που χρησιμοποιούνται είναι η **Διαφορά Συσχέτισης** (Δ), η **Εκλεκτικότητα** (selectivity), η **Διαρροή Εκτός Στόχου** (spill off-target) και η **Ευθυγράμμιση** (alignment).

3.6.1 Μετρικές Καθοδήγησης και Αξιολόγησης

Η ποσοτική αξιολόγηση της καθοδήγησης βασίζεται σε ένα σύνολο μετρικών που αποτυπώνουν την επίδραση της τόσο στην τοπική δυναμική των καθοδηγούμενων κόμβων όσο και στη συνολική συσχετιστική δομή του συστήματος. Οι βασικές μετρικές που χρησιμοποιούνται είναι η **Διαφορά Συσχέτισης** (Δ), η **Εκλεκτικότητα** (selectivity), η **Διαρροή Εκτός Στόχου** (spill off-target) και η **Ευθυγράμμιση** (alignment). Κάθε μία από αυτές αναδεικνύει μια διαφορετική πτυχή της συμπεριφοράς του μοντέλου υπό στοχευμένη καθοδήγηση.

Διαφορά Συσχέτισης (Δ). Η μετρική Δ εκφράζει τη μεταβολή της συσχέτισης μεταξύ δύο χαρακτηριστικών (a, b) πριν και μετά την εφαρμογή της καθοδήγησης. Αν C_u συμβολίζει τον πίνακα συσχετίσεων χωρίς καθοδήγηση και C_g τον πίνακα μετά την καθοδήγηση, τότε η διαφορά ορίζεται ως:

$$\Delta_{a,b} = C_g(a, b) - C_u(a, b).$$

Θετικές τιμές υποδηλώνουν ενίσχυση της συσχέτισης μεταξύ των δύο χαρακτηριστικών, ενώ αρνητικές τιμές αντιστοιχούν σε αποδυνάμωση της σχέσης τους. Η Δ αποτελεί τη θεμελιώδη ποσότητα από την οποία προκύπτουν όλες οι επόμενες μετρικές.

Εκλεκτικότητα (Selectivity). Η εκλεκτικότητα μετρά το κατά πόσο η επίδραση της καθοδήγησης παραμένει συγκεντρωμένη στους στοχευμένους κόμβους, χωρίς να εξαπλώνεται σε μη σχετιζόμενες μεταβλητές. Αν $x_{n,\ell,k}^{(g)}$ και $x_{n,\ell,k}^{(u)}$ είναι οι τιμές του χαρακτηριστικού k στις χρονικές θέσεις (n, ℓ) για την καθοδηγούμενη και μη καθοδηγούμενη διαδικασία αντίστοιχα, τότε το μέτρο μεταβολής για κάθε χαρακτηριστικό δίνεται από:

$$\text{RMS}_k = \sqrt{\frac{1}{|\Omega_k|} \sum_{(n,\ell) \in \Omega_k} (x_{n,\ell,k}^{(g)} - x_{n,\ell,k}^{(u)})^2},$$

όπου Ω_k είναι το σύνολο των έγκυρων παρατηρήσεων για το χαρακτηριστικό k . Αν το καθοδηγούμενο ζεύγος είναι οι κόμβοι (i, j) , η εκλεκτικότητα ορίζεται ως:

$$\text{selectivity} = \frac{\frac{1}{2}(\text{RMS}_i + \text{RMS}_j)}{\frac{1}{|\mathcal{V}_{\text{off}}|} \sum_{k \in \mathcal{V}_{\text{off}}} \text{RMS}_k},$$

όπου $\mathcal{V}_{\text{off}}$ είναι το σύνολο των μη καθοδηγούμενων κόμβων. Τιμές μεγαλύτερες της μονάδας υποδεικνύουν στοχευμένα και ελεγχόμενη καθοδήγηση, ενώ τιμές μικρότερες δείχνουν διαρροή προς άλλες περιοχές του δικτύου.

Διαρροή Εκτός Στόχου (Spill off-target). Η διαρροή εκτός στόχου εκφράζει το μέσο μέγεθος των μεταβολών που παρατηρούνται στις υπόλοιπες ακμές του υπογραφήματος, πέρα από την καθοδηγούμενη ακμή. Για έναν πίνακα μεταβολών Δ στο υπογράφημα, αν (i, j) είναι η καθοδηγούμενη ακμή, τότε η μετρική ορίζεται ως:

$$\text{spill}_{i,j} = \frac{1}{|\mathcal{E}_{\text{off}}|} \sum_{(a,b) \in \mathcal{E}_{\text{off}}} |\Delta_{a,b}|,$$

όπου $\mathcal{E}_{\text{off}}$ είναι το σύνολο όλων των ακμών εκτός της (i, j) . Η μετρική αυτή λειτουργεί ως δείκτης «παράπλευρης επίδρασης» της καθοδήγησης: χαμηλές τιμές αντιστοιχούν σε καθαρά τοπική παρέμβαση, ενώ υψηλές τιμές υποδηλώνουν ότι η παρέμβαση επηρεάζει ευρύτερα το σύστημα.

Ευθυγράμμιση (Alignment). Η μετρική της ευθυγράμμισης αποτελεί σημαντικό κριτήριο κατανόησης του τρόπου με τον οποίο η καθοδήγηση αλληλεπιδρά με τη γνώση που έχει αποκτήσει το μοντέλο μέσω της εκπαίδευσης. Σκοπός της είναι να ποσοτικοποιήσει το κατά πόσο οι αλλαγές που προκαλεί η καθοδήγηση συμφωνούν ή αποκλίνουν από τη δομή αναμενόμενων συσχετίσεων που το μοντέλο έχει ήδη μάθει μέσω της εκπαίδευσης. Με άλλα λόγια, η ευθυγράμμιση δείχνει αν το μοντέλο συνεργάζεται με την καθοδήγηση, ή αν αντιδρά ενισχύοντας διαφορετικά μοτίβα από αυτά που επιβάλλει το σήμα καθοδήγησης.

Η διαδικασία υπολογισμού της βασίζεται σε τρία διαδοχικά στάδια:

1. **Υπολογισμός των διαφορών συσχέτισης (Δ).** Για κάθε ένταση καθοδήγησης ($w = \{-0.7, -0.3, +0.3, +0.7\}$) συγκρίνονται οι πίνακες συσχετίσεων του καθοδηγούμενου και μη καθοδηγούμενου μοντέλου:

$$\Delta^{(w)} = C_g^{(w)} - C_u.$$

Κάθε στοιχείο $\Delta_{a,b}^{(w)}$ δείχνει πόσο μεταβλήθηκε η συσχέτιση μεταξύ των χαρακτηριστικών a, b λόγω καθοδήγησης με βάρος w .

2. **Κατασκευή των πινάκων αναμενόμενης μεταβολής (E).** Για κάθε ζεύγος καθοδήγησης (i, j) και βάρος w , αξιοποιείται ο αρχικός πίνακας συσχετίσεων (χωρίς καθοδήγηση) C_0 και εφαρμόζεται πολυ-βηματική διάχυση συσχέτισης (multi-hop propagation) για την παραγωγή ενός πίνακα αναμενόμενων επιδράσεων:

$$E_{a,b}^{(w)} = f_{mh}(C_0, i, j, w) = (u_a^{(w)} \cdot u_b^{(w)}),$$

όπου το διάνυσμα $u^{(w)}$ εκφράζει την αναμενόμενη κατεύθυνση επιρροής κάθε κόμβου με βάση τη δομή των αρχικών συσχετίσεων και το πρόσημο του w . Ο πίνακας $E^{(w)}$ λειτουργεί ως χάρτης του τι θα έπρεπε να αλλάξει στο δίκτυο, αν η καθοδήγηση ακολουθούσε πιστά τη στατιστική τοπολογία του συστήματος.

3. **Υπολογισμός της Ευθυγράμμισης (A).** Στο τελικό στάδιο συγκρίνονται, στοιχείο προς στοιχείο, οι πραγματικές μεταβολές $\Delta^{(w)}$ με τις αναμενόμενες $E^{(w)}$, ώστε να προκύψει ο πίνακας ευθυγράμμισης:

$$A^{(w)} = 1 - |\Delta^{(w)} - E^{(w)}|.$$

Τιμές $A_{a,b}^{(w)} \approx 1$ σημαίνουν ότι η μεταβολή στην ακμή (a, b) είναι σύμφωνη με την αναμενόμενη συμπεριφορά, ενώ τιμές κοντά στο μηδέν δείχνουν ότι η καθοδήγηση προκάλεσε αναστροφή ή ασυνεπή μεταβολή σε σχέση με τις εσωτερικές συσχετίσεις του μοντέλου.

Η ευθυγράμμιση επομένως δεν αξιολογεί μόνο την επιτυχία της καθοδήγησης ως προς το να αλλάξει τις συσχετίσεις, αλλά και το αν αυτές οι αλλαγές είναι *συνεπείς* με τις συσχετιστικές γνώσεις που έχει μάθει το μοντέλο από τα δεδομένα εκπαίδευσης. Παρατηρώντας πώς η ευθυγράμμιση μεταβάλλεται μεταξύ διαφορετικών βαρών w , είναι δυνατόν να εκτιμηθεί πόσο ανθεκτικό ή συνεργάσιμο είναι το μοντέλο σε καθοδηγούμενες παρεμβάσεις, δηλαδή κατά πόσο η καθοδήγηση ευθυγραμμίζεται ή συγκρούεται με τη στατιστική δομή που έχει μάθει.

Algorithm 1 Υπολογισμός Πινάκων Ευθυγράμμισης ανά Βάρος Καθοδήγησης

Require: Πίνακας συσχετίσεων χωρίς καθοδήγηση C_u , λίστα βαρών καθοδήγησης $\mathcal{W}$, ζεύγη καθοδήγησης $\mathcal{P}$

- 1: **for** κάθε βάρος $w \in \mathcal{W}$ **do**
- 2: **Υπολόγισε** πίνακα συσχετίσεων με καθοδήγηση $C_g^{(w)}$
- 3: **Δημιούργησε** πίνακα διαφορών $\Delta^{(w)} = C_g^{(w)} - C_u$
- 4: **for** κάθε ζεύγος καθοδήγησης $(i, j) \in \mathcal{P}$ **do**
- 5: **Εφάρμοσε** πολυ-βηματική διάχυση σε C_u για παραγωγή $E^{(w)}$
- 6: **Υπολόγισε** πίνακα ευθυγράμμισης:

$$A^{(w)} = 1 - |\Delta^{(w)} - E^{(w)}|$$

- 7: **Αποθήκευσε** $A^{(w)}$
 - 8: **return** Όλους τους πίνακες ευθυγράμμισης $\{A^{(w)}\}$
-

Αλγόριθμος Υπολογισμού Ευθυγράμμισης. Η παραπάνω διαδικασία παράγει έναν πίνακα ευθυγράμμισης για κάθε τιμή βαρών καθοδήγησης w , επιτρέποντας την οπτικοποίηση της σχέσης μεταξύ πραγματικών και αναμενόμενων μεταβολών στο χώρο των συσχετίσεων. Η μετρική αυτή λειτουργεί τελικά ως παράθυρο προς το εσωτερικό του μοντέλου, αποκαλύπτοντας σε ποιο βαθμό η συμπεριφορά του υπό καθοδήγηση αντανακλά την εκμάθηση των στατιστικών εξαρτήσεων που απέκτησε κατά την εκπαίδευση.

Μέρος III

Πειραματικό Μέρος

Κεφάλαιο 4

Δημιουργία Συνόλων Δεδομένων

Πριν εστιάσουμε στη δημιουργία των δικών μας συνόλων δεδομένων, είναι χρήσιμο να παρουσιαστεί συνοπτικά το πώς τα μοντέλα διάχυσης εφαρμόζονται σε διαφορετικούς τύπους δεδομένων. Η μηχανική της διάχυσης είναι ενιαία και ανεξάρτητη από το πεδίο εφαρμογής ωστόσο, η μορφή του δείγματος x_0 και η αρχιτεκτονική που υλοποιεί την αντίστροφη διαδικασία προσαρμόζονται στη γεωμετρία και τις ιδιαιτερότητες κάθε κατηγορίας δεδομένων όπως εικόνες, ήχο, κείμενο, χρονοσειρές. Με αυτόν τον τρόπο μπορούμε να εντοπίσουμε πώς η ίδια θεωρία μετασχηματίζεται όταν το πρόβλημα μεταφέρεται από τα διδιάστατα δεδομένα εικόνες στα μονοδιάστατα σήματα χρόνου. Έτσι, προετοιμάζει το έδαφος για τα επόμενα υποκεφάλαια, όπου περιγράφουμε τα σύνολα χρονοσειρών που χρησιμοποιούνται στην παρούσα εργασία (BabySlakh, Lorenz-96, PEMS-SF) και τον τρόπο με τον οποίο προσαρμόστηκε η διαδικασία διάχυσης σε αυτά.

4.1 Δεδομένα και Αναπαραστάσεις

Η βασική μηχανική της διάχυσης είναι κοινή σε κάθε τύπο δεδομένων όπως έχουμε περιγράψει η προώθηση θορύβου υλοποιείται από το βήμα (1) και η ισοδύναμη μορφή επαναμετροποίηση από την (8), ενώ η αντίστροφη ροή μαθαίνεται όπως αναλύθηκε στο Κεφ. 2.1.2. Αυτό που διαφοροποιείται ανά πεδίο είναι η αναπαράσταση του δείγματος x_0 και η αρχιτεκτονική του παραμετρικού μοντέλου που προσεγγίζει την αντίστροφη κατανομή. Παρακάτω συνοψίζουμε τις κυριότερες κατηγορίες, με έμφαση στο πώς η ίδια θεωρία προσαρμόζεται στη γεωμετρία κάθε δεδομένου.

Εικόνες

Κάθε δείγμα αναπαρίσταται ως τανυστής $x_0 \in \mathbb{R}^{H \times W \times 3}$. Η αντίστροφη ροή υλοποιείται συνήθως με U-Net πολυκλίμακας ανάλυσης και self-attention, με conditioning (π.χ. ετικέτες, κείμενο) μέσω cross-attention ή feature modulation. Τα DDPM και Improved DDPM κατέδειξαν υψηλή ποιότητα και σταθερότητα, ενώ τα latent diffusion models μετέφεραν τη διάχυση σε λανθάνοντα χώρο, μειώνοντας το υπολογιστικό κόστος [12, 27, 31, 7]. Νεότερες προσεγγίσεις με Diffusion Transformers αντικαθιστούν τις συνελίξεις με self-attention σε όλο το δίκτυο, διατηρώντας την ίδια στοχαστική θεμελίωση

Ήχος και Κυματομορφές

Για μονοδιάστατα σήματα $x_0 \in \mathbb{R}^T$, η διάχυση εφαρμόζεται απευθείας στο waveform ή σε φασματογραφικές αναπαραστάσεις. Τα DiffWave και συναφή μοντέλα έδειξαν ότι η ίδια απώλεια και ο ίδιος αντίστροφος μηχανισμός μπορούν να παράγουν φυσικό ήχο όταν η αρχιτεκτονική προσαρμόζεται σε μεγάλα receptive fields και διατήρηση φάσης [20]. Η πρακτική διαφορά είναι στην υλοποίηση του $\epsilon_\theta(x_t, t)$ (1D dilated CNNs, temporal attention)· η θεωρία παραμένει αυτή των (1)–(8).

Κείμενο και Συμβολικές Αναπαραστάσεις

Επειδή τα tokens είναι διακριτά, τα σύμβολα χαρτογραφούνται σε embeddings $e_i \in \mathbb{R}^d$ και η διάχυση εκτελείται σε συνεχές embedding space, με τελική αποδιακριτοποίηση κατά τη δειγματοληψία. Η προσέγγιση Diffusion-LM έδειξε ότι η ίδια στοχαστική αντιστροφή μπορεί να επιβάλει συντακτική και σημασιολογική συνέπεια μέσω κατάλληλου conditioning και decoding [21, 4]. Οι σχέσεις με score matching και continuous-time θέσεις εντός του πλαισίου της (1) και των continuous αντιστοιχίσεων [34].

Γράφοι και Δεδομένα Σχέσεων

Σε δομές κόμβων-ακμών η διάχυση δρα πάνω σε A και/ή X , με αντίστροφο μοντέλο που σέβεται αναλλοιωσιμότητες γραφήματος. GNN-βασισμένες υλοποιήσεις της αντιστροφής ροής παράγουν έγκυρες δομές σε προβλήματα όπως μοριακή σχεδίαση [15, 18]. Η θεωρητική ισοδυναμία με το πρότυπο forward βήμα (1) διατηρείται· αλλάζει μόνο η γεωμετρία και το inductive bias του ϵ_θ .

Βίντεο και Χωροχρονικά Δεδομένα

Τα βίντεο επεκτείνουν την εικόνα με χρονική διάσταση $x_0 \in \mathbb{R}^{H \times W \times T}$. Η αντίστροφη διαδικασία απαιτεί ταυτόχρονη χωρική-χρονική συνέπεια, επιτυγχανόμενη με 3D convolutions ή spatiotemporal transformers. Τα Video Diffusion Models και τα Latent Video Diffusion δείχνουν ότι η ίδια αντιστροφή μπορεί να ολοκληρωθεί αποτελεσματικά σε λανθάνοντα χώρο, με cross-attention για ισχυρό conditioning [14, 31].

Χρονοσειρές και Δεδομένα Ροών

Για πολυμεταβλητές ακολουθίες $x_0 \in \mathbb{R}^{K \times L}$, η θεωρία της διάχυσης εφαρμόζεται αυτούσια, όμως οι ισχυρές χρονικές εξαρτήσεις, η μη-στασιμότητα και οι μάσκες παρατήρησης απαιτούν ειδικές αρχιτεκτονικές. Παραλλαγές Temporal U-Net, TCN και Transformer-based μοντέλων με time embeddings και conditioning σε μάσκες/γνωστές τιμές, όπως στα CSDI, έχουν δώσει πολύ ενθαρρυντικά αποτελέσματα για imputation, generation και forecasting [35, 39, 40]. Η εκπαίδευση και δειγματοληψία ακολουθούν τις ίδιες αρχές των (1)–(8) και των αντίστοιχων αντιστροφών (βλ. Κεφ. 2.1.2, 2.1.3), με κατάλληλο conditioning ώστε το $\epsilon_\theta(x_t, t, \text{cond})$ να σεβαστεί την αιτιότητα και τα κενά παρατήρησης.

4.2 Χρονοσειρές: Προκλήσεις και Δομή

Οι χρονοσειρές αποτελούν ένα ξεχωριστό και απαιτητικό πεδίο για τη μοντελοποίηση στα μοντέλα διάχυσης καθώς σε αντίθεση με τις εικόνες ή το κείμενο, όπου τα δείγματα θεωρούνται ως ανεξάρτητα χωρικά tokens, μια χρονοσειρά είναι στοχαστική διαδικασία με χρονική εξάρτηση:

$$x_0 = \{x_{k,\ell}\}_{k=1..K, \ell=1..L} \in \mathbb{R}^{K \times L}, \quad (71)$$

όπου K είναι ο αριθμός μεταβλητών και L ο αριθμός χρονικών δειγμάτων. Κάθε μεταβλητή εξελίσσεται υπό λανθάνουσα δυναμική που μπορεί να συσχετίζεται με άλλες τόσο στο χρόνο όσο και στο χαρακτηριστικό, επιβάλλοντας δομικούς περιορισμούς που απουσιάζουν από ανεξάρτητα δεδομένα [39]. Επομένως η υπόθεση ανταλλαξιμότητας καταρρέει κατά μήκος του χρόνου και για αυτόν τον λόγο η εκπαίδευση diffusion μοντέλων απαιτεί ειδική αντιμετώπιση της σειράς (π.χ. χρονικά embeddings ή μάσκες) ώστε να διατηρείται η χρονική συνοχή και να αποφεύγονται ψευδείς αιτιότητες [39].

Πολυκαναλικές Συσχετίσεις Στην πράξη, πολλές χρονοσειρές όπως ενεργειακά δίκτυα, βιοσήματα ή και πολυκαναλικός ήχος περιλαμβάνουν συσχετισμένες μεταβλητές που μετρώνται ταυτόχρονα. Η διαχρονική συσχέτιση μεταξύ καναλιών αποτυπώνεται με πίνακα συσχέτισης:

$$C_{ij} = \text{corr}(x_i, x_j), \quad (72)$$

ο οποίος μπορεί να είναι συμμετρικός υποδεικνύοντας συσχέτιση ή κατευθυνόμενος εκδηλώνοντας την αιτιακή επίδραση ανάμεσα στα συμμετέχοντα κανάλια. Η ορθή γενετική μοντελοποίηση απαιτεί κοινή εκτίμηση αυτών των εξαρτήσεων. Συνήθως χρησιμοποιούνται χρονικά CNN, transformers με προσοχή στα χαρακτηριστικά, ή γράφους συσχέτισης (graph-guided diffusion) για να συλλάβουν τέτοιες δομές [35, 39].

Ακανόνιστη Δειγματοληψία και Ελλείψεις Οι πραγματικές χρονοσειρές σπάνια είναι ομοιόμορφα δειγματοληπτημένες καθώς συχνά αισθητήρες αποτυγχάνουν, διαστήματα ποικίλλουν, και μετρήσεις έρχονται ασύγχρονα. Τα diffusion μοντέλα προσαρμόζονται μέσω:

- δυαδικών μασκών για παρατηρούμενα/ελλείποντα σημεία,
- ενσωμάτωσης χρονικών δεικτών (time-stamp embeddings),
- αντικειμένων αποκατάστασης (conditional imputation objectives) που εκπαιδεύουν το μοντέλο να αναδομεί τα δεδομένα που λείπουν

Αυτές οι τεχνικές επιτρέπουν στα diffusion μοντέλα να λειτουργούν τόσο για παραγωγή όσο και για αποκατάσταση ή πρόβλεψη [35].

Μη Στασιμότητα και Μεταβλητή Κλίμακα Η στατιστική κατανομή μιας χρονοσειράς μπορεί να μεταβάλλεται με το χρόνο (τάση, εποχικότητα, απότομες αλλαγές). Κατά συνέπεια, το χρονοδιάγραμμα θορύβου $\{\beta_t\}$ και η κανονικοποίηση πρέπει να προσαρμόζονται στη τοπική διακύμανση. Συνήθεις τεχνικές περιλαμβάνουν τυποποίηση ανά χαρακτηριστικό, απομάκρυνση τάσης, ή προσαρμόσιμα επίπεδα κανονικοποίησης όπως adaptive instance normalization [39].

Αιτιότητα και Κατεύθυνση Πρόβλεψης Ιδιαίτερο χαρακτηριστικό των χρονοσειρών είναι η αιτιακή κατεύθυνση καθώς το μέλλον δεν πρέπει να επηρεάζει το παρελθόν. Αν και η προώθηση διάχυσης είναι συμμετρική, η αντίστροφη διαδικασία αποθρομβοποίησης πρέπει να εφαρμόζεται υπό μάσκα ή συνθήκη που σέβεται την αιτιακή διάταξη. Για προβλέψεις, το μοντέλο μαθαίνει:

$$p_{\theta}(x_{\text{future}} \mid x_{\text{past}}), \quad (73)$$

και οι μηχανισμοί καθοδήγησης διασφαλίζουν ότι μόνο το επιτρεπτό πλαίσιο δηλαδή το παρελθόν ή παρατηρημένα δεδομένα επηρεάζει τη διαδικασία [35, 39].

Η αξιολόγηση της ποιότητας δειγμάτων χρονοσειρών διαφέρει ουσιωδώς από εκείνη αντιληπτικών περιοχών όπως οι εικόνες. Στις χρονοσειρές, η έμφαση μετατοπίζεται σε χρονικές και φασματικές μετρικές που αποτυπώνουν τη δυναμική συνοχή του σήματος, ενώ τα σφάλματα πρόβλεψης όπως RMSE και CRPS, η φασματική ομοιότητα και οι δια-καναλικές συσχετίσεις παραμένουν κρίσιμα για τη δομική συνέπεια [39].

Οι ιδιαιτερότητες αυτές καθιστούν τις χρονοσειρές ένα απαιτητικό αλλά συναρπαστικό πεδίο εφαρμογής για τα diffusion models. Οι χρονικές εξαρτήσεις απαιτούν εξειδικευμένες χρονικές ή Fourier embeddings, ενώ η συσχετισμένη δομή των χαρακτηριστικών υποδεικνύει την ανάγκη για προσοχή ανά χαρακτηριστικό ή γραφο-καθοδηγούμενη διάχυση. Επιπλέον, η ακανόνιστη ή ελλιπής δειγματοληψία επιβάλλει μάσκες υπό όρους τόσο στην εκπαίδευση όσο και στη δειγματοληψία. Παρότι η βασική μαθηματική διατύπωση παραμένει η ίδια, η προσαρμογή της στα χαρακτηριστικά της ακολουθιακής δομής είναι απαραίτητη για σταθερή και ερμηνεύσιμη μοντελοποίηση [35, 39].

4.3 Πειραματικά Σύνολα Δεδομένων

Αφού περιγράψαμε τις γενικές αρχές και προκλήσεις των χρονοσειρών, το επόμενο βήμα είναι η πρακτική διαμόρφωση των συνόλων δεδομένων πάνω στα οποία θα εφαρμοστεί το προτεινόμενο πλαίσιο διάχυσης. Η διαδικασία αυτή περιλαμβάνει την επιλογή κατάλληλων πηγών, την απομόνωση υποσυνόλων που διαθέτουν επαρκή πολυκαναλική δομή και χρονική συνέπεια, καθώς και την προσαρμογή των ρυθμών δειγματοληψίας, της κανονικοποίησης και της μορφής αποθήκευσης. Με τον τρόπο αυτό, μετατρέπουμε πολύπλοκα ηχητικά ή φυσικά δεδομένα σε τυποποιημένες πολυμεταβλητές χρονοσειρές, κατάλληλες για εκπαίδευση και αξιολόγηση σε time-series diffusion models [12, 35].

Η μεθοδολογία αυτή εφαρμόστηκε σε τρεις διαφορετικές κατηγορίες δεδομένων: (α) σε πολυκαναλά μουσικά stems από το BabySlakh [26, 25], (β) σε συνθετικές χρονοσειρές από το δυναμικό σύστημα Lorenz-96 [24], και (γ) σε πραγματικά κυκλοφοριακά δεδομένα από το PEMS-SF [6]. Για κάθε σύνολο δεδομένων περιγράφεται η διαδικασία προεπεξεργασίας, η μείωση ρυθμού δειγματοληψίας (π.χ. από 44.1 kHz σε 50 Hz με polyphase resampling [38]), η κανονικοποίηση ως προς την αντιληπτή στάθμη LUFS σύμφωνα με το πρότυπο ITU-R BS.1770-5 [16], και η τελική δομή των πολυμεταβλητών χρονοσειρών που προκύπτουν.

4.3.1 Μουσική — BabySlakh (Track 1)

Σε αυτήν την ενότητα περιγράφουμε τη διαδικασία κατασκευής χρονοσειρών από πολυκάναλα μουσικά stems του BabySlakh (Track 1), με σκοπό τη χρήση σε μοντέλα time-series diffusion. Το BabySlakh είναι υποσύνολο του Slakh2100 [26, 25], το οποίο δημιουργείται από το Lakh MIDI Dataset [29]. Επειδή οι ακατέργαστες κυματομορφές βρίσκονται στα 44.1 kHz, εφαρμόζουμε υποδειγματοληψία προς 50 Hz ώστε να προκύψουν διαχειρίσιμες χρονοσειρές ανά stem. Η polyphase resampling υλοποιείται με SciPy [38], ενώ η στόχευση σε LUFS ακολουθεί το πρότυπο ITU-R BS.1770-5 [16].

Μεταδεδομένα Track 1 Παρακάτω παραθέτουμε τα βασικά μεταδεδομένα που χρησιμοποιήθηκαν στην προεπεξεργασία (όπως εξήχθησαν από το έργο):

- **UUID:** 1a81ae092884234f3264e2f45927f00a
- **audio_dir:** stems, **midi_dir:** MIDI
- **lmd_midi_dir:** lmd_matched/0/0/H/TR00HTB128F931F9DF/1a81ae092884234f3264e2f45927f00a.mid
- **normalized:** true, **normalization_factor:** -13.0 LUFS
- **overall_gain:** 0.18270259567062658, **target_peak:** -1.0 dBFS

Stems

Stem	inst_class	midi_program_name	plugin_name	Loud. (dB)
S00	Guitar	Distortion Guitar	elektrik_guitar.nkm	-12.821
S01	Drums	Drums	session_kit_full.nkm	-27.130
S02	Piano	Bright Acoustic Piano	the_giant_modern_studio.nkm	-16.591
S03	Bass	Electric Bass (finger)	scarbee_rickenbacker_bass_palm_muted.nkm	-21.676
S04	Strings	Choir Aahs	choir_o.nkm	-17.158
S05	Organ	Percussive Organ	fever.nkm	-16.601
S06	Guitar	Electric Guitar (jazz)	jazz_guitar2.nkm	-16.397
S07	Guitar	Distortion Guitar	elektrik_guitar.nkm	-14.950
S08	Organ	Harmonica	transistor_compact.nkm	-15.015
S09	Organ	Harmonica	transistor_compact.nkm	-17.267

Πίνακας 8: Μεταδεδομένα stems για το Track 1. Το πεδίο Loud. αναπαριστά την ολοκληρωμένη στάθμη (integrated loudness, dB LUFS).

Η διαδικασία προετοιμασίας των μουσικών stems στοχεύει στη δημιουργία μιας ενιαίας πολυκαναλικής χρονοσειράς κατάλληλης για χρήση σε μοντέλα time-series diffusion. Αφετηρία αποτελούν οι αρχικές κυματομορφές των καναλιών, οι οποίες επεξεργάζονται μέσω υποδειγματοληψίας, κανονικοποίησης και επανασύνθεσης, ώστε να προκύψει μια ομοιογενής τανυστική αναπαράσταση.

Στόχος Αναπαράστασης. Η τελική μορφή των δεδομένων είναι ένας τανυστής

$$x_0 \in \mathbb{R}^{K \times L}, \quad K = 10 \text{ (stems)}, \quad L = 50 T,$$

όπου T είναι η διάρκεια σε δευτερόλεπτα και ο ρυθμός δειγματοληψίας έχει οριστεί στα 50 Hz. Κάθε γραμμή του πίνακα αντιστοιχεί σε ένα κανάλι ή stem, και κάθε στήλη σε διαδοχικά δείγματα στον χρόνο. Με αυτόν τον τρόπο επιτυγχάνεται μια συνεκτική μορφή εισόδου για το μοντέλο διάχυσης, κοινή για όλα τα κανάλια.

Υποδειγματοληψία και Μετασχηματισμός Ρυθμού. Οι αρχικές κυματομορφές $s_k[n]$ καταγράφονται σε υψηλό ρυθμό δειγματοληψίας $f_s = 44.1$ kHz. Για να παραχθούν διαχειρίσιμες χρονοσειρές, ο ρυθμός αυτός μειώνεται στα $\tilde{f}_s = 50$ Hz μέσω υποδειγματοληψίας με αντι-παραμόρφωση (anti-aliasing). Η διαδικασία περιγράφεται ως:

$$\tilde{s}_k[m] = (s_k * h_{LP})|_{n=m \cdot R}, \quad R = \frac{f_s}{\tilde{f}_s} = \frac{44100}{50} = 882,$$

όπου h_{LP} είναι χαμηλοπερατό φίλτρο με συχνότητα αποκοπής ≤ 25 Hz. Στην πράξη εφαρμόζεται ακριβής polyphase resampling [38], ώστε να διατηρηθεί η χρονική πιστότητα και η ενεργειακή ισορροπία του σήματος.

Κανονικοποίηση Εντάσεων. Μετά τη μετατροπή του ρυθμού, κάθε κανάλι κανονικοποιείται ως προς τη συνολική ακουστική στάθμη σύμφωνα με το πρότυπο LUFS, με στόχο τα -13 LUFS. Η κανονικοποίηση αυτή εξασφαλίζει ότι όλα τα stems συμβάλλουν ισότιμα στη συνολική δυναμική, ανεξάρτητα από το αρχικό επίπεδο ηχογράφησης. Η μέγιστη τιμή περιορίζεται στο -1.0 dBFS, ώστε να αποφεύγεται υπερφόρτωση του φάσματος, σύμφωνα με το πρότυπο ITU-R BS.1770-5 [16].

Συναρμολόγηση Πολυκαναλικού Τανυστή. Μετά την υποδειγματοληψία και κανονικοποίηση, τα δέκα επεξεργασμένα κανάλια συνενώνονται χρονικά σε έναν πολυδιάστατο πίνακα:

$$x_0 = \begin{bmatrix} \tilde{s}_1[0] & \tilde{s}_1[1] & \cdots & \tilde{s}_1[L-1] \\ \tilde{s}_2[0] & \tilde{s}_2[1] & \cdots & \tilde{s}_2[L-1] \\ \vdots & \vdots & \ddots & \vdots \\ \tilde{s}_{10}[0] & \tilde{s}_{10}[1] & \cdots & \tilde{s}_{10}[L-1] \end{bmatrix} \in \mathbb{R}^{10 \times L}.$$

Η διάταξη αυτή καθιστά κάθε γραμμή ανεξάρτητη χρονοσειρά, επιτρέποντας την ταυτόχρονη επεξεργασία όλων των stems μέσα σε ενιαίο πλαίσιο διάχυσης.

Δομή Παραθύρων και Μασκών. Κατά τη φάση της εκπαίδευσης, το τανυστικό σήμα τεμαχίζεται σε παράθυρα σταθερού μήκους $L_w = 50 \cdot \Delta t$, όπου Δt είναι η διάρκεια του παραθύρου σε δευτερόλεπτα. Για κάθε παράθυρο ορίζεται μια δυαδική μάσκα παρατήρησης $M_O \in \{0, 1\}^{K \times L_w}$, η οποία προσδιορίζει ποια χρονικά σημεία θεωρούνται γνωστά και ποια θα προβλεφθούν από το μοντέλο. Η ομογενοποίηση των δεδομένων πραγματοποιείται με κανονικοποίηση τύπου z-score, χρησιμοποιώντας τα στατιστικά μ και σ κάθε καναλιού. Τα παραγόμενα σύνολα αποθηκεύονται σε αρχεία .pkl (main_data.pkl, mask_data.pkl, meanstd.pkl), ώστε να μπορούν να φορτωθούν απευθείας από το δίκτυο διάχυσης.

Η παραπάνω διαδικασία διασφαλίζει ότι τα δεδομένα εισόδου είναι πλήρως ευθυγραμμισμένα, ομοιοκανονικοποιημένα και αριθμητικά σταθερά, επιτρέποντας την εκπαίδευση του μοντέλου σε πολυκαναλικές ροές με συνεπή χρονική και φασματική ανάλυση.

Algorithm 2 Αγωγός Προεπεξεργασίας BabySlakh $\rightarrow$ Χρονοσειρές 50 Hz

- 1: **Είσοδος:** λίστα stems $S = \{S00, \dots, S09\}$, $f_s = 44.1$ kHz, στόχος $\tilde{f}_s = 50$ Hz
 - 2: **for all** $k \in S$ **do**
 - 3: φόρτωσε κυματομορφή s_k (διατήρησε gain/LUFS)
 - 4: anti-alias LPF $\rightarrow$ polyphase resampling σε $\tilde{f}_s$
 - 5: κλιμάκωσε ώστε $\text{peak} \leq -1.0$ dBFS
 - 6: στόχισε $x_0 \in \mathbb{R}^{K \times L}$, τεμάχισε σε παράθυρα L_w
 - 7: υπολόγισε μ, σ ανά κανάλι, αποθήκευσε (data, masks, meanstd) σε .pkl
-

Σχήμα δεδομένων (παράδειγμα). Για $T = 60$ s και $K = 10$: $L = 3000$ και για παράθυρο 10 s $\Rightarrow L_w = 500$.

Δομή και Χαρακτηριστικά του Συνόλου data.pkl Η αποθήκευση των δεδομένων πραγματοποιείται σε ενιαία μορφή, ώστε να διασφαλίζεται η συνέπεια μεταξύ χρονοσειρών, μασκών και χρονικών ευθυγραμμίσεων. Κάθε αρχείο data.pkl περιέχει τόσο τις τιμές των σημάτων όσο και τις αντίστοιχες μάσκες παρατήρησης, με στόχο τη γρήγορη φόρτωση και άμεση χρήση από το μοντέλο διάχυσης.

Δομή και Μορφή Αποθήκευσης. Το περιεχόμενο του αρχείου ορίζεται ως ένα *tuple* δύο στοιχείων (X, M) , όπου τα δύο μέλη έχουν κοινή διάσταση και χρονική στοίχιση:

$$X \in \mathbb{R}^{14400 \times 20}, \quad M \in \mathbb{R}^{14400 \times 20}.$$

Ο πίνακας X διαχωρίζεται σε δύο υποσύνολα στηλών:

$$X = [X_{\text{data}} \mid X_{\text{mask}}], \quad X_{\text{data}} \in \mathbb{R}^{14400 \times 10}, \quad X_{\text{mask}} \in \mathbb{R}^{14400 \times 10}.$$

Η οργάνωση αυτή επιτρέπει την παράλληλη αποθήκευση των ίδιων πληροφοριών τόσο υπό μορφή δεδομένων όσο και ως μάσκες, διευκολύνοντας τον ορισμό παρατηρούμενων και μη παρατηρούμενων σημείων σε κοινό πίνακα.

Πιο αναλυτικά:

- X_{data} : περιέχει τις πραγματικές τιμές των δέκα καναλιών χρονοσειρών (ένα για κάθε stem S00–S09 του Πίνακα 8).
- X_{mask} : αποτελεί αντιγραφή της μάσκας παρατήρησης, ώστε οι τελευταίες δέκα στήλες του X να αντικατοπτρίζουν τη χρονική πληρότητα των δεδομένων.
- M : αντιστοιχεί σε μάσκα ίδιας μορφής (14400×20) με το X , και στην παρούσα εκδοχή είναι πλήρως παρατηρημένη, δηλαδή όλες οι τιμές είναι ίσες με 1.

Η συγκεκριμένη μορφή αποθήκευσης παρέχει απλότητα στην ανακατασκευή των εισόδων, εξασφαλίζοντας ταυτόχρονα κοινό χρονικό δείκτη για όλα τα κανάλια.

Συχνότητα, Διακριτοποίηση και Διάρκεια. Το σύνολο δεδομένων έχει ρυθμό δειγματοληψίας 50 Hz, γεγονός που συνεπάγεται χρονικό βήμα

$$\Delta t = \frac{1}{50} = 0.02 \text{ s.}$$

Με συνολικό πλήθος 14400 δειγμάτων, η διάρκεια της κάθε χρονοσειράς προκύπτει ως:

$$T_{\text{tot}} = \frac{14400}{50} = 288 \text{ s} \approx 4.8 \text{ min.}$$

Η επιλογή του συγκεκριμένου ρυθμού επιτρέπει επαρκή χρονική ανάλυση, ενώ παραμένει υπολογιστικά αποδοτική για τα μοντέλα διάχυσης που επεξεργάζονται παραθυρικά τμήματα δεδομένων.

