



Received: 2025/11/29  
Revised: 2025/12/11  
Accepted: 2026/02/20  
Published: 2026/03/31

**\*Corresponding Author:**

Sera Kim  
Bldg. Sonwonil 516-ho, Naval Academy Republic of Korea, Jinhae-gu, Changwon-si, Gyeongsangnam-do, 51704, Republic of Korea  
Tel: +82-55-907-5234  
E-mail: srkim85@gmail.com

**Abstract**

본 연구는 브레이드(매듭) 기반의 이미지 데이터셋(S3braidset)을 구축하고, 이를 활용한 열교환기 적외선(IR) 열영상 분석 가능성을 탐색한다. 총 21종의 브레이드 조합을 기반으로 1500장씩의 증강된 이미지를 생성하였으며, Canny 엣지 검출 기반 전처리와 CNN 기반 학습 모델을 통해 분류 성능을 실험하였다. 특히, 유체 흐름의 시각적 패턴이 브레이드 구조와 유사하다는 점에 착안하여, 해당 데이터셋이 유체 기반 설비의 정체 영역 또는 비정상 흐름 감지에 응용 가능성을 제안한다. 열교환기의 IR 열영상을 분할 및 분석한 결과, S3braidset을 활용한 위상적 이상 패턴 식별이 정량적 진단 도구로서 유의미함을 보였다. 이 데이터셋은 향후 상태기반정비(CBM) 시스템에 통합되어 열영상 기반 이상 진단의 정확도 향상에 기여할 수 있다.

This paper introduces S3braidset, a braid-knot-based image dataset, and explores its use in infrared (IR) thermal image analysis for monitoring heat exchanger conditions. Using 21 braid configurations, we generated 1,500 augmented images per class with geometric transformations and Canny edge-based preprocessing, and trained a CNN to classify the patterns. Motivated by the visual similarity between fluid-flow structures and braided forms, we apply the dataset to detect stagnation zones and flow irregularities in fluid-related equipment. Experiments on segmented heat-exchanger IR images show that S3braidset can identify topological anomalies, providing a quantitative and interpretable basis for thermal diagnostics. The dataset is promising for integration into condition-based maintenance (CBM) systems to improve the accuracy and explainability of thermal anomaly detection.

**Keywords**

브레이드 이미지(Braid Image), 매듭 기반 데이터셋(Knot-Based Dataset), 열영상 분석(Thermal Image Analysis), 유체 흐름 시각화(Fluid Flow Visualization), 상태기반정비(CBM)(Condition-Based Maintenance)

**Acknowledgement**

이 논문은 2025년 한화시스템(주)의 재원을 지원 받아 수행된 연구임.

# 브레이드 매듭 기반 이미지 데이터셋 개발 및 열교환기 상태 확인 적용 연구

## Development of a Braid-Knot-Based Image Dataset and Its Applications to Heat Exchanger Condition Monitoring

최영두<sup>1</sup>, 김동진<sup>2</sup>, 전민규<sup>3</sup>, 강동한<sup>4</sup>, 곽형민<sup>4</sup>, 조룸빈<sup>4</sup>, 허웅<sup>5</sup>, 김세라<sup>6\*</sup>

<sup>1</sup>해군 소령/해군사관학교 기계시스템공학과 조교수

<sup>2</sup>한화시스템 해양시스템 3팀 전문연구원

<sup>3</sup>해군사관학교 기계시스템공학과 부교수

<sup>4</sup>해군사관학교 조선공학과 4학년 생도

<sup>5</sup>해군사관학교 전기전자공학과 4학년 생도

<sup>6</sup>해군사관학교 기초과학과 부교수

Youngdoo Choi<sup>1</sup>, Dongjin Kim<sup>2</sup>, Min-Gyu Jeon<sup>3</sup>, Donghan Kang<sup>4</sup>, Hyoungmin Kawk<sup>4</sup>, Rumben Cho<sup>4</sup>, Woong Heo<sup>5</sup>, Sera Kim<sup>6\*</sup>

