

Xception ile Histopatolojik Görüntülerden Oral Kanser Teşhisi

Cihan Akyel^{1,*}

¹Milli Eğitim Bakanlığı, İnşaat ve Emlak Genel Müdürlüğü, Ankara, Türkiye

Makale Tarihiçesi

Gönderim: 05.12.2022

Kabul: 18.01.2023

Yayın: 30.06.2023

Araştırma Makalesi

Öz – Oral kanser dünya genelinde sık görülen bir kanser türlerindedir. Etkili olan hücre türüne göre farklı oral kanser türleri vardır. Oral kanser türleri arasında en yüksek oran skuamöz hücreli türüne aittir. Oral kanserin erken teşhisi tedavi açısından çok önemlidir. Bu kanser türünde, lezyonlar görülüp hissedilen bölgelerde olmalarına rağmen teşhislerinde geç kalmaktadır. Teşhis sürecinde biyopsi, histopatolojik ve radyolojik görüntülerin incelenmesi, kullanılan başlıca yöntemlerdir. Hastalıkların teşhis sürecinde derin öğrenme yapılarını kullanan karar destek sistemleri sağlık sektöründe yaygınlaşmaktadır. Literatürde oral kanserin derin öğrenme ile sınıflandırılmasında farklı modelleri kullanan çalışmalar yer almaktadır. Bu çalışmada mevcut literatürden farklı olarak Xception modeli ön eğitimli ve ardışıl algoritmayla birlikte modifiye edilmiş şekilde kullanılmıştır. Normal ve oral skuamöz hücreli kanserler şeklinde iki sınıfta bulunduğu eğitim aşamasında sırasıyla %98.70 eğitim başarısı, %97.20 zar doğruluğu, %96.50 hassasiyet ve %97 duyarlılık elde edilmiştir. Elde edilen bu değerler literatürde yer alan diğer bazı çalışmalarla karşılaştırılmıştır. Çalışmada Xception modelinin Clahe ile birlikte oral kanser sınıflandırmasında uygun bir seçenek olduğu ve teşhis sürecinde yararlı olabileceği görülmüştür.

Anahtar Kelimeler – Derin öğrenme, kanser sınıflama, karar destek sistemleri, oral kanser, xception

Diagnosis of Oral Cancer from Histopathological Images with Xception

^{1*} Ministry of National Education, General Directorate of Construction and Real Estate, Ankara, Türkiye

Article History

Received: 05.12.2022

Accepted: 18.01.2023

Published: 30.06.2023

Research Article

Abstract – Oral cancer is one of the most common cancers worldwide. There are different types of oral cancer depending on the type of cell that is affected. The highest rate among oral cancers belongs to the squamous cell type. Early diagnosis of oral cancer is very important for treatment. In this type of cancer, although the lesions are in areas where they can be seen and palpated, the diagnosis is made late. Biopsy, examination of histopathological and radiological images are the main methods for diagnosis. Decision support systems that use the structures of deep learning in the diagnosis process of diseases are becoming widespread in the health sector. There are studies in the literature that use different models to classify oral cancer with Deep Learning. In this study, unlike the existing literature, the Xception model was used in a modified form with a pre-trained and sequential algorithm. In the training phase, in which there were two classes, namely normal and oral squamous cell carcinomas, 98.70% training accuracy, 97.20% dice coefficient, 96.50% sensitivity, and 97% sensitivity were obtained, respectively. These values were compared with some other studies in the literature. The study concluded that the Xception model together with Clahe is a suitable option for the classification of oral cavity cancer and can be useful for the diagnostic process.

Keywords – Cancer Classification, Decision Support Systems, Deep learning, Oral cancer, Xception

¹ cihan.akyel1@gazi.edu.tr

*Sorumlu Yazar

1. Giriş

Dünya genelinde en çok görülen altıncı kanser türü olan oral kanser görülme sıklığı giderek artmaktadır. Oral kanser kadınlara oranla erkeklerde daha fazla görülür. Bu duruma sebep olarak sigara kullanımının erkekler arasında daha yaygın olması gösterilebilir. Oral kanserler oral skuamöz hücreli kanserler (OSHK) olarak adlandırılmaktadır. Ağızda oluşan kanserlerin yaklaşık %90'ı OSHK, %5-10 arası ise minör tükürük bezi karsinomlarıdır. Oral kanserlerde hastalarda ağrı görülmektedir. Hem ağrı belirtisi hem de görülebilir bölgede olmasından kaynaklı olarak daha kolay teşhis edileceği düşünülse de genellikle teşhis hastalığın ileriki evrelerinde olabilmektedir. Bu durumun temel nedeni ağrının ilerleyen aşamalarda şiddetinin artmasıdır. Oral kanser ilerledikçe farklı organlara metastaz yapabilmektedir (Coşan ve Yılmaz, 2022).

