



Tıp Fakültesi

**T.C.
MARMARA ÜNİVERSİTESİ
TIP FAKÜLTESİ
KULAK BURUN BOĞAZ VE BAŞ BOYUN CERRAHİSİ ANABİLİM DALI**

**SULKUS TANILI HASTALARIN VİDEOSTROBOSKOPİK
GÖRÜNTÜLERİNİN YAPAY ZEKA TEMELLİ TANISAL
DEĞERLENDİRİLMESİ**

UZMANLIK TEZİ

İSTANBUL 2024



Tıp Fakültesi

**T.C.
MARMARA ÜNİVERSİTESİ
TIP FAKÜLTESİ
KULAK BURUN BOĞAZ VE BAŞ BOYUN CERRAHİSİ ANABİLİM DALI**

**SULKUS TANILI HASTALARIN VİDEOSTROBOSKOPİK
GÖRÜNTÜLERİNİN YAPAY ZEKA TEMELLİ TANISAL
DEĞERLENDİRİLMESİ**

UZMANLIK TEZİ

İSTANBUL 2024

İÇİNDEKİLER

İÇİNDEKİLER	İV
KISALTMALAR LİSTESİ	İİ
ŞEKİLLER LİSTESİ.....	İİİ
TABLolar LİSTESİ.....	İV
1. ÖZET.....	1
2. ABSTRACT	2
3. GİRİŞ VE AMAÇ.....	3
4. GENEL BİLGİLER.....	5
4.1 VOKAL KORD.....	5
4.1.1 Giriş.....	5
4.1.2 Anatomi	5
4.1.3 Histolojisi	5
4.2 BENİNG VOKAL KORD LEZYONLARI	7
4.2.1 Nodül ve polip	7
4.2.2 Kist	8
4.2.3 Laringeal papilloma.....	10
4.2.4 Psödokist	11
4.2.5 Sulkus	12
4.3 VİDEOSTROBOKOPİ	13
4.3.1 Giriş.....	13
4.3.2 Ekipman.....	15
4.4 YAPAY ZEKA VE KLİNİK KULLANIMLARI	17
4.4.1 Giriş.....	17
4.4.2 Makine öğrenimi	18
5. GEREÇ VE YÖNTEM	19
5.1 Modelin Eğitimi, Doğrulanması ve Test Edilmesi.....	23
5. BULGULAR	26
6. TARTIŞMA.....	31
KAYNAKLAR.....	34

KISALTMALAR LİSTESİ

AI	:	Yapay Zeka (Artificial Intelligence)
CNN	:	Konvolüsyonel Sinir Ağı (Convolutional Neural Network)
SVM	:	Destek Vektör Makineleri (Support Vector Machine)
FCL	:	Tam Bağlantılı Katmanlar (Fully Connected Layer)
ML	:	Makine Öğrenimi (Machine Learning)
VF	:	Vocal Fold



ŞEKİLLER LİSTESİ

ŞEKİL 1. VOKAL KORDUN HISTOLOJİK KATMAN YAPISI (R. SATALOFF ET AL., 2015).....	6
ŞEKİL 2. A. VOKAL KORD POLİPİ; B. VOKAL KORD POLİPİ	8
ŞEKİL 3. A. VOKAL KORD KERATİN KİSTİ ; B. VOKAL KORD MUKUS RETANSİYON KİST	9
ŞEKİL 4. VOKAL KORD PAPİLLOMA	11
ŞEKİL 5. VOKAL KORD PSÖDOKİSTİ.....	12
ŞEKİL 6. VOKAL KORD SULKUSU	13
ŞEKİL 7. VOKAL KORDLARIN TİTREŞİM DÖNGÜSÜNÜN STROBOSKOPİK İZLENMESİ	15
ŞEKİL 8. VİDEOSTROBOSKOPİ ÜNİTESİ.....	16
ŞEKİL 9. KONVOLÜSYONEL SINIR AĞI (CNN) MODELİNİN GELİŞTİRİLMESİ İÇİN KULLANILAN VERİ SETİNDEKİ HER ALT KÜMEDEN TEMSİL EDİCİ ÇERÇEVELER (SAĞLIKLI, NODÜL, POLİP, KİST, PSEUDOKİST, PAPİLLOM, SULKUS)	21
ŞEKİL 10. ÇOK KATMANLI KONVOLÜSYONEL SINIR AĞI (CNN) MODELİNİN YAPISI.....	22
ŞEKİL 11. GELİŞTİRİLEN KONVOLÜSYONEL SINIR AĞI (CNN) MODELLERİNİN EĞİTİM VE DOĞRULAMA SÜREÇLERİNDE EPOCH'LARA GÖRE DOĞRULUK VE LOSS (KAYIP) EĞRİLERİ: (A) İKİLİ SINIFLANDIRICI, (B) ÇOKLU SINIFLANDIRICI	25
ŞEKİL 12. KONVOLÜSYONEL SINIR AĞI (CNN) TABANLI ÇOKLU SINIFLANDIRICI İÇİN KARIŞIKLIK MATRİSİ	27
ŞEKİL 13. LARINGOLOGLARIN VE ÖNERİLEN CNN MODELİNİN ANKET VERİ SETİNDEKİ KARIŞIKLIK MATRİSLERİ	30

TABLÖLAR LİSTESİ

TABLO 1. ÇALIŞMA GRUBUNDAKİ HASTA SAYISI VE TEMSİL EDİCİ KARELER...	20
TABLO 2. İKİLİ VE ÇOKLU SINIFLANDIRMA MODELLERİ İÇİN EĞİTİM, DOĞRULAMA, TEST EDİLME VE ANKET VERİSETİNDE KULLANILAN KARE SAYISI.....	23
TABLO 3. ÇOKLU VE İKİLİ SINIFLANDIRMA İÇİN KONVOLÜSYONEL SİNİR AĞI (CNN) TABANLI MODELİN HİPERPARAMETRELERİ	24
TABLO 4. KONVOLÜSYONEL SİNİR AĞI (CNN) TABANLI İKİLİ SINIFLANDIRICI İÇİN KARIŞIKLIK MATRİSİ VE PERFORMANS METRİKLERİ.....	26
TABLO 5. KONVOLÜSYONEL SİNİR AĞI (CNN) TABANLI MODEL VE LARİNGOLOGLARIN TEST VE ANKET VERİLERİNDE ÇOKLU SINIFLANDIRMADA PERFORMANS METRİKLERİ	29

1. ÖZET

Tezin Başlığı: Sulkus tanılı hastaların videostroboskopik görüntülerinin yapay zeka temelli tanısal değerlendirilmesi

Programın Adı: Tıpta Uzmanlık Programı

Amaç: Sulkus tanısında derin öğrenme temelli, bilgisayar destekli bir tanı modeli oluşturarak klinisyenlerin laringoskopi bulgularını değerlendirmesinde yardımcı metodlar geliştirme amaçlanmıştır.

Yöntem: Sulkus tanılı 91, benign vokal kord hastalığı (polip, nodül, papillom, kist veya pseudokist) tanılı 311 ve sağlıklı 33 olmak üzere toplam 433 bireyin videostroboskopileri retrospektif analiz edildi. Videostroboskopilerden 91,159 kare çıkarıldıktan sonra CNN (Konvolüsyonel Sinir Ağı) tabanlı bir model geliştirildi ve çıkarılan karelerle test edildi. Sağlıklı ve sulkus grupları ikili sınıflandırmaya tabi tutuldu. Çalışmanın ikinci fazında, benign vokal kord lezyonları eğitim setine eklendi ve tüm gruplar üzerinde çoklu sınıflandırma yapıldı. Önerilen CNN tabanlı modelin sonuçları, beş laringologun değerlendirmeleriyle karşılaştırıldı.

Bulgular: Sulkus tanılı hastaların görüntülerini tespit etmede, CNN tabanlı algoritma ikili sınıflandırma fazında %98 doğruluk, %98 kesinlik, %98 sensitivite, %97 spesifisite ve %97 F1 Skoru' u göstererek sulkuslu ve sağlıklı grubu ayırt etmiştir. Çalışmanın çoklu sınıflandırma fazında, rastgele seçilen 544 karelik anket test veri setinde, CNN tabanlı model, beş laringologun (%76'ya karşı %72, %68, %72, %63 ve %72) doğruluğuna kıyasla daha yüksek doğruluk performansı gösterdi.

Sonuç: CNN tabanlı bir modelin kullanımı, sulkus gibi tanı sürecinde önemli zorlukların bulunduğu vokal kord hastalıklarının ayırt edilmesine önemli bir katkı sağlar. Bu yaklaşımın klinik uygulamada gerçek zamanlı olarak uygulanabilirliğini değerlendirmek için ileri araştırmalar yapılabilir.

Anahtar kelimeler: Sulkus, derin öğrenme, videostroboskopik görüntü, yapay zeka, konvolüsyonel sinir ağı (CNN)

2. ABSTRACT

Title Of Thesis: An AI-powered diagnostic assessment of videostroboscopic images in patients diagnosed with sulcus.

Program Name: Medical Specialty Program

Purpose: To develop a convolutional neural network (CNN)-based model for classifying videostroboscopic images of patients with sulcus, benign vocal fold (VF) lesions, and healthy VFs to improve clinicians' accuracy in diagnosis during videostroboscopies when evaluating sulcus.

Materials and Methods: Videostroboscopies of 433 individuals who were diagnosed with sulcus (91), who were diagnosed with benign VF diseases (i.e., polyp, nodule, papilloma, cyst, or pseudocyst [311]), or who were healthy (33) were analyzed. After extracting 91,159 frames from videostroboscopies, a CNN-based model was created and tested. The healthy and sulcus groups underwent binary classification. In the second phase of the study, benign VF lesions were added to the training set, and multiclassification was executed across all groups. The proposed CNN-based model results were compared with five laryngology experts' assessments.

Results: In the binary classification phase, the CNN-based model achieved 98% accuracy, 98% recall, 97% precision, and a 97% F1 score for classifying sulcus and healthy VFs. During the multiclassification phase, when evaluated on a subset of frames encompassing all included groups, the CNN-based model demonstrated greater accuracy when compared with that of the five laryngologists (76% versus 72%, 68%, 72%, 63%, and 72%).

Conclusion: The utilization of a CNN-based model serves as a significant aid in the diagnosis of sulcus, a VF disease that presents notable challenges in the diagnostic process. Further research could be undertaken to assess the practicality of implementing this approach in real-time application in clinical practice.

Key words: Sulcus, deep learning videostroboscopic image, artificial intelligence, convolutional neural network (CNN)

3. GİRİŞ ve AMAÇ

Sulkus, vokal kordun mediyal kenarında bulunan, bir girinti ya da oluk anlamına gelen sulkusun varlığıyla karakterize edilen bir patolojik durumdur (1). Sulkus oluşumu, kollajen lif yoğunluğunda bir artışla ilişkilidir. Bu süreç yalnızca vokal kord kenarında lamina propria'nın yüzeysel katmanında meydana gelebilir ya da vokal ligaman içinden tirotenoid kasına ulaşabilir (2). Sulkus, fonasyon sırasında iğsi şekilde glottal yetersizliğinin varlığıyla ayırt edilir, bu da artan hava kaçacağına yol açar. Tarif edilen sulkus patolojisi vokal kordlarda katılığa sebep olarak sesin kaba, nefesli ve astenik olarak ortaya çıkmasına neden olur. Sulkus hastalarında vokal kord seviyesindeki problemler reaktif olarak supraglottal hiperaktivite gözlenmesi ile sonuçlanır. Gözlemlenen klinik belirtiler, fonasyon sırasında ses kısıklığı, ses yorgunluğu ve eforu içerir (1).

