



심층학습 기반 초해상화 기법을 이용한 슬로싱 압력장 복원에 관한 연구

김효주¹·양동현^{2,3}·박정윤¹·황명권^{2,3}·이상봉^{2,†}
동아대학교 조선해양플랜트공학과¹
한국과학기술정보연구원 지능형인프라기술연구단²
과학기술연합대학원대학교 데이터 및 HPC학과³

Study on the Reconstruction of Pressure Field in Sloshing Simulation Using Super-Resolution Convolutional Neural Network

Hyo Ju Kim¹·Donghun Yang^{2,3}·Jung Yoon Park¹·Myungwon Hwang^{2,3}·Sang Bong Lee^{1,†}
Department of Naval Architecture and Offshore Engineering, Dong-A University¹
Department of Intelligent Infrastructure Technology Research, KISTI²
Department of Data and HPC Science, UST³

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.

Deep-learning-based Super-Resolution (SR) methods were evaluated to reconstruct pressure fields with a high resolution from low-resolution images taken from a coarse grid simulation. In addition to a canonical SRCNN(super-resolution convolutional neural network) model, two modified models from SRCNN, adding an activation function (ReLU or Sigmoid function) to the output layer, were considered in the present study. High resolution images obtained by three models were more vivid and reliable qualitatively, compared with a conventional super-resolution method of bicubic interpolation. A quantitative comparison of statistical similarity showed that SRCNN model with Sigmoid function achieved best performance with less dependency on original resolution of input images.

Keywords : Super-resolution(초해상화), Deep learning(심층학습), Computational Fluid Dynamics(CFD, 전산유체역학), Sloshing(슬로싱), Statistical similarity(통계적 유사성)

1. 서론

초해상화(super-resolution)는 저해상도(Low Resolution, LR) 이미지를 고해상도(High Resolution, HR) 이미지로 변환하는 방법으로써 전통적인 방법으로는 3차원 스플라인, 다항식을 이용하는 바이큐빅 보간(bicubic interpolation)이나 선형 매핑(linear mapping) 방식 등이 연구되었다.

Dong et al. (2014)에 의해 합성곱 신경망(convolution neural network, CNN)을 초해상화에 적용한 SRCNN(super-resolution CNN)이 연구되면서 본격적으로 심층학습을 통한 초해상화 방법이 이미지 해상도 개선을 위한 한 분야로 자리매김하였다. 이러한 초해상화에 대한 연구는 이미지 처리 분야에서 얼굴, 동물, 사과, 풍경 등과 같은 대상 객체를 중심으로 많이

이루어져 왔으나 (Park and Kim, 2016; Xu et al. 2017; Wang et al., 2018), 최근 들어 엔지니어링 분야에서 구조 변형률, 압력 등과 같은 물리량에 대해 초해상화를 시도하는 연구가 보고되기 시작하였다 (Lee et al., 2019; Hui et al., 2020; Gupta & Jaiman, 2021).

유동 수치해석 분야의 경우 조밀도에 따른 해석 결과의 해상도 측면에서, 계산 비용이 적은 성긴(coarse) 격자 기반의 저해상도 유동장을 조밀한(dense) 격자 계산을 통해 얻을 수 있는 고해상도 유동장으로 변환하고자 하는 딥러닝 기반 초해상화 모델 적용 사례가 연구되었다 (Fukami et al., 2018; Deng et al., 2019). 수치해석에서 딥러닝 기반 초해상화 모델 적용 시, 격자 구조를 그대로 픽셀화하고 해석을 통해 얻은 물리량을 데이터로 활용할 수 있다는 점에서 용이하나, 학습 모델 선정에 있어 대상 객체에 대한 이미지 처리와는 달리 데이터가 가지는

물리량으로써의 타당성과 데이터 간 연관성이 반드시 고려되어야 한다는 점이 어려움으로 작용한다. 그리고 데이터의 구조화, 학습 결과에 대한 신뢰도 등의 이유로 유동 해석과 심층 학습을 결합한 기존의 연구들은 2차원 실린더 층류 유동, 통계적 균일성을 지닌 난류 유동 등 학문적 가치를 갖는 기초 유동에 적용된 결과들이다. 따라서 성긴 격자에서 얻어진 수치 유동장에 대해 심층학습을 적용하여 고해상도의 유동장을 얻은 기존 연구 결과에도 불구하고, 조선해양 분야의 현업에서 발생하는 복잡한 난류 유동이나 다상 유동의 초해상화에 심층학습이 유효한지에 대해서는 여전히 불확실한 상황이다.

이에 본 연구에서는 유동 수치해석 분야에서 대표적으로 밀집된 격자를 기반으로 한 대형 계산을 요하는 슬로싱 문제를 대상으로 하였다. 슬로싱은 3차원, 다상 유동, 유체 충돌에 의한 급격한 벽면 압력 변화 등이 포함된 문제로, 격자가 조밀할수록 신뢰성 높은 유동 해석 결과를 보여줌에도 불구하고 수치 비용으로 인해 2차원 해석이나 성긴 격자에서 3차원 수치 해석을 수행하는 경우가 많다. 따라서 심층학습 기반 초해상화 적용에 따른 효율성 개선 및 확장성을 기대 해 볼 수 있고, 격자 기반 벽면 압력장에 대해 픽셀화를 통한 데이터 이미지화가 용이하며 주기적인 특성으로 인해 다량의 학습 데이터 확보가 가능하다는 점에서 대상으로 선정하였다.