Oral kanserlerin teşhis sürecinde diş hekimleri önemli bir yere sahiptir. Rutin ya da rutin dışı diş kontrollerinde oral kanserler tespit edilebilmektedir. OSHK'ler en sık görülen histopatolojik türdür ve klinik bulgular ve anamnez (hasta öyküsü) ile teşhisi mümkün olabilmektedir (Koca ve Yenidünya, 2020). Oral kanser metastaz yaparak akciğer ve mide kanseri görülme ihtimalini artırmaktadır (Sağlam ve Özsağır, 2020). Erken teşhis edilmeyen vakalarda fonksiyon kayıpları ve düzeltilmesi imkânsız hale gelen ağız ve yüz deformasyonları görülebilmektedir (Taş vd., 2020).

Oral kanserli hastaların hayatta kalma oranları yaklaşık %40'tır. Hastalığın erken teşhisi durumunda hayatta kalma oranı %80'lere çıkabilmektedir. Dudak kanserleri de oral kanser sınıfına girmektedir. Oral kanserlerin temel sebepleri arasında alkol ve sigara kullanımı ve ağız hijyeni gibi faktörler etkili olabilmektedir (Mollaoğlu vd., 2021). Oral kanserler Türkiye'de en çok görülen kanser türleri arasında ikinci sıra yer almaktadır. Oral kanserler dudak, sublingual alan ve dilde görülebilmektedir.

Oral kanserlerin teşhisinde anamnezi, fiziksel muayene, radyolojik bulguların incelenmesi ve biyopsi kullanılan yöntemler arasındadır. Oral kanserlerin erken teşhisinde ilk basamak olarak diş hekimleri görülmektedir. Bu tür klasik yöntemlerin yanı sıra yapay zekânın bu alanda kullanımı da önemli hale gelmektedir. Diş hekimliğinde yapay zekâ kullanımı hem hasta bakım kalitesi artırma hem de oral kanser teşhisi açısından önemli olabilecektir (Özkesici ve Yılmaz, 2021). Özellikle kanser teşhisi için karar vericilere destek sağlayan, model bileşeninde derin öğrenme yapılarını bulandıran karar destek sistemleri (KDS) yaygınlaşmaktadır. KDS'lerde kullanılacak derin öğrenme ile teşhis sürecini daha hızlı, başarılı hale getirmek mümkün olabilmektedir (Özdemir vd., 2022).

Bu bölümde oral kanserlerin teşhisi için literatürde yer alan derin öğrenme algoritmaları ve görüntü işleme tekniklerini içeren çalışmalar incelenmiştir. Görüntülerin sınıflandırılmasında piksel özelliklerinin kullanıldığı çalışmalar literatürde yer almaktadır. Görüntülerde yoğunluk, kontrast, parlaklık gibi piksel değerlerine göre özellikler kaydedilmekte ve algoritmalara giriş olarak verilmektedir. Aberville vd., (2017) oral kanserin teşhisi için bir çalışma sunmuşlardır. Çalışmada sınıflandırma işlemi için GLCM ile piksel özellikleri belirlenmiştir. Daha sonra bu GLCM özellikleri destek vektör makineleri algoritmasında kullanılarak sınıflandırılmıştır. Çalışmada %96 auc (area under the curve), %88.3 eğitim, %86.6 hassasiyet ve %90 özgüllük değerlerine ulaşılmıştır.

