

CR3022 Antikoru ile Cihazdan Bağımsız Pratik Kağıt Tabanlı İmmünotest ile Direkt SARS CoV-2 Teşhisİ

Dilek Çam Derin¹ 

*¹ İnönü Üniversitesi Fen Edebiyat Fakültesi Moleküller Biyoloji ve Genetik Bölümü, MALATYA
cam.dilek@gmail.com

(Alınış / Received: 01.11.2024, Kabul / Accepted: 25.12.2024, Online Yayınlanması / Published Online: 30.12.2024)

Anahtar Kelimeler

Dot blot assay,
viral diagnosis,
paper assay,
SARS CoV-2

Öz: Pandemi dünyada her an ortaya çıkabilir ve birçok ölümle sonuçlanabilir. En son görülen pandemiye şiddetli akut solunum yolu sendromu koronavirüs 2 (SARS CoV-2) sebep olmuştur. SARS CoV-2 ilk kez ortaya çıktıktı için hızlı tanı testlerinin yokluğu sebebiyle pandemi hızla ilerlemiş ve birçok kişinin ölümüne sebep olmuştur. Virüs tanısı için ilk olarak en güvenilir test olarak kabul edilen ters transkripsiyon polimeraz zincir reaksiyonu (RT-PZR) kullanılsa da eğitimli personel ihtiyacı duyması ve gelişmemiş ülkelerde bu testin uygulama zorluğu sebebiyle eksikleri vardır. Bu nedenle direkt virüs teşhisine yönelik hızlı testlerin geliştirilmesi her zaman elzemdir. Bu testler arasında kağıt tabanlı immünotestler önemlidir ve çoğunlukla dot-blot assay (noktasal test-NT) olarak bilinir. Vücut sıvılarının direkt uygulanmasına uygun olduğu için pratik ve kullanımı kolaydır. Antikor ve aptamerler tanı testlerinin en önemli bileşenleridir ve bunlardan afinitesi iyi olanlar kullanılmalıdır. Bu araştırmada antikor-aptamer sandviç testine dayalı olarak NT hazırlanmış ve viral teşhise uygun olup olmadığı bildirilmiştir.

Direct Detection of SARS CoV-2 by Practical Paper Based Imunoassay as an Instrument Free and Low Cost by CR3022

Keywords

Dot blot assay,
viral diagnosis,
paper assay,
SARS CoV-2

Abstract: Pandemia could be emerged at any time and resulted with death in the world. Severe acute respiratory syndrome coronavirus 2 (SARS CoV-2) caused the latest pandemia. Because of the absence of rapid diagnostic assays pandemia has surged in and caused the death of lots of people as SARS CoV-2 appeared at first time. Although reverse transcriptase polymerase chain reaction (RT-PCR) accepted as the most reliable test was used for the viral detection at first time, there are shortcomings including the need of educated personnel and difficulty of the usage of this test in undeveloped countries. For this reason, developing the rapid assays for direct recognition of virus is always essential. Paper based immunoassays are significant among these assays and they are known as dot-blot assay (DBA). It is practical and easy to use since they are suitable for direct application of body fluids. Antibodies and aptamers are the most important reagents of diagnostic assays and it should be used having the high affinity of them. In this work, DBA was prepared by antibody-aptamer based sandwich assay and reported the suitability of it for viral detection.

1. Giriş

İnsan sağlığı çeşitli virüs türlerinin her an ortaya çıkabilme ihtimali sebebiyle sürekli risk altındadır. Örneğin domuz gribi, kuş gribi, ebola gibi viral hastalıklar ile son zamanlarda kendini gösteren zika virüsü, koronavirüs ve maymun çiçeği vírusları hem epidemî hem de pandemiye sebep olmuştur [1]. Özellikle 2019 yılının Aralık ayında,

Çin'in Wuhan kentinden dünyaya yayılan, pozitif iplikçikli bir ribonükleik asit (RNA) virüsü içeren şiddetli akut solunum sendromu virüsü koronavirüs-2 (SARS CoV-2), çok fazla sayıda ölüme sebep olmuştur [2] [3]. Bu nedenle epidemi veya pandeminin kısa sürede yayılmasının önüne geçmek ve/veya kontrol altında tutabilmek için kolay yöntemlerle hızlı sonuç verebilen testlerin doğru bir şekilde yapılması önemlidir. Bu testlerde yaygın olarak nanopartiküler kullanılmakta ve geliştirilen biyosensörler, klinik örneklerde nükleik asit ve protein gibi analitlerin tespitinin sağlanması avantajlı özelliklerinden dolayı önemli yer tutmaktadır [2]. SARS CoV-2 teşhis için pandemiden günümüze kadar en güvenilir yöntem olarak Ters Transkriptaz Polimeraz Zincir reaksiyonu (RT-PCR) kullanılsa da, Enzyme Linked Immunosorbent Assay (ELISA) [4], Clustered Regularly Interspaced Short Palindromic Repeats (CRISPR), bilgisayarlı tomografi (CT) taraması, sekans analizi, lateral flow test (LFT) [5], Raman spektroskopisi [6], Loop-mediated izotermal amplifikasyon [7] gibi farklı metodlar da geliştirilmiştir. Bu metodlar pandemi sırasında çoğunlukla elde edilmesi zaman alan veya ekonomik olmayan kompleks ajanlar içermektedir. Ayrıca antijen saflaştırılması, ticari olarak ikili antikorların kullanılması, fonksiyonel ve çok amaçlı substrat ihtiyacı, gelişmiş ileri analiz cihazlarına ihtiyaç duyması sebebiyle dezavantajlı olabilmektedir. Bu nedenle rekombinant antikorlar ve bu antikorların diagnostikte kullanımı hem hızlı hem de ekonomiktir. Rekombinant antikorlar arasında ise tek zincirli değişken fragment (scFv) oldukça popülerdir ve teşhis testlerinde kullanılabilmektedir. SARS CoV-2 teşhisini için de farklı rekombinant antikorlar pandemi süresince hem ticari olarak hazırlanmış hem de virüsün farklı antijenik bölgelerine özgü scFv antikorları [8], yüzeye zenginleştirilmiş Raman saçılması [6], ELISA [9], LFT [10] ve plazmonik temelli biyosensörlerde [11] tanıycı ajan olarak kullanılmıştır.

Antikorların yanı sıra aptamerler de hızlı tanı testleri ve genel diagnostik testlerde kullanılan, kimyasal antikorlar olarak da adlandırılan tek zincirli DNA veya RNA zincirleridir. Aptamerler, uzun raf ömrü, düşük ekonomik maliyeti, kolay erişim ve yüksek afinite özelliklerinden dolayı antikorlara göre avantajlı görülmekte ve bu nedenle hem tek başına hem de farklı antikor veya aptamerlerle bir arada kullanılarak tanı sistemlerinde önemli yer edinmiştir. SARS CoV-2 için de virüsün farklı antijenik bölgelerine özgü aptamerler geliştirilmeye devam etmektedir [12] [13]. Aptamerler antikorlarda olduğu gibi ELISA [14], LFT [15] ve farklı biyosensorlerde [16] [17] de kullanılarak SARS CoV-2 teşhisini göstermiştir. Yukarıda bahsi geçen teşhis yöntemleri arasında hızlı, kullanımı kolay ve gelişmiş cihaz kullanımına gerek kalmadan teşhis yapan testler arasında dot-blot assay (noktasal test-NT) olarak da bilinen, nokta şeklinde damlalar kullanılarak yapılan kağıt tabanlı testler hızlı tanı testleri arasında önemli bir yere sahiptir. Kağıt tabanlı biyolojik dedektörler, biyoyumlu olması, gözenekli yapıları, kolay modifiye edilmeleri, esneklikleri, çevre dostu olması, depolama ve taşınmalarının kolay olması gibi dikkat çekici özelliklerinden dolayı potansiyelleri oldukça yüksek olan testlerdir [18]. Nanopartikül tabanlı biyosensörler de, çevresel değişkenlere bağlı olarak basit, hızlı ve spesifik renk oluşturmalarından dolayı viral patojenlerin tespitinde kullanılabilir. Yeni özellikler kazandırılan altın nanopartiküller (AuNP'ler), farklı tip viral patojenlerin tespiti için oldukça doğru ve hassas biyosensörler olarak kullanılmaktadır [19] [20]. Bu anlamda nanopartikül kullanılarak geliştirilen kağıt tabanlı biyosensörlerin başında yine NT yöntemi gelmektedir. NT metodu, bir protein çözeltisinin doğrudan nitroselüloz membran üzerine nokta olarak eklenmesini ifade eder. Bu sistemlerde protein örneğinin moleküller ağırlık bilgisi olmadıgından, özellikle belirli bir antijenin farklı antikorlarla araştırılması veya bir karışımındaki belirli bir proteinin varlığının belirlenmesinde önemli yere sahiptir. Bu metod ile yalnızca antikor veya yakalayıcı ajanın özgüllüğünün biliniyor olması viral partiküllerin tespitini kolaylaştırmaktadır [21]. Pandemiden günümüze kadar SARS CoV-2 teşhisini için birkaç NT bildirilmiştir [22][23][24] fakat bu testler ya enfeksiyon sırasında hastada gelişen antikorların tayini [22][23] için ya da antijenik teşiste sadece ikili antikorların sandviç test oluşturarak kullanılmasıyla [24][25][26] yapılmıştır. Araştırmalar hızlı, doğru ve uygun maliyetlerde yeni teknolojiler geliştirmeye yönelik devam etmektedir [27][28]. Bu bağlamda teşhis için ileri cihazların kullanımına gerek duymayan ve çiplak gözle analiz imkanı sunan kağıt tabanlı test tiplerinden biri olan NT testi hızlı ve doğru teşhis yapan testler arasındadır ve kullanım kolaylığı sunmaktadır. Ayıca rekombinant antikor ve aptamer sandviçine dayalı NT henüz bildirilmemiştir.

Bu çalışmada SARS CoV-2'nin S proteinine özgü rekombinant antikor ve aptamer kullanılarak bu çiftin NT'de hızlı ve çiplak gözle viral teşhis için uygun olup olmadığı araştırılmıştır.

2. Materyal ve Metot

2.1. Materyal

SARS CoV-2 S proteinine özgü antikorun [29] rekombinant formu ve aptamer kullanılmıştır. Aptamer sekansı 5' ATC CAG AGT GAC GCA GCA TTT CAT CGG GTC CAA AAG GGG CTG CTC GGG ATT GCG GAT ATG GAC ACG T - 3' [30] şeklindedir ve thiol modifiyeli olarak Integrated DNA Technologies (IDT)'den satın alınmıştır. NT için nitroselüloz membran kullanılmıştır ve analit olarak ticari sentetik S proteinini reseptör bağlayıcı domain (sRBD) satın alınmıştır. HAuCl₄.xH₂O, sodyum sitrat (Alpha Easer), fosfat tampon çözeltisi (PBS), TCEP Tris(2-carboxyethyl)phosphine hydrochloride ve gümüş geliştirme solüsyonu (Sigma) kullanılmıştır. Deney süresince

tüm solüsyonlar ultra saf su ile hazırlanmıştır. AuNP'lar ve NP'lerin aptamer ile konjuge halleri UV-Visible spektrofotometre ile analiz edilmiştir.

2.2. AuNP sentezi ve NT için hazırlanması

AuNP'lerin (13-14 nm) hazırlanması daha önceki çalışmamızda belirttiğimiz gibi yapıldı [5]. Kısaca 1mM HAuCl₄.xH₂O çözeltisi hazırlanarak kaynatıldı ve üzerine %1'lik sitrat çözeltisi eklendi [31]. Renk kırmızıya dönüşünce oda sıcaklığında soğumaya bırakıldı. NP'ler 30 dakika santrifüj edilerek 2 kat (2X) veya 4 kat (4X) konsantrasyon hale getirildi ve konjugasyonda kullanılmak üzere 4°C'de muhafaza edildi. Modifiye aptamerler önce TCEP ile 1 saat inkübe edildi ve konsantrasyonu ile karıştırılarak inkübe edildi. Konjugasyonun stabil kalması için oda sıcaklığında tuzla yaşılandırma işlemi yapıldı ve inkübasyon sonrası 12000 rpm de santrifüj edildi. Süpernatant atılarak buzağı serum albümin (BSA) ve sükroz içeren fosfat tamponu ile 2 kez yıkanarak aynı çözeltide yeniden süspansiyon edilerek 4°C'de saklandı.

