

Ανίχνευση Συμβάντων Ακουστικής Εκπομπής σε Μεταλλικές Πύλες Δεξαμενών Ανύψωσης σε Ποτάμια

Θ. Τσένης^{1,*}, Ν. Αγγελόπουλος¹, Β. Καπάτος¹,
¹Ινστιτούτο Βιώσιμης Κινητικότητας & Δικτύων Μεταφορών I.MET.) /
Εθνικό Κέντρο Έρευνας και Τεχνολογικής Ανάπτυξης-ΕΚΕΤΑ
*ttsenis@certh.gr

ΠΕΡΙΛΗΨΗ

Η ανίχνευση συμβάντων ακουστικής εκπομπής από μικρορωγμές αποτελεί κρίσιμο στοιχείο για την παρακολούθηση και την έγκαιρη ανίχνευση δομικών αστοχιών σε υποδομές. Αυτή η μελέτη επικεντρώνεται στην ανίχνευση τέτοιων συμβάντων σε μεταλλικές πύλες δεξαμενών ανύψωσης σε ποταμούς, στο πλαίσιο του ευρωπαϊκού έργου CRISTAL, το οποίο στοχεύει στην αύξηση του όγκου φορτίων μέσω εσωτερικών υδάτινων οδών κατά 20% και στη βελτίωση της αξιοπιστίας κατά 80%. Για τον σκοπό αυτό, αναπτύχθηκε ένα τροποποιημένο νευρωνικό μοντέλο κωδικοποιητή-αποκωδικοποιητή (autoencoder) για την αποθρομβοποίηση των εγγραφών ακουστικής εκπομπής και ανίχνευση μικρορωγμών, χρησιμοποιώντας δεδομένα από πύλες στη Γαλλία και Ιταλία. Το μοντέλο εκπαιδεύτηκε με δεδομένα από κανονική λειτουργία και τεχνητά παραγόμενες ακουστικές εκπομπές μικρορωγμών, με στόχο τη βελτιστοποίηση της ανίχνευσης μικρορωγμών. Δοκιμάστηκαν διάφορες μορφολογίες νευρωνικών δικτύων, συναρτήσεις λάθους και βελτιστοποιητές.

Keywords: ακουστική εκπομπή, νευρωνικά δίκτυο, πιεζοηλεκτρικό αισθητήριο, κωδικοποιητή-αποκωδικοποιητή

Detection of Acoustic Emission Events in Metal Water Lock Gates in Rivers

ABSTRACT

Detection of acoustic emission events from micro-cracks is a critical element for monitoring and early detection of structural failures in infrastructures. This study focuses on detecting such events in metal gates of lifting locks on rivers, within the framework of the European CRISTAL project, which aims to increase cargo volume through inland waterways by 20% and improve reliability by 80%. A modified autoencoder neural network model was developed for denoising acoustic emission recordings and detecting micro-cracks, using data from gates in France and Italy. The model was trained on data from normal operation and artificially generated acoustic emissions, with the goal of optimizing micro-crack detection. Various neural network architectures, loss functions, and optimizers were tested to optimize the model's learning process.

Εισαγωγή

Η παρακολούθηση της ακεραιότητας των υποδομών (Παρακολούθηση Δομικής Ακεραιότητας - ΠΔΑ) αποτελεί κρίσιμο στοιχείο για τη διατήρηση της ακεραιότητας και της αξιοπιστίας τους, ιδιαίτερα σε συστήματα που σχετίζονται τις υδάτινες μεταφορές. Στο πλαίσιο του ευρωπαϊκού έργου CRISTAL, η παρούσα μελέτη επικεντρώνεται στην ανίχνευση συμβάντων μικρορωγμών σε μεταλλικές πύλες δεξαμενών ανύψωσης ποταμών, χρησιμοποιώντας τεχνολογία ακουστικής εκπομπής (acoustic emission - AE) και νευρωνικά δίκτυα. Το έργο CRISTAL, χρηματοδοτείται από την ΕΕ, στοχεύει στην αύξηση του όγκου των φορτίων που μεταφέρονται μέσω εσωτερικών υδάτινων οδών κατά 20% και στη βελτίωση της αξιοπιστίας τους κατά 80%, και μια βασική πτυχή του περιλαμβάνει τη χρήση καινοτόμων τεχνολογιών για την παρακολούθηση και συντήρηση κρίσιμων στοιχείων των υποδομών, όπως οι πύλες των υδατοφραγμάτων, όπως η τεχνολογία ακουστικών εκπομπών (AE), παρακολουθώντας τα ελαστικά κύματα που παράγονται με την απελευθέρωση ενέργειας από ρωγμές ή άλλα συμβάντα αστοχιών¹.

