

[제21차 천식연구회·COPD연구회 공동 심포지엄]

Practical Introduction to AI for Clinicians

충북대학교 의과대학
박 승





목 차

01 의료 인공지능 기술

02 천식·COPD의 진단과 예후예측 연구 동향

03 충북대학교병원 인공지능센터 연구 소개

04 맺음말



CHAPTER

01

의료 인공지능 기술

■ 기술 발전에 따른 의료 시스템의 변화

ALL-OUT WAR (EXISTING MEDICINE)

Area Bombardment
Treats the entire body system where the disease is found, like carpet bombing a region.





High Collateral Damage
Traditional treatments often harm healthy cells alongside diseased ones, causing significant side effects.

One-Size-Fits-All
A standardized treatment is applied to all patients with the same general diagnosis.



SPECIAL OPERATIONS (PRECISION MEDICINE)

The 4 Pillars of Precision Tech
A multi-pronged strategy using advanced technology to attack disease with pinpoint accuracy.



AI Diagnosis: Detect & Decode
Analyzes genomes and bio-signals to identify the specific enemy signature.



Antibody Drugs (ADC): Lock-on & Detonate
A guided missile that delivers a toxic payload directly inside the target cell.



Cell & Gene Therapy: Infiltrate & Modify
Deploys "super-soldiers" (CAR-T) or "engineers" (CRISPR) to hunt or repair faulty cells.



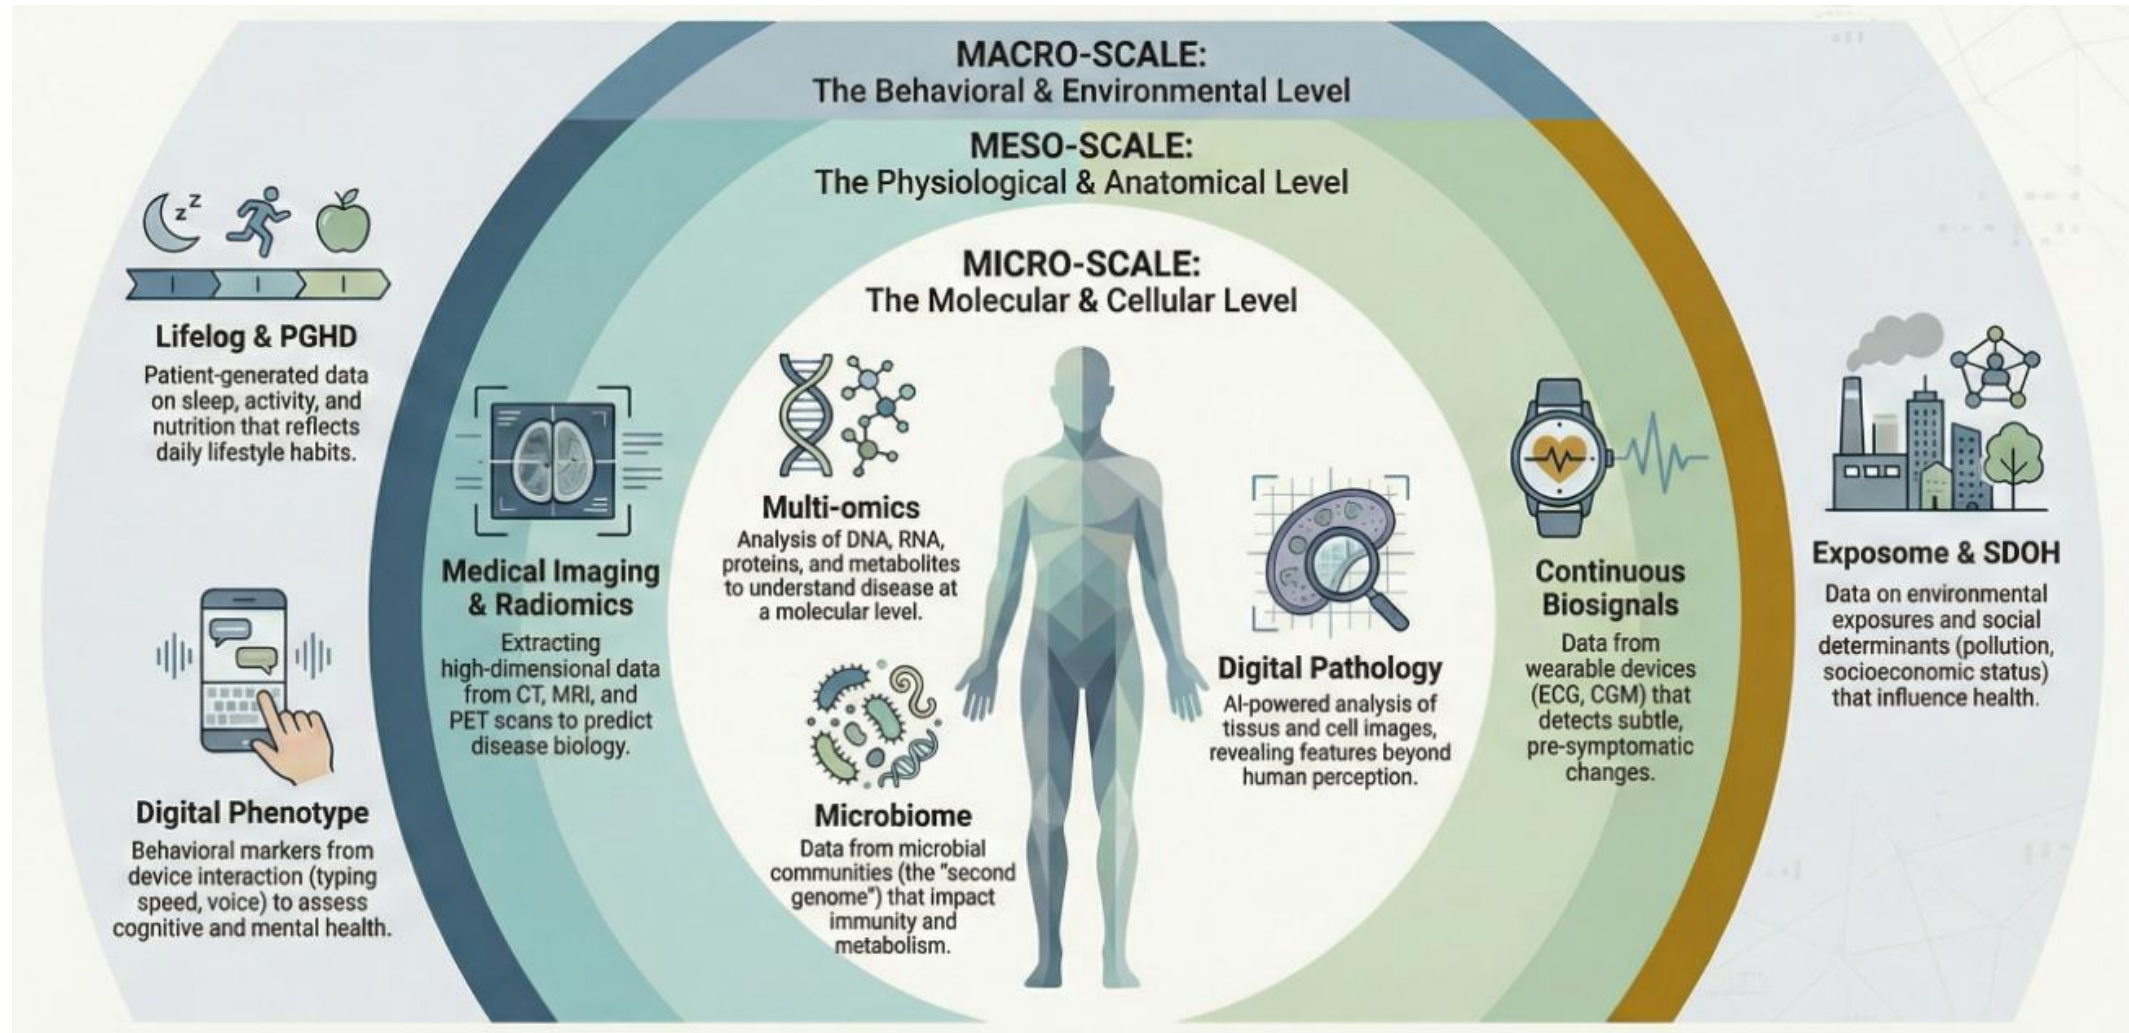
mRNA Technology: Brief & Prepare
Delivers an intelligence blueprint to teach the immune system how to fight.

AT-A-GLANCE COMPARISON TABLE

Strategy	All-Out War	Special Operations
Targeting	Area Effect	Pinpoint Strike
Side Effects	High Collateral Damage	Minimal Collateral Damage
Goal	Eradication by Force	Neutralize with Precision


인공지능(AI)을 활용한 정밀 의학

정밀 의학을 위한 데이터 기술의 발전



인공지능(AI)을 활용한 정밀 의학

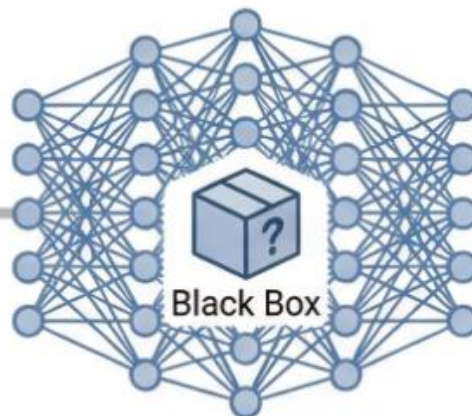
■ 의료 인공지능 기술의 발달 과정



2D Graph

Gen 1: Calculation

Characterized by manual variable definition and simple, linear models.



Neural Network

Gen 2: Pattern Recognition

Defined by automated feature learning, but often a data-hungry "black box."



