

인공지능을 활용한 CANDU 압력관 결함 사전 탐지 자동화 시스템

성 주 용¹ · 이 현 준² · 이 성 철^{3*}

¹선문대학교 컴퓨터공학과 석사과정

²알엠에스테크놀로지(주) 기술연구소 책임연구원

³선문대학교 컴퓨터공학과 교수

Automated Pre-detection System for CANDU Pressure Tube Failure Using Deep Learning

JuYong Seong¹ · Hyunjun Lee² · Sungchul Lee^{3*}

¹Master's Course, Department of Computer Science and Engineering, Sunmoon University, Cheonan-si 31460, Korea

²Research Director, RMS Technology Co., LTD, Cheonan-si, Chungcheongnam-do 31217 Korea

³Professor, Department of Computer Science and Engineering, Sunmoon University, Cheonan-si 31460, Korea

[요 약]

Canada Deuterium Uranium(CANDU) 원자로는 노심에 수평적인 구조를 적용하여 원자로 내의 연료를 실시간으로 재보급이 가능하도록 하였다. 그러나 수평적인 구조는 압력관 결함에 원인이 되기도 한다. 이를 방지하기 위해 캐나다는 법규와 표준을 정립함과 동시에 압력관의 건전성을 측정하기 위한 방법들을 연구하고 있다. 하지만 기존의 건전성 측정 방식은 법적 정기 점검이 필요한 경우 시행이 되며 주로 수동적인 방식을 이용하고 있다. 따라서, 우리는 기존 방식의 한계를 해결하기 위해 딥러닝을 활용한 결함 사전 탐지 자동화 시스템을 구현하였다. 본 연구에서는 CANDU 운전 시 발생하는 압력관의 진동을 스펙트로그램으로 변환하였고, 이를 딥러닝 이미지 분류 모델 학습에 활용하였다. 그 결과 비전 트랜스포머 모델이 가장 우수한 분류 성능을 보였다. 우리는 이 모델을 시스템에 적용하여 CANDU 압력관 결함 사전 탐지 자동화 시스템을 성공적으로 구현했다.

[Abstract]

The Canada Deuterium Uranium (CANDU) reactor utilizes a horizontal structure for its core to enable real-time reactor refueling. However, horizontal construction can lead to pressure tube failures. Canada has established legislation and standards to prevent these failures and is actively researching methods to assess pressure tube integrity. However, traditional methods for assessing pressure tube integrity are typically passive and are conducted only during planned statutory outages. To address the limitations of these methods, we have implemented an automated pre-detection system utilizing deep learning. The vibration of the pressure tube generated during CANDU operation is transformed into a spectrogram which can be used to train deep-learning image classification models. The Vision transformer model results in the best classification performance. We then apply this model to the system and successfully implement an automated system for the pre-detection of CANDU pressure tube failure.

색인어 : 캔두형 원자로, 압력관, 결함, 사전 탐지, 자동화

Keyword : CANDU Reactor, Pressure Tube, Failure, Pre-detection, Automated

<http://dx.doi.org/10.9728/dcs.2024.25.8.2135>



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.

Received 18 June 2024; Revised 01 August 2024

Accepted 08 August 2024

*Corresponding Author; Sungchul Lee

Tel: 

E-mail: sungchul@sunmoon.ac.kr

1. 서론

CANDU 원자로의 주요 특징은 핵연료 교환 시 사용되는 독특한 방식에 있다. 일반적인 원자로의 수평적인 연료봉 구조와 달리, 그림 1에서 볼 수 있듯 CANDU는 수평적인 칼란드리아관(Calandria tube)와 압력관(Pressure tube) 구조는 원자로 내 연료의 실시간 재보급을 가능하게 하며, 이를 통해 연료 교체 과정이 간소화되어 비용 절감 효과를 가져왔다. 특히, CANDU에 사용되는 중수는 고속 중성자의 속도를 낮추는 역할을 하기 때문에 핵연료의 중성자 흡수를 돕는다. 따라서, 보다 효율적인 에너지 생산을 가능하게 한다. 이를 통해 CANDU 원자로는 경제성 측면에서 많은 이점을 제공하며, 다양한 국가에서 선호되는 선택지가 되었다[1]. 하지만 이러한 수평적인 구조로 인하여 몇 가지 문제가 발생할 수 있다.

대표적으로, 압력관 내에 설치되는 연료봉의 하중으로 인해 압력관의 처짐(Creep)[2], 고온 및 고압 환경에서 압력관의 변형과 노후로 인한 누출 사고가 발생할 위험[3], 핵 연료의 장기간 사용에 따른 크랙(Crack) 등 다양한 결함이 발생한다[4]. 이러한 사고의 위험성은 원자로의 안전성을 위협하고, 여러 사고의 원인이 될 수 있다[5],[6]. 이를 방지하기 위해, 캐나다는 원자로 압력관의 건전성을 확보하기 위한 법규와 표준을 정립하고 있으며[7]-[11], 압력관의 건전성을 측정하고 모니터링하기 위한 다양한 방법에 대해 연구하고 있다. 그러나 전통적인 방식의 건전성 감지 진단 방법은 법적 정기 점검이 필요한 경우에만 시행되며, 주로 수동적인 방법을 이용한다[12]. 이러한 기존 방법들은 주로 계획된 점검기간 동안에만 원자로 운영을 중단한 후 진단할 수 있어 갑작스

러운 결함이나 문제를 실시간으로 감지하는 데 한계가 있다. 더 나아가 압력관의 결함을 분류하고 크기를 측정하는 작업은 시간이 많이 걸리기 때문 검사 및 후속 분석이 완료되어 원자로를 재가동할 때까지 상당한 시간 및 경제적 손실이 발생한다[13]. 이처럼, CANDU 원자로의 독특한 구조적 특성은 여러 이점을 제공하지만, 동시에 기술적 도전 과제를 안고 있다. 이러한 도전 과제를 해결하기 위해 다양한 기술과 많은 연구가 이루어지고 있다.