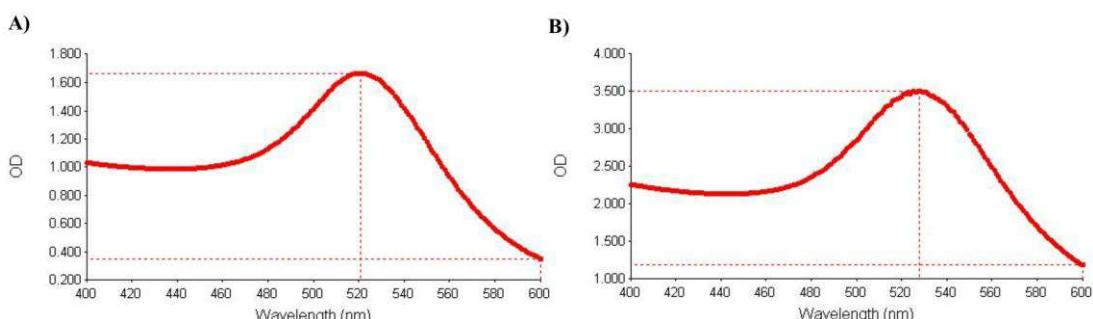
2.3. NT'lerin hazırlanması

NT'ler en az ikili olarak hazırlanmıştır. Sandviç testi yapmak üzere antikor stoğundan 0.1, 0.2 ve 3 µg/mL konsantrasyonlarından 1 µL alınarak pipet ile membranın 1. noktasına (üst) ayrı ayrı nokta şeklinde immobilize edildi ve kurumaya bırakıldı. Daha sonra BSA ile 5 dakika bloklama yapıp kurutulduktan sonra sentetik analit 0.4 µg/mL sRBD'den 1 µL alınarak eklendi ve negatif kontrol olarak 2. noktasına (alt) PBS eklendi. Daha sonra kurutma yapılarak 3 kez PBST ile yıkama yapılmış ve 37°C'de tekrar kurutulmuştur. Takiben, aptamer/AuNP konjugasyondan 1 µL alınarak membranın hem 1. hem de 2. noktasına eklendi ve 37°C'de kurutuldu. Tween-20 ile yıkama yapılarak 1 saat kurumanın ardından membrana bağlanan AuNP'lerin görünürüğünü geliştirmek/artırmak için her iki noktaya gümüş geliştirme solüsyonu olan A ve B solüsyonları 1:1 oranında katılarak 1'er µL damlatıldı ve 5-8 dakika süreyle karanlıkta bekletildi [32]. Daha sonra sodyum tiyosulfat çözeltisinden 1'er µL alınarak noktaların üzerine eklendi ve 2 dakika boyunca karanlıkta bekletildi. Son olarak PBST ile 3 kez yıkama yapıldı ve 1 saat kurumanın ardından sonuçlar gözlandı.

3. Bulgular

3.1. AuNP sentezi ve aptamer konjugasyonu

Sentezlenen AuNP'ların UV-Visible spektrofotometre ile ölçümlünde maximum absorbsiyon değeri (λ_{max}) beklenildiği üzere 522 nm olarak ölçülmüştür (Şekil 1A). Konjugasyon sonrası λ_{max} değeri yine beklenildiği üzere 526 nm'ye kaymıştır (Şekil 1B) ve konjugasyonun başarılı olduğunu göstermiştir.



Şekil 1. AuNP'lerin konjuge edilmemiş (A) ve aptamer ile konjuge edildikten (B) sonra ölçülen λ_{max} değeri.

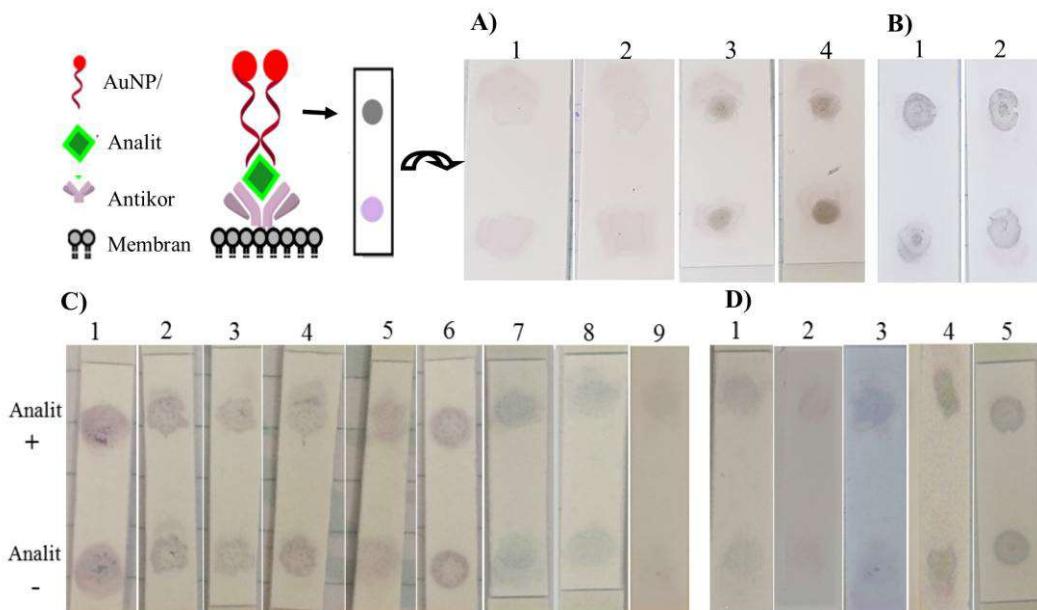
3.2. Sentetik analitin NT ile Tespiti

Viral sRBD proteini hedef olarak hazırlanan NT'lere uygulanmıştır ve NT'lere çalışma prensibi Şekil 2'de şematik olarak gösterilmiştir. Gümüş zenginleştirme solüsyonu eklenmeden önce de AuNP'lar sayesinde noktalar tespit edilse de (Şekil 2, A1-A2) gümüş görünürlüğü iyileştirdiği için NT'lere eklenmiştir (Şekil 2, A3-A4, B-D). Farklı konsantrasyonlardaki AuNP'lar, antikor ve analit miktarına göre teşhis sonuçları da farklı olmuştur. Örneğin 4X AuNP kullanılan NT'lerde (Şekil 2, A-B) test noktaları 2X AuNP'lara (Şekil 2, C-D) göre kısmen daha belirgin olmuştur fakat non spesifik bağlanmaları da kuvvetlendirme ihtiyaline karşı 2X AuNP'lar ile devam edilmiştir. Antikor/aptamer sandviç çiftinin NT'de etkinliğini kıyaslayabilmek adına aptamer/aptamer sandviç çifti ile de NT

hazırlanmıştır. Pozitif ile negatif test noktalarındaki nokta rengi yoğunlukları arasındaki fark aptamer çifti (Şekil 2, A3-A4) kullanıldığında net oluşmazken bu durum antikor/aptamer çifti kullanılan NT'lerde daha belirgin olmuşmuştur (Şekil 2, B-D).

0.2 µg/mL antikor analiti yakalamada başarılı olsa da bloklanmamış (Şekil 2, C1-C2) ve bloklu membranlarda (Şekil 2, C3-C4), pozitif ve negatif test noktalarındaki ayrı net olarak görülmemiştir. Fakat yıkama pipetle yapıldığında pozitif ve negatif noktaların farkı daha belirgin olmuştur (Şekil 2, C7-C9). Özellikle C9 NT'de negatif test noktasında hiç arka plan sinyali oluşmamıştır ve pozitif test noktası belirgin şekilde görülmüştür. Noktaların oluşumu analit direkt NT'ye yüklenliğinde (Şekil 2, C5) konjugat ile karıştırıldıktan sonra yüklenmesine (Şekil 2, C6) oranla kısmen daha iyi olmuştur ve analit diğer bütün NT'lere direkt olarak yüklenmiştir.

Antikor miktarı biraz düşürüldüğünde bloklanmış membranlarda (Şekil 2, D1-D3) pozitif ve negatif test noktaları arasındaki fark bloklanmamış membrana göre daha belirgin olmuştur (Şekil 2, D4-D5) ve negatif test noktalarında arka plan sinyalleri diğer NT'lerle karşılaştırıldığında oldukça düşüktür.



Şekil 2. SARS CoV-2 S proteinin aptamer çifti (A) ve antikor/aptamer çifti (B-D) ile NT'de tespiti ve testin çalışma prensibi. Analit +: 1. noktaya (üst) analit eklenmesini, Analit - : 2. Noktaya (alt) negatif kontrol olarak PBS eklenmesini gösterir. A-B: 4X AuNP ve C-D: 2X AuNP konjugatı içeriir. C) 0.2 µg/mL antikor kullanılmıştır. D) 0.1 µg/mL antikor kullanılmıştır. C3-C5, C7-C9 ve D1-D3 bloklu, C1-C2, C6 ve D4-D5 bloksuz membranlardır.

4. Tartışma ve Sonuç

Tasarlanan NT yönteminin yerinde ve cihaz kullanımına gerek kalmadan SARS CoV-2'nin teşhisine uygunluğu denemistiştir. Testin bu şekilde tasarımı literatür bilgilerine göre ve mevcut bildirilen NT'lerle [24][33] kıyaslandığında tarafımızca ilk kez yapılmıştır ve başarılı şekilde teşhis yaptığı gösterilmiştir. Ayrıca hazırlanan NT'ler direkt virüs teşhisine yönelik olduğu için, enfeksiyon sırasında yaklaşık 7-10 gün içerisinde gelişen antikorların teşhisini yapan ve tanının gecikmesine sebep olan NT'den [22][23] avantajlı görülmektedir. İlaveten, NT'ler pozitif veya negatif test noktalarını net şekilde göstermiştir ve arka plan sinyalleri yüksek antikor konsantrasyonlarıyla hazırlanan NT'ler hariç, bazı araştırmalarda olduğu gibi yüksek [25] çıkmamıştır ve floresans işaretlemeyle UV görüntülemeye [24] ihtiyaç duymaksızın çiplak gözle sonuç izlenmiştir. Bulgularda pozitif test noktalarının kısmen zayıf oluşmasının nedeni ticari olarak satılan ve farklı tedarikçilerden elde edilen analit-antikor-aptamer uyumunun ve afinitesinin tam olarak bildirilmemesi ve affinité zayıflığı olabilmektedir ve çalışmamızda da temel sebebin bu olduğu düşünülmektedir. Bulgulara genel olarak bakıldığından kullanılan AuNP'lar yoğunluk olarak teste uygun görünmüştür. Çünkü pozitif test noktalarından da anlaşılacağı üzere çiplak gözle analizde 2X AuNP'lardan daha az kullanılması yeterli renk değişimini sağlamayabilir. PBS negatif kontrol olarak alındığında geliştirilen NT'ler net şekilde pozitif viral teşhisini yapmıştır ve negatif test noktalarında arka plan sinyalleri beklenildiği üzere düşük çıkmıştır. 0.1 µg/mL antikor kullanılan NT'lerin teşhis profilinde 0.2 µg/mL antikor kullanımına göre bloksuz membranlarda önemli ölçüde değişiklik olmazken bloklanan membranda noktaların renk yoğunluğu azalsa da pozitif teşhis başarılı şekilde gözlenmiştir ve negatif kontrol beklenildiği üzere görülmemiştir. Böylece çok az miktarda dahi antikor ile NT'de viral tespitin çiplak gözle yapılacağı bu araştırmada gösterilmiştir. Bu nedenle bir sonraki adım olarak bu şekilde hazırlanacak NT'ler ile ilgili

optimizasyonlar yapılarak klinik örneklerin kullanılması ve böylece nazo/orofarinjeal sürüntü örneklerinden direkt SARS CoV-2 teşhisini için ön çalışmalar başlatılmıştır. Çünkü tasarlanan NT'lerin hem araştırma hem de klinik validasyon çalışmaları açısından uygun olduğu ve geliştirilmesi gerektiği düşünülmüştür. Böylece olası viral salgınlarda yeni ortaya çıkan virüslerin teşhisini için alternatif hızlı tanı testlerinin geliştirilmesine de katkıda bulunacaktır.

Teşekkür

Çalışmada yardımları dokunan Dr. Irmak İÇEN TAŞKIN ve Eray TATLICI'ya teşekkür ederim.