Ιδιότητα	Τιμή / Περιγραφή
Συχνότητα	50 Hz
Διακριτοποίηση	$\Delta t = 0.02 \text{ s}$
Δείγματα (χρόνος)	14400
Διάρκεια	$288 \text{ s} \approx 4.8 \text{ min}$
Κανάλια δεδομένων	10 (stems S00–S09)
Σχήμα X	14400×20
Σχήμα M	14400×20
Τύπος δεδομένων	float32
Κανονικοποίηση	[0, 1] (με z-score διαθέσιμο μέσω μ, σ)
Μάσκα	πλήρης παρατήρηση (τιμές 1)
Μορφή αποθήκευσης	pickle $\rightarrow$ tuple (X, M)

Πίνακας 9: Σύνοψη διαστάσεων και ιδιοτήτων του data.pkl.

Συνοπτικές Διαστάσεις και Ιδιότητες.

Ερμηνεία Καναλιών. Κάθε μία από τις δέκα στήλες του X_{data} αντιστοιχεί σε μία ανεξάρτητη χρονοσειρά μήκους 14400 δειγμάτων, η οποία αναπαριστά το χρονικό αποτύπωμα ενός επιμέρους stem. Με αυτόν τον τρόπο το μοντέλο αποκτά πλήρη πρόσβαση στη δομή των μουσικών καναλιών, ενώ η ύπαρξη των αντίστοιχων μαस्कών επιτρέπει την ευέλικτη εφαρμογή σε σενάρια πρόβλεψης, συμπλήρωσης ή αποκατάστασης χρονοσειρών.

Η ενιαία αυτή δομή διασφαλίζει την απλότητα στη φόρτωση, την επεκτασιμότητα σε μεγαλύτερα δείγματα και τη σταθερότητα των εισόδων κατά τη φάση της εκπαίδευσης του μοντέλου διάχυσης.

4.3.2 Συνθετικό Σύνολο Lorenz-96

Το συνθετικό σύστημα Lorenz-96 αποτελεί κλασικό πρότυπο μη γραμμικού δυναμικού συστήματος [24]. Προσφέρει πολυμεταβλητές χρονοσειρές με κυκλικές αλληλεπιδράσεις μεταξύ γειτονικών μεταβλητών και χρησιμοποιείται ευρέως ως *τεχνητό εργαστήριο* για πρόγνωση και αξιολόγηση μοντέλων.

Μαθηματική Περιγραφή Με K μεταβλητές:

$$\frac{dx_k}{dt} = (x_{k+1} - x_{k-2})x_{k-1} - x_k + F, \quad k = 1, \dots, K,$$

με κυκλικές οριακές συνθήκες $x_{k+K} = x_k$. Η παράμετρος F ελέγχει τον βαθμό χάους· για $F \approx 8$ το σύστημα εμφανίζει έντονη χαοτική συμπεριφορά [24].

Διαμόρφωση Συνόλου Δεδομένων Παράχθηκε χρονοσειρά με $N=15$ μεταβλητές, ολοκλήρωση με $\Delta t=0.01$ και $F=8.0$, απορρίπτοντας ~ 2000 αρχικά βήματα (warm-up). Η υλοποίηση έγινε με ReservoirPy (datasets.lorenz96) [36]. Για ομοιομορφία με τα υπόλοιπα σύνολα, χρησιμοποιούμε αναδειγματοληψία/επαναχρονισμό στα 50 Hz για την ανάλυση.

- Πλήθος χρονικών δειγμάτων (μετά το warm-up): 14400.
- Για σκοπούς παρουσίασης/ανάλυσης κρατάμε τις 10 πρώτες μεταβλητές από τις 15 συνολικά.

Παραγόμενα αρχεία

Όνομα Αρχείου	Περιγραφή
lorenz96_N15_T...csv	Πίνακας $X_{t,k}$ (στήλες X00–X14).
data.pkl	main_data και mask_data ως tuple (X, M) .
meanstd.pkl	Μέσες τιμές και τυπικές αποκλίσεις ανά χαρακτηριστικό.

Δομή αρχείου data.pkl και σχήματα Το data.pkl αποθηκεύεται ως tuple (X, M) με κοινό χρονικό ευρετήριο:

$$X \in \mathbb{R}^{14400 \times 15}, \quad M \in \mathbb{R}^{14400 \times 15}.$$

Για την παρούσα ανάλυση χρησιμοποιούμε υποσύνολο 10 καναλιών (τις πρώτες 10 μεταβλητές):

$$X_{\text{use}} \in \mathbb{R}^{14400 \times 10}, \quad M_{\text{use}} \in \{0, 1\}^{14400 \times 10}.$$

Οι τιμές του M είναι 1 παντού (πλήρης παρατήρηση). Οι τύποι δεδομένων είναι float32.

Συχνότητα, βήμα χρόνου και διάρκεια Χρονική δειγματοληψία 50 Hz (για την ανάλυση), άρα

$$\Delta t = \frac{1}{50} = 0.02 \text{ s}, \quad T_{\text{tot}} = \frac{14400}{50} = 288 \text{ s} \approx 4.8 \text{ min}.$$

Ιδιότητα	Τιμή / Περιγραφή
Dataset	Lorenz-96 (συνθετικό δυναμικό σύστημα)
Πρωτογενείς μεταβλητές	$N=15$, $F=8$, $\Delta t_{\text{ODE}}=0.01$, warm-up ~ 2000
Χρήση στην ανάλυση	Πρώτες 10 μεταβλητές (υποσύνολο των 15)
Συχνότητα (ανάλυσης)	50 Hz, $\Delta t = 0.02 \text{ s}$
Δείγματα (χρόνος)	14400
Διάρκεια	$288 \text{ s} \approx 4.8 \text{ min}$
Σχήμα X (αρχείο)	14400×15 (float32)
Σχήμα X_{use} (ανάλυση)	14400×10
Μάσκα M	ίδιο σχήμα, όλες οι τιμές 1
Μορφή αποθήκευσης	pickle $\rightarrow$ tuple (X, M)

Πίνακας 10: Σύνοψη δομής και ιδιοτήτων του Lorenz-96 συνόλου για την παρούσα εργασία.

Συνοπτική περιγραφή

Το Lorenz-96 προσφέρει πολυκαναλική χρονοσειρά με πλήρη παρατήρηση, συμβατή με μοντέλα diffusion για χρονοσειρές, επιτρέποντας ελεγχόμενο έλεγχο ικανότητας μοντέλων να αποτυπώνουν χαοτικές αλληλεπιδράσεις.

4.3.3 Traffic — Σύνολο PEMS-SF

Το σύνολο PEMS-SF από το UCI Machine Learning Repository [6] αποτελεί πραγματικό παράδειγμα πολυμεταβλητής χρονοσειράς με χωροχρονική δομή, προερχόμενο από την πλατφόρμα Caltrans PeMS [3].

Χωρικό πλαίσιο και κύριοι διάδρομοι

Κύριοι διάδρομοι/κόμβοι δικτύου.


- US-101: 400000 (SR-37 @ US-101, Novato), 400001 (US-101-N), 400010 (US-101-N, San Bruno).
- I-80: 400009 (University Ave @ I-80-W, Berkeley/Alameda), 400027 (E of Carlson Blvd @ I-80-E, Richmond/Contra Costa).
- I-580: 400026 (Lakeshore Ave on-e-diag @ I-580-E, Oakland).
- I-680: 400025 (Newell Ave @ I-680-N, Walnut Creek/Contra Costa).
- I-880: 400030 (N First St rm-s-loop @ I-880-S, San Jose/Santa Clara).
- SR-85: 400017 (Bascom Ave @ SR-85-S, San Jose/Santa Clara).

Χωρικά clusters & αναμενόμενες ροές.

- **North Bay (Marin):** 400000 κοντά στον κόμβο SR-37/US-101, με συχνό «λαιμό μπουκαλιού».
- **West Bay/Peninsula:** 400010 (San Bruno @ US-101-N) για ροές προς/από SF.
- **East Bay, παραλιακό τόξο:** 400009 (Berkeley/I-80-W), 400026 (Oakland/I-580-E), 400027 (Richmond/I-80-E) — το τόξο MacArthur Maze–Berkeley–Richmond.
- **Inland East Bay:** 400025 (Walnut Creek/I-680-N) — άξονας βορρά–νότου εσωτερικού East Bay.
- **South Bay (San Jose):** 400001 (US-101-N), 400017 (SR-85-S), 400030 (I-880-S) — ισχυρή πρωινή εισροή και απογευματινή εκροή.

Κάλυψη κατευθύνσεων & χρήσεων. Οι επισημάνσεις -N/-S/-E/-W και οι on/off-ramps (π.χ. Lakeshore Ave on-e-diag) δείχνουν ότι το υποσύνολο δεν είναι μόνο mainline, αλλά και στρατηγικό σε εισόδους/εξόδους, χρήσιμο για ramp metering και bottleneck propagation. Το τρίγωνο US-101 ↔ I-80/I-580 ↔ I-880/SR-85 καλύπτει τον βασικό «δακτύλιο» μετακινήσεων Bay Area (Peninsula–East Bay–South Bay).

Αντιπροσωπευτικότητα. Υπάρχει κλίση προς South Bay/East Bay (7/10 σταθμοί). Η παρουσία Marin (SR-37/US-101) δίνει ορατότητα σε χρόνια επιβαρυμένο διάδρομο. Πιθανή επέκταση: I-280 (Peninsula) ή SR-92/San Mateo Bridge για πλήρη δακτύλιο.



Σχήμα 8: Ακριβείς θέσεις σταθμών PEMS-SF (lat/lon) για το υποσύνολο των 10 αισθητήρων.

Χάρτης σταθμών

Πηγή και Περιγραφή Παρέχει μετρήσεις σε ανάλυση 1 min στην αρχική του μορφή. Στην παρούσα εργασία χρησιμοποιείται υποσύνολο αισθητήρων και αναδειγματοληψία/επαναχρονισμός στα 50 Hz για ομοιομορφία με τα υπόλοιπα σύνολα και τα πειράματα time-series diffusion. Χρησιμοποιούνται οι 10 πρώτοι αισθητήρες.

Εντοπισμός Μεταδεδομένων Αισθητήρων Τα μεταδεδομένα εντοπίστηκαν μέσω της διαδικτυακής πύλης Caltrans PeMS [3]. Οι Station IDs που αντιστοιχούν στα πρώτα δέκα χαρακτηριστικά είναι:

Stations: [400000, 400001, 400009, 400010, 400015, 400017, 400025, 400026, 400027, 400030].

#	ID Αισθητήρα	Περιγραφή Θέσης	Λωρίδες / Αυτοκινητόδρομος	Περιοχή (County)	Συντεταγμένες (lat, lon)
1	400000	SR-37 conn-s-diag	4 λωρ. @ US101-S (PM=19.23)	Marin	(38.081167, -122.547606)
2	400001	NB 880 rm-n-loop	5 λωρ. @ US101-N (PM=38.26)	Santa Clara	(37.364085, -121.901149)
3	400009	University Ave off-e-diag	5 λωρ. @ I80-W (PM=5.7)	Alameda	(37.863905, -122.303083)
4	400010	San Bruno Ave off-n-diag	4 λωρ. @ US101-N (PM=R20.27)	San Mateo	(37.623668, -122.400687)
5	400015	– (μη διαθέσιμο)	–	–	–
6	400017	BASCOM AVE	4 λωρ. @ SR85-S (PM=10.07)	Santa Clara	(37.253303, -121.945440)
7	400025	NEWELL AVE	5 λωρ. @ I680-N (PM=13.7)	Contra Costa	(37.891953, -122.062776)
8	400026	Lakeshore Ave on-e-diag	4 λωρ. @ I580-E (PM=43.47)	Alameda	(37.809074, -122.244479)
9	400027	E of Carlson Blvd	4 λωρ. @ I80-E (PM=1.24)	Contra Costa	(37.912647, -122.317370)
10	400030	N First St rm-s-loop	4 λωρ. @ I880-S (PM=3.64)	Santa Clara	(37.359087, -121.906538)

Πίνακας 11: Μεταδεδομένα και συντεταγμένες των πρώτων 10 αισθητήρων PEMS-SF.

Δομή και Ερμηνεία Κάθε χαρακτηριστικό $x_k(t)$ αντιστοιχεί σε μέτρηση κυκλοφορίας (π.χ. ροή, ταχύτητα, πληρότητα ή πυκνότητα) του αισθητήρα k στη χρονική στιγμή t .

Διαμόρφωση Συνόλου Δεδομένων

- Φόρτωση flow counts από pems_100days_14400x20.csv.
- Επιλογή 10 πρώτων στηλών $\Rightarrow K = 10$.
- Κανονικοποίηση z-score: $x' = (x - \mu)/\sigma$.
- Στοίχιση σε μορφή $\mathbb{R}^{K \times L}$ με $L = 14400 \times 100$.
- Τεμαχισμός σε παράθυρα μήκους L_w και χρήση μασκών M_O όπου απαιτείται για πρόγνωση/συμπλήρωση.

Δομή αρχείου data.pkl και σχήματα Το data.pkl αποθηκεύεται ως tuple (X, M) με κοινό χρονικό ευρετήριο:

$$X \in \mathbb{R}^{14400 \times 10}, \quad M \in \mathbb{R}^{14400 \times 10}.$$

- **X**: πραγματικές χρονοσειρές κυκλοφορίας (10 χαρακτηριστικά/κανάλια), float32.
- **M**: μάσκα παρατήρησης (1 = διαθέσιμη, 0 = ελλείπουσα), float32. Στην παρούσα διάταξη όλες οι τιμές είναι 1.

Συχνότητα, διακριτοποίηση και διάρκεια Για την ανάλυση χρησιμοποιείται ρυθμός 50 Hz, άρα

$$\Delta t = \frac{1}{50} = 0.02 \text{ s}, \quad T_{\text{tot}} = \frac{14400}{50} = 288 \text{ s} \approx 4.8 \text{ min}.$$

Παραγόμενα Αρχεία

Όνομα Αρχείου	Περιγραφή
traffic_N10_T144000.csv	Πίνακας $X_{t,k}$ ($t = 1:144000$, $k = 1:10$).
data.pkl	Tuple (X, M) με main_data, mask_data.
meanstd.pkl	μ, σ ανά αισθητήρα για z-score.

Ιδιότητα	Τιμή / Περιγραφή
Dataset	Traffic / PEMS-SF (μετρήσεις κυκλοφορίας)
Συχνότητα (ανάλυσης)	50 Hz, $\Delta t = 0.02$ s
Δείγματα (χρόνος)	14400
Διάρκεια	288 s $\approx$ 4.8 min
Κανάλια	10 (χαρακτηριστικά αισθητήρων)
Μάσκα	όλες οι τιμές 1 (καμία έλλειψη)
Τύπος δεδομένων	float32
Μορφή αποθήκευσης	pickle $\rightarrow$ tuple (X, M)

Πίνακας 12: Σύνοψη δομής και ιδιοτήτων του Traffic (PEMS-SF) συνόλου για την παρούσα εργασία.

Συνοπτική περιγραφή

Τελική Μορφή Δεδομένων. Μετά την προεπεξεργασία, η αναπαράσταση είναι

$$x_0 \in \mathbb{R}^{K \times L}, \quad K = 10, \quad L = 14400 \times 100 = 1,440,000.$$

Κεφάλαιο 5

Πειράματα και Σχολιασμός

Για κάθε σύνολο δεδομένων που ακολουθεί (BabySlakh, Lorenz-96, PEMS-SF), τα πειράματα πραγματοποιήθηκαν με ενιαίο πρωτόκολλο καθοδήγησης. Συγκεκριμένα, χρησιμοποιήθηκαν **όλα τα μοναδικά ζεύγη** μεταξύ των **δέκα χαρακτηριστικών** του εκάστοτε συνόλου, δηλαδή συνολικά $\binom{10}{2} = 45$ συνδυασμοί ζευγών. Κάθε ζεύγος καθοδηγήθηκε διαδοχικά με **τέσσερις διαφορετικούς συντελεστές βάρους** $-0.7, -0.3, 0.3, 0.7$, που αντιστοιχούν σε διαφορετικές εντάσεις *αρνητικής* και *θετικής καθοδήγησης*. Με αυτή τη διαδικασία διασφαλίζεται ότι για κάθε σύνολο δεδομένων καταγράφεται πλήρως η επίδραση της καθοδήγησης σε όλα τα πιθανά ζεύγη μεταβλητών, επιτρέποντας την ανάλυση των σχέσεων που αναδύονται εντός του ίδιου πλαισίου δεδομένων.




5.1 Music

Σκοπός & Λογική Ομαδοποίησης. Για το μουσικό υποσύνολο BabySlakh (Track 1), οι πολυκάνναλες χρονοσειρές (stems) αντιστοιχούν σε διακριτά ηχητικά στρώματα που καλύπτουν διαφορετικούς ρόλους στο μίγμα. Για να καταστεί δυνατή η ερμηνεία των αποτελεσμάτων της καθοδηγούμενης διάχυσης σε μουσικό-λειτουργικό επίπεδο, οι μεταβλητές ομαδοποιήθηκαν σε *λειτουργικές κατηγορίες ρόλων* με βάση την ηχητική, φασματική και ρυθμική τους ομοιότητα. Η ομαδοποίηση αυτή δεν αποτελεί απλή ταξινόμηση οργάνων, αλλά απόπειρα ανάδειξης των τρόπων με τους οποίους οι ροές πληροφορίας και οι επιδράσεις καθοδήγησης κατανέμονται μεταξύ αρμονικών, ρυθμικών και υποστηρικτικών στρωμάτων.


Συγκεκριμένα: η ομάδα *Guitar* (0, 6, 7) καλύπτει το αρμονικό και μελωδικό υλικό των κιθαρών, με κοινά φασματικά πρότυπα και χαρακτηριστικές διακυμάνσεις ενέργειας στα μεσαία φάσματα· η *Rhythmic* (1, 3) συνδυάζει τα *Drums* και *Bass* ως πυρήνα του *groove*, παρουσιάζοντας υψηλή χρονική συνεξάρτηση και προγνωστικότητα· η *Keys* (2, 5, 8, 9) συγκεντρώνει τα πλήκτρα (*Piano, Organ A/B/C*) που λειτουργούν ως αρμονικό υπόβαθρο και ενισχύουν τη σταθερότητα του τονικού πεδίου· ενώ τα *Pads/Strings* (4) επιτελούν ρόλο ατμοσφαιρικής στήριξης, με αργές εξελίξεις και υψηλή συσχέτιση χαμηλών συχνοτήτων.

Η ομαδοποίηση αυτή μειώνει την πολυπλοκότητα του πειραματικού χώρου, σταθεροποιεί την εκμάθηση συσχετίσεων εντός και μεταξύ ομάδων και καθιστά την καθοδήγηση πιο ερμηνεύσιμη καθώς οι επεμβάσεις πραγματοποιούνται πλέον σε επίπεδο ρόλων (ρυθμικό, αρμονικό, μελωδικό, υποστηρικτικό), επιτρέποντας η παρατηρούμενη μεταβολή Δ και η ευθυγράμμιση (*Align*) να αποκτήσουν άμεση μουσική σημασία — π.χ. ως ενίσχυση της χρονικής συνοχής των ρυθμικών τμημάτων ή ως ελεγχόμενη διάχυση επιδράσεων μεταξύ αρμονικών στρωμάτων.

Όπως φαίνεται στον **Πίνακα 35** του Παραρτήματος, παρουσιάζονται αναλυτικά οι μετρικές καθοδήγησης ανά `guided_pair` για το πλήρες μουσικό υποσύνολο. Με βάση αυτά τα συγκεντρωτικά αποτελέσματα, παράγονται τα παρακάτω διαγράμματα, τα οποία απεικονίζουν τη μέση συμπεριφορά των μετρικών σε επίπεδο συνόλου και αναδεικνύουν τις λειτουργικές αλληλεπιδράσεις μεταξύ των ομάδων οργάνων. Η ανάλυση αυτή επιτρέπει να παρατηρηθούν τα πρότυπα ευθυγράμμισης (Align) και μεταβολής (Delta) όπως εκδηλώνονται μεταξύ ρυθμικών, αρμονικών και μελωδικών στρωμάτων, και να αξιολογηθεί ο τρόπος με τον οποίο η καθοδήγηση επιδρά στη μουσική συνοχή και στην αλληλεξάρτηση των ρόλων στο μίγμα.

(α) Combined Δ correlations(β) L_2 Δ (energy of changes)

(γ) Selectivity (target vs off-target energy)



(δ) Spill Off-Target magnitude


Σχήμα 9: Συνοπτική απεικόνιση των βασικών μετρικών καθοδήγησης σε επίπεδο συνόλου.

Η **Εικόνα 9α** δείχνει ότι οι μεταβολές $|\Delta|$ είναι ελάχιστες για ενδιάμεσες τιμές βάρους (-0.3 έως $+0.3$) και αυξάνονται ξανά για τα άκρα (-0.7 και $+0.7$). Αυτό υποδεικνύει μια μορφή σταθερότητας στη μέτρια καθοδήγηση, όπου το σύστημα διατηρεί πιο ελεγχόμενες αποκρίσεις. Στις ακραίες τιμές όμως, η καθοδήγηση προκαλεί ισχυρότερες μεταβολές των σχέσεων.

Η **Εικόνα 9β** παρουσιάζει την καμπύλη της ενεργειακής μεταβολής ($L_2 \Delta$), η οποία ακολουθεί παρόμοια λογική. Το ελάχιστο εμφανίζεται κοντά στο -0.3 , ενώ η ενεργειακή απαίτηση αυξάνεται απότομα στα άκρα. Το σύστημα χρειάζεται περισσότερη ενέργεια για να προσαρμοστεί όταν η καθοδήγηση είναι πολύ έντονη (θετική ή αρνητική). Μουσικά αυτό σημαίνει ότι οι πιο ακραίες παρεμβάσεις απαιτούν μεγαλύτερη αναδόμηση της εσωτερικής αρμονίας, ενώ μια μέτρια αρνητική καθοδήγηση λειτουργεί πιο ομαλά και φυσικά.

Στην **Εικόνα 9γ**, η επιλεκτικότητα μειώνεται απότομα από το -0.7 προς το -0.3 και παραμένει χαμηλή μέχρι το $+0.3$, ενώ αυξάνεται ξανά στο $+0.7$. Αυτό δείχνει ότι η ακρίβεια της καθοδήγησης μειώνεται στη μέτρια περιοχή (το δίκτυο μοιράζει την επίδραση σε περισσότερα σημεία) και γίνεται πιο στοχευμένη όταν το βάρος είναι ακραίο. Μουσικά, στα μεσαία βάρη το μοντέλο απλώνει την επιρροή του και αγγίζει περισσότερα όργανα, ενώ στα άκρα λειτουργεί πιο επιλεκτικά, σαν μια μίξη που επικεντρώνεται έντονα σε συγκεκριμένα όργανα.

Τέλος, η **Εικόνα 9δ** δείχνει ότι η μέση διαρροή εκτός στόχου (spill) ακολουθεί καθαρή καμπύλη U, με ελάχιστο κοντά στο -0.3 . Αυτό επιβεβαιώνει ότι σε μέτρια καθοδήγηση η επέμβαση περιορίζεται σχεδόν αποκλειστικά στα στοχευμένα ζεύγη, ενώ στις ισχυρές τιμές (± 0.7) η επίδραση διαχέεται και σε γειτονικές σχέσεις. Μουσικά, η πιο καθαρή μορφή παρέμβασης επιτυγχάνεται με ήπια αρνητική καθοδήγηση· εκεί το μοντέλο αγγίζει μόνο τις αναμενόμενες σχέσεις, χωρίς να διαταράσσει την υπόλοιπη μίξη.




Σχήμα 10: Σταθμισμένος μέσος βαθμός ευθυγράμμισης (Weighted Alignment) μεταξύ αναμενόμενης και παρατηρούμενης μεταβολής.

Η **Εικόνα 10** παρουσιάζει μια σαφή καμπύλη απόκρισης: η ευθυγράμμιση αυξάνεται για μέτρια αρνητικά βάρη (-0.3), φτάνοντας στο μέγιστο (0.81), ενώ μειώνεται τόσο προς τις ακραίες αρνητικές όσο και προς τις θετικές τιμές. Αυτό υποδεικνύει ότι η καθοδήγηση έχει τη βέλτιστη επίδραση σε ενδιάμεση ένταση δηλαδή το μοντέλο προσαρμόζει τις συσχετίσεις του πιο συνεκτικά όταν η επίδραση της καθοδήγησης δεν είναι ούτε πολύ ασθενής ούτε υπερβολικά ισχυρή. Σε μουσικό επίπεδο, αυτό σημαίνει πως η ισορροπία ανάμεσα στη ρυθμική και την αρμονική συνοχή επιτυγχάνεται καλύτερα υπό ήπια καθοδήγηση, όπου το δίκτυο ακολουθεί τη δομή χωρίς να τη διαταράσσει.


Clustering. Κατά την ανάλυση των επιδράσεων καθοδήγησης, προκύπτει ένας ιδιαίτερα εκτενής χώρος σχέσεων: όλες οι καθοδηγούμενες ακμές (guided pairs) επηρεάζουν τις υπόλοιπες ακμές του υπογραφήματος, παράγοντας συνολικά εκατοντάδες σχέσεις. Δεδομένου ότι η διαδικασία επαναλαμβάνεται για τέσσερα διαφορετικά βάρη καθοδήγησης, ο συνολικός αριθμός σχέσεων ανέρχεται σε χιλιάδες. Η πολυπλοκότητα αυτή καθιστά αδύνατη την κατανόηση των προτύπων μόνο μέσω οπτικής επιθεώρησης ή απλής ερμηνείας επομένως απαιτείται μια αυτόματη μέθοδος ομαδοποίησης που να εντοπίζει συνεκτικές δομές μέσα σε αυτό το πλήθος αλληλεπιδράσεων.

Για τον σκοπό αυτό εφαρμόστηκε η μέθοδος K-Means clustering, ώστε να διερευνηθεί εάν οι ακμές οργανώνονται σε διακριτά πρότυπα επίδρασης. Η επιλογή του κατάλληλου αριθμού συστάδων K είναι κρίσιμη, καθώς επηρεάζει άμεσα την ερμηνευσιμότητα και τη σταθερότητα των αποτελεσμάτων. Όπως φαίνεται στο **Σχήμα 11**, το $K = 4$ προκύπτει ως η βέλτιστη επιλογή σύμφωνα με πολλαπλές μετρικές αξιολόγησης, εξασφαλίζοντας την καλύτερη ισορροπία μεταξύ συνοχής και διαχωρισιμότητας.



Σχήμα 11: Αξιολόγηση αριθμού συστάδων (K selection) βάσει μετρικών Silhouette, Calinski-Harabasz, Davies-Bouldin και WCSS. Η βέλτιστη τιμή προκύπτει στο $K = 4$, όπου συνδυάζεται υψηλή συνοχή, καθαρός διαχωρισμός και ελάχιστη ενδοσυσταδική διασπορά.

Οπτικοποίηση δομής μέσω PCA. Αφού καθορίστηκε ο βέλτιστος αριθμός συστάδων ($K = 4$), εφαρμόστηκε η τελική διαδικασία ομαδοποίησης στις σχέσεις που προκύπτουν από τη διάχυση. Για να αποτυπωθεί οπτικά η εσωτερική δομή των δεδομένων και η διάταξη των συστάδων, χρησιμοποιήθηκε Principal Component Analysis (PCA), μια μέθοδος μείωσης διαστάσεων που προβάλλει τα πολυδιάστατα σημεία σε επίπεδο δύο ή τριών αξόνων μεγίστης διασποράς. Η απεικόνιση αυτή επιτρέπει την ενστικτώδη κατανόηση του τρόπου με τον οποίο τα δεδομένα κατανέμονται στον χώρο και αποκαλύπτει εάν τα συμπλέγματα που εντοπίστηκαν από το K-Means είναι καθαρά διαχωρισμένα ή επικαλυπτόμενα. Στο επόμενο σχήμα παρουσιάζεται η προβολή PCA με τα σημεία χρωματικά κωδικοποιημένα ανά cluster, δίνοντας μια συνοπτική αλλά εύγλωττη εικόνα της τοπολογίας των σχέσεων και της συνοχής των προτύπων που προέκυψαν.



Σχήμα 12: Προβολή των χαρακτηριστικών Δ στον χώρο των δύο κυριότερων συνιστωσών (PCA, $K=4$). Κάθε σημείο αντιστοιχεί σε μία σχέση μεταξύ ζευγών, ενώ το χρώμα υποδηλώνει τη cluster στην οποία ταξινομήθηκε (cluster 0 – μπλε, 1 – πορτοκαλί, 2 – πράσινο, 3 – κόκκινο). Η διάταξη αποκαλύπτει σαφή χωρικό διαχωρισμό μεταξύ των συστάδων, με το μεγαλύτερο σύμπλεγμα (cluster 0) να συγκεντρώνεται στο κέντρο και τα υπόλοιπα να κατανέμονται περιφερειακά, υποδεικνύοντας διαφορετικά μοτίβα επίδρασης.

Η προβολή μέσω PCA αποκαλύπτει τη γενική γεωμετρία των συστάδων, όμως δεν επαρκεί από μόνη της για να ερμηνεύσει το περιεχόμενο και τη λειτουργική τους σημασία. Για να κατανοηθεί η ταυτότητα κάθε clusters, είναι απαραίτητο να εξεταστεί η εσωτερική της σύνθεση δηλαδή ποιες σχέσεις, ζεύγη και τύποι επιδράσεων τη χαρακτηρίζουν. Οι πίνακες που ακολουθούν παρουσιάζουν τη σύνθεση κάθε clusters, δείχνοντας τη σχετική συμμετοχή των κυριότερων ομάδων οργάνων, τα ποσοστά παρουσίας τους και των υποοργάνων που τα αποτελούν και με-

τρικές όπως τους μέσους δείκτες μεταβολής ($|\Delta|$), ευθυγράμμιση, επιλεκτικότητα. Μέσα από αυτήν την ανάλυση, μπορούμε να αποτυπώσουμε τον χαρακτήρα κάθε cluster αν δηλαδή αντιστοιχεί σε ρυθμικά, αρμονικά ή υβριδικά πρότυπα και να συνδέσουμε τα ποσοτικά ευρήματα με τη μουσική δομή που προκύπτει από την καθοδήγηση.

Σύνθεση Cluster 00. Ο Πίνακας 13 παρουσιάζει τους σημαντικότερους συνδυασμούς καθοδήγησης που συνθέτουν το πρώτο σύμπλεγμα (Cluster 00). Κάθε γραμμή αντιστοιχεί σε έναν συγκεκριμένο συνδυασμό μεταξύ καθοδηγούμενης ομάδας (guided_group) και επηρεαζόμενης σχέσης (affected_pair_group), και συνοδεύεται από δείκτες που περιγράφουν τη σχετική του συμμετοχή μέσα στο σύμπλεγμα (cluster share), τη συχνότητά του στο σύνολο αναφοράς (baseline share), καθώς και τον λόγο ενίσχυσης (enrichment) που εκφράζει το πόσο πιο έντονα εμφανίζεται μέσα στο συγκεκριμένο σύμπλεγμα σε σχέση με το σύνολο δεδομένων. Οι μετρικές $|\Delta|$ και sign_follow αποτυπώνουν, αντίστοιχα, το μέσο μέγεθος μεταβολής των συσχετίσεων και τον βαθμό συμφωνίας τους με το αναμενόμενο πρόσημο (alignment sign). Μέσα από αυτές τις τιμές μπορούμε να κατανοήσουμε ποιοτικά ποιοι τύποι αλληλεπιδράσεων κυριαρχούν στο συγκεκριμένο σύμπλεγμα και ποια είναι η χαρακτηριστική του συμπεριφορά ως προς τη στοχευμένη καθοδήγηση.

Πίνακας 13: Κορυφαίοι συνδυασμοί καθοδήγησης για το Cluster 00.

guided_group	affected_pair_group	cnt	cluster share (%)	baseline share (%)	enrichment	mean $ \Delta $	sign_follow
Guitar-Keys (mixed)	Guitar-Keys	84	6.3	6.7	0.938	0.119	0.226
Guitar-Keys (mixed)	Keys-Rhythmic	81	6.0	4.8	1.244	0.038	0.296
Keys-Rhythmic (mixed)	Guitar-Keys	64	4.8	4.8	0.983	0.115	0.141
Guitar-Keys (mixed)	Guitar-Rhythmic	58	4.3	3.6	1.188	0.059	0.259
Guitar-Keys (mixed)	Keys-Keys	50	3.7	3.6	1.024	0.090	0.200
Keys	Guitar-Keys	47	3.5	3.6	0.962	0.129	0.340

Ερμηνεία του Cluster 00. Το Cluster 00 κυριαρχείται από αλληλεπιδράσεις ανάμεσα στις ομάδες Guitar και Keys. Πιο συγκεκριμένα οι συνδυασμοί Guitar-Keys (ως guided_group) που επηρεάζουν ζεύγη Guitar-Keys και Keys-Rhythmic έχουν τη μεγαλύτερη συμμετοχή (cluster share 6.3% και 6.0% αντίστοιχα). Τα enrichment κοντά στη μονάδα (0.94–1.02) για τους καθαρά αρμονικούς δεσμούς Guitar-Keys και Keys-Keys δείχνουν ότι το σύμπλεγμα αντιπροσωπεύει το *baseline* μίγμα αρμονικών σχέσεων, ενώ η ελαφρά υπεραντιπροσώπηση στα Keys-Rhythmic και Guitar-Rhythmic (1.24× και 1.19×) φανερώνει μια *ήπια σύζευξη αρμονικού-ρυθμικού στρώματος*. Οι μέσες μεταβολές συσχέτισης είναι μέτριες προς μικρές (mean $|\Delta| \approx 0.04$ –0.13), όπως και τα sign_follow (0.14–0.34), κάτι που συνάδει με την επικράτηση του τεταρτημορίου Q2_HighAlign_LowDelta δηλαδή η καθοδήγηση *ευθυγραμμίζεται* με τη δομή των προσδοκώμενων επιδράσεων, αλλά λειτουργεί (χωρίς μεγάλες μετατοπίσεις).

Ανάλυση καθοδηγούμενης πλευράς Αφού εξετάσαμε τη συνολική σύνθεση των clusters, είναι εξίσου σημαντικό να αναλυθεί σε ποιά επιμέρους stems (όργανα) συμμετέχουν ενεργά στις κορυφαίες σχέσεις καθοδήγησης. Οι Πίνακες 14 και 15 παρουσιάζουν, σε αντιπαράβολή, τα πέντε επικρατέστερα στελέχη που συμβάλλουν στις δύο σημαντικότερες σχέσεις του συμπλέγματος: τη μετάβαση Guitar-Keys (mixed) → Guitar-Keys και τη Guitar-Keys (mixed) → Keys-Rhythmic. Για κάθε περίπτωση καταγράφονται το ποσοστό σταθμισμένης μεταβολής $|\Delta|$ (Δ -wtd %) και το ποσοστό συμμετοχής στον αριθμό εμφανίσεων (Count %), επιτρέποντας τη σύγκριση της σχετικής επιρροής κάθε οργάνου. Μέσα από αυτήν τη σύγκριση αναδεικνύονται τα όργανα που λειτουργούν ως βασικοί φορείς της καθοδήγησης, καθώς και οι διαφοροποιήσεις στα μοτίβα επίδρασης μεταξύ των δύο σχέσεων.

Πίνακας 14: Guitar-Keys (mixed) → Guitar-Keys – Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
Guitar-C (dist)	Guitar	18.6	19.0
Guitar-A (dist)	Guitar	17.6	13.7
Organ-A (perc)	Keys	15.7	11.9
Organ-B	Keys	14.2	14.9
Guitar-B (jazz)	Guitar	13.8	17.3

Πίνακας 15: Guitar-Keys (mixed) → Keys-Rhythmic – Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
Guitar-C (dist)	Guitar	18.2	17.9
Guitar-A (dist)	Guitar	16.4	14.8
Guitar-B (jazz)	Guitar	15.4	17.3
Organ-A (perc)	Keys	15.2	13.6
Piano	Keys	12.4	9.9

Στον Πίνακα 14 παρατηρείται ότι η καθοδήγηση Guitar-Keys (mixed) προς Guitar-Keys εκφράζεται κυρίως μέσω των τριών κιθαρών (Guitar-C, A, B), με ποσοστά $|\Delta|_{\text{wtd}}$ περίπου 14–19% και *συνολική συμμετοχή* που υπερβαίνει το 50%. Η συνύπαρξη των Organ-A και Organ-B ως δευτερευόντων κόμβων υποδεικνύει ότι οι αρμονικοί ήχοι των οργάνων αυτών συντονίζονται με τις κιθάρες για τη διατήρηση της συνοχής του αρμονικού στρώματος. Η ενέργεια της καθοδήγησης επομένως *παραμένει εντός του αρμονικού πεδίου*, ρυθμίζοντας τις μεταξύ τους σχέσεις χωρίς να μεταφέρει σημαντική επιρροή στα ρυθμικά στοιχεία.

Αντίθετα, στον Πίνακα 15 όπου η ίδια καθοδήγηση στοχεύει πλέον ζεύγη Keys-Rhythmic διατηρείται μεν η πρωτοκαθεδρία των κιθαρών (Guitar-C, A, B), όμως εμφανίζεται σαφέστερη συμμετοχή των Keys (κυρίως Organ-A και Piano). Το γεγονός ότι τα όργανα των Keys φέρουν $|\Delta|_{\text{wtd}}$ έως και 15% δηλώνει μια *ενίσχυση* ανάμεσα στο αρμονικό και το ρυθμικό στρώμα δηλαδή οι κιθάρες λειτουργούν ως φορείς ώθησης, ενώ τα Keys μεταδίδουν μέρος της καθοδήγησης προς τα ρυθμικά κανάλια (Drums, Bass).

Συνολικά, οι δύο πίνακες δείχνουν ότι:

- Τα **Guitar stems** (ιδίως τα distorted Guitar-A / C) αποτελούν τον *πυρήνα* της καθοδηγούμενης επίδρασης.
- Τα **Keys stems** (Organ, Piano) ενεργοποιούνται περισσότερο όταν η καθοδήγηση επεκτείνεται προς ρυθμικά ζεύγη, υποδεικνύοντας *αρμονικο-ρυθμική διαμεσολάβηση*.
- Το μοτίβο *Guitar* $\rightarrow$ *Keys* $\rightarrow$ *Rhythmic* αποκαλύπτει τη βασική κατεύθυνση διάχυσης της επιρροής μέσα στο Cluster 00.

