

Panoramik Radyograflarda Anatomik Yer İşaretlerinin Yapay Zeka Destekli Otomatik Tespiti

Tayyip Özcan^{*1}, Rümeysa Karayılan¹, Serkan Yılmaz²

^{*1}Erciyes Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği, KAYSERİ

²Ömer Halisdemir Üniversitesi Diş Hekimliği Fakültesi
Ağız Diş ve Çene Radyolojisi ABD, NİĞDE

(Alınış / Received: 18.11.2024, Kabul / Accepted: 25.12.2024, Online Yayınlanma / Published Online: 30.12.2024)

Anahtar Kelimeler

Tıbbi Görüntü Analizi,
Evrişimsel Sinir Ağları,
Panoramik Radyografi,
Anatomik Yer İşaretleri,
YOLO

Öz: Bilişim çağı ve yapay zekayla beraber bilgisayar bilimi diğer bilim dalları ile bir arada yürütülmeye başlamıştır ve ihtiyaç doğrultusunda bu çalışmalar artmaktadır. Radyolojik inceleme alanında da bilgisayar bilimi önemini gün geçtikçe arttırmaktadır. Panoramik radyografi de bu anlamda önemli alanlardan birisidir. Genç hekimlerin ve hekim adaylarının herhangi bir teşhis koyarken klinik tecrübe yetersizliğinin olması gibi olumsuz durumlardan dolayı panoramik radyograflar için bir karar destek programı oluşturulması amaçlanmıştır. Bu çalışmada, farklı YOLO (You Only Look Once) modelleri kullanılarak panoramik radyografi üzerindeki anatomik yer işaretlerinin tespiti otomatik olarak gerçekleştirilmesi ve karşılaştırmalar sonucunda en iyi tespit sağlayan modele karar verilmesi sağlanmıştır. Çeşitli internet sitelerinden elde edilen panoramik radyografi görüntülerinden oluşan veri setlerinin birleşimi kullanılmıştır. Toplam 14 anatomik yer işaretinin otomatik tespiti yapılmıştır. Sonuçta kullanılan performans metriğine göre YOLOv5 için 0.790, YOLOv8 için 0.802, YOLOv11 için 0.810 değerlerine ulaşılmıştır. Modellerin performans değerleri karşılaştırıldığında, anatomik yer işaretlerinin otomatik tespiti için en uygun modelin YOLOv11 olduğu sonucuna varılmıştır.

Artificial Intelligence-Assisted Automatic Detection of Anatomical Landmarks in Panoramic Radiographers

Keywords

Medical Image Analysis,
Convolutional Neural
Networks,
Panoramic Radiography,
Anatomical Landmarks,
YOLO

Abstract: In the era of information technology and artificial intelligence, computer science is increasingly being integrated with other scientific disciplines to meet growing demands. Its significance in the field of radiological examinations is becoming more pronounced with each passing day. Panoramic radiography stands out as a key area in this regard. To address challenges such as the lack of clinical experience among young physicians and medical students, this thesis aims to develop a decision support system for panoramic radiographs. In this study, different YOLO (You Only Look Once) models were used to automatically detect anatomical landmarks on panoramic radiography and to decide on the model that provides the best detection as a result of comparisons. A combination of datasets consisting of panoramic radiography images obtained from various websites was used. A total of 14 anatomical points were automatically detected. As a result, values of 0.790 for YOLOv5, 0.802 for YOLOv8, and 0.810 for YOLOv11 were achieved based on the performance metric. When the performance values of the models were compared, it was concluded that YOLOv11 was the most suitable model for automatic detection of anatomical landmarks.

1. Giriş

Teknolojinin ilerlemesiyle birlikte diş görüntüleme yöntemleri çeşitlenmiştir. Panoramik radyografi gibi modern görüntüleme teknikleri, diş sorunlarının daha hızlı ve etkili bir şekilde teşhis edilmesini sağlamış, bu da ortodontik tedavilerde başarıyı artırmıştır. Panoramik radyografi, tüm ağız ve çene-yüz bölgesinin kapsamlı bir şekilde görüntülenmesini sağlayan ve bu nedenle vazgeçilmez bir araç olarak kabul edilen bir tekniktir. Bu yöntem, geniş bir anatomik alanı tek bir film üzerinde inceleme fırsatı sunar. Müdahaleci olmayan yapısı ve tek bir çekimde ayrıntılı bilgi sağlama kapasitesi, panoramik radyografiyi çağdaş diş hekimliğinde önemli bir araç yapmaktadır [1].

Günümüzde yapay zekâ, tıp alanında ilerlemesini her geçen yıl hızla arttırmasıyla beraber radyografik görüntülerin okunması ve analiz edilmesi konusunda da doktorların işini oldukça kolaylaştıracak bir yer almayı başarmıştır. Panoramik radyografide yapay zekâ yöntemlerinin uygulanması da gitgide artmaktadır. Yapılan çalışmaların anatomik yer işaretlerinden çok panoramik radyografilerde eksik dişi veya çürümüş olan dişi bulmak üzere olduğu görülmektedir.

Literatür taramasında bu alanda araştırmacıların yoğun bir şekilde çalıştığı görülmektedir. İncelenen bazı çalışmalarda tıbbi görüntülerde yapay zekanın yerine bakıldığında: Michael Tran Duong ve arkadaşları, radyoloji kursiyerlerine daha iyi öğretim sağlayabilmek için yapay zekanın nasıl geliştirilebileceğine odaklanmayı amaçlamışlardır. Radyoloji eğitimini arttırmak için yapay zeka ile entegre bir çerçeve vurgulamışlardır. Yalnızca "Yapay Zekâ ile Arttırılmış Radyoloji" konusuyla kalmayıp "Hassas Tıp Eğitimi" olarak bilinen eğitimin de yapay zekâ ile şekillendirilebileceğini savunmuşlardır. Ayrıca "Yapay Zekâ Destekli Hassas Tıp Eğitimi" konusunun kursiyer ve eğitmenlere öğretim etkileşimlerinin yanı sıra genel iş akışı verimliliği ve teşhis doğruluğunu geliştirmeyi öğretmek daha iyi hasta sonuçlarına yol açacağı görüşündedirler [2]. Selma Güzel ve arkadaşları, panoramik diş röntgenlerine dayalı bir otomatik diş algılama ve etiketleme sistemi sunmuşlardır. Diş tespiti ve diş etiketleme aşamalarıyla nihai amaçları postmortem (ölüm sonrası) ve antemortem (ölüm öncesi) diş radyografilerinin karşılaştırılarak ölümleri belirlemek olmuştur. Sistemde önce diş bölgeleri belirlenip algılama modülü her bölge için ayrı ayrı çalışmaktadır. SVM (destek vektör makinesi) tarafından sınıflandırılan modeller en uygun atlas tabanlı modele göre etiketlenir. Maliyet fonksiyonuna göre optimum model seçimi yapılmaktadır. Sonuç olarak uygulanan algoritmanın panoramik radyografik görüntülerde dişleri tespit etme ve etiketleme konusunda umut verici olduğu anlaşılmaktadır [3]. Li ve arkadaşları, Görüntü yer işareti tespiti alandaki başarılarına rağmen, anatomik işaretler arasındaki örtülü veya açık ilişkileri yakalamak için yüksek dereceli yapısal modellemelerin yeterince kullanılmadığını öngörmüşler ve çalışmalarında doğru anatomik yüz ve tıbbi (örneğin el, pelvis) yer işareti tespiti için topolojiye uyum sağlayan yeni bir derin grafik öğrenme yaklaşımı olan Derin Uyarlanabilir Grafik (Deep Adaptive Graph - DAG) sunmuşlardır. Önerdikleri yöntem, hem yerel görüntü özelliklerinden hem de küresel şekil özelliklerinden yararlanarak grafik sinyalleri oluşturmaktadır. İncelenen tüm veri kümelerinde önceki son teknoloji yaklaşımlarla karşılaştırdıkları niceliksel sonuçlar, hem sağlık hem de doğruluk açısından üstün performans göstermiştir [4]. İki boyutlu görüntülerde manuel yer işareti tespiti tıbbi uzmanlığa bağlıdır ve süreç zaman almaktadır. Bu nedenle Shoaleh Shahidi ve arkadaşları, görüntü kaydına dayalı olarak konik ışınli bilgisayarlı tomografi görüntüleri üzerindeki kraniyofasiyal yer işaretlerinin (kafatası noktaları - landmarklar) otomatik lokalizasyonunu yapabilen bir yazılım üretmek ve doğruluğunu değerlendirmek için bir çalışma yapmışlardır. Manuel(gözlemci) ve otomatik algılama yöntemleri arasındaki her görüntüdeki her bir dönüm noktasının koordinat mesafelerindeki farkları hesaplamışlar ve ortalama hatalar olarak rapor etmişlerdir. Sistemin güvenilirlik katsayısı 0,89 iken gözlemcilerin güvenilirlik katsayısı 0,87 olarak belirlenmiştir ve bu çalışmanın doğruluğunun kabul edilebilir olduğunu göstermektedir [5].

Radyografi alanında YOLO ile yapılan bazı çalışmalara bakıldığında ise: Ayyıldız ve arkadaşları, YOLOv5'in periapikal radyografilerde dişleri tespit etmek ve numaralandırmak üzere eğitilebileceği hipotezini doğrulamak için çalışmalarda bulunmuşlardır. Yaptıkları çalışma sonucunda modeli eğitip precision (kesinlik), recall (duyarlılık) ve F1 skorlarını sırasıyla 0,9548, 0,9882 ve 0,9712 şeklinde bulmuşlar ve bu da periapikal radyografilerdeki dişlerin tespitinde YOLOv5 ile son derece iyi sonuçlar elde edildiğini göstermiştir. Diş hekimlerinin radyografik muayene süresini hızlandırabileceği ve deneyimsiz diş hekimlerinin YOLOv5 kullanarak hata oranını azaltabileceği sonucuna varılmıştır [6]. Raşî c arkadaşlarıyla birlikte gelişmiş YOLOv8 kullanarak alt çenedeki radyolüsent lezyonları otonom bir şekilde tespit edip segmentlere ayırabilen derin öğrenme modeli geliştirmek için çalışmalar yapmıştır. Veri tabanını geliştirmek için radyografik görüntüler üzerinde çeviri, ölçekleme, döndürme, yatay çevirme ve mozaik efektleri gibi tekniklerle artırma işlemleri uygulamışlardır. Artırma yapılmadan elde edilen precision, recall, mAP@50 (Mean Average Precision) ve mAP@50-95 değerleri sırasıyla %76, %75,5, %75,1 ve %48,3 olarak kaydedilirken, artırma teknikleriyle bu değerler sırasıyla %100, %94,5, %96,6 ve %72,2'ye yükselmiştir. Sonuçlara bakıldığında, sürekli evrimi ve çeşitli tıbbi alanlara entegrasyonu ile derin öğrenme modelinin, hasta bakımında devrim yaratma potansiyeline sahip olduğunu belirtmişlerdir [7]. Widiyasri ve arkadaşları, dental implant planlamasını basitleştirebilecek ve hızlandırabilecek 2