Kaynakça

- [1] Alafeef, M., Dighe, K., Moitra, P., Pan, D. 2020. Rapid, ultrasensitive, and quantitative detection of SARS-CoV-2 using antisense oligonucleotides directed electrochemical biosensor chip. *ACS nano*, 14:17028-17045.
- [2] Ibrahim, N., Jamaluddin, N. D., Tan, L. L., Mohd Yusof, N. Y. 2021. A review on the development of gold and silver nanoparticles-based biosensor as a detection strategy of emerging and pathogenic RNA virus. *Sensors*, 21(15):5114.
- [3] Daniel, S. K., Pai, P. S., Sabbella, H. R., Singh, K., Rangaiah, A., Basawarajappa, S. G., Thakur, C. S. 2022. Handheld, low-cost, aptamer-based sensing device for rapid SARS-CoV-2 RNA detection using novelly synthesized gold nanoparticles. *IEEE Sensors Journal*, 22(19): 18437-18445.
- [4] Amanat, F., Stadlbauer, D., Strohmeier, S., Nguyen, T. H. O., Chromikova, V., McMahon, M., Jiang, K., Arunkumar, G. A., Jurczyszak, D., Polanco, J., Bermudez-Gonzalez, M., Kleiner, G., Aydillo, T., Miorin, L., Fierer, D. S., Lugo, L. A., Kojic, E. M., Stoever, J., Liu, S. T. H., Cunningham-Rundles, C., Krammer, F. 2020. A serological assay to detect SARS-CoV-2 seroconversion in humans. *Nature medicine*, 26(7):1033-1036.
- [5] Çam Derin, D., Gültekin, E., Gündüz, E., Otlu, B. 2024. Comparison of Six Aptamer-Aptamer Pairs on Rapid Detection of SARS-CoV-2 by Lateral Flow Assay. *Journal of AOAC International*, 107(3):464–470.211.
- [6] Antoine, D., Mohammadi, M., Vitt, M., Dickie, J. M., Jyoti, S. S., Tilbury, M. A., Johnson, P. A., Wawrousek, K. E., Wall, J. G. 2022. Rapid, Point-of-Care scFv-SERS Assay for Femtogram Level Detection of SARS-CoV-2. *ACS sensors*, 7(3):866–873.13.
- [7] Thippornchai, N., Pengpanich, S., Jaroenram, W., Kosoltanapiwat, N., Sukphopetch, P., Kiatpathomchai, W., Leaungwutiwong, P. 2024. A colorimetric reverse-transcription loop-mediated isothermal amplification method targeting the L452R mutation to detect the Delta variant of SARS-CoV-2. *Scientific reports*, 14(1):21961.
- [8] Lisi, S., Malerba, F., Quaranta, P., Florio, R., Vitaloni, O., Monaca, E., Bruni Ercole, B., Bitonti, A. R., Del Perugia, O., Mignanelli, M., Perrera, P., Sabbatella, R., Raimondi, F., Piazza, C. R., Moles, A., Alfano, C., Pistello, M., Cattaneo, A. 2024. Selection and characterization of human scFvs targeting the SARS-CoV-2 nucleocapsid protein isolated from antibody libraries of COVID-19 patients. *Scientific reports*, 14(1):15864.
- [9] Ge, S., Wu, R., Zhou, T., Liu, X., Zhu, J., Zhang, X. 2022. Specific anti-SARS-CoV-2 S1 IgY-scFv is a promising tool for recognition of the virus. *AMB Express*, 12(1):18.
- [10] Kim, H. Y., Lee, J. H., Kim, M. J., Park, S. C., Choi, M., Lee, W., Ku, K. B., Kim, B. T., Changkyun Park, E., Kim, H. G., Kim, S. I. 2021. Development of a SARS-CoV-2-specific biosensor for antigen detection using scFv-Fc fusion proteins. *Biosensors & bioelectronics*, 175:112868.
- [11] Tohari, T. R., Anshori, I., Baroroh, U., Nugroho, A. E., Gumilar, G., Kusumawardani, S., Syahruni, S., Yuliarto, B., Arnafia, W., Faizal, I., Hartati, Y. W., Subroto, T., Yusuf, M. 2022. Development of a Single-Chain Variable Fragment of CR3022 for a Plasmonic-Based Biosensor Targeting the SARS-CoV-2 Spike Protein. *Biosensors*, 12(12):1133.
- [12] Kim, W., Song, E. S., Lee, S. H., Yang, S. H., Cho, J., Kim, S. J. 2024. A new DNA aptamer which binds to SARS-CoV-2 spike protein and reduces pro-inflammatory response. *Scientific reports*, 14(1):7516.
- [13] Yang, M., Li, C., Ye, G., Shen, C., Shi, H., Zhong, L., Tian, Y., Zhao, M., Wu, P., Hussain, A., Zhang, T., Yang, H., Yang, J., Weng, Y., Liu, X., Wang, Z., Gan, L., Zhang, Q., Liu, Y., Yang, G., Zhao, Y. 2024. Aptamers targeting SARS-CoV-2 nucleocapsid protein exhibit potential anti pan-coronavirus activity. *Signal transduction and targeted therapy*, 9(1):40.

- [14] Chen, Z., Wu, Q., Chen, J., Ni, X., Dai, J. 2020. A DNA Aptamer Based Method for Detection of SARS-CoV-2 Nucleocapsid Protein. *Virologica Sinica*, 35(3):351–354.20.
- [15] Yang, L. F., Kacherovsky, N., Panpradist, N., Wan, R., Liang, J., Zhang, B., Salipante, S. J., Lutz, B. R., Pun, S. H. 2022. Aptamer Sandwich Lateral Flow Assay (AptaFlow) for Antibody-Free SARS-CoV-2 Detection. *Analytical chemistry*, 94(20):7278–7285.
- [16] Erdem, A., Senturk, H., Yıldız, E., Maral, M. 2024. Optimized aptamer-based next generation biosensor for the ultra-sensitive determination of SARS-CoV-2 S1 protein in saliva samples. *International journal of biological macromolecules*, 281(Pt 1):136233.
- [17] Khan, R., Deshpande, A. S., Proteasa, G., Andreeșcu, S. 2024. Aptamer-based electrochemical biosensor with S protein binding affinity for COVID-19 detection: Integrating computational design with experimental validation of S protein binding affinity. *Sensors and Actuators B: Chemical*, 399:134775.
- [18] Kim, S., Lee, J. H. 2022. Current advances in paper-based biosensor technologies for rapid COVID-19 diagnosis. *Biochip journal*, 16(4):376–396.
- [19] Derin, D. C., Gültekin, E., Taşkin, I. İ., Yakupoğulları, Y. 2023. Development of nucleic acid based lateral flow assays for SARS-CoV-2 detection. *Journal of bioscience and bioengineering*, 135(2):87–92.
- [20] Najafabad, M. B., Rastin, S. J., Taghvaei, F., Khiyavi, A. A. 2022. A review on applications of gold nanoparticles-based biosensor for pathogen detection. *Advances in Natural Sciences: Nanoscience and Nanotechnology*, 13(3):033002.
- [21] Diamandis, E. P., Christopoulos, T. K. 1996. *Immunoassay*. Academic Press.
- [22] Apú, N., Madrigal-Redondo, G., Vega, M. H., Corrales-Aguilar, E., Segura-Ulate, I. 2023. Development of an instrument-free and low-cost ELISA dot-blot test to detect antibodies against SARS-CoV-2. *Open life sciences*, 18(1):20220577.
- [23] Norouzi, M., Truong, T., Jaenes, K., Warner, B. M., Vendramelli, R., Tierney, K., Kobasa, D., Tailor, N., Plant, P., Dos Santos, C., Babiuk, S., Ambagala, A., Pardee, K. 2023. Cell-Free Dot Blot: an Ultra-Low-Cost and Practical Immunoassay Platform for Detection of Anti-SARS-CoV-2 Antibodies in Human and Animal Sera. *Microbiology spectrum*, 11(2):e0245722. Advance online publication.215.
- [24] Celiker, T., Ghorbanizamani, F., Moulahoum, H., Guler Celik, E., Tok, K., Zihnioglu, F., Cicek, C., Sertoz, R., Arda, B., Goksel, T., Turhan, K., Timur, S., Yagci, Y. 2022. Fluorescent bioassay for SARS-CoV-2 detection using polypyrene-g-poly(ϵ -caprolactone) prepared by simultaneous photoinduced step-growth and ring-opening polymerizations. *Mikrochimica acta*, 189(5):202.
- [25] Connelly, G. G., Kirkland, O. O., Bohannon, S., Lim, D. C., Wilson, R. M., Richards, E. J., Tay, D. M., Jee, H., Hellinger, R. D., Hoang, N. K., Hao, L., Chhabra, A., Martin-Alonso, C., Tan, E. K. W., Koehler, A. N., Yaffe, M. B., London, W. B., Lee, P. Y., Krammer, F., Bohannon, R. C., Li, H. 2022. Direct capture of neutralized RBD enables rapid point-of-care assessment of SARS-CoV-2 neutralizing antibody titer. *Cell reports methods*, 2(8):100273.
- [26] Lee, J. H., Choi, M., Jung, Y., Lee, S. K., Lee, C. S., Kim, J., Kim, J., Kim, N. H., Kim, B. T., Kim, H. G. (2021). A novel rapid detection for SARS-CoV-2 spike 1 antigens using human angiotensin converting enzyme 2 (ACE2). *Biosensors & bioelectronics*, 171:112715.
- [27] Singh, B., Datta, B., Ashish, A., Dutta, G. 2021. A comprehensive review on current COVID-19 detection methods: From lab care to point of care diagnosis. *Sensors International*, 2:100119.
- [28] Wang, J., Drelich, A. J., Hopkins, C. M., Mecozzi, S., Li, L., Kwon, G., Hong, S. 2022. Gold nanoparticles in virus detection: Recent advances and potential considerations for SARS-CoV-2 testing development. *Wiley Interdisciplinary Reviews: Nanomedicine and Nanobiotechnology*, 14(1):e1754.
- [29] Tian, X., Li, C., Huang, A., Xia, S., Lu, S., Shi, Z., Lu, L., Jiang, S., Yang, Z., Wu, Y., Ying, T. 2020. Potent binding of 2019 novel coronavirus spike protein by a SARS coronavirus-specific human monoclonal antibody. *Emerg. Microbes Infect*, 9:382–385.
- [30] Song, Y., Song, J., Wei, X., Huang, M., Sun, M., Zhu, L., Lin, B., Shen, H., Zhu, Z., Yang, C. 2020. Discovery of Aptamers Targeting the Receptor-Binding Domain of the SARS-CoV-2 Spike Glycoprotein. *Analytical chemistry*, 92(14):9895–9900.
- [31] Huo, T. M., Peng, C. F., Xu, C. L., Liu, L. Q. 2006. Development of colloidalgold-based immunochromatographic assay for the rapid detection of medroxyprogesterone acetate residues. *Food and Agricultural Immunology*, 17:183–190.

- [32] Liu, R., Zhang, Y., Zhang, S., Qiu, W., Gao, Y. 2014. Silver enhancement of gold nanoparticles for biosensing: from qualitative to quantitative. *Applied Spectroscopy Reviews*, 49(2):121-138.
- [33] Li, J., Zhang, Z., Gu, J., Stacey, H. D., Ang, J. C., Capretta, A., Filipe, C. D. M., Mossman, K. L., Balion, C., Salena, B. J., Yamamura, D., Soleymani, L., Miller, M. S., Brennan, J. D., Li, Y. 2021. Diverse high-affinity DNA aptamers for wild-type and B.1.1.7 SARS-CoV-2 spike proteins from a pre-structured DNA library. *Nucleic acids research*, 49(13):7267–7279.

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, NIĞDE

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

Anahtar Kelimeler

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

Öz: Bilişim çağrı 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 artırmaktadır. 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 radyografiler için bir karar destek programı oluşturulması amaçlanmıştır. Bu çalışmada, farklı YOLO (You Only Look Once) modelleri kullanılarak panoramik radyografi üzerindeki anatomik yer işaretlerinin tespitinin otomatik olarak gerçekleştirmesi 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 anatominin tek bir film üzerinde inceleme fırsatı sunar. Müdafaleci 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 artırmasıyla beraber radyografik görüntülerin okunması ve analiz edilmesi konusunda doktorların işini oldukça kolaylaştıracak bir yer almaya başlamıştır. Panoramik radyografide yapay zekâ yöntemlerinin uygulanması da gitgide artmaktadır. Yapılan çalışmaların anatominin yer işaretlerinden çok panoramik radyografların eksik diş veya çürümüş olan diş bulmak üzere olduğu görülmektedir.