Görüntü ön işleme görüntülerde arka plan ve ön plan nesnelere birbirinden ayrılarak algoritmasının gerekli öznelikleri çıkarması kolaylaştırılarak başarı artışı sağlanmaktadır. Yine görüntü ön işlemenin yapılmadığı diğer bir çalışmada %70.59 eğitim başarısı elde edilmiştir. Çalışmada destek vektör makineleri yöntemi ile sınıflama görüntülerin sınıflandırılması yapılmıştır (Chu vd., 2020). Alhazmi vd., (2021) tarafından yapay sinir ağları kullanılarak yapılan çalışmada %78.95 eğitim başarısı elde edilmiştir. Başarının düşük olmasında veri setinde ön işleme yapılmamış olmasının etkisi vardır. ResNet farklı türevleri ile birlikte sınıflama aşamalarında sıkça kullanılan bir algoritmadır. Welikala vd., (2020) tarafından yapılan bir çalışmada bir ResNet türevi olan ResNet101 algoritması tercih edilmiştir. Görüntü ön işleme aşamasının yer almadığı bu çalışmada %78.30 eğitim başarısı elde edilmiştir.

Literatürde temel modellerin başarı artışı sağlayacak şekilde modifiye edilerek farklı isimlerle kullanıldığı çalışmalar yer almaktadır. EfficientNetB0'ı temel alan bir derin öğrenme algoritması çalışma kapsamında eğitim aşamaları için tercih edilmiştir. OSHK'nın teşhisi için yapılan diğer bir çalışmada %94.9 hassasiyet, %98.3 auc değerleri elde edilmiştir (Fu vd., 2020). Lin vd., (2021) çalışmalarında HRNet adlı CNN temelli bir algoritma kullanmışlardır. Normal ve kanser türünü de içeren toplam beş sınıfa sahip bir veri seti çalışma kapsamında değerlendirilmiştir. Veri setinde yer alan görüntüler, lezyonların buldukları lokasyona göre yeniden örneklenmiştir. Çalışmada %83.6 f1-skoru, %83 hassasiyet (sensitivity), %84.3 tahmin (precision) çalışmada elde edilmiştir.

Alkhadar vd. (2021) oral kanserin yapay zekâ ile teşhisi için bir çalışma sunmuşlardır. Çalışmada naive bayes, lojistik regresyon ve karar ağaçları olmak üzere farklı sınıflama algoritmaları eğitim aşamasında denenerak karşılaştırılmıştır. En yüksek başarı %76 eğitim başarısı ile karar ağaçları yöntemiyle elde edilmiştir. Shavlokhova vd., (2021) tarafından sunulan çalışmada MobileNet kullanılarak eğitim aşaması tamamlanmıştır. Çalışmada %47 hassasiyet, %96 özgüllük (specificity) elde edilmiştir. Warin vd., (2021) oral kanserin sınıflandırılması için bir çalışma sunmuşlardır. Çalışmada farklı modeller kullanılarak model başarıları arasında karşılaştırma yapılmıştır. DenseNet121 modeli kullanılarak %99 tahmin ve %100 duyarlılık (recall) değerleri elde edilmiştir. 350 tane OSHK örneği içeren ve 700 örnekten oluşan bir veri seti kullanılmıştır.

Rahman vd., (2022) tarafından sunulan AlexNet temelli algoritma ile oral kanser, OSHK ve normal olmak üzere iki sınıfa ayrılmıştır. Kaggle'a ait veri seti çalışma kapsamında tercih edilmiştir. Çalışmada %90.06 eğitim başarısı, %92.74 hassasiyet (sensitivity), %90.15 f1-skor değerleri elde edilmiştir. Jubair vd., (2022) tarafından sunulan çalışmada 480 iyi huylu 236 şüpheli olmak üzere 716 görüntünün yer aldığı bir veri seti kullanılmıştır. Bu çalışmada sırasıyla %85 eğitim başarısı, %86.7 hassasiyet (sensitivity) değerleri elde edilmiştir.

Çalışmada SVM, ResNet101, AlexNet gibi popüler sınıflandırma algoritmalarını kullanan çalışmalarla karşılaştırma sonuçlarına yer verilmiştir. Xception modelinde giriş verileri üzerine clahe ile kontrast iyileştirme uygulanmıştır. Karşılaştırma sonuçları Xception modelinin oral kanser sınıflandırmasında uygun diğer algoritmalara göre daha uygun bir çözüm olduğunu göstermiştir.

2. Materyal ve Yöntem

Çalışmada kaggle'a ait halka açık bir veri seti kullanılmıştır. Bu veri seti üzerinde veri artırma uygulanmıştır. Daha sonra veri seti %70 eğitim %20 doğrulama ve %10 test olacak şekilde ayrılarak eğitime alınmıştır. Eğitim aşamasında önerilen model için kullanılan hiper parametreler Tablo 1'de verilmiştir.

