

ABSTRACT

Electroencephalography (EEG) is a powerful neuroimaging technique widely used across various applications. Despite its advantages of non-invasiveness, portability, and high temporal resolution, EEG analysis remains challenging due to its complexity, high dimensionality, and low signal-to-noise ratio. Deep Learning (DL) models have shown significant potential in addressing these challenges by automatically extracting meaningful features from raw EEG signals and achieving high classification accuracy. However, most existing DL models are task-specific, and their generalizability across diverse EEG datasets and domains remains an open question.

This thesis investigates the feasibility of constructing a small yet representative subset of EEG datasets that encapsulates the diversity of a broader dataset collection. Such a subset would support the development and evaluation of generalizable DL models that perform robustly across various EEG classification tasks without requiring domain-specific adjustments, while also significantly reducing computational costs. Additionally, the thesis explores the generalizability and compatibility of state-of-the-art end-to-end DL models across multiple EEG datasets spanning different domains.

11 end-to-end DL models were trained and tested across 17 EEG datasets. A principled approach to subset selection was proposed, combining Ridge regression with correlation analysis to predict the median F_1 -score of models based on the selected subset. The final subset should minimize prediction error while ensuring diversity and avoiding redundancy.

The findings indicate that none of the selected DL models demonstrated outstanding generalizability across all EEG datasets, reflecting limitations in their ability to adapt to diverse domains. The representative subset, comprising SEED, DREAMER-Valence, DREAMER-Arousal, EEGMAT, and CHB-MIT datasets, demonstrated a low prediction error and weak pairwise correlations, highlighting its diversity. This work provides a foundational framework for advancing generalizable DL models for EEG classification tasks.

Keywords: Electroencephalography (EEG), Deep Learning (DL), generalizability, EEG datasets, task-specific models, subset selection, representativeness, Ridge regression, correlation analysis, classification accuracy, diversity, computational efficiency, end-to-end deep learning models, compatibility, median F_1 -score.

ZUSAMMENFASSUNG

Elektroenzephalographie (EEG) ist eine leistungsstarke Neuroimaging-Technik, die in vielen Anwendungen eingesetzt wird. Trotz ihrer Vorteile, wie Nichtinvasivität, Portabilität und hoher zeitlicher Auflösung, bleibt die Analyse von EEG-Daten aufgrund ihrer Komplexität, hohen Dimensionalität und des niedrigen Signal-Rausch-Verhältnisses herausfordernd. Deep-Learning-Modelle (DL) haben großes Potenzial gezeigt, diese Herausforderungen zu bewältigen, indem sie aussagekräftige Merkmale aus EEG-Daten extrahieren und hohe Klassifikationsgenauigkeiten erzielen. Dennoch sind die meisten DL-Modelle auf spezifische Aufgaben beschränkt, und ihre Generalisierbarkeit über verschiedene EEG-Datensätze und Domänen bleibt fraglich.

Diese Masterarbeit untersucht die Konstruktion eines kleinen, repräsentativen Subsets von EEG-Datensätzen, das die Diversität einer größeren Sammlung abbildet. Dieses Subset soll die Entwicklung generalisierbarer DL-Modelle fördern, die robust über verschiedene EEG-Klassifikationsaufgaben hinweg performen, ohne domänenspezifische Anpassungen zu benötigen, und gleichzeitig Rechenkosten reduzieren. Zudem wird die Generalisierbarkeit und Kompatibilität state-of-the-art End-to-End-DL-Modelle über verschiedene EEG-Domänen hinweg analysiert.

11 End-to-End-DL-Modelle wurden auf 17 EEG-Datensätzen trainiert und getestet. Ein systematischer Ansatz zur Auswahl eines Subsets wurde entwickelt, der Ridge-Regression mit Korrelationsanalysen kombiniert, um den Median- F_1 -Score der Modelle basierend auf dem Subset vorherzusagen. Das finale Subset minimiert die Vorhersagefehler, gewährleistet Diversität und vermeidet Redundanz.

Die Ergebnisse zeigen, dass kein DL-Modell herausragende Generalisierbarkeit über alle EEG-Datensätze aufwies, was ihre begrenzte Anpassungsfähigkeit an verschiedene Domänen verdeutlicht. Das ausgewählte Subset, bestehend aus SEED, DREAMER-Valence, DREAMER-Arousal, EEGMAT und CHBMIT, zeigte geringe Vorhersageabweichungen und schwache Korrelationen, was seine Diversität unterstreicht. Diese Arbeit bietet einen Rahmen für die Entwicklung generalisierbarer DL-Modelle für EEG-Klassifikationsaufgaben.

Schlüsselwörter: Elektroenzephalographie (EEG), Deep Learning (DL), Generalisierbarkeit, EEG-Datensätze, aufgabenspezifische Modelle, Subset-Auswahl, Repräsentativität, Ridge-Regression, Korrelationsanalyse, Klassifikationsgenauigkeit, Diversität, Recheneffizienz, Kompatibilität, End-to-End-Deep-Learning-Modelle, Median- F_1 -Score.