

Distributed Fiber Optic Acoustic Sensing - Scope and Machine Learning Based Data Modeling Techniques - an Overview

"Verteilte faseroptische Akustiksensoren - Anwendungsbereich und auf maschinellem Lernen basierende Datenmodellierungstechniken - ein Überblick"

Authors Names: Dimitre Trendafilov,
FDIBA, Technical University of Sofia

Abstract — Real-time monitoring of different assets and processes with distributed fiber optic sensing (DAS) has the potential to play a major role in many civil and industrial applications. While the measurement technology itself is well understood and developed, a key remaining challenge is the establishment of robust data analysis tools that are capable of providing real-time conversion of enormous data quantities into actionable process indicators.

This paper provides a comprehensive technical review of the data analysis techniques for distributed fiber optic technologies. The review encompasses classical methods, such as the speed of sound estimation and Joule-Thomson coefficient, as well as their data-driven machine learning counterparts, such as Convolutional Neural Network (CNN), Support Vector Machine (SVM), and Ensemble Kalman Filter (EnKF) algorithms. The study aims to help end-users establish reliable, robust, and accurate solutions that can be deployed in a timely and effective way, and pave the way for future developments in the field.

Zusammenfassung — Die Echtzeitüberwachung verschiedener Anlagen und Prozesse mit verteilter faseroptischer Sensorik (DAS) hat das Potenzial, in vielen zivilen und industriellen Anwendungen eine wichtige Rolle zu spielen. Während die Messtechnik selbst gut verstanden und entwickelt ist, besteht eine der größten Herausforderungen darin, robuste Datenanalysewerkzeuge zu entwickeln, die in der Lage sind, enorme Datenmengen in Echtzeit in umsetzbare Prozessindikatoren umzuwandeln.

Dieses Papier bietet einen umfassenden technischen Überblick über die Datenanalysetechniken für verteilte faseroptische Technologien. Der Überblick umfasst sowohl klassische Methoden wie die Schätzung der Schallgeschwindigkeit und des Joule-Thomson-Koeffizienten als auch ihre datengesteuerten Gegenstücke aus dem maschinellen Lernen wie Convolutional Neural Network (CNN), Support Vector Machine (SVM) und Ensemble Kalman Filter (EnKF) Algorithmen. Die Studie soll Endnutzern helfen, zuverlässige, robuste und genaue Lösungen zu entwickeln, die zeitnah und effektiv eingesetzt werden können, und den Weg für künftige Entwicklungen in diesem Bereich ebnen.

I. VORSTELLUNG DER TECHNOLOGIE

Verteilte faseroptische Sensoren gewinnen zunehmend an Aufmerksamkeit. Sie bestehen aus einer passiven optischen Faser und einer Abfrageeinheit, die am Ende der Faser platziert wird (siehe Abbildung 1). Diese Systeme sind in der Lage, Parameter an jeder Stelle des installierten Glasfaserkabels zu messen. Sie wurden zur verteilten Messung von Temperatur, Dehnung, akustischen und sogar chemischen Parametern wie Feuchtigkeit und dem Vorhandensein von Öl entwickelt. Die Sensoren arbeiten durch das Senden von Laserlichtimpulsen mit dem Interrogator durch die Faser. Wenn sich Lichtimpulse in der Glasfaser ausbreiten, interagieren sie auf unterschiedliche Weise und erzeugen drei Arten von Streulicht, das zurück zum Abfragesystem reflektiert wird. Diese Arten werden als Rayleigh-, Raman- und Brillouin-Streuung bezeichnet. Jede Art der Rückstreuung kann anhand ihrer Frequenz charakterisiert werden und wird von unterschiedlichen physikalischen Parametern beeinflusst. Diese bilden die Grundlage für verschiedene verteilte Sensoren wie den verteilten Temperatur-

sensor (Distributed Temperature Sensor, DTS) und den verteilten akustischen Sensor (Distributed Acoustic Sensor, DAS).




Abb. 1.

Abb. 1. Der verteilte akustische Sensor überträgt Lichtimpulse, die sich innerhalb des Faserkabels bewegen und an die Abfrageeinheit zurückgestreut werden, die das akustische Signalprofil entlang des Kabels aufzeichnet.