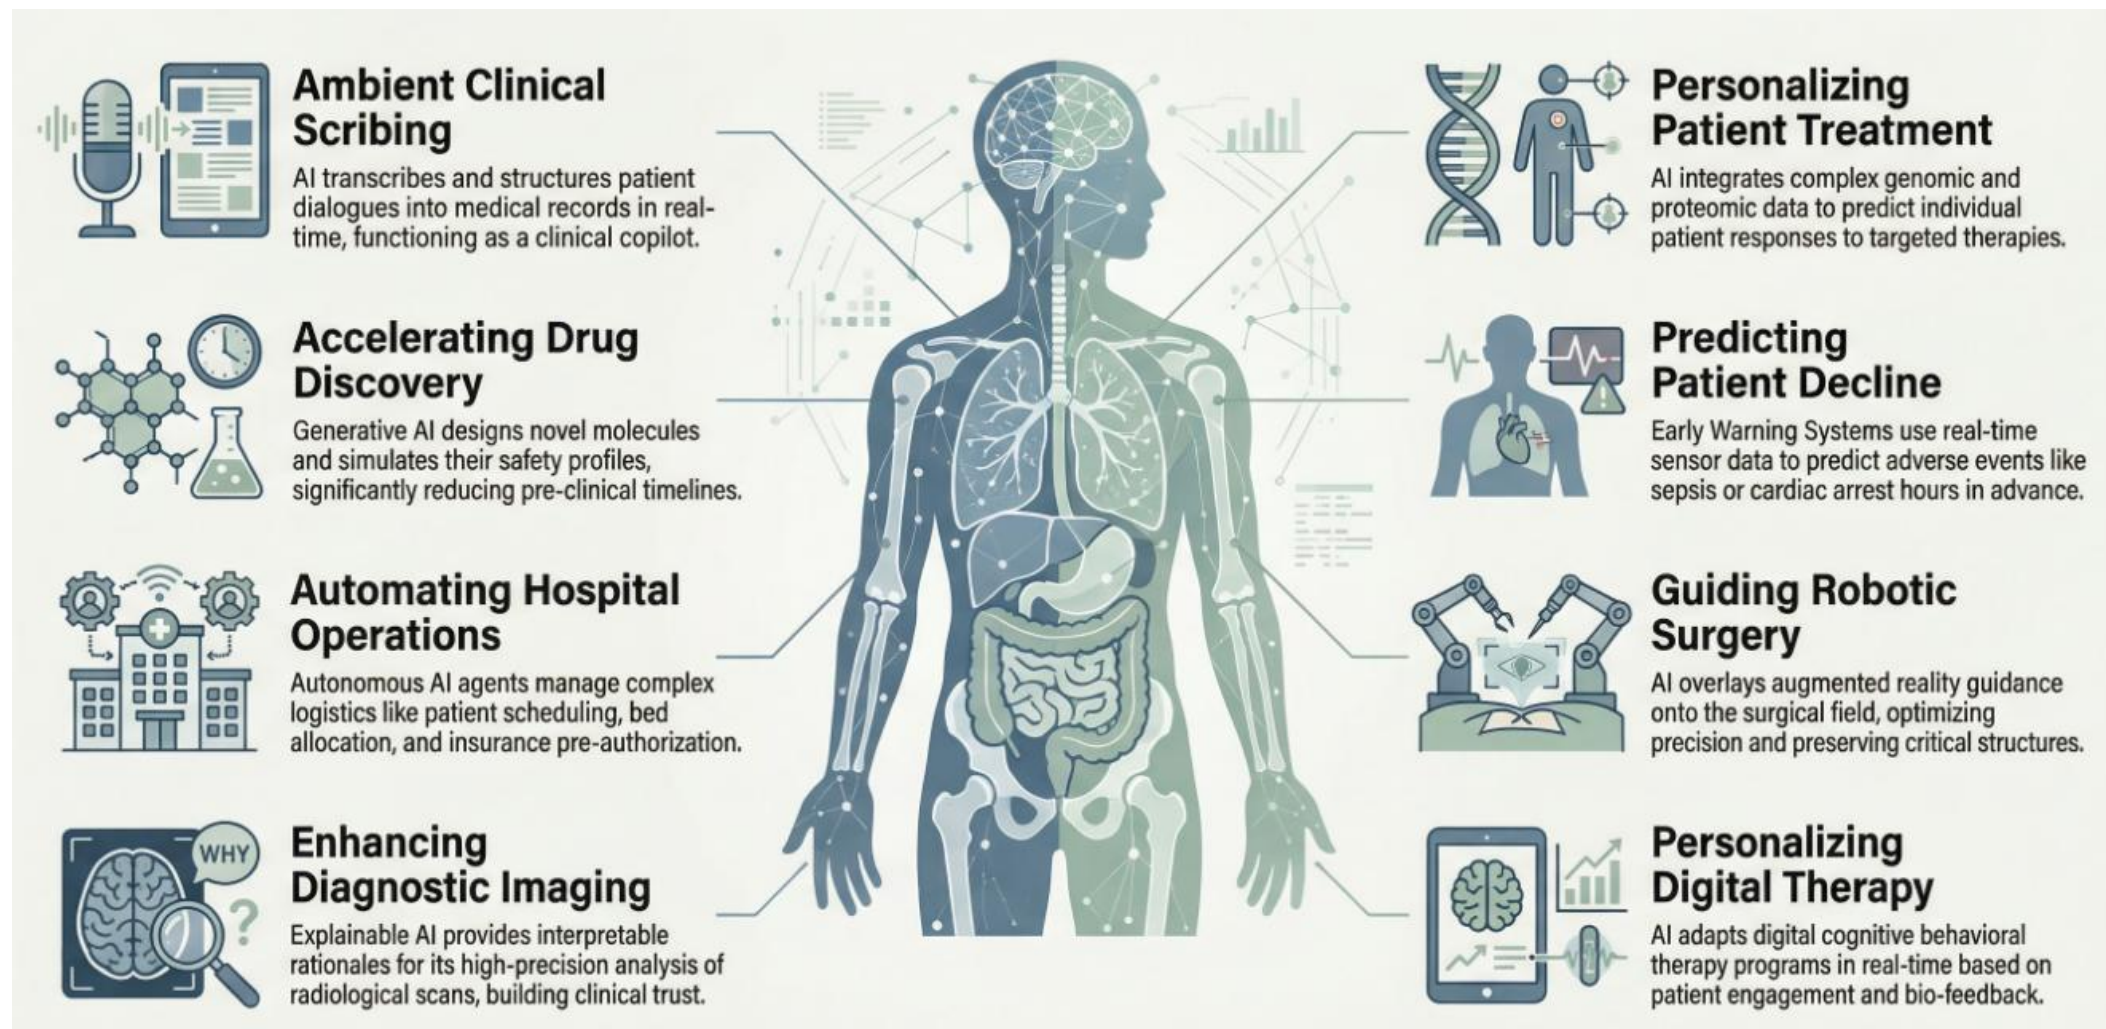
Futuristic Central Hub / Reasoning

Gen 3: Interactive Reasoning

Features multi-modal data integration, built-in explainability, and interactive dialogue.

Core Mechanism	Equation-based	Pattern Matching	Reasoning & Generation
Data Efficiency	High	Low	Very High
Interpretability	Transparent	Opaque (Black Box)	Explainable
Interaction	Static	Static	Dynamic Dialogue

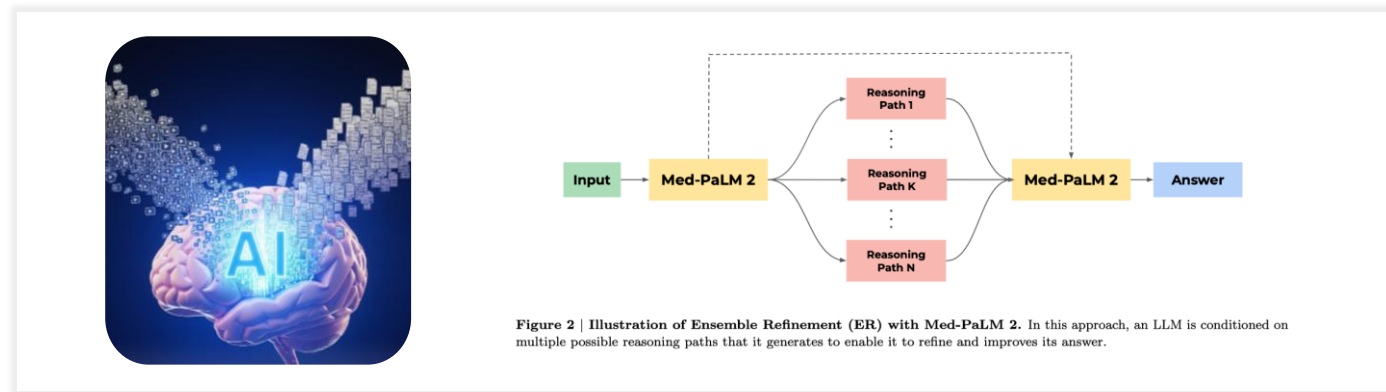
■ 의료 인공지능 기술의 적용 분야



Google Med-PaLM 2

■ 의료 특화 대규모 언어모델 (Nature Medicine, 2025)

- USMLE(미국 의사면허시험) 문제와 다양한 의료 질의응답 데이터로 성능 평가
- 의학적 근거를 바탕으로 답변을 생성하며, 답변에 대한 불확실성 표기와 근거 설명 기능 제공



미국 의사면허시험(USMLE) 평가

- 정확도 86.5% 달성
- '전문가' 수준의 성능 입증

고차원적 추론 능력 입증

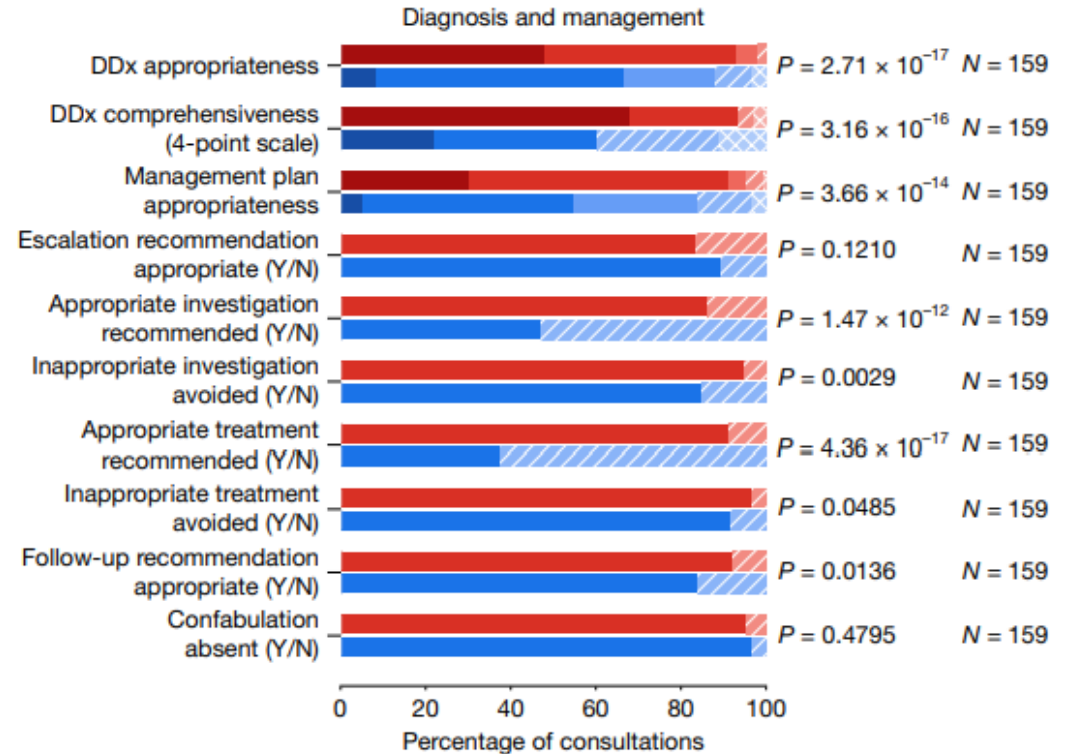

- 복잡한 의학 정보 종합
- 환자 안전을 고려한 답변
- 근거 기반의 답변 생성

의료 AI 패러다임의 전환

- 단순 정보 검색 도구를 넘어 임상 의사결정을 지원하는 '전문가 보조 시스템'으로의 활용 가능성 제시

■ 대화형 진단 AI 서비스 (Nature, 2025)

