

CNN을 활용한 이미지 데이터 기반의 충격파 구조 및 표면 압력 예측에 대한 연구

CNN-Based Shock Wave Structure and Surface Pressure Prediction Using Image Data

초록

초고속 비행체 개발 과정에서 풍동 실험을 통한 데이터 획득 및 분석 과정은 필수적이다. 하지만 초음속 실험은 초음속 풍동 확보 및 실험 모델 설계 제작, 계측 시스템 구축 등의 과정에서 상당한 시간적 비용적 소비가 발생한다. 본 연구에서는 초음속 풍동 실험 데이터를 이용하여 기계 학습을 진행하였다. 학습 데이터는 충격파-경계층 간섭 실험의 Shadowgraph 결과 이미지와 표면 압력 데이터를 이용하였다. 학습된 기계학습 모델을 이용하여 실험 환경상 구현하기 힘든 형상에 대한 충격파 구조 및 표면 압력을 예측하고 이를 CFD와 비교 검증하였다. 연구 결과 기계 학습 모델이 물리적으로 타당한 결과를 도출하는 것을 확인하였다.

Key Words : 초음속 유동(Supersonic Flow), 루드비히관(Ludwig Tube), 충격파-경계층 간섭(Shock Wave-Boundary Layer Interaction), 기계학습(Machine Learning), 합성곱신경망(Convolution Neural Network), 충격파 구조예측(Shock Wave Structure Prediction), 표면 압력 예측(Surface Pressure Prediction)

서론

최근 초음속, 극 초음속 무기체계 및 비행체에 대한 관심과 연구의 수요가 증가하고 있다. 초음속 비행체가 기동할 때 기체에서 발생하는 충격파와 기체 표면의 경계층과의 간섭은 불가피하다. 다양한 초음속, 극 초음속 기체 중 Fig. 1. 은 스크램제트 흡입구(Scramjet Inlet)에서 발생할 수 있는 충격파-경계층 간섭 현상을 보여준다. 스크램제트의 램프의 각도가 변하는 부분이나 스크램제트 격리부(Scramjet Isolator)에서 충격파와 경계층의 간섭으로 역압력구배가 발생하고 박리거품(Separation Bubble)이 발생한다⁽¹⁾. 이 현상은 실질적인 비행체 표면 형상의 변화 및 유로 면적의 변화를 야기한다. 박리거품 뒷부분에 큰 압력과 온도의 상승은 비행체의 비행 안정성 및 성능을 크게 저하시키기 때문에 스크램제트 흡입구 설계 시 이를 파악하고 해결해야 할 필요가 있다.

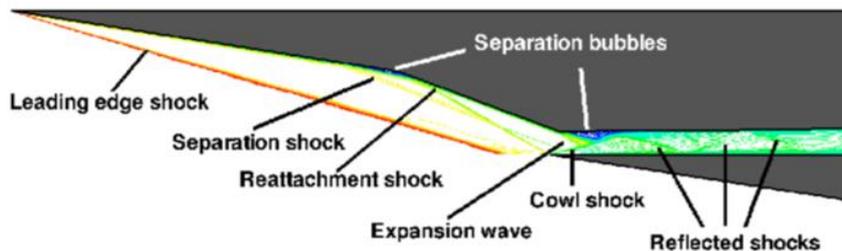


Fig. 1. Scramjet Inlet에서의 충격파-경계층 간섭 현상

스크램제트와 같은 초고속 비행체 개발 시 지상 시험을 통해 비행체에 작용하는 공력 특성 및 유동장을 분석한다. 일반적으로 초음속 풍동 실험을 진행하기 위해서는 초음속 풍동 및 여러 관측, 측정 장비를 확보해야 한다. 그리고 다양한 실험 기법들을 활용해 데이터를 획득한다. 여러 데이터 측정 기법을 위한 장비 구매 및 장소 확보 과정에서 많은 시간과 비용이 소요된다. 그리고 초음속 실험은

모델의 파손 가능성이 다분하기 때문에 고정 안정성이 중요하며 모델의 자세 변화 혹은 위치의 변화가 제한적이다. 따라서 모델의 제작 및 관리가 까다로우며 소요 비용 역시 크게 책정된다.

다양한 선행연구에서 인공지능을 사용하여 유동장 및 공력계수를 기존의 방법보다 효율적으로 추출하는 연구를 진행하였다. Y. Afshar 등은 LeNet-5 신경망 구조를 사용하여 CFD 데이터를 학습해 익형의 형상을 입력 값으로 받아 x방향 속도 u , y 방향 속도 v , 압력 p 를 출력하는 기계 학습 모델을 개발하는 연구를 진행한바 있다⁽²⁾. Yunfei 등은 Supersonic Cascade Channel에서 Symmetry Neural Network 구조를 활용하여 CFD 데이터를 학습해 표면 압력 값을 입력 값으로 받아 유동장을 출력하는 기계학습 모델을 개발하였다⁽³⁾. Zhixian 등은 FCN 신경망 구조를 사용하여 CFD 데이터와 제트 액추에이터(Jet Actuator) 실험 데이터를 학습해 실린더 형상을 입력 값으로 받아 후류의 Vortex 모양을 출력하는 기계 학습 모델을 개발하는 연구를 진행하였다⁽⁴⁾. Vinothkumar 등은 CNN과 MLP 신경망 구조를 사용하여 CFD 데이터를 학습해 익형 형상을 입력 값으로 받아 x방향 속도 u , y 방향 속도 v 를 출력하는 기계 학습 모델을 개발하는 연구를 진행하였다. 선행 연구들은 대부분 CFD 데이터를 입력 데이터로 사용하였다⁽⁵⁾.

주로 CFD 데이터를 학습에 사용한 선행 연구와 달리 본 연구에서는 초음속 실험 장비를 사용한 지상 시험 데이터를 학습 데이터로 사용하였다. 본 연구에서는 시간적, 비용적 소비를 축소하기 위한 두 종류의 기계 학습 방식을 제안한다. 첫 번째 학습 방식은 유동이 발달되지 않은 상태의 모델 이미지를 입력 값으로 받아 유동 발달 시 모델에서 발생할 충격파 구조를 예측하는 방식이다. U-Net 신경망 구조를 사용하여 초고속 카메라로부터 얻어지는 다수의 Shadowgraph 결과 데이터를 학습시켜 충격파 구조를 예측하였다. 두 번째 학습 방식은 첫 번째 학습으로부터 생성된 충격파 이미지를 사용하여 모델의 표면 압력을 예측하는 방식이다. LeNet 신경망 구조를 사용하여 압력 센서로부터 얻어지는 모델의 표면 압력 데이터를 학습시켰다. 두 가지 학습을 통해 획득한 학습 모델을 사용하여 실험 환경상 현실에서 구현하기 힘든 실험 모델의 위치나 자세에 대한 충격파 구조와 표면 압력 값을 예측하였다. 기계 학습 모델이 예측한 충격파 구조나 표면 압력 데이터를 CFD 계산 값과 비교하여 예측 값에 대한 신뢰성을 확보하였다.

1. 실험 모델 선정 및 실험 진행

실험 모델 설계 및 제작

학습 데이터를 획득하기 위해 충격파-경계층 간섭 현상을 간략하게 모사하기 위한 평판 모델과 뺨기 모델을 제작하여 연구를 진행하였다. Fig. 2. 은 평판과 뺨기 모델의 개략도를 나타낸다. Fig. 2. 의 Side View처럼 뺨기 모델에서 발생한 경사 충격파가 평판에 부딪히며 충격파와 경계층이 간섭하도록 설계하였고 뺨기 모델의 각도를 조절하여 발생하는 경사 충격파의 각도를 조절할 수 있도록 제작하였다. 본 연구에서 사용된 Ludwig Tube는 선행 연구가 진행된 타 풍동 대비 작은 시험부의 크기를 갖는다⁽⁶⁾. 작은 시험부의 크기로 인해 노즐 출구의 크기가 제한되므로 Core Flow 영역 안에 모델을 위치시키기 위해서는 모델의 크기가 선행연구보다 상대적으로 작아지게 된다. 모델의 크기가 작아지면 Side Flow의 영향이 커지므로 이를 고려해 Fig. 2. 의 Bottom View에 표시된 평판의 너비(W)를 평판의 앞전부터 경사 충격파가 부딪히는 위치까지의 거리(X_{shock})보다 길게 제작하여 Side Flow의 영향을 감소시켰다⁽⁶⁾.

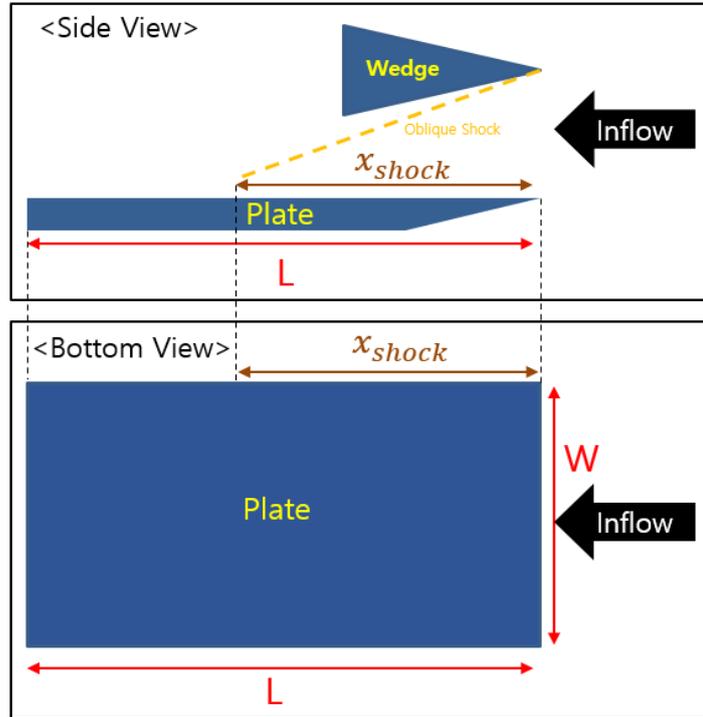


Fig 2. 평판과 췌기 모델의 개략도

Fig. 3. 은 평판 표면 압력 측정을 위해 압력 홀을 가공한 두 평판 모델의 표면을 보여준다. Fig. 3. 처럼 평판 표면 중앙에 일렬로 압력 홀을 가공하였다. 연구 초기에는 하나의 평판에 15개의 압력 홀을 가공하려고 구상하였다. 하지만 앞서 언급한 모델 크기의 제한 때문에 15개의 압력 홀을 두 개의 평판으로 나누어 제작하였다. Fig. 3. 의 (1)은 7개의 압력 홀을 가지고 있는 평판이고 Fig. 3. 의 (2)는 8개의 압력 홀을 가지고 있는 평판이다. Fig. 3. 의 (1) 평판은 7개의 압력 홀의 위치는 Fig. 3. 의 (2) 평판의 8개의 압력 홀의 위치와 중복되지 않으며 결과적으로 15개의 압력 홀이 등간격을 유지하며 일렬로 배치된 상태와 동일한 압력 분포를 측정할 수 있다. 두 평판의 길이 오차는 정밀 측정에서 약 0.03mm의 오차를 보이기 때문에 두 평판으로 동일한 실험을 진행할 시 형상으로 인한 유동의 특성 변화가 없다고 판단하였다. 평판의 길이는 약 80mm, 너비는 약 50mm이다.