boyutlu ve gri tonlamalı konik ışınli bilgisayarlı tomografi görüntülerine dayalı alveolar kemik ve mandibular kanal tespiti için otomatik ve eş zamanlı bir sistem önermişlerdir. Bu sistemde YOLOv4'ün etkili bir versiyonu olan Dental-YOLO'yu, düşük ve yüksek ölçeklerde iki ölçekli özellik haritalarıyla tanıtmışlardır. Sistem performansı ortalama %99,46 hassasiyete ulaşmıştır. Sonuçlar, Dental YOLO tespit sisteminin dental implant cerrahisi ve cerrahi öncesi tedavi planlaması için yararlı olabileceğini düşündürmüştür [8]. Zeren, ekibiyle beraber çalışmasında, proksimal femoral kırıkların tespiti için veri artırma teknikleri kullanılarak 820'ye çıkardığı 410 X-ışını görüntüsünü kullanarak YOLOv4 algoritması ile eğitim gerçekleştirmiştir. Modelin eğitimi sonucunda %90,33 doğruluk oranıyla çok tatmin edici sonuçlar elde edilmiştir. Model, üç kat daha hızlı, ortalama 1,4 saniyelik bir tespit süresiyle hız açısından doktorları geride bırakmıştır. Yapay sinir ağlarının proksimal femoral kırıkları doğru bir şekilde belirleyebileceği gösterilmiştir [9]. Almufareh ve arkadaşları, MRI'da (Manyetik Rezonans Görüntüleme) beyin kanserlerini sınıflandırmak ve tespit etmek için en son derin öğrenme mimarilerinden yararlanan iki önemli nesne tanımlama çerçevesi olan YOLOv5 ve YOLOv7'nin kapsamlı bir analizini ele almışlardır. Beyin tümörü veri seti, menenjiyomlar, gliyomlar ve hipofiz tümörleri dahil olmak üzere üç ayrı sınıfı kapsamaktadır. Tüm kategoriler için duyarlılık (recall) puanları sürekli olarak 0,78 eşiğini aşmıştır. Bu bulgular, YOLO modellerinin beyin tümörlerini hassas bir şekilde tespit etme potansiyelini doğrulamıştır [10]. Lu, arkadaşlarıyla gerçekleştirdiği çalışmada, fetal ultrason görüntülerinde kardiyak anatomik yapı konumu ve segmentasyonu için YOLOX tabanlı derin örnek segmentasyon sinir ağı önermişlerdir. Dört odacıklı görünümün 13 tip anatomik yapısı için önerilen modelin ilk örnek segmentasyon yöntemi olduğunu söylemişlerdir. Çalışma sonucunda ortalama 0,835 doğruluk elde etmişlerdir. Uyguladıkları yöntem tahmin hızı açısından en iyi performansı elde etmiştir [11].

Anatomik yer işaretleri, incelenen bölgenin anatomik oluşumlarının neler olduğunu gösteren yer işaretleridir. Panoramik radyografide anatomik yer işaretlerinin tespit edilmesi, teşhis, tedavi planlaması ve izleme dâhil olmak üzere çeşitli tıbbi uygulamalar için çok önemlidir. Bu çalışmada da panoramik radyografilerdeki anatomik yer işaretlerinin yapay zekanın bir alt dalı olan derin öğrenme yönteminin modellerinden YOLO versiyonlarının kullanılarak belirlenmesi, elde edilen sonuçlara göre en iyi modele karar verilerek dış hekimleri için hem doğru ve optimum bilginin sağlanması hem de zamandan tasarruf edilmesi planlanmıştır.

Bu çalışmanın ana katkıları şu şekilde sunulabilir:

- Arama motorları yardımı ile panoramik radyografi görüntülerinden yeni bir veri seti oluşturulmuştur.
- Oluşturulan veri setinde, en kritik 14 anatomik yer işareti, bu alanda uzman dış hekim tarafından etiketlenmiş ve model eğitime hazır hale getirilmiştir.
- Görüntü çoğullama yöntemlerinin performans etkisi incelenmiştir.
- Görüntü çoğullama ve YOLOv11 derin öğrenme modeli destekli önerilen yöntem ile en başarılı sonuç elde edilmiştir.

Çalışma bilgilerine daha ayrıntılı bir şekilde yer verilmesi için ikinci bölümde, kullanılan yöntemler ve materyaller kapsamlı bir şekilde açıklanmış, tercih edilme nedenleri ve önemleri belirtilmiştir. Üçüncü bölüm, yapılan araştırmalar sonucunda elde edilen bulguları detaylandırmaktadır. Dördüncü ve son bölümde ise bu bulguların sonuçları ve tartışmaları üzerinde durulmuştur.

2. Materyal ve Metot

Bu çalışmanın yöntem ve metot bölümü esasen iki ana aşamadan oluşmaktadır. İlk aşama, veri setinin hazırlanmasıyla ilgili süreçleri kapsamaktadır. İkinci aşamada ise, panoramik radyografilerdeki anatomik yer işaretlerinin otomatik olarak tespitini sağlamak amacıyla uygun derin öğrenme yönteminin seçilmesi ve yapılandırılması gerçekleştirilmiştir.

2.1. Veri Seti Oluşturma

Veri seti oluşturmak, bir derin öğrenme projesinin temel adımlarından biridir ve başarılı sonuçlar elde etmek için önemlidir. Veri seti oluştururken, projenin hedeflerine uygun ve güvenilir verileri toplamak ve düzenlemek kritiktir. İlk adım, projenin amacına uygun verileri tanımlamak ve kaynaklarını belirlemektir. Daha sonra, belirlenen kaynaklardan veri toplanmalı ve gerekli ön işleme adımları uygulanmalıdır. Bu ön işleme adımları, veri temizleme, eksik değerlerin doldurulması ve veri formatlarının standartlaştırılması gibi işlemler olabilmektedir.

Çalışma için çeşitli internet sitelerinden elde edilen panoramik radyografi görüntülerinden oluşan veri setlerinin birleşimi kullanılmıştır. Proje için gerekli olan panoramik radyograf görüntülerinin paylaşılması konusunda etik problemler yaşanabildiğinden isim olarak paylaşılan veriler de anonim olarak değiştirilmiştir.

2.1.1. Etiketleme Yöntemleri

Veri etiketleme bilindiği üzere, bir veri setindeki örneklerin doğru bir şekilde sınıflandırılması veya kategorize edilmesi işlemdir. Etiketleme yöntemlerini şu şekilde sıralamak mümkündür:

Manuel Etiketleme: İnsanların müdahalesini gerektirir ve genellikle el ile veya otomatik etiketleme algoritmalarıyla gerçekleştirilir. El ile etiketleme, insanların veri örneklerine bireysel olarak etiket eklemesiyle gerçekleşir ve bu yöntem yüksek kaliteli, hassas etiketler elde etmek için yaygın olarak kullanılır ama bu yöntem daha fazla zaman gerektirir.

Otomatik Etiketleme: Genellikle makine öğrenimi veya yapay zekâ algoritmaları kullanılarak gerçekleştirilir ve büyük miktarda veriyi hızlı şekilde işlemesine karşın, el ile etiketlemeye göre daha düşük doğruluk oranlarına sahip olabilmektedir.

Yarı Otomatik Etiketleme: Manuel ve otomatik etiketleme yöntemlerinin bir kombinasyonudur. Otomatik etiketlemeye göre daha yüksek doğruluk sağlarken, manuel etiketlemeye göre daha az zaman kaybına neden olur.

Kitle Kaynaklı Etiketleme: Birden fazla insan etiketleyicinin, genellikle çevrimiçi platformlar aracılığıyla veri etiketleme görevini tamamlamasıdır. Geniş veri setleri için etiketleme sürecini hızlandırır. Dikkatli bir değerlendirme ve doğrulama gerektirir.


Anatomik yer işaretlerinin bir uzman tarafından belirlenmesi ve gösterilmesi gerektiğinden etiketleme aşamasında uzmanlardan yardım alınmıştır. Etiketleme aracı olarak MakeSense kullanılmıştır. MakeSense, bir manuel etiketleme aracıdır ve insan doğruluğu, hassasiyeti gerektiren görevlerde mükemmel sonuçlar vermektedir. Aynı zamanda görüntü anotasyon projelerinde esneklik ve kontrol sunmaktadır. Bu nedenle, detaylı ve doğru etiketleme gerektiren bu projede MakeSense tercih edilmiştir.

2.1.2. Veri Ön İşleme ve Arttırma

İşlenecek veri seti üzerinde veri setinin çeşitliliğini ve kapsamını genişleterek modelin daha etkili şekilde öğrenmesini sağlayan veri boyutlandırma ve veri arttırma işlemleri gerçekleştirilmiştir.

Yeniden Boyutlandırma

Veri arttırma işlemi yapılmadan önce, görsellerin boyutları küçültülmüştür. Orijinal veri setlerinde yer alan görsellerin çözünürlüğü 2976 x 1536 pikseldir. Ancak, bu görseller 640 x 640 piksellik boyutlara indirilmiştir. Örnek bir yeniden boyutlandırma işlemi Şekil 1 ile sunulmuştur.



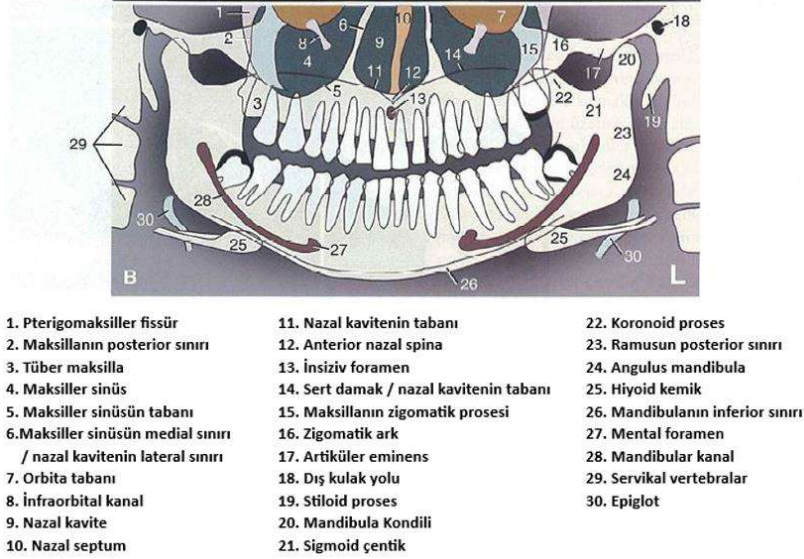
Şekil 1. Orijinal görsel ve boyutlandırılmış hali

Veri Arttırma

640 x 640 piksellik panoramik görüntülerin eğitim veri seti üzerinde Roboflow ile veri arttırma işlemleri gerçekleştirilmiştir. Bu işlemler flip (çevirme / tam aşağı döndürme), 90° rotate (90° çevirme) ve saturation %25 (%25 doygunluk ayarı)dır. Veri arttırma işlemlerinin ardından toplamda 767 yeni görüntü oluşturulmuştur.


