

가까운 벌림 빠짐 해결을 위한 딥러닝 기반의 트레이스 내삽 및 외삽 기술에 대한 고찰

박지호 · 설순지 · 변중무*

한양대학교 자원환경공학과

A Review of Deep Learning-based Trace Interpolation and Extrapolation Techniques for Reconstructing Missing Near Offset Data

Jiho Park, Soon Jee Seol, and Joongmoo Byun*

Department of Earth Resources and Environmental Engineering, Hanyang University

요약

해양 탄성파 탐사 수행 시 송·수신 케이블의 구조적인 거리차에 의해서 필연적으로 발생하는 가까운 벌림(near offset)의 트레이스(trace) 빠짐은 뒤따르는 탄성과 자료처리의 결과 및 영상화에 악영향을 끼치게 된다. 특히 가까운 벌림의 자료의 부재는 정확한 탄성과 영상화를 저해하는 다중반사파의 제거에 주요한 인자로 작용하므로 다중반사파의 영향력이 강해지는 천해 및 연안 탐사의 경우 빠짐을 효과적으로 해결해야 한다. 전통적으로 다양한 라돈 변환(Radon transform) 기반의 내삽 방법들이 가까운 벌림 빠짐의 해결책으로 제시되어왔으나 여러 한계점을 보여, 최근 이를 보완하기 위한 딥러닝(deep learning) 기반의 방법들이 제시되고 있다. 이 논문에서는 기존에 제시된 두 가지의 대표적인 딥러닝 기반의 접근법에 대해 면밀히 분석하여 앞으로 가까운 벌림 내삽 연구가 해결해야 하는 문제점들에 대해 깊이 있게 논의한다. 또한 기존의 딥러닝 기반의 트레이스 내삽 기술을 가까운 벌림 상황에 적용할 때 나타나는 한계점을 현장자료 실험을 통해 명확히 분석하여 향후 가까운 벌림 자료 빠짐의 문제는 내삽이 아닌 외삽으로 접근해야 한다는 것을 보여준다.

주요어

트레이스 내삽, 트레이스 외삽, 기계학습, 딥러닝, 가까운 벌림

ABSTRACT

In marine seismic surveys, the inevitable occurrence of trace gaps in the near offset resulting from geometrical differences between sources and receivers adversely affects subsequent seismic data processing and imaging. The absence of data in the near-offset region hinders accurate seismic imaging. Therefore, reconstructing the missing near-offset information is crucial for mitigating the influence of seismic multiples, particularly in the case of offshore surveys where the impact of multiple reflections is relatively more pronounced. Conventionally, various interpolation methods based on the Radon transform have been proposed to address the issue of the near-offset data gap. However, these methods have several limitations, leading to the recent emergence of deep-learning (DL)-based approaches as alternatives. In this study, we conducted an in-depth analysis of two representative DL-based studies to scrutinize the challenges that future studies on near-offset interpolation must address. Furthermore, through field data experiments, we precisely analyze the limitations encountered when applying previous DL-based trace interpolation techniques to near-offset situations. Consequently, we suggest that near-offset data gaps must be approached by extrapolation rather than interpolation.

KEYWORDS

trace interpolation, trace extrapolation, machine learning, deep learning, near offset

Received: 19 September 2023; Revised: 16 October 2023; Accepted: 7 November 2023

*Corresponding author

E-mail: jbyun@hanyang.ac.kr

Address: 222, Wangsimni-ro, Seongdong-gu, Seoul, Republic of Korea

©2023, Korean Society of Earth and Exploration Geophysicists

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

서론

해양 탄성과 탐사는 오랜 시간동안 대륙붕 및 해양저에 부존하고 있는 에너지 자원 탐사 또는 천해의 지형 및 자원 탐사 등과 같이 여러 목적으로 널리 활용되어 왔다. 또한 최근에는 이산화탄소 지중저장을 위한 저류층 부지 선정 및 모니터링을 위해서도 중요한 역할을 하고 있다(Ma *et al.*, 2017; Park *et al.*, 2018; Park *et al.*, 2021a). 그러나 해양 탄성과 탐사 수행 시에는 여러가지 제약이 수반될 수 있다. 탐사선의 제한에 따라 자료 취득 간격이 고정되므로 취득되는 탄성과 자료의 공간해상도에 제한이 발생할 수 있다. 또한 항해를 하며 자료를 취득하기 때문에 해류 및 어촌계의 장애물로 인해서 자료가 불규칙하게 취득되거나 트레이스(trace) 빠짐 및 자료의 손실이 발생하게 된다. 특히 대부분의 해양 탄성과 탐사는 탐사선이 송·수신 케이블을 끌고 항해하며 자료를 취득하는 견인 스트리머(towed streamer) 시스템으로 운용되기 때문에 송·수신 케이블의 구조적인 거리에 의해서 가까운 벌림(near offset)의 트레이스는 취득이 불가능하다. 따라서 취득된 자료에는 근본적으로 가까운 벌림에 큰 빠짐(big gap)이 존재하게 되어 해당 벌림에 해당되는 탄성과자료는 기록되지 않는다. 이러한 가까운 벌림 정보의 부재는 다중반사파 제거 기술인 SRME (surface-related multiple elimination) 적용에 있어 어려움을 야기시킨다(Kostov *et al.*, 2015; Qu *et al.*, 2021). 해수층에 의한 다중반사파는 탄성과 자료 영상 전체에 큰 악영향을 끼치기 때문에 하부 구조에 대한 정확한 영상화를 위해서는 자료처리 과정에서 필수적으로 제거되어야 한다. 특히 천해 및 연안 탐사의 경우 다중반사파의 영향이 더욱 커지므로 가까운 벌림의 빠짐을 효과적으로 해결해야 한다.

일반적으로 빠짐이 존재하는 탄성과 자료는 트레이스 내삽(trace interpolation) 기술을 적용하여 효과적으로 트레이스를 복구해 낼 수 있다. 따라서 가까운 벌림의 빠짐 경우도 전통적인 트레이스 내삽 기술이 적용되어 해결되어 왔다. 수많은 기존의 이론기반 트레이스 내삽 기술들 중에서 라돈 변환(Radon transform) 기반의 트레이스 내삽 기술들이 가까운 벌림의 큰 빠짐을 내삽하는 핵심 기술로 활용되어 왔다. 포물선형 라돈 변환(parabolic Radon transform) 기반의 트레이스 내삽 기술은 가까운 벌림 빠짐의 트레이스 내삽에 가장 많이 활용되어 왔다. 그러나 가까운 벌림에서의 제한된 정보와 강한 공간 진폭 변화를 가진 곡선의 탄성과 신호로 인해 얇은 반사들(shallow reflections)을 효과적으로 재구축하지 못한다는 단점이 존재한다(Kabir and Verschuur, 1995). 또한 포물선형 라돈 변환 기반의 트레이스 내삽 기술은 수직 시간차 보정(normal moveout correction)이 선행되어야 하므로 추가적인 공정이 요구되는 방법이다. 이를 보완하기 위하여 쌍곡선형 라돈 변환(hyperbolic Radon transform) 기반의 트레이스 내삽 기술이 제시되었다(Trad, 2003). 해당 방법은 포물선형 라돈 변환 기

반의 방법과 달리 추가 공정이 요구되지 않지만 쌍곡선형 라돈 변환의 시간-공간(time-space)영역의 구현은 많은 계산 비용이 소요된다는 단점이 있다. 한편, Xu *et al.* (2018)는 트레이스들 간의 교차 상관을 통해 가상의 트레이스를 만들어내는 탄성과 간섭법(seismic interferometry)의 개념을 활용한 간섭계 내삽(interferometric interpolation) 기술을 도입하였다. 또한 새롭게 도입한 간섭계 내삽 기술을 라돈 변환 영역에서 수행하여 가까운 벌림 빠짐의 트레이스 내삽 성능을 향상시키는 방법을 제시하였다. 그러나 여전히 얇은 반사들에 대한 내삽 성능을 보장하지 못하며 두 단계의 처리(processing)로 인한 많은 계산 비용 또한 문제로 남아 있다. 추가적으로 focal 변환을 통한 focal 영역에서 가까운 벌림 내삽과 그로부터 추론한 다중반사파를 이용하여 다중반사파를 동시에 제거하는 closed-loop SRME 기술(Kostov *et al.*, 2015; Lopez and Verschuur, 2015; Zhang and Verschuur, 2019)이 제시되었지만 여전히 가까운 벌림 빠짐의 트레이스 복원 성능은 보장되지 않아 다른 접근의 연구가 필요한 상황이다.