우리는 앞서 언급한 한계를 극복하기 위해, 해당 연구에서는 CANDU 원자로 운전 시 발생하는 압력관의 고유 진동 데이터를 각 결함 별로 수집하였다. 데이터는 각 결함 별 2개씩 수집되었으며, 적은 데이터로 인하여 규칙을 학습하기에 한계가 있다고 판단하였다. 따라서, 제한된 데이터에서도 규칙적 정보를 효과적으로 추출할 수 있도록 데이터를 스펙트로그램으로 변환하여 분석을 진행하였으며, 더 나아가 생성형 적대 신경망(Generative Adversarial Network, GAN) [14]의 기반 모델 중 Fast-GAN[15]을 사용하여 데이터를 증강하였다. 이를 통해 제한된 실제 데이터의 양을 보완하고, 다양한 결함 시나리오를 효과적으로 학습할 수 있도록 하였다. 증강된 데이터는 합성곱 신경망인 VGG[16], DenseNet[17], ResNet[18] 과 비전 트랜스포머를 기반으로 만들어진 ViT[19] 딥러닝 이미지 분류 모델의 학습에 이용하였다.

본 논문은 전통적인 압력관 결함 탐지 방법의 한계를 극복하고자 하였고, 적은 수의 데이터에서 최대한의 정보를 추출할 수 있는 방법과 인공지능 기술을 결합하여 실시간으로 결함을 탐지할 수 있는 자동화 시스템을 구현했다. 앞으로도 지속적인 연구와 기술 개발을 통해 CANDU 원자로를 포함한 원




그림 1. CANDU 원자로의 설계도
 Fig. 1. Schematic diagram of a CANDU reactor

자력 산업의 발전에 기여할 수 있을 것으로 기대된다. 특히 우리는 이 연구에서 제안한 딥러닝 기반 자동화 결함 탐지 시스템은 원자로의 안전성을 높이는 데 중요한 역할을 할 것이다.

II. 관련 연구

앞서 언급한 것과 같이 CANDU 원자로에서 압력관의 건전성을 파악하는 것은 원자력 사고예방에 있어서 매우 중요한 연구 주제이다. 이를 위해 CIGAR, BRANDE와 같은 진단 도구들이 사용되고 있다[20]. 이 외에도 압력관의 진단 및 수명 예측을 위한 다양한 방법들이 존재한다. 대표적인 방법으로는 직류전위차법(Direct current potential drop)[21]는, 와전류(Eddy current)[22], 음향방출법(Acoustic emission, AE)[23], 초음파(Ultrasonic)[24], 전산유체역학(Computational fluid dynamics, CFD)[25], 유한요소모델 분석(Finite element analysis, FEA)[26] 등이 있다. 하지만 이 진단 방법들은 모두 수동으로 이루어지기 때문에 실시간으로 결함을 감지하고 예측하는 데 한계가 존재한다.

CANDU 압력관 내의 결함 깊이 자동결정 전문가 시스템은 CommonKADS 지식 공학 기반 모델을 응용함으로써 전문가 시스템(Expert-system)을 구축하였다[27]. 이 시스템은 픽셀맵을 분석하여 압력관에 발생한 결함의 깊이를 자동으로 분석하는 시스템이다. 분석에 사용된 데이터는 총 280개의 결함이 있는 29개의 압력관 데이터를 이며 분석 결과, 결함의 깊이가 79%의 경우에서 0.1 mm 이내, 85%의 경우에서 0.3 mm 이내로 측정되어 임계 값인 0.1 mm에서 약 80%에 가까운 정확도를 보여주었다.

CANDU 원자로의 압력관은 지연수소균열(DHC) 위험을 줄이기 위해 초음파 비파괴 검사를 통해 결함을 식별하고 분석한다[28]. 이 시스템은 압력관의 주요 특징을 정확하게 식별하고 예상되는 모든 결함을 찾아냈다. 결함의 길이, 너비, 깊이 측정도 성공적으로 이루어졌으나, 일부 측정의 정확성을 향상시키기 위한 추가 연구가 필요함이 언급되었다. 이 엔드 투 엔드 시스템은 인간 운영자의 개입 없이 성공적으로 실행되었으며, 결과는 분석가들이 결정을 내리는 데 도움을 줄 수 있는 형식으로 출력되었다.

초음파 검사와 딥러닝을 활용한 연료 채널 결함 자동 탐지 시스템은 딥러닝을 사용하여 CANDU 원자로 연료 채널의 초음파 검사에서 결함을 자동으로 탐지하는 개념 증명(PoC)을 제시했다[29]. 18개의 전체 초음파 스캔 파일을 사용하여 제안된 솔루션을 테스트한 결과, 각 결함에서 적어도 한 지점을 자동으로 식별할 수 있었으며, 이를 통해 분석가들은 결함 영역의 위치를 신속하게 식별하고 수동 분석을 통해 각 영역의 길이와 너비를 결정할 수 있게 되었다

CANDU 연료 채널(Fuel channel)의 진동 분석은 CANDU 원자로 운전 시 발생하는 압력관의 진동을 유한요소

모델로 구현하여 모드해석을 진행했다[30]. 또한, 변형으로 인해 발생하는 진동을 감지하는 중성자 플럭스 감지기(In-core flux detector, ICFD)의 신호를 조사하여 변형을 유한요소모델에서 측정된 모드해석 결과와 비교하였다. 연구 결과 ICFD에서 수집된 고유 진동과 유한 요소 모델을 통해 생성한 고유 진동이 유사함을 증명하였고, 각 결함 별 고유진동을 파악하였다.