Etiketlenen Anatomik Yer İşaretleri

Etiketleme işlemi için 767 adet görüntü kullanılmıştır. Eğitim için 706, validation (doğrulama) için 40 ve test için 21 görüntü bulunmaktadır. Veri kümesinden her bir gözlem bir panoramik görüntü ve birbirinin simetriği 7 bölgeden oluşan 14 yer işareti konumlarından oluşmaktadır.



Şekil 2. Anatomik yer işaretlerinin bölgesel ayrımı

Projede tespit etmek için kullanılan 7 yer işareti ve simetrikleri aşağıda örnek görsel üzerinde gösterilmiştir.



Şekil 3. Etiketlenen yer işaretlerinin örnek görüntü üzerinde gösterimi

Şekil 3 ile gösterilen yer işaretlerinin isimleri sırasıyla aşağıdaki gibidir:

- Üst Sarı Bölge: Mandibula kondili
- Mor Bölge: Koronoid proses
- Mavi Bölge: Tüber maksilla
- Yeşil Bölge: Mandibular kanal
- Turuncu Bölge: Mental foramen
- Kırmızı Bölge: Angulus mandibula
- Alt Sarı Bölge: Hiyoid kemik

Görsellerin etiketlenmesi uzun zaman aldığından anatomik yer işaretlerinin hepsinin etiketlenmesi yerine seçilen, 7 yer işareti simetriği olmak üzere, 14 yer işareti kullanılacak modellerle tespit edilmek üzere ele alınmıştır.


2.2. Önerilen Yöntem

Çalışma için kullanılacak YOLO modellerinin optimale yakın parametrelerle eğitilip en iyi sonuçların alınması için genel bir yöntem önerilmiştir. Rastgele Arama Yöntemi ile random (rastgele) bir şekilde farklı

hiperparametrelerin denenmesi ve optimale yakın parametrelerin model için uygulanması önerilen yöntemin temelini oluşturmaktadır. Yöntem şema halinde Şekil 4 ile daha net anlaşılmaktadır.

Derin öğrenme, doğal dil işleme, konuşma tanıma, nesne tanıma gibi çeşitli alanlarda kullanılan, çok katmanlı yapay sinir ağlarını temel alan bir yapay zekâ yöntemidir ve makine öğrenmesinin bir alt dalıdır. Geleneksel makine öğrenmesi yöntemlerinden farklı olarak, derin öğrenme sistemleri verileri (resimler, videolar, sesler ve metinler) doğrudan kodlanmış kurallar olmadan otomatik olarak analiz edebilir, bu verilerden öğrenebilirler [58]. Derin öğrenmede model seçimi, problemin çözüm sürecinde kritik bir rol oynar. Problemin özelliklerine uygun olarak seçilen model, çözümün etkinliğini artırabilir.

Bu çalışmada, otomatik panoramik radyograf analizi için yenilikçi bir yaklaşım önerilmiştir. Bu yaklaşım, çeşitli YOLO modellerinin (YOLOv5, YOLOv8, YOLOv11) tıbbi görseller üzerindeki instance segmentation (örnek segmentasyonu) başarısının kıyaslanması ve en uygun modele karar verilmesidir. Model, tek kanallı gri tonlu görüntüleri giriş olarak kullanmaktadır. Eğitim süreçlerini hızlandırmak amacıyla, tüm modeller 640 x 640 piksel boyutundaki görüntülerle eğitilmiştir. Uzmanlar tarafından manuel olarak belirlenen 30 panoramik anatomik yer işaretinden, 14'ü bu model aracılığıyla otomatik olarak elde edilmiştir.




Şekil 4. Önerilen yöntemin şematik gösterimi

2.2.1. YOLO (You Only Look Once) Modeli

YOLO (You Only Look Once), ESA tarafından öğrenilen özellikleri kullanarak videolarda, canlı yayınlarda veya görüntülerde belirli nesnelere hızlı ve verimli bir şekilde tanımlayan, özellikle nesne tespiti (object detection) için kullanılan gerçek zamanlı bir nesne algılama algoritmasıdır. YOLO'nun temel çalışma prensiplerinden biri, görüntü üzerinde "sadece bir kez" işlem yaparak hem nesne sınıflandırması hem de nesne konumlandırması yapabilmesidir. Model, Evrişimsel Sinir Ağları (Convolutional Neural Networks- CNN) temel alınarak geliştirilmiştir ve nesne tespitini, görüntüyü tek bir işlemde analiz ederek yapar. Normalde, derin sinir ağlarında tahminler yapmak için tam bağlı (fully connected) katmanlar kullanılır. Ancak, YOLO bu katmanlar yerine 1x1 evrişimleri verimli bir şekilde kullanarak, özellik haritasındaki bilgileri sıkıştırır ve daha az karmaşıklıkla tespitler yapar. Bu sayede, gerçek zamanlı uygulamalarda yüksek performans sunar. YOLO, tam da bu nedenden "sadece bir kez bakıyorsunuz" anlamına gelir.

Geleneksel nesne tespiti yöntemlerinden farklı olarak, YOLO görüntüyü gridlere böler ve her grid hücresi için potansiyel nesne tespiti yapar. Model, her grid hücresinde bir nesne olup olmadığını, nesnenin sınıfını ve sınır kutusu (bounding box) koordinatlarını tahmin eder. Bu model, hız ve doğruluğun bir arada gerektiği uygulamalar için oldukça uygundur. Nesnelere tespit etmek için tek bir CNN kullanarak görüntüdeki tüm nesnelere eşzamanlı olarak analiz etmesi, modeli diğer iki aşamalı modellerden (örneğin R-CNN) daha hızlı hale getirir. Bu nedenle, YOLO hem bilgisayarla görme (computer vision) hem de derin öğrenme uygulamaları için popüler ve etkili bir tekniktir [12]. YOLO'nun tüm versiyonları açık kaynaklıdır ve bu da onu araştırmacılar ve geliştirici topluluğu için erişilebilir hale getirir. Bu açık yapı, iş birliğini, iyileştirmeyi ve çeşitli uygulamaların geliştirilmesini teşvik etmektedir [13].



Şekil 5. YOLO model mimarisi [12]

2.2.2. Rastgele Arama Yöntemi (Random Search) ile Hiperparametre Optimizasyonu

Rastgele arama yöntemi, hiperparametre ayarlama süreçlerinde kullanılan bir optimizasyon tekniğidir. Bu yöntem, bir modelin performansını optimize etmek için hiperparametrelerin rastgele kombinasyonlarını belirli bir aralıkta veya kümede deneyerek en iyi sonuç veren kombinasyonu bulmaya çalışmaktadır. Hiperparametrelerin her biri için bir aralık veya olası değerler kümesi tanımlanır. Parametreler bu aralık veya kümeden rastgele seçilir. Her deneme için hiperparametre kombinasyonları bağımsız olarak oluşturulur. Rastgele seçilen hiperparametrelerle model eğitilir. Performans metrikleri (örneğin doğruluk, F1 skoru) ölçülerek en iyi kombinasyon belirlenir.

Yöntem kolayca uygulanabilir olduğundan ve hiperparametre alanında daha az deneme yaparak iyi sonuçlara ulaşabildiğinden avantajlıdır. Diğer taraftan, yöntemin rastgele doğası gereği, bazı önemli hiperparametre kombinasyonları denemeyebilir. Her zaman en iyi kombinasyonu bulamayabilir.

Eğitim sonucunda en iyi değerlerin alınması için öncelikle bazı hiperparametreler Rastgele Arama Yöntemi ile düzenli aralıklarla değiştirilip alınan sonuçlar karşılaştırılmış ve buna göre en iyi sonuçların alındığı hiperparametre değerlerine karar verilmiştir. Bu değerler belirlenirken alt ve üst sınır olarak genelde kullanılan optimum aralık baz alınmıştır. Epoch için [40,70] aralığı, batch size için [16,64] aralığı, learning rate için [0,001,0,1] aralığı belirlenmiştir. Denemeler yapılarak en uygun epoch değeri 60, en uygun batch değeri 32, learning rate oranı 0.01 olarak seçilmiştir.

2.2.3. Çalışma İçin Kullanılan Değerlendirme Metrikleri

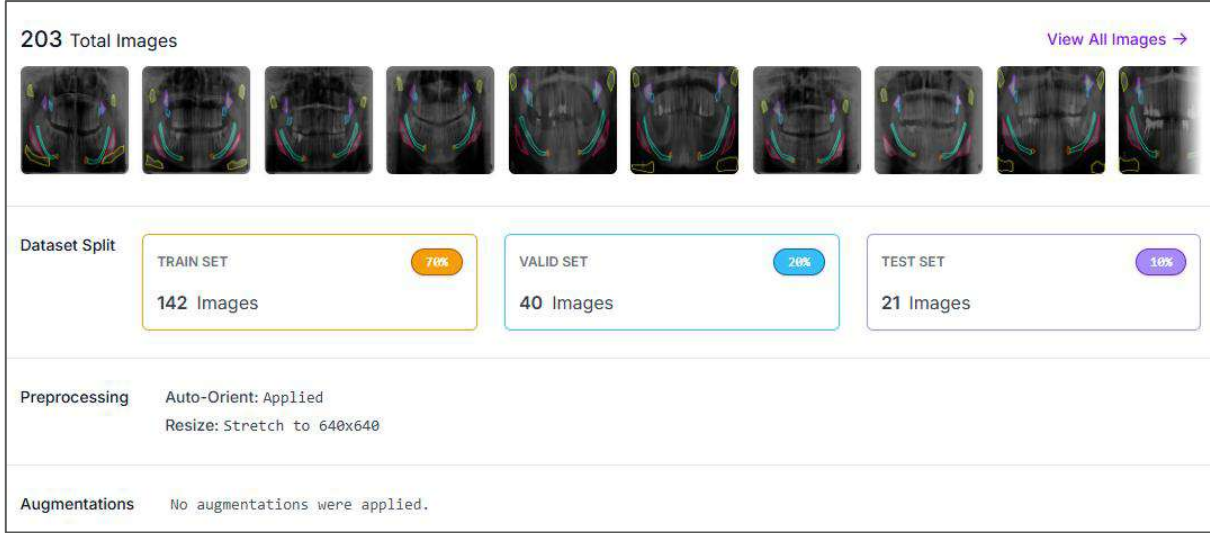
Çalışma YOLO modelleri ile anatomik yer işaretleri üzerinde instance segmentation (örnek segmentasyonu) olduğu için elde edilen sonuçlarda hem nesneyi içine alan box (kutu) değerlendirme metrikleri hem de mask (maske) değerlendirme metrikleri göz önünde bulundurulmuş ve iki ele alış şekline göre değerlendirmeler yapılmıştır. Box (kutu) hesaplamaları yalnızca nesnenin sınırlarını belirleyen kutuları hesaba katarken, mask (maske) hesaplamaları nesnenin tam şeklini yakalamaya çalışmaktadır. Bu nedenle, kutu ve maske tespiti için doğruluk oranları ve metrikler farklı olabilmektedir.

