

Elektrik-Elektronik ve Haberleşme Mühendisliği: Teori, Metodoloji ve Uygulama

Editör
Doç. Dr. Engin Hüner

Elektrik-Elektronik ve Haberleşme Mühendisliği: Teori, Metodoloji ve Uygulama

Editör

Doç. Dr. Engin Hüner

İmtiyaz Sahibi
Platanus Publishing®

Editör
Doç. Dr. Engin Hünler

Kapak & Mizanpaj & Sosyal Medya
Platanus Yayın Grubu

Birinci Basım
Ekim, 2025

Yayımcı Sertifika No
45813

ISBN
978-625-6454-11-8

©copyright
Bu kitabın yayım hakkı Platanus Publishing'e aittir. Kaynak gösterilmeden alıntı yapılamaz, izin alınmadan hiçbir yolla çoğaltılamaz.

Adres: Natoyolu Cad. Fahri Korutürk Mah. 157/B, 06480, Mamak,
Ankara, Türkiye.

Telefon: +90 312 390 1 118
web: www.platanuspublishing.com
e-mail: platanuskita@gmail.com



Platanus Publishing®

İÇİNDEKİLER

BÖLÜM 1.....	5
Hasan Polat & Oğuz Kaan Polat	
BÖLÜM 2.....	29
İleti Dizi Anten Tasarımlarında Makine Öğrenmesi Kullanımı	
Muhammed Malkoç & Ümit Çiğdem Turhal	
BÖLÜM 3.....	41
Resonance in Electrical Circuits	
Yunus Emre Ekici & Arif Memmedov & Teoman Karadağ	



BÖLÜM 1

Uzaktan Algılama Görüntülerinden Çatı Üstü Fotovoltaik Panellerin Tespitinde Derin Semantik Segmentasyon Mimarilerinin Karşılaştırmalı Analizi

Hasan Polat¹ & Oğuz Kaan Polat²

1. GİRİŞ

Artan enerji talebi, maliyetler ve ülkelerin karbon nötrlüğü hedefleri doğrultusunda, fosil yakıtların yerini giderek yenilenebilir enerji sistemleri almaktadır (H. Jiang ve diğerleri, 2021). Bu bağlamda, fotovoltaik (PV) sistemlerinin küresel olarak enerji piyasasında baskın bir konuma yükselmesiyle birlikte, bu alandaki kurulumlar ve yatırımlar son yıllarda dikkat çekici bir artış göstermiştir (García ve diğerleri, 2024). Uluslararası Yenilenebilir Enerji Ajansı (IRENA) verilerine göre, şebekeye bağlı PV sistemlerin küresel çapta kurulu gücünün 2030 yılına kadar 2156 GW'a ulaşması öngörülmektedir (Jalal, Khalil ve Haq, 2024). Ancak, PV sistemlerin doğrudan şebekeye entegre edilmesi, arz ve talep dengesinin sağlanmasında çeşitli zorlukları da beraberinde getirmektedir (Li, Lu ve Qin, 2025). Dolayısıyla, PV panellerin otomatik olarak doğru ve verimli bir şekilde tespit edilmesi, solar PV sistemlerin haritalama ve planlama süreçlerinin etkinliği açısından kritik önem taşımaktadır.

Son yıllarda uzaktan algılama teknolojilerinde kaydedilen ilerlemeler, geniş alanlara yayılan PV panellerin görüntüler üzerinden doğrudan segmente edilebilmesini mümkün kılmıştır (Li ve diğerleri, 2025). Manuel değerlendirme yöntemlerinin aksine, uzaktan algılama teknolojileri kullanılarak geniş ölçekli PV panellerin tespiti, konumlandırılması ve hata analizi otomatik bir biçimde gerçekleştirilebilmektedir. Bu doğrultuda, PV panellerin uzaktan algılama temelli olarak değerlendirilmesi günümüzde önemli bir araştırma alanı haline gelmiştir (W. Liu ve diğerleri, 2024).

Uzaktan algılama görüntülerinden PV panellerinin tespitine yönelik mevcut çalışmalar, genel olarak geleneksel yöntemler ve derin öğrenme tabanlı yaklaşımlar olmak üzere iki ana kategori altında sınıflandırılabilir. Geleneksel yaklaşımlar, bir takım özelliklerin çıkarılması, uygun özelliklerin seçimi ve makine öğrenmesi algoritmalarının uygulanması esasına dayanmaktadır (Wang

¹ Doç. Dr., Bingöl Üniversitesi, ORCID: 0000-0001-5535-4832

² Bingöl Üniversitesi, ORCID: 0009-0002-2550-8153

ve diğerleri, 2023). Özellik çıkarımında, uzaktan algılama görüntülerinden PV panellerin tespitinde sıklıkla spektral, yansımaya, radar, doku, morfolojik ve mekânsal özellikler ile manuel çıkarım indekslerine odaklanılmıştır. Çıkarılan özellik vektörlerinin sınıflandırmada ise çoğunlukla rastgele orman (RF), destek vektör makineleri (DVM) ve XGBoost gibi konvansiyonel algoritmaların kullanıldığı tespit edilmiştir (Z. Chen, Kang, Sun, Wu ve Zhang, 2022; W. Jiang, Tian, Duan, Chen ve Hu, 2023; Wang ve diğerleri, 2023; Zhang, Tian, Zhong, Liu ve Li, 2023). Ancak, geleneksel yaklaşımlarda özelliklerin temsil kabiliyeti; veri setlerine ilişkin aydınlatma koşulları, görüntüleme açısı, sensör çözünürlüğü ve arka plan karmaşıklığı gibi etkenlerden kolayca etkilenmekte ve model performansını doğrudan etkileyebilmektedir (Li, Lu, Jiang ve Qin, 2023; Wang ve diğerleri, 2023). Dolayısıyla, geleneksel yaklaşım ile heterojen dağılıma sahip uzaktan algılama görüntülerinden ayırt edici ve genelleyici özelliklerin isabetli olarak çıkarılması oldukça zorlu bir süreçtir.


Derin öğrenme mimarilerinin bilgisayarlı görü uygulamalarındaki başarımı ve etkin özelliklerin otomatik olarak çıkartabilme yetenekleri, PV panellerin tespiti ve sınıflandırılmasındaki araştırmaların bu alana eğilim göstermesine neden olmuştur (W. Liu ve diğerleri, 2024). Derin öğrenme tabanlı çalışmalar ile PV panellerin değişen ölçekli uzaktan algılama görüntülerinden semantik segmentasyonunda genel olarak kodlayıcı ve kod çözücü mimari önerilir. PV panellere ilişkin alçak ve yüksek seviyeli özelliklerin çıkarıldığı kodlayıcı bölümünde evrimsel sinir ağlarının (ESA) kabiliyetlerinden istifade edilmektedir (Li ve diğerleri, 2025). Kod çözücü blokta ise çok ölçekli özellik haritalarından aşamalı bir şekilde yukarı örnekleme yapılarak orijinal görüntü boyutunda segmentasyon haritaları elde edilir. Derin öğrenme temelli segmentasyon yaklaşımları, manuel özellik çıkarımı gereksinimini ortadan kaldırması, büyük ölçekli ve çeşitlilik içeren veri kümeleri üzerinde yüksek genelleme performansı göstermesi ve ön-eğitilmiş ESA mimarilerinin yeniden kullanılabilirliği sayesinde önemli avantajlar sunmaktadır (Gevaert ve Belgiu, 2022; Y. Liu ve Wu, 2025).

Bu çalışmada, yüksek çözünürlüklü uzaktan algılama görüntülerinden çatı üstü PV panellerin otomatik olarak tespit edilmesi amaçlanmıştır. Bu kapsamda, farklı arka plan özelliklerine sahip çatı üstü PV panellerinin tespitinde DeepLabV3+, U-Net ve SegNet gibi bilgisayarlı görü alanında yaygın olarak kullanılan derin öğrenme tabanlı segmentasyon mimarilerinin performansları karşılaştırmalı olarak analiz edilmiştir. Böylelikle, PV panel tespitinde arka plan özelliklerinin, veri dağılımındaki dengesizliklerin ve mimariye özgü anlamsal temsil farklarının performans üzerindeki etkileri incelenmiştir. Ayrıca, kodlayıcı

blokta kullanılan farklı omurga (backbone) mimarilerinin özellik çıkarımındaki yetkinlikleri, nitel ve nicel bulgular çerçevesinde değerlendirilmiştir.

2. MATERYAL VE METOT

Bu çalışmada, farklı arka plan özelliklerine sahip uzaktan algılama görüntülerinden çatı üstü PV panellerin tespitinde derin segmentasyon mimarilerinin performansı karşılaştırmalı olarak analiz edilmiştir. Önerilen modelin genel yapısı Şekil 1’de gösterilmektedir. Önerilen yaklaşım çerçevesinde, modellerin eğitiminde ve test edilmesinde kullanılan veri seti, ön işleme süreci, derin segmentasyon mimarileri ve değerlendirme metrikleri bu bölümde detaylandırılmıştır.




Şekil 1. PV panel tespit modeli

2.1. PV veri Seti

Bu çalışmada, çatı üstü PV panellerin tespitinde Çin'in Jiangsu Eyaleti'nden toplanan görüntüler kullanılmıştır (H. Jiang ve diğerleri, 2021). Görüntü verileri, yaklaşık 107.200 km²'lik bir geniş alandan alınmıştır. Çoklu ölçekli görüntüler, seyrek çalılıklar, göletler gibi sulu alanlar, tuzlu-akali araziler, rezervuarlar, düşük yoğunluklu çayırlar ve çatı üstleri gibi farklı ortamlarda kurulu olan PV panel tesislerinden elde edilmiştir. PV panel görüntüleri, zemin örnekleme mesafelerine (GSD) göre PV01, PV03 ve PV08 olarak alt gruplara ayrıştırılmış ve bitmap (BMP) formatında sunulmuştur. Veri alt gruplarının özellikleri aşağıda sırasıyla açıklanmıştır. Görüntü verileri üzerine segmentasyon mimarilerinin önerilmesi, geliştirilmesi ve test edilmesi için gerçek referans (ground-truth) haritaları poligonal etiketleme yöntemi ile oluşturulmuştur.

- PV01: Çatı üstü PV panel kurulumlarını içermekte olup, GSD değeri 0.1 m olan insansız hava araçları (İHA) görüntülerinden oluşmaktadır.
- PV03: Yer üzerine kurulan PV panel tesislerinden alınmış olup, GSD değeri 0.3 m olan hava görüntülerinden oluşmaktadır.
- PV08: Gaofen-2 ve Beijing-2 uydu görüntülerinden çıkarılan geniş ölçekli PV örneklerini içermektedir. Bu alt gruba ait görüntülerde GSD değerleri 0,81 m ve 0,80 m'dir.



Şekil 2. de her bir alt grubuna ilişkin örnek görüntüler ve gerçek referans haritaları

Bu çalışmada, 256×256 piksel boyutunda çatı üstü PV panel görüntülerinden oluşan PV01 alt veri grubu önerilen segmentasyon mimarilerin eğitim ve test edilmesinde kullanılmıştır. Şekil 2’de her bir alt grubuna ilişkin örnek görüntüler ve gerçek referans haritaları gösterilmiştir. PV01 veri seti için her bir alt kategoriye ait örnek sayıları Tablo 1’de verilmiştir. Çatı tipi PV sistemlere ilişkin tutarsızlıklar ve kayıt dışı kurulumlar, verimli bir şebeke genişletme planlaması için kritik öneme sahip olduğundan, bu sistemlerin doğru biçimde tespit edilmesi büyük önem taşımaktadır.

Tablo 1. PV01 alt veri grubuna ilişkin organizasyon yapısı

Çatı tipi	GSD derecesi	Çözünürlük	Örnek sayısı
Düz beton	~ 0.1 m	256×256	413
Çelik-Kiremit	~ 0.1 m	256×256	94
Tuğla	~ 0.1 m	256×256	138

2.2. Ön işleme

Çatı üstü PV panellerin tespitinde erişime sunulan BMP formatındaki görüntüler, derin öğrenme modellerinin eğitim verimliliğini artırmak amacıyla PNG (*portable network graphics*) formatına dönüştürülmüştür. BMP formatı sıkıştırılmamış ve büyük dosya boyutlarına sahip iken, PNG formatı kayıpsız sıkıştırma yöntemi kullanarak dosya boyutlarını küçültülmüştür. Dönüşüm ile segmentasyon mimarilerinin daha hızlı eğitimi ve her bir iterasyonda depolama alanı tasarrufu amaçlanmıştır.


Çatı üstü PV panel tespitinde arka plan türü, eğim açısı ve yüzey pürüzlülüğü gibi faktörlerin yanı sıra sınıflar arası dengesizlik gibi etmenlerin etkisini incelemek için PV01 alt veri grubu kendi içinde düz beton, tuğla ve çelik-kremit olmak üzere üç sınıfa ayrıştırılmıştır. Segmentasyon problemlerinde bir sınıfa ait toplam piksel sayısı ile ilgili sınıfın bulunduğu görüntülerdeki toplam piksel sayısı arasında belirgin bir temsil dengesizliği bulunmaktadır. Tablo 2’de PV01 veri setini oluşturan her bir kategori için sınıflar arası piksel dağılımı gösterilmektedir. Tablo 2’de piksel sayısı, ilgili sınıfa ait toplam piksel sayısını; görüntü piksel sayısı ise ilgili sınıfın bulunduğu görüntüler için toplam piksel sayısı ifade etmektedir.

Tablo 2. PV01 veri setine ilişkin her bir kategori ait sınıf piksel dağılımları

Kategori	Sınıf	Piksel Sayısı	Görüntü Piksel Sayısı
Düz beton	Arka plan	1.796e+07	2.706e+07
	PV Panel	0.911e+07	2.706e+07
Çelik-Kiremit	Arka plan	3.054e+06	6.160e+06
	PV Panel	3.105e+06	6.094e+06
Tuğla	Arka plan	8.573e+06	9.044e+06
	PV Panel	4.704e+05	8.912e+06

2.3. Semantik segmentasyon

Bu çalışma uzaktan algılama görüntülerinde PV panel tespiti için üç önde gelen derin segmentasyon mimarilerinin arka plan karmaşıklığı ve sınıf dengesizliği altındaki gerçek performans farklılıklarını ortaya koyarak, alana bir karşılaştırmalı bakış sunmaktadır. Bu kapsamda kullanılan segmentasyon mimarileri genel olarak ardışık evrişim katmanları ile özellik hiyerarşisini çıkaran ve bu temsilleri yoğun piksel düzeyinde tahmin ederek segmentasyon haritasına dönüştüren bir tasarım ilkesine dayanmaktadır (Saood ve Hatem, 2021). Şekil 3’de semantik segmentasyon mimarisinin genel çerçevesi gösterilmektedir.



Şekil 3. Semantik segmenatsyon mimarilerinin genel yapısı

2.3.1. U-Net

U-Net ilk olarak biyomedikal görüntülerin segmentasyonu amacıyla önerilmiştir (Ronneberger, Fischer ve Brox, 2015). Önerilen model ile ilgilenilen bölgenin (region of interest) piksel düzeyinde hassas bir şekilde lokalizasyonu ve sınır geçişlerinin önem arz ettiği görevlerin üstesinden gelmek üzere geliştirilmiştir. Ağın simetrik yapısı ve atlama bağlantıları ile yüksek seviyeli anlamsal bilgilerin ayrıntılı uzamsal bilgilerle birleştirilerek hem bağlamsal özellikleri yakalanması hem de uzamsal çözünürlüğün korunması sağlanmıştır. Son yıllarda U-Net ve türevleri, uzaktan algılama ve PV modül tespiti çalışmalarında yaygın biçimde kullanılmaktadır (García ve diğerleri, 2024; Li ve diğerleri, 2025). U-Net'in arka plan karmaşıklığı ve sınıf dengesizliği koşullarında dahi yüksek doğrulukla segmentasyon gerçekleştirebilmesi, onu uydu ve hava görüntülerinden PV panel haritalama çalışmalarında güçlü bir temel mimari hâline getirmiştir.

