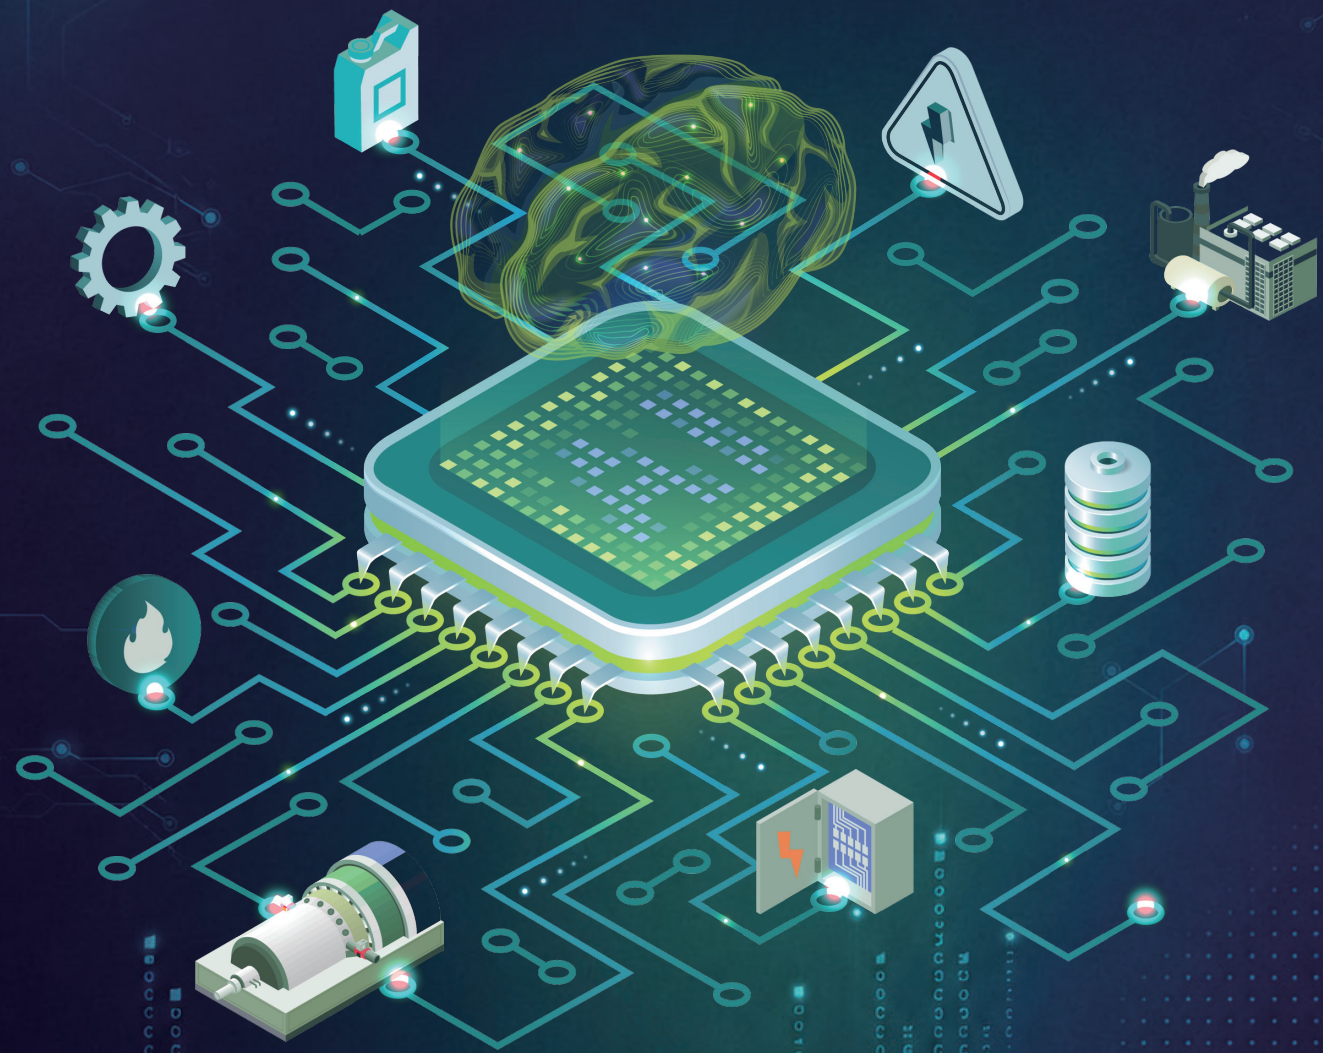
AI 기반 제4회 연소기술 특별 워크샵

2026. 8. 21(금)

대한상공회의소 국제회의장(B2, 서울 중구)



주최

사단법인 한국연소학회
The Korean Society of Combustion

NETO 탄소중립연구조합
Net Zero Research Association

AI 기반 제4회 연소기술 특별 워크샵

2026. 8. 21(금)

대한상공회의소 국제회의장(B2, 서울 중구)



주최 사단법인 한국연소학회 The Korean Society of Combustion

NETO 탄소중립연구조합 Net Zero Research Association

AI 기반 연소기술 특별 워크샵



| 일 자 | 2026년 8월 21일(금)

| 장 소 | 대한상공회의소 국제회의장(B2, 서울 중구)

| 참가신청 | 8월 14일(금)까지 홈페이지를 통해 신청(https://kosco.or.kr/) → 2026 워크샵

| 등록비 | 20만원

※ 워크샵 책자는 온라인으로 제공하며, AI 실습(tutorial)이 포함되므로 노트북을 지참하시기 바랍니다

시간	항목	주제	연사
10:00~10:20	등록		
Session I		좌장: 이창엽 연구소장 (한국생산기술연구원)	
10:20-10:30	인사말 축사	손채훈 한국연소학회 회장 이종명 대한상공회의소 산업성장본부장	
10:30-12:30	발표 1	연구 생태계의 변화: AI 툴을 활용한 체계적 문헌 검색 및 집필	박강민 교수 (국민대학교)
12:30-13:40	Break time (기념사진/ 점심 미제공)		
Session II		좌장: 김민국 책임 (한국기계연구원)	
13:40-14:20	발표 2	AI 애플리케이션 구현을 위한 고차원 분광학의 데이터 기반 통찰	도형록 교수 (서울대학교)
14:20-15:00	발표 3	복잡 유동 시스템을 위한 AI-Physics 기반 구조보존 모델링	김도균 교수 (홍익대학교)
15:00-15:40	발표 4	연소 모델링을 위한 과학적 머신러닝	김수용 교수 (서울대학교)
15:40~16:00	Break Time		
Session III			좌장: 김대식 교수 (강원대학교)
16:00-16:40	발표 5	AI 기반 발전용 가스터빈 자동 연소튜닝 개발 방향	신주곤 수석 (두산에너빌리티)
16:40-17:20	발표 6	AI 기반 석탄/바이오매스 연소설비 연료 물성 및 운전 성능 예측	류창국 교수 (성균관대학교)

| 조직위원장 | 류창국 부회장(성균관대)

| 조 직 위 원 | 김대식 부회장(강원대), 김민국 수석이사(한국기계연구원), 이창엽 수석이사(한국생산기술연구원)

| 주 최 | (사) 한국연소학회 The Korean Society of Combustion NET0 탄소중립연구조합

목 차

Session I

연구 생태계의 변화: AI 툴을 활용한 체계적 문헌 검색 및 집필 3

박강민 교수(국민대학교)

Session II

AI 애플리케이션 구현을 위한 고차원 분광학의 데이터 기반 통찰 47

도형록 교수(서울대학교)

복잡 유동 시스템을 위한 AI-Physics 기반 구조보존 모델링 75

김도균 교수(홍익대학교)

연소 모델링을 위한 과학적 머신러닝 93

김수용 교수(서울대학교)

Session III

AI 기반 발전용 가스터빈 자동 연소튜닝 개발 방향 115

신주곤 수석(두산에너빌리티)

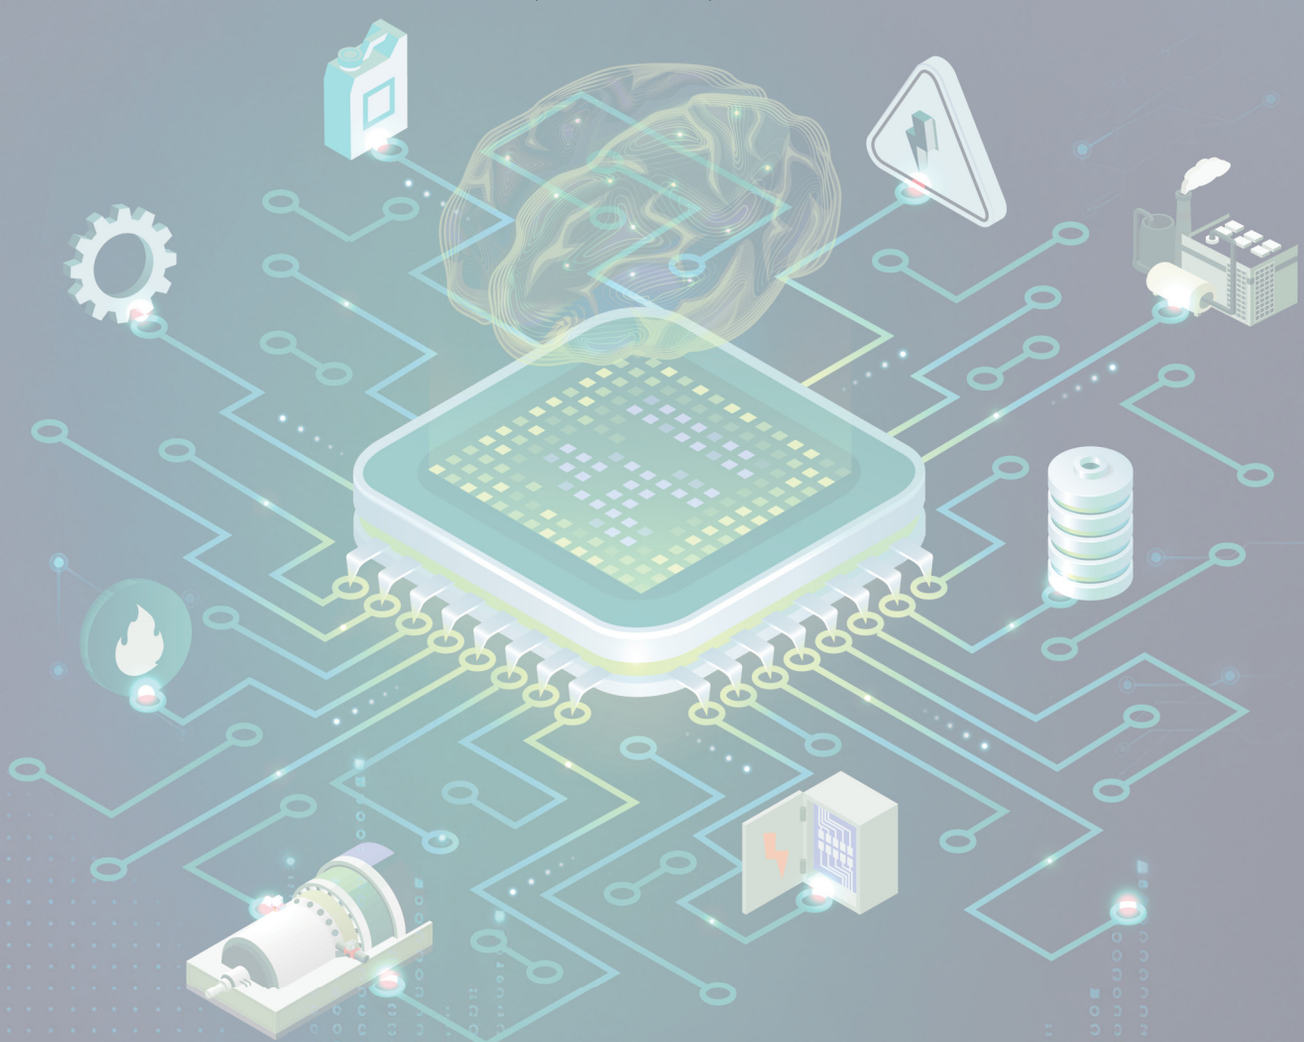
AI 기반 석탄/바이오매스 연소설비 연료 물성 및 운전 성능 예측 123

류창국 교수(성균관대학교)

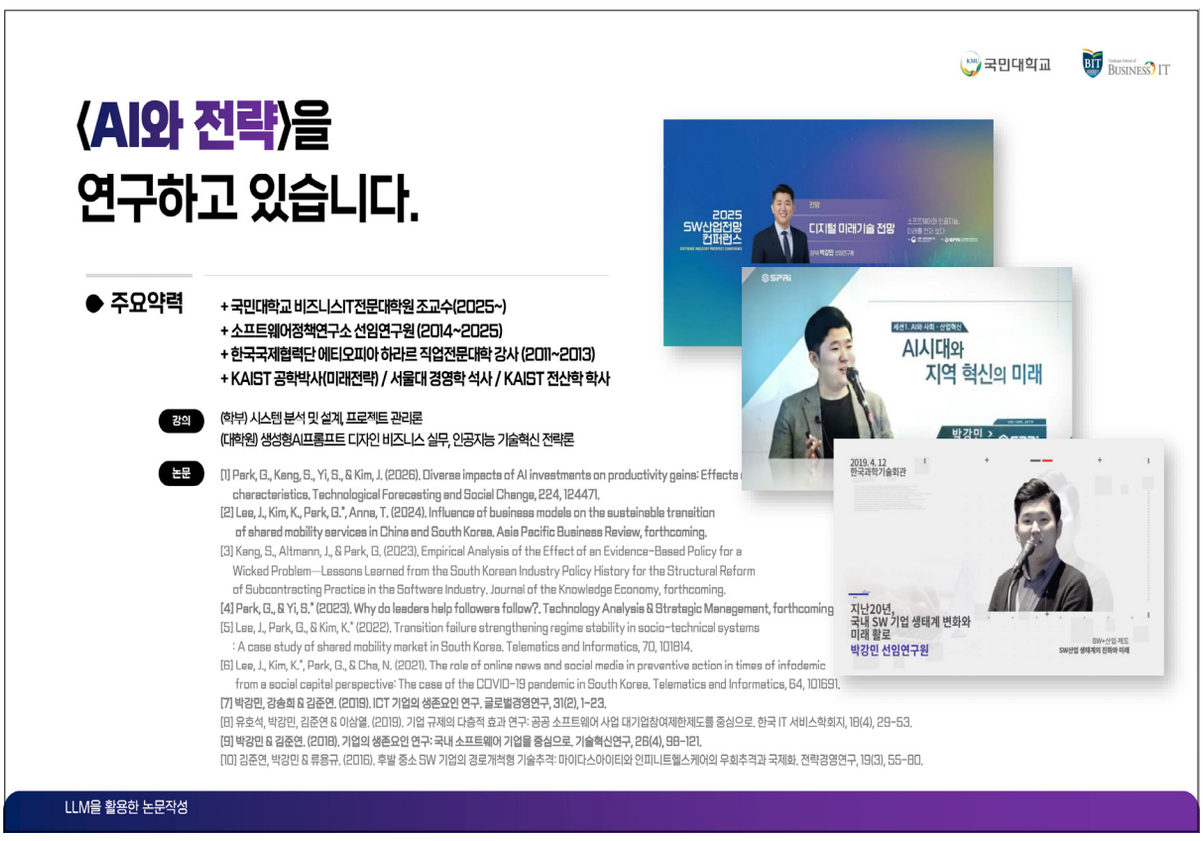
Session I

연구 생태계의 변화: AI 툴을 활용한 체계적 문헌 검색 및 집필

박강민 교수
(국민대학교)




국민대학교
BUSINESS IT
한국연소학회
LLM을 활용한 논문작성:
참고문헌 검색부터 데이터 분석까지
박강민 | 국민대학교 비즈니스IT대학원


국민대학교
BUSINESS IT
〈AI와 전략〉을
연구하고 있습니다.
● 주요약력
+ 국민대학교 비즈니스IT전문대학원 조교수(2025~)
+ 소프트웨어정책연구소 선임연구원 (2014~2025)
+ 한국국제협력단 에티오피아 하라르 직업전문대학 강사 (2011~2013)
+ KAIST 공학박사(미래전략) / 서울대 경영학 석사 / KAIST 전산학 학사
강의
(학부) 시스템 분석 및 설계, 프로젝트 관리론
(대학원) 생성형AI프롬프트 디자인 비즈니스 실무, 인공지능 기술혁신 전략론
논문
[1] Park, G., Kang, S., Yi, S., & Kim, J. (2026). Diverse impacts of AI investments on productivity gains: Effects
characteristics. Technological Forecasting and Social Change, 224, 124471.
[2] Lee, J., Kim, K., Park, G.*, Anna, T. (2024). Influence of business models on the sustainable transition
of shared mobility services in China and South Korea. Asia Pacific Business Review, forthcoming.
[3] Kang, S., Altmann, J., & Park, G. (2023). Empirical Analysis of the Effect of an Evidence-Based Policy for a
Wicked Problem—Lessons Learned from the South Korean Industry Policy History for the Structural Reform
of Subcontracting Practice in the Software Industry. Journal of the Knowledge Economy, forthcoming.
[4] Park, G., & Yi, S.* (2023). Why do leaders help followers follow?. Technology Analysis & Strategic Management, forthcoming
[5] Lee, J., Park, G., & Kim, K.* (2022). Transition failure strengthening regime stability in socio-technical systems
: A case study of shared mobility market in South Korea. Telematics and Informatics, 70, 101814.
[6] Lee, J., Kim, K.*, Park, G., & Cha, N. (2021). The role of online news and social media in preventive action in times of infodemic
from a social capital perspective: The case of the COVID-19 pandemic in South Korea. Telematics and Informatics, 64, 101691.
[7] 박강민, 강송희 & 김준연. (2019). ICT 기업의 생존요인 연구. 글로벌경영연구, 31(2), 1-23.
[8] 유호석, 박강민, 김준연 & 이상열. (2019). 기업 규제의 다층적 효과 연구: 공공 소프트웨어 사업 대기업참여제한제도를 중심으로. 한국 IT 서비스학회지, 18(4), 29-53.
[9] 박강민 & 김준연. (2018). 기업의 생존요인 연구: 국내 소프트웨어 기업을 중심으로. 기술혁신연구, 26(4), 98-121.
[10] 김준연, 박강민 & 류응규. (2016). 후발 중소 SW 기업의 경로개척형 기술추격: 마이다스아이티와 인피니트헬스케어의 우회추격과 국제화. 전략경영연구, 19(3), 55-80.
2025 SW산업전망 컨퍼런스
디지털 미래기술 전망
AI시대와 지역 혁신의 미래
2019. 4. 12 한국과학기술회관
지난20년, 국내 SW 기업 생태계 변화와 미래 활로
박강민 선임연구원
LLM을 활용한 논문작성

국민대학교 BIT Graduate School of Business IT

〈AI와 전략〉을 연구하고 있습니다.

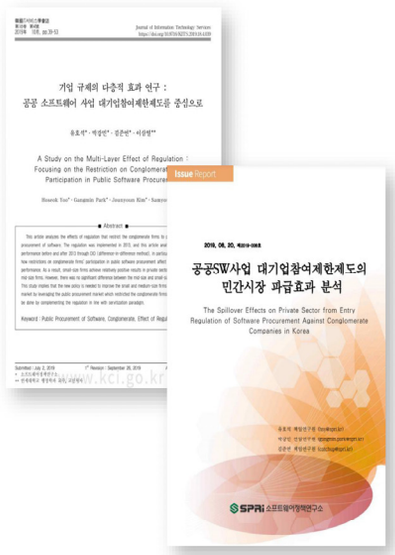
● 주요약력

+ 국민대학교 비즈니스IT전문대학원 조교수(2025~)
+ 소프트웨어정책연구소 선임연구원 (2014~2025)
+ 한국국제협력단 에티오피아 하라르 직업전문대학 강사 (2011~2013)
+ KAIST 공학박사(미래전략) / 서울대 경영학 석사 / KAIST 전산학 학사

보고서

[1] 김준연, 박강민, 윤기영, 강송희 & 이명호 (2023) SPRi DaRT 2024: 디지털 미래 시그널
[2] 박강민 & 김준연 (2022). 디지털 기술에 의한 생산성 제고: AI 기술의 역할과 가능성.
[3] 김준연, 박강민 & 신원규 (2021). 국제통상환경의 변화와 디지털 기술 패권 경쟁.
[4] 김준연, 강송희, 박강민, 김명호 & 이준민 (2020). 산업의 디지털 전환과 역기능 연구: 니치의 죽음과 카르텔.
[5] 김준연, 강송희, 박강민, 이준민 & 황원식. (2019). 디지털 신산업 혁신 생태계 연구.
[6] 김준연, 박강민, 강송희, 조원영 & 유재흥. (2018). 디지털 신산업 혁신 생태계 연구.
[7] 강송희, 박강민 & 김준연 (2018). SW에 의한 경제적 파급효과 연구: 생산성 제고와 미래 노동 구조 변화.
[8] 김준연, 박강민 & 유재흥. (2018). 지난 20년, 국내 SW기업의 생태계 변화 연구.
[9] 김준연, 유재흥 & 박강민. (2016). 제4차 산업혁명과 산업의 디지털 전환: 위기와 전략
[10] 김준연, 박강민 & 강송희. (2015). 한국강소SW 기업의 탄생과 성장.
[11] 박태형, 김태호, 박강민, 송현이 & 박재형. (2015). SW안전 산업동향 조사.
[12] 임춘성, 양병석, 강송희, 박강민 & 김정민 (2014) SW규제 개선을 통한 SW산업기반 확충안

SW산업 → 디지털 전환 → 인공지능



LLM을 활용한 논문작성

강의목표

논문 작성에
실질적인 도움이 되는
AI서비스를 익혀보는 것

TIME TABLE

구분	주제
Part 1.	데이터 분석 및 시각화 실습 • 프롬프트로 데이터 탐색·차트 생성부터 Streamlit 대시보드 구축까지
Part 2.	문헌 조사 및 갭 분석 • AI Agent로 선행연구를 탐색하고 연구 공백과 연구질문 도출
Part 3.	문헌조사를 잘 하기 위한 Agent AI 프롬프트 • 프롬프트 엔지니어링과 Agentic AI 디자인 패턴 적용
Part 4.	초안 작성 및 실전 적용 • 단계별 지시 전략으로 논문 초안과 리비전 레터 작성
Part 5.	PPT 양식 기반 강의자료 자동 생성 실습 • 내 양식을 가이드로 만들어 PPTX를 반복 생성하는 워크플로우

국민대학교 BIT Graduate School of Business IT



국민대학교 BIT Graduate School of Business IT

데이터 전처리 및 EDA

AI로 논문 작성

- MIS 분야 최고 권위지 Information Systems Research에서도

AI 관련 연구 게재는 물론, AI를 리뷰 프로세스에 직접 도입하여 학술 심사 혁신을 추진 중

INFORMATION SYSTEMS RESEARCH

Calls for Papers

ISR Special Issue: Generative AI and New Methods of Inquiry in Information Systems Research

Innovating the Review Process

The editorial team will experiment with GenAI to augment—never replace—human judgment. This may include identifying inconsistencies, verifying citations, or enhancing consistency across reviews. All editorial decisions will remain fully under human control.

No submitted manuscripts or reviewer reports will be used to train models, and all AI support will operate within ISR's confidentiality and data-handling standards.

국민대학교 BIT Graduate School of Business IT

데이터 전처리 및 EDA

AI로 논문 작성

- 긍정적 효과
  - 논문 발표 수 3.02배 증가
  - 인용 횟수 4.84배 증가
  - 연구 리더 승진 1.37년 단축
- 부정적 효과
  - 연구 주제 총량 4.63% 감소
  - 과학자 간 교류 22% 감소

Article | Published: 14 January 2026

Artificial intelligence tools expand scientists' impact but contract science's focus

Qianyue Hao, Fengli Xu, Yong Li & James Evans

Nature **649**, 1237–1243 (2026) | Cite this article

38k Accesses | **19** Citations | **1085** Altmetric | Metrics

Abstract

Developments in artificial intelligence (AI) have accelerated scientific discovery[1]. Alongside recent AI-oriented Nobel prizes[2,3,4,5,6,7,8,9], these trends establish the role of AI tools in science[10]. This advancement raises questions about the influence of AI tools on scientists and science as a whole, and highlights a potential conflict between individual and collective benefits[11]. To evaluate these questions, we used a pretrained language model to identify AI-augmented research, with an F1-score of 0.875 in validation against expert-labelled data. Using a dataset of 41.3 million research papers across the natural sciences and covering distinct eras of AI, here we show an accelerated adoption of AI tools among scientists and consistent professional advantages associated with AI usage, but a collective narrowing of scientific focus. Scientists who engage in AI-augmented research publish 3.02 times more papers, receive 4.84 times more citations and become research project leaders 1.37 years earlier than those who do not. By contrast, AI adoption shrinks the collective volume of scientific topics studied by 4.63% and decreases scientists' engagement with one another by 22%. By consequence, adoption of AI in science presents what seems to be a paradox: an expansion of individual scientists' impact but a contraction in collective science's reach, as AI-augmented work moves collectively towards areas richest in data. With reduced follow-on engagement, AI tools seem to automate established fields rather than explore new ones, highlighting a tension between personal advancement and collective scientific progress.

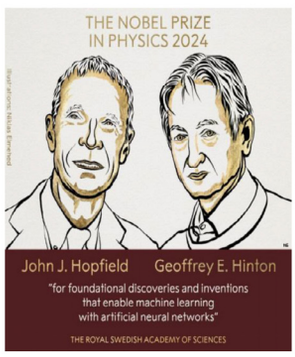
LLM을 활용한 논문작성

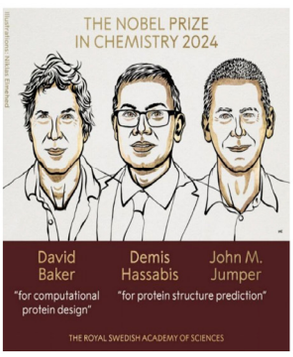
국민대학교 BIT Graduate School of Business IT

데이터 전처리 및 EDA

AI로 논문 작성

- **노벨 물리학상(2024)** : John Hopfield & Geoffrey Hinton
  인공 신경망을 이용한 머신러닝의 기초 발견과 발명으로 수상
- **노벨 화학상(2024)** : Demis Hassabis & John Jumper & David Baker
  AI로 50년 난제인 단백질 구조 예측 문제를 해결한 AlphaFold 개발로 수상





문헌조사 및 갭분석

MIS 분야 논문의 주제와 형태

연구 주제	연구 방법론	핵심 데이터/분석
AI 기술 수용 요인 분석	설문 기반 구조방정식 (SEM)	리커트 척도 설문 + 경로분석
디지털 전환이 조직 성과에 미치는 영향	패널 데이터 회귀분석	기업 재무 데이터 + 고정효과 모델
온라인 리뷰의 소비자 행동 영향	자연어 처리(NLP) + 감성분석	텍스트 마이닝 + 로지스틱 회귀
정보 보안 위험 인식과 대응 행동	실험 설계 (Experiment)	A/B 테스트 + ANOVA/t-test
플랫폼 생태계의 네트워크 효과	이중차분법 (DID)	플랫폼 거래 로그 + 인과추론
IT 투자 대비 생산성 역설	메타분석 / 체계적 문헌 고찰	다수 논문 데이터 + 효과크기 합산

MIS 논문은 가설 수립 → 데이터 수집 → **통계적 실증 분석**으로 검증하는 구조



국민대학교 BIT Graduate School of Business IT

실습환경 세팅

필요 도구들

1 LLM (Large Language Model)

Gemini, Claude, ChatGPT 등 대규모 언어 모델을 활용한다
현재 구독 중인 서비스를 연동하여 실습한다
보안이 우려되는 경우를 위한 Tip을 제공한다

2 Python

AI 연구에 가장 적합한 프로그래밍 언어이다
풍부한 라이브러리로 데이터 분석을 효율화한다
코딩 경험이 없어도 AI가 작성을 보조한다

3 IDE (통합 개발 환경)

VS Code와 Cursor AI를 활용한다
AI 기반 코드 자동완성으로 생산성을 높인다
직관적 인터페이스로 빠르게 적응할 수 있다



도구 요약

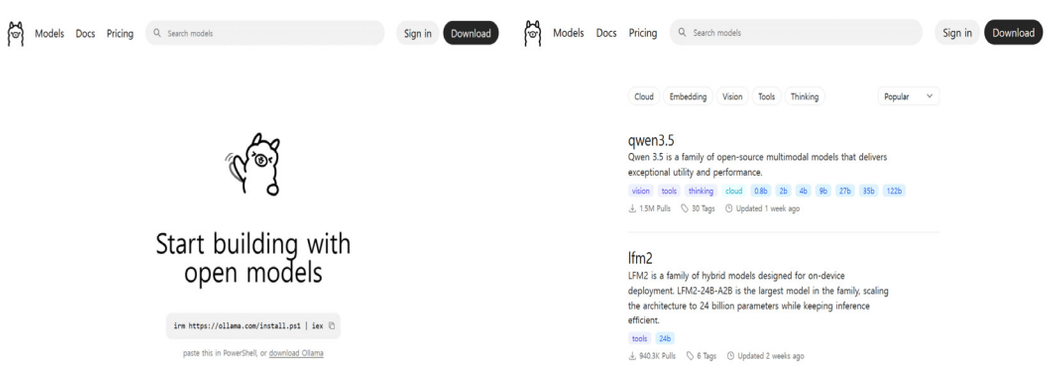
ChatGPT 대화형 AI 연구 보조	**Claude** 고급 분석 및 논리 추론
Gemini 멀티모달 데이터 처리	**Python** 데이터 분석 핵심 언어
VS Code 통합 개발 환경	**Cursor AI** AI 기반 코드 에디터

Tip 보안 우려 시 로컬 LLM(Ollama 등) 활용 가능

TIP!

보안이 걱정이라면?

- **오픈소스 모델** : LLM Open Source Model을 활용해서 내 컴퓨터에 설치 가능
- **쉽게 설치하는 방법** : Ollma나 LM Studio를 활용



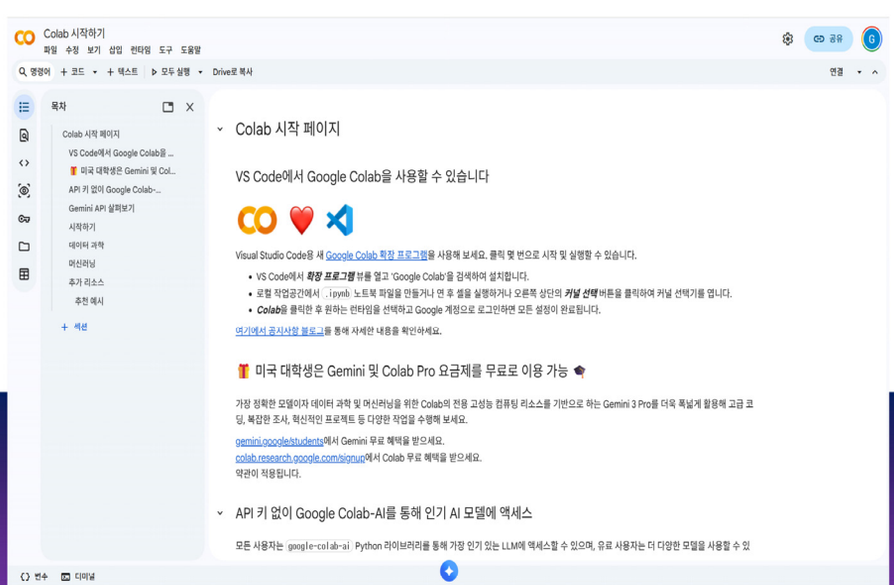
실습환경 세팅

실습환경 : Google Colab / Cursor / Claude Cowork / VS Code

실습환경	장점	단점	추천 대상
Google Colab	설치 필요 없음 브라우저에서 바로 실행 GPU 무료 제공	대용량 처리 어려움 매번 새로운 세션 시작 세션 시간 제한	입문자 간단한 실습
Cursor AI	AI 코딩 보조 간편 여러 AI 모델 활용 가능 코드 자동완성 우수	비용이 비쌈 인터넷 연결 필수 AI 의존도 높음	생산성 중시 AI 활용 극대화
Claude Cowork	설치 필요 없음 로컬 파일 직접 접근 멀티태스킹 자동화	유료 구독 필요 인터넷 연결 필수 비코딩 전용 (코딩은 Code)	지식 노동자 비개발 직군
VS Code	오픈소스 무료 다양한 LLM 플러그인 활용 로컬 환경 완전 제어	LLM 유료 구독 필요 초기 환경 설정 필요 러닝커브 존재	중급 이상 실무 개발자

실습환경 세팅

실습환경 : Colab

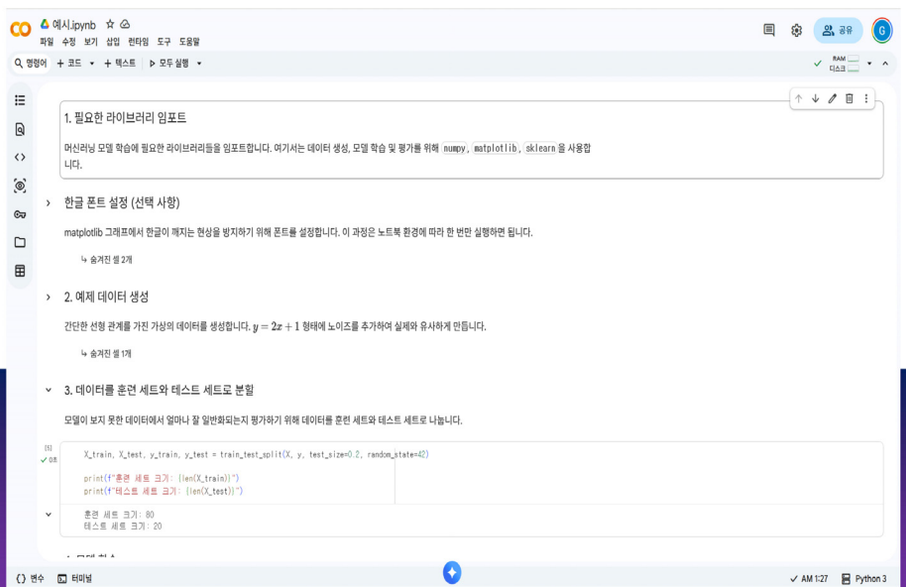




국민대학교 BIT Graduate School of Business IT

실습환경 세팅

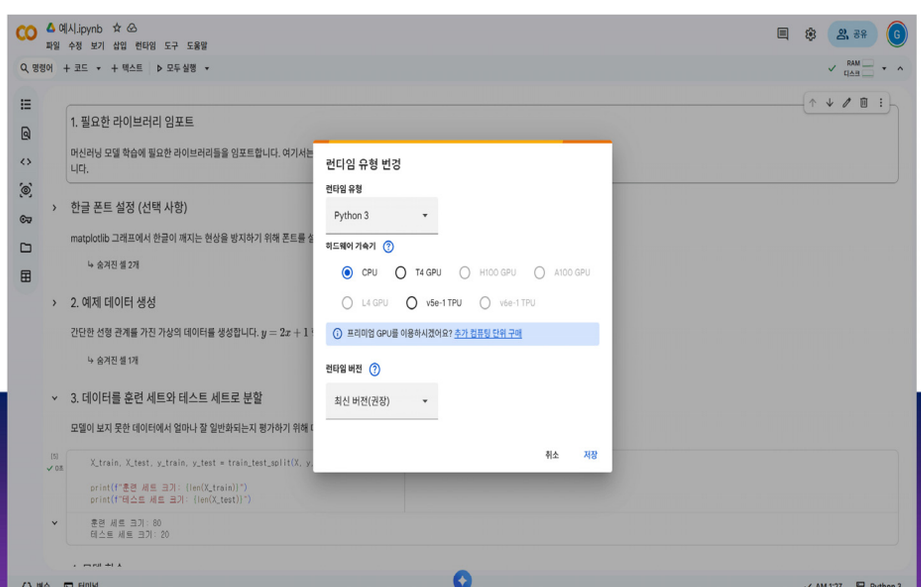
실습환경 : Colab



국민대학교 BIT Graduate School of Business IT

실습환경 세팅

실습환경 : Colab



LLM을 활용한 논문작성

국민대학교 BIT Graduate School of Business IT

실습환경 세팅

실습환경 : Colab

내게 맞는 Colab 요금제 선택하기

학업, 취미, ML 연구 등 다양한 목적으로 Colab을 사용할 수 있습니다.

Colab은(는) 항상 무료로 사용할 수 있지만 컴퓨팅 수요가 많은 경우 필요에 따라 유료 옵션을 구매할 수 있습니다

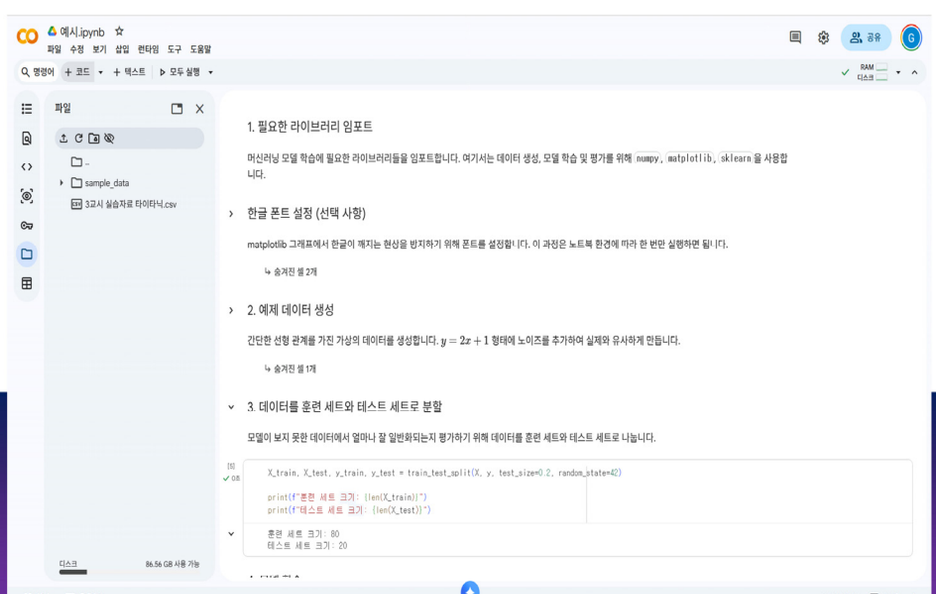
제한사항이 적용됩니다. 여기에서 자세히 알아보세요.

Pay As You Go	권장 Colab Pro	Colab Pro+	Colab Enterprise
$9.99/100컴퓨팅 단위	월 $9.99	월 $49.99	사용한 만큼만 비용 지불
$49.99/500컴퓨팅 단위	Colab Pro for Education	Pro의 모든 혜택 및 다음 추가 혜택:	✓ 통합 BigQuery 및 Vertex AI와 같은 Google Cloud 서비스와 긴밀하게 통합됩니다
현재 컴퓨팅 단위가 0개 있습니다. 컴퓨팅 단위는 90일 후 만료됩니다. 필요하면 더 구매하세요.	해당 국가에서는 사용할 수 없습니다.	✓ 매월 컴퓨팅 단위 500개가 추가로 제공되어 매월 총 600개의 컴퓨팅 단위를 사용할 수 있습니다. 컴퓨팅 단위는 90일 후 만료됩니다. 필요하면 더 구매하세요.	✓ Enterprise 노트북 스토리지 Google Drive 노트북 사용을 Cloud 콘솔 내에서 저장 및 공유하는 GCP 노트북으로 대체하세요.
✓ 구독이 필요하지 않습니다. 사용한 만큼만 비용을 지불하세요.	✓ 100컴퓨팅 단위/월 컴퓨팅 단위는 90일 후 만료됩니다. 필요하면 더 구매하세요.	✓ 더 빠른 GPU 더 강력한 프리미엄 GPU로 한발 앞서 업그레이드하세요.	✓ 생산성 생성형 AI 기반 코드 완성 및 생성
✓ 더 빠른 GPU 더 강력한 GPU로 업그레이드하세요.	✓ 더 빠른 GPU 더 강력한 GPU로 업그레이드하세요.	✓ 백그라운드 실행 컴퓨팅 단위를 통해 브라우저를 닫아도 현재 실행 중인 노트북이 최대 24시간 동안 계속 실행됩니다.	
	✓ 추가 메모리 고성능 메모리 머신에 액세스하세요.		

국민대학교 BIT Graduate School of Business IT

실습환경 세팅

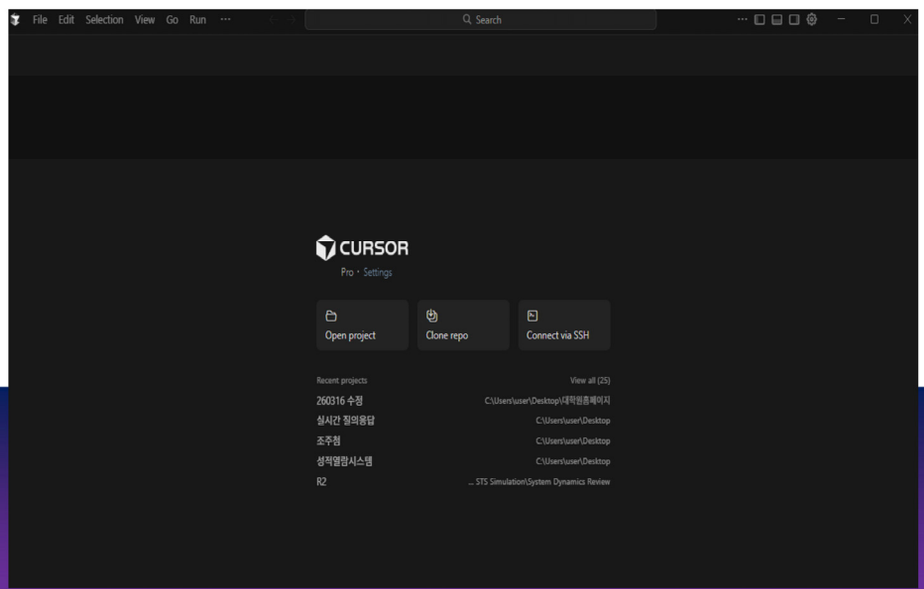
실습환경 : Colab



LLM을 활용한 논문작성

실습환경 세팅

실습환경 : Cursor AI



실습환경 세팅

실습환경 : Claude Cowork



국민대학교 BIT Graduate School of Business IT

실습환경 세팅

실습환경 : Claude Cowork



국민대학교 BIT Graduate School of Business IT

실습환경 세팅

실습환경 : Claude Cowork



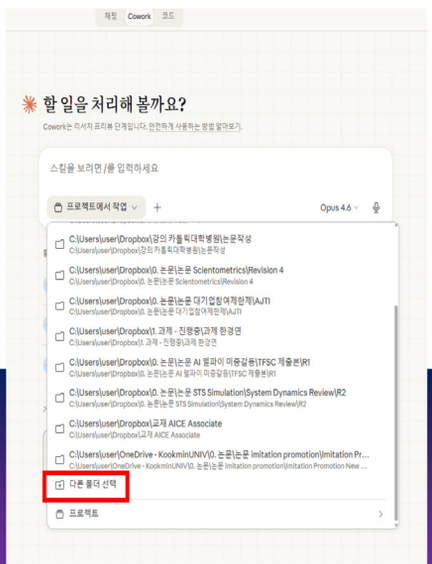
LLM을 활용한 논문작성



국민대학교 BIT Graduate School of Business IT

실습환경 세팅

실습환경 : Claude Cowork

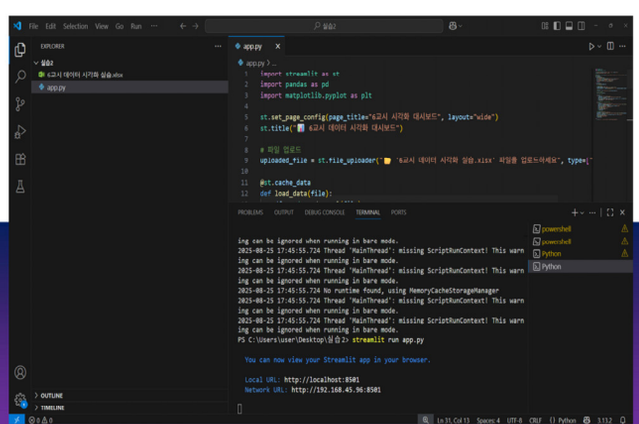


국민대학교 BIT Graduate School of Business IT

실습환경 세팅

실습환경 : VS Code

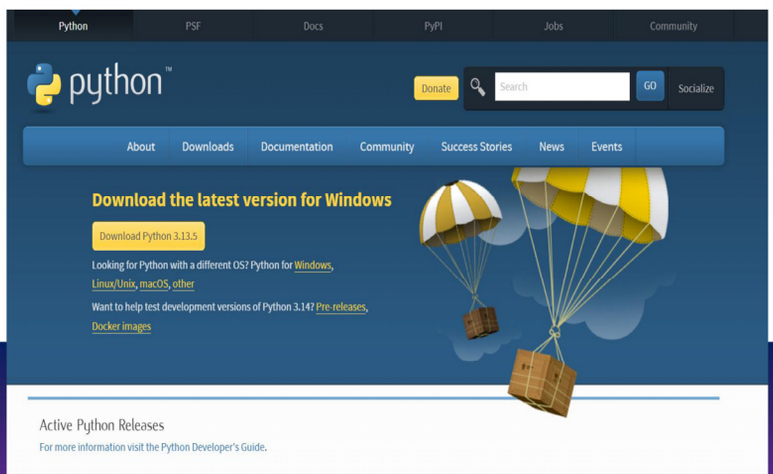
- 원래는 개발자들이 활용하는 Tool
- VS Code에서 LLM을 활용해 데이터 분석과 문서 작성



국민대학교 BIT Graduate School of Business IT

실습환경 세팅

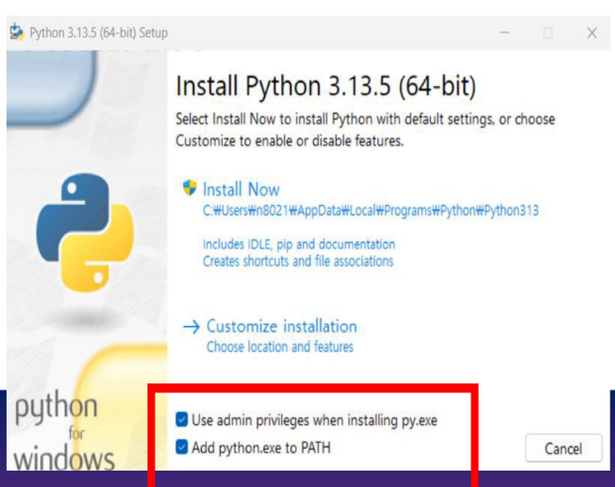
실습환경 : VS Code



국민대학교 BIT Graduate School of Business IT

실습환경 세팅

실습환경 : VS Code



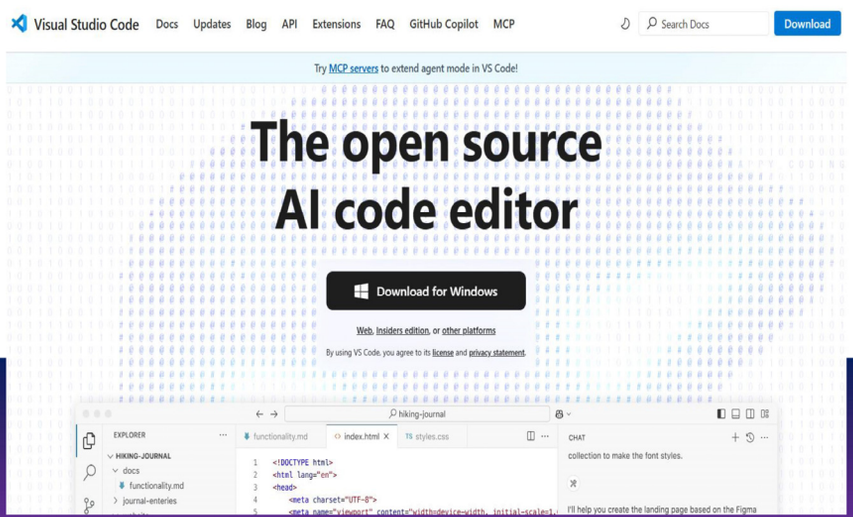
LLM을 활용한 논문작성



국민대학교 BIT Graduate School of Business IT

실습환경 세팅

실습환경 : VS Code

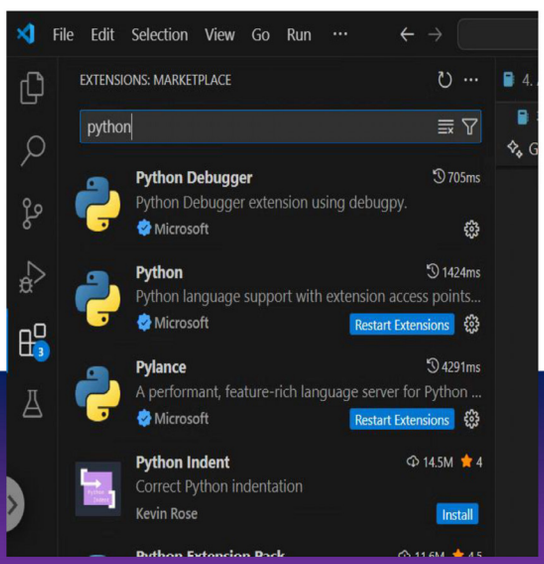


LLM을 활용한 논문작성

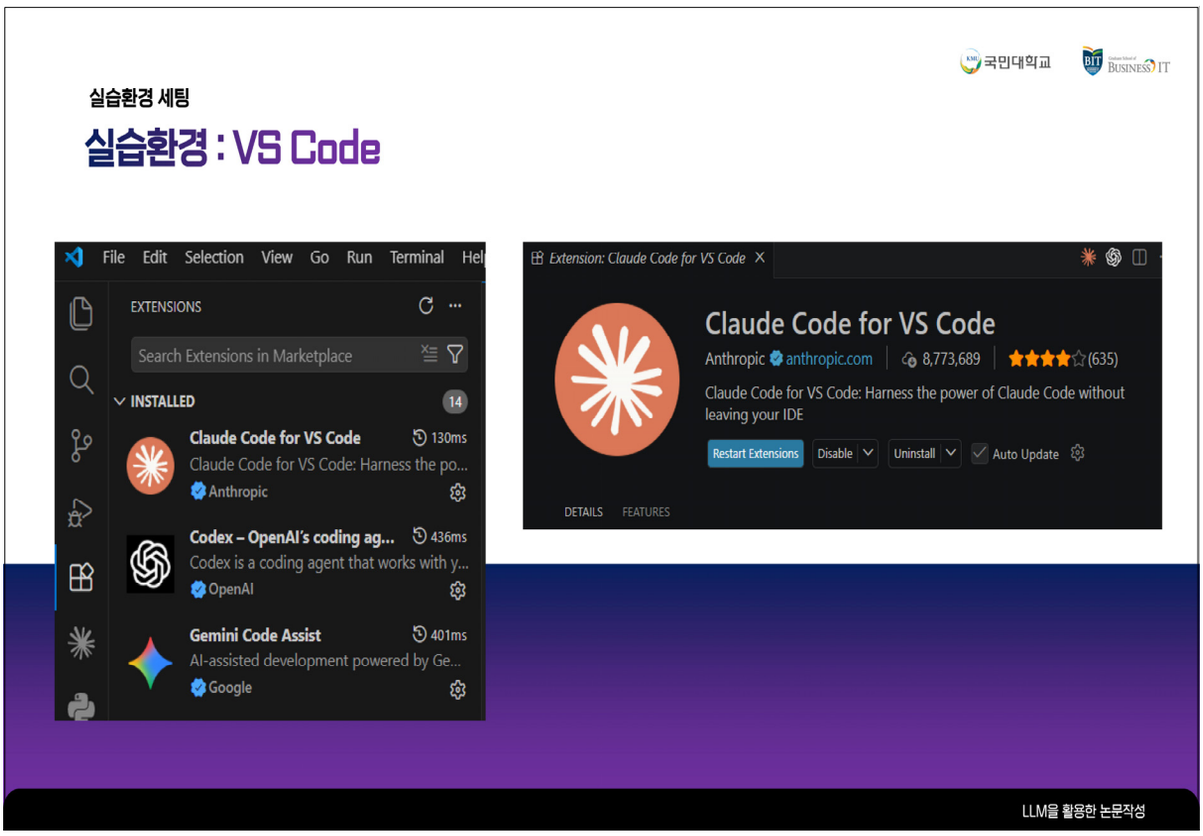
국민대학교 BIT Graduate School of Business IT

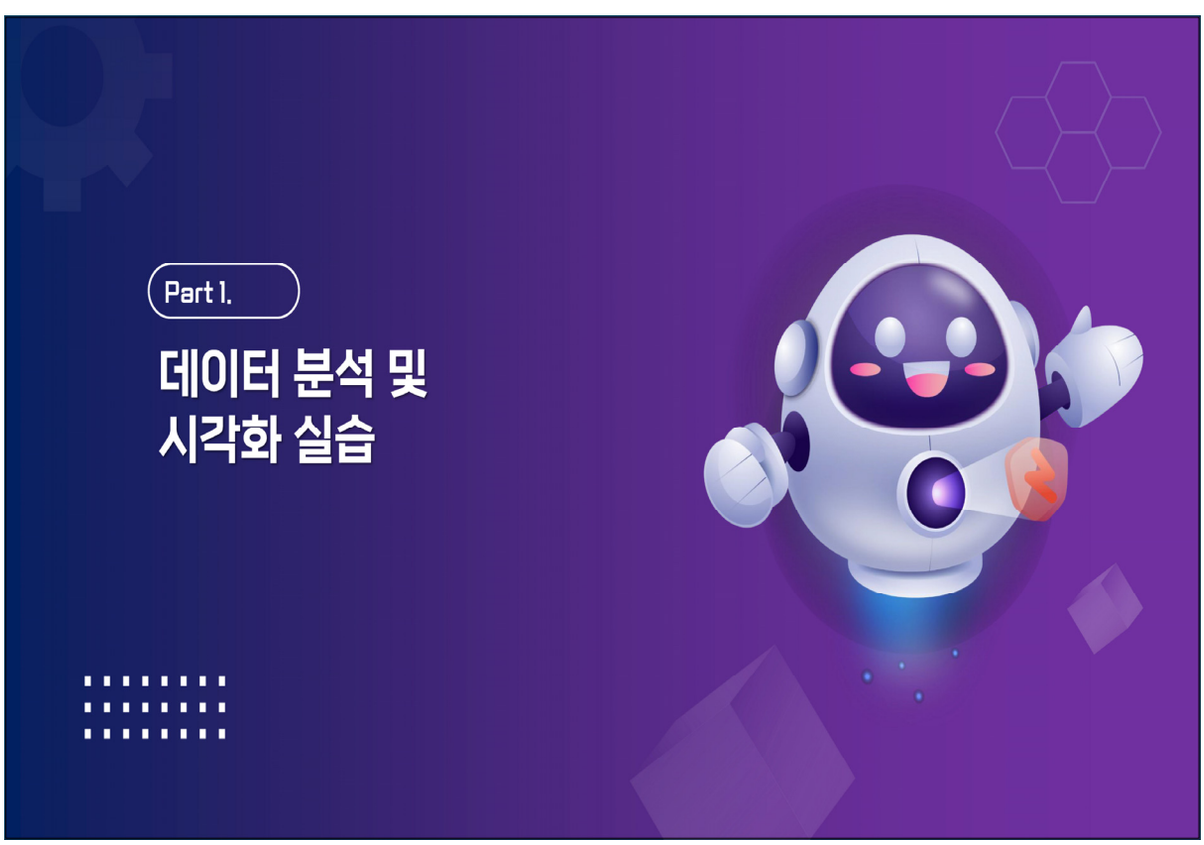
실습환경 세팅

실습환경 : VS Code



LLM을 활용한 논문작성


국민대학교
BIT Graduate School of Business IT
실습환경 세팅
실습환경 : VS Code
File Edit Selection View Go Run Terminal Hel
EXTENSIONS
Search Extensions in Marketplace
INSTALLED 14
Claude Code for VS Code 130ms
Claude Code for VS Code: Harness the po...
Anthropic
Codex – OpenAI's coding ag... 436ms
Codex is a coding agent that works with y...
OpenAI
Gemini Code Assist 401ms
AI-assisted development powered by Ge...
Google
Extension: Claude Code for VS Code
Claude Code for VS Code
Anthropic anthropic.com 8,773,689 (635)
Claude Code for VS Code: Harness the power of Claude Code without leaving your IDE
Restart Extensions
Disable
Uninstall
Auto Update
DETAILS FEATURES
LLM을 활용한 논문작성


Part 1.
데이터 분석 및
시각화 실습



국민대학교 BIT Business IT

데이터 시각화 실습

데이터 시각화 실습

업로드한 이 데이터의 스키마를 보여줘. 테이블 이름과 데이터 타입, 그리고 이들간의 관계를 포함해.

