

## NLP - LORA EĞİTİMİ PROJESİ YOL HARİTASI

Bu projede amacımız, pretrain ve fine-tune edilmiş hazır bir LLM (Instruct) modelini alıp, ona daha iyi kod yazmayı öğretmektir. Bunu **LoRA** adı verilen verimli bir yöntemle yapacağız.

---

### Kaynaklar ve İndirme Linkleri

Projeye başlamadan önce aşağıdaki kaynakları hazır edin:

- **Temel Model (Base Model):** [Qwen2.5-Coder-1.5B-Instruct](#) <sup>1</sup>
- **Veri Seti 1 (DEEP):** [CodeGen-Deep-5K](#) <sup>2</sup>
- **Veri Seti 2 (DIVERSE):** [CodeGen-Diverse-5K](#) <sup>3</sup>
- **Rehber Doküman:** [HuggingFace LoRA Training Guide](#) <sup>4</sup>

---

### Adım Adım Yapılacaklar Listesi

#### 1. Adım: Modeli Tanıyın

- Temel modeli indirin ve kurun.
- Ona birkaç Python sorusu sorun (inference yapın). Modelin eğitim öncesindeki cevap kalitesini not edin. (Örn: Prepare a code to sum two input value.)

#### 2. Adım: Verileri İnceleyin

- **Önemli:** Eğitimi solution (sadece kod) alanını kullanarak yapacaksınız.
- *Ekstra:* Deneyim kazanmak isterseniz output (düşünme adımları + kod) alanını da deneyebilirsiniz ama zorunlu değil.

#### 3. Adım: Eğitimi Başlatın

İki ayrı eğitim yapacaksınız. İkisi de aynı temel modelden sıfırdan başlayacak:

**Eğitim 1:** Temel Model + DEEP Dataset

**Eğitim 2:** Temel Model + DIVERSE Dataset

#### 4. Adım: Checkpoint Seçimi ve Test

Eğitim sırasında modeliniz belirli adımlarda (step) kaydedilecektir. Hangi kaydın en iyisi olduğunu anlamak için:

- Kaydedilen checkpoint'i yükleyin.
- Modele, eğitim verisinde **olmayan** yeni bir soru (prompt) gönderin.

- Ürettiği cevabın kalitesini gözle kontrol edin. En mantıklı ve çalışan kodu üreten checkpoint'i "Final Model" olarak seçin.

---

### Teknik Ayarlar (Önerilen Başlangıç)

⚠ Uyarı: Parametre ayarlarının "mükemmel" kombinasyonunu bulmak kolay olmayabilir. İlk denemenizde başarısız olursanız endişelenmeyin; deneme-yanılma (trial-and-error) ile birkaç farklı ayar denemeniz gerekebilir.

- **Epoch:** 3 (Öneri)
- **Rank (r):** 16, 32 veya 64
- **Alpha:** Rank değerinin 2 katı (Örn: r=16 ise alpha=32)
- **Context Length:** 1024 token (Solution alanı için)
- **System Prompt** (Zorunlu): "You are an expert Python programmer. Please read the problem carefully before writing any Python code."

---

### Hata Çözümleri (OOM - Out of Memory)

Ekran kartı hafızası yetmezse sırasıyla şunları uygulayın:

1. Flash Attention 2 aktif edin.
2. Gradient Checkpointing aktif edin.
3. Context Length'i 800'e düşürün.
4. Hala hata alıyorsanız modeli **8-bit** modunda yükleyin (Son çare).

---

### BENCHMARK GÖREVİ

Eğittiğiniz modellerin gerçekte ne kadar başarılı olduğunu görmek için onları **41 adet AtCoder sorusu** ile test edeceğiz. Amacımız en yüksek puanı alan "Checkpoint"i bulmak.

#### 1. Hazırlık: Test Ortamını Kurun

Önce testleri yapacak programı bilgisayarınıza indirin. Terminali açın ve şu komutları sırasıyla girin:

```
git clone https://github.com/naholav/CodeGen.git
cd CodeGen
pip install -r requirements.txt
```

## 2. Klasör Düzeni (⚠ En Kritik Adım)

Testin çalışması için bilgisayarınızdaki klasör yapısı **birebir** aşağıdaki gibi olmalıdır. Eğittiğiniz modelleri bu yapının içine taşıyın:

```
CodeGen/  
+-- models/  
|   +-- deep_instruction/                               <-- 1. egitim klasorunuz  
|   |   +-- checkpoints/  
|   |   |   +-- checkpoint-step-300-epoch-1/ <-- LoRA dosyalari burada  
|   |   |   +-- checkpoint-step-400-epoch-2/  
|   |   |   +-- checkpoint-step-500-epoch-2/  
|   |   |   +-- ...  
|   |  
|   +-- diverse_instruction/                             <-- 2. egitim klasorunuz  
|   |   +-- checkpoints/  
|   |   |   +-- checkpoint-step-300-epoch-1/  
|   |   |   +-- checkpoint-  
|   |   |   |   step-400-epoch-2/  
|   |   |   +-- ...
```

