




AIR LAB



GOOGLE ADK



NUR GÜMÜS
AI ENGINEER



İÇERİK

- GİRİŞ
- AI ENGINEER
- AGENT NEDİR
- AGENT ANATOMİSİ
- BEYİN=LLM
- AGENT DESIGN PATTERNS
- TOOLBOX
- MULTI AGENTIC SİSTEMLER
- AGENTLARDA BİLİNMESİ
GEREKEN KAVRAMLAR

- LIMITATIONS AND
CHALLENGES
- GOOGLE ADK NEDİR
- GOOGLE ADK ÖZELLİKLERİ
- DİĞER TOOLLARLA
KARŞILAŞTIRMA
- DEMO
- KİTAP, YOUTUBE KANALI VS
KAYNAK ÖNERİLERİ
- Q&A



GIRIS

- LLM'ler yeterince akıllılaştı (GPT, Gemini, GLM, Opus, Sonnet vs.)
- Function Calling standardı oturdu
Şimdi: LLM direkt JSON döndürüyor, hangi tool'u çağıracağını biliyor
- Framework'ler olgunlaştı
- Maliyet 10x düştü
- Gerçek production use case'ler ortaya çıktı (Cursor, Copilot, other coding agents)
- MCP standartları (farklı appleri pipelinelara bağlama kolaylığı)



AI ENGINEER

- 5 yıl önce bu title yoktu. Şimdi dünyanın en çok aranan mühendislik pozisyonu.

KLASİK ROLLER:

- Software Engineer → Kod yazar
- Data Scientist → Veriyi analiz eder
- ML Engineer → Model eğitir, deploy eder
- AI Engineer → Agent & LLM uygulamaları yapar

AI ENGINEER NE YAPAR?

- LLM'leri uygulamaya entegre eder
- Agent sistemleri tasarlar ve geliştirir
- Prompt engineering & optimization
- RAG pipeline'ları kurar
- Tool & API entegrasyonları yapar
- Production'a alır, monitor eder

ML Engineer	AI Engineer
Model eğitir	Model kullanır
Matematik ağır	Mühendislik ağır
Pytorch, TF vs.	Langchain, Google ADK, n8n vs.



AIR LAB

AGENT NEDİR?

Senaryo: Bir Ressam Agent İstiyorsunuz


Amacınız bir AI Agent'ın sizin için bir resim çizmesi. Bu agentın nelere ihtiyacı var?



Tools
(Tuval, Fırça, Boya
vs.)



Memory
(Kullanıcı rönesans
eserlerini
seviyordu)



Session
(Mesai Saati)



Instruction
(Fırçayı al, boyayı
bandır, tuvale sür
vs.)




Human in the loop
(İstedğinde
sorabilirsin)