- 51개 임상 분과(168개 질환)의 실제 의료 대화, 의료 지식 및 추론 데이터를 통해 학습 수행
- 환자의 증상과 병력을 요약하여 감별 진단 리스트 생성
- 다양한 주제에서 1차 진료 의사와 통계적으로 유사한 수준의 판단력 달성



CHAPTER

02

천식·COPD의 진단과 예후예측 연구 동향

1. COPD 장기 예후 예측을 위한 기계학습 및 딥러닝 모델 메타분석

- 입력 데이터: 총 18편의 적격 연구 (3,620편 중 선별)
 - 모델 유형: 일반 기계학습 12편, 딥러닝 6편
 - 데이터 유형: 임상 테이블 데이터, 영상 데이터(CT, X-ray) 등
 - 대상: 18~90세의 성인 COPD 환자
- 모델 출력: 최소 6개월 이후의 장기 예후 예측
 - 핵심 지표: 사망률(Mortality), 급성 악화(Exacerbation), 폐기능 저하
- 모델 성능: AUROC 0.77 (사망률 및 급성 악화)

Outcome	Sample size	AUC (95% CI)	Other performance indicators
Boueiz et al (2022) ⁹⁶	Change in FEV ₁ after 5-year period; new FEV ₁ after 5-year period	Training 4496 (10-fold cross validation); internal validation (temporal) 1833	Internal validation (cross validation) 0.71 (0.69-0.72); internal validation (temporal) 0.70*
Sharma et al (2021) ⁹⁵	Decline in FEV ₁ ≥30 mL per year over 3-year period	Training 42 (5-fold cross validation)	Accuracy 84.6%, sensitivity 0.875, specificity 0.800
Kor et al (2022) ⁹⁴	≥1 exacerbation in 6-month period (for patients who have not previously exacerbated)	Training 407; internal validation 102	Sensitivity 79.41%, specificity 77.94%, PPV 64.29%, NPV 88.33%, F1 score 71.05%, accuracy 78.43%
Le (2021) ⁹⁸	≥1 exacerbation in 1-year period	Training 190 117 (10-fold cross validation)	0.67 (0.67-0.68)
Nguyen (2017) ⁹¹	≥1 hospitalisation in 180-day period	Training 81; internal validation 27	Accuracy 88%, sensitivity 0.83, specificity 0.93
Zeng et al (2022) ⁹⁰	≥1 exacerbation in 1-year period	Training 36 047; internal validation 7529	0.866 (0.83-0.90)
Moslemi et al (2023) ⁹²	≥1 hospitalisation in 3-year period	Training 328; internal validation 141†	Accuracy 90.3% (89.6-91.0), sensitivity 56.6 (49.2-64.2), specificity 91.2 (90.5-91.8), PPV 13.7 (11.2-16.2), NPV 98.8 (98.6-99.1)
Esteban et al (2011) ⁹⁷	5-year all-cause mortality	Training 611; internal validation 348	Accuracy 78%, F1 score 71%
Moll et al (2020) ⁹⁵	All-cause mortality risk‡	Training 1974; internal validation 658; external validation 1268	Internal validation 0.731 (0.682-0.780); external validation 0.688 (0.655-0.721)
Morales et al (2018) ⁹³	3-year all-cause mortality	Training 163 587; internal validation 40 895†	0.80 (0.79-0.80)
Pinto-Plata et al (2019) ⁹⁴	3-year all-cause mortality	Training 90; internal validation 30 (100% mortality)	Accuracy 85%, sensitivity 81%, specificity 89%
Tang et al (2021) ⁹⁶	1-year all-cause mortality	Training 10 850; internal validation 4650	Accuracy 64.6%

All AUCs reported with recalculated 95% CI. HRs are reported as HR (95% CI). AUC=area under receiver operator curve. HR=hazard ratio. PPV=positive predictive value. NPV=negative predictive value. FEV₁=forced expiratory volume in 1 s. *Regression model has no event counts so 95% CIs could not be calculated; these are values reported in the original study. †Training and validation populations estimated from total population and reported train-validation split percentages. ‡Median follow-up for internal validation 6.4 years; median follow-up for external validation 7.2 years.

Table 3: Model performance for conventional machine learning

Outcome	Sample size	AUC (95% CI)	Other performance indicators
Gonzalez et al (2018) ⁹¹	≥1 exacerbation in 1-year period; ≥1 exacerbation in 3-year period	Training 6016 (COPDGene); internal validation 1000; external validation 1672 (ECLIPSE)	Internal validation 0.64 (0.60-0.68); external validation 0.54 (0.51-0.57)
Singla et al (2021) ⁹¹	≥1 exacerbation in a 5-year period	Training 10 300 (5-fold cross validation)	0.73 (0.71-0.75)*
Gonzalez et al (2018) ⁹¹	3 year all cause mortality	Training 5740 (COPDGene); internal validation 1000; external validation 1672 (ECLIPSE)	Internal validation 0.72 (0.63-0.81); External validation 0.60 (0.56-0.64)
Humphries et al (2020) ⁹²	Mortality risk†	Training 2407; internal validation 7143; external validation 1962	Internal validation HR (5 strata) 1.5 (1.0-2.2), 1.6 (1.1-2.4), 2.4 (1.6-3.5), 2.7 (1.8-4.2), 2.9 (1.7-4.9); external validation HR (5 strata) 1.5 (1.0-2.2), 1.7 (1.1-2.5), 2.9 (2.0-4.3), 5.3 (3.6-7.7), 99.7 (6.3-14.8)
Nam et al (2022) ⁹⁴	5-year all-cause mortality	Training 3475; internal validation (hold-out) 315; internal validation (temporal) 394; external validation (VHSMC) 416; external validation (AMC) 337	Internal validation (hold-out) 0.81 (0.74-0.88); internal validation (temporal) 0.76 (0.70-0.82); external validation (VHSMC) 0.72 (0.66-0.78); external validation (AMC) 0.83 (0.78-0.88)
Singla et al (2021) ⁹¹	5-year all-cause mortality	Training 10 300 (5-fold cross validation)	0.62 (no CI calculated)
Tang et al (2018) ⁹⁶	1-year all-cause mortality	Training 10 850; internal validation 4650	HR 1.54 (1.09-2.17), p<0.0001 Accuracy 78.89% (no CI)
Yun et al (2021) ⁹⁵	3-year and 5-year all-cause mortality	Training 344 (5-fold cross validation); external validation 102	Internal validation 0.80 (0.72-0.88); external 0.72 (0.57-0.86)

AUCs reported with recalculated 95% CI. HRs are reported as HR (95% CI). AMC=Asan Medical Centre dataset. AUC=area under receiver operator characteristic curve. AUPRC=area under precision recall curve. HR=hazard ratio. VHSMC=Veteran Health Service Medical Centre dataset. *Number of cases not reported, so reported 95% CI used instead of calculated 95% CI. †Median follow-up for internal validation was 7.95 years and median follow-up for external validation was 2.90 years.

Table 2: Model performance for deep learning

* L. A. Smith et al., "Machine learning and deep learning predictive models for long-term prognosis in patients with chronic obstructive pulmonary disease: a systematic review and meta-analysis," *The Lancet Digital Health*, 2023.

2. 급성 COPD 악화 예측 도구 (ACCEPT) 개발 및 검증 모델

- 입력 데이터: 3개 임상시험 통합 데이터 및 대규모 코호트 총 4,199명
 - 개발 데이터: MACRO, STATCOPE, OPTIMAL 임상시험 환자 2,380명
 - 검증 데이터: ECLIPSE 코호트 1,819명
 - 입력 변수: 악화 이력, 나이, 성별, BMI, 흡연 여부, 산소 치료 여부, 폐기능, 증상 점수(SGRQ), 현재 약물 복용력(LABA, LAMA, ICS 등)
- 모델 출력: 향후 1년 내 COPD 급성 악화의 발생 빈도 및 중증도 개별 예측
- 모델 성능: AUROC 0.81 (악화 빈도), 0.77 (중증 악화)

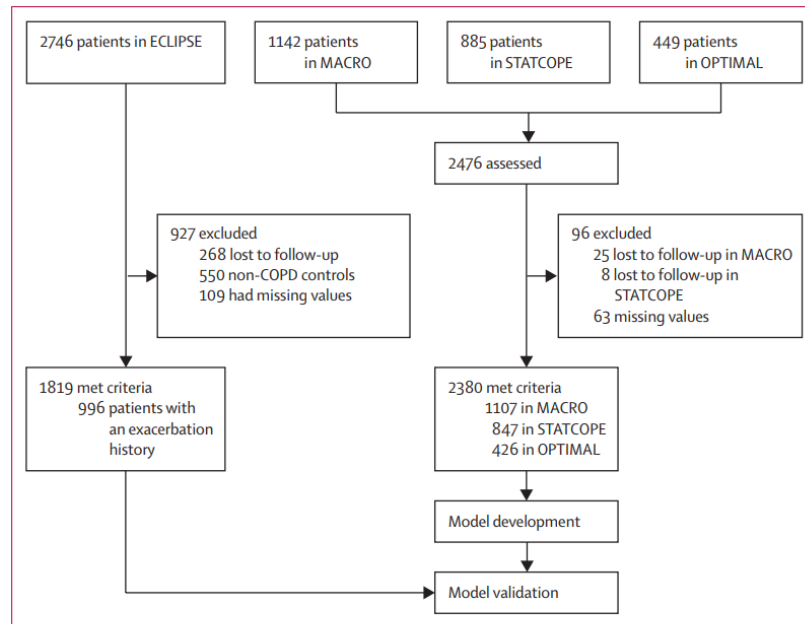


Figure 1: Flow diagram




Figure 5: Discriminative ability of ACCEPT compared with event history

3. 흉부 X-ray 기반 COPD 고위험군 예측 모델

- 입력 데이터: Mass General Brigham(MGB) 외래 환자의 흉부 X-ray 및 임상 데이터 총 27,848건
- 대상 환자: 50~80세의 흡연 경험자(12,550명) 및 비흡연자(15,298명)
 - 영상 변수: Posterior-Anterior 흉부 X-ray (CXR) 영상
 - 임상 변수: 나이, 성별, 흡연력, 호흡곤란 여부, 약물 처방 이력(SABA, 항생제)
- 모델 출력: 6년 이내 COPD 발병 여부 예측
- 모델 성능: AUROC 0.73 (흡연자), 0.70 (비흡연자)

