

자가지도 학습 기반 Deep DIC를 활용한 인장시험의 전체 변형률장 추정

(Deep DIC-Based Full-Field Strain Estimation Using Self-Supervised Learning for Tensile Testing)

정현경*, 유경호**, 오카치테디냐키야*, 조슈아나이아베리*, 남현빈***, 김판구****
(Hyeonkyeong Jeong, Kyungho Yu, Okatchteddy Nyankieya, Joshua Nyaberi, Hyunbin Nam, Pan koo Kim)

요약

기존의 딥러닝 기반 디지털 이미지 상관법(Digital Image Correlation, DIC) 방법들은 주로 합성 스펙클 데이터로 학습되어 실제 실험 환경에서 도메인 차이로 인한 성능저하가 발생할 수 있다. 본 연구에서는 Deep DIC를 기반으로, 변위-변형률 간 물리적 일관성을 학습과정에 통합한 자가지도 파인튜닝 프레임워크를 제안한다. 핵심 기여는 StrainNet의 예측 변형률과 DisplacementNet 수치미분 변형률 간 일치를 강제하는 변형률 일관성 손실의 도입으로, 두 네트워크 간 상호 제약 매커니즘을 통해 물리적으로 일관된 변형률 추정을 가능하게 한다. 1,094장의 실제 인장 시험 이미지에 대해 ZEISS 상용 소프트웨어를 기준으로 정량 평가를 수행한 결과, 합성 데이터만으로 학습된 기준 모델 대비 평균절대오차(MAE)가 14.9%에서 2.85%로, 평균제곱근오차(RMSE) 또한 16.52%에서 3.42%로 줄어들고 상관계수 0.9917을 달성하였다. 이는 변형률 일관성 제약이 자가지도 파인튜닝의 정확도를 크게 향상시키며, 합성-실험 도메인 차이를 효과적으로 완화함을 보여준다.

■ 중심어 : 디지털 이미지 상관법 ; 자가지도 학습 ; 변형률 일관성 ; 인장 시험

Abstract

Deep learning -based DIC methods trained on synthetic speckle data often suffer performance degradation on real experimental environments due to the domain gap. This study proposes a self-supervised fine-tuning framework based on Deep DIC, introducing a strain consistency loss that enforces agreement between StrainNet predictions and numerically differentiated strains from DisplacementNet. Quantitative evaluation on 1,094 real tensile test images shows that the proposed method reduces MAE from 14.9% to 2.85% and RMSE from 16.52% to 3.42%, achieving a correlation coefficient of 0.9917 against ZEISS commercial software, demonstrating that strain consistency constraint effectively mitigates the synthetic-to-real domain gap.

■ keywords : Digital image correlation ; self-supervised learning ; strain consistency ; tensile testing

1. 서론

재료 표면의 변형 상태를 넓은 영역에 걸쳐 측정하는 것은 현대 실험역학의 중요한 과제 중 하나이다. 복잡한 하중이 가해지는 환경에서 재료가 얼마나, 어떤 방향으로 변형되는지를 수치적

으로 파악하기 위해서는 전체 영역의 변위와 변형률 분포를 동시에 측정할 수 있는 기술이 필요하다. 이를 위한 다양한 광학 측정 기술 가운데 디지털 이미지 상관법(Digital Image Correlation, DIC)은 시편 표면에 도포된 스펙클 패턴의 움직임을 추적하여 비접촉 방식으로 전

* 준회원, 조선대학교 컴퓨터공학과

** 정회원, 조선대학교 시융합연구원

*** 정회원, 조선대학교 융합·접합과학공학과

**** 정회원, 조선대학교 IT융합대학 시소프트웨어학부(컴퓨터공학전공)

본 연구성과물은 2024년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업(No. RS-2024-00463238)

접수일자 : 2026년 04월 02일

게재확정일 : 2026년 05월 12일

수정일자 : 2026년 05월 04일

교신저자 : 김판구 e-mail : pkkim@chosun.ac.kr

체 영역의 변위를 측정하는 방법으로 널리 활용되고 있다[1]. DIC는 카메라 광학 특성과 이미지 처리 수준에 의해 측정 정밀도가 결정되므로, 접촉식 센서에서 발생하는 시편 간섭 문제가 없다는 장점이 있다[2].

전통적인 부분집합 기반 DIC는 참조 이미지의 작은 사각형 영역과 변형 이미지의 탐색영역 사이에서 정규화된 상호 상관값을 최대화하는 방식으로 변위를 추정한다[3]. 다항식 형상 함수를 적용한 Newton-Raphson 반복 최적화를 통해 픽셀보다 작은 단위의 변위까지 측정할 수 있으며, OpenCorr와 같은 공개 소프트웨어를 통해 연구 현장에서 폭넓게 활용되고 있다[4]. 그러나 이 방법에는 몇 가지 구조적 한계가 존재한다. 부분집합을 크게 설정하면 측정 정확도는 높아지지만 세밀한 공간 정보를 잃게 되고, 반대로 작게 설정하면 공간정보는 풍부해지지만 정확도가 떨어지는 상충관계가 있다[5]. 또한 초기에 변위를 잘못 추정할 경우 반복 계산이 올바른 값으로 수렴하지 못하고 발산하는 문제가 발생한다. 특히 파단 직전 나타나는 국부 수축(넥킹, Necking) 구간에서는 부분집합 내 변형이 저차형상 함수로 표현할 수 있는 범위를 초과하여 측정 신뢰도가 급격히 저하된다[6, 7].