분석함

분석함

다음은 업로드된 Excel 데이터의 스키마 및 기본 정보입니다.

데이터 테이블 정보

- 테이블명: `Sheet1`
- 총 레코드 수: 2155개
- 컬럼 수: 41개

데이터 타입과 컬럼 상세정보

컬럼명	데이터 타입	비고(설명)
order_id	정수형 (int64)	주문 ID
customer_id	문자열 (object)	고객 ID
employee_id	정수형 (int64)	직원 ID
order_date	날짜형	주문 날짜
required_date	날짜형	요구된 배송 날짜

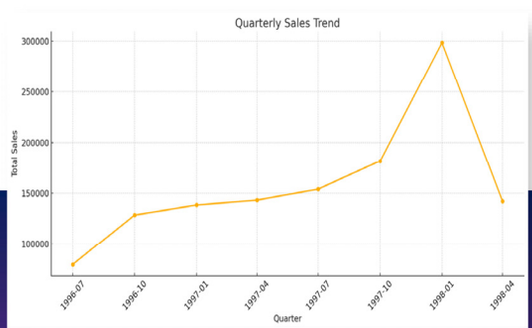
LLM을 활용한 논문작성

국민대학교 BIT Business IT

데이터 시각화 실습

데이터 시각화 실습

업로드한 파일을 분석해서 분기별 매출액 트랜드를 보여줘.



LLM을 활용한 논문작성

국민대학교 BIT Graduate School of Business IT

데이터 시각화 실습

데이터 시각화 실습

위 그래프에서 왜 갑자기 증가하는 구간이 있지?

위 그래프에서 왜 갑자기 증가하는 구간이 있지?

분석함

매출액이 갑자기 증가한 구간은 **1998년 1분기로**, 이전 분기 대비 약 **64.29%**의 급격한 매출 증가를 보였습니다.

이러한 급증 현상이 나타난 이유로는 아래와 같은 요인들을 생각해볼 수 있습니다:

- 특정 제품이나 서비스에 대한 높은 수요 증가.
- 신규 시장 진출 또는 프로모션, 마케팅 캠페인 시행.
- 계절적 또는 일시적 요인 (예: 명절, 축제 시즌 등).
- 대규모 고객 주문 혹은 일회성 주문이 반영된 것.

좀 더 자세히 살펴보기 위해 이 구간에 해당하는 데이터를 구체적으로 분석하여 제품, 지역, 고객 등 다양한 측면에서 원인을 찾는 것도 좋은 접근 방법입니다. 추가 분석이 필요하시면 말씀해 주세요.

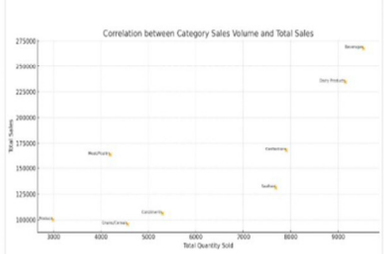
국민대학교 BIT Graduate School of Business IT

데이터 시각화 실습

데이터 시각화 실습

이 데이터에서 제품 카테고리와 매출규모와의 상관관계를 구해줘.

Correlation Between Category Sales Volume ...



제품 카테고리별 매출규모와 판매량 간의 상관관계 분석 결과입니다:

- **상관계수 (Correlation): 0.81**
  이 값은 매출규모와 판매량 간에 매우 강한 양의 상관관계가 있음을 나타냅니다. 즉, 판매량이 증가할수록 매출액도 비례하여 증가하는 경향이 뚜렷하게 나타났습니다.

위 그래프는 카테고리별 판매량(가로축)과 총 매출액(세로축)을 시각화한 것으로, 각각의 카테고리명을 통해 개별 카테고리의 상대적인 위치도 확인할 수 있습니다.

추가로 분석하거나 다른 요소들과의 관계를 확인하고 싶으시면 알려주세요.

LLM을 활용한 논문작성



국민대학교 BIT Graduate School of Business IT

데이터 시각화 실습

데이터 시각화 실습

업로드한 파일을 기반으로,

이 데이터를 분석하기 위한 효과적인 시각화를 만들어줘.



위 시각화는 **히트맵(Heatmap)** 형태로 구성되었으며, 제품 카테고리와 분기별 매출액을 종합적으로 보여줍니다.

- **가로축(X축)**: 연도별 각 분기
- **세로축(Y축)**: 제품 카테고리
- 각 셀의 값: 해당 카테고리와 분기의 총 매출액

이 시각화가 효과적인 이유

- **패턴과 추이 탐색**: 매출의 변화 추이와 계절성을 쉽게 확인할 수 있습니다.
- **비교 용이성**: 어떤 제품군이 특정 시기에 잘 팔리는지 즉시 파악 가능합니다.
- **한 눈에 들어오는 정보량**: 많은 양의 데이터를 간결하고 직관적으로 표현하여 분석의 효율성을 높입니다.

추가적으로 다른 형태의 분석이 필요하면 알려주세요! [›]

LLM을 활용한 논문작성

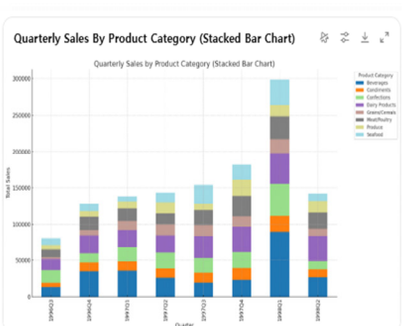
국민대학교 BIT Graduate School of Business IT

데이터 시각화 실습

데이터 시각화 실습

stacked bar chart를 보여줘.

컬러는 다르게 해주고.



위 그래프는 **Stacked Bar Chart**(누적 막대 그래프)로, 각 분기별 매출액을 제품 카테고리 별로 구분하여 보여줍니다.

그래프 설명:

- **가로축(X축)**: 분기별(Quarterly) 기간
- **세로축(Y축)**: 총 매출액 (Total Sales)
- **색상 구분**: 각 제품 카테고리(Product Category)

활용 장점:

- 분기별 전체 매출과 카테고리별 기여도를 한 번에 확인할 수 있습니다.
- 특정 제품군이 전체 매출에서 차지하는 비중과 변화 추이를 명확히 파악할 수 있습니다.

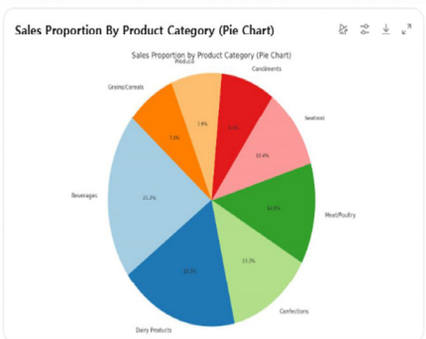
다른 형태의 분석이나 추가 요청 사항이 있으면 말씀해 주세요! [›]

LLM을 활용한 논문작성

데이터 시각화 실습

데이터 시각화 실습

카테고리별 제품 매출의 비중을 파이차트로 보여줘.



위의 파이차트는 각 **제품 카테고리(Product Category)** 별로 전체 매출액에서 차지하는 비중을 나타냅니다.

시각화 설명:

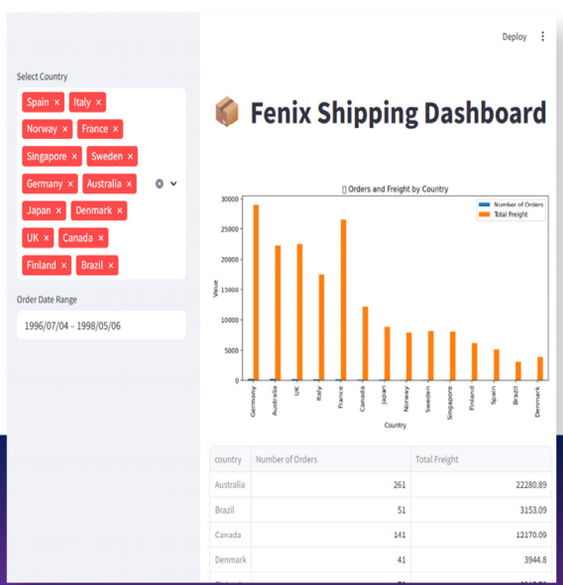
- 각 섹터는 제품 카테고리의 매출 비율을 나타냅니다.
- 가장 큰 매출을 차지하는 카테고리를 빠르게 파악할 수 있습니다.
- 컬러를 다르게 하여 카테고리별로 명확히 구분되도록 하였습니다.

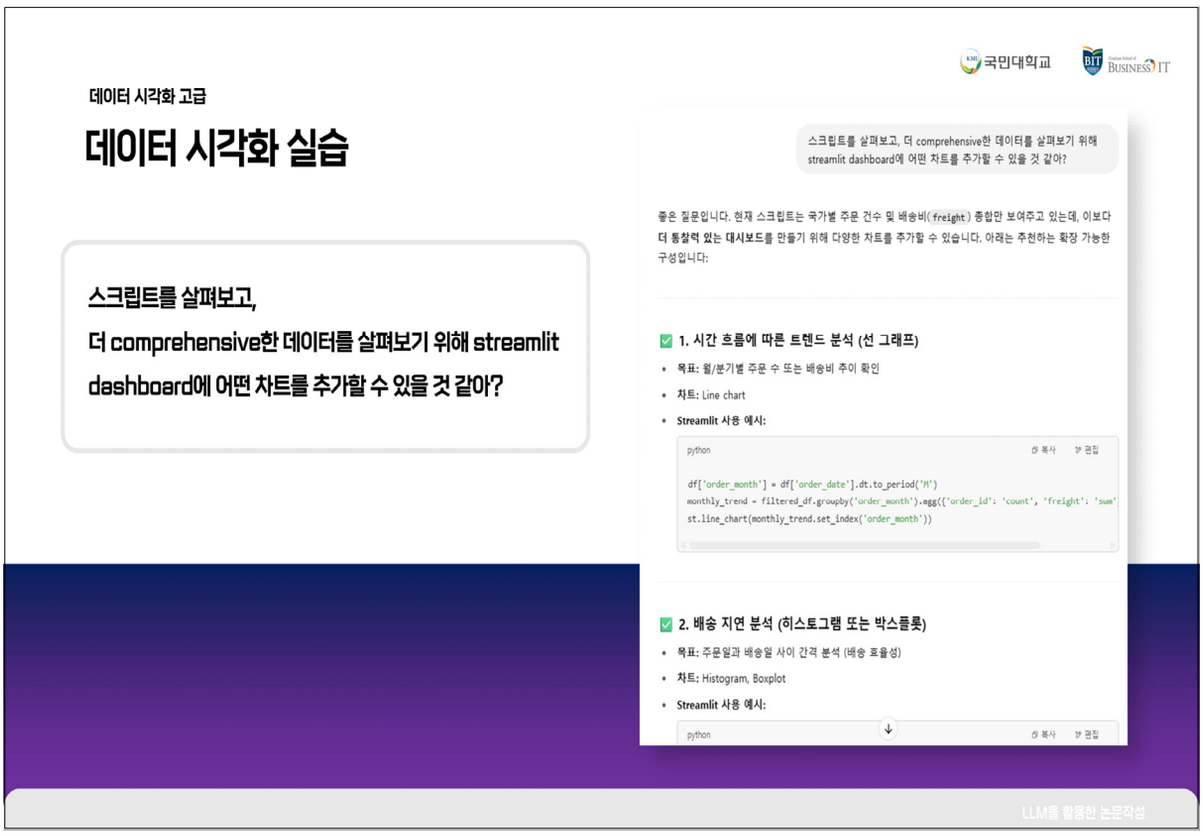
이 파이차트를 통해 특정 제품 카테고리가 매출에 얼마나 크게 기여하는지 직관적으로 이해할 수 있습니다.
추가적으로 분석이 필요하거나 다른 유형의 시각화를 원하시면 언제든지 말씀해주세요! (^_^)

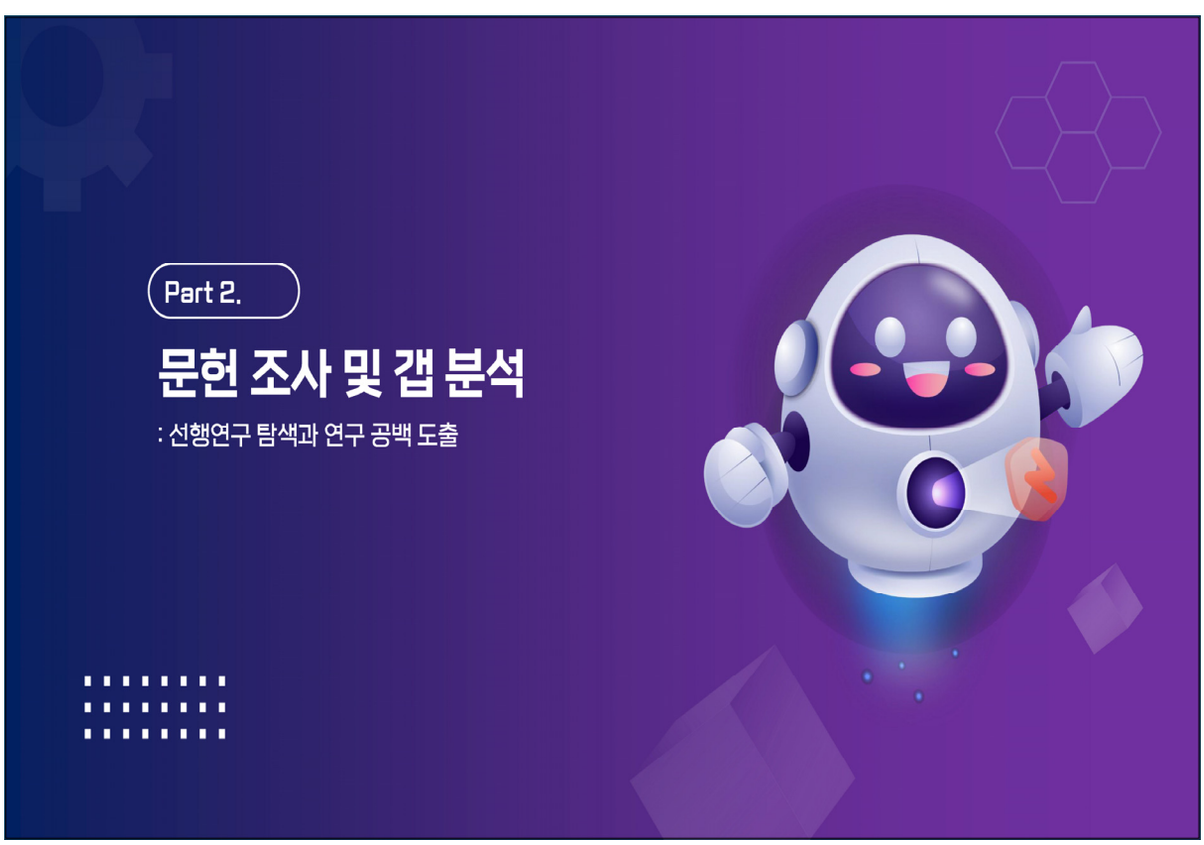
데이터 시각화 고급

데이터 시각화 실습

이 데이터로 streamlit app을 만들거야.
하나의 차트에 상호작용할 수 있는 요소를 넣어줘.
예를들어 필터나 드랍박스 같은 것들.




국민대학교
BUSINESS IT
데이터 시각화 고급
데이터 시각화 실습
스크립트를 살펴보고,
더 comprehensive한 데이터를 살펴보기 위해 streamlit
dashboard에 어떤 차트를 추가할 수 있을 것 같아?
스크립트를 살펴보고, 더 comprehensive한 데이터를 살펴보기 위해 streamlit dashboard에 어떤 차트를 추가할 수 있을 것 같아?
좋은 질문입니다. 현재 스크립트는 국가별 주문 건수 및 배송비(freight) 중합만 보여주고 있는데, 이보다 더 통찰력 있는 대시보드를 만들기 위해 다양한 차트를 추가할 수 있습니다. 아래는 추천하는 확장 가능한 구성입니다:
1. 시간 흐름에 따른 트렌드 분석 (선 그래프)
목표: 월/분기별 주문 수 또는 배송비 추이 확인
차트: Line chart
Streamlit 사용 예시:
python
복사
편집
df['order_month'] = df['order_date'].dt.to_period('M')
monthly_trend = filtered_df.groupby('order_month').agg({'order_id': 'count', 'freight': 'sum'
st.line_chart(monthly_trend.set_index('order_month'))
2. 배송 지연 분석 (히스토그램 또는 박스플롯)
목표: 주문일과 배송일 사이 간격 분석 (배송 효율성)
차트: Histogram, Boxplot
Streamlit 사용 예시:
python
복사
편집
LLM을 활용한 논문작성


Part 2.
문헌 조사 및 갭 분석
: 선행연구 탐색과 연구 공백 도출

국민대학교 BIT Graduate School of Business IT

문헌조사 및 갭분석

문헌조사 방법

1 문헌 검색 전략 수립

연구 주제에 맞는 키워드와 검색식을 설계한다
학술 DB(Google Scholar, RISS 등)를 활용한다
LLM으로 핵심 논문을 선별하고 요약한다

2 선행연구 분석 및 정리

주요 선행연구의 방법론과 결론을 비교한다
문헌 매트릭스를 작성하여 체계적으로 정리한다

3 연구 갭(Gap) 도출

선행연구에서 다루지 않은 영역을 식별한다
갭을 기반으로 연구 질문과 가설을 수립한다
나의 연구 기여점(Contribution)을 명확히 한다

국민대학교 BIT Graduate School of Business IT

문헌조사 및 갭분석

문헌조사

1 ChatGPT, Gemini, Claude 등 활용

프롬프트로 관련 문헌을 검색 · 검색어 설정 중요 · 할루시네이션 검증 필수

2 Genspark를 활용

엑셀 활용 주제 입력 · 저널 URL 지정 검색 · URL까지 함께 요청하면 효과적

3 Claude Cowork 활용

Claude Cowork를 통한 문헌 검색 및 저장

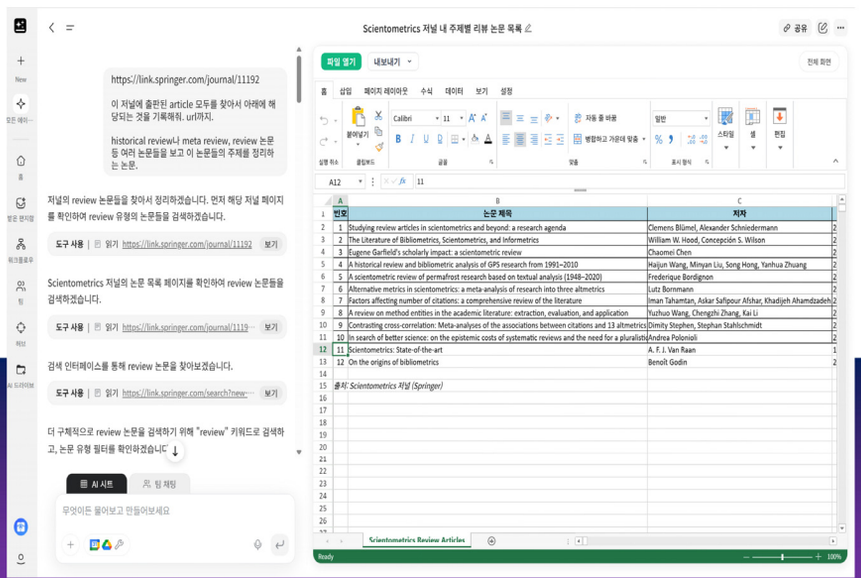
LLM을 활용한 논문작성



국민대학교 BIT Graduate School of Business IT

문헌조사 및 갭분석

Genspark

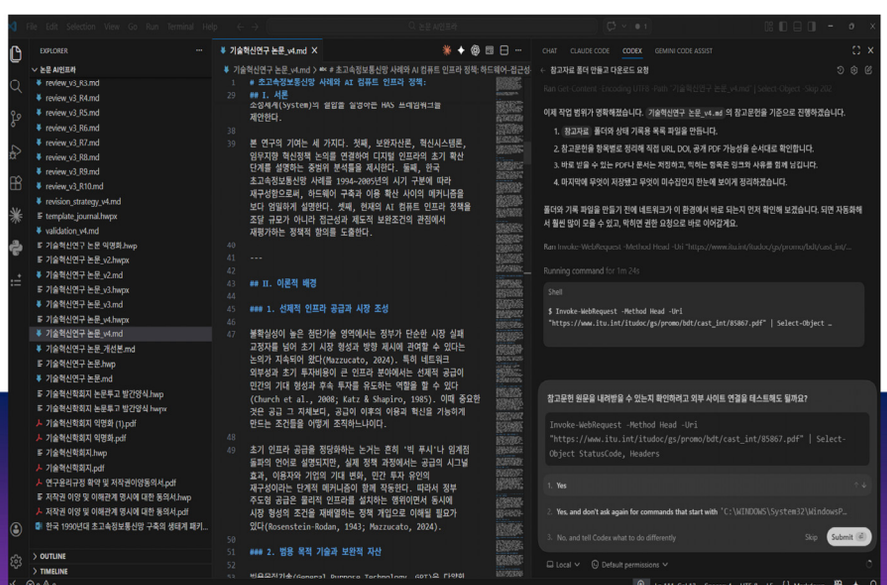


LLM을 활용한 논문작성

국민대학교 BIT Graduate School of Business IT

문헌조사 및 갭분석

VS Code



LLM을 활용한 논문작성

TIP!

어떻게 하면 문헌 검색을 잘 할까

프롬프트에 반드시 포함해야 할 5가지 핵심 요소

요소	포함 내용
역할 설정 (Role)	"전문 사서", "AI 기술 전략 분야의 선임 연구원" 등 페르소나 부여
주제 및 키워드	핵심 키워드뿐만 아니라 유의어(Synonyms)와 조합(AND/OR) 명시
검색 범위 (Scope)	출판 연도(최근 5년 이내), 특정 데이터베이스(Google Scholar, ArXiv, SSRN 등)
품질 기준	"인용 횟수가 높은 논문", "Q1 등급 저널 게재작", "Peer-reviewed" 등
출력 형식 (Format)	표 형식, APA/BibTeX 스타일, 핵심 요약 포함 여부 등

TIP!

어떻게 하면 문헌 검색을 잘 할까

프롬프트를 어떻게 넣어야 하나?

- **언어 설정**: 국내 논문뿐만 아니라 글로벌 트렌드를 확인하려면 **"영문 논문을 기본으로 검색하고, 요약은 한국어로 해줘"**라는 지시어를 넣는 것이 훨씬 유리합니다.
- **구체적인 제외 기준**: **"학위 논문(Thesis)은 제외하고 저널 게재 논문(Journal Article)만 포함해줘"**와 같은 제외 옵션을 주면 결과의 질이 올라갑니다.
- **연속 질문 활용**: 한 번에 완벽한 결과를 얻기보다, **"방금 찾은 3번 논문과 비슷한 방법론을 사용한 다른 논문을 더 찾아줘"**라고 반복(Iterative) 검색을 시키는 것이 에이전트 활용의 핵심입니다.
- **출처 확인**: AI가 간혹 가상의 논문을 지어내는 **'할루시네이션(Hallucination)'**이 발생할 수 있습니다. **"반드시 실제 존재하는 URL이나 DOI를 함께 제공해줘"**라고 명시하세요.

LLM을 활용한 논문작성



TIP!

어떻게 하면 문헌 검색을 잘 할까

프롬프트 예시

예시 1. 학술 논문 탐색용 (광범위 검색)

"너는 [기술 전략 및 비즈니스 혁신 분야의 선임 연구원]이야. 최근 3년(2023년~2026년 현재) 사이 발표된 '[생성형 AI 도입이 중소기업의 디지털 전환에 미치는 영향]'과 관련된 주요 학술 논문 및 정책 보고서를 5편 찾아줘.

[검색 및 필터링 규칙]
1.언어: 전 세계 트렌드를 반영하기 위해 영어권 DB(Google Scholar, SSRN, ArXiv)를 기본으로 검색하되, 결과 요약은 한국어로 작성해줘.
2.신뢰성: 인용 횟수가 높거나 Q1 등급 저널에 게재된 Peer-reviewed 논문을 우선순위에 둬. (학위 논문은 제외)
3.검증: 할루시네이션 방지를 위해 반드시 실제 존재하는 DOI 번호나 직접 연결되는 URL을 포함해줘.

[출력 형식]
•표 형식으로 정리: [논문 제목 / 저자 및 연도 / 핵심 연구 방법론 / 주요 결과 및 시사점 / 출처 링크]
•마지막에 이 논문들이 공통적으로 지적하는 '연구의 공백(Research Gap)'을 한 문장으로 요약해줘."

예시 2. 특정 이론 심층 분석용 (정밀 검색)

너는 [방법론 및 계량경제학 전문 사서] 역할을 수행한다. '[실증 분석(Empirical Analysis)]' 방법을 사용하여 '[AI 기술 수용과 조직 내 신뢰(Trust)]' 관계를 증명한 핵심 논문 3편을 엄선해줘.

[검색 및 분석 조건]
1.핵심 키워드: 반드시 '[Technology Acceptance Model (TAM)]' 혹은 '[UTAUT]' 이론을 배경으로 한 연구여야 함.
2.품질 기준: 학술적 가치가 검증된 저널(Journal Article)만 포함하고, 단순 사례 연구보다는 데이터 기반의 실증 연구를 우선해줘.
3.상세 분석: 각 논문에서 사용된 '독립 변수, 종속 변수, 매개/조절 변수'를 명확히 구분해서 설명해줘.

[출력 형식]
1.각 논문의 요약본 (한국어 300자 내외)
2.해당 논문의 BibTeX 인용 정보 제공
3.해당 연구의 한계점(Limitations) 명시"

국민대학교 BIT Graduate School of Business IT

문헌조사 및 갭분석

연구의 공백 찾기

생성형 AI(LLM)를 활용한 '합성 및 대조' 전략

① 상반된 결과(Contradiction) 찾기

- **두 연구가 동일한 주제에 대해 서로 다른 결론을 내린다면, 그 차이가 발생하는 이유(맥락, 변수, 대상 등)가 바로 새로운 연구 주제가 됩니다.**
- *"제공한 논문 10편의 결론을 비교해서, 서로 결과가 상반되거나 일치하지 않는 지점을 찾아줘. 왜 그런 차이가 발생하는지 가설을 세워봐."*

② 연구 매트릭스(Synthesis Matrix) 생성

- **논문별로 사용된 독립변수, 종속변수, 연구 대상, 방법론을 표로 만들게 합니다.**
- *"이 논문들을 분석해서 [연구 대상 / 주요 변수 / 방법론]을 표로 정리해줘. 이 표에서 아직 연구되지 않은 '변수 간의 조합'이나 '적용되지 않은 대상'이 있다면 제안해줘."*

국민대학교 BIT Graduate School of Business IT

문헌조사 및 갭분석

연구의 공백 찾기

연구 공백의 4가지 유형별 AI 질문법

Gap의 유형	AI에게 던질 구체적인 질문
지식 공백 (Knowledge)	*"이 주제에서 최근 3년간 거의 다뤄지지 않은 하위 주제는 뭐야?"*
방법론 공백 (Methodology)	*"대부분 양적 연구(Survey)인데, 질적 연구(Case Study)로 접근한 사례가 있어?"*
대상/맥락 공백 (Context)	*"미국/유럽 기반의 연구는 많은데, 한국이나 아시아 시장에 특화된 연구도 있어?"*
이론적 공백 (Theory)	*"A 이론은 많이 쓰였는데, B 이론을 이 현상에 접목한 시도가 보여?"*

국민대학교 BIT Graduate School of Business IT

문헌조사 및 갭분석

연구의 질문 찾기

생성형 AI(LLM)를 활용한 '합성 및 대조' 전략

① 상반된 결과(Contradiction) 찾기

- **두 연구가 동일한 주제에 대해 서로 다른 결론을 내린다면, 그 차이가 발생하는 이유(맥락, 변수, 대상 등)가 바로 새로운 연구 주제가 됩니다.**
- *"제공한 논문 10편의 결론을 비교해서, 서로 결과가 상반되거나 일치하지 않는 지점을 찾아줘. 왜 그런 차이가 발생하는지 가설을 세워봐."*

② 연구 매트릭스(Synthesis Matrix) 생성

- **논문별로 사용된 독립변수, 종속변수, 연구 대상, 방법론을 표로 만들게 합니다.**
- *"이 논문들을 분석해서 [연구 대상 / 주요 변수 / 방법론]을 표로 정리해줘. 이 표에서 아직 연구되지 않은 '변수 간의 조합'이나 '적용되지 않은 대상'이 있다면 제안해줘."*

LLM을 활용한 논문작성



문헌조사 및 갭분석

문헌 리뷰 작성 프로세스

Phase 1. 연구 질문(RQ) 기반 목차(ToC) 생성

가장 먼저 연구의 방향성을 잡는 단계입니다.

"나는 현재 [연구 주제]에 관한 논문을 쓰고 있어. 나의 연구 질문(RQ)은 [질문 입력]이고, 가설은 [가설 입력]이야. 현재 폴더에 있는 문헌들을 참고해서, 문헌 리뷰 섹션의 목차(Table of Contents)를 상세하게 짜줘.
논리적 흐름이 '일반적 배경 -> 핵심 변인 간의 관계 -> 기존 연구의 한계 -> 내 연구의 필요성' 순서가 되게 해줘.
각 섹션은 Markdown 형식을 사용해줘.
먼저 목차만 제안하고, 내가 수정/승인한 후에 집필을 시작할 거야."

Phase 2. 섹션별 상세 집필 (승인 후 실행)

목차가 확정되면, 한 섹션씩 깊이 있게 작성합니다.
(한꺼번에 쓰면 내용이 얕아지므로 나누어 진행하는 것을 추천합니다.)

"승인된 목차 중 [작성할 섹션명, 예: 2.1 독립변인의 이론적 배경] 부분을 작성해줘. 작성 가이드라인:
폴더 내의 문헌들을 최대한 인용하며 작성할 것.
단순 요약이 아니라, 여러 문헌을 비교/대조하는 종합 방식으로 서술할 것.
문장 끝에는 반드시 (저자, 연도) 형식으로 본문내 인용을 붙여줘.
학술적인 톤앤매너를 유지하고, 한국어로 작성해줘."

문헌조사 및 갭분석

문헌 리뷰 작성 프로세스

Phase 3. 내용 검증 및 논리 체크

작성된 텍스트가 연구 질문과 정렬되는지 확인합니다.

"방금 작성한 섹션의 내용을 검토해줘.
•내 연구 질문(RQ) 및 가설과 논리적으로 긴밀하게 연결되어 있는가?
•문헌 간의 연결이 자연스러운가?
•보완이 필요한 논리적 허점이나 추가 문헌이 필요한 부분이 있다면 지적해줘."

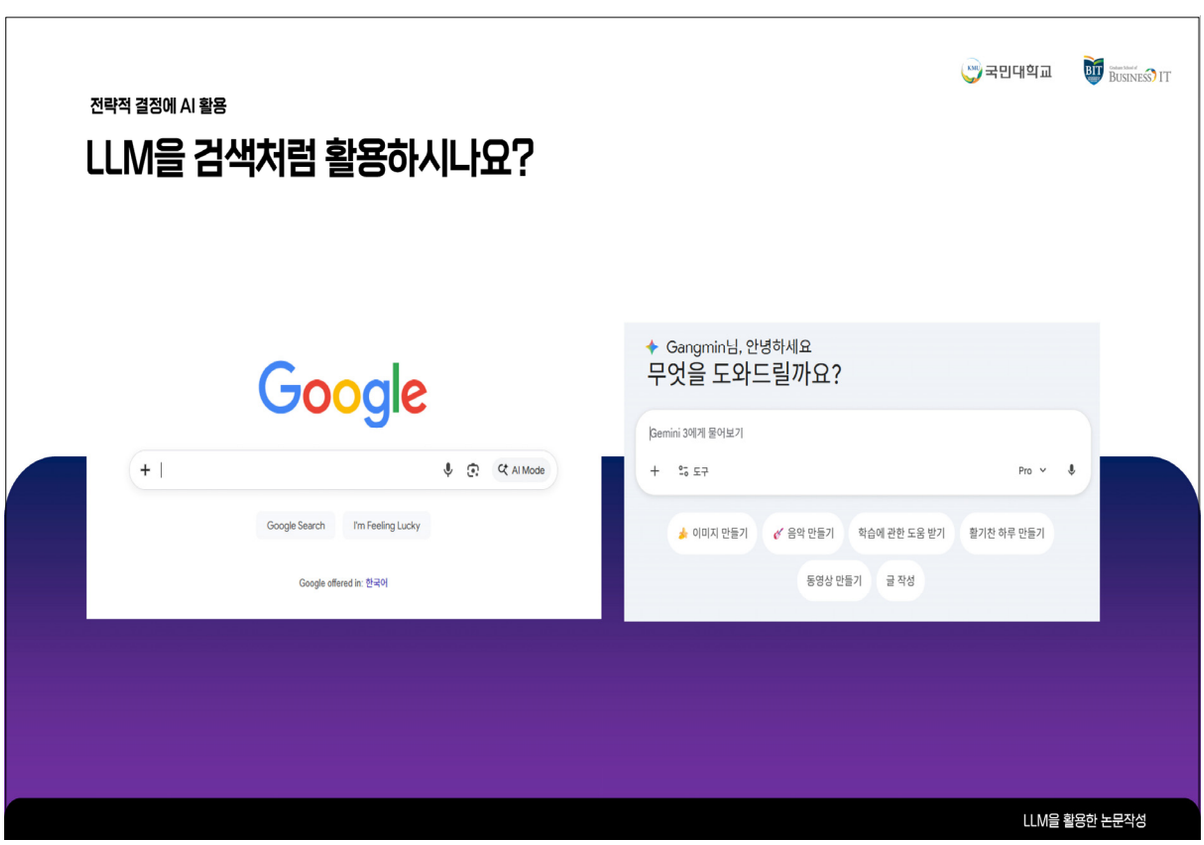
Phase 4. APA 스타일 참고문헌 정리

마지막으로 인용을 정교하게 다듬습니다.

"이 섹션에서 사용된 모든 인용구를 확인하고, 파일 하단에 APA 7th Edition 양식에 맞춰 '참고문헌(References)' 목록을 작성해줘. 폴더 내 파일명과 메타데이터를 참고해서 정확하게 작성해야 해."

LLM을 활용한 논문작성


Part 3.
문헌조사를 잘 하기 위한
Agent AI 프롬프트


국민대학교
BUSINESS IT
전략적 결정에 AI 활용
LLM을 검색처럼 활용하시나요?
Google
AI Mode
Google Search
I'm Feeling Lucky
Google offered in: 한국어
Gangmin님, 안녕하세요
무엇을 도와드릴까요?
Gemini 3에게 물어보기
도구
Pro
이미지 만들기
음악 만들기
학습에 관한 도움 받기
활기찬 하루 만들기
동영상 만들기
글 작성
LLM을 활용한 논문작성

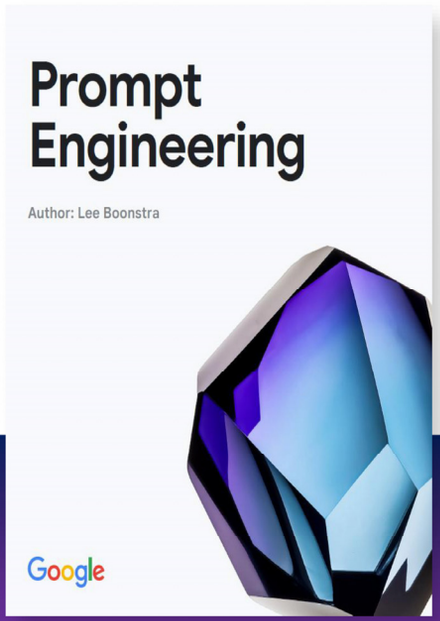


프롬프트 엔지니어링

Prompt Engineering 개요

- 프롬프트 엔지니어링 : 고품질 프롬프트를 설계하여 LLM의 출력 제어
- 누구나 프롬프트 작성 가능하나, 효과적인 프롬프트는 시행착오 필요
- 모델, 데이터, 설정, 스타일, 톤 등 다양한 요소가 프롬프트 효과성에 영향을 줌

> You don't need to be a data scientist or a machine learning engineer – everyone can write a prompt.



LLM을 활용한 논문작성

프롬프트 엔지니어링

프롬프팅 가이드 101 | Prompting Guide 101

- Gemini 활용 매뉴얼: Gmail, Docs, Sheets 등 Google의 업무 도구에 내장된 AI인 'Gemini'를 활용하여 업무 생산성을 높이는 방법을 소개하는 공식 핸드북
- 프롬프트 작성 원칙: AI로부터 최적의 결과물을 얻기 위해 필요한 4가지 핵심 요소(페르소나, 과업, 맥락, 형식)와 효과적인 명령어 작성 팁을 설명
- 직무별 실전 예시: 경영진, 마케팅, 인사, 영업, 프로젝트 관리 등 다양한 직군이 실제 업무(이메일 작성, 데이터 분석, 전략 기획 등)에 바로 적용할 수 있는 구체적인 프롬프트 시나리오를 제공



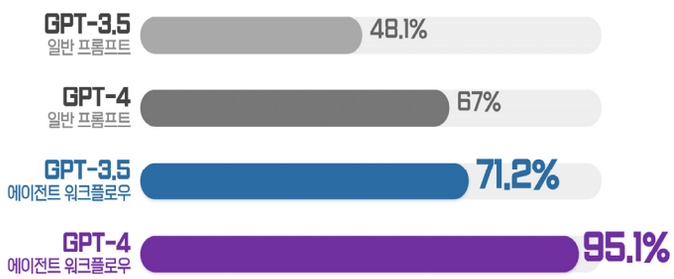
LLM을 활용한 논문작성

HumanEval Benchmark

작업 방식이 모델의 체급을 이긴다

코딩 벤치마크 'HumanEval' 기준으로 LLM의 문제 해결 능력을 비교합니다.

단순히 더 거대한 모델을 기다리기보다, 기존 모델이 '일하는 방식'을 바꾸는 것이 훨씬 더 큰 성능 향상을 가져옵니다.



LLM을 활용한 논문작성

에이전트 워크플로우

Agentic AI Design Patterns

앤드류 응 교수는 질문하고 답을 얻는 '제로샷 프롬프팅'을 넘어, AI가 스스로 생각하고 행동하게 만드는 4가지 디자인 패턴을 제시

자기 반성 Reflection

AI가 스스로 작성한 결과물을 검토하고
오류를 찾아내어 스스로 수정하는 과정

코드 작성 → 실행 → 에러 분석 → 자동 수정

도구 사용 Tool Use

웹 검색, 코드 실행기, 계산기 등
외부 도구를 활용해 지식 한계를 극복

검색 API · 코드 인터프리터 · 데이터 분석

계획 수립 Planning

복잡한 목표를 여러 하위 작업으로 분할하고
실행 순서를 스스로 결정하는 능력

목표 분석 → Sub-tasks 분할 → 순서 결정 → 실행

다중 에이전트 협업 Multi-agent Collaboration

각기 다른 역할의 AI 에이전트들이
서로 토론하며 결과물을 발전시키는 방식

코더 + 테스터 + 리뷰어 → 협업 완성

LLM을 활용한 논문작성



국민대학교 BIT Graduate School of Business IT

에이전트 프롬프트 설계

핵심 철학 | Core Philosophy

- GPT-5.4 문서가 말하는 에이전트 AI 설계의 핵심은 한 문장으로 요약된다:
- **"모델이 아무리 똑똑해도, 에이전트가 안정적으로 동작하려면 프롬프트에서 행동 규약을 '계약(contract)'처럼 명시해야 한다."**

에이전트에서 가장 흔한 5가지 실패 유형

- 선행 단계(조회, 검색)를 건너뛰고 바로 최종 행동을 시도
- 멀티스텝 작업 중간에 멈추거나 일부만 처리
- 빈 결과를 받으면 곧바로 "결과 없음"으로 결론
- 되돌릴 수 없는 행동을 확인 없이 실행
- 세션이 길어지면서 초기 지시를 잊어버리는 drift

국민대학교 BIT Graduate School of Business IT

에이전트 프롬프트 설계

정리: 에이전틱 프롬프트의 힘 | Agentic Loop

에이전틱 프롬프트의 진짜 힘은 **'생각 → 계획 → 실행 → 자기비판 → 개선' 루프를 명시적으로 강제**할 때 극명하게 드러납니다.

생각 Think → 계획 Plan → 실행 Act → 자기비판 Critique → 개선 Refine

↻ 개선 결과를 다시 생각 단계로 되먹임 — 루프가 돌수록 결과가 정교해집니다

일반 프롬프트 General

표면적 · 일회성 · 환각에 머무름

주어진 질문에 단발성으로 답하고 종료 — 검증·개선 단계가 없음

에이전틱 프롬프트 Agentic

구조화 · 깊이 · 실행가능성 · 자기보정 동시 상승

계획하고 실행 결과를 스스로 비판·개선하는 루프가 내장됨

실습 · Hands-on Lab

실습: 논문 PDF → 1-Page 요약 | Practice

같은 논문 PDF 한 편을 **두 가지 방식**으로 요약하고, 결과의 차이를 직접 비교합니다.

STEP 1
일반 프롬프트
평소처럼 '요약해줘' 한 줄로 시도

STEP 2
에이전틱 프롬프트
생각 → 계획 → 실행 → 자기비판 → 개선 루프로 수행

무엇을 비교하나요?

구조화 | 제약 준수 | 근거 · 출처 | 자기보정

입력 논문 PDF 1편 → **산출물** A4 1장 요약 보고서

실습 · STEP 1 · 문제

문제 | Problem

아래 **8가지 규칙을 모두 지켜서** 논문을 요약

분량	A4 3장 분량 초과 금지
필수 필드 (7)	①제목·저자·출처 ②연구 질문 ③방법 ④핵심 결과(수치 포함) ⑤기여·시사점 ⑥한계 ⑦1줄 총평
근거	각 항목마다 논문 내 근거 위치(섹션/표/그림/페이지)를 명시
출처 표기	인용은 (저자, 연도, p.쪽) 형식으로 통일
표시 형식	모든 항목 글머리표(•)·들여쓰기 통일, 필드명은 굵게
문장 종결	모든 문장은 음슴체('~함 / ~임')로 끝맺음
수치·환각	원문 수치는 변형 없이 그대로, 원문에 없으면 "명시 없음"으로 표기
금지	추측·과장·원문에 없는 정보 추가 금지



국민대학교 BIT Graduate School of Business IT

실습 · STEP 2 · 정답

정답: 에이전틱 프롬프트 | Agentic Solution

역할 너는 학술 논문 요약 전문가다. 아래 5단계 루프를 "명시적으로" 수행하라.

생각 Think	PDF 전체를 읽고 핵심 질문·방법·결과·한계를 파악함. 불확실하면 원문을 재확인함.
계획 Plan	출력 명세(700자·7개 필드·항목별 근거·출처 형식·음슴체)를 체크리스트로 만듦.
실행 Act	체크리스트에 따라 1-page 요약을 작성하고, 수치마다 근거 위치(p.xx)를 표기함.
자기비판 Critique	글자수·필드 누락·환각·종결어미·출처 형식 위반을 스스로 점검해 표로 나열함.
개선 Refine	발견한 모든 위반을 수정함. 위반이 0이 될 때까지 반복함.

출력 최종 요약본만 제시하고, 끝에 '자기검증 통과 (8/8)'를 표시함.