Genelde, maske tespiti için daha düşük değerler görülebilir çünkü maske tespiti daha karmaşık bir görevdir. Kutu doğru yerleştirilse bile, nesnenin şeklini doğru tahmin etmek, özellikle karmaşık nesnelere çalışırken, daha zor olmaktadır. İyi bir kutu (box) başarı tespit oranı, doğru konumlandırılmış nesnelere olduğu ve bu nesnelere şekil (mask) doğruluğunu da olumlu yönde etkileyeceğini göstermektedir. Ancak bazen şekil tespiti doğru olmasına rağmen, kutular yanlış yerleştirilebilmektedir. Bu nedenle box ve mask başarı tespit sonuçlarını beraber değerlendirmekte fayda vardır. Ayrıca iki konuyu aynı anda ele almak modelin hangi yönlerinin güçlü, hangi yönlerinin zayıf olduğunu belirlemekte yardımcı olabilmektedir.

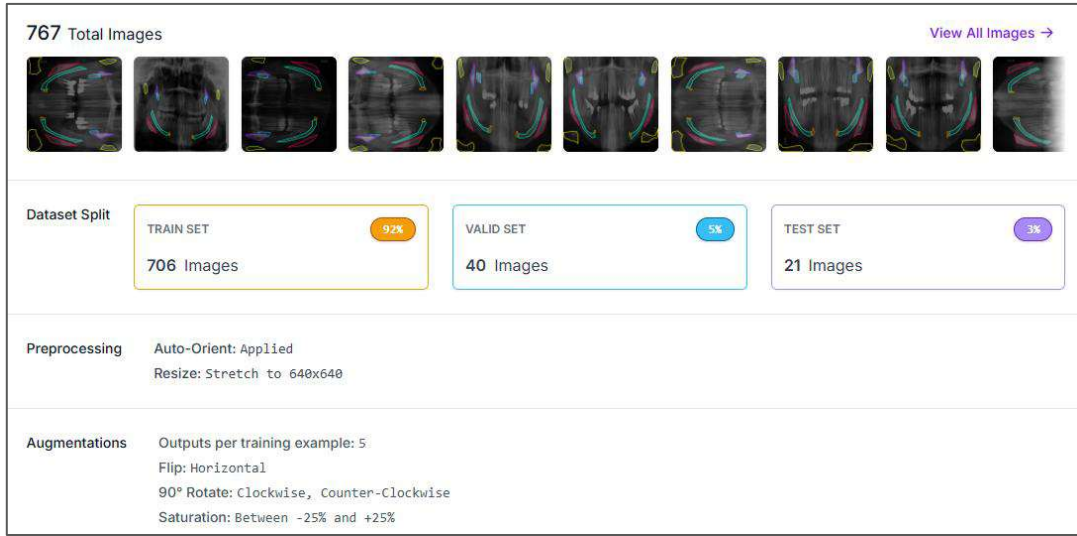
Tüm bu faktörler göz önünde bulundurulduğunda proje kapsamında analiz edilmesi gereken değerlendirme metrikleri box precision (BP - kutu kesinlik), box recall (BR- kutu duyarlılık), box mAP50 (BmAP50), box mAP50-95 (BmAP50-95), mask precision (MP - maske kesinlik), mask recall (MR - maske duyarlılık), mask mAP50 (MmAP50), mask mAP50-95 (MmAP50-95), box F1 (BF1), mask F1 (MF1), speed (çıkartım hızı) olarak ele alınmıştır.

3. Bulgular

Bu bölümde önerilen 3 modelin (YOLOv5, YOLOv8, YOLOv11) panoramik radyografi görselleri üzerinde anatomik yer işareti tespiti konusunda elde ettikleri başarı değerleri ve kayıplar değerlendirilip karşılaştırılmaktadır.



Şekil 6. 203 görüntünün ön işleme adımları



Şekil 7. Arttırma işlemleriyle oluşan 767 görüntü

Şekil 6.da gösterildiği gibi 203 görüntüden oluşan ve Şekil 7.de gösterildiği gibi çeşitli augmentation (arttırma) işlemlerinin yapılmasıyla oluşturulan 767 görüntüden oluşan 2 farklı veri seti üzerinde karar verilen hiperparametreler ile 2 farklı modelleme işlemleri yapılmış ve elde edilen değerler en sonda karşılaştırılarak gerekli değerlendirmeler yapılmıştır.

3.1. YOLOv5 ile Segmentasyon Sonuçları

YOLOv5, bilgisayarla görü uygulamalarında güçlü nesne tespiti ve segmentasyon performansı ile bilinen bir modeldir. Bu bölümde, YOLOv5 için elde edilen performans metriklerini ve eğitim sırasında kaydedilen önemli sonuçları incelenmektedir. Modelin tespit doğruluğu, mask (maske) ve box (kutu) açısından doğruluk değerleri, farklı kayıplar açısından analizi detaylı olarak tablolar ve grafikler halinde sunulmaktadır.

203 Görüntü ile Elde Edilen Değerler

Tablo 1. YOLOv5 203 Görüntü kutu için elde edilen değerler

Sınıflar	P	R	mAP50	mAP50-95	F1
Tümü	0.649	0.642	0.622	0.236	0.644
Coronoid	0.683	0.575	0.594	0.134	0.622
Foramenmentale	1.000	0.000	0.006	0.001	0.000
Hyoidbone	0.488	0.889	0.779	0.265	0.628
Mandibularangle	0.578	1.000	0.989	0.409	0.732
Mandibularcanal	0.953	1.000	0.995	0.586	0.974
Mandibularcondyle	0.458	0.825	0.690	0.189	0.586
Tubermaxilla	0.381	0.208	0.306	0.068	0.268

Tablo 1 ile görüldüğü üzere box (kutu) tespiti açısından modelin tüm sınıflarına bakıldığında istenen değerler alınmamıştır. Sınıf bazında bakıldığında yalnızca Mandibularcanal sınıfının kesinlik ve duyarlılık değerleri istenen seviyededir. Diğer sınıflara bakıldığında modelin doğru pozitif değerleri bulamadığı (Hyoidbone), güvenilirliğinin artırılması (Mandibularcondyle) ve doğruluğunun iyileştirilmesi gerektiği (Mandibularangle), yeterli etiketleme olmadığı ve sınıf dengesizliğinin olduğu (Foramenmentale) anlaşılmaktadır.

Tablo 2. YOLOv5 203 Görüntü maske için elde edilen değerler

Sınıflar	P	R	mAP50	mAP50-95	F1
Tümü	0.587	0.533	0.490	0.141	0.556
Coronoid	0.300	0.200	0.143	0.028	0.240
Foramenmentale	1.000	0.000	0.045	0.006	0.000
Hyoidbone	0.449	0.796	0.674	0.218	0.572
Mandibularangle	0.605	0.950	0.918	0.286	0.738
Mandibularcanal	0.769	0.800	0.684	0.164	0.382
Mandibularcondyle	0.472	0.812	0.689	0.211	0.596
Tubermaxilla	0.515	0.175	0.278	0.071	0.260

Tablo 2 ile mask (şekil) için elde edilen sonuçlara bakıldığında kutu tespiti bazında yapılan modellemelerden farklı olmadığı hatta değerlerin daha da düşük olduğu görülmektedir. Özellikle mAP50 ve mAP50-95 değerlerinin düşük olması modelin güvenilirliğinin az olduğunu göstermektedir ki bu durum da şekillerin istenen seviyede tespit edilememesinden kaynaklanmaktadır.

203 görüntü ile eğitim süresi 0.058 ölçülürken 767 görüntü ile 0.575 ölçülmüştür. Genel olarak eğitim süresiyle beraber hem box hem mask tespitleri açısından model incelendiğinde, veri setinin yeteri kadar büyük olmamasından kaynaklı, düşük başarı oranları elde edildiğinden aradaki eğitim süresi farkı göz ardı edilmiştir. Bunun neticesinde veri arttırımı işlemleri yapılarak modellerin eğitilmesine karar verilmiştir.

Arttırma İşlemi Sonrası Oluşan 767 Görüntü ile Elde Edilen Değerler

Mevcut 203 görüntüden oluşan veri seti üzerinde 3 farklı augmentation işlemleri yapıp sonuçta 767 veri elde edilmiştir. Veri setinin büyüklüğü arttıkça model başarısının da doğru orantılı bir şekilde artacağı göz önünde bulundurulduğundan YOLOv5 modeli başta olmak üzere YOLOv8 ve YOLOv11 modellerinin eğitimlerinde de artırma işlemi sonrası 767 görüntüden oluşan veri seti kullanılmıştır.

Tablo 3. YOLOv5 767 Görüntü kutu için elde edilen değerler

Sınıflar	P	R	mAP50	mAP50-95	F1
Tümü	0.847	0.853	0.832	0.390	0.848
Coronoid	0.826	0.838	0.783	0.241	0.830
Foramenmentale	0.532	0.525	0.442	0.120	0.526
Hyoidbone	0.841	0.870	0.857	0.401	0.854
Mandibularangle	0.980	0.988	0.986	0.506	0.982
Mandibularcanal	0.995	1.000	0.995	0.696	0.996
Mandibularcondyle	0.968	0.975	0.970	0.530	0.970
Tubermaxilla	0.785	0.775	0.788	0.236	0.778

Tablo 3 ile tahmin edilen kutu için elde edilen sonuçlara bakıldığında Mandibularange, Mandibularcanal ve Mandibularcondyle yer işareti bölgelerinin hem recall (duyarlılık) hem de precision (kesinlik) değerlerinin oldukça yüksek, F1 skorlarının da aynı şekilde yüksek olduğu görülmektedir. Bu da modelin bu anatomik bölgeleri doğru ve istikrarlı bir şekilde tanımlayabildiğini göstermektedir. Foramenmentale ise precision ve recall açısından en düşük değere sahip anatomik yer işareti bölgesi olmuştur. Bu da modelin bu bölgeyi tespit ederken zorlandığını göstermektedir.

