

Resim Dosyalarında LSB Yöntemi ile Gizlenen Steganografik Verilerin Derin Öğrenme Modelleri Kullanarak Tespit Edilmesi

Emir ÖZTÜRK^{1*}, Andaç MESUT², Özlem AYDIN FİDAN³

^{1,2,3} Bilgisayar Mühendisliği, Mühendislik Fakültesi, Trakya Üniversitesi, Edirne, Türkiye

^{*1} emirozturk@trakya.edu.tr, ² andacs@trakya.edu.tr ³ ozlema@trakya.edu.tr

(Geliş/Received: 17/02/2026;

Kabul/Accepted: 23/07/2026)

Öz: Bu çalışmada, LSB tabanlı steganografi yöntemi ile gizlenmiş verilerin tespit edilebilirliği derin öğrenme modelleri kullanılarak incelenmiştir. İnceleme için literatürde sunulan stego veri seti kullanılmış ve Evrişimsel Sinir Ağı (CNN) tabanlı ResNet-50, VGG, DenseNet, EfficientNet, MobileNet ve transformer tabanlı ViT, DeiT, Swin, BEiT modelleri kullanılarak farklı gizleme oranları, piksel başına bit sayıları ve çözünürlüklerde gerçekleştirilen deneylerden elde edilen sonuçlar değerlendirilmiştir. Ayrıca sonuçların karşılaştırılması amacıyla bir hibrit model önerisi sunulmuş ve sonuçlar irdelenmiştir. Değerlendirme sonuçları incelendiğinde düşük gizleme oranlarında tüm modellerin performanslarının birbirine yakın olduğu, yüksek gizleme oranlarında ise bozulmaların daha belirgin hale gelmesiyle ayrım gücünün arttığı gözlenmiştir. CNN mimarileri içerisinde ResNet-50 ortalama 0,88 F1 skoru ile en yüksek başarıyı sergilerken, transformer grubunda Swin Transformer tüm senaryolarda öne çıkmış ve en yüksek F1 skoru olan 0,91 değerine ulaşmıştır. Buna karşılık BEiT modeli hem düşük hem de yüksek gizleme oranlarında diğer transformer mimarilerinden düşük performans göstermiştir ve ortalama 0,75 F1 skoru elde etmiştir. Elde edilen bulgular, steganaliz görevinde hem transformer hem de CNN tabanlı yaklaşımların etkili biçimde kullanılabildiğini ortaya koymaktadır. Bununla birlikte, genel eğilim transformer tabanlı mimarilerin CNN'lere kıyasla daha yüksek performans ve temsil gücü sunduğunu göstermektedir. Öte yandan, bazı CNN mimarilerinin de transformer mimarileri kadar başarılı sonuçlar ürettiği görülmüştür.

Anahtar kelimeler: CNN, steganografi, steganaliz, transformer.

Detection of LSB-Based Steganographic Data in Image Files Using Deep Learning Models

Abstract: In this study, the detectability of data hidden with an LSB-based steganography method was examined using deep learning models. For the analysis, a stego dataset presented in the literature was used, and the results of experiments conducted at different hiding ratios (hr), bits per pixel values (hb), and image resolutions were evaluated using CNN-based models (ResNet-50, VGG, DenseNet, EfficientNet, MobileNet) and transformer-based models (ViT, DeiT, Swin, BEiT). In addition, a hybrid model was proposed in order to compare the results, and its outcomes were discussed. The results showed that at low hiding ratios the performances of all models were close, while at high hiding ratios the distortions became more visible and the discrimination ability increased. Among the CNN architectures, ResNet-50 achieved the highest performance with an average F1 score of 0.88. In the transformer group, Swin Transformer stood out in all scenarios and reached the highest F1 score of 0.91. In contrast, BEiT showed lower performance than the other transformer architectures at both low and high hiding ratios and obtained an average F1 score of 0.75. The findings indicate that both transformer- and CNN-based approaches can be used effectively for steganalysis, while the general trend shows higher performance and representation capability for transformer architectures, although some CNN models produced comparable results.

Keywords: CNN, steganography, steganalysis, transformer.

1. Giriş

Bilginin iletimi sırasında güvenliğinden emin olunmayan ortamlardan iletişim sağlanacağı durumda bilgi güvenliği yöntemlerinin kullanılması bir gereklilik olarak görülmektedir [1]. Bu güvenliğin sağlanması için kriptografi, steganografi veya belge işaretleme gibi yöntemlerin kullanılması ile mesajların gizliliğinin veya telif haklarının korunması sağlanabilmektedir. Bu yöntemler sayesinde kullanıcıların verilerini güvenli bir şekilde paylaşmalarını sağlanabilmektedir [2].

Steganografi, şüphe duyulmayacak normal dosyalara gizli mesaj saklama işlemine verilen isimdir [3]. Steganografide gizlenmek istenen bir veri ve gizlenecek bir ortam bulunur. Kriptografiden farklı olarak amaç bilginin okunamaz hale getirilmesi değil, bu bilginin ortamda bulunduğunun gizlenmesidir.

* Sorumlu yazar: emirozturk@trakya.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-3734-5171, ² 0000-0003-0853-5256, ³ 0000-0002-6401-4183

Gizlenecek ortamın seçilmesinde metin [4], resim [5,6], video [7-10] ve ses [11] gibi farklı ortamlar kullanılabilir. Bu ortamların seçilmesinde veri büyüklüğü ve gizlenecek veri kapasitesi arasındaki dengenin sağlanması amaçlanmaktadır.

Metin steganografi üzerine birçok çalışma bulunsada bu yöntemin en büyük problemi gizlenecek veri miktarının nispeten daha düşük olmasıdır. Görüntü steganografisinde ise bu kapasite metin verisine göre çok daha fazla olduğundan bilgi gizlenen ortam olarak daha çok kullanılmaktadır [12].

Bilgi gizlemek için kullanılan en bilinen yöntemlerden biri LSB (least significant bit) yöntemidir [13,14]. Yöntem ses, metin ve görüntü verileri üzerinde kullanılabilir. Bu yöntemde her pikselin en önemsiz bitlerine verinin gizlenmesi işlemi gerçekleştirilir.

Derin öğrenme algoritmaları ve modellerinin kullanımına tüm alanlarda olduğu gibi steganografi alanında da sıklıkla rastlanmaktadır. Metin steganografi [15,16], görüntü steganografi [17-19], gizleme ortamı olmayan (coverless) steganografi [20] gibi yöntemler derin öğrenme algoritmaları ile steganografi işlemi gerçekleştirmektedir.

Bir veri üzerinde bilgi gizlenip gizlenmediğinin tespiti amacıyla steganaliz yöntemleri kullanılabilir [21]. Bu yöntemler genellikle istatistiksel tabanlı olmakla beraber [22], literatürde derin öğrenme yöntemleri de steganaliz için kullanılmaktadır [23-25]. Metin steganaliz [26], görüntü steganaliz [27-29] veya video steganaliz [30] konusunda çalışmalar bulunmaktadır.

Çalışmada kullanılan mimarilerin steganaliz görevine uyarlanması literatürde de incelenmiştir. ImageNet üzerinde ön eğitilmiş evrimsel ağların transfer öğrenme ile steganalize aktarılabilirliği gösterilmiştir. Yousfi ve arkadaşları EfficientNet, ResNet ve MixNet gibi genel amaçlı modellerin JPEG steganalizinde yüksek başarımlar sağladığını sunmuştur [31]. Özellikle EfficientNet ailesi, ALASKA II steganaliz yarışmasında en yüksek başarımları veren mimari olarak öne çıkmış [32] ve uzamsal alanda EfficientNet-B0 tabanlı bir modelin BOSSBase veri setinde yaklaşık %90,7 doğruluk elde ettiği gösterilmiştir [33]. ResNet tabanlı derin artık ağların ön eğitilmiş ağırlıklarla ince ayarlanmasının steganaliz başarımlarını artırdığı [34], DenseNet mimarisinin yoğun bağlantı yapısı sayesinde Xu-Net'e kıyasla gömme oranında hata oranını yaklaşık %4,4 düşürdüğü bildirilmiştir [35]. Transformer tabanlı yaklaşımlarda ise evrim ve dikkat mekanizmasını birleştiren CVTStego-Net mimarisi, BOSSBase üzerinde S-UNIWARD için 0,4 bpp gömme oranında %90,45, WOW için ise %93,80 doğruluk elde etmiş [36], benzer biçimde Swin Transformer tabanlı R-SIT [37] ve evrimsel transformer CTNet [38] mimarileri de uzamsal steganalizde CNN tabanlı yöntemlerle yarışabilir başarımlar sunmuştur. Bu çalışmalar söz konusu omurga ağlarının steganaliz görevinde etkili biçimde kullanılabilirliğini göstermekle birlikte, çoğunlukla JPEG veya adaptif gömme senaryolarında ve farklı veri setleri üzerinde gerçekleştirildiğinden, bu çalışmadaki çok dilli LSB veri seti sonuçlarıyla karşılaştırılmamıştır.

