

Güneş Enerjisi Santrallerinde YOLO Algoritmaları ile Hotspot Kusurlarının Tespiti

Sümeyye YANILMAZ¹, Muammer TÜRKOĞLU², Muzaffer ASLAN^{3*}

¹ Fen Bilimleri Enstitüsü, Bingöl Üniversitesi, Bingöl, Türkiye

² Yazılım Mühendisliği Bölümü, Mühendislik Fakültesi, Samsun Üniversitesi, Samsun, Türkiye

³ Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Mimarlık Fakültesi, Bingöl Üniversitesi, Bingöl, Türkiye

¹ sumeyye_yanlmaz@hotmail.com, ² muammerturkoglu@samsun.edu.tr, ^{*3} muzafferaslan@bingol.edu.tr

(Geliş/Received: 21/06/2023;

Kabul/Accepted: 10/11/2023)

Öz: Güneş enerjisi santrallerindeki kusurların hızlı ve doğru bir şekilde tespit edilmesi, fotovoltaik (PV) sistemlerinde verim kaybını azaltmak ve ömrünü uzatmak açısından büyük bir öneme sahiptir. Bu çalışmada, güneş enerjisi santrallerindeki, PV modüllerdeki hotspot (sıcak nokta) tespiti için You Only Look Once (YOLO) algoritmalarının etkililiği ve avantajları incelenmiştir. YOLO algoritmaları, yüksek hızda çalışarak tek bir taramada görüntüdeki nesneleri tespit edebilme özelliğine sayesinde büyük ölçekli santrallerde verimli bir şekilde kullanılabilir. Bu doğrultuda, YOLOv5, YOLOv6, YOLOv7 ve YOLOv8 algoritmalarının performansları karşılaştırılmış ve en iyi sonuç veren model belirlenmiştir. Yapılan deneyler sonucuna göre, veri kümesinde kullanılan insansız hava aracı tarafından elde edilen 100 adet görüntünün %80'i eğitim kümesi %20'si ise test kümesi için kullanılarak YOLO algoritmaları karşılaştırılmaları yapılmıştır. Elde edilen sonuçlar doğrultusunda, YOLOv8 algoritmasının %88.7 özgürlük, %80.5 duyarlılık ve %83.8 mAP değerleri ile diğer modellere göre daha iyi sonuçlar verdiği göstermiştir. Çalışmada kullanılan veri seti gerçek güneş panellerinden elde edilen görüntülerden oluşmuştur ve bu sayede çalışmanın sonuçları gerçek dünya senaryolarına uygun bir şekilde test edilmiştir. Elde edilen sonuçlar, YOLO algoritmalarının güneş panellerindeki sıcak nokta kusurlarının tespiti için etkili bir yöntem olduğunu göstermektedir. Bu çalışma, güneş enerjisi santrallerinin daha verimli hale getirilmesi için nesne tespiti algoritmalarının kullanımının önemini vurgulamaktadır. Ayrıca, ilerideki çalışmalarla yol gösteren ve literatüre katkı sağlayan bir çalışma olarak değerlendirilebilir.

Anahtar kelimeler: Güneş panelleri, Sıcak nokta tespiti, YOLO algoritması, Görüntü işleme.

Detection of Hotspot Defects in Solar Power Plants with YOLO Algorithms

Abstract: The rapid and accurate detection of defects in solar energy plants is of great importance to reduce efficiency losses and extend the lifespan of photovoltaic systems. In this study, the effectiveness and advantages of You Only Look Once (YOLO) algorithms for hotspot detection in solar energy plants have been investigated. YOLO algorithms can be efficiently used in large-scale facilities due to their ability to detect objects in images in a single scan at high speeds. In this context, the performances of YOLOv5, YOLOv6, YOLOv7, and YOLOv8 algorithms were compared, and the best-performing model was determined. According to the results of the experiments, 80% of the 100 images obtained by an unmanned aerial vehicle in the dataset were used for training, and the remaining 20% were used for testing the YOLO algorithms. The results indicated that the YOLOv8 algorithm outperformed other models with 88.7% specificity, 80.5% sensitivity, and 83.8% mean Average Precision (mAP) values. The dataset used in the study consisted of images obtained from real solar panels, ensuring that the results of the study were tested in accordance with real-world scenarios. The findings demonstrate that YOLO algorithms are an effective method for detecting hotspot defects in solar panels. This study highlights the importance of using object detection algorithms to make solar energy plants more efficient. Additionally, it can be considered as a guiding and contributing study to the literature, providing insights for future research.

Key words: Solar panels, Hotspot detection, YOLO algorithm, Image processing.

1. Giriş

Hızla artan nüfus ve gelişen teknolojiyle birlikte enerji üretimi ve tüketimi hayatın her alanında önemli hale gelmiştir. Ancak artan enerji talebini karşılamak için kullanılan kömür, petrol, doğalgaz gibi karbondioksit (CO_2) emisyon miktarı fazla olan fosil yakıtların yanması sonucu ortaya çıkan sera gazları atmosferde birikerek küresel ısınmaya ve iklim değişikliğine de neden olmaktadır [1]. Uluslararası Enerji Ajansı'nın (IEA), 2022 yılında yayınlanan raporuna göre, 2022'de CO_2 emisyon miktarı %0,9 artarak tüm zamanların en yüksek seviyesi olan 36,8 GT'a ulaşmıştır [2]. Bu artan karbondioksit emisyonları nedeniyle ülkeler yenilenebilir enerji kaynaklarına

* Sorumlu yazar: muzafferaslan@bingol.edu.tr. Yazarların ORCID Numarası: ¹ 0009-0009-8389-5068, ² 0000-0002-2377-4979, ³ 0000-0002-2418-9472

yönelmeye başlamıştır. IEA raporlarına göre, yenilenebilir enerji kapasitesi 2022 ile 2027 yılları arasında neredeyse 2.400 GW artarak Çin'in tüm kurulu güç kapasitesine eşit olması beklenmektedir [3].

Bu kapsamda güneş enerjisi sistemleri, hızla gelişen ve gelecekte önemli potansiyele sahip olan enerji üretim teknolojilerinden biridir [4]. Güneş enerjisi genellikle termal ve PV sistemler aracılığıyla üretilmektedir. PV sistemler, güvenilirlikleri, dayanıklılıkları ve sürdürülebilir enerji üretmeleri nedeniyle önemli güç üretim sistemleri arasında kabul edilmektedir [5, 6].

PV üretim tesislerindeki kurulum kapasitesi her yıl hızla artmaktadır [7]. Üreticiler, genellikle PV modüller için 25 yıllık performans garantisini vermektedir. PV sistemler ömrünün ilk 10 yılında nominal kapasitenin en az %90'ını ve sonraki 10-15 yılında yaklaşık %80 performans garantisini sağlayan PV modüllerinin %17,6'sında arızalar meydana gelmiştir [8]. Gerçek koşullar altında, PV sistemlerin performansı zamanla azaldığı görülmektedir. Su damlacıkları, kuş pislikleri, kısmi gölgeleme, salyangoz izleri, mikro çat�aklar, hücre kırılmaları ve aşırı ısınma gibi faktörler PV sistemlerinde sıcak nokta hatalarına yol açabilmektedir [9, 10]. Sıcak nokta, PV sistemlerde üretilen gücün azaltan ve hücre bozulmasını hızlandıran önemli sorunlarından biridir [11]. Ayrıca, erken müdahale edilmezse, arızalar komşu modüllere yayılarak PV dizilerinin tamamen arızalanmasına yol açabilmektedir [12].

PV sistemlerinde sıcak nokta hatalarının erken tespiti, verim kayıplarını azaltmak ve sistem ömrünü uzatmak için oldukça önemlidir. Bu sistemlerin, düzenli denetim ve bakımlarının yapılması, sıcak nokta kusurlarının zamanında tespit edilmesini sağlar. Bununla birlikte manuel denetimlerle sıcak nokta kusurlarının zamanında tespit edilememesi hem maddi kayıplara neden olmakta hem de panellerin enerji verimliliğini düşürmektedir. Bu nedenle, PV sistemlerde sıcak nokta kusurunun erken tespiti için termografi yöntemi tercih edilmektedir [13]. Bu yöntem, modülün lamine edilmeden önce ters polariteye sahip bir voltaj uygulanarak sıcak nokta ve üretim hatalarından kaynaklanan söntlerin tespit edilmesini sağlayabilmektedir [14].