Literatür taramasında bu alanda araştırmacıların yoğun bir şekilde çalıştığı görülmektedir. İncelenen bazı çalışmalarında tıbbi görüntülerde yapay zekanın yerine bakıldığından: Michael Tran Duong ve arkadaşları, radyoloji kursiyerlerine daha iyi öğretim sağlayabilmek için yapay zekanın nasıl geliştirilebileceğine odaklanmayı amaçlamışlardır. Radyoloji eğitimini artırmak için yapay zeka ile entegre bir çerçeveye vurgulamışlardır. Yalnızca "Yapay Zekâ ile Arttırılmış Radyoloji" konusuyla kalmayıp "Hassas Tıp Eğitimi" olarak bilinen eğitimde 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 önererek 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 radyograflarının karşılaştırılarak ölüleri 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 işaretleri tespiti alanlardaki başarılarla rağmen, anatominin yer işaretlerarasındaki örtülü veya açık ilişkileri yakalamak için yüksek dereceli yapısal modellemelerin yeterince kullanılmadığını öngörmüşler ve çalışmalarında doğru anatominin yüz ve tıbbi (örneğin el, pelvis) yer işaretleri 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 yaklaşımalarla karşılaştırıldıkları niceliksel sonuçlar, hem sahıflamak hem de doğruluk açısından üstün performans göstermiştir [4]. İki boyutlu görüntülerde manuel yer işaretleri tespiti tıbbi uzmanlığa bağlıdır ve süreç zaman almaktadır. Bu nedenle Shoaleh Shahidi ve arkadaşları, görüntü kaydına dayalı olarak konik ışınılı bilgisayarlı tomografi görüntülerini üzerindeki kraniyofazial 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 bölüm 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 doğruluğunu kabul edilebilir olduğunu göstermektedir [5].

Radyografi alanında YOLO ile yapılan bazı çalışmalarla bakıldığından ise: Ayyıldız ve arkadaşları, YOLOv5'in periapikal radyografların dişleri tespit etmek ve numaralandırmak üzere eğitilebileceği hipotezini doğrulamak için çalışmalarla 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 radyografların dişlerin tespitinde YOLOv5 ile son derece iyi sonuçlar elde edildiğini göstermiştir. Diş hekimlerinin radyografik muayene süresini hızlandıracak ve deneyimsiz diş hekimlerinin YOLOv5 kullanarak hata oranını azaltabileceğini sonucuna varılmıştır [6]. Raşı'c arkadaşlarıyla birlikte gelişmiş YOLOv8 kullanarak alt çenedeki radyolusent lezyonları otomatik bir şekilde tespit edip segmentlere ayırbilen 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 bakıldığından, sürekli evrimi ve çeşitli tıbbi alanlara entegrasyonu ile derin öğrenme modelinin, hasta bakımında devrim yaratma potansiyeline sahip olduğunu belirtmişlerdir [7]. Widiasri ve arkadaşları, dental implant planlamasını basitleştirebilecek ve hızlandırabilecek 2

boyutlu ve gri tonlamalı konik işinli bilgisayarlı tomografi görüntülerine dayalı alveolar kemik ve mandibular kanal tespiti için otomatik ve eş zamanlı bir sistem önermişlerdir. Bu sisteme 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 olabileceği düşündürmüştür [8]. Zeren, ekibiyle beraber çalışmasında, proksimal femoral kırıkların tespiti için veri artırma teknikleri kullanılarak 820'ye çatıldığı 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 belirleyebileceğini 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 eşliğini aşmıştır. Bu bulgular, YOLO modellerinin beyin tümörlerini hassas bir şekilde tespit etme potansiyelini doğrulamıştır [10]. Lu, arkadaşlarıyla gerçekleştirdiği çalışmada, fetal ultrason görüntülerinde kardiyak anatomi yapı konumu ve segmentasyonu için YOLOX tabanlı derin örnek segmentasyon sinir ağrı önerimleridir. Dört odacıklı görünümün 13 tip anatomi 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 radyograflerdeki 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 diş 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 işaret, bu alanda uzman diş hekimi tarafından etiketlenmiş ve model eğitimi hale getirilmiştir.
- Görüntü çoğullama yöntemlerinin performansa 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 radyograflerdeki 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 işlemidir. 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.

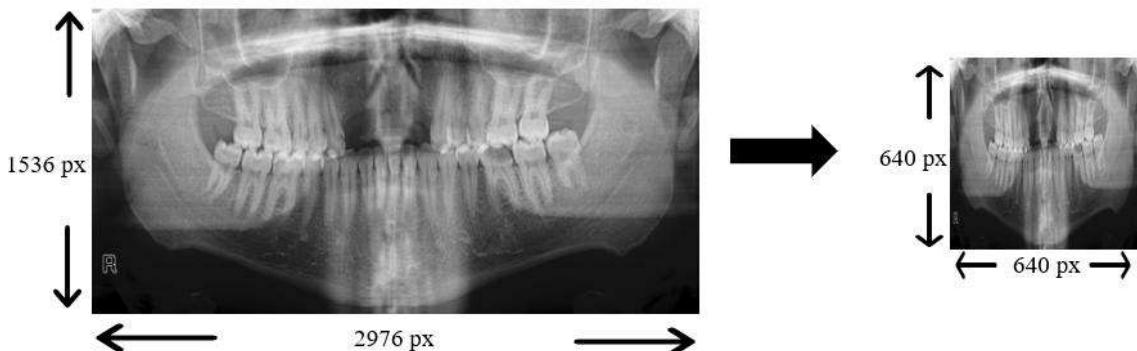
Anatomik yer işaretlerinin bir uzman tarafından belirlenmesi ve gösterilmesi gerekiğinden etiketleme aşamasında uzmanlardan yardım alınmıştır. Etiketleme aracı olarak MakeSense kullanılmıştır. MakeSense, bir manuel etiketleme aracıdır ve insan doğruluğu, hassasiyeti gerektiren görevlerde mükemmel sonuçlar 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 genişleteerek modelin daha etkili şekilde öğrenmesini sağlayan veri boyutlandırma ve veri artırma işlemleri gerçekleştirilmiştir.

Yeniden Boyutlandırma

Veri artırma 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.



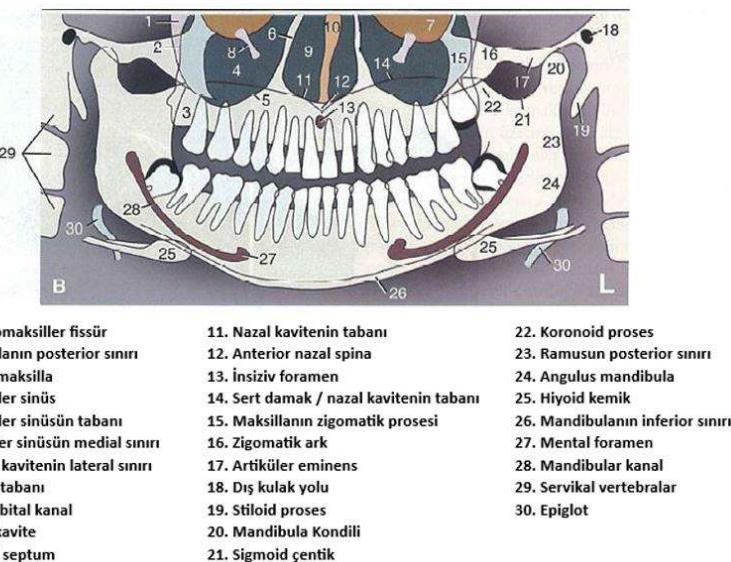
Şekil 1. Orijinal görsel ve boyutlandırılmış hali

Veri Arttırma

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

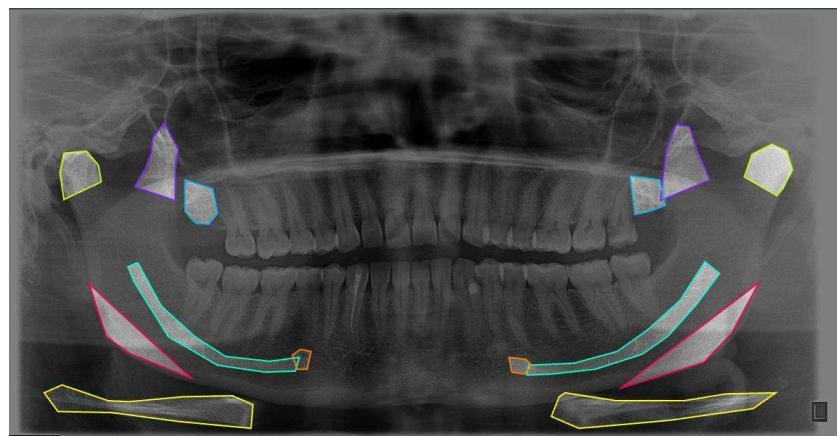
Etiketlenen Anatomik Yer İşaretleri

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 işaretini konumlarından oluşturmaktadır.



Şekil 2. Anatomik yer işaretlerinin bölgesel ayrimı

Projede tespit etmek için kullanılan 7 yer işaretti 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 alındığından anatomik yer işaretlerinin hepsinin etiketlenmesi yerine seçilen, 7 yer işaretti simetriği olmak üzere, 14 yer işaretti kullanılacak modellerle tespit edilmek üzere ele alınmıştır.

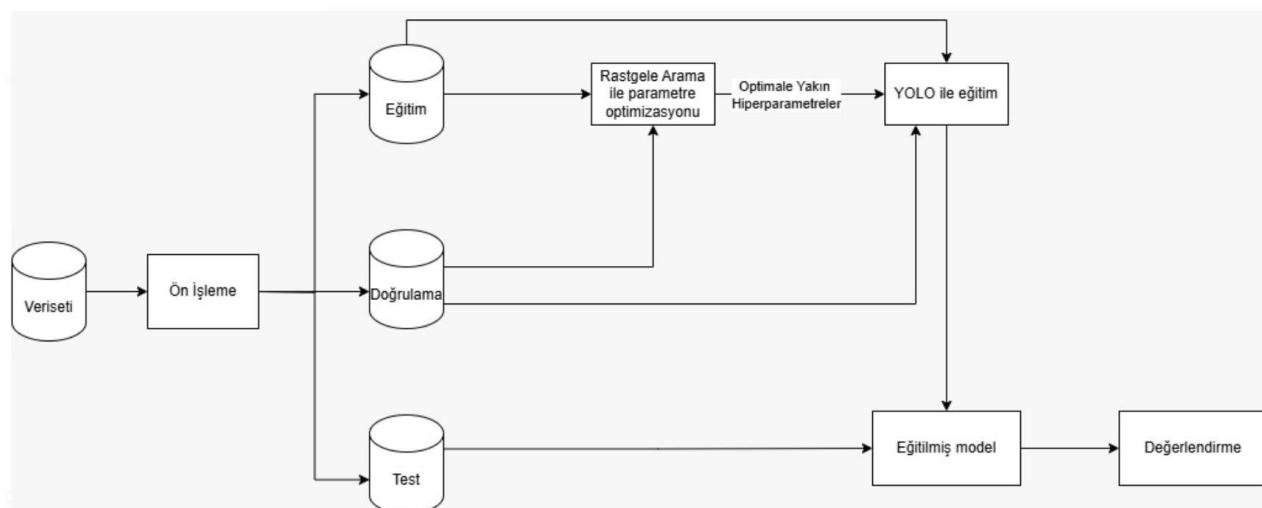
2.2. Önerilen Yöntem

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 segmentasyon) başarısının kıyaslanması ve en uygun modele karar verilmesidir. Model, tek kanallı gri tonlu görüntülerini giriş olarak kullanmaktadır. Eğitim süreçlerini hızlandırmak amacıyla, tüm modeller 640×640 piksel boyutundaki görüntülerle eğitilmiştir. Uzmanlar tarafından manuel olarak belirlenen 30 panoramik anatomik yer işaretinden, 14'ü bu model aracılığıyla otomatik olarak elde edilmiştir.