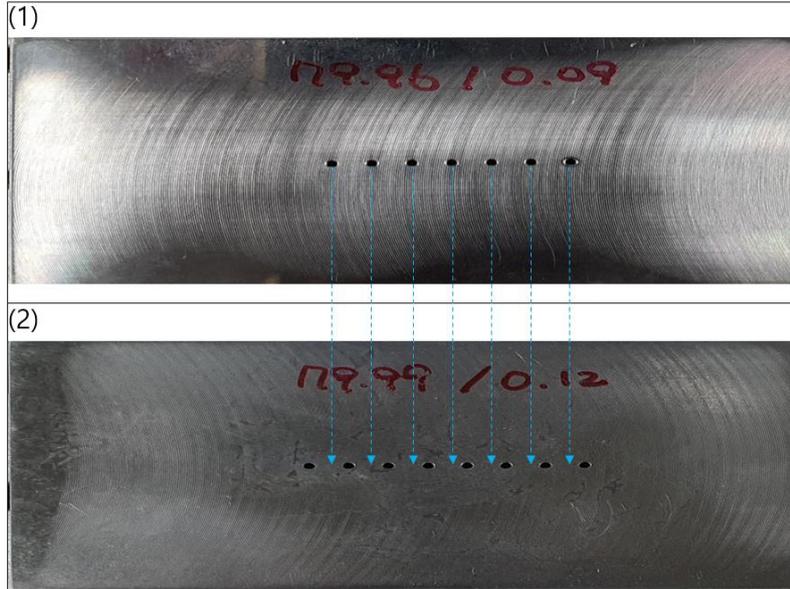


Fig. 3. 평판 표면압력 측정을 위한 평판 모델, (1) 압력 홀 7개인 평판, (2) 압력 홀 8개인 평판

최종적으로 평판과 쇄기 모델을 시험부에 설치한 모습은 Fig. 4. 와 같다.



Fig. 4. 평판과 쇄기모델이 시험부에 장착된 모습

Fig. 4. 의 평판이라고 표시된 모델은 추후 압력 측정을 위한 압력 튜브들이 위쪽으로 연결되어 있다. 따라서 평판 모델의 위치 변화는 불가하다. Fig. 4. 에서 쇄기 지지대라고 표시된 부분은 쇄기를 유동 방향으로 앞뒤로 이동시키는 역할을 한다. 따라서 평판에 부딪히는 경사 충격파의 위치를 조절할 수 있지만, 쇄기의 높이를 조절은 불가하다.

실험 장비 및 유동조건

본 연구에 사용된 초음속 장비는 Ludwig Tube이다. Fast-Acting Valve 작동방식을 취하고 있으며 Run Time은 약 100ms이다. Ludwig Tube는 Shock Tunnel이나 Shock Gun보다 더 긴 정상 유동 시간을 가진다. 정상 유동시간은 Storage Tube의 길이에 비례하여 길어진다. 본 연구에서 사용한 Ludwig Tube의 Storage Tube 길이는 약 21m, 정상 유동 시간은 약 80ms이다⁽⁷⁾. 초음속 유동 발생을

위해 사용한 노즐의 설계 마하수는 4이며 노즐 출구의 직경은 약 106.7mm이다. Fig. 6. 은 본 연구에 사용된 Ludwieg Tube의 렌더링 이미지를 나타낸다.

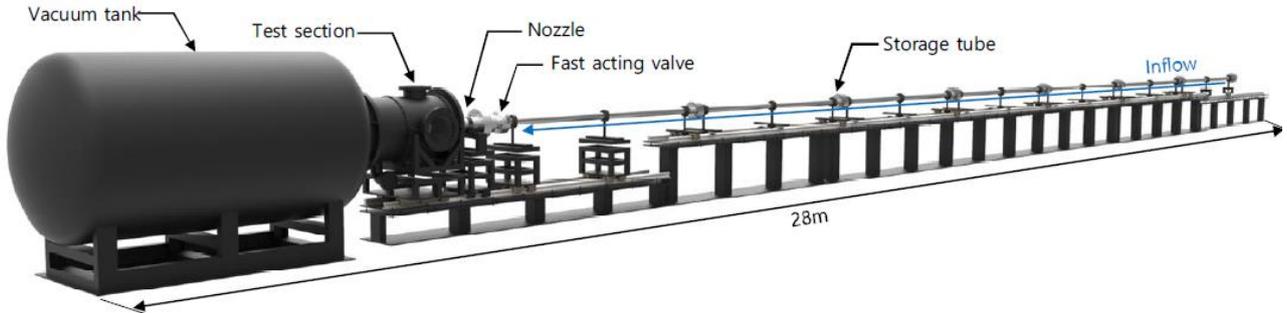


Fig 5. Ludwieg Tube의 렌더링 이미지

본 연구에서 사용한 유동의 조건은 Table 1. 과 같다.

Table 1. 유동조건

Properties		Value
Storage Tube	Total Pressure (MPa)	3±0.2
	Total Temperature (K)	295±
Nozzle Exit	Total Pressure (kPa)	15.93
	Total Temperature (K)	67.6
	Mach Number (-)	3.9±0.1
	Velocity (m/s)	656
	Density (kg/m³)	0.81
Unit Reynolds Number (m ⁻¹)		1.28E8

실험 결과

Fig. 6. 은 충격파-경계층 간섭 실험의 쇄기 각도 16°인 Case의 shadowgraph 결과 이미지를 나타낸다. Fig. 6. 의 왼쪽 이미지는 풍동 가동 전, 오른쪽은 풍동 가동 후 정상 유동 시간 동안의 shadowgraph 결과 이미지이다. Fig. 6. 에 표시된 Foot of Separation Shock은 박리영역의 시작 지점이고 Reattachment라고 표시된 지점은 경계층이 다시 평판 표면에 부착되는 지점을 의미한다. 박리영역의 크기는 쇄기 각도가 클수록 커지고 작아질수록 작아진다.

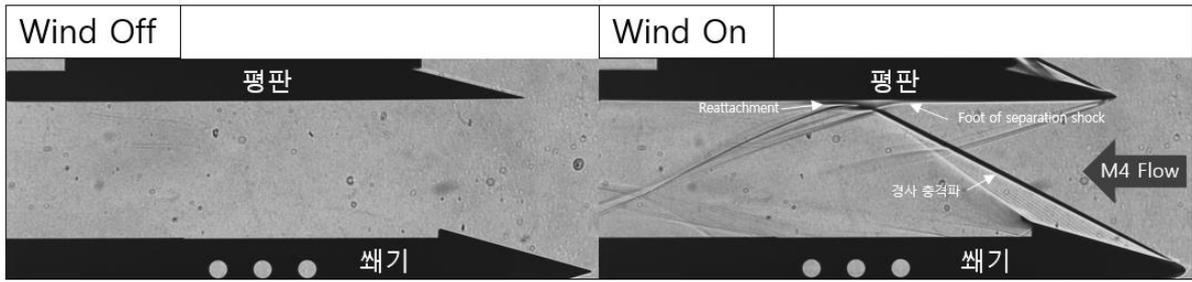


Fig. 6. 충격파-경계층 간섭 실험 Shadowgraph 결과 이미지

Fig. 7. 은 선행 연구에서 진행한 충격파-경계층 간섭 실험의 평판 표면 압력에 대한 실험값과 CFD값을 비교한 그래프이다⁽⁶⁾. y축은 자유류 압력 대비 평판의 압력으로 Separation이 시작되기 직전까지 1을 유지하다 Separation이 시작되는 지점에서 1 이상으로 값이 증가하는 것을 알 수 있다. 본 연구에서도 자유류 대비 표면압력 값이 1 이상인 지점을 박리 지점으로 생각하고 연구를 진행하였다.

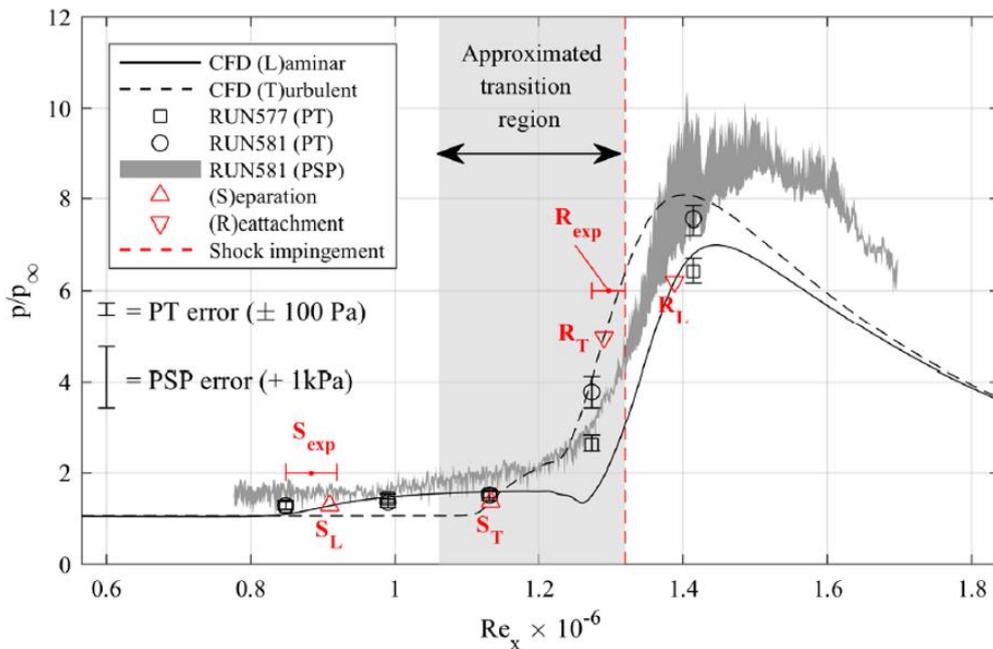


Fig. 7. 선행 연구의 압력 측정 결과 그래프

Fig. 8. 은 충격파-경계층 간섭 실험의 평판 표면 압력 측정 결과를 나타낸다. Fig. 8. 의 (1)은 충격파-경계층 간섭 실험 유동 가시화 결과인 Shadowgraph 결과 이미지에 압력 홀의 위치를 표시한 이미지이다. Fig. 8. 의 (2)는 15개의 압력 홀에서 측정한 평판 표면 압력 측정 결과이다. 1번에서 5번 압력 홀까지는 박리영역에 해당하고 Fig. 8. 의 (1) 이미지에서 7번 압력 홀 지점에서 Reattachment가 발생하고 8번 압력 홀 지점에서 최고 압력 값을 보인다. Fig. 8. 은 여러 가지 실험 Case 중 썰기 각도 16°인 Case를 보여주고 있다. 다른 각도의 썰기를 사용한 Case의 압력 분포도 Fig. 8. 의 결과와 흡사한 충격파 구조나 압력 분포의 경향을 보인다⁽⁸⁾.