Ayrıca, literatürde farklı makine öğrenimi algoritmalarının sıcak nokta tespiti için kullanıldığı görülmektedir. Bu algoritmalar, elde edilen termal görüntülerdeki özelliklerini analiz ederek panellerin sağlıklı, hatalı sıcak nokta veya hatasız olarak sınıflandırılmaktadır. Naive Bayes, Destek Vektör Makinesi (DVM), karar aacı (DT) ve k-en yakın komşu (KNN) gibi algoritmalar bu amaçla kullanılan yöntemler arasındadır.

Niazia ve diğ. (2019), PV modüllerde kategorize edilmiş sıcak nokta tespiti için Naive Bayes tabanlı sınıflandırma temelli yönlü gradyan histogram (HOG) özelliklerini kullanmışlardır. Sonuç olarak, FLIR termal kameralı ile elde edilen 375 adet termal görüntüden oluşan veri setinde sıcak nokta kusurlarının tespitinde yaklaşık %94,1'lik doğruluğa ulaşılmıştır [10].

Ali ve diğ. (2020), PV panellerin sıcak nokta tespiti ve sınıflandırması için kızılıtesi termografi tekniği kullanarak hibrit özelliklere dayalı bir DVM modeli geliştirmiştir. Özellikler olarak RGB, doku, HOG ve yerel ikili modelden (LBP) oluşan yeni bir hibrit özellik vektörü, bir veri fuzyon yaklaşımı kullanılarak oluşturulmuştur. PV panellerin elde edilen termal görüntülerini üç farklı sınıfa; sağlıklı, hatalı sıcak nokta ve hatalı olmak üzere sınıflandırmak için DVM'ye uyguladılar. Önerilen modelin ve hibrit özellik veri setinin üstünlüğünü doğrulamak için diskriminant analizi (QDA), Naive-Bayes, KNN, torbalama topluluğu (BE) makine öğrenimi algoritmalarının ve veri setlerinin karşılaştırılmasını yapmışlardır. Önerilen hibrit özellikler (veri seti III), önerilen DVM modelini kullanarak 315 PV termal örneğinden 305'ini doğru bir şekilde sınıflandırdı. DVM ile önerilen hibrit özelliklerin, diğer makine öğrenme algoritmalarına göre daha az hesaplama karmaşıklığı ve depolama alanı ile %96,8 eğitim doğruluğu ve %92 test doğruluğu sonucuna ulaşmıştır [7].

Chen ve diğ. (2020), güneş panellerinin termografik görüntülerinde sıcak nokta tespiti için RGB renk uzayından HSV uzayına dönüşümü içeren yeni bir yöntem önerilmiştir. Bu yöntemde, bir termografik görüntü RGB renk uzayından HSV renk uzayına dönüştürülür ve güneş panellerinin tüm hücreleri H kanalına göre bölütlenir. Güneş panellerinin kenarları Canny kenar algılama algoritması kullanılarak çıkarılır. Güneş panellerinin hücreleri, çıkarılan kenarlara göre böülümlere ayrılır. B kanalındaki her bir bölümlenmiş hücrenin ortalama ve standart sapmasına dayalı bir SVM modeli eğitilir. Sonuç olarak, önerilen yöntemin güneş panelleri için sıcak nokta hatalarını tespit etmede etkili olduğunu, özellikle gri alandaki ortalama ve standart sapmanın ek özelliklerile aşırı maruz kalmaya karşı sağlam olduğunu göstermektedir [11].

Ren ve diğ. (2020), PV sistemlerde derin öğrenme tabanlı sıcak nokta algılama sistem tasarımı geliştirmiştir. PV sıcak nokta tespiti için geliştirilmiş bir SSD (Sigle Shot Detection) algoritması tasarlamışlardır. SSD algoritmasındaki VGG-16 evrişimli sinir ağının yapısının yerine MobileNet ağını kullanmışlardır. DeneySEL çalışmalarında, 1500'ü sıcak nokta olan toplamda 2000 görüntüye sahip veri seti kullanılmıştır. Geliştirilmiş MobileNet-SSD algoritmasını YOLO ve SSD algoritması ile karşılaştırmışlardır. Sonuç olarak, geliştirilmiş MobileNet-SSD algoritması karşılaştırılan algoritmalarla göre PV dizilerde Sıcak nokta algılama sisteminin, geleneksel YOLO ve SSD algoritmalarına kıyasla iyi derecede güvene, yüksek algılama hızına, yavaş gözden kaçan algılama oranına ve iyi sağlamlığı sahip olduğunu göstermektedir [15].

Dhimish (2021), PV güneş hücrelerindeki sıcak nokta hatalarının erken tespiti için en uygun makine öğrenme sınıflandırıcıları DT, DVM, KNN ve diskriminant sınıflandırıcılar dahil olmak üzere dört farklı makine öğrenme sınıflandırıcı sonuçları karşılaştırılmıştır. Ayrıca, en yüksek başarıma sahip sınıflandırıcıların karmaşıklık matrisi ve alıcı çalışma karakteristikleri (ROC) kullanılarak performansları açısından da karşılaştırılmıştır. Çalışmada, en yüksek %98 doğruluk ile DC sınıflandırıcı, en düşük tespit %84 ile karar ağacı sınıflandırıcıda sağladılar [6].

Ali ve diğ. (2021), renkli görüntü tanımlayıcıları ve makine öğrenme algoritmalarını kullanarak PV modüllerde erken sıcak nokta tespitini gerçekleştirmiştir. Önerilen sistemde sıcak nokta hatalarını belirlemek için termal kamera ile donatılmış bir insansız hava aracı (İHA) kullanılmıştır. Histogram tabanlı renk tanımlayıcıları, renk momenti ve değişmezleri ve ölçek ile değişmeyen özellik dönüşüm algoritmaları ile öznitelik çıkarımını gerçekleştirdiler. Sınıflandırma için bu öznitelikler Naive Bayes, DT, rastgele orman ve k-NN makine öğrenme algoritmalarına uygulanmıştır. Deneysel çalışmalarında, 375 görüntünün %80'ini eğitim ve %20'sini test için kullanılmıştır. Yapılan testler sonucunda k-NN + rgSIFT' in 71 x 71 piksellik bir bölge boyutuyla %98,7'nin doğruluk oranıyla diğer tüm görüntü tanımlayıcıları ve makine öğrenme kombinasyonlarından daha iyi doğruluk elde edilmiştir [16].

Sun ve diğ. (2022), PV panellerin sıcak nokta tespiti için YOLOv5 (AP-YOLOv5) ağıının geliştirilmiş ankray ve tahmin kafalarına dayalı olarak yeni bir yöntem geliştirmiştir. Ayrıca, YOLOv5 ağıının PV panellerin sıcak nokta hatalarında farklı ölçeklerde algılama hassasiyetini artırmak için, veri açıklaması çerçevesinin uzunluk-genişlik oranını ve daha küçük ankraylardan oluşan bir grubu kümelemek için K-means kümeleme algoritmasını da kullanmışlardır. PV panellerin sıcak nokta hatalarını morfolojik özelliklerine göre dairesel, doğrusal ve dizi olarak sınıflandırılmış toplamda 1000 adet görüntü kullanılmışlardır. Çalışmalarında, tek aşamalı nesne algılama modelleriyle karşılaştırıldığında, önerilen ağıın ortalama kesinliğinin (mAP) %87,8, ortalama geri çağrıma oranının %89,0 ve F1 puanının %88,9 doğruluk sonucuna ulaşmıştır [17].

