

# Tensile Properties Estimation Method Using Convolutional LSTM Model

Hyeon-Joon Choi\*, Dong-Joong Kang\*

## Abstract

In this paper, we propose a displacement measurement method based on deep learning using image data obtained from tensile tests of a material specimen. We focus on the fact that the sequential images during the tension are generated and the displacement of the specimen is represented in the image data. So, we designed sample generation model which makes sequential images of specimen. The behavior of generated images are similar to the real specimen images under tensile force. Using generated images, we trained and validated our model. In the deep neural network, sequential images are assigned to a multi-channel input to train the network. The multi-channel images are composed of sequential images obtained along the time domain. As a result, the neural network learns the temporal information as the images express the correlation with each other along the time domain. In order to verify the proposed method, we conducted experiments by comparing the deformation measuring performance of the neural network changing the displacement range of images.

▶ Keyword: Deep learning, Convolutional LSTM, Displacement measurement, Tensile test and Image processing, Sequential images, Regression model

## 1. Introduction

기존의 인장 시험은 스트레인 게이지 및 물리센서를 시편에 접촉식으로 부착하고 시편에 인장력을 가해 재료의 특성을 시편에 인장력을 가해 재료의 인장 특성을 측정하는 것이다. 하지만 이러한 방법은 인장력에 대한 시험편의 순수 변형 외에도 측정을 위해 부착하는 센서의 부착물 내부의 저항 변화가 측정의 정밀도에 악영향을 미친다. 뿐만 아니라 인장력이 주어짐에 따른 시편과 센서의 온도 변화로 인해 야기되는 측정오차 또한 측정 성능을 저해하는 요인이다. 때문에 최근 비접촉으로 수집된 영상 데이터를 활용하여 재료의 인장 특성을 측정하는 방법들이 소개되고 있다. 이는 기존의 방법들과는 달리 센서를 시편에 부착하지 않음으로써 물리적인 제약 없이 시편의 변형 행태를 그대로 관측할 수 있다는 장점이 있다. 이에 본 논문에서는 카메라를 통해 얻은 영상 정보에 딥 러닝 기술을 적용해 시험편의 인장특성을 추정하는 방법을 제시한다. 시편에 인장력이 주어지면 시간에 따라 변형이

일어나고, 이 변형 특성은 카메라를 통해 취득된 영상에 나타난다는 사실은 자명하며 시각적으로 관측이 가능하다. 때문에 본 논문에서는 이러한 시편의 변형 특성을 잘 대변하는 데이터 생성모델을 제시하였다. 또한 주어진 영상에서 이러한 특성을 잘 해석하기 위한 딥 러닝 기반의 모델을 설계하고, 생성된 데이터를 활용하여 학습 및 검증을 진행하였다.

데이터 생성모델은 시편에 실제 인장력이 주어졌을 때의 행태를 잘 표현하기 위해 순차적 기하변환을 적용하였다. 시편의 변형은 인장력이 주어지는 방향으로 일어나며, 이는 시간이 지남에 따라 순차적으로 발생한다. 때문에 우리는 시편 영상에 임의의 파라미터의 기하변환을 적용하였다. 기하변환은 영상을 좌우 및 상하 방향으로의 이동, 영상의 규모 변화 및 전단 변형을 포함한다. 우리의 생성모델은 영상 이동 파라미터의 값만을 바꿔가며 순차적 변형 영상을 생성한다. 데이터 생성 모델에 대한

\* First Author: Hyeon-Joon Choi, Corresponding Author: Dong-Joong Kang

\* Hyeon-Joon Choi (hoorse11@pusan.ac.kr), School of Mechanical Engineering, Pusan National University

\* Dong-Joong Kang (djikang@pusan.ac.k), School of Mechanical Engineering, Pusan National University

Received: 2018. 10. 30, Revised: 2018. 11. 16, Accepted: 2018. 11. 23.

This work was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government(MSIT) (No.2016R1A2B4007608), National IT Industry Promotion Agency (NIPA) grant funded by the Korea government (MSIT) (No.S0602-17-1001)

자세한 내용은 2.1장에 설명되어 있다.

본 논문에서는 시계열 영상을 입력받아 유의미한 값을 추론하는 딥 러닝 기반의 회귀모델을 제안하였다. 이때 신경망의 입력은 생성된 시편의 시계열 영상이며, 이는 일련의 컨볼루션 장단기 기억 층을 거치며 입력된 영상의 위치정보 및 시간축에 따른 연속성 정보를 압축된다. 이때 컨볼루션 장단기 기억 층은 기존의 장단기 기억 층에 컨볼루션 층 연산을 적용한 개념으로, 2차원 영상의 연속성으로부터 압축된 정보를 추출하는 데에 훨씬 강력한 성능을 보인다. 압축된 정보는 완전 연결 층으로 이루어진 두 개의 회귀 모델로 연결되며, 각 모델은 입력 영상을 생성할 때 사용된 기하변환 파라미터 값을 회귀하도록 학습된다. 제안된 신경망의 학습원리 및 구조에 대한 자세한 설명은 2.2장에 기술되어 있다.