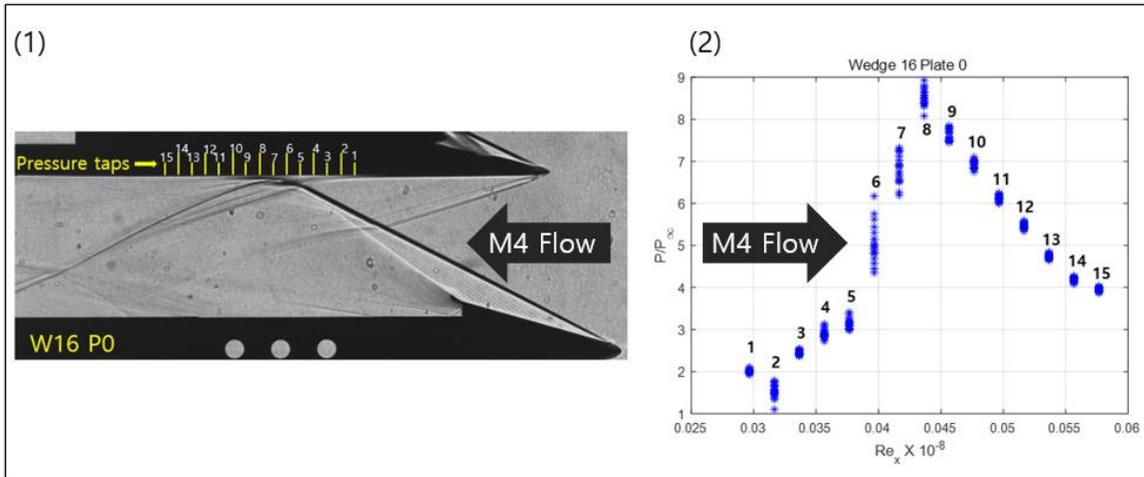


Fig. 8. 평판 표면 압력 측정 결과, (1) Shadowgraph 상 압력 홀의 위치, (2) 압력 측정 그래프

실험 결과 데이터 검증 절차

기계학습을 진행하기 전 실험 결과에 대한 검증을 위해 CFD 계산, Oil Flow Visualization을 진행하였다. 충격파 구조, 평판 표면 압력 분포 검증을 위해 CFD계산을 진행하였고 평판 표면 Streamline 비교 분석을 위해 Oil Flow Visualization을 진행하였다.

CFD 계산은 3차원 충격파-경계층 간섭 현상 계산을 위해 3차원 압축성 Navier-Stokes 방정식을 사용하였다. 계산은 In-house 코드인 KFLOW를 사용하였고 Reynolds-Averaged Navier-Stokes 코드를 이용하였다. CFD 유동 조건은 실험 유동 조건과 동일하게 설정하였다. 유동정보 및 수치기법은 Table 2. 와 같다.

Table 2. 유동정보 및 수치기법

유동정보	Mach Number	4
	Freestream Pressure	15936 Pa
	Freestream Temperature	67K
	Unit Reynolds Number	1.2E+8(m ⁻¹)
수치기법	Flux Function	AUSM+ scheme
	Turbulent Model	$\gamma - Re_\theta$ Transition
	Flow Type	Steady Flow
	Error Tolerance	1.0E-5

CFD 계산을 통한 평판 표면 압력 분포와 실험값을 비교하는 과정에서 큰 불일치성을 확인하였는데 이는 평판 앞전 형상의 영향으로 판단하였다⁽⁹⁾. Fig. 9. 은 평판 앞전 정밀 측정 결과를 보여준다. Fig. 9. 의 (1)은 평판의 설계 도면이고 Fig. 9. 의 (2)는 평판 앞전의 정밀 측정 결과를 나타낸다.

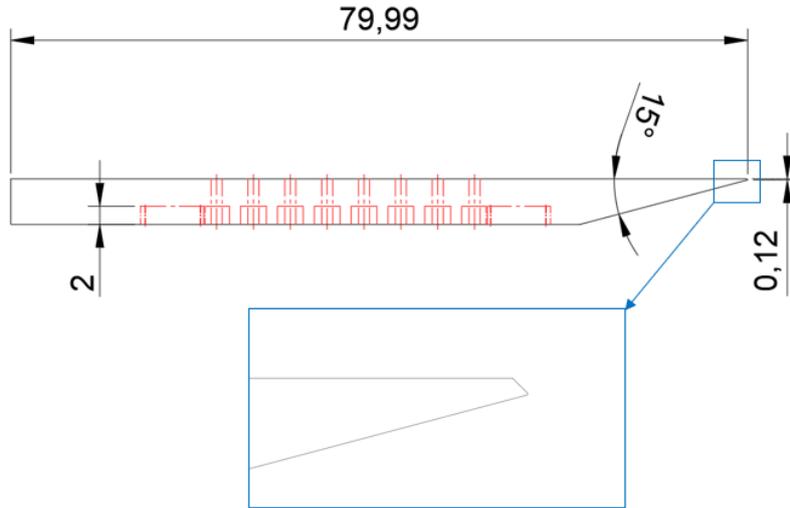


Fig. 9. 평판 앞전 정밀 측정 결과

Fig. 10. 는 평판의 앞전 형상이 평판 표면 압력에 미치는 영향을 보여준다. 뿔기 각도 20°인 Case에 대해서 실험으로 측정한 평판 표면 압력과 이상적인 형상으로 격자를 생성하여 계산한 CFD 값과 정밀 측정 결과로 격자를 생성하여 계산한 CFD 값을 비교하였다. 이상적인 형상인 뾰족한 앞전 형상으로 격자를 생성하여 계산 한 CFD 값은 1번에서 5번 압력 흡 영역에 해당하는 박리영역을 예측하지 못했다. 반면 정밀 측정 결과를 바탕으로 격자를 생성한 CFD 계산은 박리영역도 타당하게 예측하였고 박리영역 후류인 9번에서 15번 압력 흡 구간도 실험값과 높은 정확도를 보이며 잘 예측했다고 판단하였다. 충격파-경계층 간섭 현상이 강한 Unsteadiness 특성을 보이는 것을 고려할 때 Steady Flow로 가정하고 계산한 CFD 값이 신뢰성을 가진다고 판단하였다.

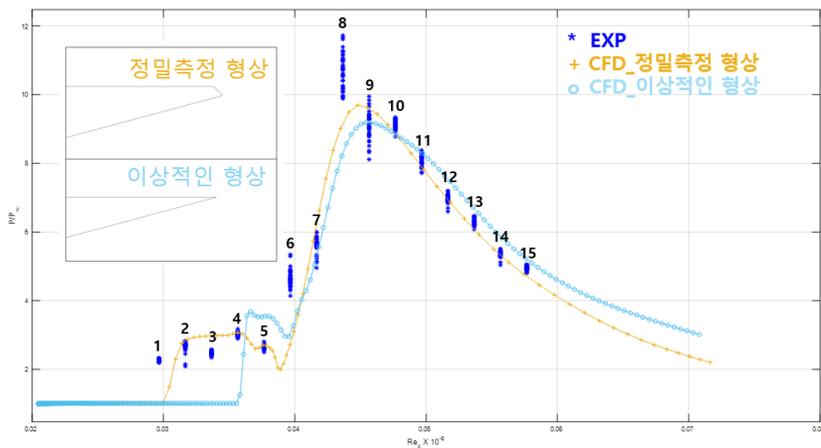


Fig. 10. 평판 앞전 형상이 표면 압력 분포에 미치는 영향

다음으로 Oil Flow Visualization 기법을 이용해서 평판 표면 Streamline을 가시화했고 CFD 결과와 비교하였다. 엔진 오일, 흰색 유화 물감, oleic acid를 적정 비율 혼합하여 도료를 제작하였고 평판 표면에 유동 방향과 수직하게 도포하여 실험을 진행하였다.

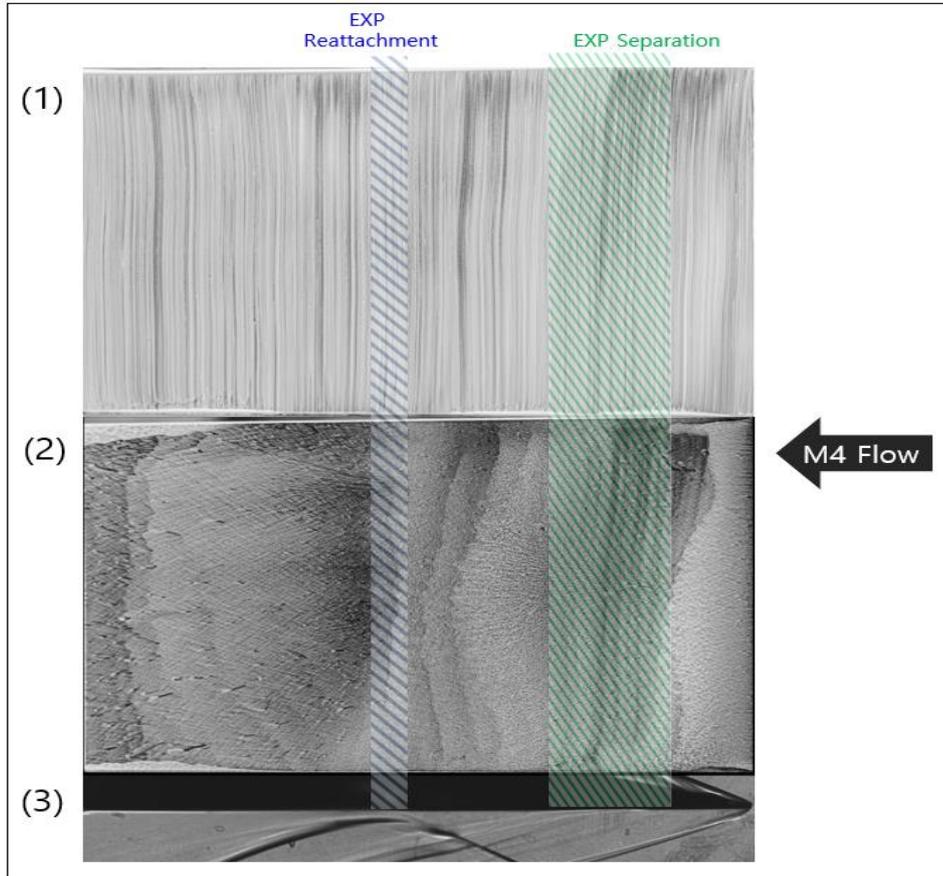


Fig. 11. Oil Flow Visualization 결과, (1)풍동 가동 전, (2)풍동 가동 후, (3) Shadowgraph 결과 이미지

Fig. 11. 은 Oil Flow Visualization 실험 결과를 나타낸다. Fig. 11. 의 (1)은 실험 전 평판 표면에 도료를 도포한 이미지이고 Fig. 11. 의 (2)는 실험 후 평판 표면 결과이다. Fig. 11. 의 (3)은 Shadowgraph 결과 이미지를 나타낸다. Fig. 11. 의 (2)와 (3)을 비교했을 때 박리영역과 Reattachment 지점이 일치하는 것을 확인하였고 Oil flow Visualization 실험이 타당하게 진행되었다고 판단하였다.

