

헤시안 프리 최적화를 결합한 PINN 기반 능동 노이즈 캔슬링 모듈 설계에 관한 연구

송순용

한국전자통신연구원

soony@etri.re.kr

A Study on the Design of a PINN-based Active Noise Cancelling Module incorporating Hessian-Free Optimization

Soonyong Song

Electronics and Telecommunications Research Institute (ETRI)

요약

본 연구는 헤시안-프리 (Hessian-Free, HF) 최적화를 물리 기반 신경망 (Physics-Informed Neural Network, PINN) 학습에 도입하여 능동 노이즈 캔슬링 (Active Noise Control, ANC)에서 요구하는 짧은 지연시간 내에 소음 저감 성능을 빠르고 안정적으로 달성할 수 있다는 가설을 수립하고 이를 검증하였다. 비교 대상 모델은 전통적 Filtered-x LMS (FxLMS), PINN+Adam, PINN+HF-CG로 설정하였다. 실험 결과 PINN+HF-CG은 25회 미만의 반복으로 1차 오퍼타이저와 동등한 MSE 성능으로 수렴하면서도 절반 가량의 계산 시간만을 필요로 하는 것과 FxLMS 방식 대비 약 2.7dB의 성능 이득이 있음을 확인할 수 있었다. 이는 제안하는 방식이 1 에포크 당 손실 감소폭을 크게 키우면서도 댐핑과 선탐색을 조합하여 발산을 억제하였기 때문이다. 이러한 결과를 통해 PINN+HF-CG 프레임워크가 일반적인 최적화 방식에 비해 학습 효율에 우위가 있어 저지연이 필요한 ANC 환경에 적합한 방식임을 확인하였다.

I. 서론

능동 노이즈 캔슬링은 목표 음장을 실시간으로 예측하여 상쇄함으로써 기계, 교통, 생활 소음을 효과적으로 줄이는 기술이다. 항공기 캐빈 및 차량 내부, VAC 덕트 등 저주파 지향 응용에서 이미 상용화 단계에 이르렀다. 그러나 이러한 응용은 스피커와 마이크 배열이 늘어날수록 제어 필터 차원과 전달 경로 모델이 기하급수적으로 증가하며, 특히 3~5 ms 이하의 지연 제약을 만족해야 하므로 고차원 최적화를 매우 빠르게 수행할 수 있는 학습 기법이 필수적이다. 기존에는 Filtered-x LMS 알고리즘이 단순성과 안정성을 이유로 주류를 형성했지만, 최적 점 근처에서 1차 그래디언트만 사용하기 때문에 수렴 속도가 느리고 잡음 스펙트럼이 급변할 때 적응이 느다는 근본적 한계를 노출한다[1].

딥러닝의 비선형 표현력은 이러한 한계를 부분적으로 극복한다. Deep ANC 접근법은 잡음 특성을 신경망이 지도학습하여 제어 파라미터를 직접 출력함으로써 복잡한 음장을 넓은 대역폭에 걸쳐 억제할 수 있음을 보였다 [2]. 그럼에도 대규모 네트워크를 마이크 입력 흐름에 맞추어 수 ms 내로 업데이트하려면 1차 오퍼타이저만으로는 계산량과 반복 횟수가 과도하게 증가한다. 물리 정보를 손실에 포함하는 PINN 구조는 적은 데이터로도 일반화 성능을 확보하지만, 손실 함수에 물리 잔차 항이 추가되어 곡률이 심해지는 경향이 있어 1차 방법의 느린 수렴 문제가 더 두드러진다[3].

HF 최적화는 빠른 수렴이 필요한 상황에서 반드시 필요한 기법으로 각광받고 있다. Martens가 제안한 HF는 헤시안 행렬 대신 임의 벡터와의 곱만 계산하여 뉴턴 방향을 근사하므로, 파라미터 수가 백만 단위를 넘어도 2차 수렴 속도를 유지할 수 있다[4]. Truncated Newton-CG, 신뢰 영역, 댐핑 조합은 Hessian이 부정이거나 조건수가 나쁜 영역에서도 발산을 방지한다[5]. 기계 학습에서는 순환 신경망 학습 등에서 HF가 L-BFGS보

다 빠르고 안정적으로 수렴한다는 보고가 누적되고 있으나[6], 제어 및 음향 적용 사례는 제한적이다. 최근 물리 정보 학습 분야에서도 HF-Natural Gradient가 대규모 PINN을 효율적으로 최적화했다는 결과가 나오며 가능성을 넓히고 있다[7].

따라서 본 연구는 PINN-HF 조합을 ANC 문제에 적용하여 이론적 타당성과 실증적 효과를 검증하고자 한다. 이를 위해 ① ANC 신호 모델을 재정의하고, ② PINN 손실에 2차 경로 동역학을 내재화하며, ③ HF-CG에 댐핑 및 라인서치를 얹어 실시간 수렴을 달성하는 프레임워크를 설계하였다. 이후 시뮬레이션을 통해 FxLMS와 adam 대비 성능을 정량적으로 비교하고 그 결과를 고찰하며 논문의 결론을 제시한다.