최근 몇 년 동안에는 기존 이론기반의 탄성과 자료 내삽 연구의 한계점을 보완하고 좀 더 도전적인 문제를 해결하기 위하여 기계학습(machine learning)분야의 딥러닝(deep learning) 기술이 탄성과 트레이스 내삽 연구에 활발히 도입되고 있다. 이에따라 최근 가까운 벌림의 빠짐의 경우에 대해서도 기존의 방법들의 단점을 보완하고 성능을 향상시키기 위하여 딥러닝 기반의 기법 두가지가 제시되었다. 이 논문에서는 기존에 연구된 Qu *et al.* (2021)과 Wang *et al.* (2022)의 두 가지 대표적인 접근 방법에 대해 자세히 살펴본다. 그리고 각 방법의 장점과 단점의 분석을 통하여 앞으로의 가까운 벌림 내삽 연구가 해결해야 될 문제점에 대해 논의해 보고자 한다. 이와 더불어 기존의 딥러닝 기반 트레이스 내삽 기술이 왜 가까운 벌림 상황에서 적용이 어려운지에 대해 고찰한다. 그리고 Mobile Viking graben Line 12 자료를 사용하여 가까운 벌림 자료와 그 외의 자료들이 가지는 자료 특성의 차이를 제시한다. 또한, 실제 현장과 같이 가까운 벌림이 없는 경우의 자료만을 학습에 사용할 때 가까운 벌림 자료에 대한 트레이스 복구 성능이 어느 정도 저하되는지를 보여주어 기존 딥러닝 기반 방법 적용의 한계점에 대해 분석하고자 한다.

가까운 벌림 빠짐에 대한 고찰

가까운 벌림 빠짐을 효과적으로 해결하기 위해서는 먼저 그 특성을 정확히 이해해야 한다. 일반적으로 해양 탄성과 탐사에서 발생하는 대표적인 트레이스 빠짐은 다음과 같다. 먼저 에어건(air gun)의 불발, 수신기의 기록 오류 등으로 발생하는 빠짐이 있다. 이런 빠짐은 보통 공통 송신원 모음(common shot gather; CSG)이나 공통 수신기 모음(common receiver gather; CRG)상에서 한, 두 트레이스의 빠짐으로 나타나기 때문에 비

교적 간단하게 해결이 가능하다. 다음으로는 해양 환경에서 탐사 시 해류의 영향으로 발생하는 송·수신 케이블의 표류(drifting)에 의한 불규칙적인 트레이스 빠짐이 발생할 수 있으며 송·수신 케이블의 제원에 따른 송·수신기의 간격(inline spacing), 탐사선의 제원에 따른 수신 케이블 간의 간격(crossline spacing) 등의 제약으로 인해 샘플링이 부족한 규칙적인 트레이스 빠짐이 있다. 각각의 경우 탄성과 자료 에너지의 누출(leakage)이나 공간 알리아싱(aliasing)의 문제 등을 발생시키기 때문에 다양한 트레이스 내삽 기술들을 적용하여 해결해 왔다. 이외에 송·수신 케이블의 물리적인 거리에 의해서 발생하는 가까운 벌림 빠짐과 수신 케이블의 페더링(feathering) 현상으로 발생하는 빠짐이 존재할 수 있다. 이러한 빠짐들은 앞서 기술한 빠짐 들보다 상대적으로 더 큰 빠짐(big-gap)으로 나타나게 된다. 이러한 자료 취득 과정에서 발생하는 다양한 종류의 트레이스 빠짐은 트레이스 내삽 기술이라는 테두리 안에서 그 해결을 위한 많은 연구가 진행되어 왔다. 트레이스 내삽 기술의 기본적인 개념은 다음과 같다. 빠짐이

존재하는 부분의 트레이스를 추론 및 계산해내기 위해서 빠진 트레이스에 인접한 주변 트레이스들 간의 신호 연결성을 파악하여 그 사이의 관계식을 구축하는 방법이다. 이러한 개념은 딥러닝 기반의 트레이스 내삽 기술에서도 중요한 기본 가정이 된다. 탄성과 모음 상에서 규칙적, 불규칙적 빠짐의 경우에는 빠진 트레이스들 사이의 관계를 파악할 수 있는 빠짐에 인접한 트레이스들이 존재한다. 이 경우에 빠짐에 인접한 트레이스가 지니고 있는 정보를 딥러닝 모델이 학습할 수 있기 때문에 트레이스 내삽 적용이 용이하다. 반면에 가까운 벌림 빠짐이나 페더링에 의한 빠짐은 연속적인 트레이스가 빠지는 큰 빠짐으로 나타나는 경우가 많아 내삽문제로도 상당히 어려운 도전적인 문제에 해당한다. 특히 가까운 벌림 자료는 공통 송신원 모음자료에서 한쪽 끝의 연속된 자료가 애초에 존재하지 않는 경우에 해당하여 엄밀히 말하면 빠짐 사이의 트레이스를 내삽하는 것이 아닌 존재하지 않는 트레이스를 새롭게 만들어 내야하는 트레이스 외삽(extrapolation)문제에 해당되게 된다 (Dragoset and Jeričević, 1998).

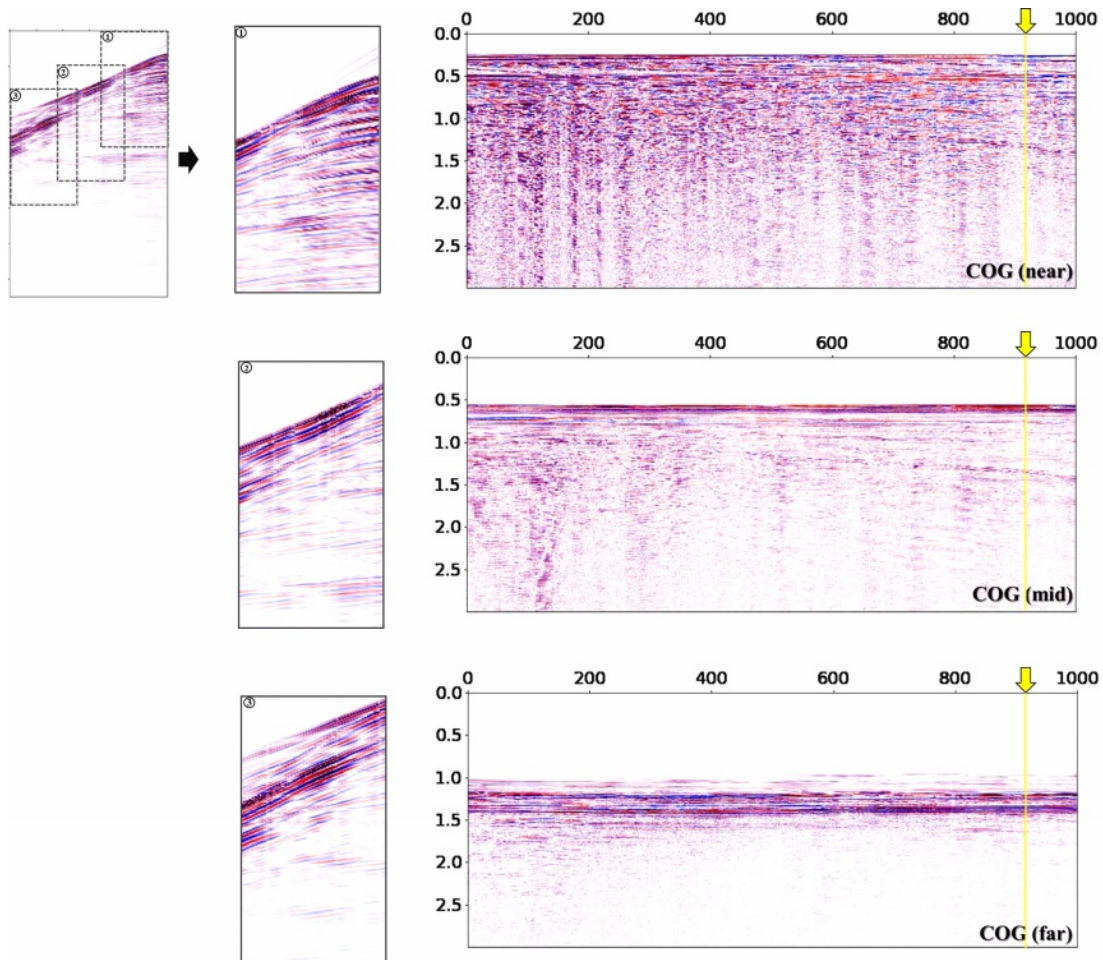


Fig. 1. Different features of near, mid, and far offset patches. The magnified sections correspond to the respective numbered boxes. The yellow arrow corresponds to left common shot gather (CSG).

대부분 지도학습(supervised learning)에 기반을 둔 딥러닝 기반 트레이스 내삽 방법들은 현장에서 조밀하게 얻어진 부분의 자료를 정답자료로 조밀하게 얻어진 자료를 임의 손상시킨 자료를 학습자료로 활용한다. 그 후 학습자료를 통해 딥러닝 모델을 훈련시키고 훈련된 모델을 이용하여 규칙적이거나 불규칙적인 빠짐이 있는 자료에 대해 내삽을 수행한다. 효과적으로 트레이스 내삽을 수행하기 위해서는 조밀하게 얻어진 자료에서 목표자료(target data)의 신호 패턴과 유사한 특성을 아우르도록 학습 패치(patch)를 다양하게 구성해야 한다. 즉, 목표자료의 복잡한 특성을 반영할 수 있는 훈련자료 생성이 필요하다. 그러나 트레이스 외삽에 해당되는 가까운 벌림 빠짐의 경우에는 탐사 시 취득이 되지 않은 경우이기 때문에 모든 모음자료에서 가까운 벌림에 해당하는 트레이스가 존재하지 않는다. 이는 딥러닝 모델 훈련을 위한 자료의 부재를 의미하며 이런 근원적인 자료의 부재의 해결이 가까운 벌림 빠짐의 외삽에서 해결해야 하는 가장 핵심적인 문제이다. 따라서 이를 해결하기 위해서는 먼저 가까운 벌림 자료가 현장에서 얻어지는 중간거리 벌림(mid offset)나 먼거리 벌림(far offset) 자료와 얼마나 유사성을 갖고 있는 지에 대한 분석이 필요하다.