Sulkus vokal kordları etkileyen bir durum olarak sınıflandırılrsa da, diğer vokal kord hastalıklarından ve sağlıklı vokal kordlardan ayırt edip teşhis etmek, sulkusun vokal kordlarda sebep olduğu minör belirtiler nedeniyle zordur. Anatomik anormalliklerin (kistler ve polipler) aksine sulkus, vokal kordlarda daha az belirginlikte bir görünüme neden olur. Videostroboskopi, sulkus tanısı için mevcut altın standart testtir (3). Videostroboskopide görülen mukozal dalga amplitüdünün azalması, ilgili vokal kord serbest kenarının düz bir görünümünden ziyade eğik olması, glottik yetersizlik ve bazı durumlarda ventriküllerin kompensatuar aşırı fonksiyonu sulkusun belirtilerindedir. (1, 2). Bununla birlikte, vokal kordlar videostroboskopi sırasında normal görünebilir (4). Dailey ve diğ. (5) ve Sünter ve diğ. (6) tarafından sulkusun videostroboskopi yoluyla teşhisi konusundaki zorluklar da bildirilmiştir. Dailey ve diğ.'e göre, sulkus sıklıkla yanlış teşhis edilen bir vokal kord mukoza hastalığıdır (5). Buna ek olarak, videostroboskopi, kişiler arasındaki önemli değişkenliğe yol açan niteliksel veriler üretir ve bu veriler, sulkus hastalığı konusunda yeterli deneyime sahip olmayan bir klinisyende, sulkusun doğru bir şekilde teşhis edilmesinde zorluğa sebep olabilir (7). Hastalığın nadir görülmesi ve klinisyenler arasında farkındalığının az olması, videostroboskopik teşhisle ilişkili zorluklar ile birlikte, klinisyenleri yardımcı bilgisayar temelli tanı yöntemlerini araştırmalarına yol açmıştır.

Bilgisayarların işlemci kapasitelerindeki gelişmeler nedeniyle derin öğrenme tekniklerinin (örneğin, konvolüsyonel sinir ağları [CNN]) yaygın olarak kullanılması, özellikle görüntü tanıma alanındaki yapay zeka (AI) modellerinde önemli ilerlemelere katkıda bulunmuştur (8). Laringologlar tarafından sıklıkla uygulanan, vokal kord hastalıkları tanısında önemli bir yeri olan videostroboskopi, makine öğrenimi (ML) ve bilgisayarla görü alanında AI modelleri için çok sayıda görüntü verisi sağlar. Bu durum, Kulak Burun Boğaz alanında AI uygulamalarıyla ilgili yayınların artmasına da yol açmıştır (9, 10, 11). Bu çalışmalar, lezyon tanıma, vokal kord titreşim analizi, vokal kord hareketinin belirlenmesi, laringeal yapıların tanımlanması ve karakterizasyonu, görüntü geliştirme ve tanı koydurucu kare (çerçeve) seçimi de dahil olmak üzere çok çeşitli uygulamaları içermektedir (10).

Bening ve malign vokal kord lezyonlarının teşhisi ve sınıflandırmasıyla ilgili çeşitli çalışmalar olmasına rağmen, sulkusun temel olarak ele alındığı ve diğer vokal kord hastalıklarından ayırt edilmesine yardımcı bilgisayar temelli tekniklerin araştırıldığı bir çalışma literatürde gözlenmedi. Bu çalışmada, ana hedefimiz, sulkusu sağlıklı vokal kordlardan ve polipler, nodüller, papillomalar, kistler ve psödokistler gibi benign vokal kord lezyonlarından ayırt etmek için sağlıklı ve hastalıklı vokal kordlara ait videostroboskopik karelerin sınıflandırılmasında kullanılacak CNN tabanlı bir model oluşturmaktır. Böylelikle videostroboskopi bulgularının değerlendirilmesinde daha objektif bir tanı metodu geliştirilerek klinik değerlendirme ve tanı koymadaki doğruluğun artmasında alternatif bir yöntem önerilecektir.

4. GENEL BİLGİLER

4.1 Vokal Kord

4.1.1 Giriş

Vokal kordlar, kas ve mukozadan oluşan fonksiyonel bir kütle olup, saniyede yüze kadar (Hz) titreşen yüksek frekanslı bir döngüyü temsil eder. Vokal kordlar, bu şekilde titreşen tek mukozadır ve vokal kordun teması, ses üreten titreşimi başlatır. Bu benzersiz fonksiyon, diğer hiçbir mukozada bulunmayan sofistike bir histolojik yapı tarafından desteklenir.

4.1.2. Anatomi

Glottis, bilateral vokal proseslerin uçları arasındaki çizgiyle iki bölgeye ayrılır: anterior glottis ve posterior glottis. Anterior glottis vokal kordları içerirken, posterior glottis kıkırdak yapıları içerir. Bu iki bölge hem yapısal hem de işlevsel olarak oldukça farklıdır. Anterior glottis, vokal kordların titreştiği ve sesin üretildiği intermembranöz bölge olarak bilinir. Posterior glottis ise, başlıca solunum görevi gören interkartilajenöz kısım olarak adlandırılır. Yenidoğanlarda anterior glottis'in posterior glottis'e oranı yaklaşık olarak eşittir, yetişkinlerde ise iki veya üç kat kadar artar. Bu durum, yenidoğanların ses çıkarmaktan ziyade solunum fonksiyonuna daha çok ihtiyaç duyduğunu ve ses fonksiyonunun yaşla birlikte geliştiği teorisini destekler. Klinik olarak, genellikle anterior glottise daha fazla dikkat edilir çünkü ses hastalığına (disfoni) yol açan lezyonların çoğu anterior glottiste meydana gelir.

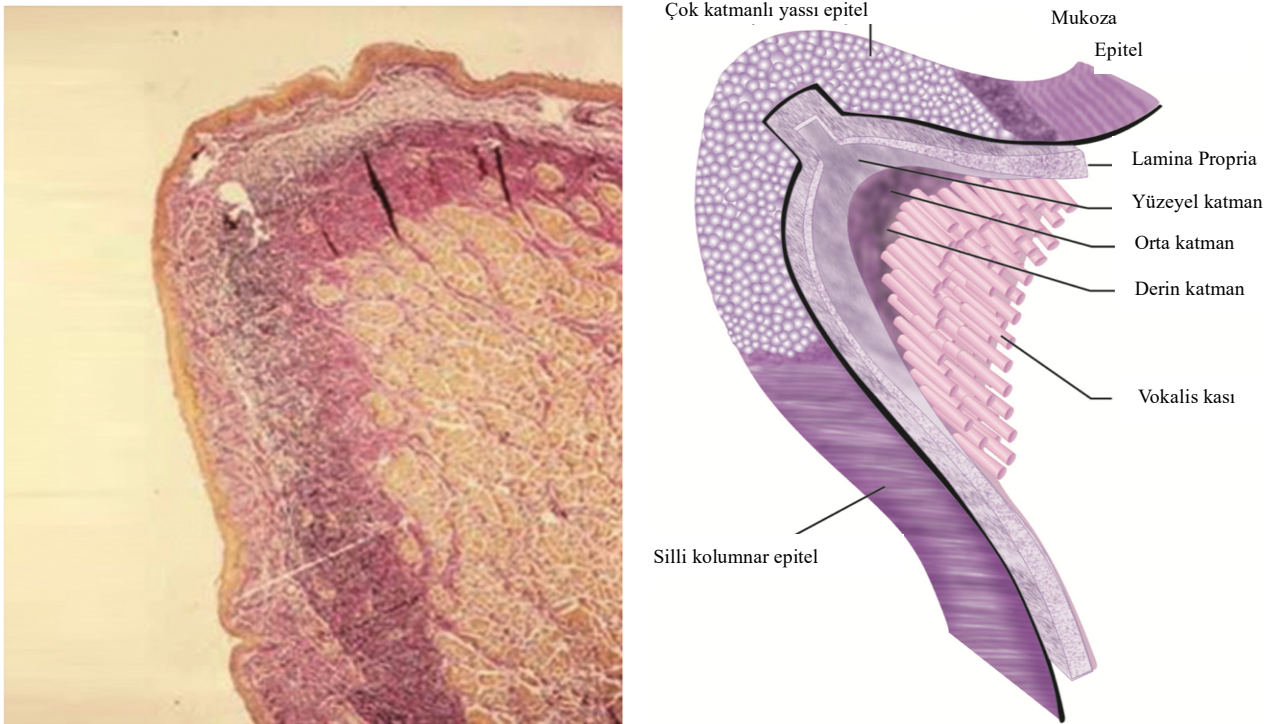
4.1.3. Histolojisi

Vokal kordlar, ön komissür ile aritenoid kıkırdakların vokal prosesleri arasında yer alır ve vücudun başka hiçbir yerinde görülmeyen benzersiz titreşim özelliklerine sahiptir. Bu özellikler, vokal kordların histolojik yapısı tarafından desteklenir ve normal yapının bozulması, tedavisi zor şiddetli disfoniye neden olur.

Vokal kordların histolojisini gösteren birçok çalışmada, vokal kordların epitel, lamina propria ve kas olmak üzere iyi bir şekilde dizayn edilmiş bir tabaka yapısından oluştuğunu ortaya koymuştur (12, 13) (Şekil 1). Vokal kordların serbest kenarını kaplayan epitelyum skuamöz epitelyumdur. Supra ve subglottik mukozayı ise silli kolumnar epitelyum kaplar. Lamina propria üç katmandan oluşur: superfisyal, orta ve derin katmanlar. Superfisyal katman

seyrek fibroz doku ve bol miktarda amorf madde içerir, bu da diğer katmanlardan daha esnek olmasını sağlar. Bu katmana "Reinke boşluğu" denir ve fonasyon sırasında mukozal titreşimin gerçekleştiği ana yerdir. Çoğu benign ve malign vokal kord hastalığı bu bölgeyi etkileyerek disfoniye neden olur. Orta katman çoğunlukla elastik liflerden oluşurken, derin katman ise başlıca kolajen liflerden oluşur. Bu iki katman, vokal ligamenti oluşturur; bu ligament altta konus elastikusa bağlanır ve önde anterior komisur tendonuna bağlanır. Ayrıca, üstte quadranguler membranla devamlı bir yapıdadır. Vokalis kası, vokal kordda ligament tabakasının altındadır ve vokal kordun ana gövdesini oluşturur. Lamina propria'nın derin katmanı ile kas arasındaki sınır belirgin değildir, çünkü derin katmandaki bazı kolajen lifleri kas dokusu ile ilişkilidir.

Vokalis kası, vokal korda sert bir iskelet yapısı sağlayan kasılabilir bir ünedir, vokal ligament ise esnek yüzey katmanının titreştiği uygun sertlik ve esnekliği sağlar. Sertlik, kastan lamina propria'nın yüzeysel katmanına doğru azalır aynı şekilde esneklik artar. Farklı doku özelliklerinin bu şekilde yapılanması, vokal kordların titreşim fonksiyonu için ideal olduğu düşünülmektedir. Bu kavram, "kaplama-vücut teorisi (cover body theory)" olarak adlandırılır; buna göre kaplama, epitel ve lamina propria'nın yüzeysel katmanından oluşurken, vücut kas ve lamina propria'nın orta-derin katmanlarını içerir (14).