## II. Related works

DIC(Digital image correlation)[1] 방법은 연속된 두 장의 디지털 영상 패턴을 인식하고, 지정된 픽셀의 위치적 변위 및 변형 패턴을 추정하는 광학 계측법이다. 주어진 두 영상의 관심 영역을 지정해두면, 첫 번째 영상의 해당 영역에 표현된 영상의 패턴이 두 번째 영상에 지정된 영역 내 어디에 위치하는지를 탐색함으로써 영상이 픽셀 수준에서 얼마나 변형되었는지 측정하는 방법이다. 이 기술은 컴퓨터와 영상 취득 장치 발달과 함께 미세 변량 측정이 요구되는 다양한 분야에 성공적으로 적용되어 왔다. 논문 [2]는 DIC 방법을 재료의 인장시험에 적용한 대표적인 사례이다. [2]의 저자는 이 방법을 사용하여 재료의 인장 특성을 추정하는 방법을 제시 하였다. 박막 시편에 인장력이 가해지는 동안 변형이 일어나는 시편의 영상을 취득하고, DIC 방법을 이용해 인장 방향 및 인장 수직 방향의 변형량을 측정하여 재료의 포아송 비를 일정 오차범위 내로 측정하였다. 이를 통해 영상 데이터를 이용하였을 때 인장시험으로부터 시편의 특성에 대한 합리적인 추론이 가능함을 확인할 수 있었다. 그러나 DIC 방법은 두 장의 영상만을 이용하여 변형량을 측정하는 방법이므로 순간적으로 인장력에 따른 진동 등의 요인으로 인해 취득된 영상에 이상 변형이 발생하는 경우 미세한 오차가 발생한다. 또한 알고리즘을 한번 구동할 때에 변형을 탐색하기 위한 관심영역 및 파라미터를 지정해주어야 하는데, 지정된 설정을 벗어나는 변형이 관측되는 경우 측정 정확도가 확연히 떨어지게 된다. 반면 본 논문에서는 단일 모델만으로도 다양한 범위의 변형을 측정할 수 있는 딥 러닝 기반의 접근법을 제시한다.

최근에는 인공지능 기술의 획기적인 발전과 함께 이러한 영상인식의 문제를 기계학습의 한 분야인 딥 러닝으로 풀어보고자 하는 연구가 활발히 시도되고 있다. 특히 컨볼루션 신경망(Convolution neural network)[3]의 등장은 인공 신경망의 영상인식 기능을 대폭 향상시켰다. 컨볼루션 신경망은 1989년

LeCun[11]이 필기체 인식을 위해 제안한 구조로 컨볼루션 연산을 수행하는 컨볼루션 레이어(convolution layer)와 서브샘플링을 위한 풀링 레이어(pooling layer)가 반복하여 적층되는 구조를 가지고 있다. 일반적인 다층 신경망은 현재 레이어의 각 뉴런이 이전 볼륨의 모든 레이어와 연결되기 때문에 고차원 데이터인 이미지를 처리하기 위해서는 너무 많은 가중치를 필요로 하며, 연산이 비효율적이다. 반면 컨볼루션 연산에서는 레이어의 각 뉴런이 입력 볼륨의 로컬한 영역에만 연결된다. 이 연결되는 영역이 이미지 전체 영역을 처리하는 기존 신경망에 비해 이 영역에만 한정하여 필터가 연산을 하게 된다. 영상의 경우 특정 픽셀의 정보는 그 근처의 픽셀들과 높은 상관관계를 가지지만 주변으로 퍼질수록 그 영향이 줄어들게 되므로 영상 전체를 대상으로 하는 기존 신경망의 연산보다 효율적이다. 풀링 레이어는 특징맵의 차원을 축소하는 서브샘플링 역할을 한다. 컨볼루션 레이어와 마찬가지로 필터가 영상 위를 이동하면서 필터에 대응하는 수용영역에서 가장 큰 값 또는 평균값을 취한다. 이러한 연산을 통해 연산량을 줄이고, 중요한 정보만을 남김으로써 강하고 전역적인 특징을 추출해낼 수 있다.