딥러닝 기술의 발전은 이러한 한계를 극복하기 위한 새로운 접근법을 제시하고있다[8-10]. 합성 스펙클 이미지 쌍과 정확한 변위 레이블을 활용하는 지도학습 방식은 반복 최적화 과정을 학습된 회귀함수로 대체함으로써, 빠른 추론 속도와 높은 정확도를 동시에 달성하였다[11]. 그 중 Deep DIC는 변위 추정을 담당하는 ResNet 기반 DisplacementNet과, 이미지 쌍으로부터 변형률 텐서를 직접 출력하는 StrainNet을 결합한 종단간(end-to-end) 구조를 채택하였다[12]. 이를 통해 수치 미분 단계를 생략하여 노이즈 증폭 문제를 구조적으로 해소하였다. 그러나 이러한 지도 학습 방법들은 합성 훈련 데이터와 조명 조건, 카메라 응답 특성, 표면 거칠기 등의 실제 실험

환경의 차이로 인해 실제 실험 이미지에 대한 일반화 성능이 제한되는 문제를 공통적으로 안고 있다[13].

레이블 데이터에 대한 의존성을 줄이기 위해 측정 이미지 자체로부터 훈련 신호를 구성하는 자기지도 및 비지도 학습 기반 DIC 방법들이 제안되었다. 이 방법들의 핵심 원리는 광도 일관성 가정에 있다. 즉 올바르게 추정된 변위장으로 참조 이미지를 변환하면 실제 변형 이미지와 밝기 분포가 일치해야 한다는 물리적 전제를 손실함수로 활용하는 것이다. 초기 비지도 CNN-DIC 연구와 UnDIC-Net 등 광도 일관성 기반 자기지도 방법들이 제안되었으나 변형률과 변위 사이의 물리적 제약을 학습 과정에 직접 반영하지 않고 있다[14, 15].

본 연구는 이러한 문제를 해결하기 위해, 변형률 일관성 제약을 손실함수에 직접 내재화한 자기지도 DIC 프레임워크를 제안한다. 제안방법은 Deep DIC의 DisplacementNet 구조를 기반으로, 레이블이 없는 실제 인장 실험 이미지 시퀀스에 대해 파인튜닝을 수행한다. 훈련 목적 함수는 광도 재구성 손실, 변형률 일관성 손실, 평활화 손실로 구성되며, 특히 변형률 일관성 손실은 물리 정보신경망(Physics-Informed Neural Network, PINN)의 원리에서 착안하여 변위장과 변형률장의 물리적 정합을 학습 과정에서 직접 강제한다[16]. 상용 DIC 소프트웨어인 ZEISS INSPECT의 측정 결과를 기준으로 삼아 1,094 프레임의 실험 이미지에서 성능을 정량적으로 평가하며, 탄성 및 소성 변형 구간에서의 예측 정확도와 국부 수축 구간에서의 측정 한계를 분석한다.

본 연구의 구성은 다음과 같다. 2장은 전통 부분집합 DIC, 지도학습 기반 딥러닝 DIC, 비지도 광학흐름 추정, 물리정보 신경망에 관한 관련 연구를 정리한다. 3장에서는 제안 방법의 네트워크 구조, 복합 손실함수, 훈련 절차를 기술한다. 4장에서는 실제 인장 실험 데이터에 대한 결과와 ZEISS INSPECT와의 비교분석을 제시한다. 5장

에서 결론과 향후 연구 방향을 논의한다.

II. 관련 연구

1. 전통 부분집합 기반 DIC

부분집합 기반 DIC는 참조 이미지의 부분집합과 변형 이미지의 탐색 영역 사이에서 영평균 정규화 상호 상관(Zero-mean Normalized Cross-Correlation, ZNCC)값을 최대화하고, 1차 또는 2차 다항식 형상 함수로 초기화 된 Newton-Raphson 반복 최적화를 통해 수렴 해를 구하는 방식으로 작동한다[3]. ZNCC의 영평균 정규화는 조명이 공간적으로 불균일한 환경에서도 안정적인 패턴 매칭을 가능하게 하며, 조명 제어가 어려운 실제 인장 시험 환경에서 특히 중요한 특성이다. OpenCorr와 같은 공개 소프트웨어를 통해 연구 현장에서 폭넓게 활용되고 있다[4]. 그러나 부분집합 크기와 측정 정확도-공간 측정 밀도 간의 상충 관계, 수렴 실패에 따른 데이터 손실, 큰 변형 영역에서의 형상함수 한계는 딥러닝 기반 대안을 탐색하게 하는 실질적인 동기가 된다.