앞선 관련 연구들처럼 압력관 결함 진단 자동화에 대한 연구가 진행되고 있으며 최근 결함과 패턴 인식에 큰 발전을 가져온 인공지능 기반으로 한 압력관 결함 감지 연구들이 진행되고 있다. 하지만 대부분의 연구는 CIGAR, BRANDE와 같은 추가적인 진단 장비를 이용하여 결함을 감지한다. 반면, 본 논문에서는 원자로 운전 중 발생하는 진동 특성을 추정하기 위해 중성자 플럭스 감지기(In-core Flux Detector, ICFD)[31]를 사용한다. ICFD를 통해 수집된 데이터는 결함에 따른 압력관의 고유 진동 특성을 분석하는 데 활용된다. 이러한 데이터를 기반으로 유한 요소 모델을 생성하고, 인공지능을 이용해 결함을 자동으로 탐지하는 시스템을 구현한다.

III. 데이터

CANDU 연료 채널(Fuel channel) 어셈블리는 여섯 가지 주요 구성 요소(그림 2)로 이루어져 있다. 일반적으로 연료 채널은 12개의 연료 번들(Fuel bundle)로 구성되어 있다. 연료 번들은 천연 우라늄을 사용한다. 칼란드리아관(Calandria tube)은 열을 이전하기 위한 역할을 하며, 속에 다시 압력관(Pressure tube)이 설치되어 있다. 압력관은 냉각재(Coolant)가 흐르는 경로를 제공한다. 가터 스프링(Gather spring, 또는 Spacer)은 압력관에 일정한 간격으로 설치되어 채널 내부의 응력을 관리하며, 압력관과 칼란드리아관의 접촉을 방지한다. 엔드 피팅(End Fitting)은 연료 채널의 끝단을 봉쇄하고, 압력관(Pressure tube)에 구조적 지지를 제공한다.




그림 2. 연료 채널의 주요 구성 요소
Fig. 2. Components of the Fuel channel

본 연구에서는 CANDU 연료 채널에서 발생할 수 있는 다양한 결함에 대한 심층적인 조사를 목표로 하였다. 유한요소모델로 구현한 압력관 예시에서 확인할 수 있듯(그림 3), 먼저




그림 3. 연료 채널 단면 및 결함 위치 표시
 Fig 3. Show fuel channel section and failure location

CANDU 연료 채널의 상세한 유한요소모델링을 수행하기 위해 연료 채널 어셈블리의 구성을 기반으로 단순화된 3차원 솔리드 모델을 개발했다. 그림 3에서 BC는 boundary conditions의 약어로, 본 논문에서는 경계조건을 말하며 경계조건은 칼란드리아관과 엔드피팅을 지지하는 압연 지지대(Rolled support, rolled joint)를 의미한다. Spring은 앞서 설명한 가터 스프링을 의미하며 칼란드리아관과 압력관의 접촉을 방지하는 역할을 한다. 칼란드리아관과 압력관이 접촉하면, 고온과 방사능 환경에서 두 관 사이의 마찰로 인해 손상이 발생할 수 있다. 이러한 손상은 압력관의 구조적 무결성을 저해하고, 원자로의 안전성을 위협할 수 있다. 가터 스프링은 이러한 접촉을 방지하여 원자로의 안정적이고 안전한 작동을 보장한다.

이러한 구성 요소를 기반으로 하여 개발된 3차원 솔리드 모델은 연료 채널의 물리적 특성을 정확하게 반영하며, 결함 시나리오의 시뮬레이션 및 분석에 사용된다. 결함 시나리오의 경우 다양한 상태에서 발생할 수 있는 일곱 가지 유형으로 구분하였으며, 표 1의 순서대로 정상상태, 경계조건변화(Boundary conditions, A1~A6), 가터 스프링 기능 상실(B1~B9), BC 2 경계조건 변화 & 가터 스프링 기능 상실(C1~C9), BC 1, 2 경계조건 변화 & 가터 스프링 기능 상실(D1~D9), BC 2, 3 경계조건 변화 & 가터 스프링 기능 상실(E1~E9), BC 1, 2, 3 경계조건 변화 & 가터 스프링 기능 상실(F1~F9)로 구성되어 있다. 그림 4에는 정상상태와 경계조건변화(A1~A6)의 예시를 보여준다.

표 1. 결함 시나리오 상태분류, 그룹화, 결함 수
 Table 1. Failure scenario categorization, grouping, and number of failures

Failure status categorization	Grouped	The number of failures
Steady state	Steady state	1
Boundary conditions failure	A1 ~ A6	6
Loss of garter spring functionality	B1 ~ B9	9
BC 2 failure & Loss of garter spring functionality	C1 ~ C9	9
BC 1, 2 failures & Loss of garter spring functionality	D1 ~ D9	9
BC 2, 3 failures & Loss of garter spring functionality	E1 ~ E9	9
BC 1, 2, 3 failures & Loss of garter spring functionality	F1 ~ F9	9

결함 상태분류의 일곱 가지 유형에 세부적으로 총 52가지의 결함 시나리오가 포함되었다(표 2). 표 2에 표시된 ‘X’는 결함을 의미하며 그림 2에서 결함이 있는 부분을 확인할 수 있다. 실험 데이터는 결함 시나리오에 대해 진동을 측정하여 얻었으며, 결함 시나리오별로 진동 데이터를 총 40초간 0.1 초 간격으로 측정하여 400개의 데이터 포인트를 수집하였다(그림 4). 본 논문에서는 CANDU 원자로의 운영 시 발생하는 압력관의 고유 진동 데이터를 결함 별 2개의 데이터를 수집하여 분석을 진행했다.