장단기 기억 신경망(LSTM network)[4]은 시계열 데이터를 다루는 데에 강력한 성능을 보이는 딥 러닝 구조이다. 이 구조는 시계열 데이터를 입력받아, 그 데이터의 연속성으로부터 유의미한 값을 추론하도록 학습하는 알고리즘이다. 기존의 순환신경망(Recurrent neural network)의 경우 데이터의 시간축 차원이 커질수록 역전파시 그라디언트가 점차 줄어 학습능력이 크게 저하되는 문제가 발생하였다. 장단기 기억 신경망은 이를 극복하기 위해 고안된 구조이다. 기존의 상태값에 셀 상태값을 추가하여 출력단으로부터 그라디언트가 크게 소실되지 않고 입력단까지 잘 전달시키도록 설계되었다. 셀 내부에서는 3개의 게이트 연산이 이루어지며, 각 게이트는 다음과 같은 역할을 수행한다. 입력 게이트는 현재 입력된 데이터의 정보를 얼마나 기억할 지를 결정하고, 망각 게이트는 이전까지 입력된 데이터의 정보를 얼마나 잊을지 결정한다. 마지막으로 출력 게이트는 현재 셀에서 연산된 출력을 얼마나 내보낼지를 결정한다. 이 연산이 매 단계마다 셀 내부에서 연산이 이루어지고, 장단기 입력 데이터의 정보를 효과적으로 함축하게 되어 신경망의 성능을 향상시킨다.

논문 [5]은 시계열 영상 데이터로부터 의미를 추론하는 컨볼루션 장단기 기억 신경망(Convolutional LSTM network)을 소개한다. 컨볼루션 장단기 기억 신경망은 기존의 장단기 기억 신경망에 컨볼루션 층을 덧붙인 신경망으로, 기존 모델보다 시계열 영상 기반 추론에 훨씬 뛰어난 성능을 보인다. [5]의 저자는 이 모델을 기후를 예측하기 위한 모델을 설계하는 데에 사용하였으며, 합리적인 결과를 추론할 수 있었다. 논문 [6]은 또 3D 컨볼루션 모델이라는 또 다른 추론 알고리즘을 제안하였는데, 이는 기존의 [5]와 달리 장단기 기억 신경망을 사용하지 않고, 기존의 컨볼루션 연산을 활용하여 시계열 영상 데이터로부터 정보를 압축하였다. 제안된 모델의 입력은 기존의 2차원 벡터에 시간 축을 덧붙인 3차원 벡터가 된다.

### III. The Proposed Scheme

#### 2.1 Sample generation

##### 2.1.1 Principle of image sample generation using affine transformation

시편에 인장력이 작용할 때 탄성구간에서는 변형이 인장력에 비례하여 발생하는 탄성구간이 존재한다. 이 구간에서 인장력에 대한 변형은 시험편 영상을 상하 및 좌우로 이동변환시키는 것과 행태가 유사하다. 이때의 변환을 기하변환 식으로 표현하면 식 (1)과 같다.

$$I' = T(t_y, t_x) S(z_y, z_x), \quad (1)$$

$$T(t_y, t_x) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ t_y & t_x & 1 \end{pmatrix}, \quad S(z_y, z_x) = \begin{pmatrix} s_x & 0 & 0 \\ 0 & s_y & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

위 식에서  $t_x, t_y$ 는 영상을 이동시킬 픽셀거리를 가리키는 파라미터이며,  $s_x, s_y$ 는 영상을 몇 배 확대할 것인지를 조절하는 파라미터이다. 본 실험에서는 사용되는 픽셀보다 작은 단위만큼 영상을 기하변환 한다. 때문에 3차 스플라인 커브를 이용한 부하소 보간법(Sub-pixel interpolation)[7]을 사용한다. Fig. 1은 기하변환을 통해 영상 샘플을 생성하는 원리를 도식화한 것이다. Fig. 2은 원본영상과 임의의 시간 후의 영상 간의 차 영상[8]과 원본 영상과 기하변환 된 영상의 차 영상을 출력한 것이다. 출력된 영상을 살펴보면 변환된 영상의 패턴이 실제 인장된 영상의 패턴과 특성이 거의 유사함을 확인할 수 있다.

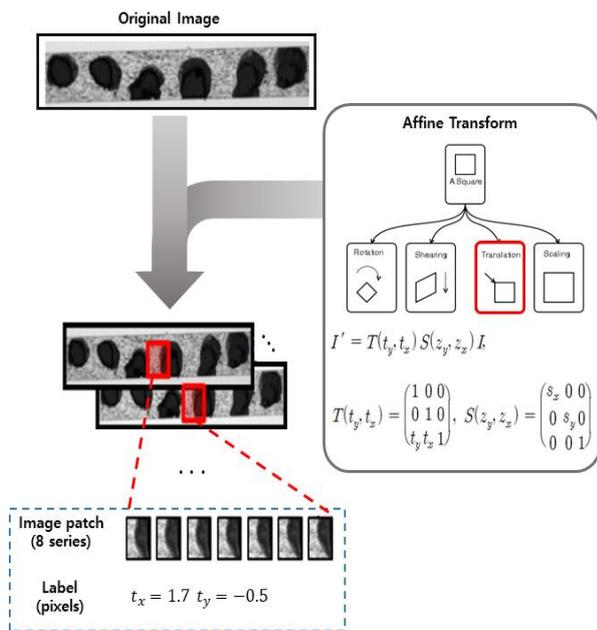
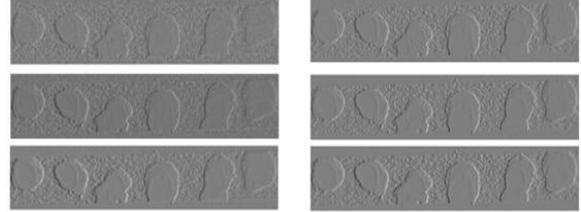