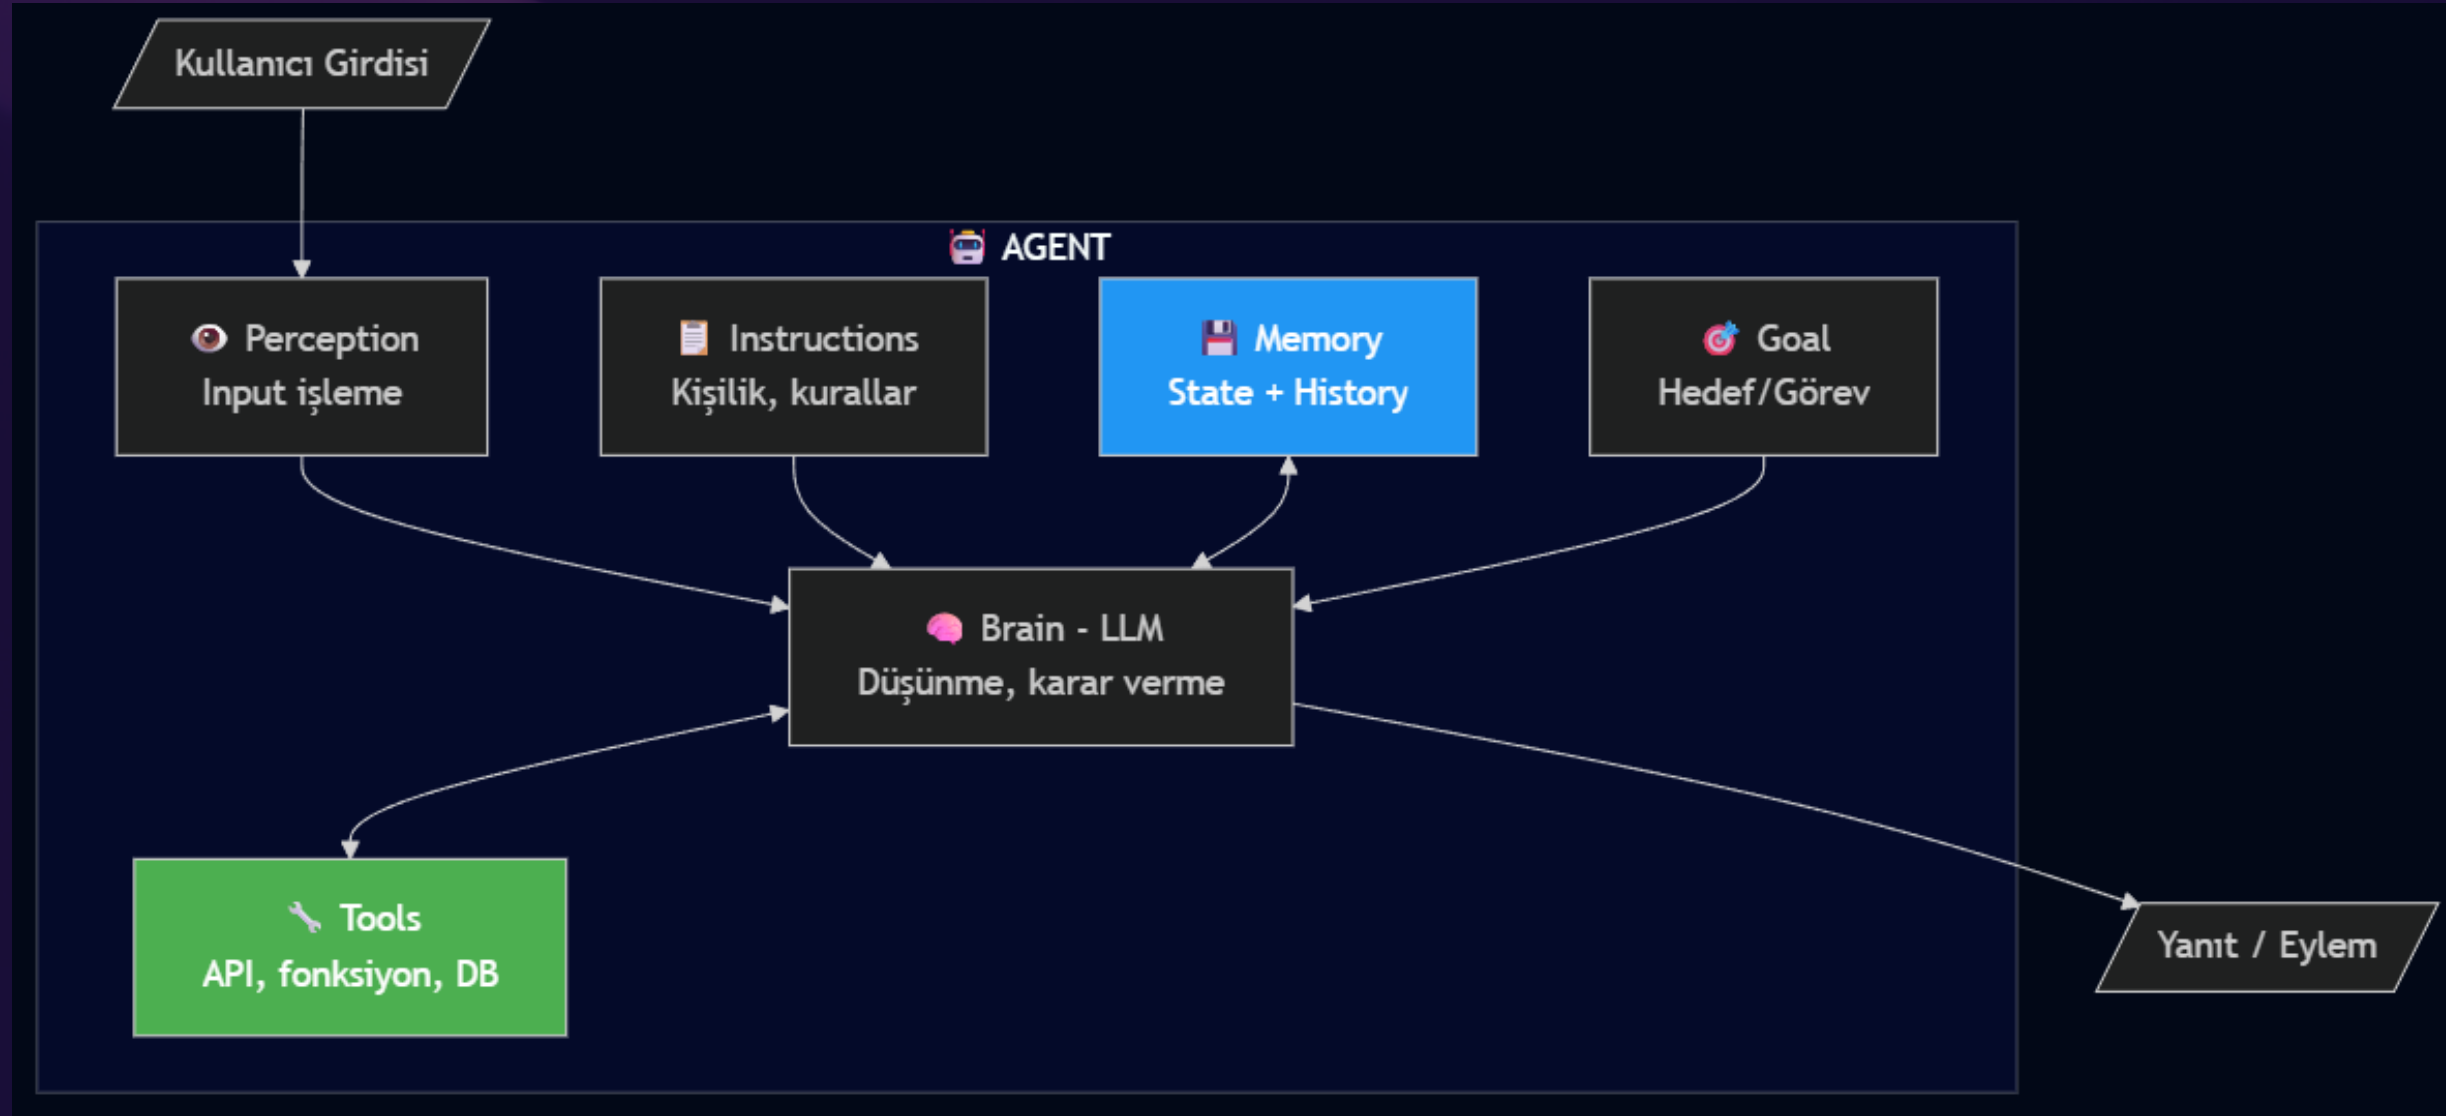


AIR LAB

AGENT NEDİR?




Agent = LLM + Tools + Reasoning Loop + Memory



Bir hedefe ulaşmak için otonom olarak planlama yapabilen, araçları kullanabilen ve çevresine tepki verebilen AI sistemi



AGENT MIMARISI



1. PERCEPTION (Algılama)

- Kullanıcıdan input alma
- Dosya okuma, API'den veri çekme
- 'Dış dünyayı görme'

2. BRAIN (Beyin = LLM)

- Karar verme merkezi
- 'Ne yapmalıyım?' sorusunu cevaplıyor
- En kritik bileşen

3. MEMORY (Hafıza)

- Kısa vadeli: Bu conversation'da ne konuştuk?
- Uzun vadeli: Bu kullanıcı kim, ne sever?

4. TOOLS (Araçlar)


- Dış dünyaya etki etme
- API çağırma, dosya yazma, email atma

5. OUTPUT (Çıktı)

- Kullanıcıya yanıt
- Veya bir aksiyon (dosya oluşturma, email gönderme)



BEYİN = LLM



Bazı Önemli Paperlar

Chain-of-Thought (CoT) Prompting

"Chain-of-Thought Prompting Elicits Reasoning in Large Language Models"

Ana Fikir:

"LLM'lere adım adım düşünmesini söylersen, reasoning performansı dramatik şekilde artar"

Anahtar Bulgular:

- "Let's think step by step" → %50+ performans artışı (matematik problemlerinde)
- Sadece büyük modellerde çalışıyor (100B+ parametre)
- Fine-tuning gerektirmiyor, sadece prompt değişikliği
- GSM8K benchmark'ta fine-tuned GPT-3'ü bile geçti

Örnek:

✗ Standart: "Roger'ın 5 tenisi var. 2 kutu daha aldı, her kutuda 3 top. Kaç topu var?"