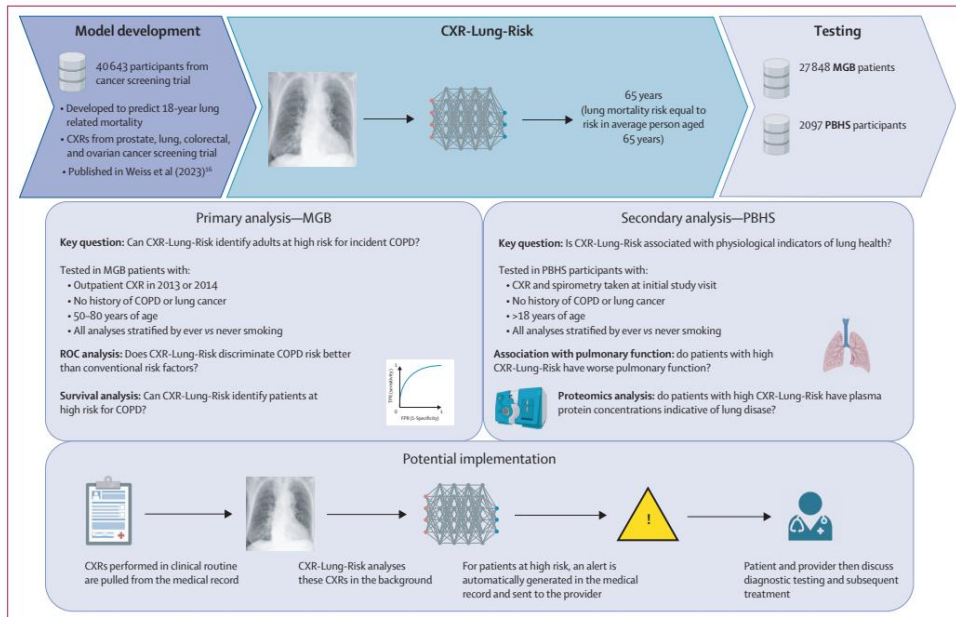


Figure 1: Schematic diagram of the study
COPD=chronic obstructive pulmonary disease. CXR=chest radiograph. MGB=Massachusetts General Brigham Hospital. PBHS=Project Baseline Health Study. ROC=receiver operating characteristic.




Figure 2: Cumulative incidence of COPD by CXR-Lung-Risk ordinal categories in (A) ever-smokers and (B) never-smokers
COPD=chronic obstructive pulmonary disease. CXR=chest radiograph.

4. 다중모달 초음파 기반 COPD 급성 악화(AECOPD) 진단 모델

- 입력 데이터: 중국일우병원(China-Japan Friendship Hospital) COPD 환자 316명
 - 임상 변수: CAT 점수 (증상 평가 설문)
 - 초음파 변수: 폐 초음파 점수(LUS score), 횡격막 이동 범위(ADE), 대퇴직근 단면적, 외측광근 두께, 대퇴사두근 수축 지수(QCI)
- 모델 출력: COPD 급성 악화 진단 여부
- 모델 성능: 외부 검증 AUROC 0.9302
 - 설명 가능한 AI 분석을 통해 횡격막 기능 저하와 근육 위축이 핵심 예측 인자임을 규명




Fig. 1 Description of ultrasound indicators. **A** Normal lung with several parallel A-lines. **B** Abnormal lung with fused B-lines. **C** Normal pleural line, characterized by smooth, regular, and continuous. **D** Abnormal pleural line, characterized by rough and irregular. **E** Measurement of diaphragm thickness. **F** Measurement of diaphragm mobility. **G** Measurement of cross-sectional area of the rectus femoris muscle. **H** Measurement of quadriceps contraction index, with the orange line representing quadriceps thickness and the blue line representing the distance from the skin to the femoral surface. The QCI is calculated as the length of the orange line divided by the length of the blue line. Abbreviations: QCI = Quadriceps Contraction Index

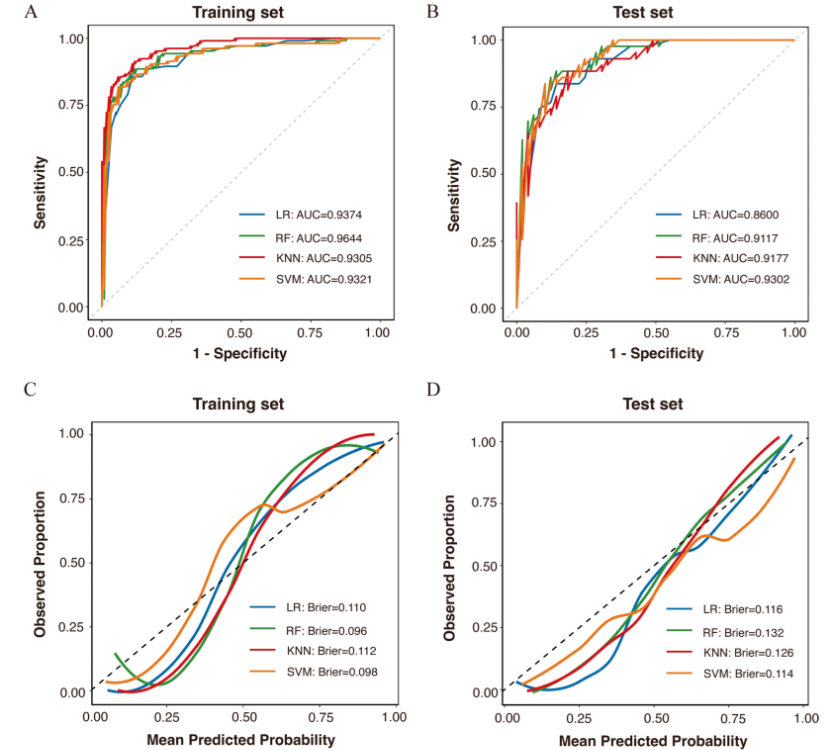


Fig. 4 Performance of machine learning models predicting AECOPD in the training and test sets. ROC curve analysis (**A, B**) and calibration curve analysis (**C, D**) for predicting AECOPD in the training and test sets. Abbreviations: AECOPD = Acute Exacerbation of Chronic Obstructive Pulmonary Disease; ROC = Receiver Operating Characteristic; LR = Logistic Regression; RF = Random Forest; KNN = K-nearest Neighbor; SVM = Support vector machine

5. 스프링고지질/스테로이드 비율 기반 천식 급성 악화(Exacerbation) 예측 모델

- 입력 데이터: 3개의 천식 코호트(MGBB-KAS, MGBB-Asthma, MGBB-LLF) 총 2,513명
 - 임상 데이터: 최대 25년치 전자의무기록 데이터 (폐기능, 처방 이력 등)
 - 대사체 데이터: 스프링고지질(77종), 스테로이드(18종), 미생물 유래 대사체(71종) 정밀 정량 분석
- 모델 출력: 향후 5년 내 천식 급성 악화(Asthma Exacerbation) 발생 위험 예측
- 모델 성능: AUROC 0.90 (Discovery), 0.89 (Replication)
 - 단일 물질보다 '스프링고지질 대 스테로이드 비율(Sphingolipid-to-Steroid Ratio)'이 급성 악화를 훨씬 더 정확하게 예측함

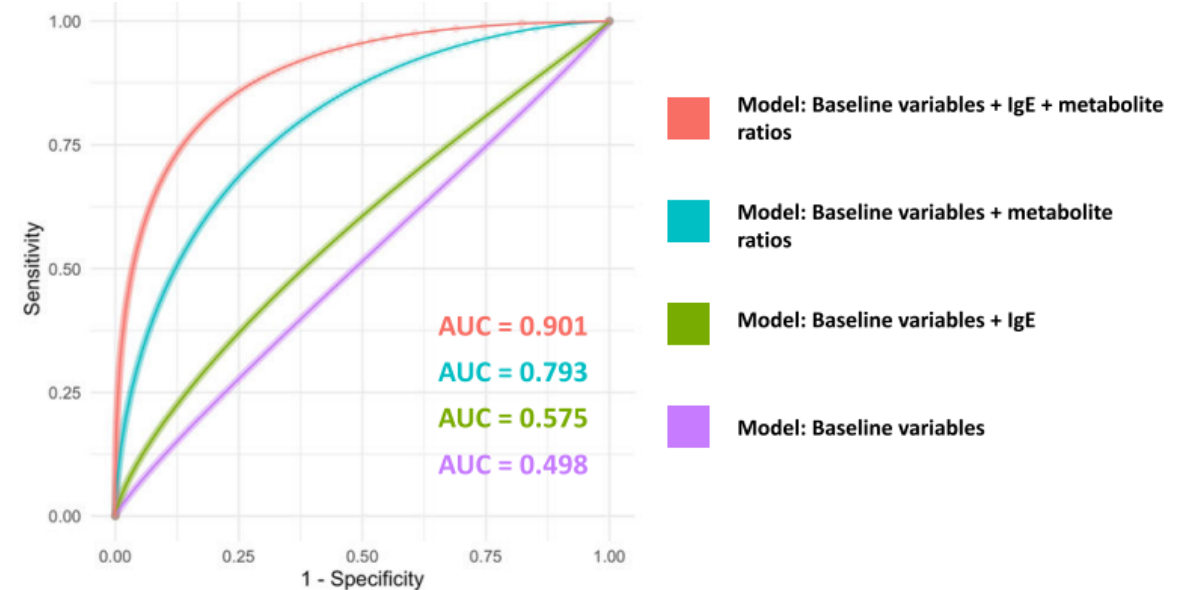
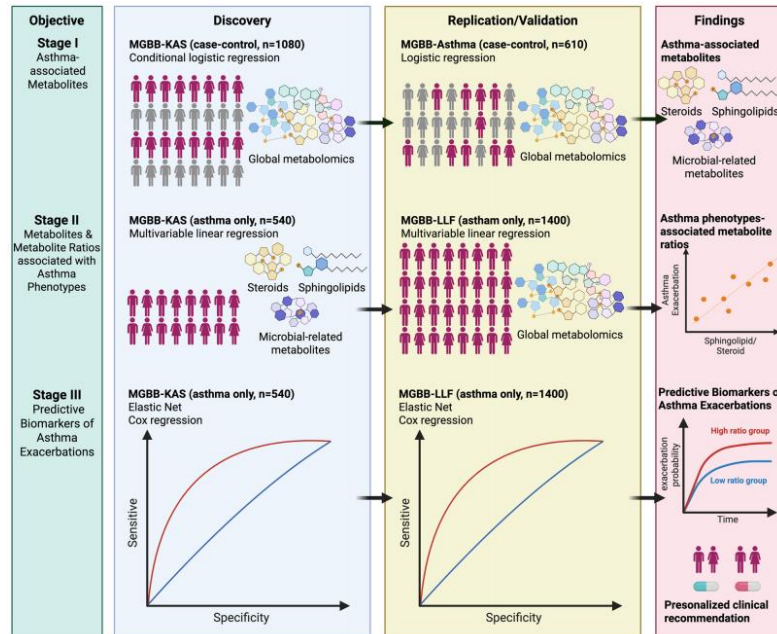