지도(supervised) 학습으로 이루어진 심층학습 기반 초해상화를 수행하기 위해 조밀한 격자에서 수행된 슬로싱 유동해석으로부터 벽면 압력장 이미지를 얻어 학습데이터로 활용하였다. 기존에 제안된 심층학습 기반 초해상화 모델인 SRCNN을 학습데이터에 적용하였으며, 표준 SRCNN 이외에도 출력 층에 활성화 함수(ReLU 및 Sigmoid)를 추가한 2가지 변형 모델을 고려하였다. 또한 각각의 모델로 복원(단, 여기에서 '복원'은 원데이터로 재구성하는 의미가 아닌 초해상화 수준의 데이터로 구성하는 심층학습의 처리 과정을 뜻하는 의미)된 고해상도 이미지 데이터가 기존의 조밀한 격자 유동해석을 통해 얻은 복잡한 입력장 데이터를 유효하게 모사할 수 있는지, 어떤 모델을 사용하는 것이 타당한지에 대해 통계적 유사성 비교를 통해 평가하고자 한다.

2. 방법

2.1 데이터 수집

심층학습 기반 초해상화 모델 학습에 사용할 슬로싱 벽면 압력장 이미지 데이터를 수집하기 위해 3차원 사각 탱크 내 슬로싱 유동해석을 수행하였다. Fig. 1에 나타낸 바와 같이 사각 탱크 사이즈의 가로(L), 폭(B), 높이(H)는 각각 0.8 m, 0.4 m, 0.5 m 이다. 그림에서 사각 탱크의 가진운동을 나타내는 식을 x_T 로 나타내었다. 식에서 A와 w_T 는 각각 가진 운동의 진폭과 주파수를 의미하고 본 연구에서 고려한 진폭과 주파수는 각각 $A=0.025L$ 와 $w_T=4.513\text{rad/s}$ 이다. 탱크 내 액체는 0.15 m 높이로 차 있으며, 따라서 충액률(filling ratio, h/H)은 0.30이다.

초해상화 학습을 수행할 관심 영역은 Fig. 1(b)에 나타낸 바

와 같이 $x = L + x_t(t)$ 평면에 해당하는 사각탱크 측면 영역 전체이다. 학습 입력(input) 데이터는 해당영역에 128×128 개의 격자점을 배치하여 유동해석을 수행하고, 압력장을 추출한 뒤 최대 및 최소값으로 정규화하여 0에서 1의 값을 갖는 128×128 픽셀 이미지데이터로 변환하는 방법으로 얻었다. 이 128×128 픽셀 이미지는 심층학습 기반 초해상화 모델의 학습에 사용되며, 추후 학습된 모델의 복원 성능을 확인하는 데는 저해상도 이미지에 해당하는 32×32 개의 격자점을 배치하여 얻은 압력장 이미지가 사용된다.

학습에 사용될 입력이미지 데이터의 신뢰성을 확보하기 위해 본 연구에서 얻은 해석 결과를 실험 (Kang and Lee, 2005) 및 수치해석 (Chen et al., 2009; Jung et al., 2015) 선행연구 결과와 비교하였다. Fig. 2는 Fig. 1(a)에 표시한 측정 지점 (probe)에서 압력 변화를 시간에 따라 나타낸 것이다. 사각 탱크의 주기적인 가진 운동에 의해 탱크 내 유체 거동 또한 일정한 주기를 가지는데, 본 연구의 유동해석 결과가 이러한 주기적 패턴을 잘 구현하며 선행연구와도 잘 일치하는 결과를 보여주는 것을 확인할 수 있다.

본 연구의 주요 목적이 심층 학습 기반 모델을 통해 벽면 압력장의 초해상화가 가능한지, 가능하다면 어떤 모델을 사용하는 것이 타당한지에 대한 기초 평가에 있으므로, 학습 대상이 되는 측면 벽에서 유동장 패턴이 다양하게 나타나는 구간을 선택하였으며 이를 Fig. 2에 붉은 점선으로 표시하였다. 해당 구간 동안 얻은 측면 벽 압력장을 대상으로 초해상화 학습을 수행하였다. 표시한 구간에서 슬로싱 주기당 200개(그림에서 붉은 점선 표시 영역 한 구간 내 등시간 간격으로)의 이미지를 수집하여, 15번의 주기 동안 총 3,000개의 입력 데이터를 얻었다. 이 중 2,800개의 이미지 데이터를 학습에, 나머지 200개의 이미지 데이터를 검증에 사용하였다.