Bu çalışmada, güneş panellerindeki sıcak nokta hatalarının tespiti için bölgesel tabanlı YOLO algoritması kullanılmıştır. Bu çalışmanın literatüre katkıları şunlardır:

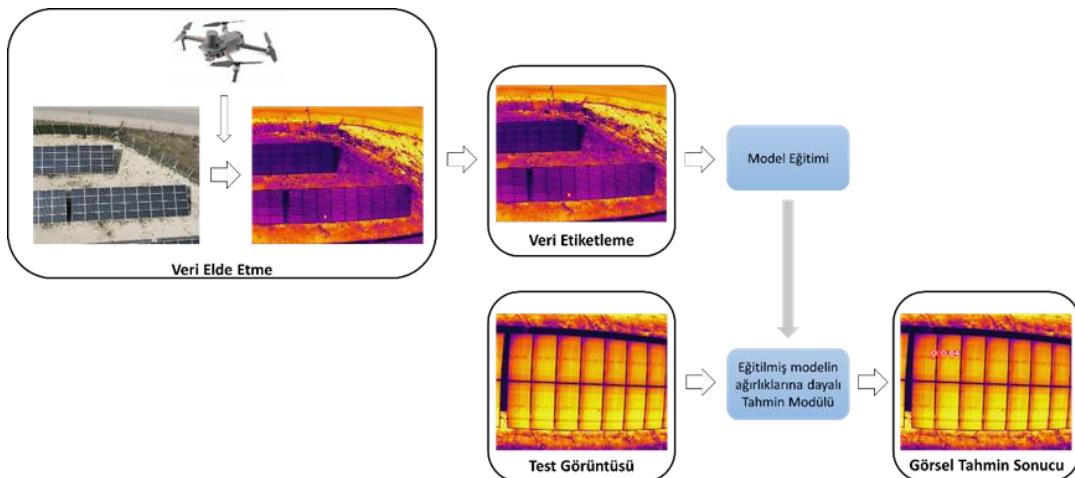
- Güneş panellerindeki sıcak nokta kusurlarının tespiti için YOLO algoritmalarının kullanımının etkinliği ve avantajları açıkça gösterilmiştir.
- Çalışmada kullanılan veri seti ve performans metrikleri diğer çalışmalarada da kullanılabilir ve karşılaştırımlar yapılabilir.
- Çalışmada, farklı YOLO algoritmalarının performansları karşılaştırılmış ve en iyi sonuç veren model belirlenmiştir.
- Bu çalışma, güneş enerjisi santrallerinin daha verimli hale getirilmesi için nesne tespiti algoritmalarının kullanımının önemi vurgulamaktadır.
- YOLO algoritmalarının performansını artırmak için farklı tekniklerin ve parametrelerin kullanımı gibi ilerideki çalışmalarla yönelik öneriler sunulmaktadır.

Makalenin genel organizasyonu şu şekildedir: Giriş bölümünde, çalışmanın amacı ve önemi açıklanmaktadır. Ayrıca, güneş enerjisi santrallerindeki sıcak nokta kusurlarının tespiti için YOLO algoritmalarının kullanımının avantajları detaylandırıldı. Ek olarak bu bölümde, güneş panellerindeki kusurların tespiti için kullanılan diğer yöntemler ve nesne tespiti algoritmaları hakkında bilgi verilmektedir. Materyal ve yöntem bölümünde ise, kullanılan veri seti, YOLO algoritmalarının nasıl kullanıldığı ve performans değerlendirmesi için kullanılan metrikler detaylandırıldı. YOLO algoritmalarının performansı ve karşılaştırılması hakkında ayrıntılı bilgi Sonuç bölümünde verilmiştir. Tartışma bölümde, çalışmanın sonuçları ve YOLO algoritmalarının güneş panellerindeki kusurların tespitindeki avantajları hakkında tartışılmır. Ayrıca, çalışmanın sınırlamaları ve ilerideki çalışmalara yönelik öneriler de sunulur. Çalışmanın önemi ve YOLO algoritmalarının güneş panellerindeki sıcak nokta kusurlarının tespiti için kullanımının avantajları Sonuç bölümünde özetlenmiştir.

2. Materyal ve Yöntem

Bu çalışmada, güneş enerjisi santrallerindeki sıcak nokta kusurlarını tespit etmek için YOLO tabanlı bir derin öğrenme modeli önerilmektedir. Veri seti, güneş tarlasındaki PV panellerinden toplanan görüntülerden oluşmaktadır ve bu bakımdan çalışmanın sonuçları gerçek dünya senaryolarına uygun bir şekilde test edilmiş ve YOLO algoritmalarının performansları karşılaştırılmıştır. Deneysel çalışmalar, farklı YOLO algoritmalarının ve farklı parametrelerin kullanımının, sıcak nokta kusurlarının tespiti için etkili olup olmadığını belirlemek için tasarlanmıştır. Önerilen çalışmanın genel diyagramı Şekil 1'de verilmiştir.

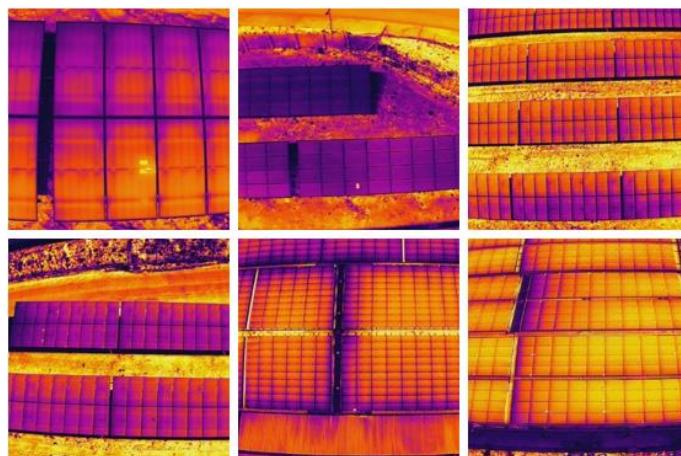
Bu bölümde, deneysel çalışmalarla kullanılan veri seti, deney tasarımi, parametreler ve performans metrikleri ayrıntılı olarak açıklanmaktadır. Ayrıca, deneysel çalışmalarındaki her bir YOLO modeli detaylandırılmıştır.



Şekil 1. Önerilen çalışmanın genel diyagramı.

2.1. Veri kümesi

Bu çalışmada, güneş paneli kusurlarının tespiti için özgün bir veri seti oluşturuldu. Bu veri seti, gerçek dünya koşullarında çekilmiş yüksek çözünürlüklü güneş paneli görüntülerinden oluşmaktadır. Veri seti, farklı güneş paneli türlerini içermektedir. Veri seti, toplamda 100 güneş paneli görüntüsünden oluşmaktadır. Her bir görüntü, ışık koşullarının ve çevresel faktörlerin değişebileceğİ gerçek dünya senaryolarını yansıtmaktadır. Görüntüler farklı açılardan çekilmiş ve farklı çözünürlüklerde sahiptirler. Her görüntü bir veya daha fazla sıcak nokta kusurları içermektedir. Kusurlar, farklı büyüklükleri, şekillere ve konumlara sahiptir. Veri setindeki bazı örnek görüntüler Şekil 2'de verilmiştir.



Şekil 2. Veri kümesine ait örnek görüntüler.

Oluşturulan özgün veri seti, <https://www.makesense.ai> programı kullanılarak etiketleme işlemi gerçekleştirildi. Her görüntüye ait etiketler, güneş panelindeki kusurların konumlarını ve sınıflarını içermektedir. Bu etiketler, uzman gözlemler tarafından manuel olarak oluşturulmuştur ve doğrulukları kontrol edilmiştir.