수집된 데이터만으로 머신러닝 기법을 통해 유의미한 규칙을 찾기에 불충분할 것으로 판단하였다. 이에 따라, 데이터의 부족 문제를 해결하기 위해 다양한 데이터 증강 방법을 적용하였다. 증강에는 노이즈 유형들과 Fast-GAN을 활용하여 이미지 데이터를 증강하는 방법을 사용하였다. 먼저, 고유진동의 강도와 진동이 발생한 시점을 변형하지 않는 방법으로 가우시안 노이즈(Gaussian noise)[32], 임펄스 노이즈(Impulse noise)[33], 점잡음(Salt and pepper noise)[34], 양자화 잡음(Quantization noise)[35]을 적용하여 이미지를 증강하였다. 이와 더불어, 데이터의 양이 적은 상황에서도 효과적으로 특징을 학습할 수 있는 Few-shot GAN 모델 중 Fast-GAN을 활용하여 추가적인 증강을 진행하였다. Fast-GAN은 “Skip-layer channel-wise excitation(SLE)”과 “Self-supervised discriminator”을 적용함으로써 기존의 GAN보다 빠른 학습 및 생성, 그리고 적은 양의 데이터로 특징을 학습한다. 생성자는 고해상도 이미지를 합성하기 위해 필연적으로 더 많은 양의 연산과 신경망을 필요로 하는데 SLE는 이를 최적화한 방법이다. SLE는 첫 번째로 학습 데이터의 특징을 최대한 보존하기 위해 사용되던 ResBlock[18]의 연산 방법을 변경하였다. 기존 ResBlock은 합성곱의 각 층의 연산을 통해 나온 결과 값을 더함으로써 특징을 보존한 반면, SLE에서는 이 덧셈 연산을 채널별 곱셈을 적용하였다. 두 번째로 기존 GAN의 연구에서는 동일한 해상도의 내에서만 Skip-connection을 사용하였지만 SLE에서는 다른 해상도간 적용함으로써 연산을 최소화하였다. 또한 “Self-supervised discriminator”는 기존 GAN의 판별자 학습 방법인 생성자에 의해 생성된 이미지와 실제 이미지를 학습 시키는 방법과 달리 여러 개의 디코더에서 생성된 이미지를 학습 시키는 방법을 통해 판별자가 이미지의 특징을 잘 보존하도록 하였다. Fast-GAN은 13개의 오픈 데이터 셋에 해당 방법을 적용하여 위 방법이 효과적임을 증명하였다.

표 2. 결함 시나리오(X: 고장 표시)
 Table 2. Failure scenarios(X: failure)

Status categorization		End fitting		Spring				End fitting	
		BC 1	BC 2	1	2	3	4	BC 3	BC 4
Steady state									
Boundary conditions failure	A-1		X						
	A-2		X					X	
	A-3	X							
	A-4	X							X
	A-5	X	X						X
	A-6	X	X					X	
Loss of garter spring functionality	B-1			X	X	X	X		
	B-2			X	X		X		
	B-3			X	X	X			
	B-4			X			X		
	B-5				X	X			
	B-6			X	X				
	B-7			X		X			
	B-8			X					
	B-9				X				
BC 2 failure & Loss of garter spring functionality	C-1		X	X	X	X	X		
	C-2		X	X	X		X		
	C-3		X	X	X	X			
	C-4		X	X			X		
	C-5		X		X	X			
	C-6		X	X	X				
	C-7		X	X		X			
	C-8		X	X					
	C-9		X		X				
BC 1, 2 failures & Loss of garter spring functionality	D-1	X	X	X	X	X	X		
	D-2	X	X	X	X		X		
	D-3	X	X	X	X	X			
	D-4	X	X	X			X		
	D-5	X	X		X	X			
	D-6	X	X	X	X				
	D-7	X	X	X		X			
	D-8	X	X	X					
	D-9	X	X		X				
BC 2, 3 failures & Loss of garter spring functionality	E-1		X	X	X	X	X	X	
	E-2		X	X	X		X	X	
	E-3		X	X	X	X		X	
	E-4		X	X			X	X	
	E-5		X		X	X		X	
	E-6		X	X	X			X	
	E-7		X	X		X		X	
	E-8		X	X				X	
	E-9		X		X			X	
BC 1, 2, 3 failures & Loss of garter spring functionality	F-1	X	X	X	X	X	X	X	
	F-2	X	X	X	X		X	X	
	F-3	X	X	X	X	X		X	
	F-4	X	X	X			X	X	
	F-5	X	X		X	X		X	
	F-6	X	X	X	X			X	
	F-7	X	X	X		X		X	
	F-8	X	X	X				X	
	F-9	X	X		X			X	




그림 4. 결함별 고유 진동값 예시
Fig. 4. Example of natural frequency by failure

Fast-GAN에는 두 장의 이미지만을 학습시켰으며 이러한 과정을 통해 증강된 데이터가 원본 데이터의 특성을 잘 반영하는지 확인하기 위해 SSIM(Structural Similarity Index)[36]과 FID(Frechet Inception Distance)[37]를 사용하여 데이터 유사도를 계산하였다. SSIM은 두 이미지 간의 구조적 유사도를 평가하고 1에 가까울수록 유사한 이미지로 판단한다. FID는 생성된 이미지와 실제 이미지 간의 분포 차이를 측정함으로써 데이터의 신뢰도 및 적합성을 검증한다. FID는 거리가 가까울수록, 즉 수치가 낮을수록 유사하다고 판단한다. LPIPS(Learned Perceptual Image Patch Similarity)[38]와 같은 다양성 측정 지표는 이번 데이터 증강 과정에서 요구되지 않는 사항으로 제외하였다. Fast-GAN에 의해 생성된 이미지의 평가지표 적용 결과 SSIM은 0.9516, FID 8.2951이 측정되었다(표 3). 측정 결과 Fast-GAN이 생성한 이미지가 실제 이미지와 매우 유사함을 확인했다.