Bu çalışmada, [39] çalışmasında sunulan LSB steganografi veri setinden belirli parametreler seçilerek örnek veri setleri oluşturulmuş ve bu örnekler kullanılarak gizli verinin tespit edilebilirliği ölçülmüştür. Tespit edilebilirliğin test edilmesi amacı ile beş adet CNN ve dört adet transformer modeli belirlenmiş ve bu modeller seçilen veri ile eğitilmiştir. Eğitim sonunda modeller teste tabi tutulmuş ve gizli bilginin tespit başarımları elde edilmiştir.

Çalışmanın ikinci bölümünde LSB yöntemi açıklanmış, üçüncü bölümde kullanılan modeller sunulmuş, dördüncü bölümünde veri setinin oluşturulma aşamalarına değinilmiş ve beşinci bölümde deneysel sonuçlara yer verilmiştir. Son bölümde ise sonuçlar irdelenmiştir.

2. LSB Yöntemi

Bir sayısal görüntü temelinde bir piksel matrisi olarak saklanmaktadır. Her piksel renkliliği ifade etmesi amacı ile belirli sayıda bayt değerine sahiptir. Örneğin 24 bpp bir resimde her piksel için 3 bayt veri saklanır.


LSB yönteminde ise bu piksellerin bayt değerleri kullanarak bilgi gizleme işlemi gerçekleştirilmektedir. Bu işlemde her pikselin bir veya birden fazla baytının en önemsiz bitlerinin değişimi ile bilginin bölünerek saklanması sağlanır. Bu durumda örnek olarak 2x2 bir resim için her pikselde 1 bit veri saklanması istendiğinde bu resimde 12 bit veri saklanabilmektedir. Resim 3x3 olduğunda ise bu sayı 27 bite çıkmaktadır. Bu da resmin boyutu büyüdükçe kapasitenin boyuta göre karesel olarak artmasını sağlamaktadır. Görüntünün renkliliği veya kanal sayısı artırıldığında bu oran daha da artmaktadır.

Steganografide gizlenen verinin elde edilmesinin engellenmesi gerekmektedir. Veri gizleme işlemi esnasında piksel başına gizlenen bit sayısı, kullanılan piksel sayısı ve verinin gizlendiği piksellerin konumu gibi etmenler verinin elde edilebilirliğini etkilemektedir. Belli bir bit sayısına kadar olan değişimler ise insan gözü ile fark edilememektedir. Bu durumun bir örneği Şekil 1'de verilmiştir.



Şekil 1. Farklı sayıda bitin değişmesinin etkisi.


Şekil 1’den de görüldüğü üzere bir piksel için değiştirilen bit sayısı arttırıldıkça değişimler gözle görülür hale gelmektedir. Bir ile 4 bit arası değişimler fark edilmezken 8 bit değişim özellikle her kanal için kullanıldığında gözle görülebilir hale gelmektedir. Ayrıca veri gizlemek için daha fazla piksel kullanıldığında bu da gizli verinin gözle olmasa da belirli yöntemler ile yakalanabilme ihtimalini arttırmaktadır. Bu durumun bir örneği Şekil 2’de verilmiştir.



Şekil 2. Farklı büyüklükte veri gizleme işlemlerinin belirginliğe etkisi.

Şekil 2’de %25, %50 ve %100 kapasite kullanımında değişen pikseller gösterilmiştir. Bu aşamada gizlenen piksellerin belirgin olması adına 8 biti değiştirilmiştir. Gerçek senaryoda ise bit sayısı 1-2-4 gibi değerlerde kalacağı için bu değişim göz ile görülemeyecektir. Göz ile görülmese de tüm bitlerin değişimi istatistiksel steganaliz yöntemlerinin veri gizliliğini tespitini kolaylaştırma ihtimali taşımaktadır.

Veri saklama işlemi sıralı bir şekilde yapılabileceği gibi rastgele bir şekilde de gerçekleştirilebilmektedir. İşlemin geriye çevrilebilir olabilmesi adına rastgelelik bir seed değeri ve bu değeri kullanarak indis değeri elde eden bir fonksiyondan oluşmaktadır. Saklama işleminin sıralı veya rastgele yapılmasında da yine verinin tespiti veya elde edilmesinin etkili olabileceği görülmektedir. Bunun örneği Şekil 3’te verilmiştir.



Şekil 3. Sıralı ve rastgele dağılımla bilgi gizleme işlemi.

Şekil 3’te resmin piksellerinin %25’ine veri gizleme işlemi sıralı ve rastgele bir şekilde gerçekleştirilmiştir. Yine şekilde görüldüğü üzere sıralı yazılan bir dosyada dosyanın başından itibaren değişiklikler görülürken rastgele seçim yapılan dosyada daha çok gürültü gibi algılanmaktadır. Bu sayede bir resim veri gizli olma ihtimalini daha belirgin gösterirken, diğeri ise bir gürültü ile aynı çıktıyı vermektedir. Çalışmada, örnek verilen bu değişimlerin stego verilerin tespit edilebilirliğini ne derece etkilediği incelenecektir.

3. Modeller

Çalışmada farklı şekillerde veri saklanmış görüntü dosyaları üzerinde saklanan verinin tespit edilebilmesi amacıyla CNN ve görüntü transformer modelleri seçilmiş ve bu modellerin birden fazla örneği kullanılmıştır. Deneylerde ResNet-50, VGG19, DenseNet, EfficientNet, MobileNet, ViT, Swin, BEiT ve DeiT kullanılmıştır. Modeller, literatürde görüntü sınıflandırma görevlerinde yaygın olarak kullanılan ve farklı temsil stratejilerini temsil eden mimariler arasından seçilmiştir.

ResNet-50, “Deep Residual Learning for Image Recognition” çalışmasında önerilen artık (residual) öğrenme prensibine dayalıdır [40]. Mimari, üç konvolüsyon katmanından oluşan darboğaz (bottleneck) bloklarını kullanır. İlk 1×1 konvolüsyon kanal sayısını küçültmekte, 3×3 konvolüsyon temel işlemi gerçekleştirmekte ve son 1×1 konvolüsyon ise boyutu geri büyütmektedir. Giriş, çıkışa doğrudan bağlanarak artık bağlantı oluşturulur ve öğrenilen fonksiyon bu artık kısım üzerinden temsil edilir.

VGG19, “Very Deep Convolutional Networks for Large-Scale Image Recognition” çalışmasında tanımlanmıştır [41]. Mimaride 3×3 boyutunda küçük filtreler kullanılarak daha derin ağ yapıları inşa edilmiştir. Konvolüsyon katmanları ardışık şekilde yığılmış, aralarda maksimum havuzlama katmanları ile boyut azaltımı yapılmış ve ağın sonunda tam bağlantılı katmanlarla sınıflandırma gerçekleştirilmiştir.

DenseNet mimarisi, “Densely Connected Convolutional Networks” adlı makalede sunulmuştur [42]. Ağ yapısında her katman, kendisinden önceki tüm katmanların çıktılarını giriş olarak alır. Bu yoğun blok (dense block) yapısı özelliklerin yeniden kullanılmasını sağlar. Bloklar arasında geçiş katmanları yer alır ve bu katmanlar 1×1 konvolüsyon ve havuzlama içererek kanal sayısı ve çözünürlük üzerinde kontrol sağlar.