→ Cevap: 11 (yanlış)

✓ CoT: "Adım adım düşünelim. Roger 5 topa başladı. 2 kutu aldı, her kutuda 3 top = 6 top. 5 + 6 = 11"

→ Cevap: 11 (doğru, ama reasoning gösteriliyor)



BEYİN = LLM



Bazı Önemli Paperlar

ReAct (Reasoning + Acting)

"ReAct: Synergizing Reasoning and Acting in Language Models" <https://arxiv.org/abs/2210.03629>

"Reasoning ve Acting'i birleştir: Düşün → Eylem yap → Gözlemle → Tekrarla"

Neden Önemli:

- CoT'un eksikliği: Sadece düşünüyor, dış dünyayla etkileşim yok
- ReAct: Düşünme + Araç kullanma (Wikipedia API, hesaplama, vs.)
- Hallucination azalıyor çünkü gerçek veriye erişiyor
- Agent'ların teorik temeli bu paper

ReAct Döngüsü:

Thought: "Colorado'nun başkenti nedir öğrenmeliyim"

Action: Search["Colorado capital"]

Observation: "Denver is the capital of Colorado"

Thought: "Denver'in nüfusunu bulmalıyım"

Action: Search["Denver population"]

...


Sonuçlar:

- HotpotQA: +%6 accuracy (CoT'a göre)
- ALFWorld: +%34 success rate
- WebShop: +%10 success rate



AIR LAB

BEYİN = LLM



Bazı Önemli Paperlar

Tree of Thoughts (ToT)

"Tree of Thoughts: Deliberate Problem Solving with Large Language Models" <https://arxiv.org/abs/2305.10601>

Ana Fikir:

"Tek bir düşünce zinciri yerine, birden fazla yolu dene ve en iyisini seç"

CoT vs ToT:

CoT: $A \rightarrow B \rightarrow C \rightarrow D$ (tek yol)

ToT: $B1 \rightarrow C1$ ✗



$A \rightarrow B2 \rightarrow C2 \rightarrow D$ ✓



$B3 \rightarrow C3$ ✗


Neden Önemli:

- Backtracking (geri dönüş) mümkün
- Paralel keşif
- Self-evaluation: "Bu yol umut verici mi?"
- Karmaşık problemlerde (24 oyunu, sudoku) çok etkili



AIR LAB

BEYİN = LLM





Bazı Önemli Paperlar

PAPER	ANA KATKI	LİNK
SELF-CONSISTENCY (WANG ET AL., 2022)	BİRDEN FAZLA COT ÇALIŞTIR, EN TUTARLI CEVABI SEÇ	ARXIV.ORG/ABS/2203.11171
LEAST-TO-MOST (ZHOU ET AL., 2022)	PROBLEMI ALT PROBLEMLERE BÖL	ARXIV.ORG/ABS/2205.10625
REFLEXION (SHINN ET AL., 2023)	AGENT HATALARINDAN ÖĞRENİR	ARXIV.ORG/ABS/2303.11366
TOOLFORMER (SCHICK ET AL., 2023)	LLM KENDİ KENDİNE TOOL KULLANMAYI ÖĞRENİR	ARXIV.ORG/ABS/2302.04761



AGENT DESIGN PATTERNLARI



1. ReAct (Reason + Act)

En basit ve yaygın pattern

Düşün → Yap → Gözlemle → Tekrarla

2. Plan-and-Execute

Önce tam plan yap, sonra execute et

Daha uzun vadeli görevler için

3. Reflexion (Self-correction)

Hata yaptığında kendini düzelt

'Öğrenen agent'

