

생성형 AI 기반 RAG 개발자 과정

생성형 AI 기반 RAG 개발자 과정

Session 0 / 33 — OT + 개발환경

LLM 이론 · LangChain · ChromaDB CRUD · Agent — 4일 핸드온

박수현 · (사)한국정보공학기술사회 · 2026

LLM 이론 · LangChain · ChromaDB CRUD · Agent — 4일 핸드온

4일을 마치면 만들 수 있는 것

Day 1 — LLM 이해와 핵심 이론

-  **Transformer · Attention · Q·K·V** 직관
-  **GPT·RLHF·MoE·추론모델** 진화 이해
-  OpenAI **API** · 챗봇 첫 코드
-  임베딩·코사인으로 미니 RAG 직접 구현

Day 3 — 실제 RAG 웹서비스

-  **Flask** REST 서비스 구조 설계
-  문서 업로드 (multipart, PDF/TXT/DOCX)
-  **ChromaDB CRUD** — 색인·조회·삭제
-  질의응답 **API + Chat History** 챗봇 완성

Day 2 — LangChain 기반 RAG

-  **LCEL · PromptTemplate** 파이프라인
-  **Loader · Splitter** (TXT/PDF/DOCX)
-  **FAISS · ChromaDB** 인덱스
-  **Retriever + RAG Chain** + 출처·평가

Day 4 — Agent 기반 서비스

-  **AI Agent** 개념과 ReAct 루프
-  **Tool 호출** — Wikipedia · Math · Custom
-  **LangGraph** · Anthropic **5대 패턴**
-  **Agentic RAG** + RAG 서비스에 Agent 결합

강의 자료 & 실습 예제 다운로드

실습 예제 (일자별)

- Day 1~4 빈칸 실습 템플릿 + 웹 데모 static(HTML/CSS/JS) + README
- 슬라이드의 코드 스니펫을 직접 따라치며 완성하는 파일
- 필요한 일자만 받아 압축 해제

 [Day 1](#) · [Day 2](#) · [Day 3](#) · [Day 4](#)

통합 교안 PDF·실습 묶음은 [인덱스 페이지](#)의 ' 강의 자료 다운로드' 카드에서도 받을 수 있습니다.

강의 슬라이드 (PDF)

- 각 회차는 뷰어에서 PDF 다운로드 가능 (인쇄·복습용)

시작하기

1. 해당 일자 압축 해제 — `tar xzf day1.tar.gz`
2. `.env` 에 `OPENAI_API_KEY` 설정
3. Day 폴더에서 실습 진행

대상 학습자

이 코스가 맞는 대상

- **Python 기본 문법**을 알고 있는 개발자
- 웹 백엔드(Flask/Django) 경험이 있거나 익숙해질 의지가 있는 학습자
- **API 호출 + JSON 처리** 정도는 직접 해 본 적 있는 분
- LLM 을 자신의 서비스/사이드 프로젝트에 결합하고 싶은 분
- LangChain·RAG·Agent 를 들어만 봤지 아직 **실제 코드로 만들어 본 적 없는** 분

이 코스가 적합하지 않은 대상

- Python 을 처음 배우는 분 (별도 입문 과정 권장)
- **수식 위주 ML 이론**을 원하는 분 (이 코스는 응용 위주)
- 모델 학습/파인튜닝이 주 목적인 분 (별도 코스)

코스 목표

"4일 안에 직접 가진 데이터로 **RAG + Agent 데모**를 돌리는 것."

4일 × 33세션 전체 지도

July 17

Day 1 (S0~8) — LLM 이해와 핵심 이론

OT/환경 · LLM 발전사 · Transformer · GPT·RLHF·MoE · OpenAI API · 챗봇 · RAG 개요 · 임베딩·유사도 · 미니프로젝트

July 17

Day 2 (S9~16) — LangChain 기반 RAG

LangChain/LCEL · Prompt · Loader · Splitter · Vector DB·FAISS · ChromaDB · Retriever · RAG Chain

July 17

Day 3 (S17~24) — 실제 RAG 웹서비스

Flask 구조 · 업로드 · 파싱·임베딩 · Chroma 조회(R) · 삭제(D) · 질의 응답 API · Chat History · 최종 프로젝트