EfficientNet mimarisinde derinlik, genişlik ve çözünürlük parametreleri bileşik ölçeklendirme yaklaşımı ile artırılmıştır [43]. Temel EfficientNet-B0 modeli, mobil cihazlar için optimize edilmiş MBConv adı verilen konvolüsyon blokları ve squeeze-and-excitation adı verilen modülleri kullanır. B1 ve diğer türevleri, bu temel üzerine farklı ölçek katsayıları uygulanarak elde edilmiştir.

MobileNetV2 mimarisinde ters artık (inverted residual) bloklar kullanılır [44]. Bu bloklarda önce kanal sayısı 1×1 konvolüsyon ile genişletilir, ardından derinlik öncelikli konvolüsyon uygulanır ve son olarak lineer aktivasyon içeren 1×1 konvolüsyon ile kanal sayısı daraltılır.

Vision Transformer (ViT) mimarisinde görüntü sabit boyutlu yamalara (patches) ayrılır, bu yamalar doğrusal gömme katmanı (linear embedding layer) üzerinden işlenerek token'lara dönüştürülür. Token'lara pozisyon bilgisi (positional encoding) eklenir ve transformer kodlayıcı (encoder) katmanları üzerinden geçirilir. Kodlayıcı bloklarında çok-başlı dikkat (multi-head attention) ve ileri beslemeli ağlar (feed-forward networks) bulunur [45].

Swin Transformer mimarisi hiyerarşik bir yapıya sahiptir ve görüntüler yama gömme (patch embedding) ile temsil edilir. Öz-dikkat (self-attention) işlemleri sabit boyutlu pencereler içinde yapılır, pencereler kaydırılarak farklı bölgeler arasında etkileşim sağlanır. Bu yöntemle hesaplama maliyeti düşürülürken genel bağlam bilgisi (global context) korunur [46].

BEiT (BERT Pre-Training of Image Transformers) modelinde görüntü transformer mimarisi temel alınmış, ancak ön eğitim süreci doğal dil işleme alanındaki BERT yaklaşımına benzetilmiştir [47]. Görüntü, sabit boyutlu yamalara bölünerek token'lara dönüştürülür. Ardından bu yamalar bir görsel tokenizer (örneğin VQ-VAE tabanlı) kullanılarak ayrık görsel kodlara (discrete visual tokens) dönüştürülür.

Ön eğitim sırasında, belirli bir orandaki yamalar maskelenir ve modelden bu maskelenmiş yamaların görsel kodlarını tahmin etmesi istenir. Böylece model, maskelenmiş parçalardan eksik bilgiyi çıkarma üzerine eğitilir. Bu yapı, dil modellerindeki maskeli dil modelleme (Masked Language Modeling, MLM) yaklaşımına benzer şekilde, görseller için maskeli görsel modelleme (Masked Image Modeling, MIM) stratejisini uygular.

DeiT, Vision Transformer mimarisinin veri verimliliğini artırmak üzere geliştirilmiş bir versiyonudur [48]. Model, büyük veri kümelerine ihtiyaç duymadan daha sınırlı miktarda etiketli veri ile eğitilebilmek amacıyla öğretici-öğrenci (bilgi damıtma, knowledge distillation) yöntemini kullanmaktadır. Damıtma sürecinde, CNN tabanlı güçlü bir öğretici model (örneğin ResNet) kullanılır ve bu model tarafından üretilen bilgi, transformer tabanlı öğrenci modele aktarılır. Bu amaçla mimariye ek bir “damıtma belirteci” (distillation token) tanımlanmıştır. Söz konusu belirteç, öğretici model çıktılarıyla etkileşime girerek öğrenci modelin dikkat mekanizmasına entegre edilir. Böylece öğrenci model, hem veri üzerinden hem de öğretici modelin aktardığı bilgidен eş zamanlı olarak öğrenir. DeiT, özellikle sınırlı veri koşullarında Vision Transformer mimarilerinin etkin biçimde eğitilebilmesini mümkün kılmaktadır.

Çalışmada karşılaştırmalı olarak değerlendirilen hazır mimarilere ek olarak, LSB steganalizine özgü bir hibrit model önerilmiştir. Önerilen model, bit-düzlem farkındalıklı hibrit (Bit-Plane Aware Hybrid, BPA-Hybrid) olarak adlandırılmıştır. Modelde görüntünün her renk kanalı en önemsiz bit-düzlemlerine (least significant bit-planes) ayrıştırılmakta ve bu düzlemler bir ön işleme katmanı olarak kullanılmaktadır. LSB yöntemi veriyi tam olarak bu

bit-düzlemlerinde sakladığından, ayrıştırma işlemi gizleme kaynaklı değişimleri doğrudan ortaya çıkarmaktadır. Elde edilen bit-düzlem haritaları CNN tabanlı bir model ile işlenmekte ve sabit sayıda görüntü token'ına dönüştürülmektedir. Bu token'lar, LoRA (Low-Rank Adaptation) yöntemi ile ince ayarlanan küçük bir dil modeline (Phi-3-mini) verilmekte ve modelden görüntünün stego veya orijinal olduğuna dair ikili karar üretmesi istenmektedir. Böylece yerel istatistiksel bozulmaların CNN ile çıkarılması ve dil modelinin karar verme kapasitesi tek bir mimaride birleştirilmektedir.

4. Kullanılan Veri Seti

Çalışmada [39] çalışmasındaki büyük veri seti üzerinden deney örnekleri oluşturulmuştur. Çalışmadaki veri setinde farklı parametreler ile gizleme yapılmış resim örnekleri bulunmaktadır. Veri setinden örnek seçilmesi için kullanılan parametreler Tablo 1'de verilmiştir.

Tablo 1. Veri seti oluşturma aşamasında seçilen parametreler.

Özellik	Değer
Dosya Sayısı	10000
Boyut	128 / 256 / 512
Gizli bilgi oranı (Hidden data rate - hr)	0,25 / 1,00
Piksel başına gizli bit oranı (Hidden bits per piksel - hb)	1 / 4
Gizleme modu	Sıralı / Rastgele
Dil	de / en / es / fr / tr

Tablo 1'de görüldüğü üzere ilgili veri setinde çözünürlüğü 128x128 ile 512x512 arasında değişen resimler bulunmaktadır. Bu resimlerin bilgi gizlenebilecek kısımlarının yüzde kaçının kullanıldığı ise hr parametresi ile belirlenmektedir. Her pikselde kaç bit gizleme yapılabileceği hb parametresi ile belirlenmektedir.

Gizleme modu sıralı olduğunda gizleme işlemi resmin sol üst pikselinden başlamakta ve sıralı bir şekilde gizleme işlemi yapılmaktadır. Rastgele seçildiğinde ise seçilen hr ve hb oranlarına göre bir seed değeri kullanılarak resmin farklı bölgelerine gizleme işlemi yapılmaktadır. Dil ise gizlenen verinin hangi dillerde olduğunu göstermektedir. Tespit için orijinal ve veri gizli olan dosyalar “stego” ve “non-stego” olarak etiketlenmiş ve ikili sınıflandırma işlemi gerçekleştirilmiştir. Bu aşamada dil parametresi kullanılmamış ve tüm dilleri içeren gizlenmiş veriler ve orijinal veriler veri seti olarak kullanılmıştır.

Gizlenmiş verinin tespit edilebilmesi için oluşturulan ilk veri setleri, Gizli bilgi oranı (hr) ve Piksel başına gizli bit oranının (hb) minimum olduğu (hr 0.25 hb 1) ve yine iki değer maksimum olduğu (hr 1.00 hb 4) durumda sıralı veya rastgele gizleme işleminin gerçekleştirildiği dosyalardan seçilmiştir. Bu seçimler sonucunda iki farklı gizleme türü, sıralı ve rastgele olmak üzere iki farklı gizleme şekli ve 3 farklı boyuttaki resim dosyalarından oluşturulmuş toplam 12 farklı veri seti elde edilmiştir.