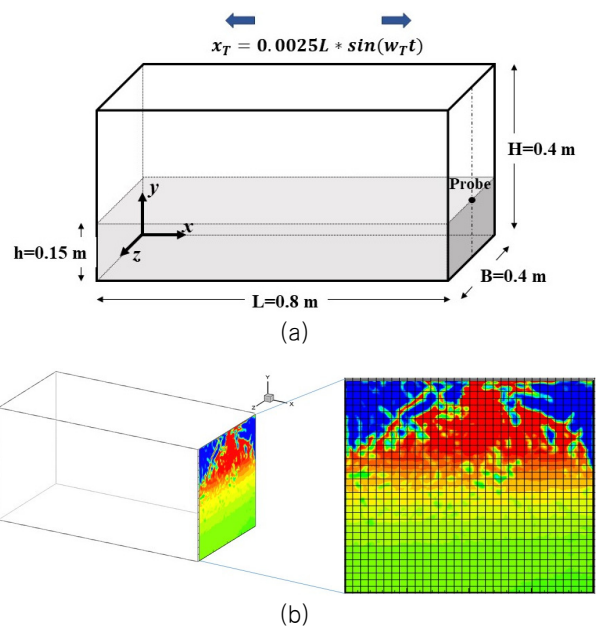


Fig. 1 (a) Schematics of CFD simulation and (b) region of interest for deep learning based super-resolution

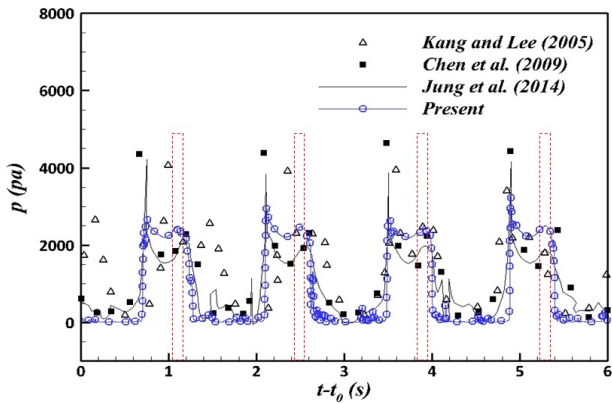


Fig. 2 Comparison of pressures histories with previous researches (data extraction intervals are marked with red dashed line)

학습 효율을 높이기 위해 학습 데이터 개수를 늘리기 위한 전처리 과정을 수행하였다. 기존의 2,800개의 학습 이미지를 좌우반전 또는 스케일 변환을 통해 22,400개~50,400개 이미지 데이터로 증폭시켰다. 이미지 좌우반전에는 OpenCV의 flip() 함수를 사용하였고, 스케일 변환은 resize() 함수에서 이중선형(bilinear) 보간법으로 이미지 사이즈를 1/n 만큼 줄였다가 영역 보간법으로 다시 n배 만큼 늘리는 방법으로 원본과 동일한 픽셀 이미지를 생성하였다.

2.2 심층학습 방법

본 연구에서 심층학습 기반 초해상화를 위해 사용된 모델은 초해상화에 딥러닝을 최초로 도입한 SRCNN (Dong et al., 2014)을 기반으로 하였다. SRCNN은 전통적인 초해상화 기법이 가지는 패치 추출, 비선형 매핑, 복원 기능을 합성곱 층이 담당하도록 구성되어 있다(Fig. 3). 그 구조는 비교적 간단하지만 기존 초해상도 기법에 비해 높은 성능을 보이는 것이 확인된 바 있다 (Dong et al., 2014).

표준 SRCNN 모델에서는 출력 층에 활성화 함수를 사용하지 않아 출력값의 제한이 없었다. 본 연구에서는 기존 SRCNN의 출력값에 최대, 최소 제약을 주기 위해 최근 딥러닝 분야에서 가장 많이 사용되는 활성화 함수인 ReLU(rectifier linear unit) 및 시그모이드(sigmoid) 함수를 출력 층에 추가한 SRCNN의 변형 모델을 추가적으로 고려하였다 (Table 1 참조).

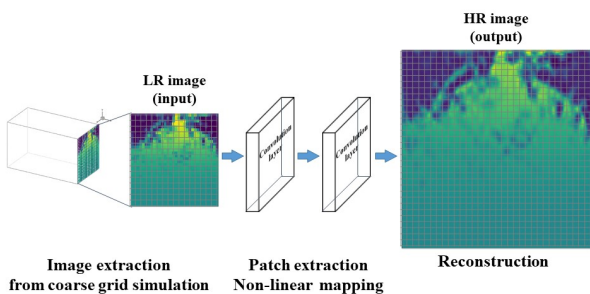


Fig. 3 Network structure of SRCNN for a sloshing flow reconstruction

Table 1 Deep-learning-based super-resolution model considered in the present study

Models		Augmentation scale
SRCNN (Dong et al., 2014)	SRCNN-A	4-7
	SRCNN-B	2-10
SRCNN with ReLU	SRCNNr-A	4-7
	SRCNNr-B	2-10
SRCNN with Sigmoid	SRCNNs-A	4-7
	SRCNNs-B	2-10

각 모델에는 학습 데이터 증폭 과정에서 스케일(s) 변환 범위가 다른 두 개($4 \leq s \leq 7$ 및 $2 \leq s \leq 10$)의 그룹을 적용하여, 입력 이미지 데이터의 증폭 과정에 의한 의존도 함께 확인하였다. Table 1과 같이, 기존 모델을 SRCNN, ReLU 및 시그모이드 활성화 함수를 추가한 모델을 각각 SRCNNr, SRCNNs 이라 명명하였고, 데이터 증폭 스케일에 따라 $4 \leq s \leq 7$ 인 그룹에 A를, $2 \leq s \leq 10$ 인 그룹에 B를 부여하여 나타내었다.