표 3. Fast-GAN 생성 이미지 평가지표 적용 결과
Table 3. Results of applying Fast-GAN generated image evaluation metrics

Evaluation metrics	SSIM	FID
Results	0.9516	8.2951

마지막으로, 학습된 Fast-GAN이 생성한 데이터는 분류기의 학습 데이터로 활용되었으며, 이를 통해 모델의 성능을 향상시키는 데 기여하였다. 이 데이터를 분석하여 다양한 결함 상황에서의 응력, 변형, 및 기타 물리적 특성을 조사함으로써 연료 채널의 안전성 및 신뢰성을 높일 수 있을 것으로 기대된다. 데이터의 다양성과 품질을 향상시킴으로써 연료 채널에 발생할 수 있는 다양한 상황에 대한 이해를 높이고, 이에 따른 적절한 대응 및 예방 조치를 취할 수 있게 될 것이다.

IV. 데이터

4-1 Training Fast-GAN in Source Domain

본 논문에서는 부족한 데이터의 한계를 해결하기 적은 수

의 이미지를 학습하여 좋은 결과를 보여준 Few-Shot GAN 중 소량의 데이터 셋으로도 고품질의 이미지를 생성하는 Fast-GAN을 이용하였다. Fast-GAN의 학습 능력을 활용하여 클래스 별 두 장의 이미지만을 사용하여 학습했다. A-1, A-2 결함이 있는 입력 이미지 그림 5(a)를 Fast-GAN을 통해 증강된 이미지 결과인 그림 5(b)와 같이 증강 할 수 있다. Fast-GAN를 통해 데이터를 증강시켜 중수로 결함 사전 탐지 모델을 위한 데이터를 100개를 확보하였다 생성된 데이터는 분류기(classifier)의 성능을 향상시키기 위해 학습, 검증, 그리고 테스트 단계에 걸쳐 활용되었다. 첫 번째는 각 분류기에 클래스 당 원본 이미지 1개, 2개를 사용하여 학습시켰고, 두 번째는 원본에 증강된 데이터를 포함하여 5개, 10개를 학습시켰다.




그림 5. (a) 입력 이미지, (b) Fast-GAN에 의해 증강된 이미지
Fig. 5. (a) Input image, (b) Fast-GAN augmented

4-2 Training Fast-GAN in source domain

결함 사전 탐지 자동화 시스템에 적용하기 가장 적합한 모델을 찾기 위해 VGG[16], DenseNet[17], ResNet[18], ViT[19]와 같은 분류 모델에 이미지를 학습시켰다. 각 모델에 제공한 데이터는 각각 1개와 2개로 구성되었으며, 추가적으로 기존에 수집된 원본 이미지에 GAN에서 증강된 데이터를 추가하여 5개와 10개의 데이터로 구성된 실험도 진행하였다. 이를 통해 다양한 모델의 성능을 비교하고, 적은 데이터 환경에서의 효율성을 평가할 수 있었다. 연구 결과에 따르면, 학습 데이터의 수가 10개를 초과할 경우 모델의 성능이 실질적으로 향상되지 않는다는 것이 확인되었다. 이는 적은 양의 데이터로 특징을 잘 학습했음을 의미한다. 반대로, 데이터가 적기 때문에 다양한 종류의 데이터에 적용할 경우 모델이 일관성을 유지할지 알 수 없다는 한계가 존재한다.

각 모델의 성능을 비교한 결과, 샘플 수에 따라 다양한 정확도를 보였다(표 4). 데이터 증강 없이 1개의 샘플당 VGG는

표 4. 클래스 별 학습 이미지 수에 따른 딥러닝 이미지 분류 모델 정확도

Table 4. Deep learning image classification model accuracy as a function of number of training images per class

	Sample per class	VGG accuracy	ResNet accuracy	DenseNet accuracy	ViT accuracy
The first standard experiment	1	0.9431	0.9356	0.9517	0.9789
The first FastGAN_Augmented	5	0.9722	0.9775	0.9878	0.9994
The second standard experiment	2	0.9656	0.9434	0.9608	0.9812
The second FastGAN_Augmented	10	0.9738	0.9832	0.9978	0.9988

0.9431, ResNet은 0.9356, DenseNet은 0.9517, ViT는 0.9789의 정확도를 기록했다. 데이터 증강 없이 2개의 샘플 당 VGG는 0.9656, ResNet은 0.9434, DenseNet은 0.9608, ViT는 0.9812의 정확도를 보였다. 데이터 증강을 포함한 5개의 샘플에서는 VGG는 0.9722, ResNet은 0.9775, DenseNet은 0.9878, ViT는 0.9994로 더욱 향상된 성능을 보였다. 데이터 증강을 포함한 10개의 샘플에서는 VGG는 0.9738, ResNet은 0.9832, DenseNet은 0.9978, ViT는 0.9988의 정확도를 보여주었다. 이러한 결과는 각 모델의 강점을 보여주며, 특히 데이터 증강을 통한 이미지 분류 정확도가 향상됨을 증명했다. 이를 통해 ViT가 다른 모델들에 비해 데이터 증강 시 가장 높은 정확도를 달성하며, 복잡한 패턴 인식에서 강력한 성능을 발휘함을 알 수 있었다.