Parametrelerin seçiminde bilgi gizlemenin minimum ve maksimum durumda yapıldığı durumların incelenmesi amaçlanmıştır. Bu durumun tespit edilebilmesi amacıyla hem sıralı hem de rastgele oluşturulan veriler farklı görüntü çözünürlüklerinde test edilmiş ve elde edilen performans değerlerinin bu değişken veri örneklerini de kapsamı hedeflenmiştir.

Tablo 1'de verilen veri setlerinin tamamı sırasıyla çalışmada sunulan CNN ve görüntü transformer modelleri ile eğitilmiş ve sonuçlar elde edilmiştir. Sonuçların eldesinde bilgi kaybının engellenmesi ve model performansının artırılması için örtüşmeli (overlapping) kayan pencere yaklaşımı kullanılmıştır. Modeller 224x224 veya 256x256 gibi girdi boyutlarına sahip olduğu için pencere boyutu modelin girdi boyutu olarak seçilmiş ve artıklığın engellenmesi için kayan pencereler şeklinde yama eldesi gerçekleştirilmiştir.

5. Deneysel Sonuçlar

Sonuçların elde edilmesinde CNN ve transformer olmak üzere iki farklı mimari seçilmiş ve bu mimariler için bazı özellikler ortak olarak belirlenmiştir. Yama sayısı, eğitim oranı, adım sayısı gibi ortak seçilen parametreler Tablo 2'de verilmiştir.

Tablo 2. Eğitim parametreleri.

Parametre	Değer	Açıklama
Maksimum eğitim	20000 adım	Erken durma olmadığı takdirde 20000 adım eğitim gerçekleştirilir
FP16	Kullanıldı	16 bit hassasiyet ile bellek ve zaman tasarrufu için kullanılır
Öğrenme Oranı (LR)	2e-4	Modelin her adımda parametrelerini ne kadar güncelleyeceğini belirler
Erken durma oranı	2	Performans gelişimi belirli bir süre boyunca durduğunda modelin eğitimi 2 defa daha denenip sonra durdurulur.
En iyi model için metrik	Ağırlıklı F1	Eğitim sırasında en iyi model seçimi, sınıflar arasındaki dengesizliği dikkate alan ağırlıklı F1 skoru üzerinden yapılır.
Optimizasyon (optimizer)	AdamW	Ağırlık sönümünü ayarlayan AdamW algoritması kullanılmıştır.
LR zaman çizelgesi (scheduler)	Doğrusal azalma	Öğrenme oranı eğitim boyunca doğrusal olarak azaltılmıştır.
Ağırlık sönümü (weight decay)	0	CNN ve transformer modellerinde ağırlık sönümü uygulanmamıştır.
Yığın boyutu (batch size)	16	512x512 örneklerin mevcut vram ile kullanılabileceği maksimum boyutta seçilmiştir.
Veri bölme oranı	%70 -%20 - %10	Sırasıyla eğitim / doğrulama / test

Modellerin ince ayarlanmasında kaynak kısıtı sebebi ile fp16 kullanılarak eğitim gerçekleştirilmiştir. Maksimum eğitim 20000 olarak belirlenmiştir ve genellikle modeller bu adım sayısına ulaşmadan eğitimi erken durma sebebi ile durdurmuşlardır. Ağırlıklı F1 sütununda açıklandığı üzere gizli veri ve orijinal veri arasında örnek sayısı farkı olacağı için eğitimler ağırlıklı olarak gerçekleştirilmiştir.

Tekrarlanabilirliğin sağlanması amacıyla veri setleri, her konfigürasyon için sabit bir seed değeri kullanılarak %70 eğitim, %20 doğrulama ve %10 test olacak biçimde bölünmüştür. Eğitim sürecinde AdamW optimizasyon algoritması, 2e-4 öğrenme oranı (learning rate) ve doğrusal azalan öğrenme oranı planlama (scheduler) kullanılmış, ağırlık azaltımı (weight decay) uygulanmamıştır. Yığın boyutu 16 olarak belirlenmiştir. Önerilen BPA-Hybrid modelinin eğitiminde ise 1e-5 öğrenme oranı, kosinüs zamanlayıcı (0.15 ısınma oranı) ve 0.01 ağırlık sönümü kullanılmış; dil modeli LoRA ($r=8$, $\alpha=16$) yöntemiyle ince ayarlanmıştır.

5.1. CNN modelleri

Sonuçların elde edilmesinde CNN modelleri için "microsoft/resnet-50", "timm/vgg19.tv_in1k", "timm/densenet121.ra_in1k", "timm/efficientnet_b1.ft_in1k" ve "google/mobilenet_v2_1.0_224" kullanılmış ve her model farklı veri setleri için ince ayarlanmıştır. Modellerin başarımları sonuçları dosya boyutlarına göre tablolarda verilmiştir.

Tablo 3. CNN modellerinin başarımları sonuçları (128x128).

Model	HR 0.25 HB 1				HR 1.00 HB 4			
	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1
MobileNet	0,8621	0,7490	0,8621	0,8016	0,8143	0,8298	0,8143	0,7905
ResNet-50	0,8457	0,7884	0,8457	0,7975	0,9936	0,9936	0,9936	0,9935
DenseNet	0,8636	0,7631	0,8636	0,8036	0,9529	0,9643	0,9529	0,9559
EfficientNet	0,8479	0,7503	0,8479	0,7954	0,9414	0,9391	0,9414	0,9304
VGG	0,8336	0,7563	0,8336	0,7919	0,9029	0,8454	0,9029	0,8684

Tablo 3'te 128x128 boyutunda elde edilen veri gizlenmiş ve orijinal görüntülerin tespiti için yapılan model eğitim sonuçları sunulmuştur. Düşük gizleme oranında (hr=0.25, hb=1) tüm CNN modelleri benzer performans göstermiş, F1 skorları yaklaşık 0.79–0.80 seviyesinde elde edilmiştir. Gizleme oranı düşük olduğundan tüm modellerin benzer sonuçlar göstermesi beklenmektedir. Gizleme oranı en yüksek düzeye çıkarıldığında (hr=1,

hb=4) modeller arasında ayrışma gözlemlenmeye başlamıştır. ResNet-50 0.99 gibi bir F1 skoruna ulaşmış ve gizli görüntüyü yüksek başarı ile tespit etmiştir. MobileNet modeli ise 0.79 değerini elde etmiştir. Bu durum, mimarinin hafif yapısı ve sınırlı temsil kapasitesi ile ilişkili olabilmektedir.

Tablo 4. CNN modellerinin başarımları sonuçları (256x256).

Model	HR 0.25 HB 1				HR 1.00 HB 4			
	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1
MobileNet	0,8164	0,7605	0,8164	0,7861	0,9857	0,9859	0,9857	0,9854
ResNet-50	0,6429	0,7646	0,6429	0,6920	1,0000	1,0000	1,0000	1,0000
DenseNet	0,7829	0,7573	0,7829	0,7663	0,8929	0,8564	0,8929	0,8711
EfficientNet	0,6521	0,7586	0,6521	0,6596	0,9900	0,9899	0,9900	0,9899
VGG	0,8621	0,7490	0,8621	0,8016	0,9243	0,9110	0,9243	0,9136

Tablo 4'te 256x256 çözünürlüğündeki sonuçlar verilmiştir. Bu çözünürlükte düşük gizleme oranı ile elde edilen sonuçlar bazı CNN modellerinde beklenenden düşük çıkmıştır. Özellikle ResNet-50 0.69 ve EfficientNet 0.66 gibi düşük F1 değerleri elde etmiştir. Bunun sebebi model karmaşıklığı, erken durma sebebiyle tam öğrenmenin gerçekleşmemesi ve yama tabanlı yaklaşımda gizlenen verinin bu çözünürlükte daha dağınık hale gelmesi olarak görülmektedir. Buna karşın diğer CNN modelleri 0.76–0.80 seviyelerinde daha istikrarlı bir performans göstermiştir. Yüksek gizleme oranında ise tüm modellerin başarımlarının belirgin şekilde arttığı ve ResNet-50 ile EfficientNet'in 0.99 seviyesine ulaştığı görülmektedir. Bu durum, yüksek oranlı gizleme işlemlerinde bozulmaların daha bariz hale gelmesi ile modellerin ayırım yapabilmesinin kolaylaştığını göstermektedir.