Fig. 1. Method for creating sequential image samples using affined transformation.



원본 이미지



실제 프레임들 간의 차영상

기하변환된 프레임들 간의 차영상

Fig. 2. Left: Difference images between real images, Right: Difference images between affine transformed images.

##### 2.1.2 Image sample generation

본 실험에서는 앞서 언급한 시험편 영상샘플에 기하변환을 활용하여 학습 영상샘플을 생성한다. 먼저 임의의 변환 파라미터  $t_x, t_y \in [-8.0, 8.0]$ 를 채택하여 실제 시험편 영상에 8차례 순차적으로 기하변환을 수행한다. 그리고 이 변형된 영상의 임의의 위치를 선정하여 부분영상을 추출한다. 이 과정을 학습샘플 (Training sample)에는 40,000회, 검증샘플 (Validation sample)에는 8,000회 반복하여 샘플을 구성한다. 이 때, 라벨 (Label) 값으로는 각 변환에 사용한 기하변환행렬의 파라미터  $t_x, t_y$  값이 사용된다.

#### 2.2 Convolutional LSTM neural network and Model design

##### 2.2.1 Principle of Convolutional LSTM model

컨볼루션 장단기 기억 신경망의 기본적인 전체 구조는 완전 연결 장단기 기억 신경망과 유사하다. 장단기 기억 층은 입력 값의 시간 축 분해능의 수만개의 셀(cell)로 이루어진다. 이때 일련의 셀 연산을 통해 연속된 데이터로부터 유의미한 값을 가지는 잠재 공간의 벡터로 압축한다. 여기서 기존의 완전 연결 장단기 기억 신경망의 경우 셀의 내부연산이 벡터와 벡터 사이의 선형연산으로 구성되어 있다. 그러나 컨볼루션 장단기 기억 신경망은 선형연산을 영상에 강력한 성능을 보이는 컨볼루션 연산으로 대체한다. 컨볼루션 장단기 기억 신경망의 내부 연산은 Fig. 3과 같다. 셀 내부의 연산이 컨볼루션 연산으로 이루어지기 때문에 셀의 출력 벡터 또한 다중채널 특징 맵의 형태로 나타난다.

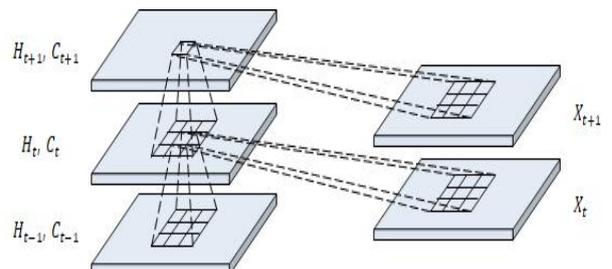


Fig. 3. Internal structure of Convolutional LSTM model.

장단기 기억 층의 각 셀에서는 3개의 게이트 연산을 수행한다. 먼저 입력 게이트  $i_t$ 는 이번 단계에서 입력 받은 입력  $X_t$ , 이전 단계 셀의 출력 값  $H_{t-1}$ ,과 상태 값  $C_{t-1}$ 을 이용하여 현재 셀의 상태 값을 얼마나 반영할 것인가를 나타내는 값을 연산한다. 이때  $W_{xi}$ ,  $W_{hi}$ 는 각각 이번 단계의 입력 값, 출력 값과 연산하는 컨볼루션 필터이며,  $W_{ci}$ 는 현재 셀의 상태 값과 요소 간 곱을 수행하는 가중치 벡터이다. 망각 게이트  $f_t$ 는 이전 단계의 상태 값을 얼마나 잊어버릴 것인가를 나타내는 값을 추론하며,  $i_t$ 와 마찬가지로  $X_t$ ,  $H_{t-1}$ ,  $C_{t-1}$ 을 이용하여 연산한다. 출력 게이트  $o_t$ 는 이번 상태 값을 얼마나 출력할 것인가를 나타내는 값이며,  $C_{t-1}$  대신  $C_t$ 를 반영하여 구해진다. 현재 셀의 상태 값  $C_t$ 은 앞서 구해진  $i_t$ 과  $f_t$ 를 이용하여 구해지며, 출력 값  $H_t$ 는  $\tanh(C_t)$ 에  $o_t$ 를 곱하여 얻어진다. 이렇게 구해진 셀의 출력 값  $H_t$ 은 첫 단계에서부터 이전 시간 단계까지 입력된 영상의 시간에 따라 변화되는 영상 간의 상호관계 정보를 나타내도록 학습된다. 각 장단기 기억 층의 셀 연산 식은 식 (2)로 표현이 가능하다.