July 17

Day 4 (S25~32) — Agent 기반 서비스

Agent 입문 · Tool · LangGraph · Agentic 5패턴 · Agentic RAG · Agent+RAG 결합 · 로컬·배포 · 최종 회고

🎯 흐름: 이론(왜) → API·챗봇 → RAG 개념 → LangChain RAG → 웹서비스화(CRUD) → 자율성(Agent)

PART A

PART A

개발환경 셋업

conda 환경 · 의존성 · .env · IDE — 약 50분

Python 3.12 — 본 코스 권장 버전

✓ 3.12 인 이유

- LangChain 1.x / LangGraph 의 권장 환경
- PyTorch · sentence-transformers 안정 지원
- 성능 개선 (3.11 대비 약 11% 향상)
- 3.13 은 일부 ML 패키지 호환성이 아직 부족

✗ 권장하지 않는 버전

- 3.9 이하 — 일부 LangChain 기능 미지원
- 3.10 — 호환은 되지만 deprecation 경고가 늘어남
- 3.13 — 일부 native 패키지 빌드 실패 가능

🎯 본 코스가 가정하는 환경

항목	값
OS	Windows / macOS / Linux 무관
Python	3.12.x
패키지 관리	conda + pip
가상환경 이름	py312_gpt
IDE	VS Code 또는 Cursor

💡 macOS Apple Silicon: 별도 설정 없이 native arm64 로 설치됩니다.

conda 설치 — Miniconda vs Anaconda

Miniconda (권장)

- 약 **400MB**
- conda + Python 만 포함
- 필요한 패키지만 추가 설치 → 디스크 절약
- 다운로드: docs.anaconda.com/miniconda

Anaconda

- 약 **3GB** — pandas/numpy/scikit-learn 등 250+ 패키지 포함
- 초보자에게는 편리하지만, 본 코스에서는 사용하지 않는 패키지가 더 많음
- 다운로드: anaconda.com/download

OS 별 설치 (Miniconda 기준)

```
# macOS (Apple Silicon)
brew install --cask miniconda

# Linux
wget https://repo.anaconda.com/miniconda/Miniconda3-latest-Linux-x86_64.sh
bash Miniconda3-latest-Linux-x86_64.sh

# Windows
# 위 URL 에서 .exe 다운로드 → 더블클릭 설치
# "Add Miniconda3 to PATH" 체크 권장 (개발자라면 OK)
```


py312_gpt 환경 만들기

명령어 세 줄이면 끝

```
# 1. 환경 생성 - Python 3.12
conda create -n py312_gpt python=3.12 -y

# 2. 활성화
conda activate py312_gpt

# 3. 확인
python --version          # → Python 3.12.x
which python              # → ~/miniconda3/envs/py312_gpt/bin/python
```

자주 만나는 셸 이슈

```
# conda activate 가 동작하지 않을 때 (bash/zsh)
conda init bash          # 또는 zsh
exec $SHELL              # 셸 재시작 없이 반영

# Windows PowerShell
conda init powershell
# 그런 다음 PowerShell 재시작
```

💡 **환경 이름 규칙:** 본 코스의 모든 코드/README 가 `py312_gpt` 를 가정합니다. 다른 이름을 쓰면 안내 명령의 환경명을 그에 맞게 바꿔 쓰세요.

핵심 의존성 한 번에

설치 — pip install

```
conda activate py312_gpt

# Day 1 ~ Day 3 전체 의존성
pip install \
  openai=1.* \
  anthropic=0.40.* \
  python-dotenv \
  flask requests tiktoken \
  langchain=1.* \
  langchain-openai \
  langchain-anthropic \
  langchain-community \
  langchain-text-splitters \
  langchain-chroma \
  faiss-cpu chromadb pypdf \
  sentence-transformers \
  langgraph \
  wikipedia duckduckgo-search
```

검증 — 모두 import 되는지

```
python -c "
import openai, anthropic, langchain, langgraph
import faiss, chromadb, tiktoken, pypdf
print('✅ 모든 핵심 패키지 import 성공')
print('openai:', openai.__version__)
print('langchain:', langchain.__version__)
"
```

⚠️ Windows + `faiss-cpu` 실패 시 `pip install --no-cache-dir faiss-cpu` 또는 `conda install -c pytorch faiss-cpu` 시도.