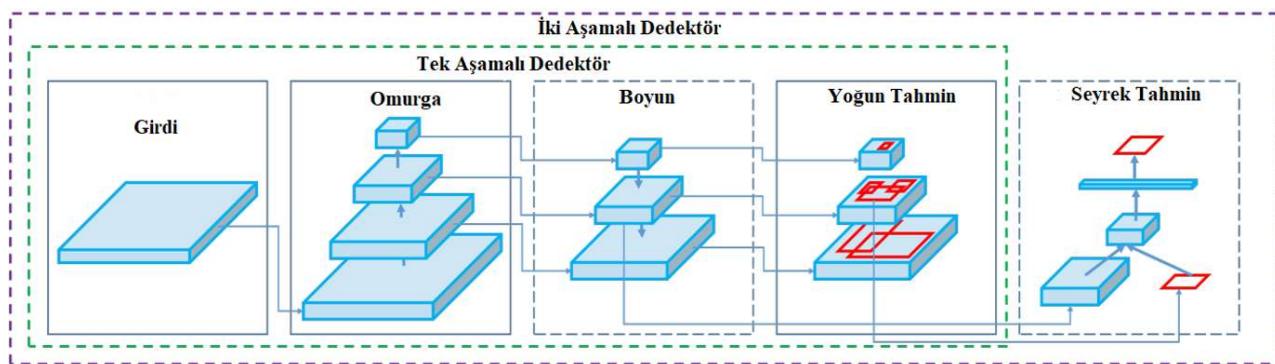


Şekil 4. Önerilen yöntemin şematik gösterimi

2.2.1. YOLO (You Only Look Once) Modeli

YOLO (You Only Look Once,), ESA tarafından öğrenilen özelliklerini kullanarak videolarda, canlı yaynlarda veya görüntülerde belirli nesneleri 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 1×1 evrimleri 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. Nesneleri tespit etmek için tek bir CNN kullanarak görüntüdeki tüm nesneleri 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 denenmeyebilir. 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

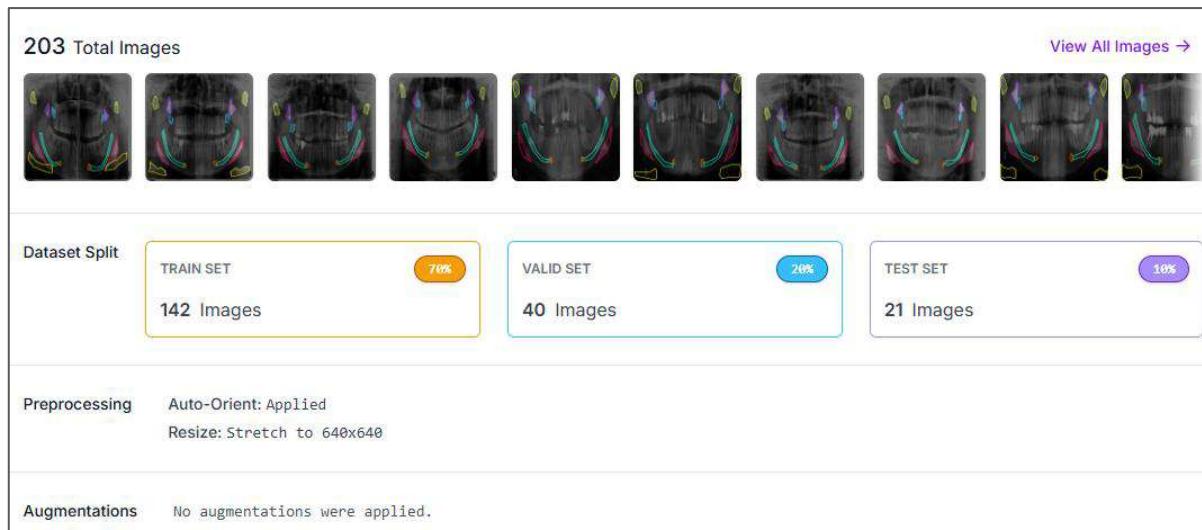
Çalışma YOLO modelleri ile anatomič yer işaretleri üzerinde instance segmentation (örnek segmentasyonu) olduğu için elde edilen sonuçlarda hem nesneyi içine alan box (kutu) değerlendirme metrikleri hem de mask (maske) değerlendirme metrikleri göz önünde bulundurulmuş ve iki ele alış şekline göre değerlendirmeler 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 nesnelerle çalışırken, daha zor olmaktadır. İyi bir kutu (box) başarı oranı, doğru konumlandırılmış nesnelerin olduğunu ve bu nesnelerin 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.

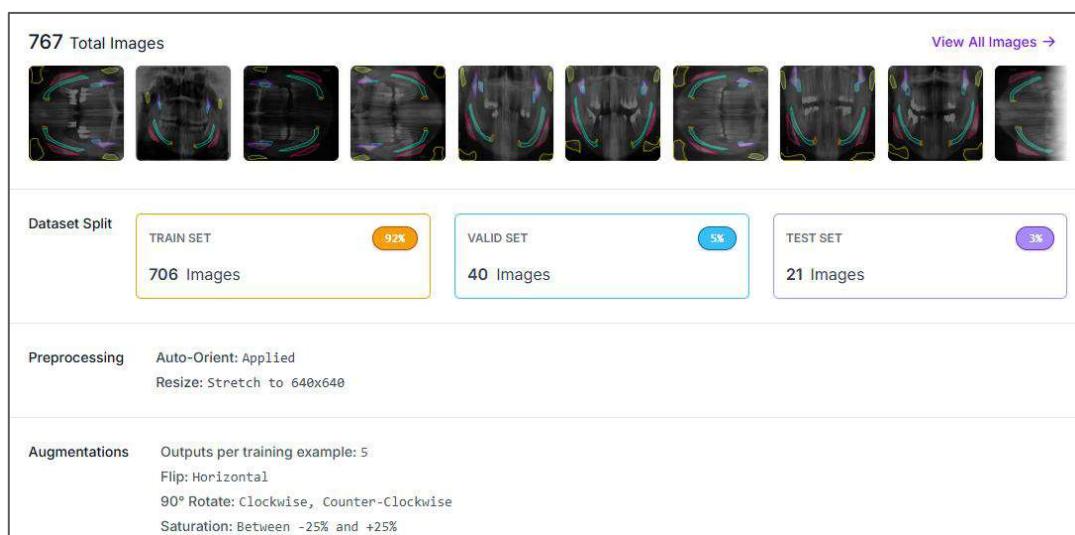
Tüm bu faktörler göz önünde bulundurulduğunda proje kapsamında analiz edilmesi gereken değerlendirme metrikleri box precision (BP – kutu kesinlik), box recall (BR- kutu duyarlılık), box mAP50 (BmAP50), box mAP50-95 (BmAP50-95), mask precision (MP – maske kesinlik), mask recall (MR – maske duyarlılık),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

3. Bulgular

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



Şekil 6. 203 görüntünün ön işleme adımları



Şekil 7. Arttırma işlemlerile 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 performansıyla 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 bakıldığından istenen değerler alınamamıştır. Sınıf bazında bakıldığından yalnızca Mandibularcanal sınıfının kesinlik ve duyarlılık değerleri istenen seviyededir. Diğer sınıflara bakıldığından 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 bakıldığından kutu tespiti bazında yapılan modellemeden 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 ardi edilmiştir. Bunun neticesinde veri arttırımı işlemleri yapılarak modellerin eğitilmesine karar verilmiştir.

Arttırma İşlemi Sonrası Oluşan 767 Görüntü ile Elde Edilen Değerler

Mevcut 203 görüntüsünden oluşan veri seti üzerinde 3 farklı augmentation işlemleri yapılip sonuca 767 veri elde edilmiştir. Veri setinin büyülüklüğü 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 görüntüsünden 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 bakıldığından Mandibularange, Mandibularcanal ve Mandibularcondyle yer işaretin 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 işaretin bölgesi olmuştur. Bu da modelin bu bölgeyi tespit ederken zorlandığını göstermektedir.

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

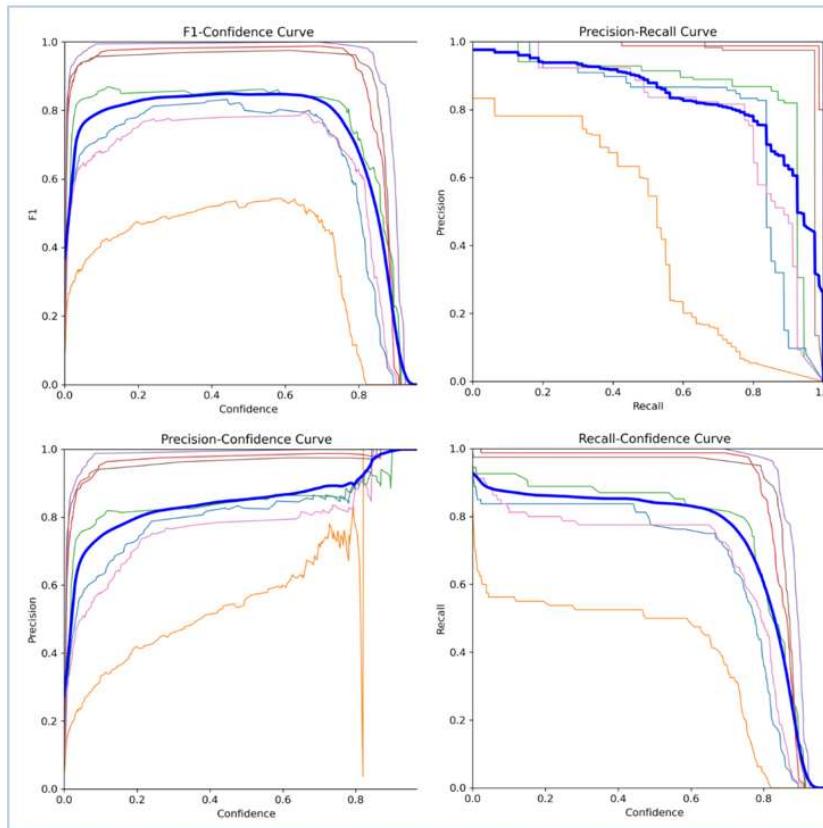
Tablo 4. YOLOv5 767 Görüntü maske için elde edilen değerler

| 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 |

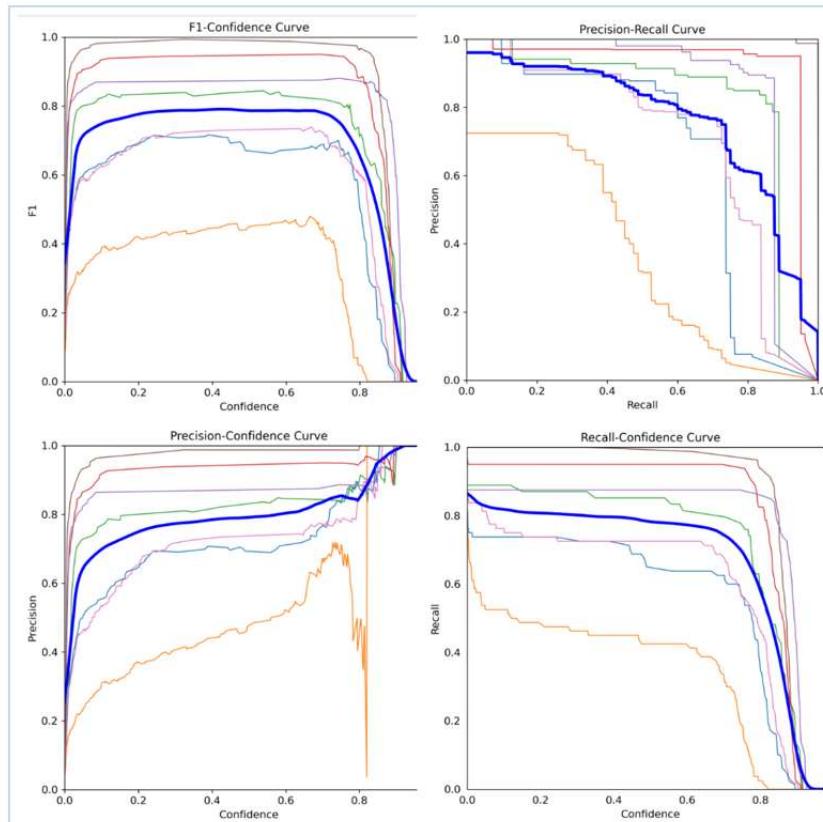
Tablo 4' teki gibi mask için elde edilen sonuçlarda da yine sınıflara göre bakıldığından Mandibularange, Mandibularcanal ve Mandibularcondyle yer işaretin hem recall (duyarlılık) hem de precision (kesinlik) değerlerinin nispeten en yüksek, F1 skorlarının da aynı şekilde yüksek olduğu görülmektedir. Modelin bu anatomik bölgeleri doğru ve istikrarlı bir şekilde tanımlayabildiğini gösterir demek mümkündür. Yine Foramenmentale, precision ve recall açısından en düşük değere sahip anatomik yer işaretin 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 edilirliğinin 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

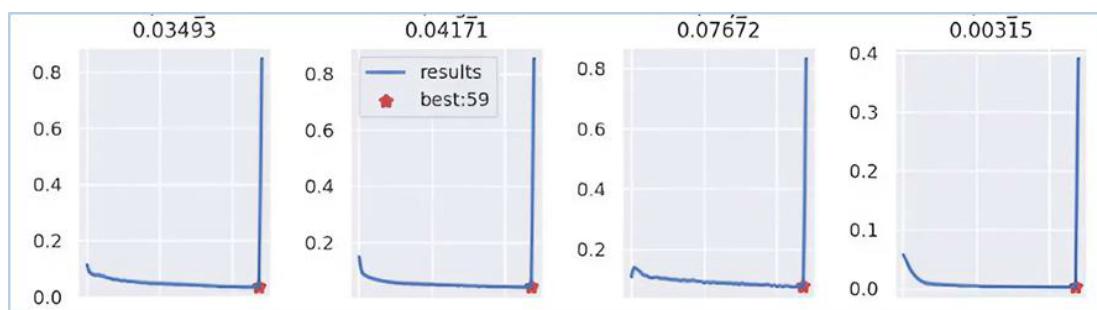
Şekil 8' de Box tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Mavi kalın çizgiyle gösterilen değer tüm sınıfların ortalamasını belirtmektedir.