$$\begin{aligned} i_t &= \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \circ C_{t-1} + b_i) \\ f_t &= \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \circ C_{t-1} + b_f) \\ o_t &= \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \circ C_t + b_o) \\ C_t &= f_t \circ C_{t-1} + i_t \circ \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \\ H_t &= o_t \circ \tanh(C_t) \end{aligned}$$

(2)

여기서  $\sigma$ 는 시그모이드(Sigmoid) 함수,  $\circ$ 는 행렬요소 간 곱, 그리고  $*$ 는 컨볼루션 연산을 가리킨다.

### 2.2.2 Model design

본 연구에서는 일정하게 변형되는 8장의 시계열 시험편 영상을 컨볼루션 장단기 기억 층에 순차적으로 입력하여 영상의 주요 특징 및 시계열 정보를 함축하도록 모델링하였다. 이때 컨볼루션 장단기 기억 층은 3개의 층으로 이루어져 있으며, 각 층은 시간 축에 따른 입력 영상 개수와 동일하게 8개로 구성되어 있다. 각 셀은 64개의 3x3 사이즈 필터로 컨볼루션 및 행렬 요소 간 곱 연산을 수행하며 특징 맵의 형태로 결과를 출력한다. 또한 마지막 장단기 기억 신경망의 마지막 셀의 출력에 전역 풀링 층(Global average pooling layer)을 연결하여 다중채널 특징 맵을 고정된 길이의 벡터로 압축한다. 이 압축된 벡터는 두 개의 회귀 모델로 나뉘어 입력된다. 각 모델은 두 개의 완전연결 층으로 구성되어 있으며, 입력 샘플 생성에 사용된 변환행렬의  $x$  및  $y$  방향 픽셀 변량을 나타내는 파라미터  $t_x$ ,  $t_y$ 를 회귀한다. 모델의 출력 단 활성화 함수로  $\tanh$ 를 사용하여 -1과 1 사이의 값을 출력하도록 하였다. 마찬가지로 데이터의 레이블 값  $t_x$ 와  $t_y$  또한

-1과 1 사이의 값으로 정규화 하였다. 이는 단순한 선형 활성화 함수가 경계 밖의 이상치 값으로 회귀하는 한계를 보완하기 위함이다. Fig. 4는 제시된 모델을 도시화한 것이다.

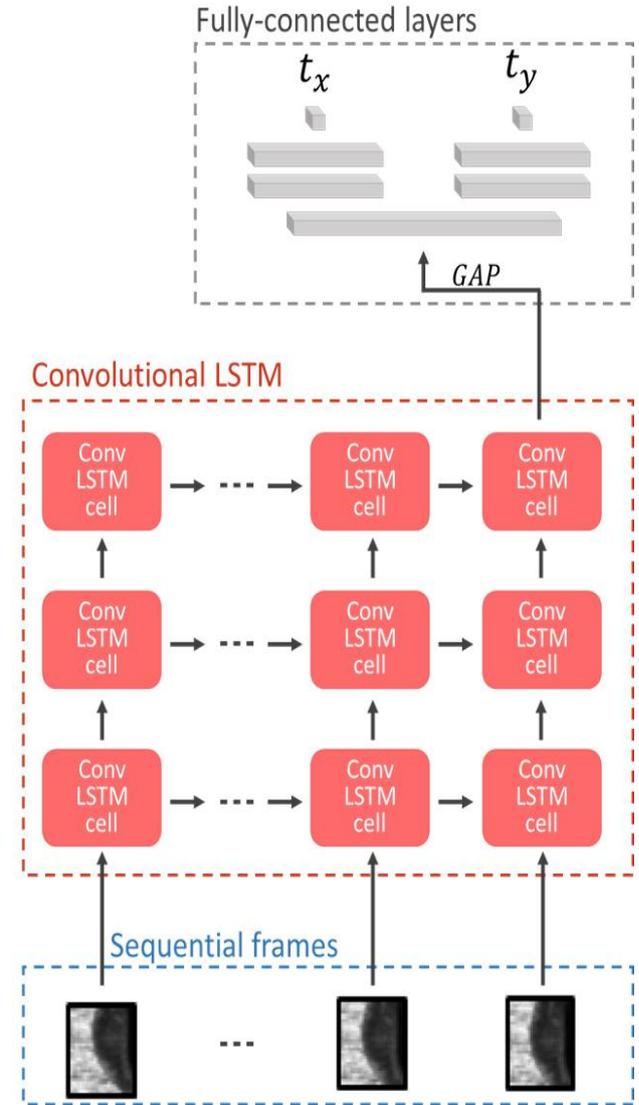


Fig. 4. Convolutional LSTM-based regression model for transformation parameters.