2. 지도학습 기반 딥러닝 DIC

딥러닝을 DIC에 최초로 적용한 연구는 합성 스펙클 쌍과 변위 레이블로 학습된 CNN이 기존 DIC에 필적하는 정확도를 훨씬 짧은 추론 시간에 달성 할 수 있음을 보였다[11]. Yang et al.이 제안한 Deep DIC는 DisplacementNet과 StrainNet을 결합한 end-to-end 구조로, 변위 미분에 의존하지 않는 직접 변형률 예측을 통해 소성 변형 및 국부 변형 영역에서의 정확도를 개선하였다 [12]. 이외에도 측정 환경에 특화된 다양한 지도학습 구조들이 제안되었다. RAFT-DIC는 순환 반복 광학흐름 구조에서 다운샘플링 연산을 제거하여 작은 변위 측정 정확도를 향상시켰으며[17], R3-DICNet는 재귀 잔차 정제 방식으로 큰 변형 조건에서의 안정성을 확보하였다

[18]. 이들 지도학습 방법의 공통적인 한계는 합성 훈련 데이터 의존성과 실제 실험 환경으로의 전이 성능 저하이다.

3. 자기지도 및 비지도 학습 기반 DIC

최근 컴퓨터 비전 분야의 비지도 광학 흐름 추정연구에 착안하여, 변위 레이블 없이 측정 이미지 자체를 훈련 신호로 활용하는 DIC 기법들이 제안되었다[19]. 이러한 방법들은 광도 일관성 가정을 손실 함수의 핵심 목적 함수로 채택한다. 초기 비지도 CNN-DIC 연구는 평균 제곱 오차와 상관 계수 기반 광도 손실의 조합이 효과적임을 입증하였으며[14], UnDIC-Net은 패치 기반 영평균 정규화 합 제곱 차이(Zero-mean Normalized Sum of Squared Differences, ZNSSD) 손실과 점진적 변형 추정을 통해 수백 픽셀 규모의 큰 변위 조건에서 안정적인 수렴을 달성하였다[15]. 기존 자기지도 방법들의 공통된 한계는 변형률은 예측 변위장의 수치 미분으로만 계산되기 때문에, 두 물리량 사이의 운동학적 일관성이 손실 함수 차원에서 명시적으로 제약되지 않는다는 점이다.

4. 물리 정보 신경망의 고체역학 적용

Raissi et al. 이 제안한 물리 정보 신경망(PINN)은 지배 방정식과 같은 물리 법칙을 손실 함수에 제약 조건으로 포함시켜, 충분한 실험 데이터 없이도 물리적으로 타당한 결과를 학습 할 수 있는 프레임워크를 제시하였다[16]. 고체역학 분야에서는 이 원리를 활용하여 적은 수의 변형 측정 데이터로부터 재료의 구성 파라미터를 역추정하거나, 미측정 영역의 응력 분포를 계산한 사례들이 보고되었다[20]. 본 연구에서 제안하는 변형률 일관성 손실은 이 개념을 DIC에 적용한 것으로, 지배 방정식을 직접 포함하는 PINN과는 달리 변위-변형률 간의 운동학적 관계에 한정된 물리 제약을 적용한 것이다.

5. Deep DIC 구조 및 본 연구와의 관계

Deep DIC는 참조 및 변형 이미지를 2채널로 입력받아, 4단계의 해상도 수준에서 스킵 연결과 전치 합성곱 디코더를 통해 원본 해상도의 변위 맵을 산출하는 DisplacementNet을 제안하였다 [12]. 이와 결합된 StrainNet은 이미지 쌍으로부터 직접 변형률 텐서를 도출하는 인코더-디코더 구조를 통해 수치 미분 과정의 노이즈 문제를 구조적으로 개선하였다. 3만6천 쌍의 합성데이터로 사전 학습된 이 모델은 밀리초 수준의 빠른 추론 속도를 보이며, 미학습 실험 데이터에 대해서도 우수한 성능을 보인다. 본 연구에서는 두 네트워크의 구조를 그대로 유지하되, 지도학습 손실 함수를 물리 정보 자기지도 손실로 교체하여 레이블 없는 실제 인장 시험 이미지에 대한 전체 가중치 파인튜닝을 수행한다.

III. 제안 방법

1. 전체 구조

제안 방법의 전체 구조는 그림 1과 같다. 연속된 두 프레임(참조 이미지 I_1 , 변형 이미지 I_2)을 2채널로 합쳐 DisplacementNet과 StrainNet에 동시에 입력한다. DisplacementNet은 픽셀 단위 변위장(u, v)을 출력하고, StrainNet은 변형률 텐서(exx, eyy, exy)를 직접 출력한다. 두 네트워크의 출력은 세 가지 손실함수를 통해 공동으로 최적화된다.