Tablo 5. CNN modellerinin başarımları sonuçları (512x512).

Model	HR 0.25 HB 1				HR 1.00 HB 4			
	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1
MobileNet	0,8657	0,7495	0,8657	0,8034	0,9979	0,9979	0,9979	0,9979
ResNet-50	0,8379	0,7834	0,8379	0,8041	1,0000	1,0000	1,0000	1,0000
DenseNet	0,8614	0,7633	0,8614	0,8037	0,9279	0,8697	0,9279	0,8967
EfficientNet	0,8536	0,7628	0,8536	0,8025	0,9907	0,9916	0,9907	0,9909
VGG	0,8636	0,7492	0,8636	0,8023	0,8657	0,7495	0,8657	0,8034

Tablo 5 512x512 çözünürlük için CNN model sonuçlarını göstermektedir. Bu çözünürlükte düşük gizleme oranı kullanıldığında CNN modelleri genel olarak 0.80 civarında sonuç vermiştir. Bu seviyede çözünürlük artışının düşük gizleme oranı için doğrudan bir iyileşme sağlamadığı görülmektedir. Yüksek gizleme oranında ise ResNet-50 %100 F1 skoru ile en iyi sonucu üretirken, EfficientNet 0.99, DenseNet 0.89 ve VGG 0.80 seviyelerinde kalmıştır. Genel olarak çözünürlük arttığında yama sayısı ve örnek arttığı için yüksek gizleme oranlarının tespit edilebilirliği kolaylaşırken, düşük gizleme oranlarında bu yamaların birçoğunun veri gizli olmayan parçalar olduğu düşünüldüğünde çözünürlük artışının tek başına yeterli olmadığı görülmektedir.

5.2. Görsel transformer modelleri

Görsel transformer modellerinin testi için “google/vit-base-patch16-224-in21k”, “microsoft/swin-base-patch4-window7-224”, “facebook/deit-base-patch16-224” ve “microsoft/beit-base-patch16-224” modelleri seçilmiş ve sunulan verisetleri kullanılarak bu modeller ince ayarlama işlemine tabi tutulmuştur.

Tablo 6. Transformer modellerinin başarımları sonuçları (128x128).

Model	HR 0.25 HB 1				HR 1.00 HB 4			
	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1
DeiT	0,8743	0,7644	0,8743	0,8157	0,8657	0,7495	0,8657	0,8034
ViT	0,8657	0,7495	0,8657	0,8034	0,9279	0,8697	0,9279	0,8967
BEiT	0,5350	0,7585	0,5350	0,4920	0,8229	0,7573	0,8229	0,7879
Swin	0,8657	0,7495	0,8657	0,8034	0,9993	0,9993	0,9993	0,9993

Tablo 6’da en düşük çözünürlük için transformer sonuçları verilmiştir. Düşük gizleme oranı ile transformer modelleri test edildiğinde DeiT, ViT ve Swin yaklaşık 0.80 seviyelerinde benzer performans göstermiştir. Buna karşın BEiT modeli 0.49 F1 skoru ile neredeyse rastgele tahmin düzeyinde kalmış ve diğerlerinden ayrılmıştır. Bu durum BEiT’in ön eğitiminde kullanılan maskeli görsel modelleme yaklaşımının düşük oranlı bozulmaları yakalamada yetersiz kalabileceğini göstermektedir. Yüksek gizleme oranında ise Swin’in 0.999 seviyesine ulaştığı, ViT’in 0.89 ve DeiT’in 0.80 civarında sonuç verdiği gözlemlenmiştir. Swin’in kaydırmalı pencere yaklaşımı, yüksek oranlı bozulmaların tespitinde belirgin avantaj sağlamıştır.

Tablo 7. Transformer modellerinin başarımları sonuçları (256x256).

Model	HR 0.25 HB 1				HR 1.00 HB 4			
	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1
DeiT	0,8657	0,7495	0,8657	0,8034	0,9929	0,9931	0,9929	0,9929
ViT	0,8721	0,7628	0,8589	0,8079	0,9871	0,9875	0,9871	0,9873
BEiT	0,8593	0,7412	0,8510	0,7923	0,8657	0,7495	0,8657	0,8034
Swin	0,8784	0,7716	0,8695	0,8176	1,0000	1,0000	1,0000	1,0000

Tablo 7’de 256x256 çözünürlük sonuçları sunulmuştur. Bu çözünürlükte düşük gizleme oranı ile tüm transformer modelleri 0.80 civarında benzer performans göstermiştir. BEiT’in 128 çözünürlükteki başarısızlığının bu seviyede tekrarlanmaması, çözünürlük artışı ile daha istikrarlı öğrenme gerçekleştirebildiğini göstermektedir. Yüksek gizleme oranında Swin 1.00, DeiT 0.99 ve ViT 0.99 F1 değerleri ile başarılı sonuçlar elde etmiştir. BEiT ise düşük gizleme oranında diğer transformer modelleri ile aynı seviyeye gelse de yüksek gizleme oranında yeniden geride kalmıştır.

Tablo 8. Transformer modellerinin başarımları sonuçları (512x512).

Model	HR 0.25 HB 1				HR 1.00 HB 4			
	Acc	Prec	Rec	F1	Acc	Prec	Rec	F1
DeiT	0,8619	0,7442	0,8587	0,7973	0,9986	0,9986	0,9986	0,9986
ViT	0,8698	0,7561	0,8664	0,8075	0,9914	0,9918	0,9914	0,9915
BEiT	0,8576	0,7389	0,8521	0,7915	0,8621	0,7687	0,8621	0,8053
Swin	0,8732	0,7634	0,8705	0,8134	1,0000	1,0000	1,0000	1,0000

Tablo 8’de görüldüğü gibi düşük gizleme oranında tüm transformer modelleri 0.80 civarında sonuç vermiştir. Yüksek gizleme oranında ise Swin 1.00, DeiT 0.998 ve ViT 0.991 seviyelerine ulaşarak oldukça başarılı sonuçlar üretmiştir. Buna karşın BEiT, 0.80 F1 değeri ile diğerlerinden belirgin biçimde ayrılmıştır. Bu bulgular, Swin’in her çözünürlük ve gizleme oranında güçlü bir model olduğunu, ViT ve DeiT’in yüksek oranlarda oldukça başarılı performans sergilediğini, ancak BEiT’in mimari yapısının steganaliz görevi için daha sınırlı performans sergilediğini göstermektedir.

Tüm modellerin bütün konfigürasyonlar için başarımları ve F1 Skorları ortalama olarak Tablo 9’da verilmiştir.

Tablo 9. Tüm mimariler için ortalama Başarım ve F1 sonuçları.