Tablo 1
Hiper Parametreler

Parametre	Değer
Yığın Boyutu (Batch size)	16
Giriş Boyutu (Input Size)	256 x 256
Öğrenme Katsayısı (Learning Rate)	0.0001
Epok Sayısı (Number of Epochs)	50
En İyileyici (Optimizer)	Adam
Kayıp Fonksiyonu (Loss Function)	Binary cross entropy
Çıkış Fonksiyonu (Output Function)	Sigmoid

2.1. Veri Seti ve Veri Artırma

Çalışmada kaggle'a ait histopatolojik görüntüleri içeren halka açık bir veri seti tercih edilmiştir. Veri seti üzerinde yatay/dikey çevirme, 90/180 derece döndürme işlemleri ile veri artırma uygulanarak, veri sayısı dört katına çıkarılmıştır. Veri artırma ile sistemin eğitim aşamasında ezbere düşmesi önlenmeye çalışılmıştır. Veri seti küçük olduğunda model, veri setini ezberleyebilmektedir. Bu durumda eğitim başarısında yapay bir artış görülürken doğrulama başarısı düşmektedir. Tablo 2'de veri setinin dağılımı verilmiştir. Dağılımda veri artırma ile oluşan veri seti %70 eğitim %20 doğrulama ve %10 test olacak şekilde ayrılmıştır.


Tablo 2

Veri Seti Dağılımları

Veri Seti	Sınıf	Sayı	Veri Artırma	Eğitim (%70)	Doğrulama (%20)	Test (%10)
Kaggle	Normal	5001	20004	14002	4002	2000
	Skuamöz hücreli kanser	5001	20004	14002	4002	2000
TOPLAM			15148	28004	8004	4000

2.2. Ön İşleme

Veri setindeki görüntüler üzerinde kontrast iyileştirme uygulanmıştır. Kontrast iyileştirme için clahe algoritması kullanılmıştır. Bu işlem için de opencv kütüphanesinde yer alan createCLAHE fonksiyonu tercih edilmiştir. Bu süreç ile görüntü üzerindeki dokuların görünürlüğü artırılmıştır. Bu yöntem ile derin öğrenme algoritması sonucu elde edilecek başarı artmaktadır. Sürece ait örnek görseller Şekil 1'de görülmektedir.




Şekil 1. Ön işleme süreci

2.3. Sınıflandırma Algoritması

Sınıflandırma aşamasında seçilen ön eğitilmiş Xception modeli temel model olarak alınmıştır. Xception 2017 yılında ortaya konan sınıflama modelidir. Model giriş akışı, orta akış ve çıkış akışı olarak üç modülden oluşmaktadır. Giriş modülü 3x3 çekirdek boyutuna sahip, evrişim katmanları ve maksimum havuzlama katmanlarını içermektedir. Orta akış modülü 8 kez tekrarlanan evrişim katmanlarından oluşmaktadır. Çıkış akışı modülü ise 2 evrişim katmanı, maksimum havuzlama, 2 evrişim katmanı ve global havuzlama katmanlarından oluşmaktadır. Bu modelde kullanılan evrişim katmanlarının tamamı ayrılabilir (seperable) evrişim katmanlarıdır. Ayrılabilir evrişim, tek bir evrişimin aynı çıktıyı üretmek için iki veya daha fazla evrişime bölünebildiği bir süreçtir. Tek bir süreç, aynı etkiyi elde etmek için iki veya daha fazla alt sürece bölünür. Bu katmanlar, geleneksel evrişim katmanlarına göre hesaplama gereksinimlerini azaltarak ağın sadeleştirmektedir.