Physikalisch gesehen ist ein verteilter faseroptischer Sensor ein passives Kabel, das orts aufgelöste Messungen durchführen kann, ähnlich wie ein dicht verteiltes Netzwerk von Punktsensoren. Als Überwachungs- und Kontrollinfrastruktur bietet diese Technologie eine Reihe von Vorteilen:

- es ist weniger schwierig zu installieren als eine große Anzahl von Sensoren
- es arbeitet im passiven Modus, was die Nutzung der Stromquelle reduziert, und ist einfach zu warten, da die meisten komplexen Elemente des Systems leicht zugänglich sind
- es kann in der rauen Umgebung mit hohem Druck und Temperatur mit ausreichenden Beschichtungsmaterialien arbeiten.
- Je nach Einsatzfeld kann die DAS-Technologie auch kostensparend sein

Es ist wichtig zu betonen, dass die DAS-Daten bei Messungen an einem beliebigen Standort ein niedriges Signal-Rausch-Verhältnis (SNR) im Vergleich zu ihren Array-Punkt-Sensor-Pendants haben. Eine der Stärken der DAS gegenüber den punktuellen Sensoren ist ihre Fähigkeit, Daten kontinuierlich entlang des Kabels zu liefern. Diese Eigenschaft, zusammen mit der Fähigkeit, Messungen mit hoher zeitlicher Frequenz durchzuführen, weist auf hohe Datenraten hin. Diese Datenrate ist letztlich nur durch die Zeit begrenzt, die die Rückstreuung jedes Impulses benötigt, um die Faser zu verlassen, bevor der nächste Impuls eingeleitet werden kann. Dies wiederum unterstreicht die Bedeutung von leistungsfähigen und effizienter Datenverarbeitungsalgorithmen.

II. ANWENDUNGEN DER DAS TECHNOLOGIE

A. Pipeline- und Perimeter Sicherheit

DAS wird für die Überwachung und Sicherung kritischer Infrastrukturen wie Pipelines und Perimeter eingesetzt. Es kann Aktivitäten wie Grabungen, Anzapfungen oder andere physische Störungen entlang des Kabels erkennen und lokalisieren.

B. Öl- und Gasindustrie

DAS kann eingesetzt werden, um Öl- und Gasbohrungen auf mögliche Lecks, Eindringlinge oder andere Anomalien zu überwachen. Dadurch wird die Sicherheit dieser Anlagen erhöht.

C. Überwachung von Infrastrukturen

DAS kann in zivilen Infrastrukturen wie Brücken, Tunneln und Eisenbahnen eingesetzt werden, um strukturelle Veränderungen, Vibrationen oder andere potenzielle Probleme zu erkennen und zu lokalisieren.

D. Grenzüberwachung

Grenzsicherheitsbehörden verwenden DAS, um lange Grenzen auf unbefugte Aktivitäten, wie z. B. die Bewegung von Personen oder Fahrzeugen, zu überwachen.

E. Seismische Überwachung

DAS wird in der Seismologie zur Überwachung von Bodenvibrationen und seismischen Aktivitäten eingesetzt. Es bietet

eine kostengünstige Lösung für die verteilte seismische Überwachung.

F. Intelligente Städte:

DAS kann in Smart-City-Initiativen integriert werden, um verschiedene Parameter wie Verkehrsfluss, Personendichte und Umweltbedingungen zu überwachen.

III. MACHINE LEARNING GESTÜTZTE DATENVERARBEITUNG

Das Aufkommen von Methoden des maschinellen Lernens in DFOS basiert auf mehrere wichtigen Faktoren. Erstens ermöglichen moderne DFOS-Systeme eine kontinuierliche Überwachung über große Entfernungen und erzeugen riesige Datenmengen, die schwierig und zeitaufwendig analysiert werden.

Die Entwicklung von leistungsstarken Grafikprozessoren (GPUs) ist in diesem Feld unumgänglich. Diese Einheiten bieten eine schnelle und fortgeschrittene maschinelle Lernanalyse.

Dank des Einsatzes des maschinellen Lernens, das zur Verarbeitung großer Datenmengen eingesetzt wird, werden Ereignisse oder Schäden erkannt und klassifiziert.

Darüber hinaus wurde maschinelles Lernen auch für DFOS zur Überwachung von Gleisen und Zügen und zur Erkennung von Mustern und Anomalien vorgeschlagen, die auf potenzielle Gefahren hinweisen könnten.

Neben der Zustandsüberwachung von Infrastrukturen wurden auch tiefe neuronale Netze auch zur genauen Erkennung von Erdbeben aus den von DAS gesammelten Daten vorgeschlagen.

Zusätzlich zu diesen spezifischen Anwendungen hat das maschinelle Lernen auch erhebliche Fortschritte in DAS-Systemen, die unabhängig von der Anwendung sind. Zum Beispiel wurden maschinelle Lernalgorithmen verwendet, um Signale schneller zu entschlüsseln – eine Alternative zu herkömmlichen Algorithmen zur Rauschunterdrückung.

Das maschinelle Lernen wurde beispielsweise bei Brillouin-DFOS in verschiedenen Phasen der Signalverarbeitung eingesetzt. Insbesondere wurden Algorithmen des maschinellen Lernens eingesetzt, um die Messgenauigkeit zu verbessern und die Signalverarbeitungszeit zu verkürzen.