Από αυτό μπορούμε να συμπεράνουμε ότι το συγκεκριμένο σύμπλεγμα λειτουργεί ως *αρμονικός κόμβος* που διατηρεί τη σταθερότητα του αρμονικού ιστού, ενώ ταυτόχρονα επιτρέπει ελεγχόμενη μεταφορά ενέργειας προς τα ρυθμικά στοιχεία όταν το μοντέλο το απαιτεί.

Ανάλυση επηρεαζόμενης πλευράς. Εκτός από την καθοδηγούμενη πλευρά, εξίσου σημαντικό είναι να εξεταστεί ποια όργανα (stems) δέχονται την επίδραση της καθοδήγησης, δηλαδή ποια τμήματα του συστήματος μεταβάλλουν περισσότερο τη συμπεριφορά τους όταν ενεργοποιείται η σχέση Guitar-Keys (mixed). Οι Πίνακες 16–19 παρουσιάζουν αναλυτικά τη σύνθεση των επηρεαζόμενων πλευρών για τις δύο βασικές σχέσεις καθοδήγησης: Guitar-Keys (mixed) $\rightarrow$ Guitar-Keys και Guitar-Keys (mixed) $\rightarrow$ Keys-Rhythmic. Για κάθε κατηγορία (Guitar, Keys, Rhythmic) παρατίθενται τα επιμέρους stems που υφίστανται τη μεγαλύτερη μεταβολή, με βάση το σταθμισμένο μέγεθος μεταβολής $|\Delta|$ και το ποσοστό παρουσίας (Count %). Η σύγκριση αυτών των πινάκων αποκαλύπτει ποια όργανα ανταποκρίνονται εντονότερα στην καθοδήγηση, πώς διαχέεται η επίδραση μεταξύ αρμονικών και ρυθμικών στρωμάτων, και πώς διαφοροποιείται η επίδραση ανάμεσα στα δύο ζεύγη σχέσεων.

Πίνακας 16: Guitar-Keys (mixed) $\rightarrow$ Guitar-Keys – Affected stems in Guitar

Stem	$ \Delta _{\text{wtd}}$ (%)	Count (%)
Guitar-C (dist)	36.1	27.4
Guitar-B (jazz)	35.4	27.4
Guitar-A (dist)	28.5	45.2

Πίνακας 17: Guitar-Keys (mixed) $\rightarrow$ Guitar-Keys – Affected stems in Keys

Stem	$ \Delta _{\text{wtd}}$ (%)	Count (%)
Organ-C	33.2	20.2
Organ-B	31.3	20.2
Organ-A (perc)	19.2	31.0
Piano	16.2	28.6

Πίνακας 18: Guitar-Keys (mixed) $\rightarrow$ Keys-Rhythmic – Affected stems in Keys

Stem	$ \Delta _{\text{wtd}}$ (%)	Count (%)
Organ-B	49.8	19.8
Organ-C	43.3	21.0
Organ-A (perc)	6.1	29.6
Piano	0.9	29.6

Πίνακας 19: Guitar-Keys (mixed) $\rightarrow$ Keys-Rhythmic – Affected stems in Rhythmic

Stem	$ \Delta _{\text{wtd}}$ (%)	Count (%)
Drums	55.8	55.6
Bass	44.2	44.4

Ερμηνεία Πινάκων 16–17. Οι Πίνακες 16–17 δείχνουν τα stems που επηρεάζονται εντονότερα όταν η καθοδήγηση Guitar-Keys (mixed) δρα σε ζεύγη Guitar-Keys. Στις κιθάρες (Πίν. 16), οι Guitar-C (dist) και Guitar-B (jazz) παρουσιάζουν τις ισχυρότερες μεταβολές ($|\Delta|_{\text{wtd}} \approx 35\%$), ενώ η Guitar-A (dist) εμφανίζεται συχνότερα ως δέκτης

καθοδήγησης. Στα πλήκτρα (Πίν. 17), οι Organ-C και Organ-B έχουν τη μεγαλύτερη ένταση μεταβολής (31–33%), ενώ τα Organ-A (perc) και Piano συμμετέχουν συχνότερα. Συνολικά, η επίδραση είναι *αρμονικά συμμετρική*: οι κιθάρες λειτουργούν ως κύριοι φορείς της αλλαγής, ενώ τα πλήκτρα απορροφούν και σταθεροποιούν την καθοδήγηση.

Ερμηνεία Πινάκων 18–19. Οι Πίνακες 18–19 δείχνουν τα stems που επηρεάζονται όταν η καθοδήγηση Guitar–Keys (mixed) στοχεύει ζεύγη Keys–Rhythmic. Στα πλήκτρα (Πίν. 18), οι Organ-B και Organ-C παρουσιάζουν πολύ υψηλές μεταβολές ($|\Delta|_{\text{wtd}}$ 43–50%), ενώ τα Organ-A (perc) και Piano εμφανίζονται συχνότερα, με ηπιότερη απόκριση. Αυτό δείχνει ότι οι Organs λειτουργούν ως βασικοί μεταφορείς της επίδρασης από τις κιθάρες προς το ρυθμικό πεδίο.

Στον Πίνακα 19, τα ρυθμικά stems δηλαδή Drums και Bass αντιδρούν έντονα και συμμετρικά ($|\Delta|_{\text{wtd}}$ 44–56%), υποδηλώνοντας ότι η καθοδήγηση Guitar–Keys τελικά μεταφράζεται σε *συνεκτική αρμονικο-ρυθμική ενίσχυση*, όπου τα πλήκτρα μεσολαβούν και οι ρυθμικοί κόμβοι απορροφούν τη δυναμική.

Καθώς ακολουθείται το ίδιο μοτίβο ανάλυσης δεδομένων, οι πίνακες με τις σχετικές πληροφορίες για κάθε cluster παρατίθενται στην Ενότητα 7 στο Παράρτημα.


Συνολική ανάλυση για το Cluster 01. Παρατηρώντας τους αντίστοιχους πίνακες για το Cluster 01, διαπιστώνεται ότι το σύμπλεγμα αυτό χαρακτηρίζεται από ισχυρότερη και πιο ενεργή καθοδήγηση σε σχέση με το Cluster 00. Οι κυρίαρχες σχέσεις (Guitar–Keys και Guitar–Rhythmic) εμφανίζουν υψηλούς συντελεστές εμπλουτισμού (έως $2.2\times$) και μέσες μεταβολές $|\Delta|$ γύρω στο 0.45, υποδεικνύοντας έντονη αλληλεπίδραση μεταξύ αρμονικών και ρυθμικών στρωμάτων. Η καθοδήγηση προέρχεται κυρίως από τις κιθάρες (Guitar-A, B, C) και το Piano, ενώ η επίδραση απορροφάται τόσο από τα όργανα (Organ-B, C) όσο και από τα ρυθμικά στοιχεία (Drums, Bass). Η δομή αυτή αποκαλύπτει έναν *υβριδικό χαρακτήρα* του συμπλέγματος: οι κιθάρες δρουν ως γέφυρα που συντονίζει τις αρμονικές μεταβάσεις των Keys με την ενεργειακή βάση των Rhythmic καναλιών. Συνολικά, το Cluster 01 αποτυπώνει μια *ενισχυμένη αρμονικο-ρυθμική σύζευξη*, όπου η καθοδήγηση δεν περιορίζεται στη διατήρηση συσχετίσεων, αλλά επιτελεί *μεταβατική λειτουργία* μεταξύ αρμονικών και ρυθμικών επιπέδων.

Συνολική ανάλυση για το Cluster 02. Παρατηρώντας τους αντίστοιχους πίνακες για το Cluster 02, διαπιστώνεται ότι το σύμπλεγμα αυτό παρουσιάζει *έντονη αρμονική εστίαση* με πρωτεύουσα καθοδήγηση από τις κιθάρες προς το πεδίο των πλήκτρων. Η σχέση Guitar → Guitar–Keys εμφανίζει τον υψηλότερο εμπλουτισμό ($3.6\times$) και τις μεγαλύτερες μεταβολές ($|\Delta| \approx 0.63$), υποδηλώνοντας στοχευμένη και συνεπή ενίσχυση ($\text{sign_follow} = 1.0$) των κιθαριστικών δεσμών με τα πλήκτρα. Οι Guitar-A, B, C λειτουργούν ως βασικοί πομποί, ενώ τα Organ-B, C και το Piano δέχονται τη μεγαλύτερη επίδραση, διαμορφώνοντας μια αλληλεπίδραση μεταξύ ηλεκτρικών κιθαρών και οργάνων πλήκτρων. Η παρουσία σχέσεων όπως Guitar–Keys → Pads/Strings με εμπλουτισμό άνω του $2\times$ δείχνει επέκταση της καθοδήγησης προς πιο μακρινές κατηγορίες πέρα από τον στενό πυρήνα. Συνολικά, το Cluster 02 αποτυπώνει ένα *καθαρά αρμονικό σύμπλεγμα* υψηλής συνοχής, όπου οι κιθάρες ηγούνται της διάχυσης και τα πλήκτρα λειτουργούν ως σταθεροποιητικοί δέκτες του αρμονικού πεδίου.

Συνολική ανάλυση για το Cluster 03. Παρατηρώντας τους αντίστοιχους πίνακες για το Cluster 03, φαίνεται ότι το σύμπλεγμα αυτό επικεντρώνεται στις *εσωτερικές σχέσεις των πλήκτρων* και στη σύνδεσή τους με τα ρυθμικά στοιχεία. Οι συνδυασμοί Keys–Keys εμφανίζουν τον υψηλότερο εμπλουτισμό (έως $4.2\times$) και σταθερά μεγέθη μεταβολής ($|\Delta| \approx 0.48$), υποδηλώνοντας συνεκτική, εσωτερική αναδιάταξη στο αρμονικό πεδίο. Οι κύριοι φορείς καθοδήγησης είναι τα Organs (B, C) και το Bass–Drums ζεύγος, με ενεργό ρόλο στη γεφύρωση αρμονικού και ρυθμικού στρώματος. Η παρουσία Guitar–Keys δεσμών με μέτριο εμπλουτισμό ($1.3\text{--}1.7\times$) υποδεικνύει δευτερεύουσα συμβολή των κιθαρών, οι οποίες λειτουργούν υποστηρικτικά και όχι ως κύριοι πομποί. Συνολικά, το Cluster 03 αναδεικνύεται ως *αρμονικο-ρυθμικός πυρήνας*, όπου τα πλήκτρα διαμορφώνουν τη δομή της καθοδήγησης και τα ρυθμικά όργανα παρέχουν τη δυναμική σύζευξη, αντιπροσωπεύοντας ένα σταθεροποιημένο αλλά ενεργό σύμπλεγμα εσωτερικής συνοχής.

Συμπεριφορά στο επίπεδο ευθυγράμμισης–μεταβολής. Αφού εξετάσαμε τη σύνθεση και τη μουσική ταυτότητα κάθε clusters, προχωρούμε σε μια ενιαία απεικόνιση όλων των σχέσεων στο επίπεδο $|\Delta|$ (κάθετος άξονας) έναντι alignment (οριζόντιος άξονας), με χρωματική κωδικοποίηση ανά cluster. Το διάγραμμα που ακολουθεί επιτρέπει να δούμε πώς συνδυάζονται η καθοδήγηση με την γνώση που έχει αποκτήσει το μοντέλο κατά την διάρκεια

της εκπαίδευσης του. οι ακμές κοντά στο ($\text{alignment} \approx 1$, $|\Delta|$ μικρό) δείχνουν ήπιες μεταβολές που συμφωνούν με την αναμενόμενη δομή, ενώ οι ακμές με μεγάλο $|\Delta|$ και χαμηλό alignment φανερώουν ισχυρές παρεμβάσεις που αντιτίθενται στις προσδοκίες του μοντέλου. Με αυτό το πλαίσιο μπορούμε να ερμηνεύσουμε πώς τα τέσσερα clusters που αναλύσαμε κατανέμονται ανάμεσα σε σύμφωνες και αντίρροπες μεταβολές και να συσχετίσουμε τις μουσικές τους λειτουργίες.




Σχήμα 13: Όλες οι σχέσεις στον χώρο $\text{alignment}-|\Delta|$, χρωματισμένες ανά cluster ($K=4$). Οι διακεκομμένες γραμμές υποδεικνύουν ενδεικτικά κατώφλια ($\text{alignment} \approx 0.75$, $|\Delta| \approx 0.25$) για οπτικό διαχωρισμό μεταξύ ήπιων/συμφωνημένων και ισχυρών/μη-συμφωνημένων μεταβολών.


Ανάλυση συμπεριφοράς ανά cluster στο επίπεδο ευθυγράμμισης-μεταβολής. Για να εμβαθύνουμε στη δυναμική που υποδηλώνει το διάγραμμα του Σχήματος 13, παρατίθεται ο συνοπτικός Πίνακας 20, ο οποίος συνοψίζει τη συμπεριφορά κάθε cluster ($\text{Cluster } 00-03$) ως προς τις τέσσερις περιοχές του επιπέδου $|\Delta|$ - alignment και για όλα τα βάρη καθοδήγησης. Η σύγκριση αυτή επιτρέπει να φανεί πώς κατανέμεται η απόκριση κάθε cluster ανάμεσα σε «ήπιες ευθυγραμμισμένες» ($Q2$) και «εντονότερες αποκλίνουσες» ($Q3-Q4$) περιοχές, καθώς και πότε εμφανίζονται σπάνια φαινόμενα ισχυρής, συμβατής μεταβολής ($Q1$). Με αυτόν τον τρόπο, ο πίνακας λειτουργεί ως *ποσοτική σύνοψη της συμπεριφοράς των συστάδων*, προσφέροντας ένα ενιαίο πλαίσιο για τη σύγκριση μεταξύ διαφορετικών βαρών καθοδήγησης και την αναγνώριση προτύπων σταθερότητας, ευθυγράμμισης ή αντιδραστικότητας στο σύνολο των πειραματικών αποτελεσμάτων.

Πίνακας 20: Κατανομή τεταρτημορίων (%) ανά cluster και weight tag.


Cluster	Weight	Q1	Q2	Q3	Q4
C00	neg_0_7	0.1	50.2	47.6	2.1
	neg_0_3	0.7	82.0	17.2	0.1
	pos_0_3	0.1	80.6	18.1	1.1
	pos_0_7	0.4	47.3	44.8	7.6
C01	neg_0_7	0.0	55.1	43.9	1.0
	neg_0_3	0.7	77.9	21.4	0.0
	pos_0_3	0.0	72.1	26.5	1.4
	pos_0_7	1.0	33.3	55.1	10.5
C02	neg_0_7	0.0	54.9	42.7	2.4
	neg_0_3	0.0	83.5	15.2	1.2
	pos_0_3	0.6	79.9	18.3	1.2
	pos_0_7	0.6	48.8	40.2	10.4
C03	neg_0_7	0.0	46.9	52.6	0.5
	neg_0_3	0.0	81.3	18.7	0.0
	pos_0_3	0.5	78.0	20.1	1.4
	pos_0_7	0.5	42.1	52.2	5.3




(α) Cluster 00



(β) Cluster 01



(γ) Cluster 02



(δ) Cluster 03

Σχήμα 14: Κατανομή τεταρτημορίων ανά weight tag για τα Clusters 00–03.


Συσχέτιση συμπεριφοράς συστάδων με τα τεταρτημόρια. Η κατανομή των ποσοστών ανά τεταρτημόριο επιβεβαιώνει και ποσοτικοποιεί τα μοτίβα που αναδείχθηκαν στην προηγούμενη ανάλυση των συστάδων. Τα clusters C00 και C02 παρουσιάζουν την πιο σταθερή και ευθυγραμμισμένη συμπεριφορά, με τη μεγάλη πλειονότητα των σχέσεων να συγκεντρώνεται στο Q2_HighAlign_LowDelta, γεγονός που συνάδει με τον αρμονικό και ελεγχόμενο χαρακτήρα τους. Αντίθετα, οι C01 και C03 εμφανίζουν μεγαλύτερη διασπορά προς τα Q3–Q4, ιδίως για υψηλά θετικά βάρη καθοδήγησης, υποδηλώνοντας αυξημένη αντιδραστικότητα και ρυθμική διαφοροποίηση. Συνολικά, η μετατόπιση των ποσοστών μεταξύ βαρών αποκαλύπτει πώς η ένταση της καθοδήγησης επηρεάζει τη δυναμική ισορροπία ανάμεσα στη σταθερότητα (αρμονικά clusters) και στη ρυθμική ευαισθησία (υβριδικά clusters). Τα ποσοτικά αποτελέσματα των τεταρτημορίων δείχνουν με σαφήνεια πώς η καθοδήγηση αλληλεπιδρά με τη γνώση που έχει ήδη αποκτήσει το μοντέλο κατά την εκπαίδευση. Τα clusters C00 και C02, όπου άνω του 80% των σχέσεων εντάσσεται στο Q2_HighAlign_LowDelta, δείχνουν ότι το μοντέλο έχει μάθει σταθερά, εσωτερικά αρμονικά πρότυπα: η καθοδήγηση τα ενισχύει χωρίς να τα διαταράσσει, λειτουργώντας συμπληρωματικά στην ήδη μαθημένη

κατεύθυνση. Αντίθετα, οι C01 και C03 παρουσιάζουν σημαντική μετατόπιση προς τα Q3–Q4 (έως και 55% για θετικά βάρη), υποδηλώνοντας ότι η καθοδήγηση ενεργοποιεί περιοχές του χώρου συσχετίσεων όπου το μοντέλο δεν είχε σαφή μαθημένα πρότυπα ή τα αναδιαμορφώνει δυναμικά. Με άλλα λόγια, εκεί όπου το μοντέλο έχει εμπιστευθεί σταθερές συσχετίσεις (αρμονικά στρώματα), η καθοδήγηση απλώς ενισχύει τις υπάρχουσες εξαρτήσεις, ενώ στα πιο αβέβια ή πολυσύνθετα πεδία (ρυθμικά–υβριδικά σύμπλοκα) η καθοδήγηση λειτουργεί ως *εξερευνητικός μηχανισμός*, προκαλώντας μεγαλύτερες αποκλίσεις και επαναπροσδιορίζοντας την ήδη εκπαιδευμένη ισορροπία.


5.2 Lorenz

Στο συνθετικό σύστημα Lorenz–96, οι μεταβλητές $\{X_0, X_1, \dots, X_9\}$ αντιπροσωπεύουν έναν κυκλικό δακτύλιο αλληλεπιδρώντων σημείων, όπου κάθε μεταβλητή επηρεάζεται από τους δύο προηγούμενους και τον έναν επόμενο δείκτη, σύμφωνα με τη δυναμική του αρχικού μοντέλου. Για να είναι δυνατή η ερμηνεία των αποτελεσμάτων της καθοδηγούμενης διάχυσης σε δομικό και χωρικά συνεπές πλαίσιο, οι μεταβλητές ομαδοποιήθηκαν σε *πέντε συνηχόμενους τομείς δύο στοιχείων* (Sector–A: X00–X01, Sector–B: X02–X03, Sector–C: X04–X05, Sector–D: X06–X07, Sector–E: X08–X09). Η ομαδοποίηση αυτή αντικατοπτρίζει τη φυσική κυκλική συμμετρία του συστήματος και επιτρέπει την παρακολούθηση της διάδοσης επιρροής κατά μήκος του δακτυλίου, όπως αυτή εκδηλώνεται μέσω των μετρικών μεταβολής ($|\Delta|$) και ευθυγράμμισης (Align). Η προσέγγιση αυτή μειώνει την πολυπλοκότητα του πειραματικού χώρου, ενισχύει την ερμηνευσιμότητα των αποτελεσμάτων και καθιστά δυνατή τη σύγκριση των προτύπων καθοδήγησης με εκείνα που παρατηρήθηκαν στα πραγματικά σύνολα (μουσικό και κυκλοφοριακό).


Όπως φαίνεται στον **Πίνακα 81** του Παραρτήματος, παρουσιάζονται αναλυτικά οι μετρικές καθοδήγησης ανά `guided_pair` για το σύνολο Lorenz–96. Με βάση τα συγκεντρωτικά αυτά αποτελέσματα, παράγονται τα ακόλουθα διαγράμματα, τα οποία συνοψίζουν τη μέση συμπεριφορά των μετρικών σε επίπεδο συνόλου και αποτυπώνουν τη ροή επιρροής κατά μήκος των τομέων του συστήματος.




(α) Combined Δ correlations



(β) L_2 Δ (energy of changes)



(γ) Selectivity (target vs off-target energy)



(δ) Spill Off-Target magnitude


Σχήμα 15: Συνοπτική απεικόνιση των βασικών μετρικών καθοδήγησης για το συνθετικό σύνολο Lorenz–96. Οι τιμές απεικονίζουν τη μέση συμπεριφορά των μεταβολών, της ενεργειακής απαίτησης, της επιλεκτικότητας και της διαρροής εκτός στόχου κατά τη διάρκεια της καθοδηγούμενης διάχυσης.

Η **Εικόνα 15α** δείχνει ότι οι μέσες μεταβολές $|\Delta|$ παραμένουν μικρές για ενδιάμεσες τιμές βάρους (-0.3 έως $+0.3$) και αυξάνονται σημαντικά στα άκρα (-0.7 και $+0.7$). Το αποτέλεσμα αυτό υποδεικνύει μια ζώνη σταθερής λειτουργίας γύρω από τη μέτρια καθοδήγηση, όπου οι παρεμβάσεις δεν διαταράσσουν ουσιαστικά την εσωτερική δυναμική του συστήματος. Αντίθετα, στις ακραίες τιμές, η καθοδήγηση ενισχύει ή αντιστρέφει έντονα τις σχέσεις, προκαλώντας μεγαλύτερες ανακατανομές στη ροή συσχετίσεων μεταξύ τομέων.

Η **Εικόνα 15β'** αποτυπώνει την ενεργειακή απαίτηση των μεταβολών ($L_2 \Delta$), η οποία ακολουθεί παρόμοια μορφή: το ελάχιστο εμφανίζεται κοντά στο -0.3 , ενώ στα άκρα του φάσματος (± 0.7) παρατηρείται απότομη αύξηση. Το σύστημα απαιτεί περισσότερη ενέργεια για να προσαρμοστεί όταν η καθοδήγηση είναι πολύ έντονη γεγονός που αντανακλά μια μη γραμμική απόκριση του χαοτικού πεδίου του Lorenz-96.

Στην **Εικόνα 15γ'**, η επιλεκτικότητα παρουσιάζει ελάχιστο κοντά στο -0.3 και αυξάνεται προς τα άκρα, υποδηλώνοντας ότι για μέτριες τιμές καθοδήγησης το μοντέλο κατανέμει τις επιδράσεις πιο ομοιόμορφα σε πολλαπλές μεταβλητές, ενώ στις ακραίες τιμές επικεντρώνεται σε συγκεκριμένους δεσμούς. Με άλλα λόγια, η ήπια καθοδήγηση οδηγεί σε ευρεία αλλά ελεγχόμενη διάδοση, ενώ η ισχυρή καθοδήγηση ενεργοποιεί στοχευμένα μοτίβα ενίσχυσης ή αναστολής.


Τέλος, η **Εικόνα 15δ'** δείχνει ότι η μέση διαρροή εκτός στόχου (spill) παρουσιάζει χαρακτηριστική καμπύλη U με ελάχιστο γύρω στο -0.3 . Αυτό επιβεβαιώνει ότι στη μέτρια καθοδήγηση η επίδραση περιορίζεται σχεδόν αποκλειστικά στα στοχευμένα ζεύγη μεταβλητών, ενώ για ακραίες τιμές (± 0.7) η παρέμβαση διαχέεται σε γειτονικές σχέσεις. Συνολικά, το σύστημα επιδεικνύει τη μεγαλύτερη σταθερότητα και καθαρότητα επιρροής στην περιοχή ήπιας αρνητικής καθοδήγησης, όπου η διάχυση ευθυγραμμίζεται περισσότερο με τη φυσική δυναμική του μοντέλου.



Σχήμα 16: Μέσος βαθμός ευθυγράμμισης (Weighted Alignment) μεταξύ αναμενόμενης και παρατηρούμενης μεταβολής για το σύνολο Lorenz-96.


Η **Εικόνα 16** παρουσιάζει μια χαρακτηριστική καμπύλη απόκρισης, όπου η ευθυγράμμιση αυξάνεται έντονα για μέτριες τιμές βάρους (-0.3 έως $+0.3$), φτάνοντας σε μέγιστες τιμές κοντά στο 0.85 , ενώ μειώνεται στα άκρα (-0.7 και $+0.7$). Το αποτέλεσμα αυτό δείχνει ότι η καθοδήγηση έχει τη βέλτιστη επίδραση όταν εφαρμόζεται με ενδιάμεση ένταση: το σύστημα προσαρμόζει τις εσωτερικές του συσχετίσεις με τρόπο πιο συνεκτικό και φυσικό. Αντίθετα, στις ακραίες τιμές βάρους η παρέμβαση γίνεται υπερβολικά επιθετική ή ανεπαρκής, προκαλώντας απώλεια ευθυγράμμισης μεταξύ αναμενόμενης και παρατηρούμενης μεταβολής. Με άλλα λόγια, η ήπια καθοδήγηση επιτρέπει τη μέγιστη συντονισμένη αλληλεπίδραση μεταξύ των τομέων του Lorenz-96, διατηρώντας την ισορροπία ανάμεσα στην εξωτερική επιρροή και τη φυσική εξέλιξη του συστήματος.

Clustering. Για το σύνολο Lorenz-96, η ανάλυση των επιδράσεων καθοδήγησης παράγει έναν πολυδιάστατο χώρο αλληλεπιδράσεων μεταξύ των τομέων (Sectors A-E), όπου κάθε καθοδηγούμενο ζεύγος επηρεάζει πολλαπλές άλλες σχέσεις. Για τον εντοπισμό συνεκτικών προτύπων συμπεριφοράς εφαρμόστηκε ομαδοποίηση μέσω K-Means, ώστε να αναδειχθούν ομάδες ακμών με παρόμοια δυναμική απόκριση. Όπως φαίνεται στο **Σχήμα 17**, το $K = 4$ επιλέχθηκε ως κατάλληλος αριθμός συστάδων, προσφέροντας καλή ισορροπία μεταξύ συνοχής και διαχωρισιμότητας.



Σχήμα 17: Αξιολόγηση αριθμού συστάδων (K selection) για το σύνολο Lorenz-96, βάσει των κριτηρίων GMM-BIC και GMM-AIC. Και τα δύο κριτήρια συγκλίνουν στη βέλτιστη τιμή $K = 4$, υποδεικνύοντας καλή ισορροπία μεταξύ πολυπλοκότητας μοντέλου και συνοχής συστάδων.

Το PCA που προκύπτει από το επιλεγμένο K Means-Clustering φαίνεται παρακάτω



Σχήμα 18: Προβολή των χαρακτηριστικών Δ στον χώρο των δύο κυριότερων συνιστωσών (PCA, $K=4$) για το σύνολο Lorenz-96. Κάθε σημείο αντιστοιχεί σε μία σχέση μεταξύ καθοδηγούμενων τομέων, ενώ το χρώμα υποδηλώνει τη cluster στην οποία ταξινομήθηκε (cluster 0 – μπλε, 1 – πορτοκαλί, 2 – πράσινο, 3 – κόκκινο). Η διάταξη παρουσιάζει σαφή διαχωρισμό μεταξύ των συστάδων, με το μεγαλύτερο σύμπλεγμα (cluster 1) να καταλαμβάνει το κεντρικό τμήμα του χώρου και τα μικρότερα να τοποθετούνται περιφερειακά, υποδεικνύοντας διαφορετικές κατηγορίες δυναμικής απόκρισης μεταξύ των τομέων του συστήματος.

Η τρέχουσα προβολή PCA (Σχήμα 18) αποκαλύπτει καθαρή, ασύμμετρη γεωμετρία καθώς παρατηρείται ένα μεγάλο κεντρικό σύμπλεγμα (cluster 1) συγκεντρωμένο γύρω από το κέντρο, ενδεικτικό ήπιων και ομοιόμορφων αποκρίσεων, και τρία μικρότερα περιφερειακά συμπλέγματα (clusters 0, 2, 3) με σαφή μετατόπιση κατά μήκος των κυρίων συνιστωσών, που υποδηλώνει διακριτά πρότυπα επίδρασης (π.χ. πιο στοχευμένες ή αντίρροπες μεταβολές μεταξύ Sectors A, B, C, D, E). Η οπτική αυτή σύνοψη αρκεί για να δούμε τον μακροσκοπικό διαχωρισμό, όχι όμως για να ερμηνεύσουμε τη λειτουργική ταυτότητα κάθε clusters. Στη συνέχεια, εξετάζουμε τη *σύνθεση* των συστάδων: ποια ζεύγη τομέων κυριαρχούν, πώς κατανέμονται οι μετρικές $|\Delta|$, alignment και selectivity, και αν τα πρότυπα που προκύπτουν αντιστοιχούν σε τοπική σύζευξη, μεταφορά επιρροής μεταξύ γειτονικών τομέων ή σε ισχυρές μη τοπικές αλληλεπιδράσεις. Αυτή η λεπτομερής ανάλυση θα επιτρέψει να αποδοθεί ο ρόλος κάθε clusters στην καθοδηγούμενη δυναμική του Lorenz96.

Πίνακας 21: Κορυφαίοι συνδυασμοί καθοδήγησης για το Cluster 00.

guided_group	affected_pair_group	cnt	cluster share (%)	baseline share (%)	enrichment	mean $ \Delta $	sign_follow
Sector-C-Sector-E (mixed)	Sector-C-Sector-D	2	3.2	0.8	3.929	0.624	0.50
Sector-B-Sector-C (mixed)	Sector-C-Sector-E	2	3.2	0.8	3.929	0.496	1.00
Sector-C-Sector-D (mixed)	Sector-C-Sector-E	2	3.2	0.8	3.929	0.487	0.50

guided_group	affected_pair_group	cnt	cluster share (%)	baseline share (%)	enrichment	mean $ \Delta $	sign_follow
Sector-A	Sector-A-Sector-E	2	3.2	0.2	15.714	0.295	0.00
Sector-C	Sector-C-Sector-E	2	3.2	0.2	15.714	0.532	1.00
Sector-A-Sector-C (mixed)	Sector-C-Sector-E	2	3.2	0.8	3.929	0.424	0.00

Σύνθεση Cluster 00. Ο Πίνακας 22 παρουσιάζει τους κυριότερους συνδυασμούς καθοδήγησης που σχηματίζουν το Cluster 00. Οι περισσότερες σχέσεις προέρχονται από ζεύγη που εμπλέκουν τον τομέα C ως κύριο κόμβο επίδρασης, με τις διασυνδέσεις Sector-C-Sector-E και Sector-C-Sector-D να εμφανίζουν τη μεγαλύτερη εμπλουτισμένη συμμετοχή ($\text{enrichment} \approx 3.9\times - 15.7\times$). Οι μετρικές $|\Delta|$ και sign_follow δείχνουν μέτριες μεταβολές (0.3–0.6) με ποικίλο βαθμό ευθυγράμμισης, γεγονός που υποδηλώνει ήπιες αλλά συνεπείς επιδράσεις ανάμεσα στους μεσαίους τομείς του συστήματος. Το σύμπλεγμα αυτό χαρακτηρίζεται από σταθερές, περιφερειακά εστιασμένες αλληλεπιδράσεις που διασυνδέουν τις C και E.

Πίνακας 22: Sector-A $\rightarrow$ Sector-A-Sector-E – Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
X00	Sector-A	50.0	50.0
X01	Sector-A	50.0	50.0

Πίνακας 23: Sector-A-Sector-D (mixed) $\rightarrow$ Sector-A-Sector-E – Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
X00	Sector-A	50.0	50.0
X06	Sector-D	50.0	50.0

Ανάλυση καθοδηγούμενης πλευράς. Οι δύο πίνακες δείχνουν ότι η καθοδήγηση εστιάζει κυρίως στους τομείς A και D, με ισοκατανεμημένες συνεισφορές ($|\Delta|_{\text{wtd}} \approx 50\%$). Η σχέση Sector-A $\rightarrow$ Sector-A-Sector-E υποδηλώνει εσωτερική σταθεροποίηση του τομέα A, ενώ η Sector-A-Sector-D $\rightarrow$ Sector-A-Sector-E αποτυπώνει διατομεακή διάδοση από τη D προς E, υποδεικνύοντας μεταφορά επιρροής μέσω της περιφέρειας.

Πίνακας 24: Sector-A $\rightarrow$ Sector-A-Sector-E – Affected stems in Sector-A

Stem	$ \Delta $ -wtd (%)	Count (%)
X00	100.0	100.0

Πίνακας 25: Sector-A $\rightarrow$ Sector-A-Sector-E – Affected stems in Sector-E

Stem	$ \Delta $ -wtd (%)	Count (%)
X08	51.2	50.0
X09	48.8	50.0

Ανάλυση επηρεαζόμενης πλευράς. Οι Πίνακες δείχνουν ότι το εσωτερικό του τομέα A παραμένει πλήρως ενεργό ($|\Delta|_{\text{wtd}} = 100\%$), ενώ η επίδραση επεκτείνεται σχεδόν ισόποσα στους κόμβους X08 και X09 του τομέα E. Αυτό αποκαλύπτει έναν άξονα μετάδοσης από το A προς το E, με διατήρηση της εσωτερικής συνέπειας και ήπια μεταφορά επιρροής στην περιφέρεια.

Η συμμετοχή των κυριότερων συνδυασμών κυμαίνεται γύρω στο 3.2%, με enrichment $\approx 3.9\times - 15.7\times$ και μέσο $|\Delta| \approx 0.3 - 0.6$. Το Cluster 00 φαίνεται να αντιπροσωπεύει μια σταθερή, συνδετική δομή μεταξύ των μεσαίων τομέων του Lorenz-96, όπου οι επιδράσεις της καθοδήγησης είναι τοπικά εστιασμένες και ενεργοποιούν μεταφορά πληροφορίας με ελεγχόμενη ένταση.

Καθώς ακολουθείται το ίδιο μοτίβο ανάλυσης δεδομένων, οι πίνακες με τις σχετικές πληροφορίες για κάθε cluster παρατίθενται στην Ενότητα 7 στο Παράρτημα.

Σύνθεση Cluster 01. Ο Πίνακας ?? συνοψίζει τους συνδυασμούς καθοδήγησης που συνθέτουν το Cluster 01. Σε αντίθεση με το προηγούμενο σύμπλεγμα, εδώ οι σχέσεις είναι πολυκεντρικές και συμμετρικές: οι περισσότερες αφορούν διατομεακές ζεύξεις μεταξύ των Sectors A-E, A-C, B-D και D-E, με πολύ χαμηλές τιμές $|\Delta|$ (0.0-0.034) και μικρή ενίσχυση (enrichment $\approx 1.05\times$). Το γεγονός αυτό υποδηλώνει ένα δίκτυο ήπιων, σχεδόν αδρανών αλληλεπιδράσεων, όπου η καθοδήγηση διαχέεται ομοιόμορφα χωρίς να δημιουργεί έντονες μεταβολές. Το Cluster 01 επομένως φαίνεται να αναπαριστά μια κατάσταση ομοιόμορφης ισορροπίας στην οποία οι τομείς αλληλεπιδρούν μεν, αλλά χωρίς να υπερτονίζουν κάποια κατεύθυνση ή τοπική δυναμική.

Ερμηνεία του Cluster 01. Οι κυριότερες σχέσεις (Sector-A-Sector-E, Sector-A-Sector-C, Sector-B-Sector-D) εμφανίζουν σχεδόν ισοδύναμα ποσοστά συμμετοχής ($\approx 0.8\%$ η καθεμία) και enrichment $\approx 1.05\times$, γεγονός που φανερώνει απουσία έντονης ιεράρχησης ή εξειδίκευσης. Οι τιμές sign_follow παραμένουν χαμηλές (0.0-0.18), υποδεικνύοντας ότι οι μεταβολές που συμβαίνουν είναι σε μεγάλο βαθμό τυχαίες και δεν ακολουθούν σαφή προσανατολισμό ως προς την αναμενόμενη κατεύθυνση της διάχυσης. Το σύμπλεγμα αυτό αντιπροσωπεύει λοιπόν την «ουδέτερη βάση» του συστήματος, όπου οι σχέσεις σταθεροποιούνται γύρω από χαμηλές τιμές $|\Delta|$ και η καθοδήγηση λειτουργεί απλώς συντηρητικά.

Ανάλυση καθοδηγούμενης πλευράς. Η ανάλυση των καθοδηγούμενων κόμβων δείχνει ότι στους συνδυασμούς Sector-A-Sector-B $\rightarrow$ Sector-B-Sector-C και Sector-B-Sector-D $\rightarrow$ Sector-B-Sector-C, οι κυρίαρχοι φορείς καθοδήγησης είναι οι κόμβοι X02 (τομέας B) και X06-X07 (τομέας D). Η συμμετοχή τους κυμαίνεται γύρω στο 40-47% της σταθμισμένης μεταβολής, με τους κόμβους X00-X01 (τομέας A) να παίζουν δευτερεύοντα ρόλο ($\approx 16-34\%$). Αυτό δείχνει ότι οι τομείς B και D λειτουργούν ως κύριοι αγωγοί καθοδήγησης, ενώ ο A παραμένει σταθεροποιητικός, απορροφώντας τις αλληλεπιδράσεις χωρίς σημαντική ανατροπή της τοπικής του δυναμικής.

Ανάλυση επηρεαζόμενης πλευράς. Οι Πίνακες των επηρεαζόμενων stems δείχνουν σχεδόν συμμετρική κατανομή: στον τομέα B, ο X02 συγκεντρώνει το 87-95% της μεταβολής, ενώ ο X03 παραμένει οριακά ενεργός. Αντίστοιχα, στην πλευρά C, οι κόμβοι X04-X05 μοιράζονται σχεδόν ισόποσα τη μεταβολή ($\approx 60\% - 40\%$). Η ομοιομορφία αυτή υποδεικνύει ότι η καθοδήγηση δεν ενισχύει συγκεκριμένες διαδρομές αλλά διαχέεται ήπια ανάμεσα στους τομείς B και C, λειτουργώντας ως μηχανισμός μικρής διόρθωσης αντί για στοχευμένη ώθηση.

Η συνολική συμμετοχή των συνδυασμών είναι χαμηλή ($\approx 0.8\%$), με enrichment $\approx 1.05\times$ και μέσο $|\Delta| < 0.04$. Το Cluster 01 αποτελεί επομένως τη «ζώνη χαμηλής ενέργειας» του συστήματος Lorenz-96: ένα δίκτυο σταθεροποιημένων συσχετίσεων όπου η καθοδήγηση διαχέεται με ελάχιστη επιρροή και χωρίς σαφή κατεύθυνση μεταφοράς. Σε αντιδιαστολή με τα υπόλοιπα συμπλέγματα, λειτουργεί ως φόντο ισορροπίας, πάνω στο οποίο αναπτύσσονται οι πιο ενεργές και επιλεκτικές δυναμικές των άλλων συστάδων.