Bu çalışmada U-Net modeli, farklı kategorilerdeki çatı üstü PV panel tespiti üzerinde genelleme kabiliyeti değerlendirilmek üzere temel segmentasyon mimarilerinden biri olarak kullanılmıştır. Ağın kodlayıcı bölümü, girdi olarak sunulan orijinal görüntüleri uzamsal olarak kademeli bir şekilde azaltırken, kod çözücü blok ise özellik haritalarını restore ederek piksel düzeyinde segmentasyon çıktıları üretmektedir (Awedat, Comert, Ayad ve Mrebit, 2025). Kodlayıcı blokta özellik temsillerini zenginleştiren ReLU aktivasyonlu evrişim katmanları ve maksimum havuzlama operasyonları bulunurken, kod çözücü bölümde ise kodlayıcıdan gelen yüksek ve alçak seviyeli öznetelik haritalarının birleştirilmesi işlemleriyle kaybolan ayrıntıların geri kazanılmasını sağlamaktadır. Bu simetrik yapı sayesinde model, piksel düzeyinde sınıflandırma ile yoğun bir segmentasyon haritası üreterek PV panel bölgelerini yüksek doğrulukla temsil edebilmektedir.

2.3.2. SegNet

SegNet, piksel düzeyinde segmentasyon için önerilen tam katmanlı sinir ağı modelidir (Badrinarayanan, Kendall ve Cipolla, 2017). Önerilen eğitilebilir

segmentasyon modeli bir kodlayıcı blok, ona karşılık gelen bir kod çözücü blok ve son olarak piksel seviyesinde bir sınıflandırma katmanından oluşur. Modelin kodlayıcı bloğunda VGG16 (Simonyan ve Zisserman, 2015) modelinin topolojik olarak ilk 13 katmanı doğrudan kullanılır. Böylelikle, önceden eğitilmiş ağırlıklar ile uzaktan algılama görüntülerinden güçlü temsillerin çıkarılması mümkün kılınabilir. Ağın yenilikçi yönü ise kod çözücü blokta düşük çözünürlüklü özellik haritalarını yeniden örnekleme biçimi olarak ön plana çıkmaktadır. Kod çözücü bloğun her bir aşamasında ona karşılık gelen kodlayıcı katmanındaki maksimum havuzlama indisleri kullanılarak, doğrusal olmayan bir yukarı örnekleme işlemi gerçekleştirilir (Badrinarayanan ve diğerleri, 2017). Başlangıçta yol görüntüsü gibi sahne problemlerini segmente etmek için geliştirilmişken (Saood ve Hatem, 2021), üstün özellikleri ile uzaktan algılama problemlerinde de başvurulmuş segmentasyon mimarisi olmuştur.

Bu çalışmada SegNet modeli, PV panel segmentasyonu için kullanılan temel mimarilerden biri olarak seçilmiştir. Böylelikle, çatı üstü PV panel tespitinde VGG16 tabanlı kodlayıcı ile önceden eğitilmiş ağırlıklar kullanılarak transfer öğrenme ve havuzlama indislerinin kullanılmasına dayanan doğrusal olmayan yukarı örnekleme tekniğinin etkinliği araştırılmıştır.

2.3.3. DeepLabV3+

DeepLabV3+ modeli, kodlayıcı ve kod çözücü bloklarından oluşan standart bir mimariyi kullanır (L. C. Chen, Zhu, Papandreou, Schroff ve Adam, 2018). Kodlayıcı bloğu, giriş görüntülerinden çok ölçekli atrous (genişletilmiş) evrişim filtreleri aracılığıyla zengin bağlamsal özellikleri çıkarırken, kod çözücü blok ise bu özellik haritalarından piksel düzeyinde segmentasyon haritalarını üretir (Li ve diğerleri, 2023; Polat, 2025). Kod çözücü bloğunda özellikle nesnelere ilişkin kaybolan sınır bilgileri, kodlayıcı bloktan gelen alçak seviyeli öznetelik haritaları ile iyileştirilir. Böylelikle, nesnelere ilişkin sınır bilgileri yüksek doğrulukla geri kazanılır. Bu yaklaşım, selef modellerine kıyasla DeepLabV3+'ın en temel yeniliğini oluşturur ve PV panel segmentasyonu gibi karmaşık arka plan ve ince geometrik yapılar içeren görevlerde performans avantajı sağlayabilir.

Kodlayıcı blokta kullanılan ESA omurga mimari tarafından üretilen yüksek seviyeli özellik haritaları, atröz uzamsal piramit havuzlama (ASPP) modülüne iletilir. ASPP modülü ile paralel ve farklı genişletme oranında ($d=6,12$ ve 18) evrişim filtreleri yüksek seviyeli özelliklere uygulanarak, çok ölçekli bağlamsal bilgilerin etkin bir şekilde yakalanması mümkün kılınır (Kleebauer, Marz, Reudenbach ve Braun, 2023). Bu çalışmada, kodlayıcı bölümde output stride (OS) faktörü 16 olarak belirlenmiştir; böylece uzamsal çözünürlük korunurken, modelin hesaplama maliyeti dengelenmiştir.

DeepLabV3+ mimarisi, kodlayıcı bölümde önceden eğitilmiş derin özellik çıkarım ağlarını omurga yapı olarak kullanması ile güçlü semantik temsil kabiliyeti sunabilir. Bu çalışmada, PV panellerinden yüksek seviyeli anlamsal özniteliklerin çıkarılmasında artık bağlantılara (residual connections) sahip derin sinir ağı modellerinden olan ResNet18 ve ResNet50 (He, Zhang, Ren ve Sun, 2016) ile gerçek zamanlı uygulamalarda hesaplama verimliliği sunan hafif bir mimari olan MobileNetV2 (Sandler, Howard, Zhu, Zhmoginov ve Chen, 2018) kullanılmıştır. Bu yaklaşım ile topolojik derinlikleri ve katman bağlantı özellikleri bakımından farklılık gösteren omurga mimarilerinin, PV panel segmentasyonundaki temsil kabiliyetlerinin karşılaştırmalı olarak analiz edilmesi amaçlanmıştır.

Model eğitim stratejisi

Bu çalışmada, omurga mimarileri dâhil olmak üzere beş farklı segmentasyon mimarisinin, farklı arka plan koşulları ve sınıf dengesizlikleri içeren çatı üstü PV panel tespit görevindeki etkinlikleri incelenmiştir. Karşılaştırmalı analizlerin tutarlı ve güvenilir biçimde gerçekleştirilebilmesi amacıyla, eğitim sürecinde kullanılan temel hiper parametre ayarları tüm modeller için aynı tutulmuştur. Bu kapsamda, her bir iterasyonda (mini-batch) 4 örnek alınmış. Maksimum tam tur sayısı (epoch) sayısı 10 olarak belirlenmiştir. Ağırlıkların güncellenmesinde başlangıç öğrenme oranı (initial learning rate) 0.001 olarak atanmış ve iyileştirici olarak Adam optimizasyon algoritması (Kingma ve Ba, 2015) tercih edilmiştir.

Eğitim sırasında modellerin aşırı uyumlamaya gitmemesi ve genelleme kabiliyetinin artırılması amacıyla, erken durdurma (early stopping) mekanizması aktif tutulmuştur. Bu mekanizma, doğrulama kümesi üzerindeki doğrulama kaybı değerlerini takip ederek, performans iyileşmesinin gözlenmediği *patience* = 4 koşula göre eğitimi sonlandırmıştır.

Her bir kategorideki veri kümesi, eğitim, doğrulama ve test aşamalarında kullanılmak üzere sırasıyla 0.6, 0.2 ve 0.2 oranlarında ayrılmıştır. Ayrıca, önerilen her bir mimarinin genel performansını ve istatistiksel kararlılığını değerlendirmek amacıyla beş katlı çapraz doğrulama (5-fold cross-validation) tekniği uygulanmıştır. Tüm segmentasyon katları akabinde ortalama ve standart sapma değerleri hesaplanarak, modellerin farklı veri alt kümeleri üzerindeki kararlılığı karşılaştırılmıştır.

2.4. Model başarımleri

Çatı üstü PV panel kurulumlarının uzaktan algılama görüntülerinden piksel seviyesinde tespitinde, önerilen derin mimarilerin sunmuş oldukları performanslar, Kesişim-Birleşim Oranı (Intersection over Union, IoU), Dice Benzerlik Katsayısı (Dice Similarity Coefficient, DSC), Duyarlılık (Recall) ve Kesinlik (Precision) olmak üzere dört yaygın metrik türünden değerlendirilmiştir.

Böylelikle, segmentasyon modellerinin farklı karakteristikte görüntü kümeleri üzerindeki genelleme kabiliyetleri nicel olarak analiz edilmiştir. Bu metrikler, segmentasyon alanında model başarısını kapsamlı biçimde değerlendirmek için yaygın olarak kullanılmaktadır (García ve diğerleri, 2024; Kleebauer ve diğerleri, 2023; W. Liu ve diğerleri, 2024). Segmentasyon problemlerinde sınıf dengesizliğinden dolayı, doğruluk metriği dikkate alınmamıştır. Doğruluk metriği sınıflara ilişkin veri dağılımının dengeli olduğu sınıflandırma problemleri için güvenilir bir metrik olarak kullanılabilir.

- **Kesişim-Birleşim Oranı (IoU):**

IoU metriği, tahmin edilen bölge ile gerçek referans (ground-truth) bölge arasındaki örtüşme miktarını dikkate alır ve özellikle semantik segmentasyon çalışmalarında modelin uzamsal doğruluğunu değerlendirmede kritik bir gösterge olarak kabul edilir. IoU metriğinin matematiksel ifadesi aşağıdaki şekilde tanımlanır.

$$IoU = \frac{TP}{TP + FP + FN}$$

Burada TP doğru tespit edilen piksellerin sayısını, FP (yanlış pozitif) pozitif sınıf olarak tahmin edilen negatif sınıf piksel sayısını, FN (yanlış negatif) ise kaçırılan pozitif pikselleri ifade eder. Yüksek IoU değeri, tahmin edilen bölge ile gerçek bölge arasındaki uzamsal örtüşmenin arttığını işaret etmektedir.

- **Dice Benzerlik Katsayısı (DSC):**

DSC metriği, tahmin edilen ve gerçek bölgeler arasındaki benzerliği ölçen, segmentasyon problemlerinde bir diğer yaygın ölçüt olarak kabul edilir (Müller, Soto-Rey ve Kramer, 2021). IoU metriğinden farklı olarak, kesişim değerini iki katına çıkarıp, özellikle küçük nesnelerin tespitinde daha dengeli bir ölçüm sunar.

$$DSC = \frac{2 \times TP}{2 \times TP + FP + FN}$$

Yüksek DSC değeri, modelin pozitif örnekleri doğru tanımlama ve yanlış sınıflandırmaları minimize etme konusunda dengeli bir performans sergilediğini gösterir.

- **Duyarlılık (Recall):**

Duyarlılık metriği, modelin ilgilenilen bölgeye (*pozitif sınıf*) ilişkin örnekleri ne ölçüde doğru tespit edebildiğini ölçer. Bu metrik, modelin “kaçırılan” pozitif örnek oranını değerlendirmede kullanılır ve şu şekilde hesaplanır:

$$\text{Duyarlılık (recall)} = \frac{TP}{TP + FN}$$

Yüksek duyarlılık değeri, ilgilenilen bölgeyi yüksek oranda doğru tespit ettiğini gösterir. Sınıf dengesizliğinin olduğu, küçük bölgelerin tespit kabiliyetinin ölçümlenmesinde kritik önem taşır.

- **Kesinlik (Precision):**

Kesinlik, modelin yaptığı pozitif tahminlerin ne kadarının gerçekten doğru olduğunu ifade eder. Yanlış pozitiflerin etkisini değerlendirmek açısından önemlidir:

$$\text{Kesinlik (precision)} = \frac{TP}{TP + FP}$$

Yüksek kesinlik değeri, modelin yanlış pozitif oranını düşük tutarak güvenilir tahminler ürettiğini göstermektedir.

Genel olarak bu dört metrik birlikte değerlendirildiğinde, modelin tahmin doğruluğu, sınıflar arası ayırım gücü ve uzamsal genelleme yeteneği hakkında kapsamlı bir değerlendirme yapılabilir. IoU ve DSC metrikleri tahmin ile gerçek referans arasındaki uzamsal örtüşme kalitesini, duyarlılık ve kesinlik ise ilgilenilen bölge için piksel seviyesinde sınıflandırma performansını yansıtarak, segmentasyon kalitesinin bütüncül ve güvenilir bir biçimde ölçülmesine olanak tanır.

3. BULGULAR

Bu çalışmada yürütülen tüm deneysel işlem adımları, Intel Core i9 işlemci, 128 GB RAM ve 48 GB VRAM kapasitesine sahip NVIDIA A100 GPU ile donatılmış bir iş istasyonu üzerinde, MATLAB 2022a (MathWorks, Natick, MA, USA) programlama ortamı kullanılarak gerçekleştirilmiştir. Deneyler, çatı tipolojilerine (düz beton, tuğla, çelik-kiremit) göre sınıflandırılmış farklı alt-veri kümeleri üzerinde yinelenebilirlik ve hesaplama verimliliği gözetilerek yürütülmüştür. Elde edilen sonuçlar, her bir alt veri kümesine ilişkin olarak ayrı alt başlıklar altında sunulmuştur. Deneysel analizlerde, modellerin performansı

hem nicel ölçütler (DSC, IoU, Duyarlılık ve Kesinlik) üzerinden değerlendirilmiş hem de görsel segmentasyon çıktıları aracılığıyla nitel olarak incelenmiştir.

3.1. Düz beton tipi çatı üstü PV panel tespiti

Tüm modellerin eğitim ve doğrulama süreçleri beş katlı çapraz doğrulama yöntemiyle yürütülmüş olup, sonuçlar her bir sınıflara özgü olmak üzere (arka plan ve PV panel) için ortalama (μ) ve standart sapma (σ) değerleriyle verilmiştir. Tablo 3'te beş katlı çapraz doğrulama sonucunda düz beton çatı üstü PV panel segmentasyon sonuçları gösterilmektedir.