Οι αυτοκωδικοποιητές (autoencoders) έχουν αρχίσει να χρησιμοποιούνται όλο και περισσότερο στον τομέα της επεξεργασίας AE, προσφέροντας έναν ισχυρό τρόπο εξαγωγής χαρακτηριστικών - ανωμαλιών. Η χρήση των αυτοκωδικοποιητών σε αυτόν τον τομέα έχει δείξει ενθαρρυντικά αποτελέσματα, ιδιαίτερα σε εφαρμογές που απαιτούν την αναγνώριση λεπτών μοτίβων σήματος που μπορεί να υποδεικνύουν πρώιμες ζημιές ή αποτυχία υλικού. Για παράδειγμα, μια μελέτη των Wang και Harald [1] χρησιμοποίησε αυτοκωδικοποιητές για την ανίχνευση υποεπιφανειακών βλαβών στα έδρανα αναλύοντας τα σήματα AE. Ο αυτοκωδικοποιητής εκπαιδεύτηκε για να ανασυνθέσει κανονικά μοτίβα σήματος, και οι αποκλίσεις από αυτή την ανασύνθεση θεωρήθηκαν ως πιθανές βλάβες, επιτρέποντας έτσι την έγκαιρη παρέμβαση πριν την καταστροφική αποτυχία.

Μια άλλη εφαρμογή αφορά την ανίχνευση σπηλαίωσης σε υδραυλικά μηχανήματα, Kirschner, O. et al. [2], όπου τα σήματα AE επεξεργάστηκαν σε γραφήματα φάσματος, και χρησιμοποιήθηκαν αυτοκωδικοποιητές για την ανίχνευση ανωμαλιών σε αυτά. Αυτή η προσέγγιση επέτρεψε την αναγνώριση συμβάντων σπηλαίωσης που συχνά είναι δύσκολο να ανιχνευθούν με παραδοσιακές μεθόδους λόγω της παροδικότητας και της χαμηλής ενέργειας τους.

Επιπλέον, η χρήση αυτοκωδικοποιητών με πολλαπλά επίπεδα νευρώνων έχει μελετηθεί, Ebrahimkhanlou, A. et al.[3], για τον εντοπισμό και την κατηγοριοποίηση πηγών AE σε σύνθετα αεροδιαστημικά πάνελ. Αυτή η προσέγγιση αξιοποιεί την ικανότητα μείωσης διαστάσεων των αυτοκωδικοποιητών για την επεξεργασία δεδομένων AE υψηλής διάστασης και τον ακριβή εντοπισμό της πηγής των εκπομπών. Οι μελέτες αυτές, και πολλές άλλες [4-6], υπογραμμίζουν την αποτελεσματικότητα των αυτοκωδικοποιητών στην ενίσχυση της αξιοπιστίας και της ακρίβειας της ανάλυσης σημάτων AE, ενεργώντας ως εργαλεία για την ανίχνευση λεπτών και πολύπλοκων παραλλαγών σημάτων. Στη συνέχεια της παρούσης μελέτης αναπτύσσεται η μεθοδολογία και τα μοντέλα που αναπτύχθηκαν, τα αποτελέσματα και η αξιολόγηση τους μαζί με συμπεράσματα.