Tüm bölgeler açısından bakıldığında genel olarak F1 skoru iyi sonuç vermiştir ancak, mAP50-95 değerlerine bakıldığında modelin genel tespit hassasiyetinin iyileştirilmesi gerektiği görülmektedir.


Tablo 4. YOLOv5 767 Görüntü maske için elde edilen değerler

Sınıflar	P	R	mAP50	mAP50-95	F1
Tümü	0.787	0.795	0.760	0.289	0.790
Coronoid	0.705	0.717	0.658	0.153	0.710
Foramenmentale	0.450	0.450	0.372	0.096	0.448
Hyoidbone	0.821	0.852	0.817	0.346	0.834
Mandibularangle	0.943	0.950	0.920	0.381	0.944
Mandibularcanal	0.870	0.875	0.858	0.260	0.872
Mandibularcondyle	0.988	0.996	0.994	0.576	0.990
Tubermaxilla	0.734	0.725	0.702	0.211	0.728


Tablo 4' teki gibi mask için elde edilen sonuçlarda da yine sınıflara göre bakıldığında Mandibularange, Mandibularcanal ve Mandibularcondyle yer işareti bölgelerinin hem recall (duyarlılık) hem de precision (kesinlik) değerlerinin nispeten en yüksek, F1 skorlarının da aynı şekilde yüksek olduğu görülmektedir. Modelin bu anatomik bölgeleri doğru ve istikrarlı bir şekilde tanımlayabildiğini gösterir demek mümkündür. Yine Foramenmentale, precision ve recall açısından en düşük değere sahip anatomik yer işareti bölgesi olmuştur. Bu da modelin bu bölgeyi tespit ederken zorlandığını göstermektedir.

Genel karşılaştırma yapıldığında modelin box yaklaşımında daha iyi bir sonuç verdiği açıktır. Bunun sebebi mask (şekil) tahmininin box (şekil etrafında bir kutu) tahmininden çok daha hassas detaylara sahip olması ve tahmin edilirliliğinin bu sebeple zor olmasıdır. Ayrıca, bu durum modelin konumlandırma konusunda başarılı olduğunu, ancak şekil segmentasyonu konusunda geliştirilmesi gerektiğini ortaya koymaktadır.

Sonuçlardan Elde Edilen Grafikler



Şekil 8. YOLOv5 kutu tespiti için elde edilen metrikler arası ilişkiler



Şekil 9. YOLOv5 maske tespiti için elde edilen metrikler arası ilişkiler

Şekil 8' de Box tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Mavi kalın çizgiyle gösterilen değer tüm sınıfların ortalamasını belirtmektedir.

Grafiklere bakıldığında mavi çizginin genel olarak başarılı sonuçlar elde ettiği ama turuncu çizgiyle belirtilen Foramenmentale sınıfının istenen sonuçları alamadığı gözlemlenmektedir.


Özellikle F1 - Confidence (F1 -Güven) grafiğine bakıldığında Foramenmentale değeri göz ardı edildiğinde sonuçların gayet başarılı olduğu söylenebilmektedir. Precision - Confidence (Kesinlik - Güven) grafiğine bakıldığında yine Foramenmentale sınıfı göz ardı edildiğinde diğer sınıfların oldukça yüksek performans sergilediği ve hatta kırmızı, mor ve kahverengi ile gösterilen Mandibularange, Mandibularcanal ve Mandibularcondyle sınıflarının 1'e yakın değerlerde ilerlediği görülmektedir. Aynı durum Recall - Confidence (Duyarlılık - Güven) grafiği için de geçerliliğini korumaktadır.

Mandibularcondyle sınıflarının 1'e yakın değerlerde ilerlediği görülmektedir. Aynı durum Recall - Confidence (Duyarlılık - Güven) grafiği için de geçerliliğini korumaktadır.

Şekil 9' da Mask tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Grafiks olarak box tespiti sonuçlarına benzer sonuçlar elde edildiği görülse de ayrıntılı bakıldığında tüm grafiklerde daha az başarı oranı olduğu açıkça gösterilmektedir.



Şekil 10. YOLOv5 kayıp değerleri



Şekil 11. YOLOv5 karmaşıklık matrisi

Şekil 10' da modelin box kayıp (box_loss), segmentasyon (mask) kayıp (seg_loss), object detection (nesne tespiti) kayıp (obj_loss) ve sınıf tespitindeki kayıp (cls_loss) değerlerinin eğitim sırasındaki skorları gösterilmektedir. Kayıp değerlerinin zamanla azalması ve ortalama olarak düşük değerler alması model açısından olumlu yorumlanmaktadır. Şekil 11' de ise YOLOv5 için Confusion (karışıklık) matrisi ile her bir sınıfın True (gerçek) değerleri olma oranları gösterilmiş ve doğruluk 1'e yaklaştıkça renk koyulaşmıştır. Confusion matrixe göre bakıldığında en iyi değeri alan sınıf yine Mandibularcanal'dır.

3.2. YOLOv8 ile Segmentasyon Sonuçları

YOLOv8, nesne tespiti ve segmentasyon görevlerinde geliştirilmiş bir model yapısı sunarak, daha yüksek hassasiyet ve hız hedeflemektedir. Bu bölümde, YOLOv8 ile yapılan deneylerin sonuçları karşılaştırmalı olarak analiz edilmektedir. Yine modelin kutu ve maske açısından doğruluğu, F1 skorları ve mAP değerleri üzerinde durulmaktadır. Sonuçlar tablo ve grafikler halinde gösterilmektedir. Eğitim sonucunda en iyi değerlerin alınması için öncelikle bazı hiperparametreler Rastgele Arama Yöntemi ile düzenli aralıklarla değiştirilip alınan sonuçlar karşılaştırılmış ve buna göre en iyi değerlerin alındığı hiperparametre değerlerine YOLOv8 modeli için karar verilmiştir. Epoch için [40,70] aralığı, batch size için [16,64] aralığı, learning rate için [0.001,0.1] aralığı belirlenmiştir. Denemeler yapılarak en uygun epoch değeri 70, en uygun batch değeri 32, learning rate oranı 0.01 olarak seçilmiştir.

Arttırma İşlemi Sonrası Oluşan 767 Görüntü ile Elde Edilen Değerler

Tablo 5. YOLOv8 kutu için elde edilen değerler

Sınıflar	P	R	mAP50	mAP50-95	F1
Tümü	0.844	0.860	0.840	0.423	0.850
Coronoid	0.798	0.793	0.781	0.246	0.794
Foramenmentale	0.543	0.562	0.492	0.112	0.552
Hyoidbone	0.821	0.889	0.856	0.478	0.852
Mandibularangle	0.983	1.000	0.995	0.504	0.990
Mandibularcanal	0.981	0.988	0.987	0.776	0.984
Mandibularcondyle	0.990	1.000	0.995	0.605	0.994
Tubermaxilla	0.794	0.787	0.774	0.241	0.788

Tablo 5' te tahmin edilen kutu için elde edilen sonuçlara bakıldığında yine Mandibularangle, Mandibularcanal ve Mandibularcondyle yer işareti bölgelerinin hem recall (duyarlılık) hem de precision (kesinlik) değerlerinin oldukça yüksek, F1 skorlarının da aynı şekilde yüksek olduğu görülmektedir. Bu da modelin bu anatomik bölgeleri doğru ve istikrarlı bir şekilde tanımlayabildiğini göstermektedir. Foramenmentale ise precision ve recall açısından en düşük değere sahip anatomik yer işareti bölgesi olmuştur. Tüm bölgeler açısından bakıldığında genel olarak F1 skoru iyi sonuç vermiştir ancak, mAP50-95 değerlerine bakıldığında yine modelin genel tespit hassasiyetinin iyileştirilmesi gerektiği görülmektedir.

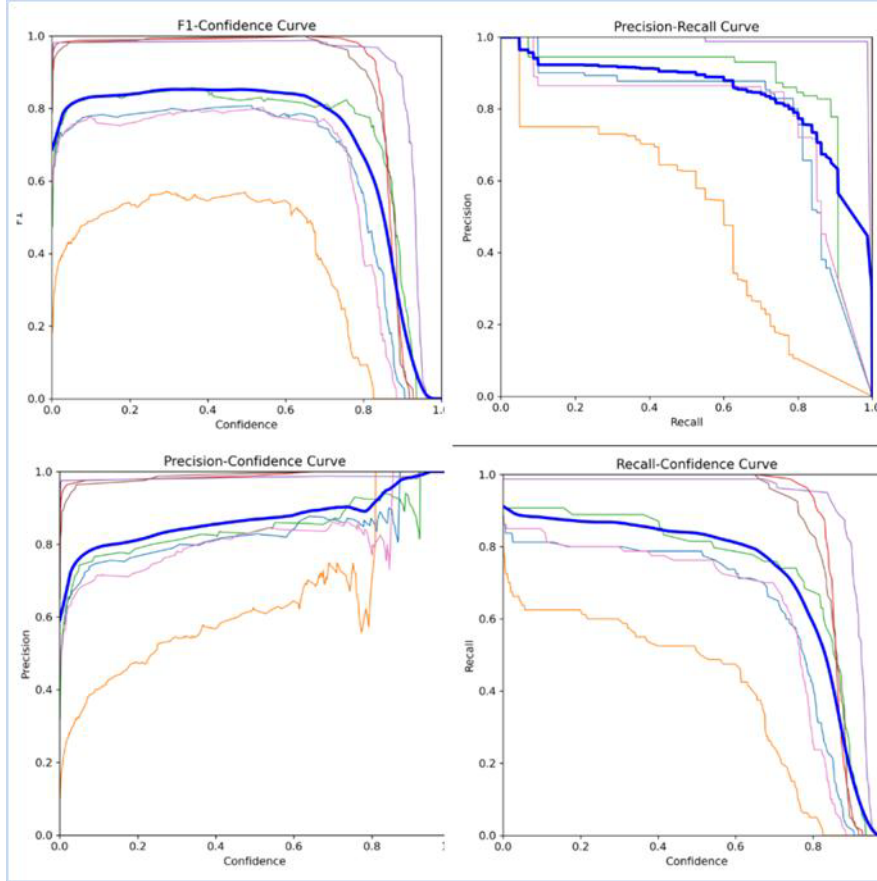
Tablo 6. YOLOv8 maske için elde edilen değerler

Sınıflar	P	R	mAP50	mAP50-95	F1
Tümü	0.818	0.792	0.786	0.327	0.802
Coronoid	0.669	0.637	0.596	0.147	0.652
Foramenmentale	0.572	0.487	0.431	0.111	0.524
Hyoidbone	0.814	0.796	0.853	0.385	0.802
Mandibularangle	0.975	0.988	0.989	0.443	0.980
Mandibularcanal	0.909	0.912	0.924	0.372	0.910
Mandibularcondyle	0.995	1.000	0.995	0.619	0.996
Tubermaxilla	0.791	0.725	0.716	0.216	0.754

Tablo 6 ile görüldüğü üzere mask için elde edilen sonuçlarda da yine sınıflara göre bakıldığında Mandibularange, Mandibularcanal ve Mandibularcondyle yer işareti bölgelerinin hem recall (duyarlılık) hem de precision (kesinlik) değerlerinin nispeten en yüksek, F1 skorlarının da aynı şekilde yüksek olduğu görülmektedir. Modelin bu anatomik bölgeleri doğru ve istikrarlı bir şekilde tanımlayabildiğini gösterir demek mümkündür.