<sup>1</sup>LCDR, ROK Navy/Assistant professor, Dept. of Electronics and Control Engineering, Republic of Korea Naval Academy

<sup>2</sup>Chief engineer, Hanwha Naval System 3 Team/Naval R&D Center

<sup>3</sup>Associate professor, Dept. of Mechanical System Engineering, Republic of Korea Naval Academy

<sup>4</sup>Senior midshipman, Dept. of Naval Architecture and Ocean Engineering, Republic of Korea Naval Academy

<sup>5</sup>Senior midshipman, Dept. of Electronics and Control Engineering, Republic of Korea Naval Academy

<sup>6</sup>Associate professor, Dept. of Natural Science, Republic of Korea Naval Academy

### 1. 서론

딥러닝의 발전과 함께 MNIST 필기 숫자 데이터셋과 같은 간단한 이미지 분류 문제들이 널리 활용되어 왔다. 그러나 MNIST는 28×28 픽셀의 손글씨 숫자로 구성된 이미지 데이터 셋으로 현대의 신경망 모델을 이용한 이미지 분석에서 단순한 기준으로 보인다는 논의가 있다. 실제로 단 한 개의 화소만 가지고도 두 개 숫자 클래스 쌍을 77~99% 정확도로 구분할 수 있을 정도이며, 이는 복잡한 딥러닝 모델 평가에 MNIST가 상대적으로 단순함을 보여준다. 이처럼 기존 MNIST 기반 분류 모델의 한계가 분명해지면서,

보다 복잡하고 실제적인 이미지 분석 과제에 대한 필요성이 대두되고 있다. 특히 유체(flow) 이미지 분석 분야는 높은 비선형성과 복잡도를 지닌 난류 등의 현상을 다루므로, 단순 문자나 객체 분류와는 차원이 다른 접근이 요구된다. 최근에는 합성곱 신경망(CNN)을 유체 역학 데이터에 적용하여 흐름의 패턴을 빠르게 식별하고 물리적 해석을 얻으려는 연구들이 나타나고 있다[1,2]. 예를 들어, [1]의 결과는 단층 구조의 얇은 CNN을 통해 소량의 학습데이터의 학습을 통하여 난류 유동을 세 가지 질적으로 구분(주기적/준주기적/혼돈 상태)하여 90% 이상의 분류가 가능하다는 결과를 얻었으며, 학습된 합성곱 커널이 난류 유동의 대규모 유동 구조(coherent structure)를 자동으로 포착하는 것도 확인하였다[3]. 이는 딥러닝의 패턴 인식 능력이 복잡한 유체 흐름의 동역학적 구조를 식별하는 데에도 유용하게 쓰일 수 있음을 시사한다.

한편, 유체 내 위상학적 구조에 주목한 새로운 접근으로서 “매듭(knot)” 개념이 관심을 끌고 있다. 물리학자들은 난류 유동의 입자 경로(streamline)들이 서로 꼬여 매듭과 같은 구조를 형성하며, 이러한 매듭의 규칙을 파악하면 난류를 해석하는 단서가 될 수 있다고 오랫동안 예상해왔다[4]. 실제로 유체가 회전하며 흐를 때 흐름선들이 서로 얽혀 매듭 이미지를 이루는 현상이 발생할 수 있다. 이러한 유체 흐름 속 매듭 현상은 지구의 핵심에서의 유동부터 대기 난류까지 광범위한 체계에서 나타나며, 복잡한 난류 구조를 이해하기 위한 새로운 시각을 제공한다. 그러나 현실의 유체에서 매듭 구조를 관측하고 정량적으로 분석하기는 어려워, 영상 기반으로 이러한 매듭 패턴을 인식할 수 있는 데이터와 기술이 미비한 실정이다. 현재까지 공개된 이미지 데이터셋 중에서는 매듭이나 꼬인 구조에 초점을 맞춘 예가 거의 없으며, 특히 유체 흐름 맥락에서 매듭 기반의 이미지 데이터셋은 알려지지 않았다. 이에 본 연구는 매듭 기반 이미지 데이터셋인 S3braidset을 최초로 구축하고, 해당 데이터셋으로 학습한 CNN 모델을 이용하여 유체 이미지 상의 매듭 구조 분포를 분석하고자 한다. 최근 연구[5]에서 가벼운 CNN과 transformer로 실제 매듭 이미지의 교차 수(crossing number)를 예측하여 이미지로부터 위상 구조 정보를 추출할 수 있음을 보였으며, 향후 학습 기반 인식과 전통적 위상 불변량 계산을 결합하는 연구 접근법을 제안한 바 있다. 이러한 흐름을