¹ <https://www.cristal-project.eu>

1. Μεθοδολογία και Μοντέλα

Η μεθοδολογία που ακολουθήθηκε για την επιθεώρηση μιας μεταλλικής πύλης σε δεξαμενές ανύψωσης ποταμών χρησιμοποιώντας ΑΕ, περιλαμβάνει την εγκατάσταση δικτύου πιεζοηλεκτρικών καταγραφών των ΑΕ που προκαλούνται από πιθανές δομικές ανωμαλίες, όπως μικρορωγμές. Τα καταγεγραμμένα σήματα ΑΕ επεξεργάζονται στη συνέχεια χρησιμοποιώντας έναν εξειδικευμένο αυτοκωδικοποιητή, ο οποίος έχει εκπαιδευτεί να διακρίνει μεταξύ του θορύβου κανονικής λειτουργίας της μεταλλικής πύλης και των συγκεκριμένων ακουστικών σημάτων που σχετίζονται με τις μικρορωγμές. Ο αυτοκωδικοποιητής επιτελεί διπλό ρόλο: αφενός αποθρομβοποιεί τα δεδομένα ΑΕ, και αφετέρου παρέχει μια πρόσθετη έξοδο που δηλώνει εάν τα ανιχνευμένα σήματα μοιάζουν με το πρότυπο που σχετίζεται με τον σχηματισμό μικρορωγμών, όπως αυτά από τα τεστ σπασίματος μύτης μολυβιού ως ένα πολύπλοκο και σύνθετο μοτίβο ΑΕ [7]-[8].

2. Δεδομένα Εκπαίδευσης - Ελέγχου και Υλοποίηση Μοντέλων


Εδώ περιγράφεται η ανάκτηση και η επεξεργασία των σημάτων εισόδου του αυτοκωδικοποιητή αλλά και η δομή του μαζί με όλες τις παραμέτρους του.

2.1 Δεδομένα και Δημιουργία Κυματομορφών

Εκτός από τα πραγματικά δεδομένα από τις δεξαμενές ανύψωσης, για να δοκιμαστούν, κατανοηθούν και αξιολογηθούν οι ικανότητες των αυτοκωδικοποιητών που αναπτύχθηκαν, χρησιμοποιήθηκαν και συνθετικά σήματα μέσω κατάλληλης συνάρτησης, η οποία παράγει διάφορες κυματομορφές, όπως ημιτονοειδή, τετραγωνικά, πριονωτά και τριγωνικά κύματα με διάφορες συχνότητες, τα οποία χρησιμοποιήθηκαν στις πρώιμες εκπαιδευσεις για καλύτερη κατανόηση των δυνατοτήτων του μοντέλου και των συσχετιζόμενων παραμέτρων του.

2.2 Μοντέλο Αυτοκωδικοποιητή

Το μοντέλο νευρωνικού δικτύου που αναπτύχθηκε αποτελείται από έναν κωδικοποιητή (encoder) και έναν αποκωδικοποιητή (decoder). Ο κωδικοποιητής περιλαμβάνει συνελκτικά και πυκνά επίπεδα που φιλτράρουν και μετατρέπουν τα εισαγόμενα σήματα σε έναν λανθάνοντα χώρο, ενώ ο αποκωδικοποιητής αναδομεί τη λανθάνουσα αναπαράσταση σε σήμα. Επιπλέον, ο αποκωδικοποιητής διαθέτει μια πρόσθετη έξοδο που προσδιορίζει εάν το σήμα εισόδου περιέχει κάποιο (συνθετικό) μοτίβο μικρορωγμής, όπως το Pencil Lead Breaks (PLB).



Σχήμα 2.1 Διάταξη Αυτοκωδικοποιητή

Πίνακας 2.1: Παράμετροι Κωδικοποιητή (Encoder)

| Στρώμα | Τύπος | Ενεργοποίηση | Dropout | Μέγεθος Εξόδου |
|---------|---------------|--------------|---------|----------------|
| Conv1 | Convolutional | ReLU | 0.5 | (N, 64, 4096) |
| Conv2 | Convolutional | ReLU | 0.5 | (N, 32, 4096) |
| Conv3 | Convolutional | ReLU | 0.5 | (N, 16, 4096) |
| Flatten | Dense | Linear | - | (N, 65535) |
| Dense | Dense | ReLU | - | (N, 4096) |


2.3 Επιπλέον Παράμετροι του Μοντέλου

Στην παρούσα μελέτη, εξετάστηκαν διάφορες παραλλαγές του μοντέλου με βάση τις ακόλουθες παραμέτρους (Πίνακα 2.1.):