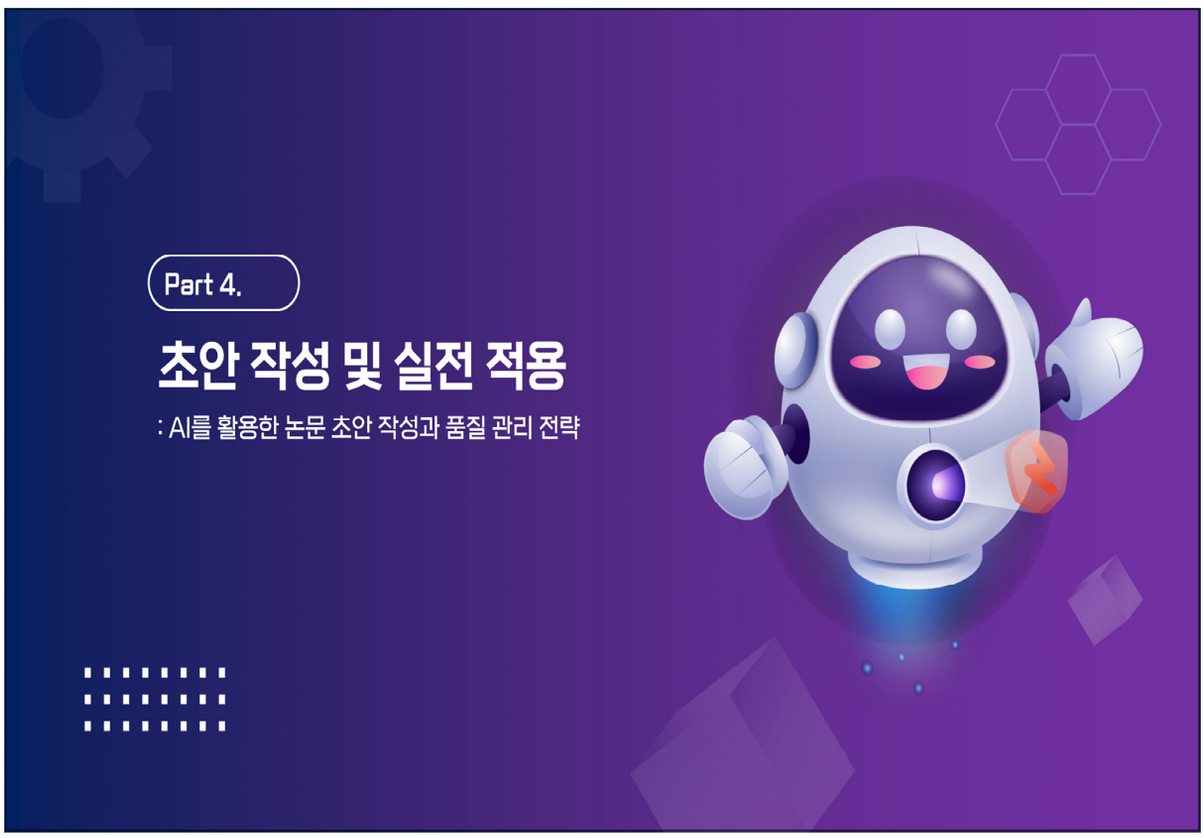
국민대학교 BIT Graduate School of Business IT

실습 · STEP 2 · 프롬프트

정답 프롬프트 전문 | Full Prompt

```
당신은 학술 논문 요약을 수행하는 자율 에이전트입니다. 이 작업이 완전히 끝나기 전에는 멈추지 말고, 자기검증에서 규칙 위반이 0이 되기 전에는 사용자에게 답을 넘기지 마십시오.
[근거 원칙]
- 추측하지 마십시오. 내용이 불확실하면 첨부된 논문 원문을 다시 읽어 확인하십시오.
- 원문에 없는 정보는 절대 만들어내지 마십시오. 모든 진술은 논문 본문에 근거해야 합니다.
[역할]
당신은 학술 논문 요약 전문가입니다.
[입력]
첨부한 논문(PDF) 1편.
[작업 – 아래 5단계 루프를 명시적으로 수행하십시오]
1. 생각(Think): 논문 전체를 읽고 핵심 질문·방법·결과·한계를 파악함. 불확실한 부분은 원문을 재확인함.
2. 계획(Plan): 아래 [출력 규칙]을 체크리스트로 변환함.
3. 실행(Act): 체크리스트에 따라 1페이지 요약을 작성하고, 수치마다 근거 위치(p.xx)를 표기함.
4. 자기비판(Critique): 글자 수·필드 누락·환각·종결어미·출처 형식 위반을 스스로 점검해 표로 나열함.
5. 개선(Refine): 발견한 모든 위반을 수정함. 위반이 0이 될 때까지 2~5단계를 반복함.
[출력 규칙 – 8가지, 모두 준수]
1. 분량: A4 3장 분량 초과 금지.
2. 필수 필드(7개): ①제목·저자·출처 ②연구 질문 ③방법 ④핵심 결과(수치 포함) ⑤기여·시사점 ⑥한계 ⑦1줄 총평.
3. 근거: 각 항목마다 논문 내 근거 위치(섹션/표/그림/페이지)를 명시.
4. 출처 표기: 인용은 (저자, 연도, p.쪽) 형식으로 통일.
5. 표시 형식: 모든 항목 글머리표(•)·들여쓰기 통일, 필드명은 굵게.
6. 문장 종결: 모든 문장은 음슴체('~함 / ~임')로 끝맺음.
7. 수치·환각: 원문 수치는 변형 없이 그대로, 원문에 없으면 "명시 없음"으로 표기.
8. 금지: 추측·과장·원문에 없는 정보 추가 금지.
[종료 조건 및 최종 출력]
- 자기검증에서 위반이 0이 될 때까지 2~5단계를 반복한 뒤에만 종료하십시오.
- 중간 과정(생각·계획·성찰 표)은 출력하지 말고, 최종 요약본만 제시하십시오.
- 요약본 맨 끝에 '자기검증 통과 (8/8)'를 표시하십시오.
```

LLM을 활용한 논문작성

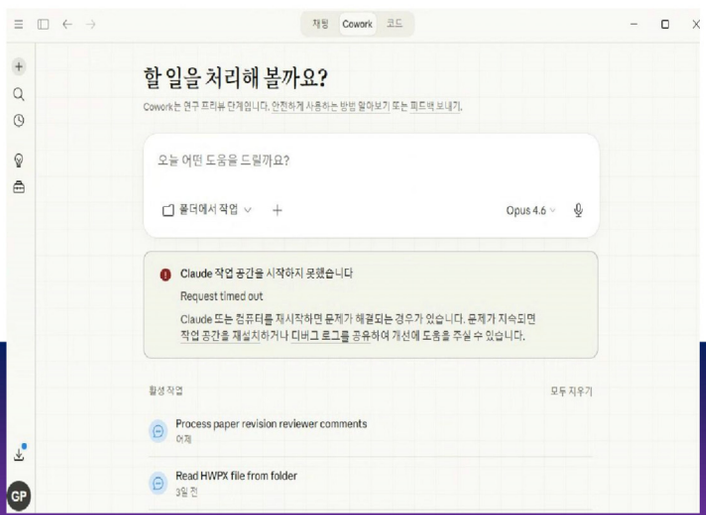

Part 4.
초안 작성 및 실전 적용
: AI를 활용한 논문 초안 작성과 품질 관리 전략


국민대학교
초안 작성 및 실전 적용
활용 도구
1
Claude Cowork 활용
클로드 Cowork를 활용해 초안을 docx로 작성
2
VS Code 활용
VS Code를 활용해 작성한 초안을 ChatGPT, Claude, Gemini 등에게 검토
LLM을 활용한 논문작성: 참고문헌 검색부터 데이터 분석까지



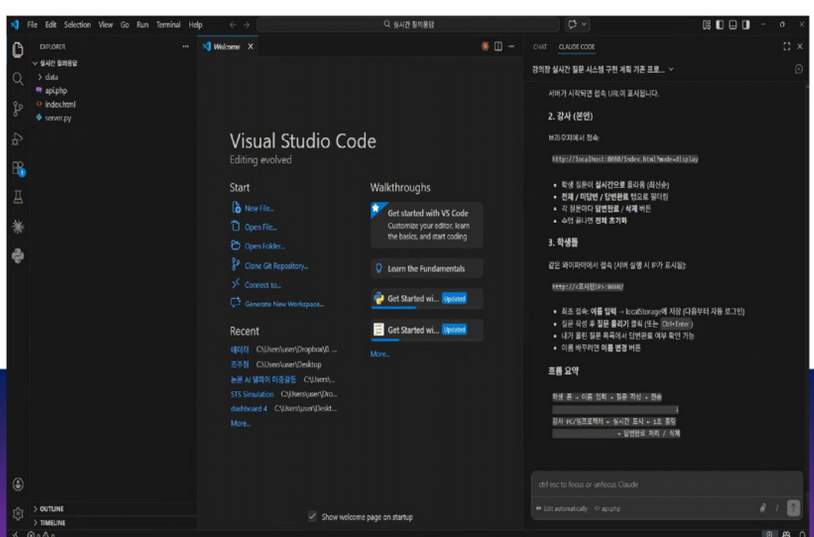
초안 작성 및 실전 적용

Claude Cowork



초안 작성 및 실전 적용

VS Code



초안 작성 및 실전 적용

초안 작성을 위한 지시 구조

AI에게 단순히 "주제에 대해 써줘"라고 하면 뻔한 내용만 나옵니다. 아래 4가지 요소를 포함한 ' 맥락 주입형 프롬프트'를 사용하세요.

요소	포함되어야 할 내용	예시 프롬프트
페르소나 (Who)	작성자의 전문성과 관점	*"너는 15년 차 전략 컨설턴트이자 경영학 박사야."*
재료 (Input)	초안의 근거가 될 데이터나 아이디어	*"내가 준 3개의 핵심 논문 요약본과 인터뷰 녹취록을 바탕으로 써줘."*
구조 (Structure)	글의 흐름과 논리 전개	*"서론-본론(3개 섹션)-결론-함축적 의미 순으로 구성해줘."*
톤앤매너 (Style)	독자와 글의 분위기	*"학술적이고 객관적인 톤을 유지하되, 문장은 간결하게 작성해줘."*

초안 작성 및 실전 적용

실패 없는 단계별 지시 전략 (Step-by-Step)

한 번에 완성본을 뽑으려 하지 말고, '점진적 구체화' 전략을 취하는 것이 결과물의 질을 압도적으로 높입니다.

① 목차(Outline)부터 승인하기

- **본문을 쓰게 하기 전, 목차를 먼저 짜게 하고 이를 수정·보완하는 과정을 반드시 거치세요.**
- *"이 주제에 대해 5개 섹션으로 구성된 상세 목차를 짜줘. 각 섹션에서 다룰 핵심 논점도 한 줄씩 포함해."*

② 섹션별 '각개격파' 지시

- **전체를 한꺼번에 쓰게 하면 뒤로 갈수록 내용이 부실해집니다. 한 섹션씩 끊어서 작성하게 하세요.**
- *"이제 1번 섹션인 '서론'만 작성해줘. 연구의 필요성을 강조하면서 최근 통계치를 인용할 자리를 표시해줘."*

③ 반복적 피드백

- **나온 결과물에 대해 "더 구체적으로", "사례를 추가해서", "문장을 더 매끄럽게"라고 추가 지시를 내립니다.**



국민대학교 BIT Graduate School of Business IT

초안 작성 및 실전 적용

작성 시 반드시 유의해야 할 점

다음 세 가지는 반드시 사람이 개입해야 합니다.

① 할루시네이션(환각) 체크

- AI는 존재하지 않는 통계나 논문을 진짜처럼 인용할 때가 있습니다. 숫자가 나오거나 특정 고유명사가 나오면 반드시 원문을 대조해야 합니다.

② 논리적 일관성 부족

- 섹션별로 따로 쓰다 보면 앞뒤 문맥이 꼬이거나 같은 말을 반복할 수 있습니다. 마지막에 전체를 읽으며 '연결 문장'을 다듬는 것은 인간의 몫입니다.

③ 고유한 통찰(Insight)의 부재

- AI는 기존 데이터를 요약하는 데는 능숙하지만, 새로운 이론적 틀을 제시하거나 독창적인 시사점을 도출하는 데는 한계가 있습니다. '결론'이나 '함축적 의미' 섹션에는 본인만의 핵심 아이디어를 직접 주입해야 합니다.

TIP!

HWP 양식 논문 작성

파일 준비

- Markdown으로 초안 작성 : 논문 내용을 .md 파일로 구조화하면 AI가 정확하게 이해
- HWP 대신 HWPX로 저장 : HWP는 바이너리라 AI가 읽기 어려움, HWPX(XML기반)로 저장해야 인식률 향상

작업 전략

- 학회 템플릿 활용 : 학회 양식 파일을 프로젝트 폴더에 넣고, 빈 곳을 채우라고 지시
- 반복 검증이 핵심 : AI 결과물을 한 번에 신뢰하지 말고, 수정 → 검증 → 재수정 반복

추천 도구

- 로컬 LLM 설치 : Ollama / LM Studio로 오픈소스 모델을 내 컴퓨터에 설치
- 양식 완벽 매칭 : Claude Co-work + VS Code + ChatGPT 조합 시 학회 양식 완벽 대응

초안 작성 및 실전 적용

리비전 레터 작성

역할 및 자료 지정

리비전 작업을 도와줘.

- 리뷰어 코멘트 : [메일내용.docx]에 있고, 각 코멘트별 답변 포인트를 내가 메모해 놓음
- 내 원고 : 같은 폴더 [revised manuscript.docx]
- 참고자료 : 이전 리비전에서 작성한 답변 샘플 (톤&형식 참고용)

멀티 에이전트 전략

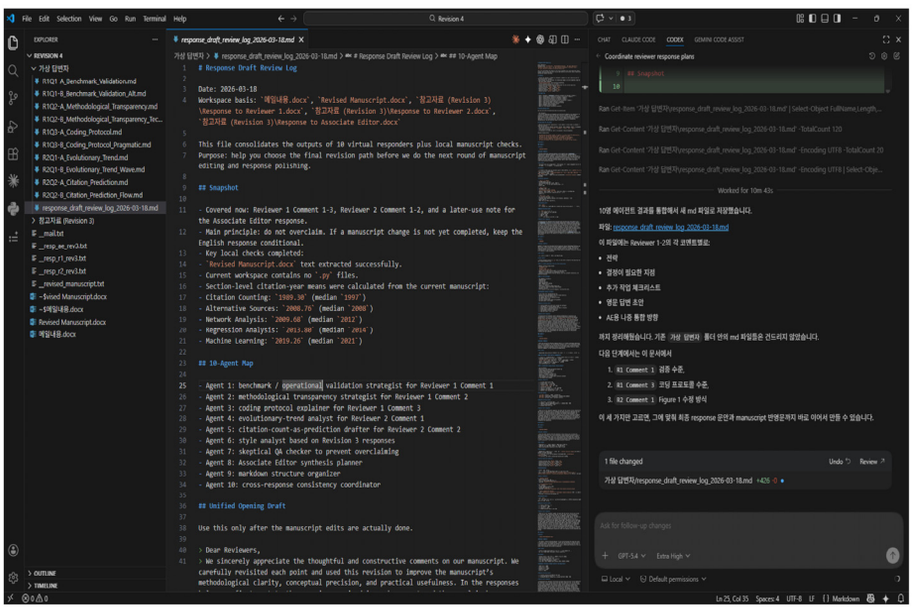
- 가상 답변자 10명을 만들어서 각 코멘트별 답변 전략을 수립하게 해
- 이어서 전략에 맞춰 답변을 작성하되, 내가 쓴 답변의 톤을 참고해서 써
- 결과물을 .md 파일로 정리해서 [가상 답변자] 폴더에 저장해 줘

후속 작업

- 여기까지만 먼저 진행하고, 이후 작업은 내가 다시 알려줄게

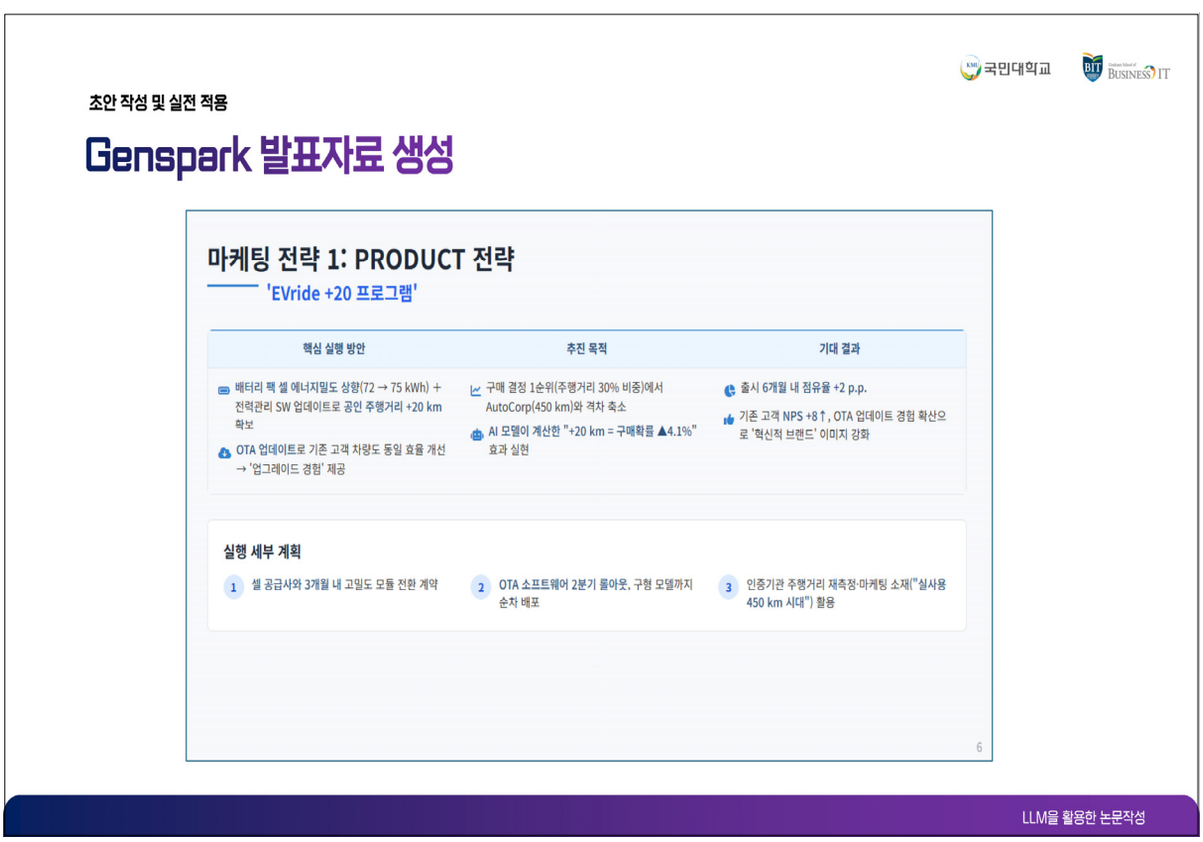
초안 작성 및 실전 적용

리비전 레터 작성



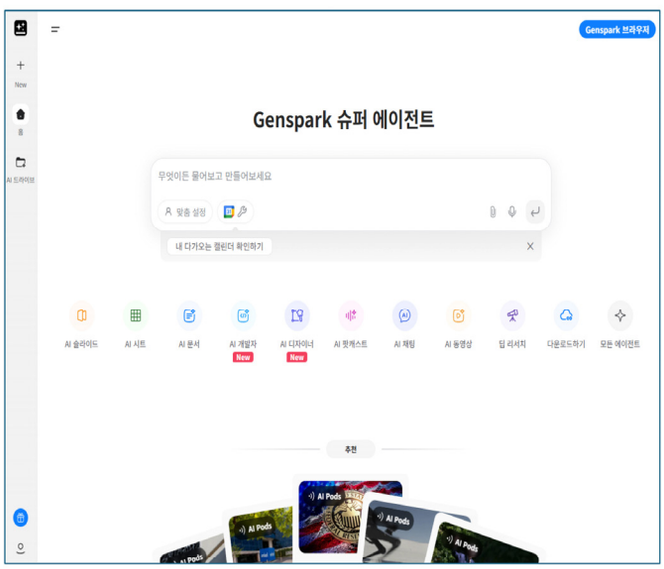
LLM을 활용한 논문작성: 참고문헌 검색부터 데이터 분석까지


Part 5.
PPT 양식 기반
강의자료 자동 생성 실습


국민대학교
초안 작성 및 실전 적용
Genspark 발표자료 생성
마케팅 전략 1: PRODUCT 전략
'EVride +20 프로그램'
핵심 실행 방안
추진 목적
기대 결과
배터리 팩 셀 에너지밀도 상향(72 → 75 kWh) + 전력관리 SW 업데이트로 공인 주행거리 +20 km 확보
OTA 업데이트로 기존 고객 차량도 동일 효율 개선 → '업그레이드 경험' 제공
구매 결정 1순위(주행거리 30% 비중)에서 AutoCorp(450 km)와 격차 축소
AI 모델이 계산한 "+20 km = 구매확률 ▲4.1%" 효과 실현
출시 6개월 내 점유율 +2 p.p.
기존 고객 NPS +8↑, OTA 업데이트 경험 확산으로 '혁신적 브랜드' 이미지 강화
실행 세부 계획
1 셀 공급사와 3개월 내 고밀도 모듈 전환 계약
2 OTA 소프트웨어 2분기 롤아웃, 구형 모델까지 순차 배포
3 인증기관 주행거리 재측정·마케팅 소재("실사용 450 km 시대") 활용
6
LLM을 활용한 논문작성

초안 작성 및 실전 적용

Genspark 발표자료 생성



초안 작성 및 실전 적용

Notebook LM 발표자료 생성

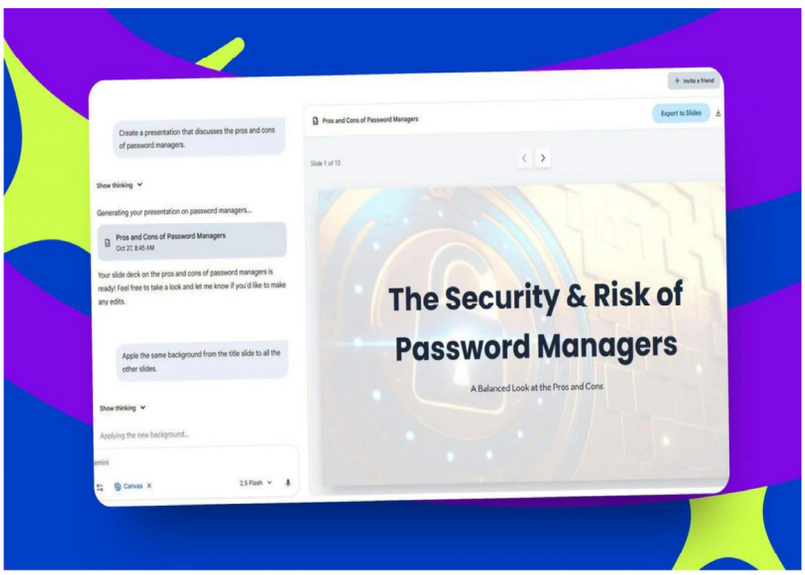




국민대학교 BIT Graduate School of Business IT

초안 작성 및 실전 적용

Gemini PPT 발표자료 생성



국민대학교 BIT Graduate School of Business IT

실습 프로젝트

VS Code로 만드는 PPTX 반복 제작 프로젝트

내 양식 그대로
기존 PPT 디자인을 규칙으로 고정해 매번 같은 톤앤매너로 생성

자료는 HWPX에서
한글 문서·PDF 양식에서 본문과 표를 추출해 슬라이드 내용으로 사용

제작 가이드 자산화
한 번 만든 가이드를 재사용해 다음 자료는 프롬프트 한 줄로 완성

STEP 1
작업 폴더 세팅

STEP 2
제작 가이드 생성

STEP 3
PPTX 자동 생성

STEP 4
다른 자료로 반복

준비물 : VS Code · Claude(또는 Gemini) 연동 · 내 PPT 양식 파일 · HWPX 원본 자료

국민대학교 BIT Graduate School of Business IT

실습 · STEP 1

VS Code에서 작업 폴더 만들고 자료 넣기

1. **File) Open Folder 로 새 폴더 생성**
   작업 폴더 하나가 곧 하나의 제작 프로젝트 (예: ppt-project)
2. **폴더 안에 자료를 모두 넣기**
   내용 원본 HWPX + 내가 쓰던 PPT 양식 파일을 함께 배치
3. **HWPX에서 내용 추출**
   본문·표·수치를 그대로 읽어 슬라이드 초안 자료로 정리
4. **한 폴더 = 하나의 맥락**
   자료가 모여 있어야 양식과 내용을 같이 참조해 생성 가능

폴더 구성 예시

```
ppt-project/
├─ source.hwpx      ← 내용 원본 (한글)
├─ template.pptx    ← 내 PPT 양식
└─ output/          ← 생성 결과
```

PDF·워드 양식도 같은 방식으로 넣으면 됩니다

국민대학교 BIT Graduate School of Business IT

실습 · STEP 2

내 양식을 뽑아 제작 가이드 만들기

프롬프트 예시

template.pptx의 디자인만 분석해서 제작 가이드(GUIDE.md)를 만들어줘.
슬라이드 크기·여백, 제목/본문 폰트와 크기, 테마 컬러 HEX,
로고와 푸터 위치, 슬라이드 유형별 구성 규칙을 표로 정리해줘.
내용은 넣지 말고 디자인 규칙만. 자료는 폴더 안 HWPX 밖으로 나가지 마.

가이드에 담기는 것

- 슬라이드 규격과 여백
- 제목·본문 폰트와 크기
- 테마 컬러 HEX 값
- 로고 · 푸터 위치
- 슬라이드 유형별 구성 규칙

산출물 : GUIDE.md
한 번 만들어 두면 이후 모든 자료가 같은 디자인으로 생성되는 기준 문서



국민대학교 BIT Graduate School of Business IT

실습 · STEP 3

가이드 + 자료로 PPTX 생성하기

프롬프트 예시

GUIDE.md 규칙을 그대로 지켜서 source.hwpx 내용으로 output.pptx를 만들어줘.

폰트·컬러·여백·푸터는 가이드 값만 사용하고 임의로 바꾸지 마.

각 장은 제목 1줄 + 핵심 3가지, 표는 원문 표 그대로, 마지막에 요약 1장.

내용은 source.hwpx 안에 있는 것만 쓰고 없는 내용은 추가하지 마.

생성 후 확인 목록

- 폰트·크기가 양식과 같은가
- 테마 컬러와 푸터가 유지됐는가
- 표·수치가 원문과 일치하는가
- 분량과 슬라이드 순서가 맞는가

수정도 프롬프트로

"3번 장 표를 두 장으로 나누고 제목은 가이드의 소제목 스타일로 바꿔줘"처럼 부분 수정 요청

국민대학교 BIT Graduate School of Business IT

실습 · STEP 4

다른 HWPX로 그대로 반복 재현하기

프롬프트 예시

폴더에 새로 넣은 report2.hwpx로 다시 만들어줘.

GUIDE.md 규칙은 그대로 유지하고 내용만 새 자료로 교체.

결과는 output/report2.pptx 로 저장해줘.

반복이 쉬워지는 이유

- 새 자료만 폴더에 추가
- 가이드는 수정하지 않음
- 디자인은 동일, 내용만 교체
- 제작 시간이 회차마다 단축

자료 교체
새 HWPX 넣기

규칙 재사용
GUIDE.md 그대로

결과 생성
같은 디자인 PPTX

한 번의 세팅이 매 학기·매 회차 반복되는 자료 제작 시간을 줄여 줍니다

국민대학교 BIT Graduate School of Business IT

Closing — 마무리

✈ AI는 '마음의 비행기'입니다 — 책임감 있는 파일럿을 위한 5계명

1. 자동화가 아닌 '협업' (Pilot-in-Command)
   → AI는 승무원일 뿐입니다. 최종 판단과 책임은 조종사인 연구자에게 있습니다.
2. 속도보다 중요한 '성찰' (Reflective Speed)
   → 압도적인 속도는 거대한 오류를 낳을 수 있습니다. 빠를수록 더 깊이 성찰하십시오.
3. 검증 가능한 '투명성' (Engineered Trust)
   → AI의 모든 결정 과정을 기록하고 감사하십시오. 신뢰는 증명에서 나옵니다.
4. 분야별 '전문성' 유지 (Domain Specialization)
   → 도구에 의존하기보다, 해당 학문의 본질과 기초 역량을 더욱 단단히 하십시오.
5. 사고의 '다양성' 확보 (Human-AI Co-evolution)
   → AI의 낯선 제안에서 영감을 얻되, 인간만의 독창적인 통찰력을 잃지 마십시오.

"기술은 도구일 뿐, 비행의 주인은 언제나 사람입니다."

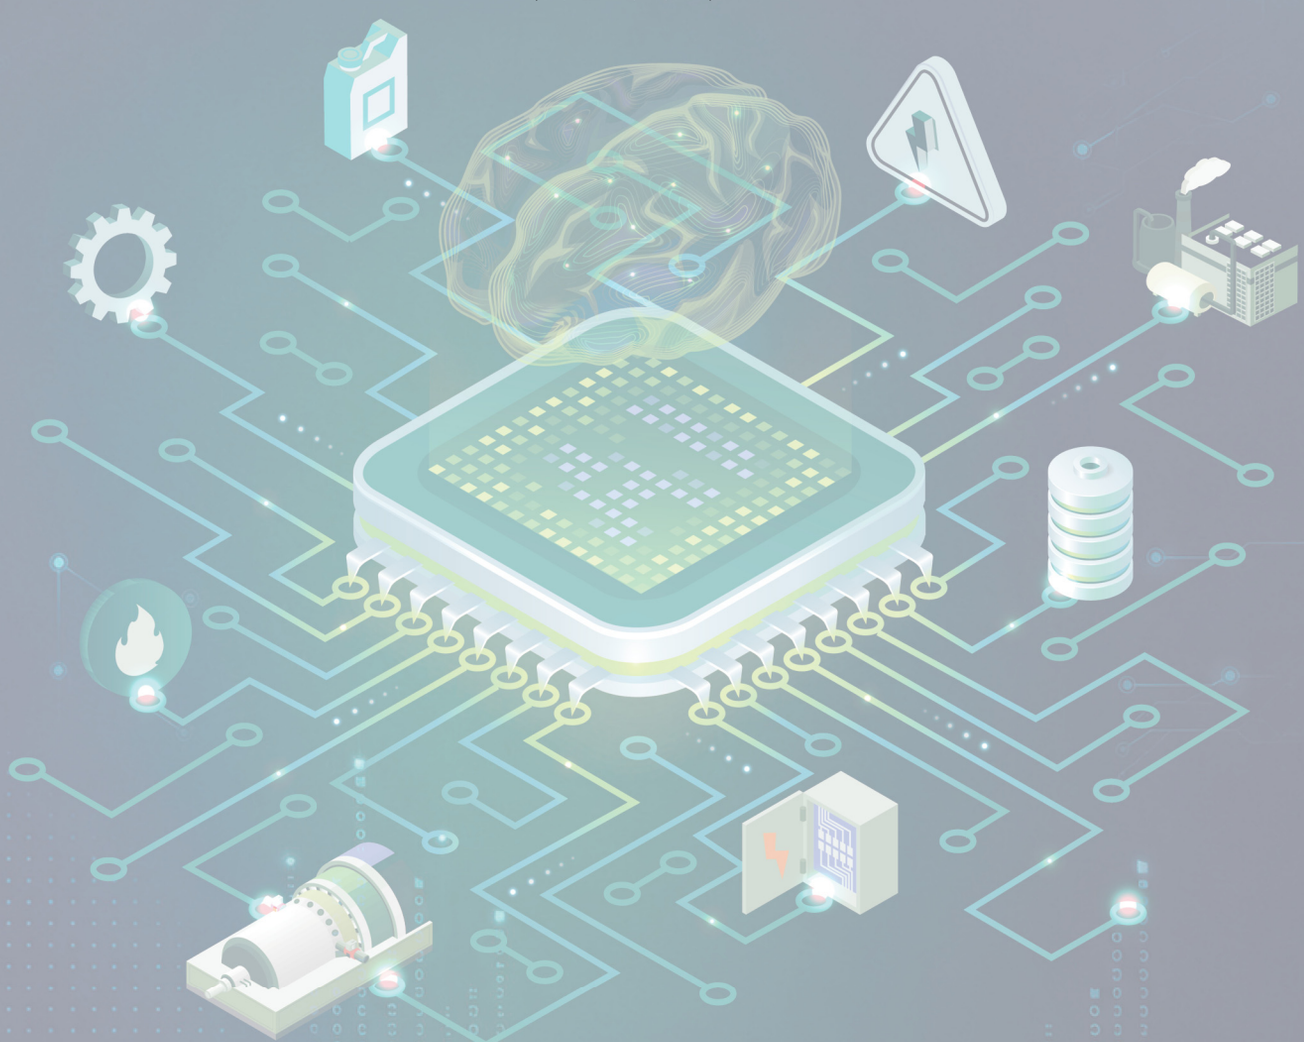
LLM을 활용한 논문작성: 참고문헌 검색부터 데이터 분석까지



Session II

AI 애플리케이션 구현을 위한 고차원 분광학의 데이터 기반 통찰

도형록 교수
(서울대학교)





Reacting Flow Laboratory
Dept. of Mechanical Engineering
Seoul National University

서울대학교 기계공학부
DEPT. OF MECHANICAL ENGINEERING
SEOUL NATIONAL UNIVERSITY

AI 기반 연소기술 특별 워크샵 2026. 8. 21.

RFL
SEOUL NATIONAL UNIVERSITY

1

RFL
Reacting Flow Laboratory

HGV

- **Hypersonic Glide Vehicle**
  - Mach 5 이상으로 활공 비행하는 무동력 활공체
    - HGV vs HCM vs BM
  - 부스터로 가속 후 분리되어 양력을 이용해 활공
    - 부스터 가속 → 분리 → 활공 → 타격



▲ 화성-8, 둥펑-17

서울대학교 기계공학부
DEPT. OF MECHANICAL ENGINEERING
SEOUL NATIONAL UNIVERSITY

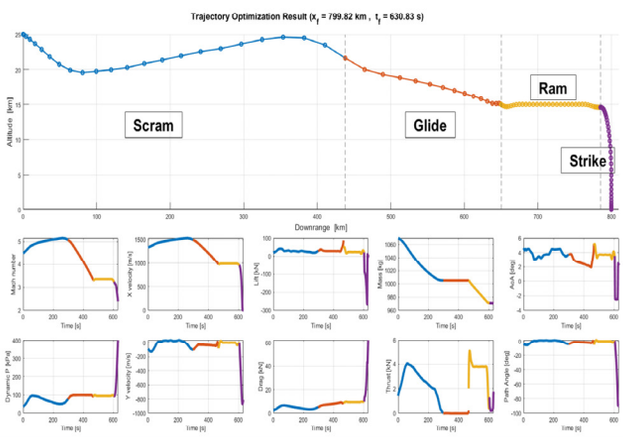
AI 기반 연소기술 특별 워크샵 2026. 8. 21.

RFL
SEOUL NATIONAL UNIVERSITY

02

Trajectory Optimization

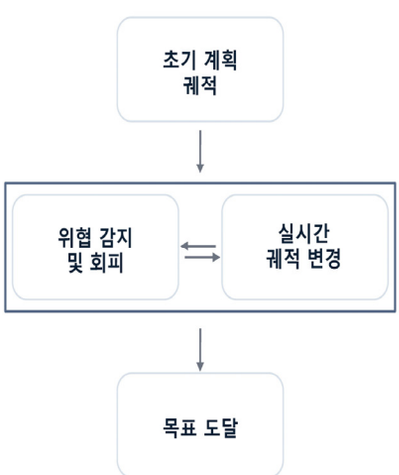
- 궤적 최적화 계산
  - 초기 상태와 제약 조건 하에서 상태·제어 변수를 최적 배분하여 주어진 목적 함수를 최소화하는 수치 기법

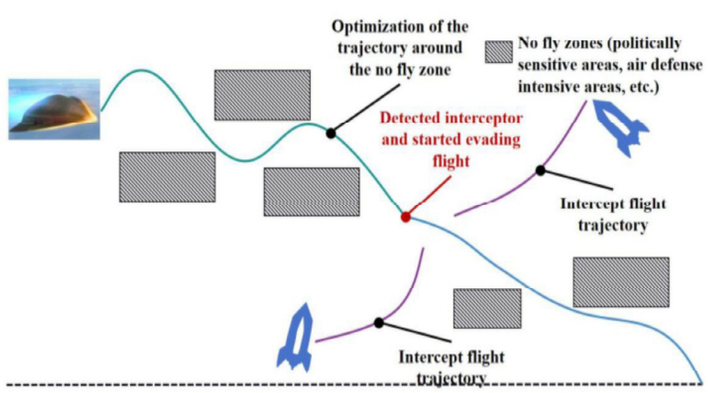


◀ 궤적 최적화 예시

실시간 궤적 변경

- 최적 궤적은 비행 중 지속적으로 변화





▲ 위협을 회피하는 극초음속 비행체 궤적



RFL

궤적 변경 원인

01

요격 미사일 회피

동적 방해

위험원 위치가 계속 변하는 이동 위협. 시간 압박이 큰 긴급 재계획.

빠른 회피 궤적 도출 필요

02

탐지망 회피

정적·준정적 방해

탐지망이 만드는 위험 영역을 예측하고 이를 회피하는 경로 재구성.

탐지 범위 내 체류 시간과 운동 에너지 손실 간 균형

03

예측모델 교란

자의적 궤적 변경

외부 장애물이 아니라 방어 측 미래 예측의 신뢰도 저하 목적.

과도한 변경에 따른 에너지·안정성 비용 검토

RFL

새 궤적이 만족해야 할 조건

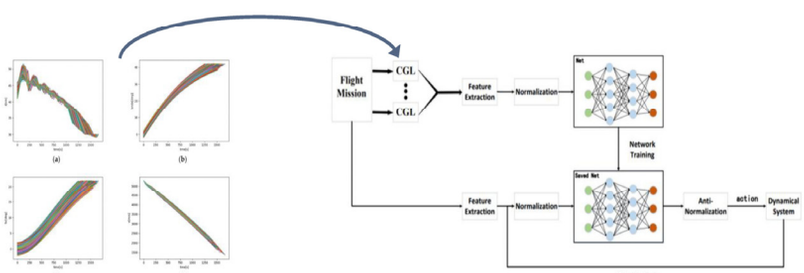
위험 감소	임무 조건	물리 제약
요격 위험 감소	기존 목적지 도달 가능성	잔여 에너지 여유
탐지·추적 노출 감소	대체 목적지 후보 적합성	열·구조 하중 한계
예측 가능성 완화	허용 시간 내 궤적 변경	제어 안정성 유지

RFL Reacting Flow Laboratory

최적 해가 존재하는 경우의 궤적 생성 AI

- **최적 궤적을 DNN이 학습하여 궤적을 즉시 예측**
  - 문제: 극초음속 비행체 재진입 궤적, 현재 상태에서 목표까지 실시간 궤적 도출

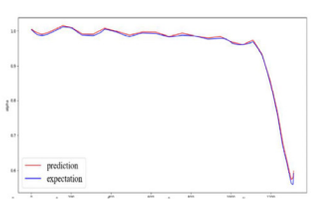




RFL Reacting Flow Laboratory

최적 해가 존재하는 경우의 궤적 생성 AI

- **DNN 궤적 예측 결과**
  - 90%의 무작위 궤적에서 0.1° 수준의 도달 지점 오차, 0.1° 수준의 제어 변수 오차 달성
  - DNN으로 궤적 생성 시 수 초 소요



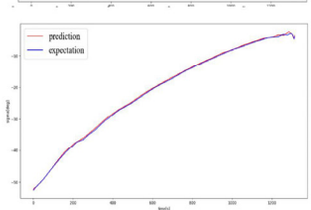


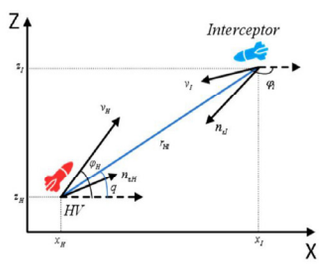
Table 4. Error statistics of Monte Carlo simulation (90 percent probability).

	The Absolute Terminal Longitude	The Absolute Terminal Latitude	The Absolute Terminal Range Angle
error (°)	0.042	0.125	0.126

최적 해가 존재하지 않는 경우의 궤적 생성 AI

- **DRL을 통해 도출한 궤적을 DNN이 학습**
  - 문제: 정면에서 다가오는 요격 미사일 회피
  - 회피 상황은 최적 궤적이 존재하지 않음 → 강화학습을 통해 바람직한 회피 궤적 생성

TD3 (DRL) 시행착오로 회피법 발명 → **몬테카를로** 다양한 초기조건 성공사례 수집 → **DNN 압축** 4차 다항식 계수 5개 → **온라인** 1 ms 회피 명령



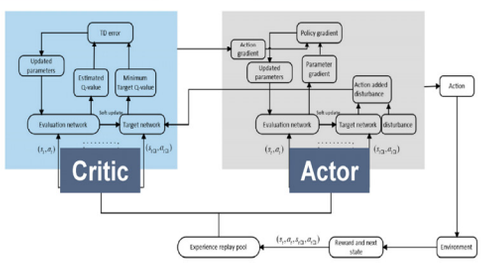


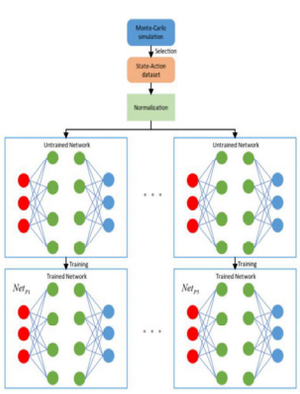
Figure 3. TD3 algorithm framework.

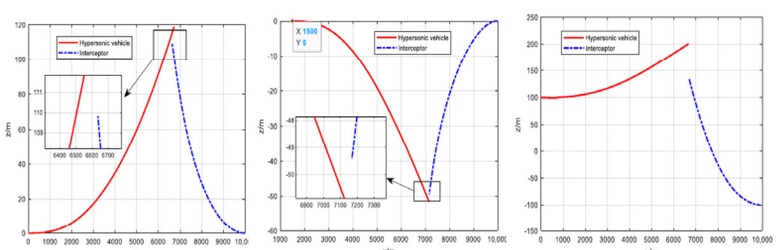
$$R = r1 + r2 + r3 + r4$$

$$\begin{cases} r1 = -c_1 e^{-\dot{q}} + 1 \\ r2 = -c_2 \Delta E \\ r3 = c_3 \log_2(R_f - 4) \\ r4 = \begin{cases} -10, & bad\_end \\ 10, & good\_end \end{cases} \end{cases}$$

최적 해가 존재하지 않는 경우의 궤적 생성 AI

- **학습된 DNN의 궤적 도출 결과**
  - 무작위 상황에서 요격 미사일과의 최소 거리 5m 상회
  - 초기 상황 입력 시 회피 명령 계산 시간 1ms 이하





RFL Reacting Flow Laboratory

최종 목표

- 난수의 위협을 실시간으로 회피하여 목표를 타격하는 HGV 미사일 시나리오 다수 생성

HGV 위협 시나리오 다수 생성

1 난수로 다양한 위협 환경을 생성

- **요격 미사일 회피** — 추격 요격기 기동 대응
- **탐지망 회피** — 레이더·센서망 우회
- **예측모델 교란** — 상대 추정 알고리즘 교란

반복

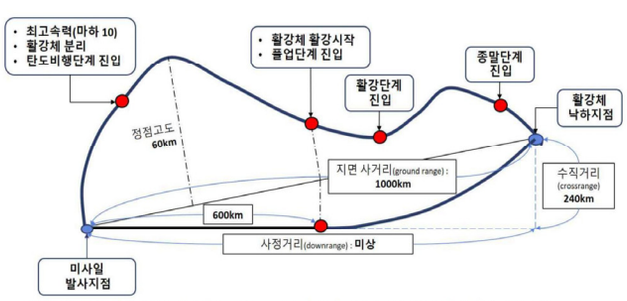
2 실시간 위협 회피 — 비행 중 회피 기동 궤적 생성

3 목표까지 실시간 궤적 생성 — 회피 이후 목표 타격 궤적 생성

RFL Reacting Flow Laboratory

AI 명령 실행의 물리적 한계 실시간 평가

- **AI에 의한 실시간 궤적 변경 명령의 물리적 실행 가능성 평가 필요**
  - 비행속도, 자세, 고도, 가속 범위 등의 물리적 제한을 실시간으로 결정하여야 함
  - 물리적 제한은 직전-현재 비행 상태의 고려가 필수적
  - 흡입구, 연소실, 노즐, 외부 공력의 실시간 모니터링이 필수적



※ 출처: 북한 극초음속미사일 시험발사(2022. 1. 11)에 대한 언론보도를 활용하여 필자가 직접 작성

<그림 2> 북한 극초음속미사일 2형 시험발사 활강궤적 개요도

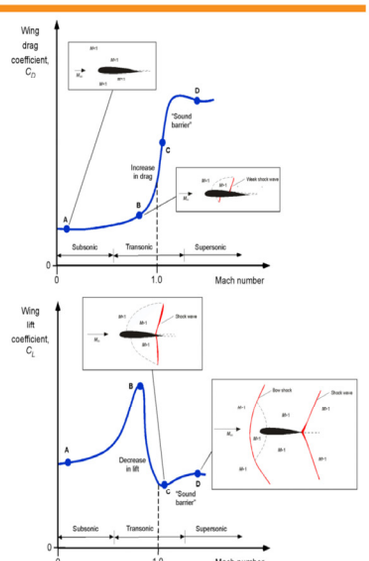
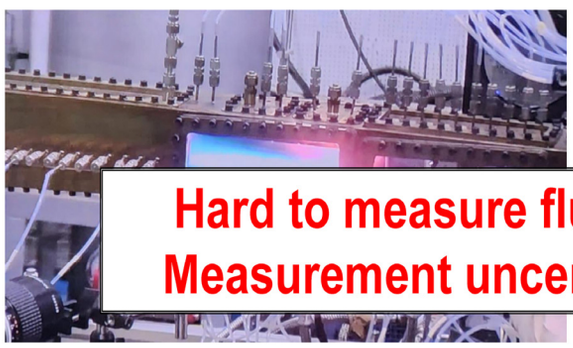


Figure 7. As transonic conditions develop, a wing experiences a rapid increase in drag and the onset of buffet.

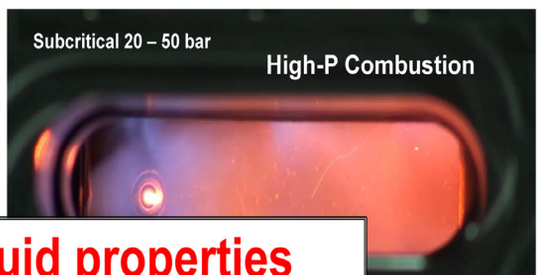
High Speed & Highly Turbulent Environment

Supersonic Kerosine Combustion (KARI & SNU)



Subcritical 20 – 50 bar

High-P Combustion



Hard to measure fluid properties
Measurement uncertainty is high!

- Intense radiation (High P + Soot)
- Fast turbulent flows
- Complex compressible flow field
- Significant refractive index distortion



Supercritical Combustion (SNU & KIER)

Production of Optical Signals

First thing to do: You need to generate an optical signal containing interested information with high enough SNR.

~~**Hard to measure fluid properties**~~
Measurement uncertainty is high!

Conc., Temp., Press.: TDLAS, FTIR

Data-Driven Method Needed!

✓ **Spontaneous Photon Emission**
- Spectrum Analysis: relatively high temperature medium
  Conc., Temp., Press.

✓ **Refractive Index Variation**
- Density Field: Schlieren, Shadowgraph
- Temp., Roughness, Distance: Interferometry

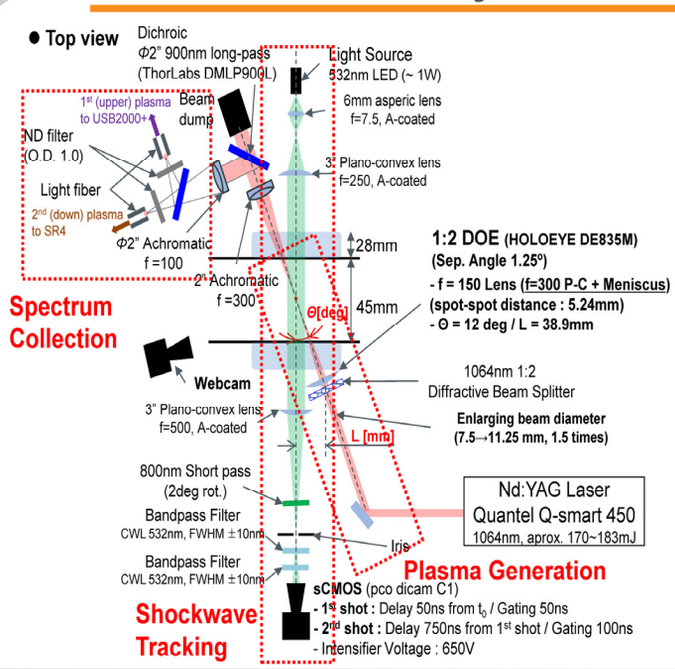
High-Speed Schlieren , Photron



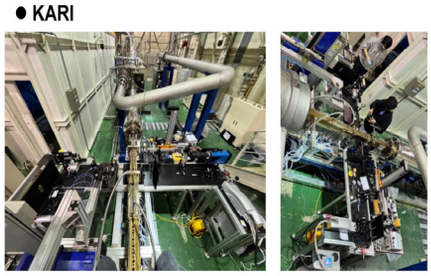
https://photron.com/wp-content/uploads/2014/04/schlieren2.jpg

There are optical signals easy to understand and post-process for extracting information of interests.