Fig. 1은 각 벌림에 따른 특성 차이를 보여주는 간단한 예제이다. 그림에서 보이는 것처럼 신호들이 비슷한 경사(slope)를 갖는 것처럼 보여도 가까운 벌림에서 먼거리 벌림까지 신호들의 연속적인 특성이 다름을 확인할 수 있다. 또한 Fig. 1의 공통 벌림 모음(common offset gather)들에서 보이는 것처럼 가까운 벌림의 경우는 같은 지역에서 취득한 자료라도 다른 벌림과 서로 다른 특성을 보인다. 먼 벌림으로 갈수록 시간차(moveout)의 영향에 더 지배적이기 때문에 신호의 연속성이 상대적으로 저해된다. 반대로 가까운 벌림 범위에서는 시간차에 대한 영향이 거의 없이 지하의 지질구조에 의한 영향만을 고려하면 되지만 다중반사파가 큰 영향을 끼치게 되므로 그림

에서 보이는 것처럼 다른 벌림 모음에 비해 보다 복잡한 신호 특성을 보이고 있다(Hargreaves, 2006). Fig. 2는 같은 현장에서 취득한 자료에서 가까운 벌림 자료가 보여주는 서로 다른 이벤트의 특성을 보여준다. Fig. 2a와 2b의 공통 송신기 모음 자료는 같은 지역의 다른 송신기에 의해 취득된 자료로 확대 그림에서 보이는 것처럼 지질학적 구조의 차이와 다중반사파들로 인해서 t-x 영역 상에서 전혀 다른 특성을 보여준다. 여기서, 단순히 t-x 영역상에서의 식별이 아닌 보다 정밀한 분석을 위하여 Park *et al.* (2021b)에서 제안한 탄성과 자료 분석 기술인 합성곱 오토인코더 티즈니(Convolutional auto-encoder t-distributed stochastic neighbor embedding) 분석을 도입한다. 해당 분석 기술은 입력 자료들을 합성곱 오토인코더를 통해 잠재공간(latent) 영역 상으로 변환하고 각 입력들의 유사도(similarity)를 계산 및 학습하여 2D 영역상으로 도시하는 방법으로 자료간의 특성을 보다 면밀하고 직관적으로 분석해준다. 2D 영역상에 도시된 각 점들은 각 입력 자료에 대응되고 해당 점들은 중첩될수록 혹은 거리가 가까울수록 유사도가 높음을 의미한다. Fig. 2c의 분석 결과에서 보이는 것처럼 두 자료의 특성을 공유하는 교집합 부분도 존재하지만 두 가까운 벌림 자료의 특성이 분석 맵 상에서 명확하게 다른 부분도 있음을 알 수 있다. 이는 실제 현장 자료에서는 가까운 벌림 자료들이 다양하고 복잡한 특성을 지니고 있음을 암시한다. 즉, 가까운 벌림 빠짐을 효과적으로 해결하기 위해서는 가까운 벌림 자료가 지니는 다양한 특성을 고루 반영할 수 있는 학습자료의 구성이 필수적으로 요구된다. 따라서 실제로 현장자료에 전혀 존재하지 않는 가까운 벌림 자료를 모사해 내기 위한 학습자료를 만들 수 있는 자료 증대 기술이 요구된다. 이처럼 가까운 벌림 빠짐의 문제는 외삽의 영역이기 때문에 새로운 접근법이 필요하다.




Fig. 2. Different properties of near offset in the t-x domain and convolutional autoencoder t-distributed stochastic neighbor embedding (CAE t-SNE) analysis results of near-offset traces of two common shot gathers (CSGs). Panel (a) shows CSG #1000 and the magnified part of the near offset. Panel (b) presents CSG #600 and the magnified part of the near offset. Panels (a) and (b) demonstrate different properties of near-offset traces in the same field data. Panel (c) shows CAE t-SNE analysis (Park *et al.*, 2021b) results. The green and gray dots indicate CSG #1000 and CSG #600, respectively. Non-overlapping regions in the analysis results demonstrate different features.

딥러닝 기반의 가까운 벌림 빠짐 내삽에 대한 고찰

트레이스 내삽 기술 분야에 Jia and Ma (2017)가 성공적으로 머신러닝 기술을 도입한 이래로 최근 몇 년간 다양한 연구들이 제시되어 왔다. 단순한 머신러닝 기술을 넘어서 더 고도화된 컴퓨터 비전 분야의 딥러닝 기술들이 도입되었고 규칙적(Wang *et al.*, 2019; Park *et al.*, 2021b; Wang *et al.*, 2023), 불규칙적(Mandeli *et al.*, 2019; Pan *et al.*, 2020; Park *et al.*, 2022), 연속적(Yu and Wu, 2022; He *et al.*, 2021; Dou *et al.*, 2023) 빠짐 등 다양한 빠짐을 해결하기 위한 딥러닝 기반의 트레이스 내삽 기술이 제시되었다. 또한 최근에는 최종 탄성파 이미지 개선을 위한 성공적인 다중반사파 제거를 위하여 도전적인 문제인 가까운 벌림의 빠짐 문제에 대한 연구도 시도되었다. 이 논문에서는 딥러닝 기반의 가까운 벌림 빠짐 내삽 방법의 대표적인 두 연구에 대해 비교 분석한 내용을 기술하고자 한다.

첫번째로 Qu *et al.* (2021)은 앞서 기술한 훈련을 위해 사용할 정답(label)이 존재하는 학습자료의 부재를 해결하는데 초점을 두어 연구를 진행하였다. 학습자료로 활용할 현장자료가 없는 실정을 반영하여 목표 현장자료의 중간거리 및 먼거리 자료들로부터 층서 구조와 속도 모델, 요소파를 먼저 얻어내고 이를 이용하여 현장자료와 최대한 유사한 합성자료를 생성하였다. 이렇게 생성된 합성자료는 U-Net 모델의 훈련 자료로 활용한다. 그 후 학습된 U-Net 모델에 의해 채워진 가까운 벌림 빠짐 자료는 포물선형 라돈 변환 트레이스 내삽의 선행 내삽으로 적용되고 다시 한번 포물선형 라돈 변환 트레이스 내삽을 거쳐 최종 내삽이 수행된다. 즉, 딥러닝 기반의 방법과 전통적인 방법을 순차적으로 수행하는 혼합형 내삽 방식이다. Qu *et al.* (2021)은 기존의 포물선형 라돈 변환 트레이스 내삽 기술을 단독으로 사용할 때 얇은 반사들의 재구축이 힘든 한계점을 극복하기 위하여 딥러닝 기반의 트레이스 내삽 기술을 선행 내삽으로 사용하였다. 학습한 U-Net을 선행 내삽으로 활용하여 좋은 초기값(initial value)를 부여하였고 이후 수행되는

포물선형 라돈 변환 트레이스 내삽을 통한 최종 내삽 결과를 증진시켰다. Fig. 3은 이 연구에서 제안한 합성자료로 훈련한 U-Net 모델의 결과를 보여준다. 실험에서 가까운 벌림 빠짐 트레이스의 최대 개수는 12개이다. Fig. 3b는 현장의 사전정보를 이용한 모델링을 통해 만들어낸 합성자료의 공통 송신기 모음이고 Fig. 3a는 학습자료를 위하여 3b의 가까운 벌림을 임의 손상시킨 공통 송신기 모음이다. 이 연구에서는 Fig. 3b와 3a를 정답과 훈련자료로 사용하여 U-Net 모델을 학습시키고 이를 적용시켜 Fig. 3c의 결과를 도출한다. Fig. 4는 기존의 포물선형 라돈 변환 기반의 트레이스 내삽 결과와 이 연구에서 제안한 방법으로 내삽한 공통 송신원 모음 자료를 비교한 결과를 보여준다. 또한 추가적으로 각각의 기법으로 내삽된 자료들을 이용하여 SRME를 수행한 후의 공통 벌림 모음(common offset gather)결과도 보여준다. Fig. 4에서 보이는 것처럼 합성자료로 학습한 딥러닝 모델을 선행 내삽으로 사용한 결과가 그렇지 않은 결과보다 더 향상된 SRME 결과를 보여준다는 것을 알 수 있다.

Qu *et al.* (2021)은 실제로 현장자료에서 가까운 벌림의 자료가 없는 것이 가까운 벌림 자료 내삽에서 가장 중요한 문제라는 것을 인식하였다. 그리고 이에 대한 해법으로 현장자료와 최대한 비슷한 합성자료를 생성시켜 학습자료로 활용하는 방법을 제시하는데 큰 의의가 있다. 그러나 이를 위해서는 속도 구조나 요소파 등 현장자료에 대한 여러 사전 정보를 필수적으로 알아야 한다. 여기서 속도구조와 같은 사전 정보는 실제 현장에서 정확하게 추출하는 것은 어려우며 또한 사전 정보들을 바탕으로 정교한 모델링을 수행해 현장자료와 유사한 합성자료를 생성해야 하므로 훈련자료 생성에 매우 많은 시간과 노력이 요구된다. 또한 이렇게 훈련된 딥러닝 모델은 주어진 학습자료에 점진적 과적합(creeping overfitting)된 모델이어서 현장자료가 생성한 합성자료와 다를 경우 내삽 성능의 현저한 저하를 유발하게 된다. 이러한 점을 극복하려면 현장자료의 다양성을 포괄할 수 있는 다양한 특성을 지닌 합성자료를 생성해야 한다. 그러나 Fig. 2에서 보여준 것처럼 실제 현장자료에




Fig. 3. Panels (a) and (b) show one development data pair (the input and target shot profile, respectively), panel (c) presents the corresponding predicted data, and panel (d) shows the convergence diagram for L1 loss as a function of the epoch. The red dots and blue circles denote the L1 loss of the training set and the development set, respectively (Qu *et al.*, 2021).