Fig. 2. Anwendung des DAS Fehlfahrens in Bezug auf Bahntransport Sicherheit. Copyright: www.sensonic.com

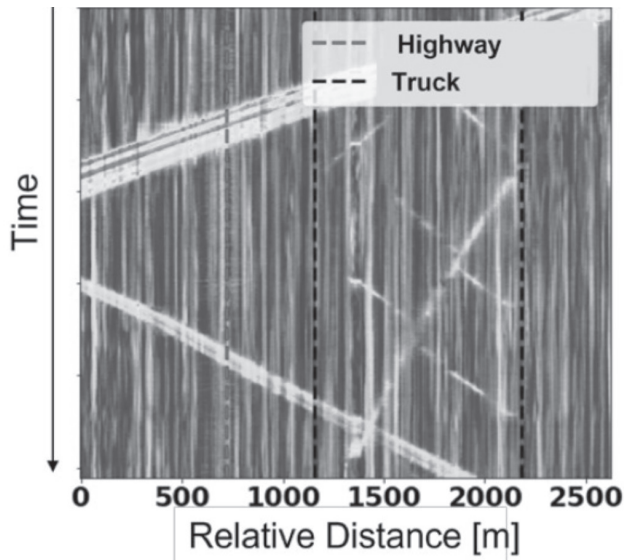


Fig. 3 Signatur von Zügen und Umweltgeräuschen

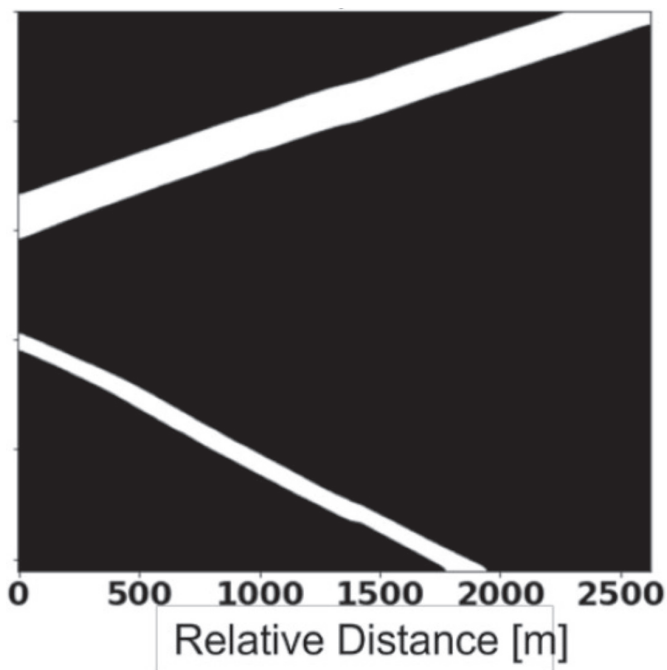


Fig.4 Signatur des neuronalen Netzes

IV. SCHLUSSFOLGERUNG

Die Algorithmen des maschinellen Lernens, insbesondere die NN-basierten Algorithmen, haben die Fähigkeit nützliche Merkmale aus riesigen Datenmengen durch DAS zu extrahieren und gleichzeitig eine hohe Genauigkeit Vorhersagen und können somit den Datenmodellierungsprozess vereinfachen. Trotz ihrer potenziellen Effektivität für bestimmte Anwendungen kann ihre Blackbox-Natur Herausforderungen mit sich bringen, wenn es darum geht, das Vertrauen der Interessengruppen zu gewinnen. Diese Herausforderung ist weniger groß bei konventionellen Ansätzen, die sich auf physikalische Strömungsmodelle stützen, die auf wissenschaftlich nachgewiesenen Phänomenen durch Experimente beruhen.

Die Kombination dieser beiden Ansätze wird in diesem Bereich der Sensortechnik erheblich voranbringen und hochgenaue Messungen mit erklärbaren Ergebnissen liefern.

[1] Rosenberger, M.; Hall, A.: Distributed Acoustic Sensing als Basistechnologie fuer Anwendungen im Bahnbereich. SIGNAL+DRAHT (108) 9/2016, pp. 73–84

[2] Rosenberger, M.; Lancaster, G.: Echtzeit-Gleisueberwachung für nachhaltige Instandhaltungsstrategien. ETR Mai 2017, pp. 37-41

[3] Rosenberger, M.; Lancaster, G.: Distributed Acoustic Sensing (DAS) im Bahnbereich: Umsetzung einer Vision. SIGNAL+DRAHT(110) 7+8/2018, pp. 47-57

[4] Rosenberger, M.: How Distributed Acoustic Sensing supports condition based maintenance strategies. ETR International Edition 2/2018, pp. 28-31