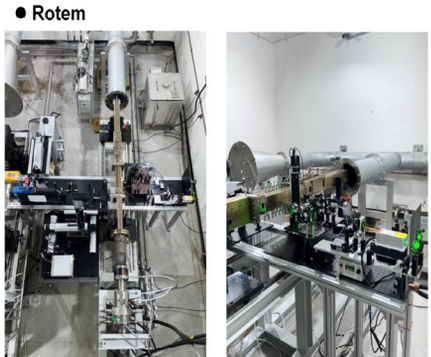
LIBS + Velocimetry



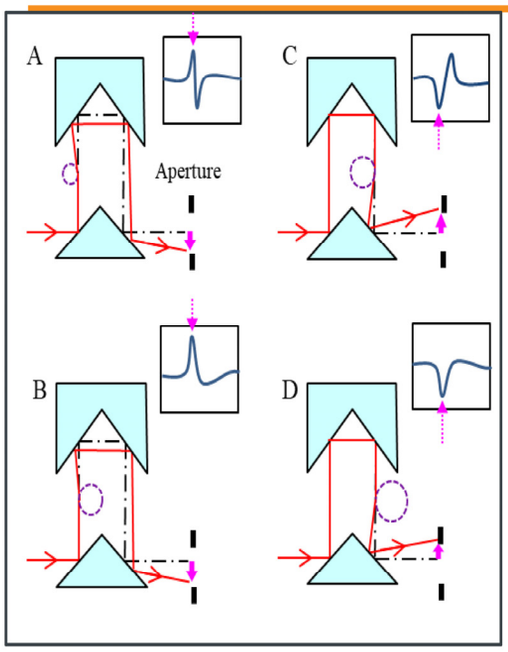
● KARI

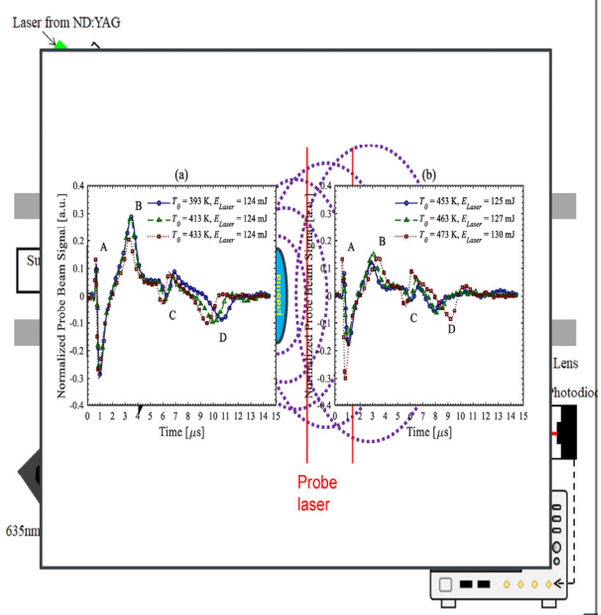


● Rotem



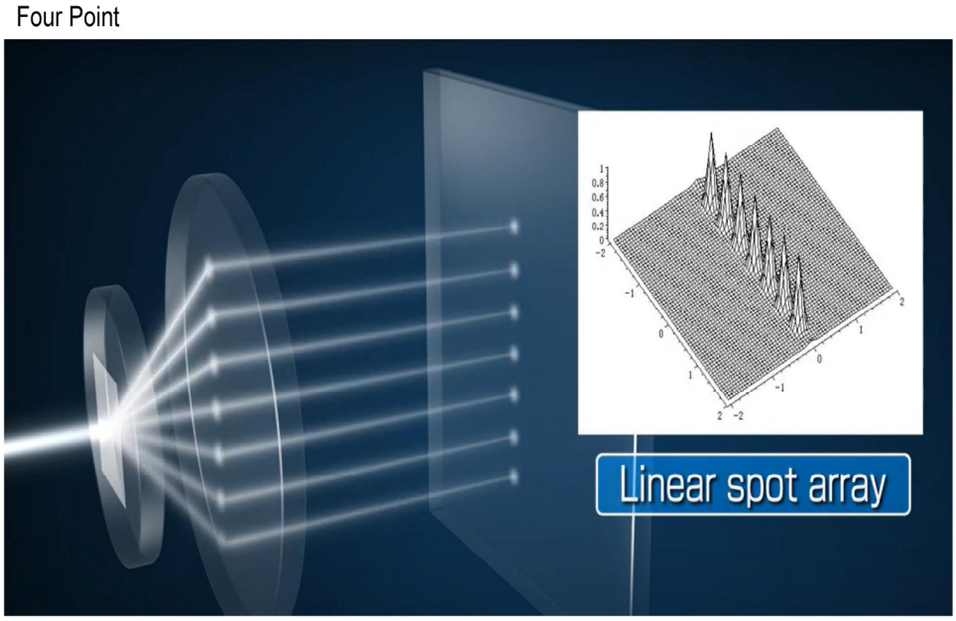
LIBS + Velocimetry





1:4 Velocimetry

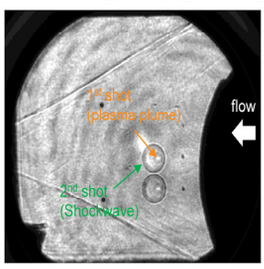
Four Point



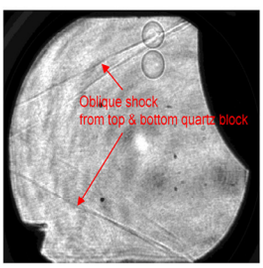
RFL Reacting Flow Laboratory

Raw data Sample

● Ma 2.0, Air + H_2O + CO_2



Core flow

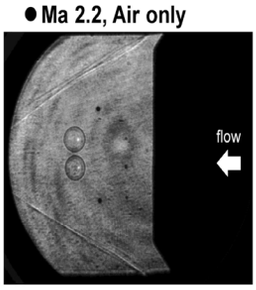


Near B.L.

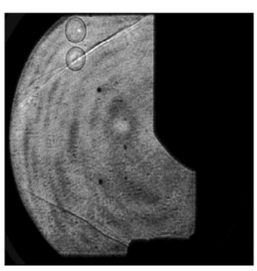
sCMOS (pco dicam C1)
- **1st shot :** Delay **50**ns from t_0
  Gating **50**ns
- **2nd shot :** Delay **750**ns from 1st shot
  Gating **100**ns
- **Intensifier Voltage :** 650V

※ Spatial resolution
- Longitudinal : 48.4 pixel/mm
- Lateral : 47.8 pixel/mm

● Ma 2.2, Air only



Core flow

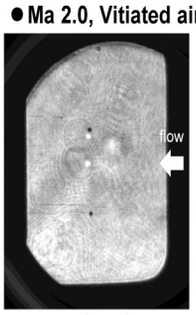


Near B.L.

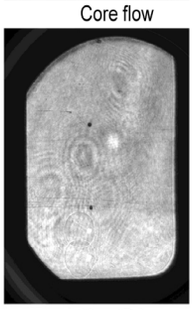
sCMOS (pco dicam C1)
- **1st shot :** Delay **50**ns from t_0
  Gating **50**ns
- **2nd shot :** Delay **750**ns from 1st shot
  Gating **100**ns
- **Intensifier Voltage :** 650V

※ Spatial resolution
- Longitudinal : 44.4 pixel/mm
- Lateral : 48.6 pixel/mm

● Ma 2.0, Vitiated air



Core flow



Near B.L.

sCMOS (pco dicam C1)
- **1st shot :** Delay **20**ns from t_0
  Gating **20**ns
- **2nd shot :** Delay **1800**ns from 1st shot
  Gating **50**ns
- **Intensifier Voltage :** 650V

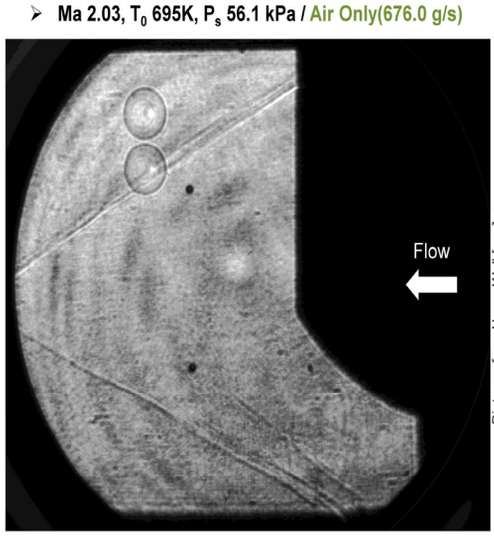
※ Spatial resolution
- Longitudinal : 47.4 pixel/mm
- Lateral : 49.2 pixel/mm

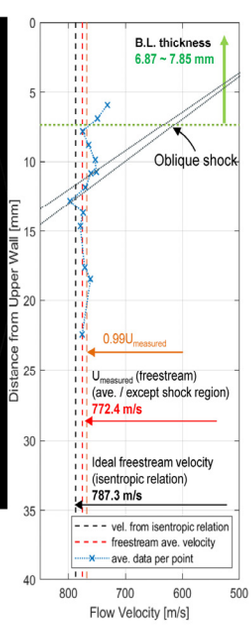
RFL Reacting Flow Laboratory

Velocimetry Result

➢ Ma 2.03, T_0 695K, P_s 56.1 kPa / Air Only(676.0 g/s)

KARI





sCMOS (pco dicam C1)
- **1st shot :** Delay 50ns from t_0
  Gating 50ns
- **2nd shot :** Delay 750ns from 1st shot
  Gating 100ns
- **Intensifier Voltage :** 650V

※ Spatial resolution
- Longitudinal : 48.4 pixel/mm
- Lateral : 47.8 pixel/mm

Femtosecond Laser

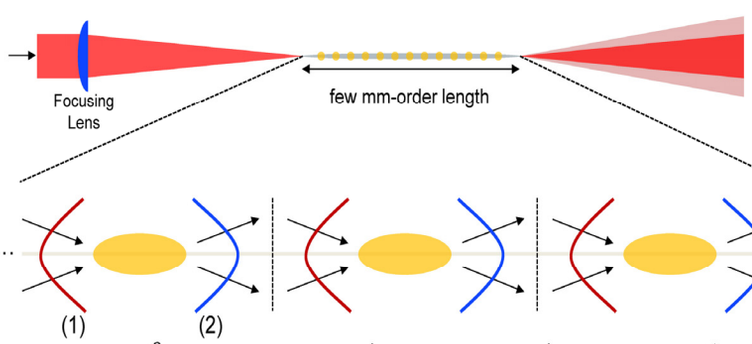
Another easy optical signal

Molecule Velocity Measurement

Femtosecond laser and focusing characteristics

Two **nonlinearities** of femtosecond laser pulse induces **"Filamentation"**.

: (1) **Kerr self-focusing** + (2) **Plasma defocusing** (ionization)



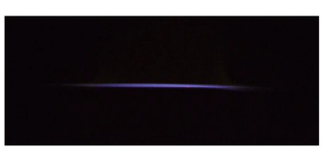


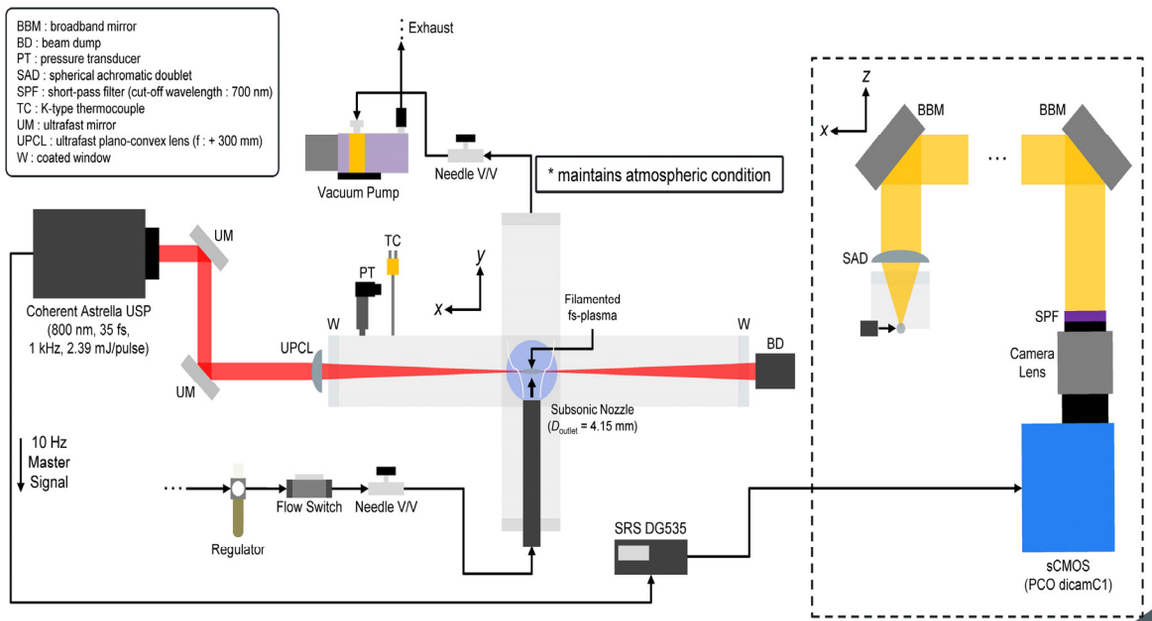
Fig. Filamentation induced by focusing 800 nm laser pulse (Astrella, ~ 35 fs, 1 kHz, 2.55 mJ/pulse, f:+300 mm thin lens, static condition)

$$P_{cr} = \frac{\alpha\lambda_0^2}{4\pi n_0 n_2} \rightarrow n = n_0 + n_2 I_L \left(\chi^{(3)} = \frac{4}{3}\varepsilon_0 c n_2 {n_0}^2\right) \rightarrow n \cong n_0 - \frac{\rho(\vec{r},t)}{\rho_c}$$

1. Power of input beam exceeds thresholds.
2. Refractive index increases near optical-axis.
3. Plasma consumes energy and energy-gained free-electrons dissipates.

α : depends on initial spatial distribution
ε_0 : permittivity at vacuum
n_0 : linear refractive index
n_2 : nonlinear refractive index

Experimental Setup



Non-gated long exposure videos

Case	D_{outlet} (mm)	Q_{outlet} (LPM)	V_{outlet} (m/s)	P_{cell} (torr)	T_{cell} (K)	γ	Ma
a	4.15	75	92.4	755	294	1.3985	0.269
b		100	123	752	294		0.358

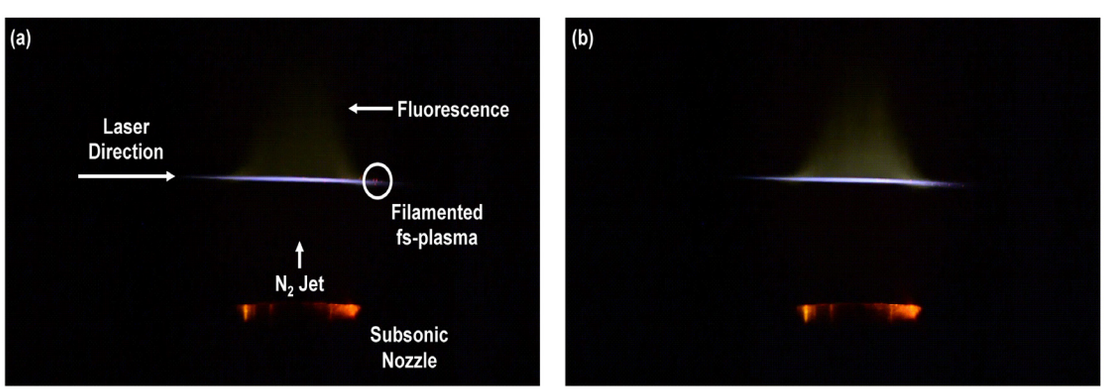


Fig. N_2 visible fluorescence generated along subsonic jet with outlet velocity (a) 92.4 m/s and (b) 123 m/s.
(Astrella, ~ 35 fs, 1 kHz, 2.39 mJ/pulse, f:+300 mm thin lens, **exposure time : 40 ms**)

Gated short exposure (500 ns) shots

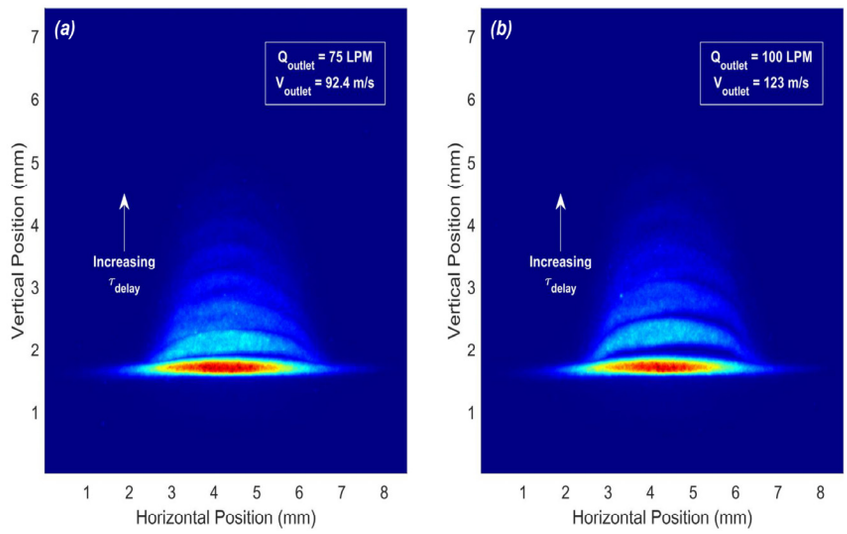


Fig. N_2 visible fluorescence generated along subsonic jet with outlet velocity (a) 92.4 m/s and (b) 123 m/s.
(Astrella, ~ 35 fs, 1 kHz, 2.39 mJ/pulse, f:+300 mm thin lens, **gate time : 500 ns**)

1D Velocimetry

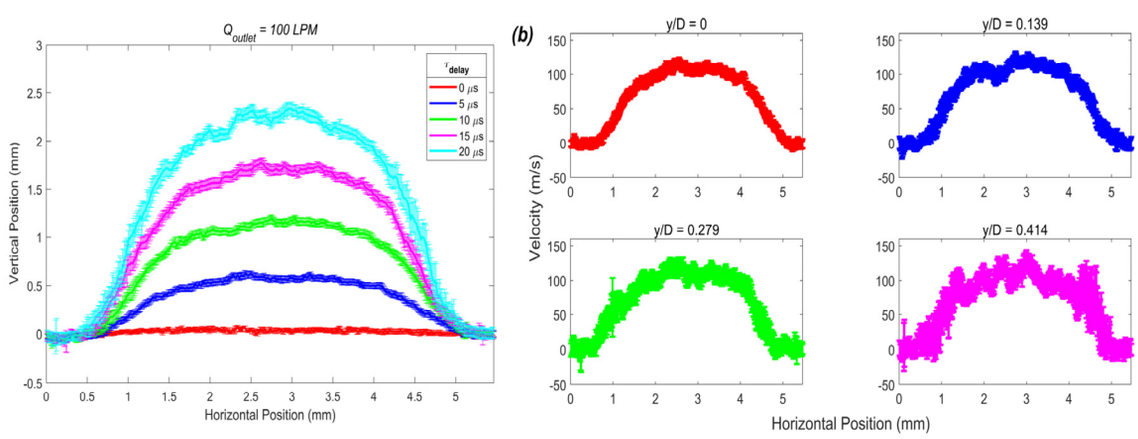
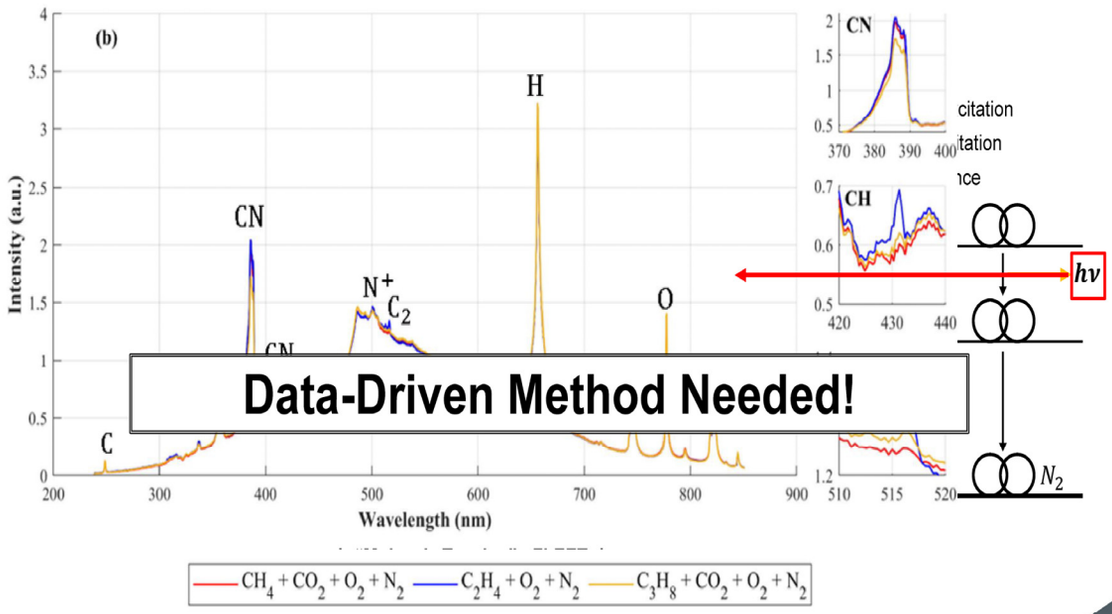


Fig. (a) Spatial displacements of the tagged N_2 as a function of gate delay time. (b) Velocity along varying positions.

Direct/Indirect Electronic Excitation



Data-driven analysis

- High-order data dimension reduction

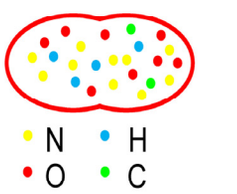


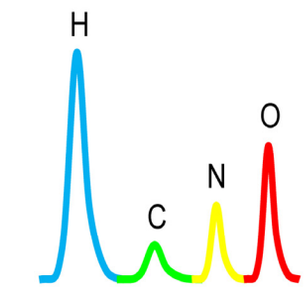
Laser-induced breakdown spectroscopy

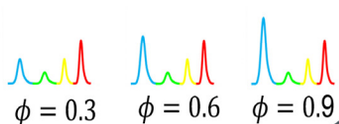
- Quantitative atom concentration measurements using ns-LIBS
- Stochastic high-energy collisions make the optical signal hard to understand



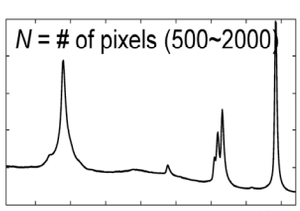
Generation of laser-induced plasma(LIP)







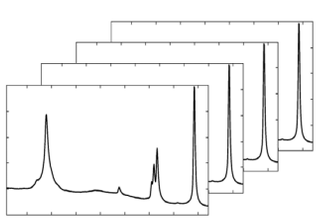
Signal dimension needs to be reduced



Test spectrum ($\in \mathbb{R}^N$)

$f: \mathbb{R}^N \rightarrow \mathbb{R}^1$

P, T, or C

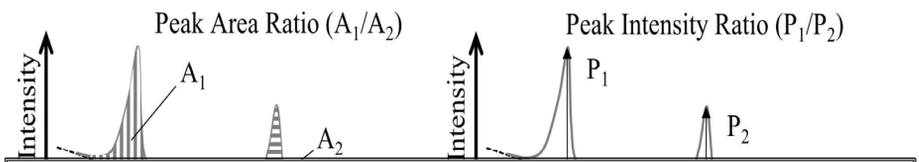


Calibration spectra ($\in \mathbb{R}^N$)

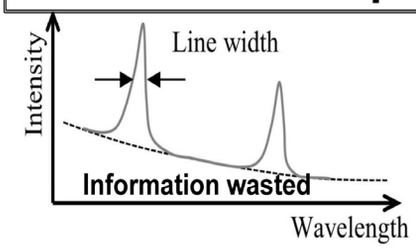
Known P, T, or C

Reducing data dimension is important for saving computational cost

Classic methods to extract information from spectrum



Wasted random-like spectral features also contain property information.



For example,

H/N ~ ϕ
Line width ~ T

Spectrum as a sum of spectrum bases

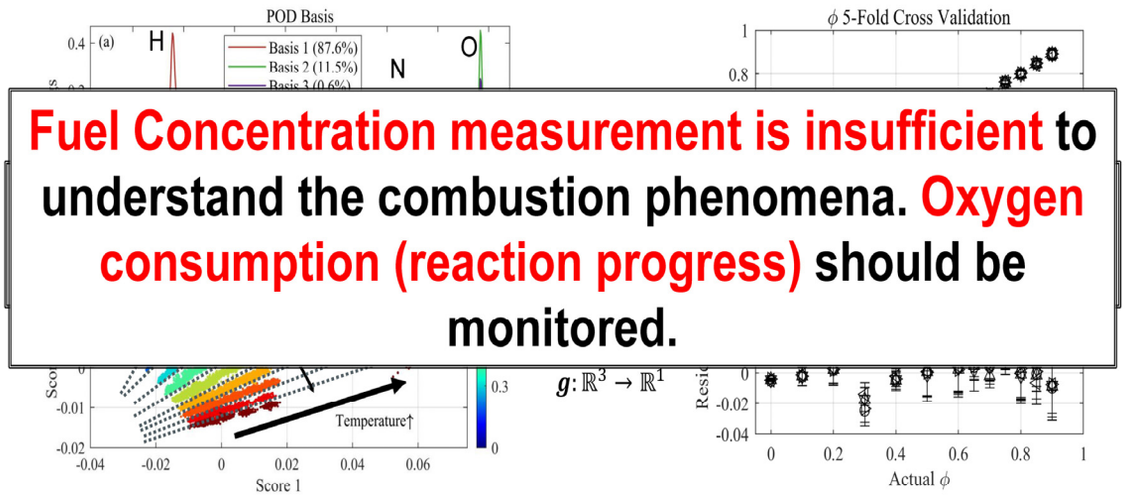
Extract using POD

POD-Bases indicate the most property-sensitive direction!
High-order basis vectors account for all the random-like features sensitive to the interested properties.

- **Objective**
- **Every part is participating**

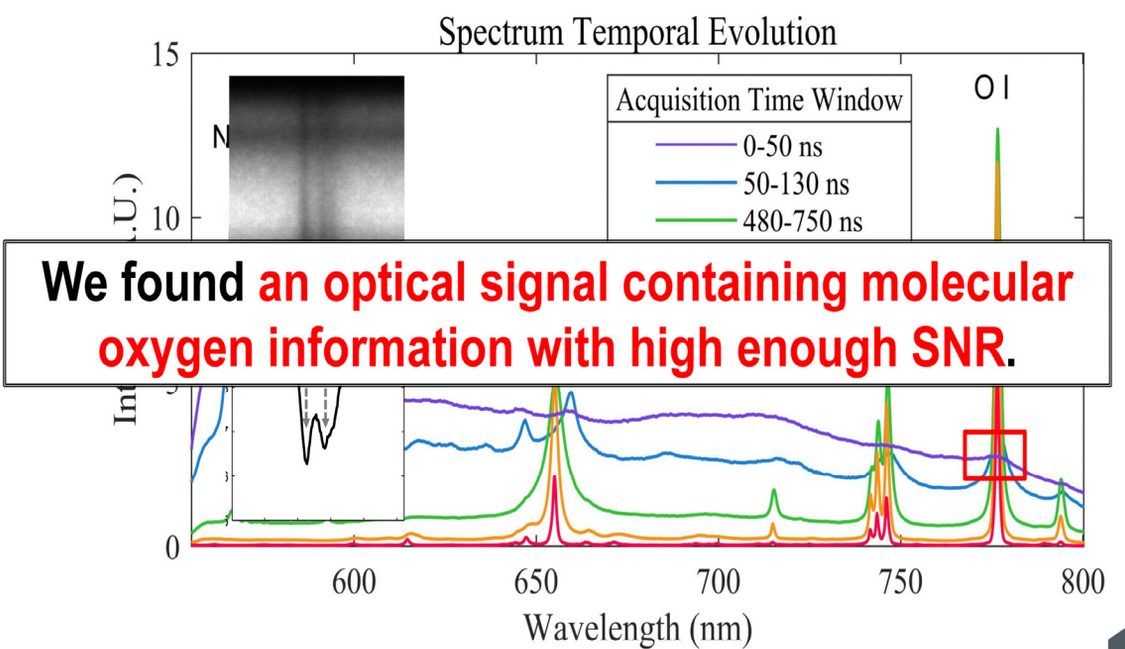
A set ($Score_1$, $Score_2$) represents a single spectrum ($\mathbb{R}^N \rightarrow \mathbb{R}^2$)

Used POD and MLR to convert spectra from USB spectrometer to ϕ



Fuel Concentration measurement is insufficient to understand the combustion phenomena. Oxygen consumption (reaction progress) should be monitored.

Absorption Spectroscopy



We found an optical signal containing molecular oxygen information with high enough SNR.

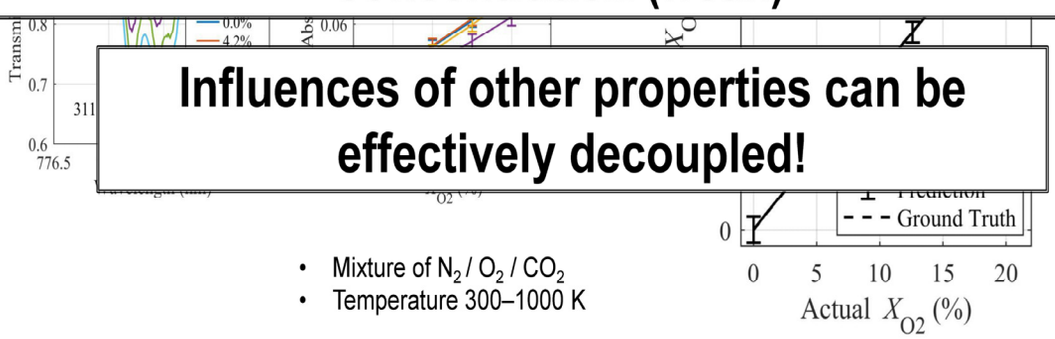
RFL

X_{O2} Measurement

- Temperature also affects the absorption lines
- Impact of two determinants, O2 conc. & Temp. were **modelled 'statistically'**

Most optical signals are dependent on multiple properties, e.g., temperature (strong), CO_2/H_2O concentration (weak)

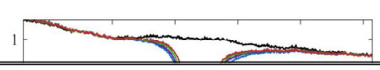
Influences of other properties can be effectively decoupled!

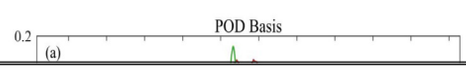


- Mixture of N_2 / O_2 / CO_2
- Temperature 300–1000 K

RFL

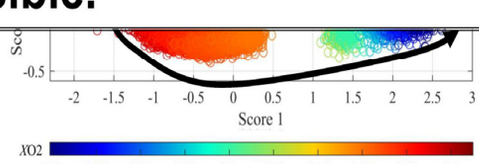
Transmittance spectra were fed to POD for X_{O2}





<u>Without the help of POD and Data-Driven Machine Learning</u>, measuring O_2 mole fraction with the significant density/temperature variations is impossible.

Transmittance spectrum = $\frac{spectrum_{mixture}}{spectrum_{N2}}$

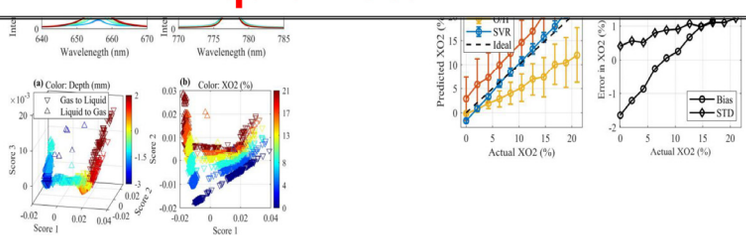


Two-Phase Fluid Measurements

- Peak area ratio analysis cannot distinguish different gas mixture ratios affected by liquid-plasma interaction.
- Proper orthogonal decomposition successfully illustrates the complicated spectrum change.



Even in two-phase flows, POD-aided ML technique works, because the model can disregard property-insensitive spectral features, e.g., interactions with liquid water.

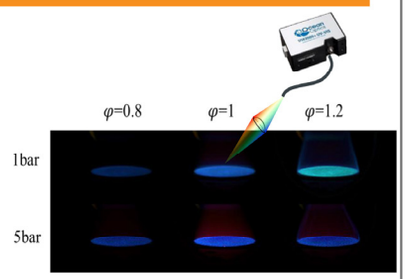


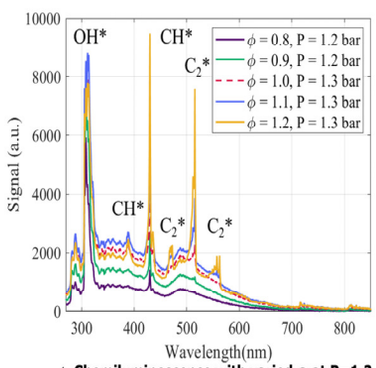
Flame Emission Spectroscopy

Concentration, Pressure, and Temperature

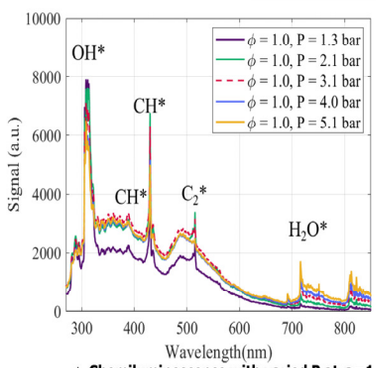
Flame Emission Spectroscopy

- Introduction
  - Flame emission (Chemiluminescence)
    - Chemiluminescence changes with the gas properties (φ, χ, P, T)
    - Intensity of emission from atoms and radicals is the function of gas properties
    - → Chemiluminescence can be calibrated to gas properties





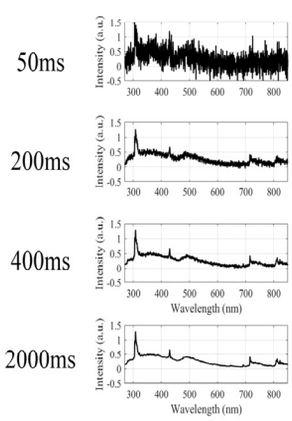
▲ Chemiluminescence with varied φ at P=1.2



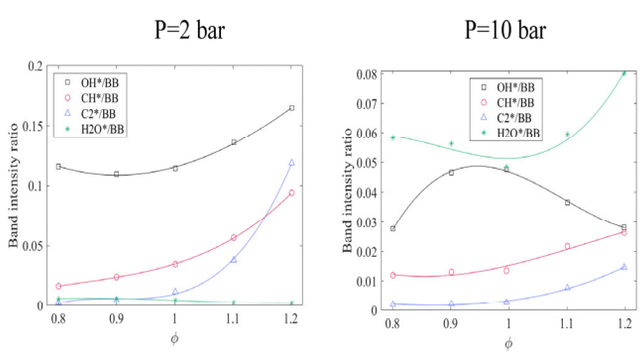
▲ Chemiluminescence with varied P at φ=1

Statistical Noise Reduction Scheme

- Introduction
  - Issues in Flame emission spectroscopy
    - Temporal resolution : signal-to-noise ratio (SNR) is too low using short exposure times
    - Accuracy : the nonlinear and non-monotonic trends of signals



▲ The signals with different exposure time (P=10 bar, φ=1)

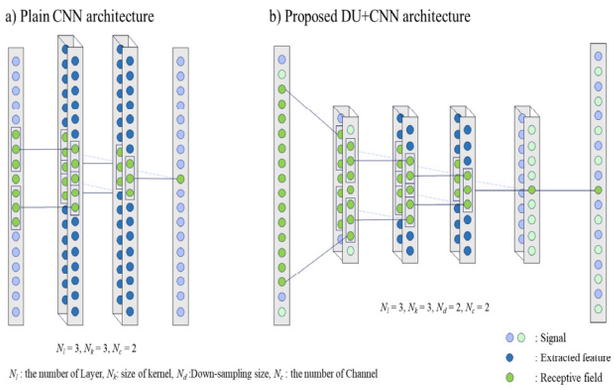


▲ Nonlinear trends of the signals

Statistical Noise Reduction Scheme

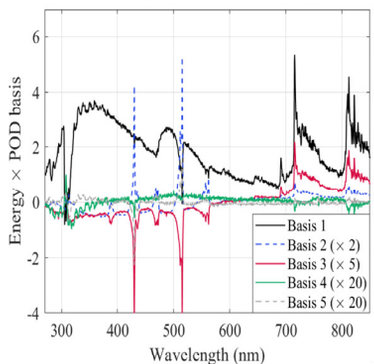
- **Exploitation of global contextual information in spectrum**

  - Neural network architecture



  - Regularization method (POD loss)

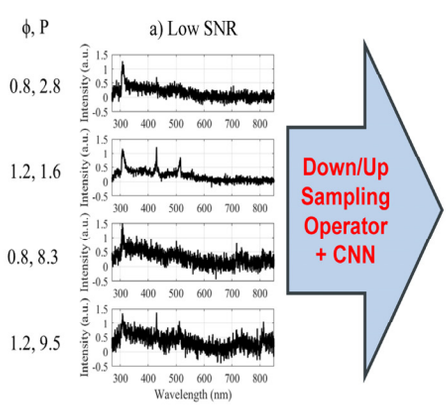
$$L = \frac{1}{N}\sum_{i=1}^{N}[(1-\alpha)\|\hat{y}_i - y_i\|_2^2 + \alpha\|\boldsymbol{POD}(\hat{y}_i) - \boldsymbol{POD}(y_i)\|_2^2]$$



Statistical Noise Reduction Scheme

- **Result**

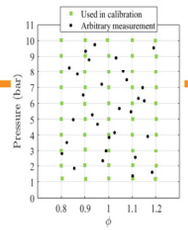
  - Trained CNN to denoise the signals (DU+CNN)



▲ Flame emission spectra captured for (a) Low-SNR (0.2 s), (b) denoised low SNR signal, and (c) 2 s High-SNR signal (2 s)

RFL Reacting Flow Laboratory

Machine Learning

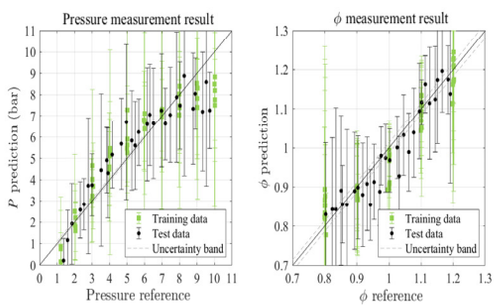


Train + Validation data

Test data

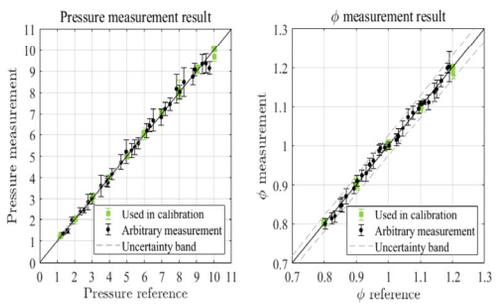
- **Result**
  - Prediction of gas properties (P, φ) using Low SNR data
    - Overall accuracy and precision are improved

Low SNR + Conventional (BI/MLR)



After Using CNN Filter

Low SNR + CNN + POD + Kriging



	Calibration error	Prediction error	Stand. Deviation
P	54%	43%	49%
ϕ	13%	11%	13%

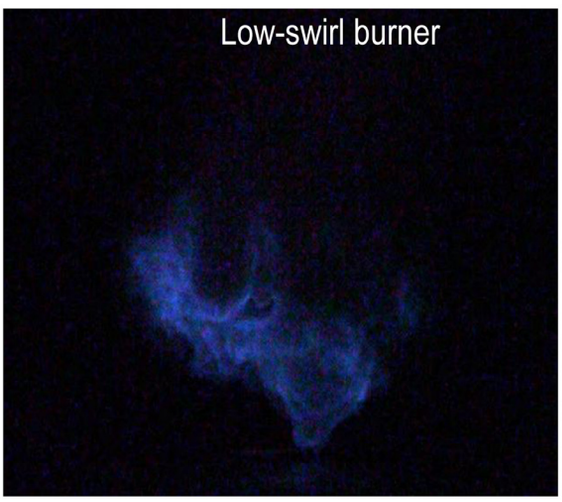
	Calibration error	Prediction error	Stand. Deviation
P	4.3%	4.7%	5.2%
ϕ	0.61%	1.4%	1.4%

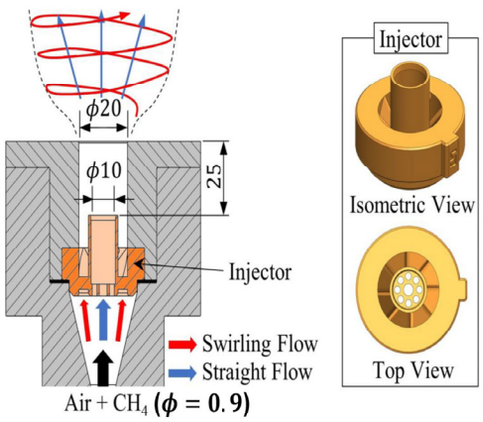
RFL Reacting Flow Laboratory

Measurements in Turbulent Flames

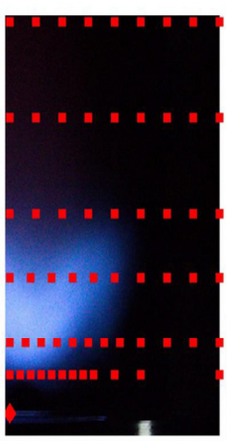
0D Quantitative Measurements: Molecular Oxygen Conc. & Reaction Progress

Low-swirl burner

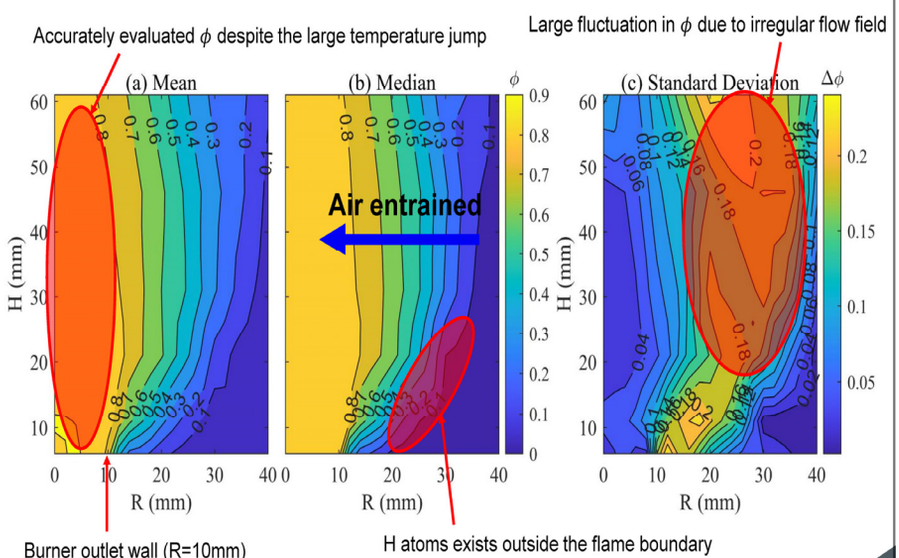




Distribution of ϕ

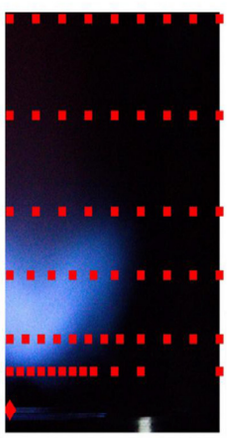


($\phi = 0.9$)



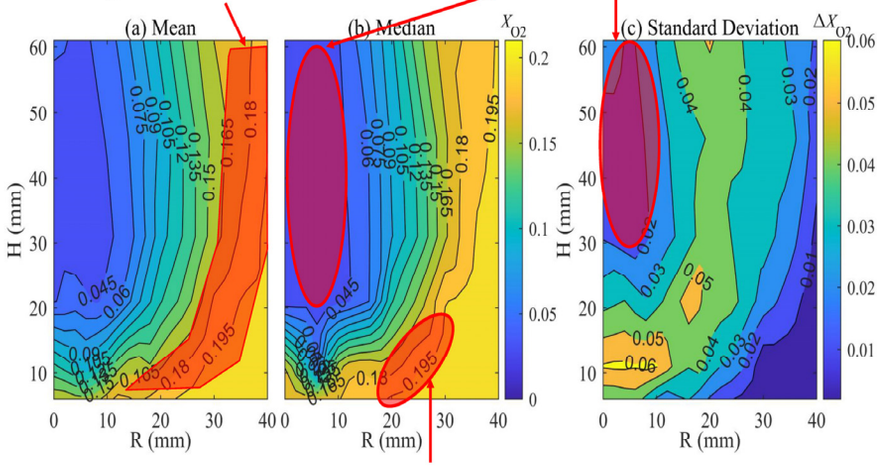
RFL

Distribution of X_{O2}



Lowered X_{02} far outside the reaction zone

Complete combustion zone is maintained in the center up to 61 mm from the burner outlet without much fluctuation



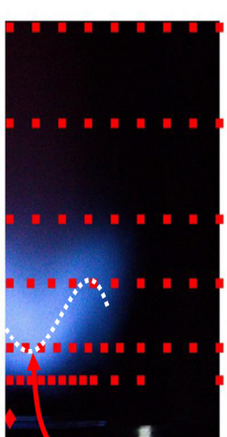
Lowered X_{02} even under the flame, hinting the product gas in the outer region of the flame

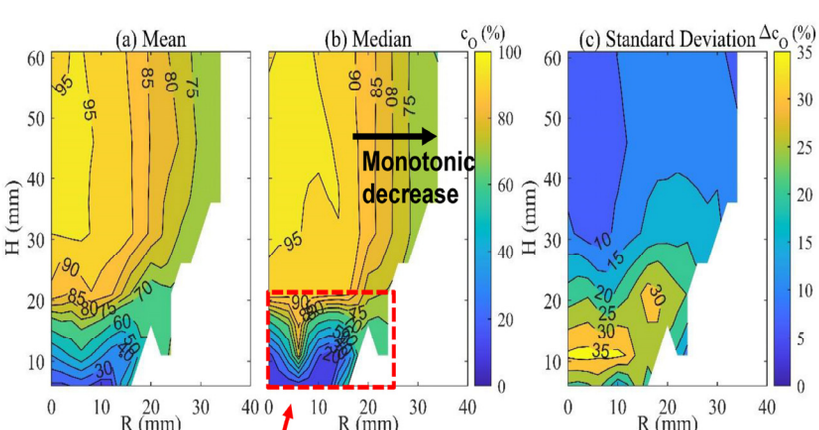
RFL

Distribution of Progress Variable

$$c_O = \frac{1}{2\phi}(2 - (9.52 + \phi)\, X_{02})$$

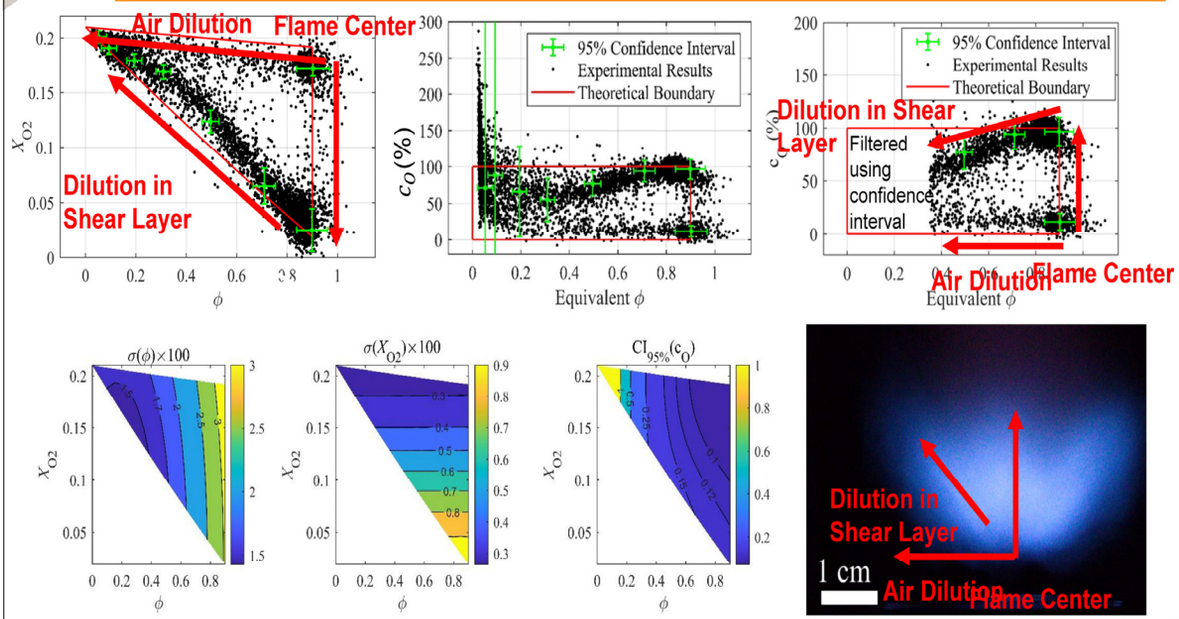
($\phi = 0.9$, $Re_D \sim 3900$)





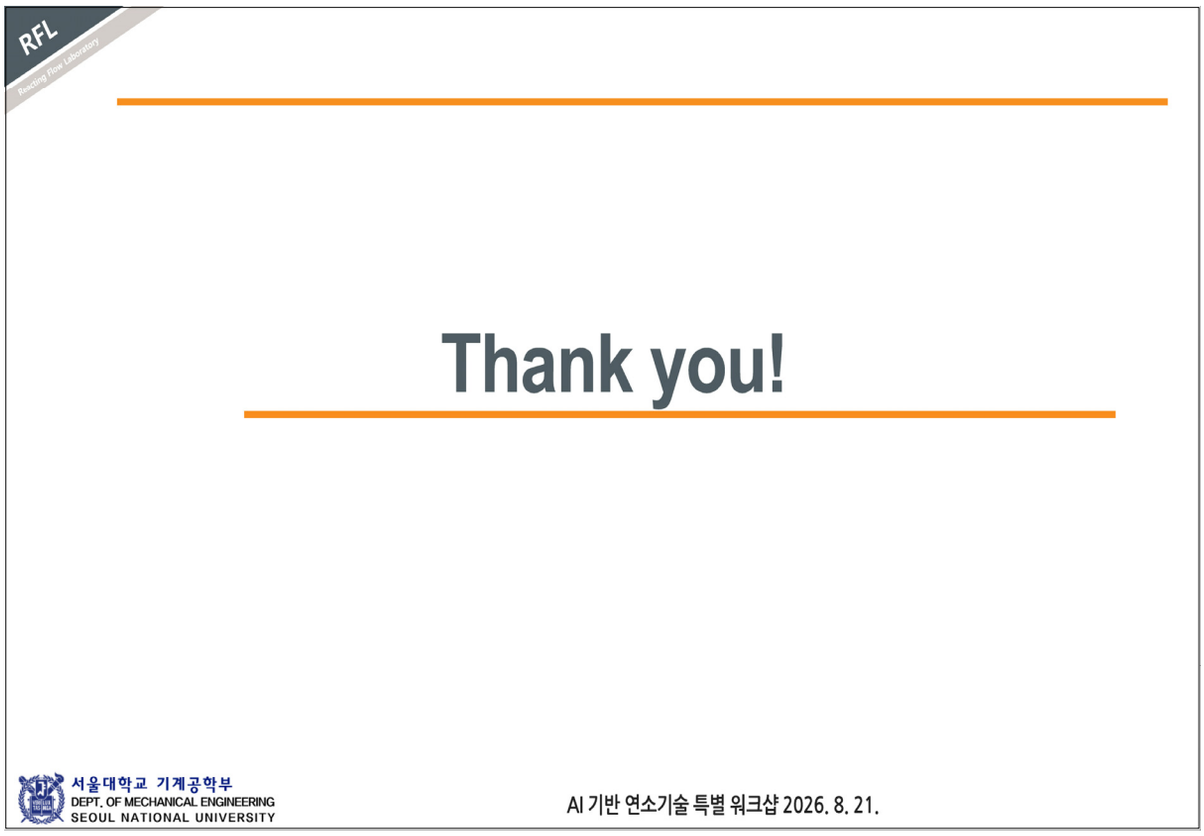
'W' shaped flame front shown in c_O map

Insight on Turbulent Combustion



Conclusion

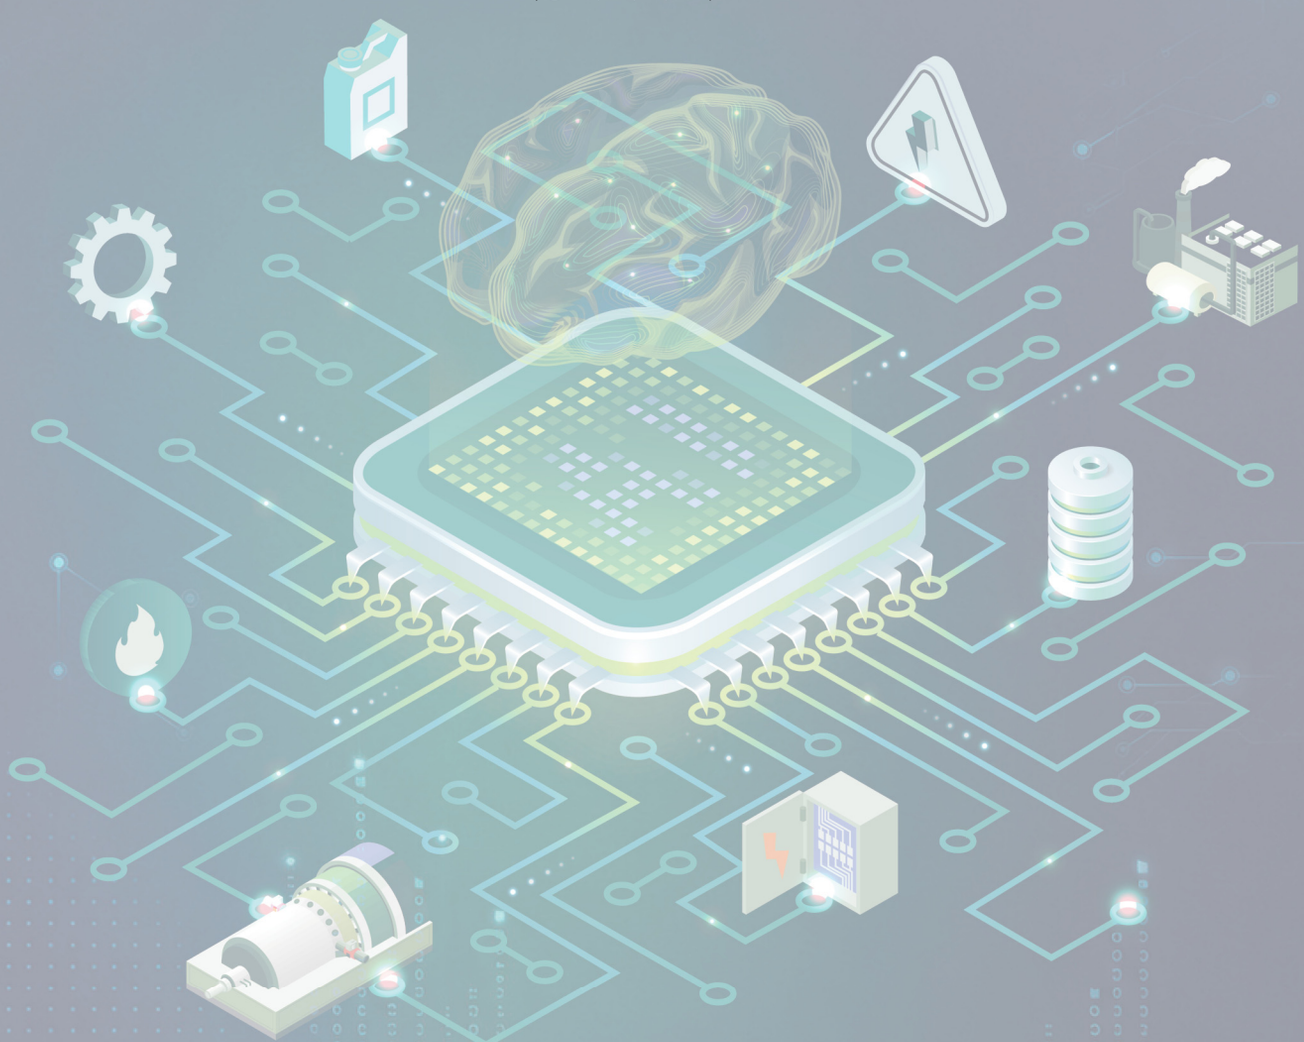
- **Data-driven analysis has opened up new possibilities for optical measurements.**
- **Hidden physical information can be extracted from complex optical signals.**
- **Calibration accuracy has been significantly improved through data-driven analysis.**
- **Laser-induced plasma can serve as a UV light source for optical measurements.**
- **The advancement in machine learning-assisted optical measurements provides new insights into turbulent combustion behavior.**


RFL
Reacting Flow Laboratory
Thank you!
서울대학교 기계공학부
DEPT. OF MECHANICAL ENGINEERING
SEOUL NATIONAL UNIVERSITY
AI 기반 연소기술 특별 워크샵 2026. 8. 21.