Şekil 1. Vokal Kordun Histolojik Katman Yapısı (15)


4.2. Bening Vokal Kord Lezyonları

4.2.1. Nodül ve polip

Vokal kord nodülleri ve polipleri larinksin benign lezyonlarıdır (Şekil 2). Genellikle sesin yüksek derecede, yanlış kullanımıyla oluşan fonotrauma sonucu oluşurlar. Sosyal iletişim ve mesleki performans için sağlıklı bir ses üretimi önemlidir. Sesin mesleki veya sosyal beklentilerden dolayı yüksek derecede kullanımı disfoniye neden olur (16). Oluşan disfoni, ses üretimi için kompensatuar mekanizmaların daha fazla kullanılmasına ve mevcut sorunun kötüleşmesine yol açabilir. Nodüller genellikle 18-40 yaş arası çocuklarda ve yetişkin kadınlarda görülür (17). Geçmiş yıllarda, kulak burun boğaz uzmanlarına başvuruların %1'inde ses kısıklığının nedeni olarak nodüller tespit edilmiştir. Bir çalışmada, ses kısıklığı şikayeti olan öğretmenlerin %43'ünde nodül saptanmıştır (18). Polipler ise genellikle 30-50 yaş arasındaki hem erkekleri hem de kadınları etkiler.

Konuşma sırasında subglottik basınç, nefes verilmesinin başlangıcına kadar artar ve bu artan basınç da vokal kordları birbirinden ayırır. Vokal kordlar ayrıldıktan sonra, Bernoulli kuvvetleri ve vokal kordların viskoelastik özellikleri tarafından tekrar bir araya gelirler. Bu döngü, pasif titreşime ve ses üretimine neden olur (16). Normal fonasyonun gerçekleşebilmesi için birkaç faktör bulunmaktadır. Bunlardan bazıları vokal kordların yaklaşmalarını engelleyecek bir patolojinin olmaması ve sağlam, doğru yapılandırılmış lamina propria ve epitelyum bulunmasıdır.

Hem vokal kord nodülleri hem de polipler genellikle orta membranoz vokal kord bölgesinde bulunur ve başlıca yüzeysel lamina propria içindedir. Nodüller genellikle lamina propria'nın en yüzeysel kısmını içerebilir ve bazal membrana kadar uzanabilir, genellikle vokal kord üzerindeki bir 'callus' olarak düşünülür (19). Polipler de yüzeysel lamina propria'yı içerir ve eksofitik bir morfolojiye sahiptir. Nodüllerin 'callus' oluşumunun aksine, polipler çoğunlukla ince ve atrofik bir epitelyum altında yer alan kapsülsüz jelatinöz bir materyalden oluşur. Polipler zamanla yavaşça gelişebilir veya akut vokal kord kanaması ile hızlı bir şekilde oluşabilir (20).




Şekil 2. A. Vokal Kord Polipi; B. Vokal Kord Nodülü

4.2.2. Kist

İntrakordal vokal kord kistleri ilk olarak 19. yüzyılda tanımlanmıştır (21). Bu lezyonlar bulguları ve etiyolojileri açısından iyi tanımlanmış ve karakterize edilmiştir (22). İntrakordal kistler genellikle yüzeysel lamina propria içinde bulunur, ancak altta yatan vokal kord ligamentine ve/veya üstteki epitelyume bağlı olabilirler. Nodül veya polipler gibi diğer benign vokal kord lezyonlarından daha az sıklıkla görülürler.

Klasik olarak iki tür vokal kord kisti tanımlanmıştır: (1) Mukus retansiyon kistleri ve (2) epidermoid/keratin kistler (Şekil 3). Histolojik olarak, mukus retansiyon kistleri küboidal epitelyum ile kaplanmıştır ve lümenleri musin ile doludur (23). Epidermoid/keratin kistleri genellikle keratinize epitelyum ile kaplanmıştır ve stratifiye bazofilik keratin pulları içerir. Subepitelyal fibroz doku bazen lenfositler ve plazma hücreleri tarafından infiltrasyona uğramış olabilir (23). Eğer kistten patlama veya sızma olursa, keratin etrafında yoğun bir yabancı cisim reaksiyonuna sebep olabilir. Fibronektin ve kollajen tip IV'e karşı gelişen monoklonal antikorlarla yapılan immünohistokimyasal analizde, kistlerin normal veya hafif kalınlaşmış bazal membran ile lamina propria içindeki fibronektinin normal dağılım gösterdiği histopatolojik yapısı gösterilmiştir (24). Mukus retansiyon kistleri musin içerdikleri

için boyut olarak değişebilirler, epidermoid kistler ise iç yapısındaki keratin nedeniyle nadiren çaplarında azalma gösterirler. Her iki kist türü de glottal epitelyumun altında opak sferoid/oval kitleler olarak görünür, ve epidermoid kistler, içlerinde keratin bulunduğu için genellikle biraz daha beyaz renklidir.



Şekil 3. A. Vokal Kord Keratin Kisti ; B. Vokal Kord Mukus Retansiyon Kist


Mukus retansiyon kistleri ve epidermoid/keratin kistlerinin patofizyolojisi kesin olarak belirlenmemiştir, ancak birkaç teori öne sürülmüştür. Mukus retansiyon kistlerinin gelişimi muhtemelen glandüler kanalların tıkanması nedeniyle oluşur. Bu glandüler kanalların tıkanmasının nedeni olarak inflamasyon ve fonotrauma öne sürülmektedir. Epidermoid/keratin kistlerinin oluşumunu açıklayan iki baskın teori vardır: edinsel ve konjenital (23). İlk olarak 1956'da önerilen 'edinsel' teori, bu lezyonların cilt kistlerinin etiyolojisi ile benzerlik göstererek vokal kordlara travma sonrası oluştuğunu belirtir (25). Travma teorisine göre, mikrotravma veya inflamasyonla üretilen skuamöz epitelin küçük bir yarığı, subepitel dokuda küçük skuamöz epitel parçalarının yerleşmesine neden olur ve orijinal mikrotravmanın iyileşmesinden sonra bu yapı içe doğru büyür (25). İlk olarak 1958'de önerilen 'konjenital' teori, larinksin gelişimi sırasında dördüncü ve altıncı brankiyal arkuslardan kalan konjenital anomalliklerin intrakordal kistlere dönüşmesiyle lezyonların geliştiğini belirtir (26). Bu teori, intrakordal kistlerin, sulkusların ve mukozal köprülerin sıklıkla birlikte görüldüğü gerçeğini ve dolayısıyla aynı konjenital varlığın evriminde üç farklı aşamayı temsil ettiklerini açıklamak için kullanılmıştır.

4.2.3. Laringeal papilloma

Lareneal papillomatozis, en yaygın olarak tip 6 ve 11 insan papilloma virüsü (HPV) ile enfeksiyonunun bir formudur. Bu, genellikle tekrarlayan bir benign neoplazmdır ve bu nedenle tekrarlayan solunum papillomatozisi (RRP) olarak da adlandırılır. Nüksler, zamanlama ve tümör yükü ile ilişkili olarak düzensiz bir şekilde meydana gelir. RRP'ye bağlı morbidite, çok sayıda cerrahi işlem, disfoni, hava yolu tıkanıklığı veya maligniteye dönüşümün sonuçlarına ikincil olarak ortaya çıkar.

Makroskopik olarak, HPV lezyonları pedinküllü veya sesil olabilen eksofitik lezyonlardır (Şekil 4). Genellikle normal lareneal dokuya kıyasla daha pembe bir tona sahiptirler ve lobule bir yüzeye sahiptirler. Her papillanın ortasındaki damar, yüzeyde lekeli bir desen oluşturur, bu da daha az belirgin sesil büyümeleri tanımlamada yardımcı olur. Lezyonlar çoğunlukla kolumnar ve skuamöz epitelyumun birleşim noktalarında meydana gelir. Bunlar, vestibulum, yumuşak damağın nazofaringeal yüzeyi, epiglotisin lareneal yüzeyi, ventrikül kenarları, vokal kordların alt yüzeyi, karina ve bronşiyal çıkıntılardır (27).

Histolojik olarak, papilloma ince fibro-vasküler merkezlerle karakterize parmak benzeri çıkıntılar şeklinde görülen skuamöz epitelyumdan oluşur. Skuamöz epitelyum, bazal ve parabazal hiperplaziye sahip olup, nükleer büyüme, düzensiz nükleer membran, hiperkromazi ve perinükleer halo ile karakterize koilositler içerir (28).



Şekil 4. Vokal Kord Papilloma

4.2.4. Psödokist

Psödokist, vokal kord paralizisi, parezi veya skar gibi glottal yetmezlikle ilişkili bir subepiteliyal lezyondur. Yapısal olarak yüzeysel olup bazen intraepiteliyal görünebilirler. Bu lezyonlar genellikle kabarcık benzeri bir görünüme sahiptir ve ince bir epitelyumla kaplanmış kapsülsüz yarı katı sıvıdan oluşur (Şekil 5). Kalıcı pseudokistler bazen tek taraflı Reinke ödemi görünümünü alır. Bu pseudokistler, ses teli perezisinin asimetrik ve zorlayıcı bir kapanmaya neden olması nedeniyle ortaya çıkar; bu da vokal kordların çarpma bölgesinde (striking zone) artan kaydırıcı kuvvetleri (shearing force), mikrodamar hasarı ve ardından psödokist oluşumuyla sonuçlanır (29).




Şekil 5. Vokal Kord Psödokisti

4.2.5. Sulkus

Sulkus, vokal kordların kenarında bulunan bir çöküntü, oluk veya yarık ile karakteriz patolojik bir durumdur (1) (Şekil 6). Sulkus'un etiyolojisi hala bir tartışma konusudur. Konjenital ya da kazanılmış bir patoloji olduğunu destekleyen çalışmalar mevcuttur. Ford yaptığı çalışmada, sulkusun klinik prezentasyondaki çeşitliliği açıklamak için hastalığı üç farklı tipe ayırmıştır. Fizyolojik sulkus olarak da adlandırılan tip I sulkusta, mukozal dalgalanma minimal etkilenecek vokal kord fonksiyonları üzerinde olumsuz bir etkisi yoktur. Tip II sulkus (Sulkus verjetür), membranöz vokal kord boyunca epitel dokusundaki girintiyi ifade eder. Öte yandan, tip III sulkus (sulkus vokalis), ligament veya vokalis kasına derinlemesine uzanan lokal cep veya çukur ile karakterizedir ve şiddetli disfoniye yol açar (30, 31, 32). Tip III sulkus ile tip II sulkus arasındaki temel farklar, tip III sulkuslu hastaların genellikle fonotravma geçmişiyle sahip olmaları ve tip III sulkusun inflamasyonla birlikte görülmesi ve daha sık olarak tek taraflı bulunmasıdır (33). Tip III sulkusun bu özellikleri, patolojinin edinilmiş bir süreç olduğuna işaret eder. Öte yandan, tip II sulkusun tipik olarak genç yaşlardan itibaren görülüyor olması, literatürdeki ailesel vakalar ve lezyonların iki taraflı olarak gözlemlenmesi tip II sulkus için konjenital bir süreci düşündürür. (34, 35).