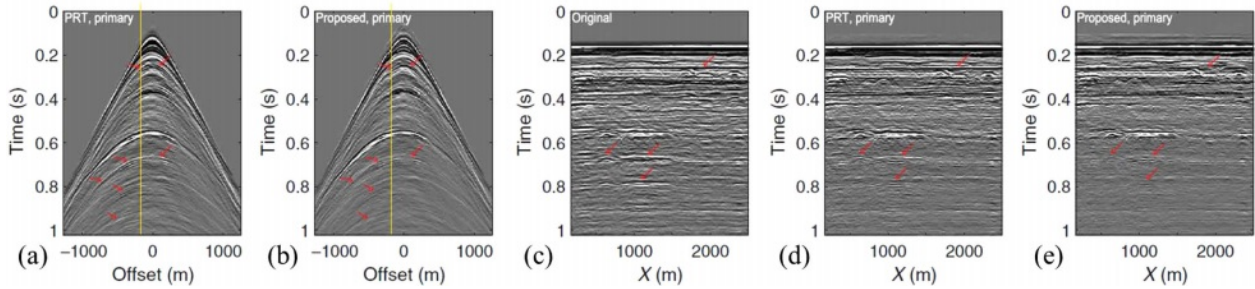


Fig. 4. Panels (a) and (b) show the estimated primaries based on the parabolic Radon transform (PRT)-reconstructed data and proposed workflow, respectively. Panel (c) presents the common-offset section of the input data (indicated by the yellow vertical line in Figure 4a), and panels (d) and (e) show the common-offset primary section of the PRT-reconstructed data and data reconstructed using the proposed workflow, respectively (indicated by the yellow vertical lines in Figures 4a and 4b) (Qu *et al.*, 2021).

서는 같은 지역에서 취득된 자료라도 가까운 벌림의 특성이 매우 다른 경우가 존재하므로 이러한 특성을 전부 반영하도록 하는 합성자료 생성은 매우 도전적이고 어려운 문제이다.

한편 Wang *et al.* (2022)는 Qu *et al.* (2021)에서의 추가적인 노력이나 비용을 줄이고자 현장자료 자체를 훈련자료로 활용하는 자기지도학습(self-supervised learning) 기반의 가까운 벌림 복구 방법을 제시하였다. 또한 가까운 벌림 자료 내삽 모델의 성능향상을 위한 자료 증대 기법으로 Fig. 5와 같은 이미 회전 기법을 제안하였다. Fig. 5에서 볼 수 있는 것처럼 제시한 새로운 자료증대 기법은 먼저 탄성과 모음을 하나의 이미지로 가정하고 이를 임의의 각도로 회전시킨다. 그 후 이로부터 패치(patch)를 추출하여 일종의 선형 시간차 보정(linear moveout correction)의 효과를 보일 수 있는 자료를 생성한다. 이렇게 추가로 증대한 자료와 현장자료를 임의의 손상시켜 가까운 벌림 자료를 모사한 자료를 이용하여 딥러닝 모델의 학습에 사용할 훈련자료를 구축한다. 이 연구에서는 수정된 U-Net 구조를 기본 구조(backbone architecture)로 채택하였고 이를

자기지도학습기반의 내삽 모델을 훈련에 사용하였다. 자기지도학습은 크게 두 단계로 구성된다. 제한적인 자료를 활용하여 모델의 학습 성능을 높이기 위해 목표 작업(target task)와 다른 선행 작업(pre-task)을 수행하고 해당 모델의 가중치(weight)를 목표 작업을 위한 선행 학습 모델(pre-trained model)로 사용하여 전이 학습(transfer learning)을 수행한다. 이때 선행 학습 모델의 가중치의 일부분을 동결(freeze) 시킨 상태로 학습을 진행하는 경우도 있다. 이 연구에서 자기지도학습을 위한 선행 작업은 규칙적인 빠짐을 내삽하는 것으로 정의하였다. 이를 위해 자료를 50% 규칙적으로 손상시켜 훈련자료를 생성하였고 그 후 모델 학습을 통해 규칙적인 트레이스 빠짐을 내삽하는 모델을 선행 학습 모델로 생성하였다. 그 후 앞서 자료 증대 기법과 현장자료 임의의 손상을 통해 생성해 놓은 훈련자료들을 입력자료로 하고 선행 작업을 통해 만든 선행 학습 모델을 사용하여 동일한 수정된 U-Net 구조에 전이 학습을 수행하였다. 이 단계에서는 선행 작업에 의해 훈련된 딥러닝 모델을 이용하여 미조정(fine-tuning)하여 최종적으로

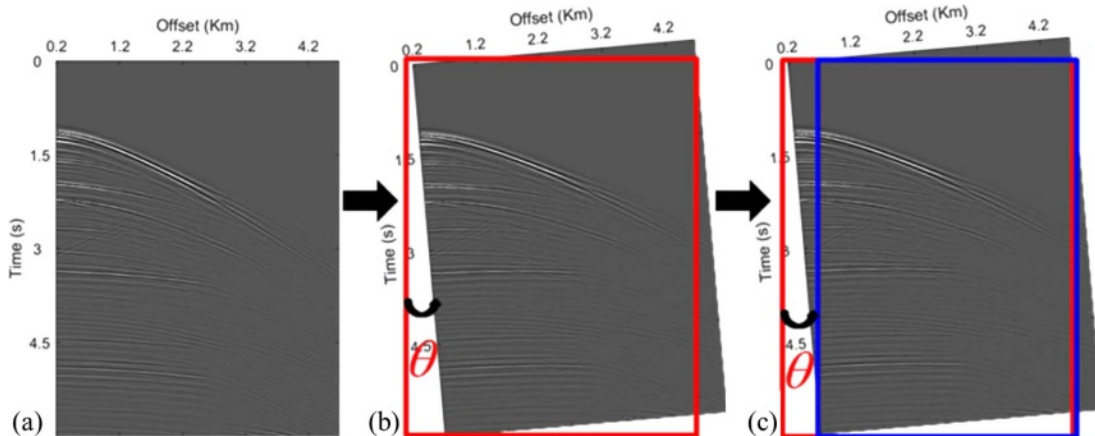


Fig. 5. Illustration depicting the generation of training data for the intelligent near offset reconstruction. Panel (a) indicates the common shot gather (CSG) with near-offset information unrecorded. Panel (b) presents a counterclockwise rotation of (a), and panel (c) indicates the truncation of (b) (Wang *et al.*, 2022).




Fig. 6. Near offset information recovery analysis of a specific validation record. Panel (a) shows the labeled complete data. Panel (b) indicates the seismic data with near-offset information unrecorded. Panel (c) represents the seismic data after the near-offset information recovery. Panel (d) shows the residual between (a) and (c) (Wang *et al.*, 2022).

목표 작업인 가까운 벌림을 내삽하는 모델을 도출하게 된다. Wang *et al.* (2022)의 연구에서는 가까운 벌림 빠짐 트레이스를 최대 8개를 내삽하는 기술을 제시하였고 Fig. 6에 그 결과를 도시하였다. Fig. 6a는 정답자료로 사용된 온전히 취득된 공통 송신기 모음 자료이고 Fig. 6b는 가까운 벌림 빠짐을 모사하기 위해 8개의 트레이스를 손상시킨 자료이다. Fig. 6c는 훈련된 모델을 적용하여 얻은 내삽 결과이고 Fig. 6d는 정답과 결과의 잔차를 보여준다. t-x 영역상에서의 결과 비교는 내삽이 잘 수행된 것으로 보이나 Fig. 6d에서 보이는 잔차들은 진폭 복구에 아쉬움을 보인다.