Model	128 HR0.25	128 HR1	256 HR0.25	256 HR1	512 HR0.25	512 HR1	Ortalama F1
MobileNet	0,8016	0,7905	0,7861	0,9854	0,8034	0,9979	0,8608
ResNet-50	0,7975	0,9935	0,692	1,0000	0,8041	1,0000	0,8812
DenseNet	0,8036	0,9559	0,7663	0,8711	0,8037	0,8967	0,8496
EfficientNet	0,7954	0,9304	0,6596	0,9899	0,8025	0,9909	0,8615
VGG	0,7919	0,8684	0,8016	0,9136	0,8023	0,8034	0,8302
DeiT	0,8157	0,8034	0,8034	0,9929	0,7973	0,9986	0,8686
ViT	0,8034	0,8967	0,8079	0,9873	0,8075	0,9915	0,8824
BEiT	0,492	0,7879	0,7923	0,8034	0,7915	0,8053	0,7454
Swin	0,8034	0,9993	0,8176	1,0000	0,8134	1,0000	0,9056

Tablo 9’da verilen ortalama F1 sonuçları, mimarilerin farklı çözünürlük ve gömme senaryolarındaki genel davranışını karşılaştırmalı olarak ortaya koymaktadır. CNN tabanlı modeller arasında ResNet-50’nin 0.8812 ortalama F1 skoru ile en yüksek değere ulaştığı görülmektedir. Özellikle yüksek HR seviyelerinde elde edilen çok yüksek skorlar, artık bağlantıların (residual connections) derin temsil öğrenimini stabil tutarak ince steganografik izlerin korunmasına katkı sağladığını düşündürmektedir. Buna karşılık MobileNet ve EfficientNet daha düşük parametre sayısına sahip olmalarına rağmen 0.8608 ve 0.8615 ortalama F1 değerleri ile birbirine oldukça yakın ve dengeli bir performans sergilemiştir. Bu durum, hafif mimarilerin de uygun eğitim koşullarında steganaliz görevinde rekabetçi sonuçlar üretebildiğini göstermektedir. VGG ise 0.8302 ortalama F1 skoru ile CNN grubu içerisinde en düşük performansı göstermiş ve daha eski, ardışık konvolüsyon bloklarına dayalı yapısının bu problemde temsil kapasitesi açısından sınırlı kaldığını ortaya koymuştur. DenseNet’in 0.8496 F1 değeri ise yoğun bağlantı yapısına rağmen tüm senaryolarda istikrarlı fakat üst düzey olmayan bir performansa işaret etmektedir.

Transformer tabanlı mimariler değerlendirildiğinde, Swin Transformer’ın 0.9056 ortalama F1 skoru ile tüm modeller arasında en yüksek genel başarıyı elde ettiği görülmektedir. Kaydırmalı pencere yaklaşımının çok ölçekli özellik çıkarımına olanak tanınması, hem lokal hem de global bağlamı birlikte modelleyerek steganografiye özgü düşük genlikli istatistiksel bozulmaları yakalamada avantaj sağlamış görünmektedir. ViT ve DeiT mimarileri de sırasıyla 0.8824 ve 0.8686 ortalama F1 skorları ile çoğu CNN modelinin üzerinde konumlanmış ve dikkat (self-attention) temelli temsil öğreniminin bu görev için etkili olduğunu göstermiştir. Buna karşın BEiT modelinin 0.7454 ortalama F1 değeri ile belirgin biçimde geride kalması, maskeli görsel modelleme temelli ön eğitim stratejisinin steganaliz gibi çok ince sinyal farklılıklarının kritik olduğu problemlerde doğrudan avantaj sağlamayabileceğine işaret etmektedir.

Genel eğilim değerlendirildiğinde transformer tabanlı mimarilerin ortalama performans açısından CNN modellerine kıyasla daha yüksek bir başarı düzeyi sunduğu görülmektedir. Bununla birlikte ResNet gibi artık bağlantı kullanan derin CNN mimarilerinin halen güçlü ve rekabetçi sonuçlar üretmesi, steganaliz probleminin yalnızca global bağlam modelleme ile değil, aynı zamanda yüksek frekanslı yerel örüntülerin hassas biçimde korunmasıyla da yakından ilişkili olduğunu göstermektedir. Bu bulgular, mimari seçimin veri yapısı ve gömme senaryosu ile birlikte değerlendirilmesi gerektiğini ortaya koymaktadır.

ResNet-50 modelinin 256x256 çözünürlükte düşük gizleme oranındaki (hr=0.25) görece düşük başarımı (F1=0.692) daha ayrıntılı incelendiğinde, bu durumun eğitim sürecinin erken sonlanmasından kaynaklandığı görülmüştür. Eğitim logları incelendiğinde, ilgili konfigürasyonda modelin 20000 adımlık üst sınıra ulaşmadan, yalnızca 3000 adımda erken durma ile eğitimi sonlandırdığı belirlenmiştir. Aynı modelin aynı çözünürlükte yüksek gizleme oranında (hr=1.00) 1.00 F1 skoruna ulaşması, yüksek çözünürlükte seyrekleşen düşük oranlı gizlemenin daha uzun bir eğitimden dolayı daha esnek bir erken durma kriteri gerektirmesi olduğunu göstermektedir.

BEiT modelinin düşük başarımı ise ön eğitim stratejisi ile ilişkilendirilmektedir. BEiT, maskeli görsel modelleme ile ön eğitildiğinden anlamsal temsiller öğrenmekte ve yüksek frekanslı artık bilgileri bastırma eğilimi göstermektedir. LSB gömme işlemi yüksek frekanslı bileşenlerde değişim oluşturduğundan, BEiT’in ön eğitim önyargısı steganaliz görevinde dezavantaja dönüşmektedir.

5.3. Önerilen hibrit modelin sonuçları

Önerilen BPA-Hybrid modeli, 128x128 çözünürlüğündeki İngilizce veri seti üzerinde, ikili sınıflandırma görevinde 1000 örnek ile eğitilmiş ve test edilmiştir. Modelin başarımları sonuçları Tablo 10'da verilmiştir.

Tablo 10. Önerilen BPA-Hibrit modelinin başarımları sonuçları (128x128).

Model	Doğruluk	Kesinlik	F1	MCC
BPA-Hybrid (Phi-3-mini)	0,856	0,868	0,854	0,712

Tablo 10'da sunulan sonuçlar, önerilen BPA-Hybrid modelinin 128x128 çözünürlüğünde 0.856 doğruluk, 0.868 kesinlik, 0.854 F1 skoru ve 0.712 MCC (Matthews Correlation Coefficient) değeri elde ettiğini göstermektedir. Önerilen model, yalnızca İngilizce veri seti üzerinde 1000 örnek ile ve tek bir konfigürasyonda (düşük gizleme oranı) eğitilmiştir; buna karşılık Tablo 3 ve Tablo 6'da raporlanan tekil CNN ve transformer modelleri çok dilli veri seti üzerinde, farklı eğitim parametreleri ve daha geniş örnek sayısı ile eğitilmiştir. Eğitim verisi, dil dağılımı ve hiper-parametreler aynı olmadığından, bu değerler doğrudan ve birebir bir başarımları karşılaştırması olarak kullanılmamalıdır. Bu çerçevede, düşük gizleme oranında tekil CNN modelleri yaklaşık 0.79–0.80, ViT, DeiT ve Swin gibi transformer modelleri ise 0.80–0.82 aralığında F1 skoru üretirken, BPA-Hybrid modelinin çok daha az eğitim örneği ile 0.854 F1 skoruna ulaşması dikkat çekicidir. Özellikle ayırımı en çok güçleştiği düşük gizleme oranı senaryosunda, bit-düzlem temelli ön işlemenin sınırlı veri ile dahi tutarlı bir başarımları sağlayabildiği görülmektedir. MCC değerinin 0.712 olması, sınıflar arasındaki dengesizliğe rağmen modelin kararlarının rastgelelikten uzak ve tutarlı olduğunu göstermektedir. Yüksek gizleme oranı koşullarında tekil modeller halihazırda 0.99 seviyesine ulaştığından, önerilen yaklaşımın asıl katkısı ayırımı güçleştiği düşük gizleme oranı rejiminde ortaya çıkmaktadır.

5.4. Hesaplama maliyeti

Modellerin yalnızca başarımları değil, gerçek zamanlı bir steganaliz sistemi için kritik olan hesaplama maliyetleri de değerlendirilmiştir. Her model için parametre sayısı, eğitim süresi, eğitim verimi, yama başına çıkarım gecikmesi (inference latency) ve tepe GPU bellek kullanımı Tablo 11'de verilmiştir.

Tablo 11. Modellerin hesaplama maliyeti.