Σύνθεση Cluster 02. Το Cluster 02 αποτελεί μια μικρή αλλά έντονα στοχευμένη ομάδα αλληλεπιδράσεων, όπως φαίνεται στον Πίνακα ?. Οι κυρίαρχες σχέσεις προέρχονται από συνδυασμούς μεταξύ των Sectors A-B, B-C, C-D και A-D, με κύριες επιδράσεις προς τα ζεύγη Sector-E. Η εμπλουτισμένη συμμετοχή είναι ιδιαίτερα υψηλή (enrichment $\approx 6.9\times - 10.3\times$), ενώ οι μέσες μεταβολές $|\Delta|$ κυμαίνονται γύρω στο 0.2 - 0.34. Αυτό δείχνει ότι το σύμπλεγμα συγκεντρώνει λίγες αλλά ενεργές αλληλεπιδράσεις, οι οποίες προκαλούν ουσιαστική μεταβολή στο τοπικό δυναμικό του συστήματος.

Ερμηνεία του Cluster 02. Οι συνδυασμοί Sector-C-Sector-E και Sector-A-Sector-E εμφανίζονται επανειλημμένα ως αποδέκτες καθοδήγησης, δηλώνοντας ότι ο τομέας E λειτουργεί ως τελικός δέκτης επιρροών. Η συμμετοχή των ζευγών A-B και B-C ως πηγές δείχνει ότι η ενέργεια της καθοδήγησης μεταδίδεται από τα εσωτερικά τμήματα του συστήματος (A-D) προς τα περιφερειακά (E). Η απουσία θετικού sign_follow (0.0 σε όλες τις περιπτώσεις) υποδηλώνει ότι οι μεταβολές αυτές δεν ευθυγραμμίζονται με τις αναμενόμενες, αλλά αντιπροσωπεύουν αντιδραστικές αποκλίσεις — δηλαδή τοπικές διαταραχές που επανακαταλαμβάνουν ενέργεια αντί να τη σταθεροποιούν.


Ανάλυση καθοδηγούμενης πλευράς. Η καθοδήγηση προέρχεται κυρίως από τα ζεύγη Sector-A-Sector-B και Sector-B-Sector-C, όπου οι κόμβοι X00-X02-X05 μοιράζονται ισόποσα τη σταθμισμένη μεταβολή ($\approx 50\%$). Αυτό φανερώνει έναν καθαρό μηχανισμό μετάδοσης κατά μήκος της αλυσίδας $A \rightarrow B \rightarrow C$, μέσω του οποίου ενεργοποιούνται οι αντίστοιχες συνδέσεις προς E. Οι τομείς αυτοί λειτουργούν ως «ενεργά ενδιάμεσα στάδια» που ενισχύουν τη ροή της καθοδήγησης και καθορίζουν την κατεύθυνση διάδοσης.

Ανάλυση επηρεαζόμενης πλευράς. Στην πλευρά των επηρεαζόμενων stems, παρατηρείται συμμετρική απόκριση μεταξύ των X08-X09 (τομέας E), με ποσοστά $|\Delta|_{\text{wtd}}$ περίπου 50 %. Η ίδια δομή επαναλαμβάνεται τόσο για το ζεύγος $A-B \rightarrow A-E$ όσο και για το $B-C \rightarrow C-E$, γεγονός που αποδεικνύει ότι η καθοδήγηση δρα με συνέπεια και προβλεψιμότητα στα άκρα του συστήματος. Τα εσωτερικά stems (π.χ. X00, X05) παραμένουν πλήρως ενεργά ($|\Delta|_{\text{wtd}} = 100\%$), επιβεβαιώνοντας ότι η επίδραση προέρχεται από το κέντρο και καταλήγει προς τα σύνορα του μοντέλου.

Η συνολική συμμετοχή των κορυφαίων συνδυασμών φτάνει το 8.3 %, με πολύ υψηλές τιμές enrichment ($\approx 7 - 10\times$) και μεσαίες προς υψηλές μεταβολές $|\Delta|$ (0.19 – 0.34). Το Cluster 02 αντιπροσωπεύει ένα ενεργό υποσύστημα του Lorenz-96, στο οποίο η καθοδήγηση προκαλεί εντονότερη, μη ευθυγραμμισμένη απόκριση, αντιπροσωπεύοντας φάσεις ανακατανομής ενέργειας και αστάθειας. Πρακτικά, λειτουργεί ως ζώνη μετάδοσης, όπου η καθοδήγηση διαπερνά διαδοχικά τους τομείς A-B-C πριν καταλήξει στον E, αναδιαμορφώνοντας τις ισορροπίες του συστήματος.

Ο αριθμός των δειγμάτων που ανήκουν στο Cluster03 είναι αμελητέος (7) και δεν θα αναλυθούν

Αφού αναλύθηκαν τα επιμέρους clusters, παρουσιάζεται συνολικά η κατανομή όλων των σχέσεων στο επίπεδο $|\Delta|$ -alignment, με χρωματική διάκριση ανά cluster.




Σχήμα 19: Όλες οι σχέσεις στον χώρο alignment- $|\Delta|$, χρωματισμένες ανά cluster ($K = 4$) για το Lorenz-96. Οι διακεκομμένες γραμμές υποδεικνύουν ενδεικτικά κατώφλια (alignment ≈ 0.50 , $|\Delta| \approx 0.05$) για οπτικό διαχωρισμό μεταξύ ήπιων/ευθυγραμμισμένων και ισχυρών/μη ευθυγραμμισμένων μεταβολών.

Για να εμβαθύνουμε στη δυναμική που υποδηλώνει το διάγραμμα του Σχήματος 19, παρατίθεται ο Πίνακας 26, ο οποίος συνοψίζει τη συμπεριφορά των Cluster 00–03 στις τέσσερις περιοχές του επιπέδου

Πίνακας 26: Κατανομή τεταρτημορίων (%) ανά cluster και weight tag για το Lorenz-96.

Cluster	Weight	Q1	Q2	Q3	Q4
C00	neg_0_7	0.0	65.3	34.7	0.0
	neg_0_3	0.0	96.0	4.0	0.0
	pos_0_3	2.7	76.0	0.0	21.3
	pos_0_7	0.0	0.0	0.0	100.0
C01	neg_0_7	0.1	51.3	48.5	0.1
	neg_0_3	0.0	81.3	18.7	0.0
	pos_0_3	0.1	78.8	20.7	0.4
	pos_0_7	0.5	46.8	48.2	4.4
C02	neg_0_7	0.0	0.0	0.0	100.0
	neg_0_3	37.5	62.5	0.0	0.0
	pos_0_3	0.0	100.0	0.0	0.0
	pos_0_7	0.0	33.3	66.7	0.0
C03	neg_0_7	0.0	0.0	0.0	100.0
	neg_0_3	18.2	54.5	0.0	27.3
	pos_0_3	0.0	100.0	0.0	0.0
	pos_0_7	0.0	27.3	54.5	18.2



Σχήμα 20: Κατανομή τεταρτημορίων ανά weight tag για τα Clusters 00–03 στο Lorenz–96. Κάθε υπογράφημα εμφανίζει 16 μπάρες (4 βάρη × 4 τεταρτημόρια).

Συσχέτιση συμπεριφοράς συστάδων με τα τεταρτημόρια. Η κατανομή των ποσοστών ανά τεταρτημόριο στον Πίνακα 26 ποσοτικοποιεί τη διαφορετική δυναμική που χαρακτηρίζει κάθε cluster του Lorenz–96. Τα C00 και C01 συγκεντρώνουν το μεγαλύτερο μέρος των σχέσεων στη ζώνη Q2_HighAlign_LowDelta, γεγονός που υποδηλώνει σταθερή και ευθυγραμμισμένη απόκριση ανάμεσα στην καθοδήγηση και στο μοντέλο το οποίο στην προκειμένη περίπτωση ακολουθεί συνεκτικά τις συσχετίσεις που έχει μάθει κατά την διάρκεια της εκπαίδευσης του. Αντίθετα, τα C02 και C03 εμφανίζουν σημαντική μετατόπιση προς τα Q4 (και εν μέρει Q3) όταν αυξάνεται το βάρος καθοδήγησης, γεγονός που φανερώνει περιοχές έντονης αντίδρασης και μη-ευθυγραμμισμένων μεταβολών.


Η σύγκριση μεταξύ αρνητικών και θετικών βαρών δείχνει ότι, ενώ τα μέτρια αρνητικά βάρη ενισχύουν την ευθυγράμμιση (κυριαρχία Q2), τα θετικά προκαλούν μετατόπιση της ενέργειας προς περιοχές υψηλής μεταβολής (Q4), όπου η καθοδήγηση υπερισχύει της φυσικής σταθερότητας του συστήματος. Συνολικά, αυτές οι τάσεις καταδεικνύουν ότι η καθοδήγηση στο Lorenz–96 δρα με διπλό ρόλο: στα σταθερά, καλά μαθημένα μοτίβα λειτουργεί υποστηρικτικά, ενώ στα πιο χαοτικά ή ευαίσθητα υποχώρια εισάγει ελεγχόμενη διαταραχή, αποκαλύπτοντας έτσι τη λεπτή ισορροπία μεταξύ εκμάθησης και εξαναγκασμένης δυναμικής.

5.3 Traffic

Στο δίκτυο Caltrans PeMS–SF, οι σταθμοί (400000–400030) καλύπτουν κρίσιμες αρτηρίες του κόλπου του Σαν Φρανσίσκο, όπως τους αυτοκινητοδρόμους US-101, I-80, I-880, SR-85, I-680 και I-580. Για να είναι δυνατή η ερμηνεία των αποτελεσμάτων της καθοδηγούμενης διάχυσης σε χωρικό επίπεδο, οι αισθητήρες ομαδοποιήθηκαν σε λειτουργικά συνεκτικές ζώνες ροής με βάση τη γεωγραφική τους θέση και τον κυκλοφοριακό ρόλο τους. Συγκεκριμένα: η ομάδα *South Bay Core* (400001, 400017, 400030) αντιπροσωπεύει τον κύριο πυρήνα μετακινήσεων γύρω από το San Jose, με έντονη ημερήσια συμμετρία (πρωινή εισροή, απογευματινή εκροή)· η *US-101 Axis* (400000, 400010) αποτυπώνει τη ραχοκοκαλιά βορρά–νότου της χερσονήσου, η οποία παρουσιάζει χρόνια συμφόρηση και λειτουργεί ως βασικό κανάλι μεταφοράς ροής· η *East Bay Waterfront Arc* (400009, 400026, 400027) περιλαμβάνει το παραλιακό τόξο Berkeley–Oakland–Richmond, όπου οι ροές εμφανίζουν ισχυρή χωρική συσχέτιση και φαινόμενα διάδοσης συμφόρησης· ενώ η ομάδα *Inland East Bay / Misc* (400025, 400015) καλύπτει τον εσωτερικό άξονα Walnut Creek–I-680, καθώς και κόμβους που δεν ανήκουν σε κάποιο κύριο cluster. Η ομαδοποίηση αυτή μειώνει την πολυπλοκότητα του πειραματικού χώρου, σταθεροποιεί την εκμάθηση συσχετίσεων (εντός και μεταξύ ζωνών) και καθιστά

την καθοδήγηση πιο ερμηνεύσιμη: οι μεταβολές στις μετρικές Δ και Align μπορούν πλέον να συνδεθούν άμεσα με διακριτούς ρόλους ροής (π.χ. κύριος διάδρομος, παράκτιο τόξο, εσωτερική παράκαμψη). Με τον τρόπο αυτό, το μοντέλο διάχυσης λειτουργεί ως ένα δίκτυο μεταφοράς πληροφορίας όπου οι επιδράσεις στο εσωτερικό των ομάδων αντανακλούν συνεκτικές χωρικές ροές, ενώ η αλληλεπίδραση μεταξύ των ομάδων αποτυπώνουν τη διάδοση συμμόρφωσης μεταξύ διαδρόμων δηλαδή ένα φαινόμενο ανάλογο με τη μεταφορά ενέργειας που παρατηρήθηκε στο Lorenz-96.

Όπως φαίνεται στον Πίνακα 77 του Παραρτήματος, παρουσιάζονται αναλυτικά οι μετρικές καθοδήγησης ανά `guided_pair` για το πλήρες κυκλοφοριακό υποσύνολο PEMS-SF. Με βάση αυτά τα συγκεντρωτικά αποτελέσματα, παράγονται τα παρακάτω διαγράμματα, τα οποία απεικονίζουν τη μέση συμπεριφορά των μετρικών σε επίπεδο συνόλου και αναδεικνύουν τις χωρικές σχέσεις μεταξύ των ομάδων αισθητήρων. Η ανάλυση αυτή επιτρέπει να παρατηρηθούν τα πρότυπα ευθυγράμμισης και μεταβολής (*Align*, Δ) όπως εκδηλώνονται μεταξύ των κύριων διαδρόμων του δικτύου (US-101, I-80/I-580, I-880/SR-85) και να αξιολογηθεί ο τρόπος με τον οποίο η καθοδήγηση επιδρά στη συνοχή των χωρικών ροών.



Σχήμα 21: Συνοπτική απεικόνιση των βασικών μετρικών καθοδήγησης σε επίπεδο συνόλου.


Η Εικόνα 21α' δείχνει ότι οι μεταβολές $|\Delta|$ είναι ελάχιστες για ενδιάμεσες τιμές βάρους (-0.3 έως $+0.3$) και αυξάνονται ξανά στα άκρα (-0.7 και $+0.7$). Το εύρημα αυτό υποδεικνύει ότι το δίκτυο ροής παραμένει πιο σταθερό υπό μέτρια καθοδήγηση, όπου οι μεταβολές μεταξύ των αισθητήρων περιορίζονται σε ελεγχόμενα πλαίσια. Στις ακραίες τιμές, αντίθετα, η καθοδήγηση ενισχύει απότομα τις χωρικές συσχετίσεις, προκαλώντας πιο έντονες μεταβολές στις συζευγμένες διαδρομές (π.χ. μεταξύ South Bay και East Bay).

Η Εικόνα 21β' παρουσιάζει την καμπύλη της ενεργειακής μεταβολής ($L_2 \Delta$), η οποία ακολουθεί παρόμοια μορφή: το ελάχιστο εμφανίζεται γύρω στο -0.3 , ενώ η συνολική «ενεργειακή απαίτηση» αυξάνεται σημαντικά για τα άκρα βάρη. Αυτό σημαίνει ότι το σύστημα χρειάζεται περισσότερη ενέργεια προσαρμογής όταν η καθοδήγηση είναι πολύ ισχυρή, καθώς επιχειρεί να αναδιαμορφώσει συσχετίσεις σε πολλαπλές κατευθύνσεις ροής. Σε ήπια αρνητική καθοδήγηση, αντίθετως, η δυναμική παραμένει ομαλή και τοπική.

Στην Εικόνα 21γ', η επιλεκτικότητα μειώνεται προοδευτικά από το -0.7 προς το $+0.7$, υποδηλώνοντας ότι σε μέτριες ή θετικές τιμές βάρους η καθοδήγηση τείνει να διαδίδει την επιρροή της σε περισσότερες ακμές του δικτύου. Η πιο υψηλή επιλεκτικότητα στις αρνητικές τιμές δείχνει ότι οι επεμβάσεις εστιάζουν αυστηρότερα στα στοχευμένα ζεύγη, ενώ η σταδιακή πτώση προς τα θετικά βάρη αντικατοπτρίζει αύξηση της διασποράς των επιδράσεων μεταξύ διαδρόμων. Μεταφορικά, το δίκτυο περνά από μια κατάσταση τοπικής εξισορρόπησης σε πιο διάχυτη χωρική σύζευξη.

Τέλος, η Εικόνα 21δ' δείχνει ότι η μέση διαρροή εκτός στόχου (spill) αυξάνεται μονότονα από το -0.7 προς

το +0.7, υποδεικνύοντας ότι η θετική καθοδήγηση προκαλεί μεγαλύτερη διάδοση της επίδρασης σε μη στοχευμένους αισθητήρες. Η χαμηλότερη τιμή στο αρνητικό άκρο (−0.7) αντιστοιχεί σε πιο «καθαρή» καθοδήγηση, όπου η επίδραση παραμένει εντός των αναμενόμενων χωρικών σχέσεων. Έτσι, η ήπια αρνητική καθοδήγηση φαίνεται να επιτυγχάνει την πιο αποτελεσματική ισορροπία μεταξύ ενέργειας αλλαγής και στοχευμένης παρέμβασης, ενώ τα θετικά βάρη οδηγούν σε φαινόμενα υπερδιάχυσης στις γειτονικές ροές.




Σχήμα 22: Σταθμισμένος μέσος βαθμός ευθυγράμμισης (Weighted Alignment) μεταξύ αναμενόμενης και παρατηρούμενης μεταβολής.

Η **Εικόνα 22** παρουσιάζει τη μέση σταθμισμένη ευθυγράμμιση (Weighted Alignment) μεταξύ της αναμενόμενης και της παρατηρούμενης μεταβολής για κάθε τιμή βάρους. Η καμπύλη δείχνει μέγιστη ευθυγράμμιση για μέτρια αρνητική καθοδήγηση (−0.3, 0.61), ενώ μειώνεται προοδευτικά τόσο προς τις ισχυρά αρνητικές (−0.7) όσο και προς τις θετικές τιμές (+0.7, 0.27). Το αποτέλεσμα αυτό υποδηλώνει ότι η καθοδήγηση είναι πιο αποτελεσματική όταν ασκείται με ήπια ένταση, επιτρέποντας στο μοντέλο να προσαρμόζει τις χωρικές συσχετίσεις χωρίς να προκαλεί υπερβολικές αντιδράσεις στο δίκτυο. Σε αυτό το καθεστώς, οι αισθητήρες εντός των ίδιων διαδρόμων (π.χ. South Bay ή East Bay) διατηρούν συνεκτικές μεταβολές ως προς τη ροή, ενώ η υπερβολικά ισχυρή καθοδήγηση αποσυντονίζει τη συμφασικότητα και οδηγεί σε μείωση της συνολικής χωρικής συνέπειας.


Clustering. Για την ανάλυση των επιδράσεων καθοδήγησης στο κυκλοφοριακό σύνολο PEMS-SF, εξετάστηκε ένας εκτενής χώρος αλληλεπιδράσεων: οι 45 καθοδηγούμενες ακμές (guided pairs) μεταξύ αισθητήρων επηρεάζουν τις υπόλοιπες 45 ακμές του υπογραφήματος, και καθώς αυτό επαναλαμβάνεται για 4 περιπτώσεις βαρών πολυπλοκότητα αυξάνεται σημαντικά με αποτέλεσμα να είναι δύσκολη η απλή οπτική ή διαισθητική ερμηνεία. Για τον λόγο αυτό είναι αναγκαία η αυτοματοποιημένη ομαδοποίηση για την ανάδειξη συνεκτικών προτύπων ροής.

Σε αντίθεση με την ανάλυση του μουσικού συνόλου, εδώ χρησιμοποιήθηκε το Gaussian Mixture Model (GMM) ως πιο εύκαμπτη παραμετρική μέθοδος, ικανή να περιγράψει επικαλυπτόμενα clusters και συνεχείς μεταβάσεις επιδράσεων. Η επιλογή του βέλτιστου αριθμού συστάδων K πραγματοποιήθηκε βάσει των κριτηρίων Akaike Information Criterion (AIC) και Bayesian Information Criterion (BIC). Όπως φαίνεται στο **Σχήμα 23**, και τα δύο κριτήρια παρουσιάζουν σαφή βελτίωση έως το $K = 4$, με τις καμπύλες να σταθεροποιούνται πέρα από αυτό το σημείο. Έτσι, το $K = 4$ επιλέχθηκε ως η βέλτιστη ισορροπία μεταξύ προσαρμογής και απλότητας, επιτρέποντας την ερμηνεία των συστάδων ως διακριτών «τρόπων απόκρισης» του δικτύου (π.χ. τοπική ενίσχυση, αντίρροπη μεταβολή, δια-διαδρομική διάχυση).



Σχήμα 23: Αξιολόγηση του αριθμού συστάδων (K) για το κυκλοφοριακό σύνολο PEMS-SF βάσει των κριτηρίων Bayesian Information Criterion (BIC) και Akaike Information Criterion (AIC). Οι χαμηλότερες τιμές αντιστοιχούν σε καλύτερη προσαρμογή του μοντέλου, με το $K = 4$ να αναδεικνύεται ως σημείο ισορροπίας μεταξύ πολυπλοκότητας και συνοχής.

Οπτικοποίηση δομής μέσω PCA. Αφού καθορίστηκε ο βέλτιστος αριθμός συστάδων ($K = 4$) με το GMM, εφαρμόστηκε η τελική ομαδοποίηση στις σχέσεις του κυκλοφοριακού γραφήματος. Για την οπτική απεικόνιση της εσωτερικής δομής χρησιμοποιήθηκε Principal Component Analysis (PCA), ώστε τα πολυδιάστατα δεδομένα να προβληθούν σε επίπεδο δύο κυρίων συνιστωσών. Η προβολή αυτή αποκαλύπτει πώς κατανέμονται τα clusters στον χώρο και κατά πόσο τα πρότυπα επίδρασης του δικτύου είναι σαφώς διαχωρισμένα ή αλληλεπικαλυπτόμενα, προσφέροντας μια συνοπτική εικόνα της χωρικής οργάνωσης των συσχετίσεων υπό καθοδήγηση.



Σχήμα 24: Προβολή των χαρακτηριστικών Δ στον χώρο των δύο κυριότερων συνιστωσών (PCA, $K=4$) για το κυκλοφοριακό σύνολο PEMS-SF. Κάθε σημείο αντιστοιχεί σε μία σχέση μεταξύ ζευγών αισθητήρων, ενώ το χρώμα υποδηλώνει τη cluster στην οποία ταξινομήθηκε (cluster 0 – μπλε, 1 – πορτοκαλί, 2 – πράσινο, 3 – κόκκινο). Η διάταξη αποκαλύπτει καθαρό διαχωρισμό μεταξύ των συστάδων, με το μεγαλύτερο σύμπλεγμα (cluster 0) να συγκεντρώνεται στο κεντρικό τμήμα του χώρου, ενώ τα υπόλοιπα διατάσσονται περιφερειακά. Το αποτέλεσμα υποδεικνύει διαφορετικά πρότυπα επίδρασης της καθοδήγησης, όπου ορισμένες ομάδες ακμών αντιδρούν τοπικά, ενώ άλλες παρουσιάζουν πιο έντονη χωρική διαφοροποίηση ή αντιρροπιστική συμπεριφορά.

Η προβολή μέσω PCA αποκαλύπτει τη γενική γεωμετρία των συστάδων, όμως δεν αρκεί για να ερμηνευτεί το λειτουργικό τους περιεχόμενο. Για να κατανοηθεί η ταυτότητα κάθε cluster, απαιτείται εξέταση της εσωτερικής

της σύνθεσης δηλαδή ποιες σχέσεις αισθητήρων και τύποι επιδράσεων την χαρακτηρίζουν. Οι πίνακες που ακολουθούν παρουσιάζουν τη σύνθεση κάθε cluster, με τα ποσοστά συμμετοχής των κύριων διαδρόμων και τις μέσες τιμές μετρικών όπως $|\Delta|$, alignment και επιλεκτικότητα. Μέσα από αυτήν την ανάλυση αναδεικνύεται ο ρόλος κάθε cluster ως προς τη χωρική της συμπεριφορά αν, για παράδειγμα, αντιστοιχεί σε τοπική σύζευξη, αντίρροπη ροή ή ευρύτερη διάχυση επιρροής στο δίκτυο.

Πίνακας 27: Κορυφαίοι συνδυασμοί καθοδήγησης για το Cluster 00.

guided_group	affected_pair_group	cnt	cluster share (%)	baseline share (%)	enrichment	mean $ \Delta $	sign_follow
East Bay Waterfront Arc–South Bay Core (mixed)	East Bay Waterfront Arc–South Bay Core	33	3.7	3.6	1.013	0.089	0.000
East Bay Waterfront Arc–South Bay Core (mixed)	South Bay Core–South Bay Core	27	3.0	1.4	2.210	0.090	0.148
East Bay Waterfront Arc–South Bay Core (mixed)	East Bay Waterfront Arc–US-101 Axis	27	3.0	2.7	1.105	0.068	0.074
East Bay Waterfront Arc–South Bay Core (mixed)	South Bay Core–US-101 Axis	27	3.0	2.7	1.105	0.119	0.000
South Bay Core–US-101 Axis (mixed)	East Bay Waterfront Arc–South Bay Core	26	2.9	2.7	1.064	0.117	0.000
East Bay Waterfront Arc–US-101 Axis (mixed)	East Bay Waterfront Arc–South Bay Core	25	2.8	2.7	1.023	0.115	0.000

Πίνακας 28: EBWA–SBC (mixed) → EBWA–SBC – Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
E of Carlson Blvd @ I-80-E (Richmond)	East Bay Waterfront Arc	21.3	19.7
N First St @ I-880-S (Santa Clara)	South Bay Core	20.4	18.2
Lakeshore Ave @ I-580-E (Oakland)	East Bay Waterfront Arc	16.2	16.7
US-101-N (Santa Clara)	South Bay Core	15.3	16.7
Bascom Ave @ SR-85-S (Santa Clara)	South Bay Core	14.3	15.2

Πίνακας 29: EBWA–SBC (mixed) → EBWA–US-101 – Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
Lakeshore Ave @ I-580-E (Oakland)	East Bay Waterfront Arc	17.6	16.7
Bascom Ave @ SR-85-S (Santa Clara)	South Bay Core	17.1	16.7
University Ave @ I-80-W (Berkeley)	East Bay Waterfront Arc	16.8	16.7
US-101-N (Santa Clara)	South Bay Core	16.7	16.7
N First St @ I-880-S (Santa Clara)	South Bay Core	16.2	16.7

Πίνακας 30: EBWA–SBC (mixed) → EBWA–SBC – Affected stems in EBWA

Stem	$ \Delta $ -wtd (%)	Count (%)
University Ave @ I-80-W (Berkeley)	73.3	72.7
Lakeshore Ave @ I-580-E (Oakland)	26.7	27.3

Πίνακας 31: EBWA–SBC (mixed) → EBWA–SBC – Affected stems in SBC

Stem	$ \Delta $ -wtd (%)	Count (%)
Bascom Ave @ SR-85-S (Santa Clara)	45.6	48.5
N First St @ I-880-S (Santa Clara)	31.6	27.3
US-101-N (Santa Clara)	22.8	24.2

Πίνακας 32: EBWA–SBC (mixed) → EBWA–US-101 – Affected stems in EBWA

Stem	$ \Delta $ -wtd (%)	Count (%)
E of Carlson Blvd @ I-80-E (Richmond)	49.2	33.3
University Ave @ I-80-W (Berkeley)	42.9	33.3
Lakeshore Ave @ I-580-E (Oakland)	7.9	33.3

Πίνακας 33: EBWA–SBC (mixed) → EBWA–US-101 – Affected stems in US-101 Axis

Stem	$ \Delta $ -wtd (%)	Count (%)
SR-37 @ US-101 (Marin)	50.8	66.7
San Bruno Ave @ US-101-N (San Mateo)	49.2	33.3

Σύντομη ποσοτική περίληψη. Μερίδιο κορυφαίων συνδυασμών $\approx 2.8\%$ – 3.7% . Ενίσχυση $\approx 1.01 \times$ – $2.21 \times$. Μέση $|\Delta| \approx 0.068$ – 0.119 .

Σύνθεση Cluster 00. Ο Πίνακας 27 παρουσιάζει τους σημαντικότερους συνδυασμούς καθοδήγησης που συνθέτουν το πρώτο σύμπλεγμα (Cluster 00). Κάθε γραμμή αντιστοιχεί σε έναν συγκεκριμένο συνδυασμό μεταξύ καθοδηγούμενης ομάδας (guided_group) και επηρεαζόμενης σχέσης (affected_pair_group), συνοδευόμενο από δείκτες που

περιγράφουν τη σχετική του συμμετοχή μέσα στη cluster (cluster share), τη συχνότητά του στο σύνολο αναφοράς (baseline share), καθώς και τον λόγο ενίσχυσης (enrichment), που δείχνει πόσο πιο έντονα εμφανίζεται η σχέση στο συγκεκριμένο σύμπλεγμα. Οι μετρικές $|\Delta|$ και sign_follow αποτυπώνουν, αντίστοιχα, το μέσο μέγεθος μεταβολής των συσχετίσεων και τον βαθμό συμφωνίας τους με την αναμενόμενη κατεύθυνση (δηλαδή κατά πόσο η μεταβολή ακολουθεί το πρόσημο του πίνακα αναμενόμενων επιδράσεων E).

Το Cluster 00 κυριαρχείται από αλληλεπιδράσεις μεταξύ των ομάδων East Bay Waterfront Arc (EBWA) και South Bay Core (SBC), με πιο έντονη παρουσία των συνδυασμών EBWA-SBC (mixed) $\rightarrow$ EBWA-SBC και EBWA-SBC (mixed) $\rightarrow$ SBC-SBC. Οι τιμές εμπλουτισμού κοντά στο $1.0-1.1\times$ για τις ενδο-περιφερειακές σχέσεις δείχνουν ότι η cluster αναπαριστά το βασικό υπόβαθρο ροής του δικτύου, όπου η καθοδήγηση λειτουργεί ομαλά εντός των ίδιων διαδρόμων. Αντίθετα, η υψηλότερη τιμή $2.21\times$ για τη σχέση EBWA-SBC $\rightarrow$ SBC-SBC υποδηλώνει τοπική ενίσχυση και ισχυρή χωρική συζευξη εντός του νοτίου κόμβου (South Bay). Οι μέσες μεταβολές συσχέτισης παραμένουν σχετικά μικρές ($|\Delta| \approx 0.07-0.12$), ενώ τα sign_follow είναι χαμηλά έως μέτρια, χαρακτηρίζοντας το σύμπλεγμα ως «σταθερό υπόβαθρο» ροής που αντιδρά προβλέψιμα στις επεμβάσεις καθοδήγησης.

Ανάλυση καθοδηγούμενης πλευράς. Οι Πίνακες 28 και 29 παρουσιάζουν τα κυρίαρχα σημεία καθοδήγησης (guided stems) που συμβάλλουν στους δύο σημαντικότερους συνδυασμούς του συμπλέγματος. Στην περίπτωση EBWA-SBC $\rightarrow$ EBWA-SBC, η καθοδήγηση εκφράζεται κυρίως μέσω των αισθητήρων E of Carlson Blvd (Richmond) και N First St (San Jose), οι οποίοι αντιπροσωπεύουν τα άκρα του παραλιακού-νότιου τόξου. Οι τιμές $|\Delta|-\text{wtd} \approx 20$ και η συμμετοχή τους πάνω από 18 λειτουργούν ως ισχυροί μεταφορείς της επίδρασης. Οι υπόλοιποι σταθμοί (Lakeshore Ave, US-101 N, Bascom Ave) συνεισφέρουν μικρότερες αλλά σταθερές επιδράσεις, διατηρώντας τη συνοχή του άξονα EBWA-SBC.

Αντίστοιχα, στην καθοδήγηση EBWA-SBC $\rightarrow$ EBWA-US-101, οι ενεργοί κόμβοι μοιράζονται σχεδόν ισοδύναμα μεταξύ παραλιακών (Lakeshore Ave, University Ave) και νοτίων (Bascom Ave, N First St) αισθητήρων, ενώ το US-101 N εμφανίζεται ως κόμβος διαμεσολάβησης. Αυτό δείχνει ότι η καθοδήγηση μεταφέρεται με ελεγχόμενο τρόπο από το παραλιακό τόξο προς τον άξονα US-101, διαμορφώνοντας μια μορφή γέφυρας ροής μεταξύ East Bay και South Bay.

Ανάλυση επηρεαζόμενης πλευράς. Οι Πίνακες 30-33 παρουσιάζουν τους αισθητήρες που δέχονται την ισχυρότερη επίδραση της καθοδήγησης (affected stems). Στην ενδο-ομαδική σχέση EBWA-SBC $\rightarrow$ EBWA-SBC, οι κόμβοι του EBWA (University Ave, Lakeshore Ave) παρουσιάζουν έντονες μεταβολές ($|\Delta|-\text{wtd} \approx 70$ ενώ, στο SBC, οι Bascom Ave, N First St και US-101 N αντιδρούν συμμετρικά με ποσοστά 23-46. Αυτό υποδεικνύει ότι η καθοδήγηση προκαλεί ισόρροπη προσαρμογή μεταξύ των δύο περιοχών, χωρίς ασύμμετρη μεταφορά επιρροής.

Στη σχέση EBWA-SBC $\rightarrow$ EBWA-US-101, η επίδραση μετατοπίζεται προς τον άξονα US-101, με τους κόμβους SR-37 (Marin) και San Bruno (San Mateo) να απορροφούν σχεδόν το 100 ($|\Delta|-\text{wtd} \approx 50$ H σύζευξη αυτή δείχνει ότι το Cluster 00 λειτουργεί ως μηχανισμός μεταβίβασης καθοδήγησης από την παραλιακή ζώνη (EBWA) προς τον κεντρικό διάδρομο US-101, προάγοντας συντονισμένες προσαρμογές στις ροές των δύο πλευρών του κόλπου.

Συνολική ερμηνεία του Cluster 00. Συνολικά, το Cluster 00 αντιπροσωπεύει ένα υποδίκτυο με ήπια διάχυση πληροφορίας και μεταβολές συσχέτισης οι οποίες ευθυγραμμίζονται με τις αναμενόμενες χωρικές σχέσεις και παραμένουν σε ήπια ένταση. Οι αλληλεπιδράσεις EBWA-SBC αποτελούν τον πυρήνα της δραστηριότητας, ενώ η σταδιακή μεταφορά επιρροής προς τον άξονα US-101 δείχνει μια μορφή φυσικής διάχυσης καθοδήγησης μεταξύ παραλιακών και κεντρικών διαδρόμων. Η δυναμική αυτή συνάδει με τη συμπεριφορά του τεταρτημορίου Q2_HighAlign_LowDelta: η καθοδήγηση είναι καλά ευθυγραμμισμένη με τη χωρική δομή, διατηρώντας σταθερότητα και αποτρέποντας υπερβολικές μεταβολές στις ροές.

Καθώς ακολουθείται το ίδιο μοτίβο ανάλυσης δεδομένων, οι πίνακες με τις σχετικές πληροφορίες για κάθε cluster παρατίθενται στην Ενότητα 7 στο Παράρτημα.

Cluster 01. Το Cluster 01 χαρακτηρίζεται από διασυστάδια καθοδήγησης που ωθεί ροές προς τον άξονα US-101 μέσω South Bay Core (SBC). Κυριαρχούν οι συνδυασμοί EBWA-SBC (mixed) και Inland/Misc-SBC (mixed) με επηρεαζόμενες σχέσεις SBC-US-101 (μερίδιο 5.1-7.7%, εμπλουτισμός $1.88\times-2.81\times$). Οι μέσες τιμές $|\Delta|$ είναι υψηλές ($\approx 0.94-1.09$), ενώ το sign_follow είναι ουσιαστικά μηδενικό, στοιχείο που υποδηλώνει χαμηλή συμφωνία με την «αναμενόμενη» κατεύθυνση επιδράσεων και, άρα, πιο επιθετική/ανακατανεμητική παρέμβαση.

Καθοδηγούμενη πλευρά). Στους κορυφαίους συνδυασμούς, οι κόμβοι του East Bay Waterfront Arc (University Ave, Lakeshore Ave) και του SBC (Bascom Ave, N First St, US-101 N) μοιράζονται σχεδόν ισότιμα τον ρόλο «φορέα» της καθοδήγησης ($|\Delta|$ -wtd ≈ 16 –17%, Count ≈ 16 –17%). Αυτό δείχνει οργανωμένη ώθηση από παραλιακό και νότιο τόξο προς συνδέσεις που εμπλέκουν τον US-101.

Επηρεαζόμενη πλευρά (δέκτες επίδρασης). Στις σχέσεις EBWA–SBC $\rightarrow$ SBC–US-101, οι Bascom Ave και N First St απορροφούν το μεγαλύτερο μέρος της επίδρασης στο SBC ($|\Delta|$ -wtd 31–43%), ενώ στην πλευρά του US-101 δεσπάζει ο San Bruno με πλήρη απορρόφηση (100%). Αντίστοιχα, στο EBWA–SBC $\rightarrow$ Inland/Misc–US-101, οι Newell Ave (I-680) και Unk μοιράζονται την επίδραση ($\approx 50/50$), με τον San Bruno να μένει και πάλι ο μοναδικός δέκτης στην πλευρά US-101 (100%).

Ερμηνεία. Σε αντιδιαστολή με το «βασικό υπόβαθρο» του Cluster 00, το Cluster 01 αποτυπώνει ένα *καθεστώς έντονης μεταφοράς επιρροής* προς τον US-101 (ιδίως το San Bruno). Ο υψηλός εμπλουτισμός και οι μεγάλες $|\Delta|$ μαζί με χαμηλό sign_follow συνάδουν με τεταρτημόριο «HighDelta, LowAlign», δηλαδή, ένα μοτίβο ανακατανομής των χωρικών δεσμών παρά ευθυγράμμισης με το αναμενόμενο πρότυπο. Πρακτικά, η καθοδήγηση λειτουργεί ως ισχυρή γέφυρα ροής που σπρώχνει ζεύξεις του SBC προς τον US-101, με τον San Bruno να δρα ως σημείο συγκέντρωσης της μεταβολής.

Σύνθεση Cluster 02 . Το Cluster 02 αντιπροσωπεύει ένα καθεστώς *ενισχυμένης εσωτερικής σύζευξης* μεταξύ East Bay Waterfront Arc (EBWA) και South Bay Core (SBC), με κορυφαίους συνδυασμούς όπως EBWA–SBC (mixed) $\rightarrow$ EBWA–SBC και EBWA–SBC (mixed) $\rightarrow$ EBWA–EBWA. Τα μερίδια είναι αυξημένα (6.2%–9.2%), ενώ ο εμπλουτισμός φτάνει έως $5.1\times$, υποδεικνύοντας ισχυρή υπεραντιπροσώπηση των ενδο-παραλιακών και παραλιακο-νοτίων δεσμών. Οι μέσες μεταβολές $|\Delta|$ παραμένουν υψηλές (0.82–0.90) με σχεδόν μηδενικό sign_follow, δείχνοντας δυναμική, αλλά όχι απαραίτητα ευθυγραμμισμένη, αναπροσαρμογή των ροών.

Καθοδηγούμενη πλευρά (φορείς). Η καθοδήγηση προέρχεται κυρίως από τους κόμβους University Ave (Berkeley) και Lakeshore Ave (Oakland) στην πλευρά του EBWA, σε συνδυασμό με τους Bascom Ave, N First St και US-101 N στο SBC. Οι τιμές $|\Delta|$ -wtd γύρω στο 17 ανάμεσα στους παραλιακούς και νότιους κόμβους, με έντονη ροή πληροφορίας εντός της ίδιας χωρικής υποπεριοχής.