Wang *et al.* (2022)의 연구는 가까운 벌림 자료가 중간거리나 먼거리와 다른 신호의 특성을 가진다는 점에 착안하여 가까운 벌림 자료와 비슷한 특성의 다양한 훈련자료를 확보하기

위해 새로운 자료 증대 기법인 이미지 회전 기법을 도입했다는 점에서 의미가 있다. 또한 가까운 벌림에 대한 훈련자료의 부족을 자기지도학습 기법을 도입해 극복하고자 한 시도도 새로운 접근방법의 제안으로 의미가 있다. 하지만 이 연구에서는 Fig. 6a에서 보이는 것처럼 현장자료가 가까운 벌림까지 완전하게 취득되었다는 가정하에 수치 실험이 수행되었다. 일반적으로 딥러닝 기반의 트레이스 내삽 연구에서 조밀하게 혹은 완전하게 취득된 탄성과 모음을 정답자료로 활용하고 이를 임의 손상하여 목표자료의 빠짐 패턴을 모사하여 훈련자료로 활용하는 경우가 대부분이다. 따라서 이 연구의 실험 가정은 타당해 보일 수 있다. 그러나 앞서 기술한 대로 해양탄성과 탐사에서 가까운 벌림의 경우는 일반적으로 취득될 수 없기에 완전하게 취득된 정답자료가 있다는 가정이 성립하지 않게

된다. 즉, 이 연구에서는 실제로 존재하지 않는 가까운 벌림 자료를 존재한다는 가정하에 실험을 수행한 근본적인 문제가 존재한다. 또한, 제안한 자료증대 기법인 이미지 회전은 영거리 벌림(zero offset) 근처에서의 수평 이벤트를 반대 방향의 경사로 만들 수 있는 위험이 존재하여 실제로 학습에 어느 정도 도움이 될 수 있을지에 대해서는 보다 정량적인 고찰이 필요하다. 한편, 자기주도학습의 선행학습으로 사용한 규칙적인 트레이스 손상 복구 문제도 내삽이 아닌 외삽 그리고 규칙적인 빠짐이 아닌 큰 벌림 문제로 볼 수 있는 가까운 벌림 빠짐 문제의 선행학습으로 적합한 방법인가에 대한 연구도 더 논의가 필요하다. 그리고 앞서 언급한대로 가까운 벌림의 경우는 엄연하게 트레이스 외삽이 필요한 문제이므로 이를 위한 추가적인 연구가 필요한 상황이다.

가까운 벌림 모음 자료의 학습자료 활용이 외삽 성능에 미치는 영향

앞선 두 연구는 도전적인 가까운 벌림 빠짐 문제에 대한 해결법으로 새로운 방식의 자료 증대기법을 도입한 새로운 방법을 제시하였다. 두 연구에서는 가까운 벌림 빠짐의 최대 간격을 150 m ~ 200 m로 가정하고 최대 빠짐 트레이스 수를 8~12개, 약 10개의 연속적인 트레이스 빠짐으로 가정하여 실험을 진행하였다. 적은 수의 빠짐으로 보일 수 있지만 이는 실제 현장자료에서 극명하게 다른 특성을 보여준다. Fig. 7은 10개의 연속적인 트레이스 빠짐의 유무에 있어 학습에 사용되는 추출되는 패치가 서로 얼마나 다를 수 있는지를 보여준다. 그림에서 보이는 것처럼 단 10개의 트레이스 차이에 의해서 추출된 패치가 갖는 이벤트의 유무(Fig. 7의 파란색 화살표), 경사(Fig. 7의 검은색 화살표) 및 진폭의 연속적인 변화 특성 등

다양한 부분이 달라지고 이러한 특성의 차이는 훈련 모델의 성능에 영향을 끼치게 된다.

이러한 부분을 보다 명확히 보여주기 위해 이 섹션에서 우리는 현장자료 실험을 통해 가까운 벌림 모음자료가 학습에 사용된 경우와 그렇지 않은 경우의 가까운 벌림 자료의 외삽 성능이 얼마나 달라지는지에 대한 연구결과를 비교 분석하였다.

연구에 사용한 현장자료 및 딥러닝 모델

실험을 위해 사용한 현장자료는 Mobile Viking graben line 12 자료로 공공데이터(open data)이기 때문에 다양한 연구에 널리 활용되고 있는 자료이다(Madiba and McMechan, 2003). 이 자료는 1001개의 송신원이 기록되어 있고 각각의 송신원에 대해 120개의 수신채널(receiver channel)에 총 6초동안 0.004 초의 샘플링 간격으로 자료가 기록되어 있다. 여기서 송신기와 수신기 간격은 모두 25 m이다.

이 연구에서는 가까운 벌림 외삽을 위한 딥러닝 모델로 Park *et al.* (2021b)과 Park *et al.* (2022)를 참고하여 Fig. 8과 같은 개선된 형태의 U-Net 구조인 U-Net3+ (Huang *et al.*, 2020) 구조를 도입하였다. 일반적인 U-Net 구조는 낮은 단계의 상세 특성 맵(low-level detailed feature maps)과 높은 단계의 의미 특성 맵(high-level semantic feature maps)을 단순 스킵 연결(skip connection) 방식의 결합으로 연결되기 때문에 충분한 특성을 반영하기에 구조가 부족하다. U-Net3+는 다중 규모 특성(multi-scale feature)을 사용하여 상기의 문제를 효과적으로 완화시키는 구조로서 U-Net 구조의 인코더와 디코더 사이의 내부 연결 방식을 수정하여 전체 규모의 특성(full scale feature)을 반영한다. 또한 복합 손실 함수를 적용하여 학습하는 이미지 픽셀(pixel) 맵의 더 정확한 위치 정보와 테두리를 보장할 수 있게 하여 빠진 트레이스 복구에 있어 장점을 지닌다.

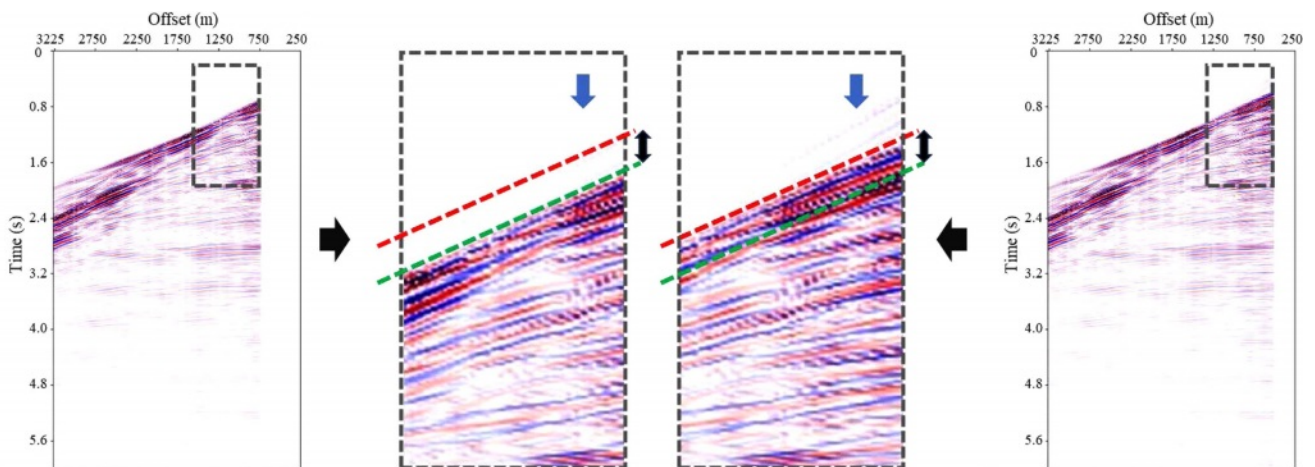
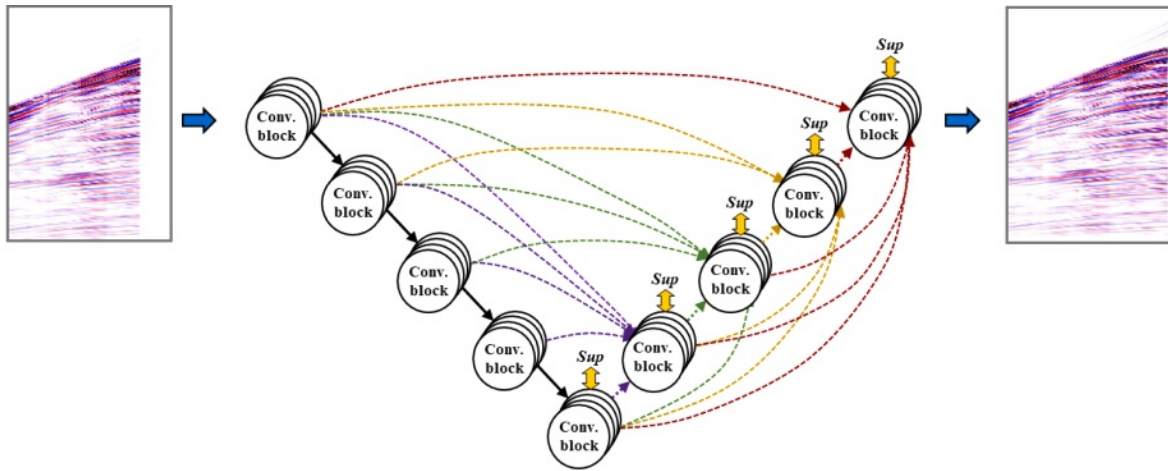


Fig. 7. Differences in near offset range show how the extracted patches used for training can differ in the presence or absence of 10 consecutive trace misses. As shown, gap of only 10 traces can change the nature of the event presence, slope, and amplitude of extracted patches, and differences in these characteristics will affect the performance of the training model.



: convolutional block (consists of convolutional layer, batch normalization, and activation function)
 : pooling layer
 : full scale dense skip connection
 : deep supervision

Fig. 8. Simple illustration of the proposed U-Net3+ architecture. .