Session II

복잡 유동 시스템을 위한 AI-Physics 기반 구조보존 모델링

김도균 교수
(홍익대학교)



AI기반 연소기술 특별 워크샵 08/21/2026

복잡 유동 시스템을 위한 AI-Physics기반 구조보존 모델링

From Classical Simulation to Predictive Intelligence

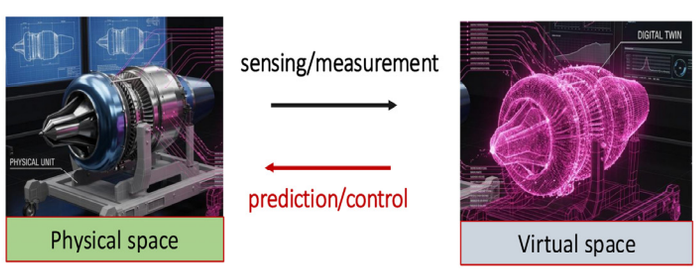
홍익대학교
기계시스템디자인공학과

김도균

What is Digital Twin?

Our Brain as an analogy: internal model + prediction + feedback

- Craik (1943): "a human mental model has a similar relation-structure to that of the process it imitates." (The nature of explanation, 1943)
- "Intelligence arises when a physical brain system mirrors the relational structure of reality."
- Karl Friston: perception itself is prediction-error minimization (active inference)



a closed loop — the twin earns its name only by closing it

Digital Twin is a **closed-loop prediction** (predictive intelligence)

What is Prediction in mathematical language?

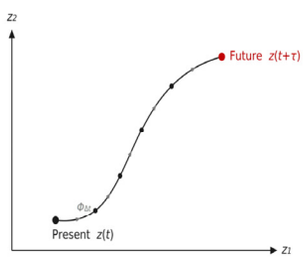
- Dynamical system:

$$\frac{d\mathbf{z}}{dt} = \mathbf{F}(\mathbf{z})$$

- Present state → Future state:

$$\mathbf{z}(t+\tau) = \Phi_\tau[\mathbf{z}(t)]$$

state: $\mathbf{z} = [\mathbf{u}, p, T, Y_1, \ldots, Y_N, \cdots]$



- Classical simulator is a dynamical system

$$\mathbf{z}_{n+1} = \Phi_{\Delta t}(\mathbf{z}_n)$$

- Autoregressive rollout to predict the future

$$\mathbf{z}_0 \rightarrow \mathbf{z}_1 \rightarrow \mathbf{z}_2 \rightarrow \cdots \rightarrow \mathbf{z}_N$$



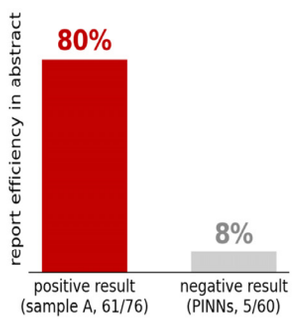
turbulent combustor is a high-dimensional dynamical system

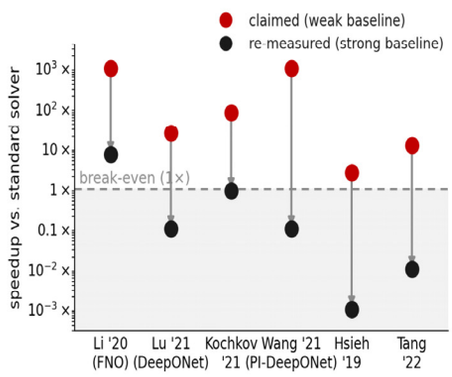
Can AI Replace the Classical Simulator?

Strategy	Formulation	What AI Learns	Advantage	Challenge
Skip simulation *PINN, DeepONet, FNO, PINO*	$z(t+\tau) \approx \widehat{\Phi}_\tau^{AI}[z(t), \mu, BC]$	full flow map	extremely fast inference	generalization / extrapolation
Imitate simulation *AI rollout model, MeshGraphNet*	$z_{n+1} = \hat{\Phi}_{\Delta t}^{AI}(z_n)$	time-step operator	learn full dynamics	instability outside trained time-window
Augment simulation *unknown closure, matrix solver*	$\frac{dz}{dt} = F_{\text{resolved}}(z) + \underbrace{F_{\text{closure}}^{AI}(z)}_{\text{unknown physics}}$	unknown physics closure correction	learn only unknown physics	What to learn? What to preserve?

The literature looks optimistic…?

- 94.8% of ML-for-PDE papers report only positive results
- 79% of papers claiming to beat numerical solvers used a weak baseline
- Natural experiment: positive results(non-PINNs) report efficiency 80% ; negative results (PINNs) 8%





McGreivy & Hakim, "Weak baselines and reporting biases lead to overoptimism in machine learning for fluid-related partial differential equations" , arXiv 2024

A Harder challenge: 3D turbulence

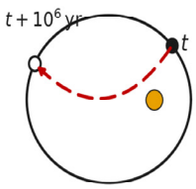
- Learned model barely outperform a trivial no change prediction (persistence) (Dai et al. 2026)
- The best model still make ~2X larger error than a spectral solver with true questions (Dai et al. 2026)
- Low pointwise error does not guarantee physical fidelity (energy spectrum) (Dai et al. 2026)
- High a priori correlation does not produce a posteriori stability (Park & Choi, JFM 2021)
- Good accuracy on trained flow failed to predict unseen flows (Rumsey & Coleman 2022)

Easy metric passes; the hidden physics fails.

Theoretical Warning: Turbulence may not be directly predicted

Flow can be a computer!

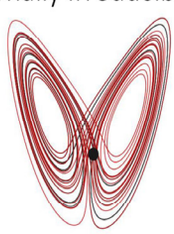
- Computationally reducible dynamics



Future can be evaluated directly

$Cost(T) \sim Cost(10^6 T)$

- Computationally irreducible dynamics



Future must be computed

$Cost(T) \ll Cost(10^6 T)$

- If flow is universal Turing Machine, there are always **undecidable questions**
- Euler flow is a universal Turing machine: Cardona et al., PNAS (2021)

✓ **Deterministic ≠ Decidable**
✓ **For turbulence, to predict is to compute (in general)**

Turbulence cannot be solved by answer-matching

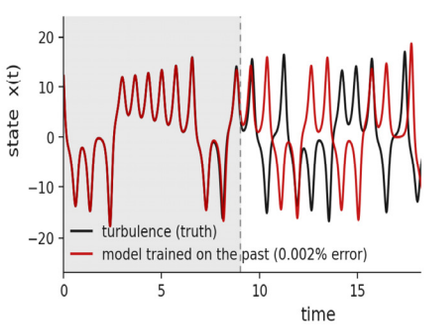
Prediction can be considered as extrapolation

- Theoretical ceiling

Direct shortcuts may not exist at all: fluid dynamics can encode universal computation.

- Training Data Covers the Past , not the future

$$\underbrace{z_0 \to z_1 \to z_2 \to \cdots \to z_N}_{\text{DNS / training data}} \to \hat{z}_{N+1} \to \hat{z}_{N+2} \to \cdots$$



- Chaos amplifies Tiny Errors

Proxy ≠ Reality

A-priori accuracy is only a proxy. Prediction is judged a-posteriori.



End of the Age of Scaling: Toward General AI

Reward Hacking
beats the benchmark,
misses the usefulness
(= easy metric passes,
hidden physics fails)

Hallucination
plausible answers,
never graded by the world
(= a-priori fit,
a-posteriori divergence)

Imitation Ceiling
human data runs out;
mimicry cannot surpass
(= training data covers
the past, not the future extrapolation)

The failures we saw in turbulence — now appearing in general AI.



Age of Experience

Richard S. Sutton

MISSING	**experience** — the right kind of data
STRATEGY	self-play + grounded reward: the world itself grades
LESSON	the **Bitter** Lesson: built-in knowledge loses



Age of Research

Ilya Sutskever

MISSING	**ideas** — the mechanism of generalization
STRATEGY	internal structure & value function: beauty, simplicity, symmetry
LESSON	the **BitterSweet** Lesson: structure is the mechanism

One says: remove priors, add experience. The other: experience is not enough — add structure.

Our Strategy: Closed-Loop Predictive Intelligence

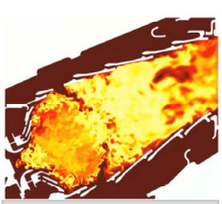


Physical space

the world that grades

sensing / grounded reward

prediction / control



Digital Twin

GPU-resident LES + AI layer

Learn experience from the simulator

- Learn from rollout experience, not answer labels — physics grades *a-posteriori*: energy budget, spectra, circulation
- Simulation is not optional — turbulence is irreducible: to experience the future is to compute it

Preserve the structure and learn unknown physics

- Preserve structure by construction — conservation, symmetry (DEC):
- Use internal value function as directional guidance
- Not learning the data pointwise, learn the way the information transfer

Learn from experience. Preserve structure. Let reality grades

What must be preserved? What should be learned?

- **What to preserve?**

Structures

- Information Topology
- Operation Topology
- Symmetry/equivariance
- Physical laws

Reduce admissible function space

- **What to learn?**

Uncertainties

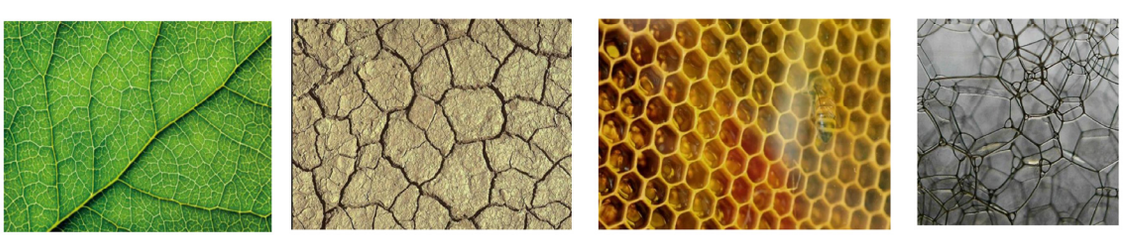
- Discretization
- Dynamics/Physics
- Constitutive relations
- Subgrid closure
- Causality
- Fidelity

To enhace extrapolation, increase linear algorithm alignment

Hard-code what physics already knows; learn only the unresolved degrees of freedom.

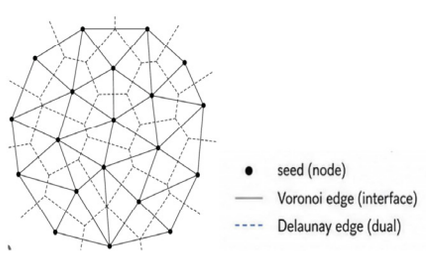
How should information flow through the Network?

- how to design topological structure of information transfer?
- A recurring pattern in nature and a useful computational structure



Voronoi patterns in Nature

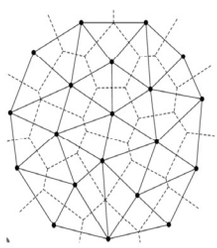
- Voronoi diagram:
  - Convex cells
  - Natural control volumes and local neighborhoods
  - Orthogonal primal-dual pairing
  - Reduced coordinate-induced bias



Voronoi Structure for both LES and AI-Physics

LES solver

- cell — control volume
- face flux — across interface
- divergence — (co-differential)
- conservation — update



AI-Physics (VNN)

- node state — feature at node
- edge message — along interface
- aggregation — at node
- learned — correction

LES computation:	AI-Physics:
• control volume update	• message passing on edges
• flux across faces	• closure / SGS inference
• exact conservation	• uncertainty-aware correction

LES:

$$\frac{dq}{dt} = -\mathbf{B}f$$

TNN:

$$h_i^{n+1} = \psi\left(h_i^n, \sum_j m_{ij}\right)$$

In AI-Physics, messages should represent physically meaningful flux transfer.

Neural messages should live on the same topological geometry as physical fluxes.

Coordinate-free Differential Operators as Built-in Physics

- Nature does not come with a coordinate system.
- Fluid quantities can be represented as differential forms on topological geometry
  - Differential describe circulation, flux, and volumetric measure more naturally than coordinate-dependent vectors.
  - Stokes theorem and $d^2=0$ enforce exact compatibility between grad, curl and div.

$$p \in \Omega^0, \qquad u^\flat \in \Omega^1, \qquad \omega = du^\flat \in \Omega^2, \qquad \mathcal{E}\, dV \in \Omega^3$$

$$\int_{\partial\Omega} \omega = \int_{\Omega} d\omega \qquad d^2 = 0$$

$$\mathcal{L}_v\omega = d(i_v\omega) + i_v(d\omega)$$

Coordinate-free representation

$\Longleftrightarrow$

$$\nabla \times (\nabla f) = 0 \qquad \int_{\partial V} \mathbf{A} \cdot d\mathbf{S} = \int_V \nabla \cdot \mathbf{A}\, dV$$

$$\nabla \cdot (\nabla \times \mathbf{A}) = 0 \qquad \oint_{\partial S} \mathbf{A} \cdot d\mathbf{r} = \int_S (\nabla \times \mathbf{A}) \cdot d\mathbf{S}$$

$$\mathcal{L}_v\mathbf{A} = \nabla(\mathbf{v} \cdot \mathbf{A}) + (\nabla \times \mathbf{A}) \times \mathbf{v}$$

Coordinate-dependent representation

Encode differential identities by constructing rather than rediscovering from data

Learn Advection Operator with preserving Kinetic Energy

- Discrete conservation law

$$V_j \frac{d\phi_j^i}{dt} + \sum_k 2d_{jk} F^i(\phi_j, \phi_k) = 0$$

- Kinetic Energy conservation is enforced by constructing the discrete advection operator to be skew-symmetric
- Learn the remaining degrees of freedom required for ≥2nd-order consistency and accuracy.
- Voronoi Neural Network is a proper structure to enforce the energy-preserving structure and optimize the operator

Learn conservative fluxes with enforcing the Entropy law

Hyperbolic conservation law

$$\frac{\partial \phi_i}{\partial t} + \frac{\partial f_i(\phi)}{\partial x} = 0$$

$$f_i = \begin{bmatrix} \rho u \\ \rho u^2 + p \\ (\rho E + p)u \end{bmatrix}$$

+ dot product

entropy variable

$$v_i = \frac{\partial \rho s}{\partial \phi_i}$$

$$v = \begin{bmatrix} s + \frac{u^2}{2T} \\ \frac{u}{T} \\ \frac{1}{T} \end{bmatrix}$$

➡

Entropy conservation law

$$\frac{\partial \rho s}{\partial t} + \frac{\partial G}{\partial x} = 0$$

Global Entropy conservation

➡ $$\frac{d\int_\Omega \rho s \, dV}{dt} = 0$$

Discrete conservation law

$$\frac{d\phi_j^i}{dt} + \sum_k 2d_{jk} F^i(\phi_j, \phi_k) = 0$$

➡

Discrete Entropy conservation law

$$\frac{d\rho_j s_j}{dt} + \sum_k d_{jk} \left(v_j^i - v_k^i\right) F^i(\phi_j, \phi_k) = 0$$

⬇

Global Entropy conservation

$$\sum_j \sum_k d_{jk} \left(v_j^i - v_k^i\right) F^i(\phi_j, \phi_k) = 0$$

⬅

(weak) discrete Entropy condition

$$\left(v_j^i - v_k^i\right) F^i(\phi_j, \phi_k) = \Psi_j - \Psi_k$$

$d_{jk} = -d_{kj}$ skew-symmetric



Entropy-preserving Flux Formulations

- Entropy-conserving Flux and Entropy-source term

Discrete Flux : $F_i = F_i^c + F_i^d = F_i^c + P_{ij}\frac{\partial \psi_j}{\partial x}$ $\quad \Lambda_{ij} = P_{ik}\frac{\partial \psi_k}{\partial v_j}$ positive semi-definite in order to satisfy entropy principle

- Discrete Helmholtz free energy of the 2-phase interface

$$f(T,\rho,Y_i,\nabla Y_i) = f_m(T,\rho,Y_i) + f_{nl}(T,\nabla Y_i) = f_m + \kappa_f Y_l^2(1-Y_l^2) + \lambda_f|\nabla Y_l|^2$$

- Entropy-source flux term at the phase interface

$$F^d_{\rho Y_k} = C_k(|u|+\bar{c})\bar{\alpha}_k\Delta\rho_k$$

$$F^d_{\rho u} = \bar{u}^i\sum_k F^d_{\rho Y_k} + \Delta u^i(|u|+\bar{c})\sum_k C_k\overline{\rho Y_k}$$

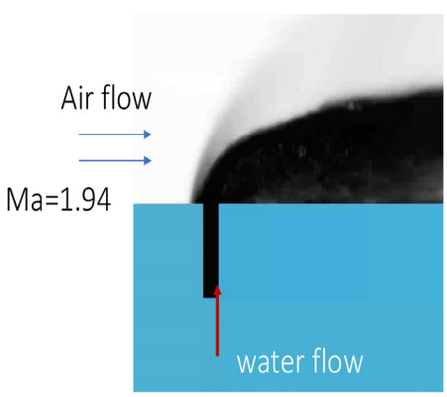
$$F^d_{\rho E} = (|u|+\bar{c})\sum_k C_k\bar{\alpha}_k\Delta(\rho_k e_k) + \frac{\bar{u}^2}{2}\sum_k F^d_{\rho Y_k} + (|u|+\bar{c})\bar{u}\Delta u\sum_k C_k\overline{\rho Y_k}$$

Dissipative coefficient is dynamically computed based on the Gibbs residuals

$$C_k = f(\Delta Gr_k)$$

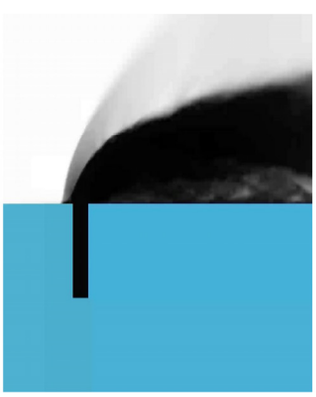
$$\Delta Gr_k = \Delta s_k - \bar{\beta}\Delta h_k + \bar{\beta}\bar{v}_k\Delta P$$

Target: Structure preservation at Coarse Resolution



5th order WENO scheme

- Accuracy improves through grid refinement
- Stability is obtained through numerical dissipation
- Transport structure is preserved only approximately

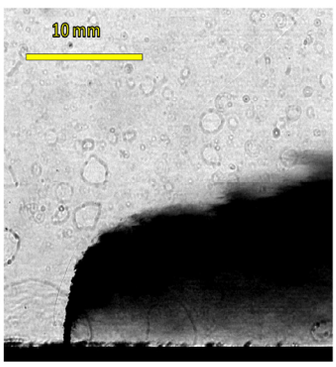


Learned Discrete Advection Operator

- Preserve Lie transport topology
- Suppress thermodynamic entropy production
- Minimize information loss
- Preserve information transfer (Whitney form)

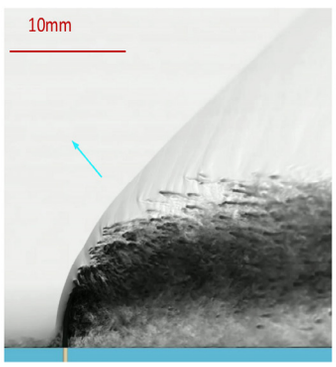
Qualitative Comparison: Structure preservation at Coarse Resolution
: liquid jet atomization in supersonic flow

Experiment
Shadowgraph images (AFRL)



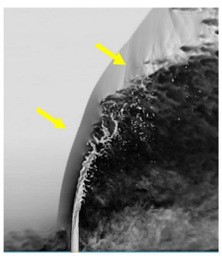
2017 data
50K fps recording
10 fps playback
0.159 μs exposure
44.3 (W) × 43.3 (V) μm/pixel

Simulation
Velocity magnitude at the center

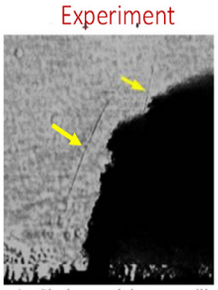


contour levels
- white: 700m/s
- black: 0m/s

Simulation



Experiment

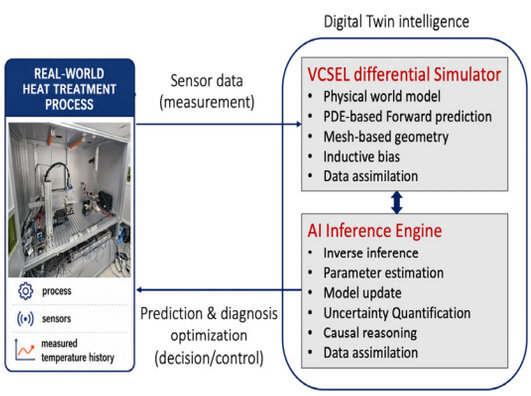


19

Structure-preserving Digital Twin for VCSEL Heating Process

Predictive intelligence requires both simulator and AI inference

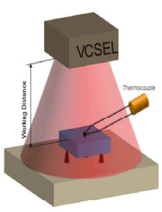
- **Simulator as a world model**
  - Predict admissible future states under physical constraints.
- **AI as an inference and learning engine**
  - Learns hidden states, uncertain parameters, and model discrepancies from data
- **Sensors as reality feedback**
  - Synchronize the virtual model with the real sensor data
- **Digital Twin as a closed loop**
  - Predict(simulate) → compare → infer → update → optimize

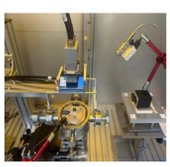


✓ Simulator predicts.
✓ AI infers.
✓ Sensors correct

Predict 4D temperature field under heating/cooling process

- VCSEL Heating Process





- Direct prediction of T(x,y,z,t)
  - PINN: (laser input) → T(x,y,z,t)
  - Neural Operator: T_0(x,y,z) → T(x,y,z,t)

→
- No high-fidelity data available (unknown material)
- Limited extrapolation (material, geometry)
- Maybe, it is Turing complete (no free shortcut)

- Why we need Voronoi-based Neural Network to predict 4D temperature?
  - No need to learn energy conservation (Stokes law holds)
  - Hard-code dissipative/entropy production through Hodge operators
  - Preserve the way the information transfer from node to node through message passing
  - Classical simulation do not provide inverse inference automatically.

A Hierarchy of what AI is asked to learn

- Filtered Partial Differential Equation by coarse graining

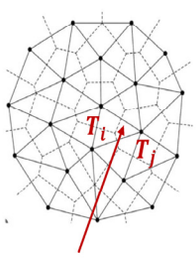
$$\bar{T} = \mathcal{G}_\Delta T \qquad \rho c_p \frac{\partial \bar{T}}{\partial t} = \nabla \cdot \left[k(\bar{T})\nabla \bar{T}\right] - \nabla \cdot q_{\mathrm{SGS}}$$

Heat flux vector: $q = q_{resolved} + q_{SGS}$

unknown flux : $q_{\mathrm{SGS}} = -\left(\overline{k(T)\nabla T} - k(\bar{T})\nabla \bar{T}\right)$

↓

- Graph structure with message passing



$$T_i^{t+1} = T_i^t + \Delta t\, \Phi_i^t,$$
$$\Phi_i^t = \frac{1}{\rho_i C_{p,i} V_i}\left(\sum_{j \in N(i)} m_{ij} + Q_i\right)$$

$$m_{ij} = S_{ij}\, \mathbf{n}_{ij} \cdot \hat{\mathbf{q}}_{ij}(T_i, T_j, \theta), \qquad m_{ij} = -m_{ji}$$

- Level1: learn full flux

$$m_{ij} = NN(T_i, T_j, \nabla T, S_{ij} n_{ij})$$

not working for unseen data (material, geometry)

- Level2: learn only SGS flux

$$m_{ij} = q_{FV} + NNsgs(T_i, T_j, \nabla T, S_{ij} n_{ij})$$

not accurate enough for unseen material

Physical reasoning Reduces the Learning Problem

❑ vector closure → scalar potential → moments → one learnable parameter

$$q_{\mathrm{SGS}} = -\left(\overline{k(T)\nabla T} - k(\bar{T})\nabla\bar{T}\right) \qquad k(T)\nabla T = \nabla K(T), \longrightarrow \qquad \Pi_{\mathrm{SGS}} = \overline{K(T)} - K(\bar{T}), \qquad q_{\mathrm{SGS}} = -\nabla\Pi_{\mathrm{SGS}}$$

- assume heat conductivity profile as: $k(T) = a_0 + a_1 T + a_2 T^2 + a_3 T^3 + a_4 T^4$

$$\Pi_{\mathrm{SGS}} = \frac{a_1}{2}\mu_2 + a_2\left(\bar{T}\mu_2 + \frac{1}{3}\mu_3\right) + a_3\left(\frac{3}{2}\bar{T}^2\mu_2 + \bar{T}\mu_3 + \frac{1}{4}\mu_4\right) + a_4\left(2\bar{T}^3\mu_2 + 2\bar{T}^2\mu_3 + \bar{T}\mu_4 + \frac{1}{5}\mu_5\right)$$

- apply symmetry invariance:

$$\mu_2 \simeq C_2\Delta^2|\nabla\bar{T}|^2 \qquad \mu_3 \sim \Delta^4\,\nabla\bar{T}^T H(\bar{T})\nabla\bar{T} + \Delta^4|\nabla\bar{T}|^2\nabla^2\bar{T}$$

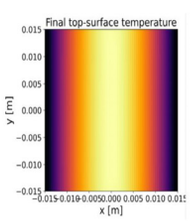
- learn only dynamic scalar parameter:

$$C_2 = NN(T, \Delta, theta)$$

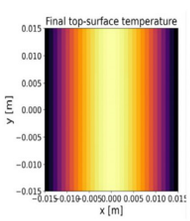
Cross-Material Prediction by AI-Physics model

- Training AI for Silicon-Carbode (15mmX15mm), laser 60%, distance=50mm
- Test Copper oxide (30mmx30mm, 40%laser, 40mm) and Iron-Oxide (50mmx50mm, 35%laser)

Copper oxide

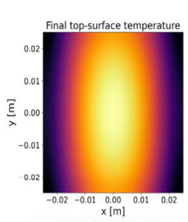


(a) High-Fidelity Simulation

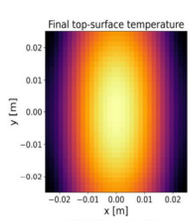


(b) AI-Physics Prediction

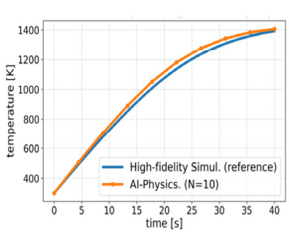
Iron-Oxide



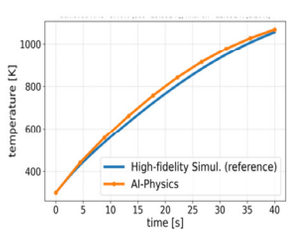
(a) High-Fidelity Simulation



(b) AI-Physics Prediction



(a) Copper oxide



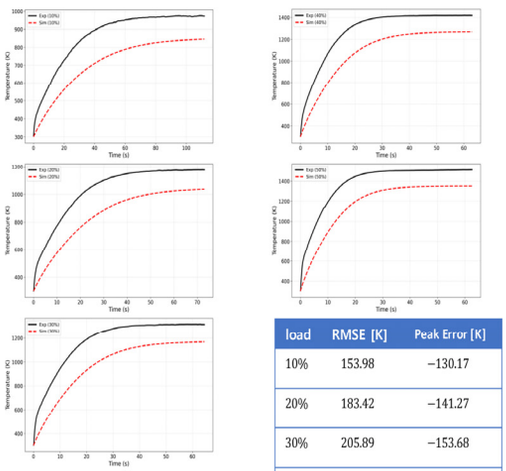
(b) Iron oxide

- 15X speed up at the similar accuracy
- Fully-differentiable solver (JAX)

Reality Check: Prediction model update through closed loop digital twin

SiC experiment vs. AI-Physics model

- No calibration on VCSEL Power

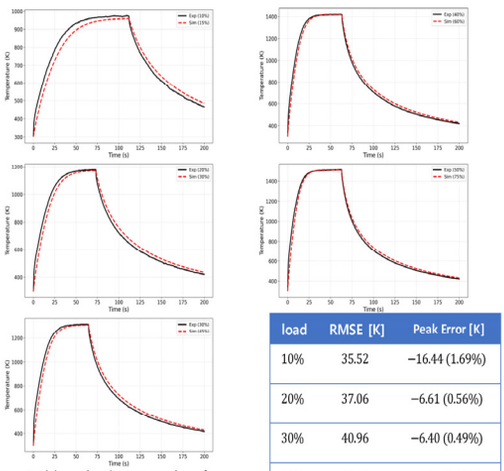


load	RMSE [K]	Peak Error [K]
10%	153.98	−130.17
20%	183.42	−141.27
30%	205.89	−153.68
40%	204.43	−150.67
50%	215.25	−163.09

- A consistent error of ~150K observed at the peak

After VCSEL power calibration

- No calibration on VCSEL Power

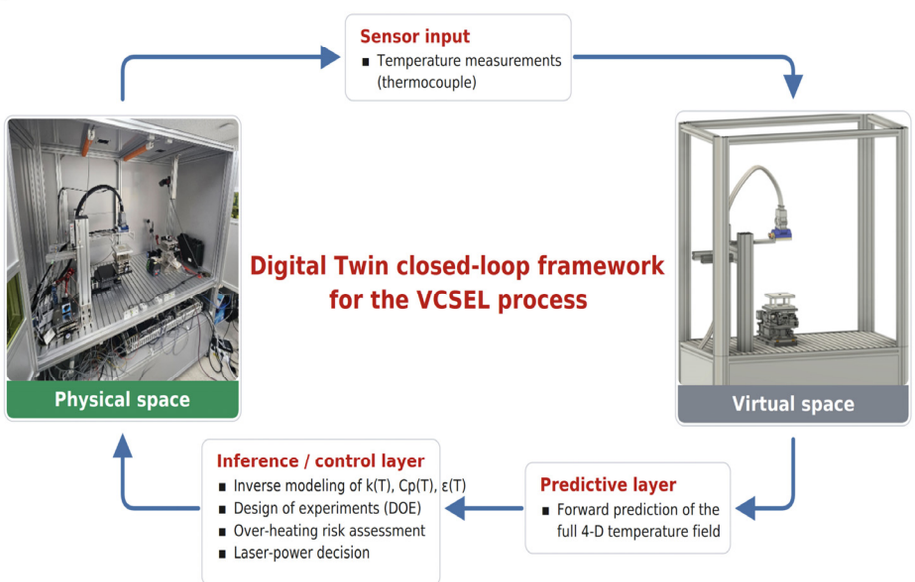


load	RMSE [K]	Peak Error [K]
10%	35.52	−16.44 (1.69%)
20%	37.06	−6.61 (0.56%)
30%	40.96	−6.40 (0.49%)
40%	32.17	+1.90 (0.13%)
50%	37.01	−2.94 (0.19%)

- With a single correction factor, peak temperature and cooling behavior are reproduced across all power levels

AI-Physics simulator based Digital Twin for VCEL Process

❑ Prediction, inversion, experimental design, and control can be based on AI-Physics differentiable model

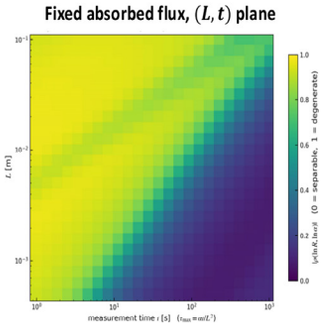


Design Experiment by AI-Physics Model

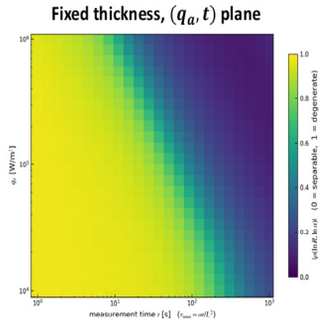
Identifiability Analysis for thermal diffusion α and radiation R

- The sensitivity correlation $|\rho_{R,\alpha}|$ screens experimental conditions
  - $|\rho_{R,\alpha}| \to 1$ (Yellow regime) R–α degeneracy **(inseparable)**
  - $|\rho_{R,\alpha}| \to 0$ (Blue regime) R–α separable **(identifiable)**
- Design variables: absorbed flux $\boldsymbol{q_a}$, thickness $\boldsymbol{L}$, measurement time $\boldsymbol{t}$ ($\tau = \alpha t/L^2$)

Fixed absorbed flux, (L, t) plane



Fixed thickness, (q_a, t) plane



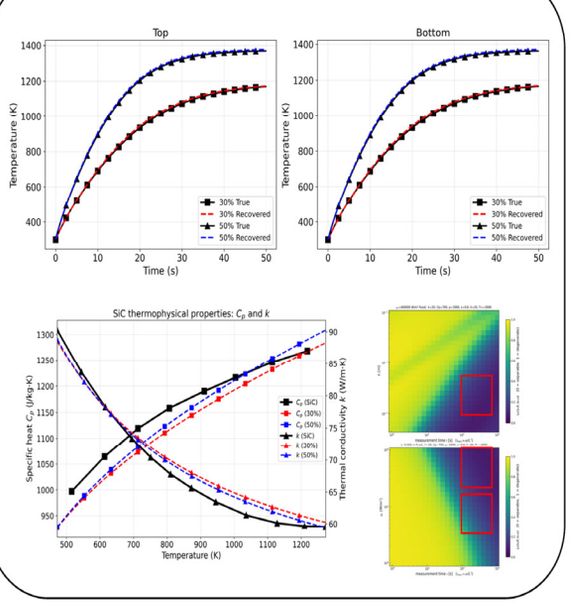
Significance

- This analysis is a regime-screening of whether an experimental condition encodes **radiation information separably from diffusion**
- A small $|\rho_{R,\alpha}|$ only flags a candidate condition for emissivity separation
- The final identifiability of the three properties (k, C_p, ε) is assessed separately via **the dimensional Identifiability analysis**

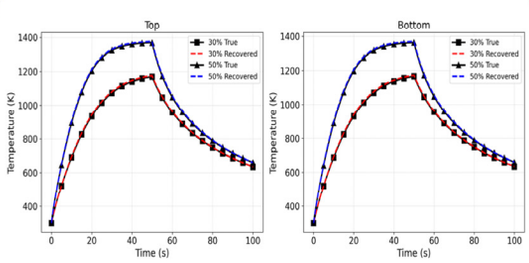
Predictive intelligence should tell us not only what will happen, but what experiment will be informative

Inverse Inference in an Identifiable Regime

Reference-property inverse estimation



Extrapolation validation on the cooling phase

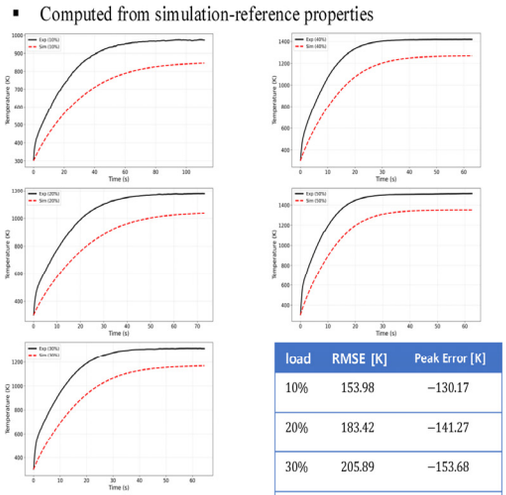


출력	물성	RMSE	Max error [%]
30%	c_p	33.17 [J/Kg· K]	4.06
	k	1.833 [$W/m \cdot K$]	4.50
	ϵ (true 0.75)	0.0032 [-]	0.42
50%	c_p	26.06 [J/Kg· K]	3.55
	k	1.371 [$W/m \cdot K$]	3.39
	ϵ (true 0.75)	0.0171 [-]	2.28

Reality Check: Prediction model update through closed loop digital twin

SiC experiment vs. simulation validation

- Computed from simulation-reference properties

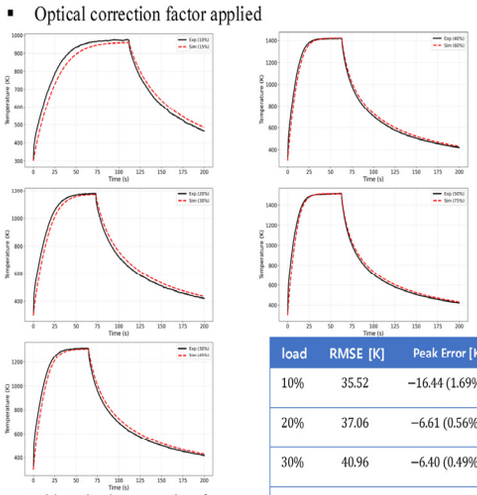


load	RMSE [K]	Peak Error [K]
10%	153.98	−130.17
20%	183.42	−141.27
30%	205.89	−153.68
40%	204.43	−150.67
50%	215.25	−163.09

- A consistent error of ~150K observed at the peak

Simulated VCSEL power calibration

- Optical correction factor applied

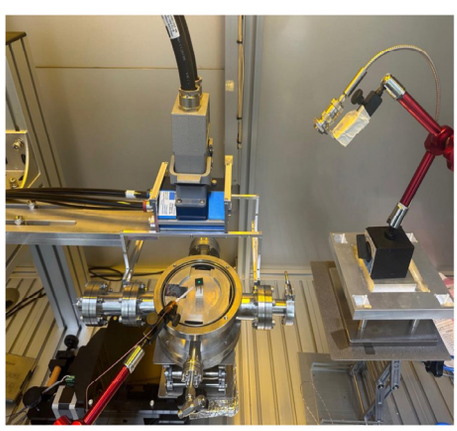


load	RMSE [K]	Peak Error [K]
10%	35.52	−16.44 (1.69%)
20%	37.06	−6.61 (0.56%)
30%	40.96	−6.40 (0.49%)
40%	32.17	+1.90 (0.13%)
50%	37.01	−2.94 (0.19%)

- With a single correction factor, peak temperature and cooling behavior are reproduced across all power levels

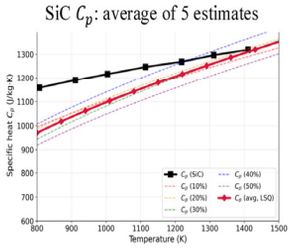
Reality Check: Inverse estimate through Digital Twin.

Pyrometer measurement setup

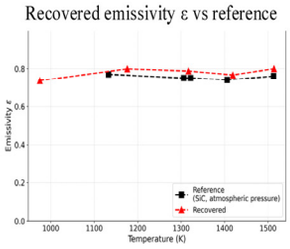


Inverse estimation results

SiC C_p: average of 5 estimates



Recovered emissivity ε vs reference



- Estimation uses top-sensor data only, with k and R_f fixed at reference values
- Estimation was restricted to T > 850 K, below which pyrometer readings are unreliable per the instrument specification.
- $C_p(T)$ and ε were recovered with maximum errors of 7% and 5%, respectively, relative to literature references.

SOC 제작용 핵심 공정 무인 자동화 시스템 및 디지털 트윈 구축

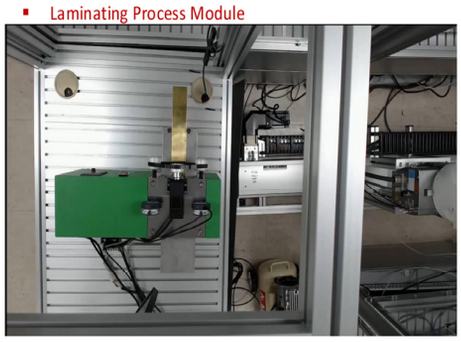
- Laser Cutting Process Module



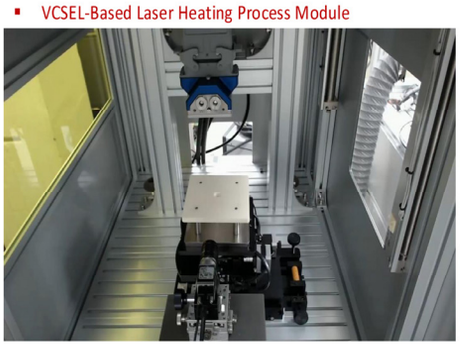
- Spray Coating Process Module



- Laminating Process Module



- VCSEL-Based Laser Heating Process Module



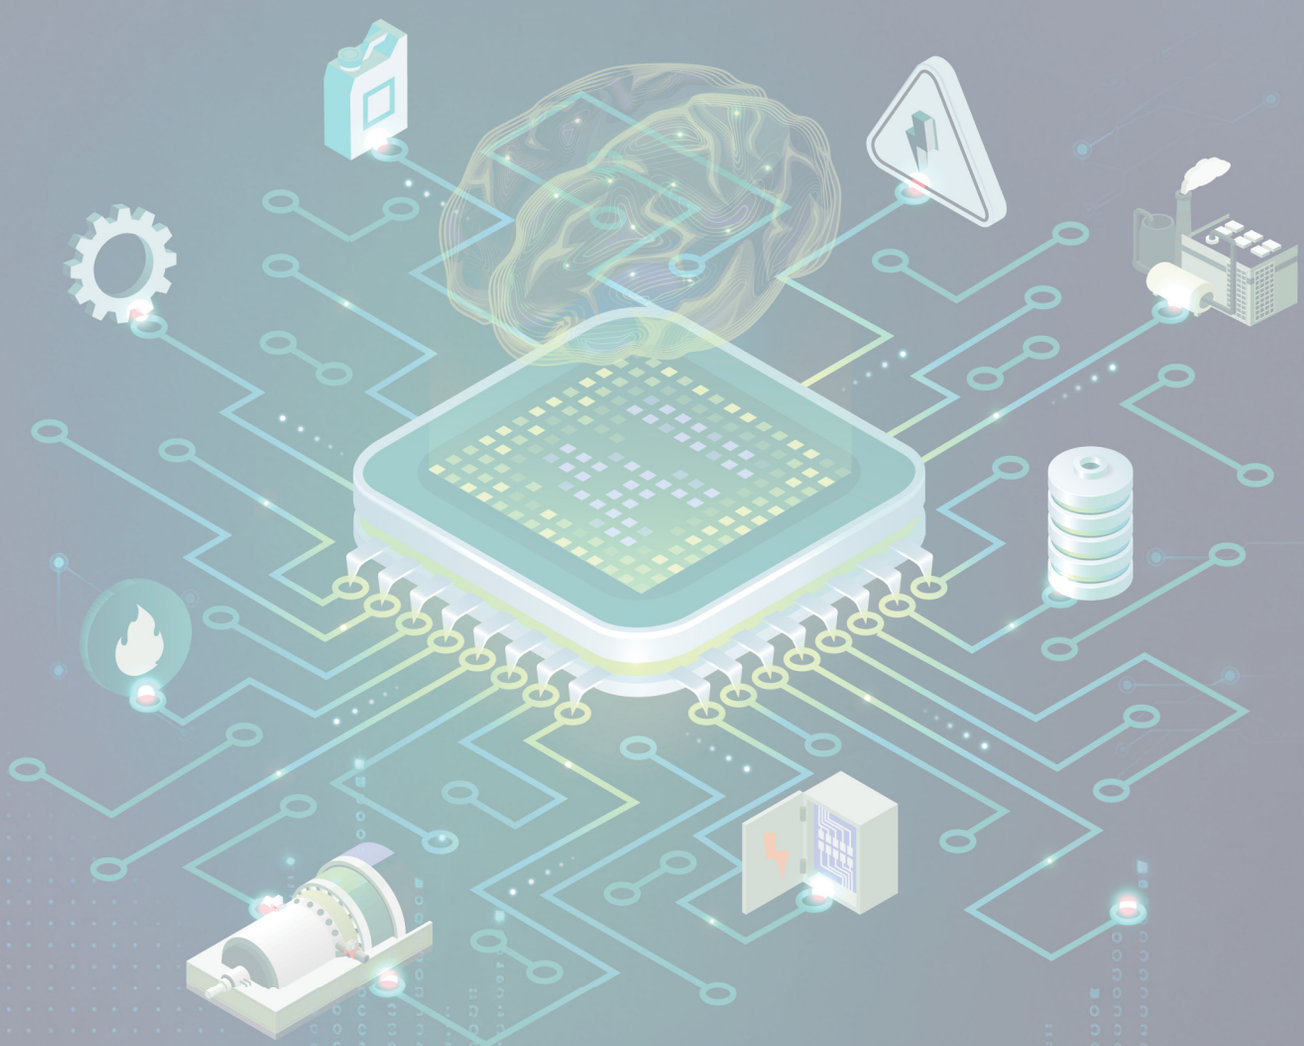
What I have learned…

- For sufficiently rich dynamics, prediction may require computing the future.
- Therefore, predictive intelligence needs a world model (Age of experience).
- Every prediction is an extrapolation in time — and extrapolation needs a rule for what can happen.
- Structural Extrapolation hypothesis (Age of Research):
  - Physics improves extrapolation not simply because it adds constraints, but by changing what the neural network is asked to extrapolate.
  - Keep the nonlinearity in the simulator; leave the network a nearly-linear problem.
- Perhaps intelligence begins when a system can experience possible futures before reality arrives.

Session II

연소 모델링을 위한 과학적 머신러닝

김수용 교수
(서울대학교)



연소 모델링을 위한 과학적 머신러닝

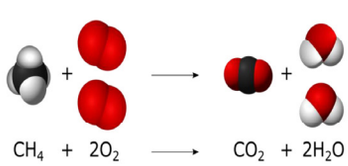
김수용

조교수
서울대학교 기계공학부

2026년 8월 21일 (금)
AI 기반 연소기술 특별 워크샵

Combustion Science and Engineering

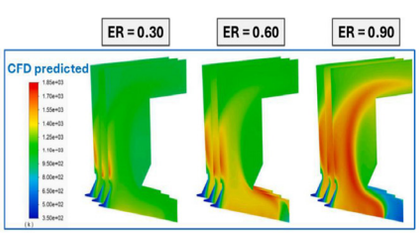
Scientific discovery



Simulation



Control



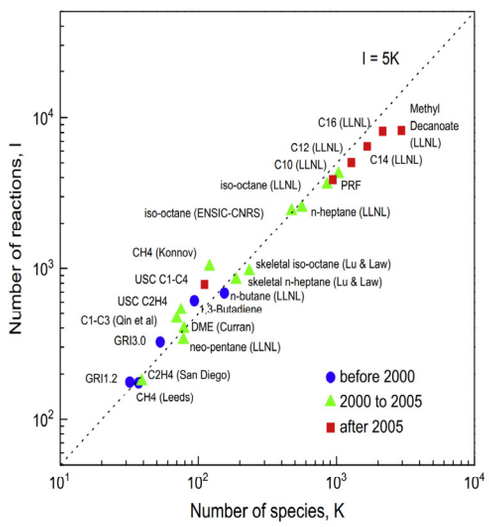
Combustion = Chemical reactions + Transport phenomena

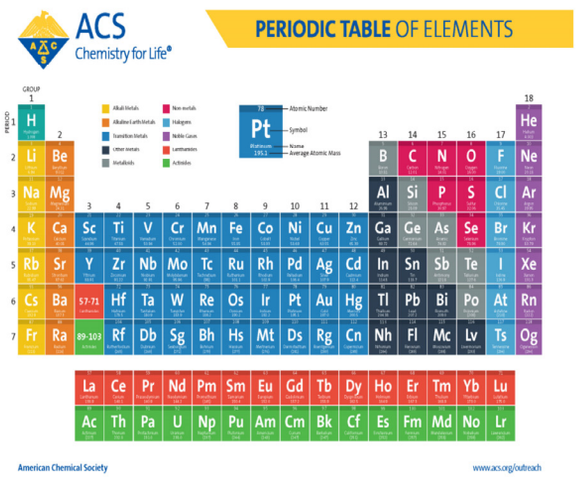
Image source: wikipedia, Oak Ridge National Laboratory, Wang et al. 2024 *Chem. Eng. J.*

2

Are We Sufficiently Knowledgeable?