Yapılan histolojik çalıřmalar, tip II ve tip III sulkusun farklı özellikler sergilediđini ve aynı patolojinin farklı dereceleri olmadıklarını doğrulamaktadır. Lee ve diđ. (36), tip III sulkusta epitel kalınlaşması ile birlikte çevre dokularda ve epitelde inflamasyon varlığını ortaya koymuştur. Tip II sulkusta epitelyal incelme görülmekle birlikte epitelde inflamasyon yoktur. Bununla birlikte çevre dokuda (lamina propria) inflamasyon görülmektedir (6)



Şekil 6. Vokal Kord Sulkusu

4.3. Videostrobokopi

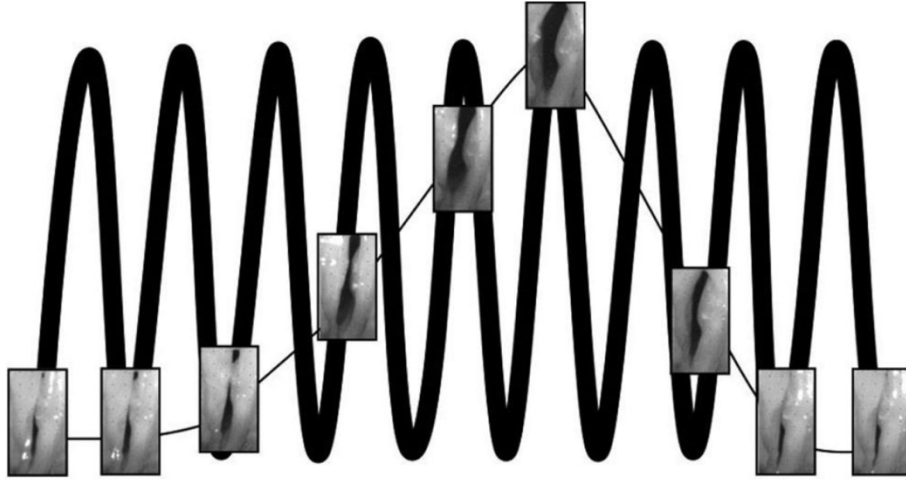
4.3.1. Giriş

Videostroboskopi, klinisyenin larenksi ve vokal kordların görüntülemesini ve çeşitli fonasyon görevleri sırasında vokal kordların görünen hareketlerini izlemesini sağlayan bir araçtır. Bu şekilde videostroboskopi, disfoni etiyolojisini belirlemenin bir yolunu sağlar. Sesin çođu klinik deđerlendirmesi için videostroboskopik larenks muayenesi, larenks yapısını ve fonksiyonunu anlamann kritik ve gerekli bir parçasıdır. Bu, tam bir laringeal ve ses deđerlendirmesinin parçası olarak gerçekleştirilen temel veya minimal prosedürler dizisinin bir parçası olarak kabul edilir.

Tam bir ses deęerlendirmesi, fonasyon sırasında vokal kordların grntlenmesini iermelidir ve videostroboskopi, oęu klinik durumda etkili bir yntemdir (37). Ses bozukluklarında uzmanlařmıř dil ve konuřma terapistlerine ynelik yakın tarihli bir ankette, katılımcıların %81'i ses deęerlendirmelerinde videostroboskopiye kullanma olasılıklarının yksek olduęunu belirtmiřtir (38). Ayrıca, dil ve konuřma terapistlerinin %94' videostroboskopinin ses terapisi hedeflerini belirlemede nemli olduęunu, %81'i ise videostroboskopinin hastaları eęitmede nemli bir ara olduęunu bildirmiřtir (38). Bu nedenle, videostroboskopi yaygın olarak kullanılmakta olup, ses bozukluęu olan hastaların tanı ve tedavisinde deęerli bir ara olduęu vurgulanmıřtır. Videostroboskopik muayene hem dil ve konuřma terapistleri hem de laringologlar tarafından yapılır, ancak yalnızca laringologlar grntleri tıbbi tanı koymak iin kullanır.

Stroboskop, hızlı titreřim veya devinim halindeki bir cismin hareketini incelemek iin kullanılan bir cihazdır. Larengeal muayenelerde, stroboskop, larinksli periyodik olarak ıřık darbeleriyle aydınlatarak ses teli hareketinin yavařlamıř veya durduęunu grnmesini saęlar (37). Videostroboskopi ile periyodik ıřığın aydınlatıęı karelerin toplamının grntlendięini, gerek dngden dngye titreřim hareketinin grntlenmedięini anlamak nemlidir.

İnsanlar saniyede 5'ten fazla grnt algılayamadıęı iin, saniyede 6 dng bile gzlemleyebilmek iin ok hızlıdır. Dolayısıyla, vokal kordların saniyede 100 ila 300 kez titreřmesi, klinisyenlerin vokal kordların titreřim dngsnn gzlenmesini engelleyecek kadar hızlı gerekleřir. Ayrıca, mevcut oęu video kayıt ekipmanı insan sesinin temel frekansının ok altında olan saniyede 33 kareden fazlasını kaydetmeye izin vermez. Videostroboskopi, insanın bu kadar hızlı bir dngy takip etmedeki kısıtlılıęını ve kayıt almadaki kısıtlılıęları ařarak vokal kordların titreřiminin deęerlendirilmesine olanak saęlar. Seilen moda baęlı olarak, videostroboskopi, titreřimin spesifik noktasını deęerlendirmek isteyen kiřinin birleřik bir titreřim dngsndeki aynı noktanın devamlı olarak gzlenmesine veya titreřim dngs iindeki birok noktanın deęerlendirilebilmesi iin bir dng iinde farklı zaman noktalarındaki titreřimin incelemesine olanak tanır (37). İlk durumda, ıřık kaynaęı sesin temel frekansıyla aynı frekansta darbelerle aydınlatır. İkinci durumda ise, ıřık, titreřimin gerek temel frekansından biraz daha hızlı bir frekansta darbelerle aydınlatılır. Bu asenkron ıřık darbesi birok titreřim dngs boyunca, vokal kordların titreřim dngsndeki farklı bir zaman noktalarında gzlenmesine olanak tanır. Bu etkinin řematik bir gsterimi Őekil 7'de gsterilmiřtir. Sonu olarak, vokal kordların titreřiminin yavařlatılıęı illzyon grlr. Gz, srekli bir yavař hareket dizisi olan vokal kordların titreřimini algılamıř olur.



Şekil 7. Vokal Kordların Titreşim Döngüsünün Stroboskopik İzlenmesi

4.3.2. Ekipman

Videostroboskopi için özel ekipman gereklidir. Bu ekipman, bir monitör, dijital video kayıt sistemi, ses sinyali kaydı için mikrofonlu kamera, esnek veya rijit bir endoskopa bağlı lens adaptörü, bir ses frekansını tespit eden ve ışık kaynağı içeren bir stroboskop, ve ses frekansının tespiti için bir mikrofon veya elektrotlografi (EGG) içerir (Şekil 8).

Tekniğin başarısı ekipmanın kalitesine oldukça bağlıdır (39). Işık yeterince parlak olmalı, frekansın tespiti doğru, hızlı bir şekilde olmalı ve geniş bir frekans aralığını tespit edebilmelidir. Çoğu disfonik hasta muayene esnasında sesini uzun süre sürdürmediği için hastanın temel frekansına hızlıca kilitlemelidir. Ayrıca, kayıt ve kamera ekipmanı uyumlu ve yüksek çözünürlüklü olmalıdır. Sonuçta elde edilen görüntünün kaliteli olabilmesi videostroboskopi ekipmanlarının her birinin düzgün ve koordineli çalışması gerekir.

Parlak ve net bir görüntü elde etmek amacıyla flexible (esnek) veya rijit endoskoplar kullanılarak videostroboskopi uygulanabilir. Flexible bir endoskop burun yoluyla geçirilir, velumdan geçerek farinkse ulaşır ve devamlı konuşma sırasında vokal kordların titreşimini görüntülenmesini mümkün kılar. Flexible endoskopun, oral kaviteden yapılan müdahelerde yüksek gag refleksi gösteren bireylerde veya küçük çocuklarda kullanımı daha iyidir. Aynı zamanda flexible endoskop çeşitli açılardan muayene yapabilmek ve velofarengeal fonksiyonu incelemek için kullanılabilir. Ancak flexible endoskop kullanımı çoğu zaman intranazal lokal anestezi gerektirir. Düşük büyütmede bir görüntü verir ve vokal kordlara daha az ışık iletilerek daha az aydınlatma sağlar. Bu nedenle vokal kord görüntülerinin çözünürlüğü

daha dūřüktür. Rijit videostroboskopide genellikle 70 derece rijit bir endoskop kullanılır ve genellikle flexible bir endoskoptan daha yüksek çözünlüklü görüntüler elde edilir ve yapılan işlem daha az invazivdir. Yüksek çözünlüklü chip-tip flexible endoskoplar, endoskopun ucuna yerleştirilmiş dahili bir video kamerası sayesinde flexible endoskopun çözünlük dezavantajlarını elimine eder iyi bir aydınlatma ve yüksek çözünlük sağlar. Ancak standart bir rijit veya flexible endoskopa göre daha pahalıdır.



Şekil 8. Videostroboskopi Ünitesi

4.4. Yapay Zeka ve Klinik Kullanımları

4.4.1. Giriş

Yapay zeka (AI), insan zekası gerektiren görevleri otomatikleştirebilen bilgisayar algoritmalarını ifade eder (40). Son 10 yılda, hesaplama gücündeki ilerlemeler, yaygın olarak benimsenen CNN teknikleri ve büyük dijital veri setlerinin kullanılabilirliği sayesinde, AI modelleri özellikle görüntü tanıma ve konuşma işleme alanlarında önemli ölçüde ilerlemiştir. Bu son gelişmeler, araştırmacıları AI'nın radyoloji, dermatoloji, oftalmoloji ve patoloji gibi görüntü analizine dayanan çeşitli tıbbi disiplinlerdeki uygulamalarını araştırmaya yönlendirmiştir (41).

AI uygulamaları, kulak burun boğaz—baş ve boyun cerrahisinde hızla gelişen bir alan olmakla birlikte ve giderek artan sayıda yayın göze çarpmaktadır (9). Klinisyenler için AI uygulamalarının yeni alanlarından biri, video-endoskopide lezyon tespiti ve görüntü analizi olup, bu alana son zamanlarda "videonomics" adı verilmiştir (42). Nisan 2021'de FDA tarafından onaylanan ilk AI cihazı, kolonoskopi sırasında kolon poliplerinin gerçek zamanlı tespitine olanak sağlayan bir algoritmadır (43). Laringoskopi, laringologlar tarafından uygulanan en yaygın video-endoskopik prosedürlerden biridir ve ML ve bilgisayarla görü (computer vision) alanlarındaki AI modelleri için zengin bir görüntü kaynağı sağlar. ML ve bilgisayarla görü teknikleri birbirini tamamlar. ML algoritmaları, bilgisayarın örnek verilerden öğrenmesini ve yeni veriler üzerinde tahminler yapmasını sağlar. Bilgisayarla görü teknikleri, bilgisayarların dijital görüntüler veya videolar aracılığıyla görsel dünya hakkında yüksek düzeyde analitik içgörü kazanmasına olanak tanır. AI, laringoskopide geniş uygulama potansiyeli göstermiştir. Bu durum, laringeal kanserlerin bilgisayar destekli tanısından (44), veri seti oluşturmayı kolaylaştırmak için videolarda otomatik önemli kare seçimine kadar uzanır (45).