딥러닝 모델 훈련 단계 및 외삽 결과

먼저 Wang *et al.* (2022)에서의 현장자료 실험처럼 가까운 벌림 자료가 학습에 사용되는지 유무에 따른 성능을 비교하기 위해서 동일한 U-Net3+ 모델과 매개변수를 사용하여 딥러닝 모델을 생성하였다. 그 후 훈련된 딥러닝 모델들을 가까운 벌림

모음자료가 포함된 학습자료와 그렇지 않은 학습자료인 두 가지 훈련자료로 각각 학습을 수행하였다. 훈련자료는 Fig. 9와 같은 공통 송신원 모음 자료들이 사용되었다. 여기서 최대 가까운 벌림 거리를 250 m로 가정하였고 그에 따라 가까운 벌림에서의 빠짐 트레이스 갯수는 10개이다. 먼저 첫번째 학습

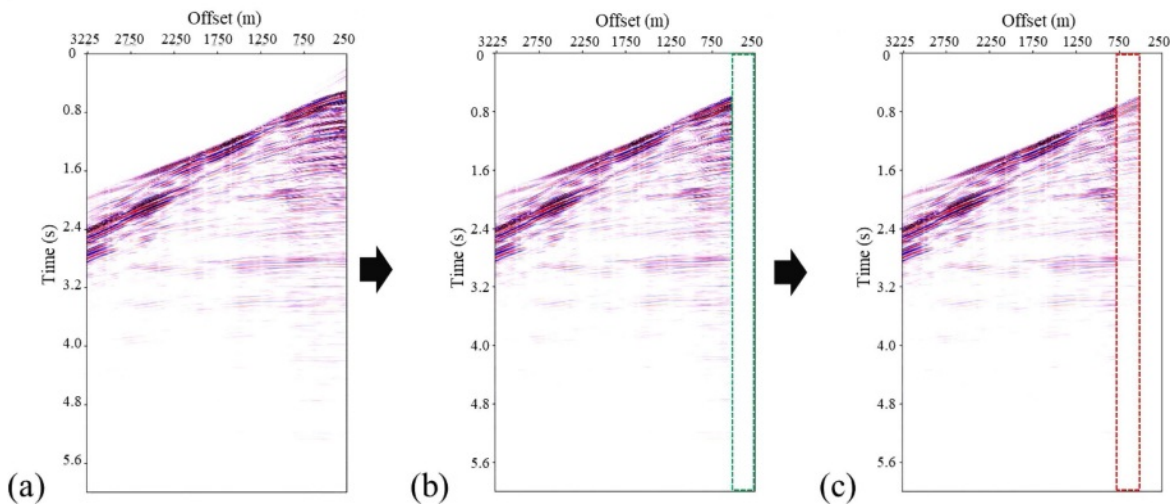


Fig. 9. Training and label data generation. Panel (a) shows the original fully sampled common shot gather (CSG). Panel (b) indicates decimated CSG for label data where 10 traces are missing in the green box, where the field situation is simulated with no near-offset data. Panel (c) indicates the decimated CSG from Figure 9(b) for training data. The red box corresponds to 10 consecutive traces of decimated data for simulating the near offset gap.

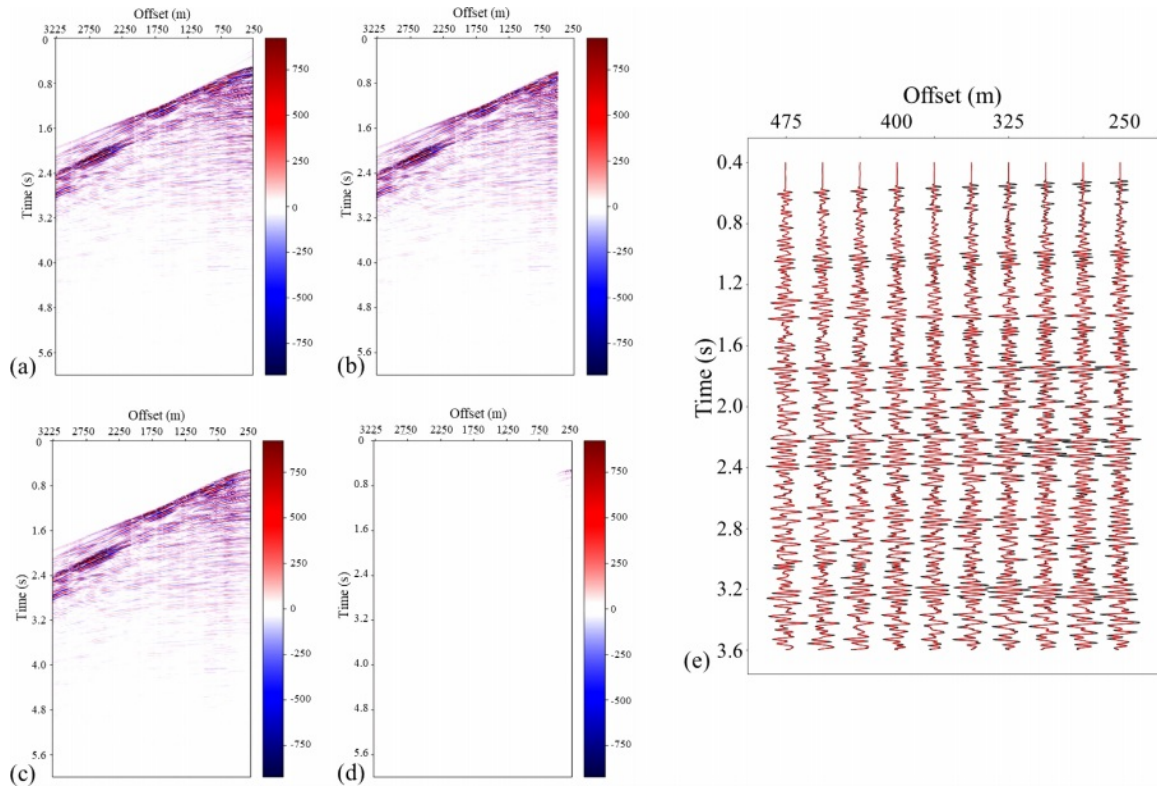


Fig. 10. Extrapolation results of the trained U-Net3+ on data where the ground truth for near offset gap (fully sampled common shot gather in Figure 9a). Panel (a) shows the label data. Panel (b) shows 10 traces of decimated data. Panel (c) presents the interpolation results of the trained model. Panel (d) indicates the difference between (b) and (c). Panel (e) shows the wiggle trace plots. The black and red indicate label data and extrapolation results, respectively.

모델인 가까운 벌림 모음자료가 학습에 사용되는 경우는 Fig. 9a와 같이 빠짐이 없는 자료에서 다양한 빠짐이 있는 자료들을 모사하여 추출된 패치들을 입력자료로 하여 학습이 진행되

었다. 이와는 달리 두번째 학습모델인 가까운 벌림 모음자료가 학습에 사용되지 않는 경우는 Fig. 9b와 같이 10개의 가까운 벌림 자료가 빠진 자료를 기반으로 다양한 빠짐이 있는 자료




Fig. 11. $f-k$ spectrum of each data. Panel (a) corresponds to the ground truth shown in Figure 10a. Panel (b) corresponds to the decimated data shown in Figure 10b. Panel (c) corresponds to the interpolation results shown in Figure 10c. Panel (d) indicates the difference between (a) and (c).

들을 모사한 후 이 자료들에서 추출된 패치들을 입력으로 하여 학습이 진행되었다. 학습 시 손실 함수는 구조적 유사지수 손실 함수를 사용하였고 ADAM 최적기를 이용하여 모델을 최적화하였다.

우리는 먼저 가까운 벌림 빠짐에 대해 정답이 존재하는 자료로 학습한 즉 첫번째 모델에 의해 외삽된 결과를 Fig. 10에 나타내었다. Fig. 10a는 정답자료로 사용된 공통 송신기 모음 자료이고 Fig. 10b는 10개 트레이스가 손상된 가까운 벌림 빠




Fig. 12. Amplitude spectrum of the summation of all traces in each common shot gather (CSG). Blue and orange correspond to the original and interpolated CSG, respectively.