Tablo 3. Düz beton çatı üstü PVpanel segmentasyon sonuçları

Derim mimariler	Sınıf	Model Başarım Metrikleri							
		DSC		IoU		Duyarlılık		Kesinlik	
		μ	σ	μ	σ	μ	σ	μ	σ
U-Net	Arkapl an	0.89 8	0.03 3	0.81 7	0.05 5	0.89 1	0.08 3	0.91 2	0.06 4
	PV panel	0.79 6	0.04 9	0.66 3	0.06 7	0.82 2	0.12 2	0.79 4	0.11 3
SegNet	Arkapl an	0.92 6	0.07 0	0.86 8	0.11 6	0.88 3	0.12 1	0.98 1	0.01 3
	PV panel	0.79 1	0.27 6	0.71 0	0.30 1	0.95 6	0.01 3	0.73 6	0.31 6
DeepLabV 3+ ResNet18	Arkapl an	0.94 8	0.03 3	0.90 3	0.05 9	0.93 9	0.07 1	0.96 5	0.02 3
	PV panel	0.90 4	0.03 6	0.82 6	0.05 6	0.92 7	0.03 6	0.88 8	0.09 2
DeepLabV 3+ ResNet50	Arkapl an	0.95 6	0.03 3	0.91 7	0.05 9	0.94 3	0.05 6	0.96 9	0.01 6
	PV panel	0.92 1	0.03 1	0.85 5	0.05 3	0.94 0	0.02 2	0.90 5	0.06 0
DeepLabV 3+ MobileNet	Arkapl an	0.94 9	0.03 5	0.90 4	0.06 3	0.92 9	0.06 5	0.97 1	0.01 1
	PV panel	0.90 5	0.04 0	0.82 9	0.06 6	0.94 0	0.01 6	0.87 6	0.08 1

Not: μ : ortalama değeri, σ ise standart sapmayı göstermektedir. En yüksek sonuçlar ise kalın yazı tipi olarak vurgulanmıştır

Tablo 3'te nicel bulgular incelendiğinde, DeepLabV3+ tabanlı mimarilerin genel olarak diğer modellere kıyasla daha yüksek doğruluk sergilediği görülmektedir. DeepLabV3+ ResNet50 modeli, PV panel sınıfında $DSC = 0.921 \pm 0.031$ ve $IoU = 0.855 \pm 0.053$ değerleriyle en yüksek segmentasyon başarımını

elde etmiştir. Bu model ayrıca duyarlılık (0.940 ± 0.022) ve kesinlik (0.905 ± 0.060) metriklerinde de dengeli bir performans göstermiştir. Elde edilen bu sonuçlar, ResNet50 tabanlı derin özellik çıkarımının PV panel sınırlarını ayırt etmede güçlü bir temsil kabiliyeti sunduğunu göstermektedir.

DeepLabV3+ ResNet18 modeli de benzer şekilde yüksek doğruluk değerleri üretmiş ($DSC = 0.904 \pm 0.036$, $IoU = 0.826 \pm 0.056$) ve özellikle sınıf dengesizliğinin belirgin olduğu bölgelerde istikrarlı sonuçlar elde etmiştir. MobileNet tabanlı DeepLabV3+ mimarisi ise daha hafif yapısı nedeniyle hesaplama açısından avantaj sağlamakla birlikte doğruluk açısından ResNet50 tabanlı modelin bir miktar gerisinde kalmıştır ($DSC = 0.905 \pm 0.040$, $IoU = 0.829 \pm 0.066$).

Klasik kodlayıcı–kod çözücü yapısındaki U-Net ve SegNet mimarileri, genel olarak PV panel tepitinde daha düşük bir performans göstermiştir (U-Net $DSC = 0.796$, SegNet $DSC = 0.791$). Bu iki modelin özellikle IoU ve kesinlik değerlerinde gözlenen yüksek standart sapmaları, karmaşık çatı dokularında sınıf sınırlarını doğru biçimde tanımlamakta zorlandıklarını ortaya koymaktadır.

3.2. Tuğla tipi çatı üstü PV panel tespiti

Tablo 4’de eğimli tuğla tipi çatı üstü panel tespitinde beş farklı model tarafından sağlanan segmentasyon sonuçları gösterilmektedir. her sınıf için beş katlı çapraz doğrulama ile elde edilen segmentasyon performans bulguları, ortalama ve standart sapma türünden nicel olarak analiz edilmiştir. Elde edilen deneysel bulgular tuğla tipi çatılar için genel segmentasyon performansının düz beton tipi çatı üstü panel tipolojisine göre daha yüksek olduğunu göstermiştir. Özellikle, PV panel kurulumlarının daha yüksek bir doğrulukla arkaplandan ayrıştırılabildiği nicel bulgular ışığında doğrulanmıştır.

Tablo 4. Tuğla tipi çatı üstü PV panel segmentasyon sonuçları

Derim mimariler	Sınıf	Model Başarım Metrikleri							
		DSC		IoU		Duyarlılık		Kesinlik	
		μ	σ	μ	σ	μ	σ	μ	σ
U-Net	Arkapl an	0.98	0.00	0.96	0.01	0.98	0.00	0.97	0.01
		1	6	3	2	5	5	7	3
	PV panel	0.68	0.07	0.52	0.08	0.65	0.12	0.72	0.09
		0	6	0	6	9	3	5	6
SegNet	Arkapl an	0.98	0.00	0.97	0.00	0.95	0.00	0.97	0.00
		6	4	2	8	5	1	7	9
	PV panel	0.77	0.07	0.64	0.10	0.68	0.10	0.90	0.05
		8	8	2	2	8	4	5	0

DeepLabV3+ ResNet18	Arkaplan	0.99 1	0.00 2	0.98 3	0.00 5	0.99 7	0.00 1	0.98 6	0.00 5
	PV panel	0.86 4	0.02 1	0.76 1	0.03 4	0.79 5	0.04 5	0.94 9	0.04 6
DeepLabV3+ ResNet50	Arkaplan	0.99 3	0.00 2	0.98 7	0.00 5	0.99 8	0.00 1	0.98 8	0.00 5
	PV panel	0.88 1	0.04 5	0.80 1	0.07 1	0.82 3	0.07 8	0.96 8	0.02 8
DeepLabV3+ MobileNet	Arkaplan	0.99 4	0.00 1	0.98 8	0.00 2	0.99 7	0.00 1	0.99 0	0.00 3
	PV panel	0.89 7	0.02 7	0.81 5	0.04 5	0.84 9	0.05 4	0.95 5	0.03 5

Not: μ : ortalama değeri, σ ise standart sapmayı göstermektedir. En yüksek sonuçlar ise kalın yazı tipi olarak vurgulanmıştır

Genel bulguların DeepLabV3+ modelinin diğer U-Net ve SegNet segmentasyon mimarilerine göre daha üstün performans sunduğu tespit edilmiştir. DeepLabV3+ MobileNetV2 PV panel tespitini 0.897 ± 0.027 DSC ve 0.815 ± 0.045 IoU segmentasyon başarımları ile en yüksek performansta gerçekleştirmiştir. Omurga mimari olarak ResNet modelinin de PV panel sınıfı için $DSC=0.881 \pm 0.045$ ve $IoU=0.881 \pm 0.045$ değerleri ile tatmin edici temsil kabiliyetine sahip olduğunu göstermiştir. U-Net ve SegNet modellerinin ise DeepLabV3+ modellerine göre genel olarak daha düşük bir performansta karşılık verdiği gözlemlenmiştir. U-Net ve SegNet için sırasıyla segmentasyon başarımları DSC metriği türünden 0.680 ± 0.076 ve 0.778 ± 0.078 olarak elde edilmiştir. Her iki model için düşük duyarlılık ve kesinlik başarımları PV panel tespitinde piksel seviyesinde doğru tahminlerin düşük doğrulukla gerçekleştiği göstermiştir.

Tüm modeller için arkaplan sınıf segmentasyon performansının PV panel sınıfına kıyasla dikkat çekici düzeyde arttığı gözlemlenmiştir. DeepLabV3+ MobileNetV2 modeli arkaplan sınıfı için $DSC=0.994 \pm 0.001$ ve $IoU=0.988 \pm 0.002$ başarımları sunarak, arkaplan sınıfının tuğla tipi çatı üstü veri setinden daha yüksek doğrulukla piksel seviyesinde tespit edilebildiği göstermiştir. Farklı görüntü örneklerinden oluşan segmentasyon katları arkaplan sınıfının daha düşük varyansla tespit edildiği ortaya çıkarmıştır. Düşük varyans değeri, segmentasyon modellerinin farklı arkaplan tipolojilerine rağmen tutarlı ve sağlam sonuçlar sunduğunun göstergesi olarak kabul edilebilir.

3.3. Çelik-kiremit tipi çatı üstü PV panel tespiti

Çelik-kiremit tipi arka plan tipolojisine sahip PV01 görüntü grubu için genel olarak segmentasyon bulguların her iki sınıf için dengeli bir şekilde elde edildiği gözlemlenmiştir. Tablo 5'te her bir modelin ortalama segmentasyon performansları gösterilmiştir.

Tablo 5. Çelik-Kiremit tipi çatı üstü PV panel segmentasyon sonuçları

Derim mimariler	Sınıf	Model Başarım Metrikleri							
		DSC		IoU		Duyarlılık		Kesinlik	
		μ	σ	μ	σ	μ	σ	μ	σ
U-Net	Arkapl an	0.86	0.07	0.77	0.11	0.82	0.07	0.91	0.06
		6	3	0	1	9	1	5	3
	PV panel	0.85	0.07	0.75	0.10	0.91	0.04	0.81	0.12
		7	6	6	9	2	3	9	7
SegNet	Arkapl an	0.92	0.03	0.85	0.06	0.92	0.04	0.92	0.05
		3	6	8	2	9	7	1	8
	PV panel	0.92	0.01	0.86	0.02	0.92	0.04	0.93	0.03
		9	4	9	4	7	1	4	7
DeepLabV 3+ ResNet18	Arkapl an	0.96	0.01	0.93	0.03	0.96	0.00	0.96	0.03
		5	9	3	5	6	8	4	4
	PV panel	0.96	0.01	0.93	0.02	0.96	0.02	0.96	0.00
		6	3	5	3	5	7	8	2
DeepLabV 3+ ResNet50	Arkapl an	0.97	0.01	0.94	0.03	0.96	0.02	0.97	0.01
		1	6	4	0	8	2	4	4
	PV panel	0.97	0.01	0.94	0.02	0.97	0.01	0.97	0.01
		2	2	6	3	3	5	1	5
DeepLabV 3+ MobileNet	Arkapl an	0.96	0.01	0.93	0.03	0.96	0.00	0.96	0.03
		5	6	3	0	7	4	3	0
	PV panel	0.96	0.01	0.93	0.02	0.96	0.02	0.96	0.01
		5	5	3	8	6	0	5	9

Not: μ : ortalama değeri, σ ise standart sapmayı göstermektedir. En yüksek sonuçlar ise kalın yazı tipi olarak vurgulanmıştır.

Tablo 5'te görüldüğü üzere, DeepLabV3+ ResNet50 modeli tüm değerlendirme metrikleri (DSC, IoU, duyarlılık ve kesinlik) açısından diğer modellere kıyasla daha üstün bir performans sergilemiştir. Bu model ile PV panellerinin DSC ve IoU değerleri sırasıyla 0.972 ± 0.012 ve 0.946 ± 0.023 olarak elde edilmiştir. Ayrıca, PV panel tespitinde 0.973 ± 0.015 duyarlılık ve 0.971 ± 0.015 kesinlik değerleri ile dengeli bir performans göstermiştir.

PV panelleri dışındaki diğer unsurları temsil eden arka plan sınıfında da genel olarak kararlı ve dengeli bir segmentasyon başarımı gözlenmiştir. En yüksek doğruluğun elde edildiği DeepLabV3+ ResNet50 modeli, arka plan sınıfını $DSC = 0.971 \pm 0.016$ ve $IoU = 0.944 \pm 0.030$ değerleriyle yüksek doğrulukta segmente etmiştir. Klasik kodlayıcı-kod çözücü yapısına sahip U-Net ve SegNet mimarilerinin ise DeepLabV3+ modellerine kıyasla daha düşük doğrulukta PV panel ve arka plan sınıfları ayırt ettiği belirlenmiştir. Bu iki model için PV panel segmentasyon sonuçları $DSC = 0.957 \pm 0.076$ ve $IoU = 0.929 \pm 0.014$ olarak elde edilmiştir.

3.4. Genel performans değerlendirmesi

Farklı çatı tipleri için önerilen modeller tarafından gerçekleştirilen semantik segmentasyon sonucunda elde edilen genel çıktılar Tablo 6'da gösterilmiştir. Beş katlı çapraz doğrulama neticesinde her iki sınıf (Pv panel ve arkaplan) için elde edilen ortalama sonuçlar ile farklı modellerin performans etkinlikleri karşılaştırılmıştır.


Tablo 6'da görüldüğü üzere Düz beton çatılar üzerinde, DeepLabV3+ ResNet50 modeli ortalama $DSC=0.938$ ve $IoU=0.886$ performansı ile en iyi segmentasyon başarısına ulaşmıştır. Aynı çatı tipleri için DeepLabV3+ ResNet18 ve DeepLabV3+ MobileNetV2 modelleri sırasıyla, 0.926 ve 0.927 DSC performansları ile ResNet50 omurga mimarisini takip etmişlerdir. SegNet ve U-Net modellerinin etkinlikleri DeepLabV3+ modellerine kıyasla daha düşük olup, her iki model için DSC ve IoU performansları sırasıyla (0.858, 0.789) ve (0.847, 0.740) olarak ölçülmüştür.

Tuğla tipi çatılarda elde edilen sonuçlarda, DeepLabV3+ modelleri arasında MobileNetV2 omurga mimarisi tarafından $DSC = 0.946$ ve $IoU = 0.902$ değerleriyle en yüksek doğruluk oranına ulaşılmıştır. Aynı çatı tipinde DeepLabV3+ ResNet50 modeli (0.940, 0.894), DeepLabV3+ ResNet18 ise (0.927, 0.872) değerleriyle benzer düzeyde performans göstermiştir. Klasik mimarilerden SegNet ve U-Net modellerinin ortalama sonuçları sırasıyla (0.882, 0.807) ve (0.831, 0.741) olarak kaydedilmiştir.

Tablo 6. Farklı çatı tiplerine göre segmentasyon modellerinin ortalama performansları

Çatı Tipi	Mimariler	DSC	IoU
Düz beton	U-Net	0.847	0.740
	SegNet	0.858	0.789
	DeepLabV3+ ResNet18	0.926	0.864
	DeepLabV3+ ResNet50	0.938	0.886
	DeepLabV3+ MobileNetV2	0.927	0.866
Tuğla	U-Net	0.831	0.741
	SegNet	0.882	0.807
	DeepLabV3+ ResNet18	0.927	0.872
	DeepLabV3+ ResNet50	0.940	0.894
	DeepLabV3+ MobileNetV2	0.946	0.902
Çelik-Kiremit	U-Net	0.862	0.763
	SegNet	0.926	0.864
	DeepLabV3+ ResNet18	0.966	0.934
	DeepLabV3+ ResNet50	0.971	0.945
	DeepLabV3+ MobileNetV2	0.965	0.933

Çelik-kiremit çatılar için yapılan deneylerde, tüm modellerin performanslarının diğer çatı tiplerine göre daha yüksek olduğu gözlenmiştir. Bu kategoride DeepLabV3+ ResNet50 modeli DSC = 0.971 ve IoU = 0.945 ile en yüksek doğruluk değerine ulaşmıştır. Bunu DeepLabV3+ ResNet18 (0.966, 0.934) ve DeepLabV3+ MobileNetV2 (0.965, 0.933) izlemiştir. SegNet ve U-Net modellerinin değerleri sırasıyla (0.926, 0.864) ve (0.862, 0.763) olarak ölçülmüştür. Elde edilen bulguların daha iyi karşılaştırılması için farklı çatı tipi kategorileri için her bir model tarafından sağlanan ortalama performans değerleri görsel olarak Şekil 4'te sunulmuştur.




Şekil 4. Farklı çatı tüplerinde göre segmentasyon modellerinin ortalama perfromasları.

(a): U-Net, (b): SegNe, (c): DeepLabV+ ResNet18, (d): DeepLabV+ ResNet50, (e): DeepLabV+ MobileNetV2

3.5. Görsel Segmentasyon Bulguları

Bu bölümde, farklı çatı tipi gruplarına ilişkin görüntüler üzerinde test edilen segmentasyon mimarilerinin performansları yalnızca nicel ölçütlerle değil, aynı zamanda segmentasyon tahminlerinin görsel çıktıları üzerinden nitel olarak da değerlendirilmiştir. Bu bağlamda, DeepLabV3+, SegNet ve U-Net modelleri tarafından üretilen segmentasyon çıktıları, örnek görüntüler üzerinden karşılaştırmalı olarak ele alınmıştır. Şekil 5’de farklı derin mimarilere ilişkin görsel segmentasyon bulguları gösterilmektedir. Görsel bulgular ile modellerin farklı arka plan dokularında kenar belirleme doğruluğu, nesne bütünlüğünü koruma kabiliyeti, arka plan ayrımı ve ışık-gölge koşullarına karşı dayanıklılığı görsel olarak ortaya konmuştur. Böylelikle, modellerin tam olarak nicel metriklerle yansıtılamayan, gerçek sahne koşullarındaki davranışları gözlemlenmeye çalışılmıştır.