## IV. Experiment and Results

실험에서는 구성된 모델을 총 100 에포크(Epoch)동안 학습시켰으며 목적함수로는 회귀 모델의 학습에 효과적인 후버 손실 값[9]을 사용하였다. 최적화 방법은 제곱근평균제곱 전파법(Root mean square propagation)을 사용했다. 학습률은 초기 값으로 0.0001에서 시작하고 *exponential decay scheduler*를 사용하여 매 에포크마다 차츰 작은 값으로 수렴하도록 하였다. Fig. 5는 기하변환 파라미터를 다양하게 구성하여 회귀한 결과이다. 이때 변환 파라미터 중 이동 변량을 나타내는  $t_x$ ,  $t_y$ 와 규

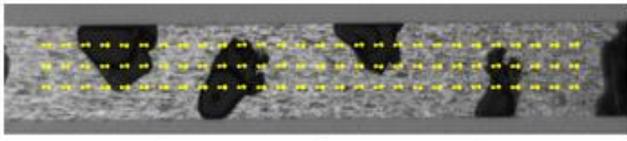
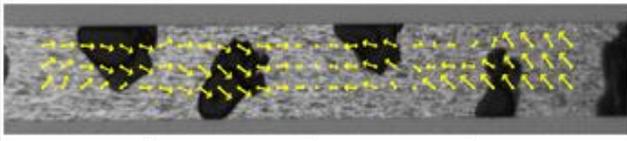
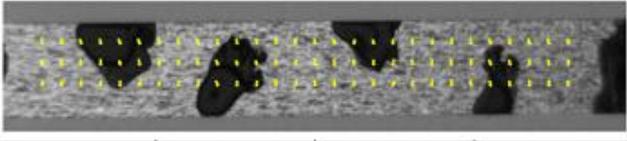
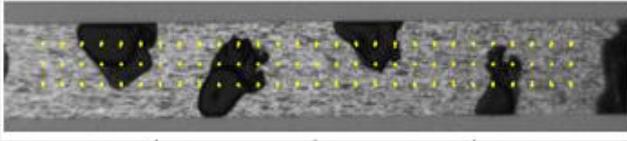
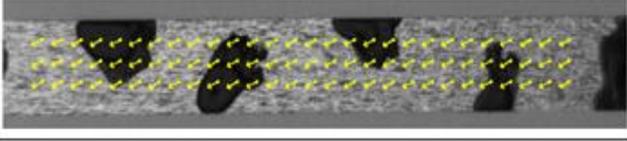
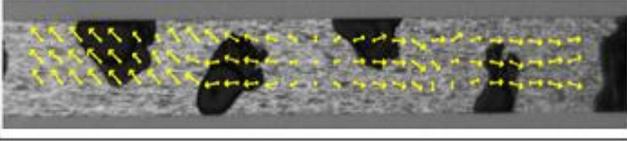
Affine transform parameters							
$t_x$	$t_y$	$\varepsilon_x$	$\varepsilon_y$	$t_x$	$t_y$	$\varepsilon_x$	$\varepsilon_y$
5.0	0.0	1.0	1.0	0.0	0.0	0.9	1.0
							
0.0	-2.0	1.0	1.0	0.0	0.0	1.0	0.95
							
-6.0	3.5	1.0	1.0	0.0	0.0	1.1	1.05
							

Fig. 5. Regression results of transformed images using sub-pixel interpolation.

모 변환율을 나타내는  $z_x, z_y$ 을 변화시키며 회귀결과를 관측하였다. Fig. 5의 좌측 열은  $t_x, t_y$  값만 변화시키며 이동 변환만 적용한 데이터에 대한 회귀 결과이며, 우측 열은  $z_x, z_y$  값을 변화시키며 규모 변환만 적용한 샘플에 대한 회귀 결과이다. 이동 변환만 수행한 경우에 실제 변환된 방향으로 변환 경향을 잘 예측하는 모습을 확인할 수 있었다. 반면 규모 변환된 영상 샘플에 대해서는 신경망이 변환 경향을 합리적으로 추론하지 못하는 한계가 있었다. 그러나 실제 시편의 경우 규모 변환이 얼마나 이루어지는지에 대한 측정 결과는 인장특성을 추론하는데 큰 의미가 없다. 우리는 학습된 모델의 회귀성능을 정량적으로 평가하기 위해 임의로 생성된 시편의 연속 부분 영상에 대해 파라미터  $t_x$ 와  $t_y$ 를 예측하였다. 이때 데이터는 이동 변환에 사용된 파라미터의 규모별로 테스트 샘플을 나누었으며, 각 규모별로 모델의 성능을 평가하였다. 평가척도로는 파라미터에 대한 모델의 예측값과 참값 사이의 평균 제곱근 오차와 오차율을 사용하였으며 산식은 각각 식 (3), (4)과 같다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (t_i - \hat{t}_i)^2} \quad (3)$$