Çalışmada Xception modeli imageNet ağırlıkları ile birlikte ön eğitilmiş olarak kullanılmıştır. Bu durum eğitim süresinin azalmasını ve başarı artışını sağlamaktadır. Xception modelinin çıkışı, önce flatten katman ile ardışıl algoritmaya hazırlanmıştır. Daha sonra bu modelin çıkış katmanı ile elde edilen öznelikler, geliştirilen sıra tabanlı bir algoritmaya girdi olarak alınmıştır. Sıra tabanlı algoritma yoğun katman (dense layer), aktivasyon (activation) ve bırakma (dropout) katmanlarından oluşmaktadır. Bırakma katmanları ile öğrenilmesi gerekmeyen özellikler azaltılarak, sistemin ezberine düşmesi önlenmeye çalışılmıştır. Son katman olarak kullanılan dense katmanında çıkış sınıf sayısı kadar nöron yer almaktadır. Algoritmanın genel yapısı Şekil 2’de görülmektedir.



Şekil 2. Sınıflama algoritması

3. Araştırma Bulguları

Çalışmada normal ve OSHK olmak üzere ikili sınıflama yapılmıştır. Temel model olarak Xception dışında ResNet50, VGG16 ve VGG19 modelleri de eğitim aşamalarında kullanılmış ve karşılaştırılmıştır. Tablo 3’te eğitim aşamasında farklı modellerle elde edilen sonuçlar yer almaktadır.

Tablo 3

Eğitim aşaması model karşılaştırmaları

Model	Eğitim Başarısı (Accuracy)	Zar Doğruluğu (Dice Coefficient)
VGG16	94,80	93,30
VGG19	94,85	93,55
ResNet50	97,50	96,10
Önerilen Model	98.70	97.20

Tablo 4 önerilen yaklaşımın diğer bazı çalışmalarla olan karşılaştırma sonuçlarını temsil etmektedir. Şekil 3'te test veri seti ile elde edilen precision (tahmin), recall (duyarlılık) ve f1-skor değerleri yer almaktadır.

Tablo 4

Eğitim aşaması karşılaştırma sonuçları

Çalışma	Model	Eğitim Başarısı – Accuracy (%)	Özgüllük-Specificity (%)	Tahmin-Precision (%)	Duyarlılık-Recall (%)	Hassasiyet-Sensitivity (%)	AUC (%)	F1-Skor-F1-Score (%)
Lin vd., (2021)	HRNet	-	-	84.30	-	83.00	-	83.60
Warin vd., (2021)	DenseNet	-	-	99.00	100	-	-	-
Jubair vd., (2022)	EfficientNetB0	85.00	-	-	-	86.70	-	-
Fu vd., (2020)	DCNN	-	-	-	-	94.90	98.30	-
Rahman vd., (2022)	AlexNet	90.60	-	-	-	92.74	-	90.15
Alhazmi vd., (2021)	CNN	78.95	-	-	-	-	-	-
Chu vd., (2020)	SVM	70.59	-	-	-	-	-	-
Welikala vd., (2020)	ResNet101	78.30	-	-	-	-	-	-
Shavlokhova vd., (2021)	MobileNet	-	96.00	-	-	47.00	-	-
Aberville vd., (2017)	SVM	88.30	90.00	-	-	86.60	96.00	-
Alkhadar vd. (2021)	Karar Ağacı	76.00	-	-	-	-	-	-
Önerilen Model	Xception	98.70	97.00	97.00	97.00	96.50	98.40	97.30

	precision	recall	f1-score
0	0.96	0.98	0.97
1	0.98	0.96	0.97
accuracy			0.97
macro avg	0.97	0.97	0.97
weighted avg	0.97	0.97	0.97

Şekil 3. Test veri seti başarı değerleri

4. Sonuçlar ve Tartışma

Özellikle medikal görüntülerin sınıflandırılmasında imageNet gibi büyük veri tabanları ile eğitilmiş ön eğitilmiş modellerin, başarı artışı sağladığı görülmektedir. Ayrıca veri setlerindeki görüntülerin kontrast iyileştirmeye tabi tutulması, derin öğrenme algoritmaları ile elde edilen başarıyı artırmaktadır. Bu durumun temel sebebi görüntüdeki ön plan ve arka planda kalan öğeler arasındaki ayrıştırmanın artmasıdır. Bu durumda evrişim

katmanlarında elde edilecek gereksiz özellikler azaltılarak, sınıflandırma açısından algoritmanın daha sade ve efektif olması sağlanmaktadır. Bu durumlar göz önüne alınarak çalışmada ön eğitilmiş Xception modeli, clahe ile görüntü ön işleme uygulanmış görüntülerle birlikte kullanılmıştır. Xception modelinde yer alan ayrılabilir evrişim katmanları, hesaplama işlemlerini azaltarak ağırlık hızını artırmaktadır. Xception çalışmada denenen diğer modellere göre daha yüksek başarı gösterdiği için tercih edilmiştir.