Şekil 5. Farklı derin mimarilere ilişkin görsel segmentasyon bulguları

Şekil 5’de görüldüğü üzere düz beton tipi çatılarda, panel sınırlarının belirgin ve arka planın nispeten homojen olması nedeniyle segmentasyon modelleri genel olarak yüksek doğrulukla sonuçlar üretmiştir. Kenar algılamanın özellikle DeepLabV3+ ResNet50 modeli tarafından en net biçimde gerçekleştiği, doğru pozitif ve doğru negatif kararlar arasında keskin sınır geçişlerinin olduğu tespit edilmiştir. ResNet18 ve MobileNetV2 mimarilerin kodlayıcı olarak kullanıldığı DeepLabV3+ modelleri için ise genel olarak panel biçimlerinin doğru tahmin edildiği, ancak piksel seviyesinde az sayıda yanlış pozitif tahmin kaynaklı sınır

pürüzlerinin oluştuğu da gözlemlenmiştir. SegNet'te sınırlar daha yumuşak, U-Net'te ise bazı panellerin kısmen eksik tespit edildiği görülmüştür.

Tuğla tipi çatılarda, yüzey dokusunun karmaşıklığı ve renk varyasyonları modellerin performansını belirgin biçimde etkilemiştir. DeepLabV3+ tabanlı modeller, özellikle ResNet50 kodlayıcı ile tuğla deseni ve gölgelenmeden kaynaklanan karışıklığa rağmen panel bölgelerini doğru biçimde yakalamıştır. Bununla birlikte, SegNet ve U-Net modelleri benzer renk ve dokular için panel kenar bilgilerini kısmen kaybetmiştir. Dolayısıyla, bu modellerin düşük kontrasta sahip ortamlar için sınır duyarlılıklarının yetersiz kaldığını göstermektedir.

Çelik-kiremit çatılarda, yüksek yansıtıcı yüzeyler ve kontrast değişimleri modeller için en zorlu koşulu oluşturmalarına rağmen, özellikle DeepLabV3+ ResNet50 mimarisinin panel alanlarını büyük oranda doğru şekilde ayırdığı gözlemlenmiştir. Ancak, MobileNetV2 mimarisi tarafından parlama bölgelerinde yanlış pozitif olarak tahmin edilen alanların arttığı tespit edilmiştir. Özellikle, U-Net modeli tarafından panel bütünlüğün sağlanamadığı, düşük kontrastlı panel alanları için yanlış negatif kararlar verdiği görsel bulgulardan rapor edilmiştir.

Genel olarak, DeepLabV3+ ResNet50 modeli tüm çatı tiplerinde sınır doğruluğu, gölgeleme ve parlama karşısında dayanıklılık ve arka plan ayrımı açısından en istikrarlı sonuçları üretmiştir. SegNet ve U-Net modelleri ise özellikle dokusal varyasyonun yüksek olduğu alanlarda sınıf karışımı ve bölünmüş segmentasyon eğilimi göstermiştir.

4. TARTIŞMA

Bu çalışmada, farklı çatı tipleri üzerine kurulan PV panel kurulumlarının uzaktan algılama görüntülerinden tespitinde derin öğrenme tabanlı semantik segmentasyon mimarilerinin karşılaştırmalı analizine odaklanılmıştır. Önerilen modellerin, çatı tiplerine göre değişen doku, gölgeleme ve yansıma gibi heterojen arka plan karakteristikleri karşısındaki sağlamlık ve genelleyici düzeyleri, nicel ve nitel bulgular ışığında kapsamlı biçimde değerlendirilmiştir. Ayrıca, eğitim sürecinde örnekleme sayılarının ve sınıflar arası dengesizliğin model performansları üzerindeki etkileri araştırılmıştır.

Nicel ve nitel analizlerin bütüncül değerlendirmesi sonucunda, tüm çatı tipleri için DeepLabV3+ tabanlı segmentasyon çerçevelerinin genel olarak en yüksek performansını sergilediği belirlenmiştir. DeepLabV3+ tarafından düz beton, tuğla ve çelik-kiremit tipi çatı üstü PV panel segmentasyonu sırasıyla 0.921, 0.897 ve 0.972 DSC değerleriyle başarıyla gerçekleştirilmiştir. Bu oranlar, kodlayıcı-kod çözücü blok yapısına sahip diğer segmentasyon mimarilerinden olan U-Net ve SegNet'in önemli ölçüde üzerinde bulunmuştur. DeepLabV3+ mimarisinin daha üstün performans göstermesi, modelin kodlayıcı blokta üretilen sığ (shallow)

özellikleri segmentasyon sürecine entegre edebilmesi ile ilişkilendirilebilir. Ayrıca, farklı genişletme oranlarına sahip evrişim filtrelerinden oluşan ASPP modülünün, çok ölçekli özellik haritalarını etkin biçimde işlemesi sayesinde, panel segmentasyonunu destekleyen bağlamsal bilgilerin sağlam bir biçimde yakalanabilmesine olanak tanıdığı düşünülmektedir (Yan, Wang, Xu, Sun ve Diao, 2023).

Literatürde de uzaktan algılama görüntülerinden PV panel tespitinde DeepLabV3+ mimarisinin diğer derin segmentasyon ağlarına kıyasla üstün performans sergilediği çeşitli çalışmalar tarafından rapor edilmiştir (H. Jiang ve diğerleri, 2021; Li ve diğerleri, 2023; Yan ve diğerleri, 2023). Dolayısıyla, bu çalışmada elde edilen bulguların mevcut literatürü destekler nitelikte olduğu söylenebilir.

PV panellerinin uzaktan algılama görüntülerinde kapladığı alanın küçük olması, hedef bölge ile arka plan arasında piksel dağılımında dengesizliğe yol açmaktadır. Bu sınıflar arası dengesizlik, derin öğrenme modellerinin eğitim verimliliğini düşürerek, piksel seviyesinde yanlış tahmin riskini artırır (Pena Pereira, Rafiee ve Lhermitte, 2024). Bu çalışmada, sınıf dengesizliğinin en yüksek olduğu tuğla çatı tipindeki görüntülerden PV panelleri, $DSC=0.897$ değeri ile en düşük doğrulukla tespit edilmiştir. Buna karşılık, çelik-kiremit çatıların yüksek yansıtıcı yüzeyleri ve kontrast değişimleri gibi daha zorlu koşullarına rağmen, sınıflar arası piksel dağılımlarının daha dengeli olması panel tespitinde $DSC=0.972$ ile en yüksek performansı sağlamıştır. Modeller tarafından elde edilen sınıflara özgü segmentasyon performansı farklılıklarının, sınıflar arası dengesizlikle doğru orantılı olarak arttığı gözlemlenmiştir.

Semantik segmentasyon piksel düzeyinde sınıflandırma işlemi olup, her bir sınıfı temsil eden piksel sayısı eğitim sırasında eğitim verimliliğini doğrudan etkiler. Önerilen derin öğrenme tabanlı modellerin daha az sayıda örnekle temsil edilen sınıflar için üstün sağlaması veri artırım teknikleri kullanılarak sentetik yeni görüntüleri sürece dahil edilmesi ile mümkün olabilir. Azınlıklık sınıflar için tespit doğruluğu böylelikle artabilir (Awedat ve diğerleri, 2025; Lekavičius ve Gružauskas, 2024; Rudro ve diğerleri, 2024). Bu karşın, bu çalışmada öncelikle önerilen segmentasyon mimarilerin farklı tipoloji, veri dağılım dengesizli ve örnekleme sayısına görevlerdeki etkinlikleri karşılaştırılmıştır. Dolayısıyla, veri artırım tekniklerine başvurulmamış, gerçek dünya problemleri senaryoları karşı model kabiliyetleri ortaya konmuştur.

5. SONUÇ

Bu çalışmada, yüksek çözünürlüklü uzaktan algılama görüntülerinden farklı çatı tipolojilerinde yer alan PV panellerin piksel düzeyinde tespitinde, popüler derin segmentasyon mimarilerden olan DeepLabV3+, SegNet ve U-Net

modellerinin performansları karşılaştırmalı incelenmiştir. Deneysel bulgular, tüm çatı tipleri genelinde DeepLabV3+ mimarisinin diğer modellere kıyasla tutarlı biçimde daha yüksek segmentasyon doğruluğu ve genelleme kabiliyeti sergilediğini ortaya koymuştur. Ayrıca, farklı veri dağılımı ve örnekleme yoğunluğuna sahip alt veri kümeleri üzerinde yapılan karşılaştırmalı analizler, sınıf dengesizliği ve piksel temsil azlığının model başarımını anlamlı düzeyde etkilediğini göstermiştir. Özellikle, PV panellerin az sayıda piksel ile temsil edildiği durumlarda model doğruluğu belirgin biçimde düşerken, dengeli dağılıma sahip veri gruplarında yüksek yansıma ve düşük kontrast gibi zorluklara rağmen daha kararlı sonuçlar elde edilmiştir. Kodlayıcı bloğunda omurga yapı (backbone) olarak gelişmiş ESA tabanlı özellik çıkarıcıların kullanılabilmesi, ASPP yapısı ile çok ölçekli bağlamsal bilgilerin yakalanması ve düşük–yüksek seviye özelliklerin etkin biçimde birleştirilebilmesinin DeepLabV3+ modelinin avantajları yönü olarak vurgulanmıştır.

İleriye dönük olarak, segmentasyon başarımını geliştirmek amacıyla ağ mimarilerinin modern modül ve katman eklentileriyle güçlendirilmesi ve sentetik veri üretimini mümkün kılan esnek veri artırma yöntemlerinin etkinliğinin değerlendirilmesi planlanmaktadır. Bu yaklaşımların, azınlık sınıfların daha iyi temsil edilmesini sağlayarak modelin farklı çatı tiplerinde daha tutarlı sonuçlar üretmesine katkı sağlayacağı düşünülmektedir.

KAYNAKÇA

- Awedat, K., Comert, G., Ayad, M. ve Mrebit, A. (2025). Advanced fault detection in photovoltaic panels using enhanced U-Net architectures. *Machine Learning with Applications*, 20(February), 100636. doi:10.1016/j.mlwa.2025.100636
- Badrinarayanan, V., Kendall, A. ve Cipolla, R. (2017). SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12), 2481–2495. doi:10.1109/TPAMI.2016.2644615
- Chen, L. C., Zhu, Y., Papandreou, G., Schroff, F. ve Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11211 LNCS, 833–851. doi:10.1007/978-3-030-01234-2_49
- Chen, Z., Kang, Y., Sun, Z., Wu, F. ve Zhang, Q. (2022). Extraction of Photovoltaic Plants Using Machine Learning Methods: A Case Study of the Pilot Energy City of Golmud, China. *Remote Sensing*, 14(11). doi:10.3390/rs14112697
- García, G., Aparcedo, A., Nayak, G. K., Ahmed, T., Shah, M. ve Li, M. (2024). Generalized deep learning model for photovoltaic module segmentation from satellite and aerial imagery. *Solar Energy*, 274(April), 112539. doi:10.1016/j.solener.2024.112539
- Gevaert, C. M. ve Belgiu, M. (2022). Assessing the generalization capability of deep learning networks for aerial image classification using landscape metrics. *International Journal of Applied Earth Observation and Geoinformation*, 114(June), 103054. doi:10.1016/j.jag.2022.103054
- He, K., Zhang, X., Ren, S. ve Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2016-Decem, 770–778. doi:10.1109/CVPR.2016.90
- Jalal, M., Khalil, I. U. ve Haq, A. ul. (2024). Deep learning approaches for visual faults diagnosis of photovoltaic systems: State-of-the-Art review. *Results in Engineering*, 23(May), 102622. doi:10.1016/j.rineng.2024.102622
- Jiang, H., Yao, L., Lu, N., Qin, J., Liu, T., Liu, Y. ve Zhou, C. (2021). Multi-resolution dataset for photovoltaic panel segmentation from satellite and aerial imagery. *Earth System Science Data*, 13(11), 5389–5401. doi:10.5194/essd-13-5389-2021
- Jiang, W., Tian, B., Duan, Y., Chen, C. ve Hu, Y. (2023). Rapid mapping and spatial analysis on the distribution of photovoltaic power stations with Sentinel-1&2 images in Chinese coastal provinces. *International Journal of Applied Earth*

Observation and Geoinformation, 118(January), 103280.
doi:10.1016/j.jag.2023.103280

- Kingma, D. P. ve Ba, J. L. (2015). Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–15.
- Kleebauer, M., Marz, C., Reudenbach, C. ve Braun, M. (2023). Multi-Resolution Segmentation of Solar Photovoltaic Systems Using Deep Learning. *Remote Sensing*, 15(24), 1–21. doi:10.3390/rs15245687
- Lekavičius, J. ve Gružas, V. (2024). Data Augmentation with Generative Adversarial Network for Solar Panel Segmentation from Remote Sensing Images. *Energies*, 17(13). doi:10.3390/en17133204
- Li, L., Lu, N., Jiang, H. ve Qin, J. (2023). Impact of Deep Convolutional Neural Network Structure on Photovoltaic Array Extraction from High Spatial Resolution Remote Sensing Images. *Remote Sensing*, 15(18). doi:10.3390/rs15184554
- Li, L., Lu, N. ve Qin, J. (2025). Joint-task learning framework with scale adaptive and position guidance modules for improved household rooftop photovoltaic segmentation in remote sensing image. *Applied Energy*, 377(June 2024). doi:10.1016/j.apenergy.2024.124521
- Liu, W., Huo, H., Ji, L., Zhao, Y., Liu, X. ve Li, J. (2024). A Method for Extracting Photovoltaic Panels from High-Resolution Optical Remote Sensing Images Guided by Prior Knowledge. *Remote Sensing*, 16(1). doi:10.3390/rs16010009
- Liu, Y. ve Wu, Y. (2025). Fault diagnosis of photovoltaic modules: A review. *Solar Energy*, 293(March), 113489. doi:10.1016/j.solener.2025.113489
- Müller, D., Soto-Rey, I. ve Kramer, F. (2021). Robust chest CT image segmentation of COVID-19 lung infection based on limited data. *Informatics in Medicine Unlocked*, 25(July). doi:10.1016/j.imu.2021.100681
- Pena Pereira, S., Rafiee, A. ve Lhermitte, S. (2024). Automated Rooftop Solar Panel Detection Through Convolutional Neural Networks. *Canadian Journal of Remote Sensing*, 50(1). doi:10.1080/07038992.2024.2363236
- Polat, H. (2025). DAMMD-Net: A lightweight and enhanced deep segmentation network for skin lesion detection. *Digital Signal Processing: A Review Journal*, 167(1), 105477. doi:10.1016/j.dsp.2025.105477
- Ronneberger, O., Fischer, P. ve Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture*