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

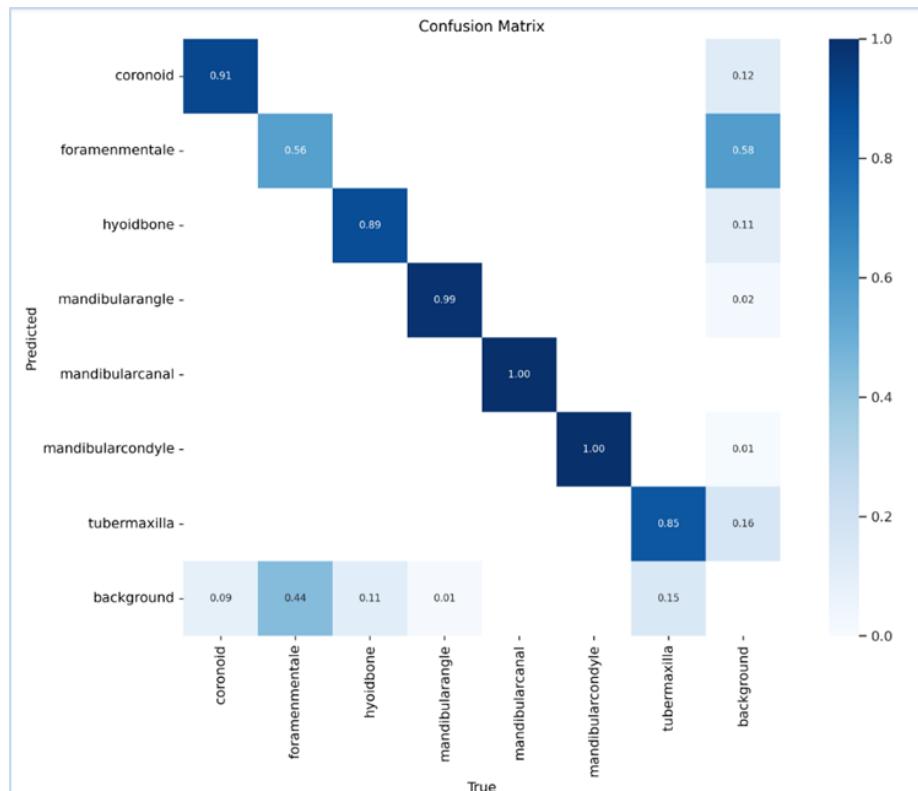
Özellikle F1 – Confidence (F1 -Güven) grafiğine bakıldığından Foramenmentale değeri göz ardı edildiğinde sonuçların gayet başarılı olduğu söylenebilmektedir. Precision – Confidence (Kesinlik - Güven) grafiğine bakıldığından yine Foramenmentale sınıfı göz ardı edildiğinde diğer sınıfların oldukça yüksek 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. Grafiksel olarak box tespiti sonuçlarına benzer sonuçlar elde edildiği görülse de ayrıntılı bakıldığından tüm grafiklerde daha az başarı oranı olduğu açıkça gösterilmektedir.



Şekil 10. YOLOv5 kayıp değerleri



Şekil 11. YOLOv5 karmaşalık 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 sırasında skorları gösterilmektedir. Kayıp değerlerinin zamanla azalması ve ortalama olarak düşük değerler olması model açısından olumlu yorumlanmaktadır. Şekil 11' de ise YOLOv5 için Confusion (karmaşıklık) matrisi ile her bir sınıfın True (gerçek) değerleri olma oranları gösterilmiş ve doğruluk 1'e yaklaştıkça renk koyulmuştur. Confusion matrixe göre bakıldığından 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 karşılaştırımlı 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 bulunduğu 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 bakıldığından yine Mandibularangle, Mandibularcanal ve Mandibularcondyle yer işaretini 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 işaretini bölgesi olmuştur. Tüm bölgeler açısından bakıldığından genel olarak F1 skoru iyi sonuç vermiştir ancak, mAP50-95 değerlerine bakıldığından yine modelin genel tespit hassasiyetinin iyileştirilmesi gerektiği görülmektedir.

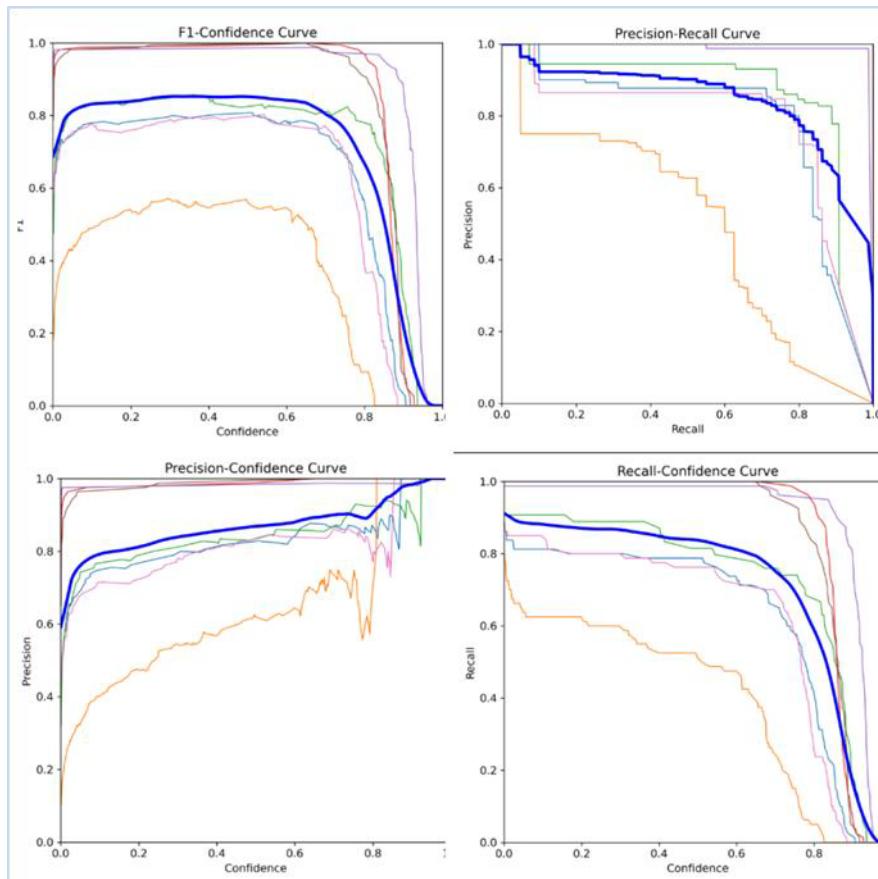
Tablo 6. YOLOv8 maske için elde edilen değerler

| 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 bakıldığından Mandibularange, Mandibularcanal ve Mandibularcondyle yer işaretleri 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 açıklıktır. Bunun sebebi mask (şekil) tahmininin box (şekil etrafında bir kutu) tahmininden çok daha hassas detaylara sahip olması ve tahmin edilirliğinin 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 bakıldığından tespit hassasiyetinin artırılması gerekişi görülmektedir.

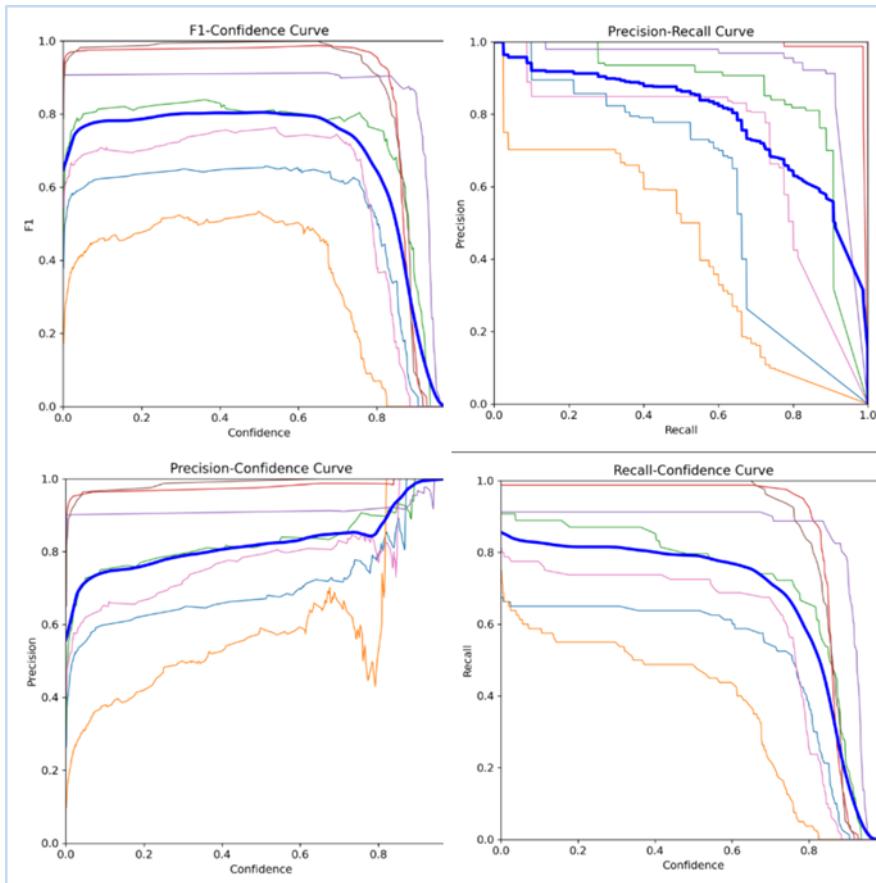
Sonuçlardan Elde Edilen Grafikler



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

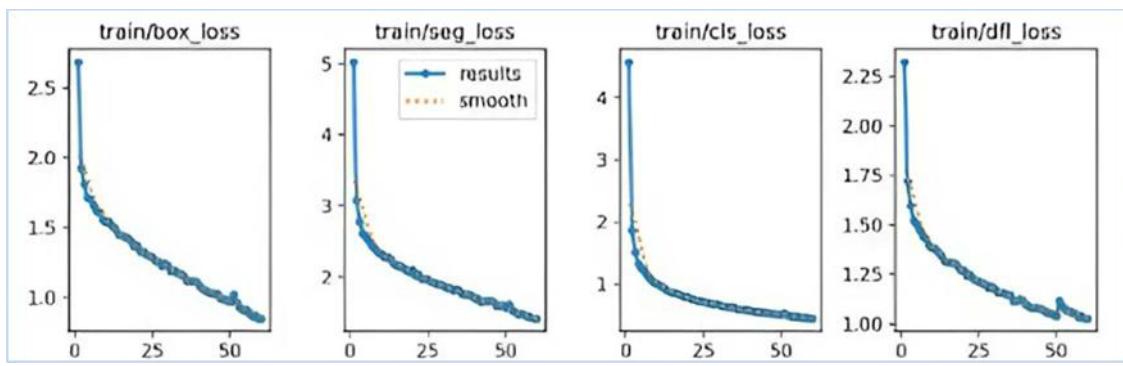
Şekil 12' de Box tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Mavi kalın çizgiyle gösterilen değer tüm sınıfların ortalamasını belirtmektedir. Grafiklere bakıldığından mavi çizginin genel olarak başarılı sonuçlar elde ettiği ama turuncu çizgiyle belirtilen Foramenmentale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

Özellikle F1 - Confidence (F1 - Güven) grafiğine bakıldığından Foramenmentale değeri göz ardı edildiğinde sonuçların gayet başarılı olduğu söylenebilmektedir. Hatta optimum seviyenin uzun bir süre korunduğu da gözlemlenmektedir. Precision - Confidence (Kesinlik - Güven) grafiğine bakıldığından 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.