4. Tool-use Patterns

Hangi tool'u ne zaman çağıracacağını bilme





AIR LAB

TOOLBOX

➡ AGENT ORCHESTRATION

Google ADK, CrewAI, LangChain, LangGraph, n8n, AutoGen

➡ DATABASE

MongoDB, Redis, PostgreSQL, SQLite

➡ MONITORING & OBSERVABILITY

Langfuse, LangSmith, Weights & Biases, OpenTelemetry

➡ API LAYER

Flask, FastAPI, Django REST

➡ MCP

Tool'lar için USB-C standardı

➡ VECTOR DATABASE

Pinecone, Qdrant, Chroma, pgvector

➡ LLM PROVIDERS

OpenAI, Anthropic, Google Gemini, Ollama (local), Groq or local

➡ DOCUMENT PROCESSING

Unstructured, PyPDF, LlamaParse, Docling, DeepParse

➡ KNOWLEDGE GRAPH


Neo4j, Amazon Neptune

➡ FLOW PLANNING

Mermaid



MULTI AGENTIC SİSTEMLER



NEDEN MULTI-AGENT?

1. System Prompt Şişmesi

Tek agent'a her şeyi öğretmek → 5000+ token prompt

→ Modelin kafası karışır

2. Uzmanlaşma (Separation of Concerns)

Her agent TEK bir iş bilsin

Frontend Agent, Backend Agent, Review Agent...

3. Maliyet Optimizasyonu

Basit iş → Ucuz model (Gemini Flash)

Zor iş → Pahalı model (GPT-4, Opus)

4. Paralel Çalışma Bağımsız agent'lar aynı anda çalışabilir



5. Debug & Test "Hangi agent hata yaptı?" sorusu cevaplanabilir

ÖRNEK: Cursor IDE – 8 agent'a kadar paralel çalışma – Frontend, Backend, Reviewer, DevOps agent'ları – Günlük milyarlarca completion




AIR LAB

MULTI AGENTIC SİSTEMLER



PROMPT ENGINEERING



"System Prompt vs User Prompt:

- System: Agent'in KİMLİĞİ (değişmez)
- User: Her istekte gelen mesaj


Few-shot Examples:

- 'Şöyle input gelirse, şöyle output ver'
- 2-3 örnek genellikle yeterli

Structured Output (JSON Mode):

- LLM'e 'JSON döndür' dersen, parse etmesi kolay
- Tool calling buna dayanıyor"

DsPy tarzı kütüphaneler



TOKEN ECONOMICS

"Context Window:


- LLM'in bir seferde görebildiği maksimum token
- GPT-4 Turbo: 128K, Gemini: 1M+

Input vs Output Fiyatlandırma:

- Input (prompt) genellikle UCUZ
- Output (generation) genellikle PAHALI
- 10x fark olabilir!

Truncation:

- Context'e sığmıyorsa, eski mesajları kes
- Ya da özetle (summarization)"



MODEL PARAMETRELERİ

"Temperature:



- 0 = Deterministik (hep aynı cevap)
- 1 = Yaratıcı (her seferinde farklı)
- Agent'lar için genellikle 0-0.3

Top-p, Top-k:

- Hangi token'ları düşüneceğini sınırlar
- Genellikle default bırakılır

Max Tokens:

- Maksimum output uzunluğu
- Agent loop'larında dikkat: Çok uzun = pahalı"



PRODUCTION CONCERNS

"Rate Limiting:

- API'ler saniyede X istek kabul eder
- Aşırsan 429 hatası

Retry Logic:

- API hata verirse, bekle ve tekrar dene
- Exponential backoff: 1s, 2s, 4s, 8s...


Cost Monitoring:

- Agent'lar loop'ta çalışır, maliyet hızla artar
- Max iteration, max token limitleri koy

Fallback:

- Ana model çökerse, yedek modele geç
- GPT-4 → GPT-3.5, Opus → Sonnet"





MEMORY

MEMORY KATMANLARI

1. Short-term (Conversation History)

- Bu oturumda ne konuştuk?
- Context window içinde tutuluyor

2. Long-term (Persistent)

- Kullanıcı tercihleri, geçmiş kararlar
- Veritabanında saklanıyor

3. Episodic (Experience)

- "Geçen sefer X yaptığımda Y olmuştu"
- Reflexion pattern için

4. Semantic (Knowledge)

- RAG ile dış bilgiye erişim
- Vector database'de



⚠ Memory = Context Window Yönetimi
Sonsuz hafıza yok, stratejik olmalı





AIR LAB

TOOLS



TOOL ÇAĞIRMA NASIL ÇALIŞIR?