V. 결 과

실험 결과 ViT를 기반 모델이 중수로 결함을 분류하는 데 가장 우수한 성능을 보여주었다. 중수로 결함 데이터는 시계열 데이터의 특성을 가지며, 이는 시간적인 변화와 패턴을 정확히 반영하는 것이 매우 중요하다. 트랜스포머 모델 기반인 ViT는 셀프 어텐션 메커니즘을 통해 각 시간 단계에서 중요한 정보를 효과적으로 강조할 수 있어, 시간적인 연속성을 잘 파악할 수 있어 시계열 기반의 스펙트로그램 (Spectrogram) 데이터를 처리하는 데 매우 적합하다는 것을 입증한다. 또한, 실험에서는 두 장의 이미지를 학습시킨 Fast-GAN의 데이터를 추가적으로 적용 했을 때 ResNet, DenseNet, ViT 모델 전부 더 나은 성능을 보여준 것으로 나타났다. 모델이 증강된 데이터 기반으로 학습을 하더라도 일반화 능력이 향상되었으며, 이로 인해 더 나은 분류 결과가 나타났다. 결과적으로, 가장 우수한 성능을 보여준 ViT 모델과 Fast-GAN을 활용하여 압력관이 운전될 때 발생하는 신호를 분석하도록 시스템을 설계하였다.

VI. 결 론

본 논문은 Fast-GAN 기술과 딥러닝 이미지 분류 모델을 함께 활용함으로써 적은 수의 데이터로도 높은 정확도를 달성할 수 있음을 증명했다. 또한 기존에 연구되지 않은 중성자

플럭스 감지기의 데이터를 활용함으로써 정기 점검에만 압력관을 검사하기 때문에 압력관의 문제를 실시간을 탐지할 수 없는 기존 방법의 한계를 극복하였다.

우리는 유한요소 모델을 이용하여 CANDU 원자로의 운전 중 발생하는 압력관의 결함 별 고유 진동 데이터를 수집하였다. 압력관의 진동 데이터는 스펙트로그램으로 변환한 뒤 딥러닝 모델에 학습시켜 실시간으로 결함을 탐지하고 분석할 수 있게 하였다. 이를 통해 중수로 운영 중 발생할 수 있는 다양한 결함을 조기에 발견하고 대응할 수 있는 능력이 크게 향상될 것으로 기대된다. 이 시스템은 높은 정확도로 결함을 분류할 수 있으며, 기존의 정기 점검 방식보다 훨씬 더 신속하고 효율적인 결함 탐지가 가능하다.

결과적으로, 이 시스템은 중수로의 안전성을 크게 향상시키고, 갑작스러운 결함으로 인한 위험을 최소화하는 데 중요한 역할을 할 것이다. 본 연구의 결과는 압력관 결함 탐지뿐만 아니라, 다른 유형의 구조적 모니터링에도 적용될 수 있는 가능성을 보여준다. 예를 들어, 원자력 산업 외에도 항공 [39], 교량[40], 철도[41] 등 다양한 산업 분야에서 실시간 결함 탐지 시스템으로 활용될 수 있을 것이다. 이는 산업 전반에 걸쳐 안전성을 높이고 유지보수 비용을 절감하는 데 기여할 것으로 기대된다.

감사의 글

이 논문은 2023년도 정부(산업통상자원부)의 재원으로 한국에너지기술평가원의 지원을 받아 수행된 연구임(20224B1 0100060, 회전설비 인공지능형 진동 감시 시스템 개발)

참고문헌

- [1] A. A. Galahom and A. Ibrahim, "Integrated Analysis to Investigate the Viability of Using Thorium-Based Fuel Instead of Traditional Fuel in CANDU Reactor," *Nuclear Engineering and Design*, Vol. 398, 111969, November 2022. <https://doi.org/10.1016/j.nucengdes.2022.111969>
- [2] K. Lee, D. Wowk, and P. Chan, "Finite Element Analysis of an Empty 37-Element CANDU® Fuel Bundle to Study the Effects of Pressure Tube Creep," *CNL Nuclear Review*, Vol.