Veri seti, deneysel çalışmalarında önerilen yöntem doğruluğunu ve hassasiyetini ölçmek için eğitim ve test veri kümesi olarak bölünmüştür. Eğitim veri seti, toplam veri setinin %80'ini oluştururken, geri kalan %20'lük kısmı test veri seti olarak ayrılmıştır. Ayrıca, eğitim veri setini çeşitlendirmek ve algoritmanın daha genelleyici olmasını sağlamak amacıyla yatay ve dikey dönüşüm, parlaklık değişimi ve görüntü döndürme gibi veri artırma yöntemleri

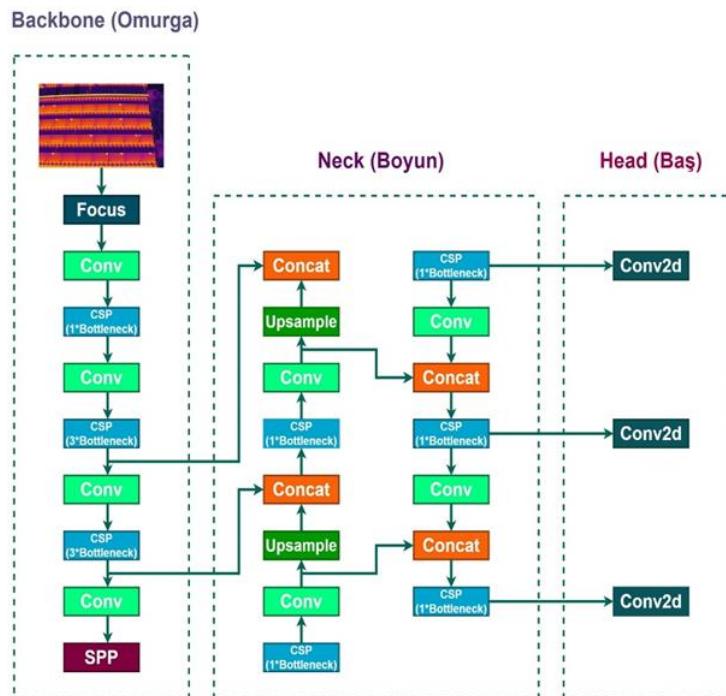
kullanılmıştır. Ham veri setindeki 100 görüntü, veri artırma teknikleri kullanılarak toplamda 240 görüntü elde edilmiştir.

2.2. YOLO algoritması

YOLO, sınırlayıcı kutuları ve sınıf olasılıklarını tahmin etmek için tek bir sinir ağını kullanan, GoogLeNet'ten ilham alan CNN tabanlı bir derin öğrenme algoritmasıdır [18, 19]. YOLO modeli, tek bir ağ yapısında nesneleri algılama, sınıflandırma ve tek aşamalı dedektör olarak çalışabilmektedir [20]. Ayrıca, nesnelerin sınıfını (class) ve konumunu (bounding box) aynı anda tespit edebilir. YOLO, önce girdi görüntüsünü bir dizi konvolüsyon ve örnekleme katmanından geçirir. Ardından, nesne konumlarını tahmin etmek için bir son katman kullanır. Bu son katmanda, önceki katmanlardan gelen özellik haritaları, nesnelerin konumları ve sınıfları hakkında bilgi içeren tespit haritalarına dönüştürülür. Bu tespit haritaları daha sonra sınıflandırma işlemiyle birleştirilir ve görüntüdeki nesnelerin türleri belirlenir. Tek bir ağ yapısı içerisinde bulunan tüm algılama hattı, diğer sinir ağı mimarilerinin çoğundan daha yüksek doğrudan algılama performansı sunar [18]. Bu model genellikle tek aşamalı modellere göre genellikle daha basit, hızlı ve güvenilir doğruluk sonuçları sunmaktadır [20]. YOLO mimarisi, farklı boyutlarda ve farklı hızlarla çalışan birkaç farklı modelleri mevcuttur. Bu modeller sırasıyla YOLO, YOLOv2, YOLOv3, YOLOv4, YOLOv5, YOLOv6, YOLOv7, YOLOv8, YOLOX ve YOLOR şeklinde sıralanmaktadır. Literatür çalışmaları incelendiğinde, YOLOv3, YOLOv4, YOLOv5 modellerinin en yaygın kullanılan modeller olduğu gözlemlenmiştir [20]. Bu çalışmada da YOLOv5, YOLOv6, YOLOv7, YOLOv8 modellerinin kullanılmaktadır.

2.2.1. YOLOv5 algoritması

YOLOv5 algoritması Joseph Redmon tarafından geliştirilen YOLO algoritmasının devamı niteliğindedir. YOLOv5 mimarisi, Phil Wang, Glenn Jocher ve Alexey Bochkovskiy gibi araştırmacılarından oluşan bir ekip tarafından yönetilen Ultralytics adlı bir yapay zekâ araştırma şirketi tarafından geliştirilmiştir. Bu model, 2020 yılında tek aşamalı hedef tanıma algoritması olarak piyasaya sürülmüştür ve açık kaynaklı bir yazılım olarak Github'da yayınlanmıştır. YOLOv5 algoritması, PyTorch kütüphanesi üzerinde yeni bir eğitim ortamı altında derlenerek geliştirilmiştir [19]. Ayrıca, bu ağ modelinin önceki sürümlere kıyasla algılama doğruluğu ve hızı oldukça yüksektir [18]. YOLOv5 model mimarisi Şekil 3'te verilmiştir.

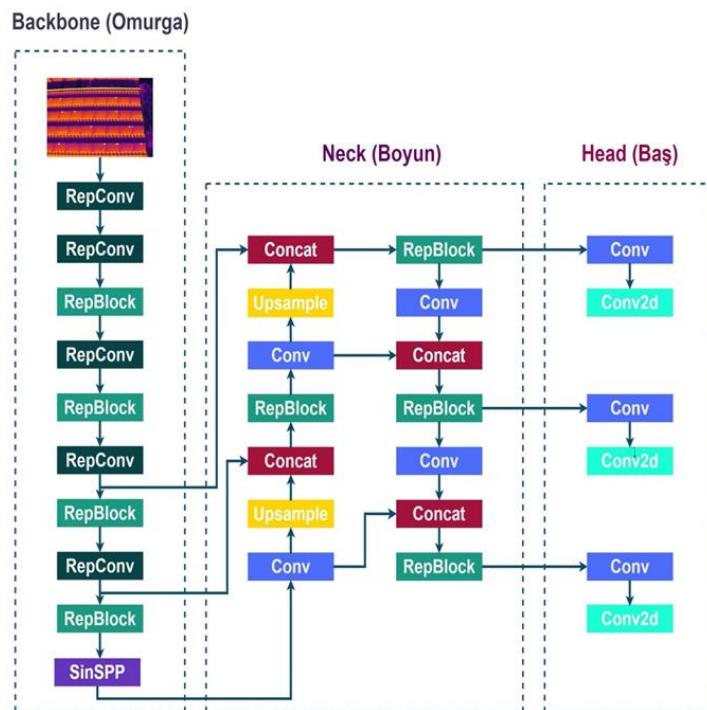


Şekil 3. YOLOv5 model mimarisi [19].

YOLOv5 algoritması, boyut ve model parametrelerinin miktarına göre artan dört farklı ağ modeli mimarisine ayrılabilir. Bunlar; YOLOv5s, YOLOv5m, YOLOv5l ve YOLOv5x mimarileridir. Bu mimariler arasında YOLOv5s ağının hızla hesaplama hızına ve en düşük ortalamaya kesinlik özelliğine sahiptir. YOLOv5x ağının ise YOLOv5s ağının tam tersi özelliğine sahiptir [19]. YOLOv5 ağ mimarisini backbone (omurga), neck (boyun) ve head (baş) kısmı olmak üzere üç ana bölümden oluşturmaktadır. Omurga üzerindeki ESA katmanında, giriş görüntüsünün farklı ölçeklerdeki öznitelikleri çıkarılmaktadır. Boyun kısmı, omurgadan aldığı görüntü özelliklerini kullanarak farklı görüntü taneciklerinde toplar ve özellik haritası oluşturur ve bunları tahmin katmanına taşır. Baş kısmında ise, sınırlayıcı kutular ve tahmin edilen kategoriler oluşturmak için görüntü özelliklerini tahmin eder [20, 21].

2.2.2. YOLOv6 algoritması

YOLOv6 modeli, 2022 yılında Meituan Görsel Zekâ Departmanı tarafından çoklu nesneler üzerinde iyi algılama performansı sonuçları ve yüksek çıkış hızı ile önerilmiştir [22]. YOLO mimarisini temelinde inşa edilmiş ve daha yüksek doğruluk, daha hızlı performans ve daha fazla ölçeklenebilirlik özellikleri sağlamak üzere tasarlanmıştır. YOLOv6 modeli, Python programlama dili kullanılarak PyTorch kütüphanesi ile yazılmıştır [18]. Ayrıca, omurga, boyun ve baş yapısını donanıma göre yeniden tasarlayarak çeşitli iyileştirmeler ve yeni yöntemler sunmuştur [23]. Şekil 4'de model mimarisini verilen YOLOv6 modeli, önceki YOLO mimarilerinden daha az parametre kullanarak daha yüksek doğruluk elde etmek için EfficientRep tabanlı yeni bir omurga tasarlanmıştır. Boyun bölümü için, değerlendirme sonuçları ile nesne algılama hızı arasında iyi bir denge sağlamak için Rep-PAN uygulamıştır [22]. Boyun kısmında, önceki YOLO modellerinde kullanılan 3x3 konvolüsyon katmanları yerine, 1x1 ve 3x3 konvolüsyon katmanlarından oluşan bir yapı kullanılmıştır. Ayrıca Global Average Pooling (GAP) işlemi yerine, Spatial Pyramid Pooling (SPP) işlemi kullanılmıştır [23].