Επηρεαζόμενη πλευρά (δέκτες). Οι μεγαλύτερες μεταβολές παρατηρούνται στους κόμβους του EBWA, όπου ο E of Carlson (Richmond) εμφανίζει πλήρη απορρόφηση ($|\Delta|$ -wtd = 100 %, Count = 100 %). Στην πλευρά του SBC, οι Bascom Ave, US-101 N και N First St συμμετέχουν ισόρροπα ($|\Delta|$ -wtd ≈ 28 –39 %), σχηματίζοντας ένα τοπικά συνεκτικό τρίγωνο επίδρασης. Η έλλειψη σημαντικών αποδεκτών πέρα από αυτές τις περιοχές δείχνει περιορισμένη διάχυση της καθοδήγησης εκτός των βασικών ροικών διαδρόμων.

Ερμηνεία. Το Cluster 02 απεικονίζει μια *πυκνή, εσωτερικά ενισχυμένη ροή* μεταξύ East Bay και South Bay, όπου η καθοδήγηση παραμένει τοπική και ισχυρή, εντείνοντας τις συνδέσεις μεταξύ γειτονικών διαδρόμων χωρίς να προκαλεί εκτεταμένες ανακατανομές. Ο συνδυασμός υψηλού εμπλουτισμού και μεγάλου $|\Delta|$, σε συνδυασμό με χαμηλό sign_follow, τοποθετεί τη cluster κοντά στο τεταρτημόριο Q1_HighAlign_HighDelta – δηλαδή έντονη, τοπικά προσανατολισμένη ενίσχυση των ροών με μικρότερη αναφορά στο παγκόσμιο πρότυπο ευθυγράμμισης. Πρακτικά, λειτουργεί ως *ζώνη συντονισμού υψηλής ενέργειας* μεταξύ EBWA και SBC, όπου η καθοδήγηση πολλαπλασιάζει τις τοπικές αλληλεπιδράσεις αντί να διαχέεται προς τον US-101.

Σύνθεση Cluster 03 . Η cluster κυριαρχείται από δια-ομαδικές συνδέσεις που «δένουν» το Inland East Bay / Misc (Inland) με το South Bay Core (SBC) και το East Bay Waterfront Arc (EBWA). Οι ισχυρότεροι συνδυασμοί είναι EBWA–SBC (mixed) $\rightarrow$ Inland–SBC (9.5%, $3.50\times$) και EBWA–SBC (mixed) $\rightarrow$ EBWA–Inland (7.6%, $2.80\times$), ενώ ακολουθούν παραλλαγές με πηγή EBWA–US-101 και SBC–US-101. Οι μέσες $|\Delta|$ είναι μεσαίες–υψηλές (0.30–0.48) με πρακτικά μηδενικό sign_follow, δείχνοντας μοτίβο *ανακατανομής* δεσμών (χαμηλή ευθυγράμμιση) αντί για «εκλέπτυνση» του υπάρχοντος προτύπου.


Καθοδηγούμενη πλευρά (φορείς). Ως κύριοι φορείς της καθοδήγησης εμφανίζονται οι κόμβοι του EBWA (University Ave, Lakeshore Ave, και σε εναλλακτικό κορυφαίο combo ο E of Carlson) μαζί με τους Bascom, US-101 N και N First στο SBC. Οι συνεισφορές είναι σχεδόν ισοβαρείς ($|\Delta|$ -wtd ≈ 16 –17%, Count ≈ 16 –17%), υποδεικνύοντας ότι η ώθηση ξεκινά συντονισμένα από παραλιακούς και νότιους κόμβους για να περάσει προς Inland.

Επηρεαζόμενη πλευρά (δέκτες). Στο Inland, ο Unk και ο Newell (I-680) μοιράζονται την απορρόφηση ($\approx 59/41\%$ για Inland–SBC, $\approx 50/50\%$ για EBWA–Inland). Στο SBC, οι US-101 N και N First δέχονται το μεγαλύτερο μέρος ($|\Delta|$ -wtd ≈ 40 –46%), με τον Bascom να ακολουθεί ($\approx 15\%$). Στην πλευρά του EBWA για τη σχέση EBWA–Inland οι University ($\approx 48\%$), E of Carlson ($\approx 30\%$) και Lakeshore ($\approx 22\%$) απορροφούν την επίδραση. Το μοτίβο αυτό δείχνει στοχευμένη διοχέτευση προς Inland και ταυτόχρονα σύνδεση του SBC με τους εσωτερικούς διαδρόμους.

Ερμηνεία. Το Cluster 03 λειτουργεί ως *πύλη επαναζύγωσης* μεταξύ παραλιακού τόξου και δρόμων προς το εσωτερικό της πόλης καθώς η καθοδήγηση μεταφέρει ενέργεια από EBWA/SBC σε Inland και σε ακμές εκτός ομάδας, με μεσαίο–υψηλό $|\Delta|$ αλλά χαμηλή ευθυγράμμιση. Σε όρους τεταρτημορίων, η συμπεριφορά είναι LowAlign με $|\Delta|$ από μέτριο έως υψηλό (δηλ. μεταξύ Q3 και Q4), υποδηλώνοντας ότι η καθοδήγηση εδώ *αναδομεί* διαδρομές αντί να ενισχύει υπάρχουσες τοπικές συζεύξεις. Πρακτικά, οι κόμβοι Newell και Unk προκύπτουν ως ευαίσθητοι δέκτες μεταφοράς, ενώ οι US-101 N και N First λειτουργούν ως νότια σημεία διασύνδεσης προς τον εσωτερικό άξονα.

Quant mini-summary: Top-combos share ≈ 5.3 –9.5%; Enrichment $\approx 2.8\times$ –3.5 $\times$; Mean $|\Delta| \approx 0.30$ –0.48; sign_follow ≈ 0.0 .

Συμπεριφορά στο επίπεδο ευθυγράμμισης–μεταβολής. Αφού αναλύσαμε τη σύνθεση και τα πρότυπα ροής κάθε cluster, προχωρούμε σε μια ενοποιημένη απεικόνιση όλων των σχέσεων του κυκλοφοριακού δικτύου στο επίπεδο $|\Delta|$ (κατακόρυφος άξονας) έναντι alignment (οριζόντιος άξονας), με χρωματική κωδικοποίηση ανά cluster. Το διάγραμμα αυτό επιτρέπει να συσχετίσουμε την επίδραση της καθοδήγησης με τη γνώση που έχει αποκτήσει το μοντέλο κατά την εκπαίδευση, και να παρατηρήσουμε πώς η χωρική δυναμική των αισθητήρων εκδηλώνεται μέσω συμφωνημένων ή αντίρροπων μεταβολών. Οι ακμές κοντά στην περιοχή (*alignment* ≈ 1 , $|\Delta|$ μικρό) αντιστοιχούν σε σταθερές, προβλέψιμες σχέσεις μεταξύ αισθητήρων που διατηρούνται υπό καθοδήγηση, ενώ εκείνες με υψηλές τιμές $|\Delta|$ και χαμηλό alignment υποδηλώνουν ισχυρές επανακατανομές ή αντιρροπιστικές αντιδράσεις του συστήματος. Με βάση αυτή τη χαρτογράφηση μπορούμε να ερμηνεύσουμε πώς τα τέσσερα clusters του PEMS–SF κατανέμονται μεταξύ ήπιων/ευθυγραμμισμένων και ισχυρών/μη-ευθυγραμμισμένων μεταβολών, αντανακλώντας διαφορετικούς τύπους χωρικής συζεύξεως και συμπεριφοράς ροής στο δίκτυο.




Σχήμα 25: Όλες οι σχέσεις του δικτύου στον χώρο ευθυγράμμισης-μεταβολής (alignment- $|\Delta|$), χρωματισμένες ανά cluster ($K = 4$). Οι διακεκομμένες γραμμές δείχνουν ενδεικτικά κατώφλια (alignment ≈ 0.75 , $|\Delta| \approx 0.25$) για την οπτική διάκριση μεταξύ ήπιων/συμφωνημένων και ισχυρών/μη-ευθυγραμμισμένων μεταβολών.

Ανάλυση συμπεριφοράς ανά cluster στο επίπεδο ευθυγράμμισης-μεταβολής. Για να εμβαθύνουμε στη δυναμική που απεικονίζεται στο Σχήμα 25, παρατίθεται ο επόμενος πίνακας, ο οποίος συνοψίζει τη συμπεριφορά κάθε cluster (Cluster 00–03) ως προς τις τέσσερις περιοχές του επιπέδου $|\Delta|$ -alignment και για όλα τα βάρη καθοδήγησης. Η σύγκριση αυτή δείχνει πώς κατανέμεται η απόκριση κάθε cluster μεταξύ ήπιων, ευθυγραμμισμένων μεταβολών (Q2) και ισχυρότερων, μη-ευθυγραμμισμένων προσαρμογών (Q3–Q4), προσφέροντας μια συνοπτική εικόνα της σταθερότητας και της αντιδραστικότητας των κυκλοφοριακών ροών υπό καθοδήγηση.

Πίνακας 34: Κατανομή τεταρτημορίων (%) ανά cluster και weight tag.

Cluster	Weight	Q1	Q2	Q3	Q4
C00	neg_0_7	2.4	78.3	15.8	3.5
	neg_0_3	1.0	95.4	2.4	1.2
	pos_0_3	1.4	53.5	44.1	1.0
	pos_0_7	0.4	17.9	77.4	4.3
C01	neg_0_7	2.8	0.0	0.0	97.2
	neg_0_3	0.0	0.0	0.0	100.0
	pos_0_3	2.8	0.0	0.3	96.9
	pos_0_7	11.7	0.0	1.1	87.2
C02	neg_0_7	1.1	0.0	0.8	98.1
	neg_0_3	0.0	0.0	0.0	100.0
	pos_0_3	0.8	0.0	0.0	99.2
	pos_0_7	2.3	0.0	0.0	97.7
C03	neg_0_7	16.5	2.5	1.9	79.2
	neg_0_3	11.8	0.6	0.0	87.6
	pos_0_3	18.4	0.0	0.0	81.6
	pos_0_7	17.7	0.0	1.2	81.0



Σχήμα 26: Κατανομή τεταρτημορίων ανά weight tag για τα Clusters 00–03.

Συσχέτιση συμπεριφοράς συστάδων με τα τεταρτημόρια. Η κατανομή των ποσοστών ανά τεταρτημόριο επιβεβαιώνει με ποσοτικό τρόπο τα πρότυπα που παρατηρήθηκαν στην ανάλυση των συστάδων του κυκλοφοριακού συνόλου PEMS-SF. Τα clusters C00 και C03 παρουσιάζουν πιο ισορροπημένη συμπεριφορά, με αξιοσημείωτη παρουσία τόσο στο Q2_HighAlign_LowDelta όσο και στο Q3–Q4, υποδεικνύοντας συνδυασμό σταθερών και μερικώς αντιρροπιστικών αντιδράσεων. Η C00, ειδικότερα, εμφανίζει έντονη συγκέντρωση στο Q2 για χαμηλά αρνητικά βάρη (άνω του 95%), ενώ για υψηλότερα θετικά βάρη (pos_0_7) η κατανομή μετατοπίζεται προς το Q3–Q4, με το Q4 να υπερβαίνει το 77%. Η συμπεριφορά αυτή υποδηλώνει ότι η καθοδήγηση αρχικά ενισχύει σταθερές, τοπικά ευθυγραμμισμένες σχέσεις, αλλά σε ισχυρότερη εφαρμογή οδηγεί σε ενεργοποίηση δυναμικών, μη-ευθυγραμμισμένων μεταβολών στο δίκτυο.

Αντίθετα, τα clusters C01–C02 συγκεντρώνουν σχεδόν το σύνολο των σχέσεών τους στο Q4_LowAlign_HighDelta (έως και 100%), αντικατοπτρίζοντας καθαρά αντιδραστική συμπεριφορά και ισχυρές παρεμβάσεις της καθοδήγησης σε περιοχές όπου το μοντέλο δεν είχε σταθερά μαθημένα πρότυπα. Η C03 παρουσιάζει ένα ενδιάμεσο προφίλ, με αυξανόμενη μετατόπιση προς το Q4 για όλα τα βάρη ($\approx 80\%$) αλλά και μικρό ποσοστό συμμετοχής στο Q1, υποδεικνύοντας περιορισμένα φαινόμενα συμβατής ενίσχυσης.

Συνολικά, ο πίνακας αναδεικνύει έναν σαφή διαχωρισμό μεταξύ σταθερών–ευθυγραμμισμένων συστάδων (C00) και έντονα αντιδραστικών (C01–C02–C03). Η καθοδήγηση επομένως δρα διττά: σταθεροποιεί τις υφιστάμενες ροές για ήπια βάρη, ενώ σε υψηλότερη ένταση προκαλεί ανακατανομή και αναδιάρθρωση δεσμών, ιδίως σε δια-περιφερειακές συνδέσεις του δικτύου.

Κεφάλαιο 6

Μελλοντικές Επεκτάσεις

Η εργασία αυτή κατέδειξε ότι η καθοδήγηση μέσω ζευγών μπορεί να αποτελέσει ένα ευέλικτο και ερμηνεύσιμο πλαίσιο για τον έλεγχο της διάχυσης σε πολυμεταβλητές χρονοσειρές. Ωστόσο, αρκετές πτυχές παραμένουν ανοιχτές για περαιτέρω διερεύνηση. Οι δυνατότητες επέκτασης αφορούν τόσο τη βελτίωση της αποδοτικότητας και της προσαρμοστικότητας του μηχανισμού καθοδήγησης, όσο και τη γενίκευση του μοντέλου σε πιο σύνθετα σενάρια αλληλεξαρτήσεων. Στις παρακάτω ενότητες συνοψίζονται βασικές κατευθύνσεις για μελλοντική έρευνα, οι οποίες μπορούν να ενισχύσουν τη θεωρητική κατανόηση και την πρακτική εφαρμοσιμότητα των time-series diffusion models.

- **Δυναμικός Online Multi-hop Correlation Υπολογισμός.** Στην παρούσα εργασία, ο πίνακας συσχετίσεων C_{offline} υπολογίζεται εκ των προτέρων από πλήρη δεδομένα χρονοσειρών και παραμένει στατικός καθ' όλη τη διαδικασία διάχυσης. Μία μελλοντική ερευνητική κατεύθυνση θα μπορούσε να είναι η υλοποίηση *δυναμικού, εντός-εκτέλεσης* (online) υπολογισμού των πολυβηματικών συσχετίσεων. Μια τέτοια προσέγγιση θα επέτρεπε στον πίνακα C_t να ενημερώνεται σε κάθε βήμα t , λαμβάνοντας υπόψη τη στιγμιαία κατάσταση του δείγματος x_t και των καναλιών καθοδήγησης, αποτυπώνοντας έτσι *μη στατικές* αλληλεξαρτήσεις. Ωστόσο, η διαδικασία αυτή είναι ιδιαίτερα απαιτητική υπολογιστικά, καθώς ο υπολογισμός πολυβηματικών (π.χ. 3-hop ή 5-hop) συσχετίσεων σε κάθε βήμα απαιτεί πολλαπλές πράξεις πίνακα όπως C^2 , C^3 , C^4 ή ακόμη και εκθετικούς μετασχηματισμούς. Αυτό την καθιστά προς το παρόν μη εφικτή με τους διαθέσιμους πόρους. Σε μελλοντικά έργα, η υλοποίηση online multi-hop correlation θα μπορούσε να διερευνηθεί με τη χρήση προσεγγιστικών τεχνικών όπως low-rank factorization ή sparse propagation για μείωση του υπολογιστικού κόστους και επιτάχυνση της διάδοσης.
- **Καθοδήγηση Πολλαπλών Ζευγών (Multi-Pairs Guidance).** Η τρέχουσα μεθοδολογία βασίζεται αποκλειστικά σε μεμονωμένα ζεύγη χαρακτηριστικών (i, j) , όπου κάθε ζεύγος επιβάλλει μια αμφίδρομη καθοδήγηση μεταξύ δύο καναλιών. Μια φυσική επέκταση θα ήταν η καθιέρωση *πολλαπλών ταυτόχρονων ζευγών* (multi-pairs) που δρουν συλλογικά ή ιεραρχικά. Μέσα από αυτήν τη λογική, θα μπορούσαν να εξεταστούν τριάδες, τετράδες ή γενικότερα k -συνδυασμοί χαρακτηριστικών ώστε να εντοπιστούν *συνεργατικά πρότυπα καθοδήγησης*. Για παράδειγμα, στο μουσικό σύνολο η συνδυασμένη καθοδήγηση μεταξύ Guitar–Bass–Drums θα μπορούσε να περιγράψει πιο πλούσιες χρονικές σχέσεις και συσχετίσεις ρυθμού. Η πλήρης διερεύνηση όλων των πολυζευγών είναι υπολογιστικά εκρηκτική ($\mathcal{O}(N^k)$) και γι' αυτό στο παρόν έργο δεν κατέστη εφικτή. Στο μέλλον, θα μπορούσε να εξεταστεί μια στρατηγική επιλογής υποσυνόλων ζευγών βάσει σημασίας, εντροπίας ή στατιστικής συσχέτισης, με σκοπό τη μείωση της πολυπλοκότητας χωρίς απώλεια πληροφορίας, και τη δημιουργία πληρέστερων μοντέλων αλληλεπίδρασης.
- **Διερεύνηση Παραμέτρων Πολυβηματικής Συσχέτισης και Καθοδήγησης.** Η υλοποίηση που παρουσιάστηκε χρησιμοποίησε την εκθετική μορφή (exponential multi-hop method) με παράμετρο εξασθένησης $\alpha = 0.7$. Μια πλήρης μελλοντική μελέτη θα μπορούσε να συγκρίνει εναλλακτικές μεθόδους διάχυσης όπως την polynomial ή τη neighbors-based προσέγγιση, οι οποίες ενδέχεται να προσφέρουν διαφορετικά προφίλ διάδοσης της συσχέτισης.

Η συγκριτική ανάλυση διαφορετικών συνδυασμών:

$$\text{method} \in \{\text{exponential}, \text{polynomial}, \text{neighbors}\}, \quad \alpha_{\text{decay}} \in [0.1, 1.0], \quad \text{max_hops} \in \{2, 3, 4, 5\}$$

θα μπορούσε να αποκαλύψει ποιο σχήμα διάχυσης οδηγεί σε σταθερότερες συσχετίσεις ανάλογα με τη δομή κάθε συνόλου δεδομένων (μουσικό, συνθετικό, κυκλοφοριακό).

Παράλληλα, θα ήταν χρήσιμη η λεπτομερής βελτιστοποίηση των υπερπαραμέτρων καθοδήγησης όπως λ_g , α_{spill} , broadcast_w και corr_power , ώστε να επιτευχθεί η βέλτιστη εκλεκτικότητα και ελαχιστοποίηση της διαρροής σε μη καθοδηγούμενα κανάλια. Η συστηματική διερεύνηση των παραμέτρων αυτών μέσω πειραματικής χαρτογράφησης (parameter sweep) και αυτοματοποιημένης αξιολόγησης μπορεί να αποτελέσει σημαντικό επόμενο βήμα για την περαιτέρω βελτίωση των time-series diffusion models.

Μέρος IV

Παράρτημα

Κεφάλαιο 7

Παράρτημα

Music Dataset

Πίνακας 35: Μετρικές καθοδήγησης ανά guided_pair — Complete Dataset

guided_pair	weight	mean abs delta	l1 abs delta	l2 delta	top5 abs delta	top10 abs delta	frac sign aligned	avg align ment	select- ivity	spill offtarget	quadrant
0_1	-0.7	0.01527	0.6871	0.04956	0.1188	0.06584	0.4762	0.86848	70.78	0.2745	LowΔ_HighAlign
	-0.3	0.00624	0.2806	0.01997	0.04793	0.02680	0.4762	0.97266	67.68	0.1488	LowΔ_HighAlign
	0.3	0.00741	0.3336	0.02433	0.05817	0.03158	0.6667	0.96819	68.49	0.1361	LowΔ_HighAlign
	0.7	0.01745	0.7855	0.05820	0.1382	0.07448	0.6444	0.84351	74.28	0.2300	LowΔ_HighAlign
0_2	-0.7	0.00996	0.4483	0.03989	0.07821	0.04223	0.4878	0.78263	67.01	0.3257	LowΔ_HighAlign
	-0.3	0.00396	0.1784	0.01549	0.03098	0.01679	0.5366	0.95740	65.37	0.1932	LowΔ_HighAlign
	0.3	0.00357	0.1607	0.01166	0.02524	0.01430	0.5333	0.94411	70.91	0.2172	LowΔ_HighAlign
	0.7	0.00808	0.3638	0.02624	0.05677	0.03279	0.5778	0.72146	79.27	0.2920	LowΔ_LowAlign
0_3	-0.7	0.01427	0.6420	0.04995	0.1112	0.06051	0.5000	0.75629	65.27	0.2787	LowΔ_HighAlign
	-0.3	0.00579	0.2607	0.02064	0.04484	0.02455	0.5250	0.94903	65.00	0.1251	LowΔ_HighAlign
	0.3	0.00505	0.2274	0.01869	0.03899	0.02149	0.5682	0.95889	69.67	0.0986	LowΔ_HighAlign
	0.7	0.01021	0.4594	0.03917	0.07795	0.04324	0.5455	0.80833	71.65	0.1758	LowΔ_HighAlign
0_4	-0.7	0.3372	15.175	0.4294	0.9225	0.7460	0.4634	0.63989	71.91	0.2602	HighΔ_LowAlign
	-0.3	0.2947	13.260	0.3832	0.8497	0.6698	0.4878	0.70869	62.26	0.1348	HighΔ_LowAlign
	0.3	0.3022	13.598	0.3691	0.7016	0.5999	0.4667	0.68667	63.14	0.2407	HighΔ_LowAlign
	0.7	0.3012	13.552	0.3675	0.7155	0.6097	0.4667	0.60419	72.31	0.2877	HighΔ_LowAlign
0_5	-0.7	0.02152	0.9682	0.07243	0.1718	0.09041	0.4750	0.68290	63.91	0.2279	LowΔ_LowAlign
	-0.3	0.00875	0.3936	0.02901	0.06967	0.03685	0.4750	0.93627	63.55	0.1401	LowΔ_HighAlign
	0.3	0.00818	0.3680	0.02791	0.06471	0.03470	0.4000	0.91351	66.53	0.1480	LowΔ_HighAlign
	0.7	0.01871	0.8421	0.06363	0.1487	0.07963	0.4222	0.63064	70.24	0.2211	LowΔ_LowAlign
0_6	-0.7	0.4948	22.268	0.6827	1.497	1.261	0.2250	0.38199	47.14	0.4304	HighΔ_LowAlign
	-0.3	0.3358	15.110	0.5160	1.251	0.9500	0.2000	0.65210	46.42	0.3244	HighΔ_LowAlign
	0.3	0.1169	5.2596	0.1839	0.4653	0.3389	0.4091	0.84516	38.91	0.3637	LowΔ_HighAlign
	0.7	0.2211	9.9478	0.3231	0.7419	0.5817	0.5000	0.59322	47.40	0.4197	HighΔ_LowAlign
0_7	-0.7	0.2842	12.789	0.4333	1.046	0.7409	0.4615	0.59804	90.64	0.3513	HighΔ_LowAlign
	-0.3	0.1289	5.8010	0.1901	0.4381	0.3527	0.4615	0.86247	75.54	0.2341	LowΔ_HighAlign
	0.3	0.3379	15.207	0.5043	1.222	0.9216	0.5333	0.67239	60.16	0.2881	HighΔ_LowAlign
	0.7	0.4157	18.707	0.5749	1.319	1.022	0.6000	0.55241	83.44	0.2494	HighΔ_LowAlign
0_8	-0.7	0.2852	12.835	0.4125	0.9836	0.7713	0.5000	0.51442	168.6	0.3284	HighΔ_LowAlign
	-0.3	0.2004	9.0198	0.3122	0.7790	0.5688	0.5714	0.77478	129.2	0.1659	LowΔ_HighAlign
	0.3	0.3063	13.782	0.4257	0.9687	0.7646	0.3778	0.62389	97.96	0.2053	HighΔ_LowAlign
	0.7	0.3300	14.852	0.4549	1.023	0.8131	0.4000	0.42575	123.4	0.2756	HighΔ_LowAlign
0_9	-0.7	0.3388	15.244	0.4487	0.9685	0.7894	0.5714	0.51042	161.8	0.2311	HighΔ_LowAlign
	-0.3	0.2826	12.715	0.3939	0.8953	0.7109	0.6429	0.72417	113.7	0.1793	HighΔ_LowAlign
	0.3	0.1756	7.9036	0.2463	0.5476	0.4441	0.3111	0.74798	82.24	0.1990	LowΔ_HighAlign
	0.7	0.2442	10.991	0.3077	0.6053	0.5280	0.3556	0.49417	102.6	0.2008	HighΔ_LowAlign
1_2	-0.7	0.01584	0.7128	0.05456	0.1277	0.06758	0.3333	0.94060	82.12	0.1829	LowΔ_HighAlign
	-0.3	0.00674	0.3034	0.02237	0.05385	0.02865	0.3095	0.98531	79.05	0.1208	LowΔ_HighAlign
	0.3	0.00718	0.3232	0.02455	0.05899	0.03122	0.5556	0.97949	83.93	0.1288	LowΔ_HighAlign

συνεχίζεται στην επόμενη σελίδα

guided_pair	weight	mean abs delta	l1 abs delta	l2 delta	top5 abs delta	top10 abs delta	frac sign aligned	avg align ment	select- ivity	spill offtarget	quadrant
	0.7	0.01598	0.7192	0.05565	0.1322	0.06997	0.3778	0.90927	90.58	0.1861	LowΔ_HighAlign
1_3	-0.7	0.01665	0.7493	0.05337	0.1314	0.07147	0.4286	0.94249	85.81	0.1635	LowΔ_HighAlign
	-0.3	0.00711	0.3198	0.02273	0.05574	0.03044	0.4762	0.98553	82.81	0.0993	LowΔ_HighAlign
	0.3	0.00714	0.3213	0.02356	0.05820	0.03100	0.5227	0.98547	77.74	0.0755	LowΔ_HighAlign
	0.7	0.01647	0.7412	0.05627	0.1368	0.07198	0.4091	0.94187	85.22	0.1293	LowΔ_HighAlign
1_4	-0.7	0.1834	8.2540	0.2793	0.7016	0.4895	0.5238	0.79388	45.56	0.3412	LowΔ_HighAlign
	-0.3	0.1525	6.8624	0.2344	0.5488	0.3985	0.5000	0.84306	39.46	0.2647	LowΔ_HighAlign
	0.3	0.1706	7.6769	0.2513	0.5677	0.4219	0.6667	0.83491	43.24	0.1656	LowΔ_HighAlign
	0.7	0.1681	7.5632	0.2631	0.6305	0.4568	0.6444	0.83076	48.65	0.2622	LowΔ_HighAlign
1_5	-0.7	0.01592	0.7163	0.05282	0.1235	0.06544	0.4146	0.94442	79.03	0.1956	LowΔ_HighAlign
	-0.3	0.00662	0.2977	0.02172	0.05111	0.02720	0.3902	0.98627	73.44	0.1057	LowΔ_HighAlign
	0.3	0.00646	0.2908	0.02143	0.05041	0.02738	0.6000	0.98040	68.78	0.1272	LowΔ_HighAlign
	0.7	0.01428	0.6428	0.04893	0.1131	0.06094	0.6000	0.90680	65.92	0.2004	LowΔ_HighAlign
1_6	-0.7	0.2423	10.902	0.3624	0.9058	0.6617	0.5610	0.75834	57.76	0.3015	HighΔ_HighAlign
	-0.3	0.1919	8.6375	0.2932	0.7111	0.5335	0.6098	0.81435	47.62	0.1993	LowΔ_HighAlign
	0.3	0.1616	7.2701	0.2617	0.6423	0.4845	0.5682	0.84045	51.51	0.2125	LowΔ_HighAlign
	0.7	0.2062	9.2807	0.3230	0.7826	0.6221	0.6136	0.80083	62.14	0.2980	LowΔ_HighAlign
1_7	-0.7	0.2268	10.204	0.3685	0.9848	0.6812	0.6250	0.77259	53.05	0.2584	HighΔ_HighAlign
	-0.3	0.1724	7.7599	0.3147	0.8730	0.5707	0.4750	0.82684	46.07	0.1757	LowΔ_HighAlign
	0.3	0.1864	8.3862	0.3021	0.7987	0.5452	0.5333	0.81590	43.05	0.1779	LowΔ_HighAlign
	0.7	0.2213	9.9601	0.3583	0.9482	0.6586	0.5333	0.78541	49.12	0.2228	HighΔ_HighAlign
1_8	-0.7	0.1825	8.2138	0.2948	0.7572	0.5173	0.4524	0.74362	51.18	0.2612	LowΔ_HighAlign
	-0.3	0.1405	6.3241	0.2304	0.5686	0.3987	0.4524	0.84872	42.77	0.1978	LowΔ_HighAlign
	0.3	0.1646	7.4073	0.2619	0.6122	0.4549	0.4667	0.83103	44.99	0.2125	LowΔ_HighAlign
	0.7	0.2066	9.2971	0.3180	0.7793	0.5614	0.5778	0.75938	48.79	0.2637	LowΔ_HighAlign
1_9	-0.7	0.2192	9.8636	0.3647	0.9518	0.6663	0.5000	0.70835	54.40	0.2567	HighΔ_LowAlign
	-0.3	0.1754	7.8908	0.3025	0.7769	0.5457	0.4048	0.81326	44.96	0.1982	LowΔ_HighAlign
	0.3	0.1264	5.6885	0.2277	0.5701	0.4002	0.5556	0.87105	47.01	0.1841	LowΔ_HighAlign
	0.7	0.1695	7.6262	0.3028	0.8038	0.5514	0.5333	0.79810	51.55	0.2144	LowΔ_HighAlign
2_3	-0.7	0.00957	0.4306	0.03787	0.07432	0.04032	0.3250	0.92554	65.43	0.1297	LowΔ_HighAlign
	-0.3	0.00386	0.1736	0.01429	0.02963	0.01621	0.3250	0.98449	61.66	0.0864	LowΔ_HighAlign
	0.3	0.00326	0.1467	0.01166	0.02453	0.01390	0.6364	0.97081	60.95	0.0792	LowΔ_HighAlign
	0.7	0.00662	0.2981	0.02366	0.05002	0.02817	0.5909	0.84768	68.72	0.1116	LowΔ_HighAlign
2_4	-0.7	0.3796	17.080	0.4822	0.9116	0.8184	0.3659	0.63317	54.32	0.2222	HighΔ_LowAlign
	-0.3	0.3443	15.494	0.4412	0.8805	0.7345	0.3902	0.66185	44.90	0.2219	HighΔ_LowAlign
	0.3	0.3079	13.854	0.3860	0.7101	0.6277	0.4667	0.69426	48.63	0.2497	HighΔ_LowAlign
	0.7	0.2969	13.361	0.3847	0.7573	0.6432	0.4667	0.69938	60.78	0.2370	HighΔ_LowAlign
2_5	-0.7	0.02536	1.1410	0.08282	0.2028	0.1063	0.6341	0.86974	77.17	0.3027	LowΔ_HighAlign
	-0.3	0.01099	0.4946	0.03613	0.08814	0.04626	0.6341	0.97057	75.69	0.1758	LowΔ_HighAlign
	0.3	0.01076	0.4844	0.03535	0.08764	0.04576	0.2444	0.93199	71.52	0.2103	LowΔ_HighAlign
	0.7	0.02449	1.1021	0.08138	0.2021	0.1047	0.2222	0.69549	80.74	0.2688	LowΔ_LowAlign
2_6	-0.7	0.3619	16.288	0.5364	1.242	1.019	0.4250	0.57395	31.80	0.2679	HighΔ_LowAlign
	-0.3	0.2796	12.582	0.4502	1.128	0.8234	0.3750	0.72838	29.12	0.1922	HighΔ_LowAlign
	0.3	0.1345	6.0537	0.1843	0.3989	0.3263	0.4773	0.85604	28.52	0.2901	LowΔ_HighAlign
	0.7	0.1732	7.7918	0.2438	0.5543	0.4469	0.4545	0.73921	34.54	0.3034	LowΔ_LowAlign
2_7	-0.7	0.2613	11.759	0.3503	0.7609	0.6153	0.4250	0.70038	57.43	0.2349	HighΔ_LowAlign
	-0.3	0.1814	8.1625	0.2544	0.5436	0.4548	0.5000	0.81559	47.63	0.2289	LowΔ_HighAlign
	0.3	0.2949	13.269	0.4110	0.9252	0.7372	0.4444	0.70250	47.40	0.2965	HighΔ_LowAlign
	0.7	0.3362	15.131	0.4514	0.9820	0.8094	0.4222	0.61472	56.91	0.2754	HighΔ_LowAlign
2_8	-0.7	0.2838	12.770	0.3774	0.8285	0.6806	0.5854	0.69401	57.91	0.3193	HighΔ_LowAlign
	-0.3	0.2031	9.1386	0.2758	0.6158	0.4769	0.5610	0.80421	48.90	0.2309	LowΔ_HighAlign
	0.3	0.3210	14.443	0.4744	1.0430	0.8751	0.4000	0.67166	52.25	0.2875	HighΔ_LowAlign
	0.7	0.3668	16.506	0.5026	1.0440	0.8955	0.3556	0.50624	60.91	0.3346	HighΔ_LowAlign
2_9	-0.7	0.3383	15.226	0.4536	0.9488	0.8049	0.6098	0.64762	59.92	0.2562	HighΔ_LowAlign
	-0.3	0.2903	13.063	0.4136	0.9272	0.7438	0.5854	0.72337	50.77	0.2038	HighΔ_LowAlign
	0.3	0.2199	9.8967	0.3082	0.6340	0.5557	0.5333	0.76102	52.22	0.2614	HighΔ_HighAlign
	0.7	0.2745	12.353	0.3685	0.7679	0.6425	0.4667	0.60143	61.78	0.2948	HighΔ_LowAlign
3_4	-0.7	0.3366	15.147	0.4172	0.7973	0.6968	0.5366	0.67370	43.74	0.2019	HighΔ_LowAlign
	-0.3	0.2985	13.434	0.3860	0.7689	0.6508	0.6341	0.70615	36.75	0.1996	HighΔ_LowAlign
	0.3	0.2988	13.447	0.3726	0.7019	0.6311	0.4091	0.69925	34.90	0.2345	HighΔ_LowAlign
	0.7	0.2780	12.512	0.3613	0.7322	0.6241	0.5227	0.70754	41.74	0.2373	HighΔ_LowAlign
	-0.7	0.02418	1.0881	0.07771	0.1872	0.0996	0.5385	0.88096	83.24	0.2861	LowΔ_HighAlign
3_5	συνεχίζεται στην επόμενη σελίδα										

guided_pair	weight	mean abs delta	l1 abs delta	l2 delta	top5 abs delta	top10 abs delta	frac sign aligned	avg align ment	select- ivity	spill offtarget	quadrant
	-0.3	0.01061	0.4776	0.03428	0.08259	0.04387	0.5385	0.97299	83.67	0.1645	LowΔ_HighAlign
	0.3	0.01030	0.4637	0.03389	0.08209	0.04326	0.4091	0.95297	79.82	0.1765	LowΔ_HighAlign
	0.7	0.02313	1.0408	0.07597	0.1842	0.09692	0.3636	0.79061	81.25	0.2371	LowΔ_HighAlign
3_6	-0.7	0.3084	13.878	0.4278	0.9512	0.7663	0.6154	0.65747	37.00	0.2035	HighΔ_LowAlign
	-0.3	0.2431	10.938	0.3642	0.8472	0.6345	0.5897	0.75959	32.83	0.1607	HighΔ_HighAlign
	0.3	0.2049	9.2212	0.2649	0.5337	0.4656	0.3409	0.78332	33.02	0.2637	LowΔ_HighAlign
	0.7	0.2339	10.529	0.3013	0.5954	0.5238	0.3409	0.70262	39.58	0.2981	HighΔ_LowAlign
3_7	-0.7	0.3175	14.289	0.4001	0.7893	0.6834	0.5128	0.68359	51.53	0.1886	HighΔ_LowAlign
	-0.3	0.2166	9.7471	0.3124	0.6869	0.5507	0.4872	0.78662	42.28	0.2200	HighΔ_HighAlign
	0.3	0.2323	10.453	0.3174	0.6487	0.5550	0.6136	0.77012	40.76	0.2938	HighΔ_HighAlign
	0.7	0.2669	12.009	0.3548	0.6838	0.6124	0.5909	0.73776	47.46	0.3040	HighΔ_LowAlign
3_8	-0.7	0.2964	13.340	0.3863	0.7523	0.6738	0.4750	0.62347	57.20	0.2727	HighΔ_LowAlign
	-0.3	0.2129	9.5790	0.2856	0.6137	0.5067	0.5750	0.78990	47.42	0.1733	LowΔ_HighAlign
	0.3	0.3011	13.552	0.4380	0.9733	0.8170	0.4545	0.69108	44.70	0.2666	HighΔ_LowAlign
	0.7	0.3410	15.345	0.4749	1.0010	0.8593	0.3864	0.56375	52.05	0.3231	HighΔ_LowAlign
3_9	-0.7	0.3711	16.698	0.5063	1.1010	0.9018	0.4500	0.59619	55.20	0.2175	HighΔ_LowAlign
	-0.3	0.2966	13.348	0.4445	1.0500	0.8123	0.5250	0.72012	44.89	0.2059	HighΔ_LowAlign
	0.3	0.1917	8.6246	0.2560	0.5393	0.4577	0.4091	0.79334	45.28	0.2484	LowΔ_HighAlign
	0.7	0.2474	11.135	0.3485	0.7817	0.6052	0.4545	0.68219	52.76	0.2540	HighΔ_LowAlign
4_5	-0.7	0.2398	10.791	0.3282	0.7049	0.5950	0.3171	0.72764	54.88	0.1351	HighΔ_LowAlign
	-0.3	0.1690	7.6049	0.2336	0.5072	0.4231	0.3659	0.82720	46.22	0.1213	LowΔ_HighAlign
	0.3	0.2377	10.696	0.3256	0.6713	0.5419	0.4667	0.75945	48.22	0.1331	HighΔ_HighAlign
	0.7	0.2392	10.764	0.3349	0.6999	0.5619	0.3556	0.70972	60.80	0.1236	HighΔ_LowAlign
4_6	-0.7	0.5558	25.011	0.6748	1.265	1.154	0.4500	0.47384	29.29	0.0197	HighΔ_LowAlign
	-0.3	0.3306	14.876	0.4666	1.082	0.8691	0.4000	0.67947	28.40	0.0085	HighΔ_LowAlign
	0.3	0.3105	13.972	0.3952	0.7358	0.6315	0.4318	0.68705	28.07	0.0103	HighΔ_LowAlign
	0.7	0.3659	16.466	0.4712	0.9672	0.7693	0.4545	0.63059	28.97	0.0248	HighΔ_LowAlign
4_7	-0.7	0.4211	18.949	0.4986	0.8139	0.7623	0.4615	0.57294	21.08	0.0474	HighΔ_LowAlign
	-0.3	0.2472	11.125	0.3080	0.6311	0.5200	0.4615	0.75169	20.79	0.0294	HighΔ_HighAlign
	0.3	0.2766	12.449	0.3672	0.7937	0.6182	0.4667	0.72771	20.99	0.0634	HighΔ_LowAlign
	0.7	0.3609	16.242	0.4553	0.9088	0.7702	0.5778	0.65242	21.26	0.1026	HighΔ_LowAlign
4_8	-0.7	0.3720	16.742	0.4698	0.9065	0.8063	0.5122	0.61075	30.96	0.1348	HighΔ_LowAlign
	-0.3	0.2885	12.984	0.3444	0.5907	0.5451	0.5122	0.70761	26.89	0.1042	HighΔ_LowAlign
	0.3	0.3069	13.810	0.3646	0.6369	0.5834	0.4667	0.68920	26.91	0.0490	HighΔ_LowAlign
	0.7	0.3438	15.473	0.4175	0.7662	0.6895	0.5333	0.61168	27.66	0.0628	HighΔ_LowAlign
4_9	-0.7	0.3480	15.660	0.4353	0.7708	0.7307	0.5122	0.63218	26.82	0.0989	HighΔ_LowAlign
	-0.3	0.2437	10.968	0.3046	0.5973	0.5167	0.4390	0.74987	25.60	0.0574	HighΔ_HighAlign
	0.3	0.3184	14.329	0.3764	0.6509	0.5979	0.4222	0.68636	27.16	0.0245	HighΔ_LowAlign
	0.7	0.3721	16.747	0.4367	0.7692	0.6921	0.4222	0.59297	27.27	0.0437	HighΔ_LowAlign
5_6	-0.7	0.2263	10.185	0.2921	0.5891	0.4885	0.6154	0.78625	49.37	0.2132	HighΔ_HighAlign
	-0.3	0.1630	7.3356	0.2317	0.5278	0.4051	0.6667	0.84551	51.77	0.1609	LowΔ_HighAlign
	0.3	0.1605	7.2223	0.2561	0.5824	0.4151	0.4091	0.82133	34.92	0.1787	LowΔ_HighAlign
	0.7	0.1818	8.1789	0.2734	0.6089	0.4479	0.3864	0.68883	46.02	0.1932	LowΔ_LowAlign
5_7	-0.7	0.2236	10.061	0.2942	0.6429	0.5203	0.4103	0.68600	60.48	0.1725	HighΔ_LowAlign
	-0.3	0.1050	4.7235	0.1583	0.3707	0.2874	0.4359	0.88182	48.82	0.1577	LowΔ_HighAlign
	0.3	0.1475	6.6384	0.2753	0.6823	0.4525	0.4000	0.85098	47.24	0.1498	LowΔ_HighAlign
	0.7	0.1823	8.2031	0.2933	0.6769	0.5056	0.2667	0.71047	61.46	0.1331	LowΔ_LowAlign
5_8	-0.7	0.2151	9.6773	0.3475	0.8375	0.6149	0.4750	0.66960	69.98	0.2099	HighΔ_LowAlign
	-0.3	0.1519	6.8372	0.2710	0.6393	0.4608	0.4500	0.84429	57.15	0.1475	LowΔ_HighAlign
	0.3	0.08965	4.0343	0.1473	0.3604	0.2577	0.5333	0.87020	59.58	0.1200	LowΔ_HighAlign
	0.7	0.1390	6.2549	0.2286	0.5496	0.4099	0.5333	0.62722	69.64	0.1381	LowΔ_LowAlign
5_9	-0.7	0.2315	10.419	0.3537	0.8296	0.6078	0.5250	0.66050	69.02	0.2125	HighΔ_LowAlign
	-0.3	0.1623	7.3054	0.2767	0.6444	0.4722	0.4750	0.83002	56.34	0.1578	LowΔ_HighAlign
	0.3	0.1051	4.7315	0.1543	0.3330	0.2666	0.3556	0.84954	57.69	0.0761	LowΔ_HighAlign
	0.7	0.1516	6.8225	0.2178	0.5205	0.3943	0.4000	0.60519	69.46	0.1041	LowΔ_LowAlign
6_7	-0.7	0.4279	19.255	0.5650	1.203	1.015	0.4359	0.53426	32.02	0.0557	HighΔ_LowAlign
	-0.3	0.3004	13.519	0.3935	0.8336	0.6855	0.4615	0.68634	32.15	0.0276	HighΔ_LowAlign
	0.3	0.4035	18.157	0.5431	1.149	0.9758	0.4091	0.61387	33.76	0.0308	HighΔ_LowAlign
	0.7	0.5043	22.692	0.6298	1.190	1.075	0.5000	0.51056	34.19	0.0923	HighΔ_LowAlign
6_8	-0.7	0.3271	14.720	0.4208	0.8629	0.7134	0.5122	0.60530	67.47	0.1706	HighΔ_LowAlign
	-0.3	0.2390	10.753	0.3469	0.8048	0.6539	0.4634	0.74036	58.29	0.1014	HighΔ_HighAlign
	0.3	0.4408	19.837	0.6124	1.214	1.091	0.4545	0.56808	41.58	0.0618	HighΔ_LowAlign