Fig. 12. 은 CFD로 계산한 평판 표면 Streamline 결과와 Oil Flow Visualization 결과를 비교한 결과이다. Fig. 12. 의 (1)은 CFD로 계산한 u 속도 유동장 Contour이고 Fig. 12. 의 (2)는 반쪽 평판에 대한 Oil Flow Visualization 결과이고 Fig. 12. 의 (3)은 CFD로 계산한 나머지 반쪽 평판의 표면 Streamline 분포와 u 속도 Contour이고 Fig. 12. 의 (4)는 shadowgraph 결과 이미지를 나타낸다. Fig. 12. 에 영역1은 CFD로 계산한 Reattachment 지점, 영역2는 Oil Flow Visualization 결과와 shadowgraph 결과로 판단한 Reattachment 지점, 영역3은 CFD로 계산한 박리지점, 영역4는 Oil Flow Visualization 결과와 shadowgraph 결과로 판단한 박리 영역 지점을 나타낸다. Reattachment 지점은 계산과 실험에서 높은 일치율을 보였다. 이는 Fig. 10. 에서 정밀 측정 형상으로 계산한 CFD 결과와 실험값의 박리영역 이후의 표면 압력 분포가 높은 일치율을 보이는 결과를 통해 알 수 있다. 반면 Separation 시작 지점은 Fig. 12. 에서 CFD로 계산한 영역3과 Oil Flow Visualization 결과와 shadowgraph 결과로 판단한 영역4의 크기가 큰 차이를 보이는데 이는 앞서 언급한 충격파-경계층 간섭의 unsteadiness 성질의 영향으로, CFD는 unsteadiness 성질을 반영하지 못하고 실험은 unsteadiness 성질을 반영한 것에 대한 결과로 판단한다.

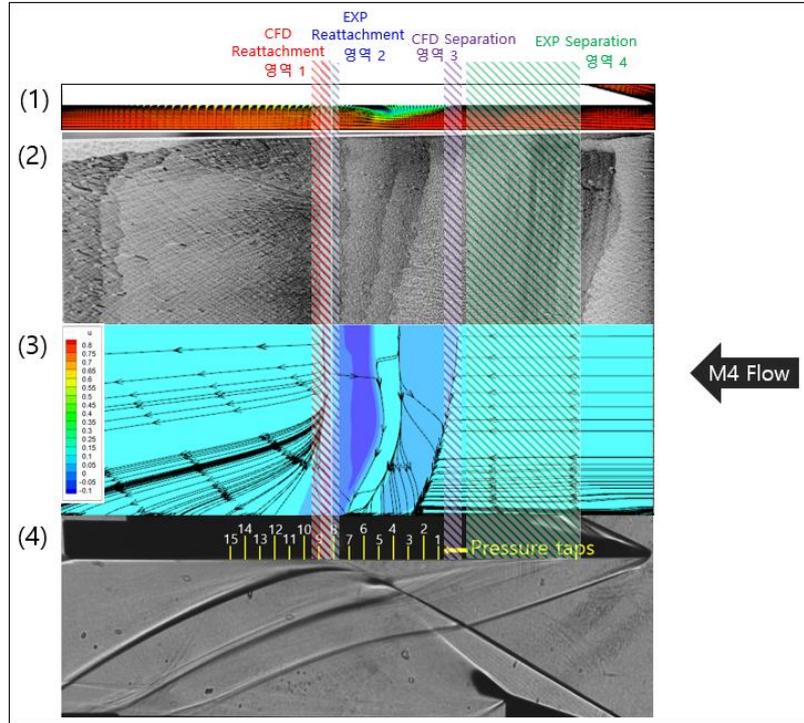


Fig. 12. Shadowgraph, CFD, Oil Flow Visualization 결과 비교, (1) CFD u Contour, (2) 풍동 가동 후 Oil Flow Visualization, (3)CFD 평판표면 u Contour 및 Streamline, (4) Shadowgraph 결과 이미지

결과적으로 Unsteadiness 성질 반영 여부에 따라 Separation 시작 지점을 예측함에 있어 CFD 계산 값과 실험 값은 오차를 보이지만 그럼에도 Fig. 10. 와 Fig. 12. 을 통해 Separation 영역 내부 압력, 최고 압력 값, 최고 압력 지점, 후류 압력 분포는 높은 일치율을 보이기 때문에 신뢰도를 갖는다고 판단하였다. 따라서 추후 기계학습 결과로 도출된 충격파 구조나 평판 표면 압력을 검증할 때 앞서 언급한 것과 동일한 격자 생성 방법과 수치 기법을 사용해도 신뢰성을 확보할 수 있다고 판단하였다.

학습을 위한 데이터 확보

Fig. 13. 는 충격파-경계층 간섭 현상이 발생하는 지점의 대략적인 충격파 구조를 나타낸다. Fig. 13. 에 표시된 S지점은 경계층 Separation이 시작되는 지점으로 Foot of Separation Shock이라고 정의된다. 앞서 언급한 대로 Foot of Separation Shock 지점은 강한 Unsteadiness 성질을 가지며 유동 진행 방향으로 앞뒤로 진동한다⁽¹⁰⁾. Foot of Separation Shock의 진동으로 박리영역의 시작 지점은 초고속 카메라가 획득하는 모든 이미지에서 조금씩 다른 지점에 위치하며 기계학습에 사용할 충분한 수의 이미지를 얻을 수 있다. 10,000 fps의 촬영 조건에서 한번 실험할 때마다 정상 유동 시간 내 약 600장의 Shadowgraph 결과 이미지를 획득할 수 있다.

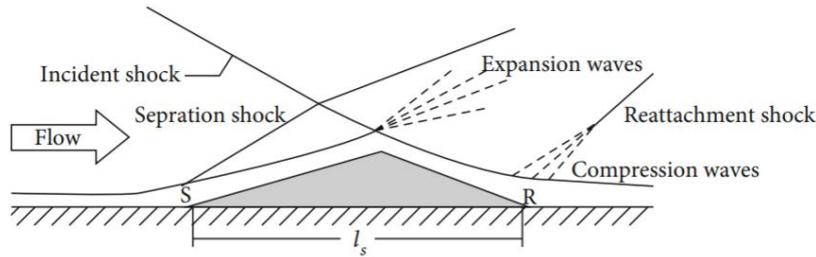


Fig. 13. 충격파-경계층 간섭 현상의 충격파 구조

충격파 구조 예측을 위한 기계학습은 두 가지 단계를 거쳐 진행하였다. 첫 번째 학습은 코드 검증의 절차로 경사 충격파 관계식의 해를 구해 MATLAB으로 생성한 이미지를 사용하여 경사 충격파 구조 예측 가능 여부를 판단하였다. 두 번째 학습은 실제 실험 이미지를 학습하여 충격파 구조 예측을 진행하였다. 먼저 코드 검증 절차에 사용한 경사 충격파 관계식은 식 (1)과 같다.

$$\tan(\theta) = 2 \cot(\beta) \left[\frac{M^2 \sin^2(\beta) - 1}{M^2(\gamma + \cos(2\beta) + 2)} \right] \tag{1}$$

식 (1)에서 θ 는 썩기의 각도, β 는 경사 충격파의 각도, M 은 자유류 마하수를 의미한다. Fig. 14. 은 MATLAB을 이용하여 식 (1)의 해를 구해 마하수 4 조건에서 만들어낸 경사 충격파 생성 전후의 이미지이다. θ 각도를 10° 에서 40° 까지 0.01° 간격으로 3,000장의 이미지를 생성하여 학습을 진행하였다. 3000개의 데이터 중 2400개의 데이터는 학습에 사용하였고 600개의 데이터는 Validation을 위해 사용하였다.

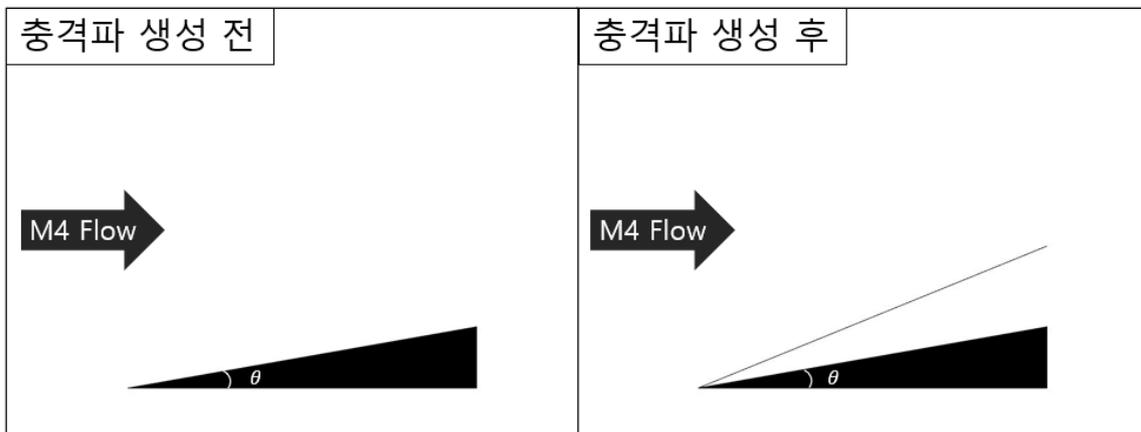


Fig. 14. MATLAB으로 생성한 경사 충격파 생성 전후 이미지

실제 실험 이미지를 사용하여 진행한 학습은 초고속 카메라로 획득한 Shadowgraph 결과 이미지를 사용하여 진행하였다. 앞서 언급한 바와 같이 Foot of Separation Shock 지점이 앞뒤로 진동하기 때문에 한 번의 실험에서 학습에 사용할 수 있는 이미지가 약 600장 얻어지고 학습을 위해 썩기 각도를 14° 에서 20° 까지 2° 간격으로 변경하며 이미지를 획득하였고 Fig. 4. 에 표시된 썩기 지지대를 통해 썩기의 위치를 앞뒤로 이동시키며 총 8,400장의 Shadowgraph 결과 이미지를 획득하여 학습을 진행하였다. 8,400개의 데이터 중 7,620개의 데이터는 학습에 사용하였고 1,680개의 데이터는 Validation을 위해 사용하였다.