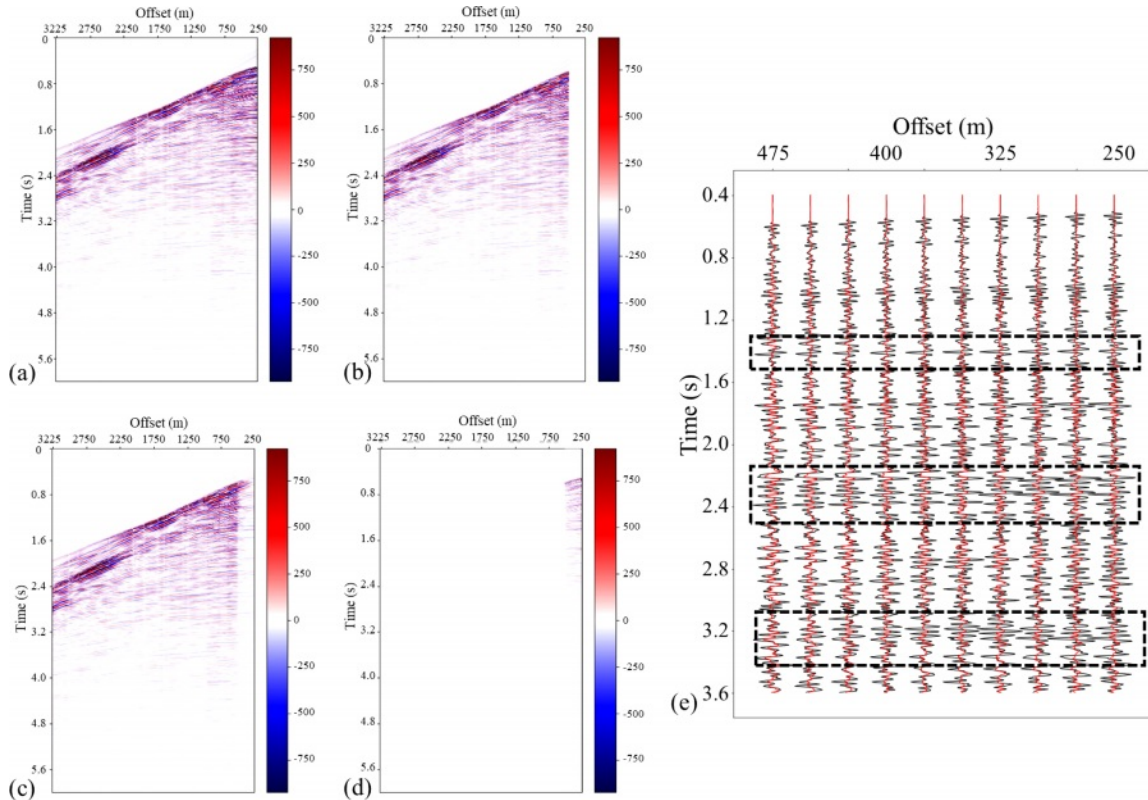


Fig. 13. Extrapolation results of the trained U-Net3+ on data with the near offset gap (shown in Figure 9b). Panel (a) shows the ground truth data. Panel (b) shows 10 traces of decimated data (label). Panel (c) presents the extrapolation results of the trained model. Panel (d) indicates the difference between (b) and (c). Panel (e) shows the wiggle trace plots. The black and red indicate label data and extrapolation results, respectively. Black boxes show poor prediction performance for coherent events.

집 자료이다. Fig. 10c는 외삽 결과이고 Fig. 10d는 정답과 외삽 결과와의 잔차를 보여준다. Fig. 10e는 내삽된 트레이스들(빨간색)과 정답 트레이스들(검은색)을 도시한 그림이다. Fig. 10e에서 보이는 것처럼 가까운 벌림 빠짐에 정답이 있다고 가정한 실험에서는 추가적인 자료 증대 기법의 적용 없이도 앞서 Wang *et al.* (2022)의 결과인 Fig. 6과 같이 만족할만한 내삽 결과를 보여준다. 이는 기존의 U-Net 모델에 비하여 성능이 개선된 U-Net3+ 모델의 학습 성능을 뒷받침하는 결과이기도 하다. 보다 정량적인 분석을 위해 이 연구에서는 $f-k$ 스펙트럼과 진폭 스펙트럼을 제시한다. Fig. 11은 보다 정량적인 분석을 위해 도시한 $f-k$ 스펙트럼을 보여준다. Fig. 11a와 11b는 각각 Fig. 10a와 10b에 상응하는 $f-k$ 스펙트럼이다. 그림에

서 보이는 것처럼 가까운 벌림의 10개 트레이스 제거 전 후에 $f-k$ 스펙트럼 상에서 주황색과 빨간색 화살표가 가리키는 두 부분에서 큰 차이점을 보이고 있다. Fig. 11c는 트레이스 내삽 후의 $f-k$ 스펙트럼을 보여주고 있으며 Fig. 11d는 원자료 11a와 내삽 결과 11c의 잔차를 보여준다. Fig. 11c와 11d에서 보이는 것처럼 첫번째 U-Net3+ 모델을 적용한 결과는 원자료의 스펙트럼처럼 완벽하게 트레이스의 진폭까지 복구된 것은 아니지만 Fig. 12의 진폭 스펙트럼상에서 확인할 수 있는 것처럼 적절한 내삽 성능을 보여주고 있다.

Fig. 13은 Fig. 9b처럼 가까운 벌림 빠짐에 대해 정답이 존재하지 않는다 가정하고 빠짐에 인접한 자료로만 학습한 두번째 모델에 의해 외삽된 결과를 보여준다. 내삽이 아닌 외삽의

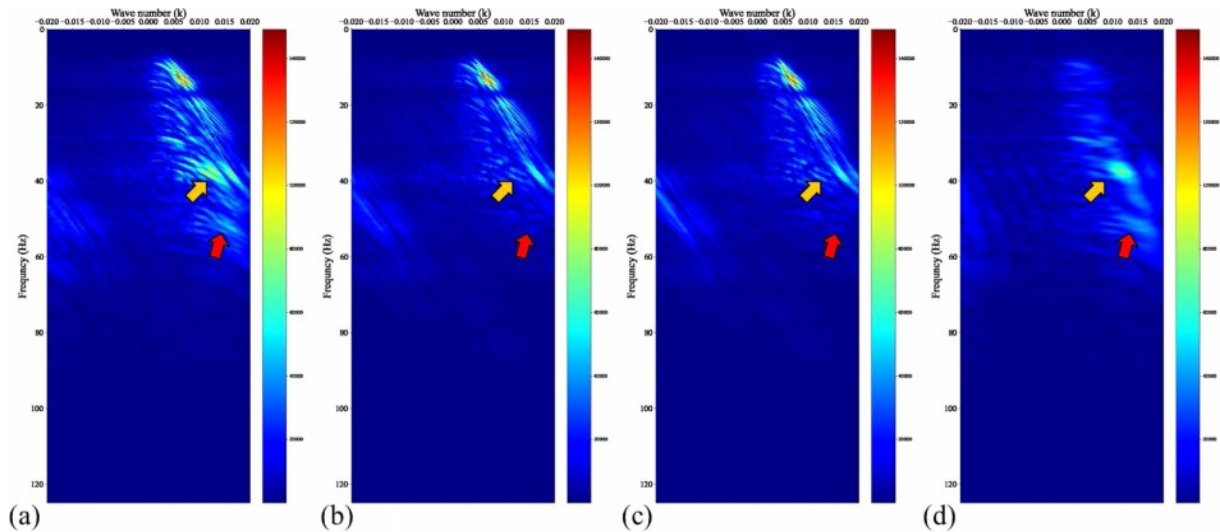


Fig. 14. $f-k$ spectrum of each data. Panel (a) corresponds to the ground truth shown in Figure 13a. Panel (b) corresponds to the decimated data shown in Figure 13b. Panel (c) corresponds to the extrapolation results shown in Figure 13c. Panel (d) indicates the difference between (a) and (c).




Fig. 15. Amplitude spectrum of the summation of all traces in each common shot gather (CSG). Blue and orange correspond to the original and extrapolated CSG, respectively.

영역에서는 Fig. 13에서 보이는 것처럼 이 경우에는 t-x 영역 상에서도 명확하게 트레이스 복구 성능이 저하된 것을 확인할 수 있다. Fig. 13e의 트레이스 비교 그림에서도 외삽된 트레이스들과 정답 트레이스들이 초기 1~2개의 트레이스 이후부터는 급격한 성능 저하를 보임을 알 수 있다. 또한 그림에 표시된 검은 박스 부분에서 보이는 것처럼 명확하게 보이는 연속적인 신호들을 혼란된 모델이 전혀 복구해내지 못하고 있다. 또한 Fig. 14의 $f-k$ 스펙트럼과 Fig. 15의 진폭 스펙트럼에서 보이는 것처럼 Fig. 11c와 11d의 결과와는 달리 두번째 U-Net3+ 모델은 복구한 트레이스의 진폭뿐만 아니라 신호의 특성까지 복구하지 못하는 것을 확인할 수 있다.

토의 및 결론

탄성과 영상화에 악영향을 끼치는 다중반사파를 효과적으로 제거하기 위해서는 해양 탐사 시 필연적으로 발생하는 가까운 벌림 빠짐을 해결해야 한다. 그러나 기존의 전통적인 가까운 벌림 빠짐 내삽 기술인 라돈변환 기반의 방법들은 가까운 벌림 빠짐의 독특한 특성과 어려움으로 인해 만족할만한 결과를 얻어내지 못하고 있었다. 이를 해결하기 위해 최근에는 기계학습을 이용한 트레이스 내삽기법의 접근법으로 가까운 벌림 빠짐 문제를 해결하려는 시도가 있었다. 그러나 이 연구에서는 우선 가까운 벌림 빠짐의 특성에 대해 면밀히 고찰하였고 이를 토대로 해당 문제는 트레이스 내삽이 아닌 외삽으로의 접근하는 것이 더 타당하다고 결론 지었다.

