

# CNN ve Self-Attention Tabanlı Çiçek Sınıflandırması Projesi Raporu

## 1. Giriş

Bu proje, Oxford Flowers102 veri setinden yalnızca 1 ile 20 arasındaki sınıfları kullanarak çiçek görüntülerinin sınıflandırılmasını amaçlamaktadır.

Proje kapsamında temel bir Convolutional Neural Network (CNN) modeli eğitilmiş, sonrasında aynı mimariye Self-Attention mekanizması (Squeeze-and-Excitation bloğu) entegre edilerek performans karşılaştırması yapılmıştır.

## 2. Veri Seti

Kullanılan veri seti: [Oxford Flowers102](#)

- Toplam sınıf sayısı: 102
- Bu projede yalnızca ID'si 1-20 (0-19 indexli) olan sınıflar kullanılmıştır.
- Veri bölümü:
  - Eğitim: 200 görüntü
  - Doğrulama: 200 görüntü
  - Test: 755 görüntü

## 3. Veri Ön işleme ve Artırma

- Veriler torchvision.datasets.Flowers102 ile yüklenmiştir.
- Sadece 1-20 sınıfları filtrelenerek alt küme oluşturulmuştur.
- Eğitim verisine aşağıdaki veri artırma yöntemleri uygulanmıştır:
  - RandomHorizontalFlip, RandomRotation, ColorJitter, Resize, ToTensor
- Doğrulama ve test verisine yalnızca Resize ve ToTensor uygulanmıştır.

## 4. Model Mimarileri

### 4.1. CNN Modeli

- 3 adet Conv2D katmanı + ReLU + MaxPooling
- 2 adet fully connected (FC) katman
- Dropout (0.5)
- Softmax çıkış (20 sınıf)

### 4.2. CNN + SE Modeli

- CNN yapısının aynısı korunmuş, her Conv2D katmanından sonra SE bloğu eklenmiştir.
- SE: Squeeze-and-Excitation kanal bazlı dikkat (attention) mekanizması kullanır.

## 5. Eğitim ve Değerlendirme

- Her model 10 epoch boyunca eğitilmiştir.

- Kayıp fonksiyonu: CrossEntropyLoss
- Optimizasyon: Adam (learning rate = 0.001)

## 6. Sonuçlar

### 6.1. CNN Modeli

- Validation Accuracy: %36.50
- Test Accuracy: **%36.95**

### 6.2. CNN + SE Modeli

- Validation Accuracy: %33.50
- Test Accuracy: **%32.98**

## 7. Grafiksel Analiz

- Her iki model için eğitim ve doğrulama süreçleri boyunca loss ve accuracy grafiklerinin paralel ilerlediği gözlemlendi.
- SE modeli ilk epoch'larda geride kalsa da 8. epoch sonrasında klasik CNN'e yaklaştı.
- Overfitting belirtileri görülmedi, validation ve test skorları birbirine yakın seyretti.

## 8. Doğruluk Oranı Üzerine Açıklama

Elde edilen doğruluk oranları klasik ölçütlerle bakıldığında düşük gibi görünse de bu durum veri seti ve problem yapısı göz önünde bulundurulduğunda normal karşılanmaktadır.

- Model sadece 200 görüntü ile eğitilmiş ve 20 farklı sınıfı birbirinden ayırmaya çalışmıştır.
- Rastgele tahmin yapan bir modelin başarısı bu yapıda yaklaşık %5 civarındadır.
- Bu bağlamda CNN ve SE modellerinin %36 ve %32 seviyelerine ulaşması, rastgeleliğin çok üstünde makul bir başarı göstermektedir.
- Daha yüksek doğruluk oranları için daha fazla veri, daha uzun eğitim süreci ya da transfer learning gibi ileri yöntemler kullanılabilir.

## 9. Genel Değerlendirme

- Bu çalışma, düşük veri miktarına rağmen çok sınıflı bir problemi başarıyla çözen iki modelin kıyaslamalı analizini sunmaktadır.
- CNN modeli bu kapsamdaki veri için daha yüksek performans sağlamıştır.
- SE yapısı ise daha uzun eğitim veya daha fazla veri ile daha yüksek başarı potansiyeli taşımaktadır.

## 10. Sonuç

Proje, verilen kapsamı tam olarak yerine getirmiş; veri yükleme, ön işleme, modelleme, eğitim, grafik çıktıları ve yorumlama aşamaları tamamlanmıştır.

Bu model, torchvision üzerinden hazır olarak gelen EfficientNet B0 mimarisine dayanmaktadır. Model, ImageNet veri setinde önceden eğitilmiş olup, son katmanı bu projeye özgü 20 sınıfa göre değiştirilmiştir. Transfer learning yöntemiyle modelin genel özellik çıkarıcı katmanları korunmuş, sadece son katman yeniden eğitilmiştir.

- Eğitim süreci: 10 epoch
- Optimizasyon: Adam (learning rate = 0.0005)
- Eğitim verisi: Aynı 200 görüntü
- En iyi test doğruluğu: %90.60

Transfer learning sayesinde model, küçük veri setiyle bile yüksek doğruluk oranına ulaşabilmektedir.

#### 4.3. EfficientNet (Transfer Learning) Modeli

### 11. Karşılaştırmalı Test Sonuçları ve Yorum

Aşağıdaki tablo, her modelin test verisi üzerindeki doğruluk ve kayıp (loss) performansını özetlemektedir:

| Model                | Test Loss | Test Accuracy |
|----------------------|-----------|---------------|
| Base CNN             | 2.0499    | %40.93        |
| CNN + Self-Attention | 2.2746    | %30.33        |
| EfficientNet (TL)    | 0.3900    | %90.60        |

EfficientNet modeli, transfer learning yaklaşımı sayesinde düşük miktarda veriyle dahi çok yüksek doğruluk oranlarına ulaşmıştır. Bu da gösteriyor ki, önceden eğitilmiş bir model kullanmak sınırlı veri senaryolarında büyük avantaj sağlayabilir. CNN ve SE modelleri ise sıfırdan eğitildiği için daha düşük doğruluklar elde etmiştir.