συνεχίζεται στην επόμενη σελίδα

guided_pair	weight	mean abs delta	l1 abs delta	l2 delta	top5 abs delta	top10 abs delta	frac sign aligned	avg align ment	select- ivity	spill offtarget	quadrant
6_9	0.7	0.5065	22.791	0.6624	1.233	1.153	0.5227	0.43985	47.30	0.1118	HighΔ_LowAlign
	-0.7	0.4127	18.572	0.4946	0.8223	0.7873	0.6829	0.51797	55.27	0.1154	HighΔ_LowAlign
	-0.3	0.2696	12.134	0.3392	0.6698	0.5712	0.6341	0.73763	51.90	0.0432	HighΔ_LowAlign
	0.3	0.3658	16.459	0.4822	0.9108	0.8510	0.5227	0.61982	40.76	0.0290	HighΔ_LowAlign
	0.7	0.4601	20.706	0.5341	0.9414	0.8528	0.5227	0.52003	39.67	0.0570	HighΔ_LowAlign
7_8	-0.7	0.4554	20.492	0.5381	0.9166	0.8515	0.3590	0.48820	28.21	0.1339	HighΔ_LowAlign
	-0.3	0.2628	11.828	0.3292	0.6171	0.5536	0.5128	0.72824	24.40	0.0878	HighΔ_LowAlign
	0.3	0.2831	12.739	0.3544	0.6579	0.5675	0.5333	0.72170	24.07	0.0858	HighΔ_LowAlign
	0.7	0.4062	18.280	0.4932	0.8555	0.7986	0.6000	0.59308	26.37	0.1157	HighΔ_LowAlign
7_9	-0.7	0.4094	18.425	0.4773	0.8121	0.7602	0.2308	0.47448	25.33	0.1051	HighΔ_LowAlign
	-0.3	0.2251	10.128	0.2861	0.5771	0.4928	0.4103	0.75672	23.19	0.0508	HighΔ_HighAlign
	0.3	0.2994	13.473	0.3480	0.6015	0.5386	0.5778	0.70957	23.24	0.0585	HighΔ_LowAlign
	0.7	0.4075	18.336	0.4757	0.8199	0.7483	0.6444	0.58995	24.07	0.0976	HighΔ_LowAlign
8_9	-0.7	0.1947	8.7612	0.2310	0.3940	0.3605	0.6098	0.62307	48.15	0.0805	LowΔ_LowAlign
	-0.3	0.1527	6.8698	0.1947	0.3986	0.3126	0.6341	0.81835	50.91	0.0360	LowΔ_HighAlign
	0.3	0.3058	13.759	0.4772	1.198	0.8935	0.6889	0.72507	45.64	0.0255	HighΔ_LowAlign
	0.7	0.4296	19.332	0.6372	1.524	1.201	0.6222	0.55510	42.76	0.0488	HighΔ_LowAlign

Clusters

Cluster 01 — Συνοπτική Παρουσίαση

Slide 1 — Top combos (by cluster_share only)

Πίνακας 36: Κορυφαίοι συνδυασμοί για Cluster 01.

guided_group	affected_pair_group	cnt	cluster share (%)	baseline share (%)	enrichment	mean $ \Delta $	sign_follow
Guitar-Keys (mixed)	Guitar-Keys	29	9.9	6.7	1.480	0.422	0.034
Guitar-Rhythmic (mixed)	Guitar-Keys	20	6.8	3.6	1.871	0.410	0.050
Guitar-Keys (mixed)	Keys-Pads/Strings	14	4.8	2.4	1.964	0.455	0.000
Guitar-Keys (mixed)	Guitar-Guitar	12	4.1	1.8	2.245	0.494	0.000
Keys-Rhythmic (mixed)	Guitar-Keys	12	4.1	4.8	0.842	0.430	0.000
Keys	Guitar-Keys	10	3.4	3.6	0.935	0.425	0.000

Slide 2 — Guided-side composition (top combos)

Πίνακας 37: Guitar-Keys (mixed) → Guitar-Keys — Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
Piano	Keys	26.2	24.1
Guitar-A (dist)	Guitar	21.7	20.7
Guitar-B (jazz)	Guitar	16.1	17.2
Organ-A (perc)	Keys	13.9	15.5
Guitar-C (dist)	Guitar	12.2	12.1

Πίνακας 38: Guitar-Rhythmic (mixed) → Guitar-Keys — Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
Bass	Rhythmic	38.1	37.5
Guitar-C (dist)	Guitar	22.5	22.5
Guitar-B (jazz)	Guitar	15.5	17.5
Guitar-A (dist)	Guitar	12.1	10.0
Drums	Rhythmic	11.9	12.5

Slide 3 — Affected-side composition (top combos)

Πίνακας 39: Guitar-Keys (mixed) → Guitar-Keys — Affected stems in Guitar

Stem	$ \Delta $ -wtd (%)	Count (%)
Guitar-C (dist)	56.2	62.1
Guitar-B (jazz)	39.3	31.0
Guitar-A (dist)	4.6	6.9

Πίνακας 40: Guitar-Keys (mixed) → Guitar-Keys — Affected stems in Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
Organ-B	46.1	41.4
Organ-C	24.5	24.1
Organ-A (perc)	18.0	20.7
Piano	11.4	13.8

Πίνακας 41: Guitar-Rhythmic (mixed) → Guitar-Keys — Affected stems in Guitar

Stem	$ \Delta $ -wtd (%)	Count (%)
Guitar-C (dist)	40.3	45.0
Guitar-B (jazz)	34.0	30.0
Guitar-A (dist)	25.8	25.0

Πίνακας 42: Guitar-Rhythmic (mixed) → Guitar-Keys — Affected stems in Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
Organ-B	58.3	50.0
Organ-C	20.1	20.0
Organ-A (perc)	14.8	20.0
Piano	6.8	10.0

Cluster 02 – Συνοπτική Παρουσίαση

Slide 1 – Top combos (by cluster_share only)

Πίνακας 43: Κορυφαίοι συνδυασμοί για Cluster 02.

guided_group	affected_pair_group	cnt	cluster share (%)	baseline share (%)	enrichment	mean $ \Delta $	sign_follow
Guitar	Guitar-Keys	9	6.5	1.8	3.587	0.635	1.000
Guitar-Keys (mixed)	Guitar-Keys	8	5.8	6.7	0.870	0.420	1.000
Keys-Rhythmic (mixed)	Guitar-Keys	7	5.1	4.8	1.046	0.540	0.857
Guitar-Keys (mixed)	Guitar-Pads/Strings	6	4.3	1.8	2.391	0.388	0.833
Guitar-Rhythmic (mixed)	Guitar-Keys	6	4.3	3.6	1.196	0.564	1.000
Guitar-Keys (mixed)	Keys-Pads/Strings	5	3.6	2.4	1.495	0.479	0.600

Slide 2 – Guided-side composition (top combos)

Πίνακας 44: Guitar → Guitar-Keys – Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
Guitar-A (dist)	Guitar	50.0	50.0
Guitar-C (dist)	Guitar	27.3	33.3
Guitar-B (jazz)	Guitar	22.7	16.7

Πίνακας 45: Guitar-Keys (mixed) → Guitar-Keys – Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
Guitar-C (dist)	Guitar	21.4	25.0
Guitar-B (jazz)	Guitar	19.7	18.8
Organ-B	Keys	19.1	18.8
Piano	Keys	18.3	18.8
Organ-A (perc)	Keys	12.5	12.5

Slide 3 – Affected-side composition (top combos)

Πίνακας 46: Guitar → Guitar-Keys – Affected stems in Guitar

Stem	$ \Delta $ -wtd (%)	Count (%)
Guitar-B (jazz)	60.9	55.6
Guitar-C (dist)	33.0	33.3
Guitar-A (dist)	6.1	11.1

Πίνακας 47: Guitar → Guitar-Keys – Affected stems in Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
Organ-B	41.5	33.3
Organ-C	34.9	44.4
Piano	23.6	22.2

Πίνακας 48: Guitar-Keys (mixed) → Guitar-Keys – Affected stems in Guitar

Stem	$ \Delta $ -wtd (%)	Count (%)
Guitar-B (jazz)	57.2	50.0
Guitar-C (dist)	22.0	25.0
Guitar-A (dist)	20.7	25.0

Πίνακας 49: Guitar-Keys (mixed) → Guitar-Keys – Affected stems in Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
Organ-C	62.7	62.5
Organ-B	37.3	37.5

Cluster 03 – Συνοπτική Παρουσίαση

Slide 1 – Top combos (by cluster_share only)

Πίνακας 50: Κορυφαίοι συνδυασμοί για Cluster 03.

guided_group	affected_pair_group	cnt	cluster share (%)	baseline share (%)	enrichment	mean $ \Delta $	sign_follow
Keys-Rhythmic (mixed)	Keys-Keys	15	7.3	2.4	3.018	0.481	0.000
Keys	Keys-Keys	13	6.3	1.5	4.185	0.477	0.000
Keys-Rhythmic (mixed)	Guitar-Keys	13	6.3	4.8	1.308	0.354	0.000
Guitar-Keys (mixed)	Keys-Keys	13	6.3	3.6	1.744	0.403	0.000
Guitar-Keys (mixed)	Guitar-Keys	11	5.4	6.7	0.805	0.447	0.000
Keys	Guitar-Keys	10	4.9	3.6	1.341	0.423	0.000

Slide 2 – Guided-side composition (top combos)

Πίνακας 51: Keys-Rhythmic (mixed) → Keys-Keys – Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
Organ-B	Keys	27.6	26.7
Bass	Rhythmic	27.1	26.7
Drums	Rhythmic	22.9	23.3
Organ-C	Keys	19.9	20.0
Organ-A (perc)	Keys	2.5	3.3

Πίνακας 52: Guitar-Keys (mixed) → Keys-Keys – Guided stems

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
Guitar-A (dist)	Guitar	38.0	34.6
Organ-B	Keys	17.5	19.2
Piano	Keys	12.4	11.5
Organ-A (perc)	Keys	11.4	7.7
Organ-C	Keys	8.7	11.5

Slide 3 – Affected-side composition (top combos)

Πίνακας 53: Keys-Rhythmic (mixed) → Keys-Keys – Affected stems in Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
No records found / missing in source.		

Πίνακας 54: Keys-Rhythmic (mixed) → Keys-Keys – Affected stems in Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
No records found / missing in source.		

Πίνακας 55: Guitar-Keys (mixed) → Keys-Keys – Affected stems in Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
No records found / missing in source.		

Πίνακας 56: Guitar-Keys (mixed) → Keys-Keys – Affected stems in Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
No records found / missing in source.		

quadrant-alignment

Cluster00-weights(-0.7,0.3,0.7)

Πίνακας 57: Κατανομή τεταρτημορίων για Tags: neg_0_7, pos_0_3, pos_0_7.

Tag	Quadrant	n	Share	Enrich.	Align mean	Delta mean
neg_0_7	Q1_HighAlign_HighDelta	2	0.1%	1.49	0.895	0.217
neg_0_7	Q2_HighAlign_LowDelta	682	50.2%	0.99	0.928	0.007
neg_0_7	Q3_LowAlign_LowDelta	646	47.6%	1.01	0.250	0.003
neg_0_7	Q4_LowAlign_HighDelta	28	2.1%	1.16	0.260	0.753
pos_0_3	Q1_HighAlign_HighDelta	2	0.1%	0.75	0.767	0.309
pos_0_3	Q2_HighAlign_LowDelta	1095	80.6%	1.02	0.944	0.010
pos_0_3	Q3_LowAlign_LowDelta	246	18.1%	0.93	0.393	0.002
pos_0_3	Q4_LowAlign_HighDelta	15	1.1%	0.93	0.118	1.286
pos_0_7	Q1_HighAlign_HighDelta	5	0.4%	0.75	0.817	0.301
pos_0_7	Q2_HighAlign_LowDelta	642	47.3%	1.05	0.929	0.006
pos_0_7	Q3_LowAlign_LowDelta	608	44.8%	0.96	0.220	0.006
pos_0_7	Q4_LowAlign_HighDelta	103	7.6%	0.95	0.115	1.341

Πίνακας 58: Q1_HighAlign_HighDelta — Κορυφαίες ομάδες για neg_0_7, pos_0_3, pos_0_7.

Tag	Guided	Affected	Count	Share	Enrich ×	Mean Δ	Sign-follow
neg_0_7	Keys	Guitar-Keys	1	50.0%	1.00	0.217	0.00
neg_0_7	Keys	Keys-Keys	1	50.0%	1.00	0.217	0.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Keys	1	50.0%	1.00	0.392	1.00
pos_0_3	Keys-Pads/Strings (mixed)	Guitar-Keys	1	50.0%	2.00	0.227	0.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Keys	3	60.0%	2.00	0.261	0.67
pos_0_7	Guitar-Keys (mixed)	Guitar-Rhythmic	1	20.0%	2.00	0.269	1.00
pos_0_7	Guitar-Rhythmic (mixed)	Guitar-Keys	1	20.0%	1.00	0.451	0.00

Tag	Guided	Affected	Count	Share	Enrich ×	Mean Δ	Sign-follow
neg_0_7	Guitar-Keys (mixed)	Guitar-Keys	45	6.6%	0.84	0.009	0.20
neg_0_7	Guitar-Keys (mixed)	Keys-Rhythmic	41	6.0%	1.17	0.004	0.24
neg_0_7	Keys-Rhythmic (mixed)	Guitar-Keys	39	5.7%	0.98	0.006	0.13
pos_0_3	Guitar-Keys (mixed)	Guitar-Keys	72	6.6%	0.94	0.012	0.21
pos_0_3	Guitar-Keys (mixed)	Keys-Rhythmic	67	6.1%	1.24	0.007	0.31
pos_0_3	Keys-Rhythmic (mixed)	Guitar-Keys	52	4.7%	0.97	0.010	0.15
pos_0_7	Guitar-Keys (mixed)	Guitar-Keys	46	7.2%	1.08	0.016	0.13
pos_0_7	Guitar-Keys (mixed)	Keys-Rhythmic	41	6.4%	1.21	0.008	0.29
pos_0_7	Keys-Rhythmic (mixed)	Guitar-Keys	31	4.8%	0.89	0.005	0.10

Πίνακας 60: Q3_LowAlign_LowDelta — Κορυφαίες ομάδες για neg_0_7, pos_0_3, pos_0_7.

Tag	Guided	Affected	Count	Share	Enrich ×	Mean Δ	Sign-follow
neg_0_7	Guitar-Keys (mixed)	Guitar-Keys	38	5.9%	1.00	0.004	0.29
neg_0_7	Guitar-Keys (mixed)	Keys-Rhythmic	38	5.9%	1.37	0.002	0.32
neg_0_7	Keys-Rhythmic (mixed)	Guitar-Keys	25	3.9%	1.03	0.005	0.16
pos_0_3	Guitar-Keys (mixed)	Keys-Rhythmic	14	5.7%	1.33	0.002	0.21
pos_0_3	Guitar-Keys (mixed)	Guitar-Keys	13	5.3%	0.87	0.001	0.38
pos_0_3	Guitar-Rhythmic (mixed)	Keys-Keys	12	4.9%	1.29	0.000	0.17
pos_0_7	Guitar-Keys (mixed)	Keys-Rhythmic	38	6.2%	1.28	0.011	0.26
pos_0_7	Guitar-Keys (mixed)	Guitar-Keys	33	5.4%	0.79	0.012	0.30

Tag	Guided	Affected	Count	Share	Enrich×	Mean Δ	Sign-follow
pos_0_7	Guitar-Rhythmic (mixed)	Keys-Rhythmic	28	4.6%	1.28	0.002	0.39

Πίνακας 61: Q4_LowAlign_HighDelta – Κορυφαίες ομάδες για neg_0_7, pos_0_3, pos_0_7.

Tag	Guided	Affected	Count	Share	Enrich×	Mean Δ	Sign-follow
neg_0_7	Guitar-Keys (mixed)	Guitar-Keys	6	21.4%	1.10	0.708	0.33
neg_0_7	Guitar-Keys (mixed)	Keys-Keys	3	10.7%	1.29	0.721	0.67
neg_0_7	Keys	Keys-Keys	3	10.7%	1.29	1.097	0.33
pos_0_3	Guitar-Keys (mixed)	Guitar-Rhythmic	4	26.7%	1.60	0.844	0.75
pos_0_3	Guitar-Keys (mixed)	Guitar-Keys	3	20.0%	0.80	0.955	0.33
pos_0_3	Guitar-Keys (mixed)	Guitar-Guitar	2	13.3%	0.80	0.843	0.50
pos_0_7	Guitar-Keys (mixed)	Guitar-Keys	7	6.8%	0.69	1.409	0.57
pos_0_7	Guitar-Keys (mixed)	Guitar-Rhythmic	7	6.8%	1.57	1.201	0.71
pos_0_7	Guitar	Guitar-Keys	6	5.8%	1.18	0.926	0.67

Cluster01-weights(-0.7,-0.3,0.3,0.7)

Πίνακας 62: Κατανομή τεταρτημορίων για Tags: neg_0_3, neg_0_7, pos_0_3, pos_0_7 – Cluster 01.

Tag	Quadrant	n	Share	Enrich.	Align mean	Delta mean
neg_0_3	Q1_HighAlign_HighDelta	2	0.7%	1.25	0.766	0.234
neg_0_3	Q2_HighAlign_LowDelta	229	77.9%	0.96	0.955	0.005
neg_0_3	Q3_LowAlign_LowDelta	63	21.4%	1.20	0.509	0.001
neg_0_7	Q2_HighAlign_LowDelta	162	55.1%	1.08	0.932	0.011
neg_0_7	Q3_LowAlign_LowDelta	129	43.9%	0.93	0.180	0.004
neg_0_7	Q4_LowAlign_HighDelta	3	1.0%	0.57	0.180	0.826
pos_0_3	Q2_HighAlign_LowDelta	212	72.1%	0.91	0.931	0.014
pos_0_3	Q3_LowAlign_LowDelta	78	26.5%	1.36	0.400	0.003
pos_0_3	Q4_LowAlign_HighDelta	4	1.4%	1.15	0.235	0.897
pos_0_7	Q1_HighAlign_HighDelta	3	1.0%	2.07	0.795	0.430
pos_0_7	Q2_HighAlign_LowDelta	98	33.3%	0.74	0.930	0.006
pos_0_7	Q3_LowAlign_LowDelta	162	55.1%	1.18	0.179	0.005
pos_0_7	Q4_LowAlign_HighDelta	31	10.5%	1.32	0.134	1.245

Πίνακας 63: Q1_HighAlign_HighDelta – Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 – Cluster 01.

Tag	Guided	Affected	Count	Share	Enrich×	Mean Δ	Sign-follow
neg_0_3	Keys	Guitar-Keys	1	50.0%	5.50	0.250	0.00
neg_0_3	Keys	Keys-Pads/Strings	1	50.0%	5.50	0.218	0.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Guitar	1	33.3%	3.33	0.267	0.00
pos_0_7	Guitar-Rhythmic (mixed)	Guitar-Guitar	1	33.3%	3.33	0.515	0.00
pos_0_7	Guitar-Rhythmic (mixed)	Guitar-Keys	1	33.3%	1.67	0.507	0.00

Πίνακας 64: Q2_HighAlign_LowDelta — Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 — Cluster 01.

Tag	Guided	Affected	Count	Share	Enrich ×	Mean Δ	Sign-follow
neg_0_3	Guitar-Keys (mixed)	Guitar-Keys	27	11.8%	1.52	0.007	0.04
neg_0_3	Guitar-Rhythmic (mixed)	Guitar-Keys	18	7.9%	2.00	0.009	0.06
neg_0_3	Guitar-Keys (mixed)	Keys-Pads/Strings	13	5.7%	2.84	0.001	0.00
neg_0_7	Guitar-Keys (mixed)	Guitar-Keys	21	13.0%	1.65	0.019	0.05
neg_0_7	Guitar-Rhythmic (mixed)	Guitar-Keys	15	9.3%	1.68	0.015	0.07
neg_0_7	Guitar-Keys (mixed)	Guitar-Guitar	10	6.2%	2.90	0.035	0.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Keys	19	9.0%	1.28	0.013	0.05
pos_0_3	Guitar-Rhythmic (mixed)	Guitar-Keys	16	7.5%	2.42	0.045	0.06
pos_0_3	Keys	Guitar-Keys	9	4.2%	1.10	0.010	0.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Keys	7	7.1%	1.08	0.003	0.14
pos_0_7	Guitar-Rhythmic (mixed)	Guitar-Keys	7	7.1%	3.60	0.001	0.00
pos_0_7	Keys-Pads/Strings (mixed)	Guitar-Keys	6	6.1%	2.42	0.021	0.00

Πίνακας 65: Q3_LowAlign_LowDelta — Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 — Cluster 01.

Tag	Guided	Affected	Count	Share	Enrich ×	Mean Δ	Sign-follow
neg_0_3	Keys-Pads/Strings (mixed)	Guitar-Keys	5	7.9%	2.05	0.001	0.00
neg_0_3	Guitar-Rhythmic (mixed)	Keys-Pads/Strings	4	6.3%	2.87	0.000	0.00
neg_0_3	Guitar-Keys (mixed)	Guitar-Pads/Strings	3	4.8%	1.56	0.001	0.00
neg_0_7	Guitar-Keys (mixed)	Guitar-Keys	8	6.2%	1.06	0.003	0.00
neg_0_7	Keys	Guitar-Keys	7	5.4%	1.33	0.013	0.00
neg_0_7	Guitar-Keys (mixed)	Keys-Pads/Strings	6	4.7%	1.39	0.001	0.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Keys	9	11.5%	1.90	0.002	0.00
pos_0_3	Guitar-Keys (mixed)	Keys-Pads/Strings	8	10.3%	2.14	0.000	0.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Pads/Strings	5	6.4%	1.69	0.002	0.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Keys	19	11.7%	1.71	0.006	0.00
pos_0_7	Guitar-Keys (mixed)	Keys-Pads/Strings	10	6.2%	1.88	0.001	0.00
pos_0_7	Guitar-Rhythmic (mixed)	Keys-Pads/Strings	8	4.9%	2.03	0.000	0.00

Πίνακας 66: Q4_LowAlign_HighDelta — Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 — Cluster 01.

Tag	Guided	Affected	Count	Share	Enrich ×	Mean Δ	Sign-follow
neg_0_7	Guitar	Guitar-Keys	1	33.3%	3.00	0.495	0.00
neg_0_7	Keys	Guitar-Keys	1	33.3%	4.00	0.966	0.00
neg_0_7	Keys	Keys-Pads/Strings	1	33.3%	12.00	1.018	0.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Guitar	2	50.0%	3.00	0.921	0.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Keys	1	25.0%	1.00	0.526	0.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Pads/Strings	1	25.0%	6.00	1.222	0.00
pos_0_7	Guitar-Rhythmic (mixed)	Guitar-Keys	7	22.6%	2.61	0.907	0.14
pos_0_7	Guitar-Keys (mixed)	Guitar-Guitar	3	9.7%	2.24	1.328	0.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Keys	3	9.7%	0.98	1.256	0.00

Cluster02-weights(-0.7,-0.3,0.3,0.7)

Πίνακας 67: Κατανομή τεταρτημορίων για Tags: neg_0_3, neg_0_7, pos_0_3, pos_0_7 — Cluster 02.

Tag	Quadrant	n	Share	Enrich.	Align mean	Delta mean
neg_0_3	Q2_HighAlign_LowDelta	137	83.5%	1.03	0.948	0.007
neg_0_3	Q3_LowAlign_LowDelta	25	15.2%	0.86	0.489	0.001
neg_0_3	Q4_LowAlign_HighDelta	2	1.2%	8.23	0.672	0.328
neg_0_7	Q2_HighAlign_LowDelta	90	54.9%	1.08	0.927	0.013
neg_0_7	Q3_LowAlign_LowDelta	70	42.7%	0.91	0.250	0.007
neg_0_7	Q4_LowAlign_HighDelta	4	2.4%	1.37	0.296	0.717
pos_0_3	Q1_HighAlign_HighDelta	1	0.6%	3.09	0.771	0.399
pos_0_3	Q2_HighAlign_LowDelta	131	79.9%	1.01	0.944	0.013
pos_0_3	Q3_LowAlign_LowDelta	30	18.3%	0.94	0.459	0.005
pos_0_3	Q4_LowAlign_HighDelta	2	1.2%	1.03	0.000	1.594
pos_0_7	Q1_HighAlign_HighDelta	1	0.6%	1.23	0.871	0.676
pos_0_7	Q2_HighAlign_LowDelta	80	48.8%	1.09	0.940	0.013
pos_0_7	Q3_LowAlign_LowDelta	66	40.2%	0.86	0.171	0.008
pos_0_7	Q4_LowAlign_HighDelta	17	10.4%	1.30	0.265	1.073

Πίνακας 68: Q1_HighAlign_HighDelta — Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 — Cluster 02.

Tag	Guided	Affected	Count	Share	Enrich ×	Mean Δ	Sign-follow
pos_0_3	Guitar-Keys (mixed)	Guitar-Keys	1	100.0%	2.00	0.399	1.00
pos_0_7	Keys	Keys-Keys	1	100.0%	10.00	0.676	1.00

Πίνακας 69: Q2_HighAlign_LowDelta — Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 — Cluster 02.

Tag	Guided	Affected	Count	Share	Enrich ×	Mean Δ	Sign-follow
neg_0_3	Guitar-Keys (mixed)	Guitar-Keys	14	10.2%	1.32	0.009	1.00
neg_0_3	Guitar	Guitar-Keys	8	5.8%	3.01	0.028	1.00
neg_0_3	Guitar-Keys (mixed)	Guitar-Pads/Strings	6	4.4%	2.89	0.001	0.83
neg_0_7	Guitar-Keys (mixed)	Guitar-Keys	10	11.1%	1.42	0.017	1.00
neg_0_7	Guitar	Guitar-Keys	6	6.7%	2.65	0.037	1.00
neg_0_7	Guitar-Rhythmic (mixed)	Guitar-Rhythmic	5	5.6%	1.91	0.031	1.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Keys	12	9.2%	1.31	0.033	1.00
pos_0_3	Guitar	Guitar-Keys	8	6.1%	3.49	0.014	1.00
pos_0_3	Keys-Rhythmic (mixed)	Guitar-Keys	7	5.3%	1.10	0.003	0.86
pos_0_7	Guitar-Keys (mixed)	Guitar-Keys	5	6.2%	0.95	0.033	1.00
pos_0_7	Keys-Rhythmic (mixed)	Guitar-Keys	5	6.2%	1.16	0.008	0.80
pos_0_7	Keys	Guitar-Keys	4	5.0%	1.14	0.020	1.00

Πίνακας 70: Q3_LowAlign_LowDelta — Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 — Cluster 02.

Tag	Guided	Affected	Count	Share	Enrich ×	Mean Δ	Sign-follow
neg_0_3	Keys-Rhythmic (mixed)	Keys-Pads/Strings	3	12.0%	3.94	0.000	1.00
neg_0_3	Guitar-Rhythmic (mixed)	Keys-Keys	2	8.0%	5.78	0.000	1.00
neg_0_3	Guitar-Rhythmic (mixed)	Keys-Pads/Strings	2	8.0%	3.61	0.000	1.00
neg_0_7	Guitar-Keys (mixed)	Guitar-Keys	4	5.7%	0.97	0.038	1.00
neg_0_7	Keys-Pads/Strings (mixed)	Keys-Pads/Strings	4	5.7%	5.46	0.005	1.00
neg_0_7	Keys-Rhythmic (mixed)	Keys-Pads/Strings	4	5.7%	3.03	0.000	1.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Pads/Strings	5	16.7%	4.40	0.000	1.00
pos_0_3	Guitar-Rhythmic (mixed)	Keys-Pads/Strings	4	13.3%	3.52	0.000	1.00

Tag	Guided	Affected	Count	Share	Enrich $\times$	Mean Δ	Sign-follow
pos_0_3	Guitar-Keys (mixed)	Keys-Pads/Strings	3	10.0%	2.08	0.006	0.67
pos_0_7	Guitar	Guitar-Keys	7	10.6%	4.36	0.030	1.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Keys	5	7.6%	1.10	0.005	1.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Pads/Strings	5	7.6%	3.25	0.001	1.00

Πίνακας 71: Q4_LowAlign_HighDelta – Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 – Cluster 02.

Tag	Guided	Affected	Count	Share	Enrich $\times$	Mean Δ	Sign-follow
neg_0_3	Guitar-Keys (mixed)	Guitar-Keys	1	50.0%	1.50	0.391	1.00
neg_0_3	Guitar	Guitar-Guitar	1	50.0%	1.50	0.266	1.00
neg_0_7	Guitar	Guitar-Guitar	1	25.0%	4.50	0.826	1.00
neg_0_7	Guitar	Guitar-Keys	1	25.0%	2.25	0.506	1.00
neg_0_7	Guitar	Guitar-Pads/Strings	1	25.0%	9.00	0.485	0.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Keys	1	50.0%	2.00	1.251	1.00
pos_0_3	Keys	Keys-Keys	1	50.0%	4.00	1.938	1.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Keys	5	29.4%	2.98	1.261	1.00
pos_0_7	Guitar	Guitar-Guitar	2	11.8%	3.81	0.908	1.00
pos_0_7	Guitar-Rhythmic (mixed)	Guitar-Rhythmic	2	11.8%	2.38	0.533	1.00

Cluster03-weights(-0.7,-0.3,0.3,0.7)

Πίνακας 72: Κατανομή τεταρτημορίων για Tags: neg_0_3, neg_0_7, pos_0_3, pos_0_7 – Cluster 03.

Tag	Quadrant	n	Share	Enrich.	Align mean	Delta mean
neg_0_3	Q2_HighAlign_LowDelta	170	81.3%	1.00	0.947	0.003
neg_0_3	Q3_LowAlign_LowDelta	39	18.7%	1.05	0.495	0.001
neg_0_7	Q2_HighAlign_LowDelta	98	46.9%	0.92	0.934	0.006
neg_0_7	Q3_LowAlign_LowDelta	110	52.6%	1.12	0.284	0.008
neg_0_7	Q4_LowAlign_HighDelta	1	0.5%	0.27	0.508	0.492
pos_0_3	Q1_HighAlign_HighDelta	1	0.5%	2.42	0.747	0.474
pos_0_3	Q2_HighAlign_LowDelta	163	78.0%	0.99	0.937	0.005
pos_0_3	Q3_LowAlign_LowDelta	42	20.1%	1.03	0.372	0.001
pos_0_3	Q4_LowAlign_HighDelta	3	1.4%	1.21	0.000	1.709
pos_0_7	Q1_HighAlign_HighDelta	1	0.5%	0.97	0.871	0.262
pos_0_7	Q2_HighAlign_LowDelta	88	42.1%	0.94	0.943	0.005
pos_0_7	Q3_LowAlign_LowDelta	109	52.2%	1.12	0.208	0.004
pos_0_7	Q4_LowAlign_HighDelta	11	5.3%	0.66	0.173	1.331

Πίνακας 73: Q1_HighAlign_HighDelta – Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 – Cluster 03.

Tag	Guided	Affected	Count	Share	Enrich $\times$	Mean Δ	Sign-follow
pos_0_3	Guitar-Keys (mixed)	Guitar-Pads/Strings	1	100.0%	4.00	0.474	0.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Pads/Strings	1	100.0%	10.00	0.262	0.00

Πίνακας 74: Q2_HighAlign_LowDelta — Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 — Cluster 03.

Tag	Guided	Affected	Count	Share	Enrich×	Mean Δ	Sign-follow
neg_0_3	Keys	Keys-Keys	14	8.2%	4.25	0.005	0.00
neg_0_3	Keys-Rhythmic (mixed)	Keys-Keys	14	8.2%	3.09	0.004	0.00
neg_0_3	Guitar-Keys (mixed)	Keys-Keys	13	7.6%	1.97	0.002	0.00
neg_0_7	Keys-Rhythmic (mixed)	Keys-Keys	9	9.2%	3.06	0.016	0.00
neg_0_7	Guitar-Keys (mixed)	Keys-Keys	8	8.2%	2.16	0.007	0.00
neg_0_7	Keys-Rhythmic (mixed)	Guitar-Keys	8	8.2%	1.40	0.007	0.00
pos_0_3	Keys-Rhythmic (mixed)	Keys-Keys	14	8.6%	3.13	0.002	0.00
pos_0_3	Keys	Keys-Keys	13	8.0%	3.87	0.012	0.00
pos_0_3	Guitar-Keys (mixed)	Keys-Keys	12	7.4%	1.87	0.004	0.00
pos_0_7	Keys-Rhythmic (mixed)	Keys-Keys	12	13.6%	4.76	0.005	0.00
pos_0_7	Guitar-Keys (mixed)	Keys-Keys	9	10.2%	2.65	0.009	0.00
pos_0_7	Keys	Keys-Keys	9	10.2%	4.22	0.016	0.00

Πίνακας 75: Q3_LowAlign_LowDelta — Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 — Cluster 03.