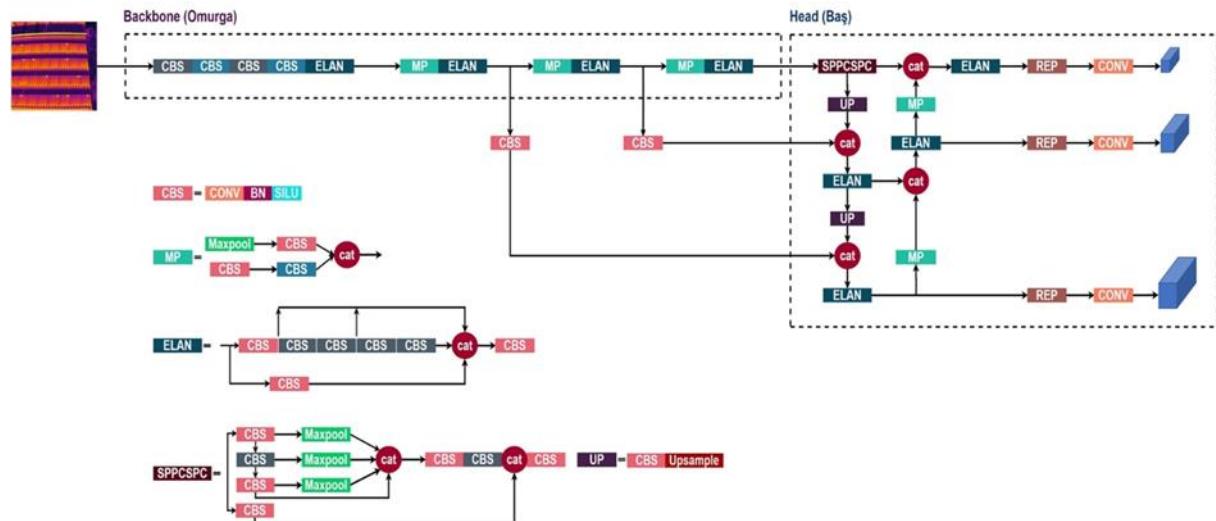


Şekil 4. YOLOv6 model mimaris [23].

2.2.3. YOLOv7 algoritması

YOLOv7 algoritması, OpenCV AI Kit (OAK) tarafından geliştirilen bir sürümdür ve ilk olarak 2022 yılının temmuz ayında piyasaya sürülmüştür [24]. YOLO serisi algoritması içinden geliştirilmiş algılama hızı en hızlı ve en doğru gerçek zamanlı nesne dedektörü olduğu iddia ediliyor [25]. YOLOv7 uçtan uça gerçek zamanlı YOLOv5'e benzer bir yapıya sahiptir. Ancak YOLOv7 de evrişimli katmanlar kullanır ve bu da YOLOv7'yi

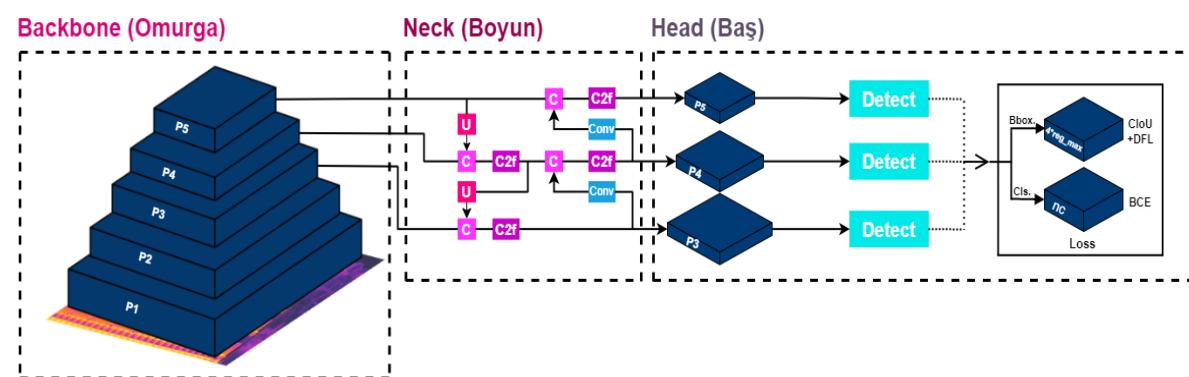
evrişimli bir ağ yapar [26]. YOLOv7 algoritmasının derin öğrenme çerçevesi, PyTorch derin öğrenme çerçevesi kullanılarak geliştirilmiştir. Ayrıca derin öğrenme modelinin oluşturulması ve eğitilmesi için TensorFlow derin öğrenme çerçevesinde kullanılabilir. PyTorch çerçeve algoritması akademisyenlerin araştırmalarında, TensorFlow çerçeve algoritması ise mühendislerin uygulama geliştirmesinde elverişlidir [26]. YOLOv7 ağ mimarisini omurga, boyun ve baş kısmı olmak üzere üç ana bölümden oluşmaktadır. YOLOv7 algoritmasının ağ modelinin omurga ağı temel olarak evrişim, ELAN modülü, MPCConv modülü ve SPPCSPC modülünden oluşur [27]. YOLOv7 model mimarisini Şekil 5'de verilmiştir.



Şekil 5. YOLOv7 model mimarisı [27]

2.2.4. YOLOv8 algoritması

YOLOv8, Ocak 2023'te YOLOv5'i geliştiren Ultralytics şirketi tarafından piyasaya sürüldü [27]. YOLOv8 algoritması, yüksek doğruluk ve hız elde ettiği kanıtlanmış son teknoloji bir nesne algılama modelidir [28, 29]. Şekil 6'da model mimarisini verilen YOLOv8 algoritmasının ağ mimarisini omurga, boyun ve baş kısmı olmak üzere üç ana birleşenden oluşmaktadır.



Şekil 6. YOLOv8 model mimarisı [30].

YOLOv8 algoritması yeni bir mimariye, iyileştirilmiş evrişimli katmanlara omurga ve daha gelişmiş bir algılama kafasına sahiptir [27]. YOLOv8 algoritması bir görüntüyü daha küçük bölgelerden oluşan bir ızgaraya bölgerek her nesne için bir sınırlayıcı kutu ve sınıf olasılıkları tahmin ederek çalışır [28]. YOLOv8 algoritması, özellik çıkartma sürecini iyileştirmek için YOLOv7 ağından daha hızlı ve daha hassas olan Darknet-53 omurga

ağıını kullanır. Darknet-53, 53 katmanlı evrişimli bir sinir ağıdır ve evrişimsel ağı nedeniyle önceki sürümlerden daha etkilidir [28-30]. YOLOv8 algoritmasının önceki YOLO sürümlerine göre en önemli iyileştirmelerden biri, eğitim sürecinde farklı konfigürasyonlara sahip birden fazla modelin kullanılmasını içeren Pseudo Supervision (PS) adlı bir teknik içermesidir. YOLOv8 algoritması, nesne algılamanın doğruluğunu ve sağlamlığını artırmak için DarkNet-53, PS ve YOLOv4 mimarisini birleştirir. YOLOv8 mimarisi boyut ve model parametrelerinin miktarına göre artan beş ağ modeli mimarisine ayrılabilir. Bunlar; YOLOv8n-seg, YOLOv8s-seg, YOLOv8m-seg, YOLOv8l-seg ve YOLOv8x-seg mimarileridir [29].