II. 본론

ANC 시스템에서 오류 신호는 1차 잡음 $d[n]$ 과 스피커 출력 $y[n]$ 이 2차 경로 $S(z)$ 을 거쳐 합성된 결과로, $e[n] = d[n] + S(z)y[n]$ 과 같이 정의할 수 있다. 본 연구에서 사용할 PINN 기반 ANC 컨트롤러는 원도 길이 M 인 데이터 $[x[n], x[n-1], \dots, x[n-M+1]]$ 을 입력받아 오류 신호를 최소화하는 스피커 전압을 출력한다. 네트워크는 두 개의 완전 연결 층과 Activation을 위한 Tanh 비선형 층을 사용하여 총 289개의 가중치를 가지게 된다. 이 구조는 비선형의 표현력이 충분하고 자동미분이 용이해 2차 연산에 적합하다. PINN 손실은 잔류 음압의 제곱합으로 정의되며, 2차 경로 모델이 직접 포함되어 있으므로 별도 전처리나 메타 파라미터 없이도 물리 제약을 내재화할 수 있다. 손실 그래디언트와 헤시안-벡터 곱 Hv 는 PyTorch 자동미분으로 계산하되, 그래프 재사용을 위해 `retain_graph=True` 옵션을 설정했고, 벡터 사본을 전달해 인-플레이스 수정으로 인한 버전 충돌을 방지했다.

HF-CG는 각 외부 반복에서 전체 파라미터에 대한 그라디언트를 계산한 뒤, 내부 루프에서 $(H + \lambda I)p = -g$ 형태의 선형 시스템을 TN-CG 방식으로 근사적으로 풀어 뉴턴 방향 p 를 찾는다. 이 때 Hv 는 자동미분으로 계산되어 메모리 부담 없이 2차 정보를 활용할 수 있다. 댐핑계수 λ 는 초기값 1.0에서 시작한다. 선탐색 (line-search) 기법에서 목적 함수를 충분히 감소시키는지 판정하기 위한 조건으로 Armijo 부등식을 도입한다. Armijo 선탐색이 실패할 때마다 두 배씩 증가해 수정 헤시안 $H + \lambda I$ 가 항상 positive definite가 되도록 보장해 CG 수렴성을 확보한다. 내부 CG는 잔차 norm이 0.0001 이하로 떨어지면 조기 종료되므로 불필요한 Hv 계산을 중지하여 계산량을 줄일 수 있다. 또한 Steihaug 변형을 적용해 trust region 또는 negative curvature를 탐지시 발산 방지를 위해 계산을 종료하여 안정성을 유지한다. 업데이트 단계에서는 Armijo 충분 감소 조건을 만족할 때 까지 스텝 크기 α 를 0.5씩 축소하며 최대 10회 까지 백트래킹하고 그 안에 조건을 충족하지 못하면 파라미터를 롤백한 뒤 λ 를 다시 두 배로 키워 재시도한다. 이렇게 HF-CG의 곡률 활용 능력과 Armijo 조건을 통한 보수적인 스텝 조정 과정이 결합되면, 과도한 댐핑이 가져오는 수렴 지연을 피하면서도 헤시안 부정부호 구간이나 모델 불일치로 인한 발산을 효과적으로 억제하여 전체 알고리즘이 빠른 수렴 속도와 균형 잡힌 안정성을 동시에 달성하게 된다.

시뮬레이션에서는 사람이 듣고자 하는 유용한 신호는 포함하지 않고, 오직 제거 대상인 소음만 존재하는 환경을 가정하였다. 디지털 처리 조건은 8kHz 샘플링 주파수와 0.5s 초 동안의 4000개의 샘플 길이로 설정하였으며, 제거할 1차 소음 $d[n]$ 은 저주파 톤인 200Hz 정현파와 0.3rms의 백색소음을 합성하여 신호를 생성하였다. 스피커에서 방사된 안티노이즈가 오류 마이크에 도달할 때의 전달 특성을 나타내는 2차 경로 $S(z)$ 는 두 개 계수 $[0.8, 0.2]$ 로 이루어진 FIR 필터로 근사하여 단순화 하였다. 비교 대상은 두 가지 모델로 설정하였다. 첫 번째는 전통적 FxLMS로 8-tap FIR 필터와 학습률 $\mu = 0.01$ 을 적용한 모델이다. 두 번째는 PINN + Adam으로, 초기 학습을 0.01로 150 에포크 동안 1차 옵티마이저로 학습시켰다. 마지막으로 제안한 방법인 PINN + HF-CG는 25에포크만 학습을 수행하되 각 반복마다 Truncated CG 20회로 뉴턴 방향을 구하고, 수정 헤시안 $H + \lambda I$ 의 안정성을 보장하기 위해 초기 댐핑 $\lambda_0 = 1.0$, Armijo 선탐색 실패시 λ 를 두 배로 증분하는 전략을 적용하였다.