Tag	Guided	Affected	Count	Share	Enrich×	Mean Δ	Sign-follow
neg_0_3	Guitar-Pads/Strings (mixed)	Guitar-Keys	3	7.7%	1.63	0.001	0.00
neg_0_3	Guitar-Rhythmic (mixed)	Guitar-Keys	3	7.7%	3.97	0.001	0.00
neg_0_3	Keys	Guitar-Keys	3	7.7%	2.78	0.001	0.00
neg_0_7	Keys	Keys-Keys	11	10.0%	5.31	0.021	0.00
neg_0_7	Guitar-Keys (mixed)	Guitar-Keys	6	5.5%	0.93	0.009	0.00
neg_0_7	Keys	Guitar-Keys	6	5.5%	1.34	0.002	0.00
pos_0_3	Guitar-Rhythmic (mixed)	Guitar-Keys	6	14.3%	2.57	0.001	0.00
pos_0_3	Keys	Guitar-Keys	4	9.5%	5.39	0.001	0.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Guitar	3	7.1%	4.71	0.000	0.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Keys	8	7.3%	1.07	0.004	0.00
pos_0_7	Guitar-Rhythmic (mixed)	Guitar-Keys	8	7.3%	1.83	0.002	0.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Guitar	6	5.5%	2.89	0.001	0.00

Πίνακας 76: Q4_LowAlign_HighDelta — Κορυφαίες ομάδες για neg_0_3, neg_0_7, pos_0_3, pos_0_7 — Cluster 03.

Tag	Guided	Affected	Count	Share	Enrich×	Mean Δ	Sign-follow
neg_0_7	Guitar	Guitar-Guitar	1	100.0%	18.00	0.492	0.00
pos_0_3	Guitar-Keys (mixed)	Guitar-Keys	1	33.3%	1.33	1.309	0.00
pos_0_3	Keys	Guitar-Keys	1	33.3%	2.67	1.934	0.00
pos_0_3	Keys	Keys-Keys	1	33.3%	2.67	1.885	0.00
pos_0_7	Keys	Keys-Keys	3	27.3%	5.52	1.180	0.00
pos_0_7	Guitar-Rhythmic (mixed)	Guitar-Guitar	2	18.2%	4.21	1.304	0.00
pos_0_7	Guitar-Keys (mixed)	Guitar-Guitar	1	9.1%	2.10	0.386	0.00

Traffic

Πίνακας 77: Μετρικές καθοδήγησης ανά guided_pair — Complete Dataset

guided_pair	weight	mean abs delta	l1 abs delta	l2 delta	top5 abs delta	top10 abs delta	frac sign aligned	avg align ment	select- ivity	spill offtarget	quadrant
0_1	-0.7	0.14782	6.65204	0.15090	0.19334	0.17641	0.75000	0.77203	0.77169	0.38516	HighΔ_HighAlign
	-0.3	0.14599	6.56971	0.14789	0.15938	0.15811	0.65909	0.86276	0.77290	0.38448	HighΔ_HighAlign
	0.3	0.14975	6.73873	0.15227	0.16954	0.16463	0.66667	0.49990	0.77198	0.38377	HighΔ_HighAlign
	0.7	0.16246	7.31063	0.16871	0.25111	0.20897	0.68889	0.11568	0.77027	0.38373	HighΔ_LowAlign
0_2	-0.7	0.14423	6.49022	0.18419	0.43026	0.31228	0.54545	0.82671	0.43688	0.38432	HighΔ_HighAlign
	-0.3	0.10340	4.65305	0.10996	0.19794	0.15725	0.54545	0.90002	0.43349	0.38485	HighΔ_HighAlign
	0.3	0.08851	3.98297	0.09483	0.15007	0.12067	0.48889	0.72668	0.42934	0.38573	HighΔ_HighAlign
	0.7	0.09832	4.42459	0.13066	0.26305	0.18150	0.48889	0.27399	0.42762	0.38635	HighΔ_LowAlign
0_3	-0.7	0.89123	40.10551	0.90268	1.13167	1.04315	0.79545	0.25131	1.75572	0.37766	HighΔ_LowAlign
	-0.3	0.88642	39.88873	0.89003	1.01526	0.96179	0.79545	0.14564	1.54035	0.37106	HighΔ_LowAlign
	0.3	0.86908	39.10861	0.87279	0.91978	0.90419	0.80000	0.40419	1.34509	0.37629	HighΔ_LowAlign
	0.7	0.86676	39.00442	0.87650	0.96170	0.93218	0.80000	0.22017	1.27244	0.40596	HighΔ_LowAlign
0_4	-0.7	0.10994	4.94752	0.12165	0.18791	0.16011	0.27273	0.70045	0.95440	0.40891	HighΔ_HighAlign
	-0.3	0.11215	5.04677	0.11381	0.13128	0.12796	0.29545	0.85462	0.84015	0.38948	HighΔ_HighAlign
	0.3	0.12750	5.73769	0.12870	0.16387	0.14929	0.17778	0.70183	0.70495	0.38655	HighΔ_HighAlign
	0.7	0.13830	6.22372	0.14488	0.23636	0.19458	0.17778	0.33903	0.63483	0.38863	HighΔ_LowAlign
0_5	-0.7	0.07607	3.42313	0.10842	0.26386	0.18067	0.37209	0.73724	0.86154	0.38454	HighΔ_HighAlign
	-0.3	0.05275	2.37371	0.05818	0.10765	0.08248	0.34884	0.90637	0.85818	0.38555	HighΔ_HighAlign
	0.3	0.04969	2.23616	0.06894	0.11271	0.07995	0.35556	0.36276	0.85401	0.38684	LowΔ_LowAlign
	0.7	0.06378	2.86994	0.12698	0.24279	0.14640	0.35556	0.04268	0.85222	0.38771	HighΔ_LowAlign
0_6	-0.7	0.05598	2.51893	0.08304	0.21394	0.14134	0.47727	0.84257	0.60068	0.38684	HighΔ_HighAlign
	-0.3	0.03413	1.53579	0.03636	0.05373	0.04979	0.36364	0.94687	0.55938	0.38606	LowΔ_HighAlign
	0.3	0.04878	2.19513	0.05416	0.10415	0.07861	0.28889	0.76544	0.51098	0.38805	LowΔ_HighAlign
	0.7	0.06295	2.83256	0.08725	0.19106	0.13273	0.31111	0.40726	0.48620	0.39039	HighΔ_LowAlign
0_7	-0.7	0.05604	2.52165	0.10305	0.28432	0.18365	0.44186	0.80059	0.92907	0.38318	HighΔ_HighAlign
	-0.3	0.02468	1.11040	0.03843	0.09795	0.06849	0.37209	0.95000	0.92329	0.38450	LowΔ_HighAlign
	0.3	0.01705	0.76721	0.04413	0.08702	0.05005	0.17778	0.49183	0.91544	0.38922	LowΔ_HighAlign
	0.7	0.03598	1.61927	0.10021	0.21909	0.12499	0.22222	0.10617	0.91072	0.39128	LowΔ_LowAlign
0_8	-0.7	0.78344	35.25484	0.79098	0.83720	0.83022	0.25000	0.13498	1.28709	0.38597	HighΔ_LowAlign
	-0.3	0.80453	36.20385	0.80515	0.82910	0.82382	0.25000	0.15579	1.15127	0.36661	HighΔ_LowAlign
	0.3	0.81207	36.54298	0.81300	0.84618	0.83326	0.20000	0.11377	0.99882	0.37517	HighΔ_LowAlign
	0.7	0.81156	36.52025	0.81549	0.87178	0.85027	0.20000	0.04114	0.92808	0.38028	HighΔ_LowAlign
0_9	-0.7	0.19143	8.61453	0.22498	0.48481	0.36464	0.47727	0.73522	1.16949	0.38470	HighΔ_HighAlign
	-0.3	0.15383	6.92257	0.15835	0.24719	0.20637	0.47727	0.83398	1.17046	0.38429	HighΔ_HighAlign
	0.3	0.13684	6.15782	0.14151	0.19767	0.16917	0.35556	0.54246	1.17075	0.38481	HighΔ_HighAlign
	0.7	0.14507	6.52834	0.17378	0.32220	0.23359	0.35556	0.12572	1.17072	0.38640	HighΔ_LowAlign
1_2	-0.7	0.09751	4.38797	0.13145	0.29340	0.19761	0.62222	0.89909	0.49500	0.38435	HighΔ_HighAlign
	-0.3	0.08411	3.78481	0.08689	0.11816	0.10519	0.60000	0.91946	0.49130	0.38504	HighΔ_HighAlign
	0.3	0.09208	4.14351	0.09508	0.13457	0.11849	0.53333	0.79111	0.48606	0.38561	HighΔ_HighAlign
	0.7	0.10630	4.78328	0.12439	0.23604	0.17679	0.57778	0.37618	0.48264	0.38619	HighΔ_LowAlign
1_3	-0.7	0.73962	33.28289	0.75167	0.94320	0.86089	0.68889	0.35720	1.84811	0.36295	HighΔ_LowAlign
	-0.3	0.73994	33.29725	0.74441	0.86142	0.80598	0.68889	0.28148	1.63121	0.36813	HighΔ_LowAlign
	0.3	0.71646	32.24071	0.72287	0.76319	0.74779	0.80000	0.45032	1.42719	0.34598	HighΔ_LowAlign
	0.7	0.71965	32.38431	0.72362	0.79014	0.76275	0.82222	0.30895	1.34613	0.35411	HighΔ_LowAlign
1_4	-0.7	0.50890	22.90032	0.51649	0.55051	0.54857	0.22222	0.39681	1.00755	0.36416	HighΔ_LowAlign
	-0.3	0.53429	24.04323	0.53479	0.55070	0.54766	0.22222	0.44514	0.90238	0.37269	HighΔ_LowAlign
	0.3	0.54014	24.30625	0.54149	0.57078	0.56016	0.20000	0.36893	0.77569	0.37909	HighΔ_LowAlign
	0.7	0.53462	24.05812	0.54096	0.59343	0.57551	0.17778	0.18196	0.70835	0.38083	HighΔ_LowAlign
1_5	-0.7	0.16490	7.42042	0.17047	0.19045	0.18734	0.65909	0.74599	0.93237	0.38013	HighΔ_HighAlign
	-0.3	0.17732	7.97957	0.17824	0.18459	0.18446	0.59091	0.83548	0.92817	0.38235	HighΔ_HighAlign
	0.3	0.18439	8.29743	0.18445	0.19254	0.18972	0.66667	0.49427	0.92283	0.38391	HighΔ_HighAlign
	0.7	0.19215	8.64658	0.20206	0.28066	0.23445	0.68889	0.12499	0.92028	0.38412	HighΔ_LowAlign
1_6	-0.7	0.51123	23.00541	0.51759	0.55955	0.55723	0.36364	0.42925	0.65503	0.36840	HighΔ_LowAlign
	-0.3	0.54026	24.31159	0.54070	0.55508	0.55391	0.36364	0.44878	0.61818	0.37338	HighΔ_LowAlign
	0.3	0.54892	24.70146	0.55029	0.58352	0.57216	0.31111	0.38948	0.57224	0.37819	HighΔ_LowAlign
	0.7	0.54140	24.36304	0.54911	0.60725	0.58977	0.28889	0.32631	0.54793	0.38013	HighΔ_LowAlign
1_7	-0.7	0.35876	16.14399	0.36908	0.41089	0.40801	0.56818	0.63473	1.00053	0.37389	HighΔ_HighAlign
	-0.3	0.39028	17.56251	0.39106	0.40576	0.40429	0.56818	0.62081	0.99519	0.37684	HighΔ_HighAlign
	0.3	0.39856	17.93503	0.40143	0.43407	0.42386	0.64444	0.53242	0.98664	0.38120	HighΔ_HighAlign
	0.7	0.39944	17.97472	0.40380	0.45703	0.44071	0.66667	0.20304	0.98222	0.38401	HighΔ_LowAlign
1_8	-0.7	0.86470	38.91172	0.87306	0.90952	0.90362	0.28889	0.08504	1.33461	0.34861	HighΔ_LowAlign

συνεχίζεται στην επόμενη σελίδα

guided_pair	weight	mean abs delta	l1 abs delta	l2 delta	top5 abs delta	top10 abs delta	frac sign aligned	avg align ment	select- ivity	spill offtarget	quadrant
	-0.3	0.88586	39.86363	0.88629	0.90250	0.89894	0.28889	0.08751	1.21505	0.36577	HighΔ_LowAlign
	0.3	0.88827	39.97207	0.88926	0.91883	0.90821	0.20000	0.09094	1.08514	0.36847	HighΔ_LowAlign
	0.7	0.88380	39.77090	0.88832	0.94726	0.92613	0.20000	0.07651	1.02439	0.36841	HighΔ_LowAlign
1_9	-0.7	0.06189	2.78500	0.13717	0.37477	0.22981	0.51111	0.87268	1.25063	0.38407	HighΔ_HighAlign
	-0.3	0.02527	1.13719	0.04381	0.11592	0.07412	0.51111	0.96200	1.25018	0.38594	LowΔ_HighAlign
	0.3	0.02123	0.95547	0.04630	0.10882	0.06148	0.22222	0.67453	1.24920	0.38770	LowΔ_HighAlign
	0.7	0.04103	1.84629	0.11964	0.26487	0.14519	0.22222	0.20792	1.24842	0.38833	LowΔ_LowAlign
2_3	-0.7	0.89018	40.05789	0.90313	1.08851	0.99772	0.51111	0.12556	1.41201	0.37161	HighΔ_LowAlign
	-0.3	0.90359	40.66162	0.90833	1.02484	0.96466	0.51111	0.10383	1.17026	0.36897	HighΔ_LowAlign
	0.3	0.88872	39.99218	0.89325	0.96239	0.93618	0.66667	0.12487	1.01594	0.37181	HighΔ_LowAlign
	0.7	0.87895	39.55265	0.88993	1.01517	0.96651	0.66667	0.34994	0.99562	0.40833	HighΔ_LowAlign
2_4	-0.7	0.30324	13.64575	0.31049	0.33328	0.33295	0.26667	0.66214	0.64116	0.38167	HighΔ_HighAlign
	-0.3	0.32271	14.52186	0.32347	0.33248	0.33217	0.31111	0.67960	0.54399	0.37637	HighΔ_HighAlign
	0.3	0.32780	14.75085	0.33069	0.35299	0.34568	0.33333	0.66900	0.43730	0.38400	HighΔ_HighAlign
	0.7	0.33291	14.98083	0.33340	0.36189	0.35299	0.31111	0.52649	0.39567	0.38659	HighΔ_HighAlign
2_5	-0.7	0.15049	6.77224	0.18509	0.40551	0.28615	0.59091	0.81645	0.57601	0.37832	HighΔ_HighAlign
	-0.3	0.11385	5.12314	0.12089	0.20100	0.16183	0.59091	0.88891	0.56624	0.38241	HighΔ_HighAlign
	0.3	0.10278	4.62503	0.11817	0.19157	0.15102	0.48889	0.72407	0.55951	0.38713	HighΔ_HighAlign
	0.7	0.11386	5.12371	0.16105	0.29585	0.21410	0.46667	0.27451	0.55818	0.38878	HighΔ_LowAlign
2_6	-0.7	0.21947	9.87623	0.22678	0.24986	0.24866	0.47727	0.76614	0.32507	0.37375	HighΔ_HighAlign
	-0.3	0.23512	10.58033	0.23660	0.24705	0.24654	0.50000	0.76896	0.29456	0.37924	HighΔ_HighAlign
	0.3	0.24417	10.98760	0.24621	0.26889	0.26144	0.42222	0.74305	0.26107	0.38446	HighΔ_HighAlign
	0.7	0.24948	11.22677	0.25051	0.29472	0.27690	0.42222	0.61288	0.24422	0.38676	HighΔ_HighAlign
2_7	-0.7	0.05188	2.33461	0.11263	0.28679	0.17981	0.59091	0.92590	0.62567	0.38229	HighΔ_HighAlign
	-0.3	0.01879	0.84570	0.03726	0.08629	0.05122	0.45455	0.98068	0.62040	0.38511	LowΔ_HighAlign
	0.3	0.02408	1.08348	0.05426	0.10525	0.06600	0.51111	0.82300	0.61600	0.38819	LowΔ_HighAlign
	0.7	0.03779	1.70061	0.10760	0.19650	0.11716	0.53333	0.37539	0.61405	0.38972	LowΔ_LowAlign
2_8	-0.7	0.70492	31.72122	0.71194	0.75082	0.74854	0.40000	0.26240	0.97996	0.39991	HighΔ_LowAlign
	-0.3	0.72824	32.77077	0.72993	0.75822	0.75086	0.42222	0.27353	0.83670	0.37068	HighΔ_LowAlign
	0.3	0.74669	33.60094	0.74829	0.80697	0.78525	0.33333	0.24563	0.68246	0.37578	LowΔ_LowAlign
	0.7	0.75273	33.87283	0.75801	0.86534	0.82560	0.33333	0.13920	0.63531	0.37722	HighΔ_LowAlign
2_9	-0.7	0.10128	4.55773	0.13185	0.31430	0.20199	0.48889	0.90689	0.84272	0.38476	HighΔ_HighAlign
	-0.3	0.08057	3.62587	0.08333	0.10566	0.09658	0.46667	0.92044	0.84050	0.38516	HighΔ_HighAlign
	0.3	0.08732	3.92952	0.08933	0.11701	0.10451	0.53333	0.83570	0.83758	0.38579	HighΔ_HighAlign
	0.7	0.09740	4.38311	0.11882	0.21862	0.15708	0.57778	0.43655	0.83679	0.38608	HighΔ_LowAlign
3_4	-0.7	0.91038	40.96732	0.91267	1.00235	0.95618	0.31111	0.06749	1.91080	0.36812	HighΔ_LowAlign
	-0.3	0.91173	41.02769	0.91229	0.95679	0.93344	0.31111	0.07330	1.65573	0.37054	HighΔ_LowAlign
	0.3	0.89823	40.42056	0.89906	0.91442	0.91225	0.00000	0.03719	1.38721	0.36086	HighΔ_LowAlign
	0.7	0.88244	39.70988	0.88718	0.91844	0.91430	0.00000	0.00651	1.27108	0.33992	HighΔ_LowAlign
3_5	-0.7	1.24239	55.90746	1.24484	1.37962	1.32877	0.81818	0.09037	2.00511	0.36759	HighΔ_LowAlign
	-0.3	1.23174	55.42852	1.23257	1.30568	1.27496	0.81818	0.00000	1.76095	0.36319	HighΔ_LowAlign
	0.3	1.20709	54.31921	1.20920	1.22624	1.22357	0.80000	0.14267	1.52019	0.35100	HighΔ_LowAlign
	0.7	1.19192	53.63661	1.20106	1.22983	1.22563	0.80000	0.25873	1.42038	0.35713	HighΔ_LowAlign
3_6	-0.7	0.98489	44.32025	0.98835	1.10158	1.04474	0.34091	0.01860	1.57143	0.36043	HighΔ_LowAlign
	-0.3	0.98828	44.47278	0.98923	1.04899	1.01801	0.34091	0.01239	1.32849	0.36358	HighΔ_LowAlign
	0.3	0.97110	43.69941	0.97280	0.99573	0.99136	0.33333	0.01129	1.09931	0.35883	HighΔ_LowAlign
	0.7	0.95171	42.82685	0.96013	1.00324	0.99527	0.33333	0.03891	1.02533	0.35305	HighΔ_LowAlign
3_7	-0.7	1.28464	57.80865	1.28750	1.41909	1.35643	0.75000	0.03338	2.06346	0.35954	HighΔ_LowAlign
	-0.3	1.28001	57.60022	1.28102	1.35694	1.31914	0.75000	0.00000	1.83589	0.36091	HighΔ_LowAlign
	0.3	1.25614	56.52621	1.25858	1.28023	1.27582	0.80000	0.04123	1.61364	0.35370	HighΔ_LowAlign
	0.7	1.23949	55.77704	1.24905	1.28443	1.27791	0.80000	0.35673	1.51945	0.35159	HighΔ_LowAlign
3_8	-0.7	0.09905	4.45742	0.11347	0.17166	0.13706	0.24444	0.74306	2.44727	0.38974	HighΔ_HighAlign
	-0.3	0.10218	4.59795	0.10546	0.13677	0.11955	0.24444	0.86169	2.11607	0.38822	HighΔ_HighAlign
	0.3	0.09618	4.32804	0.09692	0.10487	0.10369	0.02222	0.63191	1.73071	0.37932	HighΔ_HighAlign
	0.7	0.09563	4.30350	0.10926	0.16742	0.13524	0.02222	0.09400	1.53451	0.36678	HighΔ_LowAlign
3_9	-0.7	0.88704	39.91666	0.89470	1.06013	0.97805	0.55556	0.18456	2.37991	0.37193	HighΔ_LowAlign
	-0.3	0.88691	39.91079	0.89005	0.99317	0.93991	0.55556	0.13194	2.17118	0.37170	HighΔ_LowAlign
	0.3	0.86268	38.82065	0.86793	0.90684	0.89274	0.80000	0.26755	1.95854	0.35612	HighΔ_LowAlign
	0.7	0.85715	38.57155	0.86453	0.92875	0.90395	0.82222	0.44025	1.86366	0.37328	HighΔ_LowAlign
4_5	-0.7	0.32688	14.70939	0.33064	0.35322	0.35165	0.45455	0.53085	1.12571	0.38006	HighΔ_HighAlign
	-0.3	0.34201	15.39041	0.34244	0.35657	0.35325	0.45455	0.62557	0.99952	0.37959	HighΔ_HighAlign
	0.3	0.34785	15.65310	0.34819	0.36983	0.36200	0.20000	0.50518	0.84969	0.38147	HighΔ_HighAlign

συνεχίζεται στην επόμενη σελίδα

guided_pair	weight	mean abs delta	l1 abs delta	l2 delta	top5 abs delta	top10 abs delta	frac sign aligned	avg align ment	select- ivity	spill offtarget	quadrant
4_6	0.7	0.33986	15.29356	0.34512	0.38954	0.37507	0.20000	0.25202	0.76957	0.38377	HighΔ_LowAlign
	-0.7	0.10354	4.65952	0.10601	0.11663	0.11602	0.54545	0.84922	0.63414	0.37556	HighΔ_HighAlign
	-0.3	0.10978	4.94013	0.11040	0.11534	0.11514	0.54545	0.89880	0.60577	0.38062	HighΔ_HighAlign
	0.3	0.11570	5.20658	0.11637	0.13279	0.12719	0.66667	0.88376	0.57628	0.38906	HighΔ_HighAlign
	0.7	0.11833	5.32505	0.12067	0.15515	0.14231	0.62222	0.69902	0.56492	0.39222	HighΔ_HighAlign
4_7	-0.7	0.24450	11.00231	0.25009	0.26727	0.26672	0.36364	0.62797	1.16376	0.37889	HighΔ_HighAlign
	-0.3	0.25953	11.67885	0.26009	0.26773	0.26692	0.34091	0.72203	1.05496	0.38009	HighΔ_HighAlign
	0.3	0.26470	11.91148	0.26515	0.28091	0.27536	0.20000	0.64425	0.92400	0.38399	HighΔ_HighAlign
	0.7	0.26114	11.75126	0.26362	0.29292	0.28339	0.17778	0.34674	0.85576	0.38572	HighΔ_LowAlign
4_8	-0.7	0.13235	5.95565	0.13302	0.15193	0.14688	0.73333	0.73550	1.21289	0.35863	HighΔ_HighAlign
	-0.3	0.13306	5.98774	0.13442	0.14463	0.14214	0.75556	0.89367	1.16496	0.37454	HighΔ_HighAlign
	0.3	0.14202	6.39071	0.14328	0.17361	0.16217	1.00000	0.87259	1.11642	0.39176	HighΔ_HighAlign
	0.7	0.14506	6.52770	0.15152	0.21499	0.19063	0.97778	0.53174	1.09329	0.39890	HighΔ_HighAlign
4_9	-0.7	0.49919	22.46364	0.50522	0.52479	0.52445	0.35556	0.41212	1.42496	0.37157	HighΔ_LowAlign
	-0.3	0.51786	23.30371	0.51818	0.52456	0.52416	0.35556	0.46741	1.31467	0.37594	HighΔ_LowAlign
	0.3	0.51742	23.28388	0.51853	0.52793	0.52633	0.20000	0.41756	1.18075	0.37729	HighΔ_LowAlign
	0.7	0.50914	22.91138	0.51361	0.53221	0.52891	0.17778	0.21804	1.10715	0.37821	HighΔ_LowAlign
5_6	-0.7	0.13105	5.89746	0.13561	0.16085	0.15816	0.34884	0.76020	0.75187	0.38017	HighΔ_HighAlign
	-0.3	0.14484	6.51802	0.14606	0.16005	0.15777	0.32558	0.83481	0.70138	0.38174	HighΔ_HighAlign
	0.3	0.15400	6.92986	0.15575	0.18621	0.17466	0.31111	0.69768	0.64385	0.38590	HighΔ_HighAlign
	0.7	0.16369	7.36625	0.16570	0.22513	0.20123	0.31111	0.40132	0.61510	0.38835	HighΔ_LowAlign
5_7	-0.7	0.06463	2.90818	0.07036	0.10210	0.08699	0.65909	0.79810	1.08705	0.38348	HighΔ_HighAlign
	-0.3	0.06446	2.90066	0.06582	0.07509	0.07306	0.59091	0.92682	1.08372	0.38495	HighΔ_HighAlign
	0.3	0.07282	3.27681	0.07352	0.09354	0.08568	0.68889	0.50378	1.07925	0.38688	HighΔ_HighAlign
	0.7	0.09135	4.11053	0.12120	0.24772	0.16805	0.68889	0.12666	1.07660	0.38842	HighΔ_LowAlign
5_8	-0.7	1.03713	46.67068	1.03911	1.06363	1.06269	0.34091	0.02846	1.48974	0.35740	HighΔ_LowAlign
	-0.3	1.05079	47.28554	1.05094	1.06189	1.06027	0.34091	0.00519	1.33618	0.36290	HighΔ_LowAlign
	0.3	1.05624	47.53082	1.05641	1.08261	1.07242	0.20000	0.06401	1.15880	0.36829	HighΔ_LowAlign
	0.7	1.05181	47.33131	1.05362	1.11465	1.09251	0.20000	0.05940	1.06914	0.37137	HighΔ_LowAlign
5_9	-0.7	0.05955	2.67974	0.11160	0.26874	0.16719	0.50000	0.83433	1.35340	0.38441	HighΔ_HighAlign
	-0.3	0.03386	1.52366	0.04365	0.09451	0.06634	0.50000	0.94794	1.35109	0.38592	LowΔ_HighAlign
	0.3	0.03044	1.36978	0.05526	0.10008	0.06347	0.33333	0.56694	1.34822	0.38712	LowΔ_HighAlign
	0.7	0.04810	2.16471	0.12660	0.24964	0.14079	0.28889	0.15473	1.34602	0.38779	LowΔ_LowAlign
6_7	-0.7	0.03411	1.53497	0.06239	0.16820	0.10459	0.34884	0.89495	0.79652	0.37780	LowΔ_HighAlign
	-0.3	0.01876	0.84412	0.02130	0.03851	0.03029	0.27907	0.96818	0.75511	0.38308	LowΔ_HighAlign
	0.3	0.02685	1.20839	0.03069	0.06353	0.04822	0.31111	0.84609	0.70731	0.38993	LowΔ_HighAlign
	0.7	0.04278	1.92530	0.08225	0.19487	0.11877	0.31111	0.53343	0.68384	0.39293	LowΔ_HighAlign
6_8	-0.7	0.34444	15.49981	0.34749	0.36994	0.36755	0.59091	0.68691	0.96827	0.36330	HighΔ_HighAlign
	-0.3	0.35478	15.96495	0.35551	0.36625	0.36509	0.61364	0.66766	0.89974	0.37177	HighΔ_HighAlign
	0.3	0.36529	16.43796	0.36606	0.40155	0.38830	0.66667	0.68822	0.84324	0.38628	HighΔ_HighAlign
	0.7	0.36633	16.48478	0.37090	0.44389	0.41773	0.66667	0.44484	0.82190	0.39009	HighΔ_LowAlign
6_9	-0.7	0.41446	18.65087	0.42304	0.45264	0.45132	0.34091	0.54032	1.01689	0.37366	HighΔ_HighAlign
	-0.3	0.43922	19.76511	0.43969	0.45137	0.45004	0.34091	0.55359	0.98294	0.37644	HighΔ_HighAlign
	0.3	0.44370	19.96668	0.44503	0.46539	0.45857	0.31111	0.50311	0.94206	0.37930	HighΔ_HighAlign
	0.7	0.43767	19.69503	0.44208	0.48290	0.46910	0.28889	0.40361	0.92049	0.38089	HighΔ_LowAlign
7_8	-0.7	0.86373	38.86781	0.86831	0.90025	0.89731	0.27273	0.09916	1.57789	0.36207	HighΔ_LowAlign
	-0.3	0.88140	39.66296	0.88188	0.89528	0.89347	0.27273	0.09561	1.41550	0.36340	HighΔ_LowAlign
	0.3	0.89261	40.16759	0.89307	0.93298	0.91764	0.20000	0.09708	1.22439	0.37388	HighΔ_LowAlign
	0.7	0.89187	40.13414	0.89482	0.97660	0.94746	0.20000	0.04305	1.12557	0.37650	HighΔ_LowAlign
7_9	-0.7	0.30889	13.89999	0.31613	0.34172	0.34146	0.68182	0.69502	1.43001	0.37872	HighΔ_HighAlign
	-0.3	0.33159	14.92153	0.33230	0.34125	0.34114	0.65909	0.67464	1.42861	0.37935	HighΔ_HighAlign
	0.3	0.33512	15.08036	0.33800	0.35662	0.35125	0.64444	0.60598	1.42597	0.38087	HighΔ_HighAlign
	0.7	0.33663	15.14849	0.33984	0.37232	0.36199	0.68889	0.25288	1.42359	0.38170	HighΔ_LowAlign
8_9	-0.7	0.72727	32.72714	0.73279	0.76484	0.76216	0.26667	0.18554	1.83236	0.38111	HighΔ_LowAlign
	-0.3	0.74318	33.44332	0.74450	0.75901	0.75764	0.28889	0.23460	1.69441	0.37313	HighΔ_LowAlign
	0.3	0.75625	34.03123	0.75738	0.80397	0.78583	0.20000	0.15221	1.53743	0.37309	HighΔ_LowAlign
	0.7	0.75759	34.09152	0.76249	0.85204	0.81885	0.20000	0.07466	1.45977	0.37295	HighΔ_LowAlign

Clusters

Πίνακας 78: Συνοπτικό πάνελ για Cluster 01: κορυφαίοι συνδυασμοί, καθοδηγούμενα stems και επηρεαζόμενα stems.
Top combos (by cluster_share only)

guided_group	affected_pair_group	cnt	cluster share (%)	baseline share (%)	enrich	mean $ \Delta $	sign_follow
Guitar–Keys (mixed)	Guitar–Keys	29	9.9	6.7	1.48	0.422	0.034
Guitar–Rhythmic (mixed)	Guitar–Keys	20	6.8	3.6	1.871	0.410	0.050
Guitar–Keys (mixed)	Keys–Pads/Strings	14	4.8	2.4	1.964	0.455	0.000
Guitar–Keys (mixed)	Guitar–Guitar	12	4.1	1.8	2.245	0.494	0.000
Keys–Rhythmic (mixed)	Guitar–Keys	12	4.1	4.8	0.842	0.430	0.000
Keys	Guitar–Keys	10	3.4	3.6	0.935	0.425	0.000

Guided stems – Guitar–Keys (mixed) → Guitar–Keys

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
Piano	Keys	26.2	24.1
Guitar-A (dist)	Guitar	21.7	20.7
Guitar-B (jazz)	Guitar	16.1	17.2
Organ-A (perc)	Keys	13.9	15.5
Guitar-C (dist)	Guitar	12.2	12.1

Guided stems – Guitar–Rhythmic (mixed) → Guitar–Keys

Stem	Group	$ \Delta $ -wtd (%)	Count (%)
Bass	Rhythmic	38.1	37.5
Guitar-C (dist)	Guitar	22.5	22.5
Guitar-B (jazz)	Guitar	15.5	17.5
Guitar-A (dist)	Guitar	12.1	10.0
Drums	Rhythmic	11.9	12.5

Affected stems in Guitar – Gtr–Keys (mixed) → Guitar–Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
Guitar-C (dist)	56.2	62.1
Guitar-B (jazz)	39.3	31.0
Guitar-A (dist)	4.6	6.9

Affected stems in Keys – Gtr–Keys (mixed) → Guitar–Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
Organ-B	46.1	41.4
Organ-C	24.5	24.1
Organ-A (perc)	18.0	20.7
Piano	11.4	13.8

Affected stems in Guitar – Gtr–Rhythmic (mixed) → Guitar–Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
Guitar-C (dist)	40.3	45.0
Guitar-B (jazz)	34.0	30.0
Guitar-A (dist)	25.8	25.0

Affected stems in Keys – Gtr–Rhythmic (mixed) → Guitar–Keys

Stem	$ \Delta $ -wtd (%)	Count (%)
Organ-B	58.3	50.0
Organ-C	20.1	20.0
Organ-A (perc)	14.8	20.0
Piano	6.8	10.0

Σύντομη ποσοτική περίληψη. Μερίδιο κορυφαίων συνδυασμών $\approx 3.4\%$ – 9.9% . Ενίσχυση $\approx 0.84\times$ – $2.24\times$. Μέση $|\Delta| \approx 0.41$ – 0.494 .

Πίνακας 79: Συνοπτικό πάνελ για Cluster 02.

Top combos								
guided_group		affected_pair_group	cnt	cluster share (%)	baseline share (%)	enrich	mean Δ	sign_follow
EBWA-SBC (mixed)		EBWA-SBC	33	3.7	3.6	1.013	0.089	0.000
EBWA-SBC (mixed)		SBC-SBC	27	3.0	1.4	2.210	0.090	0.148
EBWA-SBC (mixed)		EBWA-US-101	27	3.0	2.7	1.105	0.068	0.074
EBWA-SBC (mixed)		SBC-US-101	27	3.0	2.7	1.105	0.119	0.000
SBC-US-101 (mixed)		EBWA-SBC	26	2.9	2.7	1.064	0.117	0.000
EBWA-US-101 (mixed)		EBWA-SBC	25	2.8	2.7	1.023	0.115	0.000
Guided stems — EBWA-SBC (mixed) → EBWA-SBC				Guided stems — EBWA-SBC (mixed) → EBWA-US-101				
Stem	Group	Δ -wtd (%)	Count (%)	Stem	Group	Δ -wtd (%)	Count (%)	
E of Carlson Blvd @ I-80-E (Richmond)	EBWA	21.3	19.7	Lakeshore Ave @ I-580-E (Oakland)	EBWA	17.6	16.7	
N First St @ I-880-S (Santa Clara)	SBC	20.4	18.2	Bascom Ave @ SR-85-S (Santa Clara)	SBC	17.1	16.7	
Lakeshore Ave @ I-580-E (Oakland)	EBWA	16.2	16.7	University Ave @ I-80-W (Berkeley)	EBWA	16.8	16.7	
US-101-N (Santa Clara)	SBC	15.3	16.7	US-101-N (Santa Clara)	SBC	16.7	16.7	
Bascom Ave @ SR-85-S (Santa Clara)	SBC	14.3	15.2	N First St @ I-880-S (Santa Clara)	SBC	16.2	16.7	
Affected in EBWA — EBWA-SBC (mixed) → EBWA-SBC				Affected in SBC — EBWA-SBC (mixed) → EBWA-SBC				
Stem	Δ -wtd (%)	Count (%)	Stem	Δ -wtd (%)	Count (%)			
University Ave @ I-80-W (Berkeley)	73.3	72.7	Bascom Ave @ SR-85-S (Santa Clara)	45.6	48.5			
Lakeshore Ave @ I-580-E (Oakland)	26.7	27.3	N First St @ I-880-S (Santa Clara)	31.6	27.3			
			US-101-N (Santa Clara)	22.8	24.2			
Affected in EBWA — EBWA-SBC (mixed) → EBWA-US-101			Affected in US-101 Axis — EBWA-SBC (mixed) → EBWA-US-101					
Stem	Δ -wtd (%)	Count (%)	Stem	Δ -wtd (%)	Count (%)			
E of Carlson Blvd @ I-80-E (Richmond)	49.2	33.3	SR-37 @ US-101 (Marin)	50.8	66.7			
University Ave @ I-80-W (Berkeley)	42.9	33.3	San Bruno Ave @ US-101-N (San Mateo)	49.2	33.3			
Lakeshore Ave @ I-580-E (Oakland)	7.9	33.3						

Σύντομη ποσοτική περίληψη. Μερίδιο $\approx 2.8\%-3.7\%$, Ενίσχυση $\approx 1.01 \times - 2.21 \times$, Μέση $|\Delta| \approx 0.068-0.119$.

Πίνακας 80: Συνοπτικό πάνελ για Cluster 03.

Top combos							
guided_group	affected_pair_group	cnt	cluster share (%)	baseline share (%)	enrich	mean $ \Delta $	sign_follow
EBWA-SBC (mixed)	SBC-US-101	27	7.7	2.7	2.812	0.936	0.000
Inland / Misc-SBC (mixed)	SBC-US-101	18	5.1	1.8	2.813	0.936	0.000
EBWA-Inland / Misc (mixed)	SBC-US-101	18	5.1	1.8	2.813	0.941	0.000
EBWA-SBC (mixed)	EBWA-US-101	18	5.1	2.7	1.875	1.086	0.000
EBWA-SBC (mixed)	Inland / Misc-US-101	18	5.1	1.8	2.813	0.947	0.000
EBWA-US-101 (mixed)	SBC-US-101	18	5.1	1.8	2.813	0.946	0.000
Guided stems – EBWA-SBC (mixed) → SBC-US-101				Guided stems – EBWA-SBC (mixed) → Inland / Misc-US-101			
Stem	Group	$ \Delta $ -wtd (%)	Count (%)	Stem	Group	$ \Delta $ -wtd (%)	Count (%)
University Ave @ I-80-W (Berkeley)	EBWA	16.8	16.7	E of Carlson Blvd @ I-80-E (Richmond)	EBWA	16.7	16.7
Lakeshore Ave @ I-580-E (Oakland)	EBWA	16.8	16.7	N First St @ I-880-S (Santa Clara)	SBC	16.7	16.7
Bascom Ave @ SR-85-S (Santa Clara)	SBC	16.7	16.7	US-101-N (Santa Clara)	SBC	16.7	16.7
N First St @ I-880-S (Santa Clara)	SBC	16.7	16.7	Lakeshore Ave @ I-580-E (Oakland)	EBWA	16.7	16.7
US-101-N (Santa Clara)	SBC	16.6	16.7	Bascom Ave @ SR-85-S (Santa Clara)	SBC	16.7	16.7
Affected in SBC – EBWA-SBC (mixed) → SBC-US-101				Affected in US-101 Axis – EBWA-SBC (mixed) → SBC-US-101			
Stem		$ \Delta $ -wtd (%)	Count (%)	Stem		$ \Delta $ -wtd (%)	Count (%)
Bascom Ave @ SR-85-S (Santa Clara)		43.3	33.3	San Bruno Ave @ US-101-N (San Mateo)		100.0	100.0
N First St @ I-880-S (Santa Clara)		31.1	33.3				
US-101-N (Santa Clara)		25.6	33.3				
Affected in Inland / Misc – EBWA-SBC (mixed) → Inland / Misc-US-101				Affected in US-101 Axis – EBWA-SBC (mixed) → Inland / Misc-US-101			
Stem		$ \Delta $ -wtd (%)	Count (%)	Stem		$ \Delta $ -wtd (%)	Count (%)
Newell Ave @ I-680-N (Walnut Creek)		52.0	50.0	San Bruno Ave @ US-101-N (San Mateo)		100.0	100.0
Unk		48.0	50.0				

Σύντομη ποσοτική περίληψη. Μερίδιο $\approx 5.1\%-7.7\%$, Ενίσχυση $\approx 1.88 \times -2.81 \times$, Μέση $|\Delta| \approx 0.936-1.086$.