3. Deneysel Çalışmalar ve Sonuçlar

Kapsamlı gerçekleştirilen deneysel çalışmalarında, colab ortamında gerçekleştirilmiştir. Bu çalışmada, nesne tespiti ve sınıflandırma alanında oldukça popüler olan YOLO algoritması kullanılmıştır. Bu algoritmanın YOLOv5, YOLOv6, YOLOv7 ve YOLOv8 modelleri, güneş panellerindeki sıcak nokta kusur tespiti için adapte edilmiştir. Bu deneysel çalışmalarında, insansız hava aracı ile elde edilen 100 görüntü kullanılmıştır. Bu veri kümesinin %80 eğitim kümesi olarak kullanılırken, test kümesi için ise %20'si kullanılmıştır. Ayrıca, eğitim kümesi için yatay ve dikey dönüşüm, parlaklık değişimi ve görüntü döndürme gibi veri artırma teknikleri kullanılarak görüntü sayısı 240'a çıkartılmıştır. Bu sayede, daha iyi eğitim gerçekleştirilmesi ve bu sayede test performansının artırılması amaçlanmıştır.

Deneysel çalışmalarında, YOLO algoritmalarının performansını değerlendirmek için Duyarlılık (Duy), Özgüllük (Özg) ve Ortalama Duyarlılık (mAP) değerleri kullanılmıştır. Bu değerler ile ilgili matematiksel formüller Denklem (1-3)'de verilmiştir.

$$\text{Özg} = \frac{TP}{TP+FP} \quad (1)$$

$$Duy = \frac{TP}{TP+FN} \quad (2)$$

$$mAP = \frac{1}{n} \sum_{k=1}^n AP_k \quad (3)$$

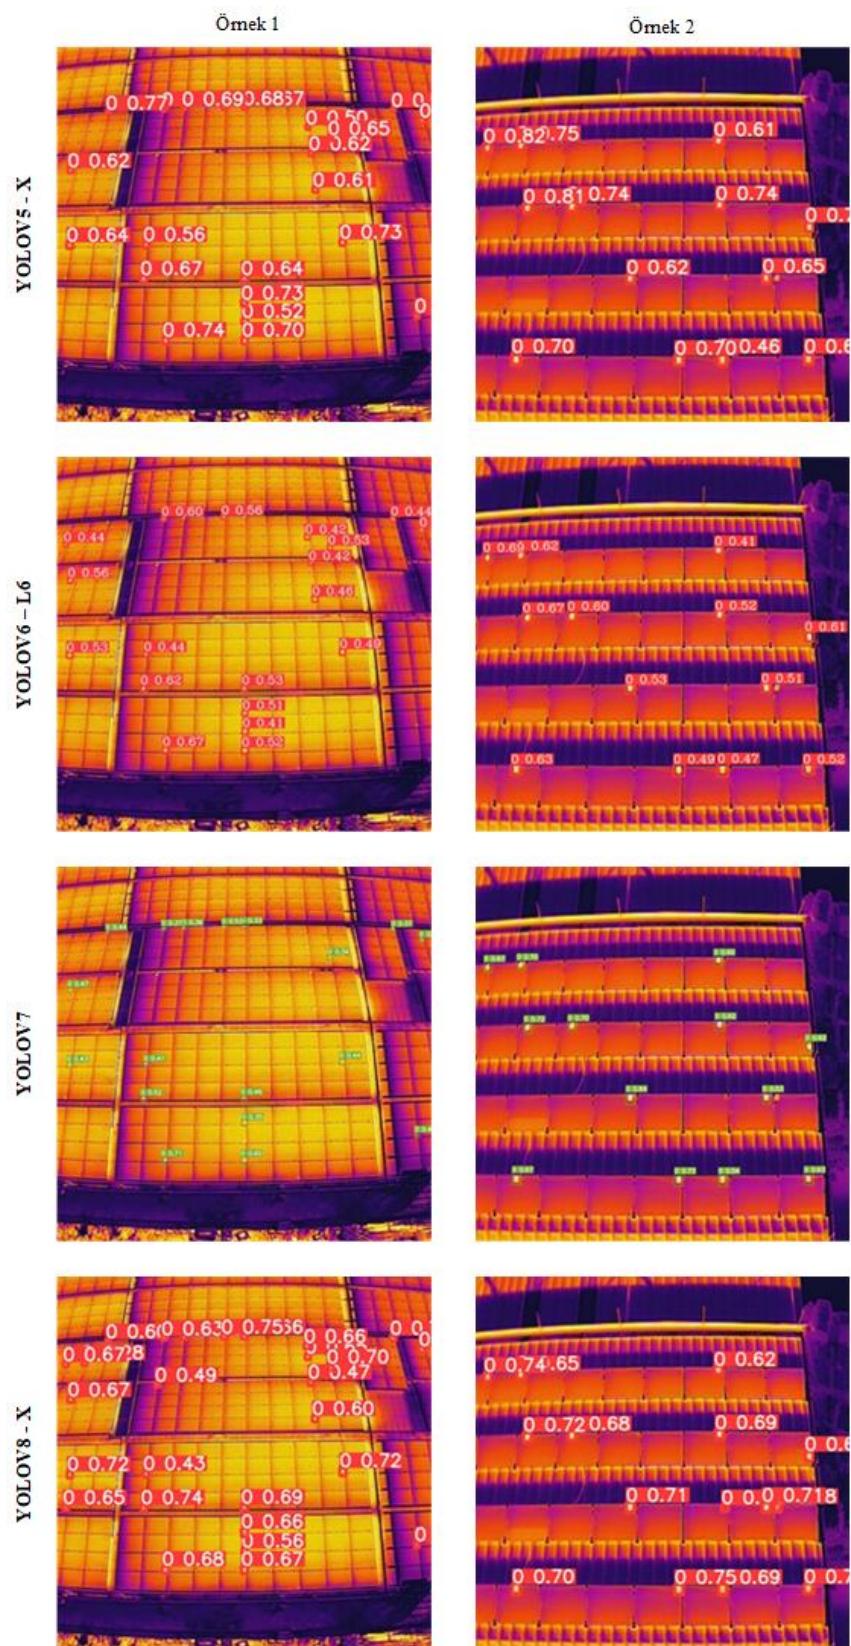
Burada TP karmaşıklık matrisindeki doğru pozitiflerin, FP hatalı pozitiflerin ve FN hatalı negatiflerin sayılarını göstermektedir.

Güneş panellerindeki sıcak nokta kusur tespiti için adapte edilen YOLO algoritmalarının eğitim aşamasında, eğitim tur sayısı (epoch) 100, parti boyutu (batch size) 16, öğrenme katsayıısı 0.0001 ve optimizasyon algoritması Stochastic Gradient Descent (SGD) olarak belirlenmiştir. Bu deneysel çalışma sonuçları performans değerlendirme ölçütlerine göre Tablo 1'de verilmiştir.

Tablo 1. YOLO modellerinin performansları (%)

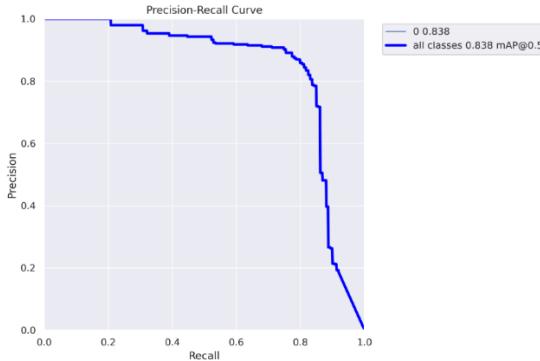
| Model | Versiyon | Özgüllük | Duyarlılık | mAP@.5 |
|--------|----------|----------|------------|--------|
| YOLOV5 | X | 62,60 | 53,50 | 52,90 |
| | X6 | 87,40 | 65,30 | 75,20 |
| YOLOV6 | M | - | - | 59,98 |
| | L6 | - | - | 67,46 |
| YOLOV7 | X | 72,54 | 69,77 | 68,79 |
| | N | 80,20 | 76,30 | 79,00 |
| YOLOV8 | M | 87,30 | 73,50 | 78,50 |
| | X | 88,70 | 80,50 | 83,80 |

Tablo 1'de, YOLO algoritmasına dayalı YOLOV5, YOLOV6, YOLOV7 ve YOLOV8 modelleri ile bu modellere ait versiyonlarının performans sonuçları verilmiştir. Bu sonuçlara göre, bu modeller arasında en iyi performans, YOLOV8x modeli ile %88.7 özgüllük, %80.5 duyarlılık ve %83.8 mAP değerleri elde edilmiştir. Diğer yandan, en iyi ikinci performans ise YOLOV5x modeli üretmiştir. Ayrıca, tüm YOLO modellerinin sonuçları incelendiğinde, tümünde en geniş kapsamlı versiyonları yüksek performans göstermiştir. Tablo 1'de en iyi performansa sahip YOLO modellerinin görsel sonuçları Şekil 7'de verilmiştir.