먼저 이 논문에서는 가까운 벌림 빠짐에 대한 기계학습 기반 방법으로 최근에 연구된 Qu *et al.* (2021)과 Wang *et al.* (2022)의 두가지 대표적인 방법에 대해 자세히 살펴보고 각 방법의 장점과 단점을 분석하였다. 두 방법 모두 가까운 벌림 빠짐에 대한 문제가 기존의 일반적인 내삽 문제와 다른 특성을 가지고 있다는 것을 시작으로 하여 이를 해결하기 위한 새로운 방법들을 제안하였으나 추가적인 개선이 요구된다. 먼저 Qu *et al.* (2021)의 방법의 경우 현장과 유사한 합성 자료를 생성하는데 요구되는 많은 시간 비용과 계산 비용을 효과적으로 줄일 수 있는 방법의 고안이 필요하고 현장의 요소파, 속도모델 등의 사전정보를 매 현장마다 새로이 알아내서 적용하는 방법을 대체할 수 있는 방법이 필요하다. 즉, 실제 현장에서의 적용성을 향상시킬 수 있는 방법이 필요하다. Wang *et al.* (2022)은 이러한 대안으로 공통 송신원 모음에 대해 이미지 회전을 통한 자료 증대를 제안했지만 수평한 이벤트가 역경사로 바뀔 수 있는 한계점에 대한 보완이 필요하다. 그리고 실제 현장에서는 가까운 벌림 자료가 존재하지 않아 학습자료로 사용이 불가능하다는 근본적인 문제 또한 남아있다. 이 논문에서는 가까운 벌림 자료의 부재가 외삽문제 해결에 미치는 중요성과 어려움을 현장자료 실험을 통해서 명확히 보여주었다.

기존의 연구들에 대한 장단점 분석과 수치실험을 통해, 가까

운 벌림 빠짐의 복구 성능 개선을 위해서는 정답이 없는 가까운 벌림을 효과적으로 외삽해 낼 수 있는 접근이 필요하다는 것을 알았다. 이를 위해서는 같은 현장이더라도 특성이 다르고 특히 다중반사파에 큰 영향을 받는 가까운 벌림의 특성을 잘 반영하여 모사할 수 있는 발전된 자료 증대 기술이 필요하다고 생각한다. 또한 트레이스 외삽 기법으로서 접근에 맞는 합리적이고 좋은 성능을 보일 수 있는 체계적인 작업체계(workflow)의 개발 혹은 도입이 필요하다. 또한 가까운 벌림 자료의 외삽이 SRME와 같은 자유면 다중반사파제거 외에도 잔여 다중반사파(residual multiple)과 같은 도전적인 문제 해결을 위한 기술로 발전하길 바라고 이러한 연구에 이 논문이 좋은 시발점이 될 수 있기를 바란다.

감사의글

이 논문은 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원과(No. 2021R1A2C2014315) 2022년도 정부(교육부, 산업통상자원부)의 재원으로 K-CCUS 추진단의 지원을 받아 수행된 연구입니다(KCCUS20220001, 온실가스 감축 혁신인재양성사업).

References

- Dou, T., Li, K., Duan, H., Li, T., Dong, L., and Huang, Z., 2023, MDA GAN: Adversarial-Learning-Based 3-D Seismic Data Interpolation and Reconstruction for Complex Missing, *IEEE Transactions on Geoscience and Remote Sensing*, **61**, 1-14. doi: 10.1109/TGRS.2023.3249476
- Dragoset, W., and Jeričević, Z., 1998, Some remarks on surface multiple attenuation, *Geophysics*, **63**(2), 331-789. doi: 10.1190/1.1444377
- Hargreaves, N., 2006, Surface multiple attenuation in shallow water and the construction of primaries from multiples, *SEG Technical Program Expanded Abstract 2006*, 2689-2693. <https://doi.org/10.1190/1.2370080>
- He, T., Wu, B., and Zhu, X., 2021, Seismic Data Consecutively Missing Trace Interpolation Based on Multistage Neural Network Training Process, *IEEE Geoscience and Remote Sensing Letters*, **19**, 1-5. doi: 10.1109/LGRS.2021.3089585
- Huang, H., Lin, L., Tong, R., Hu, H., Zhang, Q., Iwamoto, Y., Han, X., Chen, Y., and Wu, J., 2020, UNet3+: A full-scale connected unet for medical image segmentation, *arXiv*. <https://doi.org/10.48550/arXiv.2004.08790>
- Jia, Y., Yu, S., and Ma, J., 2017, What can machine learning do for seismic data processing? An interpolation application, *Geophysics*, **82**(3), V163-V177. <https://doi.org/10.1190/geo2016-0300.1>
- Kabir, M. M. N., and Verschuur, D. J., 1995, Restoration of missing offsets by parabolic Radon transform, *Geophysical Prospecting*, **43**, 347-368. <https://doi.org/10.1111/j.1365->

- 2478.1995.tb00257.x
- Kostov, C., de Melo, F. X., Raj, A., Zarkhidze, A., Cooke, A., Miers, G., and Bacon, J., 2015, Multiple attenuation for shallow-water surveys: Notes on old challenges and new opportunities, *The Leading Edge*, **34**(7), 760-768. doi: 10.1190/tle34070760.1
- Lopez, G. A., and Verschuur, D. J., 2015, Closed-loop surface-related multiple elimination and its application to simultaneous data reconstruction, *Geophysics*, **80**(6), V189-V199. <https://doi.org/10.1190/geo2015-0287.1>
- Ma, J., Wang, X., Gao, R., Zhang, X., Wang, Z., Wei, Y., Ma, J., Zhao, X., Huang, C., Jiang, S., Li, L., Yu, H., and Wang, H., 2017, Jingbian CCS project in China: 2015 update, *Energy Procedia*, **114**, p.5768-5782. <https://doi.org/10.1016/j.egypro.2017.03.1715>
- Madiba, G. B., and McMechan, G. A., 2003, Processing, inversion, and interpretation of a 2D seismic data set from the North Viking Graben, North Sea, *Geophysics*, **68**(3), 837-848. doi: 10.1190/1.1581036
- Mandelli, S., Lipari, V., Bestagini, P., and Tubaro, S., 2019, Interpolation and Denoising of Seismic Data using Convolutional Neural Networks, *arXiv*. <https://doi.org/10.48550/arXiv.1901.07927>
- Pan, S., Chen, K., Chen, J., Qin, Z., Cui, Q., and Li, J., 2020, A partial convolution-based deep-learning network for seismic data regularization¹, *Computers and Geosciences*, **145**, 104609. doi: 10.1016/j.cageo.2020.104609
- Park, J., Choi, J., Seol, S. J., Byun, J., and Kim, Y., 2021b, A method for adequate selection of training data sets to reconstruct seismic data using a convolutional U-Net, *Geophysics*, **86**(5), V375-V388. <https://doi.org/10.1190/geo2019-0708.1>
- Park, S.-E., Kim, D.-S., Oh, J.-W., Min, D.-J., and Kim, B.-Y., 2021a, Review of the Applicability of 4D Time-Lapse Seismic Monitoring System Based on Frequency-Domain Reverse-Time Migration to Pohang CCS Demonstration, *Journal of the Korean Society of Mineral and Energy Resources Engineers*, 394-407. (In Korean with English abstract). <https://www.jksmer.or.kr/articles/article/KGW2/>
- Park, J., Yeoh, Z., Seol, S. J., and Byun, J., 2022, Seismic data interpolation using attention-based deep learning, *83rd EAGE Annual Conference 2022*, (1), 1-5. <https://scholar.google.co.kr/citations?user=2b-At00AAAAJ&hl=ko>
- Park, M.-H., Lee, C. S., Kim, B.-Y., Kim, J.-H., Kim, K. J., and Shinn, Y. J., 2018, Preliminary results of the pre-injection monitoring survey at an offshore CO₂ injection site in the Yeongil Bay, *The Journal of Engineering Geology*, **28**(2), p.247-258. (In Korean with English abstract). <https://koreascience.kr/article/JAKO201821142173409.page>
- Qu, S., Verschuur, E., Zhang D., and Chen, Y., 2021, Training deep networks with only synthetic data: Deep-learning-based near-offset reconstruction for (closed-loop) surface-related multiple estimation on shallow-water field data, *Geophysics*, **86**(3), A39-A43. <https://doi.org/10.1190/geo2020-0723.1>
- Trad, D., 2003, Interpolation and multiple attenuation with migration operators, *Geophysics*, **68**(6), 2043-2054. <https://doi.org/10.1190/1.1635058>
- Wang, B., Han, D., and Li, J., 2022, Missing shots and near-offset reconstruction of marine seismic data with towered streamers via self-supervised deep learning, *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-9. doi: 10.1109/TGRS.2022.3172145
- Wang, B., Zhang, N., Lu, W., and Wang, J., 2019, Deep-learning-based seismic data interpolation: A preliminary result, *Geophysics*, **84**(1), V11-V20. <https://doi.org/10.1190/geo2017-0495.1>
- Wang, Y., Lu, W., and Li, Y., 2023, A self-adaptive antialiasing framework for seismic data interpolation, *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-12. doi: 10.1109/tgrs.2023.3272644
- Xu, Z., Sopher, D., Juhlin, C., Han, L., and Gong, X., 2018, Radon-domain interferometric interpolation for reconstruction of the near-offset gap in marine seismic data, *Journal of Applied Geophysics*, **151**, 125-141. doi: 10.1016/j.jappgeo.2018.02.012
- Yu, J., and Wu, B., 2022, Attention and Hybrid Loss Guided Deep Learning for Consecutively Missing Seismic Data Reconstruction, *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-8. doi: 10.1109/TGRS.2021.3068279
- Zhang, D., and Verschuur, E., 2019, Integration of closed-loop surface-related multiple estimation and full wavefield migration for shallow water, *81st Annual International Conference and Exhibition*, 1-5. <https://doi.org/10.3997/2214-4609.201900779>