배경으로, 본 연구는 S3braidset 데이터셋이라는 기반을 마련함으로써 보다 많은 연구자들이 이미지 속 매듭 패턴을 활용한 구조 기반 유체 영상 해석을 시도할 수 있도록 하는 한편, 그 효용성 있는 활용 가능성을 제시하고자 한다.

즉, 본 연구는 유체 난류 등 복잡한 물리 현상 이미지에 적용할 수 있도록 매듭 형태의 패턴을 모은 새로운 이미지 데이터셋(S3braidset)을 제작하였다. 그 후 해당 데이터셋을 이용하여 소형 CNN 모델을 학습시키고, 경계를 강화한 유체 이미지 분할 결과에 적용함으로써, 이미지 내에 존재하는 윤곽 구조들을 매듭 클래스들의 분포로 해석하는 응용 실험을 수행하였다. 이는 복잡한 유체 움직임 영상을 위상학적 패턴 분포로 변환하여 해석하는 새로운 방법론을 제시한 것이다.

## 2. S3braid 데이터셋 구성

본 장에서는 새롭게 구축한 매듭 기반 이미지 데이터셋 S3braidset의 구성과 이미지 전처리 방법을 상세히 기술한다. S3braidset은 매듭론의 braid 꼬임 구조를 응용하여 만들어진 이미지들로 구성되며, 세 가닥 끈이 꼬여있는 브레이드 군  $B_3$ 의 원소들인 총 21개의 클래스를 포함한다. 이 논문에서 각 클래스에 대한 기호 표기는 다음과 같다:  $\$0\$$  (아무 꼬임이 없는 경우),  $\$1\$$  (첫 번째 가닥과 두 번째 가닥 사이 한 번 오른손 꼬임 교차),  $\$2\$$  (두 번째-세 번째 가닥의 한 번의 오른손 꼬임 교차)로 이름을 붙였다(Fig. 1 참조).



Fig. 1. Diagrams for  $\$1\$$ ,  $\$2\$$  in  $B_3$

추가로  $\$m1\$$  (첫 번째-두 번째 가닥 왼손 꼬임 방향 교차, 즉 1의 거울상),  $\$m2\$$  (두 번째-세 번째 가닥의 왼손 꼬임 교차),  $\$11\$$ (연속 두 번 교차: 먼저 1, 다시 1),  $\$12\$$ ,  $\$21\$$ ,  $\$22\$$ ,  $\$1m2\$$  (1 교차 후 2의 반대 교차),  $\$m12\$$  (1의 반대 교차 후 2 교차), ... 등 최대 2회 꼬임까지 표현된 클래스들이 대상이다. 다시 설명하

자면 여기서 'm' 접두사는 해당 숫자 교차의 역방향 (mirror) 을 의미한다. 이와 같이 가능한 모든 연속하여 2회 이하 교차 조합(중복 교차 포함)을 고려하여 총 21개 클래스가 정의되었다. 각 클래스의 브레이드 패턴은 수학적으로는 3가닥 브레이드군  $B_3$ 에서 길이  $\sigma_1, \sigma_2$ 인 브레이드 워드(word)에 해당한다.