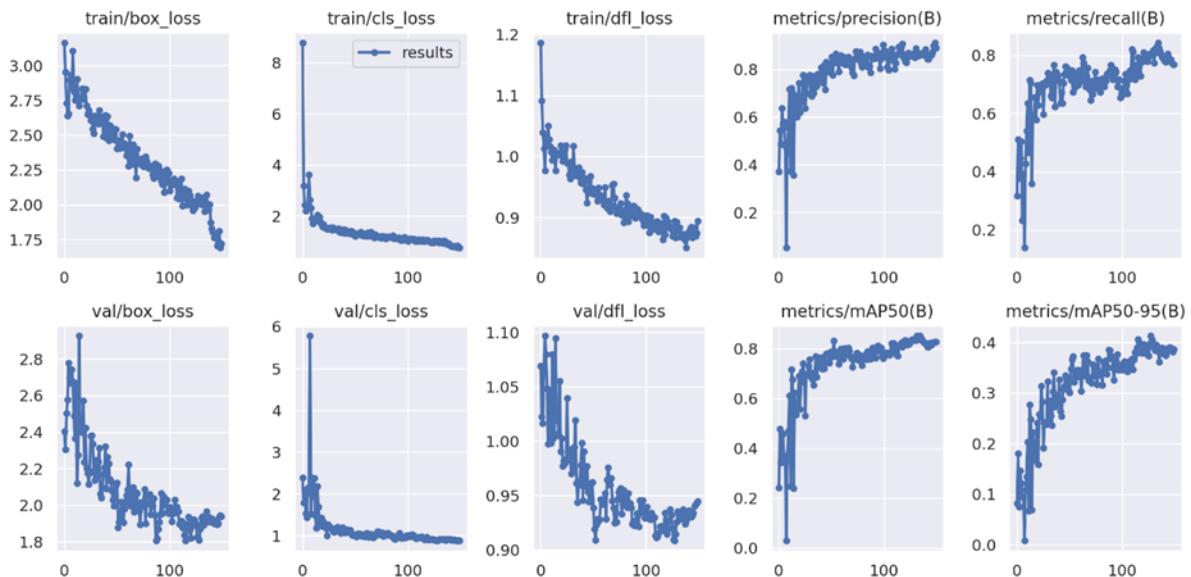
Şekil 7. YOLO modellerinin görsel tahmin sonuçları.

Şekil 7'den anlaşılacağı üzere, en iyi performansa sahip YOLOv8x modelinin, hemen hemen tüm sıcak nokta hatalarını doğru tespit etmiştir. Ayrıca Şekil 8'de verilen özgüllük-duyarlılık eğrisi de bu başarımı ortaya koymaktadır.



Şekil 8. YOLOv8 modelin özgüllük-duyarlılık eğrisi

Şekil 7'deki veriler yakından incelendiğinde, tespit sonuçları 0 ile %75 arasında bir değer dağılımı sergilemektedir. Bu sonuçlar, modelin tek bir sınıfı (var/yok) tespit etme görevini gerçekleştirdiğini göstermektedir. Bu değerlendirme, modelin güneş panellerini başarılı bir şekilde tespit etme yeteneğini yansımaktadır. Ayrıca, %50'nin üzerindeki tespit sonuçları, modelin görevini yerine getirdiğini ve güneş panellerini doğru bir şekilde tanımladığını göstermektedir. Elde edilen bu sonuçlar, modelin Sıcak nokta Kusurlarının Tespiti konusundaki başarı ve güvenilirligini vurgulamaktadır. Diğer yandan, bu modelin eğitim (train) ve kayıp (loss) grafikleri Şekil 9'da verilmiştir.



Şekil 9. YOLOv8 modelinin eğitim/kayıp grafikleri.

Şekil 8'de sunulan grafiklerden anlaşılacağı üzere, modelin doğruluğunu artırma ve kaybı azaltma yönünde olumlu bir eğilim gözlenmektedir. Grafikleri incelediğimizde, eğitim sürecinin başlangıcından itibaren modelin hızla öğrenmeye başladığını ve bu öğrenmenin 100 iterasyon sonrasında yavaş bir şekilde öğrenmeye devam ettiğini görülmektedir. Buna ek olarak, grafikler aynı zamanda modelin öğrenme hızının başlangıçta daha yüksek olduğunu ve zamanla yavaşladığını işaret etmektedir.

Deneysel çalışmaların kapsamında, modelimizin performansını çeşitli açılardan değerlendirmek için iki farklı yaklaşım benimsendi. İlk olarak, veri setini %80 eğitim ve %20 test olarak bölgerek, modelin bu bölünmüş veri seti üzerindeki performansı incelendi. Bu yaklaşım, modelin temel performansını belirlememizde önemli bir rol oynadı. İkinci olarak, daha fazla güvenilirlik sağlamak amacıyla 10 kat çapraz doğrulama yöntemini kullanıldı. Her bir çapraz doğrulama katmanı, veri setini 10 eşit parçaaya böldü ve her bir parça sırayla test verisi olarak kullanıldı, geri kalanlar ise eğitim verisi olarak kullanılmıştır. Bu yöntem, modelin performansının varyasyonunu daha ayrıntılı bir şekilde analiz etmemize olanak sağladı. YOLOv8 algoritmasının performansını değerlendirdiğimizde elde ettigimiz sonuçlar oldukça tatmin ediciydi. Bu model, güneş paneli tespiti görevinde %79 özgürlük, %78 duyarlılık ve %81 mAP gibi yüksek performans değerleri üretti. Bu sonuçlar, YOLOv8 algoritmasının güneş paneli kusurlarını etkili bir şekilde tespit edebildiğini ve güvenilir sonuçlar ürettiğini açıkça gösteriyor. Bu başarı, güneş enerjisi santrallerindeki Sıcak nokta kusurlarının tespiti konusundaki potansiyel uygulamaları daha da vurguluyor.

4. Sonuç

Bu çalışma, güneş panellerindeki sıcak nokta kusur tespiti için YOLO tabanlı bir derin öğrenme modeli önerilmektedir. YOLO algoritmaları, tek bir seferde görüntüdeki nesneleri tespit edebilme konusunda insan gözünden daha hızlı ve doğru sonuçlar elde edebilme yeteneğine sahiptir. Bu özellikleri sayesinde, güneş enerji santralinin verimliliğini artırmak açısından önemli bir rol oynayabilir.

Sonuç olarak, bu çalışmada güneş panellerindeki sıcak nokta tespiti için YOLO algoritmalarını kullanılabiliğin ve performansı hakkında önemli bir bilgi sağlamaktadır. Deneysel çalışma kapsamında, orijinal olarak kaydedilmiş etiketlenmiş güneş paneli görüntülerini kullanarak YOLO algoritmalarının performansları karşılaştırılmıştır. Bu karşılaştırma sonucunda YOLOv8 algoritmasının %88.7 özgürlük, %80.5 duyarlılık ve %83.8 mAP değerleri ile diğer modellere göre daha iyi bir sonuç verdiği gözlemlenmiştir. Ayrıca, en iyi ikinci performans ise YOLOv5 modeli ile üretilmiştir. YOLOv5 ve YOLOv8 algoritmalarının, güneş enerjisi santrallerindeki kusurların tespiti etkili bir araç olduğu sonucuna varılmıştır. Elde edilen sonuçlar, güneş enerjisi santralleri için YOLO algoritmalarının kullanımının önemini vurgulamaktadır.