딥러닝 모델의 학습률, 배치사이즈, 옵티마이저 등 모든 하이퍼파라미터는 Grid Search (Shekar and Dagneu, 2019)를 통해 각 모델 및 학습데이터 별 최적값으로 선택하였다. 옵티마이저로는 Adam (Kingma and Ba, 2014)을 사용하였고, 손실함수(loss function)로는 MSE (mean square error)를 사용하였다. 잡음 대비 최대 전력비를 나타내는 PSNR (peak signal-to-noise ratio) 또한 각 모델의 초해상화 성능을 평가하는데 참고하였다. 학습률 (learning rate)은 0.001로 설정하였으며, 학습 반복 횟수인 에폭 (epoch)은 1,000으로 설정하였으며, 모델의 학습데이터에 대한 과적합을 방지하기 위해 학습 조기 종료(early-stopping) 기법을 사용하여 최적 모델을 결정하였다.

3. 결과 및 토론

3.1 심층학습 결과

Fig. 4는 각 모델 별 최적 에폭에서 MSE 값을 보여준다. 자세한 값과 해당 에폭에서의 PSNR 값은 Table 2에 나타내었다.




Fig. 4 MSE values of the super-resolution models or super-resolution models ($p^* = p / (p_{max} - p_{min})$)

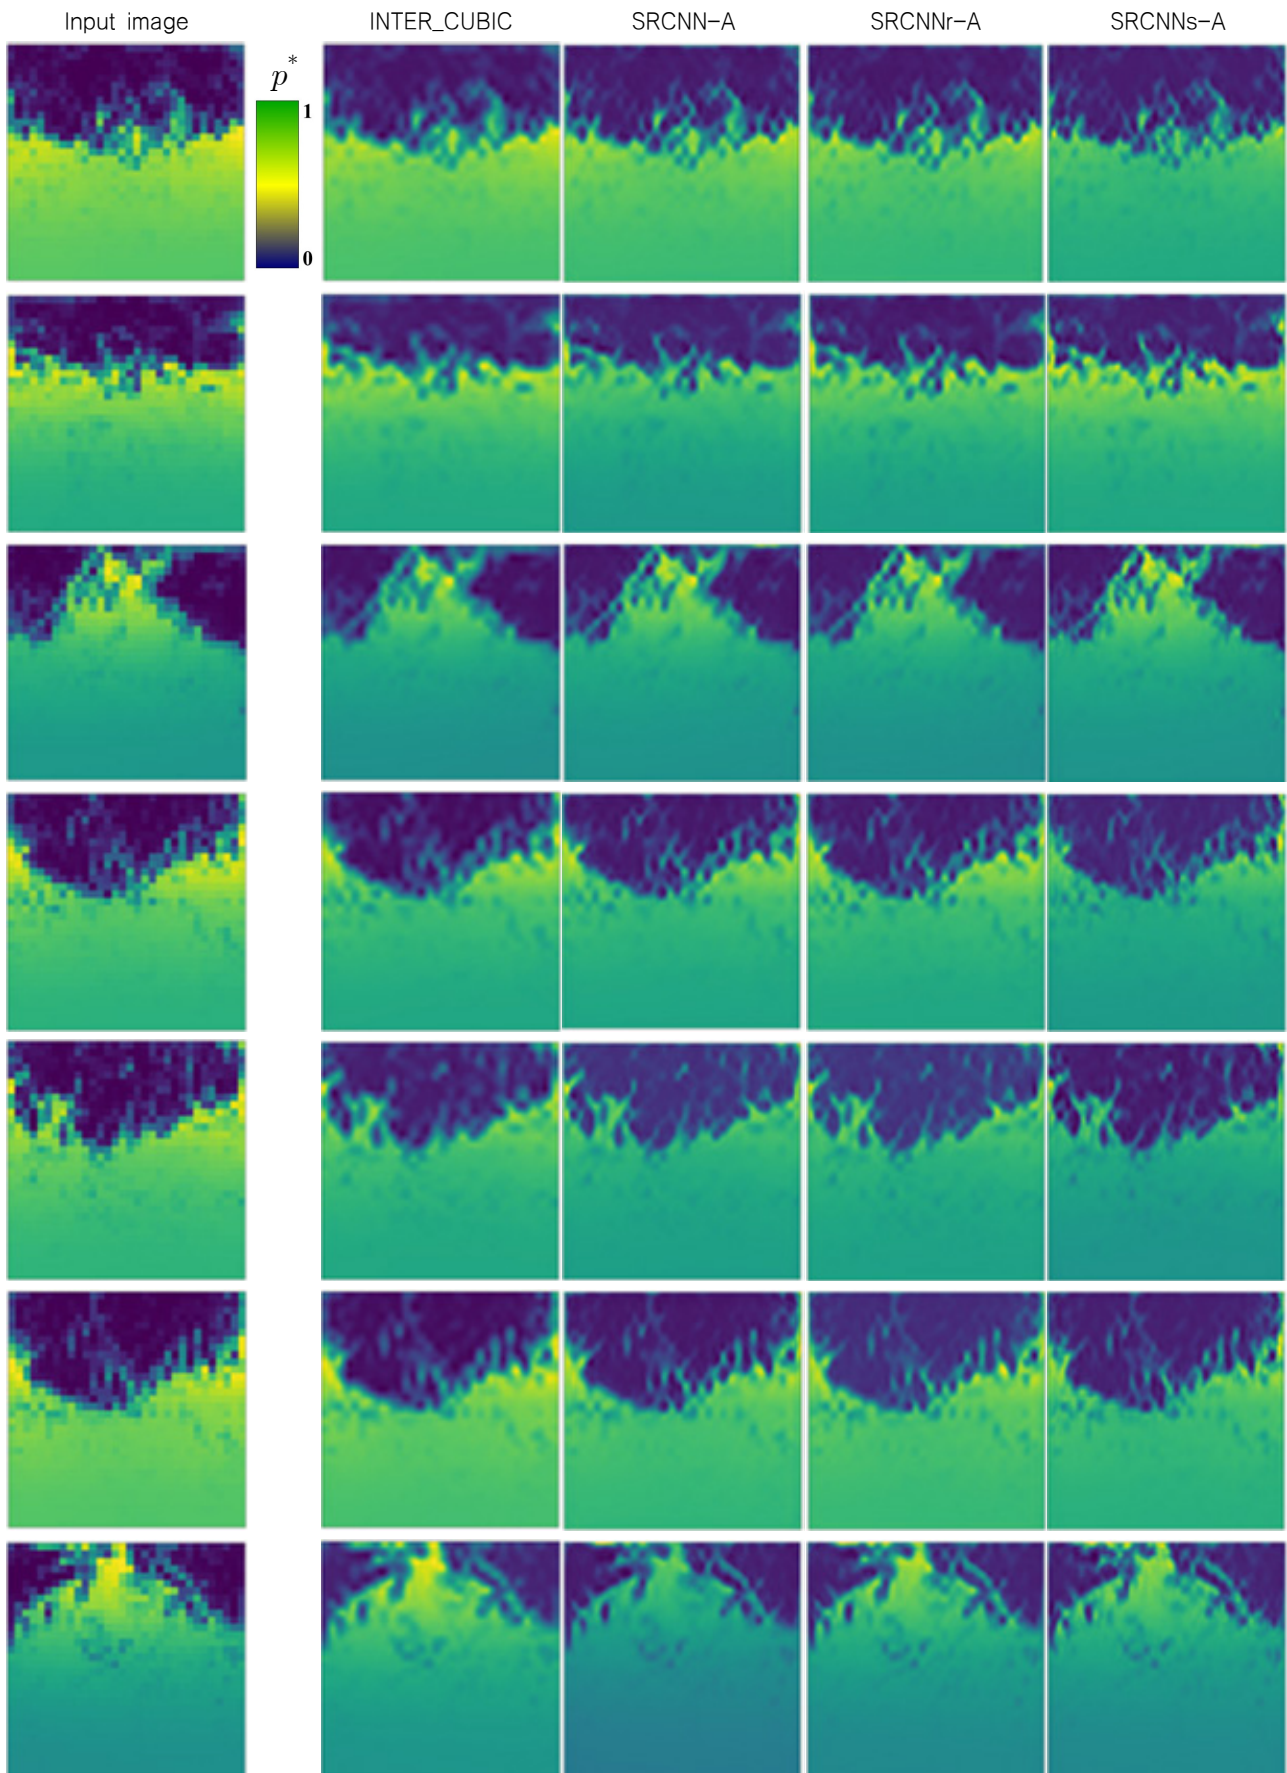


Fig. 5 Reconstructed pressure fields by traditional method

Table 2 MSE and PSNR values of the super-resolution models at the best epoch

Models	training		validation	
	MSE	PSNR	MSE	PSNR
SRCNN-A	0.00362	24.42076	0.005131	22.90762
SRCNN-B	0.003629	24.41038	0.005126	22.90888
SRCNNr-A	0.003093	24.67149	0.005142	22.8998
SRCNNr-B	0.00322	24.93401	0.005193	22.85319
SRCNNs-A	0.003244	24.90129	0.005186	22.86204

학습 및 검증 결과 매우 작은 손실 값을 가지고 모든 모델에서 학습이 충분히 이루어진 것을 볼 수 있다. 검증 결과에서 $4 \leq s \leq 7$ 에 해당하는 A 그룹이 $2 \leq s \leq 10$ 에 해당하는 B 그룹에 비해 근소한 차이로 검증 손실이 작게 나타나는 경향을 보인다. 그러나 전반적으로, 기존의 SRCNN 모델 기준 3% 이내의 차이에서 유사한 학습 및 검증 결과를 보이고 있다.