Sonuçlar bölümünde yer verilen karşılaştırma sonuçlarına göre önerilen yaklaşımın başarılı olduğu görülmektedir. Önerilen yaklaşım ile sırasıyla %98.70 eğitim başarısı, %97.20 zar doğruluğu %97 tahmin, %97 duyarlılık ve %97 f1-skor değerleri elde edilmiştir. Duyarlılık ve tahmin değerleri yüksek ve 2 sınıf içinde yakın değerlerdedir. Bu durum modelin, 2 sınıfın eğitiminde de başarılı olduğunu göstermiştir. Derin öğrenme algoritmalarında bırakma katmanları görüntülerdeki gereksiz özelliklerin atılmasını sağlayarak başarıyı artırmaktadır. Fakat bizim algoritmamızda seçilen 0.4 bırakma değerinin üzerine çıkıldığında başarı düşüşü görülebilmektedir. Her algoritma ve modelin optimum parametreleri farklı olacağı için denemelerle en uygun olanlar seçilmelidir. Bunun yanı sıra ön işlem uygulanan verilerin eğitime alınması başarıyı artırmıştır.

Derin öğrenme ile desteklenen KDS'lerin hastalık teşhisinde kullanımı yaygınlaşmaktadır. Derin öğrenme yapılarının KDS'lerin model bileşeninde kullanılması, teşhis sürecinde insan faktörünün bertaraf edilerek daha başarılı ve hızlı sonuçlar elde edilmesine olanak sağlayabilecektir. Çalışma kapsamında önerilen model teşhis sürecinde karar vericilere karar desteği sağlayabilecektir. Çalışma içerdiği karşılaştırmalar ve literatür taraması ile sonraki çalışmalar açısından yol gösterici olabilir. İleriki çalışmalarda görüntüler dilimlere ayrılarak eğitime alınabilir. Bu yöntem birçok çalışmada özellikle ekran kartı kısıtından dolayı tercih edilmektedir. Bu sayede eğitime alınacak veri setlerindeki olası piksel kayıpları en aza indirgenmiş olmaktadır. Ayrıca modeldeki katmanlar farklı kombinasyonlarla ve parametrelerle denenerek daha iyi sonuçlar elde edilebilir.

Yazar Katkıları

Cihan Akyel: Araştırmada kullanılan veri setini hazır hale getirmiş, hazırladığı model ile eğitimleri gerçekleştirmiş, sonuçları değerlendirmiş ve makalenin yazılmasını gerçekleştirmiştir.

Çıkar Çatışması

Yazar çıkar çatışması bildirmemiştir.

Kaynaklar

- Alhazmi, A., Alhazmi, Y., Makrami, A., Salawi, N., Masmali, K., & Patil, S. (2021). Application of artificial intelligence and machine learning for prediction of oral cancer risk. *J. Oral Pathol. Med.*, 50(5), 444–450.
- Alkhadar, H., Macluskey, M., White, S., Ellis, I., & Gardner, (2021). A. Comparison of machine learning algorithms for the prediction of five-year survival in oral squamous cell carcinoma. *J. Oral Pathol. Med.* 50(4), 378–384.
- Aubreville, M., Knipfer, C., Oetter, N., Jaremenko, C., Rodner, E., Denzler, J., Bohr, C., Neumann, H., Stelzle, F., & Maier, A. (2017). Automatic Classification of Cancerous Tissue in Laserendomicroscopy Images of the Oral Cavity using Deep Learning. *Scientific Reports*, 7, 1-10.
- Chollet, F. (2017, November). Xception: Deep Learning with Depthwise Separable Convolutions, *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, HI, USA, <https://ieeexplore.ieee.org/document/8099678>
- Chu, C.S., Lee, N. P., Adeoye, J., Thomson, P., & Choi, S.W. (2020). Machine learning and treatment outcome prediction for oral cancer. *J. Oral Pathol. Med.*, 49(10), 977–985
- Coşan, G., & Yılmaz, S. (2022). Oral Kanserlerin Tanısında Tükürük Biyobelirteçlerinin Rolü. *Akdeniz Tıp Dergisi*, 8 (2), 218-224. DOI: <https://doi.org/10.53394/akd.1057801>