Genel karşılaştırma yapıldığında modelin box yaklaşımında daha iyi bir sonuç verdiği açıktır. Bunun sebebi mask (şekil) tahmininin box (şekil etrafında bir kutu) tahmininden çok daha hassas detaylara sahip olması ve tahmin edilirliliğinin bu sebeple zor olmasıdır. Ancak, YOLOv8 segmentasyon konusunda daha başarılı olduğu için şekil değerleri YOLOv5'e göre daha iyi sonuç vermiştir. Ama mAP50-95 değerlerine bakıldığında tespit hassasiyetinin artırılması gerektiği görülmektedir.


Sonuçlardan Elde Edilen Grafikler



Şekil 12. YOLOv8 kutu tespiti için elde edilen metrikler arası ilişkilere


Şekil 12' de Box tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Mavi kalın çizgiyle gösterilen değer tüm sınıfların ortalamasını belirtmektedir. Grafiklere bakıldığında mavi çizginin genel olarak başarılı sonuçlar elde ettiği ama turuncu çizgiyle belirtilen Foramenmentale sınıfının istenen sonuçları alamadığı gözlemlenmektedir.

Özellikle F1 - Confidence (F1 -Güven) grafiğine bakıldığında Foramenmentale değeri göz ardı edildiğinde sonuçların gayet başarılı olduğu söylenebilmektedir. Hatta optimum seviyenin uzun bir süre korunduğu da gözlemlenmektedir. Precision - Confidence (Kesinlik - Güven) grafiğine bakıldığında yine Foramenmentale sınıfı göz ardı edildiğinde diğer sınıfların oldukça yüksek performans sergilediği ve hatta kırmızı, mor ve kahverengi ile gösterilen Mandibularange, Mandibularcanal ve Mandibularcondyle sınıflarının YOLOv5 sonuçlarına göre 1'e daha yakın değerlerde ilerlediği görülmektedir.




Şekil 13. YOLOv8 maske tespiti için elde edilen metrikler arası ilişkiler

Şekil 13 ile maske tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Grafikselsel olarak box tespiti sonuçlarına benzer sonuçlar elde edildiği görülse de yine mask için ayrıntılı bakıldığında tüm grafiklerde biraz az başarı oranı olduğu açıkça gösterilmektedir. Ama başarılı tespitin seviyesini uzun süre korumasının mask için de sağlanabildiği gözlemlenmektedir. Bu durum YOLOv8 modelinin segmentasyon için oldukça güçlü bir model olduğunun kanıtı niteliğinde sayılmaktadır.



Şekil 14. YOLOv8 kayıp tespiti

Şekil 14 ile modelin kaybının hızlı bir şekilde azaldığı, bounding box tahminlerinin hızla geliştirildiğini gösterilmektedir. Segmentasyon kaybının hızla düşüp, yavaşlayarak dengelendiği, modelin segmentasyon maskelerini öğrenmeye başladığı, süreç boyunca daha hassas hale geldiği görülmektedir. Sınıf tespitindeki kayıp hızla azalıp sabit bir noktaya yaklaşmakta, modelin sınıf tahminlerinde giderek daha az hata yaptığını göstermektedir. Bounding box koordinatları (dfl_loss - mesafe alan kaybı) ise modelin bounding box'ların konumunu daha hassas şekilde tahmin etmeye başladığını göstermektedir.



Şekil 15. YOLOv8 karmaşıklık matrisi

Şekil 15' te YOLOv8 için Confusion (karmaşıklık) matrisi ile her bir sınıfın True (gerçek) değerleri olma oranları gösterilmiş ve doğruluk 1'e yaklaştıkça renk koyulaşmıştır. Confusion matrisine göre bakıldığında en iyi değeri alan sınıflar Mandibularcanal, Mandibularangle ve Mandibularcondyle' dir.

3.3. YOLOv11 ile Örnek Segmentasyon Sonuçları

YOLOv11, daha yeni optimizasyon teknikleri ve model iyileştirmeleri içeren gelişmiş bir model sürümüdür. Bu bölümde, YOLOv11'in genel performansını detaylandırılmakta ve modelin yer işaretlerinin tespiti senaryolarındaki başarımı değerlendirilmektedir.

Önceki modellerde olduğu gibi aynı hiperparametreler Rastgele Arama Yöntemi değiştirilip sonuçlar karşılaştırılmış en iyi değerlerin alındığı hiperparametre değerlerine YOLOv11 modeli için karar verilmiştir. En uygun epoch değeri 60, batch değeri 32, learning rate oranı 0.01 olarak seçilmiştir.

Arttırma İşlemi Sonrası Oluşan 767 Görüntü ile Elde Edilen Değerler

Tablo 7. YOLOv11 kutu için elde edilen değerler

Sınıflar	P	R	mAP50	mAP50-95	F1
Tümü	0.855	0.839	0.832	0.433	0.846
Coronoid	0.817	0.800	0.830	0.287	0.806
Foramenmentale	0.689	0.500	0.493	0.143	0.578
Hyoidbone	0.826	0.889	0.857	0.464	0.854
Mandibularangle	0.949	0.975	0.966	0.505	0.960
Mandibularcanal	0.983	0.988	0.980	0.779	0.984
Mandibularcondyle	0.980	0.988	0.987	0.589	0.982
Tubermaxilla	0.739	0.738	0.709	0.263	0.736

Tablo 7 incelendiğinde tahmin edilen kutu için elde edilen sonuçlara bakıldığında yine Mandibularange, Mandibularcanal ve Mandibularcondyle yer işareti bölgelerinin hem recall (duyarlılık) hem de precision (kesinlik) değerlerinin oldukça yüksek, F1 skorlarının da aynı şekilde yüksek olduğu görülmektedir. Bu modelin bu anatomik bölgeleri doğru ve istikrarlı bir şekilde tanımlayabildiğini göstermektedir. Foramenmentale ise precision ve recall açısından en düşük değere sahip anatomik yer işareti bölgesi olmuştur yani model bu bölgeyi tespit ederken zorlanmıştır.

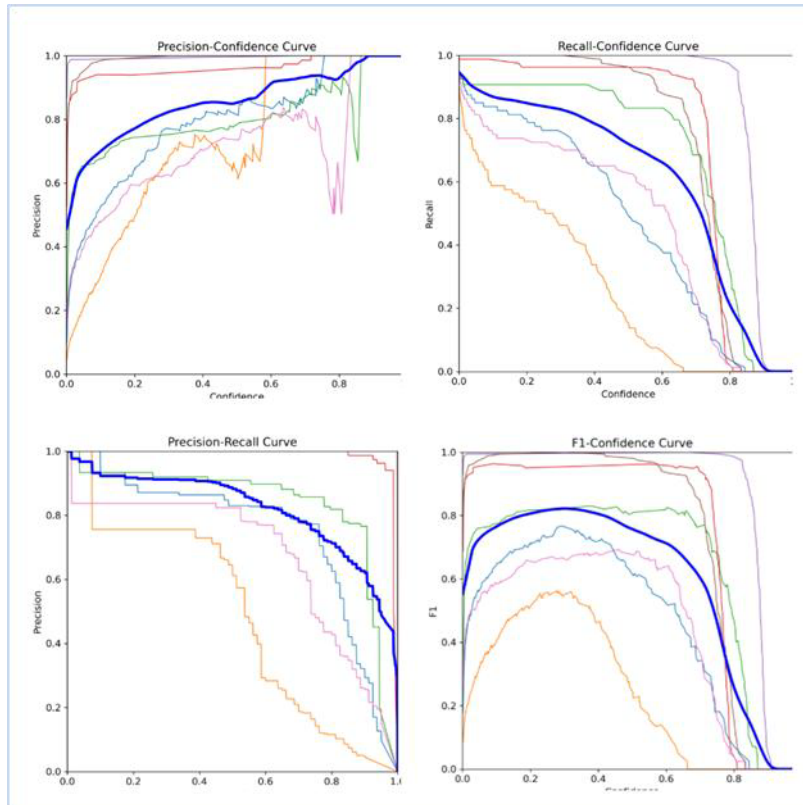
Tüm bölgeler açısından bakıldığında genel olarak F1 skoru iyi sonuç vermiştir, mAP50-95 değerlerine bakıldığında diğer modellere göre daha yüksektir ama modelin zorlayıcı eşik değerlerinde hala geride kaldığı söylenebilmektedir.

Tablo 8. YOLOv11 maske için elde edilen değerler

Sınıflar	P	R	mAP50	mAP50-95	F1
Tümü	0.823	0.800	0.795	0.330	0.810
Coronoid	0.683	0.662	0.650	0.169	0.672
Foramenmentale	0.681	0.450	0.462	0.124	0.270
Hyoidbone	0.793	0.852	0.786	0.359	0.820
Mandibularangle	0.963	0.988	0.980	0.439	0.974
Mandibularcanal	0.921	0.925	0.941	0.375	0.920
Mandibularcondyle	0.981	0.988	0.987	0.598	0.984
Tubermaxilla	0.740	0.738	0.759	0.248	0.738

Tablo 8 incelendiğinde modelin box yaklaşımında daha iyi bir sonuç verdiği açıktır. Bunun sebebi mask (şekil) tahmininin box (şekil etrafında bir kutu) tahmininden çok daha hassas detaylara sahip olması ve tahmin edilirliliğinin bu sebeple zor olmasıdır. Ancak, segmentasyon konusunda YOLOv8'e göre biraz daha iyi sonuç vermiştir. Ama mAP50-95 değerlerine bakıldığında tespit hassasiyetinin hala artırılması gerektiği görülmektedir.


Sonuçlardan Elde Edilen Grafikler



Şekil 16. YOLOv11 kutu tespiti için elde edilen metrikler arası ilişkiler


Şekil 16' da Box tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Mavi kalın çizgiyle gösterilen değer tüm sınıfların ortalamasını belirtmektedir. Grafiklere bakıldığında mavi çizginin genel olarak başarılı sonuçlar elde ettiği ama turuncu çizgiyle belirtilen Foramenmentale sınıfının istenen sonuçları alamadığı gözlemlenmektedir. Aynı zamanda önceki model grafikleriyle kıyaslandığında grafiklerdeki ortalamayı gösteren mavi çizginin YOLOv8deki gibi başarılı değerde uzun süre kaldığı söylenememektedir.