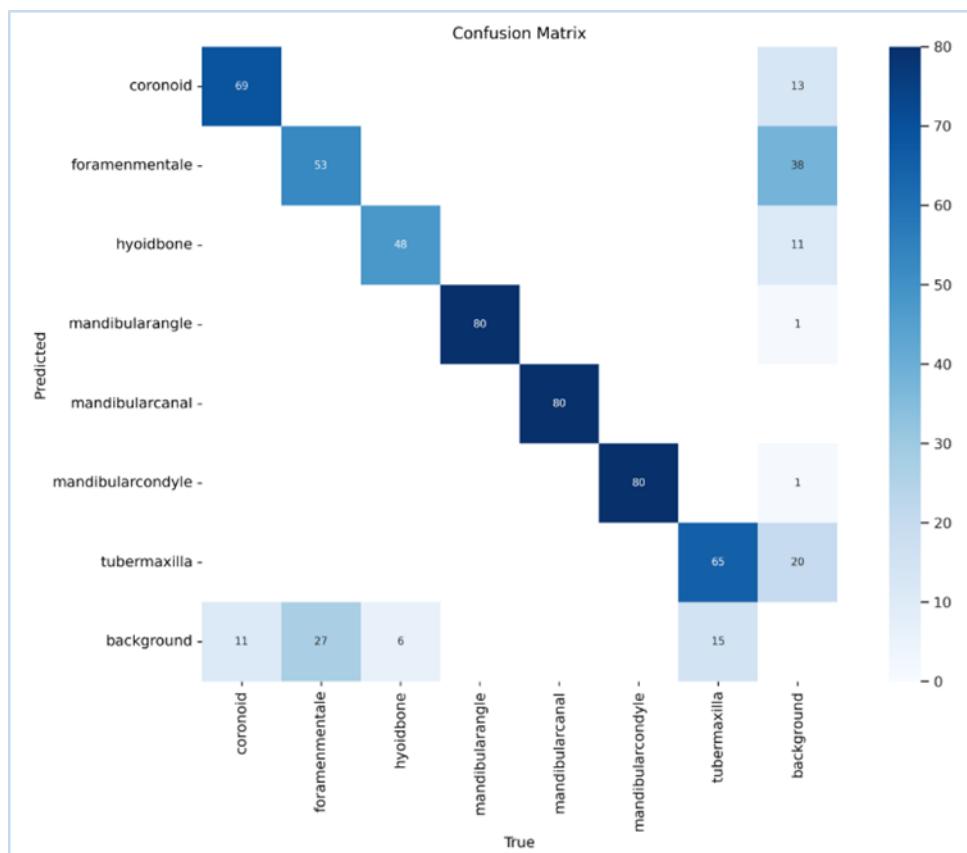
Şekil 13. YOLOv8 maske tespiti için elde edilen metrikler arası ilişkiler

Şekil 13 ile maske tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Grafiksel olarak box tespiti sonuçlarına benzer sonuçlar elde edildiği görülsel de yine mask için ayrıntılı bakıldığından 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 olduğunu kanıtlamaktadır.



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 yaptığı 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 yaklaştırmak için renk koyulmuştur. Confusion matrixe göre bakıldığından 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 detaylandırmakta ve modelin yer işaretlerinin tespiti senaryolarındaki başarımı değerlendirmektedir.

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 bakıldığından yine Mandibularangle, Mandibularcanal ve Mandibularcondyle yer işaretleri 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 işaretleri bölgesi olmuştur yani model bu bölgeyi tespit ederken zorlanmıştır.

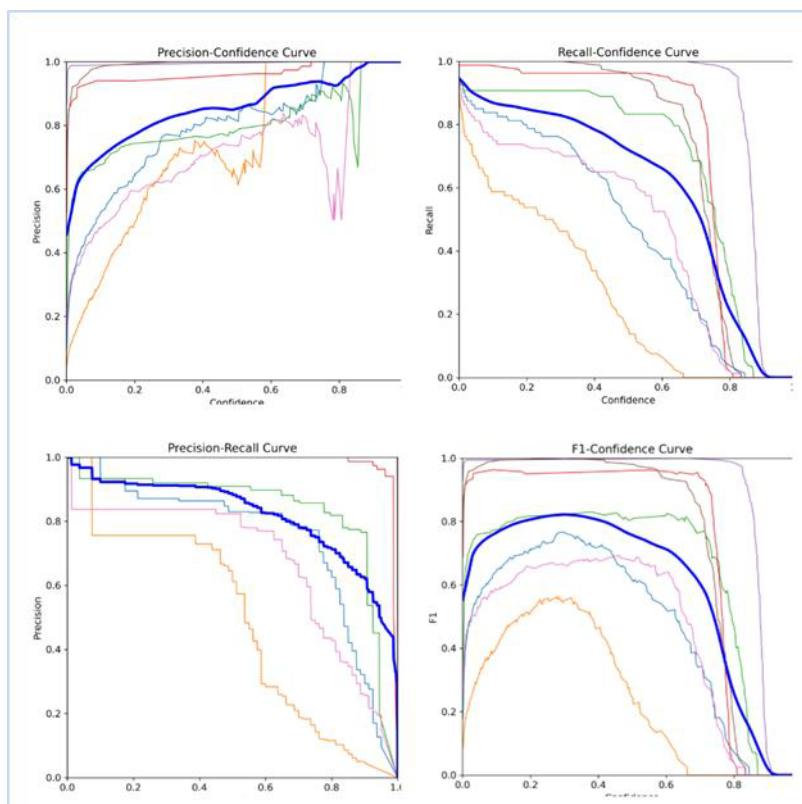
Tüm bölgeler açısından bakıldığından genel olarak F1 skoru iyi sonuç vermiştir, mAP50-95 değerlerine bakıldığından diğer modellere göre daha yüksektir ama modelin zorlayıcı eşik değerlerinde hala geride kaldığı söyleneilmektedir.

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 edilirliğinin bu sebeple zor olmasıdır. Ancak, segmentasyon konusunda YOLOv8'e göre biraz daha iyi sonuç vermiştir. Ama mAP50-95 değerlerine bakıldığından tespit hassasiyetinin hala artırılması gereği görülmektedir.

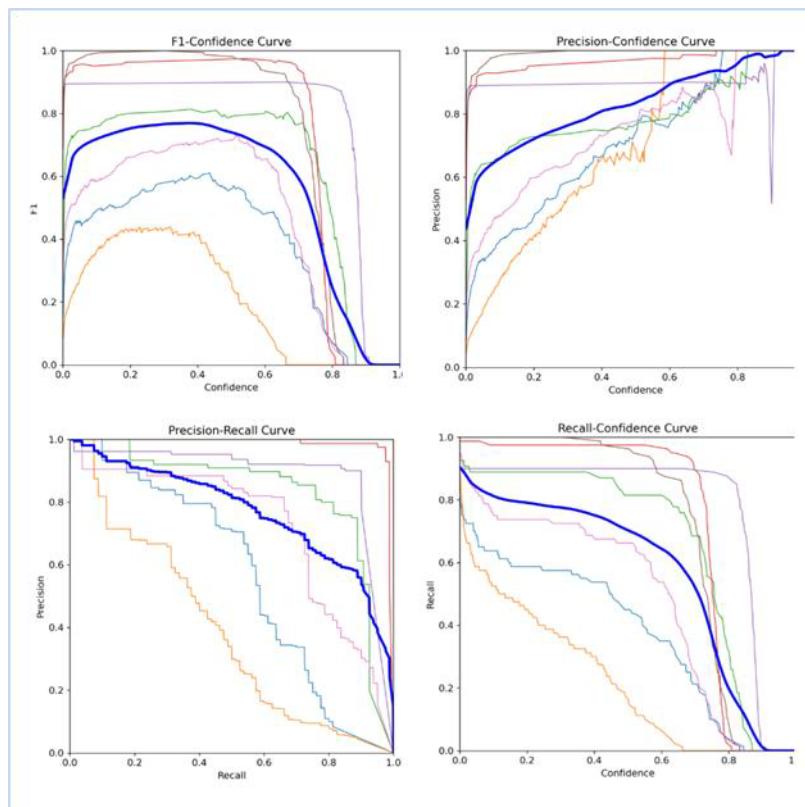
Sonuçlardan Elde Edilen Grafikler



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

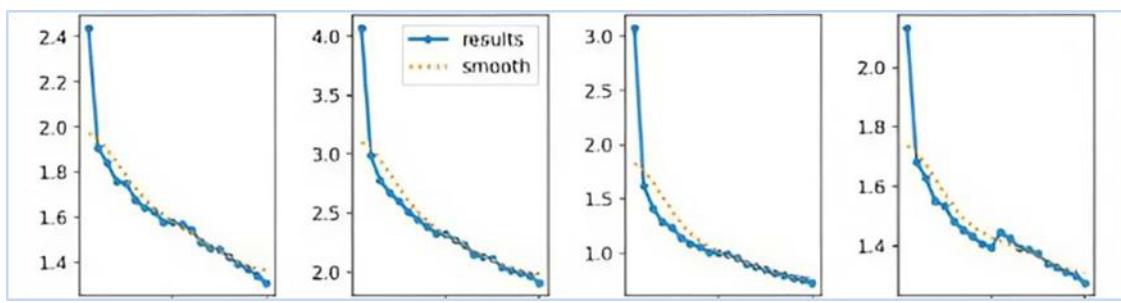
Şekil 16' da Box tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Mavi kalın çizgiyle gösterilen değer tüm sınıfların ortalamasını belirtmektedir. Grafiklere bakıldığından mavi çizginin genel olarak başarılı sonuçlar elde ettiği ama turuncu çizgiyle belirtilen Foramenmentale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

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



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

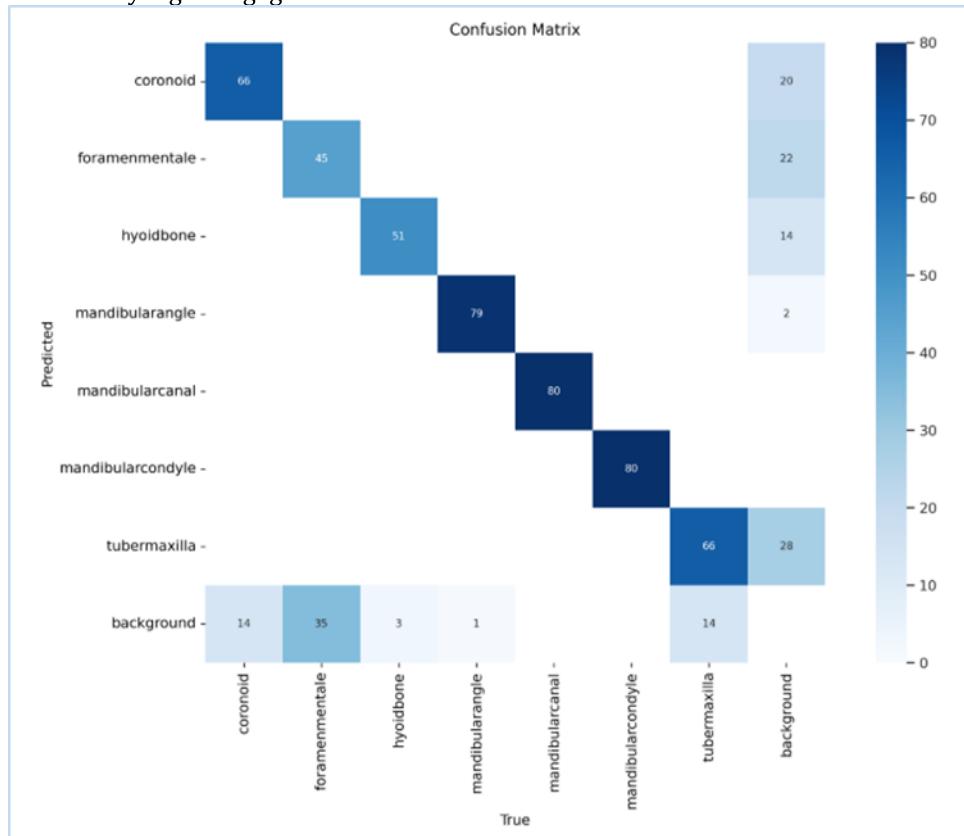
Şekil 17' de Mask tespiti için elde edilen metriklerin değerleri grafik üzerinde gösterilmektedir. Grafiksel olarak box tespiti sonuçlarına benzer sonuçlar elde edildiği görülselde mask için ayrıntılı bakıldığından tüm grafiklerde daha az başarı oranı olduğu açıklar.