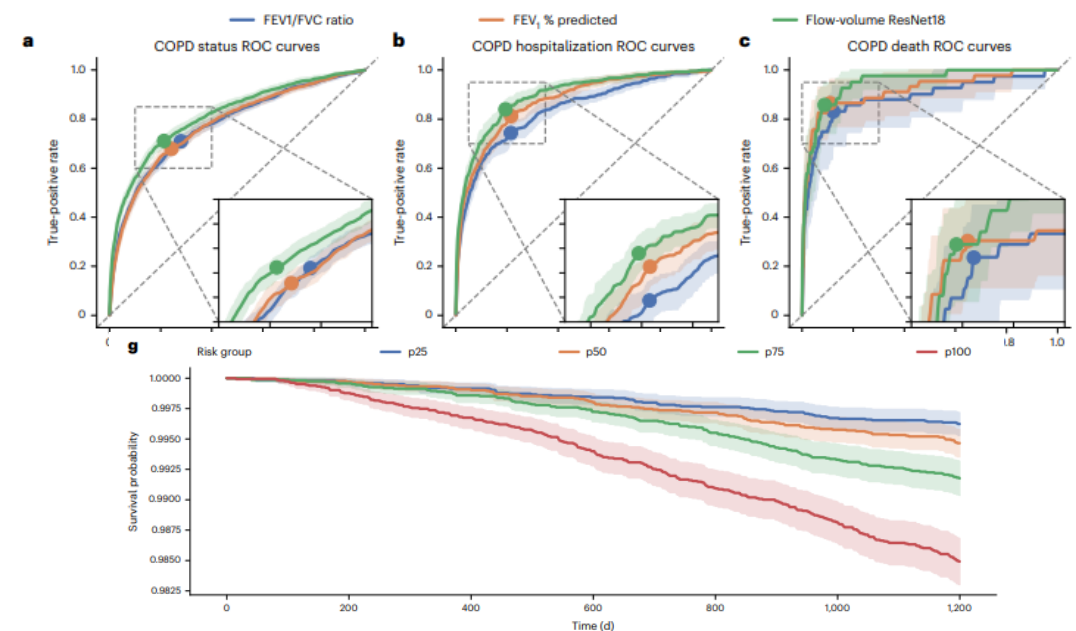
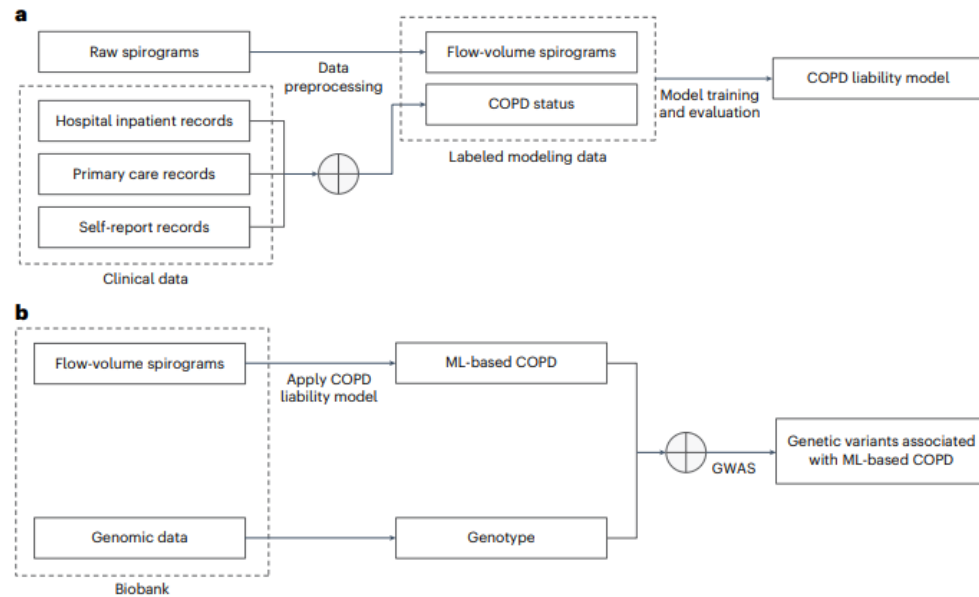
Fig. 1 | Study workflow. MGBB-KAS The Mass General Brigham-Karolinska Asthma Study, MGBB-asthma The Mass General Brigham Biobank-Asthma, MGBB-LLF Mass General Brigham Biobank-Longitudinal Lung Function. This figure was created in BioRender. Su, J. (2025) <https://BioRender.com/iqdbinq>.

* Y. Chen et al., "The ratio of circulatory levels of sphingolipids to steroids predicts asthma exacerbations," *Nature Communications*, 2026.

천식·COPD의 진단과 예후예측 연구 동향

6. Raw Spirogram 기반 COPD 위험도 예측 및 유전체 발굴 모델

- 입력 데이터: UK Biobank(UKB) 유럽계 혈통 325,027명의 폐기능 검사 및 임상 기록
 - 임상 레이블: 자가 보고(Self-report), 1차 진료 및 병원 입원 기록(ICD 코드) 등
 - 입력 변수: 호흡 곡선 전체를 나타내는 원시 유량-용적 스피로그래프(Raw Flow-Volume Spirograms)
- 모델 출력: 정량적 COPD 위험도 점수
- 모델 성능
 - AUROC 0.82 (COPD 상태), 0.89 (입원), 0.95 (사망) 달성
 - 기존 진단 기준으로는 찾지 못했던 67개의 새로운 유전적 위치 규명




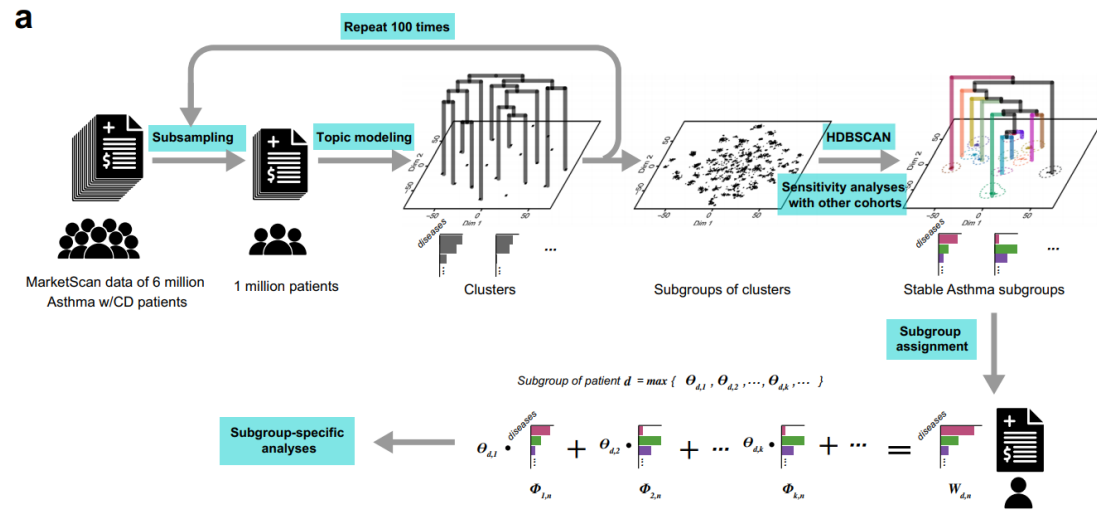
* J. Cosentino et al., "Inference of chronic obstructive pulmonary disease with deep learning on raw spirometry identifies new genetic loci and improves risk models," *Nature Genetics*, 2023.

천식·COPD의 진단과 예후예측 연구 동향

7. 동반질환 매핑 기반 천식 엔도타입 규명 및 유전적 특성 분석

- 입력 데이터: 대규모 다국적 임상 및 유전체 데이터셋
 - 임상 데이터: 미국 MarketScan 데이터베이스
 - 유전체 데이터: 영국 UK Biobank, 미국 BioVU, 일본 BioBank Japan 등 다인종 코호트
 - 분석 기법: 자연어 처리 기술인 토픽 모델링(Topic Modeling)을 환자의 진단 기록에 적용
- 모델 출력: 동반질환 패턴에 따른 천식 서브그룹 분류 및 특이 유전 변이 예측
- 핵심 성과

- 22개의 천식 동반질환 패턴을 발견하였으며, 이 중 11개는 독립 코호트(UK Biobank)에서도 재현됨
- 총 109개의 천식 위험 유전자를 식별했으며, 이 중 6개는 특정 서브그룹에만 특이적으로 작용하는 새로운 변이임
- 천식을 단일 질환이 아닌, 동반질환과 유전적 배경이 상이한 다양한 엔도타입의 집합으로 재정의함



* G. Jia et al., "Discerning asthma endotypes through comorbidity mapping," *Nature Communications*, 2022.

CHAPTER

03

충북대학교병원 인공지능센터 연구 소개


인공지능센터 조직도 및 주요 업무






의료 인공지능 (Medical AI)

- 질병 예측·진단·예후 관리를 위한 AI 임상결정 지원 서비스 (CDSS)
- (보건복지부) K-MIMIC / (과기정통부) Dr.Answer 2.0



첨단 바이오 (Advanced Bio.)