F1 - Confidence (F1 -Güven) grafiğine bakıldığında Foramenmentale değeri göz ardı edildiğinde sonuçların genel olarak başarılı olduğu söylenebilmektedir. Precision - Confidence (Kesinlik - Güven) grafiğine bakıldığında kırmızı, mor ve kahverengi ile gösterilen Mandibularange, Mandibularcanal ve Mandibularcondyle sınıflarının oldukça yüksek değerler aldığı ama diğer sınıflar için aynı şeyin söylenemeyeceği açıktır. Aynı durum Recall - Confidence (Duyarlılık - Güven) grafiği için de geçerliliğini korumaktadır.



Şekil 17. YOLOv11 maske tespiti için elde edilen metrikler arası ilişkiler

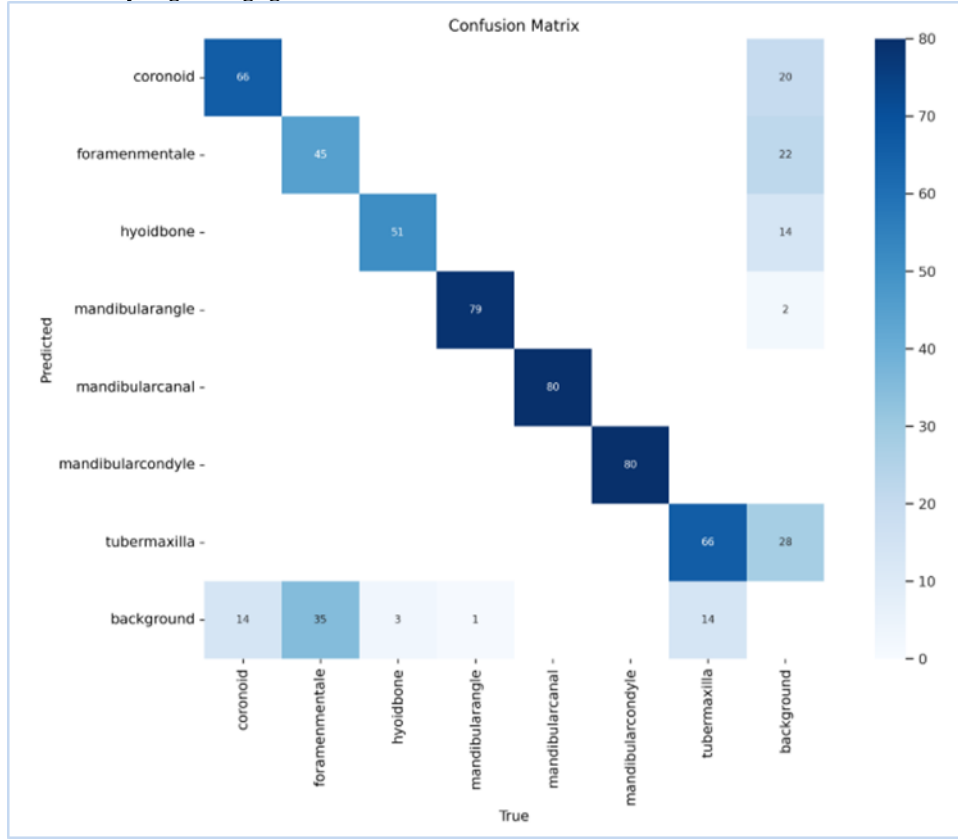
Şekil 17' de Mask tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Grafikselsel olarak box tespiti sonuçlarına benzer sonuçlar elde edildiği görülse de mask için ayrıntılı bakıldığında tüm grafiklerde daha az başarı oranı olduğu açıktır.



Şekil 18. YOLOv11 Loss (kayıp) değerleri

Şekil 18' deki grafik değerlerinde modelin (box_loss) kaybının azaldığı, bounding box tahminlerinin geliştirildiğini gösterilmektedir. Segmentasyon kaybının (seg_loss) belirgin şekilde iyileştiği, ancak bu kaybın hâlâ nispeten yüksek olduğu söylenebilmektedir. Sınıf tespitindeki kayıp (cls_loss) nesnelere doğru sınıflandırmada sürekli bir

ilerleme kaydetmiştir. Bounding box koordinatları (df_loss – mesafe alan kaybı) ise modelin bounding box sınırlarını giderek daha iyi öğrendiği görülmektedir.



Şekil 19. YOLOv11 Confusion Matrix

Şekil 3.19’ da YOLOv11 için Confusion (karmaşıklık) matrisi ile her bir sınıfın True (gerçek) değerleri olma oranları gösterilmiş ve doğruluk 1’e yaklaştıkça renk koyulaşmıştır. Confusion matrisine göre bakıldığında en iyi değeri alan sınıflar Mandibularcanal, Mandibularange ve Mandibularcondyle’ dir.

3.4. Eğitilen Modellerin Karşılaştırılması

Bu bölümde YOLOv5, YOLOv8 ve YOLOv11 modellerinin sonuçları farklı değerlendirme metrikleri açısından karşılaştırılmaktadır. Her modelin doğruluk, hız ve işlem kapasitesi gibi önemli faktörler dikkate alınarak performans analizi yapılmıştır. Ayrıca, segmentasyon ve nesne tespiti görevlerinde elde edilen metrikler üzerinden modellerin güçlü ve zayıf yönleri incelenmiştir. Bu karşılaştırma, her modelin belirli veri kümesi ve uygulama senaryoları için ne kadar uygun olduğunun daha net anlaşılması için yapılmıştır.

Tablolar Bazında Modellerin Karşılaştırılması

Tablo 9. Tüm modellerin kutu tespiti için F1, mAP50, mAP50-95 değerleri

Model	F1	mAP50	mAP50-95	Eğitim Süresi
YOLOv5	0.848	0.832	0.390	0.705
YOLOv8	0.850	0.840	0.423	0.625
YOLOv11	0.846	0.832	0.433	0.528

Tablo 9 değerlerine bakıldığında box tespiti için F1 metriğinde en başarılı skora YOLOv8’in sahip olduğu görülmektedir. Bu YOLOv8’in daha dengeli bir performans sunduğunu göstermekteyken öte yandan YOLOv5 ve YOLOv11 de oldukça yakın performans sergilemişlerdir. Aynı zamanda mAP50 değerinde de yine YOLOv8 diğerlerinden daha yüksek performans göstermiştir, mAP50-95 değerinde YOLOv11 öne çıkmakta ve bu sonuca göre YOLOv11’in daha karmaşık senaryolardaki kutu tespiti için performans sunduğu söylenebilmektedir. Sonuç olarak, YOLOv8 genelde ön plana çıkarken YOLOv11 eğitim süresinin diğerlerinden düşük olması ve mAP50-95

değerinden dolayı tercih edilebilir seviyede görünmektedir. YOLOv5 dengeli bir performans sergilediği halde diğer modellerden geri kalmaktadır.

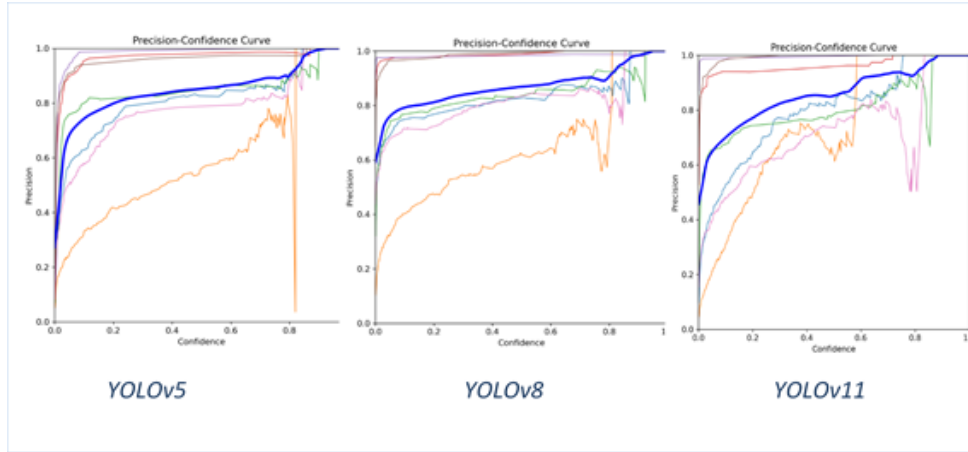
Tablo 10. Tüm modellerin maske tespiti için F1, mAP50, mAP50-95 değerleri

Model	F1	mAP50	mAP50-95	Eğitim Süresi
YOLOv5	0.790	0.760	0.289	0.705
YOLOv8	0.802	0.786	0.327	0.625
YOLOv11	0.810	0.795	0.330	0.528


Tablo 10 değerlerine bakıldığında mask tespitinde F1 metriklerinde en başarılı skora sahip olan model YOLOv11 olduğu görülmektedirken YOLOv8 az farkla onu takip etmektedir. mAP50 metriği için en iyi performansı sergileyen YOLOv11, mAP50-95 metriğinde de öne çıktığı gözlemlenmektedir. Az farkla YOLOv8 de onu takip etmektedir. Eğitim süresi olarak da yine YOLOv11 avantajlı görünmektedir. Sonuçta mask tespiti için YOLOv11 modelinin daha başarılı olduğu ve tercih edilebilir olduğu gözlemlenmektedir.

Grafiksel Olarak Modellerin Karşılaştırılması


Bu kısımda YOLOv5, YOLOv8 ve YOLOv11 modellerine ait değerlendirme metrikleri grafikler şeklinde karşılaştırılmış ve en iyi model ortaya konulmuştur. Şekil 20, Şekil 21, Şekil 22 ve Şekil 23' te karşılaştırılan grafikler bakıldığında YOLOv8'in genel olarak tüm değerlerde stabil ve başarılı değerler aldığını göstermektedir. YOLOv11'in de yine yüksek değerlere ulaştığı ama bazı sınıflarda fazla dalgalanmalar yaşandığı görülmektedir. Bu durum dalgalanma olan sınıflarda daha az güvenli tahminler yapıldığını göstermektedir. Diğer yandan YOLOv8 eğrisinin daha pürüzsüz ve az dalgalı olması modelin daha tutarlı olduğunu göstermektedir. YOLOv11 ise bu tutarlılığa sahip olmadığı görülmektedir.