Model	Büyüklik (M)	Eğitim (s)	Süre/Büyüklik (s/M)	Gecikme b1 (ms)	Maks bellek (MB)
ResNet-50	25,6	847,2	33,1	4,699	237,8
VGG19	143,7	534,8	3,7	4,324	238,5
DenseNet121	8,0	489,5	61,2	4,296	237,2
EfficientNet-B1	7,8	447,4	57,4	4,511	237,2
MobileNetV2	3,5	476,2	136,1	4,364	237,2
ViT	86,6	433,0	5,0	3,506	298,6
DeiT	86,6	768,9	8,9	3,452	298,6
BEiT	86,5	630,1	7,3	5,904	299,4
Swin	87,8	948,8	10,8	12,722	552,3

Tablo 11'de, modellerin başarımlarının yanı sıra gerçek zamanlı bir steganaliz sistemi için kritik olan hesaplama maliyetleri sunulmuştur. Tabloda her model için model büyüklüğü (parametre sayısı), eğitim süresi, eğitim süresinin model büyüklüğüne oranı, inferans gecikmesi ve maksimum GPU bellek kullanımı verilmiştir. Ölçümler 224x224 yama boyutu, fp16 hassasiyet ve bir GPU ile alınmıştır. Inferans gecikmesi için batch=1 seçilmiştir. Model büyüklükleri incelendiğinde, transformer tabanlı mimarilerin (ViT, DeiT, BEiT ve Swin) yaklaşık 86–88 milyon parametre ile CNN modellerinin büyük bölümünden daha geniş bir parametre uzayına

sahip olduğu görülmektedir. CNN grubunda ise VGG19 143.7 milyon parametre ile en büyük model olurken, MobileNetV2 3.5 milyon parametre ile en hafif mimari olarak öne çıkmaktadır.

Eğitim süresinin model büyüklüğüne oranı (saniye / milyon parametre) değerlendirildiğinde, eğitim maliyetinin yalnızca ham parametre sayısına değil, mimari tasarıma da bağlı olduğu görülmektedir. Transformer tabanlı modeller görece yüksek parametre sayılarına karşın, paralelleştirilebilir dikkat hesabı sayesinde düşük birim-parametre maliyeti (yaklaşık 5–11 s/M) sergilemektedir. Buna karşın hafif CNN mimarilerinde (MobileNetV2, EfficientNet, DenseNet) bu oran belirgin biçimde yükselmektedir. Bunun nedeni, küçük parametrelili olmalarına kıyasla veri yükleme ve adım başına gerçekleştirilen sabit işlem maliyetlerinin belirginleşmesidir. Dolayısıyla, küçük parametre sayısına sahip bir modelin doğrudan daha düşük eğitim maliyetine sahip olacağı şeklindeki beklenti her zaman karşılanmamaktadır.

Çıkarım aşamasında ise CNN modelleri yaklaşık 4.3–4.7 ms aralığında gecikme sağlamaktadır. Transformer grubunda ViT ve DeiT sırasıyla 3.5 ms civarında düşük gecikme sunarken, en yüksek başarıyı veren Swin modeli kaydırmalı pencere yapısı nedeniyle 12.7 ms gecikme ve 552 MB ile en yüksek bellek kullanımına sahiptir. En yüksek ortalama F1 skorunu elde eden Swin modeli aynı zamanda en yüksek gecikme ve bellek maliyetini getirirken, ResNet-50 gibi CNN mimarileri daha düşük bir maliyetle rekabetçi sonuçlar üretebilmektedir. Bu nedenle, gerçek zamanlı veya kaynak kısıtlı bir steganaliz uygulamasında model seçiminin yalnızca başarıyı değil, gecikme ve bellek gereksinimleri de göz önünde bulundurularak yapılması gerektiği görülmektedir.

6. Sonuç

Gizli verilerin şüphe uyandırmadan aktarılabilmesi için steganografi yöntemleri önemli bir araç olarak öne çıkmaktadır. Steganografi, görünürde sıradan olan dijital ortamlar içerisine bilgi gizleyerek verinin varlığını saklamayı amaçlamaktadır. Özellikle görüntüler, yüksek veri kapasitesi nedeniyle bu alanda sıklıkla tercih edilmektedir. Ancak gizlenen verinin tespit edilebilmesi de güvenlik açısından büyük önem taşımakta ve bu noktada steganaliz yöntemleri devreye girmektedir. Geleneksel istatistiksel yöntemlerin sınırlılıkları dikkate alındığında, derin öğrenme mimarileri bu tür ince istatistiksel farklılıkların otomatik olarak öğrenilmesi için güçlü bir alternatif sunmaktadır. Özellikle CNN ve transformer tabanlı modeller, görsel verilerdeki karmaşık paternleri öğrenme yetenekleri sayesinde steganaliz çalışmalarında öne çıkmaktadır.

Bu çalışmada gerçekleştirilen deneyler, LSB tabanlı steganografi ile gizlenmiş verilerin derin öğrenme tabanlı modellerle tespit edilebilirliğini ortaya koymuştur. Genel olarak, gizleme oranı ve piksel başına bit sayısı arttıkça modellerin başarılarının da yükseldiği gözlenmiştir. Bununla birlikte bu artışın doğrusal olmadığı, bazı çözünürlük ve model kombinasyonlarında beklenmedik düşüşler yaşandığı belirlenmiştir. Bu durum, kullanılan mimarilerin farklı tasarım yaklaşımları, ön eğitim stratejileri ve yama tabanlı ayrıştırma yönteminin sonuçları etkilediğini göstermektedir.

Transformer tabanlı modellerin özellikle yüksek gizleme oranlarında CNN mimarilerine kıyasla daha avantajlı olduğu görülmektedir. Bununla birlikte ResNet-50 gibi modern CNN yapıları da transformer mimarilerine yakın sonuçlar elde edebilmektedir. Bu sonuçlara dayanarak steganaliz çalışmalarında farklı senaryolar için farklı mimarilerin avantaj sağlayabileceği söylenebilmektedir. İlerleyen çalışmalarda, VLM tabanlı bir yaklaşımın özelleştirilmesi ile farklı senaryolarda gizlenmiş verilerin tespiti ve belirli bir kısmının elde edilebilmesi amaçlanmaktadır.

Teşekkür

Bu çalışma Trakya Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından 2024/196 numaralı proje kapsamında desteklenmiştir. E.Ö., A.Ş.M ve Ö.A.F fikir sahibi ve makale yazımı, sonuç yorumu gerçekleştirdi. E.Ö. deneyleri gerçekleştirdi.

Kaynaklar

- [1] Kumar N, Soni M. Randomized salt LSB: a novel approach to steganography with improved concealment and robustness. Int J Inf Technol 2025; 1-14.