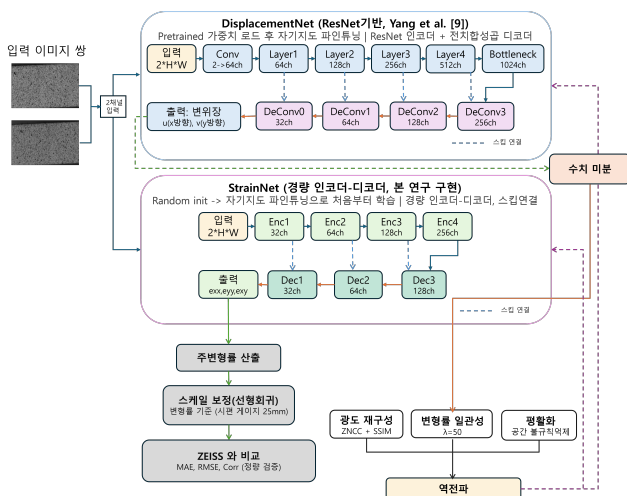


그림 1. 제안방법의 전체 구조.

추론 단계에서는 StrainNet의 출력으로부터 주 변형률을 산출하고, 인장시험기의 공칭 변형률을 기준으로 선형 스케일 보정을 수행한 뒤, ZEISS의 측정 결과와 비교하여 정량 검증한다. 기존 Deep DIC가 합성 데이터 기반 지도학습 손실만 사용한 것과 달리, 제안 방법은 실제 이미지 기반 자기지도 손실로 전체 구조를 파인튜닝하며, 스케일 보정과 검증을 학습과 분리하여 수행한다는 점이 핵심적인 차이이다.

2. 네트워크 구조

DisplacementNet은 ResNet기반 인코더 (FeatureResNet)와 전치 합성곱 디코더 (SegResNet)로 구성된다. 인코더는 2채널 입력을 받아 6단계의 특징 맵을 추출하며, 디코더는 스킵연결을 통해 원본 해상도의 2채널 변위 맵을 출력한다. 총 파라미터 수는 약 4,900만 개이며, 합성 데이터로 사전 학습된 가중치를 초기값으로 사용한다. StrainNet은 경량 인코더-디코더 구조로 구성된다. 인코더는 4단계로 특징을 압축하고, 디코더는 스킵 연결을 통해 3채널 (exx, eyy, exy) 변형률 맵을 원본 해상도로 복원한다. StrainNet은 별도의 pretrained 가중치 없이 자기지도 파인튜닝 과정에서 처음부터 학습된다. 이는 기존 Deep DIC의 StrainNet이 합성 데이터 기반 지도학습만으로 학습된 것과 대비된다. 학습 데이터에서 학습된 변형률 예측기는 실제 실험 환경의 광학 특성과 노이즈 분포를 충분히 반영하지 못할 가능성이 있으므로, 본 연구에서는 StrainNet에 한해 사전 학습을 사용하지 않고 변위장과의 운동학적 일관성 제약 하에서 실험 데이터에 직접 적응하도록 공동 학습을 수행하였다.

3. 손실함수

전체 손실함수는 다음의 식 (1)과 같이 광도 재구성 손실, 변형률 일관성 손실, 평활화 손실의 가중 합으로 구성된다.

$$L_{total} = L_{photo} + \lambda \cdot L_{strain} + L_{smooth} \quad (1)$$

광도 재구성 손실은 DisplacementNet이 예측한 변위장으로 참조이미지를 워핑(Warping)한 결과와 변형 이미지와 일치하도록 유도하며, ZNCC와 구조적 유사도(Structural Similarity Index Measure, SSIM)의 조합으로 계산된다. 평활화 손실은 변위장의 공간적 불연속성을 억제하는 정규화항이다. 본 연구의 핵심 기여는 변형률 일관성 손실의 도입이다. StrainNet이 직접 예측한 변형률과 DisplacementNet의 변위장을 수치 미분하여 얻은 변형률 사이의 평균 제곱 오차(Mean Squared Error, MSE)를 손실로 부과함으로써, 두 네트워크가 물리적으로 일관된 예측으로 수렴하도록 상호 제약한다. 기존 자기지도 방식은 변형률을 수치 미분의 후처리 결과로만 취급하여 학습 과정에 변형률 정보를 반영하고 있지 않으나, 제안 방법은 이를 손실함수 수준에서 명시적으로 제약한다는 점에서 근본적으로 다르다. 변형률 일관성 손실의 가중치는 MSE기반 출력 스케일이 광도 손실 대비 현저히 작으므로, 실효적 균형을 위해 $\lambda=50$ 으로 설정하였다.