1. LLM tool listesini görür
2. "Bu görevi yapmak için X tool'u lazım" der
3. Framework tool'u çağırır
4. Sonuç LLM'e geri döner
5. LLM sonucu yorumlar

ÖRNEK:

User: "Hava nasıl?"

LLM: `<tool_call>weather_api("Istanbul")</tool_call>`

System: `{"temp": 18, "condition": "sunny"}`

LLM: "İstanbul'da hava güneşli, 18°C"

⚠ LLM SADECE GEREKTİĞİNDE TOOL KULLANMALI

Basit soru → Direkt cevap

Dış veri lazım → Tool çağır



AIR LAB

SESSION

SESSION YÖNETİMİ

Neden önemli?

- Agent sonsuz çalışmamalı
- Maliyet kontrolü
- Timeout handling

LIMITLER:

Max Iterations: Kaç loop dönebilir?



Max Tokens: Ne kadar harcayabilir?

Timeout: Kaç saniye/dakika çalışabilir?

Cost Limit: Max \$ harcama


BEST PRACTICE:

- Her session'a unique ID ver
- Logları sakla (debugging için)
- Graceful shutdown (yarıda kalan iş için)





LIMITATIONS AND CHALLENGES



HALLUCINATION:

LLM yanlış bilgi uydurabilir.

Çözüm: Tool ile doğrulama, RAG kullanımı

INFINITE LOOP:

Agent aynı şeyi tekrar tekrar yapabilir.

Çözüm: Max iteration limiti, loop detection

MALİYET:

Her LLM çağrısı para. Loop = çok para.

Çözüm: Ucuz model tercih et, cache kullan

LATENCY:

Her LLM çağrısı 1-5 saniye.

5 turlu agent = 5-25 saniye bekleme

Çözüm: Streaming, paralel çağrılar

PROMPT INJECTION:

Kullanıcı agent'ı manipüle edebilir.

Çözüm: Input validation, sandboxing

EVALUATION:


'Agent iyi çalışıyor mu?' ölçmek zor.

Çözüm: Benchmark, A/B test, human eval, LLM AS A JUDGE



AIR LAB

OVERENGINEERING



⚠ LLM HER ZAMAN GEREKLİ Mİ?

HAYIR!

✗ LLM GEREKMEZ:

- JSON parse
- Tarih hesaplama
- Basit API çağırısı
- Format dönüştürme

✓ LLM GEREKİR:

- Belirsiz input anlama
- Karar verme (trade-off)
- Özet/sentez
- Doğal dil → yapı

KURAL: Klasik kod yapabiliyorsa → klasik kod yap

Klasik otomasyon, algoritmalar karşılayabiliyorsa; onları kullan.

GOOGLE ADK

GOOGLE ADK NEDİR?

Agent Development Kit

- Google'ın açık kaynak agent framework'ü
- Python-first
- Gemini-optimized (ama diğer LLM'ler de çalışır)

TEMEL BİLEŞENLER:

- Agent: Ana class
- Tool: Fonksiyon tanımlama
- Runner: Çalıştırma
- Session: State yönetimi

BASİT ÖRNEK:

```
from google.adk import Agent, Tool
```

```
@Tool
```

```
def get_weather(city: str) -> str:  
    return f"{city}: 18°C, güneşli"
```

```
agent = Agent(  
    model="gemini-2.0-flash",  
    tools=[get_weather],  
    instruction="Sen bir hava durumu  
asistanısın"  
)
```

GOOGLE ADK

ADK'DA HER ŞEY HAZIR

Diğer framework'lerde KENDİN YAZARSIN:

- Konuşma geçmişi? → Kendin tut
- Kullanıcı tercihleri? → Kendin kaydet
- Oturumlar arası hafıza? → Kendin tasarla
- Veritabanı bağlantısı? → Kendin kur
- State yönetimi? → Kendin implement et

ADK'da HEPSİ BUILT-IN:

- Session → Konuşma takibi
- State → Veri saklama (4 farklı scope!)
- Memory → Uzun vadeli hafıza
- SessionService → Persistence
- MemoryService → Arama & geri çağırma

GOOGLE ADK: SESSION

SESSION = BİR KONUŞMA THREAD'İ

Her kullanıcı etkileşimi = 1 Session

Session İçeriği:

- id → Benzersiz session ID
- user_id → Kim konuşuyor?
- app_name → Hangi agent?
- events → Konuşma geçmişi (kronolojik)
- state → Agent'in not defteri
- last_update → Son aktivite zamanı

KOD:

```
from google.adk.sessions import  
InMemorySessionService
```

```
service = InMemorySessionService()
```

```
session = await service.create_session(  
    app_name="seyahat_asistani",  
    user_id="ahmet_123")
```



AIR LAB

GOOGLE ADK: STATE

STATE = AGENT'IN NOT DEFTERİ (4 Scope!)