- [2] Putra ABW, Jufri MT, Lantara D, Assyauqi A, Wajiansyah A, Pranolo A. Steganography for data hiding in digital audio data using combined least significant bit and 4-wrap length method. In: 2018 2nd East Indonesia Conference on Computer and Information Technology (EIConCIT), 2018; IEEE. pp. 336-339.
- [3] Sharma VK, Soni BP, Janu N, Aziz S, Shekhawat D. Review on image steganography using different LSB methods. *J Discrete Math Sci Cryptogr* 2024; 27(4): 1319-1329.
- [4] Xiang L, Qin J, Xiang X, Tan Y. Text coverless information hiding based on BERT entity recognition. *Hum-Centric Comput Inf Sci* 2024; 14.
- [5] Su W, Ni J, Sun Y. Stegastylegan: Towards generic and practical generative image steganography. In: Proceedings of the AAAI Conference on Artificial Intelligence, 2024. pp. 240-248.
- [6] Sk A, Chakraborty S, Sen S. A novel blocked based U-Net model for image steganography. *Multimed Tools Appl* 2025; 1-20.
- [7] Li N, Qin J, Xiang X, Tan Y. Robust coverless video steganography based on inter-frame keypoint matching. *J Inf Secur Appl* 2023; 79: 103653.
- [8] Yang L, Xu D, Wang R, He S. Adaptive HEVC video steganography based on distortion compensation optimization. *J Inf Secur Appl* 2023; 73: 103442.
- [9] Mou C, Xu Y, Song J, Zhao C, Ghanem B, Zhang J. Large-capacity and flexible video steganography via invertible neural network. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023. pp. 22606-22615.
- [10] Meng L, Jiang X, Zhang Z, Li Z, Sun T. A robust coverless video steganography based on maximum DC coefficients against video attacks. *Multimed Tools Appl* 2024; 83(5): 13427-13461.
- [11] Li J, Wang K, Jia X. A coverless audio steganography based on generative adversarial networks. *Electronics* 2023; 12(5): 1253.
- [12] Xiang X, Tan Y, Qin J, Tan Y. Advancements and challenges in coverless image steganography: A survey. *Signal Process* 2025; 228: 109761.
- [13] Neeta D, Snehal K, Jacobs D. Implementation of LSB steganography and its evaluation for various bits. In: 2006 1st International Conference on Digital Information Management, 2006; IEEE. pp. 173-178.
- [14] Yang CH, Weng CY, Wang SJ, Sun HM. Adaptive data hiding in edge areas of images with spatial LSB domain systems. *IEEE Trans Inf Forensics Secur* 2008; 3(3): 488-497.
- [15] Öztürk E, Mesut AŞ, Fidan ÖA. A character based steganography using masked language modeling. *IEEE Access* 2024; 12: 14248-14259.
- [16] Mesut AŞ, Aydın Ö, Öztürk E. Anlamsal yöntemler kullanan bir metin steganografi uygulaması. In: Proceedings of the 1st International Symposium on Digital Forensics and Security (ISDFS), 2013. pp. 21-24.
- [17] Aydın Ö, Mesut AŞ, Öztürk E. Finding the optimal color channel for information hiding in LSB insertion method. *J Fundam Sci Appl* 2020; 26(1): 1-5.
- [18] Kich I, Ameer EB, Taouil Y, Benhfid A. Image steganography scheme using dilated convolutional network. In: 2021 12th International Conference on Information and Communication Systems (ICICS), 2021; IEEE. pp. 305-309.
- [19] Xu Y, Mou C, Hu Y, Xie J, Zhang J. Robust invertible image steganography. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022. pp. 7875-7884.
- [20] Zhang C, Gao X, Liu X, Hou W, Yang G, Xue T, Wang L, Liu L. IDGAN: Information-driven generative adversarial network of coverless image steganography. *Electronics* 2023; 12(13): 2881.
- [21] Kheddar H, Hemis M, Himeur Y, Megias D, Amira A. Deep learning for steganalysis of diverse data types: A review of methods, taxonomy, challenges and future directions. *Neurocomputing* 2024; 581: 127528.
- [22] Chen Z, Huang L, Miao H, Yang W, Meng P. Steganalysis against substitution-based linguistic steganography based on context clusters. *Comput Electr Eng* 2011; 37(6): 1071-1081.
- [23] Xu Q, Zhang R, Liu J. Linguistic steganalysis by enhancing and integrating local and global features. *IEEE Signal Process Lett* 2023; 30: 16-20.
- [24] Zou J, Yang Z, Zhang S, ur Rehman S, Huang Y. High-performance linguistic steganalysis, capacity estimation and steganographic positioning. In: International Workshop on Digital Watermarking, 2020; Springer. pp. 80-93.
- [25] Yang J, Yang Z, Ge X, Zou J, Gao Y, Huang Y. Link: Linguistic steganalysis framework with external knowledge. In: ICASSP 2023 - IEEE International Conference on Acoustics, Speech and Signal Processing, 2023; IEEE. pp. 1-5.
- [26] Yang MB, Pang K, Wang H, Huang Y. Towards next-generation steganalysis: LLMs unleash the power of detecting steganography. *arXiv preprint arXiv:2405.09090*, 2024.
- [27] Pevný T, Bas P, Fridrich J. Steganalysis by subtractive pixel adjacency matrix. In: Proceedings of the 11th ACM Workshop on Multimedia and Security, 2009. pp. 75-84.
- [28] Fridrich J, Kodovsky J. Rich models for steganalysis of digital images. *IEEE Trans Inf Forensics Secur* 2012; 7(3): 868-882.
- [29] Gao X, Yi J, Liu L, Tan L. A generic image steganography recognition scheme with big data matching and an improved ResNet50 deep learning network. *Electronics* 2025; 14(8): 1610.
- [30] Liu P, Li S. Steganalysis of intra prediction mode and motion vector-based steganography by noise residual convolutional neural network. In: IOP Conference Series: Materials Science and Engineering, 2020; IOP Publishing. 012068.

- [31] Yousfi Y, Butora J, Khvedchenya E, Fridrich J. ImageNet pre-trained CNNs for JPEG steganalysis. In: 2020 IEEE International Workshop on Information Forensics and Security (WIFS), 2020; IEEE. pp. 1-6.
- [32] Yousfi Y, Butora J, Fridrich J, Fuji Tsang C. Improving EfficientNet for JPEG steganalysis. In: Proceedings of the 2021 ACM Workshop on Information Hiding and Multimedia Security, 2021. pp. 149-157.
- [33] Hong E, Lim K, Oh TW, Jang H. Lightweight image steganalysis with block-wise pruning. *Sci Rep* 2023; 13(1): 16148.
- [34] Ozcan S, Mustacoglu AF. Transfer learning effects on image steganalysis with pre-trained deep residual neural network model. In: 2018 IEEE International Conference on Big Data (Big Data), 2018; IEEE. pp. 2280-2287.
- [35] Yang J, Shi YQ, Wong EK, Kang X. JPEG steganalysis based on DenseNet. *arXiv preprint arXiv:1711.09335*, 2017.
- [36] Bravo-Ortiz MA, Mercado-Ruiz E, Villa-Pulgarin JP, Hormaza-Cardona CA, Quinones-Arredondo S, Arteaga-Arteaga HB, Orozco-Arias S, Cardona-Morales O, Tabares-Soto R. CVTStego-Net: A convolutional vision transformer architecture for spatial image steganalysis. *J Inf Secur Appl* 2024; 81: 103695.
- [37] Delgado-Martínez MC, Ramírez Rodríguez FA, Guevara-Navarro E, Cardona-Pérez LM, García-Herrera S, Isaza G, Tabares-Soto R, Bravo-Ortiz MA. R-SIT: A Swin-Transformer-based architecture for spatial image steganalysis. In: Iberoamerican Congress on Pattern Recognition (CIARP), November 2025; Cham: Springer Nature Switzerland. pp. 99-114.
- [38] Wei KK, Luo WQ, Tan SQ, Huang JW. CTNet: A convolutional transformer network for color image steganalysis. *J Comput Sci Technol* 2025; 40(2): 413-427.
- [39] Öztürk E, Mesut A, Fidan ÖA. Comprehensive dataset for analyzing detectability in LSB steganography. *Bilişim Teknol Derg* 2026; 19(1): 79-90.
- [40] He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016. pp. 770-778.
- [41] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*, 2014.
- [42] Huang G, Liu Z, van der Maaten L, Weinberger KQ. Densely connected convolutional networks. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017. pp. 4700-4708.
- [43] Tan M, Le Q. EfficientNet: Rethinking model scaling for convolutional neural networks. In: International Conference on Machine Learning, 2019; PMLR. pp. 6105-6114.
- [44] Sandler M, Howard A, Zhu M, Zhmoginov A, Chen LC. MobileNetV2: Inverted residuals and linear bottlenecks. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018. pp. 4510-4520.
- [45] Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X, Unterthiner T, Dehghani M, Minderer M, Heigold G, Gelly S. An image is worth 16×16 words: Transformers for image recognition at scale. *arXiv preprint arXiv:2010.11929*, 2020.
- [46] Liu Z, Lin Y, Cao Y, Hu H, Wei Y, Zhang Z, Lin S, Guo B. Swin transformer: Hierarchical vision transformer using shifted windows. In: Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021. pp. 10012-10022.
- [47] Bao H, Dong L, Piao S, Wei F. BEiT: BERT pre-training of image transformers. *arXiv preprint arXiv:2106.08254*, 2021.
- [48] Touvron H, Cord M, Douze M, Massa F, Sablayrolles A, Jégou H. Training data-efficient image transformers & distillation through attention. In: International Conference on Machine Learning, 2021; PMLR. pp. 10347-10357.