Notes in Bioinformatics), 9351, 234–241. doi:10.1007/978-3-319-24574-4_28

- Rudro, R. A. M., Nur, K., Sohan, M. F. A. Al, Mridha, M. F., Alfarhood, S., Safran, M. ve Kanagarathinam, K. (2024). SPF-Net: Solar panel fault detection using U-Net based deep learning image classification. *Energy Reports*, 12(June), 1580–1594. doi:10.1016/j.egy.2024.07.044
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. ve Chen, L. C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 4510–4520. doi:10.1109/CVPR.2018.00474
- Saood, A. ve Hatem, I. (2021). COVID-19 lung CT image segmentation using deep learning methods: U-Net versus SegNet. *BMC Medical Imaging*, 21(1), 1–11. doi:10.1186/s12880-020-00529-5
- Simonyan, K. ve Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*, 1–14.
- Wang, Y., Cai, D., Chen, L., Yang, L., Ge, X. ve Peng, L. (2023). A Downscaling Methodology for Extracting Photovoltaic Plants with Remote Sensing Data: From Feature Optimized Random Forest to Improved HRNet. *Remote Sensing*, 15(20). doi:10.3390/rs15204931
- Yan, Z., Wang, P., Xu, F., Sun, X. ve Diao, W. (2023). AIR-PV: a benchmark dataset for photovoltaic panel extraction in optical remote sensing imagery. *Science China Information Sciences*, 66(4), 7–8. doi:10.1007/s11432-022-3663-1
- Zhang, H., Tian, P., Zhong, J., Liu, Y. ve Li, J. (2023). Mapping Photovoltaic Panels in Coastal China Using Sentinel-1 and Sentinel-2 Images and Google Earth Engine. *Remote Sensing*, 15(15). doi:10.3390/rs15153712



BÖLÜM 2

İleti Dizi Anten Tasarımlarında Makine Öğrenmesi Kullanımı

Muhammed Malkoç¹ & Ümit Çiğdem Turhal²


Giriş

Yüksek kazanç ve dar huzme gerektiren uydu, nokta-nokta ve radar uygulamalarında iki ana yaklaşım kullanılır: (i) büyük açıklık antenleri (horn/parabolik), (ii) faz dizileri (elektronik tarama). Parabolikler yüksek frekanslarda hacim ve imalat hassasiyeti nedeniyle zorlayıcıdır; faz dizileri ise besleme ağı kayıpları, karmaşıklık ve ölçeklenebilirlik/tarama sınırları taşır. Bu tablo karşısında düzlemsel mimarili yansıtıcı dizi antenler (YDA; reflectarray) ve ileti dizi antenler (İDA; transmitarray), antenler, geniş açıklık etkisini daha düşük profil ve görece düşük maliyetle sunan çekici bir alternatif olarak öne çıkmıştır

İDA mikroşerit dizi ve mercek antenlerin avantajlarını (yüksek kazanç, düzlemsel ve hafif yapı) YDA'ya kıyasla besleme gölgelemesi olmaksızın bir araya getiren yüksek kazançlı bir açıklık anteni sınıfıdır (Abdelrahman, Yang, Elsherbeni, & Nayeri, 2017). Geleneksel parabolik antenlerle karşılaştırıldığında, YDA ve İDA, hacimli paraboloidi düzlemsel bir diziyle değiştirir. Bu yöntem, tasarım ve entegrasyon zorluğu ile imalat maliyetini büyük ölçüde azaltır ve sistemi havacılık-uzay mikrodalga uzaktan algılama uygulamaları için uygun hâle getirir (T.-J. Li, Wang, Li, & Hou, 2022).

¹ Arş. Gör.; Bilecik Şeyh Edebali Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Bölümü. ORCID No: 0000-0002-8346-2475

² Doç. Dr.; Bilecik Şeyh Edebali Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Bölümü ORCID No: 0000-0003-2387-1637



Şekil 1. (a) Yansıtıcı Dizi Anten (b) İletici Dizi Anten

İDA tasarımında iki temel performans ölçütü öne çıkar: iletim genliği ve iletim fazı. Birim hücrenin, yüksek iletim genliğini korurken en az 360° (2π) faz ayarlama aralığı sağlaması beklenir. Hedeflenen faz tepkisini elde etmek için başlıca teknikler şunlardır: çok katmanlı Frekans Seçici Yüzey (FSY) temelli birim hücrelerin geometrisinin ayarlanması yansıtıcı yamaların döndürülmesi, her hücredeki faz ofsetinin elektronik olarak denetlenmesi ve ayarlanabilir analog elemanların (ör. varaktörler) yanı sıra PIN diyotlar ile RF-MEMS çözümlerinin kullanılması.

Bununla birlikte klasik tasarım akışı—birim hücre taramasıyla iletim fazı/genlik tablolarının çıkarılması, hedef faz dağılımına göre bit-kuantize yerleşim ve tam-dalgaya doğrulama/ince ayar—yüksek boyutlu tasarım uzaylarında hem zaman hem de hesaplama maliyeti açısından zorlayıcıdır.

Faz-genlik eşbağımlılığı, eğik gelişte yanıt değişimi ve hücreler arası bağlaşım gibi fiziksel etkiler, “yerel periyodik” varsayımın ötesinde ek yinelemeler gerektirir (Nematollahi, Laurin, Page, & Encinar, 2015). Ayrıca faz kuantizasyonu ve sınırlı faz aralığı, ana lob kazancı ve yan lob seviyelerinde performans kaybına yol açabileceğinden sistem düzeyi dengelemeler ister (Hum & Perruisseau-Carrier, 2014; Balanis, 2016).

Tam da bu noktada makine öğrenmesi (MÖ), iki tamamlayıcı rol üzerinden motivasyon kazanır: (i) ileri (surrogate) modelleme ile “geometriden (faz, genlik)” eşlemesini çok daha hızlı yaklaştırmak ve pahalı tam-dalgaya taramaların yerini kısmen almak; (ii) ters tasarım ile “hedef yanıtın geometri/topoloji” eşlemesini doğrudan öğrenerek arama-optimizasyon döngülerini kısaltmak (Ma, Liu, Kudyshev, Boltasseva, Cai, & Liu, 2021; Molesky, Lin, Piggott, Jin, Vučković, & Rodriguez, 2018). Surrogate modeller, büyük açıklıklar için hücre düzeyi yanıtları milisaniyeler mertebesinde öngörebildiğinde, dizi sentezi ve çoklu senaryo taramaları pratik hâle gelir (Ma et al., 2021).

Ters tasarım yaklaşımları ise bir-çoğa (one-to-many) doğaya sahip faz/iletim hedeflerinde aday geometrileri doğrudan önerebildiği için evrimsel/deneysel aramaların deneme-yanılma maliyetini azaltır (Molesky et al., 2018).

Bu iki çizgi, geniş bant/çok kutuplaşma/çok band gibi zorlu hedefler için “fizik-bilinçli” (physics-aware) ya da “çok sadakatli” (multi-fidelity) veri stratejileriyle birleştirildiğinde daha az simülasyonla daha geniş tasarım uzayının keşfine imkân tanır (Pestourie, Pérez-Arancibia, Lin, Shin, Capasso, & Johnson, 2018; Ma et al., 2021).

Elbette MÖ yaklaşımlarının sınırları da vardır: eğitim verisinin kapsayıcılığı ve gürültüsü genelleme performansını doğrudan etkiler; üretim toleransları ve malzeme kayıpları gibi “laboratuvar-gerçeği” kısıtlarının modele dâhil edilmesi gereklidir; ayrıca metriklerin (ör. faz MAE, 1/3 dB kazanç bant genişliği, SLL, açıklık verimi) standardize raporlanması yeniden üretilebilirlik için kritiktir (Ma et al., 2021; Abdelrahman et al., 2017). Bu nedenle İDA bağlamında MÖ kullanımı, klasik akışın yerine geçen “sihirli değnek” değil; tasarım hızlandırıcısı ve akıllı arama/iyileştirme bileşeni olarak konumlandığında en fazla değeri üretir (Abdelrahman et al., 2017; Molesky et al., 2018).

1. Klasik Tasarım Akışı

Klasik akış, (i) birim-hücre (unit cell) için tam dalga analizlerle geometriden iletim genliği/ $\angle$ faz veri tabanı oluşturma, (ii) hedef faz dağılımının açıklıkta sentezi ve uygun hücre parametrelerine ters eşleme, (iii) dizi düzeyinde tam dalga doğrulama ve ölçümle sonuçların teyidi adımlarından oluşur (Belen, Caliskan, Koziel, Pietrenko-Dabrowska, & Mahouti, 2023; Gosal, Almajali, McNamara, & Yagoub, 2016).

Birim-hücre veri tabanı tipik olarak sonsuz periyodik koşullarda elde edilir ve her bir parametre kombinasyonu için $|S_{21}|$ ve $\angle S_{21}$ çıkarılır; bu veri, açıklık sentezinde hücre parametrelerinin seçilmesi için temel çalışır (Gosal et al., 2016).

Bu aşamada amaç, hedef fazı sağlarken iletim kaybını düşük tutmaktır; örneğin Ku-bant bir tasarımda birim-hücre ekleme kaybının 0.5 dB’den küçük olması ve 360° faz kapsamasının sağlanması dizi performansını belirgin şekilde iyileştirir (M.-Y. Li, Ban, & Yan, 2021). Geniş bant ve/veya yüksek verimli tasarımlarda toplam faz gereksinimini azaltan semiplanar/dereceli kalınlık gibi yapısal stratejiler, 360° yerine ~50° civarında efektif faz aralığıyla 1 dB kazanç bant genişliği ve açıklık verimi artışı sağlayabilmektedir (Ramazannia Tuloti, Rezaei, & Tavakkol Hamedani, 2018).

Açıklık faz haritası, odak/ışın yönüne göre yol farkını telafi edecek şekilde belirlenir ve hücre kütüphanesinden hedef $\angle$ faz ve $|S_{21}|$ ’e en yakın parametre kombinasyonları seçilerek dizi yerleşimi oluşturulur (Belen et al., 2023).

Besleyici geometrisi nedeniyle pek çok hücre eğik geliş altında çalıştığından, birim-hücre yanıtının açıya duyarlılığı (örn. 20–30° gelişte faz/|S21| değişimleri) mutlaka değerlendirilir ve gerekli ise yerel ince ayar yapılır (M.-Y. Li et al., 2021). Dizi düzeyi doğrulamada tepe kazanç, SLL, HPBW, 1/3 dB kazanç bant genişliği ve kutuplaşma metrikleri sayısal ve deneysel olarak raporlanır; çoklu-kutuplaşma ve mod çeşitliliği gibi özellikler uygulamaya göre ayrıca gösterilir (Zhong, Chen, Shi, & Shi, 2016). Yüksek frekansta/ince özellikli yapılarda üretim toleransları ve malzeme kayıpları sonuçları etkilediği için prototip doğrulaması kritik önemdedir; örneğin mm-dalga bandında %60+ açıklık verimi sınıfı sonuçlar yakalanabilmekte ve bu veriler ölçümlerle desteklenmektedir (Deng, Xu, Xu, & Zhu, 2024).

Makine öğrenmesi (MÖ) bu akışı hızlandırıcı olarak iki temel biçimde besler: ileri (surrogate) modelleme ve ters (inverse) tasarım (Belen et al., 2023). İleri modellemede amaç, “geometriden (|S21|, $\angle$ S21)” eşlemesini düşük maliyetle yaklaştırarak pahalı birim-hücre taramalarını ve dizi sentezinde hızlı seçim adımını hızlandırmaktır; yakın dönemde düşük örnek sayılarıyla güvenilir vekil modeller ve uyarlanabilir mimariler gösterilmiştir (Belen et al., 2023; Peng & Chen, 2024). Ters tasarımda amaç, “hedef (|S21|, $\angle$ S21, frekans/açı) değerlerinden geometri” haritalamasını doğrudan öğrenerek çok parametrelili hücrelerde veritabanı inversiyonunu otomatikleştirmektir; İDA bağlamında inverse neural network yaklaşımı bu ihtiyaca doğrudan yanıt verir (Gosal et al., 2016). Literatürde MÖ, sadece İDA’ya değil akraba platformlara (RA/anten dizileri) da uygulanmış; surrogate-destekli optimizasyon, konsensus/kompozit DNN ve özinyeli mimariler ile tasarım-doğrulama döngüsünün toplam süresi kayda değer biçimde düşürülmüştür (Freni, Mussetta, & Pirinoli, 2012; Mahouti, Belen, Çalık, & Koziel, 2022; Stanković, Olćan, Donćov, & Kolundžija, 2022). Raporlama tarafında, (i) 1 dB kazanç bant genişliği (%): tepe kazançtan –1 dB aralık, (ii) açıklık verimi (%): tepe kazançtan çıkarımla, (iii) $\angle$ faz kapsamı (°) ve |S21|: merkez ve bant uçlarında, (iv) açı toleransı: eğik gelişte ek kayıp/faz kayması, (v) faz hatası: hedef–gerçek farkın ortalama/ σ , (vi) MÖ metrikleri: faz/genlik MAE ve eğitim örneği sayıları gibi göstergeler standart biçimde verilmelidir (Belen et al., 2023; M.-Y. Li et al., 2021; Ramazannia Tuloti et al., 2018; Zhong et al., 2016).

2. Makine Öğrenmesi ile Tasarım

İleti dizi antenlerde (İDA) birim-hücrelerin çok boyutlu geometrik uzayı ile hedeflenen iletim fazı/genliği arasında güvenilir ve hızlı bir eşleme kurmak tasarım döngüsünün kritik darboğazıdır; son çalışmalar, veri güdümlü vekil (surrogate) modellerin bu darboğazı yüzler mertebesinde örnekle kurulup geniş bant ve çoklu bant tasarımlarda yeniden kullanılabilirdiğini deneysel doğrulamalarla göstermektedir (Belen et al., 2023). İDA özelinde ileri (forward)

ve ters (inverse) sinir ağıları fikri, hücre veritabanının oluşturulması ve çok-değerli ters ilişkinin çözümlenmesi için erken dönemde önerilmiş ve INN (inverse neural network) ile veritabanı inversiyonu gösterilmiştir (Gosal et al., 2016).

2.1. İleri (Surrogate) Modelleme

Klasik akışta, sonsuz periyodik sınırlarla elde edilen birim-hücre veritabanı $|S21|$ ve $\angle S21$ haritalarını sağlar; MÖ ile bu haritaları öğrenen vekiller, dizi sentezi sırasında hücre seçimini ve çok senaryolu taramayı ciddi biçimde hızlandırır (Belen et al., 2023; Gosal et al., 2016).

Örneğin (Belen et al., 2023) çalışması, 8–14/22–28/28–36 GHz bantlarında üç farklı İDA için yüzlerle ifade edilen örneklerle eğitilen vekillerin $|S21|$ MAE $\approx$ 0.014–0.021, $\angle S21$ MAE $\approx$ 4.8–5.6° seviyesinde doğruluk verdiğini ve tasarımın deneyle teyit edildiğini bildirir

Aynı çalışma, Latin Hypercube örnekleme, küçük eğitim setleri (ör. 270 eğitim / 100 hold-out) ve çok katmanlı birim-hücreler için de güvenilir vekil kurulabildiğini açıkça raporlar; bu, “ilk veri maliyeti” sorununa pratik bir yanıt sunar (Belen et al., 2023).

Daha geniş bağlamda, aktif öğrenme ve çok-sadakatli (coarse+fine) stratejilerin simülasyon sayısını bir mertebeden fazla azaltabildiği ve vekil değerlendirmesinin tam çözüme göre iki mertebe hızlı olabildiği gösterilmiştir (Pestourie, Mroueh, Nguyen, Das, & Johnson, 2020).

2.2. Ters Tasarım

İDA’da hedeflenen iletim fazı/genlikten doğrudan geometriye geçiş, çok parametrelili hücrelerde çoklu çözüm (one-to-many) doğası nedeniyle zorlayıcıdır; INN ve tandem/bidirectional ağlar bu çoklu çözümü olasılıksal biçimde yakalayarak ileri+ters süreci tek çatı altında kurar (Gosal et al., 2016; Wang et al., 2023).