1) SESSION STATE (varsayılan)

Bu konuşmaya özel, konuşma bitince gider

```
state["current_step"] = 3  
state["aradigi_ucus"] = "IST→JFK"
```

2) USER STATE (user: prefix)

Kullanıcıya özel, TÜM konuşmalarda kalır

```
state["user:name"] = "Ahmet"  
state["user:preferred_language"] = "tr"  
state["user:favorite_airline"] = "THY"
```

3) APP STATE (app: prefix)

Tüm kullanıcılar için geçerli, global

```
state["app:version"] = "2.1"  
state["app:total_users"] = 1450  
state["app:maintenance_mode"] = False
```

4) TEMP STATE (temp: prefix)

Sadece bu işlem sırasında, hiç kaydedilmez

```
state["temp:api_response"] = raw_data  
state["temp:intermediate_calc"] = result
```

💡 TEMPLATE DESTEĞİ:

```
instruction = "Merhaba {user:name},  
dil tercihin: {user:preferred_language}"
```

→ ADK otomatik olarak state'ten değerleri enjekte eder!



AIR LAB

GOOGLE ADK: MEMORY

MEMORY = SESSIONLAR ARASI HAFIZA

State → Kısa süreli (bir konuşma içinde)

Memory → Uzun süreli (konuşmalar ARASINDA)

1. Konuşma biter



2. `add_session_to_memory(session)`

Gemini önemli bilgileri çıkarır



3. Memory Bank'a kaydeder
(embedding olarak, aranabilir)



4. Yeni konuşmada agent memory'yi arar

`search_memory("kullanıcının bütçesi")`



5. İlgili bilgileri bulur ve kullanır

HAZIR TOOL'LAR:

└── `PreloadMemory` → Her turda otomatik hafıza yükle

└── `LoadMemory` → Agent karar versin, gerektiğinde yükle

MEMORY SERVICE SEÇENEKLERİ:

└── `InMemoryMemoryService` → Test için (RAM)

└── `VertexAiRagMemoryService` → Production (RAG + embedding)



AIR LAB

DİĞER FRAMEWORKLER

LANGCHAIN: En eski, en olgun. Devasa topluluk. Ama 'chain' mantığıyla başladığı için multi-agent sonradan eklendi. Bazen gereksiz karmaşık. Bir tool eklemek için 5 farklı class lazım.

LANGGRAPH: LangChain'in 'bunu düzelt' denemesi. Graph yapısı - node'lar ve edge'ler. Çok güçlü ama öğrenme eğrisi dik. State machine biliyorsanız rahat edersiniz.

CREWAI: En kolay başlangıç. 'Rol bazlı takım' metaforu.

'Sen araştırmacısın, sen yazarsın, sen editörsün' diyorsun, geri kalanı framework hallediyor. Ama production'da sınırları var.

N8N: Kod yazmadan agent! Visual drag-and-drop.

Teknik olmayan insanlar için mükemmel. Ama karmaşık logic'te sınırlı.

GOOGLE ADK: En yeni ama Google'in arkasında. Multi-agent native, MCP native, deployment native.

Diğerlerinin hatalarından ders almış.

Dezavantaj: Topluluk henüz küçük, doküman az."



AIR LAB

DİĞER FRAMEWORKLER

LANGCHAIN

Felsefe: "Her şeyi chain'le, her LLM çağrısını bileşenlere ayır"

Güçlü: 100+ entegrasyon, devasa ekosistem

Zayıf: Aşırı abstraction, "chain of chains" karmaşıklığı

Kod: Chain → Prompt → LLM → Parser → Tool → Memory (her biri ayrı class)

İdeal: RAG uygulamaları, çok API'li projeler

LANGGRAPH

Felsefe: "Agent = State Machine, her adım bir node"

Güçlü: Tam kontrol, conditional branching, checkpoints

Zayıf: Öğrenme eğrisi dik, basit işler için overkill

Kod: Graph() → add_node() → add_edge() → compile()