4. 파인튜닝 절차

파인튜닝은 다음 순서로 수행된다. 먼저 Deep DIC 공식 저장소에서 제공하는 사전 학습된 Displacement 가중치를 로드한다. StrainNet은 무작위 초기화로 시작한다. 두 네트워크의 전체 가중치를 Adam 옵티마이저로 동시에 최적화하며, 초기 학습률은 1×10^{-5} 로 설정하였다. 총 30 에포크 동안 학습하며, 5 에포크마다 체크포인트를 저장한다. 추론 시에는 항상 첫 번째 프레임(참조 프레임)과 현재 프레임을 비교하는 절대 변위 방식을 사용한다. 이는 이전 프레임의 예측값을 계속 누적하는 방식에서 발생할 수 있는 오차 누적문제를 방지하기 위함 뿐 아니라 자기지도 학습에서 사용되는 광도 일관성 기반 손실이 참조 프레임을 기준으로 안정적으로 계산되도록 하기 위한 선택이기도 하다. 따라서 프레임을 순차적으로 이어 계산하는 기존 Deep DIC방법과 구별된다. 표 1에서는 기존 Deep DIC와 제안방

법을 비교하여 정리하였다.

표 1. 기존 Deep DIC와 제안 방법의 비교

| 항목 | 기존 Deep DIC | 제안 방법 |
|------------|-----------------|-------------------------------------|
| 학습 데이터 | 합성 스페클 3만6천쌍 | 실제 인장시험 이미지 1094쌍 |
| 정답 레이블 | 필요(변위 레이블) | 불필요(자기지도) |
| 손실 함수 | 지도학습 MSE | ZNCC + SSIM + 평활화 + 변형률 일관성 |
| 변형률 일관성 손실 | 없음 | 있음 (StrainNet ↔ DisplacementNet) |
| 추론 방식 | 순차 프레임 비교 | 참조 프레임 기준 절대변위 |
| 스케일보정 | 불필요(지도학습) | 시험기 공칭 변형률 기반 선형보정 |

5. 스케일 보정 절차

자기지도 학습은 광도 일관성에 기반하므로, 예측된 변형률의 상대적 경향은 정확히 추적하나 절대 스케일의 복원에는 구조적 한계가 있다. 이를 보완하기 위해 인장 시험기에서 측정된 크로스헤드 변위와 게이지 길이(25 mm)로부터 산출한 공칭 변형률을 기준으로 선형 스케일 보정을 수행한다. 이는 DIC 측정과 독립적인 기계적 측정값이므로 자기지도 학습의 원칙과 상충하지 않으며, 별도의 레이블이 아닌 단위 변환에 해당한다. 다만 본 절차는 인장 시험기의 기계적 측정값에 의존하므로, 시험기 데이터가 제공되지 않는 환경에서는 적용이 제한된다. 순수 이미지 데이터만으로 절대 스케일을 복원하기 위해서는 시편 형상 정보로부터 픽셀-물리 단위 변환 계수를 직접 검출하거나, 카메라 캘리브레이션 정보를 사전 지식으로 활용하는 접근이 가능하며, 이는 향후 연구 과제로 남긴다.

IV. 실험

1. 실험 데이터

본 연구에서 사용한 데이터는 인장 시험기에 장착된 카메라로 촬영한 스페클 패턴 이미지 시퀀스이다. 실험 환경은 그림 2와 같으며, 촬영된 이미지 시퀀스의 대표 프레임은 그림 3에 나타



그림 2. 실제 인장 시험 촬영 환경



그림 3. 실제 인장 시험에서 얻어진 스펙클 패턴 이미지 시퀀스의 대표 프레임

내었다. 시편은 사각형 시편(두께 0.94 mm, 폭 6.00 mm)을 사용하였으며, 시험 속도는 1.26 mm/min 으로 변위 제어 방식으로 수행되었다. 총 1,094장의 TIFF 이미지(약 1초 간격)와 0.1초 간격의 하중-변위-변형률 CSV데이터가 수집되었다. 변형률 범위는 0%에서 최대 약 91%에 이르며, 마지막 프레임(frame 1094)에서 파단이 발생하였다. 모든 이미지는 128×128 픽셀로 리사이징하여 네트워크에 입력하였다.

2. 학습 결과

제안 모델($\lambda = 50$)의 학습 손실은 초기값에서 시작하여 약 10 에포크 이후 안정적으로 수렴하였으며, 최종 손실 약 0.0146에 도달하였다. 각 모델의 손실 함수 구성이 상이하므로 절대 손실값의 직접 비교는 적절하지 않으며, 성능 비교는 ZEISS 기준 정량 지표를 통해 수행한다. 표 2의 제거 연구(Ablation Study) 결과는 각 손실 함수의 기여를 보여준다. 광도 손실만 적용한 경우(상관계수, Corr 0.8213)에 비해 변형률 일관성 손실을 추가하면 상관계수가 0.9459로 상승하며, 가중치를 적절히 조정($\lambda = 50$)했을 때 0.9917까