Lorenz

Πίνακας 81: Μετρικές καθοδήγησης ανά guided_pair — Complete Dataset

guided_pair	weight	mean abs delta	l1 abs delta	l2 delta	top5 abs delta	top10 abs delta	frac sign aligned	avg align ment	select- ivity	spill offtarget	quadrant
0_1	-0.7	0.02724	1.22596	0.12289	0.23771	0.12113	0.48718	0.77115	25.88610	0.00362	HighΔ_HighAlign
	-0.3	0.00507	0.22826	0.02248	0.04354	0.02218	0.61538	0.95749	24.08380	0.00105	LowΔ_HighAlign
	0.3	0.03111	1.40013	0.17461	0.26391	0.13912	0.39535	0.87595	22.45650	0.00615	HighΔ_HighAlign
	0.7	0.19100	8.59486	0.54638	1.59693	0.85700	0.37209	0.58596	25.03281	0.18782	HighΔ_LowAlign
0_2	-0.7	0.03692	1.66154	0.14996	0.28831	0.15542	0.35000	0.74938	25.78605	0.11202	HighΔ_HighAlign
	-0.3	0.01070	0.48132	0.03183	0.06968	0.04257	0.32500	0.94936	25.40429	0.01797	HighΔ_HighAlign
	0.3	0.04106	1.44751	0.19538	0.31068	0.17370	0.65116	0.87389	24.32031	0.00423	HighΔ_HighAlign
	0.7	0.22148	9.96665	0.55897	1.59656	0.95982	0.67442	0.59147	25.69053	0.01092	HighΔ_LowAlign
0_3	-0.7	0.02722	1.22502	0.12233	0.23607	0.12040	0.36585	0.91268	78.25704	0.00274	HighΔ_HighAlign
	-0.3	0.00554	0.24944	0.02283	0.04535	0.02376	0.19512	0.98341	59.57983	0.00195	LowΔ_HighAlign
	0.3	0.03208	1.44346	0.17859	0.27184	0.14361	0.52381	0.95187	51.39861	0.00932	HighΔ_HighAlign
	0.7	0.19286	8.67862	0.55046	1.61272	0.86578	0.40476	0.77046	68.68200	0.23912	HighΔ_HighAlign
0_4	-0.7	0.02741	1.23347	0.12279	0.23605	0.12053	0.36585	0.70885	36.88948	0.00355	HighΔ_HighAlign
	-0.3	0.00607	0.27315	0.02369	0.04866	0.02384	0.43902	0.94473	33.80777	0.00199	LowΔ_HighAlign
	0.3	0.03333	1.49990	0.18287	0.28030	0.14911	0.52381	0.82442	36.11436	0.00613	HighΔ_HighAlign
	0.7	0.19414	8.73621	0.55367	1.62270	0.87175	0.57143	0.52615	41.00186	0.30846	HighΔ_LowAlign
0_5	-0.7	0.06333	2.84987	0.20700	0.54291	0.28037	0.32432	0.88599	29.33698	0.00012	HighΔ_HighAlign
	-0.3	0.01293	0.58165	0.04279	0.10912	0.05690	0.32432	0.97823	29.08938	0.00005	HighΔ_HighAlign
	0.3	0.08301	3.73564	0.33007	0.65851	0.35884	0.45000	0.92124	28.50242	0.00008	HighΔ_HighAlign
	0.7	0.42201	18.99056	0.83397	1.91765	1.72290	0.46341	0.60612	28.24810	0.00018	HighΔ_LowAlign
0_6	-0.7	0.02708	1.21851	0.12342	0.23856	0.12042	0.46154	0.78473	27.49326	0.00273	HighΔ_HighAlign
	-0.3	0.00540	0.24308	0.02292	0.04494	0.02337	0.56410	0.96031	25.46902	0.00136	LowΔ_HighAlign
	0.3	0.03153	1.41883	0.17644	0.26745	0.14113	0.39535	0.87937	23.81210	0.00814	HighΔ_HighAlign
	0.7	0.19202	8.64109	0.54845	1.60699	0.86212	0.34884	0.59426	26.64522	0.25632	HighΔ_LowAlign
0_7	-0.7	0.05204	2.34174	0.16020	0.34507	0.20341	0.42500	0.72900	23.07933	0.09034	HighΔ_HighAlign
	-0.3	0.01943	0.87451	0.04806	0.11174	0.07273	0.45000	0.93972	23.72216	0.02440	HighΔ_HighAlign
	0.3	0.06892	3.10156	0.21831	0.46956	0.28466	0.51163	0.84439	22.50858	0.01235	HighΔ_HighAlign
	0.7	0.29377	13.21973	0.61258	1.62950	1.19877	0.51163	0.52789	23.12396	0.02774	HighΔ_LowAlign
0_8	-0.7	0.02791	1.25593	0.12488	0.24146	0.12302	0.39024	0.86161	111.55546	0.00391	HighΔ_HighAlign
	-0.3	0.00642	0.28892	0.02449	0.05164	0.02757	0.46341	0.97360	108.47178	0.00249	LowΔ_HighAlign
	0.3	0.03417	1.53779	0.18711	0.28690	0.15193	0.71429	0.94516	66.69768	0.20049	HighΔ_HighAlign
	0.7	0.19422	8.73992	0.55380	1.62248	0.87090	0.71429	0.72425	89.03283	0.31647	HighΔ_HighAlign
0_9	-0.7	0.04085	1.83813	0.13383	0.30612	0.17112	0.39024	0.72939	44.52385	0.00476	HighΔ_HighAlign
	-0.3	0.01097	0.49386	0.02990	0.06964	0.04261	0.41463	0.94442	39.70053	0.00251	HighΔ_HighAlign
	0.3	0.03831	1.72383	0.19623	0.31136	0.16555	0.32500	0.86248	41.13929	0.00703	HighΔ_HighAlign
	0.7	0.19484	8.76794	0.54267	1.58449	0.86030	0.45000	0.55280	48.35948	0.07093	HighΔ_LowAlign
1_2	-0.7	0.00595	0.26790	0.01163	0.02832	0.02196	0.37500	0.41654	17.65799	0.00595	LowΔ_LowAlign
	-0.3	0.00233	0.10499	0.00460	0.01237	0.00885	0.32500	0.72997	16.67364	0.00274	LowΔ_HighAlign
	0.3	0.00440	0.19786	0.01127	0.03000	0.01816	0.35556	0.72625	15.48989	0.00353	LowΔ_HighAlign
	0.7	0.02818	1.26788	0.11613	0.22839	0.12355	0.37778	0.36045	16.90010	0.01216	HighΔ_LowAlign
1_3	-0.7	0.00223	0.10047	0.00549	0.01325	0.00873	0.57143	0.74927	26.82034	0.00074	LowΔ_HighAlign
	-0.3	0.00038	0.01690	0.00085	0.00226	0.00149	0.54762	0.95392	22.75718	0.00032	LowΔ_HighAlign
	0.3	0.00028	0.01247	0.00056	0.00148	0.00105	0.50000	0.92852	21.34149	0.00021	LowΔ_HighAlign
	0.7	0.00122	0.05473	0.00251	0.00656	0.00476	0.52273	0.64445	24.95266	0.00045	LowΔ_LowAlign
1_4	-0.7	0.00253	0.11390	0.00677	0.01671	0.00972	0.78571	0.34142	84.98127	0.00334	LowΔ_LowAlign
	-0.3	0.00061	0.02760	0.00122	0.00311	0.00199	0.78571	0.69299	60.34069	0.00092	LowΔ_LowAlign
	0.3	0.00046	0.02056	0.00075	0.00189	0.00140	0.62791	0.65104	85.39802	0.00046	LowΔ_LowAlign
	0.7	0.00137	0.06187	0.00273	0.00741	0.00512	0.69767	0.38206	105.68366	0.00109	LowΔ_LowAlign
1_5	-0.7	0.04096	1.84319	0.18606	0.35817	0.18200	0.48718	0.63471	24.63827	0.00435	HighΔ_LowAlign
	-0.3	0.01004	0.45173	0.04467	0.08636	0.04381	0.71795	0.92899	22.80493	0.00114	HighΔ_HighAlign
	0.3	0.05572	2.50727	0.28987	0.46504	0.24971	0.34884	0.84958	21.57323	0.01444	HighΔ_HighAlign
	0.7	0.23292	10.48144	0.63219	1.83856	1.04536	0.32558	0.54975	23.93237	0.26191	HighΔ_LowAlign
1_6	-0.7	0.00218	0.09799	0.00532	0.01345	0.00883	0.30000	0.42414	15.90007	0.00047	LowΔ_LowAlign
	-0.3	0.00033	0.01481	0.00076	0.00196	0.00132	0.32500	0.74964	12.93165	0.00015	LowΔ_HighAlign
	0.3	0.00024	0.01088	0.00050	0.00134	0.00094	0.46667	0.74301	12.38373	0.00013	LowΔ_HighAlign
	0.7	0.00111	0.05003	0.00227	0.00592	0.00429	0.44444	0.38830	14.77712	0.00033	LowΔ_LowAlign
1_7	-0.7	0.01757	0.79085	0.02984	0.07008	0.06003	0.42500	0.42240	17.17752	0.00815	HighΔ_LowAlign
	-0.3	0.00835	0.37572	0.01624	0.04392	0.03056	0.42500	0.73040	16.82381	0.00564	LowΔ_HighAlign

συνεχίζεται στην επόμενη σελίδα

guided_pair	weight	mean abs delta	l1 abs delta	l2 delta	top5 abs delta	top10 abs delta	frac sign aligned	avg align ment	select- ivity	spill offtarget	quadrant
1_8	0.3	0.02944	1.32478	0.08975	0.22071	0.12584	0.51111	0.71323	15.55130	0.01688	HighΔ_HighAlign
	0.7	0.10958	4.93126	0.32783	0.87438	0.47987	0.46667	0.33557	16.64570	0.07629	HighΔ_LowAlign
	-0.7	0.00228	0.10250	0.00701	0.01643	0.00931	0.09524	0.56605	43.61379	0.00712	LowΔ_LowAlign
	-0.3	0.00056	0.02505	0.00129	0.00321	0.00207	0.14286	0.85465	43.00747	0.00139	LowΔ_HighAlign
	0.3	0.00028	0.01259	0.00061	0.00162	0.00100	0.31818	0.90059	36.61306	0.00064	LowΔ_HighAlign
1_9	0.7	0.00087	0.03930	0.00224	0.00521	0.00330	0.31818	0.60364	40.84043	0.00136	LowΔ_LowAlign
	-0.7	0.01279	0.57539	0.03443	0.08472	0.05061	0.61905	0.38723	91.60642	0.00830	HighΔ_LowAlign
	-0.3	0.00327	0.14733	0.00677	0.01801	0.01175	0.61905	0.71850	70.55728	0.00242	LowΔ_HighAlign
	0.3	0.00254	0.11440	0.00413	0.00897	0.00811	0.48780	0.70007	77.77233	0.00139	LowΔ_HighAlign
	0.7	0.00580	0.26088	0.01047	0.02600	0.02064	0.48780	0.40800	98.32433	0.00333	LowΔ_LowAlign
2_3	-0.7	0.00429	0.19312	0.00767	0.01880	0.01534	0.44186	0.73439	29.96075	0.00543	LowΔ_HighAlign
	-0.3	0.00192	0.08636	0.00376	0.01015	0.00701	0.48837	0.95014	28.78511	0.00276	LowΔ_HighAlign
	0.3	0.00398	0.17927	0.01022	0.02664	0.01626	0.40909	0.92581	26.07406	0.00380	LowΔ_HighAlign
	0.7	0.02687	1.20926	0.11334	0.21718	0.11767	0.40909	0.62208	28.64535	0.01492	HighΔ_LowAlign
	-0.7	0.00281	0.12644	0.00563	0.01437	0.01018	0.76744	0.34136	138.73832	0.00265	LowΔ_LowAlign
2_4	-0.3	0.00143	0.06430	0.00266	0.00691	0.00509	0.83721	0.68911	88.26106	0.00155	LowΔ_LowAlign
	0.3	0.00317	0.14243	0.00827	0.02090	0.01305	0.79070	0.65134	179.16943	0.00413	LowΔ_LowAlign
	0.7	0.02437	1.09643	0.10701	0.19663	0.10660	0.79070	0.36757	229.70264	0.01919	HighΔ_LowAlign
	-0.7	0.04965	2.23427	0.21062	0.40107	0.21121	0.20000	0.62858	24.56313	0.16837	HighΔ_LowAlign
	-0.3	0.01615	0.72658	0.05702	0.11798	0.06649	0.25000	0.92033	24.16404	0.03666	HighΔ_HighAlign
2_5	0.3	0.06418	2.88830	0.28599	0.49780	0.27844	0.79070	0.85232	23.23983	0.00576	HighΔ_HighAlign
	0.7	0.25804	11.61198	0.63364	1.79635	1.12441	0.72093	0.55380	24.49289	0.01475	HighΔ_LowAlign
	-0.7	0.00446	0.20082	0.00813	0.01994	0.01625	0.27500	0.42701	18.42563	0.00644	LowΔ_LowAlign
	-0.3	0.00195	0.08779	0.00397	0.01081	0.00733	0.25000	0.74205	17.81147	0.00309	LowΔ_HighAlign
	0.3	0.00416	0.18717	0.01069	0.02814	0.01699	0.31111	0.73418	16.23601	0.00394	LowΔ_HighAlign
2_6	0.7	0.02748	1.23656	0.11454	0.22237	0.12012	0.31111	0.37197	17.55677	0.01504	HighΔ_LowAlign
	-0.7	0.01282	0.57687	0.02449	0.06113	0.04762	0.53659	0.41661	17.25813	0.00869	HighΔ_LowAlign
	-0.3	0.00564	0.25387	0.01003	0.02444	0.01942	0.58537	0.73090	16.00715	0.00236	LowΔ_HighAlign
	0.3	0.02116	0.95212	0.06660	0.15596	0.09143	0.53333	0.73914	15.15100	0.00114	HighΔ_HighAlign
	0.7	0.10776	4.84909	0.30880	0.78625	0.47224	0.55556	0.36826	16.71388	0.00301	HighΔ_LowAlign
2_8	-0.7	0.00255	0.11491	0.00523	0.01350	0.00915	0.34884	0.56534	36.97227	0.00669	LowΔ_LowAlign
	-0.3	0.00122	0.05468	0.00230	0.00593	0.00449	0.34884	0.85044	38.67121	0.00332	LowΔ_HighAlign
	0.3	0.00326	0.14664	0.00843	0.02214	0.01374	0.52273	0.90021	35.71698	0.00813	LowΔ_HighAlign
	0.7	0.02442	1.09898	0.10393	0.19777	0.10754	0.52273	0.60968	37.20242	0.11509	HighΔ_LowAlign
	-0.7	0.00572	0.25739	0.01526	0.03223	0.02183	0.23256	0.38019	119.35302	0.00232	LowΔ_LowAlign
2_9	-0.3	0.00110	0.04932	0.00192	0.00449	0.00372	0.25581	0.71314	92.25433	0.00153	LowΔ_HighAlign
	0.3	0.00187	0.08400	0.00504	0.01259	0.00812	0.46341	0.69710	135.07617	0.00349	LowΔ_LowAlign
	0.7	0.02004	0.90161	0.09215	0.16098	0.08827	0.43902	0.40708	168.24120	0.01263	HighΔ_LowAlign
	-0.7	0.00117	0.05257	0.00260	0.00712	0.00447	0.35556	0.67189	35.94844	0.00139	LowΔ_LowAlign
	-0.3	0.00027	0.01197	0.00048	0.00129	0.00089	0.42222	0.93532	31.68059	0.00054	LowΔ_HighAlign
3_4	0.3	0.00028	0.01281	0.00058	0.00155	0.00100	0.50000	0.88709	43.94415	0.00051	LowΔ_HighAlign
	0.7	0.00102	0.04570	0.00229	0.00632	0.00388	0.50000	0.52131	43.44033	0.00073	LowΔ_LowAlign
	-0.7	0.04085	1.83813	0.18532	0.35697	0.18087	0.26829	0.88816	66.19800	0.00275	HighΔ_HighAlign
	-0.3	0.01045	0.47004	0.04520	0.08825	0.04514	0.29268	0.97648	49.50233	0.00203	HighΔ_HighAlign
	0.3	0.05668	2.55052	0.29091	0.47094	0.25416	0.52381	0.94111	45.73517	0.01923	HighΔ_HighAlign
3_5	0.7	0.23418	10.53831	0.63572	1.84864	1.05130	0.50000	0.72938	61.33835	0.29581	HighΔ_HighAlign
	-0.7	0.00135	0.06068	0.00276	0.00697	0.00530	0.57143	0.76843	25.77004	0.00031	LowΔ_HighAlign
	-0.3	0.00021	0.00951	0.00043	0.00113	0.00081	0.54762	0.95744	20.52729	0.00013	LowΔ_HighAlign
	0.3	0.00019	0.00871	0.00046	0.00122	0.00079	0.54545	0.93298	20.25405	0.00007	LowΔ_HighAlign
	0.7	0.00094	0.04222	0.00212	0.00566	0.00377	0.54545	0.65982	24.30226	0.00022	LowΔ_LowAlign
3_7	-0.7	0.01506	0.67750	0.02610	0.06348	0.05153	0.46512	0.70716	25.90715	0.00811	HighΔ_HighAlign
	-0.3	0.00755	0.33960	0.01486	0.03985	0.02755	0.51163	0.94164	25.98170	0.00537	LowΔ_HighAlign
	0.3	0.02808	1.26345	0.08681	0.21146	0.12048	0.59091	0.90601	23.84213	0.02168	HighΔ_HighAlign
	0.7	0.10734	4.83051	0.32432	0.85852	0.47071	0.61364	0.59542	25.57577	0.10470	HighΔ_LowAlign
	-0.7	0.00099	0.04457	0.00248	0.00626	0.00368	0.48889	0.89190	230.74547	0.00200	LowΔ_HighAlign
3_8	-0.3	0.00029	0.01324	0.00048	0.00117	0.00083	0.53333	0.98023	167.63886	0.00055	LowΔ_HighAlign
	0.3	0.00030	0.01331	0.00054	0.00127	0.00087	0.30233	0.98056	148.03704	0.00046	LowΔ_HighAlign
	0.7	0.00075	0.03378	0.00201	0.00450	0.00259	0.34884	0.89446	233.24983	0.00093	LowΔ_HighAlign
	-0.7	0.01019	0.45852	0.03051	0.07161	0.04080	0.44444	0.68006	43.08365	0.00729	HighΔ_LowAlign
	-0.3	0.00259	0.11663	0.00554	0.01492	0.00910	0.51111	0.93945	38.95161	0.00237	LowΔ_HighAlign
3_9	0.3	0.00225	0.10134	0.00363	0.00827	0.00727	0.48780	0.91414	51.40688	0.00148	LowΔ_HighAlign
	0.7	0.00528	0.23780	0.00941	0.02282	0.01783	0.58537	0.59576	51.42094	0.00357	LowΔ_LowAlign

συνεχίζεται στην επόμενη σελίδα

guided_pair	weight	mean abs delta	l1 abs delta	l2 delta	top5 abs delta	top10 abs delta	frac sign aligned	avg align ment	select- ivity	spill offtarget	quadrant
4_5	-0.7	0.04104	1.84686	0.18554	0.35439	0.18024	0.29268	0.58552	38.28249	0.00330	HighΔ_LowAlign
	-0.3	0.01109	0.49921	0.04637	0.09152	0.04746	0.29268	0.91538	33.77888	0.00208	HighΔ_HighAlign
	0.3	0.05781	2.60145	0.29105	0.47899	0.25914	0.38095	0.78976	37.05084	0.02553	HighΔ_HighAlign
	0.7	0.23439	10.54763	0.63678	1.84934	1.05267	0.42857	0.47394	42.43599	0.31430	HighΔ_LowAlign
4_6	-0.7	0.00138	0.06220	0.00322	0.00840	0.00513	0.78571	0.35589	84.91718	0.00176	LowΔ_LowAlign
	-0.3	0.00623	0.01584	0.00061	0.00163	0.00109	0.78571	0.70948	60.33367	0.00059	LowΔ_HighAlign
	0.3	0.00032	0.01427	0.00057	0.00152	0.00105	0.60465	0.65979	87.44733	0.00043	LowΔ_LowAlign
	0.7	0.00102	0.04572	0.00207	0.00582	0.00380	0.67442	0.39277	104.45244	0.00087	LowΔ_LowAlign
4_7	-0.7	0.01184	0.53293	0.02200	0.05762	0.04218	0.55814	0.35439	200.38335	0.00770	HighΔ_LowAlign
	-0.3	0.00623	0.28051	0.01232	0.03191	0.02364	0.53488	0.68278	129.20975	0.00407	LowΔ_LowAlign
	0.3	0.02571	1.15690	0.08108	0.19437	0.11147	0.41860	0.67363	155.10087	0.02879	HighΔ_LowAlign
	0.7	0.10336	4.65100	0.31688	0.83108	0.45506	0.48837	0.39346	236.40934	0.13590	HighΔ_LowAlign
4_8	-0.7	0.00023	0.01054	0.00035	0.00087	0.00063	0.64444	0.52142	29.29528	0.00260	LowΔ_LowAlign
	-0.3	0.00009	0.00412	0.00012	0.00024	0.00019	0.68889	0.84189	25.94623	0.00116	LowΔ_HighAlign
	0.3	0.00015	0.00656	0.00033	0.00072	0.00045	0.85714	0.86113	28.20910	0.00077	LowΔ_HighAlign
	0.7	0.00051	0.02303	0.00149	0.00345	0.00193	0.80952	0.51905	30.29188	0.00184	LowΔ_LowAlign
4_9	-0.7	0.00773	0.34782	0.02589	0.05804	0.03130	0.55556	0.25247	23.94546	0.00682	LowΔ_LowAlign
	-0.3	0.00181	0.08157	0.00414	0.01119	0.00661	0.55556	0.68513	21.62095	0.00204	LowΔ_LowAlign
	0.3	0.00159	0.07150	0.00270	0.00636	0.00544	0.61538	0.60608	21.83465	0.00182	LowΔ_LowAlign
	0.7	0.00417	0.18755	0.00771	0.01848	0.01392	0.61538	0.44019	23.80942	0.00387	LowΔ_LowAlign
5_6	-0.7	0.04084	1.83783	0.18660	0.35987	0.18137	0.56410	0.65813	26.04387	0.00293	HighΔ_LowAlign
	-0.3	0.01030	0.46367	0.04530	0.08797	0.04474	0.69231	0.93357	23.95458	0.00136	HighΔ_HighAlign
	0.3	0.05613	2.52590	0.29030	0.46665	0.25163	0.44186	0.85331	22.91957	0.02149	HighΔ_HighAlign
	0.7	0.23364	10.51381	0.63447	1.84566	1.04903	0.39535	0.55790	25.43042	0.29516	HighΔ_LowAlign
5_7	-0.7	0.06382	2.87191	0.21522	0.45170	0.25657	0.20000	0.61104	22.08777	0.12666	HighΔ_LowAlign
	-0.3	0.02525	1.13620	0.07186	0.15963	0.09765	0.22500	0.91024	22.64989	0.04010	HighΔ_HighAlign
	0.3	0.08953	4.02875	0.28461	0.57872	0.36583	0.48837	0.82466	21.53879	0.01798	HighΔ_HighAlign
	0.7	0.32592	14.66618	0.66970	1.71651	1.33653	0.48837	0.50757	22.15261	0.03684	HighΔ_LowAlign
5_8	-0.7	0.04115	1.85168	0.18774	0.35909	0.18214	0.34146	0.78822	111.99760	0.00339	HighΔ_HighAlign
	-0.3	0.01142	0.51381	0.04754	0.09521	0.04954	0.31707	0.95739	102.66232	0.00217	HighΔ_HighAlign
	0.3	0.05832	2.62418	0.29163	0.48319	0.26069	0.66667	0.93337	70.04126	0.31044	HighΔ_HighAlign
	0.7	0.23404	10.53181	0.63630	1.84639	1.05044	0.76190	0.69128	91.58374	0.31683	HighΔ_LowAlign
5_9	-0.7	0.05397	2.42851	0.19322	0.42052	0.22792	0.24390	0.61575	46.87909	0.00556	HighΔ_LowAlign
	-0.3	0.01649	0.74213	0.05376	0.11662	0.06660	0.34146	0.91506	40.78946	0.00250	HighΔ_HighAlign
	0.3	0.06098	2.74398	0.28522	0.49990	0.26767	0.57500	0.83050	41.86165	0.01347	HighΔ_HighAlign
	0.7	0.23117	10.40272	0.61847	1.78501	1.02313	0.55000	0.50929	49.70882	0.16724	HighΔ_LowAlign
6_7	-0.7	0.01560	0.70189	0.02676	0.06418	0.05304	0.40000	0.43198	17.76992	0.00866	HighΔ_LowAlign
	-0.3	0.00776	0.34909	0.01529	0.04140	0.02815	0.37500	0.74130	17.62672	0.00603	LowΔ_HighAlign
	0.3	0.02869	1.29104	0.08813	0.21575	0.12294	0.53333	0.72361	16.05921	0.02126	HighΔ_HighAlign
	0.7	0.10857	4.88558	0.32600	0.86699	0.47555	0.48889	0.34178	17.15579	0.10574	HighΔ_LowAlign
6_8	-0.7	0.00119	0.05352	0.00317	0.00748	0.00447	0.07143	0.57688	47.29844	0.00331	LowΔ_LowAlign
	-0.3	0.00034	0.01508	0.00063	0.00159	0.00108	0.07143	0.86461	46.04857	0.00085	LowΔ_HighAlign
	0.3	0.00027	0.01216	0.00045	0.00114	0.00080	0.22727	0.90506	38.82100	0.00051	LowΔ_HighAlign
	0.7	0.00064	0.02873	0.00154	0.00362	0.00217	0.22727	0.61395	43.93215	0.00109	LowΔ_LowAlign
6_9	-0.7	0.01064	0.47875	0.03144	0.07382	0.04296	0.57143	0.40418	98.90497	0.00771	HighΔ_LowAlign
	-0.3	0.00268	0.12042	0.00586	0.01571	0.00979	0.57143	0.73335	72.85842	0.00234	LowΔ_HighAlign
	0.3	0.00233	0.10499	0.00380	0.00867	0.00756	0.43902	0.71171	83.72792	0.00149	LowΔ_HighAlign
	0.7	0.00542	0.24390	0.00966	0.02334	0.01845	0.48780	0.41043	107.91625	0.00347	LowΔ_LowAlign
7_8	-0.7	0.01113	0.50107	0.02050	0.05279	0.03949	0.41860	0.56828	30.59611	0.01159	HighΔ_LowAlign
	-0.3	0.00601	0.27058	0.01140	0.02992	0.02208	0.41860	0.84460	32.42632	0.00764	LowΔ_HighAlign
	0.3	0.02618	1.17814	0.08050	0.19583	0.11264	0.45455	0.88351	30.19120	0.07859	HighΔ_HighAlign
	0.7	0.10530	4.73868	0.31958	0.84398	0.46298	0.52273	0.55244	31.12958	0.27613	HighΔ_LowAlign
7_9	-0.7	0.00629	0.28284	0.01543	0.03825	0.02244	0.44186	0.39342	121.37261	0.00279	LowΔ_LowAlign
	-0.3	0.00325	0.14645	0.00619	0.01561	0.01123	0.55814	0.71393	102.59703	0.00188	LowΔ_HighAlign
	0.3	0.02103	0.94614	0.06728	0.15771	0.09059	0.48780	0.71963	106.09586	0.01489	HighΔ_HighAlign
	0.7	0.09526	4.28671	0.30152	0.77486	0.41782	0.56098	0.42807	137.78255	0.04808	HighΔ_LowAlign
8_9	-0.7	0.00788	0.35444	0.02598	0.05619	0.03063	0.28889	0.56041	33.33586	0.02653	LowΔ_LowAlign
	-0.3	0.00197	0.08878	0.00407	0.01057	0.00652	0.31111	0.84669	29.62085	0.00418	LowΔ_HighAlign
	0.3	0.00151	0.06785	0.00257	0.00632	0.00495	0.46341	0.88920	37.02128	0.00214	LowΔ_HighAlign
	0.7	0.00373	0.16793	0.00759	0.01863	0.01271	0.41463	0.56524	38.16226	0.00400	LowΔ_LowAlign

Clusters01-03 Tables

Πίνακας 82: Συγκεντρωτικός πίνακας κορυφαίων συνδυασμών καθοδήγησης (Top combos) ανά Cluster για το Lorenz.

Cluster	guided_group	affected_pair_group	cnt	cluster share (%)	baseline share (%)	enrichment	mean $ \Delta $	sign_follow
C01	Sector-A-Sector-E (mixed)	Sector-B-Sector-E	16	0.8	0.8	1.05	0.002	0.125
C01	Sector-A-Sector-C (mixed)	Sector-B-Sector-D	16	0.8	0.8	1.05	0.001	0.000
C01	Sector-B-Sector-D (mixed)	Sector-A-Sector-C	16	0.8	0.8	1.05	0.000	0.000
C01	Sector-B-Sector-D (mixed)	Sector-A-Sector-D	16	0.8	0.8	1.05	0.034	0.188
C01	Sector-A-Sector-D (mixed)	Sector-D-Sector-E	16	0.8	0.8	1.05	0.023	0.125
C01	Sector-B-Sector-D (mixed)	Sector-A-Sector-E	16	0.8	0.8	1.05	0.001	0.000
C02	Sector-C-Sector-D (mixed)	Sector-C-Sector-E	2	8.3	0.8	10.312	0.294	0.000
C02	Sector-A-Sector-B (mixed)	Sector-A-Sector-E	2	8.3	0.8	10.312	0.212	0.000
C02	Sector-B-Sector-C (mixed)	Sector-C-Sector-E	2	8.3	0.8	10.312	0.336	0.000
C02	Sector-A-Sector-D (mixed)	Sector-A-Sector-E	2	8.3	0.8	10.312	0.191	0.000
C02	Sector-B-Sector-C (mixed)	Sector-B-Sector-C	1	4.2	0.6	6.875	0.337	0.000
C02	Sector-C-Sector-D (mixed)	Sector-C-Sector-D	1	4.2	0.6	6.875	0.302	0.000

C03: δεν δόθηκαν πίνακες Top combos — placeholder για μελλοντική ένταξη.

Κεφάλαιο 8

Bibliography

- [1] Anderson, B. D. O. “Reverse-Time Diffusion Equation Models”. Στο: *Stochastic Processes and their Applications* 12.3 (1982), σσ. 313–326. DOI: 10.1016/0304-4149(82)90051-5.
- [2] Bao, F. κ.ά. “Analytic-DPM: An Analytic Estimate of the Optimal Reverse Variance in Diffusion Probabilistic Models”. Στο: *arXiv preprint arXiv:2201.06503* (2022). eprint:
- [3] Caltrans. *Performance Measurement System (PeMS) Portal*. Accessed 2025-11-05. 2025. URL:
- [4] Chen, T., Zhang, R. και Hinton, G. E. “Analog Bits: Generating Discrete Data using Diffusion Models with Self-Conditioning”. Στο: *arXiv preprint arXiv:2208.04202* (2022). eprint:
- [5] Chen, X. και Collaborators. “Sequential Diffusion Models for Spatiotemporal Forecasting”. Στο: *Preprint* (2023).
- [6] Cuturi, M. *PEMS-SF*. UCI Machine Learning Repository, 2011. DOI: 10.24432/C52G70. URL:
- [7] Dhariwal, P. και Nichol, A. “Diffusion Models Beat GANs on Image Synthesis”. Στο: *Advances in Neural Information Processing Systems (NeurIPS)* (2021).
- [8] Gneiting, T. και Raftery, A. E. “Strictly Proper Scoring Rules, Prediction, and Estimation”. Στο: *Journal of the American Statistical Association* 102.477 (2007), σσ. 359–378. DOI: 10.1198/016214506000001437.
- [9] Gu, A. και Dao, T. “Mamba: Linear-Time Sequence Modeling with Selective State Spaces”. Στο: *arXiv preprint arXiv:2401.09417* (2024).
- [10] Gu, A., Goel, K. και Re, C. “Efficiently Modeling Long Sequences with Structured State Spaces”. Στο: *International Conference on Learning Representations (ICLR)*. 2022.
- [11] Hertz, A. κ.ά. “Prompt-to-Prompt Image Editing with Cross Attention Control”. Στο: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. Originally released as “Plug-and-Play Diffusion Features for Text-to-Image Editing” (arXiv:2208.01626, 2022). 2023. eprint: URL:
- [12] Ho, J., Jain, A. και Abbeel, P. “Denoising Diffusion Probabilistic Models”. Στο: *Advances in Neural Information Processing Systems (NeurIPS)*. 2020, σσ. 6840–6851.
- [13] Ho, J. και Salimans, T. “Classifier-Free Diffusion Guidance”. Στο: *arXiv preprint arXiv:2207.12598* (2022). eprint:
- [14] Ho, J. κ.ά. “Video Diffusion Models”. Στο: *arXiv preprint arXiv:2204.03458* (2022). eprint:
- [15] Hoogeboom, E. κ.ά. “Equivariant Diffusion for Molecule Generation in 3D”. Στο: *arXiv preprint arXiv:2203.17003* (2022). eprint:
- [16] International Telecommunication Union. *Algorithms to measure audio programme loudness and true-peak audio level*. ITU-R, 2023. URL:
- [17] Katharopoulos, A. κ.ά. “Transformers are RNNs: Fast Autoregressive Transformers with Linear Attention”. Στο: *Proceedings of the 37th International Conference on Machine Learning (ICML)*. PMLR, 2020, σσ. 5156–5165. URL:
- [18] Kim, D., Park, J. και Choi, J. “GraphDiff: Diffusion-based Graph Generation with Classifier Guidance”. Στο: *arXiv preprint arXiv:2302.07098* (2023). eprint:

- [19] Kingma, D. P. κ.ά. “Variational Diffusion Models”. Στο: *arXiv preprint arXiv:2107.00630* (2021). eprint:
- [20] Kong, Z. κ.ά. “DiffWave: A Versatile Diffusion Model for Audio Synthesis”. Στο: *arXiv preprint arXiv:2009.09761* (2020). eprint:
- [21] Li, X. L. κ.ά. “Diffusion-LM Improves Controllable Text Generation”. Στο: *arXiv preprint arXiv:2205.14217* (2022). eprint:
- [22] Liu, H. κ.ά. “Unified Multimodal Guidance for Diffusion Models in Time Series”. Στο: *Preprint* (2023).
- [23] Liu, H., Zeng, A. και Xu, Q. “Guided Diffusion for Time Series and Sequential Decision-Making”. Στο: *arXiv preprint arXiv:2305.16314* (2023). eprint:
- [24] Lorenz, E. N. “Predictability: A Problem Partly Solved”. Στο: *Seminar on Predictability*. ECMWF. Reading, UK, 1995. URL:
- [25] Manilow, E. κ.ά. *BabySlakh*. Zenodo, 2019. DOI: 10.5281/zenodo.4603870. URL:
- [26] Manilow, E. κ.ά. “Cutting Music Source Separation Some Slakh: A Dataset to Study the Impact of Training Data Quality and Quantity”. Στο: *IEEE Workshop on Applications of Signal Processing to Audio and Acoustics (WASPAA)*. New Paltz, NY, 2019. URL:
- [27] Nichol, A. και Dhariwal, P. “Improved Denoising Diffusion Probabilistic Models”. Στο: *arXiv preprint arXiv:2102.09672* (2021). eprint:
- [28] Pinson, P. και Tastu, J. “Probabilistic Forecasting of Wind Power Generation Using Quantile Regression”. Στο: *IEEE Transactions on Sustainable Energy* 4.1 (2013), σσ. 42–49. DOI: 10.1109/TSTE.2012.2204918.
- [29] Raffel, C. “Learning-Based Methods for Comparing Sequences, with Applications to Audio-to-MIDI Alignment and Matching”. Διδακτορική διατρ. Columbia University, 2016. DOI: 10.7916/D8N58MHV. URL:
- [30] Ren, Y. και Collaborators. “Physics-Informed Guidance for Diffusion Models”. Στο: *Preprint* (2024).
- [31] Rombach, R. κ.ά. “High-Resolution Image Synthesis with Latent Diffusion Models”. Στο: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2022, σσ. 10684–10695.
- [32] Sohl-Dickstein, J. κ.ά. “Deep Unsupervised Learning using Nonequilibrium Thermodynamics”. Στο: *arXiv preprint arXiv:1503.03585* (2015). eprint:
- [33] Song, J., Meng, C. και Ermon, S. “Denoising Diffusion Implicit Models”. Στο: *arXiv preprint arXiv:2010.02502* (2020). eprint:
- [34] Song, Y. κ.ά. “Score-Based Generative Modeling through Stochastic Differential Equations”. Στο: *arXiv preprint arXiv:2011.13456* (2021). eprint:
- [35] Tashiro, Y. κ.ά. “CSDI: Conditional Score-based Diffusion Models for Imputation”. Στο: *arXiv preprint arXiv:2107.03502* (2021). eprint:
- [36] Trouvain, N. κ.ά. “ReservoirPy: An Efficient and User-Friendly Library to Design Echo State Networks”. Στο: *Artificial Neural Networks and Machine Learning – ICANN 2020*. Springer, 2020, σσ. 494–505. DOI: 10.1007/978-3-030-61616-8_40.
- [37] Vaswani, A. κ.ά. “Attention Is All You Need”. Στο: *Advances in Neural Information Processing Systems (NeurIPS)*. 2017, σσ. 5998–6008. URL:
- [38] Virtanen, P. κ.ά. “SciPy 1.0: fundamental algorithms for scientific computing in Python”. Στο: *Nature Methods* 17.3 (2020), σσ. 261–272. DOI: 10.1038/s41592-019-0686-2.
- [39] Yuan, H. και Qiao, M. “Diffusion Models for Time-Series and Forecasting: A Survey”. Στο: *arXiv preprint arXiv:2310.01111* (2023). eprint:
- [40] Zhang, Y. κ.ά. “TimeLatent: Latent Diffusion Models for Time-Series Generation and Forecasting”. Στο: *Advances in Neural Information Processing Systems (NeurIPS)*. 2024.