- 미세생리시스템(MPS) 기반 신약 독성 평가 AI 기술
- (산업통상부) 의약품 독성평가 AI 소프트웨어 및 플랫폼 구축



디지털 헬스케어 (Digital Healthcare)

- 자연어처리 기반 개인 맞춤형 건강 관리 서비스
- (과기정통부) 멀티모달 생체데이터 활용 스마트시티 헬스케어 개발



교육 (Education)

- 디지털 바이오 헬스 분야 융합 연구 인력 양성
- (과기정통부) 항노화 바이오헬스 인재양성 / (고용노동부) K-Digital Training

AI 기반 의료·바이오 연구 성과 (최근 5년)



	SCI급 논문	주요 연구 내용
01 중환자 및 호흡기 환자 진단 및 예후예측	12편	<ul style="list-style-type: none"> ▪ 흉부 X-ray 기반 결핵 진단 보조 모델 ▪ 신생아 중환자실(NICU) 내 응급 삽관 필요성 실시간 예측 모델 ▪ 패혈증 환자의 사망 위험도 및 재원 기간 예측 모델
02 생체신호 기반 심혈관질환 진단	5편	<ul style="list-style-type: none"> ▪ 심전도(ECG) 기반 심방세동 조기 선별 및 자동 진단 모델 ▪ 비심인성 실신 환자의 퇴원 후 재발 가능성 예측 모델 ▪ 카와사키병 환자의 1차 치료(IVIG) 저항성 예측 모델
03 멀티모달 데이터 기반 암 진단 및 예후 예측	2편	<ul style="list-style-type: none"> ▪ 갑상선 유두암 수술 후 재발 가능성 예측 모델 ▪ 임상 정보와 영상 데이터 연계 갑상선암 예후예측 모델
04 신경계 및 근골격계 환자 진단 및 예후예측	3편	<ul style="list-style-type: none"> ▪ 응급실 내원 직후 뇌출혈 vs 뇌경색 감별 모델 ▪ 일반 중환자실 환자의 뇌졸중 발생 조기 감지 모델 ▪ 손 통증 환자의 SPECT영상 기반 관절염 진단 및 아형 분류 모델
05 자연어처리 기반 의료정보 제공 기술	2편	<ul style="list-style-type: none"> ▪ 암 환자의 질의에 대한 맞춤형 의학 정보 제공 및 상담 챗봇 ▪ 약물 간 상호작용 위험도 자동 분석 및 약물 정보 추출 챗봇
06 인공지능 제반 기술 (변수선별, 성능개선, 합성)	15편	<ul style="list-style-type: none"> ▪ 설명 가능한 AI (XAI) 기반의 입력 변수 선별 기법 ▪ 진단 정확도 향상을 위한 의료 영상 화질 개선 모델 ▪ 희귀 질환 등 데이터 부족 문제 해결을 위한 의료 영상 합성 기술

한국형 중환자 빅데이터(K-MIMIC) 구축 및 AI-CDSS 개발 사업

과제 개요

- (보건복지부) 2021.08 – 2026.06 / 총 533.9 억원
- 다기관 중환자 의료 데이터 수집 및 AI 기반 진단 보조 시스템 개발

- ### 연구 주제
- 기계환기 이탈 가능성 조기 예측 모델
 - 신생아 중환자 기관삽관 적응증 예측 모델
 - 패혈증 중환자 사망률 예측 모델
 - 비신경계 중환자 뇌졸중 예측 모델
 - PPG waveform 기반 혈액학적 변수 추정



충북대학교병원

- 의공학과 박승 교수
- 호흡기내과 신윤미 교수
- 호흡기내과 양지열 교수
- 호흡기내과 양범희 교수
- 내분비내과 전현정 교수
- 신경과 염규선 교수
- 소아청소년과 윤신애 교수
- 외상외과 설영훈 교수
- 영상의학과 김 욱 교수

계명대동산병원


- 소아청소년과 박재현 교수

충남대병원

- 마취통증의학과 홍부휘 교수
- 신경과 정혜선 교수
- 소아청소년과 강미현 교수
- 중환자의학과 문재영 교수

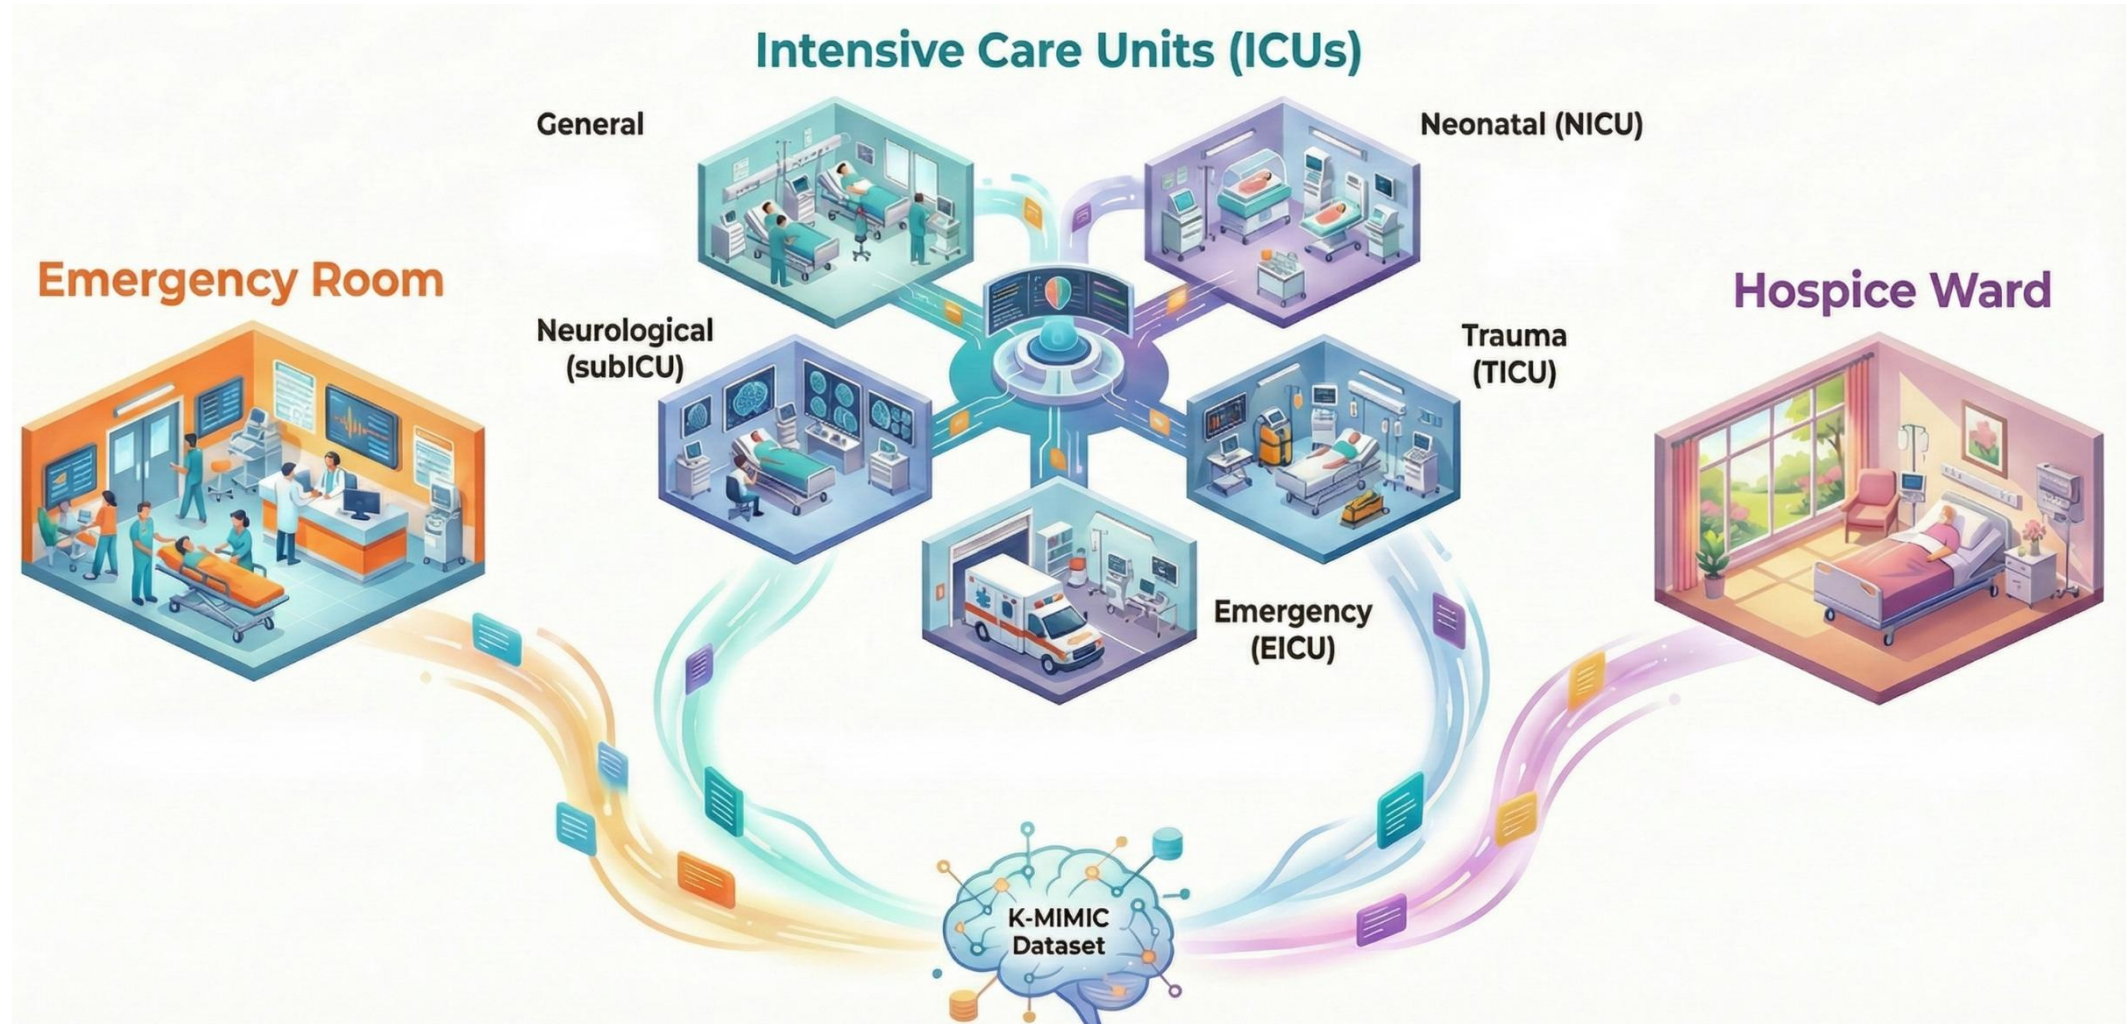
한국형 중환자 빅데이터(K-MIMIC) 구축 및 AI-CDSS 개발 사업