Hydrocarbon fuels

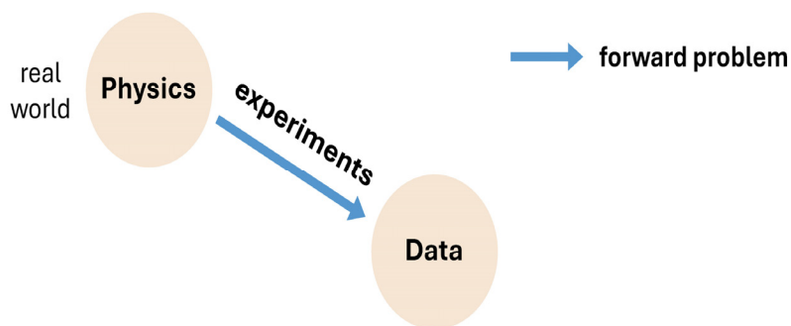




Lu and Law 2009 Prog. Energ. Combust. Sci.

3

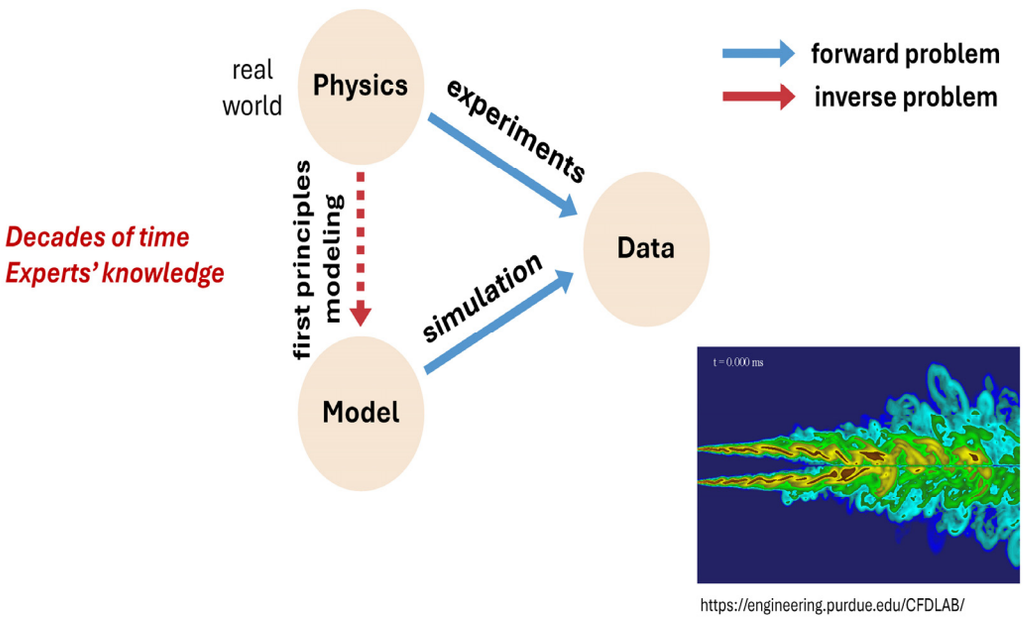
How Do We Understand Our Physics?



4



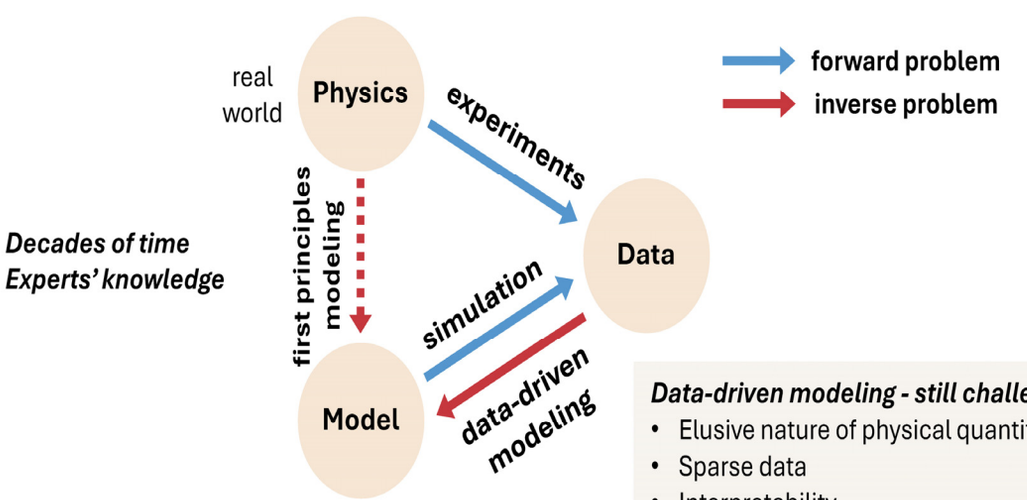
From Observation to Model?



https://engineering.purdue.edu/CFDLAB/

5

Alternative Ways?



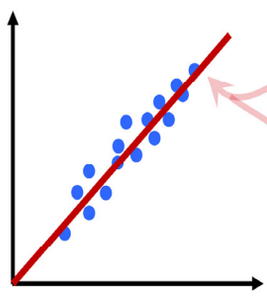
Data-driven modeling - still challenging.

- Elusive nature of physical quantities
- Sparse data
- Interpretability
- Generalizability
- Model uncertainty

6

Is Data-Driven Modeling New?

Not at all, curve fitting!



$$X = \begin{bmatrix} x_1^{(1)} & \cdots & x_1^{(n)} \\ \vdots & \ddots & \vdots \\ x_d^{(1)} & \cdots & x_d^{(n)} \end{bmatrix} \qquad Y = \begin{bmatrix} y^{(1)} & \cdots & y^{(n)} \end{bmatrix}$$

Step 1 hypothesis – linear function

$$y = \theta^T x$$

Step 2 find parameters – optimization

Objective function:

$$J(\theta) = \frac{1}{n}\sum_{i=1}^{n}\left(\theta^T x^{(i)} - y^{(i)}\right)^2$$

$$= \frac{1}{n}\left(X^T\theta - Y^T\right)^T\left(X^T\theta - Y^T\right)$$

Minima: $\nabla_\theta J(\theta) = \frac{2}{n}X^T\left(X^T\theta - Y^T\right) = 0$

Optimal parameters: $\theta^* = \left(XX^T\right)^{-1}XY^T$

7

What if We Have More Complex Physics?

Supercritical organic fluids

(Harmen et al. 2018 *AIP Conf. Proc.*)

Author	Equations
Dittus-Boelter (1930)	$Nu_b = 0.023Re_b^{0.8}Pr_b^n$ $n = 0.3$ for cooling, $n = 0.4$ for heating
Krasnochekov and Protopopov (1959)	$Nu_b = Nu_{0,b}\left(\frac{\bar{c}_p}{c_{p,b}}\right)^{0.35}\left(\frac{k_b}{k_w}\right)^{-0.33}\left(\frac{\mu_b}{\mu_w}\right)^{0.11}$ $Nu_{0,b} = \left(\frac{\frac{f_b}{8}Re_b\overline{Pr}}{12.7\left(\frac{f_b}{8}\right)^{0.5}\left(\overline{Pr}^{\frac{2}{3}}-1\right)+1.07}\right)$ $f = (1.82\log_{10}(Re_b) - 1.64)^{-2}$
Gnielinski (1976)	$Nu = \frac{(f/8)(Re-1000)Pr}{1+12.7(f/8)^{0.5}(Pr^{2/3}-1)}$ *For smooth tubes:* $f = (0.790\ln(\mathrm{Re}) - 1.64)^{-2}$, $10^4 < \mathrm{Re} < 10^6$

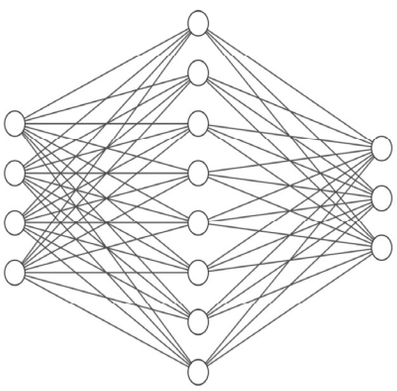
Author	Equations
Jackson and Hall, (1979)	$Nu_b = 0.0183Re_b^{0.82}\overline{Pr}^{0.5}\left(\frac{\rho_w}{\rho_b}\right)^{0.3}\left(\frac{\bar{c}_p}{c_{pb}}\right)^n$ $\bar{c}_p = \left(\int_{T_w}^{T_b} c_p dT\right)/(T_b - T_w)$ $n = 0.4$ for $T_b < T_w < T_{pc}$ and $1.2T_{pc} < T_b < T_w$ $n = 0.4 + 0.2[(T_w/T_{pc}) - 1]$ for $T_b < T_{pc} < T_w$ $n = 0.4 + 0.2[(T_w/T_{pc}) - 1]\,[1 - 5(T_b/T_{pc} - 1)]$ for $T_{pc} < T_b < 1.2T_{pc}$ and $T_b < T_w$
Petukhov et al., (1983)	$Nu_b = \frac{(f/8)Re_b\overline{Pr_b}}{1+900/Re_b+12.7\sqrt{f/8}\left(\overline{Pr_b}^{2/3}-1\right)}$ $f = f_0(\rho_w/\rho_b)^{0.4}(\mu_w/\mu_b)^{0.2}$ $f_0 = (1.82\log_{10}(Re_b) - 1.64)^{-2}$
Razumovskiy et al., (1990)	$Nu_b = \frac{(f_r/8)Re_b\overline{Pr_b}}{1.07+12.7\sqrt{f_r/8}\left(\overline{Pr_b}^{2/3}-1\right)}\left(\bar{c_p}/c_{p,b}\right)^{0.65}$ $f_r = f_0(\rho_w/\rho_b)^{0.18}(\mu_w/\mu_b)^{0.18}$
Kang and Chang (2009)	$Nu_b = 0.0244Re_b^{0.762}\overline{Pr}^{0.552}\left(\frac{\rho_w}{\rho_b}\right)^{0.0293}$ $\overline{Pr} = \bar{c_p}\frac{\mu}{k}$
Mokry et al. (2010)	$Nu_b = 0.0061Re_b^{0.904}\overline{Pr}^{0.833}\left(\frac{\rho_w}{\rho_b}\right)^{0.564}$

Finding a proper hypothesis group would be one of the challenging tasks.

8



Neural Networks



Theorem (informal): Let f be a sigmoid activation. Given any continuous function 'h' on a compact set $C \in \mathbb{R}^d$, there exists a NN with 1-hidden layer and a choice of parameters such that its output

$$F(x) = \sum_{i=1}^{m} v_i f\left(\theta^T x + \theta_0\right)$$

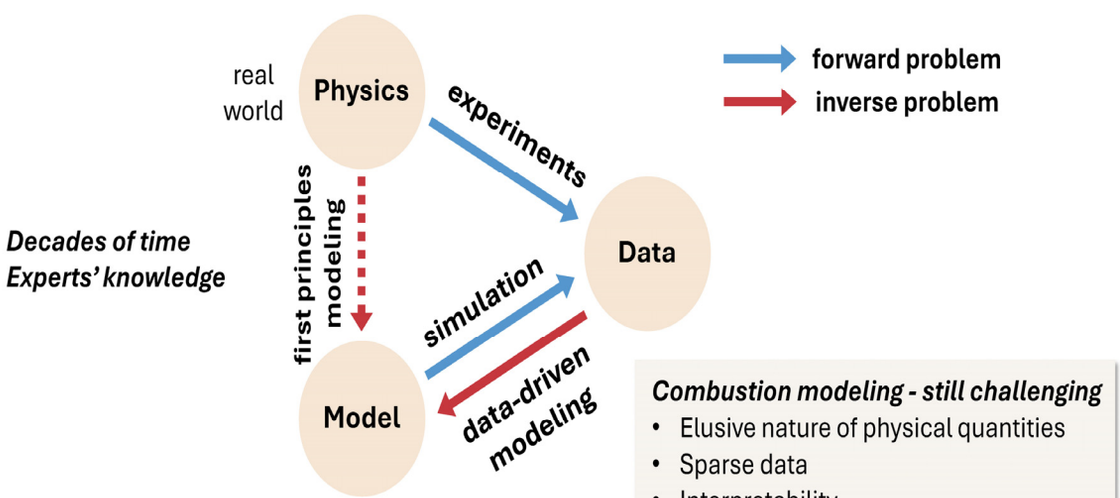
approximates 'h' to any desired accuracy $\varepsilon > 0$, i.e., $|F(x) - h(x)| < \varepsilon$ for all $x \in C$. (from Cybenko's result in 1989)

"Universal Approximation Theorem"

Slide adapted from MIT 6.867

9

Towards Interpretable and Generalizable Models



Combustion modeling - still challenging

- Elusive nature of physical quantities
- Sparse data
- Interpretability
- Generalizability
- Model uncertainty

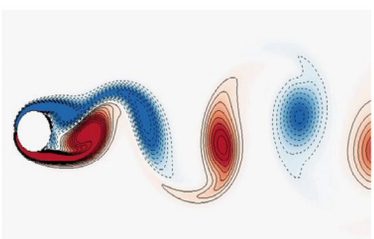
10

Dynamical System as a Lens for Engineers

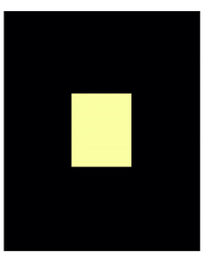
dynamical system $\frac{d\boldsymbol{u}}{dt} = \boldsymbol{f}(\boldsymbol{u}, t, \boldsymbol{\theta})$ ➡ $\boldsymbol{u} = \int \boldsymbol{f}(\boldsymbol{u}, t, \boldsymbol{\theta})\, \boldsymbol{dt}$

is engineers' lens for **physical comprehension** and **design tools**!

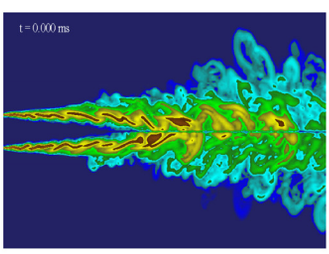
fluid motion



thermal behaviors



reacting flows



Today, we will only focus on ODEs/PDEs modeling.

Image credits (October 2025):
https://www.shantanubailoor.com/carreau-cylinder
https://medium.com/data-science/simulation-101-conductive-heat-transfer-a4f09b3e16b4
https://engineering.purdue.edu/CFDLAB/

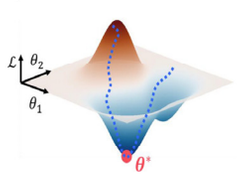
11

Two Scenarios in PDE-Based Inverse Modeling

fully known ⟵ ***domain knowledge*** ⟶ *unknown*

Model calibration

parameter estimation



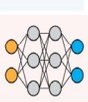
$$\rho c \frac{dT(\boldsymbol{r},t)}{dt} = \nabla \cdot [k \nabla T(\boldsymbol{r},t)] + \rho H \frac{d\omega(\boldsymbol{r},t)}{dt}$$

$$\frac{d\omega(\boldsymbol{r},t)}{dt} = [1-\omega(\boldsymbol{r},t)]^n A \exp\left[-\frac{E_a}{RT(\boldsymbol{r},t)}\right]$$

Model construction

known PDEs

$$\rho c \frac{dT(\boldsymbol{r},t)}{dt} = \nabla \cdot [k \nabla T(\boldsymbol{r},t)]$$

\+ 

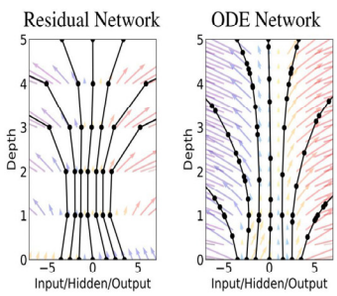
data-driven model

12

Latent Dynamics Modeling

Residual neural network

$$\boldsymbol{u}_{t+1} = \boldsymbol{u}_t + \boldsymbol{f}(\boldsymbol{u}_t, \boldsymbol{\theta})$$

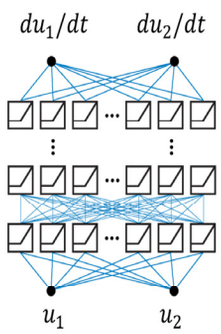


Neural ordinary differential equation

$$\frac{d\boldsymbol{u}}{dt} = \boldsymbol{f}(\boldsymbol{u}, t, \boldsymbol{\theta}) \approx \mathrm{NN}(\boldsymbol{u}, t, \boldsymbol{\theta})$$

(universal approximation theorem)

Chen et al. 2018 *NIPS*



Time scales are widely separated in combustion.

13

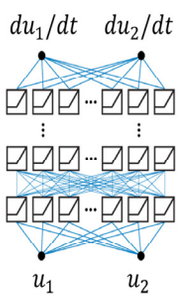
Neural ODEs – Challenges

Neural ordinary differential equations

$$\frac{d\boldsymbol{u}}{dt} = \boldsymbol{f}(\boldsymbol{u}, t, \boldsymbol{\theta}) \approx \mathrm{NN}(\boldsymbol{u}, t, \boldsymbol{\theta})$$

(universal approximation theorem)

Chen et al. 2018 *NIPS*



- ❑ Pure data-driven modeling for PDEs or ODEs
- ❑ Critics
  - Not interpretable
  - Difficult to generalize
  - Challenging to train neural networks due to stiffness (**Kim** et al. 2021 *Chaos*)

$$\frac{du}{dt} = u(1-u) \Rightarrow \text{Need a gigantic NN}$$

- ❑ **My perspective: the latent dynamics are always simple!**

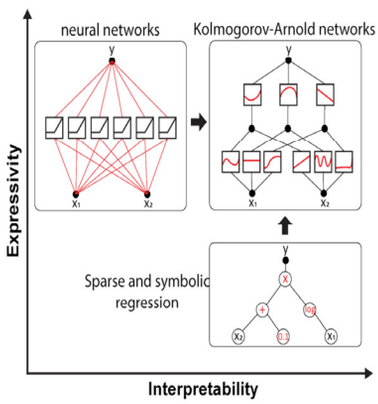
Navier-Stokes equation $\quad \frac{D\boldsymbol{u}}{Dt} = \frac{\partial \boldsymbol{u}}{\partial t} + (\boldsymbol{u}\cdot\nabla)\boldsymbol{u} + \nu\nabla^2\boldsymbol{u} - \frac{1}{\rho}\nabla p + \frac{1}{\rho}\boldsymbol{f}$

Question: Can we develop a compact and transparent latent modeling technique?

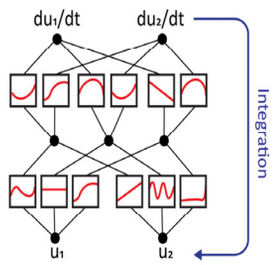
14

Compact and Transparent Machine Learning Model

Interpretable machine learning



Kolmogorov-Arnold network ordinary differential equations



$$\frac{d\boldsymbol{u}}{dt} = \mathrm{KAN}(\boldsymbol{u}, t, \boldsymbol{\theta})$$

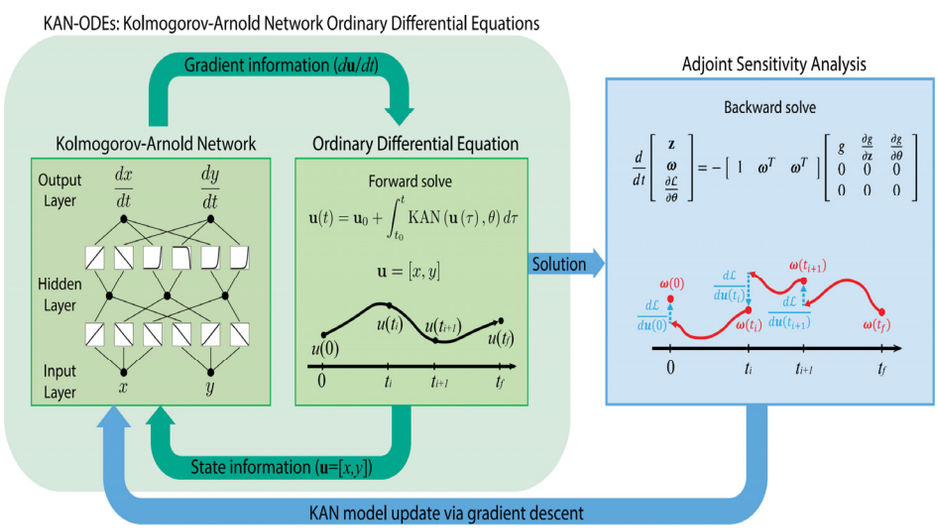
$$\frac{d\boldsymbol{u}}{dt} = \mathrm{Symbolic}(\boldsymbol{u}, t, \boldsymbol{\theta})$$

Koenig[#], **Kim[#]** and Deng 2024 *Comput. Meth. Appl. Mech. Eng.*
Koenig, **Kim*** and Deng* 2025 *Neural Netw.*
Koenig[#], **Kim[#]** and Deng 2025 *Phys. Chem. Chem. Phys.*
(#: equal contribution, *: corresponding)

- ❑ **KAN-ODEs: A new approach leveraging the concepts of neural ODEs and symbolic regression**
- ❑ **Foundation for a compact and transparent modeling tool for dynamical systems**

15

Kolmogorov-Arnold Network Ordinary Differential Equations



Exploit time-dependent information in our data through adjoint sensitivity analysis

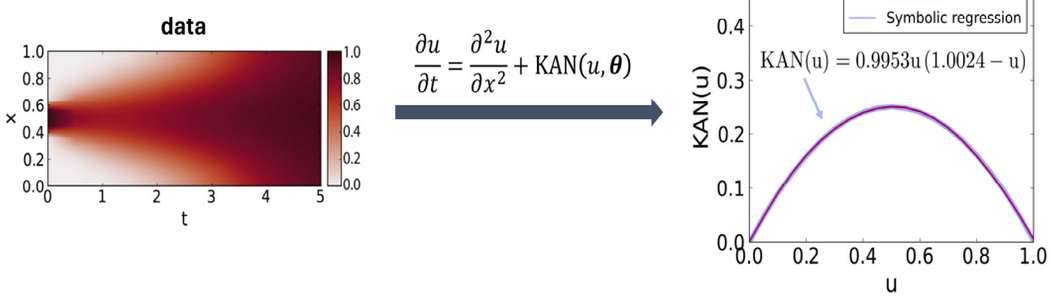
16



Symbolic Modeling of Source Terms

Fisher KPP PDEs $\frac{\partial u}{\partial t} = \frac{\partial^2 u}{\partial x^2} + u(1-u)$ (*known* / *unknown*)

Goal: derive a source term in PDEs using KAN-ODEs



Learning the hidden physics or latent dynamics from observation
(can be extended to any modeling such as in porous media)

Koenig#, **Kim#** and Deng 2024 *Comput. Meth. Appl. Mech. Eng.*

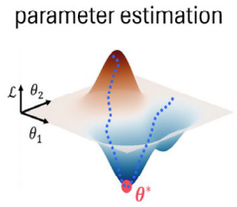
17

The Other Scenarios in PDE-Based Inverse Modeling

fully known ⟵ ***domain knowledge*** ⟶ *unknown*

Model calibration

parameter estimation



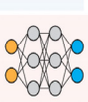
$$\rho c \frac{dT(\boldsymbol{r},t)}{dt} = \nabla \cdot [k \nabla T(\boldsymbol{r},t)] + \rho H \frac{d\omega(\boldsymbol{r},t)}{dt}$$

$$\frac{d\omega(\boldsymbol{r},t)}{dt} = [1-\omega(\boldsymbol{r},t)]^n A \exp\left[-\frac{E_a}{RT(\boldsymbol{r},t)}\right]$$

Model construction

known PDEs

$$\rho c \frac{dT(\boldsymbol{r},t)}{dt} = \nabla \cdot [k \nabla T(\boldsymbol{r},t)]$$

\+ 

data-driven model

18

Motivating Example: Nanocomposite Combustion Physics

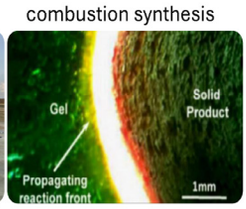
solid rocket booster



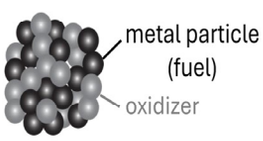
explosives

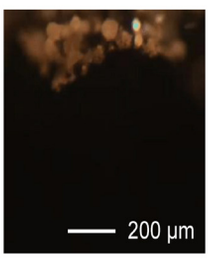


combustion synthesis



Nanocomposite combustion





Laminar premixed flame theory: $S \sim (\alpha\dot{\omega})^{0.5}$

Wrong for nanocomposite

Tsai#, **Kim#**, and Deng 2024 *Proc. Combust. Inst.*

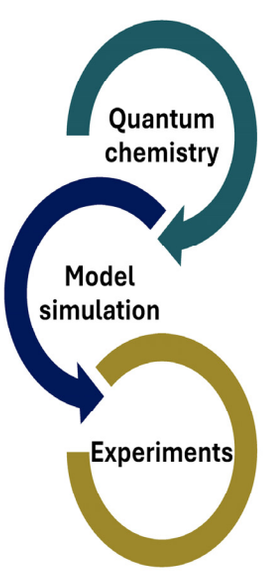
- **Challenge**: incapable of measuring α and $\dot{\omega}$ for nanocomposites
- **Research goals**:
  1. Combustion wave propagation theory
  2. Quantitative analysis of heterogeneous flame dynamics and instability

Kim et al. 2025 *ACS Nano*
Kim and Deng 2023 *Chem. Eng. J.*
Cha#, Wang#, **Kim#** et al. 2024 *ACS Appl. Mater. Interfaces*

19

Reaction Mechanism Generation

Forward approach

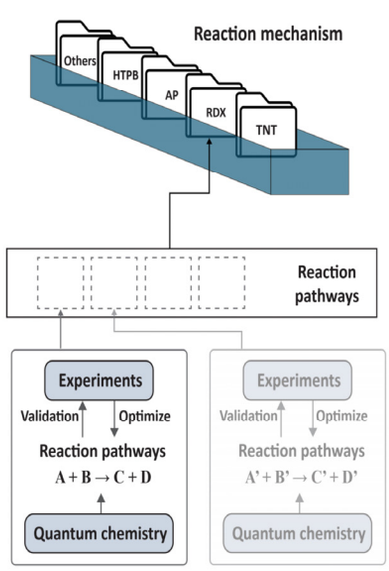


Reaction pathways
Reaction parameters

Prediction for flame dynamics

Tuning and validation w/ canonical configurations

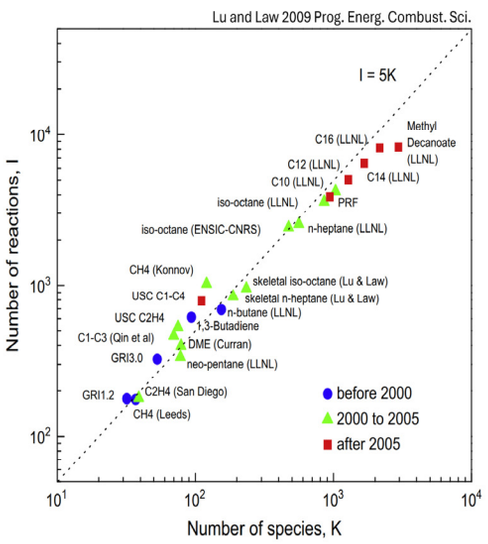
Bottom-up approach

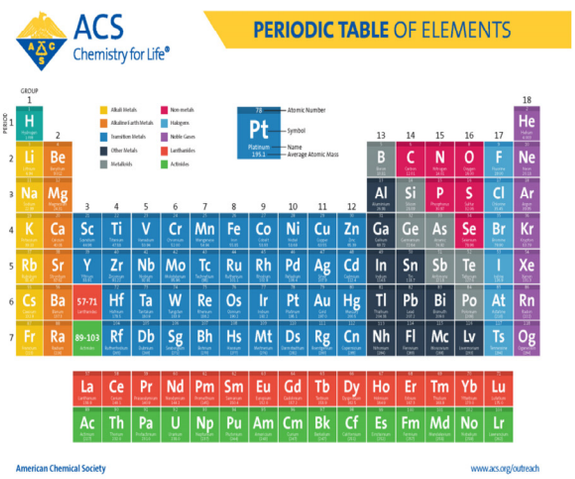


20

Is the Bottom-Up Approach Tractable?

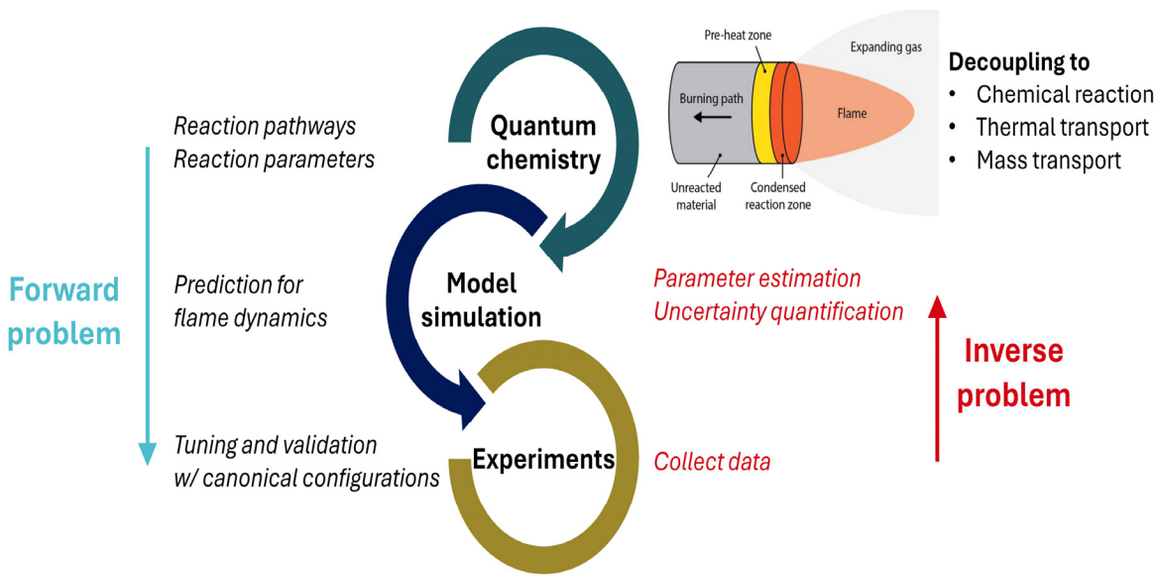
Hydrocarbon fuels: C/H/N/O





21

Change in Perspective



22

Model Calibration for Reaction-Transport Equations

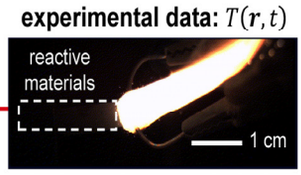
infer parameters
- thermodynamic: T_f
- transport: α, h
- kinetic: A, n, E_a

chemically reacting flow

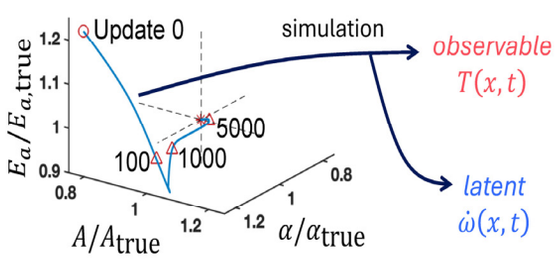
$$\rho c \frac{dT(\boldsymbol{r},t)}{dt} = \nabla \cdot [k \nabla T(\boldsymbol{r},t)] + \rho H \frac{d\omega(\boldsymbol{r},t)}{dt}$$

$$\frac{d\omega(\boldsymbol{r},t)}{dt} = [1-\omega(\boldsymbol{r},t)]^n A \exp\left[-\frac{E_a}{RT(\boldsymbol{r},t)}\right]$$

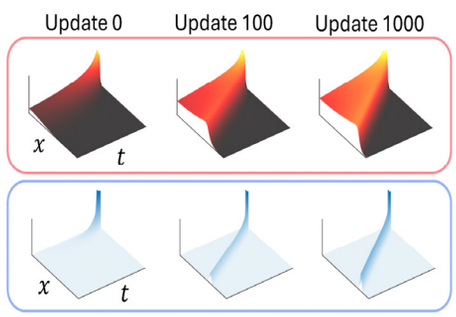
experimental data: $T(\boldsymbol{r},t)$



PDE-constrained optimization



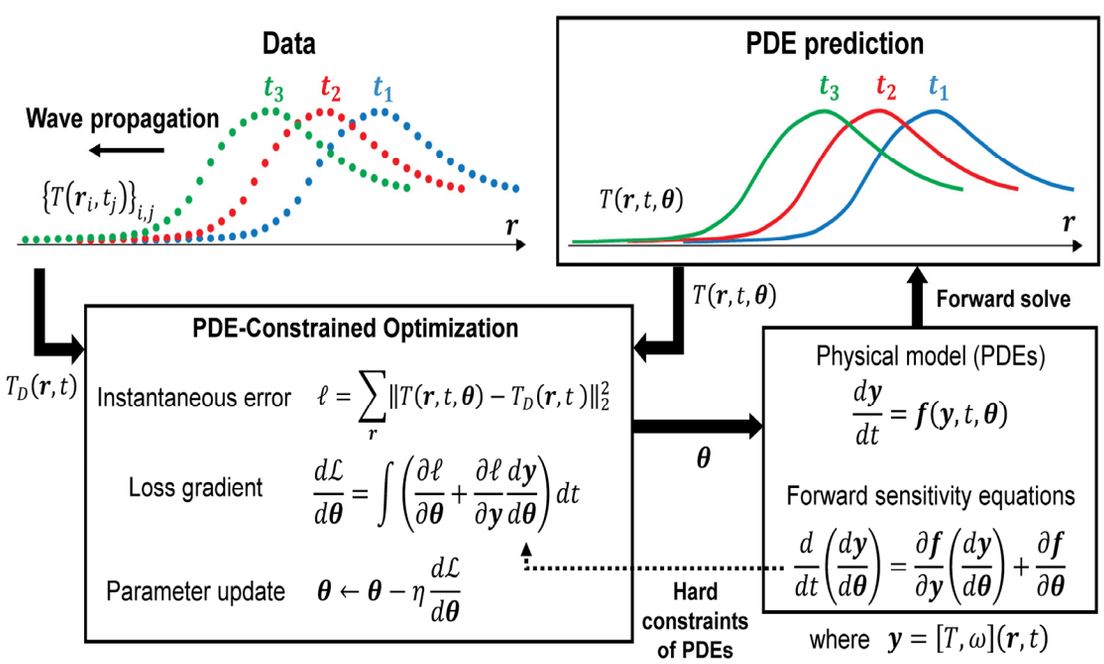
Decoding reaction-transport coupling!



Kim and Deng 2024 *Nat. Commun.*

23

PDE-Constrained Optimization

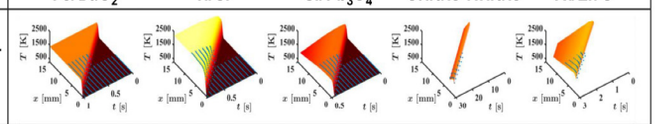
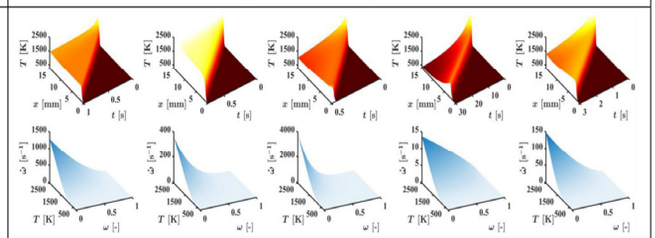
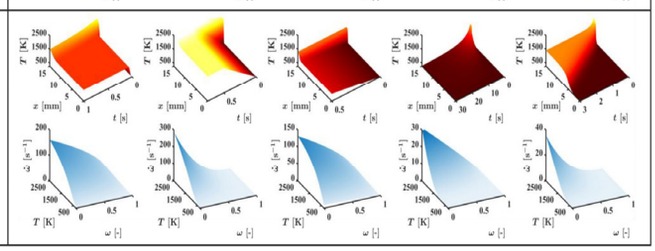


Kim and Deng 2024 *Nat. Commun.*

24



Test with Experimental Data

	Fe/BaO_2	Ti/Si	Si/Pb_3O_4	Citrate-Nitrate	Al/Zr/C
Measurement					
Our approach					
Curve-fitting					

O **Accurate** prediction in our approach

Boddington et al. 1986

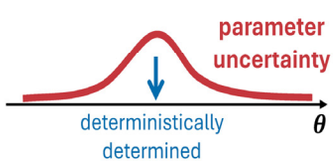
X **Wrong** prediction in a curve-fitting approach

Kim and Deng 2024 *Nat. Commun.*

25

Uncertainty Quantification for Prediction Reliability

"Experimental data are always noisy."



Sampling approach (e.g. MCMC)
– *intractable* with nonlinear PDEs

Kim and Deng, in peer review in *Journal of Computational Physics*

26

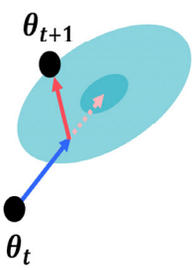
Conventional Approach: Markov Chain Monte Carlo

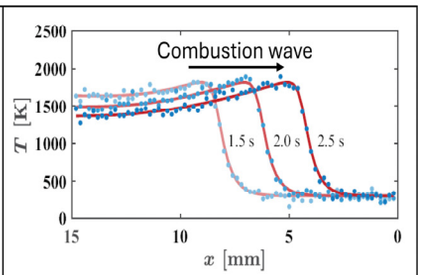
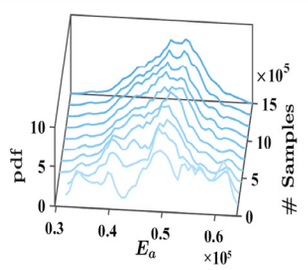
Metropolis-Adjusted Langevin Approach (MALA)

$\theta_0 \rightarrow \theta_1 \rightarrow \theta_2 \rightarrow \cdots \rightarrow \theta_M$

$$\theta_{t+1} = \theta_t + \frac{\tau^2}{2}\nabla \log P(\boldsymbol{\theta}|\mathcal{D}) + \tau\epsilon_t$$

PDE information — Random walk $\epsilon_t \sim N(0, I)$



Experimental observation	
Sample size test	

Kim and Deng, in peer review in *Journal of Computational Physics*

27

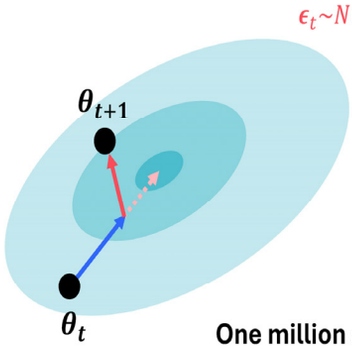
Conventional Approach: Markov Chain Monte Carlo

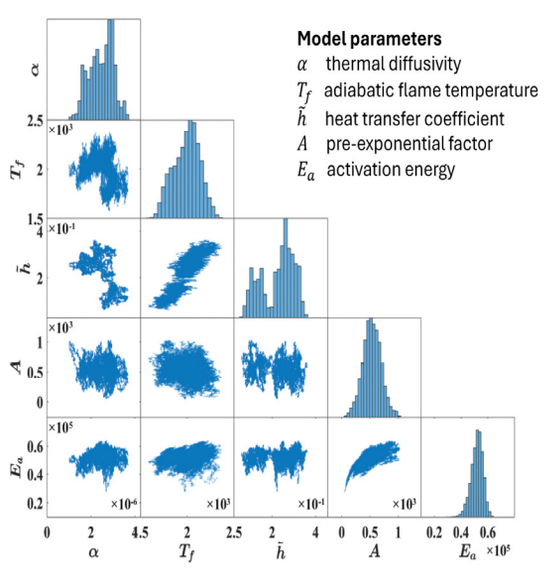
Metropolis-Adjusted Langevin Approach (MALA)

$\theta_0 \rightarrow \theta_1 \rightarrow \theta_2 \rightarrow \cdots \rightarrow \theta_M$

$$\theta_{t+1} = \theta_t + \frac{\tau^2}{2}\nabla \log P(\boldsymbol{\theta}|\mathcal{D}) + \tau\epsilon_t$$

PDE information — Random walk $\epsilon_t \sim N(0, I)$





Model parameters
- α thermal diffusivity
- T_f adiabatic flame temperature
- $\tilde{h}$ heat transfer coefficient
- A pre-exponential factor
- E_a activation energy

One million samples do not accurately represent the posterior distributions.

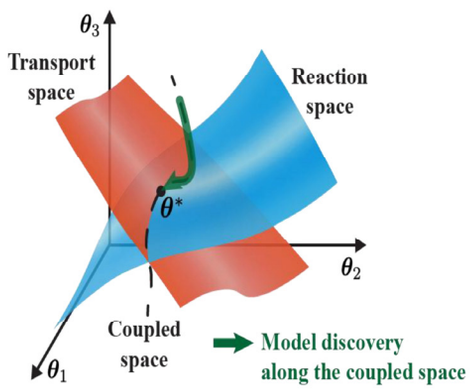
Kim and Deng, in peer review in *Journal of Computational Physics*

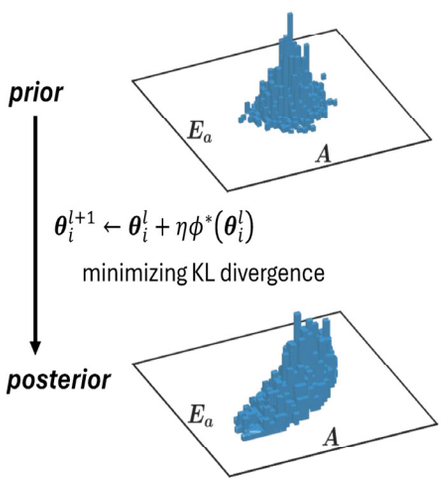
28



Our PDE-Constrained Stein Variational Gradient Descent

PDE-constrained optimization	Stein variational gradient descent
Deterministic approach using a sensitivity analysis	Transforming prior to posterior



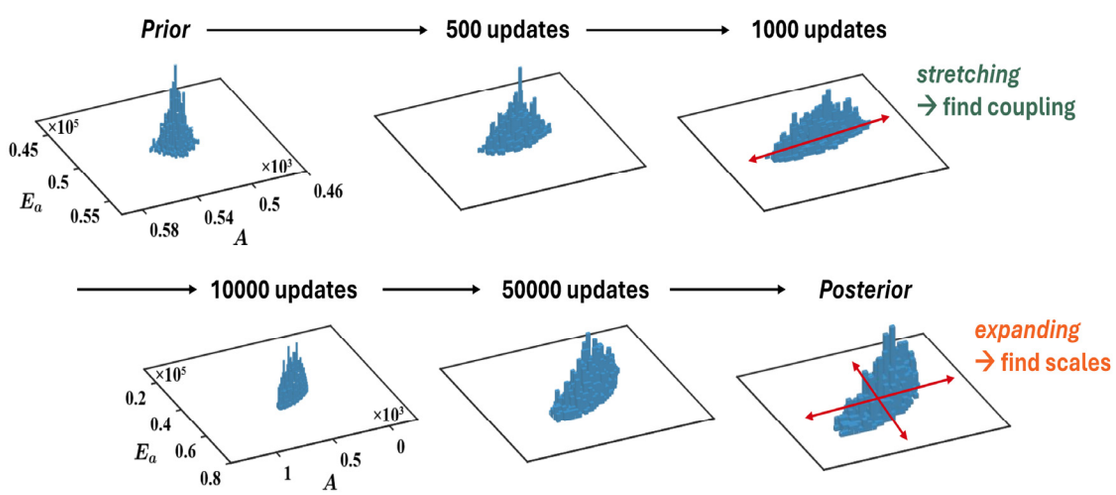


Kim and Deng, in peer review in *Journal of Computational Physics*

29

Our PDE-Constrained Stein Variational Gradient Descent

$$\phi^*(\theta) = \frac{1}{N}\sum_{j=1}^{N}\left[\underbrace{k(\theta_j,\theta)\nabla_{\theta_j}\log p(\theta_j|\mathcal{D})}_{\text{forcing to high probability}} + \underbrace{\nabla_{\theta_j}k(\theta_j,\theta)}_{\text{repulsing}}\right]$$

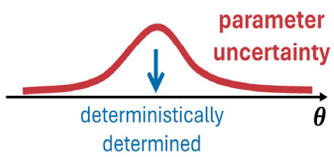


Kim and Deng, in peer review in *Journal of Computational Physics*

30

Uncertainty Quantification for Prediction Reliability

"Experimental data are always noisy."



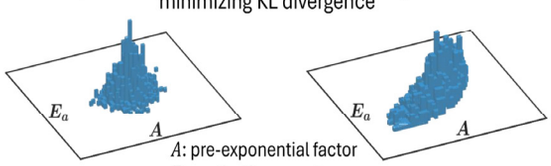
Sampling approach (e.g. MCMC)
– *intractable* with nonlinear PDEs

New PDE-based Stein variational approach

PDE-constrained optimization + Stein variational gradient descent

$$\theta_i^{l+1} \leftarrow \theta_i^l + \eta\phi^*(\theta_i^l)$$

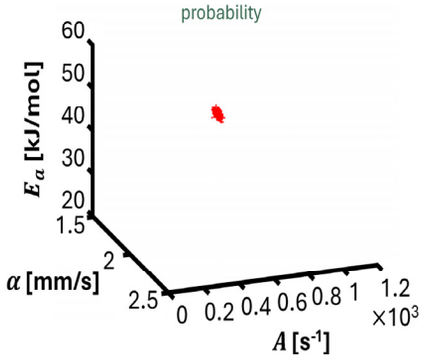
prior → *posterior* (minimizing KL divergence)



A: pre-exponential factor
E_a: activation energy

❑ **Efficient & numerically stable approach for PDEs**

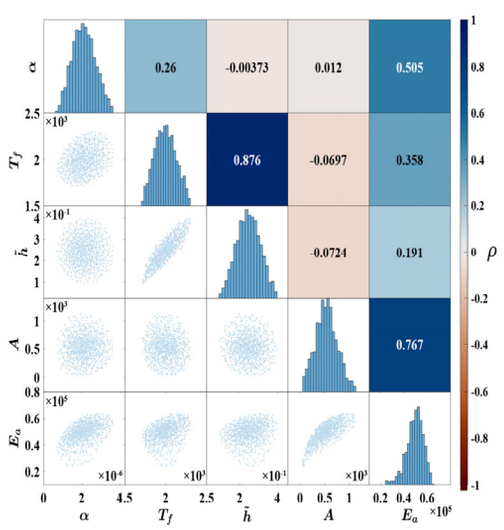
$$\phi^*(\theta) = \frac{1}{N}\sum_{j=1}^{N}\left[\underbrace{k(\theta_j,\theta)\nabla_{\theta_j}\log p(\theta_j|\mathcal{D})}_{\text{forcing to high probability}} + \underbrace{\nabla_{\theta_j}k(\theta_j,\theta)}_{\text{repulsing}}\right]$$



Kim and Deng, in peer review in *Journal of Computational Physics*

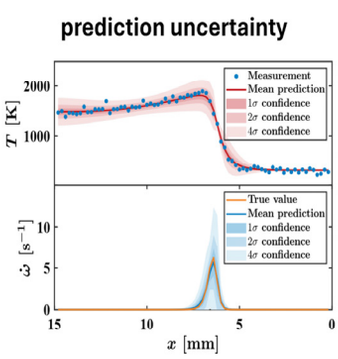
31

Uncertainty Quantification for Prediction Reliability



uncertainty propagation

$$\frac{d\boldsymbol{u}}{dt} = \boldsymbol{f}(\boldsymbol{u}, t, \boldsymbol{\theta})$$



Model parameters

α	thermal diffusivity
T_f	adiabatic flame temperature
$\tilde{h}$	heat transfer coefficient
A	pre-exponential factor
E_a	activation energy

Kim and Deng, in peer review in *Journal of Computational Physics*

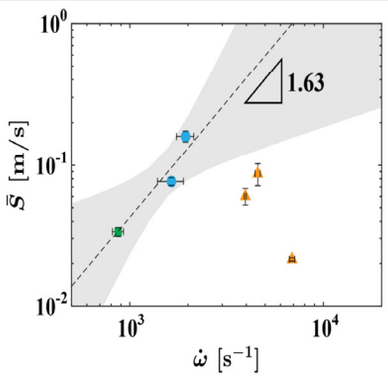
ρ Pearson correlation

32



Theories for Combustion Wave and Flame Instability

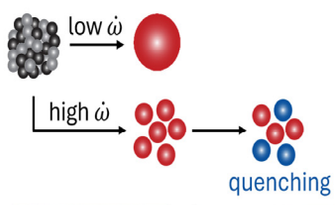
Wave propagation

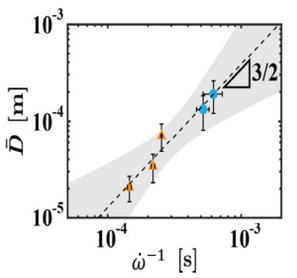


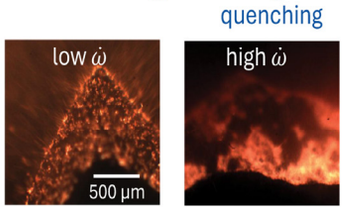
- Nanocomposite: $S \propto \dot{\omega}^{1.63}$
- Laminar premixed theory: $S_L \propto \dot{\omega}^{0.5}$

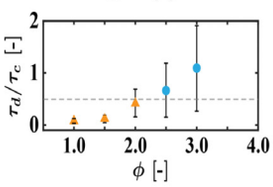
Heterogeneous flame structure and instability

$$\frac{S}{S_L} \sim \frac{A}{A_L} \propto \dot{\omega}^{1.13}$$









❑ **First theoretical analysis for nanocomposite combustion – enabled by an inverse approach**

Kim et al. 2025 *ACS Nano*

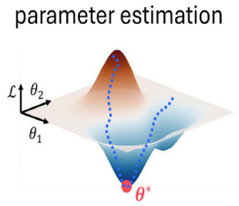
33

Concluding Remarks

fully known ⟵ ***domain knowledge*** ⟶ *unknown*

Model calibration

parameter estimation



$$\rho c \frac{dT(\boldsymbol{r},t)}{dt} = \nabla \cdot [k \nabla T(\boldsymbol{r},t)] + \rho H \frac{d\omega(\boldsymbol{r},t)}{dt}$$

$$\frac{d\omega(\boldsymbol{r},t)}{dt} = [1-\omega(\boldsymbol{r},t)]^n A \exp\left[-\frac{E_a}{RT(\boldsymbol{r},t)}\right]$$

Model construction

known PDEs

$$\rho c \frac{dT(\boldsymbol{r},t)}{dt} = \nabla \cdot [k \nabla T(\boldsymbol{r},t)]$$

\+

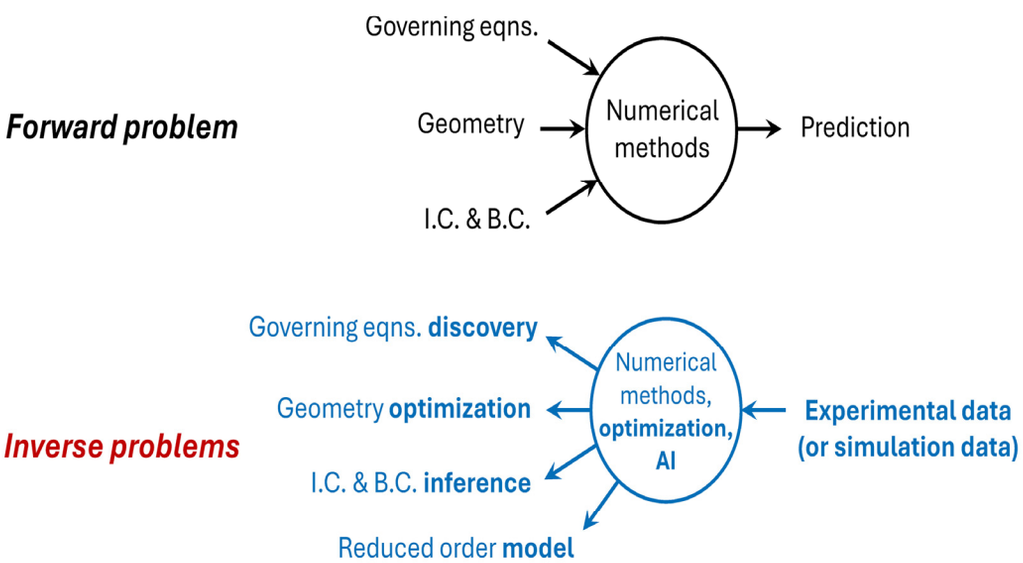


data-driven model

Interpretable modeling can be achieved by PDE-constrained optimization and KAN-ODEs for reaction dynamics.