본 코스 실습 코드

```
git clone https://aithub.com/lovehvun/tutorial-aenai.git
```

📁 주요 폴더 매핑

폴더	다루는 세션
1.openai/1.intro/	Day1 S4 — REST / SDK old / SDK new
1.openai/2~5.chatbot*/ · 8.streaming/	Day1 S5 — 챗봇 (history · sqlite · session · SSE)
2.langchain/7.RAG/1.basics/	Day1 S7·8 — 임베딩·유사도·미니 RAG
2.langchain/1.llm_models~4.chaining/	Day2 S9·10 — LangChain · LCEL · Prompt
2.langchain/7.RAG/2.loaders/	Day2 S11·12 — Loader · Splitter
2.langchain/7.RAG/3.vectorstore/	Day2 S13·14 — FAISS · ChromaDB
2.langchain/7.RAG/4.rag_chain/	Day2 S15·16 — Retriever · RAG Chain
2.langchain/7.RAG/8.web_app/	Day3 S17~24 — Flask RAG 웹서비스 (CRUD)
2.langchain/7.RAG/5.conversational/	Day3 S23 — Chat History RAG
2.langchain/8.agents/	Day4 S25·26·28 — Agent · Tool · 패턴
2.langchain/9.langgraph/	Day4 S27 — LangGraph
2.langchain/7.RAG/6.agentic/ · 7.local_model/	Day4 S29·31 — Agentic RAG · 로컬

API Key 는 `.env` 에 — 코드에 하드코딩하지 말 것

`.env` 파일 (저장소 루트)

```
# OpenAI
OPENAI_API_KEY=sk-proj- ...

# Anthropic (Day 3 에서 사용)
ANTHROPIC_API_KEY=sk-ant- ...

# Google Gemini (옵션)
GOOGLE_API_KEY= ...

# LangSmith (옵션 - Agent 추적)
LANGCHAIN_TRACING_V2=true
LANGCHAIN_API_KEY= ...
```

`.gitignore` 에 반드시

```
.env
.env.*
*.key
```

Python 에서 불러오기

```
# pip install python-dotenv
from dotenv import load_dotenv
import os

# 같은 폴더의 .env
load_dotenv()

# 상위 폴더의 .env (1.openai/1.intro 에서 루트 .env 참조)
load_dotenv(dotenv_path='../.env')

api_key = os.getenv('OPENAI_API_KEY')
```

 본 코스 코드는 대부분 루트 `.env` 를 참조합니다
(`load_dotenv(dotenv_path='../.env')`).

API Key — 깃(git)에 올리면 5분 안에 도용

#	원칙	위반 시
1	<code>.env</code> 에 저장, <code>.gitignore</code> 에 추가	GitHub 봇이 5분 내 키 수집 → 무단 사용 → 청구서 폭탄
2	결제 한도(spend limit) 를 무조건 설정	도용 발생해도 손해 최소화
3	Usage 알림 이메일 활성화	비정상 사용 즉시 감지
4	노출 의심되면 즉시 폐기 후 재발급	시간 끌수록 손해 커짐
5	다른 사람과 절대 공유 금지 — 팀이면 키 별도 발급	누가 썼는지 추적 불가

사고 사례

- OpenAI: 한 학생이 API 키를 코드에 하드코딩한 채 `git push` → 2시간 만에 봇이 발견 → 약 600달러 누적
- AWS: 동일 패턴으로 EC2 마이닝 → 며칠 만에 수만 달러

PART B

PART B

IDE 선택

VS Code · Cursor · Claude Code — 약 10분

VS Code vs Cursor vs Claude Code

항목	VS Code	Cursor	Claude Code
가격	무료	월 \$20 (Pro)	API 종량제
AI 모델	GitHub Copilot (별도)	GPT-4o · Sonnet · 자체	Claude (Opus/Sonnet/Haiku)
Python 지원	확장으로 우수	확장으로 우수 (VS Code 기반)	CLI 기반, 모든 에디터 무관
본 코스 적합도	★★★★ — 기본기	★★★★★ — AI 페어 코딩	★★★★★ — 터미널 워크플로우
추천 대상	처음 IDE 고르는 분	AI 보조에 익숙해지고 싶은 분	터미널 작업이 손에 익은 분