Generative yaklaşımlar (ör. GAN) ve normalizing flow/INN temelli çerçeveler, istenen optik/EM yanıt için çeşitli ve geçerli tasarımlar üretme kapasitesine sahiptir; bu, ters haritanın çok-değerli yapısını yönetmek açısından kritiktir (Z. Liu, Zhu, Rodrigues, Lee, & Cai, 2018). Özellikle 2021 yılındaki Li Jiang et al. ve 2023 yılındaki Wang et al çalışmaları; faz manipülasyonu için NN tabanlı ters tasarımın ve INN ile uçtan uca ileri-ters ortak öğrenmenin pratik uygulanışını ayrıntılı gösterir (Jiang, Li, Wu, Wang, & Gao, 2021a, 2021b; Wang et al., 2023).

2.3. Hibrit Akışlar: MÖ + Optimizasyon/Fizik

İleri/ters modeller, Bayes optimizasyonu, çok amaçlı evrimsel arayıcılar veya adjoint/topoloji optimizasyonu ile birleştirildiğinde, açıklık düzeyinde faz hatası, |S21| kaybı, verim, kalınlık/üretilebilirlik gibi çoklu hedefler tek maliyet fonksiyonunda dengelenebilir (Z. Li, Pestourie, Lin, Johnson, & Capasso, 2022; Tian et al., 2024).

Aktif öğrenme + Bayes yaklaşımları, yeni örneklemeyi model belirsizliğine göre seçerek veri verimliliğini artırır; yakın dönem çalışmalar EM tasarımda tasarım süresini anlamlı biçimde kısaltmıştır (J. Liu et al., 2025; Pestourie et al., 2020).

2.4. Fizik-Bilinçli (Physics-Aware) Modeller Ve Bağlaşım Etkileri

Birim-hücreler arası bağlaşım ve eğik geliş etkileri, LPA varsayımını zorlar; bu durumda küreselden düzleme yaklaşım hataları ve aç-bağımlı hedefler MÖ eğitimine dâhil edilmelidir (Belen et al., 2023).

Metayüzeylerde yerel-olmayan (non-local) etkileşimler görüldüğünde, küresel (global) optimizasyon veya ters-öğrenme zorunlu hâle gelir; doğrudan deneysel doğrulamalı örnekler mevcuttur (Cai et al., 2020).

2.5. İDA Özeline Uygulama Haritası

(i) Hedef faz dağılımı ψ_i yol farkına göre belirlenir; broadside'de $\vec{r}_i \cdot \hat{r}_0 = 0$ koşulu geçerlidir.

(ii) Birim-hücre veritabanı periyodik sınırlarla oluşturulur; çok katmanlı yapılarda faz aralığı/bant genişliği/kayıp dengesi veriye yansıtılır.

(iii) İleri vekil ($MAE_{|S21|}$, $MAE_{\angle}$) eğitilir ve dizi sentezinde hızlı seçimde kullanılır; küçük veriyle güvenilir vekiller raporlanmıştır.

(iv) Ters ağ/INN ile hedef ($|S21|$, $\angle$) değerlerinden geometri eşlemesi yapılır; çok-değerli harita yönetilir ve veritabanı inversiyonu otomatikleşir (Gosal et al., 2016; Wang et al., 2023).

(v) Hibrit optimizasyon (Bayes/evrimsel/adjoint) ile açıklık hedefleri (faz, |S21|, SLL, η_{ap} , kalınlık) birlikte minimize edilir; aktif öğrenme veri maliyetini düşürür (Pestourie et al., 2020; Tian et al., 2024).

2.6. Raporlama ve Yeniden Üretilebilirlik

- **Vekil doğruluğu:** $MAE_{\angle}$ [°], $MAE_{|S21|}$ [dB]; eğitim/doğrulama/test ayrımı ve örnek sayıları, örnekleme şeması (örn. LHS) (Belen et al., 2023).

- **Dizi metrikleri:** Tepe kazancı, 1 dB/3 dB kazanç bant genişliği, SLL, X-pol/XPD; mümkünse ölçüm ile teyit.
- **Genelleme testleri:** eğitim dışı frekans/açı ve geometri; aktif öğrenme/çok-sadakat stratejilerinin etkisi (Pestourie et al., 2020).
- **Üretim bilinci:** tolerans yayılımı ve DFM (Design-for-Manufacturing) vurgusu; büyük alanlı meta-optiklerde endüstri-ölçekli yaklaşımlar artık sistematik olarak raporlanıyor (Ueno, Hu, & An, 2024).

3. Sonuç

Bu çalışmada, ileti dizi anten (İDA) tasarımında klasik akış ile makine öğrenmesi (MÖ) yaklaşımlarını tek bir çatı altında özetledik. Klasik yöntemin başlıca darboğazları (faz–genlik eşbağımlılığı, eğik geliş açısı ve hücreler arası bağlaşım etkileri, faz kuantizasyonu) netleştirildi; MÖ’nün ise bir “ikame” değil, ileri (surrogate) ve ters tasarım ile yineleme maliyetini azaltan bir hızlandırıcı olduğu vurgulandı. Uygulayıcılar için, raporlama standardı ($MAE \angle |S_{21}|$, tepe kazanç, 1/3–1 dB kazanç bant genişliği, SLL, açıklık verimi) ve kısa bir kontrol listesi önerildi. Sonuç olarak, önerilen yol haritası tasarım döngülerini kısaltırken sonuçların karşılaştırılabilirliğini ve üretilebilirliğini artırır; ileri çalışmalarda açı–frekans genellemesi, bağlaşımın yerel-periyodik ötesi modellenmesi ve kuantizasyon–DFM dengesi önceliklidir.

Kaynakça

- Abdelrahman, A. H., Yang, F., Elsherbeni, A. Z., & Nayeri, P. (2017). Analysis and design of transmitarray antennas. Morgan & Claypool.
- Balanis, C. A. (2016). Antenna theory: Analysis and design (4th ed.). Wiley.
- Belen, M. A., Caliskan, A., Koziel, S., Pietrenko-Dabrowska, A., & Mahouti, P. (2023). Optimal design of transmitarray antennas via low-cost surrogate modelling. *Scientific Reports*, 13(1), 15044. <https://doi.org/10.1038/s41598-023-42134-w>
- Cai, H., Srinivasan, S., Czaplewski, D. A., Martinson, A. B. F., Gosztola, D. J., Stan, L., ... López, D. (2020). Inverse design of metasurfaces with non-local interactions. *Npj Computational Materials*, 6(1), 116. <https://doi.org/10.1038/s41524-020-00369-5>
- Deng, W.-Q., Xu, S., Xu, Z., & Zhu, S.-Y. (2024). Automated Design of Millimeter-wave Dielectric Transmitarray Antenna Using Tandem Network. *IEEE Antennas and Wireless Propagation Letters*, 1–5. <https://doi.org/10.1109/LAWP.2024.3378281>
- Freni, A., Mussetta, M., & Pirinoli, P. (2012). Neural Network Characterization of Reflectarray Antennas. *International Journal of Antennas and Propagation*, 2012(1), 541354. <https://doi.org/10.1155/2012/541354>
- Gosal, G., Almajali, E., McNamara, D., & Yagoub, M. (2016). Transmitarray Antenna Design Using Forward and Inverse Neural Network Modeling. *IEEE Antennas and Wireless Propagation Letters*, 15, 1483–1486. <https://doi.org/10.1109/LAWP.2015.2514065>
- Hum, S. V., & Perruisseau-Carrier, J. (2014). Reconfigurable reflectarrays and array lenses for dynamic antenna beam control: A review. *IEEE Transactions on Antennas and Propagation*, 62(1), 183–198. <https://doi.org/10.1109/TAP.2013.2287296>
- Jiang, L., Li, X., Wu, Q., Wang, L., & Gao, L. (2021a). Neural network enabled metasurface design for phase manipulation. *Optics Express*, 29(2), 2521–2528. <https://doi.org/10.1364/OE.413079>
- Jiang, L., Li, X., Wu, Q., Wang, L., & Gao, L. (2021b). Neural network enabled metasurface design for phase manipulation. *Optics Express*, 29(2), 2521–2528. <https://doi.org/10.1364/OE.413079>
- Li, M.-Y., Ban, Y.-L., & Yan, F.-Q. (2021). Wideband Low-Profile Ku-Band Transmitarray Antenna. *IEEE Access*, 9, 6683–6688. <https://doi.org/10.1109/ACCESS.2020.3048346>

- Li, T.-J., Wang, G., Li, H., & Hou, B. (2022). A review of reflectarray and transmitarray antennas for microwave remote sensing. *IEEE Access*, 10, 117870–117889.
- Li, T.-J., Wang, G.-M., Li, H.-P., & Hou, H.-S. (2022). Circularly Polarized Double-Folded Transmitarray Antenna Based on Receiver-Transmitter Metasurface. *IEEE Transactions on Antennas and Propagation*, 70(11), 11161–11166. <https://doi.org/10.1109/TAP.2022.3188532>
- Li, Z., Pestourie, R., Lin, Z., Johnson, S. G., & Capasso, F. (2022). Empowering Metasurfaces with Inverse Design: Principles and Applications. *ACS Photonics*, 9(7), 2178–2192. <https://doi.org/10.1021/acsphotonics.1c01850>
- Liu, J., Lian, G., You, W., Zhang, R., Cheng, Y., Zhang, C., & Che, R. (2025). Bayesian Active Learning for Accelerated Design of Broadband Polarization-Insensitive Metasurfaces. *Intelligent Computing*, 4, 0135. <https://doi.org/10.34133/icomputing.0135>
- Liu, Z., Zhu, D., Rodrigues, S. P., Lee, K.-T., & Cai, W. (2018). Generative Model for the Inverse Design of Metasurfaces. *Nano Letters*, 18(10), 6570–6576. <https://doi.org/10.1021/acs.nanolett.8b03171>
- Mahouti, P., Belen, M. A., Çalik, N., & Koziel, S. (2022). Computationally Efficient Surrogate-Assisted Design of Pyramidal-Shaped 3-D Reflectarray Antennas. *IEEE Transactions on Antennas and Propagation*, 70(11), 10777–10786. <https://doi.org/10.1109/TAP.2022.3191131>
- Ma, W., Liu, Z., Kudyshev, Z. A., Boltasseva, A., Cai, W., & Liu, Y. (2021). Deep learning for the design of photonic structures. *Nature Photonics*, 15(2), 77–90.
- Molesky, S., Lin, Z., Piggott, A. Y., Jin, W., Vučković, J., & Rodriguez, A. W. (2018). Inverse design in nanophotonics. *Nature Photonics*, 12(11), 659–670. <https://doi.org/10.1038/s41566-018-0246-9>
- Nayeri, P., Yang, F., & Elsherbeni, A. Z. (2018). Reflectarray antennas: Theory, designs, and applications. Wiley.
- Nematollahi, H., Laurin, J.-J., Page, J. E., & Encinar, J. A. (2015). Design of broadband transmitarray unit cells with comparative study of different numbers of layers. *IEEE Transactions on Antennas and Propagation*, 63(4), 1473–1481. <https://doi.org/10.1109/TAP.2015.2402285>
- Peng, F., & Chen, X. (2024). A Low-Cost Optimization Method for 2-D Antennas Using a Disassemblable Convolutional Neural Network. *IEEE Transactions on Antennas and Propagation*, 72(9), 7057–7067. <https://doi.org/10.1109/TAP.2024.3437750>

- Pestourie, R., Mroueh, Y., Nguyen, T. V., Das, P., & Johnson, S. G. (2020). Active learning of deep surrogates for PDEs: Application to metasurface design. *Npj Computational Materials*, 6(1), 164. <https://doi.org/10.1038/s41524-020-00431-2>
- Pestourie, R., Pérez-Arancibia, C., Lin, Z., Shin, W., Capasso, F., & Johnson, S. G. (2018). Inverse design of large-area metasurfaces. *Optics Express*, 26(26), 33732–33747. <https://doi.org/10.1364/OE.26.033732>
- Ramazannia Tuloti, S. H., Rezaei, P., & Tavakkol Hamedani, F. (2018). High-Efficient Wideband Transmitarray Antenna. *IEEE Antennas and Wireless Propagation Letters*, 17(5), 817–820. <https://doi.org/10.1109/LAWP.2018.2817363>
- Reis, J. R., Vala, M., & Caldeirinha, R. F. S. (2019). Review Paper on Transmitarray Antennas. *IEEE Access*, 7, 94171–94188. <https://doi.org/10.1109/ACCESS.2019.2924293>
- Stanković, Z. Ž., Olčan, D. I., Dončov, N. S., & Kolundžija, B. M. (2022). Consensus Deep Neural Networks for Antenna Design and Optimization. *IEEE Transactions on Antennas and Propagation*, 70(7), 5015–5023. <https://doi.org/10.1109/TAP.2021.3138220>
- Tian, Z., Yang, Y., Zhou, S., Zhou, T., Deng, K., Ji, C., ... Liu, J. S. (2024). High-dimensional Bayesian optimization for metamaterial design. *Materials Genome Engineering Advances*, 2(4), e79. <https://doi.org/10.1002/mgea.79>
- Ueno, A., Hu, J., & An, S. (2024). AI for optical metasurface. *Npj Nanophotonics*, 1(1), 36. <https://doi.org/10.1038/s44310-024-00037-2>
- Wang, Y., Yang, Z., Hu, P., Hossain, S., Liu, Z., Ou, T.-H., ... Wu, W. (2023). End-to-End Diverse Metasurface Design and Evaluation Using an Invertible Neural Network. *Nanomaterials*, 13(18), 2561. <https://doi.org/10.3390/nano13182561>
- Zhong, X., Chen, L., Shi, Y., & Shi, X. (2016). Design of Multiple-Polarization Transmitarray Antenna Using Rectangle Ring Slot Elements. *IEEE Antennas and Wireless Propagation Letters*, 15, 1803–1806. <https://doi.org/10.1109/LAWP.2016.2537386>



BÖLÜM 3

Resonance in Electrical Circuits

Yunus Emre Ekici¹ & Arif Memmedov² & Teoman Karadağ³

Resonant circuits, in electrical engineering, are passive circuits comprising inductance (L) and capacitance (C) in which the phenomenon known as resonance takes place. Resonance occurs when the inductive reactance X_L and capacitive reactance X_C are equal in magnitude but opposite in phase, resulting in their cancellation (Boran & Karadağ, 2024). At that specific frequency—termed the resonant frequency—the total reactive impedance is neutralized, so the circuit behaves as though it is purely resistive (Liu, Zhu, Li, Teng, & Sun, 2024). In such a regime, the phase angle between applied voltage and resulting current is zero. Consequently, reactive power (which arises due to phase shifts between voltage and current) becomes zero, meaning that all the electrical energy being transferred is active power. This defines the working condition of passive LC (or RLC) resonant circuits in which energy storage in the magnetic field (inductor) and electric field (capacitor) balance out in steady-state AC operation (Ekici, Ka, Aydın, & Akdağ, 2024; Jiang, Chau, Liu, & Lee, 2017).

There are essentially two types of resonance in passive L-C-R networks:

1. Voltage (Series) Resonance: In a series resonant circuit, inductance and capacitance are connected in series. At the resonant frequency $f_0 = 1/(2\pi\sqrt{LC})$, the inductive and capacitive reactances are equal in magnitude, but opposite in sign, leading the reactive portion of the impedance to vanish. Thus the total impedance reduces to the resistive component, current is maximized, and voltage and current are in phase (Tiggelman, Reimann, Van Rijs, Schmitz, & Hueting, 2009).