표2. Ablation Study (동일 선형 보정 후 비교)

| 방법 | MAE(%) | RMSE(%) | Corr |
|--------------------------------|---------|---------|--------|
| Pretrained only | 14.19 | 16.5228 | 0.7825 |
| +Photometric | 11.7816 | 15.1405 | 0.8213 |
| +Smooth | 15.3946 | 17.9382 | 0.7369 |
| +Strain ($\lambda = 0.2$) | 7.3491 | 8.6135 | 0.9459 |
| +Strain ($\lambda = 50$, 제안) | 2.8515 | 3.4218 | 0.9917 |

지 도달하였다. 이는 변형률 일관성 손실이 두 네트워크 간 상호 제약 매커니즘으로 작용하여 변형 추적 정확도를 크게 향상시킴을 입증한다. 평활화 손실은 단독 추가 시 오히려 상관계수가 하락(0.7369)하였는데, 이는 인장 시험 특성상 국부 수축 구간에서 변형률이 좁은 영역에 급격히 집중되는 비균일 분포를 갖기 때문으로, 일정한 강도의 평활화 제약이 낮은 변형률 영역의 노이즈를 억제하는 동시에 높은 변형률 집중 영역의 실제 신호까지 억제한 것으로 판단된다. 이러한 현상은 변형률 분포 특성에 따라 평활화 강도를 적응적으로 조절하는 손실 함수 설계로 완화 가능성이 있으며, 이는 향후 연구를 통해 검증해 나갈 계획이다. 최종 제안 방법은 스케일 보정 후 MAE 2.85%, RMSE 3.42%, 상관계수 0.9917을 달성하였다. 표 2의 Pretrained only 행은 합성 데이터로만 학습된 원본 Deep DIC 모델을 동일 실험 데이터에 그대로 적용한 결과로, 제안 방법은 이 기준 대비 MAE를 약 5분의 1수준으로 감소시켰다. 다만 기준 모델은 합성-실험 도메인 차이로 인해 실제 이미지에서 낮은 초기 성능을 보이므로, 본 비교는 파인튜닝의 도메인 적응 효과를 중심으로 해석되어야 한다. 본 연구의 비교는 동일 네트워크 구조 내에서 학습 전략의 차이를 통제된 결과이며, 측정 원리가 상이한 전통 부분집합 DIC(Open Corr등)와의 교차 검증은 제안 방법의 일반성을 보다 폭넓게 입증하기 위한 후속 연구 방향으로 남긴다. 그림 4는 5개 대표 프레임에 대한 원본 시편 이미지, u 변위장, 정량 비교

를 위해 StrainNet의 출력으로부터 주 변형률을 산출한 주변형률 맵을 시각화한 것이다. u 변위장은 프레임이 진행됨에 따라 최대 약 2픽셀 수준의 변화를 보이며, 파단 직전 프레임에서 오른쪽 파단부에 변위가 집중되는 패턴이 관찰된다. 전체 구간에 걸쳐 시편 내부는 낮은 변형률(파란색)을 유지하고 경계부에서 높은 변형률(빨간색)이 집중되는 패턴은 순수 인장 시험의 물리적 특성과 부합한다.

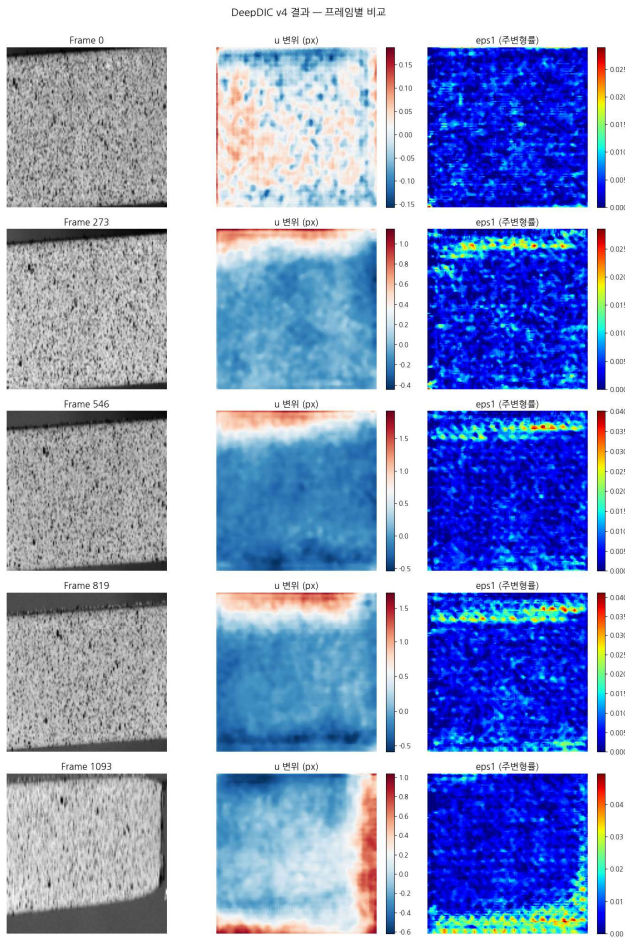


그림 4. 대표 프레임의 시편 내부 영역에 대한 시각화.