4.4.2. Makine öğrenimi

Makine öğrenimi (ML) sınıflandırıcıları, denetimli öğrenme, denetimsiz öğrenme, yarı denetimli öğrenme ve pekiştirmeli öğrenme gibi çeşitli alt türlere ayrılabilir. Denetimli öğrenme, veriyi sınıflandırmak veya sonuçları tahmin etmek için algoritmaları eğitmek amacıyla etiketli veri setleri kullanır. Öte yandan, denetimsiz öğrenme, etiketlenmemiş veri setlerini analiz etmek ve özellik bulmak için algoritmalar kullanır. Yarı denetimli öğrenme, denetimli ve denetimsiz öğrenmenin bir kombinasyonudur. Daha küçük etiketli bir veri seti kullanarak daha büyük, etiketlenmemiş bir veri setinde etiketleme ve özellik çıkarımına olanak sağlar. Pekiştirmeli öğrenmede, bir algoritma deneme yanılma yoluyla öğrenerek, sonucu maksimize edecek kararlar dizisi oluşturur.

En yaygın denetimli ML algoritmaları, sinir ağları, destek vektör makineleri (SVM) ve k-en yakın komşular olmuştur. Sinir ağları, insan beyninin nöronal yapısını kabaca modelleyen algoritmalarlardır. Sinir ağları, düğüm adı verilen binlerce ila milyonlarca yapay nörondan oluşur ve bu düğümler bir dizi birbirine bağlı katman halinde düzenlenmiştir. Eğitim verileri bu katmanlardan geçerken karmaşık şekillerde çarpılıp toplanır, bu da giriş ve çıkış değişkenleri arasındaki ilişkilerin öğrenilmesini sağlar. Yaygın sinir ağı mimarileri arasında ileri beslemeli sinir ağları, CNN'ler ve tekrarlayan sinir ağları bulunur. SVM, girdileri daha yüksek boyutlu bir alana dönüştürerek iki sınıfa ayıran bir karar sınırı arar. K-en yakın komşular algoritması, benzer vaka örneklerinin sonuçlarına dayanarak tahminler yapar. Daha büyük veri setleri gerektirme eğiliminde olan sinir ağlarıyla karşılaştırıldığında, destek vektör makineleri daha az gözlem gerektirir. Bu nedenle, destek vektör makineleri genellikle çok hızlı bir şekilde eğilirken, sinir ağlarının eğitim süresi veri setinin büyüklüğüne bağlı olarak günler veya haftalar olabilir. Ancak, aynı miktarda eğitim süresi ve hesaplama gücü verildiğinde, sinir ağları genellikle destek vektör makinelerinden daha iyi performans gösterir. Laringoskopi verilerinin AI temelli incelenmesindeki temel kısıtlılık, laringoskopi veri setlerinin sınırlı büyüklüğüdür; bu nedenle, destek vektör makineleri, özellikle daha küçük veri setleri için, sinir ağlarına göre pratik olabilir. Ancak, laringoskopi veri setleri büyüdüğünde, yeterli veri ve hesaplama gücü sağlandığında sinir ağlarının daha iyi performans gösterme potansiyeli artabilir.

5. GEREÇ ve YÖNTEM

Çalışma planı ortaya konduktan sonra, etik kurul talep formu düzenlenerek Marmara Üniversitesi Tıp Fakültesi Etik Kurulu'na başvuruldu. Yapılan değerlendirmeler sonrasında 27 Ekim 2023 tarihinde 09.2022.1449 protokol numarasıyla 'Etik Kurul Onayı' alındı ve Helsinki Bildirgesi'ne uygun olarak retrospektif bir çalışma gerçekleştirildi. Tüm hasta verileri anonim hale getirildi ve kör bir şekilde kullanıldı. Çalışma retrospektif olarak tasarlandığı için hastalardan aydınlatılmış onam alınmadı.


CNN tabanlı modeli eğitmek için gerekli videostroboskopi karesi, Marmara Üniversitesi Kulak Burun ve Boğaz ve Baş Boyun Cerrahisi Anabilim dalı veri tabanından elde edildi. 2019 Ocak - 2023 Ekim tarihleri arasında kaydedilmiş videostroboskopi görüntüleri toplandı. Videostroboskopik işlemler XION Medical Systems rijit 8x180 mm veya fleksible 3.9 mm laringoskopi kullanılarak gerçekleştirilmişti. Yaş, cinsiyet veya ırk bazlı dışlanma kriterleri uygulanmadı. Yedi kategoriye ait 433 kohorta yapılan videostroboskopiler retrospektif olarak değerlendirildi: sağlıklı, polip, nödul, papillom, kist, psödokist ve sulkus. Videolar saniyede 25 kare sayısında kaydedilmişti (fps). Her kare boyutu 768x576 pikseldi. Videostroboskopinin incelenmesi sonrası kaydedilen teşhisler ve operasyon sonrası doğrulanmış patolojik teşhisler gözden geçirerek yedi kategori tekrar incelendi. Bir veri seti oluşturmak için ilgili videostroboskopi kayıtlarından hastalığı gösteren kareler seçildi. Vokal kordların ayırt edilemediği, tükrüğün görüntüyü engellediği, ışığın yeterli olmadığı görüntüler elenerek vokal kord hastalıklarının ayırt edildiği karelere odaklanılarak veri seti oluşturuldu. Veri seti hazırlama sürecinde toplam 91.159 bilgilendirici kare elde edildi. Her bir kare vokal kord etrafında analizin dışında olması beklenen alanları ortadan kaldırmak için 451x468 piksele boyutlandırıldı ve kırmızı-yeşil-mavi (RGB) renk formatında kaydedildi. Böylece veri seti analizinde AI modelinin daha az boyutta veri analiz ederek işlemin süresinin kısaltılması hedeflendi. Videolardaki her kareyi dikkatlice incelenerek ve hastalık göstergelerine göre kategorize edildi. Tablo 1, her çalışma grubundan seçilen katılımcı sayısının ve karelerin ayrıntılarını paylaşmaktadır. Şekil 9 ise etiketlenilip sınıflara ayrılan karelerin örneklerini göstermektedir.

Tablo 1. Çalışma Grubundaki Hasta Sayısı ve Temsil Edici Kareler

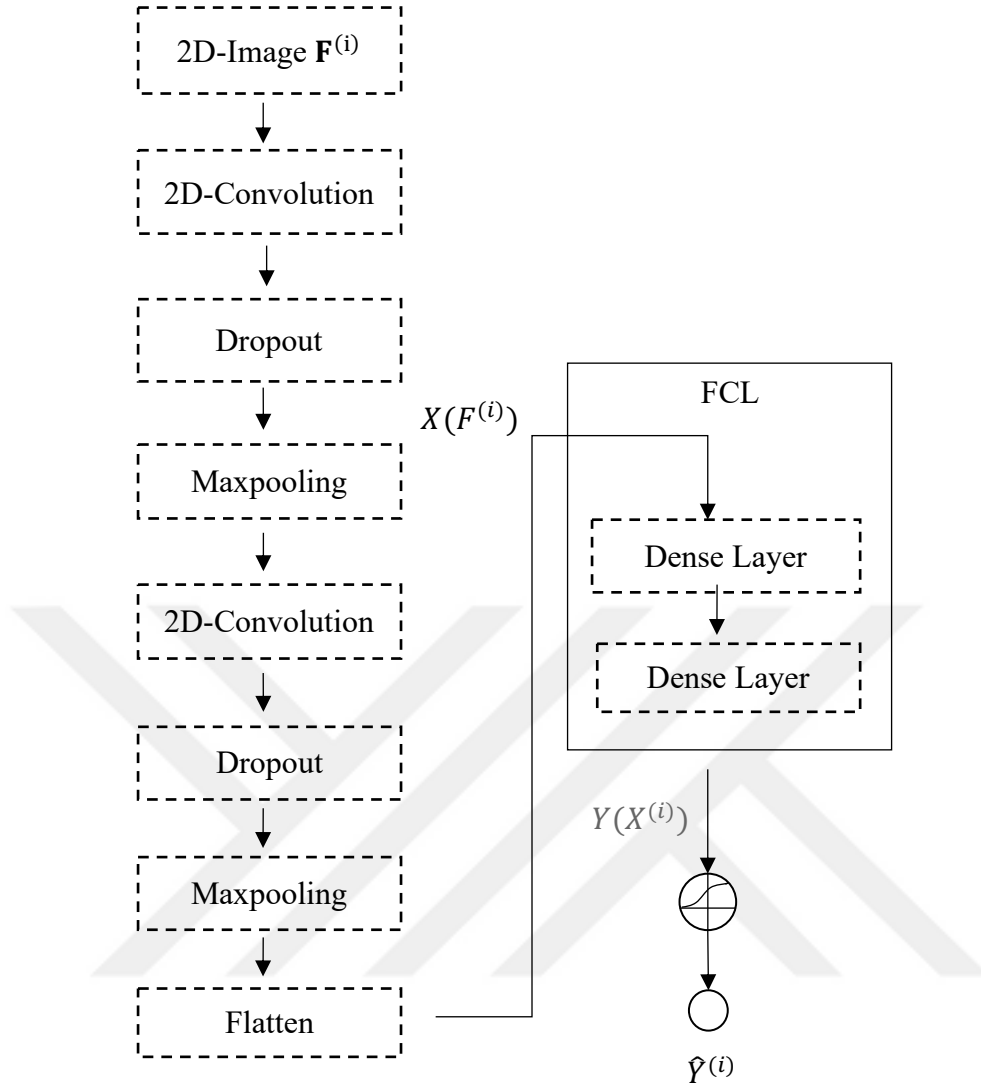
Etiket	Çalışma Grubu	Hasta Sayısı	Kare Sayısı
0	Sağlıklı	33	8889
1	Nodül	99	11517
2	Papilloma	16	6570
3	Polip	132	37359
4	Sulkus	91	13409
5	Kist	50	11779
6	Psödokist	12	1636
	Total	433	91159

Çalışma iki sınıflandırıcı geliştirdi. Literatürde sulkusun teşhis edilmesinin zor olduğu ve videostroboskopik muayene esnasında kolaylıkla gözden kaçırılıp vokal kordların normal olarak değerlendirilebileceği bildirilmiştir. (1, 5). Bu sebepler çalışmanın ilk aşamasında sulkuslu hastalara ait görüntüleri sağlıklı katılımcayı ait görüntülerden ayırt edebilecek ikili bir sınıflandırıcı geliştirildi. Çalışmanın ikinci aşamasında ise belirli bir görüntüyü yedi farklı kategoriden birine ayırmak için çoklu sınıflandırıcı geliştirildi.