Güneş panellerindeki sıcak nokta kusurlarının tespiti, sadece güç verimliliğini artırmakla kalmaz, aynı zamanda güvenliği de sağlar. Kusurlu panellerin erken tespiti, yanım ve diğer tehlikeli durumların önlenmesine yardımcı olur. Ayrıca, güneş panellerindeki sıcak nokta kusur tespiti için YOLO algoritmalarının kullanımı, güç verimliliği ve güvenliği artırmada önemli bir araçtır. YOLOv5 ve YOLOv8 algoritmalarının yüksek doğruluk oranları, güneş enerjisi santrallerindeki kusurların hızlı ve doğru bir şekilde tespit edilmesine yardımcı olur. Bu çalışma, güneş enerjisi santrallerindeki bakım ve güvenlik uygulamalarının geliştirilmesinde faydalı olabilir.

Gelecek çalışmalarda, SSD ve Faster R-CNN gibi farklı nesne tespiti algoritmaları kullanılarak güneş panellerindeki kusurların tespiti için en iyi algoritmanın belirlenmesi planlanmaktadır. Ayrıca, bu çalışmada sunulan en iyi performansa sahip YOLO algoritması, uzaktan algılama teknikleri ile entegre edilerek, güneş panellerindeki kusurların tespiti için daha kapsamlı bir çözüm için odaklanılacaktır.

Teşekkür

Veri setinin oluşturulması sürecindeki desteklerinden dolayı Sines Enerjiye teşekkür ederiz.

Kaynaklar

- [1] Yilmaz F, Ozturk M, Selbas R. Investigation of the thermodynamic analysis of solar Energy-Based multi-generation plant for sustainable multi-generation. Sustainable Energy Technologies and Assessments, 2022; 53: 102461.
- [2] International Energy Agency (IEA). CO₂ Emissions in 2022. IEA, Paris, France. <https://www.iea.org/reports/co2-emissions-in-2022> (Erişim tarihi: Mayıs 2023)
- [3] International Energy Agency (IEA). Renewables 2022: Analysis and Forecast to 2027. IEA, Paris, France. <https://www.iea.org/reports/renewables-2022> (Erişim tarihi: Mayıs 2023)
- [4] Taşkin O. Kusurlu güneş panelinde (PV) verimlerin ölçülmesi. Uludağ Üniversitesi Mühendislik Fakültesi Dergisi, 2019; 24(1): 289-298.
- [5] Açıkgöz H, Korkmaz D. Elektrolüminesans görüntülerde arızalı fotovoltaik panel hücrelerin evrişimli sinir ağı ile otomatik sınıflandırılması. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 2022; 34(2): 589-600.
- [6] Dhimish M. Defining the best-fit machine learning classifier to early diagnose photovoltaic solar cells hot-spots. Case Studies in Thermal Engineering. 2021; 25, 100980.

- [7] Ali M. U. Khan H. F. Masud M. Kallu K. D. Zafar A. A machine learning framework to identify the hotspot in photovoltaic module using infrared thermography. *Solar Energy*. 2020; 208: 643-651.
- [8] Goudelis G. Lazaridis P. I. Dhimish M. A review of models for photovoltaic crack and hotspot prediction. *Energies*. 2022; 15(12): 4303.
- [9] Mustafa R. J. Gomaa M. R. Al-Dhaifallah M. Rezk H. Environmental impacts on the performance of solar photovoltaic systems. *Sustainability*. 2020; 12(2): 608.
- [10] Niazi K. A. K. Akhtar W. Khan H. A. Yang Y. Athar S. Hotspot diagnosis for solar photovoltaic modules using a Naive Bayes classifier. *Solar Energy*. 2019; 190, 34-43.
- [11] Chen J. Li Y. Ling Q. (2020, August). Hot-Spot Detection for Thermographic Images of Solar Panels. In 2020 Chinese Control and Decision Conference (CCDC); 22-24 August 2020; Hefei, China: IEEE pp. 4651-4655.
- [12] Prajapati N. Raj, A. Aiyar R. Paraye M. Detection and Identification of faults in a PV Module using CNN-based Algorithm. International Conference for Emerging Technology (INCET); 27-29 May 2022; Belgaum, India: IEEE pp. 1-5.
- [13] Afifah A. N. N. Suyuti A. (2020, December). Hotspot detection in photovoltaic module using Otsu thresholding method. In 2020 IEEE International Conference on Communication, Networks and Satellite (Comnetsat); 17-18 December 2020; Batam, Indonesia: IEEE. pp. 408-412.
- [14] Cipriani G. Boscaino V. Di Dio V. Cardona F. Zizzo G. Di Caro S. (2019, June). Application of thermographic techniques for the detection of failures on photovoltaic modules. In 2019 IEEE international conference on environment and electrical; 11-14 June 2019; Genova, Italy: IEEE. pp. 1-5
- [15] Ren Y. Yu Y. Li J. Zhang W. Design of photovoltaic hotspot detection system based on deep learning. The 2020 3rd International Conference on Computer Information Science and Artificial Intelligence (CISAI); 25-27 September 2020; Inner Mongolia, China: In *Journal of Physics: Conference Series* 1693(1) pp. 012075)
- [16] Ali M. U. Saleem S. Masood H. Kallu K. D. Masud M. Alvi M. J. Zafar A. Early hotspot detection in photovoltaic modules using color image descriptors: An infrared thermography study. *International Journal of Energy Research*. 2022;46(2):774-785.
- [17] Sun T. Xing H. Cao S. Zhang Y. Fan S. Liu P. A novel detection method for hot spots of photovoltaic (PV) panels using improved anchors and prediction heads of YOLOv5 network. *Energy Reports* 2022; 8: 1219-1229
- [18] Sevi M. Aydin İ. Akin E. YOLOv5 ile Topluluk Öğrenmesine Dayalı Olarak Ray Yüzeyindeki Kusurların Tespiti. Demiryolu Mühendisliği 2023; 17: 115-132.
- [19] Kıvrak O. Gürbüz M.Z. Performance Comparison of YOLOv3, YOLOv4 and YOLOv5 algorithms: A Case Study for Poultry Recognition. *Avrupa Bilim ve Teknoloji Dergisi* 2022; 38: 392-397.
- [20] Ağdaş M.T. Gülsençen Ş. Güvenlik Kameralarında Otomatik Silah ve Bıçak Tespit Sistemi: Karşılaştırmalı YOLO Modelleri. *Avrupa Bilim ve Teknoloji Dergisi* 2022; 41: 16-22.
- [21] Chen Z. Wu R. Lin Y. Li C. Chen S. Yuan Z. Zou X. (2022). Plant disease recognition model based on improved YOLOv5. *Agronomy* 2022; 12(2): 365
- [22] Azizah A. N. Fatichah C. Tajweed-YOLO: Object Detection Method for Tajweed by Applying HSV Color Model Augmentation on Mushaf Images. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)* 2023; 7(2); 236-245.
- [23] Wei, J., & Qu, Y. (2023). Lightweight improvement of YOLOv6 algorithm for small target detection. <https://www.researchsquare.com/article/rs-2687469/v1> (Erişim Tarihi: Mayıs 2023).
- [24] Dewi C. Chen A. P. S. Christanto H. J. Deep Learning for Highly Accurate Hand Recognition Based on Yolov7 Model. *Big Data and Cognitive Computing* 2023; 7(1): 53.
- [25] Tang F. Yang F. Tian X. Long-Distance Person Detection Based on YOLOv7. *Electronics* 2023; 12(6); 1502.
- [26] Chen J. Ma B. Ji C. Zhang J. Feng Q. Liu X. Li Y. Apple inflorescence recognition of phenology stage in complex background based on improved YOLOv7. *Computers and Electronics in Agriculture* 2023; 211: 108048.
- [27] Cao L. Zheng X. Fang, L. The Semantic Segmentation of Standing Tree Images Based on the YOLOv7 Deep Learning Algorithm. *Electronics* 2023; 12(4); 929.
- [28] Terven J. Cordova-Esparza D. A comprehensive review of YOLO: From YOLOv1 to YOLOv8 and beyond. *arXiv preprint arXiv* 2023;2304.00501.
- [29] Aboah A. Wang B. Bagci U. Adu-Gyamfi Y. Real-time multi-class helmet violation detection using few-shot data sampling technique and yolov8. In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition; 17-24 June 2023; Vancouver, BC, Canada: IEEE pp. 5349-5357.
- [30] Zhao H. Jin J. Liu Y. Guo Y. Shen Y. FSDF: A high-performance fire detection framework. *Expert Systems with Applications* 2024; 238: 121665.