$$error\ rate = \frac{1}{n} \sum_{i=1}^n \left( \frac{|t_i - \hat{t}_i|}{\max\ magnitude(t)} \right) \quad (4)$$

여기서  $t_i$ 와  $\hat{t}_i$ 는 각각 모델이 예측한 값과 참값을 가리키며, 식 (4)의  $\max\ magnitude(t)$ 는 테스트 샘플 생성에 사용된 변

환 파라미터의 최대 규모를 의미한다. 본 실험에서는 파라미터 최대 규모를 8.0으로 설정하였다. 테스트에 사용된 샘플은 총 8,000개이며 파라미터의 규모 별로 1,000개를 생성하여 검증하였다. Table 1은 실험한 결과이며, 파라미터의 규모별로 모델의 성능이 다르게 측정되었다. 규모 [0.0, 1.0]에서는  $t_x, t_y$  값의 평균 제곱근 오차 값이 각각 0.3000, 0.3005로 크게 측정된 반면, [7.0, 8.0]에서는 0.1853, 0.1905로 작은 오차를 기록하였다. 마찬가지로 오차율의 경우 각각 2.9%, 3.0%로 기록되었고, [7.0, 8.0]에서는 1.9%, 1.9%를 기록하였다. 이 실험결과를 통해 단일모델을 사용하여 회귀하였음에도 불구하고 다양한 규모의 변환에 대해 합리적으로 추론하고 있음을 확인할 수 있다.

Table 1. Regression results of convolutional LSTM model according to the range of translation parameters

absolute( $t_x, t_y$ )	RMSE(pixel)		errorrate(%)	
	$t_x$	$t_y$	$t_x$	$t_y$
[0.0, 1.0]	0.3000	0.3005	2.9	3.0
[1.0, 2.0]	0.3122	0.2909	3.0	2.9
[2.0, 3.0]	0.2847	0.2852	2.8	2.9
[3.0, 4.0]	0.2750	0.2623	2.7	2.6
[4.0, 5.0]	0.2448	0.2520	2.4	2.6
[5.0, 6.0]	0.2545	0.2518	2.5	2.5
[6.0, 7.0]	0.2540	0.2594	2.5	2.6
[7.0, 8.0]	0.1853	0.1905	1.9	1.9

## V. Conclusions

본 논문에서는 컨볼루션 장단기 기억 신경망 학습을 통해 시편의 인장 특성을 추정하는 방법을 제안하였다. 실험은 먼저 실제 인장시험 시의 시편의 변형 특성을 반영한 샘플 생성 알고리즘을 하여 학습 및 검증 샘플을 생성하였다. 이후 생성된 학습샘플을 사용하여 컨볼루션 장단기 기억 신경망 학습을 시행하였고, 검증샘플을 사용하여 학습된 신경망의 변환 파라미터에 대한 회귀성을 평가하였다. 그 결과, 파라미터의 규모별로 성능이 상이하였으며, 규모가 큰 샘플에 대해 더 강력한 성능을 입증하였다. 이는 인장력이 가해짐에 따라 시편의 파단이 이루어지는 시점에서 갑작스럽게 변형이 발생하는데, 이때 국부 변형에 대한 더욱 정밀한 측정이 가능함을 의미한다. 또한 기존의 DIC 방법은 변형의 규모가 일정하지 않는 경우 파라미터를 바꿔가며 반복적으로 영상을 분석해야 하는 비용이 발생하는 반면, 우리가 제시하는 모델은 단일 모델을 사용함으로써 폭넓은 변형 규모에 대해 합리적인 추론이 가능하였다.

추가 연구방향으로 모델의 성능 향상을 위하여 다양한 딥 러닝 기법을 적용해볼 수 있다. 예를 들어 연구 [10]과 [11]과 같이 영상 수준의 네트워크 구조에 *Attention module*을 첨가하는 것만으로도 추가 성능개선을 기대해볼 수 있다. 딥 러닝에서 *Attention*이란 신경망이 어떠한 결과를 추론할 때에 추출한 데이터의 특징 중 중요한 부분에 초점을 맞춰 판단하도록 하는 기법이다. 특히 인장 시험에서 사용하는 시편은 표면에 임의 패턴의 마킹을 하여 제작하였는데, 마킹이 되지 않은 부분은 실제로 인장이 되었다고 하더라도 취득된 영상에서는 픽셀단위 이동이 잘 인식되지 않는 한계점이 있다. 때문에 신경망이 마킹이 이루어진 부분에 집중하여 판단하도록 하는 모듈을 잘 설계할 필요가 있다. 또한 본 논문에서 다루는 문제는 영상뿐만 아니라 시간 축에 대해서도 데이터로부터 의미를 추론하는 문제이기 때문에 연구 [12]와 [13]에서 제시하는 바와 같이 장단기 기억 신경망 기반의 *Attention* 기법에 대한 추가 연구도 필요할 것으로 생각된다.