V. 결론

본 연구는 합성 데이터로 사전 학습된 Deep DIC모델을 레이블 없는 실제 인장 시험 이미지에 적용시키기 위한 자기지도 파인튜닝 프레임워크를 제안하였다. 제안 방법의 핵심은 변위장의 수치미분과 StrainNet의 직접 예측이 일치하도록 강제하는 변형률 일관성 손실에 있으며, 이를 통해 DisplacementNet과 StrainNet이 상호 제약 하

에 물리적으로 정합된 예측을 학습하도록 유도하였다. 이는 변형률을 변위의 수치 미분 결과로만 산출하던 기존 자기지도 접근의 구조적 한계를 보완한 것이다. 아울러 광도 기반 자기지도 학습에 내재된 절대 스케일 모호성은 인장시험기에서 독립적으로 기록되는 공칭 변형률을 기준으로 한 선형 보정을 통해 해소하였다. ZEISS를 기준으로 한 정량 검증에서 제안 방법은 기준 모델 대비 MAE를 14.19%에서 2.85%로, RMSE를 16.52%에서 3.42%로 감소시키고 상관계수 0.9917을 달성하여, 자기지도 파인튜닝이 합성-실험 도메인 차이를 효과적으로 완화할 수 있음을 뒷받침하였다. 다만 현재의 정량 평가는 공간 평균 변형률의 시간적 추이에 한정되어 있으므로, 국부 변형 개시 및 파단 직전 프레임에서 제안 방법과 ZEISS 측정 결과 간의 픽셀 단위 오차 분포를 분석하는 국부 정밀 검증은 향후 연구에서 다루고자 한다. 계산 효율성 측면에서 제안 모델은 DisplacementNet 약 50.84M 파라미터로 구성되며, 단일 GPU(NVIDIA RTX A5000) 환경에서 128×128 입력 기준 단일 프레임의 추론 시간은 평균 10.30 ms(약 97 FPS)로 측정되었다. 이는 본 연구의 촬영 간격(약 1초) 대비 충분히 빠른 처리 속도로, 실시간 처리 성능에 해당하나, 고속 카메라 기반 동적 변형 측정 응용을 위해서는 추가적인 모델 경량화가 요구된다. 한편 제안 방법의 변형률 일관성 손실은 변위장 미분 가능성을 전제하므로, 균열이나 파단과 같은 불연속 변형 영역에서는 제약의 유효성이 감소할 수 있으며, 본 연구의 실험에서도 파단 직전 프레임에서 예측 정확도가 연속 변형 구간 대비 저하되는 경향이 관찰되었다. 후속 연구에서는 별도의 스케일 보정 없이 절대 변형률을 직접 추정할 수 있는 학습 구조의 설계, 시편 내부 균일 변형 영역에 대한 추적 성능 개선, 전통 부분집합 기반 DIC 및 타 계열 자기지도 DIC 기법과의 교차 검증을 통한 일반성 입증 그리고 합성-실험 간 도메인 격차의 원인을 체계적으로 규명하는 방향으로 프레임워크를 확장할 계획이다.