Çalışmamızda, her iki sınıflayıcı için de 8 katmanlı CNN tabanlı bir model sunulmuştur. Şekil 10'da gösterilen modelin genel mimarisi, her birine dropout ve maxpooling katmanlarının eşlik ettiği iki konvolüsyonel katmanı içerir. Konvülsiyonel katmanlar belirli bir karenin sınıfa özgü özelliklerini çıkarır. Konvolüsyonel katmanlardan sonra, iki yoğun katmandan (dense layer) oluşan Tam Bağlantılı Katmanlar (FCL) entegre edilir. FCL, ikili sınıflayıcı durumunda iki çıkışa sahipken, çok sınıf sınıflandırma için yedi çıkışına sahiptir. Model, TensorFlow altyapısına sahip Keras kullanılarak oluşturuldu. Hem Keras hem de TensorFlow'un sürümü 2.8.0 idi. Uygulama, Windows için 3.9.10 sürümü Python kullanılarak yapıldı. Model, kusursuz bir yürütme için özel yazılımımıza sorunsuz bir şekilde entegre edildi.



Şekil 9. Konvolüsyonel Sinir Ağı (CNN) Modelinin Geliştirilmesi için Kullanılan Veri Setindeki Her Alt Kümeden Temsil Edici Çerçeveler (Sağlıklı, Nodül, Polip, Kist, Psödokist, Papillom, Sulkus)



Şekil 10. Çok Katmanlı Konvolüsyonel Sinir Ağı (CNN) Modelinin Yapısı

Orijinal veri kümesinden seçilen kareler, CNN tabanlı sınıflandırıcıları eğitmek, doğrulamak ve test etmek için uygun setlere ayrılmıştır. Ayrıca, CNN tabanlı modelin sınıflandırma performansını değerlendirmek için orijinal veri kümesinden toplanan 544 karelik anket verileri, beş laringolog ve CNN tabanlı modele test ettirilerek altı grubun (beş laringolog ve bir model) sonuçları karşılaştırıldı. Tablo 2, hem ikili hem de çoklu sınıflandırmalarında eğitim, doğrulama ve test aşamalarında kullanılan kare sayısını göstermektedir ve laringologların, CNN tabanlı modele kıyasla performansını ölçmek için hazırlanan anket verilerinin sayısını göstermektedir.

Tablo 2. İkili ve Çoklu Sınıflandırma Modelleri için Eğitim, Doğrulama, Test edilme ve Anket Verisetinde Kullanılan Kare Sayısı

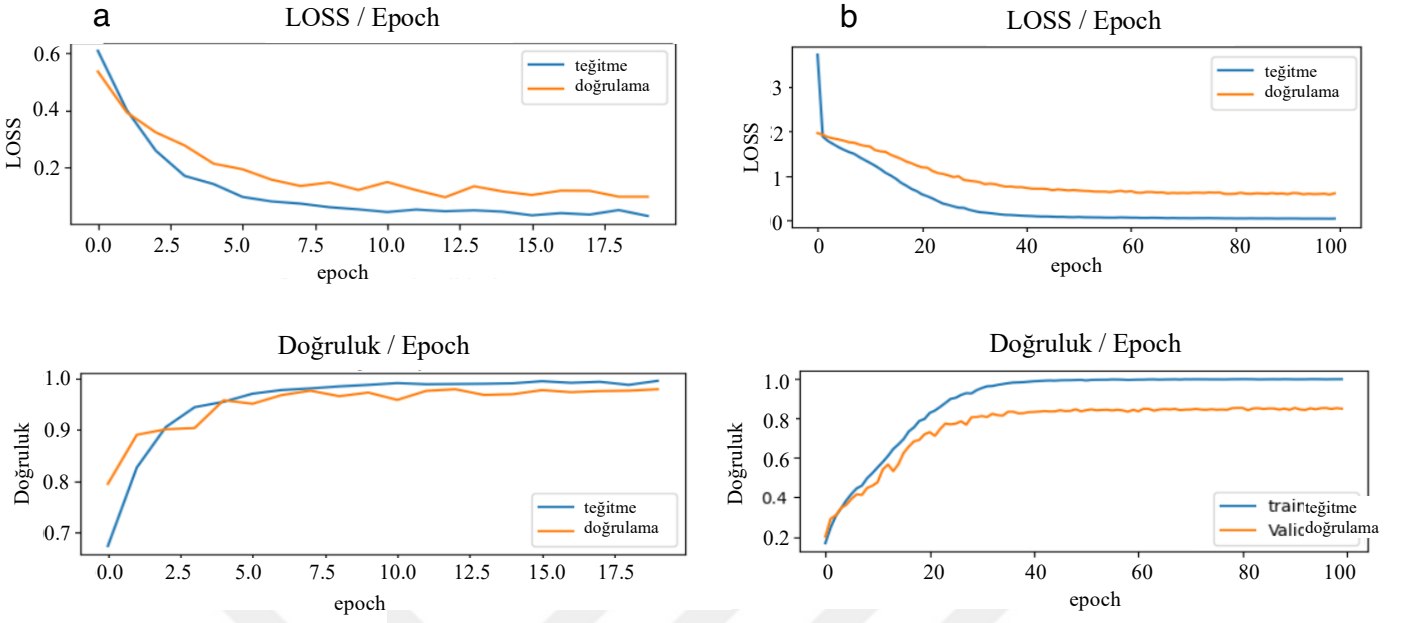
İkili Sınıflandırma					
Alt Grup	Eğitim	Doğrulama	Test edilme	Total	
0: Sağlıklı	5575	1394	1743	8712	
1: Sulkus	5575	1394	1743	8712	
Total	11150	2788	3486	17424	
Çoklu Sınıflandırma					
Alt Grup	Eğitim	Doğrulama	Test edilme	Anket	Total
0: Sağlıklı	3147	786	1066	104	5103
1: Nodül	3205	801	992	75	5073
2: Papilloma	3216	804	980	100	5100
3: Polip	3190	797	1013	75	5075
4: Sulkus	3184	803	984	40	5011
5: Kist	3217	804	979	75	5075
6: Psödokist	1032	258	305	75	1670
Total	20191	5053	6319	544	32107

5.1. Modelin Eğitimi, Doğrulanması ve Test Edilmesi

Adaptif Momentum (ADAM) algoritması, eğitim setinden alınan m örnekleri içeren bir mini batch kullanarak model parametrelerini yinelemeli olarak optimize etmek için kullanıldı. İki kayıp (Loss) fonksiyonunu kapsayan maliyet fonksiyonu, tüm mini batch üzerinden hesaplandı. İlk kayıp fonksiyonu, ikili sınıflandırma için ikili çapraz-entropi fonksiyonu ve çoklu sınıflandırma için kategorik çapraz-entropi (veya softmax) fonksiyonu olarak tanımlandı. İkinci kayıp fonksiyonu ise tüm parametrelerin l_2 -normudur. l_2 -normu, aşırı uyumu önlemek için bir düzenleme fonksiyonu olarak görev yapar. En iyi modeli bulmak için, model hiperparametrelerinin yinelemeli olarak değiştirildiği sistematik bir yaklaşım kullanıldı. Her ayarlardan sonra, model yeniden eğitildi ve performansını değerlendirmek için doğrulandı. Bu süreç, en optimal sonuç elde edilene kadar devam etti. Her eğitim yinelemesi için epoch sayısı durma kriteri olarak kullanıldı. Tablo 3, altı çizili hiperparametrelerin optimal değerlerini göstermektedir. Şekil 11, eğitim ve doğrulama süreçleri sırasında epoch sayısına göre doğruluk ve kayıp eğrilerini göstermektedir. Bu eğriler, CNN tabanlı modellerin optimal hiperparametreleriyle elde edilmiştir.

Tablo 3. Çoklu ve İkili Sınıflandırma için Konvolüsyonel Sinir Ağı (CNN) Tabanlı Modelin Hiperparametreleri

Katmanlar	Parametreler (Çoklu Sınıflandırma)	Parametreler (İkili Sınıflandırma)
Girdi katmanı	Görüntü boyutu = 112x117x1x1	Görüntü boyutu = 45x46x3x1
Conv 2D	Filtre Sayısı = 16, Filtre Boyutu = (5x5), Adım (Stride) = (1,1), Dolgu (Padding) = Valid, Düzenleyici (Regularizer) = L2 (0.002), Aktivasyon Fonksiyonu = ReLU	Filtre Sayısı = 10, Filtre Boyutu = (5x5), Adım (Stride) = (1,1), Dolgu (Padding) = Valid, Düzenleyici (Regularizer) = L2 (0.002), Aktivasyon Fonksiyonu = ReLU
Dropout	Dropout oranı = 0.5	Dropout ratioranı = 0.5
Max-pooling	pool boyutu = (2,2)	pool boyutu = (2,2)
Conv 1D	Filtre Sayısı = 32, Filtre Boyutu = (5x5), Adım (Stride) = (1,1), Dolgu (Padding) = Valid, Düzenleyici (Regularizer) = L2 (0.002), Aktivasyon Fonksiyonu = ReLU	Filtre Sayısı = 20, Filtre Boyutu = (5x5), Adım (Stride) = (1,1), Dolgu (Padding) = Valid, Düzenleyici (Regularizer) = L2 (0.002), Aktivasyon Fonksiyonu = ReLU
Dropout	Dropout oranı = 0.5	Dropout oranı = 0.5
Max-pooling	pool boyutu = (2,2)	pool boyutu = (2,2)
Dense (Yoğun Katman)	Nöron sayıları = 512, Aktivasyon Fonksiyonu = ReLU,	Nöron sayıları = 256, Aktivasyon Fonksiyonu = ReLU,
Çıktı Yoğun Katmanı	Nöron sayıları = 7, Aktivasyon Fonksiyonu = Softmax	Nöron sayıları = 1, Aktivasyon Fonksiyonu = Sigmoid
LOSS (Kayıp) fonksiyonu	Categorical cross entropy + Düzenleme terimi	Binary cross entropy + Düzenleme terimi
Optimizatör	ADAM	ADAM
Yığın Boyutu	1000	20
Epoch sayısı	100	20
Öğrenme hızı	0.001	0.001
Performans Metrikleri	Doğruluk, Kesinlik, Duyarlılık, Özgüllük, F1 Skoru, Loss	Doğruluk, Kesinlik, Duyarlılık, Özgüllük, F1 Skoru, Loss



Şekil 11. Geliştirilen Konvolüsyonel Sinir Ağı (CNN) Modellerinin Eğitim ve Doğrulama Süreçlerinde Epoch'lara Göre Doğruluk ve LOSS (Kayıp) Eğrileri: (a) İkili Sınıflandırıcı, (b) Çoklu Sınıflandırıcı

Analizde verimliliği artırmak için bir veri ön işleme gerçekleştirildi. RGB renk formatından gri tonlamasına dönüştürülmesi ile birlikte, renk kanallarının üçten bire düşürülmesi sağlandı. Ek olarak, karelerin orijinal boyutlarının %25'ine yeniden boyutlandırıldı ve 0'dan 255'e kadar olan orijinal piksel değerleri [0,1] aralığına normalleştirildi. Sonuç olarak, karelerin boyutu, çoklu sınıf sınıflandırması için gri tonlamasında 112×117 piksel ve ikili sınıflandırma için RGB formatında 45×46 piksel olarak belirlendi.

Model parametrelerini iteratif olarak optimize etmek için adaptatif momentum (ADAM) algoritması kullanıldı. Çeşitli değerlendirme ölçütleri (örneğin, doğruluk, duyarlılık, kesinlik, F1 skoru, makro ortalama F1 skor [multiclassifikasyonda hesaplanan F1 puanı ortalaması], Cohen-Kappa puan [CKS], ve Matthews korelasyon faktörü [MCC]) değerleri sınıflayıcı performansını değerlendirmek için kullanıldı.