- 10, No. 1, pp. 39-51, 2021.
- [3] R. Choubey and M. P. Puls, "Crack Initiation at Long Radial Hydrides in Zr-2.5Nb Pressure Tube Material at Elevated Temperatures," *Metallurgical and Materials Transactions A*, Vol. 25, No. 5, pp. 993-1004, May 1994. <https://doi.org/10.1007/BF02652274>
- [4] J. Cui and G. K. Shek, "The Effect of Load Reduction on Crack Initiation Behavior of Hydrides from Flaws in Zr-2.5Nb Pressure Tube Material," in *Proceedings of the 18th International Conference on Nuclear Engineering*, Xi'an, China, pp. 597-606, May 2010. <https://doi.org/10.1115/ICONE18-29880>
- [5] V. G. Snell, J. Q. Howieson, S. Alikhan, G. M. Frescura, F. King, J. T. Rogers, and H. Tamm, "CANDU Safety under Severe Accidents," in *Proceedings of an Advisory Group Meeting on Technical Feasibility and Reliability of Passive Safety Systems for Nuclear Power Plants*, Jülich, Germany, pp. 321-351, November 1994.
- [6] H.-S. Yoo and J.-G. Chung, "A Review of Pressure Tube Failure Accident in the CANDU Reactor and Methods for Improving Reactor Performance," *Journal of the Korean Nuclear Society*, Vol. 30, No. 3, pp. 262-272, June 1998.
- [7] Canadian Standards Association, Requirements for Class 1C, 2C, and 3C Pressure-Retaining Components and Supports in CANDU Nuclear Power Plants, Author, Toronto, Canada, CAN/CSA-N285.2-M89, January 1989.
- [8] Canadian Standards Association, Technical Requirements for In-Service Evaluation of Zirconium Alloy Pressure Tubes in CANDU Reactors, Author, Toronto, Canada, N285.8-05, 2005.
- [9] Canadian Standards Association, General Requirements for Pressure-Retaining Systems and Components in CANDU Nuclear Power Plants, Author, Toronto, Canada, CAN/CSA-N285.0-M91, November 1991.
- [10] B. Carroll and J. C. Jin, "Considerations for the Use of Probabilistic Assessments in Regulatory Decision Making Related to Pressure Boundary Component Aging," in *Proceedings of ASME 2017 Pressure Vessels and Piping Conference*, Waikoloa: HI, July 2017.
- [11] Centre for Regulatory Innovation, A Study for the Canadian Nuclear Safety Commission on Artificial Intelligence Applications and Implications for the Nuclear Industry, Author, Ottawa, Canada, August 2023.
- [12] P. Zacharis, G. West, G. Dobie, Lardner T., and Gachagan, A, "Data-Driven Analysis of Ultrasonic Inspection Data of Pressure Tubes," *Nuclear Technology*, Vol. 202, No. 2-3, pp. 153-160, 2018. <https://doi.org/10.1080/00295450.2017.1421803>
- [13] L. Obrutsky, J. Renaud, and R. Lakhani, "Steam Generator Inspections: Faster, Cheaper and Better, Are We There Yet?," in *Proceedings of IV Conferencia Panamericana de END*, Buenos Aires, Argentina, October 2007.
- [14] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, ... and Y. Bengio, "Generative Adversarial Nets," in *Proceedings of the 27th International Conference on Neural Information Processing Systems (NIPS '14)*, Montreal, Canada, pp. 2672-2680, December 2014.
- [15] B. Liu, Y. Zhu, K. Song, and A. Elgammal, "Towards Faster and Stabilized GAN Training for High-Fidelity Few-Shot Image Synthesis," in *Proceedings of the 9th International Conference on Learning Representations (ICLR 2021)*, Online, May 2021. <https://doi.org/10.48550/arXiv.2101.04775>
- [16] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," arXiv:1409.1556, September 2014. <https://doi.org/10.48550/arXiv.1409.1556>
- [17] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition," in *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas: NV, pp. 770-778, June 2016. <https://doi.org/10.1109/CVPR.2016.90>
- [18] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely Connected Convolutional Networks," in *Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu: HI, pp. 2261-2269, July 2017. <https://doi.org/10.1109/CVPR.2017.243>
- [19] A. Dosovitskiy, L. Beyer, A. Kolesnikov, D. Weissenborn, X. Zhai, T. Unterthiner, ... and N. Houlsby, "An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale," arXiv:2010.11929, October 2020. <https://doi.org/10.48550/arXiv.2010.11929>
- [20] N. Pavan Kumar, V. H. Patankar, and M. S. Kulkarni, Ultrasonic Gauging And Imaging Of Metallic Tubes And Pipes: A Review, Bhabha Atomic Research Centre, Mumbai, India, BARC/2020/E/012, November 2020.
- [21] Y. Gou, Y. Li, Y. Liu, H. Chen, and S. Ying, "Evaluation of a Delayed Hydride Cracking in Zr-2.5Nb CANDU and RBMK Pressure Tubes," *Materials & Design*, Vol. 30, No. 4, pp. 1231-1235, April 2009. <https://doi.org/10.1016/j.matdes.2008.06.011>
- [22] S. Shokralla, T. W. Krause, and J. Morelli, "Surface Profiling With High Density Eddy Current Non-Destructive Examination Data," *NDT & E*