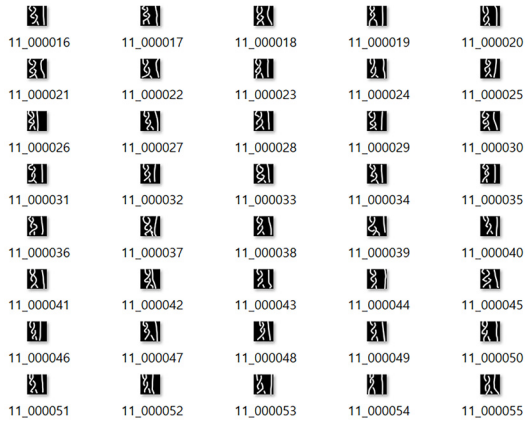


Fig. 2. Examples in the \$11\$ braid class

각 클래스를 구성하는 이미지는 1,500장씩을 포함하도록 데이터를 확장하였다. 우선 클래스 당 원본 브레이드 도식 이미지를 직접 100장씩 제작하였다. 이들은 각기 무작위한 모양과 위치 변형을 가미하여 생성된 기본 패턴 이미지로서, 검은 배경에 흰 선으로 매듭 형태를 나타내었다.

다음으로 데이터 증강을 통해 각 원본 이미지에서 추가 이미지들을 만들어냈다. 크기(scale) 증강으로는 원본 대비 80% 크기로 축소한 버전과 120% 크기로 확대한 버전을 생성하여, 원본까지 합쳐 크기 변형된 이미지 3장을 확보하였다. 이어서 회전(rotation) 증강으로 각 크기 변형된 이미지에 대해  $\pm 20^\circ, \pm 40^\circ$ 의 각도로 회전시킨 이미지를 추가하였다. 회전 변형은 원본 각도( $0^\circ$ )를 포함하여 총 5가지 각도로 부여되었다. 결과적으로 한 원본 이미지로부터 크기 3종  $\times$  회전 5종 = 15장의 이미지가 파생되며, 100장 원본에 대해 총 1,500장의 이미지가 한 클래스에 대응하게 된다. 이러한 증강 과정을 통해 데이터셋 전체 규모는 21개 클래스  $\times$  1,500장 = 31,500장의 이미지로 확대되었다. 각 증강 과정에서는 이미지의 해상도와 종횡비를 보존하였으며, 회전이나 스케일 조정 시 생기는 빈 공간은 배경색(검은색)으로 채웠다. 증강 후의 이미지는  $256 \times 256$  픽셀의 정사각형으로 정규화

하고 중심 정렬하여, 모든 데이터가 동형의 텐서 형태로 학습에 활용될 수 있도록 전처리하였다.

### 3. 데이터셋 적용 및 학습

이 장에서는 S3braidset을 이용한 CNN 학습 실험과, 학습된 모델을 유체 영상 분할에 적용한 이미지 분석 결과를 다룬다. 실험은 (1) 데이터셋을 학습하는 분류 모델의 구조 및 성능 평가, (2) 실제 유체 이미지의 분할(segmentation) 결과에 해당 모델을 적용하여 각 세그먼트의 매듭 클래스를 예측하고 분포를 해석하는 두 부분으로 구성된다.

#### 3.1 CNN 학습 구조 및 성능

본 연구에서는 MNIST 숫자 분류기와 유사한 소형 CNN 모델을 설계하여 매듭 패턴 분류에 적용하였다. 모델 아키텍처는 총 4개의 학습 층으로 구성된 간단한 구조이다. 입력으로  $256 \times 256$  흑백 예지 이미지를 받아, 첫 번째 합성곱 계층에서  $5 \times 5$  커널의 필터 6개를 적용하고 ReLU 활성화 함수 및  $2 \times 2$  맥스풀링을 수행한다. 두 번째 합성곱 계층에서도  $5 \times 5$  필터 16개를 적용하고 ReLU 및  $2 \times 2$  풀링을 거쳐, 출력 특징맵의 공간 해상도를 감소시키면서 중요한 패턴 특징을 추출한다. 이후 3번째 계층으로 완전 연결층(fully-connected layer)을 두어 120차원의 은닉 뉴런 출력을 만들고 ReLU 활성화를 적용한 뒤, 4번째 출력 계층에서 소프트맥스(softmax) 함수를 사용하여 21차원 확률 분포 출력을 생성한다(각 차원은 해당 매듭 클래스일 확률). 이러한 구조는 전형적인 LeNet-5 계열의 경량 CNN과 유사하며, 매듭 이미지의 분류를 수행하기에 충분한 용량을 갖추면서도 과적합을 피하기 위해 비교적 적은 파라미터로 설계되었다. 학습에는 교차 엔트로피 손실 함수와 Adam 옵티마이저를 사용하였고, 배치 크기 32로 50 epoch까지 학습을 진행하였다. 데이터셋의 80%를 학습에 사용하고 20%를 검증 세트로 유지하여, 에포크마다 검증 정확도를 모니터링하면서 조기 종료(early stopping) 기법을 적용하였다. 학습 과정에서 과적합을 방지하기 위해 합성곱 층 이후 드롭아웃(dropout)을 적용하였고, 가중치 감소를 모든 계층에 적용하여 가중치 값이 지나치게 커지는 것을 억제하였다. 훈련 결과, 제안