Şekil 20. Kesinlik değerlerine göre model grafikleri



Şekil 21. Duyarlılık değerlerine göre model grafikleri



Şekil 22. Kesinlik - Duyarlılık değerlerine göre model grafikleri



Şekil 23. F1 değerlerine göre model grafikleri


Örnek Görüntü Etiketlemeleri ile Modellerin Karşılaştırılması

Bu bölümde her bir model için örnek görüntü üzerinde segmentasyon işleminin her sınıf üzerindeki başarımları karşılaştırılmaktadır.




Şekil 24. YOLOv5 örnek görüntü üzerinde etiketlenen bölgelerin gösterimi

Şekil 24' te YOLOv5 için örnek bir görüntü üzerinde anatomik yer işaretlerinin tespitindeki başarımları gösterilmektedir. Bu görüntüye bakıldığında Mandibularcondyle 0.69, Coronoid 0.58, Tubermaxilla 0.30 ve 0.36, Mandibularcanal 0.77, Mandibularangle 0.56 ve 0.60, Hyoidbone 0.74 ve 0.67 değerlerini almış, Foramenmentale ise tespit edilememiştir.



Şekil 25. YOLOv8 örnek görüntü üzerinde etiketlenen bölgelerin gösterimi

Şekil 25' te YOLOv8 için örnek bir görüntü üzerinde anatomik yer işaretlerinin tespitindeki başarımları gösterilmektedir. Bu görüntüye bakıldığında Mandibularcondyle 0.90 ve 0.86, Coronoid 0.77 ve 0.69, Tubermaxilla 0.82 ve 0.83, Mandibularcanal 0.87 ve 0.91, Mandibularangle 0.73, Hyoidbone 0.80 değerlerini almış, Foramenmentale ise yine tespit edilememiştir.



Şekil 26. YOLOv11 örnek görüntü üzerinde etiketlenen bölgelerin gösterimi

Şekil 26' da YOLOv11 için örnek bir görüntü üzerinde anatomik yer işaretlerinin tespitindeki başarımları gösterilmektedir. Bu görüntüye bakıldığında Mandibularcondyle 0.64 ve 0.76, Coronoid 0.39 ve 0.57, Tubermaxilla 0.57 ve 0.69, Mandibularcanal 0.84 ve 0.83, Mandibularangle 0.74 ve 0.74, Hyoidbone 0.73 ve 0.79, Foramenmentale 0.31 ve 0.27 değerlerini almıştır.

Modellerin hepsi bir arada değerlendirildiğinde YOLOv8'in tespit değerlerinin yüksek olduğu gözlemlenmektedir. Diğer taraftan YOLOv11 görsel üzerinde daha fazla tespitte bulunabilmiş ve Foramenmentale diğer modellerde bulunamazken YOLOv11 ile tespit edilebilmiştir. Fakat bu görseller yüzlerce görüntü arasından yalnızca birini ifade ettiğinden modeller hakkında net bilgi, elde edilen tablolar ve grafikler tarafından sağlanmaktadır.

Nihai Sonuç

Grafikler, modelin eğitim sürecini, loss (hata) değerlerindeki düşüşü ve optimizasyon davranışını anlamak için önemliyken tablolar, eğitim süreci tamamlandıktan sonra, modelin gerçek performansını ölçen nihai metriklere odaklanmaktadır.

Grafiklere bakıldığında, YOLOv8 daha avantajlı görünmektedir. Bu, modelin daha hızlı ve kararlı bir şekilde loss değerlerini azaltarak optimize olduğunu ve eğitim sırasında daha iyi bir öğrenme kapasitesine sahip olduğunu göstermektedir. Tablolara bakıldığında ise, YOLOv11'in özellikle mAP50-95 gibi farklı eşiklerde daha yüksek doğruluk göstermesi ve mask tespitindeki üstünlüğü, modelin farklı görevlerde daha iyi genelleştirdiğini ve özellikle mask tespiti gibi detaylı analizlerde daha başarılı olduğunu ortaya koymaktadır.

Hem metriklere hem de grafiklere bakarak tutarlılık ve genel performans istenirse, YOLOv8 biraz daha dengeli bir model olarak değerlendirilmektedir. En yüksek doğruluk metrikleri ve kısa eğitim süresiyle üstün olan model ise YOLOv11'dir.

4. Tartışma ve Değerlendirme

Panoramik radyografi, dişler, çeneler, göz çukurunun üst kısmı, maksiller sinüsler, mandibula ve temporomandibuler eklem gibi geniş bir bölgeyi kapsayarak tüm bu yapıların birlikte görüntülenmesini sağlar. Bu nedenle, medikal görüntüleme açısından önemli bir klinik ve araştırma aracıdır [14]. Ancak, anatomik işaretlerin tanımlanması genellikle zor ve zaman alıcı bir süreçtir, bu yüzden otomatik yöntemlerin geliştirilmesi büyük önem taşır. Farklı radyografi türleri üzerinde otomatik anatomik işaret tespiti ile ilgili çalışmalar yapılmış olsa da panoramik radyografi görüntüleri üzerindeki araştırmalar daha sınırlıdır.

Bu çalışmanın amacı, panoramik anatomik yer işaretlerini otomatik olarak doğru ve güvenilir bir şekilde tespit etmektir. YOLOv5, YOLOv8 ve YOLOv11 modelleri kullanılarak çeşitli internet sitelerinden elde edilen panoramik radyografi görüntülerinden oluşan veri setlerinin birleşimi kullanılmıştır. Eğitim için görüntüler, daha hızlı ve etkili deneyler sağlamak amacıyla 2976 x 1536 boyutundan 640 x 640'a küçültülmüştür. Toplamda 14 anatomik noktanın otomatik olarak tespit edildiği çalışmada, ortalama F1 performans değerleri sırasıyla şu şekilde elde edilmiştir: YOLOv5 modeli için 0.790, YOLOv8 modeli için 0.802, YOLOv11 modeli için 0.810. Uygulanan 3 farklı modelin eğitimi sonucunda elde edilen değerlerin kıyaslaması ve başarı oranlarının göz önünde bulundurulması sonucunda Panoramik Radyografi görüntülerinde anatomik yer işareti tespitinin derin öğrenme ile otomatik yapılması için en uygun modelin YOLOv11 olacağı kararına varılmıştır.

Önerilen yaklaşım, doktor adaylarının panoramik radyografiler üzerindeki anatomik yer işaretlerini daha doğru bir şekilde tespit etmelerini ve uzman doktorların yorgunluk ve yoğunluk gibi faktörlerden kaynaklanabilecek hataları minimuma indirmeyi hedeflemektedir. Olabildiğince optimum sonuna ulaşabilmek adına çalışmalar gerçekleştirilmiştir. Sonuç olarak, yeterince yüksek başarı oranlarına ulaşılmış olsa da daha fazla veri kullanılarak çok daha iyi sonuçların elde edilmesinin, mevcut değerlere bakıldığında kaçınılmaz olduğu görülmektedir. Aynı zamanda yapılan çalışmada anatomik yer işaretlerinin bir kısmı kullanıldığından, ilerleyen çalışmalarda tüm yer işaretleri ile modellerin eğitilmesi tavsiye edilmektedir.

Kaynakça

- [1] Pişiren A., 2020. Panoramik radyografi. (Web Sayfası: <https://akinpisiren.com/panoramik-radyografi>), (Erişim tarihi: Aralık 2023).
- [2] Duong, M. T., Rauschecker, A. M., Rudie, J. D., Chen, P. -H., Cook, T. S., Bryan, R. N., Mohan, S., 2019. "Artificial Intelligence for Precision Education in Radiology", The British Journal of Radiology, 92, 20190389.
- [3] Diyva, V. K., Jatti, A., Meheraj S.P., Joshi, R., 2016, "Image Processing and Parameter Extraction of Digital Panoramic Dental X-rays with ImageJ", International Conference on Computational Systems and Information Systems for Sustainable Solutions, 450-454.
- [4] Li W., Lu Y., Zheng K., Liao H., Lin C., Luo J., Cheng C., Xiao J., Lu L., Kuo C., Miao S., 2020. Structured landmark detection via topology-adapting deep graph learning. Department of Computer Science, University of Rochester, Rochester, NY, USA, 2004.08190v6.

- [5] Shahidi S, Bahrampour E, Soltanimehr E, Zamani A, Oshagh M, Moattari M, et al. The accuracy of a designed software for automated localization of craniofacial landmarks on CBCT images. *BMC Med Imaging* 2014;14:32.
- [6] Ayyıldız, H., Orhan, M., & Bilgir, E. (2024). Tooth numbering with polygonal segmentation on periapical radiographs: An artificial intelligence study. *Clinical Oral Investigations*, 28, 610. <http://doi.org/10.1007/s00784-024-05999-3>
- [7] Rašić, M., Tropčić, M., Karlović, P., Gabrić, D., Subašić, M., & Knežević, P. (2023). Detection and segmentation of radiolucent lesions in the lower jaw on panoramic radiographs using deep neural networks.
- [8] Widiyasri, M., Suciati, N., Arifin, A. Z., Faticah, C., Astuti, E. R., Indraswari, R., Putra, R. H., & Choiruzain. (2022). Dental-YOLO: Alveolar bone and mandibular canal detection on cone beam computed tomography Images for dental implant planning.
- [9] Zeren, M., Arslankaya, S., Altuntaş, Y., Cam, N., Kirelli, Y., Özdemir, M., (2023). doctors versus YOLO: comparison between YOLO algorithm, orthopedic and traumatology resident doctors and general practitioners on detection of proximal femoral fractures on X-ray images with multi methods. *International Journal of Artificial Intelligence Tools*, 1-24. <http://dx.doi.org/10.1142/S0218213023500562>
- [10] Almufareh, M. F., Khan, A., Imran, M., Humayun, M., & Asim, M. (2023). Automated Brain Tumor Segmentation and Classification in MRI Using YOLO-Based Deep Learning. *Jouf University, Saudi Arabia*.
- [11] Lu, Y., Li, K., Pu, B., Tan, Y., Zhu, N., (2024). A YOLOX-based deep instance segmentation neural network for cardiac anatomical structures in fetal ultrasound images. *IEEE/ACM Transactions on Computational Biology and Bioinformatics*, 21 (4), 1007-1018.
- [12] Bochkovskiy, A., Wang, C.-Y., & Liao, H.-Y. M. (2020). YOLOv4: Optimal speed and accuracy of object detection. <https://arxiv.org/abs/2004.10934>
- [13] Meel, A., 2021. Guide to the model & its controversy. (<https://viso.ai/computer-vision/yolov5-controversy/>), (Kasım 2024).
- [14] Çağıl, H., 2009. Serbest Çalışan Diş Hekimlerinin Kullandıkları Radyografik Teknik ve Ekipmanları bitirme tezi. İzmir: Ege Üniversitesi Diş Hekimliği Fakültesi Oral Diagnoz ve Radyoloji Anabilim Dalı.