34

Ongoing ML Work in Our Group



35

Ongoing ML Work in Our Group

Ongoing projects will be briefly shared in the workshop.

- Virtual sensors
- Gradient-based design optimization

36



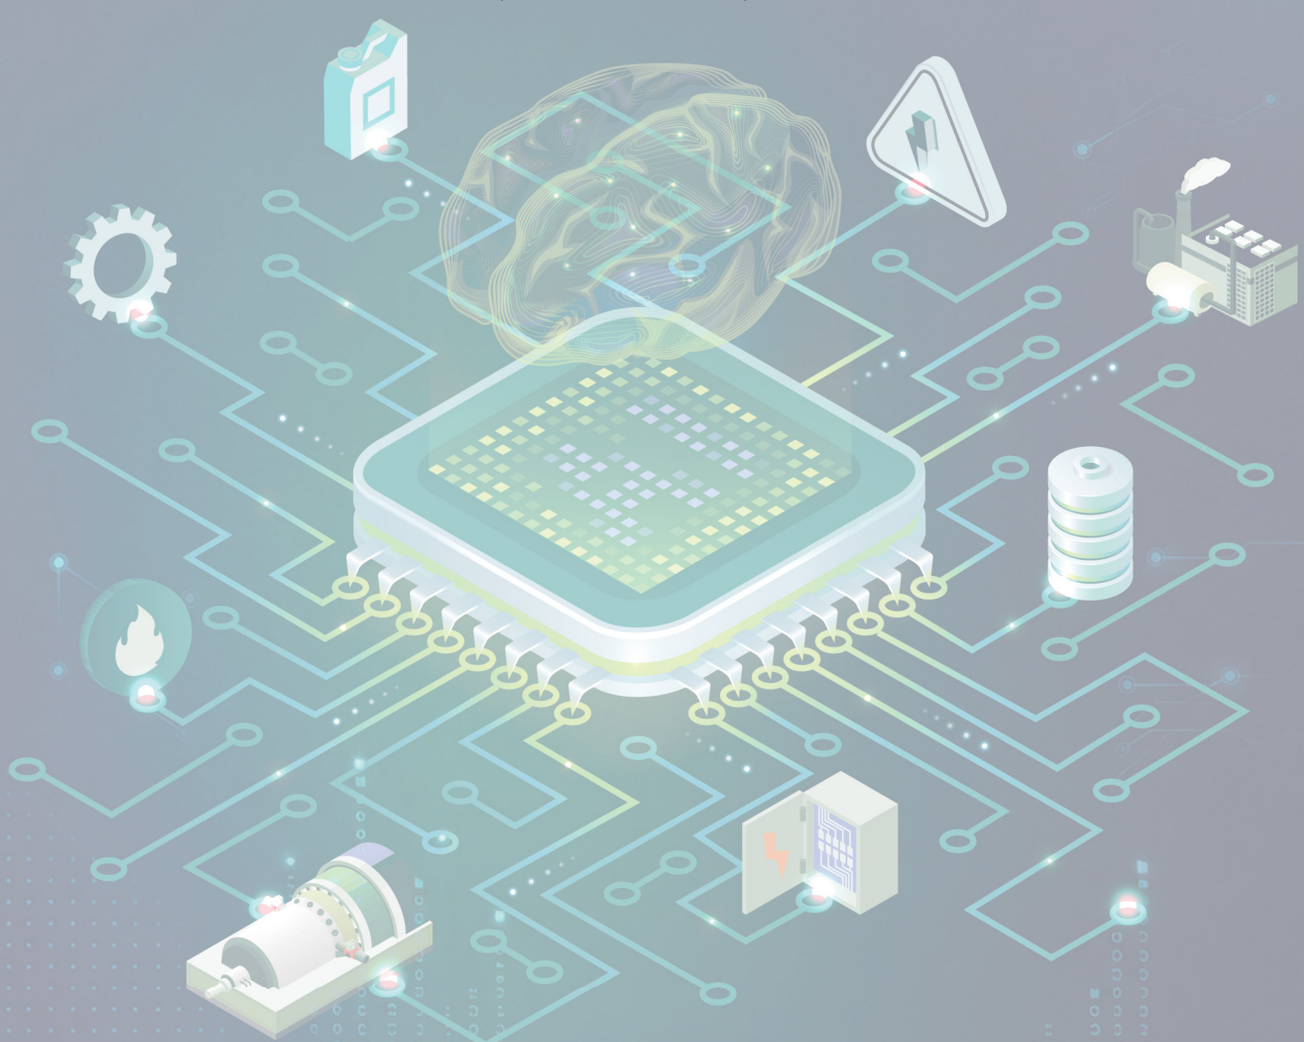
Contact Information

Suyong Kim
(suyong@snu.ac.kr)

Session III

AI 기반 발전용 가스터빈 자동 연소튜닝 개발 방향

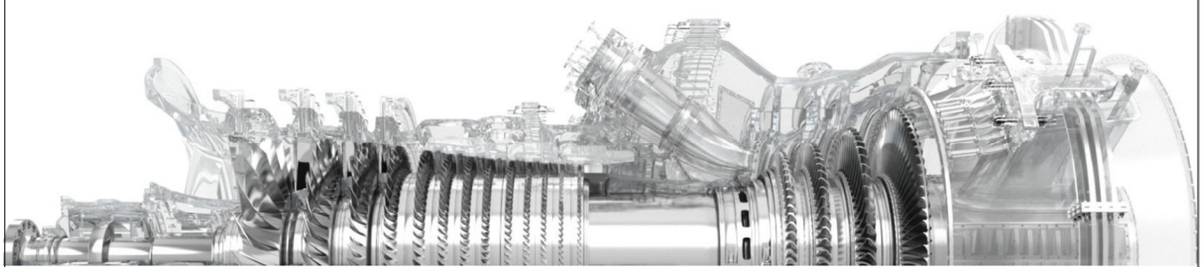
신주곤 수석
(두산에너빌리티)



DOOSAN

발전용 가스터빈 Auto-tuning 솔루션 개발 방향

Confidential



2026. 08. 21

두산에너빌리티 GT연소기개발팀
신주곤 수석

본 문서는 (주)두산에너빌리티 정보자산으로, 승인을 받지 않은 문서의 열람, 수정, 배포, 복사를 금지합니다.
This document is the informational asset of Doosan Enerbility Co., Ltd. Thus, unauthorized access, revision, distribution and copying of this document are strictly prohibited.

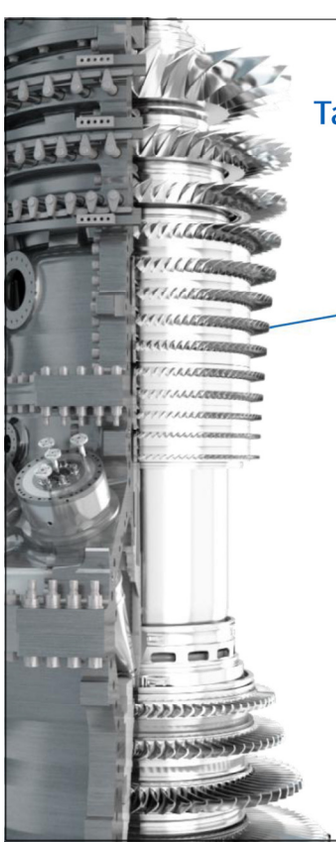


Table of Contents

1. 발전용 가스터빈 연소기의 개발과 운전특성
2. 발전용 가스터빈 연소튜닝
3. 발전용 가스터빈 연소튜닝의 AI 기술접목
4. AI 기반 Auto-tuning 솔루션 개발 방향

1

1. 발전용 가스터빈 연소기의 개발과 운전특성

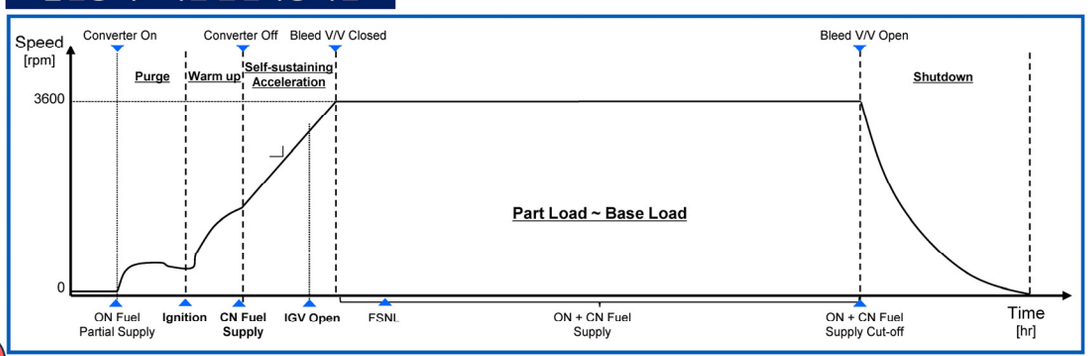
Confidential

발전용 가스터빈 연소기 개발 과정

Concept	Single nozzle test	Single Can Mid-pressure test	Single Can High pressure test	FSFL* Engine Test
• 연소기 노즐 형상정의 : 공력설계/냉각,연소해석	• 단일 노즐 연소특성 분석 :혼합률/가시화/동압/배기가스 (압력조건 < 8barg)	• 1 Can 연소특성 분석 : 온도분포/동압/배기가스 (압력조건 ~8barg)	• 연소기 최종설계 검증 • 1 Can 연소특성 분석 (압력조건 ~25barg)	• GT 성능평가 • GT 부하별 연소튜닝

* FSNL : Full Speed No Load

발전용 가스터빈 운전특성 곡선



* ON: Outer Nozzle / CN: Center Nozzle
* IGV : Inlet Guide Vane

2

2. 발전용 가스터빈 연소튜닝

Confidential

발전용 가스터빈 연소튜닝 [Engine Test]

Ignition Warm up (Speed control)
- 점화성공을 위한 최적의 연소모드 선정(점화 연료유량 확인)
- 안정적인 rpm 상승을 위해 최적의 warm up 연료유량 선정

Self-sustaining Acceleration (Torque control)
- GT 자체적인 회전 승속을 위해 연료유량을 증가
- IGV Open 에 따른 공기량 증가와 함께 연소동압(<100Hz) 감시
- Bleed V/V의 닫히는 구간의 연소동압 / 배기가스 온도분포 감시

Part/Base Load (+Load Rejection)
- GT의 전 부하 구간의 운전성능 확인을 위해 단계적 부하상승[min 10MW/단계]
- GT Turndown 성능을 위한 연료분배비 조정(CO / NOx / 연소동압 감시)
- Base Load 조건의 GT 안정적 성능구현을 위한 연료분배비/최대유량 검증(NOx / 연소동압 감시)
- Load Rejection Test를 수행하여 안정적인 FSNL의 복귀 검증 (연소동압 감시)

Ambient Temp
- 대기의 온도변화(계절변화)에 따른 연료분배비 재조정(NOx / 연소동압 감시)
- Part ~ Base Load 까지 연소튜닝을 수행 후 연소기 노즐별 부하별 운전스케줄을 수정
- 부하 증/감발을 반복하는 Load Swing을 통해 최종 운전스케줄 검증(연소동압 감시)

3

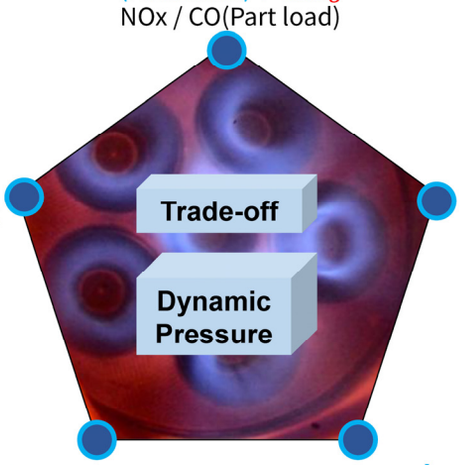
2. 발전용 가스터빈 연소튜닝

Confidential

[Operating Region]

Low emissions
(Performance) ← Tuning
NOx / CO(Part load)

Reliable operation
(Performance) ← Tuning
No Blow-out / Flash Back
Easy Light-off



Operational flexibility
(Performance) ← Tuning
Wide Turn-down
Fuel Flexibility
(Wobbe index)
(Fuel carbon content)

Robust combustor
(Materials)
Chamber Strength and Life

Low pressure loss
(Design)
Minimize negative impact on cycle efficiency

4

2. 발전용 가스터빈 연소튜닝[Doosan Enerbility]

Confidential

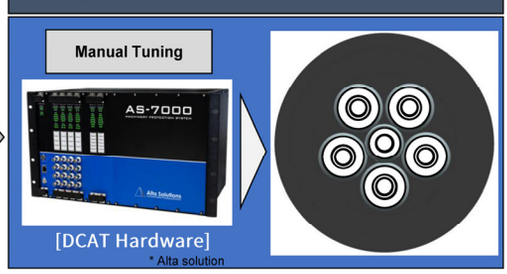
❖ **연소기 연소튜닝**

- GT 부하별 연료분배비를 조정하고 배기가스와 연소동압 특성을 Mapping 하여 최적의 분배조건 확보
- 튜닝우선순위 : Step1. 연료분배비 조정 / Step2. 연료온도 조정 / Step3. 부하이동 혹은 IGV 변동

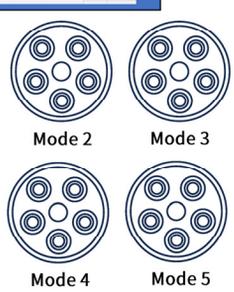
MONITORING Part

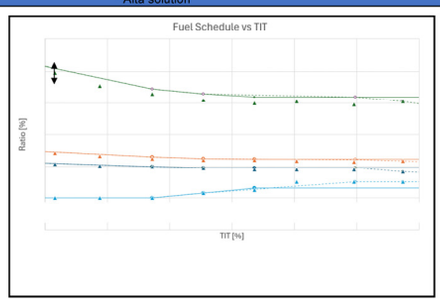


Tuning Part



Band	Frequency (Alarm)





5

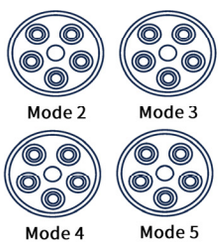
2. 발전용 가스터빈 연소튜닝[Doosan Enerbility]

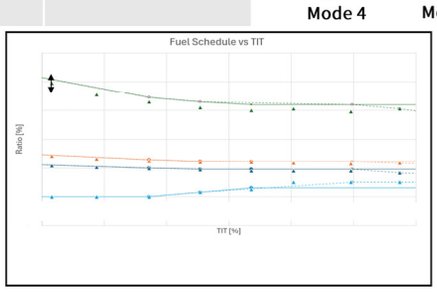
Confidential

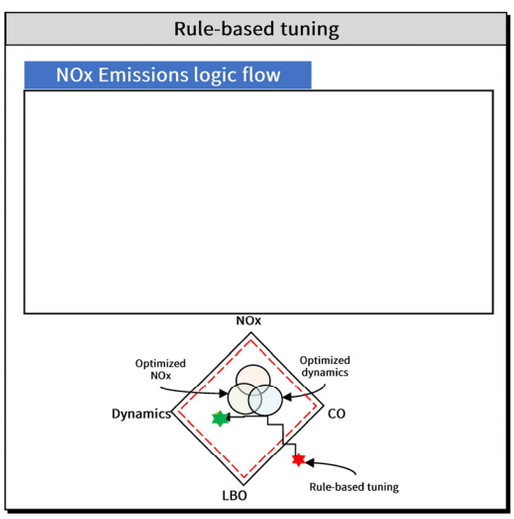
❖ 연소기 연소튜닝

- GT 부하별 연료분배비를 조정하고 배기가스와 연소동압 특성을 Mapping 하여 최적의 분배조건 확보
- 튜닝 우선순위 : Step1. 연료분배비 조정 / Step2. 연료온도 조정 / Step3. 부하이동 혹은 IGV 변동
- 연소튜닝 주기 : (1) 계절변화(여름 / 겨울) (2) 계획예방정비(A, B: 연소기 분해조립 시) → GT 1기 마다 별도 관리
- 튜닝 소요시간 : 22hr/GT (60분/부하, 22개 부하 기준) → 1회 연소튜닝 자업 시 최소 3일 소요
- GT보호용 Tuning Support : DCAT을 통해 실시간 Rule-based tuning → 데이터 감시기반 분배비 조정(최대 4회/변수 이동)

Band	Frequency (Alarm)







6

3. 발전용 가스터빈 연소튜닝의 AI 기술접목

Confidential

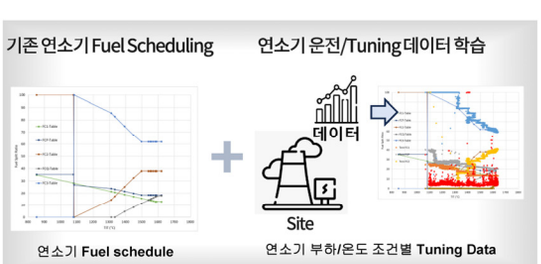
❖ AI 기반 연소튜닝 기술 확보의 필요성

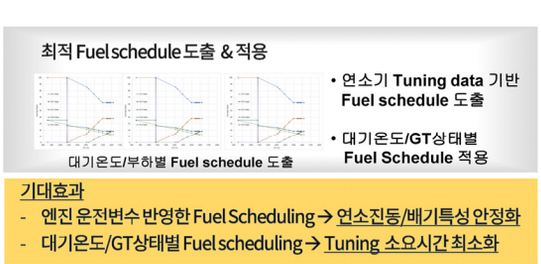
[As-Is]

- 엔지니어 경험에 강한 의존성을 갖고 있어 튜닝 경험/지식의 공유에 제한이 있음
- 발전소 현장에 존재하는 다수의 운전데이터 사이의 Correlation 파악에 제한이 있음
  : 현장에서 연료분배비 선정에 있어 활용하는 변수는 제한적임(연소동압 / NOx / 배기가스 온도변화)
- Rule-based tuning 은 특정시점을 기준으로 보수적인 튜닝결과만을 도출함
  : 현시점의 최적의 운전조건을 구현하는 연료분배비는 알 수 없음

[To-Be]

- 연소튜닝 시 확보된 운전데이터 (대기조건, 연소동압, 배기가스 정보 등)의 다변수 간의 복잡한 비선형 관계 학습
- 현재 시점의 대기조건과 GT 상태를 입력 → 연소진동/배출가스 모두 만족하는 부하별 최적 Fuel schedule 도출
  : 연소튜닝 시 튜너의 의존성을 낮추며 튜닝 소요시간 축소 및 현장 의사결정 지원이 가능한 Auto-tuning system 구축





7

3. 발전용 가스터빈 연소튜닝의 AI 기술접목

Confidential

❖ AI 기술 단계별 로드맵

[1단계] AI 도입 초기: 현장 자료 DB화 (2026~2028)

주요내용	대상기술	목표
DB검증	• GT Auto-tuning system - 최적 Fuel Schedule 도출	• AI 학습을 위한 DB 타당성 검토 • PoC 기반 가능성 검토

[2단계] AI 활용 본격화: 학습형/실물 AI 도입 (2028~2030)

학습형 AI 도입 — • 예측 모델의 개발 및 학습 - 부하별 최적 Fuel Schedule 도출 → 예측 AI 모델 개발 및 학습

[3단계] AI 도입 성숙: Digital Twin을 통한 예측(2030~2032)

현장 자료 (DB) + 학습형 AI (모델) = Digital Twin (생성형 AI) → 예상 데이터 도출

Site 운전데이터 학습

기대효과
- PJT 리스크 사전관리
- 주요인자의 관리 통한 가스터빈 품질문제 개선

❖ AI 기반 Auto-tuning 솔루션 개발 계획 [1단계]

[Step1] 데이터 수집 및 정제
- 발전소 현장 운전데이터 파싱
  : 대기조건, Fuel Split, NOx/CO, 동압 등
- 결측치 및 이상치 제거
  : 센서 고장, 정지/트립 구간 데이터 필터링
- 데이터 타임 스탬프 동기화
  : 대기 센서 vs GT 내 센서 간의 Delay 매칭

[Step2] 데이터 타임프레임 및 피처 엔지니어링
- 입력 변수(Input Features) 정의
  : GT부하, 연소기 압력, NOx/CO, 배기온도, 동압 등 40여개
- 출력 변수(Target Label) 정의
  : 튜닝 이력 기준 부하 vs Fuel schedule
- 제약 조건(Constraints) 정의
  : 주파수 범위별 동압 기준치, NOx/CO 배출 및 온도차이 기준치

[Step3] AI 알고리즘 선정 및 모델 학습
- 머신러닝 알고리즘 적용
  : XGBoost, Random Forest, LightGBM 등
- AI 역문제(Inverse Problem) / 대리모델(Surrogate Model)

[Step4] 검증 및 사용자 인터페이스(UI) 구현
- 교차 검증(Cross-validation) 기반 예측 오차(R^2, RMSE) 평가
- 현재 조건에 최적화된 부하 vs Fuel schedule Table 출력

8

4. AI 기반 Auto-tuning 솔루션 개발 방향

Confidential

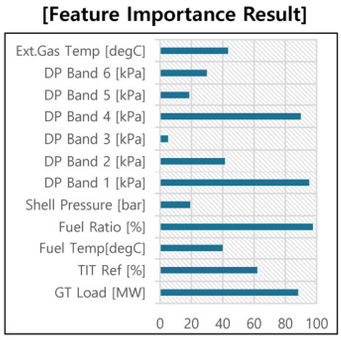
❖ Auto-tuning 솔루션 구축을 위한 핵심 모델과 기능 정의

Part1 SPEED — ① LightGBM
1차 스크리닝 / 변수 중요도 추출
초고속 학습으로 초/분 단위 운전데이터를 빠르게 처리하고 변수 중요도를 추출

Part2 ROBUSTNESS — ② Random Forest
검증 · 이상치 탐지
데이터 정제 단계의 이상치를 판별하고 다른 모델 예측 결과를 검증

Part3 ACCURACY — ③ XGBoost
정밀 예측 대리모델 엔진
높은 예측 정밀도와 과적합 방지 기능으로 동압(RMS)·NO_x/CO 예측의 메인 엔진 역할

[Feature Importance Result]



[순방향 대리모델 (Surrogate Model)]

[Input]
: 대기조건
: GT Load
: Fuel Ratio
→ XGBoost MODEL

[Output]
: Band 별 연소동압 예측 크기
: 배기가스 NOx / CO 예측
: 터빈 후단 배기가스 온도분포 예측

[역문제 최적화 (Inverse Problem)]

[Input]
: 동압기준
: NOx 기준
: Ext. Temp.
→ 최적화 알고리즘

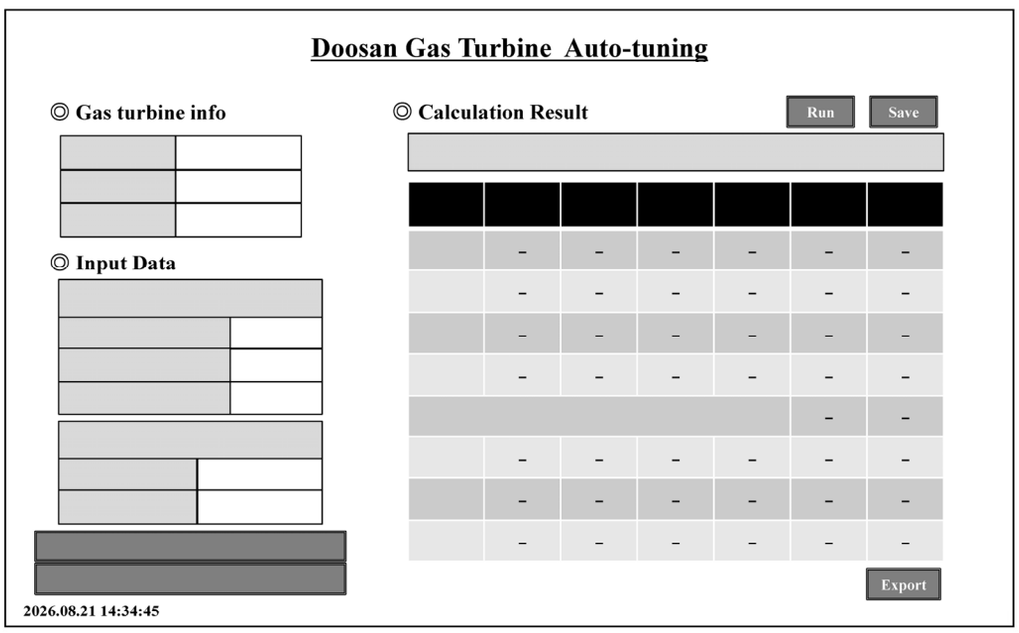
[Output]
: 부하별 최적 Fuel Schedule Table
: Band연소동압/ NOx 등 주요감시 대상

9

4. AI 기반 Auto-tuning 솔루션 개발 방향

Confidential

❖ 1단계 Auto-tuning 솔루션 UI (안)



10

발전용 가스터빈 Auto-tuning 솔루션 개발 방향

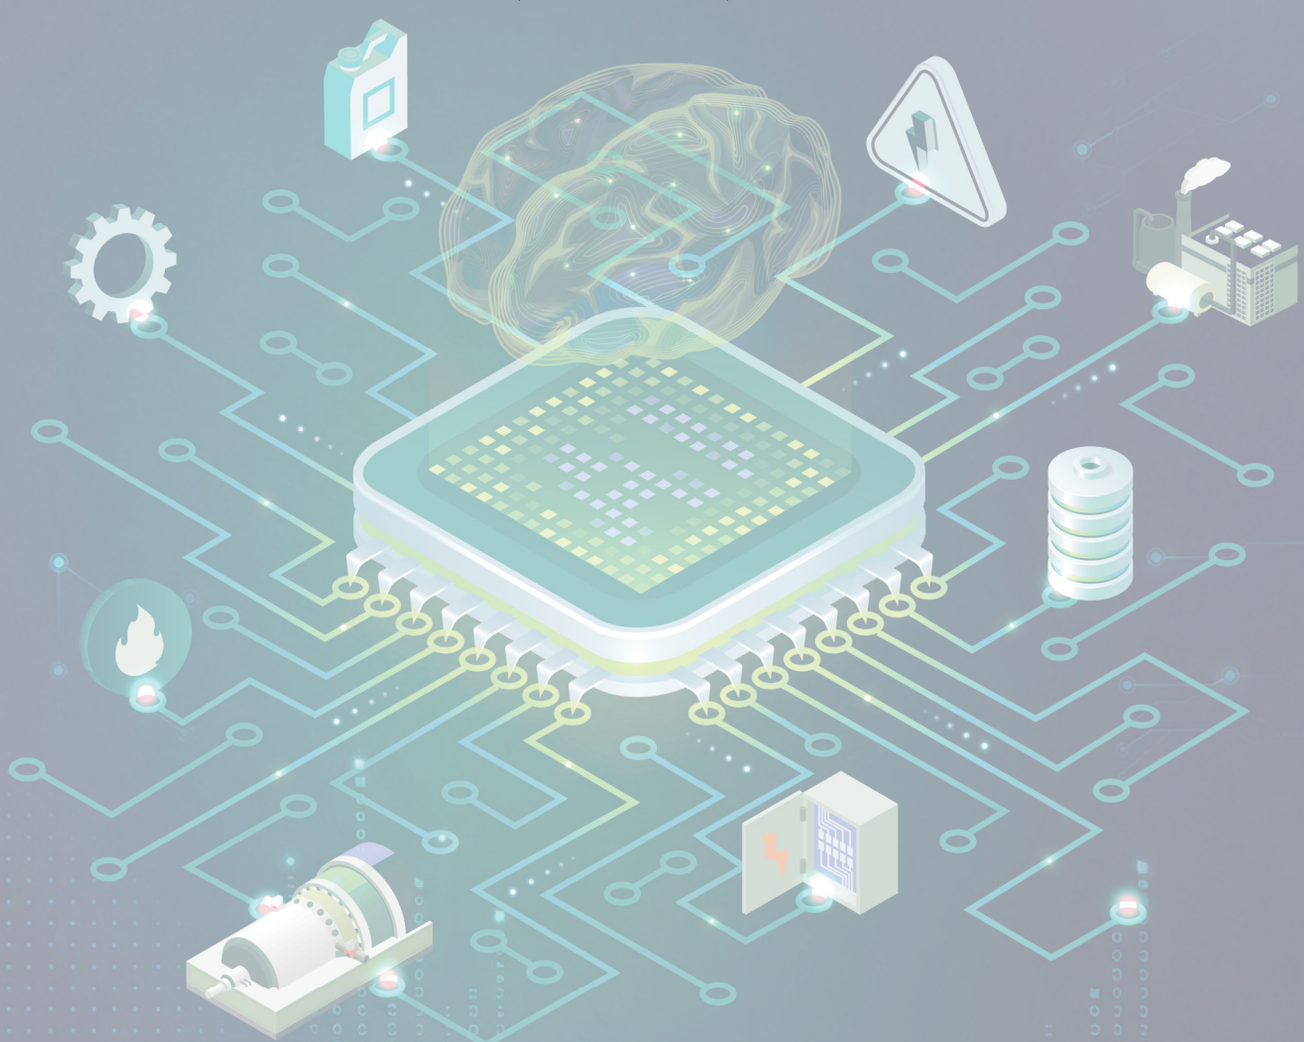
감사합니다

11

Session III

AI 기반 석탄/바이오매스 연소설비 연료 물성 및 운전 성능 예측

류창국 교수
(성균관대학교)





AI 기반 연소기술 특별 워크샵

AI 기반 석탄/바이오매스 연소설비 연료 물성 및 운전 성능 예측

26.08.21

류 창 국

성균관대학교 기계공학부

E-mail: cryu@skku.edu

http://eelab.skku.edu/

Unique Origin Unique Future

(사) 한국연소학회 The Korean Society of Combustion

Outline

석탄/바이오매스 연소 설비 개요

1. MLP : 바이오매스 투입량 및 물성 예측 소프트센서 개발

2. GRU + Transformer hybrid: 석탄화력 보일러 성능의 장주기 예측

결론

석탄 / 바이오매스 연료 물성

3

□ 석탄 / 바이오매스: 대표적인 발전 및 산업용 고체연료
- ○ 고정된 화학구조 없고 균질하지 않음
- ○ 연소 과정: 건조 → 열분해(pyrolysis) → 촤(char) 전환
- ○ 탄화도에 따른 구분: 바이오매스 → 이탄 → 갈탄 → 아역청탄 → 역청탄 → 무연탄 (갈탄 → 무연탄: 석탄)


Wood pellet


Wood chip

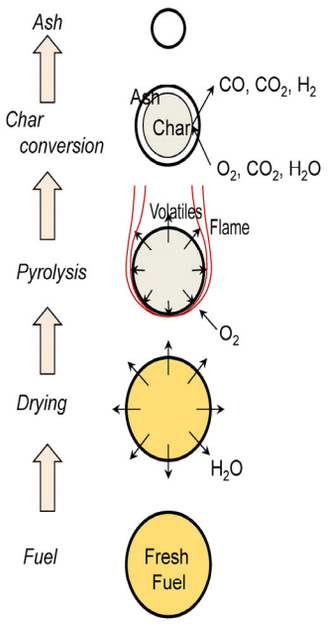

Coal

□ 연료 특성에 대한 표준 분석

Moisture (수분)	Combustible (가연분)					Ash (회분)
	Volatile matter (휘발분)		Fixed carbon (고정탄소)			
	C	H	O	N	S	

- ○ 공업 분석(Proximate analysis): 수분, 휘발분, 고정탄소, 회분
- ○ 원소 분석(Ultimate analysis): C, H, O, N, S
- ○ 분석 정밀도보다 **대표성 있는 시료 채취가 더 중요**

석탄/바이오매스 연소과정

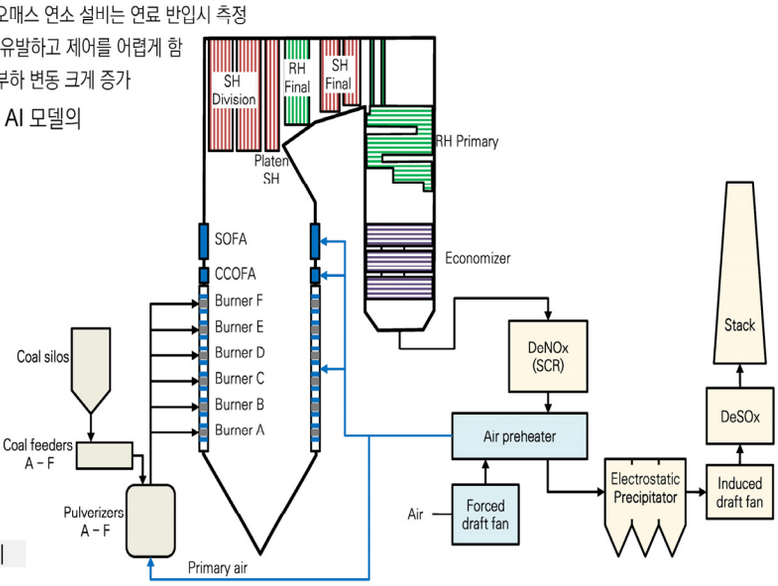


고체연료 연소설비

4

□ 고체연료 연소설비의 주요 특징
- ○ 물리화학적 현상과 응답 시간이 다른 설비들의 통합 시스템
  - • 연료 피더, 공기 예열 공급, 연소로 + 보일러, 배가스 정제 설비(탈질, 탈황, 집진), 증기 사이클/터빈
- ○ 연료 투입량의 정확한 측정이 어렵고, 연료 물성 변동은 측정 불가능
  - • 연료 조성 분석: 석탄 화력은 일 1회, 바이오매스 연소 설비는 연료 반입시 측정
  - • 연료 물성과 투입량 변화는 성능의 변동을 유발하고 제어를 어렵게 함
- ○ 발전 설비의 경우 재생에너지 발전량에 따른 부하 변동 크게 증가

➔ 계측 자료와 물리적인 원리를 기반으로 한 AI 모델의 활용 가능성 매우 높음:
1. 연료 물성 실시간 예측
2. NOx 저감 및 보일러 효율 향상
3. 부하 변동에 따른 운전 장애 최소화



석탄화력 설비 구성 예시



연소 설비 관련 주요 AI 모델

5

□ 고체연료 연소설비에 활용되는 주요 AI 모델 아키텍처

모델	특징	활용 분야
Convolutional neural network (**CNN**)	▪ 국부적인 1차원(시계열), 2차원(이미지) 데이터의 패턴 추출에 효과적	화염 등 상태 진단, 이상 감지 등
Multi-layer perceptron (**MLP**)	▪ 여러 입, 출력 변수 사이의 비선형적 정적(static)인 관계 학습	운전 변수에 따른 성능, 연료 물성 예측 등
Recurrent neural network (**RNN**)	▪ 시계열 데이터의 시간적 의존성 학습 ▪ 대표 모델: Gated recurrent unit (GRU), Long short-term memory (LSTM)	운전 변수의 변화에 대한 연소 성능의 시간별 동적 거동 예측
Temporal convolutional network (**TCN**)	▪ 1D causal convolution을 이용해 과거 시계열의 패턴과 시간 지연 관계를 학습. ▪ 시계열 병렬 처리로 학습 안정적, 긴 입력 구간에 유리	보일러의 다변량 시계열 예측 및 장주기 (long-horizon) 성능 예측
Transformer	▪ Self attention mechanism 통해 시계열 내 서로 떨어진 시점 간의 중요도와 장거리 의존관계를 직접 학습 ▪순자 연산에 의존하지 않아 긴 입력 시퀀스 및 다변량 데이터 처리에 효과적	운전 변수의 변화에 대한 다단계, 장주기 (long-horizon) 성능 예측

고체연료 연소설비 대상 AI 모델 개발 사례

6

Part 1.
연료 투입량 및 물성 예측 소프트센서 개발

순환유동층 연소 시스템
(Circulating fluidized bed)

계측 자료
(배가스 조성, 공기량, 가스 온도, 보일러 전열량 등)

↓

MLP

↓

연료 투입량, 조성
(수분, CHONS, 회분 함량, 발열량, 과잉공기비 등)

Part 2.
석탄화력 보일러 성능 장주기 예측

500 MWe 미분탄 화력
(Pulverized coal boiler)

미래 운전 시나리오,
최근 운전 및 계측 이력

↓

GRU-Transformer hybrid

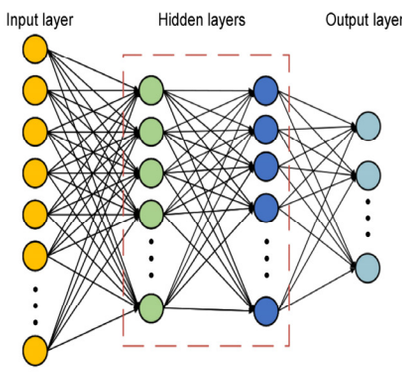
↓

미래 20분간의
보일러 출구 가스 온도, NOx, O_2 농도

7

Part 1

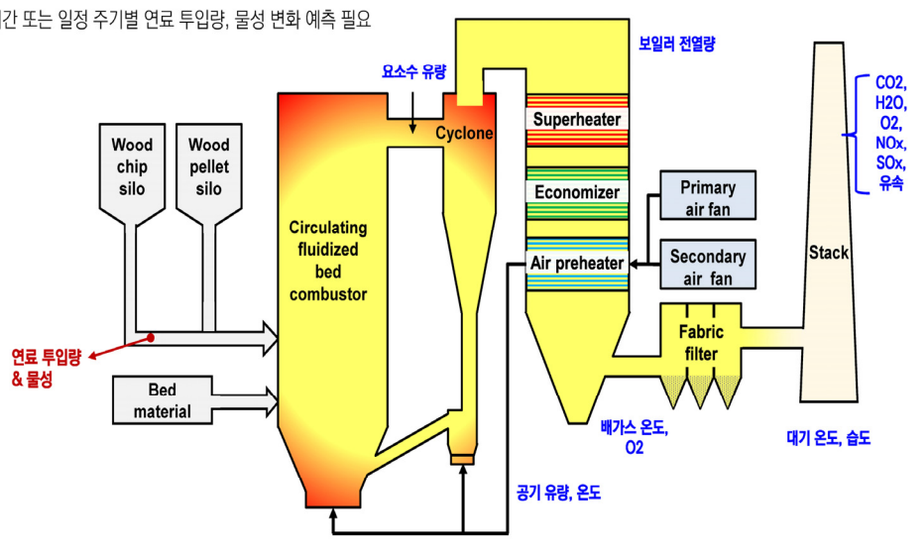
MLP: 연료 투입량 및 물성 예측 소프트센서 개발



8

1 대상 설비

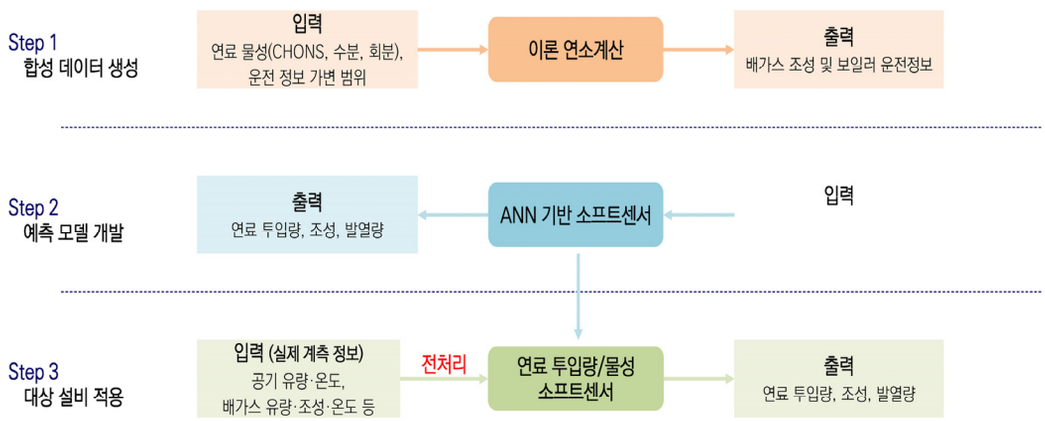
- 대상설비: 253 MW_{th} 순환유동층 보일러
  - 연료: 우드펠릿 + 우드칩 혼합
- 연료 투입량 및 물성 예측 소프트센서 개발
  - 연료 혼합비 일정하지 않고, 우드칩의 물성 변화가 매우 큼
  - 연료 질량 유량의 직접 계측이나 제어 없음
  - ➔ 실시간 또는 일정 주기별 연료 투입량, 물성 변화 예측 필요





1 모델 개발 절차

9



1 합성 데이터 생성: 주요 계산식 #1

10

□ 연소 반응 물질수지

$$(H_2O)_w\, C_xH_yO_zN_nS_s + \alpha(1+\lambda)(O_2 + aH_2O + bN_2)$$
$$= xCO_2 + [w + \frac{y}{2} + a\alpha(1+\lambda)]H_2O + \alpha\lambda O_2 + sSO_2 + nf_{NOx}NOx + \left[b\alpha(1+\lambda) + \frac{n(1-fNOx)}{2}\right]N_2$$

- w, x, y, z, n, s: 연료 조성 계수, α: 연료 1몰당 필요 산소량, λ: 과잉공기비, f_{NOx}: Fuel-N의 NOx 전환율

□ 보일러 열수지

$$\dot{m}_{fuel}\int_{298}^{T_{fuel}} C_{p,fuel}\,dT + \dot{m}_{air}\int_{298}^{T_{air}} C_{p,air}\,dT + \dot{m}_{fuel}LHV = \dot{Q}_{steam} + \dot{Q}_{loss} + \sum \dot{m}_p \int_{298}^{T_{exit}} C_{p,p}\,dT + \dot{m}_{ash}\int_{298}^{T_{exit}} C_{p,ash}\,dT$$

연료 현열 | 공기 현열 | 발열량 | 보일러 전열량 | 열손실 | 출구 배가스 현열 | 회분 현열

□ 고위발열량 (HHV), 저위발열량(LHV)

$$HHV\ [MJ/kg] = 0.3491C + 1.1783H + 0.1005S - 0.1034O - 0.0151N - 0.0211Ash$$ Channiwala & Parikh 상관식

$$LHV\ [MJ/kg] = HHV - 2.4419(M + 9H)/100$$

연료 조성: Moisture, C, H, O, N, S, Ash
연료 투입량: $\dot{m}_{fuel}$
과잉공기비: λ
외기 온도: T_{atm}, 상대습도
공기 예열 온도: T_{air}
보일러 출구 배가스 온도: T_{exit}
Fuel-N의 NOx 전환율 :f_{NOx}

→ 열 및 물질수지 합성 데이터 →

공기 유량: $\dot{V}_{air}$
배가스 조성: CO2, H2O, O2, NOx, SOx
배가스 유량: $\dot{V}_{product}$
전열량: $\dot{Q}_{steam} + \dot{Q}_{loss}$

1 합성 데이터 생성: 주요 가정 및 입력값 범위

□ 연료 조성 범위
- ㅇ C, H, N, S, Ash, Moisture: 공업/성분 분석값 기준 Min/Max 확장
- ㅇ O = 100 – C – H – N – S

□ 운전부하 범위: 80~100%

□ 운전변수 범위: 측정값 기준 최소-최대

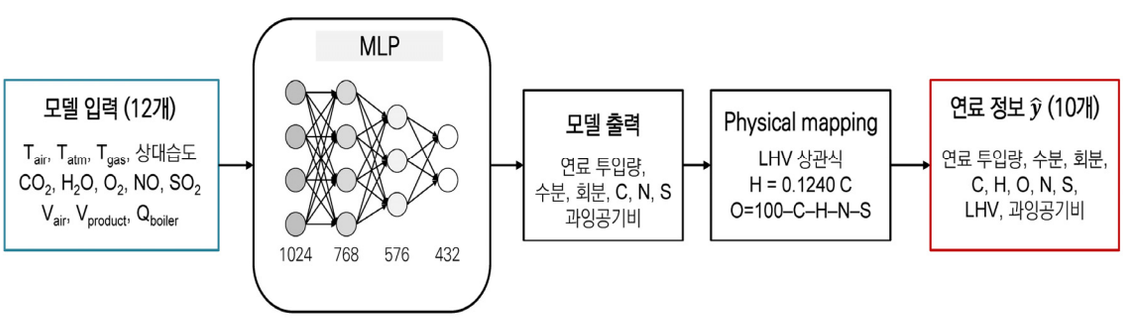
Parameter		Unit	Min	Max
연료 조성	C	[%daf]	47.08	54.37
	N		1	2.1
	S		0.01	0.26
	Ash	[%wet]	0.3	11.24
	Moisture		5.4	24.2
운전 변수	보일러 출구 가스 온도	[˚C]	280	350
	연소공기 온도		225	270
	외기온도		-10	40
	상대습도	[%]	5	100
	연료 투입량	[kg/s]	15	22
	과잉공기비		0.09	0.23

□ 주요 가정
- ㅇ 연료 H/C 질량비 고정: H/C = 0.1240
  - 합성 데이터 생성 시 H = 0.1240 C로 종속 산정
  - C와 H의 비물리적 조합 방지 및 연료 조성 일관성 확보
- ㅇ Fuel-N의 NOx 전환율(f_{NOx}): 4.7% (설계값)
- ㅇ 연료 내 황(Fuel-S)은 전량 SO_2로 전환 가정
- ㅇ 보일러 열손실
  - 방열손실: 0.239% (설계값)
  - 미연탄소 손실: 0.700%(참고문헌1)

□ 합성 데이터 생성
- ㅇ 데이터 수: 백만개
- ㅇ 데이터셋 분할: Train 80%, Validation 10%, Test 10%

[1]Ke et al., Journal of the Energy Institute, 105 (2022) 415–423.