2. Parallel (Current) Resonance: In a parallel resonant configuration, the inductor and capacitor connect in shunt (parallel). At resonance, branch currents through L and C cancel (because they are equal and opposite), so the net reactive current drawn from the source is zero (KARADAĞ, MAMMADOV, & DİKMEN, 2022). The input impedance is maximized, the supply current is

¹ Dr., Department of Electric Vehicle Technologies, OIZ Vocational College, Inonu University, 44900 Malatya, Türkiye, ORCID No: 0000-0001-7791-0473

² Prof. Dr.,

³ Assoc. Prof. Dr Department of Electric Electronic Engineering, Inonu University, Malatya, Türkiye

Department of Electric Electronic Engineering, İstinye University, 34460 İstanbul, Türkiye, ORCID No: 0000-0002-7682-7771

minimized, and voltage and current remain in phase across the source (Hu, Li, Zhao, & Li, 2021).

In real-world circuits, resistive losses, non-idealities in inductors and capacitors (parasitic resistances, leakage, etc.), and finite conductivity affect the sharpness and exact behavior of resonance (Bhavsingh, Suresh Babu, & Mangu, 2023). These factors determine the quality factor (Q), which quantifies how sharply the circuit responds around the resonant frequency and how narrow its bandwidth is. Higher loss (larger resistance) lowers Q ; conversely, higher L/C ratio or lower resistive losses increases Q (Seo, Ryu, Choi, & Jeong, 2007).

Mathematically, for a damped R-L-C circuit, the impedance in series form is expressed as (Karadağ, 2022):

$$Z = R + j(XL - XC)$$

where $j = \sqrt{-1}$. At resonance $XL = XC$, so $Z = R$, purely real, and the phase angle $\phi = \arctan((XL - XC)/R) = 0$, rendering the power factor unity (Kumar & Yi, 2023).

Similarly, for a parallel circuit, admittance (the reciprocal of impedance) has an imaginary part composed of inductive and capacitive contributions; at resonance, this imaginary part becomes zero, so the admittance is purely real $\rightarrow$ input impedance maximum, and as before, phase difference between voltage and current is zero (Bellido, Esteve, & Jordán, 2024).

In practical design and applications, resonant circuits are used in filters, oscillators, wireless power transfer, induction heating, tuned amplifiers, and impedance matching networks (Lara-Reyes et al., 2022). The designer selects L and C to set resonance at desired frequency, and manages R (or losses) to control the quality factor and bandwidth for achieving the necessary selectivity and stability (Li, Li, & Ruan, 2023).

1. Resonance Phenomena in Series R, L, and C Circuits

Figure 1 shows a series-connected r, l, c circuit. The complex impedance of this circuit is determined by Equation 1:




Figure 1. a series-connected r, l, c circuit

$$z = r + j \cdot w \cdot l + \frac{1}{jwc} = r + j \left(wl - \frac{1}{wc} \right) = r + jx = z \cdot e^{j\varphi} \quad (1)$$

Here;

$$x = w \cdot l - \frac{1}{wc}; z = \sqrt{r^2 + x^2}; \varphi = \arctan \frac{w \cdot l - \frac{1}{wc}}{r} \quad (2)$$

For resonance to occur in the circuit, φ must be 0. For Equation 2 to be obtained,

$$x = w \cdot l - \frac{1}{wc} = 0 \quad (3)$$

must hold. To obtain $x = 0$ in equation (3), one of the parameters w , l , or c must be changed. The resonance values of these parameters;

$$w_0 = \frac{1}{\sqrt{lc}}; L_0 = \frac{1}{w^2 c}; C_0 = \frac{1}{\omega^2 l} \quad (4)$$

As defined. If the voltage U at the ends of the circuit and the resistance r are constant, the current flowing through the circuit takes on a maximum value equal to u / r . Since the reactive component of the current will be zero, it will only have an active component. In Figure 2, in the resonance case, if $x_l = x_c$ and the reactive resistance r is greater than the active resistance, the voltages at the ends of l and c are greater than the source voltage.




Figure 2. if $x_L = x_C$ and the reactive re-resistance r is greater than the active resistance

Therefore, the resonance phenomenon occurring in the series r , l , and c circuit is called voltage resonance. The following equation is used to ensure that the voltage across l and c is greater than the source voltage:

$$r < \omega_0 \cdot l = \frac{1}{\omega_0 \cdot c} = \sqrt{\frac{l}{c}} = \rho \quad (5)$$

In the expression Equality 5, since the unit of the quantity $\sqrt{l/c}$ is Ohm, it is denoted by ρ and referred to as the characteristic or wave resistance of the circuit r , l , c .

$$Q = \frac{U_{C0}}{U} = \frac{U_{L0}}{U} = \frac{I_0 \cdot \omega_0 \cdot L}{I_0 \cdot r} = \frac{\omega_0 \cdot L}{r} = \frac{\rho}{r} \quad (6)$$

In Equation 6, the Q factor characterizes the resonance properties of the circuit and is therefore called the resonance or quality factor. The inverse of the quality factor is called the circuit's damping ratio. It is expressed by the following equation.

$$d = \frac{1}{Q} \quad (7)$$

The resonance phenomenon is examined from an energy perspective. The total energy of the magnetic and electric fields at the desired moment is described by the following equation:

$$w = w_m + w_e \quad (8)$$

The current in the circuit at resonance;

$$i = I_m \sin \omega_0 t, \quad (9)$$

The voltage across the capacitor terminals;

$$u_c = \frac{1}{c} \int_{-\infty}^t i \, dt = u_{cm} \sin(\omega_0 t - \frac{\pi}{2}) = -u_{cm} \cos \omega_0 t \quad (10)$$

and total energy;

$$w = w_m + w_c = \frac{Li^2}{2} + \frac{Cu_c^2}{2} = \frac{LI_m^2}{2} \sin^2 \omega t + \frac{Cu_m^2}{2} \cos^2 \omega t \quad (11)$$

is determined. On the other hand;

$$u_{cm} = \frac{1}{\omega_0 C} \cdot I_m = \sqrt{\frac{L}{C}} \cdot I_m \quad (12)$$

is obtained. Thus;

$$w = w_m + w_c = \frac{LI_m^2}{2} + \frac{Cu_m^2}{2} = s b t \quad (13)$$

is obtained, which shows that the total of magnetic and electric field energies is independent of time. A decrease in magnetic field energy causes an increase in electric field energy, while a decrease in electric field energy causes an increase in magnetic field energy. Thus, energy continuously flows from the magnetic field to the electric field and vice versa. The energy taken from the source is entirely converted into heat in the circuit. In other words, in resonance, the circuit is equivalent to an active resistance.

2. Frequency Characteristics of Series R, L, C Circuits




Figure 3. The frequency characteristics of the circuit

Suppose that the voltage $u = u_m \sin(\omega t)$ at the terminals of the circuit shown in Figure 3.a has a constant amplitude u_m and a frequency that varies between 0 and ∞ . The change in frequency ω causes changes in x_L and x_C , and consequently changes in Iu_L and u_C . The frequency dependence curves of the circuit parameters are called frequency characteristics, while the frequency dependence curves of current and voltage are called resonance characteristics.

In Figure 3.a, the frequency characteristics of the circuit are illustrated, while Figure 3.b presents the resonance curves of $I(\omega)$, $u_L(\omega)$, $u_C(\omega)$ and $\varphi(\omega)$. As observed from these curves, variation of the frequency within the range $0-\omega_0$

leads to an increase in the reactive impedances, which consequently affects the other circuit parameters. At the frequency $\omega=\omega_0$, the resonance phenomenon occurs in the circuit. Under this condition, $\varphi=0$, $u_L=u_C$, and the current reaches its maximum value as $I=u/r$, exhibiting a purely active character. The frequency dependence of the current clearly indicates that a series RLC circuit possesses a “selective property.” This property is widely exploited in electrical communication systems and radio engineering applications, where the resonance regime is considered the standard mode of operation.

In order to determine the influence of the circuit parameters on the resonance curve, these curves are formulated as functions of dimensionless quantities.

$$I / I_0 = F_1(w^*) \quad (14)$$

Here;

$$I_0 = \frac{u}{r} \rightarrow \text{current flowing through the circuit at resonance}$$

$$w^* = \frac{w}{w_0} \rightarrow \text{normalized (relative) frequency}$$

$$w_0 \rightarrow \text{resonance frequency}$$

The expression of the circuit's complex impedance is transformed as shown below.

$$\begin{aligned} z &= \sqrt{r^2 + \left(w_L - \frac{1}{w_C}\right)^2} = \sqrt{r^2 + w_0^2 L^2 \left(\frac{w}{w_0} - \frac{1}{w w_0 L C}\right)^2} = \\ &= r \sqrt{1 + Q^2 \left(w^* - \frac{1}{w^*}\right)^2} \end{aligned} \quad (15)$$

Here;

$$w^* - \frac{1}{w^*} \rightarrow \text{characterizes the deviation of the circuit relative to its resonance frequency.}$$

$$Q \left(w^* - \frac{1}{w^*}\right) = \xi \quad (16)$$

The expression in Equation (16) is referred to as the “generalized detuning.” When the formulation given in Equation (16) is substituted into the corresponding term of Equation (15);

$$z = r \sqrt{1 + \xi^2} \quad (17)$$

Equation 17 is obtained.

The current flowing through the circuit is;

$$I = \frac{u}{z} = \frac{u}{r\sqrt{1+Q^2\left(w^*-\frac{1}{w^*}\right)^2}} = \frac{I_0}{\sqrt{1+\xi^2}} \quad \text{or} \quad \frac{I}{I_0} = \frac{1}{\sqrt{1+\xi^2}} = F(w^*) \quad (18)$$

It is obtained as follows. These equations show that the effect of the parameters on the resonance curve is entirely characterized by the quality factor Q .

By drawing a horizontal line corresponding to the value $\frac{I}{I_0} = \frac{1}{\sqrt{2}}$, the circuit's *frequency passband limit* ($w_{\text{upper}}^* - w_{\text{lower}}^*$) is determined.




Figure 4. Graph of increase in selectivity of the circuit

As illustrated in Figure 4, an increase in the quality factor Q results in a narrower frequency bandwidth, thereby enhancing the selectivity of the circuit. At very low frequency ranges, a logarithmic scale is employed for more accurate representation.

$$\lg\left(\frac{w_2}{w_1}\right) = \lg\left(\frac{t_2}{t_1}\right) = \lg\left(\frac{w_2^*}{w_1^*}\right) = 1 \quad (19)$$

where;

$(w_1^* - w_2^*)$ the frequency range is called the “decade” (tenfold change).

$$\log_2\left(\frac{w_2^*}{w_1^*}\right) = 1 \quad (20)$$

The situation indicated by Equality 20 is called “octave” (doubling) when the frequencies are limited.

Example 1




Figure 5

In the circuit shown in Figure 5.a, the devices are shown in resonance with $U=200\text{V}$; $U_{10}=204\text{V}$; $U_{20}=180\text{V}$; $I_0=4\text{A}$. Knowing that the frequency is $f=50\text{Hz}$, calculate the parameters of the coil r and L_0 , the capacitance C_0 , and the resistance r .

Solution

First, we calculate the capacitance resistance.

$$X_{c_0} = \frac{U_{c_0}}{I_0} = \frac{180}{4} = 45\Omega = \frac{1}{2\pi f C_0}$$

$$C_0 = \frac{1}{2\pi f X_{c_0}} = \frac{1}{2\pi \cdot 50 \cdot 45} = \frac{1}{314.45} = 70,77 \cdot 10^{-6} \text{F} = 70,77 \mu\text{F}$$

Resonance time;

$$X_{L_0} = X_{C_0} = 45\Omega = 2\pi f L_0$$

$$L_0 = \frac{X_{L_0}}{2\pi f} = \frac{45}{314} = 0,1433 \text{H} = 143,3 \text{mH}$$

The complex resistance of the coil;

$$Z_{b_0} = \frac{U_{10}}{I_0} = \frac{204}{4} = 51\Omega = \sqrt{r^2 + X_{L_0}^2} \Rightarrow r = \sqrt{Z_{b_0}^2 - X_{L_0}^2} =$$

$$= \sqrt{51^2 - 45^2} = 24\Omega$$

Resonance time;

$$z_0 = r + r_1 = \frac{U}{I_0} = \frac{200}{4} = 50\Omega \quad \text{and}$$

$$r_1 = z_0 - r = 50 - 24 = 26\Omega$$

The phasor diagram of the circuit is shown in Figure 5.b.

Example 2




Figure 6

$r=100\Omega$; the capacitor with inductance $L=5.05\text{mH}$ and capacitance $C=0.05\mu\text{F}$ is connected in series (Figure 6). Calculate the resonance frequency, characteristic resistance, damping ratio, resonance time U_{L_0} , and C_0 . At what frequencies do the voltages across the capacitor and inductor reach their maximum values ($U_{C_{max}} = U_{L_{max}}$)? Calculate the voltages if the input voltage to the circuit is $U = 10\text{V}$.

Solution

Resonance frequency;

$$\omega_0 = \frac{1}{\sqrt{LC}} = \frac{1}{\sqrt{5,05 \cdot 10^{-3} \cdot 0.05 \cdot 10^{-6}}} = 6,28 \cdot 10^4 \text{ s}^{-1}$$

$$f_0 = \frac{\omega_0}{2\pi} = \frac{2\pi \cdot 10^4}{2\pi} = 10^4 \text{ Hz}$$

Characteristic resistance;

$$\rho = \sqrt{\frac{L}{C}} = \sqrt{5,05 \cdot 10^{-3} / 0.05 \cdot 10^{-6}} = 318\Omega$$

$$d = \frac{r}{\rho} = \frac{100}{318} = 0,314$$

$$U_{L_0} = U_{C_0} = I_0 \cdot \rho = \rho \cdot \frac{U}{r} = 318 \cdot \frac{10}{100} = 31,8 \text{ V}$$

The frequencies and voltage values at which $U_{C_{max}}$ and $U_{L_{max}}$ occur in capacitance and inductance are calculated as follows.

$$w_L = w_0 \cdot \sqrt{\frac{2}{2-d^2}} = 6,28 \cdot 10^4 \sqrt{\frac{2}{2-0,314^2}} = 6,45 \cdot 10^4 s^{-1}$$

$$w_C = w_0 \cdot \sqrt{\frac{2-d^2}{2}} = 6,13 \cdot 10^4 s^{-1}$$

$$f_L = \frac{w_L}{2\pi} = 10250 \text{ Hz} ; f_C = \frac{w_C}{2\pi} = 9750 \text{ Hz}$$

$$U_{Lm} = U_{Cm} = \frac{2U}{d\sqrt{4-d^2}} = \frac{2 \cdot 10}{0,314 \sqrt{4-0,314^2}} = 32,2 \text{ V}$$

Example 3

The voltage $U = 1\text{V}$ is applied across the terminals of a series-connected circuit with $r = 10\Omega$, $L = 100\mu\text{H}$, and $c = 100\text{pF}$. Calculate the resonance frequency w_0 , characteristic impedance ρ , damping ratio d , and quality factor Q of the circuit. Find the resonance time, the current I_0 flowing through the circuit, the power P_0 dissipated in the circuit, the voltage U_{L_0} across the inductor, and the voltage U_{C_0} across the capacitor. Calculate the absolute value of the passband.