■ 충북대병원 내 수집 데이터 목록



한국형 중환자 빅데이터(K-MIMIC) 구축 및 AI-CDSS 개발 사업

- 충북대병원 내 중환자실, 응급실, 호스피스병동에서 데이터 수집



중환자 호흡기질환 진단 및 예후예측 연구 성과

1. 중환자실 환자의 자발 호흡 시험(SBT) 성공 예측 모델

- 입력 데이터: 충북대병원 중환자실 내 기계 환기 환자 652명
 - 인구통계 및 활력징후 변수: 나이, 성별, BMI, 심박수, 호흡수, GCS
 - 호흡 및 기계환기 관련 변수: 기계환기 모드, PS level, FiO₂, P/F ratio, pCO₂, TV-6mL/kg PBW, 기계환기 지속 시간
- 모델 출력: 자발 호흡 시험(SBT) 성공 여부
- 모델 성능: AUROC 0.80

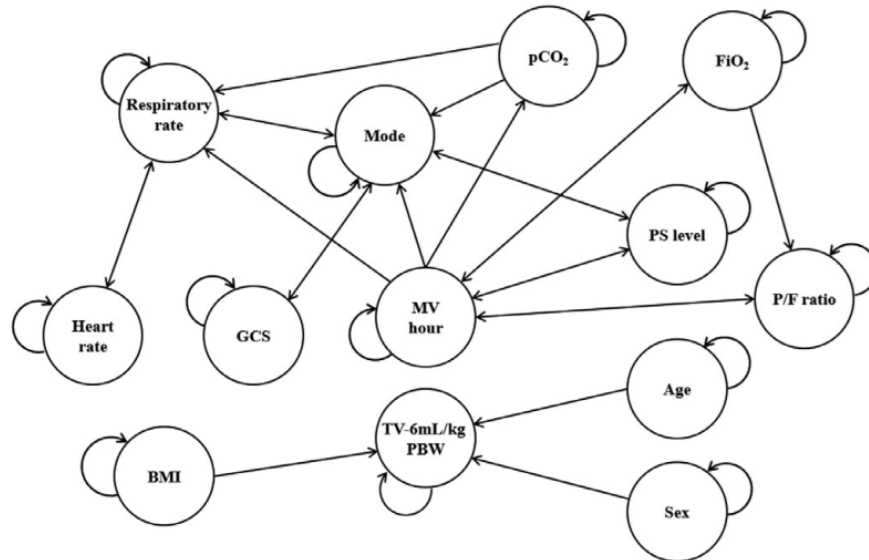


Fig. 3. Graph structure of 13 input features. The circle and arrow indicate a node (i.e., a feature) and edge, respectively. The edges are interpreted as follows: The FiO₂ feature affects P/F ratio feature values, not vice versa.


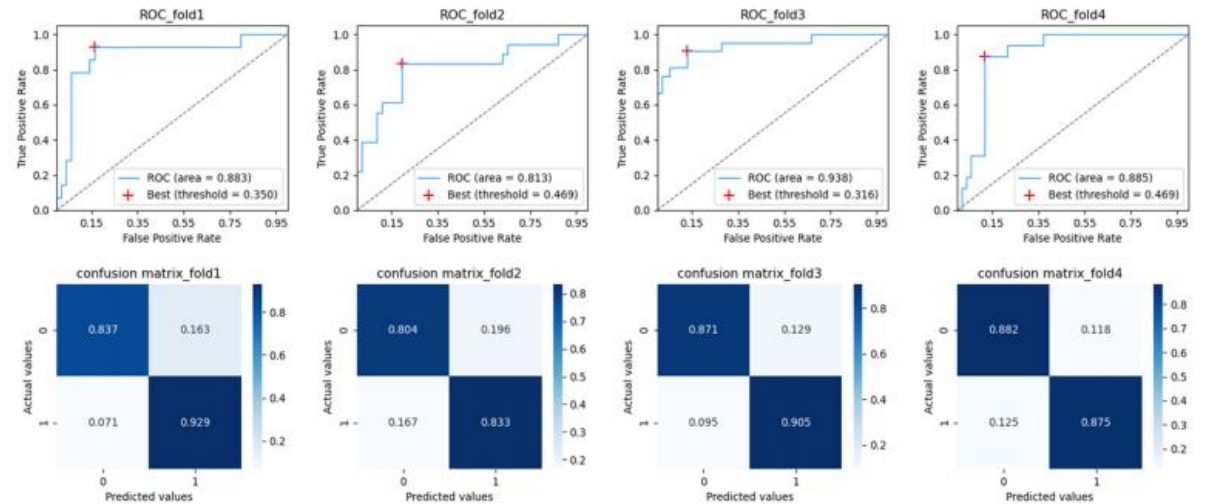
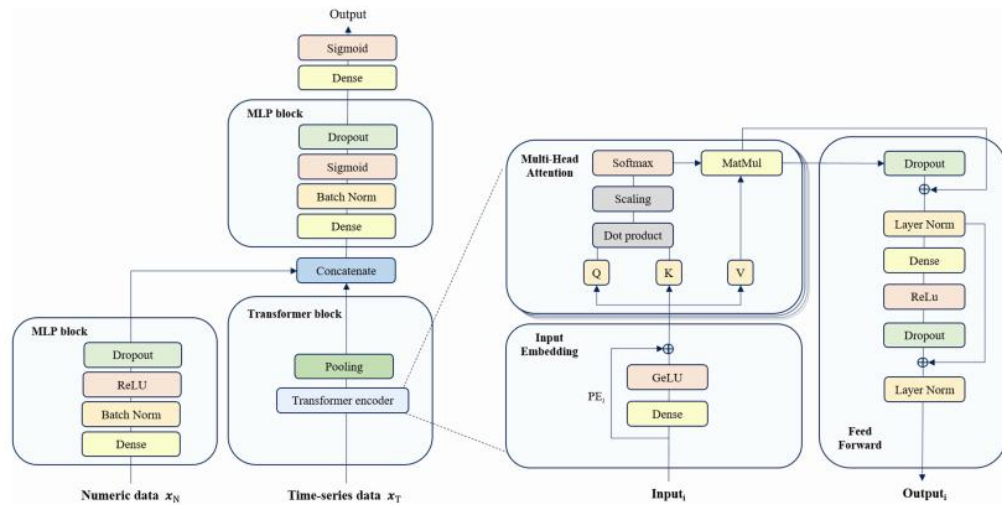


Fig. 7. ROC curves of the conventional models, clinical indicators, and the FT-GAT. CatBoost, categorical boost; SVM, support vector machine; LGBM, light gradient boosting machine; XGBoost, extreme gradient boosting; MLP, multi-layer perceptron.

중환자 호흡기질환 진단 및 예후예측 연구 성과

2. 신생아 중환자실 환자의 기관 내 삽관 필요성 예측 모델

- 입력 데이터: 충북대병원 신생아 중환자실 내 호흡곤란 환자 219명
 - 출생 관련 변수: 재태 주수, 출생 체중, 성별, APGAR 점수, 제왕절개 여부, 산전 스테로이드 사용, 임신성 고혈압/당뇨, 조기 양막 파수, 원외 출생, 다태아 여부
 - 임상 및 활력징후 변수: 초기 체온, CRIB-II 점수, 심박수, 호흡수, FiO2, SpO2
 - 혈액가스분석(CBGA) 변수: pH, PCO2, PO2, Base Excess, Lactate
- 모델 출력: 3시간 이내 기관 내 삽관 필요 여부
- 모델 성능: AUROC 0.890





* S. Park et al., "Real-time prediction for neonatal endotracheal intubation using multimodal transformer network," *IEEE Journal of Biomedical and Health Informatics*, 2023.

* S. Park et al., "Predicting the need for intubation within 3 h in the neonatal intensive care unit using a multimodal deep neural network," *Scientific Reports*, 2023.

중환자 호흡기질환 진단 및 예후예측 연구 성과

- 3. 약한 지도학습 기반 측면 흉부 X-Ray 기반 결핵 예측 모델
 - 입력 데이터: 4개의 공개 데이터셋에서 수집한 총 91,629장의 lateral chest X-Ray
 - 라벨링된 영상: 1,115 건 / 라벨링되지 않은 영상: 90,514 건
 - 모델 출력: 결핵 양성 여부
 - 모델 성능 (AUROC): 내부 검증 0.9069, 외부 검증 0.9083



■ 기계학습을 이용한 COPD 급성 악화 예측 모델 개발

▪ 연구 목표

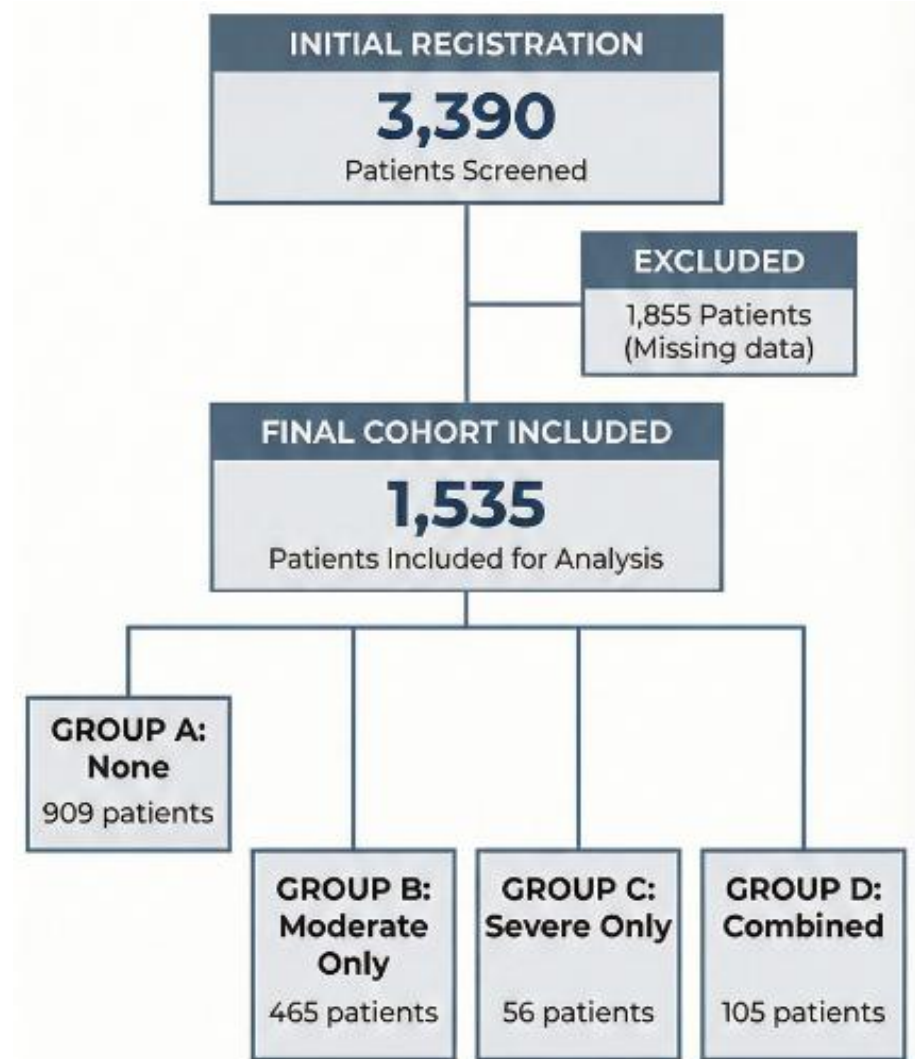
- 임상 데이터를 활용하여 향후 1년 내 급성 악화 발생 여부 예측
- 악화의 중증도에 따라 Moderate / Severe 두 가지 타겟으로 나누어 모델링
- 설명 가능한 AI 기술을 통해 주요 위험 인자 규명