1 ANN 개발: 모델 구조



□ 학습 설정
- ㅇ 입력 Gaussian noise: σ=0.005
- ㅇ 총 손실함수: Property, Physics, Local consistency의 가중합
  - Property loss (연료 물성 오차): clean/noisy 예측값을 모두 정답 Y에 일치
  - Physics loss (물리 재구성 오차): 예측 연료상태를 열·물질수지 함수모델 F(·)에 재입력
  - Local consistency loss (국소 일관성): 입력 noise 전후 예측값의 변화 억제
- ㅇ 최적화 알고리즘: AdamW optimizer

$$L_{total} = L_{property} + 0.1L_{physics} + 0.05L_{local}$$

$$L_{property} = \frac{1}{2}[MSE_{std}(\hat{y}_c, y) + MSE_{std}(\hat{y}_n, y)]$$

$$L_{physics} = \frac{1}{2}[Huber_{std}(F(\hat{y}_c), x_c) + Huber_{std}(F(\hat{y}_n), x_c)]$$

$$L_{local} = MSE_{std}[\hat{y}_n, stopgrad(\hat{y}_c)]$$

$$x_n = x_c + \varepsilon,\ \varepsilon \sim N(0, 0.005^2\mathbf{I})$$

· x_c: 원본 표준화 입력
· x_n: Gaussian noise가 추가된 입력
· $\hat{y}_c = f_\theta(x_c),\ \hat{y}_n = f_\theta(x_n)$

$$Huber_\delta(r) = \begin{cases} \frac{1}{2}r^2, & |r| \le \delta \\ \delta\left(|r| - \frac{1}{2}\delta\right), & |r| > \delta \end{cases}$$

· $r = \hat{y} - y,\ \delta = 1.0$



1 ANN 개발: 예측 성능 평가방법

□ 평가 방법

○ MAE (Mean absolute error, 평균 절대 오차)

$$MAE = \frac{1}{n}\sum_{i=i}^{n}|y_i - \hat{y}_i|$$

○ MAPE (Mean absolute percentage error, 평균 절대 백분율 오차)

$$MAPE = \frac{100\%}{n}\sum_{i=i}^{n}\left|\frac{A_t - Ft}{A_t}\right|$$

○ RMSE (Root mean squared error, 평균 제곱근 오차)

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=i}^{n}(y_i - \hat{y}_i)^2}$$

○ R^2 score (R-squared, 결정계수)

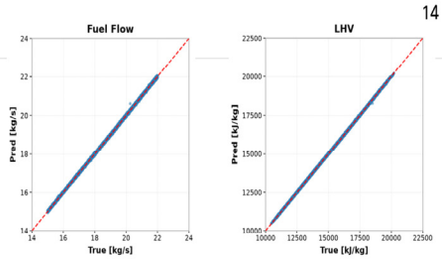
$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2}$$

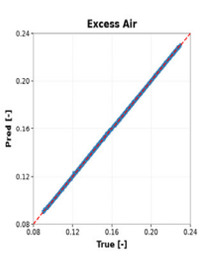
1 합성 데이터 기반 예측 성능

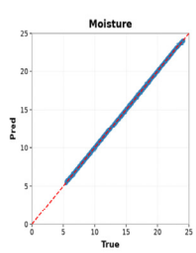
□ 모든 출력 변수에서 R2 0.999 수준의 높은 예측 성능

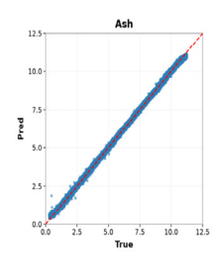
○ Ash는 가장 큰 상대오차를 보이지만, 절대오차로는 0.061 wt.% 수준

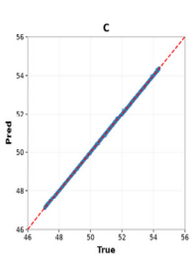
예측변수	MAE	RMSE	MAPE%	R^2 점수
C	0.009	0.011	0.017	0.999
H	0.003	0.004	0.045	0.999
O	0.009	0.012	0.022	0.999
N	0.007	0.009	0.542	0.999
S	0.001	0.001	0.927	0.999
Moisture	0.042	0.054	0.330	0.999
Ash	0.061	0.081	2.556	0.999
Fuel flow	0.014	0.019	0.078	0.999
LHV	13.704	17.809	0.092	0.999
Exces air	0.001	0.001	0.143	0.999

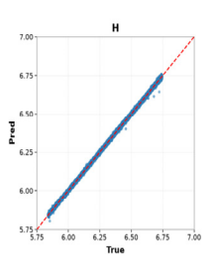


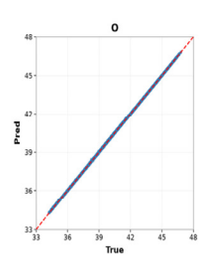


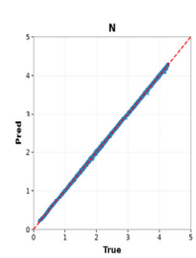


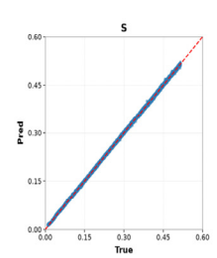












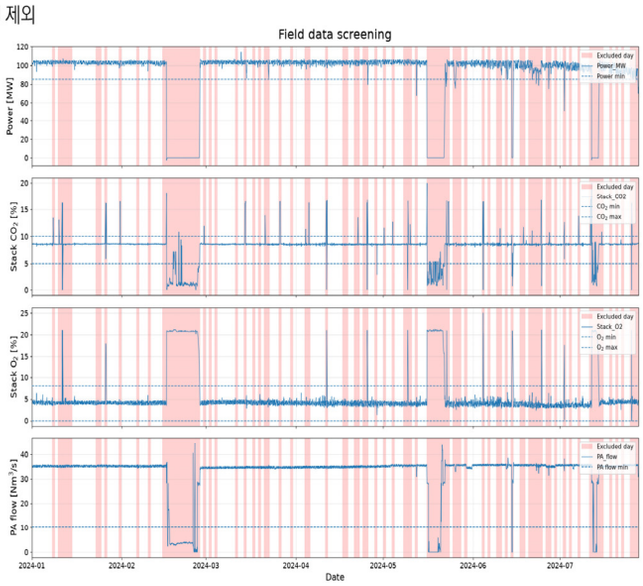
1 대상 설비 적용: 현장 데이터 전처리

□ 취득 데이터
- ○ 데이터: 300,960 points(209일 (2024.01.01-2024.07.27), 1분 간격, 30 variables)

□ 데이터 필터링: 운전·계측 이상 구간에 대한 screening
- ○ 1일 1,440 분 중 이상/결측 데이터가 28 분(2%) 초과 시 해당 일 제외
- ○ 이상/결측 판단 기준
  - 터빈 출력 > 85 MWe
  - SNCR 후단 NO: 0~60 ppm
  - Stack CO_2: 5~10%
  - Stack O_2: 0~8%
  - PA flow > 10 Nm^3/s
  - $Stack_{gas\ velocity}$ > 15 m/s
  - T_{gas} > 250°C 등
- ○ 최종 115 / 209일 유효 데이터 확보 (55.0%)

□ 데이터 전처리
- ○ O_2 농도를 기준으로 한 보일러 출구 가스 조성 계산
- ○ 스팀 물성 → 보일러 전열량 계산 등

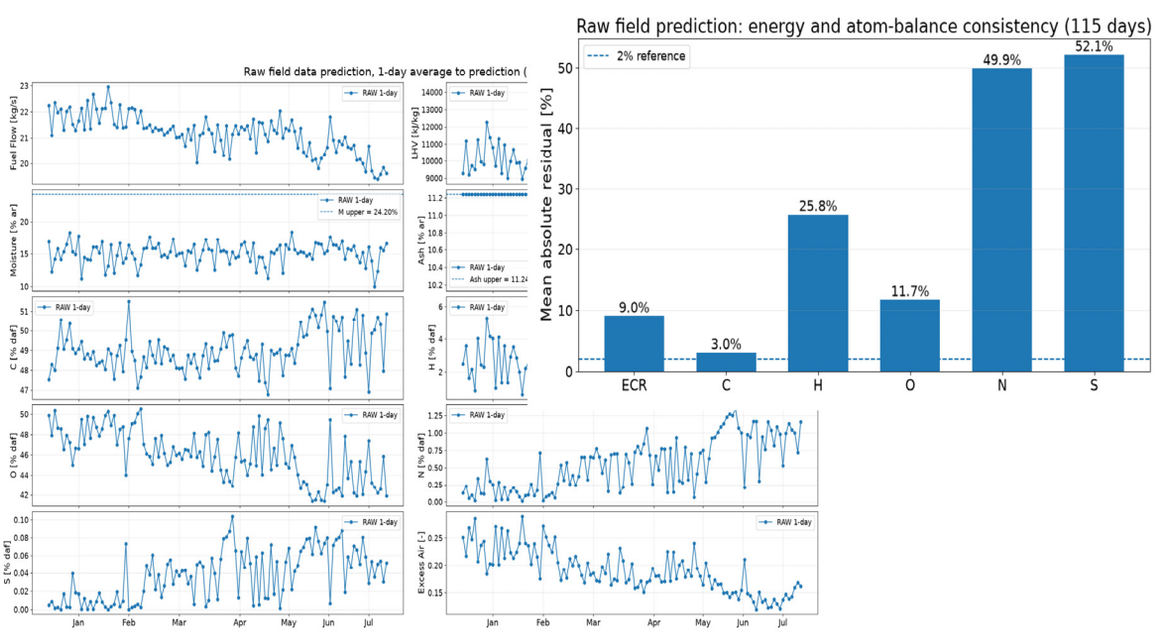
□ 현장 데이터 예측 단위
- ○ 이상·결측 및 일중 운전변동을 고려하여 1일 가중평균 데이터로 ANN 예측 수행



1 대상 설비 적용: 현장 Raw 데이터 예측 결과

□ 연료 투입량 및 물성 예측 결과 일별 변동이 크고 만족스럽지 못함

□ Energy consistency ratio(ECR) 및 H/O/N/S balance에서 상당한 불일치 확인





1 대상 설비 적용: 계측값 보정

□ 열 및 물질수지 정합성을 높이도록 보일러 전열량을 제외한 11개 입력값에 대한 보정 계수(α_i) 도출

$$X_{corr,i} = X_{raw,i}\alpha_i$$

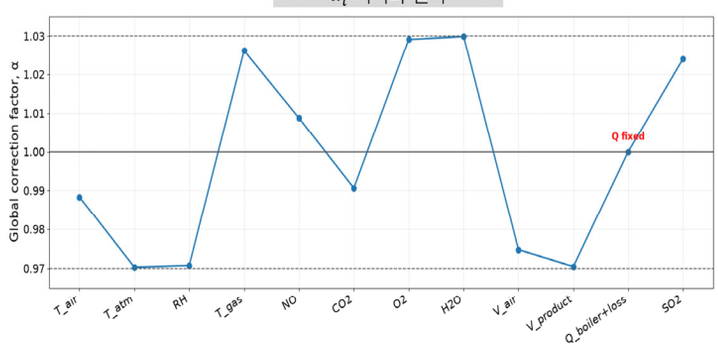
- 보정 계수(α_i) 최적화: Global 최적화 + Local 정밀 최적화 기법을 결합하여 도출
- 최적화 범위 (3% 이내 보정): $0.97 \leq \alpha_i \leq 1.03$
- 최적화 손실 함수:

$$L_{total} = L_{FWD} + L_{ECR} + L_{CHO} + 0.1L_{NS} + L_{Fuel} + 0.01L_{\alpha}$$

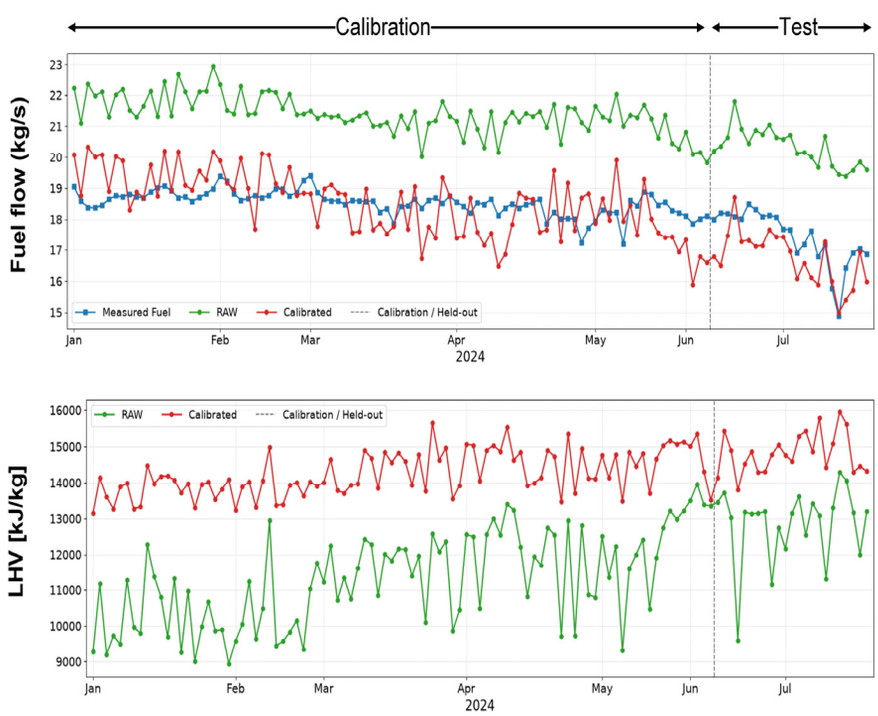
- 92일 자료 활용 보정, 23일 대상 평가

항목	내용	가중치
FWD	ANN 예측 물성으로 계측 변수 재구성	1
ECR	Energy balance	1
CHO	C/H/O atom balance	1
NS	N/S balance	0.1
Fuel	일별 실측 fuel flow와 예측값 비교	1
α	과도한 입력 보정 억제	0.01

α_i 최적화 결과

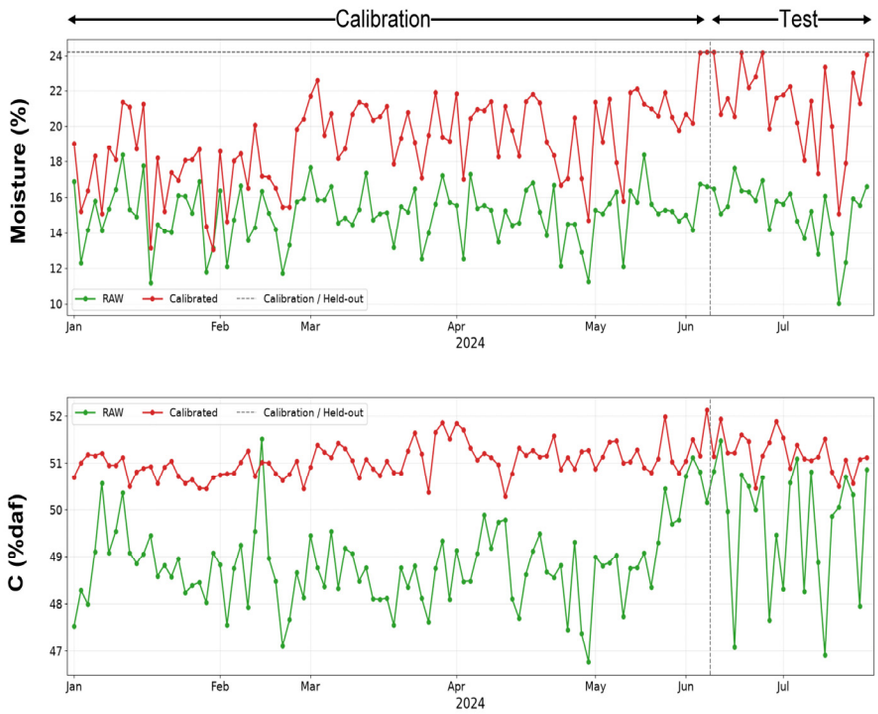


1 대상 설비 적용: 보정 전후 연료 투입량, LHV 비교



19

1 대상 설비 적용: 보정 전후 수분, C 함량 비교



20

1 대상 설비 적용: 보정 전후 O, N 함량 비교



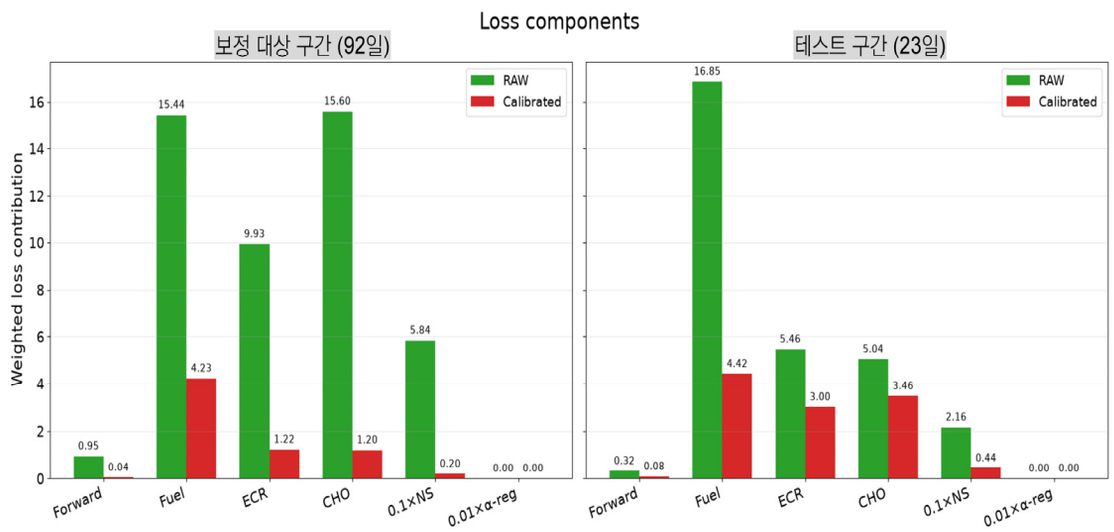


21

1 대상 설비 적용: 보정에 따른 효과 비교

- 입력 변수 보정 후 연료 투입량 차이 및 열/물질수지 오차 크게 감소
- Test 구간에서도 개선 경향이 유지되어 보정 효과의 일반화 가능성 확인

→ **현장 데이터의 계측 오차 영향을 감소시키고, 예측성과 물리 일관성을 동시에 개선**



22

Part 2

GRU + Transformer hybrid: 석탄화력 보일러 성능 장주기 예측

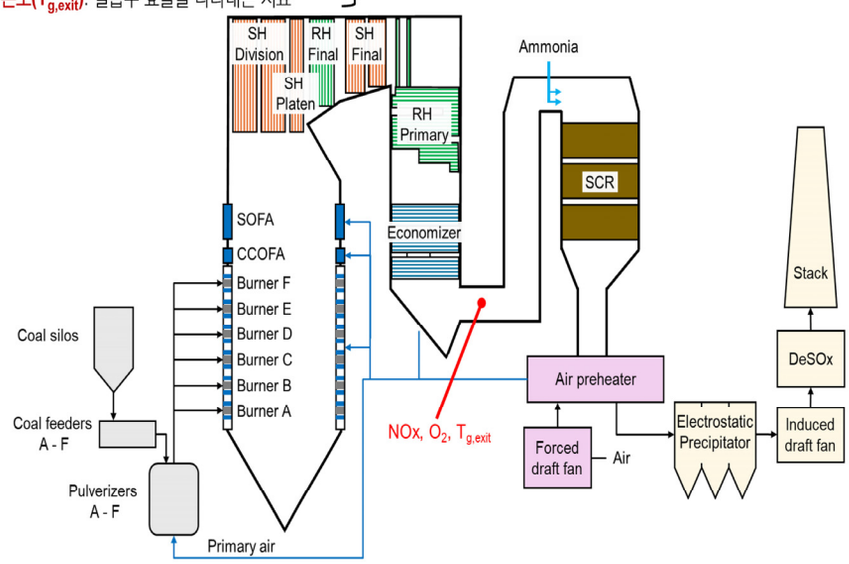
Long-horizon prediction of NOx emissions and boiler performance for operational optimization using a guided rollout hybrid forecasting network *Energy vol.360, 141578, 2026.09*

2 대상 시스템 및 연구 목표

23

- 대상 시스템: 500 MWe 석탄화력 (접선연소식 보일러; 7/8호기 시리즈)
- 연구 목표: 보일러 출구에서의 3개 핵심 성능 지표에 대한 장주기(20분) 예측
  - 1. **NOx 농도**: 배출 저감을 위한 연소 최적화의 목표 변수
  - 2. **O_2 농도**: 연소 상태를 나타내는 지표
  - 3. 가스 온도($T_{g,exit}$): 열흡수 효율을 나타내는 지표

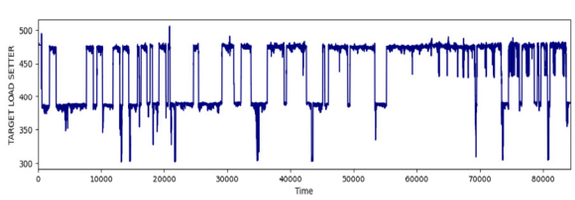
→ 운전변수 최적화, 탈질설비(SCR)의 선제적 암모니아 주입 등에 활용



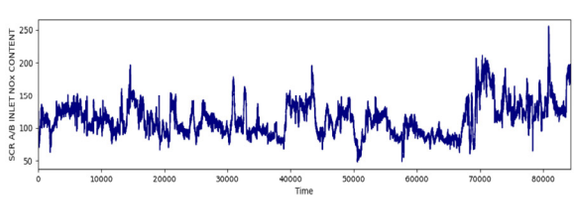
2 운전자료 획득

24

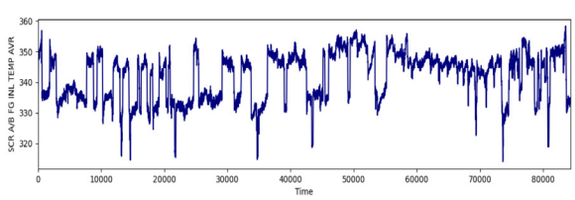
- 운전자료: 69일간(2025.07.07–2025.09.13) 177개 변수, 84,360개 데이터 포인트, 1분 간격
- Dataset 구분: Training set 80%, Validation set 10%, Test set 10%



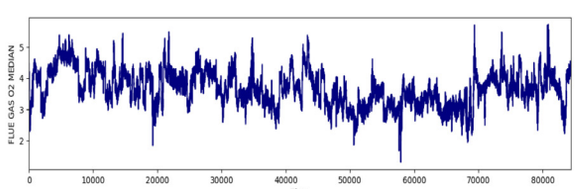
목표 부하



NOx 농도 (ppm)



가스 온도 ($T_{g,exit}$, °C)



O_2 농도 (%dry)



2 데이터 전처리 및 분류

□ 데이터 전처리
- ○ 고정값 변수 및 이상 측정값 제거
- ○ 반복 측정 데이터 평균화
- ○ 단위와 스케일 차이 제거를 위한 표준화 (평균 = 0, 표준편차 = 1)
  - $x_{norm} = \frac{x - \mu}{\sigma}$

□ 데이터 분류
- ○ Operation variables: 발전소 운전자가 제어 가능
- ○ Target metrics: 예측 대상 지표 (NOx, O_2, $T_{g,exit}$)
- ○ Steam parameters: 보일러 상태와 열관성 이력을 나타내는 인자들
  - 다양한 스팀 관련 인자들 중 예측 성능을 비교하여 최종 인자들 선정

운전자료 전처리 후 분류된 입력 변수 목록 및 데이터 범위

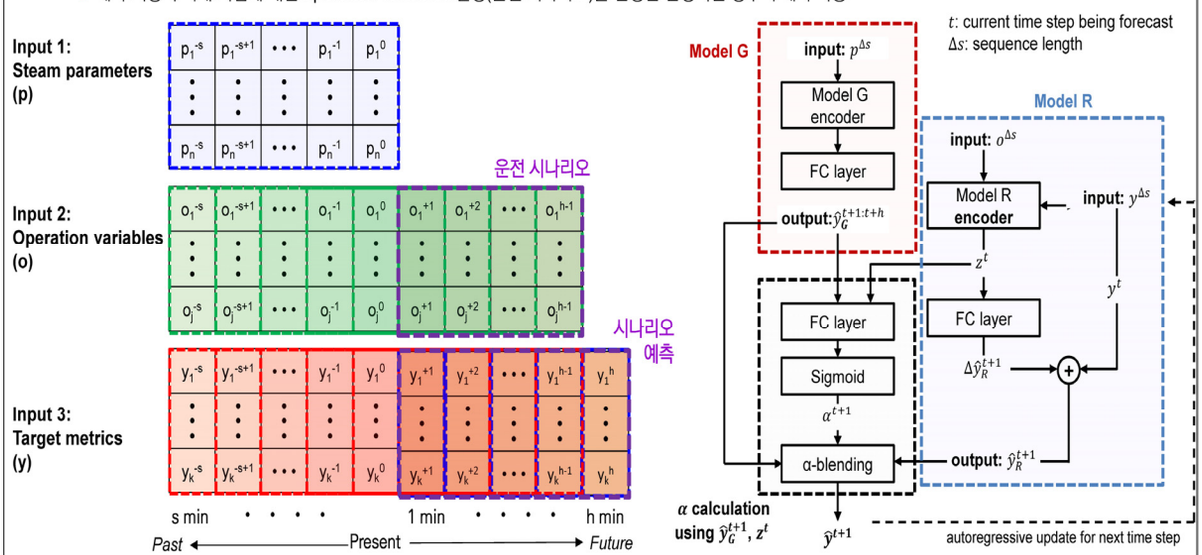
	Features	Unit	Avg.	Min	Max
Operation variables	Target load	MW	439.2	301.5	506.0
	Coal demand of burner A	%	74.15	0.0	95.11
	Coal demand of burner B	%	76.63	0.0	95.21
	Coal demand of burner C	%	76.74	50.72	95.21
	Coal demand of burner D	%	76.66	50.72	95.21
	Coal demand of burner E	%	55.65	0.0	93.55
	Coal demand of burner F	%	11.55	0.0	83.69
	SA master control	%	41.88	23.51	53.97
	Feedwater flow	ton/h	1394.4	924.9	1665.3
	Main steam pressure	kg/cm^{2}g	217.4	150.4	254.2

	Features	Unit	Avg.	Min	Max
Target metrics	NOx concentration	ppm	113.7	48.18	255.2
	O_2 concentration	%	3.68	1.28	5.72
	Exit gas temperature ($T_{g,exit}$)	°C	341.9	313.8	358.3

	Features	Unit	Avg.	Min	Max
Steam parameters (후보 목록)	ECO header outlet T	°C	331.8	317.8	339.7
	Furnace header outlet T	°C	427.0	378.6	457.8
	Division SH inlet T	°C	436.8	395.6	469.4
	Platen SH attemperator inlet T	°C	478.5	433.5	516.8
	Platen SH attemperator outlet T	°C	462.2	429.5	478.7
	Platen SH outlet T	°C	515.6	479.4	538.9
	Final SH attemperator outlet T	°C	506.2	476.6	522.8
	Final SH outlet T	°C	562.1	535.4	572.3
	RH attemperator inlet T	°C	326.8	261.0	334.8
	RH attemperator outlet T	°C	300.1	27.17	47.63
	Primary RH outlet P	kg/cm^{2}g	40.90	467.5	519.5
	Final RH inlet T	°C	497.5	574.8	602.4
	Final RH outlet T	°C	590.4	26.22	46.10
	Final RH outlet P	kg/cm^{2}g	39.56		

2 모델 아키텍쳐

□ Guided rollout hybrid forecasting network (GRHFNet)
- ○ 예측의 guidance를 제공하는 Model G와 rollout 방식의 예측을 수행하는 Model R로 구성
- ○ **Model G:** 최근의 steam parameters로부터 예측 지평 전체의 guidance 생성
- ○ **Model R:** 예측 지평 내 각 time step별로 guidance를 활용한 예측을 수행
- ○ 예측 지평의 미래 시점에 대한 operation variables 설정(운전 시나리오)을 반영한 안정적인 장주기 예측 가능



2 손실함수 및 hyperparameter 설정

27

□ 손실 함수(loss function): $\mathcal{L} = \mathcal{L}_{base} + \alpha\mathcal{L}_{h=1} + \beta\mathcal{L}_{trend}$

○ 손실 함수 구성

- $\mathcal{L}_{base}$: 오차에 대한 기본 손실 함수
- $\mathcal{L}_{h=1}$: 첫 번째 time step (미래 1분)에 대한 보조적 손실함수
- $\mathcal{L}_{trend}$: 전체 경향에 대한 손실 함수

○ 개별 손실함수 l: Huber loss

- $l(e) = \begin{cases} \frac{1}{2}e^2 & (|e| \le \delta) \\ \delta\left(|e| - \frac{1}{2}\delta\right) & (|e| > \delta) \end{cases}$ $\quad e = \hat{y} - y, \delta = 1$
- Target metric 별 및 예측 지평 내 step 별로 가중치 변화 (λ_f, ω_h)

□ 예측 성능의 평가

○ Rooted mean squared error (RMSE)

$$RMSE(y_i, \hat{y}_i) = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i)^2} \quad (y_i\text{: true value, } \hat{y}_i\text{: predicted value})$$

○ R^2 score

$$R^2 = 1 - \frac{\sum_{i=1}^{n}(y_i - \hat{y}_i)^2}{\sum_{i=1}^{n}(y_i - \bar{y})^2}$$

Hyperparameters		
GRU	Hidden size	64
	Layers	2
TCN	Hidden size	64
	Blocks	3
	Kernel size	3
	Dropout ratio	0.1
Transformer	Model dimension	64
	Layers	2
	nhead	4
α		0.8
β		0.45
λ_f		[1.2, 1.0, 0.7]
ω_h		$[0.96^0, 0.96^1, \dots, 0.96^{19}]$
Optimizer		AdamW
Learning rate		0.002
Weight decay		1e-4
Batch size		64
Scheduler		ReduceLROnPlateau
Scheduler factor		0.9
Scheduler patience		5

모델 구조 및 훈련 과정의 hyperparameter 구성

2 변수 간 시간지연 분석

28

□ Cross-correlation: 두 변수 사이의 시간 의존적 선형 관계 평가

Cross-correlation coefficient: $\rho_{xy}(k) = \frac{E[(x_t - \bar{x})(y_{t+k} - \bar{y})]}{\sigma_x\sigma_y}$

□ 기준 변수: $T_{g,exit}$

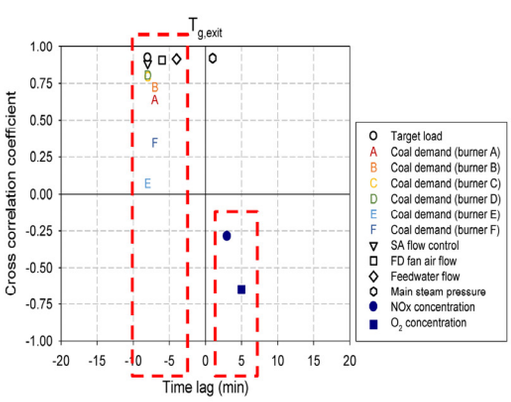
○ $T_{g,exit}$은 목표 부하 및 운전변수 변화를 4–8분 후행

○ NOx 및 O_2는 가스 샘플링 시간 등으로 인해 $T_{g,exit}$을 2–5분 후행

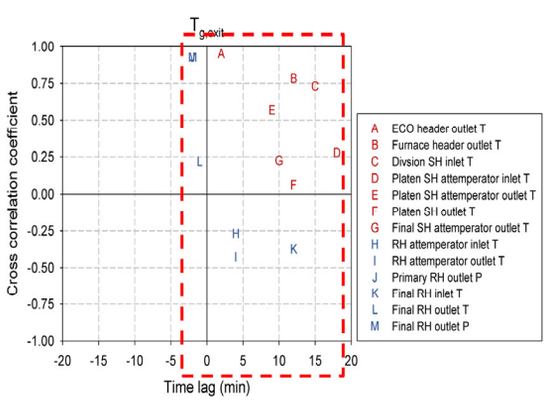
○ 증기 측의 온도, 압력 변화는 긴 튜브 경로와 열관성으로 인해 $T_{g,exit}$을 최대 18분 후행

→ 현재의 운전변수 변화에 대해 Target metrics 3개는 최대 15분 동안, 증기측 변수는 최대 30분 동안 영향을 받음

➔ 입력 시퀀스 길이(Δs): 30 분, 예측 지평 길이 (h): 20 분



운전 변수 및 O_2, NOx 농도와 $T_{g,exit}$ 사이의 시간 지연



Steam parameters와 $T_{g,exit}$ 사이의 시간 지연



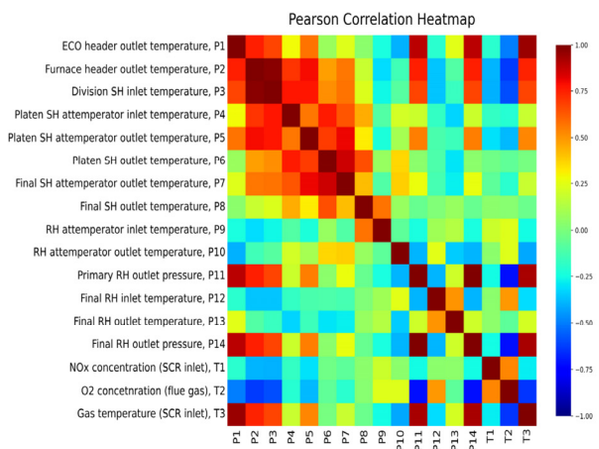
2 Model G 입력을 위한 최종 steam parameter 선정

□ 물리적으로 서로 다른 세 가지 선정 방법으로 최적 조합 평가

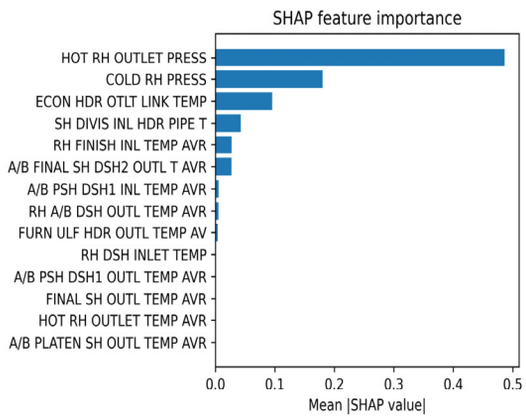
- o Correlation analysis (CA)
  - Pearson correlation, mutual information 기반의 상관계수 평가
- o Shapley additive explanations (SHAP)
  - 변수 기여도 기반 선정
- o Grey wolf optimization (GWO)
  - 최적 변수 조합 탐색

CA	SHAP	GWO
ECO header outlet T	ECO header outlet T	Platen SH outlet T
Furnace header outlet T	Division SH inlet T	RH attemperator inlet T
Primary RH outlet P	Primary RH outlet P	Final RH inlet T
Final RH outlet P	Final RH outlet P	Final RH outlet T

각 선정방법으로 선택된 steam parameter 4개의 조합



Correlation analysis (CA)



SHAP analysis

2 Model G 입력을 위한 최종 steam parameter 선정

□ Steam 입력 변수 선정 방법(CA, SHAP, GWO)에 따른 예측 성능 비교

- o 모델 구성: GRU-GRU, Transformer-Transformer
- o 평가 지표: 20분 평균 R^2, 20분 후 R^2 감소율(decay)

Model G – Model R	Method	NOx		O_2		$T_{g,exit}$	
		R^2	Decay (%)	R^2	Decay (%)	R^2	Decay (%)
GRU-GRU	CA	0.934	7.17	0.940	5.21	0.979	4.32
	SHAP	0.935	7.17	0.943	5.21	0.980	4.11
	GWO	0.917	10.41	0.936	5.53	0.985	3.16
Transformer-Transformer	CA	0.943	6.23	0.936	5.16	0.993	1.21
	SHAP	0.938	6.70	0.931	6.30	0.987	2.76
	GWO	0.925	8.96	0.930	6.75	0.991	1.55

⇒ 평균 R^2 가 높고 감소율이 작은 CA 기반의 조합 선정

CA
ECO header outlet T
Furnace header outlet T
Primary RH outlet P
Final RH outlet P

2 GRHFNet: 최종 모델의 예측 결과 예시

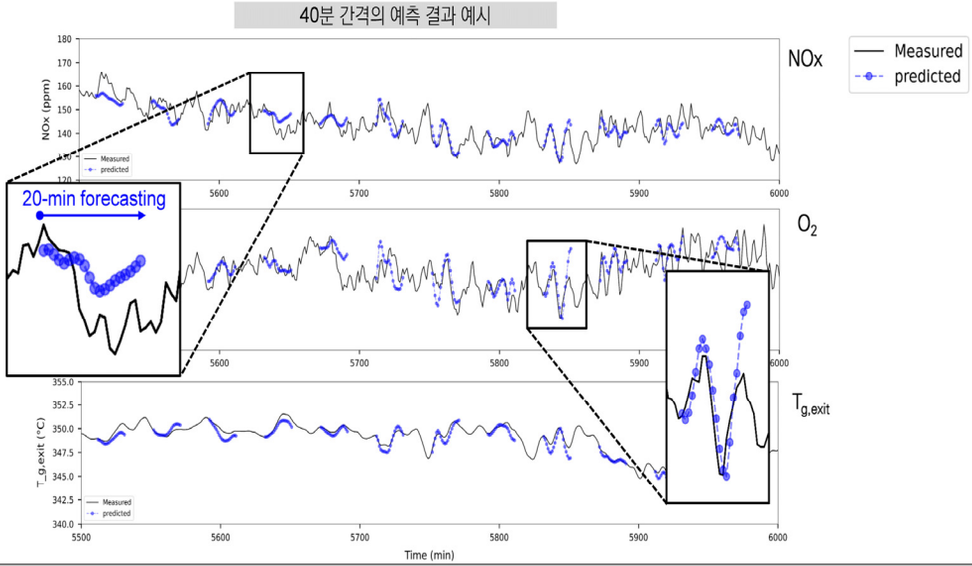
31

□ 3개 target metrics에 대해 경향과 크기 모두에서 양호한 예측 성능을 보임

- ○ $T_{g,exit}$: 지표의 변동성이 낮아 미래의 변화를 거의 완벽하게 예측
- ○ NOx and O_2: 상대적으로 오차가 크지만 경향 예측은 합리적
  - • 연료 물성의 불규칙성, 난류 반응 등에 따른 빈번한 데이터 변동이 예측 정확도를 제한

→ 보일러 운전 최적화 연구에 충분히 신뢰성 있음

40분 간격의 예측 결과 예시



2 GRHFNet: model G + model R의 조합별 성능 평가

32

*Trans: Transformer

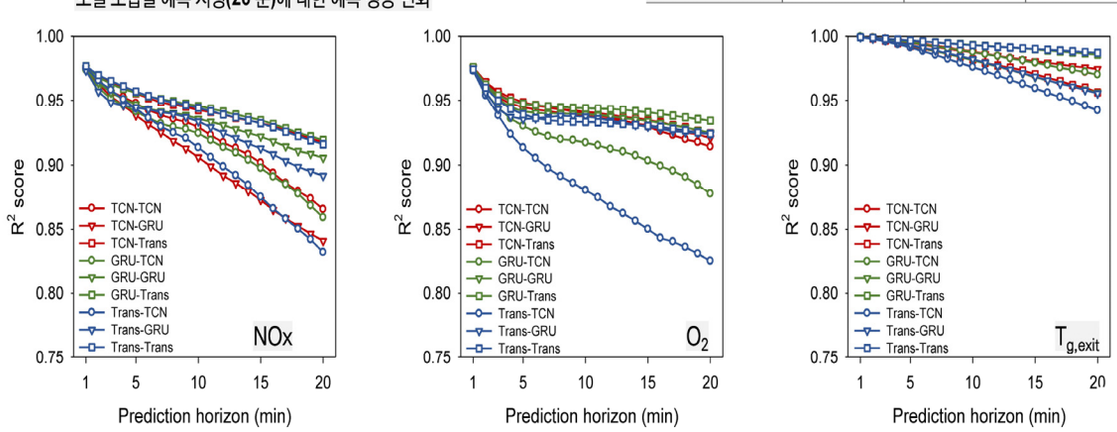
□ 최종 모델로 GRU-Transformer 선정

- ○ 주요 예측 모델로 Transformer 적용시 예측 성능이 전반적으로 향상됨
- ○ Rollout 과정에서 Transformer가 전체 입력 이력 중 중요한 지점의 값을 선택적으로 가중 평가 → 장기 예측시 과도한 오차 누적을 줄임
- ○ $T_{g,exit}$: 상대적으로 낮은 변동성으로 가장 높은 예측 정확도를 보임

모델 조합별 성능 평균

Model G	Model R	NOx RMSE (ppm)	NOx R^2	O_2 RMSE (%)	O_2 R^2	$T_{g,exit}$ RMSE (°C)	$T_{g,exit}$ R^2
TCN	TCN	5.589	0.922	0.120	0.937	0.841	0.986
TCN	GRU	5.986	0.903	0.115	0.940	0.828	0.987
TCN	Trans	4.941	0.943	0.116	0.942	1.020	0.980
GRU	TCN	5.588	0.917	0.131	0.917	0.826	0.986
GRU	GRU	5.392	0.934	0.116	0.940	1.075	0.979
GRU	**Trans**	**4.952**	**0.945**	**0.113**	**0.946**	**0.878**	**0.993**
Trans	TCN	5.784	0.906	0.148	0.883	1.182	0.973
Trans	GRU	5.402	0.928	0.119	0.936	1.063	0.979
Trans	Trans	4.979	0.943	0.123	0.936	0.610	0.993

모델 조합별 예측 지평(20 분)에 대한 예측 성능 변화



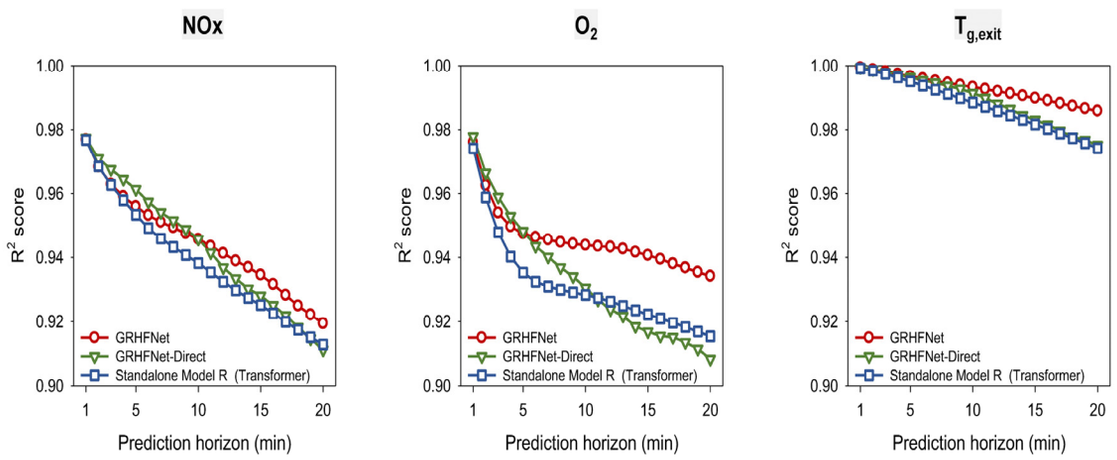


2 GRHFNet: guidance와 rollout 방식의 효과 평가

33

□ Guidance가 없거나 rollout 방식이 아닌 직접 예측 방식 대비 성능 비교

○ 예측 초기 단계에서는 영향이 제한적이나, 장기 예측 지평에서 차이가 뚜렷함



2 운전 최적화 적용 예시 #1

34

□ 최적화 목표: NOx 배출 저감

○ 부하 변동은 실제 운전값 그대로 유지

○ 버너별 연료 공급와 공기 공급은 time step별로 ±1%의 완만한 변화만 허용

○ NOx 제외한 다른 성능 지표(O_2, $T_{g,exit}$)의 변화는 최소화하도록 함

○ 최적화 알고리듬: grey wolf optimization (GWO)

□ 임의로 선택한 지점에서의 최적화 결과

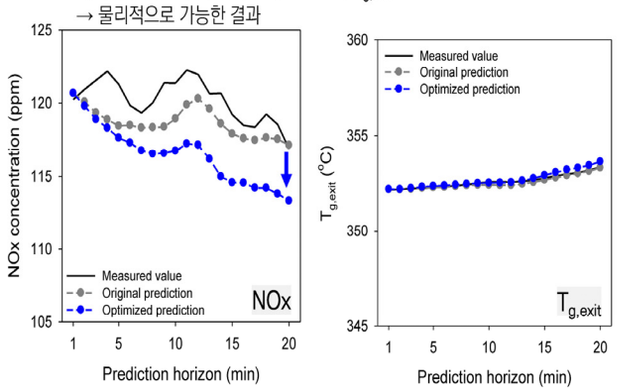
○ 하부 버너(B, D)의 석탄 공급 증가, 상부 버너(E)의 석탄 공급 감소

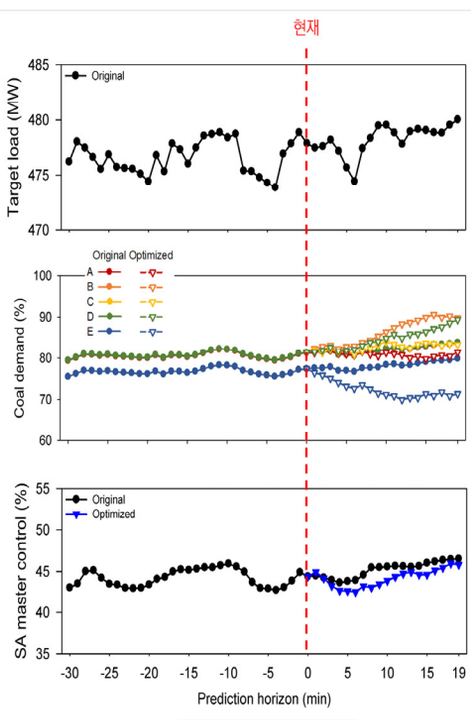
○ SA master 제어값 소폭 감소(공기 공급 감소)

○ 20분 후 NOx 3.9 ppm 감소

○ 다른 성능 지표 변화 미미: O_2 −0.04%, $T_{g,exit}$ +0.3°C

→ 물리적으로 가능한 결과





Operation optimization

35

2 운전 최적화 적용 예시 #2

□ 운전 최적화의 일반화 가능성 평가

- ㅇ 5개의 부하 변동 구간별로 20개의 임의의 시점을 선택하여 최적화 결과를 분석
- ㅇ 대부분의 조건에서 NOx 저감에 효과적인 운전 조건을 확인함

Load change (MWe)		Changes in NOx emission (ppm)			
		Avg.	Max.	Min.	Standard deviation
Large increase	$15 \le \Delta L$	**−2.04**	−3.48	−0.38	1.04
Small increase	$5 < \Delta L \le 15$	**−1.09**	−4.35	−0.44	1.31
Steady	$-5 < \Delta L \le 5$	**−2.52**	−5.66	0.05	1.04
Small decrease	$-15 < \Delta L \le -5$	**−2.25**	−4.18	−0.51	1.21
Large decrease	$\Delta L \le -15$	**−1.34**	−6.10	−0.13	1.65

20분의 예측 지평 내 NOx 배출 농도 최적화 결과: 부하 변동 크기에 따른 비교

36

결론

□ 연소 설비의 성능 예측 및 운전 최적화를 위한 AI 모델 개발

- ㅇ 'Domain knowledge': 관련 변수, 제약조건, 물리적으로 의미 있는 목표 선정에 필수적인 기본 요소
- ㅇ 데이터의 물리적인 특성에 맞는 모델 아키텍쳐 구성 필요
  - CNN: 곡선/이미지의 국소 패턴 → 고장 예측
  - MLP: 특징 기반 소프트센싱 → 운전인자별 영향 평가
  - LSTM/GRU, TCN, Transformer: 시계열 동역학의 장주기 예측
  - Hybrid 구조: 복수의 물리 메커니즘과 응답 거동을 더 잘 포착하는데 효율적
  - 강건한 예측 성능을 위해 물리 정보를 반영한(Physics-informed) 데이터의 처리와 모델 설계 필요
- ㅇ 대상 설비에서 획득한 계측 자료의 편향, 센서 특성/오류, 데이터 간 시차 등에 대한 이해와 이에 기반한 전처리 필수적
- ㅇ **AI 모델 개발 결과의 실제 적용을 위한 다양한 사례 연구 필요**

□ **AI should complement, not replace, physical understanding**

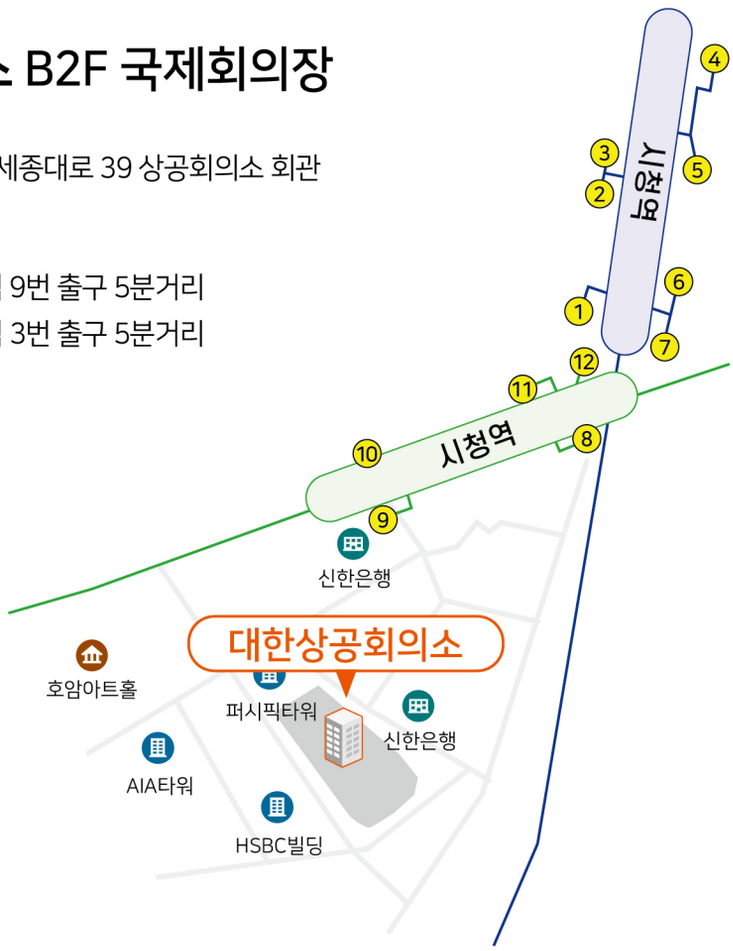
오시는 길

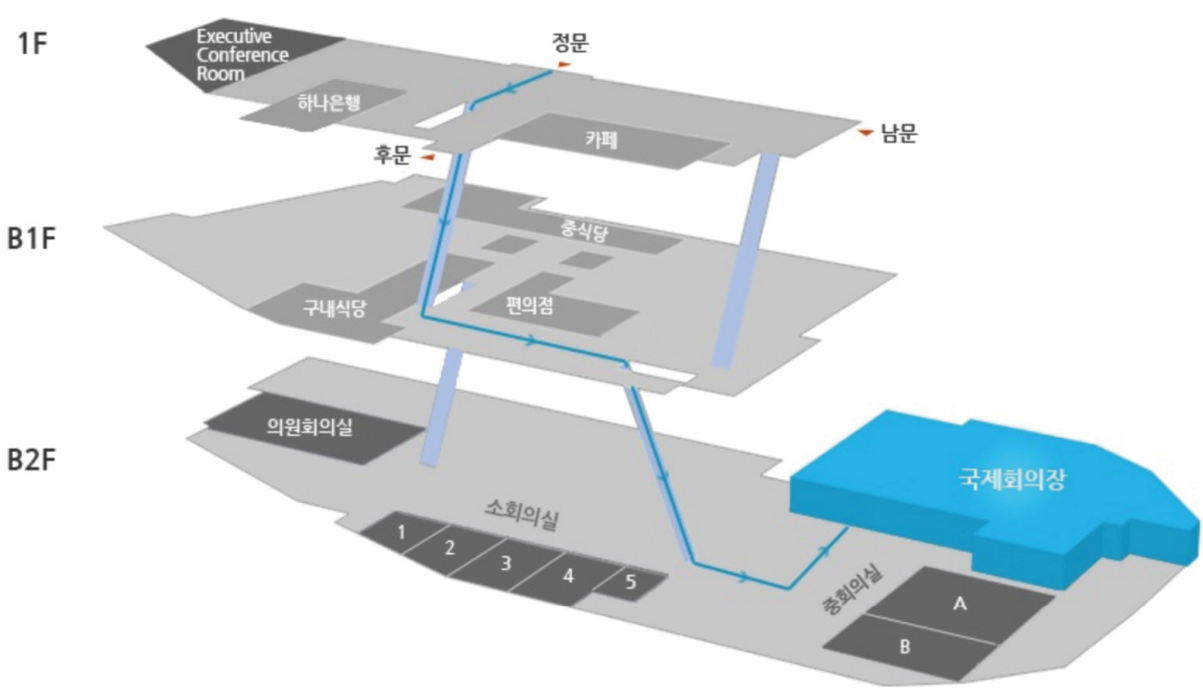
대한상공회의소 B2F 국제회의장

■ **주소** 서울특별시 중구 세종대로 39 상공회의소 회관

■ **찾아오시는 길**

- 지하철 2호선 : 시청역 9번 출구 5분거리
- 지하철 1호선 : 서울역 3번 출구 5분거리





AI 기반 제4회 연소기술 특별 워크샵

인쇄일	2026년 8월 19일
발행일	2026년 8월 21일
편집인	손채훈
발행소	사단법인 한국연소학회
주소	서울시 관악구 관악로1 서울대학교 40동 103호
홈페이지	https://kosco.or.kr/
연락처	사무국 02-880-8626 (kosco@snu.ac.kr)
인쇄	㈜에이퍼브, 02-2274-3666

AI 기반 제4회
연소기술 특별 워크샵