다음으로 평판 표면 압력 예측을 위한 데이터 확보 절차이다. 압력 측정은 Pressure Scanner를 사용하여 진행하였다. 사용한 Pressure Scanner는 Fig. 15. 와 같다.

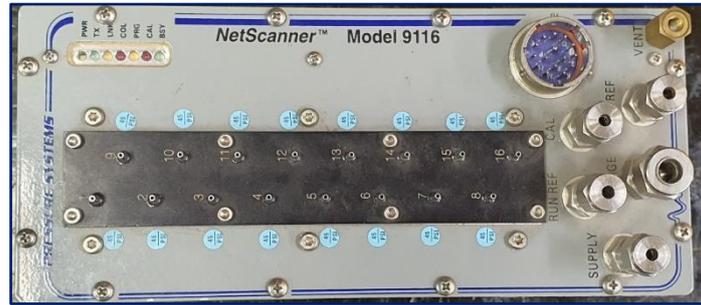


Fig. 15. 평판 표면 압력 측정에 사용한 Pressure Scanner (Net Scanner 9116)

한 번의 실험 진행 시 정상 유동 구간에서 약 600장의 Shadowgraph 결과 이미지를 얻을 수 있는 반면 Pressure Scanner는 약 10개의 압력 데이터를 얻는다. 따라서 Data Augmentation 과정을 거쳐 이미지 데이터와 같은 수의 압력 데이터를 생성하였다. Data Augmentation이란 기계학습에서 사용되는 데이터 증강 기법이다. 기존 데이터에서 약간 수정된 사본 혹은 기존 데이터에서 새로 생성된 데이터를 추가하여 데이터양을 늘린다. 또한 Data augmentation은 정규화 역할을 하며 기계학습에서 overfitting을 줄이는 효과를 동반한다⁽¹¹⁾. Fig. 8. 의 (2)는 10회 반복실험을 통해 측정된 압력 값을 나타낸다. 10회의 반복실험을 통해 15개 측정점의 압력 값 변동 범위를 파악하였고 각 측정점의 최대, 최소값 범위 내에서 Data Augmentation을 진행하였다. 학습에 사용될 평판 표면 압력 데이터는 충격파 구조 예측을 위한 학습데이터와 동일하게 8,400개의 데이터를 확보하였다. 8,400개의 데이터 중 6,720개의 데이터는 학습에 사용하였고 1,680개의 데이터는 Validation을 위해 사용하였다.

2. 충격파 구조 예측

충격파 구조 예측을 위한 CNN의 구조

CNN(Convolution Neural Network)이란 동물의 시각 신경 구조를 모방해 만들어진 딥러닝 신경망 모델이다. Convolution이란 일정 영역의 값들에 대해 가중치를 적용하여 하나의 값을 만드는 연산으로 Convolution 필터가 일정 영역에서 필터의 가중치와 데이터 값을 곱하여 더하는 연산이다⁽¹²⁾. Fig. 16. 은 Convolution 필터의 계산 과정을 나타낸다.

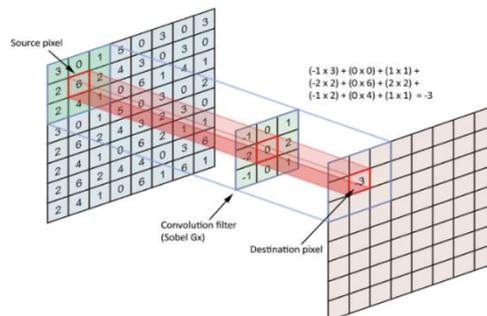


Fig. 16. Convolution 필터의 계산 과정

Fig. 16. 에 표시된 Source Pixel을 Convolution 필터가 훑고 지나가며 Destination Pixel 값을 연산한다. Convolution 연산과 Pooling 과정이 반복되면서 이미지에서 특징을 추출한다. 초음속 유동장

예측을 위해 Fig. 17. 과같이 U자 형태의 CNN 구조를 사용하였다. U-Net으로 알려진 이 신경망 구조는 Convolution, Max-pooling, Up-convolution 과정이 반복되며 대칭형 구조를 갖는다. Input Image를 Convolution과 Max-pooling 과정 거치며 특징을 추출하고 Up-convolution 과정을 거치며 이미지의 크기를 원상태로 되돌리며 Weight를 업데이트한다. 그 과정에서 Skip Connection을 통해 기존 이미지의 정보를 보존하며 업데이트되는 이미지 정보를 덮어씌운다. 마지막 레이어의 Activation Function은 Sigmoid Function을 사용하였다.

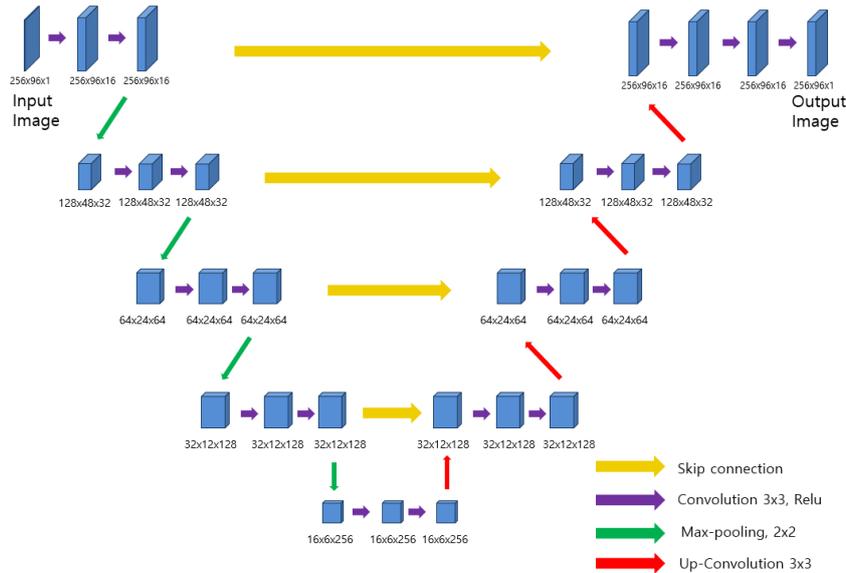


Fig. 17. 총격파 구조 예측 학습에 사용된 U-Net 신경망의 구조

총격파 구조 예측 결과

학습을 마친 기계학습 모델의 성능 검증을 위해서 PPT 프로그램을 이용하여 이미지를 생성하였다. PPT 프로그램으로 실험 이미지를 생성하면 간편하게 모델의 위치나 모양을 변경할 수 있다는 장점이 있다.

먼저 MATLAB으로 생성한 이미지를 학습한 기계학습 모델이 예측한 경사 총격파 구조가 경사 총격파 관계식을 만족하는지 확인하기 위한 절차를 진행하였다. Fig. 18. 은 PPT 프로그램으로 생성한 임의의 썩기 모델에 대해 기계학습 모델이 예측한 경사 총격파 구조 예측 결과이다. Fig. 18. 의 썩기 모델(1)에서 썩기의 각도 θ_1 은 식 (2)를 사용하여 계산하고 경사 총격파 각도 β_1 은 식(3)을 사용하여 계산할 수 있다. 마찬가지로 썩기 모델(2)에서 썩기의 각도 θ_2 는 식 (4)를 사용하고 경사 총격파 각도 β_2 은 식(5)을 사용하여 계산할 수 있다. 썩기 모델(1)에 대해서 기계학습 모델이 예측한 경사 총격파의 각도는 약 40.116°이고 경사 총격파 관계식을 통해 계산한 이론 값은 40.259°로 약 0.35%의 오차를 보였다. 마찬가지로 썩기 모델(2)에 대해서 기계학습 모델이 예측한 경사 총격파의 각도는 약 51.709°이고 경사 총격파 관계식을 통해 계산한 이론 값은 약 51.407°로 약 0.58%의 오차를 보인다. 따라서 총격파의 구조를 예측하는 코드의 구현이 성공적이라고 판단하였다.

$$\theta_1 = \tan^{-1} \frac{b}{a} = 26.426^\circ \tag{식(2)}$$

$$\beta_1 = \tan^{-1} \frac{c}{a} = 40.116^\circ \tag{식(3)}$$

$$\theta_2 = \tan^{-1} \frac{b}{a} = 33.929^\circ \quad \text{식(2)}$$

$$\beta_2 = \tan^{-1} \frac{c}{a} = 51.709^\circ \quad \text{식(3)}$$

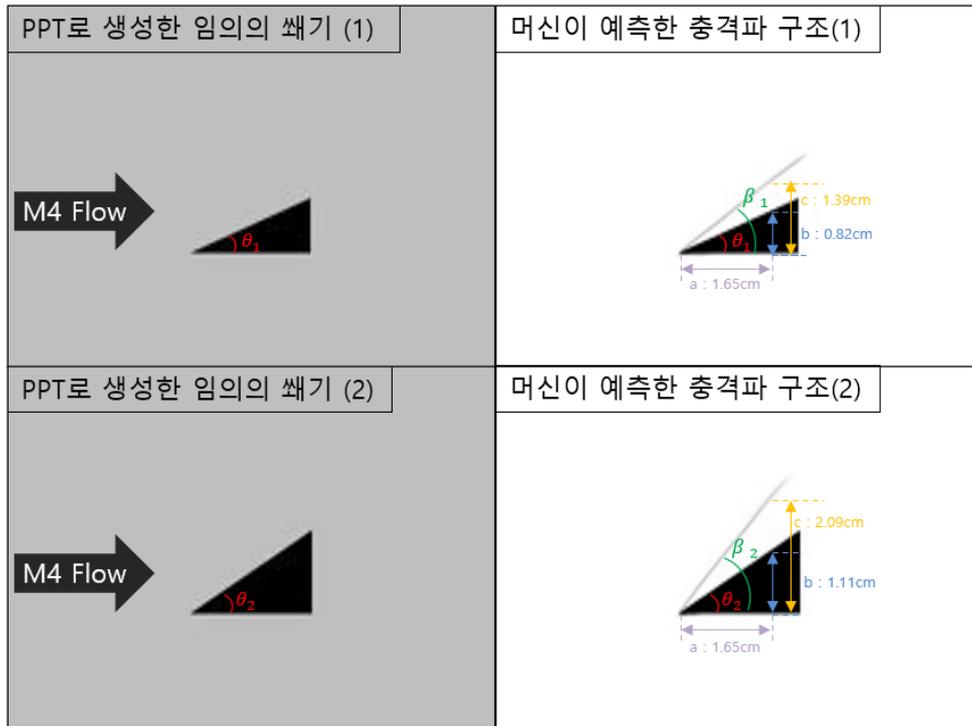


Fig. 18. PPT 프로그램으로 생성한 임의의 쇄기 모델에 대해서 기계학습 모델이 예측한 경사 충격파 구조

다음으로 Shadowgraph 결과 이미지를 학습한 기계학습 모델의 성능 검증을 진행하였다. 검증은 두 가지 단계로 진행하였다. 첫 번째로 학습 데이터와 정확히 일치하는 형상을 PPT 프로그램으로 생성하여 검증을 진행하였고, 두 번째로 학습에 사용하지 않은 형상을 PPT 프로그램으로 생성하여 검증을 진행하였다. Fig. 19. 은 학습데이터와 정확히 일치하는 형상을 PPT 프로그램으로 생성하고 기계학습 모델로 예측한 결과를 나타낸다.