된 CNN 모델은 매듭 패턴 분류에서 높은 정확도를 보였다. 혼동행렬(confusion matrix) 분석 결과 대부분 클래스에서 오분류 비율이 낮았으며, 특히 \$0\$, \$1\$, \$2\$ 등 단일 교차 패턴은 98% 이상의 높은 F1-점수를 보였다. 일부 복잡한 패턴의 경우 (예: \$12\$ vs \$21\$, \$1m2\$ vs \$m12\$) 약간의 혼동이 관찰되었는데, 이는 두 패턴이 시각적으로 유사한 위치에 교차를 갖거나 회전 변형에 의해 비슷하게 보일 수 있기 때문으로 추정된다. 이는 S3braidset 데이터셋의 패턴들이 기계 학습을 통해 충분히 분류 가능함을 시사한다. 또한 합성곱 계층의 일부 커널 시각화를 통해, 모델이 교차선의 존재 유무, 교차 위치와 방향 등 구조적 특징에 민감하게 반응하고 있음을 확인하였다.

3.2 유체 이미지 분할 및 매듭 분포도 분석

다음으로, 학습된 매듭 분류 CNN 모델을 활용하여 실제 유체 흐름 이미지를 분석하는 실험을 수행하였다. 대상 데이터로는 폭발 현상을 촬영한 고속 카메라 영상에서 한 프레임을 추출한 폭발 구름 이미지를 사용하였다. 이 영상에는 폭발로 인한 뜨거운 기체가 피어오르며 형성된 버섯구름 형태가 담겨 있는데, 이는 전형적으로 고리 모양의 와류 구조를 형성하는 것으로 알려져 있다[6].



Fig. 3. The missile drill strike in North Korea [7]

이 논문에서는 이미지(예시 Fig. 3)를 입력하고 먼저 영상 분할을 수행한 후 각 분할된 영역의 매듭 패턴을 CNN으로 예측하는 절차를 거쳤다. 분할 방법으로는 물리적 객체의 경계를 강조하기 위해 에지 검출 기반 분할을 선택하였다. 구체적으로, 폭발 구름 컬러 이미지를 그레이스케일로 변환하고 대비를 향상시킨 뒤, 캐니 에지 검출을 적용하였다. 그 결과 폭발

구름 외곽과 내부의 뭉치진 밀도 경계 등이 흰색 윤곽선으로 추출되었다. 이 에지 영상에서 연결 요소 분석을 통해 연속된 윤곽선 픽셀 덩어리들을 식별함으로써, 폭발 구름의 이미지가 몇 개의 의미있는 세그먼트(부분 영역)로 나뉘었다. 세그먼트들은 대략적으로 버섯구름의 윗부분 돔, 하단의 고리형 연기 링, 및 주변으로 흩어진 작은 구름 조각들로 분리되었다. 각 세그먼트 영역에 대해 팽창 연산을 약간 적용하여 폐곡선 형태를 이루도록 보정한 뒤, 그 형상 윤곽만을 추출한 이미지 패치를 생성하였다. 이 패치들은 S3braidset 이미지와 유사한 형태(흰 배경에 검은 윤곽선)로 전처리되어 CNN의 입력으로 사용되었다.