▪ KOCOSS 코호트

- 전체 환자: 3,390명
- 제외: 1,855명 (주요 변수 결측 등)
- 최종 분석 대상: 1,535명

▪ 타겟 그룹 정의

- Moderate Exacerbation: 570명 (37.1%)
- Severe Exacerbation: 161명 (10.5%)



KOCOSS 데이터 기반 COPD 예측 모델

■ 기계학습을 이용한 COPD 급성 악화 예측 모델 개발

▪ 다양한 변수 세트를 활용한 모델 학습 수행

- 임상적 연관성에 따라 Set 1 ~ 4의 4가지 조합 테스트

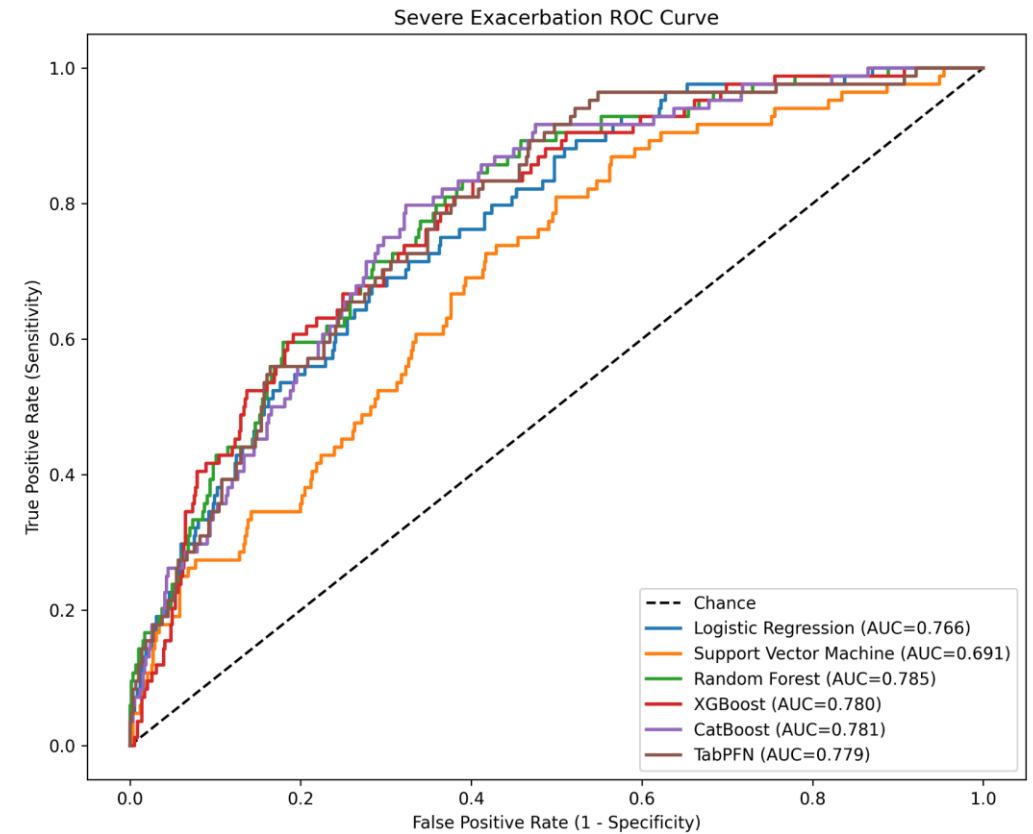
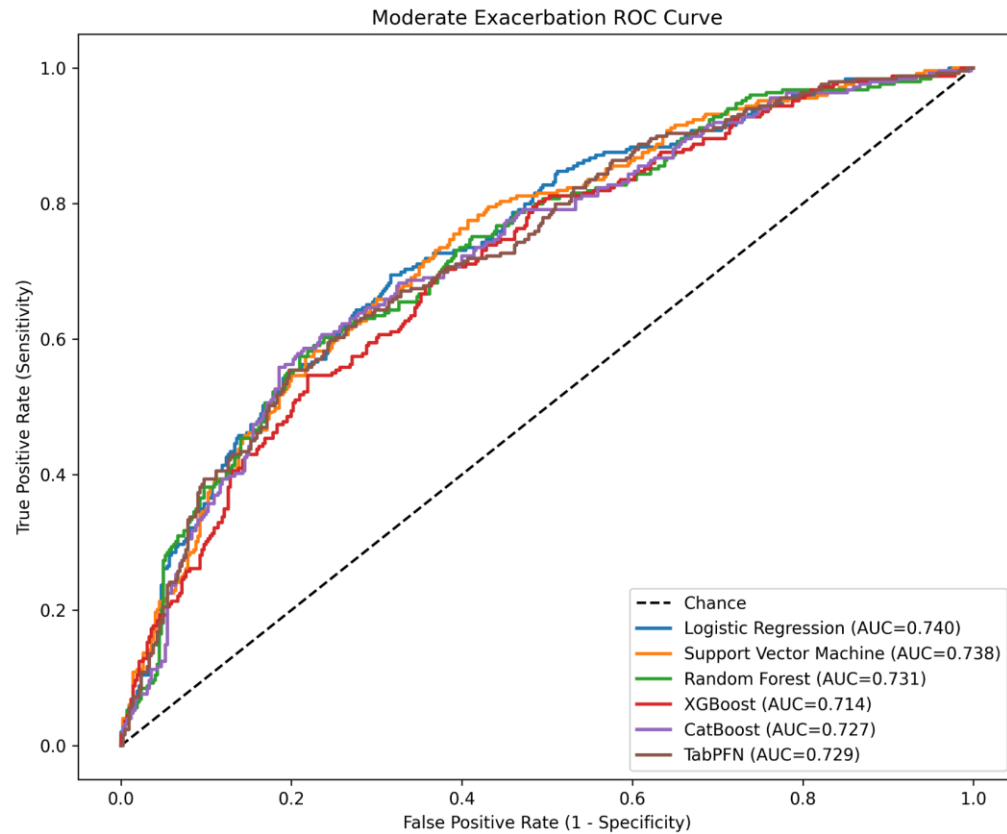
- 검증: Stratified 5-Fold Cross Validation

변수 구분	변수명	Set 1 (Standard)	Set 2 (Inflammation)	Set 3 (CAT/DLCO)	Set 4 (Exercise)
인구학적	나이 (Age)	0	0	0	0
	체질량지수 (BMI)	0	0	0	0
	맥박 (Pulse)	0	0	0	0
과거력	과거 악화 여부 (History of AE)	0	0	0	0
	결핵 과거력 (Tb History)	0	0	0	0
	천식 동반 여부 (Asthma)	0			0
	현재 흡연 여부 (Current Smoker)	0	0	0	0
	흡연량 (Pack-years)	0	0	0	0
약물	ICS/LABA 사용 여부	0	0		
증상 및 설문	SGRQ 총점 (Total Score)	0			0
	SGRQ 영향 점수 (Impact Score)		0		
	CAT 점수 (CAT Score)			0	
	객담 유무 (Sputum)		0		
폐기능 검사	FEV1 예측치 % (FEV1 %pred)	0			
	FEV1/FVC 비율 (BDR Ratio)		0	0	0
	폐확산능 (DLCO %pred)			0	
혈액 검사	호산구 수 (Eosinophils)	0		0	0
	호중구 수 (Neutrophils)		0	0	
	백혈구 수 (WBC)	0	0	0	0
	혈소판 수 (Platelet)	0	0	0	
운동 능력	6분 보행 전 산소포화도 (SpO2)				0

■ 기계학습을 이용한 COPD 급성 악화 예측 모델 개발

▪ 머신러닝 모델 학습 결과



- Moderate: 0.714-0.740, Severe: 0.691-0.785



KOCOSS 데이터 기반 COPD 예측 모델

■ 기계학습을 이용한 COPD 급성 악화 예측 모델 개발

- Severe 악화는 객관적인 폐기능(FEV1) 저하가 가장 결정적인 요인이었음
- Moderate 악화는 환자의 '자각 증상(SGRQ 점수)'이 가장 강력한 예측 인자였음
- 이는 고위험군 선별 시 환자의 폐기능 검사뿐만 아니라 설문(SGRQ/CAT)을 통한 증상 모니터링이 중요함을 시사함





CHAPTER

04

맺음말

- 의료 AI 기술이 단순 분석을 넘어 상호작용과 추론이 가능한 '설명 가능한 AI'로 발전하면서, 정밀 의학 실현의 핵심 도구로 자리잡고 있음.
- 본 연구진은 흉부 X-ray, 생체신호, 임상 정보 등 멀티모달 데이터를 융합하여, 호흡기 질환의 진단 및 예후 예측 정확도를 높이는 연구에 집중해 왔으며, 중환자실 자발 호흡 시험 및 신생아 응급 삽관 예측 모델 등을 개발하여, 임상 현장에서의 실질적인 유용성을 입증하였음.
- 아울러 KOCOSS 코호트 데이터를 심층 분석하여 COPD 급성 악화 및 중증도를 선제적으로 판별하는 고정밀 예측 모델을 구축함으로써 만성 질환 관리 영역까지 연구를 확장하고 있음.
- 향후 데이터 기술과 임상 현장의 유기적인 결합을 통해 환자 맞춤형 치료를 선도하고, 의료진을 능동적으로 지원하는 '임상결정 보조 시스템' 을 완성해 나가고자 함.

감사합니다

Q&A