- Fu Q, Chen Y, Li Z, Jing Q, Hu C, Liu H, Bao J, Hong Y, Shi T, Li K, Zou H, Song Y, Wang H, Wang X, Wang Y, Liu J, Liu H, Chen S, Chen R, Zhang M, Zhao J, Xiang J, Liu B, Jia J, Wu H, Zhao Y, Wan L., & Xiong X. (2020). A deep learning algorithm for detection of oral cavity squamous cell carcinoma from photographic images: A retrospective study. *EClinicalMedicine*, 27,1-7. DOI: <https://doi.org/10.1016/j.eclinm.2020.100558>
- Jubair F, Al-Karadsheh O, Malamos D, Mahdi, S. A., Saad, Y., & Hassona, Y. (2022). A novel lightweight deep convolutional neural network for early detection of oral cancer. *Oral Dis.*,28(4), 1123-1130. DOI: <https://doi.org/10.1111/odi.13825>
- Koca C. G., & Yenidünya O. (2020). Diş Hekimliği Öğrencilerinde Oral Kanser Farkındalık Düzeylerinin Değerlendirilmesi. *Osmangazi Tıp Dergisi*, 42(5), 90-95.
- Lin H, Chen H, Weng L, Shao, J., & Lin, J. (2021). Automatic detection of oral cancer in smartphone-based images using deep learning for early diagnosis. *J Biomed Opt*, 26(8),1-16. DOI: <https://doi.org/10.1117/1.JBO.26.8.086007>
- Mollaoğlu N., Peker İ., Uğar Çankal D. A., Gültekin S. E., & Kılınc Y. (2021). Oral Prekanseroz Lezyonların Teşhis ve Tedavisi. *ADO Klinik Bilimler Dergisi*, 10(3), 159-164.
- Özdemir, G., Bilen, Ö. & Canım Ateş, S. (2022). Hastane Aciline Gelenlerde Kalp Krizi Risk Olasılığının Belirlenmesi için Bir Karar Destek Sisteminin Oluşturulması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 10(4), 2093-2106.
- Özkesici M. Y., & Yılmaz S. (2021). Oral ve Maksillofasiyal Radyoloji’de Yapay Zeka. *Sağlık Bilimleri Dergisi*, 30(3), 346-351. DOI: <https://doi.org/10.34108/eujhs.1040476>
- Rahman AU, Alqahtani A, Aldhafferi N, Nasir MU, Khan MF, Khan MA, & Mosavi A. (2022) Histopathologic Oral Cancer Prediction Using Oral Squamous Cell Carcinoma Biopsy Empowered with Transfer Learning. *Sensors (Basel)*, 22(10), 1-14.
- Sağlam E., & Özsağır Z. B (2020). Oral Kanser ve Periodontal Hastalık İlişkisi Disease. *Osmangazi Tıp Dergisi*. 42(5), 241-248.
- Shavlokhova, V., Sandhu, S., Flechtenmacher, C., Koveshazi, I., Neumeier, F., Padrón-Laso, V., Jonke, Ž., Saravi, B., Vollmer, M., & Vollmer, A. (2021). Deep Learning on Oral Squamous Cell Carcinoma Ex Vivo Fluorescent Confocal Microscopy Data: A Feasibility Study. *J. Clin. Med.* 10(22), 1-13.
- Taş A., Yılmaz S., & Sindel A. (2020). Oral Skuamoz Hücreli Karsinom – 3 Olgu Sunumu. *Osmangazi Tıp Dergisi*, 42(5), 142-147.
- Warin K, Limprasert W, Suebnukarn S, Limprasert, W., Jantana, P., & Jinaporntham, S. (2021). Automatic classification and detection of oral cancer in photographic images using deep learning algorithms. *J Oral Pathol Med*, 50(9). DOI: <https://doi.org/10.1111/jop.13227>
- Welikala, R.A., Remagnino, P., Lim, J. H., Chan, C.S., Rajendran, S., Kallarakkal, T.G., Zain, R.B., Jayasinghe, R. D., Rimal, J., & Kerr, A. R. (2020). Automated Detection and Classification of Oral Lesions Using Deep Learning for Early Detection of Oral Cancer. *IEEE Access*, 8, 132677–132693.