


The Elephant in the Room: Towards A Reliable Time-Series Anomaly Detection Benchmark

- **Hintergrund:** Anomalie-Erkennung in Zeitseriendaten
- **Model:** TSB-AD
- **Evaluations-Modell:** VUS-PR
- **Probleme:**
 - + fehlerhafte Datensätze, fehlerhaftes oder inkonsistentes Labeling
 - + Bewertungen haben einen Bias, durch Klasseninbalance
 - + Inkonsistentes Benchmarking



- **Datensatz:**
 - 1070 Hoch-qualitative Zeitserien aus sehr diversen Datensatzsammlung
 - Sammlung von 40 Datensätzen
 - 13 univariate und 20 multivariat Datensätze zur Anomalie-Erkennung
 - multivariate Zeitreihen wurden in univariate Formate umgewandelt, indem jeder Kanal als eigenständige Zeitreihe betrachtet wird
- **Umsetzung:**
 - Implementierung von 40 statistischen Algorithmen zur Detektion der Anomalien
 - Mit Hyperparameter-Tuning
 - Einheitliches Setup für einen reproduzierbaren und fairen Vergleich
 - Binäre Klassifizierung der Datenpunkte: *Normal* und *Abnormal*
- **Evaluation**
 - VUS-PR (Volume Under Surface of Precision-Recall) ist die zuverlässigste und genaueste Metrik für die Anomalie-erkennung in Zeitreihen
 - Evaluation von über 40 Anomalie-erkennungsalgorithmen
- **Ergebnisse:**
 - Stellen gängige Meinung über die Überlegenheit fortschrittlicher neuronaler Netzwerkarchitekturen in Frage
 - Zeigen, dass einfachere Architekturen und statistische Methoden oft eine bessere Leistung erbringen als komplexe neuronale Netzwerke

- Allerdings könnten neuronale Netze gute Ergebnisse bei multivariaten Zeitreihen liefern
- VUS-PR zeigte im Vergleich zu anderen Maßnahmen erhebliche Robustheit gegenüber Verzögerungen
- Die Top 12 Methoden bestehen überwiegend aus statistischen Ansätzen
- In TSB-AD-M zeigen neuronale Netzwerkmethoden wie CNN und OmniAnomaly bessere Ergebnisse, aber auch statistische Methoden bleiben in multivariaten Fällen sehr effektiv
- Foundation-Model-basierte Ansätze starke Leistung bei der Erkennung von Punktanomalien zeigen
- **Einfluss von IoT-Technologien**
 - hat die Menge an sequentiellen Messungen drastisch erhöht
 - wesentliche Grundlage für viele Aufgaben in der Analyse
 - Zentrale Aufgaben u.a. Zeitreihenanalyse
- **Bemerkungen:**
 - Ausführliche Erklärungen, sowie Datensätze und implementierte Algorithmen im Git
 - Paper erklärt auch viel zum Hintergrund
 - Komplette Implementierung eventuell zu umfangreich, aber Vergleich mit eigenem Neuronalem Netz möglich
- **Allgemeine Probleme**
 - Missing Labels bzw. Inkonsistente Labelings
 - Bias im Datensatz (Anomalien treten überwiegend gegen Ende einer Zeitreihe auf)
 - Ungleichgewichten im Datensatz zw. Normalen und Abnormalen Datenpunkten
- **Algorithmen:**
 - Statistische Methoden: Fokus auf klassische Ansätze, die auf mathematischen Modellen basieren, um Anomalien durch Abweichungen von erwarteten Mustern zu identifizieren.
 - Neuronale Netzwerk-basierte Methoden: Diese Methoden lernen typische Muster in historischen Trainingsdaten, die keine Anomalien enthalten. Abweichungen in neuen Testdaten werden als potenzielle Anomalien erkannt.
 - Foundation-Model-basierte Methoden: Diese Modelle zeichnen sich durch beeindruckende Few- Shot- und Zero-Shot-Fähigkeiten aus. Hier kann man LLMs adaptieren wie z.B. OFA Modell oder MOMENT (Modell für Zeitreihen)