각 모델 별 이미지 복원 정도를 확인하기 위해 저해상도 입력 이미지를 전통적인 초해상화 방식과 학습된 딥러닝 기반 초해상화 모델들로 복원한 이미지를 각각 비교하여 Fig. 5에 나타내었다. 그림에서 첫 열은 입력으로 사용된 32×32 픽셀 이미지이며, 두 번째 열은 전통적인 인터큐빅(inter-cubic) 방식으로 복원한 이미지, 세 번째에서 다섯 번째 열은 본 연구에서 고려된 SRCNN, SRCNNr, SRCNNs 초해상화 모델을 통해 복원한 이미지를 각각 나열 한 것이다. 각 모델 복원 결과는 앞서 검증 손실이 더 작았던 A 그룹 모델들을 적용한 이미지를 대표적으로 나타내었다.

인터큐빅 방법을 적용해 복원한 이미지에 비해 딥러닝 기반 초해상화 모델들을 통해 복원한 이미지에서 해상도 개선과 그에 따른 구체적인 패턴 구현이 확연하게 향상된 것을 확인할 수 있었다. 특히, 시그모이드 활성화 함수를 추가한 SRCNNs-A 모델을 적용한 결과를 보면 타 모델들에 비해 좀더 높은 선명도로 복원된 것처럼 보인다.

이와 같이 복원된 이미지를 통해 심층학습 기반 초해상화 방법을 통해 얻은 복원 이미지가 전통적 방법에 비해 높은 선명도를 보인다는 것과, 이를 유동장 이미지에 적용할 수 있는 가능성을 정성적으로 확인하였다. 그러나 이렇게 복원된 이미지가 유동해석의 관점에서 조밀한 격자를 통해 얻을 수 있는 실제 고해상도 유동장 이미지를 대체할 수 있는가를 평가하기 위해서는 이미지 데이터가 본래 의미하는 압력값이 물리량의 관점에서 타당한가를 판단할 수 있는 보다 정량적인 비교 기준이 필요하다. 이에 다음 장에서는 학습 모델들을 통해 복원된 이미지 내 압력 값들이 통계적으로 유사한지를 정량적으로 비교하였다.

3.2 복원 데이터의 통계적 유사성 검토

딥러닝 기반 초해상화 모델을 통해 복원된 압력장으로 실제 유동해석을 통해 얻은 고해상도 압력장을 대체 가능하지 확인하기 위해 학습에 쓰이지 않은 새로운 압력장 데이터에 각 학습

된 모델들을 적용하여 복원된 결과들의 통계량을 비교하였다. 통계량 비교에는 앞선 딥러닝 모델 성능 확인에 사용된 성근 격자에 대한 유동해석을 통해 얻은 32×32 픽셀 이미지 3,000개(각 모델명 뒤에 숫자 32를 붙여 표시)와 더불어, 추가적으로 복원 정도를 평가할 목적으로, 조밀한 격자에 대한 유동해석을 통해 얻은 128×128 픽셀 이미지를 영역 보간법을 통해 32×32 픽셀로 하향화하여 의도적으로 저해상도로 변환한 이미지 3,000개(각 모델명 뒤에 숫자 128을 붙여 표시)를 사용하였으며 이를 Table 3에 나타내었다.

먼저 복원된 결과 이미지들에 대해 각 모델 별 총 평균, RMS(root mean square) 값, 최대 및 최소값을 비교하여 Fig. 6에 나타내었다. 기준이 되는 조밀한 격자에서 얻은 128×128 원본 데이터 통계값을 기준으로 표시선을 추가하였다. 우선 복원 결과들을 비교하기 전에 유동해석을 통해 얻은 두 데이터셋(128×128 격자 및 32×32 격자)의 총 통계량을 비교해보면, 평균 및 RSM 값 뿐만 아니라 최대, 최소값이 동일하게 나타나는 것을 볼 수 있다.

Table 3 Case table for statistic similarity test

Models	Input image	Number of images
SRCNN-A32	32×32	3000
SRCNN-A128	128×128	3000
SRCNN-B32	32×32	3000
SRCNN-B128	128×128	3000
SRCNNr-A32	32×32	3000
SRCNNr-A128	128×128	3000
SRCNNr-B32	32×32	3000
SRCNNr-B128	128×128	3000
SRCNNs-A32	32×32	3000
SRCNNs-A128	128×128	3000
SRCNNs-B32	32×32	3000
SRCNNs-B128	128×128	3000