본 코스 강의 시연 환경

- VS Code + Python 확장 으로 시연 (가장 보편적)
- 다른 IDE 가 익숙하면 그걸로 진행해도 됩니다

본 코스에서 도움 되는 5가지

확장	역할
Python (Microsoft)	인터프리터, 디버거, 린팅 — 필수
Pylance	타입 추론, 자동완성 — Python 확장 설치 시 자동
Jupyter	<code>.ipynb</code> 노트북, 인라인 결과 — 회차 4 부터 권장
Ruff	빠른 린터·포매터 (PEP8 자동 정리)
dotenv	<code>.env</code> 파일 syntax highlight

설치 — 한 번에

```
code --install-extension ms-python.python
code --install-extension ms-toolsai.jupyter
code --install-extension charliermarsh.ruff
code --install-extension mikestead.dotenv
```

인터프리터 선택

```
Ctrl + Shift + P
→ Python: Select Interpreter
→ py312_gpt
```

💡 **확인 방법:** VS Code 좌하단에 `Python 3.12.x ('py312_gpt')` 가 표시되어야 OK.

PART C

PART C

첫 실행

Hello, LLM — 약 10분

코드 4줄로 첫 호출

hello_llm.py

```
from openai import OpenAI
client = OpenAI() # OPENAI_API_KEY 는 환경변수에서 자동 인식

resp = client.chat.completions.create(
    model="gpt-4o-mini",
    messages=[{"role": "user", "content": "한 줄로 자기소개해줘"}],
)
print(resp.choices[0].message.content)
```

실행

```
conda activate py312_gpt
cd tutorial-genai/1.openai/1.intro
python 3.sdk_new.py
```

예상 출력 (예시)

저는 OpenAI 가 만든 인공지능 비서로,
다양한 질문에 답변하고 글쓰기·요약·
분석·코드 작성 같은 작업을 도와드립니다.

잘 안 될 때 — 디버그 체크리스트

에러 메시지	원인	해결
<code>ModuleNotFoundError: No module named 'openai'</code>	conda 환경 활성화 안 함	<code>conda activate py312_gpt</code>
<code>openai.AuthenticationError: 401</code>	API Key 누락 또는 만료	<code>.env</code> 확인, 플랫폼에서 키 재발급
<code>openai.RateLimitError: 429</code>	초당 호출 한도 초과	<code>time.sleep(1)</code> 추가, 결제수단 등록 확인
<code>openai.InsufficientQuotaError</code>	무료 크레딧 소진	결제수단 등록 + spend limit 설정
<code>ssl.SSLError</code>	회사망/프록시 차단	핫스팟 사용 또는 IT 부서 문의

가장 흔한 시나리오 (90%)

```
# 1. 어디서 실행 중인지 확인
which python          # → py312_gpt 가 아니면 활성화 누락

# 2. .env 가 같은 디렉토리에 있는지
ls -la .env

# 3. .env 에 키가 실제로 있는지 (값은 마스킹)
grep "^OPENAI" .env
```

오늘 정리 7가지

1.  Python **3.12** + **conda** 환경 `py312_gpt` 생성
2.  핵심 의존성 (`openai`, `langchain`, `chromadb` 등) 설치
3.  소스 코드 클론 — `tutorial-genai/`
4.  `.env` 에 OPENAI_API_KEY 저장 + `.gitignore` 등록
5.  결제 한도 (Soft \$5, Hard \$20) 설정
6.  VS Code 인터프리터 선택 → `py312_gpt`
7.  첫 호출 — `Hello, LLM` 응답 확인

시작 전 — 점검 4가지

- [] **conda activate py312_gpt** 가 정상 동작
- [] **OPENAI_API_KEY** 가 `.env` 에 저장됨, Hard limit 설정됨
- [] `python 3.sdk_new.py` 실행해 출력 확인
- [] (옵션) **ANTHROPIC_API_KEY** 도 같이 발급 (Agent 실습용)

최종 점검

```
cd tutorial-genai
conda activate py312_gpt
python -c "
from openai import OpenAI
r = OpenAI().chat.completions.create(
    model='gpt-4o-mini',
    messages=[{'role':'user','content':'준비 완료?'}],
    max_tokens=20
)
print('✅', r.choices[0].message.content)
"
```

위 한 줄이 응답 출력되면 **개발환경 준비 완료.**

안 되면 슬라이드 18(트러블슈팅) 참고 또는 강사에게 화면 공유 요청.