5. BULGULAR

CNN tabanlı model, sulkus içeren kareleri tespit etmede ikili sınıflandırma aşamasında tüm ölçümlerde %95'in üzerinde performans elde etti. Tablo 4, karelerin ilgili alt kümelere sınıflandırılmasına ilişkin modelin tahminlerini bir karışıklık matrisi olarak ve karışıklık matrisinden türetilen metrikler olarak göstermektedir.

Çalışmanın ikinci aşamasında, dahil edilen tüm gruplardan 6.319 kare içeren test verilerinde modelin çoklu sınıflandırma performansı değerlendirildi. CNN tabanlı model, çoklu sınıflandırmada %85 doğruluk elde etti. Tablo 5 ve Şekil 12, diğer metrikler ve karışıklık matrisi için ayrıntılı sonuçları sunmaktadır. CNN tabanlı modelin ve 5 laringologun, 544 kare içeren anket verilerinde sınıflandırma performansını için karşılaştırmak karışıklık matrisleri ve performans metrikleri incelendi.

Tablo 4. Konvolüsyonel Sinir Ağı (CNN) Tabanlı İkili Sınıflandırıcı için Karışıklık Matrisi ve Performans Metrikleri

		Gerçek Etiket		Metrik	Değer
		Pozitif: Sulkus	Negatif: Sağlıklı		
Tahmin edilen Etiket	Pozitif : Sulkus	TP: 1739	FP: 37	Doğruluk (%)	98
				Duyarlılık (%)	97
	Negatif : Sağlıklı	FN: 25	TN: 1684	Kesinlik (%)	98
				F1 Skoru (%)	97
				Loss	0.087

Kısaltmalar. TP Gerçek pozitif; FP Yalancı pozitif; TN Gerçek negatif; FN Yalancı negatif

	Sağlıklı	Nodül	Papilloma	Polip	Sulkus	Kist	Psödokist		
Sağlıklı	983	18	0	18	28	17	5	0	
Nodül	14	805	17	44	47	36	8	1	
Papilloma	7	35	931	58	40	24	3	2	
Polip	31	49	16	801	67	59	5	3	
Sulkus	10	24	6	38	752	15	1	4	
Kist	16	46	8	43	33	821	2	5	
Psödokist	5	15	2	11	17	7	281	6	
	0	1	2	3	4	5	6		
								True Values	
								Predicted Values	

Şekil 12. Konvolüsyonel Sinir Ağı (CNN) Tabanlı Çoklu Sınıflandırıcı için Karışıklık Matrisi

CNN tabanlı model, sağlıklı grupta laringologların performansına kıyasla karşılaştırılabilir duyarlılık (%80'e karşı %62 ila %89 [ortalama %79.6]) ve önemli ölçüde yüksek doğruluk metrikleri (%85'e karşı %66 ila %76 [ortalama %69.8]) gösterdi. Nodül grubunda, CNN tabanlı model, laringologlar tarafından elde edilenlerle karşılaştırılabilir duyarlılık (%76'ya karşı %67 ila %77 [ortalama %71.2]) ve doğruluk metrikleri (%69'a karşı %63 ila %84 [ortalama %74.8]) elde etti. Papilloma grubunda, CNN tabanlı model daha yüksek duyarlılık (%91'e karşı %80 ila %84 [ortalama %81.2]) performansı, ancak laringologlara kıyasla daha düşük doğruluk performansı (%80'e karşı %91 ila %98 [ortalama %94.2]) gösterdi. Polip grubunda, CNN tabanlı model, laringologlarla karşılaştırıldığında daha düşük duyarlılık (%73'e karşı %87 ila %96 [ortalama %92]) ancak daha yüksek doğruluk (%74'e karşı %52 ila %72 [ortalama %59.4]) gösterdi. Sulkus grubunda, CNN tabanlı model, laringologlar tarafından elde edilenlere karşılaştırılabilir doğruluk metrikleri (%72'ye karşı %72 ila %83 [ortalama %78.2]) ve daha yüksek duyarlılık (%78'e karşı %55 ila %64 [ortalama %60.8]) gösterdi. Kist grubunda, CNN tabanlı model, laringologlar tarafından elde edilenlere karşılaştırılabilir doğruluk performansı (%74'e karşı %70 ila %87 [ortalama %80.4]) ve daha yüksek duyarlılık (%73'e karşı %37 ila %44 [ortalama %41.4]) seviyelerine ulaştı. Son olarak, psödokist kategorisinde, CNN tabanlı model, laringologların performansına kıyasla daha yüksek duyarlılık (%82'ye karşı %5 ila %50 [ortalama %25.6]) ve doğruluk metrikleri (%79'a karşı %22 ila %62 [ortalama %45.4]) gösterdi. Ayrıca, CNN tabanlı model, doğruluk, CKS, makro ortalama F1 skoru ve MCC gibi çeşitli metriklerde daha yüksek puanlar elde ederek laringologları geride bıraktı. Bu sonuçlar, CNN tabanlı modelin, çok sınıflı sınıflandırma görevinde uzman laringologlara kıyasla güçlü performansını vurgulamaktadır. Tablo 4, doğruluk, duyarlılık, kesinlik, CKS, makro ortalama F1 skoru ve ortalama MCC değerlerini belirtmektedir ve Şekil 13 ise ilgili karışıklık matrislerini göstermektedir. Son olarak, CNN tabanlı model, yalnızca sınıflandırmada üstün doğruluk göstermekle kalmayıp, aynı zamanda laringologlara kıyasla çok daha hızlı sınıflandırma süreleri elde etmiştir (CNN: milisaniyeler, laringologlar: C1: 32 dakika, C2: 42 dakika, C3: 30 dakika, C4: 36 dakika ve C5: 35 dakika).

Tablo 5. Konvolüsyonel Sinir Ağı (CNN) Tabanlı Model ve Laringologların Test ve Anket Verilerinde Çoklu Sınıflandırmada Performans Metrikleri

	Alt Grup	Duyarlılık	Kesinlik	F1 Skor	Doğruluk, CKS*, MCC**
CNN – Test edilme (6319 kare)	0:Sağlıklı	92%	92%	92%	Doğruluk: 85% CKS: 0.8234 Average MCC: 0.8238
	1:Nodül	81%	83%	82%	
	2:Papilloma	95%	85%	90%	
	3:Polip	79%	78%	78%	
	4:Sulkus	76%	89%	82%	
	5:Kist	84%	85%	84%	
	6:Psödokist	92%	83%	87%	
CNN – Anket (544 kare)	0:Sağlıklı	80%	85%	82%	Doğruluk :76% CKS: 0.7164 Average MCC: 0.7169
	1:Nodül	76%	69%	72%	
	2:Papilloma	91%	80%	84%	
	3:Polip	73%	74%	73%	
	4:Sulkus	78%	72%	74%	
	5:Kist	73%	74%	74%	
	6:Psödokist	82%	79%	80%	
C1 - Anket (544 kare)	0:Sağlıklı	88%	66%	75%	Doğruluk :72% CKS: 0.6593 Average MCC : 0.6708
	1:Nodül	68%	84%	75%	
	2:Papilloma	81%	92%	87%	
	3:Polip	96%	58%	72%	
	4:Sulkus	63%	82%	71%	
	5:Kist	43%	86%	57%	
	6:Psödokist	25%	59%	35%	
C2 - Anket (544 kare)	0:Sağlıklı	71%	76%	73%	Doğruluk :68% CKS: 0.6282 Ort. MCC :0.6326
	1:Nodül	76%	63%	69%	
	2:Papilloma	80%	98%	88%	
	3:Polip	88%	72%	79%	
	4:Sulkus	59%	72%	65%	
	5:Kist	39%	74%	51%	
	6:Psödokist	50%	28%	36%	
C3 - Anket (544 kare)	0:Sağlıklı	88%	68%	77%	Doğruluk :72% CKS: 0.6593 Ort. MCC :0.6707
	1:Nodül	68%	78%	73%	
	2:Papilloma	80%	95%	87%	
	3:Polip	95%	57%	71%	
	4:Sulkus	64%	83%	72%	
	5:Kist	44%	87%	58%	
	6:Psödokist	25%	62%	36%	
C4 - Anket (544 kare)	0:Sağlıklı	62%	73%	67%	Doğruluk:63% CKS: 0.5623 Ort. MCC: 0.5721
	1:Nodül	77%	67%	72%	
	2:Papilloma	81%	95%	88%	
	3:Polip	87%	52%	65%	
	4:Sulkus	55%	72%	62%	
	5:Kist	37%	70%	49%	
	6:Psödokist	5%	22%	8%	
C5 - Anket (544 kare)	0:Sağlıklı	89%	66%	76%	Doğruluk:72% CKS: 0.6594 Ort. MCC:0.6699
	1:Nodül	67%	82%	74%	
	2:Papilloma	84%	91%	87%	
	3:Polip	94%	58%	72%	
	4:Sulkus	63%	82%	71%	
	5:Kist	44%	85%	58%	
	6:Psödokist	23%	56%	32%	

Kisaltmalar *Cohen-Kappa Score (CKS); ** Matthews Correlation Coefficient (MCC)

	Sağlıklı	Nodül	Papillom	Polip	Sulkus	Kist	Psödökist
Sağlıklı	92	11	0	0	24	8	5
Nodül	2	51	0	0	1	2	5
Papilloma	0	0	61	3	0	1	1
Polip	1	11	14	96	2	26	16
Sulkus	9	0	0	0	47	1	0
Kist	0	1	0	1	0	32	3
Psödökist	0	1	0	0	1	5	10
	0	1	2	3	4	5	6

Klinisyen 1

	Sağlıklı	Nodül	Papillom	Polip	Sulkus	Kist	Psödökist
Sağlıklı	74	1	0	0	22	1	0
Nodül	10	57	0	0	2	8	14
Papilloma	0	0	60	1	0	0	0
Polip	0	6	15	88	1	12	1
Sulkus	16	0	0	0	44	1	0
Kist	1	2	0	1	1	29	5
Psödökist	3	9	0	10	5	24	20
	0	1	2	3	4	5	6

Klinisyen 2

	Sağlıklı	Nodül	Papillom	Polip	Sulkus	Kist	Psödökist
Sağlıklı	92	10	0	0	23	6	5
Nodül	2	51	0	1	1	4	6
Papilloma	0	0	60	3	0	0	0
Polip	1	12	15	95	2	27	16
Sulkus	9	0	0	0	49	1	0
Kist	0	1	0	1	0	33	3
Psödökist	0	1	0	0	1	4	10
	0	1	2	3	4	5	6

Klinisyen 3

	Sağlıklı	Nodül	Papillom	Polip	Sulkus	Kist	Psödökist
Sağlıklı	65	2	0	0	22	0	0
Nodül	12	58	0	1	2	6	7
Papilloma	0	0	61	3	0	0	0
Polip	4	8	5	87	2	33	28
Sulkus	16	0	0	0	41	0	0
Kist	1	4	0	5	0	28	2
Psödökist	1	0	0	1	2	3	2
	0	1	2	3	4	5	6