REFERENCES

- [1] Schreier, H., Ortu, J.-J., Sutton, M. A., *Image correlation for shape, motion and deformation measurements: Basic concepts, theory and applications*, Springer, 2009.
- [2] Pan, B., Xie, H., et al., Two-dimensional digital image correlation for in-plane displacement and strain measurement: a review, *Measurement Science and Technology*, 20, 6, 062001, 2009.
- [3] Pan, B., Xie, H., Wang, Z., Equivalence of digital image correlation criteria for pattern matching, *Applied Optics*, 49, 28, 5501-5509, 2010.
- [4] Jiang, Z., OpenCorr: An open source library for research and development of digital image correlation, *Optics and Lasers in Engineering*, 165, 107566, 2023.
- [5] Atkinson, D. J., van Rooyen, M., Becker, T. H., An artificial neural network for digital image correlation dynamic subset selection based on speckle pattern quality metrics, *Strain*, 60, 4, e12471, 2024.
- [6] Iadicola, M. A., Augmented use of standard mechanical testing measurements for sheet metal forming: digital image correlation for localized necking, *AIP Conference Proceedings*, 1567, 1, 2013.
- [7] Yu, L., Pan, B., The errors in digital image correlation due to overmatched shape functions, *Measurement Science and Technology*, 26, 4, 045202, 2015.
- [8] 유경호, 김형주, 김정인, 전찬준, 김판구, "확산모델의 미세조정을 통한 웹툰 생성연구," *스마트미디어저널*, 제12권, 제7호, 76-83쪽, 2023년. Kyungho Yu, Hyungju Kim, Jeongin Kim, Chanjun Chun, Pankoo Kim, "A Study on the Generation of Webtoons through Fine-Tuning of Diffusion Models," *Smart Media Journal*, Vol. 12, No. 7, pp. 76-83, Aug. 2023.
- [9] 왕흥요, 유경호, 김판구, "조류 피해 예방시스템의 객체 탐지 모델 성능향상 기법 연구," *스마트미디어저널*, 제14권, 제8호, 73-80쪽, 2025년. Xinyao Wang, Kyungho Yu, Pankoo Kim, "A Study on Performance Enhancement Techniques for Object Detection Models in Bird Collision Prevention Systems," *Smart Media Journal*, Vol. 14, No. 8, pp. 73-80, Aug. 2025.
- [10] 유태웅, 서다솜, 김민우, 이슬기, 오일석, "가시성을 표시한 사과 검출 데이터셋과 적응형 히트맵 회귀를 이용한 딥러닝 검출," *스마트미디어저널*, 제12권, 제10호, 19-28쪽, 2023년. Tae-Woong Yoo, Dasom Seo, Minwoo Kim, Seul Ki Lee, Il-Seok Oh, "Apple detection dataset with visibility and deep learning detection using adaptive heatmap regression," *Smart Media Journal*, Vol. 12, No. 10, pp. 19-28, Nov. 2023.
- [11] Boukhtache, S., et al., When deep learning meets digital image correlation, *Optics and Lasers in Engineering*, 136, 106308, 2021.
- [12] Yang, R., et al., Deep DIC: Deep learning-based digital image correlation for end-to-end displacement and strain measurement, *Journal of Materials Processing Technology*, 302, 117474, 2022.
- [13] Pan, B., Digital image correlation for surface deformation measurement: historical developments, recent advances and future goals, *Measurement Science and Technology*, 29, 8, 082001, 2018.
- [14] Wang, Y., et al., Unsupervised CNN-Based DIC for 2D Displacement Measurement, *arXiv preprint*, arXiv:2306.02234, 2023.
- [15] Yang, J., Feng, Y., Wang, L., Efficient and robust deformation measurement based on unsupervised learning, *Measurement*, 242, 115908, 2025.
- [16] Raissi, M., Perdikaris, P., Karniadakis, G. E., Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations, *Journal of Computational Physics*, 378, 686-707, 2019.
- [17] Pan, B., Liu, Y., User-independent, accurate and pixel-wise DIC measurements with a task-optimized neural network, *Experimental Mechanics*, 64, 8, 1199-1213, 2024.
- [18] Yang, J., Qian, K., Wang, L., R3-DICnet: an end-to-end recursive residual refinement DIC network for larger deformation measurement, *Optics Express*, 32, 1, 907-921, 2023.
- [19] Tian, L., et al., Unsupervised learning of optical flow with CNN-based non-local filtering, *IEEE Transactions on Image Processing*, 29, 8429-8442, 2020.
- [20] Haghghat, E., et al., A physics-informed deep learning framework for inversion and surrogate modeling in solid mechanics, *Computer Methods in Applied Mechanics and Engineering*, 379, 113741, 2021.

 저 자 소 개

**정현경(준회원)**

2015년 조선대학교 애니메이션 학과
학사 졸업.

2025년~ 조선대학교 일반대학원
컴퓨터공학과 석사과정.

<주관심분야 : 딥러닝, 컴퓨터비전,
객체인식>

**남현빈(정회원)**

2009년 울산대학교 첨단소재공학과
학사 졸업.

2012년 울산대학교 첨단소재공학과
석사 졸업.

2020년 부산대학교 재료공학과 박사
졸업.

<주관심분야 : 에너지 소재, 극저온
물성, 상변태 거동, 이종재 접합>

**유경호(정회원)**

2017년 조선대학교 컴퓨터공학과
학사 졸업.

2019년 조선대학교 컴퓨터공학과
석사 졸업.

2023년 조선대학교 컴퓨터공학과
박사 졸업.

2025년 ~ 조선대학교 AI융합연구원
연구교수

<주관심분야 : 생성형 AI, 자연어 처리>

**김관구(정회원)**

1994년 서울대학교 컴퓨터공학과 박
사 졸업.

2007년~현재 조선대학교 컴퓨터공학
과 교수

<주관심분야 : 지능형 정보처리, 시맨
틱 웹, 온톨로지, 자연어처리, 데이터
마이닝 등>

**Okatch Teddy Nyankieya(준회원)**

2024년 Pioneer International
University 정보기술 학사 졸
업.

2025년~ 조선대학교 일반대학원
컴퓨터공학과 석사과정.

<주관심분야 : 생성형 인공지능,
컴퓨터비전>

**Joshua Nyaberi(준회원)**

2024년 Pioneer International
University 정보기술 학사 졸
업.

2025년~ 조선대학교 일반대학원
컴퓨터공학과 석사과정.

<주관심분야 : 생성형 인공지능,
디지털 이미지 상관법, 컴퓨터비전>