İdeal: Karmaşık workflow, retry logic, human-in-the-loop



DİĞER FRAMEWORKLER

CREWAI

Felsefe: "Agent = Takım üyesi, görev dağılımı yap"

Güçlü: En kolay syntax, hızlı prototip

Zayıf: Production sınırları, debugging zor

Kod: `Agent(role=...) → Task(agent=...) → Crew([...])`

İdeal: İçerik üretimi, araştırma, basit otomasyon

N8N

Felsefe: "Kod yazmadan otomasyon"

Güçlü: Visual builder, 400+ entegrasyon, self-host

Zayıf: Karmaşık agent logic'te sınırlı

Kod: Yok! Drag-and-drop

İdeal: İş akışı otomasyonu, non-developer kullanıcılar

GOOGLE ADK


Felsefe: "Agent lifecycle: build → test → deploy → monitor"

Güçlü: Multi-agent native, MCP, Google ekosistemi

Zayıf: Yeni, küçük topluluk

Kod: `Agent(model=..., tools=[...], sub_agents=[...])`

İdeal: Google Cloud projeleri, multi-agent sistemler



DEMO: DERS PLANLAYICI





AIR LAB

GERÇEK ÖRNEK: DRONE KONTROL

 Paper: arxiv.org/abs/2601.15486 (Ocak 2025) "A Universal LLM – Drone Command and Control Interface"

Bir MCP Server yazıyorsunuz – drone'a MAVLink komutları gönderiyor. Sonra herhangi bir LLM'i bağılıyorsunuz. Claude'a diyorsunuz ki: 'En yakın markete uç' Claude ne yapıyor?

1. Önce Google Maps MCP'ye soruyor: 'En yakın market nerede?'
2. Koordinatları alıyor
3. Sonra Drone MCP'ye diyor: 'Bu koordinata uç'
4. Drone kalkıyor ve uçuyor 2 farklı MCP server, 1 LLM, 1 drone. Hepsi doğal dille kontrol ediliyor

Bu neden önemli? Eskiden drone uçurmak için:

- MAVLink komutlarını bilmen lazımdı
- Koordinat hesaplaması yapman lazımdı
- Özel yazılım kullanman lazımdı

Şimdi: 'Şu binayı bul ve fotoğrafını çek' diyorsun.

Paper Ocak 2025'te yayınlandı. Hem simülasyonda hem GERÇEK drone'da test edildi. Claude, GPT, Gemini hepsiyle çalışıyor."



AIR LAB

GERÇEK ÖRNEK: THY MCP SERVER

Claude, ChatGPT veya herhangi bir LLM'e doğal dille THY hizmetlerine erişim sağlıyor:

—— ✈️ Uçuş Arama & Durum Takibi

"TK123 uçuşunun durumu ne?"

"İstanbul-New York arası yarınki uçuşlar?"

—— 📋 Rezervasyon Yönetimi

"PNR ABC123 ile check-in yapabilir miyim?"

—— 🎫 Miles&Smiles Bilgisi

"Kaç milim var?"

—— 🌍 Destinasyon Bilgisi

"Tokyo'ya bagaj hakkım ne kadar?"

KULLANIM:

Claude Desktop'ta THY MCP entegrasyonu:
[claude.ai/settings/integrations](https://mcp.turkishtechlab.com/sse)


URL: <https://mcp.turkishtechlab.com/sse>

ŞU AN: Digital Lab projesi (henüz resmi ürün değil)

AMA: Gerçek API'lerle çalışan, fonksiyonel bir sistem



AIR LAB



USE CASES & PROJE FIKIRLERİ



KAYNAKLAR

KİTAPLAR

- "Building LLM Apps" - Chip Huyen
- "AI Engineering" - Chip Huyen
 - Oceanofpdf tarzı siteler en iyi dostunuz

YOUTUBE

- AI Jason (agent tutorials)
- Sam Witteveen (Google ADK)
- Matt Shumer (HyperWrite)


PAPER'LAR

- CoT: arxiv.org/abs/2201.11903
- ReAct: arxiv.org/abs/2210.03629
- ToT: arxiv.org/abs/2305.10601

FRAMEWORK DOCS


TOPLULUK

- Reddit
- X
- AI Discord'lar





AIR LAB



THANK YOU

www.airlab.yildizskylab.com