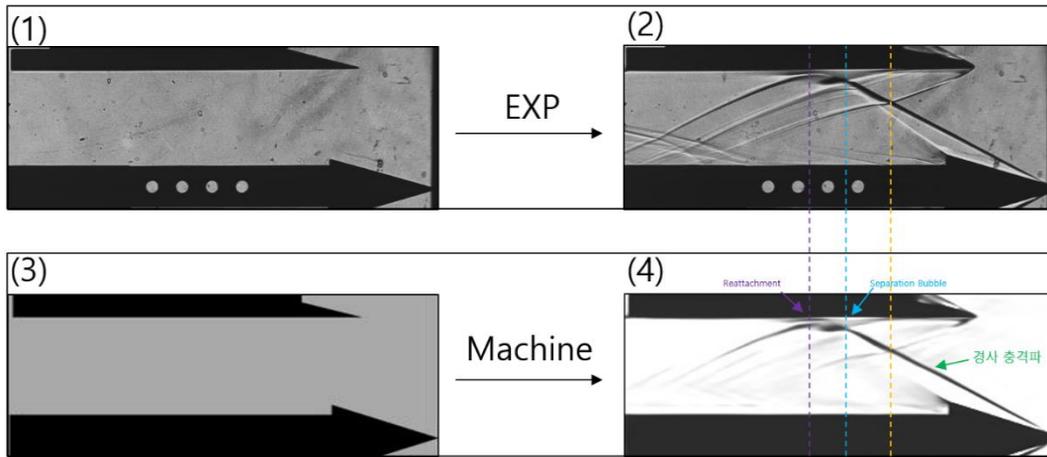


Fig. 19. 학습 데이터와 일치하게 PPT 프로그램으로 생성한 형상에 대한 기계학습 모델의 예측 결과
 (1) 풍동 가동 전 Shadowgraph 결과 이미지, (2) 풍동 가동 후 Shadowgraph 결과 이미지,
 (3) PPT 프로그램으로 생성한 (1)과 동일 형상의 모델 이미지, (4) 기계 학습 모델이 예측한 충격파 구조

Fig. 19. 의 (1)은 풍동 가동 전 Shadowgraph 결과 이미지, Fig. 19. 의 (2)는 풍동 가동 후 Shadowgraph 결과 이미지, Fig. 19. 의 (3)은 Fig. 19. 의 (1)형상과 정확히 일치하도록 PPT 프로그램으로 생성한 이미지, Fig. 19. 의 (4)는 Fig. 19. 의 (3)이미지에 대해 기계학습 모델이 예측한 충격파 구조이다. Fig. 19. 의 (1), (2), (3), (4)는 모두 뺨기 모델의 각도 14°인 같은 형상에 대한 이미지이다. Fig. 19. 의 (2)와 Fig. 19. 의 (4)를 비교해보면 경사 충격파를 비롯하여 Reattachment, 박리영역, Foot of Separation Shock 지점의 위치가 높은 일치율을 보이는 것을 확인할 수 있다.

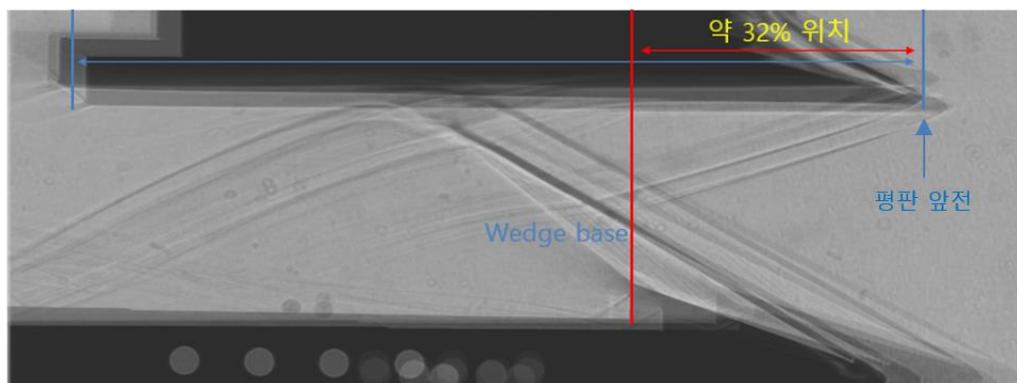


Fig. 20. 학습 데이터를 겹쳐 놓은 이미지

두 번째로 기계학습 모델이 학습하지 않은 형상에 대한 충격파 구조 예측을 진행하였다. Fig. 20. 는 모든 Shadowgraph 학습 데이터를 겹쳐 놓은 결과이다. Fig. 20. 에 표시된 Wedge Base 선은 겹쳐진 여러 뺨기 모델의 Base 중 유동 방향 기준으로 가장 후류에 위치한 뺨기 모델의 Base 위치를 나타낸다. 이 선은 평판의 길이 대비 평판 앞전에서부터 약 32% 지점에 위치하고 있다. 학습에 사용하지 않은 형상 역시 PPT 프로그램을 사용하여 생성하였으며 Fig. 20. 의 뺨기의 위치와 중복되지 않게 생성하였다.

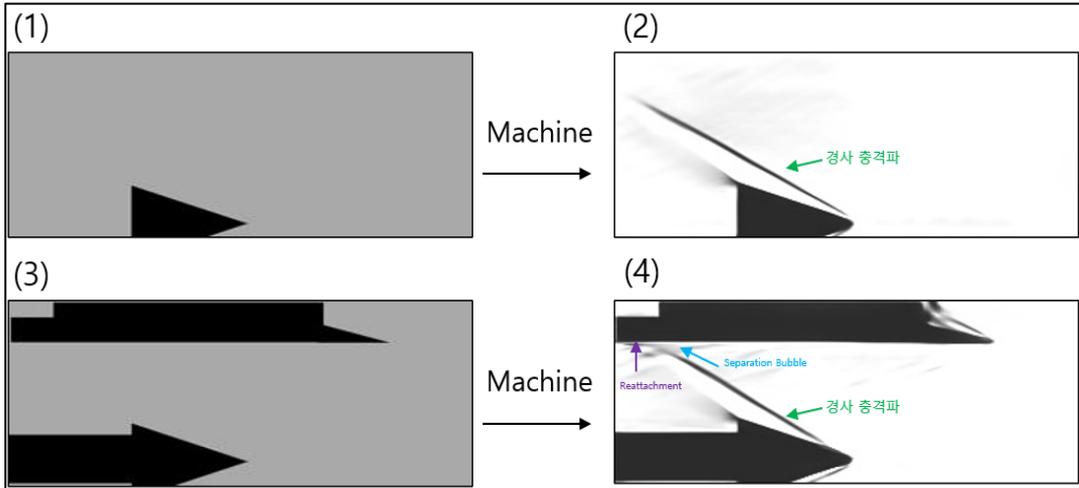


Fig. 21. 학습에 사용하지 않은 형상에 대한 충격파 구조 예측, (1) PPT 프로그램으로 생성한 뺨기 모델 이미지, (2) (1)형상에 대한 기계학습 모델의 충격파 구조 예측 결과, (3) PPT 프로그램으로 생성한 충격파-경계층 모델 이미지, (4) (3)형상에 대한 기계학습 모델의 충격파 구조 예측 결과

Fig. 21. 는 학습에 사용하지 않은 형상에 대한 충격파 구조 예측 결과이다. Fig. 21. 의 (1), (2) 이미지는 17° 뺨기 모델에 대한 충격파 구조 예측 결과를 나타낸다. 앞서 진행했던 코드의 검증에 위한 학습은 모든 데이터가 뺨기 모델 형상으로만 구성되어 있고 실제 실험 데이터를 사용한 학습은 충격파-경계층 간섭 현상에 대한 형상으로만 구성되어 있다. Fig. 21. 의 (2) 이미지에서 뺨기의 각도는 17°, 경사 충격파 각도는 약 30°로 충격파 관계식을 만족하는 것을 확인하였는데 이를 통해 평판과 뺨기가 함께 구성된 데이터를 학습해도 기계학습 모델이 경사 충격파 관계식을 잘 학습했다고 판단하였다. 또한 기계학습 모델이 평판과 뺨기 모델에 해당하는 충격파의 형상을 인식해서 학습했다고 판단하였다. Fig. 21. 의 (3) 이미지는 PPT 프로그램으로 생성한 뺨기 각도 17°인 충격파-경계층 간섭 모델이다. 뺨기 모델을 Fig. 20. 의 뺨기 위치보다 후류 쪽으로 이동시켜 충격파 구조를 예측하였다. Fig. 21. 의 (4)의 이미지 역시 뺨기에서 발생한 경사 충격파가 평판에 부딪히며 발생하는 박리영역, Reattachment 등의 충격파 구조를 잘 예측한 것을 확인하였다.

3. 평판 표면 압력 예측

평판 표면 압력 예측을 위한 CNN의 구조

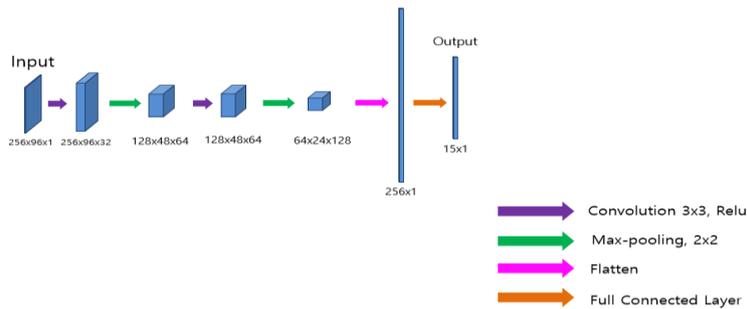


Fig. 22. 평판 표면 압력 학습에 사용된 LeNet 신경망 구조

평판 표면 압력 예측을 위해 Fig. 22. 과 같은 CNN 구조를 사용하였다. LeNet으로 알려진 이 신경망 구조는 가장 기본적인 신경망 구조로서 두 개의 Convolution 층, 두 개의 Max-pooling 층, 하나의 Full connected Layer로 구성된다. Convolution과 Max-pooling 과정 거치며 특징을 추출하며 15개의 압력 값을 출력한다. 마지막 레이어의 Activation function은 linear function을 사용하였다.