1. *Αριθμός Επιπέδων*: Εξετάστηκαν μοντέλα με 1, 2 και 3 επίπεδα νευρώνων.
2. *Συνελκτικά Επίπεδα*: Εξετάστηκαν μοντέλα με και χωρίς συνελκτικά επίπεδα (convolutional layers).
3. *Συνάρτηση Απώλειας*: Εξετάστηκαν διάφορες συναρτήσεις απώλειας όπως το 'MSE (Mean Squared Error)', 'HuberLoss', και 'L1Loss'.
4. *Βελτιστοποιητές*: Δοκιμάστηκαν διάφοροι βελτιστοποιητές όπως οι 'Adam', 'RMSprop', 'Adamax', και 'SGD' για τη βελτιστοποίηση της εκμάθησης του μοντέλου.
5. *Κανονικοποίηση L2*: Η κανονικοποίηση L2 (L2 Regularization) εξετάστηκε με τιμές 0.0 και $1e-5$.
6. *Μέγεθος Λανθάνοντος Χώρου*: Το μέγεθος του λανθάνοντος χώρου (latent space) δοκιμάστηκε σε τιμές 4, 10, 128, 512, 1024, 2048, και 4096.
7. *Συνάρτησης Ενεργοποίησης ReLU – SiLU*: Καθορίζει τη χρήση της συνάρτησης ενεργοποίησης ReLU, με εναλλακτική τη χρήση της συνάρτησης SiLU.

3. Αποτελέσματα και Συζήτηση

Τα αποτελέσματα, σχήμα 3.1 και 3.2 δείχνουν ότι το μοντέλο μπορεί να ανιχνεύσει με ακρίβεια μικρορωγμές. Πιο συγκεκριμένα:



Σχήμα 3.1 Αξιολόγηση παραμέτρων ως προς το ολικό λάθος εκπαίδευσης



Σχήμα 3.2 Αριστερά σήμα εισόδου (με μοτίβο μικρορωγμής), στη μέση η έξοδος εκπαίδευσης μαζί με τεχνητό θόρυβο 5% και τη σήμανση ότι είναι μικρορωγμή (microcrack:1.0). Δεξιά η έξοδος με πρόβλεψη μικρορωγμής 0.9999771 και cosine similarity:0.999998 και SSIM(Structural Similarity Index Measure):0.999711

- Η MSELoss υπερέρχει σταθερά έναντι της L1Loss όσον αφορά το γενικό λάθος. Η MSELoss παρουσιάζει πιο ομαλή εκπαίδευση, χαμηλότερες τιμές απώλειας και πιο σταθερή σύγκλιση, ειδικά με συνελκτικές αρχιτεκτονικές.
- Για την MSELoss και την L1Loss, οι συνελκτικές αρχιτεκτονικές τείνουν να αποδίδουν καλύτερα ή τουλάχιστον ισάξια με τα μη συνελκτικά μοντέλα.
- Με τους βελτιστοποιητές Adam ή AdamW, η συμπεριφορά σύγκλισης είναι γενικά πιο σταθερή όταν χρησιμοποιούνται συνελκτικές αρχιτεκτονικές.
- Με 1 επίπεδο, το γενικό λάθος τείνει να είναι χαμηλότερο για αρχιτεκτονικές με ένα επίπεδο, ιδιαίτερα όταν συνδυάζονται με συνελκτικά μοντέλα. Με 2 Επίπεδα, το γενικό λάθος τείνει να είναι ελαφρώς υψηλότερη, ειδικά για μεγαλύτερα μεγέθη λανθάνουσας μεταβλητής και όταν χρησιμοποιείται η L1Loss.
- Λανθάνων μέγεθος: 4...512, το γενικό λάθος είναι συνήθως χαμηλό, ιδιαίτερα όταν συνδυάζεται με συνελκτικές αρχιτεκτονικές και τη χρήση των Adam ή AdamW.

