

Zastosowanie uczenia maszynowego do analizy nieliniowych systemów dynamicznych z klasyfikacją chaotycznych i periodycznych szeregów czasowych

Streszczenie

Przedmiotem niniejszej pracy jest zastosowanie technik uczenia maszynowego do identyfikacji szeregów czasowych o charakterze chaotycznym i okresowym, a także rekonstrukcja dwuparametrowych diagramów bifurkacyjnych pochodzących z nieliniowych układów dynamicznych. Choć taką klasyfikację można początkowo traktować jako problem binarny, wrażliwość na warunki początkowe i zmiany parametrów powodują zjawisko *concept drift*, co stanowi istotne wyzwanie dla tradycyjnych metod uczenia maszynowego z nadzorem. Aby stawić czoła tym problemom, opracowano i porównano różnorodne modele uczenia maszynowego z uznanymi technikami nienależącymi do nurtu uczenia maszynowego.

Praca rozpoczyna się od przedstawienia podstawowych pojęć z zakresu układów dynamicznych i teorii chaosu, a także zawiera przegląd istniejących metod numerycznych służących do analizy i klasyfikacji systemów dynamicznych. Wykorzystując model łuku elektrycznego Pentegova-Sydoretsa jako zbiór danych wyjściowych, zastosowano różne metody uczenia maszynowego z nadzorem, takie jak perceptrony wielowarstwowe, głębokie sieci neuronowe, lasy szeregów czasowych oraz algorytm k-najbliższych sąsiadów. W celu poprawy uogólniania modeli i zniwelowania wpływu *concept drift* wprowadzono metody dekompozycji sygnału, które zwiększyły odporność sieci neuronowych.

W dalszej części badań skupiono się na metodach bez nadzoru i z częściowym nadzorem, takich jak modele mieszanin gaussowskich czy algorytm klastrowy k-średnich, aby zmniejszyć zależność od dużych, etykietowanych zbiorów danych. Metody te wykazały poprawę skuteczności w trudnych scenariuszach klasyfikacyjnych. Ponadto zbadano techniki samonadzorowanego uczenia, w tym SimCLR, VICReg i SimSiam. Dokonano też analizy nowych metod, tj. modułu Temporal Contrastive, rozszerzając jego implementację na niekontrastowe metody uczenia samonadzorowanego. Przedstawiono również autorską metodę Confidence Semi-Supervised Retraining wnoszącą znaczący wkład w rozwój metod uczenia samonadzorowanego. Jej zastosowania wykraczają poza klasyfikację sygnałów i szeregów czasowych, obejmując m.in. wizję komputerową czy przetwarzanie języka naturalnego.

Praca kończy się podsumowaniem kluczowych wyników i wskazaniem możliwych kierunków dalszych badań. Zaprezentowane strategie potwierdzają potencjał integracji zaawansowanych modeli uczenia maszynowego w analizie nieliniowych układów dynamicznych.