평판 표면 압력 예측 결과

평판 표면 압력 학습은 입력 값이 충격파 이미지이고 출력 값은 표면 압력 값이다. 따라서 앞서 진행하였던 충격파 예측의 결과 이미지를 입력 값으로 사용하여 표면 압력 예측을 진행하였다. 표면 압력 예측은 두 가지 단계로 진행하였다. 먼저 평판 표면압력 학습에 사용된 형상과 정확히 일치하는 형상에 대한 압력 값 예측을 진행하였다. 다음으로 학습하지 않은 형상에 대한 평판 표면 압력 예측을 진행하였다. Fig. 23. 는 학습에 사용한 형상과 정확히 일치하는 형상에 대한 평판 표면 압력 예측 결과를 나타낸다. Case 1과 case 2 두가지 형상에 대해 평판 표면 압력 예측을 진행하였다. Fig. 23. 의 (1), (5) 이미지는 실험에서 획득한 Shadowgraph 결과 이미지이고 Fig. 23. 의 (2), (6) 이미지는 Fig. 23. 의 (1), (5) 형상과 정확히 일치하게 PPT 프로그램으로 생성한 이미지이다. Fig. 23. 의 (3), (7)은 충격파를 예측하는 기계학습 모델을 이용해서 예측한 충격파 이미지이다. 마지막으로 Fig. 23. 의 (4), (8)은 Fig. 23. 의 (3), (7) 형상에 대해 기계학습 모델을 이용해 평판 표면 압력을 예측한 결과이다. Fig. 23. 의 (4), (8)그래프에서 검은색 점은 실험에서 획득한 평판 표면 압력이고 빨간색 점은 기계 학습 모델이 예측한 압력이다. x축은 Pressure Tap의 번호이다. 기계학습 모델이 예측한 값이 실험값과 높은 정확도를 가지며 일치하는 것을 확인할 수 있다.

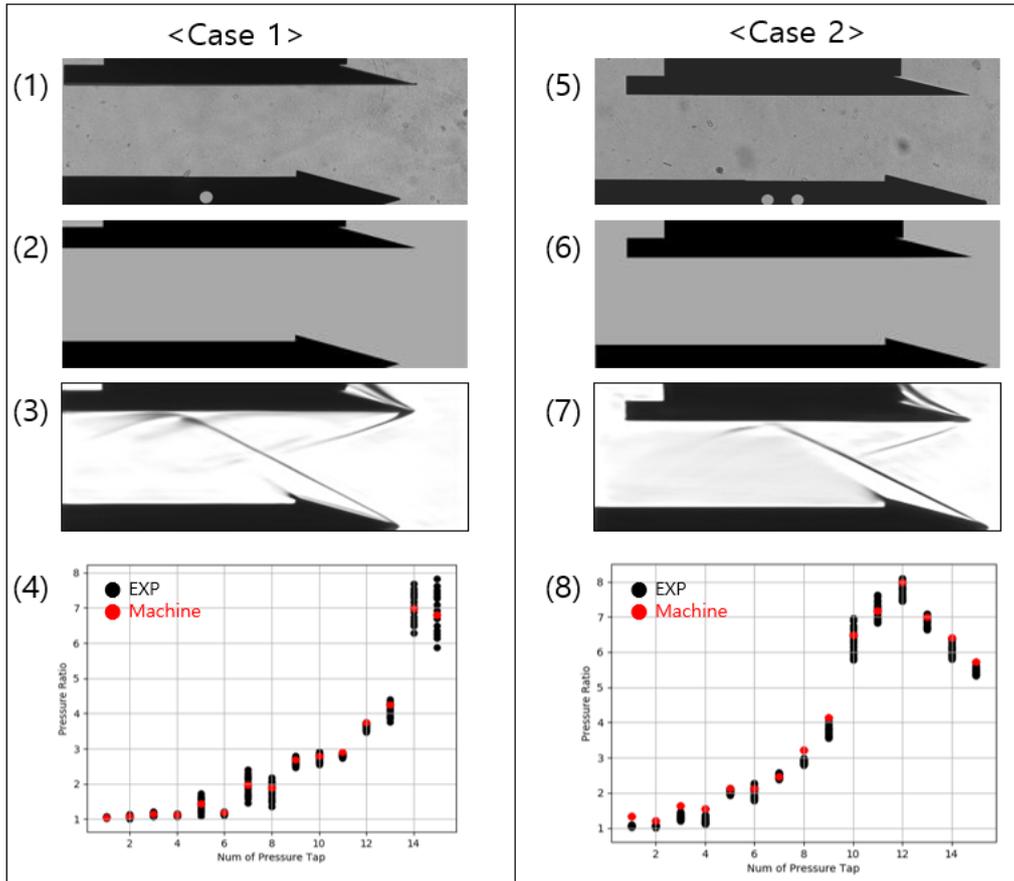


Fig. 23. 학습 데이터와 정확히 같은 형상에 대한 평판 표면 압력 예측

(1) 풍동 가동 전 Shadowgraph 결과 이미지, (2) (1)형상과 동일하게 생성한 이미지, (3) (2)형상에 대해 기계 학습 모델이 예측한 충격파 구조, (4) (3) 이미지에 대해 기계학습 모델이 예측한 압력 값과 실험값 비교 그래프, (5) 풍동 가동 전 Shadowgraph 결과 이미지, (6) (5)형상과 동일하게 생성한 이미지, (7) (6)형상에 대해 기계 학습 모델이 예측한 충격파 구조, (8) (7) 이미지에 대해 기계학습 모델이 예측한 압력 값과 실험값 비교 그래프

다음으로 학습에 사용하지 않은 형상에 대한 평판 표면 압력 예측을 진행하였다. 학습에 사용하지 않은 형상 역시 PPT 프로그램으로 생성하였으며 Fig. 20. 를 참고하여 쇄기의 위치가 학습 이미지와 겹치지 않게 하였다. 네 가지 Case의 형상에 대해서 기계학습 모델이 예측한 표면 압력 값과 동일 형상에 대한 CFD 계산을 통해 충격파 구조 및 평판 표면 압력을 비교 분석하였다. 먼저 충격파 구조 예측을 진행하였다. Fig. 24, Fig. 25, Fig. 26, Fig. 27은 각각 Case 3, Case 4, Case 5, Case 6 형상에 대해 기계학습 모델이 예측한 충격파의 이미지와 CFD 밀도 Contour를 나타낸다. Case 3, Case 4, Case 5, Case 6은 쇄기 모델을 Fig. 20. 에 나타난 쇄기 모델과 겹치지 않게 생성하였으며 각 case의 쇄기 모델 위치는 Table. 과 같다. 네 가지 Case 모두 학습 데이터들보다 쇄기와 평판의 거리가 가깝도록 설정하여 실험실 환경상 구현할 수 없는 쇄기의 위치를 구현하였다.

Table 2. 학습에 사용하지 않은 형상 데이터의 뺄기 위치 정보

	평판 앞전으로부터 위치	평판에서 뺄기의 앞전까지의 높이
Fig. 20의 뺄기위치	약 32 %	1
Case 3의 뺄기위치	약 37 %	0.86
Case 4의 뺄기위치	약 75 %	0.5
Case 5의 뺄기위치	약 32 %	0.69
Case 6의 뺄기위치	약 47 %	0.63