4. Συμπεράσματα και Μελλοντική Εργασία

Αυτή η εργασία ανέπτυξε μια πρωτότυπη μεθοδολογία για την ανίχνευση μικρορωγμών σε μεγάλες μεταλλικές κατασκευές (όπως οι μεταλλικές πύλες ανύψωσης ποταμών). Καταγράφοντας την ΑΕ κανονικής λειτουργίας και εντέχνως εισάγοντας μέσα στο σήμα αυτό την ΑΕ μικρορωγμών είτε με μεθόδους προσομοίωσης εφαρμοζόμενες επί της κατασκευής (τεχνικές PLB [7]-[8]), είτε παραγόμενες εργαστηριακά (tensile testing machine), την ανίχνευση στο ίδιο το αυτούσιο σήμα ΑΕ της κατασκευής την απευθείας ανίχνευση μοτίβων μικρορωγμών, με τη χρήση ειδικά τροποποιημένων αυτοκωδικοποιητών. Με το τρόπο αυτό απλώς επιλέγουμε τα σημεία ενδιαφέροντος στην κατασκευή υπό επιτήρησή (κρίσιμα σημεία στατικής επάρκειας της), και στη συνέχεια εκπαιδεύεται το νευρωνικό ανίχνευσης (με επιτηρούμενη εκπαίδευση) για έκαστο τέτοιο σημείο, με τη χρήση είτε συνθετικών σημάτων ΑΕ για μικρορωγμές είτε με εργαστηριακή παραγωγή τους, με χρήση κατάλληλων μεταλλικών δοκιμίων κάτω από εργαστηριακή ελαστική και πλαστική παραμόρφωση [9]. Τα επόμενα βήματα είναι να εφαρμοστεί η μεθοδολογία σε διάφορες μεγάλες μέταλλο-κατασκευές.

5. Ευχαριστίες – Acknowledgements

This publication has been produced within the project CRISTAL (Critical Infrastructure Simulation of the Multi-Order Interconnected Layers). This project has received funding from European Union's Horizon 2020 research and innovation program under grant agreement No 101021746.

6. Αναφορές

- [1] Y. Wang, R. H. Hestmo, and A. Vinogradov «Early sub-surface fault detection in rolling element bearing using acoustic emission signal based on a hybrid parameter of energy entropy and deep autoencoder» *Measurement Science and Technology*, 34(6), 064008 (2023)
- [2] O. Kirschner, and S. Riedelbauch «Cavitation detection in hydraulic machinery by analyzing acoustic emissions under strong domain shifts using neural networks» *Physics of Fluids*, 35(2) (2023)
- [3] A. Ebrahimkhanlou, M. B. Schneider, B. Dubuc, and S. Salamone «A deep learning framework for acoustic emission sources localization and characterization in complex aerospace» *Materials evaluation*, 79(4), 391-400 (2021)
- [4] H. Yun, H. Kim, Y. H. Jeong, and M. B. Jun «Autoencoder-based anomaly detection of industrial robot arm using stethoscope based internal sound sensor» *Journal of Intelligent Manufacturing*, 34(3), 1427-1444 (2023)
- [5] G. W. Lee, S. Livadiotis, and S. Salamone «Applicability of Data Augmentation Through Variational Autoencoder for Two-Dimensional Acoustic Emission Source Discrimination on Hollow Cylindrical Structures» *STRUCTURAL HEALTH MONITORING* (2023)
- [6] B. Chalançon, A. Roda-Buch, E. Cornet, G. Rapp, T. Weisser, and L. Brambilla «Acoustic emission monitoring as a non-invasive tool to assist the conservator in the reactivation and maintenance of historical vehicle engines» *Studies in Conservation*, 69(2), 102-112 (2024)
- [7] F. Falcetelli, M. B. Romero, and S. Pant «Modelling of pencil-lead break acoustic emission sources using the time reversal technique» *AMS Laurea* (2018)
- [8] G. R. Kirikera, V. Shinde, M. J. Schulz, A. Ghoshal, M. Sundaresan and R. Allemang «Damage localisation in composite and metallic structures using a structural neural system and simulated acoustic emissions» *Mechanical Systems and Signal Processing*, 21(1), 280-297 (2007)
- [9] A. C. E. Sinclair, D. C. Connors, and C. L. Formby «Acoustic emission analysis during fatigue crack growth in steel» *Materials Science and Engineering*, 28(2), 263-273 (1977)