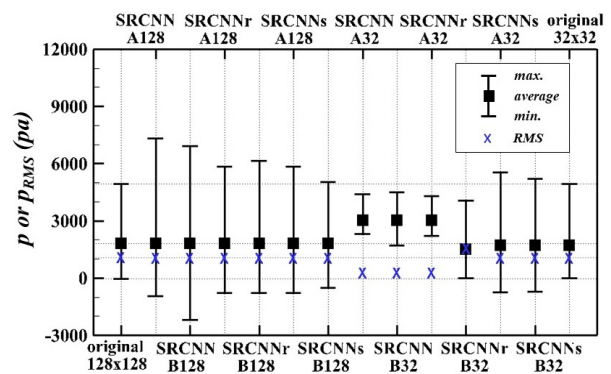


Fig. 6 Comparison of total statistics for each deep learning-based super-resolution (original 32×32 (128×128) means original flow-fields dataset from coarse (dense) grid simulation)




Fig. 7 Average and RMS values by grid position ($p_a^* = p_a / (p_{a,max} - p_{a,min})$, $p_r^* = p_r / (p_{r,max} - p_{r,min})$)

조밀한 격자(128×128) 유동장을 하향화 한 이미지를 복원한 경우, 모든 모델에서 평균값 및 RMS값이 원본 데이터를 잘 따르는 것을 확인할 수 있다. 그러나 복원된 이미지 중 SRCNN을 적용한 모델에서 최대 및 최소값이 원본과 상이한 분포를 보이는 것을 확인하였다. 이 차이는 출력층 활성화 함수를 수정한 SRCNNr, 특히 SRCNNs 모델을 적용하는 것으로 확연히 감소되는 것을 확인하였다.

성긴 격자(32×32) 유동장을 복원한 이미지 데이터의 경우에는 SRCNN 및 SRCNNr 모델을 적용했을 때 평균값 및 RMS값 또한 원본 데이터와 매우 상이한 결과를 보였는데, SRCNNs 모델을 적용한 경우에는 평균값 및 RMS값은 원본 데이터셋과 거의 동일하게 나타났으며, 다른 모델들에 비해 최대, 최소값 또한 상대적으로 원본 데이터셋 기준에서 크게 벗어나지 않는 결과를 보였다. 결과적으로, 총 통계량의 경우, SRCNNs 모델에서 입력 데이터에 대한 의존도가 가장 낮게 나타났다. 이를 통해 출력층에 적용된 시그모이드 함수가 기존 데이터셋의 통계적 분포를 가장 잘 유지한다는 것을 확인하였다.

이미지 내 위치별 물리량 분포 유사도를 확인하기 위해 필드(field) 통계량 또한 비교하여 Fig. 7에 나타내었다. 그림에서 p_a 는 필드 평균 압력값을, p_r 은 필드 평균 RMS값을 나타낸다. 앞서 유동해석을 통해 얻은 128×128 격자 및 32×32 격자 원본 데이터셋의 총 통계량이 거의 동일했던 것과는 달리, 평균 및 RMS의 필드 분포는 세부적인 패턴에서 다소 차이를 보이는 것을 알 수 있다.

먼저 128×128 픽셀 이미지를 32×32 픽셀로 하향화 한 이미지를 복원 한 경우 총 통계량 결과와 동일하게, 모델에 관계없이 평균 및 RSM 값 분포가 원본 분포와 거의 동일하게 나타나는 것을 확인할 수 있다. 반면 32×32 픽셀 이미지를 복원했을 때, SRCNN 및 SRCNNr 모델의 경우 앞서 총 통계량에서 보여준 결과와 같이 필드 통계량 또한 분포 범위가 원본과 매우 상이하게 나타나는 것을 볼 수 있다. 그러나 SRCNNs 모델을

통해 복원된 결과 이미지에서는 원본과 유사한 범위에서 필드 내 위치별 분포 또한 잘 구현하는 것을 확인할 수 있었다.

마지막으로 각 3,000 개의 복원 이미지셋 전체의 물리량 분포 유사도를 히스토그램을 통해 확인하였다(Fig. 8). 비교를 위해 32×32 픽셀 원본 데이터에서 측정된 빈도수에는 128×128 픽셀과 동일한 수준해서 비교 가능하도록 측정 빈도수에 16배(=4×4)하여 나타내었다. 두 원본 데이터셋의 경우 피크 빈도값은 차이가 있지만 피크가 나타나는 압력값 범위 및 전체 분포가 거의 동일하게 나타나는 것을 확인했다. 기준이 되는 128×128 픽셀 원본 데이터와 비교했을 때, 점 통계량 및 필드통계량이 원본과 잘 매치되는 결과를 보여준 SRCNNs 모델이 입력데이터 종류(128×128 격자 및 32×32 격자 유동장)에 관계없이 원본 데이터셋들과 거의 동일한 히스토그램 분포를 보여준다.

4. 결론

본 연구에서는 딥러닝 기반 초해상화 모델을 적용하여 저해상도 슬로싱 유동해석 이미지를 고해상도 이미지로 변환하고, 복원된 이미지 데이터셋의 통계량 비교를 통해 유동해석 관점에서의 물리량 복원 성능을 평가하였다. 학습에는 초해상화 합성곱 신경망 모델(SRCNN), 및 ReLU 또는 시그모이드 활성화 함수를 추가한 SRCNNr, SRCNNs 모델을 고려했다.