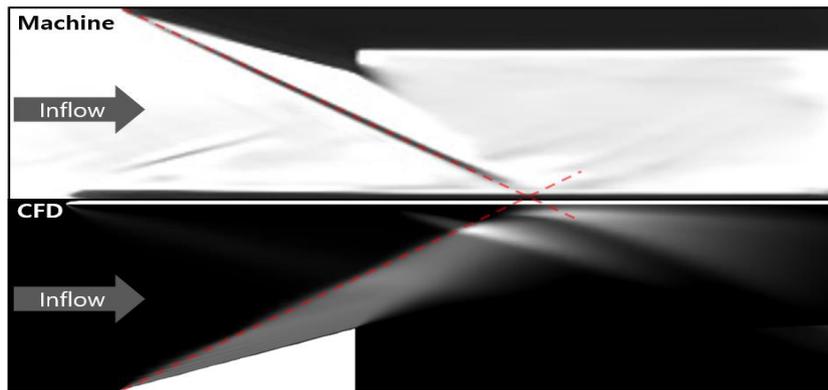


Fig. 24. Case 3의 유동 구조 비교

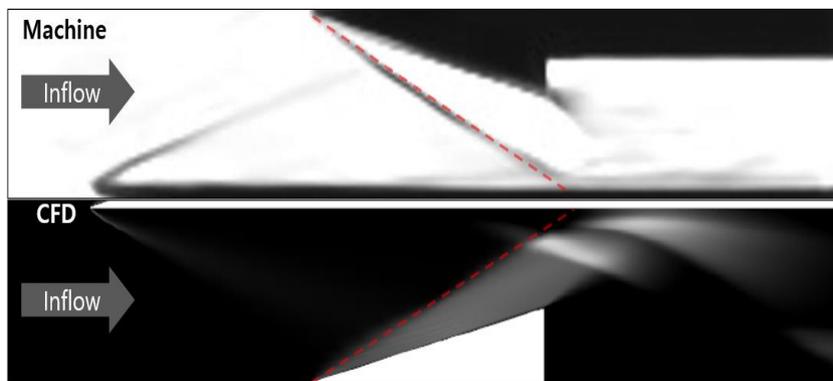


Fig. 25. Case 4의 유동 구조 비교

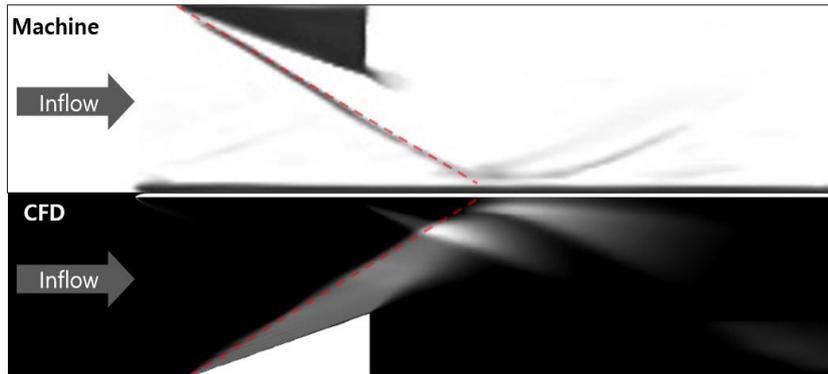


Fig. 26. Case 5의 유동 구조 비교

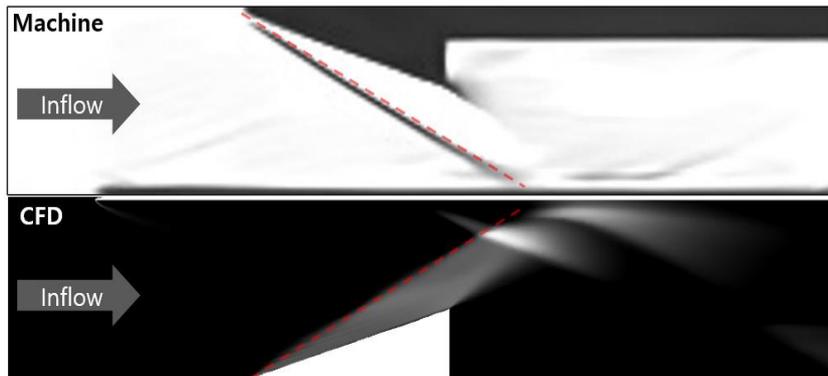


Fig. 27. Case 6의 유동 구조 비교

학습에 사용하지 않은 형상에 대해 기계학습 모델이 예측한 경사 충격파와 CFD의 경사 충격파가 평판의 같은 위치에 부딪히는 것으로 기계학습 모델이 예측한 충격파의 구조가 타당하다고 판단하였다. 따라서 기계학습 모델이 예측한 충격파 이미지를 사용하여 평판 표면 압력 예측을 진행하고 이를 CFD 계산을 통한 평판 표면 압력 값과 비교하였다. Fig. 28. 은 Case 3, Case 4, Case 5, Case 6에 대한 기계 학습 모델이 예측한 평판 표면 압력 값과 CFD계산 값을 비교한 그래프이다.

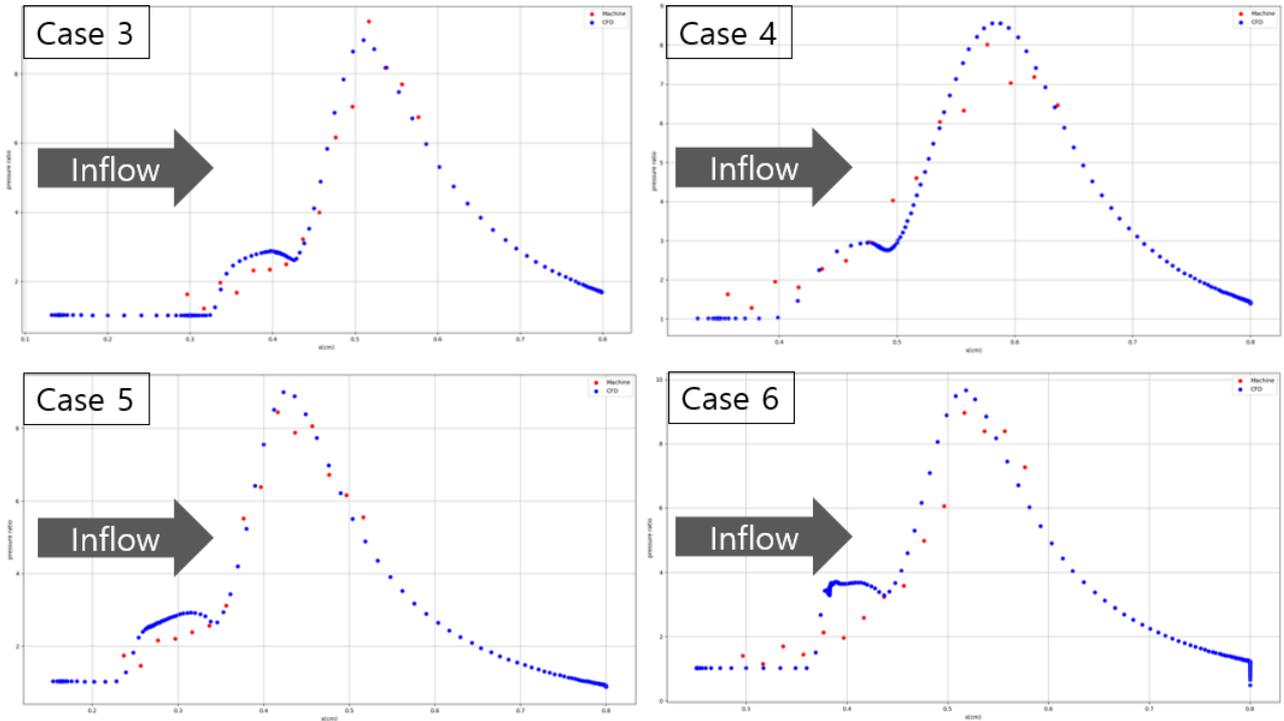


Fig. 28. 학습하지 않은 형상에 대한 기계학습 모델이 예측한 평판 표면 압력과 CFD 계산 값과의 비교

빨간 점은 기계학습 모델이 예측한 평판 표면 압력이고 파란 점은 CFD로 계산한 평판 표면 압력이다. 박리영역 후류에서 발생하는 최고 압력 지점의 위치와 그 값을 잘 예측하였다고 판단하였다. Separation 시작 지점은 앞서 언급하였던 Unsteadiness 반영 차이로 오차가 발생하였는데 기계학습 모델이 실험 값에 나타난 Unsteadiness 성질을 학습한 것으로 판단한다

결론

본 연구에서는 기계학습을 통해 일반적인 초음속 실험 절차를 축약할 수 있는 방법을 제시하였다. 충격파-경계층 간섭 실험 데이터를 이용하여 학습을 진행했고 기계 학습 모델을 이용하여 충격파 구조와 표면 압력을 예측하였다. 그 결과 기계학습 모델이 예측한 충격파의 구조와 표면 압력 값이 CFD 계산 값과 높은 일치율을 보였다. 이는 기계 학습 모델이 초음속 유동에 적용되는 물리현상을 파악하고 있다고 해석되므로 수식을 통해 해를 얻는 기존의 연구 방식과 다른 관점의 해석을 가능하게 한다.

학습된 기계 학습 모델을 보유한 상태라면 간단한 이미지 생성 프로그램을 사용하여 손쉽게 실험 모델의 위치를 바꾸거나 형상을 바꾸면서 빠른 시간내에 다양한 실험 Case에 대한 정보 획득이 가능하다. 풍동 장비, 실험 기법을 구현하기 위한 장비, CFD 계산을 위한 컴퓨팅 파워 등을 고려하면 본 연구에서 제시한 기계학습 모델의 높은 비용 절감 효과를 기대할 수 있다.

학습에 필요한 많은 데이터 확보의 어려움은 기계학습의 극복 과제로 거론된다. 하지만 본 연구에서 사용한 Ludwig Tube의 긴 정상 유동 시간을 활용하면 다수의 데이터를 비교적 쉽게 획득할 수 있다. 본 연구에서는 충격파-경계층 간섭 현상에 대한 데이터를 학습에 사용하였지만 간단한 충격파 구조를 갖는 썬기 모델 실험부터 복잡한 충격파 구조를 갖는 Scramjet Inlet 내부유로 실험까지 넓은 범위에서 활용될 수 있음을 확인하였다.

현재까지 진행 사항으로 기존의 실험과 CFD를 완벽히 대체할 수 있다고 주장하기에는 어려움이 있다. 하지만 새로운 초음속 비행체 개발 초기 단계에 이상적인 충격파 배치를 찾거나 압력 분포를 예측하는 작업에 소요되는 시간적, 비용적 절감 효과가 클 것으로 기대한다.

참고문헌

- [1] Krishnan, L., Sandham, N.D. and Steelant, J, “Shock-Wave/Boundary-Layer Interactions in a Model Scramjet Intake” AIAA Journal, vol, 47, pp, 1680–1691, July 2009.
- [2] Y.Afshar, Saakaar Bhatnagar, Shaowu Pan, K. Duraisamy and S. Kaushik, “Prediction of Aerodynamic Flow Fields Using Convolutional Neural Networks”, Computational Mechanics, Vol, 64, pp, 525–545, 2019.
- [3] Yunfei Li, J. Chang, Chen Kong and Ziao Wang ,” Flow Field Reconstruction And Prediction of The Supersonic Cascade Channel Based on a Symmetry Neural Network Under Complex And Variable Conditions”, AIP Advances, vol, 10, pp, 065116, 2020.
- [4] Zhixian Ye, Qian Chen, Yang Zhang, Jianfeng Zou and Yao Zheng , “Identification of Vortex Structures in Flow Field Images Based on Convolutional Neural Network and Dynamic Mode Decomposition” , IJETA Journal, vol, 10, pp, 501–506, December 2019.
- [5] Vinothkumar Sekar and Boo Cheong Khoo, “Fast Flow Field Prediction Over Airfoils Using Deep Learning Approach”, Physics of Fluids, vol, 31, pp, 057103, May 2019.
- [6] Gaetano M. D. Currao, “Hypersonic Transitional Shock Wave Noundary Layer Interatcion on a Flat Plate” AIAA Journal, vol, 58, pp, 1–16, November 2019.
- [7] 김영주, 변영환, 박수형, 박기수, 이종국. “건국대학교 Ludwig Tube 개념 설계에 관한 연구” 한국항공우주학회지, vol, 46.9, pp, 703–711. 2018.
- [8] 한민현, 변영환, 박수형. "건국대학교 Ludwig Tube(KULT)를 이용한 충격파-경계층 간섭에 대한 연구." 한국추진공학회 학술대회논문집, pp, 199–200, 2020.
- [9] H. K. CHENG, J. GORDON HALL, T. C. GOLIAN, A. HERTZBERG, “Boundary-Layer Displacement and Leading-Edge Bluntness Effects in High-Temperature Hypersonic Flow” AIAA Journal, vol, 28, May 1961.
- [10] Jean-Paul Dussauge, Pierre Dupont, Jean-François Debiève, “Unsteadiness in Shock Wave Boundary Layer Interactions With Separation” Aerospace Science and Technology, vol, 10, Issue 2, pp, 85–91, 2006.
- [11] Perez, Luis, and Jason Wang. “The Effectiveness of Data Augmentation in Image Classification Using Deep Learning.” ViXra, 2017.
- [12] Yamashita, R., Nishio, M., Do, R.K.G, “Convolutional Neural Networks: an Overview And Application in Radiology”. Insights Imaging, vol, 9, pp, 611–629, 2018.