Fig. 4. The result from Fig. 3.

학습된 매듭 분류 CNN을 각 세그먼트 패치에 적용한 결과, 폭발 구름 이미지 내 존재하는 구조들이 어떤 매듭 패턴에 대응되는지에 대한 분포도를 얻을 수 있었다. 가장 눈에 띄는 것은 버섯구름 상단의 돔 부분인 클래스 \$m1m2\$로 분류되었다는 점이다. CNN 모델은 이러한 구름 돔의 윤곽을 인식하여 \$m1m2\$로 판단한 것이다. 이는 작은 소용돌이 두 개가 맞물린 형태의 불균형 역방향 난류일 가능성을 암시한다.




Fig. 5. The distribution of braid images in Fig. 4.

한편, 버섯구름 하부에서 피어오르는 기둥 부분과 외곽으로 말려나가는 연기 띠에서는 클래스 \$m21\$ 예측이 다수 나타났다. 이것이 의미하는 바는 구름 기둥이나 가장자리 부근에 한 쪽 방향으로 휘어진 소용돌이 구조가 있다는 해석이 가능하다. 예를 들어 상승하는 기둥이 비틀리며 한쪽으로 경사질 경우 해당 패턴으로 분류될 수 있다. 이는 폭발 구름의 대칭성과 회전 방향 등이 매듭 분포를 통해 가시화된 것으로 볼 수 있다.

해당 방법은 다양한 유체 흐름 분석에 이용될 수 있다. 이 논문에서는 열교환기 내의 열 분포도를 확인하기 위하여 적용하는 방식에 대해서 확인하기 위해 열 교환기내 이미지(Fig. 6)를 확인하자.




Fig. 6. Distribution of temperature on the heat exchanger internal radial surface [8]




Fig. 7. The distributions of braid images in Fig. 6.

두 분포도 전체에서 \$m1m2\$의 빈도 증가 원인을 분석하면 다음과 같다. \$m1m2\$는 역방향 꼬임이 두 차례 연속된 형태로, 불균형한 흐름 혹은 급격한 온도 경계면에서 자주 검출된다. 즉, 열교환기에서 \$m1m2\$가 많이 검출된다는 것은 경계 유동의 불안정성과 비정상적 열전달 영역, 그리고 강한 온도 구배가 있는 경계

혹은 전이 영역이 많다는 뜻이다. 특히 원형 구조 상에서 날개형 벽면 근처나 내부 코어 주위의 급격한 변화 영역에서 이러한 형태가 집중적으로 나왔음을 알 수 있다. 특히 improved model에서는 \$m1m2\$가 다소 줄고 다른 브레이드 클래스의 비중이 다소 늘어났다는 것은, 전체 유동이 보다 안정화되고 단순화된 경로를 따라 흐르며 예측 가능성이 높아졌음을 시사한다. 즉, 브레이드 데이터셋 기반 분석은 단순 이미지 분류를 넘어, 유체의 복잡도, 흐름 패턴 변화, 안정화 여부를 시각적이고 정량적으로 파악할 수 있는 가능성을 보여준다.

이를 정리하면 해당 분석 방식은 다음과 같은 기술적 이점을 제공할 수 있다:

1. 경계 중심의 패턴 해석: IR 영상은 온도 그라디언트에 기반한 영상이므로 에지 기반 구조 해석이 적합하다. Canny 기반의 전처리는 불필요한 세부 색상 정보를 제거하고, 구조 중심의 정보만을 추출함으로써 CNN이 형태 구조에 집중하도록 유도한다[10].

2. 정량화된 위상 분포 해석: 기존 IR 영상 해석은 비정상 영역의 "위치" 또는 "강도"에 주로 의존했지만, 본 방법은 특정 위치의 패턴이 어떤 위상 유형에 가까운지를 정량적 분포도로 해석한다. 이를 통해 단일 스냅샷이 아닌, 시간 흐름에 따른 패턴 분포 변화도 추적할 수 있다.