- International*, Vol. 62, pp. 153-159, March 2014. <https://doi.org/10.1016/j.ndteint.2013.12.008>
- [23] J. I. Mieza, G. Vigna, E. Chomik, and G. Domizzi, "Delayed Hydride Cracking Velocity in Zr-2.5Nb: Detection by Acoustic Emission and Theoretical Model Testing," *Journal of Materials Science*, Vol. 43, No. 14, pp. 4945-4952, July 2008. <https://doi.org/10.1007/s10853-008-2723-x>
- [24] M. Trelinski, "Inspection of CANDU rEactor Pressure Tubes Using Ultrasonics," in *Proceedings of the 17th World Conference on Nondestructive Testing*, Shanghai, China, pp.25-28, October 2008.
- [25] Z. Lu and M. H. A. Piro, "Computational Fluid Dynamic Investigations of Flow Bypass through an Aged CANDU Pressure Tube," *Annals of Nuclear Energy*, Vol. 178, 109345, December 2022. <https://doi.org/10.1016/j.anucene.2022.109345>
- [26] S. Ramachandra Prabhu, Development of Probabilistic Finite Element Models for Assessment of Deformation in CANDU Fuel Channels, Ph.D. Dissertation, University of Waterloo, Waterloo, Canada, January 2022.
- [27] T. Lardner, G. M. West, G. Dobie, and A. Gachagan, "An Expert-Systems Approach to Automatically Determining Flaw Depth within Candu Pressure Tubes," in *Proceedings of the 10th International Topical Meeting on Nuclear Plant Instrumentation, Control and Human Machine Interface Technologies (NPIC & HMIT 2017)*, San Francisco: CA, pp. 11-15, June 2017.
- [28] T. Lardner, G. West, G. Dobie, and A. Gachagan, "Automated Sizing and Classification of Defects in CANDU Pressure Tubes," *Nuclear Engineering and Design*, Vol. 325, pp. 25-32, December 2017. <https://doi.org/10.1016/j.nucengdes.2017.09.029>
- [29] I. Hammad, R. Simpson, H. D. Tague, and S. Hall, "Using Deep Learning to Automate the Detection of Flaws in Nuclear Fuel Channel UT Scans," *IEEE Transactions on Ultrasonics, Ferroelectrics, and Frequency Control*, Vol. 69, No. 1, pp. 323-329, January 2021. <https://doi.org/10.1109/TUFFC.2021.3112078>
- [30] J.-H. Park, D.-B. Yoon, Y.-C. Choi, and C.-G. An, "Analysis for the Vibration Behavior of a CANDU Fuel Channel under Normal and Abnormal Support Conditions," in *Proceedings of the 19th International Conference on Structural Mechanics in Reactor Technology (SMiRT 19)*, Toronto, Canada, Paper # O-01/4, August 2007.
- [31] J. Park, J. H. Lee, T.-R. Kim, J.-B. Park, S. K. Lee, and I.-S. Koo, "Identification of Reactor Internals' Vibration Modes of a Korean Standard PWR Using Structural Modeling and Neutron Noise Analysis," *Progress in Nuclear Energy*, Vol. 43, No. 1-4, pp. 177-186, 2003. [https://doi.org/10.1016/S0149-1970\(03\)00021-0](https://doi.org/10.1016/S0149-1970(03)00021-0)
- [32] M. Arslan, M. Guzel, M. Demirci, and S. Ozdemir, "SMOTE and Gaussian Noise Based Sensor Data Augmentation," in *Proceedings of the 4th International Conference on Computer Science and Engineering (UBMK)*, Samsun, Turkey, pp. 1-5, September 2019. <https://doi.org/10.1109/UBMK.2019.8907003>
- [33] Y. LeCun, Y. Bengio, and G. Hinton, "Deep Learning," *Nature*, Vol. 521, No. 7553, pp. 436-444, May 2015. <https://doi.org/10.1038/nature14539>
- [34] A. Wunderlich and J. Sklar, "Data-Driven Modeling of Noise Time Series with Convolutional Generative Adversarial Networks," *Machine Learning: Science and Technology*, Vol. 4, No. 3, 035023, September 2023. <https://doi.org/10.1088/2632-2153/acee44>
- [35] E. Fons, P. Dawson, X. Zeng, J. Keane, and A. Iosifidis, "Evaluating Data Augmentation for Financial Time Series Classification," arXiv:2010.15111, October 2020. <https://doi.org/10.48550/arXiv.2010.15111>
- [36] Z. Wang, A. C. Bovik, H. R. Sheikh, and E. P. Simoncelli, "Image Quality Assessment: From Error Visibility to Structural Similarity," *IEEE Transactions on Image Processing*, Vol. 13, No. 4, pp. 600-612, April 2004. <https://doi.org/10.1109/TIP.2003.819861>
- [37] M. Heusel, H. Ramsauer, T. Unterthiner, B. Nessler, and S. Hochreiter, "GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium," in *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS'17)*, Long Beach: CA, pp. 6629-6640, December 2017. <https://doi.org/10.48550/arXiv.1706.08500>
- [38] R. Zhang, P. Isola, A. A. Efros, E. Shechtman, and O. Wang, "The Unreasonable Effectiveness of Deep Features as a Perceptual Metric," in *Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, Salt Lake City: UT, pp. 586-595, June 2018. <https://doi.org/10.1109/CVPR.2018.00068>
- [39] J. Griffaton, J. Picheral, and A. Tenenhaus, "Enhanced Visual Analysis of Aircraft Engines Based on Spectrograms," in *Proceedings of the 26th International Conference on Noise and Vibration Engineering (ISMA 2014)*, Leuven, Belgium, pp. 2795-2808, September 2014.
- [40] S. Farhadi, M. Corrado, O. Borla, and G. Ventura, "Prestressing Wire Breakage Monitoring Using Sound Event Detection," *Computer-Aided Civil and*

Infrastructure Engineering, Vol. 39, No. 2, pp. 186-202, January 2024. <https://doi.org/10.1111/mice.13079>

- [41] M. S. A. Hashmi, M. Ibrahim, I. S. Bajwa, H.-U.-R. Siddiqui, F. Rustam, E. Lee, and I. Ashraf, "Railway Track Inspection Using Deep Learning Based on Audio to Spectrogram Conversion: An On-the-Fly Approach," *Sensors*, Vol. 22, No. 5, 1983, March 2022. <https://doi.org/10.3390/s22051983>



성주용(JuYong Seong)

2017년~2022년: 선문대학교 학사과정
2022년~현 재: 선문대학교 석사과정
※ 관심분야 : 통계학, 머신러닝, 인공지능, 패턴인식



이현준(Hyunjun Lee)

2010년 : 선문대학교 대학원 (이학석사)
2013년 : 선문대학교 대학원 (이학박사)

2013년~현 재: 알엠에스테크놀러지(주) 책임연구원
※ 관심분야 : 데이터베이스, 신호처리, 인공지능



이성철(Sungchul Lee)

2012년 : University of Nevada, Las Vegas (이학석사)
2018년 : University of Nevada, Las Vegas (이학박사 - Computer Science)

2018년~2020년: Department of Computer Science, University of Wisconsin-Whitewater
2020년~2021년: School of Computing and Information Systems, Grand Valley State University
2021년~현 재: 선문대학교 컴퓨터공학부 교수
※ 관심분야 : 인공지능(AI), 웹/앱 어플리케이션, 블록체인