


Wykorzystanie techniki generatywnej sieci przeciwstawnej (GAN) do zwiększenia dokładności predykcji dla mikroskopii interferencyjnej z uśrednianiem w czasie

W. Forjasz^{1,†}, M. Cywińska¹


¹Politechnika Warszawska, Instytut Mikromechaniki i Fotoniki, ul. św. A. Boboli 8, 02-525 Warszawa, Polska

†email: wiktforjasz.stud@pw.edu.pl

Zastosowanie sieci neuronowych pozwala na precyzyjne rozwiązywanie złożonych problemów, w których analityczne określenie problemu odwrotnego może być skomplikowane lub niemożliwe. Z tego względu, zaobserwować można dynamiczny rozwój sieci neuronowych wraz z ich coraz szerszą aplikacją w różnych dziedzinach. W obszarze metrologii optycznej, konwolucyjne sieci neuronowe świetnie nadają się do rozwiązywania zagadnień związanych z analizą obrazów interferencyjnych. Przykładem, nad którym skupiamy się w ramach niniejszej pracy jest problem wyznaczenia rozkładu amplitudy drgań obiektu, zakodowanej w modulacji amplitudy obrazów interferencyjnych rejestrowanych techniką z uśrednianiem w czasie (ang. Temporal Averaging Interferometry, TAI) [1]. W technice TAI amplituda rejestrowanych interferogramów opisana jest funkcją Bessela, przez co klasyczne algorytmy, takie jak, metoda czasowej dyskretnej zmiany fazy (ang. temporal phase shifting, TPS) [2], czy jednoramkowa metoda spieralnej transformacji Hilberta (HST) [3], dopasowane do cosinusoidalnych zmian fazy, będą generować błędy. W przypadku uczenia głębokiego kluczowym aspektem poza odpowiednio zaprojektowaną architekturą sieci CNN oraz dobrze przygotowanym zbiorem treningowym, jest dobór metody nadzorowania uczenia. W przeprowadzonym badaniu porównano możliwości predykcyjne architektury sieci neuronowej DeepBessel [4] trenowanej standardową metodą uczenia nadzorowanego z techniką generatywnej sieci przeciwstawnej (ang. Generative Adversarial Network, GAN) [5]. Polega ona na koncepcji wykorzystania w procesie treningowym dwóch współpracujących sieci. Pierwsza generuje rozwiązanie dopasowane do konkretnego problemu (sieć generatora - w naszym przypadku jest to sieć DeepBessel). Druga sieć ma za zadanie rozróżniać wartości wzorcowe i wygenerowane (sieć dyskryminatora (rys. 1.)). Pracując w ten sposób obie sieci rywalizują ze sobą, w rezultacie poprawiając swoje zdolności predykcji.



Rysunek 1: Schemat przedstawiający zasadę działania metody GAN.



Rysunek 2: Porównanie metod uczenia.

Podziękowania i źródła finansowania

Niniejsza praca została sfinansowana przez NCN (PRELUDIUM 2021/41/N/ST7/04057) oraz Politechnikę Warszawską w ramach Inicjatywy Doskonałości: Uczelni Badawczej (YOUNG PW 504/04496/1143/45.010012)

Literatura

- [1] S. Petitgrand, R. Yahiaoui, A. Bosseboeuf and K. Danaie, *Proc. SPIE* 4400, 51-60 (2001)
- [2] K. Patorski, A. Styk, *Opt. Eng.* 45, 085602 (2006).
- [3] M. Trusiak, A. Styk, K. Patorski, *Opt. Lasers Eng.* 110, 100-112 (2018).
- [4] M. Cywińska, W. Forjasz, E. Wdowiak, M. Jóźwik, A. Styk, M. Trusiak (w recenzji w *Optics and Lasers in Engineering*)
- [5] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, Y. Bengio, *CACM* 63, 139 - 144 (2020).