3. 확장성 및 경량화: 본 연구에 적용된 SmallCNN 모델은 28x28 해상도의 경량 이미지 기반 분석을 목적으로 설계되어, edge device 혹은 IoT 센서와의 연동에도 무리가 없다. 이를 통해 현장 내 실시간 이상 탐지 시스템에 쉽게 통합할 수 있다[9].

4. CBM 시스템 통합 가능성: 상태기반정비(condition-based maintenance) 시스템은 장비 상태 데이터를 실시간으로 모니터링하고, 이상 징후가 발생할 경우 자동으로 정비 알람을 제공하는 체계다. S3braidset 분석 모듈은 IR 영상 데이터를 구조적 패턴으로 분석함으로써, CBM 시스템의 핵심 구성요소인 정량 진단 엔진으로 기능할 수 있다.

이와 같은 장점은 실제 산업 현장에서 다음과 같은 응용 가능성을 제시한다. 예를 들어 열교환기의 튜브 벽면에서 국소적으로 발생하는 오염, 결로 형성, 또는 유량 저하로 인해 비정상적인 온도 분포가 발생하는 경우, 이를 S3braidset 기반 모델이 자동으로 탐지하고, 해당 영역의 위상 분포를 통해 위험 레벨을 수

치화할 수 있다. 또한 과거의 IR 영상과의 비교를 통해 열화 추세를 추적하거나, 예지 정비 시점 설정에도 활용할 수 있다.

#### 4. 결론

본 연구에서는 S3braidset이라 명명한 매듭 기반 이미지 데이터셋을 구축하고, 이를 활용한 CNN 분류 및 유체 이미지 분석 기법을 제안하였다. S3braidset은 매듭 이론의 브레이드 표현을 응용하여 생성된 최초의 공개 이미지 데이터셋으로서, 단순한 필기체나 사물 이미지와 달리 구조적 패턴 자체를 학습하기 위한 새로운 벤치마크를 제공한다. 해당 데이터셋을 통해 소형 합성곱 신경망이 복잡한 위상 패턴도 높은 정확도로 분류할 수 있음을 보였으며, 나아가 실제 폭발 구름 영상에 적용하여 유체 흐름의 구조적 해석이라는 새로운 가능성을 탐색하였다. 이러한 시도는 딥러닝을 통해 이미지 속에 숨겨진 물리적 구조를 알아내는 방향의 연구로서, 난류 해석, 물리 현상 예측 등 광범위한 분야에 파급효과를 가질 수 있다.

이 연구에서 모델이 학습한 내부 표현은 교차선, 고리 등 인간 전문가가 해석할 수 있는 구조 요소들로 이루어져 있어 설명 가능성 측면에서도 흥미로운 장점을 보인다. 또한 중간에 추출된 매듭 분포와 같은 해석 가능한 이미지를 제공함으로써, 딥러닝과 전통적인 과학 해석 사이의 갭을 메우는 역할을 할 수 있다. 예를 들어 폭발 구름 사례에서 얻어진 매듭 분포도는 유체 역학자들에게 해당 난류의 회전 방향, 대칭성, 소용돌이 개수 등에 대한 정량적 단서를 제공할 수 있을 것으로 기대된다.

본 연구의 제한점과 향후 과제도 몇 가지 논의할 수 있다. 첫째, S3braidset 자체는 인공적으로 생성된 2차원 패턴 이미지이므로, 이를 실제 자연 현상의 데이터에 완벽히 대응시키는 데에는 추가 연구가 필요하다. 예를 들어 향후에는 3차원 유체 흐름에서의 와류선(circuit) 데이터와 매듭 클래스를 연결짓는 방향으로 데이터셋을 확장할 수 있다. 2차원 영상에서는 겹쳐보이는 구조도 3차원에서는 서로 다른 높이에 있을 수 있으므로, 시간적 연속 영상이나 다각도 데이터를 활용한 입체적 매듭 인식으로 발전시킬 필요가 있다. 둘째, 분할된 세그먼트 단위가 아니라 이미지 전체에서 직접 매듭 구조를 탐지하는 통합 모델로의