**Dikkat:** Checkpoint klasörlerinizin isminde mutlaka step ve epoch kelimeleri geçmelidir. (Örn: checkpoint-step-500-epoch-2)

---

## 3. Küçük Bir Kod Ayarı

İndirdiğiniz CodeGen klasöründeki **livecodebench\_eval.py** dosyasında 70. satırı bulun: Buradaki isimlerin klasör isimlerinizle aynı olduğundan emin olun.

```
# Varsayılan: model_types: tuple = ("deep_think", "deep_instruction",  
"diverse_think", "diverse_instruction")  
  
# Sizin klasor isimlerinize gore degistirin: model_types: tuple =  
("deep_instruction", "diverse_instruction")
```

**Not:** Buradaki isimler models/ altındaki klasor isimleriyle **birebir aynı** olmalı!

Aynı dosyada **100. Satırı Bulun:** Eğer eğitim sırasında System Prompt'u değiştirdiyseniz burayı da güncelleyin. Değiştirmediyse dokunmayın.

---

## 4. Testi Başlatma

Artık modelleri sınav yapabiliriz. Terminalde şu komutları çalıştırın:

**DEEP için:** `python livecodebench_eval.py --model_type deep_instruction --platform atcoder --difficulty easy`

**DIVERSE için:** `python livecodebench_eval.py --model_type diverse_instruction --platform atcoder --difficulty easy`

---

## 5. Sonuçları Okuma ve Raporlama

Test bittiğinde sonuçlar results/livecodebench/summary.json dosyasına yazılacaktır.

1. Dosyayı açın.
2. Her checkpoint için **Pass@1** değerine bakın.
3. En yüksek yüzdeye sahip olan checkpoint sizin **kazanan modelinizdir**.

Örnek Çıktı:

|                                              |                  |
|----------------------------------------------|------------------|
| deep_instruction_checkpoint-step-300-epoch-1 | 19.5%            |
| deep_instruction_checkpoint-step-400-epoch-2 | 22.0%            |
| deep_instruction_checkpoint-step-500-epoch-2 | 26.8% <-- En iyi |
| deep_instruction_checkpoint-step-600-epoch-3 | 24.4%            |

---

### Sık Yapılan Hatalar

- **"Checkpoint directory not found"**: models klasörünün içindeki klasör isimleriniz yanlış. Yukarıdaki şemayı tekrar kontrol edin.
- **"No checkpoints found"**: Checkpoint klasör isimleriniz checkpoint-step-... formatında değil. İsimleri düzeltin.

---

## Teslim Edilecekler ve GitHub Reposu

Projenin en önemli çıktısı hazırlayacağınız **GitHub Reposu** ve **Proje Raporudur**.

### 1. GitHub Reposu (Zorunlu)

Aşağıdaki dosyaları içeren düzenli bir repo oluşturmalısınız:

- train.py (Eğitim kodlarınız)
- eval.py (Test kodlarınız)
- requirements.txt (Gerekli kütüphaneler)
- Eğitim Logları (Loss değerlerini içeren dosyalar)

### 2. Proje Raporu ve Grafikler (Zorunlu)

Hazırlayacağınız raporda şu analiz kesinlikle yer almalı:

- **Loss Grafiği**: Train, Validation ve Test veri setlerindeki **Loss** (hata) değerlerinin değişimini gösteren bir grafik hazırlayın.
- **Veri Sıklığı**: Bu grafikte değerler her 20 adımda (step) bir işaretlenmiş olmalıdır.

- **Yorumlama:** Grafięe bakarak modelin öğrenip öğrenmediğini, ezberleyip ezberlemediğini (overfitting) yorumlayın.
- **En iyi Checkpoint:** Eğitimde farklı adımlarda kaydettiğiniz modellerin (checkpoints) arasından en iyi olanı Benchmarka göre nasıl belirlediğinizi aşağıdaki tablo ile gösterin:

| Model               | En İyi Checkpoint | Pass@1 | Cozulen Soru |
|---------------------|-------------------|--------|--------------|
| Base Model          | -                 | ?      | ?27?/41      |
| Deep_instruction    | step-120          | ?%     | ?33?/41      |
| Diverse_instruction | step-180          | ?%     | ?35?/41      |