그림 1에 시뮬레이션 실험 결과를 나타내었다. 실험 결과 PINN + HF-CG는 처음 5 에포크만에 MSE가 0.014 수준까지 급격히 떨어진 뒤 13번째 에포크에서 0.0068을 기록하였고, 최종 반복에서 0.00649에 수렴하였다. 그래프에서 MSE가 상승하는 구간이 관찰되지 않은 것은 댐핑 조절과 Armijo 선탐색이 서로 맞물려 큰 스텝으로 인한 발산을 효과적으로 억제하였기 때문이며, 미세 진동도 적어 곡선이 부드럽게 표현된다. 반면 동일한 네트워크를 1차 옵티마이저로 학습한 PINN + Adam은 MSE가 완만하게 감소하여 150에포크에 도달하였을 때 0.0065에 도달하였다. 두 모델은 성능이 거의 동일하지만, 수렴 속도와 계산 비용은 크게 차이가 있다. FxLMS 기준선이 0.0095에 머무른 것과 비교하면 딥러닝 기반의 방법들은 모두 2.7dB의 소음 저감 효과를 보여 주었으며, PINN + HF-CG는 PINN + Adam에 비해 여섯배 적은 반복으로 동일한 성능을 달성할 수 있었다. 에포크당 평균 실행 시간은 PINN + Adam이 6.5ms, PINN + HF-CG가 21ms로 측정이 되었는데, 에포크 수를 대입하면 PINN + Adam은 $6.5\text{ms} \times 150 = 0.98\text{s}$, PINN + HF-CG는 $21\text{ms} \times 25 = 0.53\text{s}$ 로 실제 계산에 필요한 시간을 절반 가까이 줄일 수 있었다. 이를 통해 PINN + HF-CG 방법이 적게 계산하더라도 빠르게 줄어드는 효율을 달성하였음을 알 수 있다.

III. 결론

본 연구는 PINN에 헤시안-프리 Truncated Newton-CG를 접목한 능동 노이즈 캔슬링 학습 프레임워크(PINN+HF-CG)를 제안하고, 실험적 검증을 통해 그 효율을 입증하였다. 제안법은 1차 옵티마이저(Adam)와 동일한 MSE를 달성하면서도 외부 반복 수와 학습 시간을 절반 이하로 단축해, 지연에 민감한 온라인 제어 문제에서 2차 곡률 정보를 활용할 때의 실질적 이점을 분명히 보여 주었다. 댐핑과 Armijo 선탐색을 결합한 HF-CG는 발산 없이 안정적으로 수렴했고, 수렴 경로도 매끈해 예측 가능성이 높았다. 향후, 세 가지 방향의 후속 연구가 할 필요가 있을 것으로 예상된다. 첫째, 시간지연이 큰 전달 경로를 포함하는 고차 모델에서도 HF-PINN의 성능과 안정성을 검증해야 한다. 둘째, FPGA 및 DSP 같은 저전력 임베디드 플랫폼에 맞춘 경량화 기법을 개발해 저지연으로 구동할 수 있도록 해야 한다. 셋째, 마이크로폰 어레이를 통한 공간 소음 예측과 다중 입력 다중 출력(MIMO) 제어 구조로 확장해 자동차, 혼합현실, 헤드셋, 의료 초음파 기기 등 레이턴시가 엄격한 다양한 응용까지 범용성을 확인하는 작업이 필요하다. 이러한 후속 연구가 이루어진다면, 2차 최적화 기반 실시간 학습 프레임워크가 다양한 현장의 고성능 ANC 요구를 충족하는 핵심 기술이 될 것으로 기대된다.

ACKNOWLEDGMENT

본 연구는 한국전자통신연구원 연구운영비지원사업의 일환으로 수행되었음 [25ZR1100, 자율적으로 연결제어진화하는 초연결 지능화 기술 연구]

참 고 문 헌

- [1] Yang, F. et al., "Frequency-Domain Filtered-x LMS Algorithms for Active Noise Control: A Review and New Insights," Applied Sciences, 2018.
- [2] Zhang, H. et al., "Deep ANC: A deep learning approach to active noise control," Neural Networks, 2021.
- [3] Johannes D, S., et al., "Physics-informed neural networks for acoustic boundary admittance estimation," Applied Acoustics, 2024.
- [4] Martens, J., "Deep learning via Hessian-free optimization," Proc. ICML, 2010.
- [5] Stephen G, N., "Truncated Newton methods for large-scale minimization," Mathematical Programming, 1983.
- [6] Martens, J., et al., "Learning recurrent neural networks with Hessian-free optimization," Proc. ICML, 2011.
- [7] Jnini, A. et al., "Hessian-Free Natural Gradient Descent for Physics-Informed Machine Learning," OpenReview, 2024.




그림 1. ANC 학습 알고리즘별 MSE 오류 수렴 곡선