확장도 고려된다. 예를 들어, 영역 분할과 분류를 결합한 센서스-기반 세그멘테이션이나 딥러닝 객체 검출(detector) 기법을 활용하여, 하나의 신경망이 영상 내 여러 매듭 패턴을 동시에 식별하도록 할 수 있을 것이다. 셋째, 매듭 클래스의 범위를 늘려 보다 복잡한 매듭이나 다가닥 꼬임까지 분류할 수 있도록 데이터셋을 보강할 수 있다. 예를 들면 3회 이상의 교차를 갖는 패턴이나 4가닥 이상의 브레이드로 클래스를 확장하면, 난류 내 더욱 복잡한 구조까지 포착할 수 있을 것으로 보인다.

추가로 S3braidset 데이터셋은 단순한 이미지 분류를 넘어, 열영상 내 유체 흐름의 패턴을 정량적이고 설명 가능한 방식으로 해석할 수 있는 새로운 분석 도구로 기능한다. 향후 더 많은 실제 IR 열영상 데이터셋을 바탕으로 학습 및 전이학습(fine-tuning)을 적용하고, 비정상 패턴의 자동 식별 및 경보 시스템으로 발전시킨다면, 열교환기뿐 아니라 다양한 열 기반 장비의 상태 진단 및 CBM 시스템 고도화에 크게 기여할 수 있을 것이라고 기대한다.

#### 참고문헌

- [1] Shizheng Wen, Michael W. Lee, Kai M. Kruger Bastos, Ian K. Eldridge-Allegra, & Earl H. Dowell, 'Feature Identification in Complex Fluid Flows by Convolutional Neural Networks,' *Theoretical and Applied Mechanics Letters*, VOL. 13, NO. 6, 2023, 100482.
- [2] Masaki Morimoto, Kai Fukami, Kai Zhang, Aditya G. Nair, & Koji Fukagata, 'Convolutional Neural Networks for Fluid Flow Analysis: Toward Effective Metamodeling and Low Dimensionalization,' *Theoretical and Computational Fluid Dynamics*, VOL. 35, 2021.
- [3] Shizheng Wen, Michael W. Lee, Kai M. Kruger Bastos, Ian K. Eldridge-Allegra, & Earl H. Dowell, 'Feature Identification In Complex Fluid Flows by Convolutional Neural Networks,' *Theoretical and Applied Mechanics Letters*, VOL. 13, NO. 6, 2023. <https://doi.org/10.1016/j.taml.2023.100482>
- [4] Natalie Wolchover, 'Could Knots Unravel Mysteries of Fluid Flow?,' *Quanta Magazine*, December 9, 2013. <https://www.quantamagazine.org/december-3-2014-learning-to-move-20131209/> (accessed 2025)
- [5] Anne Dranowski, Yura Kabkov, & Daniel Tubbenhauer, 'On Knot Detection via Picture Recognition,' arXiv:2510.06284, 2025.
- [6] Wikipedia, Vortex Ring. (accessed 2025)
- [7] 홍제표, '북한판 '괴물 미사일' 첫선...내륙 표적지 정밀타격,' *노컷뉴스*, 2024. 9. 19.

<https://v.daum.net/v/20240919155702844> (accessed 2025)

[8] Sungbin Lee, Manyul Jeon, Hyungpil Park, Donghyeok Park, Hoonhyuk Park, Jongin Bae, & Heesung Park, 'A Numerical Investigation on Heat Transfer Enhancement of a Dual-Impeller Heat Exchanger for Electro-Optical Tracking System Cooling via System Structural Modification,' *Journal of KSPE*, VOL. 42, NO. 10, 2025, pp. 871-877.

[9] A. Grall, C. Bérenguer, & L. Dieulle, 'A Condition-Based

Maintenance Policy for Stochastically Deteriorating Systems,' *Reliability Engineering & System Safety*, VOL. 76, NO. 2, 2002, pp. 167-180.

[10] Y. LeCun, L. Bottou, Y. Bengio, & P. Haffner, 'Gradient-Based Learning Applied to Document Recognition,' *Proceedings of the IEEE*, VOL. 86, NO. 11, 1998, pp. 2278-2324.