슬로싱 탱크 측면 벽을 대상으로 수행한 유동장 초해상화 학습은 낮은 검증손실로 고려한 모든 모델에서 우수한 성능을 보였으며, 복원된 이미지 또한 고해상도 슬로싱 유동장이 보이는 세부적인 유동 패턴을 보다 선명하게 구현함으로써 전통적인 초해상화 방식에 비해 뛰어난 복원 성능을 보였다. 복원된 이미지가 단순한 해상도 개선뿐만 아니라 유동해석 관점에서 대량 계산 결과를 대체할 수 있는가를 판단하기 위해 이미지에 적용된 물리량 데이터에 대한 통계량 비교를 수행하였다. 그 결과, 출력 층에 시그모이드 함수를 추가한 SRCNNs 모델에서 입력의 원본 해상도에 관계없이 통계량 분포가 거의 유지되는 것을 확인하였다. SRCNN 및 SRCNNr 모델의 경우 입력의 원본 해상도가 낮은 경우 복원 이미지 통계량이 유지되지 않아 유동해석 복원 모델로서 적합하지 않은 것을 확인하였다. 결과적으로, 저해상도 유동장 이미지를 딥러닝 기반 초해상도 기법으로 복원할 경우, 원본 데이터 필드가 기존 해상도에 따라 상이하게 분포하는 한계로 필드 통계량 분포가 동일한 패턴 구현은 다소 어려움이 있으나, 시그모이드 활성화 함수를 적용한 모델로 복원 결과 총 통계량 및 히스토그램을 통해 복원된 이미지데이터가 가지는 물리량 값 자체는 고해상도 유동해석 결과를 대체 가능함을 확인하였다.

향후에는 이와 같이 저해상도 유동장 데이터가 가지는 근본적인 한계점을 극복하기 위해, 저해상도-고해상도 유동장 데이터 간 관계성을 고려한 입력데이터 하향화 모델을 학습 단계에 적용시켜 개선된 초해상화 딥러닝 모델을 구현하고자 한다. 또한 초해상화를 통해 얻어진 벽면 압력의 상승기와 하강기 등과




Fig. 8 Histogram of pressure distribution for different datasets

같은 시간 특성에 대한 통계적 유효성도 검토할 예정이다.

후 기

본 논문은 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(No. NRF-2019R1A2C1004682)을 받아 수행된 기초연구사업입니다.

References

Chen, Y.G., Djidjeli, K. & Price, W.G., 2009. Numerical simulation of liquid sloshing phenomena in partially filled containers. *Computers & Fluids*, 38(4), pp.830-842.

Deng, Z., He, C., Liu, Y. & Kim, K. C., 2019. Super-resolution reconstruction of turbulent velocity fields using a generative adversarial network-based artificial intelligence framework. *Physics of Fluids*, 31(12), pp.125111.

Dong, C., Loy, C.C., He, K. & Tang, X., 2014. Learning a deep convolutional network for image super-resolution. *European conference on computer vision*, pp.184-199.

Fukami, K., Fukagata, K. & Taira, K., 2018. Super-resolution reconstruction of turbulent flows with machine learning. *Journal of Fluid Mechanics*, 870, pp.106-120.

Gupta, R. & Jaiman, R., 2021. Hybrid physics-based deep learning methodology for moving interface and fluid-structure interaction. *arXiv preprint arXiv:2102.09095*.

Hui, X., Bai, J., Wang, H. & Zhang, Y., 2020. Fast pressure distribution prediction of airfoils using deep learning. *Aerospace Science and Technology*, 105, pp.105949.

Jung, J. H., Yoon, H. S. & Lee, C. Y., 2015. Effect of natural frequency modes on sloshing phenomenon in a rectangular tank. *International Journal of Naval Architecture and Ocean Engineering*, 7(3), pp.580-594.

Lee, S. I., Yang, G. M., Lee, J., Lee, J. H., Jeong, Y. J., Lee, J. G. & Choi, W., 2019. Recognition and visualization of crack on concrete wall using deep learning and transfer learning. *Journal of the Korean Society of Agricultural Engineers*, 61(3), pp.55-65.

Kang, D.H. & Lee, Y.B., 2005. *Summary report of sloshing model test for rectangular model*. No. 001. South Korea: Daewoo Shipbuilding & Marine Engineering Co., Ltd.

Kingma, D. P. & Ba, J., 2014. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.

Park, W. S. & Kim, M., 2016. CNN-based in-loop filtering for coding efficiency improvement. *In 2016 IEEE 12th Image, Video, and Multidimensional Signal Processing Workshop (IVMSP)*, pp.1-5.

Shekar, B.H., & Dagnev, G., 2019. Grid search-based hyperparameter tuning and classification of microarray cancer data. *Second International Conference on Advanced Computational and Communication Paradigms*, pp.1-8.

Xu, X., Sun, D., Pan, J., Zhang, Y., Pfister, H. & Yang, M. H., 2017. Learning to super-resolve blurry face and text images. *In Proceedings of the IEEE international conference on computer vision*, pp.251-260.



김효주



양동헌



박정윤



황명권



이상봉