## REFERENCES

- [1] Feipeng Zhu., Pengxiang Bai, Jingbin Zhang, Dong Lei, and Xiaoyuan He, "Measurement of true stress-strain curves and evolution of plastic zone of low carbon steel under uniaxial tension using digital image correlation" *Optics and Lasers in Engineering*, Vol. 65, pp. 81-88, Feb. 2015.
- [2] H. G. Min, D. J. Kang, K. J. Kim, and J. H. Park, "New Non-Contact Measurement Method of Deformation at Tensile Test of Thin Film via Digital Image Correlation Technique", *International Journal of Precision Engineering and Manufacturing*, Vol. 18, no. 11, pp. 1509-1517, Jun. 2017.
- [3] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proc. of the IEEE*, Vol. 86, pp. 2278-2324, Nov. 1998.
- [4] S. Hochreiter and J. Schmidhuber. Long short-term memory. *Neural Computation*, Vol. 9, no. 8, pp. 1735-1780, Mar. 1997.
- [5] Xingjian Shi and Zhoung Chen, "Convolutional LSTM Network: A Machine Learning Approach for Precipitation Nowcasting" *Computer Vision and Pattern Recognition*, 2015. *Proceedings CVPR '15*, Computer Society Conference on, Sep. 2015.
- [6] Ji, S., Xu, W., Yang, M., Yu, K., "3D Convolutional Neural Networks for Human Action Recognition", *IEEE transactions on pattern analysis and machine intelligence*, Vol. 35, no. 1, pp. 221-231. Sep. 2013.
- [7] Wenxin Hu, and Hong Miao. "Sub-pixel displacement algorithm in temporal sequence digital image correlation based on correlation coefficient weighted fitting", *Optics and Lasers in Engineering*, Vol. 110, pp. 410-414, Nov. 2018.
- [8] Huafeng Li, Xinkun Liu, Zhengtao Yu, and Yafei Zhang, "Performance improvement scheme of multifocus image fusion derived by difference images", *Signal Processing*, Vol. 128, pp. 474-493, Nov. 2016.
- [9] S. Lambert-Lacroix and L. Zwald, "Robust regression through the Hubers criterion and adaptive lasso penalty", *Electronic Journal of Statistics*, Vol. 5, pp. 1015-1053, 2011.
- [10] W. Yin, H. Schutze, "ABCNN: Attention-Based Convolutional Neural Network for Modeling Sentence Pairs", *Computation and Language*, Dec. 2015.
- [11] F. Wang and M. Jiang, "Residual Attention Network for Image Classification", *Computer Vision and Pattern Recognition*, 2017. *Proceedings CVPR '17*, Computer Society Conference on, Sep. 2017.
- [12] Jiasen Lu, Caiming Xiong, Devi Parikh and Richard Socher, "Knowing When to Look: Adaptive Attention via A Visual Sentinel for Image Captioning", *Computer Vision and Pattern Recognition*, 2016. *Proceedings CVPR '16*, Computer Society Conference on, Dec. 2016.
- [13] Ilya Sutskever, Oriol Vinyals and Quoc V. Le, "Sequence to Sequence Learning with Neural Networks", *Computer Vision and Pattern Recognition*, 2014. *Proceedings CVPR '14*, Computer Society Conference on, Sep. 2014.

## Authors



Hyeon-Joon Choi received his B.S. degree from School of Naval Architecture & Ocean Engineering at Pusan National University, Pusan, Korea in 2017. Now he is a Master student at Pusan National Univ. in school of Mechanical Engineering.

His research interests include image processing, machine learning, and deep learning.



Dong-Joong Kang received his BS degree in Precision Engineering from Pusan National University, Pusan, Korea, in 1988, and his MS and Ph.D. degrees in Mechanical, and Automation & Design Engineering from KAIST, Korea, in 1990 and 1999,

respectively. In 1997 to 2000, he was a research engineer at SAIT (Samsung Advanced Institute of Technology). Now he is a professor at the School of Mechanical Engineering in Pusan National University. He is also an associate editor of the International Journal of Control, Automation, and Systems since 2007. His current research interests are machine vision, pattern recognition, and visual inspection in factory.