Solution

$$w_0 = \frac{1}{\sqrt{LC}} = \frac{1}{\sqrt{100 \cdot 10^{-6} \cdot 100 \cdot 10^{-12}}} = 10^7 s^{-1}$$

$$f_0 = \frac{w_0}{2\pi} = \frac{10^7}{2\pi} \approx 1,6 \cdot 10^6 \text{ Hz} = 1,6 \text{ MHz}$$

$$\rho = \sqrt{\frac{L}{c}} = \sqrt{\frac{100 \cdot 10^{-6}}{100 \cdot 10^{-12}}} = 1000\Omega$$

$$d = \frac{r}{\rho} = \frac{10}{1000} = 0,01$$

$$Q = \frac{\rho}{r} = \frac{1000}{10} = 100$$

$$I_0 = \frac{U}{r} = \frac{1}{10} = 0,1\text{A} = 100\text{mA}$$

$$P_0 = I_0^2 \cdot r = (0,1)^2 \cdot 10 = 0,1\text{W} = 100\text{mW}$$

$$U_{L_0} = U_{C_0} = I_0 \cdot \rho = 0,1 \cdot 1000 = 100\text{V}$$

The pass band is determined by the following expression.

$$2\Delta f_0 = \frac{f_0}{Q} = 1,6 \cdot 10^6 / 100 = 16000 \text{ Hz} = 16 \text{ kHz}$$

3. Resonance Phenomena in Parallel Circuits




Figure 7. parallel R, L, C circuit

Figure 7 shows a real parallel R, L, C circuit. The input complex impedance of this circuit is:

$$\begin{aligned} y &= y_1 + y_2 = \frac{1}{r_1 + j\omega l} + \frac{1}{r_2 - j\frac{1}{\omega c}} = \\ &= (g_1 + g_2) - j(b_1 + b_2) = g - jb \end{aligned} \quad (21)$$

Here;

$$\begin{aligned} g_1 &= \frac{r_1}{r_1^2 + (\omega L_1)^2} ; \quad b_1 = \frac{\omega L}{r_1^2 + (\omega L)^2} \\ g_2 &= \frac{r_2}{r_2^2 + \left(\frac{1}{\omega C}\right)^2} ; \quad b_2 = \frac{-\frac{1}{\omega C}}{r_2^2 + \left(\frac{1}{\omega C}\right)^2} \end{aligned} \quad (22)$$

are defined by these expressions.

Resonance in a parallel circuit;

$$b = b_1 + b_2 = 0 \text{ or } b_1 = -b_2 \quad (23)$$

In this case, since the directions of the currents i_{1rewt} and i_{2rewt} are opposite and their values are equal, their sum is 0, and resonance occurs in the circuit. Accordingly, the resonance formed in such a circuit is called current resonance. As seen in the phasor diagram in Figure 7.b, at the resonance time, the current in the unbranched part of the circuit is equal to the sum of the active parts of the branch currents, and is active in character and minimum in value. Theoretically, if $r_1 = r_2 = 0$, the current in the undivided part of the circuit is taken as $i = 0$. (Figure 7.c)

If the parameters of Equality 21 are substituted into Equality 22;

$$\frac{wL}{r_1^2 + (wL)^2} - \frac{\frac{1}{wC}}{r_2^2 + \left(\frac{1}{wC}\right)^2} = 0 \quad (24)$$

is obtained. In this rule, by keeping four of the elements w , L , C , r_1 and r_2 constant and varying one, resonance may not occur. For example, if the value of the changed parameter is taken as imaginary or complex from equation (24), resonance does not occur in the circuit. Two positive real values can be taken for L and C , in which case two resonance regimes are obtained in the circuit.

By solving equation (24), the resonance frequency is obtained as:

$$w_{re2} = \frac{1}{\sqrt{LC}} \sqrt{\frac{\rho^2 - r_1^2}{\rho^2 - r_2^2}} \quad (25)$$

can be written. Here, the characteristic resistance;

$$\rho = \sqrt{\frac{L}{C}} \quad (26)$$

The input complex resistance of the circuit in resonance;

$$Z_{rez} = r_{rez} = \frac{\rho^2 + r_1 r_2}{r_1 + r_2} \quad (27)$$

Quality factor of the circuit;

$$Q = \frac{\rho}{r_1 + r_2} \quad (28)$$

The resonance value of the current in the unbranched section;

$$I_{rez} = \frac{U}{r_{rez}} \quad (29)$$

And the power consumed in the circuit;

$$P_{rez} = I_{rez}^2 \cdot r_{rez} = I_{1rez}^2 \cdot r_1 + I_{2rez}^2 \cdot r_2 \quad (30)$$

can be expressed in this form.

If $r_1 = r_2 = 0$ is assumed in the special case, the resonance equations can be listed as follows.

Resonance rule;

$$\frac{1}{w_{rez} \cdot L} = w_{rez} \cdot C \quad (31)$$

Resonance frequency;

$$w_{rez} = w_0 = \frac{1}{\sqrt{LC}} \quad (32)$$

The input resistance of the circuit in resonance condition;


$$Z_{rez} = \infty \quad (33)$$

The current in the unbranched part of the circuit;


$$I_{rez} = \frac{U}{Z_{rez}} = \frac{U}{\infty} = 0 \quad (34)$$

Here, in a parallel circuit, the sum of reactive energies is obtained as a constant only when $r_1 = r_2 = 0$. If $r_1 \neq r_2 \neq 0$ in the resonance case, the sum of energies is taken as non-zero.

4. Frequency Characteristics of Parallel R, L, C Circuits



(a)



(b)

Figure 8. Frequency characteristics of the r, l, c circuit in the special case where $r_1 = r_2 = 0$

Figure 8.b shows the frequency characteristics of the parallel r, l, c circuit given in Figure 8.a in the special case where $r_1 = r_2 = 0$. Here, $b_1(w) = b_L(w) = \frac{1}{wL}$ represents the inductive reactance, and $b_2 = b_C(w) = -wc$ represents the capacitive reactance.

$$b = b_1 + b_2 \quad (35)$$

The $b(w)$ characteristic equals '0' at frequency $w=w_0$, at which point resonance occurs in the circuit. The resonance time is the current in the undivided part of the circuit.

$$I = |B| \quad (36)$$

Since $I = |B|$, the $|b| \cdot (w)$ curve forms the $I(w)$ resonance curve with another scale. As seen in Figure 8.b, in this case, the resonance time is taken as $I=0$.

In real circuits, since $r_1 \neq r_2 \neq 0$, the I current is different from '0'.

Example 4




Figure 9

Figure 9 shows the circuit parameters as $r=25\Omega$, $L=3.2\text{mH}$, and $c=50\mu\text{F}$. The circuit is active and powered by a sinusoidal generator with a voltage of 20V. Determine the resonance frequency f_0 and the currents I_0, I_{L_0} and I_{C_0} . By varying the frequency within the $0-4f_0$ range, plot the resonance curves for $I = F_1(t)$, $I_L = F_2(t)$; $I_C = F_3(t)$; $\varphi = F_4(t)$.

Solution

From Equation 15 formula;

$$w_0 = \frac{1}{\sqrt{LC}} = \frac{1}{\sqrt{3,2 \cdot 10^{-3} \cdot 50 \cdot 10^{-6}}} = \frac{1}{4 \cdot 10^{-4}} = 2500 \text{ s}^{-1}$$

$$f_0 = \frac{w_0}{2\pi} = \frac{2500}{6,28} = 398 \text{ Hz}$$

$$i_{r_0} = i_0 = \frac{U}{r} = \frac{20}{25} = 0,8 \text{ A}$$

$$b_{L_0} = \frac{1}{w_0 L} = \frac{1}{2500 \cdot 3,2 \cdot 10^{-3}} = 0,125 \Omega^{-1}$$

$$b_{c_0} = w_0 c = 2500 \cdot 50 \cdot 10^{-6} = 0,125 \Omega^{-1}$$

$$I_{L_0} = I_{C_0} = b_{L_0} \cdot U = 0,125 \cdot 20 = 2,5 \text{ A}$$

For establishing resonance curves;

$$I = y \cdot U; I_L = b_L U; I_C = b_C U; \varphi = -\arctg \frac{b_L - b_C}{g}$$

The results are presented in the table below.

f	$b_L = \frac{1}{\omega L}$	$b_C = \omega C$	$y = \sqrt{g^2 +}$	$\varphi(0)$	I(A)	I_L (A)	I_C (A)	ω_s^{-1}	$b_L - b_C$
0	∞	0	$y = \infty$	-90°	∞	∞	0	0	∞
f_0	0.125	0.125	0.04	0	0.8	2.5	2.5	2500	0
$2f_0$	0.0625	0.25	0.192	77.96°	3.84	1.25	5	5000	-0.187
$3f_0$	0.0417	0.375	0.336	83.16°	6.72	0.834	7.5	7500	-0.333
$4f_0$	0.0312	0.5	0.471	85.12°	9.41	0.624	10	10000	-0.468

The resonance curves are shown in Figure 10.




Figure 10. The resonance curves

Example 5




Figure 11

Figure 11 shows $r_2 = 20\Omega$, $\frac{1}{\omega C} = 30\Omega$ and $\omega L = 40\Omega$. Calculate r and the total resistance of the circuit at resonance.

Solution

According to Equation 24;

$$\frac{\omega L}{r_1^2 + (\omega L)^2} = \frac{\frac{1}{\omega C}}{r_2^2 + \left(\frac{1}{\omega C}\right)^2}$$

$$\frac{40}{r_1^2 + 40^2} = \frac{30}{20^2 + 30^2} \Rightarrow r_1^2 = 133,33$$

$$r_1 = \pm\sqrt{133,33} = \mp 11,547\Omega$$

Here; $r_1 = 11,547\Omega$

From Equation 25;

$$\rho^2 = \frac{L}{C} = \frac{\omega L}{\omega C} = \omega L \cdot \frac{1}{\omega C} = 40 \cdot 30 = 1200 \Omega^2$$

From Equation 26;

$$Z_{\text{rez}} = r_{\text{rez}} = \frac{\rho^2 + r_1 r_2}{r_1 + r_2} = \frac{1200 + 11,547 \cdot 20}{11,547 + 20} = 45,359\Omega$$

Example 6

Figure 11 shows the parameters of the low-loss circuit: $r_1 = 9\Omega$, $r_2 = 1\Omega$; $L = 100\mu\text{H}$, $C = 100\text{pF}$. For the resonance condition of the circuit, calculate the frequency, total input resistance, currents flowing through the branches, and power dissipated in the circuit. The voltage across the circuit terminals is $U = 200\text{V}$.

Solution

The circuit has low losses, therefore;

$$w_{rez} = w_0 = \frac{1}{\sqrt{LC}} = \frac{1}{\sqrt{100 \cdot 10^{-6} \cdot 100 \cdot 10^{-12}}} = 10^7 \text{ s}^{-1}$$

The circuit's resonance resistance;

$$r_{rez} = \frac{\rho^2}{r_1 + r_2} = Q^2(r_1 + r_2) = \frac{L}{(r_1 + r_2)C} = \frac{100 \cdot 10^{-6}}{10 \cdot 100 \cdot 10^{-12}} = 100 \text{ k}\Omega$$

$$Q = \sqrt{\frac{L}{(r_1 + r_2)^2 C}} = \sqrt{\frac{10^{-4}}{100 \cdot 10^{-10}}} = 100$$

$$\frac{I_{1rez}}{I_{rez}} \approx \frac{I_{2rez}}{I_{rez}} \approx Q$$

$$I_{1rez} \approx I_{2rez} \approx Q I_{rez} = Q \cdot \frac{U}{r_{rez}} = 100 \cdot \frac{200}{10^5} = 0,2 \text{ A}$$

$$I_{rez} = \frac{U}{r_{rez}} = \frac{200}{10^5} = 0.002 \text{ A} = 2 \text{ mA}$$

$$P_{rez} = I_{rez}^2 \cdot r_{rez} = I_{1rez}^2 r_1 + I_{2rez}^2 r_2 = 0,04 \cdot 9 + 0,04 \cdot 1 = 0,4 \text{ W}$$

References

- Bellido, J. L., Esteve, V., & Jordán, J. (2024). Performance Enhancement in LC Series Resonant Inverters with Current-Controlled Variable-Transformer and Phase Shift for Induction Heating. *Electronics (Switzerland)*, 13(15). <https://doi.org/10.3390/electronics13152911>
- Bhavsingh, B., Suresh Babu, G., & Mangu, B. (2023). Comparison of Series/Series and Parallel/Series Resonance Circuit in 1.5 kW Inductive Wireless Power Transfer for EV Applications. *Journal of Electrical and Electronic Engineering*, 11(1), 1–14. <https://doi.org/10.11648/j.jeece.20231101.11>
- Boran, F., & Karadağ, T. (2024). Energy Production by Electrogenic Bacteria. In *PIONEER AND INNOVATIVE STUDIES IN ENGINEERING* (pp. 167–186). All Sciences Academy. Retrieved from https://www.researchgate.net/publication/387602807_Recycling_Lithium_Batteries_A_Biotechnological_Solution_Bacteria
- Ekici, Y. E., Ka, T., Aydın, A. A., & Akdağ, O. (2024). Driving Range Problem in Electric Vehicles and Methods to Increase. In *Article and Reviews in Engineering* (pp. 253–286). <https://doi.org/10.5281/zenodo.13950544>
- Hu, Y., Li, Z., Zhao, C., & Li, Y. (2021). Analytical loss model of series-resonant indirect-matrix-type power electronics transformers using MOSFETs. *Journal of Power Electronics*, 21(11), 1659–1668. <https://doi.org/10.1007/s43236-021-00304-x>
- Jiang, C., Chau, K. T., Liu, C., & Lee, C. H. T. (2017). An overview of resonant circuits for wireless power transfer. *Energies*, 10(7). <https://doi.org/10.3390/en10070894>
- Karadağ, T. (2022). Doğru akım devreleri ve problem çözümleri. In *Mühendislik Bilimleri Araştırma ve Uygulama* (pp. 1–33). Lvre de Lyon. Retrieved from https://bookchapter.org/kitaplar/Muhendislik_Bilimleri_Arastirma_ve_Uygulama.pdf
- KARADAĞ, T., MAMMADOV, A., & DİKMEN, İ. C. (2022). Devre Analizinde Değişken Rejimler. In *Mühendislik Bilimlerinde Güncel Araştırmalar ve Uygulama* (pp. 37–68). Lvre de Lyon. Retrieved from https://bookchapter.org/kitaplar/Muhendislik_Bilimlerinde_.pdf
- Kumar, V., & Yi, K. H. (2023). 6.78 MHz loosely coupled inductive wireless power transfer with series–parallel resonators. *Journal of Power Electronics*, 23(2), 355–362. <https://doi.org/10.1007/s43236-022-00552-5>
- Lara-Reyes, J., Ponce-Silva, M., Cortés-García, C., Lozoya-Ponce, R. E., Parrilla-Rubio, S. M., & García-García, A. R. (2022). High-Power-Factor LC Series Resonant Converter Operating Off-Resonance with Inductors Elaborated

- with a Composed Material of Resin/Iron Powder. *Electronics (Switzerland)*, 11(22). <https://doi.org/10.3390/electronics11223761>
- Li, J., Li, R., & Ruan, X. (2023). Resonance analysis of multiple grid-connected inverters' series and parallel network. *IET Renewable Power Generation*, 17(5), 1106–1118. <https://doi.org/10.1049/rpg2.12666>
- Liu, Y., Zhu, H., Li, X., Teng, J., & Sun, X. (2024). Series Resonant Current Source High-frequency Link Inverter Grid Connection Technology Based on Model Predictive Control. *CPSS and ISESC 2024 - 2024 CPSS and IEEE International Symposium on Energy Storage and Conversion*, 848–854. <https://doi.org/10.1109/ISESC63657.2024.10785517>
- Seo, S., Ryu, N., Choi, H., & Jeong, Y. (2007). Novel high-Q inductor using active inductor structure and feedback parallel resonance circuit. *Digest of Papers - IEEE Radio Frequency Integrated Circuits Symposium*, 467–470. <https://doi.org/10.1109/RFIC.2007.380925>
- Tiggelman, M. P. J., Reimann, K., Van Rijs, F., Schmitz, J., & Hueting, R. J. E. (2009). On the trade-off between quality factor and tuning ratio in tunable high-frequency capacitors. *IEEE Transactions on Electron Devices*, 56(9), 2128–2136. <https://doi.org/10.1109/TED.2009.2026391>