

김정훈

ML Engineer / AI Researcher

portfolio.jhkim3ispark.work

삼일PwC 금융본부 LLM/Data Engineer

bandlagom0927@gmail.com

010-9559-9471 · 서울

github.com/thuygom



소개

기업 스키마를 검색·생성에 사용할 수 있도록 정리하고 Text-to-SQL 모델 학습과 실행 검증을 수행했습니다. 데이터 조회 권한과 장시간 AI 작업의 상태를 DB에서 관리하고, 추론 API·GPU 관측 경로를 구성했습니다.

경력·학력

이즈파크 R&D Center · AI Researcher

2025.08-현재

일학습병행 인턴 2025.08-2026.02 / 정규직 2026.03-현재

TieMing의 AI 개발 2인 중 1인으로 명함 OCR/KIE, 검색, 실시간 STT, CRM Text-to-SQL과 대화형 음성 기능을 담당했습니다.

AI Summit Seoul 2026 공개 시연·Android 비공개 베타·Play Store 등록 준비 중

portfolio-tieming.jhkim3ispark.work

한성대학교 컴퓨터공학부·빅데이터 전공·공학사

2019.03-2026.02

GPA 3.95/4.5 · IRIS Lab 학부연구원 2024-2026 · 논문 5편, 제1저자 4편

주요 경험

- DB의 약어·누락된 관계로 스키마 선택이 어려워 설명을 보완했습니다. Qdrant·Elasticsearch 검색 순위를 결합해 질문별 후보를 좁혔습니다.
- Distil-Qwen3-4B에 QLoRA를 적용하고 문법 유효성·DB 실행 성공·정답 결과 일치를 나누어 평가했습니다.
- 장시간 음성 처리에서는 단계별 산출물·작업 소유권·tenant 접근 범위를 DB와 인증 계층에서 관리했습니다.

개발·운영

- vLLM·FastAPI 추론 API와 Docker·cloudflared 배포를 구성했습니다. Prometheus·Grafana에서 서비스·컨테이너 상태와 GPU 메모리·온도·전력을 함께 관측했습니다.
- NIPA 고성능 컴퓨팅 지원사업의 **A100 2장**으로 LLM을 학습하고 있습니다. Weights & Biases로 실험을 관리하고 Hugging Face 비공개 저장소에 가중치를 보관합니다.

수상·자격·병역

수상—한성공학경진대회 대상(2023.09), 한성 SW페스티벌 최우수상(2024.11), ACK 2025 은상(2025.11), KSC 2025 장려상(2026.01), AI 스마트워크톤 은상(2026).

자격—SW개발 L5(2026), 정보처리산업기사·리눅스마스터 2급(2022).

병역—공군 정보체계 병 21개월·전문하사(2021.12-2022.12) 복무. Linux 서버·정보체계 관리.

모델 학습·기업 데이터 적용

CRM Text-to-SQL ·사내 조회와 권한 제어

2026.06-현재

- DB의 약어·누락된 관계로 스키마 선택이 어려워 설명을 보완했습니다. Qdrant·Elasticsearch 검색 순위를 결합해 질문별 후보를 좁혔습니다.
- SQLGlot으로 단일 SELECT/CTE·허용 스키마·LIMIT를 검사하고, READ ONLY transaction과 timeout으로 실행 범위를 제한했습니다.
- 사내 영업 데이터의 사용자별 조회 범위를 제한하도록 PostgreSQL RLS 기반 행 접근 제어를 설계·검증했습니다.
- 빈 결과·all-null·제외 대상·오류를 구분해 유효 결과에만 차트를 만들었습니다. 문서 검색에도 권한 정보를 적용하고, 검증 환경에서 권한 회수·복원에 따라 인용 근거가 달라지는 것을 확인했습니다.

[portfolio-t2s.jhkim3ispark.work](#)

Text-to-SQL ·별도 모델 학습 실험

- Distil-Qwen3-4B를 NF4 QLoRA로 후학습했습니다(학습 2,172건). 동일 템플릿 분포의 **합성 검증 241건에서 SQL token 완전 일치 85.1%**를 기록했습니다.
- 별도 실제 100질문은 **실행 결과 완전 일치 45%**, pipeline 완료 95/100, 평균 value-Jaccard 0.767이었습니다. 학습 adapter와 CRM 서비스 추론 경로를 분리했습니다.

GomOCR ·명함 OCR/KIE 후학습

2026.04-현재

- 검수 명함 2,906건을 train 2,034 / validation 581 / fixed test 291로 나누고 ID·이미지 SHA-256 교차 중복을 점검했습니다.
- Qianfan-OCR의 vision tower를 고정하고 language model·projector를 NF4 QLoRA로 후학습했습니다. RTX 4090 2장 DDP·BF16·effective batch 16을 적용했습니다.
- 후학습·출력 보정 후 기존 모델 대비 **필드 값 정확도 30.2 → 65.3%, 목록 micro-F1 54.5 → 80.2%**를 기록했습니다(고정 test 291건).
- JSON 실패만 재생성해 같은 adapter의 **parse 오류를 27 → 1건**으로 줄였습니다. 조건은 validation에서 정했고 test는 이전 관측 세트입니다. 주소 F1·record exact의 소폭 회귀도 확인했습니다.

[portfolio-gomocr.jhkim3ispark.work](#)

서비스 통합

iScribe · 실시간 STT · 음성 처리

2026.03-현재

- AMI 회의 4건(경계 허용오차 0초 · 겹침 발화 포함)에서 **가중 DER 28.72 → 26.92%**인 Community-1을 선정했습니다.
- 실시간 STT의 5화자 연결음성 1건(enroll · loose 평가)에서 동기화 · 중복 전사를 수정해 **WER 62.77 → 34.06%**, DER 48.58 → 30.23%로 줄였습니다.
- 실시간 세션 · 장시간 job을 분리하고 PostgreSQL 원장으로 재시작 복구를 구현했습니다. GPU advisory lock · OIDC로 작업 진입과 tenant 접근을 제어했습니다.

iscribe.jhkim3ispark.work

체험 계정: demo / 비밀번호: demo

TieMing · 명함 · 검색 · 음성 통합

- 명함의 이름 · 소속 · 연락처를 외부 검색과 CRM 조회로 연결하고 음성 입력 · 회의 기록을 같은 관계 맥락에서 사용할 수 있도록 AI 기능을 통합했습니다.

portfolio-tieming.jhkim3ispark.work

논문 5편 · 제1저자 4편

MRO —Multimodal Routing Optimization via Neural Architecture Search of Fusion Paths

IJIBC 17(3), 144-154 · KCI 등재 · 2025.08 · 제1저자

IN-MRO —암시적 NAS 정책학습 기반 멀티모달 경로 최적화

KSC 2025.12 · 제1저자 · 장려상(2026.01 수상)

AURA —멀티모달 인플루언서 지지도 추정을 위한 Attention 기반 사용자 반응 분석

KIPS 2025.05 · 제1저자

SCOPE-X —창작자 보호를 위한 SNS 정서 리스크 지표화

KIPS 2025.11 · 공동저자 · 은상

SCOPE —A Transformer-Based System for Predicting Influencer Popularity via Comment Sentiment and Topic Analysis

AICOMPS 2024 · 제1저자

특허 출원 · 심사청구

데이터베이스 설명 자동 생성 및 환각 억제 기능을 갖는 Text-to-SQL 전처리 방법

10-2026-0119188 · 2026.06.30 · 발명자 김정훈