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 söylemelmektedir. Sınıf tespitindeki kayıp (cls_loss) nesneleri doğru sınıflandırmada sürekli bir

ilerleme kaydetmiştir. Bounding box koordinatları (df_l_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 yaklaşıkça renk koyulmuştur. Confusion matrixe göre bakıldığından en iyi değeri alan sınıflar Mandibularcanal, Mandibularangle 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 olduğunu 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 bakıldığından 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 görülmektedir. YOLOv5 dengeli bir performans sergilediği halde diğer modellerden geri kalmaktadır.

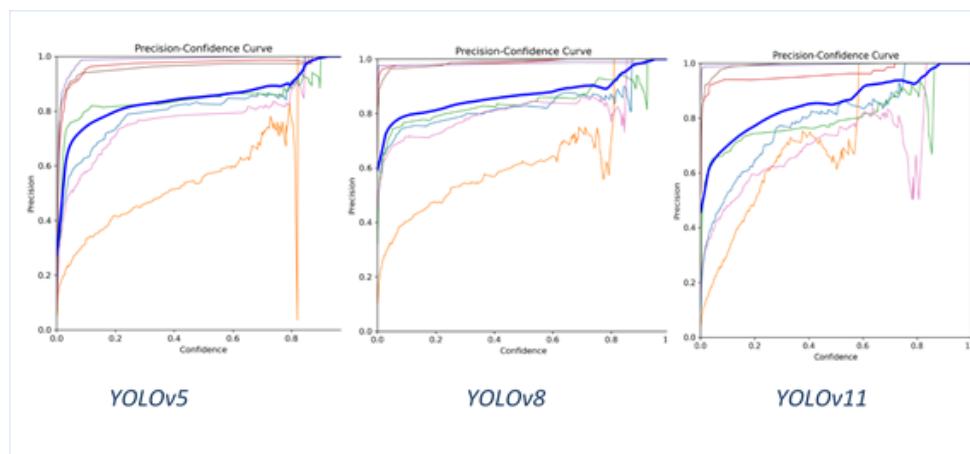
Tablo 10. Tüm modellerin maske tespiti için F1, mAP50, mAP50-95 değerleri

| 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 |

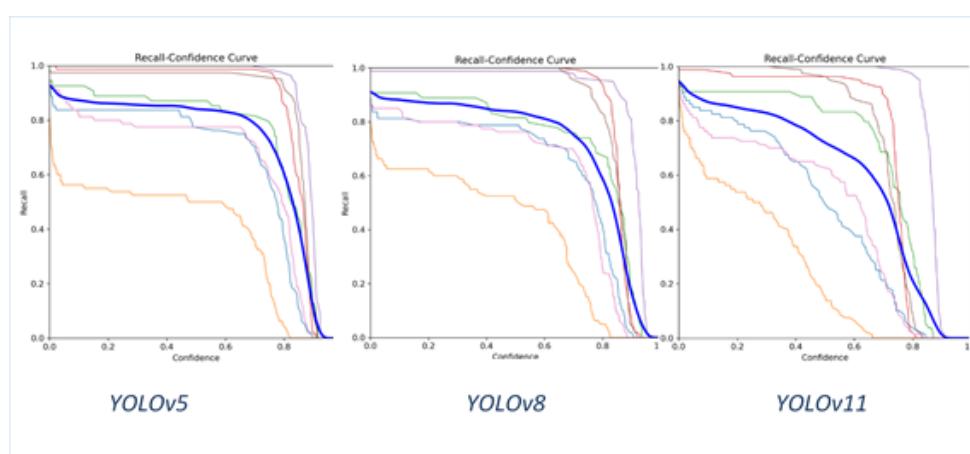
Tablo 10 değerlerine bakıldığında mask tespitinde F1 metriklerinde en başarılı skora sahip olan model YOLOv11 olduğu görülmekteken YOLOv8 az farkla onu takip etmektedir. mAP50 metriği için en iyi performansı sergileyen YOLOv11, mAP50-95 metriğinde de öne çıktıgı gözlemlenmektedir. Az farkla YOLOv8 de 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

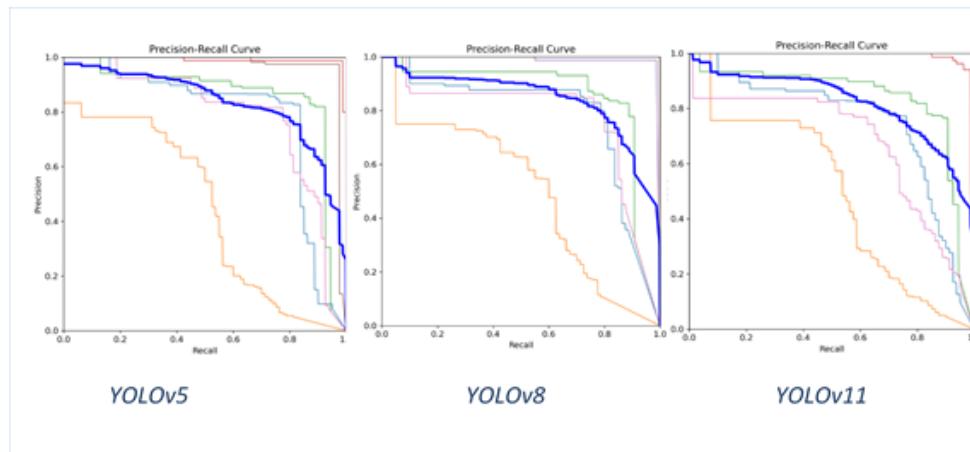
Bu kısımda YOLOv5, YOLOv8 ve YOLOv11 modellerine ait değerlendirme metrikleri grafikler şeklinde karşılaştırılmış ve en iyi model ortaya konulmuştur. Şekil 20, Şekil 21, Şekil 22 ve Şekil 23' te karşılaştırılan grafikler bakıldığından YOLOv8'in genel olarak tüm değerlerde stabil ve başarılı değerler aldığı 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.



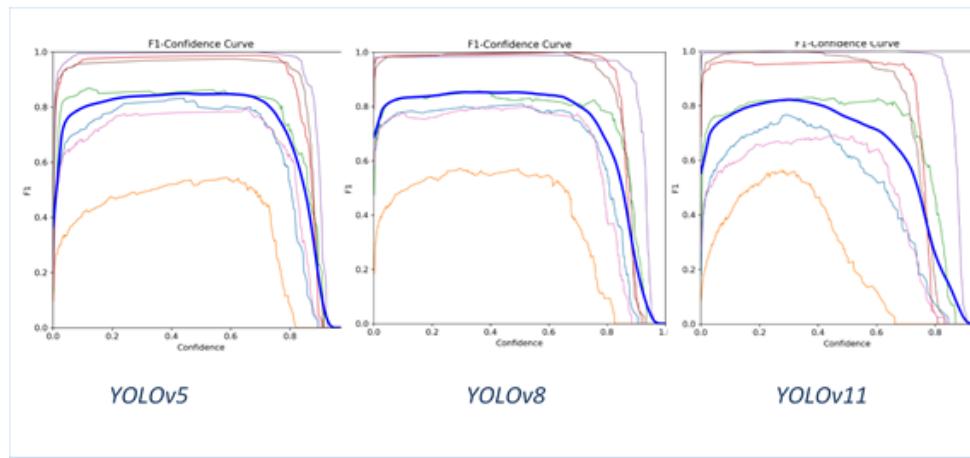
Şekil 20. Kesinlik değerlerine göre model grafikleri



Şekil 21. Duyarlılık değerlerine göre model grafikleri



Şekil 22. Kesinlik - Duyarlılık değerlerine göre model grafikleri



Şekil 23. F1 değerlerine göre model grafikleri

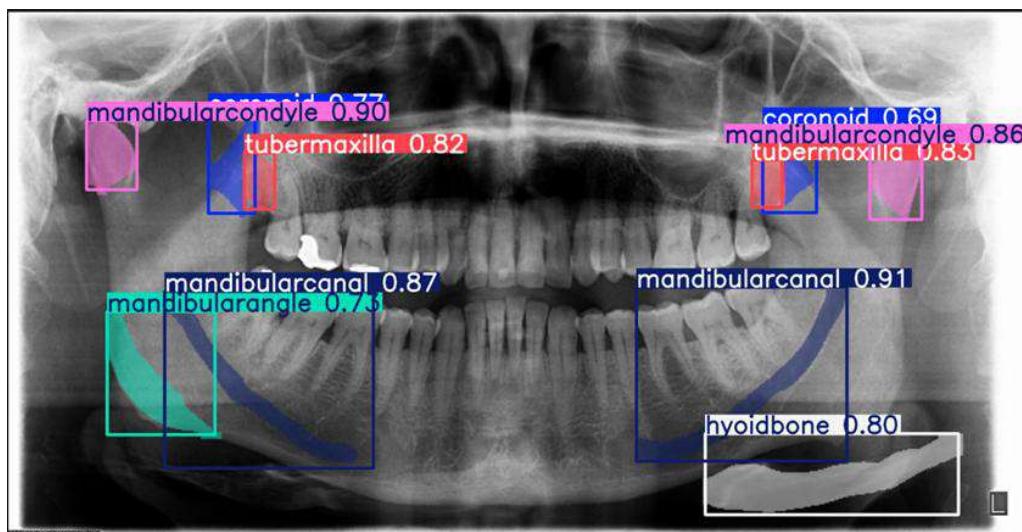
Örnek Görüntü Etiketlemeleri ile Modellerin Karşılaştırılması

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



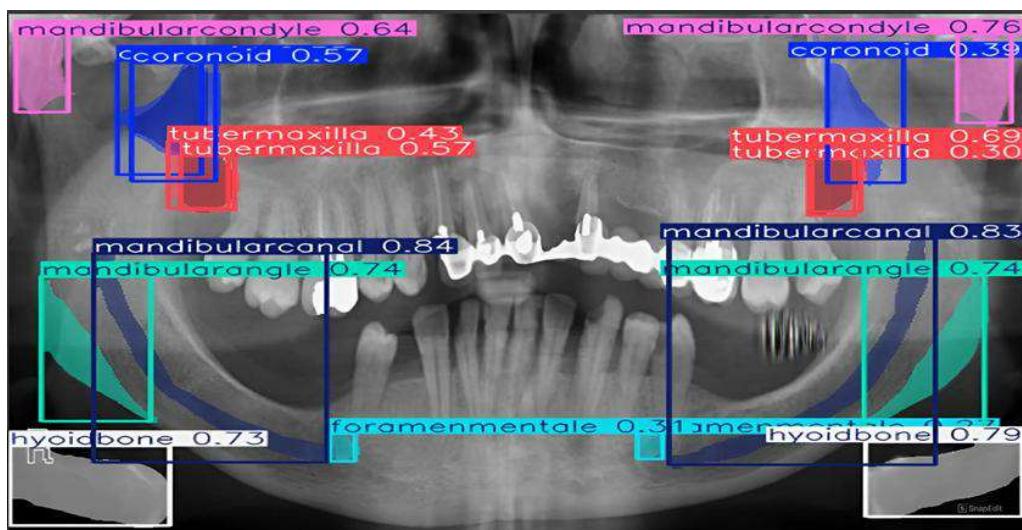
Şekil 24. YOLOv5 örnek görüntü üzerinde etiketlenen bölgelerin gösterimi

Şekil 24' te YOLOv5 için örnek bir görüntü üzerinde anatomi yer işaretlerinin tespitindeki başarımları gösterilmektedir. Bu görüntüye bakıldığından Mandibularcondyle 0.69, Coronoid 0.58, Tubermakilla 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 anatomi yer işaretlerinin tespitindeki başarımları gösterilmektedir. Bu görüntüye bakıldığından 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 anatomi yer işaretlerinin tespitindeki başarımları gösterilmektedir. Bu görüntüye bakıldığından 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 genelleştiğini 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 işaretinin 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 gerçekleştirilmişdir. Sonuç olarak, yeterince yüksek başarı oranlarına ulaşmış olsa da daha fazla veri kullanılarak çok daha iyi sonuçların elde edilmesinin, mevcut değerlere bakıldığına kaçınılmaz olduğu görülmektedir. Aynı zamanda yapılan çalışmada anatomik yer işaretlerinin bir kısmı kullanıldığından, ilerleyen çalışmalarında 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 Image]", 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, Soltaninehr 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] Widiasri, 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., Altuntas, 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.