Klinisyen 4

	Sağlıklı	Nodül	Papillom	Polip	Sulkus	Kist	Psödökist
Sağlıklı	93	11	0	0	25	6	5
Nodül	2	50	0	0	1	3	5
Papilloma	0	0	63	4	0	1	1
Polip	0	12	12	94	1	26	17
Sulkus	9	0	0	0	47	1	0
Kist	0	1	0	2	0	33	3
Psödökist	0	1	0	0	1	5	9
	0	1	2	3	4	5	6

Klinisyen 5

	Sağlıklı	Nodül	Papillom	Polip	Sulkus	Kist	Psödökist
Sağlıklı	82	3	1	2	7	2	0
Nodül	2	57	0	4	7	6	7
Papilloma	2	2	69	7	4	3	0
Polip	4	6	4	71	9	3	0
Sulkus	6	2	0	5	45	5	0
Kist	6	3	2	7	1	35	0
Psödökist	2	2	0	2	2	1	33
	0	1	2	3	4	5	6

Önerilen CNN Modeli

Şekil 13. Laringologların ve Önerilen CNN Modelinin Anket Veri Setindeki Karışıklık Matrisleri

6. TARTIŞMA

Sulkus, vokal kordların serbest kenarında bulunan bir oluğu ifade eder ve genellikle mukozal dalgalanmanın olumsuz etkilenmesi ile ilişkilidir (1). Klinik semptomlarla birlikte videostroboskopi, sulkus için altın standart bir tanı yöntemidir. Bununla birlikte, tanı süreci mevcut literatürde de gösterildiği gibi zorluklar içerebilir (5, 6). Tanı süreci subjektiftir ve büyük ölçüde muayeneyi yapan kişinin deneyimine bağlıdır. Ayrıca tüm hekimler, vokal kord hastalığının teşhisi için larenksi tam olarak görselleştirecek yeterli eğitim veya ekipmana sahip değildir. Bu zorluklar, klinisyenlere tanı sürecinde yardımcı olmak için AI içeren ek bilgisayar tabanlı sistemlerin geliştirilmesini gerekli kılmıştır.

Çalışmamızda, sulkus tanısı konmuş hastaların görüntülerini diğer vokal kord hastalıkları ve sağlıklı bireylerin görüntülerinden ayırt etmek amacıyla iki CNN tabanlı sınıflandırıcı modelleri geliştirildi. Önerilen modeller ikili ve çoklu sınıflandırmada kayda değer performans metrikleri sergiledi. Özellikle belirtmek gerekirse, ikili sınıflandırıcı %98 doğruluk ve %97 F1 skoru elde etti. Çoklu sınıflandırıcı, sulkus, sağlıklı bireyler ve benign vokal kord hastalıklarını ayırt etmede klinisyenlere benzer şekilde %85 doğruluk elde etti. Çalışmamızın bulguları, CNN tabanlı modellerin klinik laringoskopi değerlendirmelerini geliştirme potansiyeline sahip olduğunu ve sulkus gibi zorlu koşulların teşhisi için modern bir otomatik sistemin geliştirilmesine katkıda bulunma potansiyeli taşıdığını göstermektedir.

Önceki çalışmalar, laringoloji alanında çeşitli uygulamalarda (glottal alan segmentasyonu, vokal kord titreşim analizi, vokal kord hareketlerini belirleme ve lezyon tanıma) AI modellerini araştırmıştır (10). Vokal kord lezyonu tanıma ve sınıflandırma bağlamında, çoğu çalışma destek vektör makineleri (SVM) ve k-en yakın komşu algoritması gibi geleneksel ML yöntemlerini kullanmıştır (46, 47, 48, 49, 50, 51, 52, 53, 54). Bununla birlikte, özellikle lezyon tanıma ve sınıflandırma alanında daha büyük veri setlerinin dahil edilip derin öğrenme gibi önemli hesaplama yetenekleri sergileyen algoritmaların (özellikle CNN) kullanıldığı sınırlı sayıda çalışmada mevcuttur (44, 55, 56, 57, 58, 59). Ayrıca CNN tabanlı modellerle sulkusun değerlendirilmesi ve sınıflandırılması alanında hiçbir çalışma yapılmamıştır. Bildiğimiz kadarıyla, mevcut literatürde yalnızca Türkmen ve diğ. (53), sulkusu bir dizi vokal kord hastalığı ile birlikte sınıflandırmıştır. Çalışmalarında, kan damarlarını segment etmek için alan büyütme (region growing) ve damarların dallanması baz alan (vessel-linking based) bir segmentasyon algoritması kullanmışlardır. Kan damarlarından çıkarılan özellikleri, SVM, rastgele orman ve k-en yakın komşu sınıflandırma algoritmalarına girdi olarak kullanarak görüntüleri sağlıklı, polip, nodül, sulkus ve larenjit gruplarına

sınıflandırmışlardır. Türkmen ve diğ., geliştirdikleri yöntemin performansını 70 hastadan alınan laringeal kareleri kullanarak değerlendirip sağlıklı, polip, nodül, larenjit ve sulkus sınıfları için duyarlılık oranlarının sırasıyla %86, %94, %80, %73 ve %76 olduğunu bulmuştur. Bunu yaparken çalışmalarında vokal kordu etkili bir şekilde sınıflandırmak için insan müdahalesi ve ML tekniklerini birleştiren ikili bir karar ağacı modeli (decision tree model) kullanmışlardır. Bildiğimiz kadarıyla, çalışmamız sulkusu CNN tabanlı bir modelle değerlendiren ilk çalışmadır. Türkmen ve diğ.'in aksine, sınıflandırma sürecimizde insan müdahalesi yer almamıştır. Aksine, yalnızca AI tabanlı bir model kullanılmıştır. İnsan müdahalesi, önerilen sınıflandırıcıları eğitmek ve test etmek amacıyla tüm veri setinin hazırlanması ve anket verilerinin oluşturulması ile sınırlı kalmıştır.

AI modelleri ve klinisyenler arasında karşılaştırmalı araştırma yapmak, AI uygulamalarının tanı araçları olarak geniş çapta kullanımını doğrulamak ve teşvik etmek için son derece önemlidir (60). Ren ve diğ. (57) ve Xiong ve diğ. (44), normal, prekanseröz ve kanserli laringeal lezyonların AI tabanlı sınıflandırılması amacıyla yaptıkları çalışmada AI tabanlı sınıflandırıcının sonuçlarını klinisyenlerin sonuçlarıyla karşılaştırdılar. Araştırmacılar, CNN tabanlı modellerinin lezyonları sınıflandırmada klinisyenlere kıyasla daha yüksek doğruluk oranları sergilediğini gösterdiler (44, 57). Biz de çalışmamızda, CNN tabanlı modelin performans metriklerini ve klinisyenlerin performans metriklerini karşılaştırdık. Veri setlerini oluşturmak için videostrobokopi karesi dahil etme sürecinde hiçbir kısıtlama uygulamamıza rağmen, CNN tabanlı sınıflandırıcının F1 skoru, sağlıklı, polip, sulkus, kist ve psödokist gibi çeşitli gruplarda beş laringologun ortalama F1 skorlarını aştı. Ancak, nodül ve papilloma gruplarında, CNN tabanlı sınıflandırıcının F1 skoru daha düşük bulundu. Bu çalışmaya dahil edilen klinisyenlerin, laringoloji alanında en az beş yıl deneyime sahip laringologlardan seçili olması geliştirdiğimiz AI modeli ile elde edilen sınıflandırma performansı kayda değer kılmaktadır. Bununla birlikte, klinisyenlerin lezyonları sınıflandırmadaki doğruluğunun, videostroboskopi karelerinin gösterilmesinden ziyade video kaydının tamamının gösterilmesiyle artacağını şüphesizdir.

Çalışmamızda, veri seti, 25 fps ile kaydedilmiş videostroboskopilerden kareler çıkarılarak oluşturulmuştur. Önerilen modellerin hızlı analiz yeteneğini göz önünde bulundurarak, videostroboskopiler sırasında gerçek zamanlı değerlendirmeler yapacak ileri AI modellerinin geliştirilmesi gelecekteki araştırma konusu olması gerektiği düşünülmektedir. Azam ve diğ. (59) tarafından yapılan bir çalışmada, laringeal skuamöz hücreli kanserlerin hem beyaz ışık hem de dar bant videostroboskopilerini gerçek zamanlı değerlendirebilecek bir CNN modelinden ilk defa bahsedilmiştir. Mevcut literatürde bu eksiklik göz önüne alındığında, araştırmamızın bir sonraki aşaması, videostroboskopileri gerçek zamanlı değerlendirebilecek ileri AI modelleri geliştirmeye odaklanacaktır. Bu yöntemin uygulanmasıyla, özellikle sulkus gibi zor lezyonların değerlendirilmesi sırasında klinisyenlerin tanı doğruluğunun artırılma potansiyeli bulunmaktadır.

Bu çalışmanın belirli kısıtlılıkları vardır. AI algoritması için veri olarak videostroboskopiden elde edilen karelerin dahil edilmesi, klinisyenlerin sulkus tanısı sürecinde rutin olarak değerlendirdiği birçok videostroboskopi bulgusunun elenmesine neden olmaktadır. Çalışmamızda videostroboskopilerin tamamının yerine videostroboskopi karelerini değerlendirmesi, klinisyenlerin sulkusu doğru bir şekilde değerlendirme kapasitesini kısıtlayabilir. Çalışmamızın diğer bir kısıtlılığı, rutin biyopsi veya cerrahi geçirmeyen hastaların dahil edilmesi ile ilgilidir. Veri setine dahil edilme kriterleri arasında, vokal kord lezyonunun patolojik olarak da doğrulanması ve lezyonun patolojik tanısı olmadığı takdirde araştırmacılar tarafından videostroboskopilerin değerlendirilip tanılarının gözden geçirilmesi yer almaktadır. Ancak, lezyonların özgün görsel özellikleri ve videostroboskopilerin tekrarlı incelemeleri neticesinde, veri setinin doğruluğu sağlanmıştır.

KAYNAKLAR

1. Giovanni A, Chanteret C, Lagier A. Sulcus vocalis: a review. *European archives of oto-rhino-laryngology*. 2007;264:337-44.
2. Hirano M, Yoshida T, Tanaka S, Hibi S. Sulcus vocalis: functional aspects. *Annals of otology, rhinology & laryngology*. 1990;99(9):679-83.
3. Lim J-Y, Kim J, Choi SH, Kim K-m, Kim YH, Kim HS, et al. Sulcus configurations of vocal folds during phonation. *Acta oto-laryngologica*. 2009;129(10):1127-35.
4. Saraniti C, Patti G, Verro B. Sulcus Vocalis and Benign Vocal Cord Lesions: Is There Any Relationship? *International Journal of Environmental Research and Public Health*. 2023;20(9):5654.
5. Dailey SH, Spanou K, Zeitels SM. The evaluation of benign glottic lesions: rigid telescopic stroboscopy versus suspension microlaryngoscopy. *Journal of Voice*. 2007;21(1):112-8.
6. Sunter AV, Yigit O, Huq GE, Alkan Z, Kocak I, Buyuk Y. Histopathological characteristics of sulcus vocalis. *Otolaryngology--Head and Neck Surgery*. 2011;145(2):264-9.
7. Yildiz MG, Sagiroglu S, Bilal N, Irfan K, Orhan I, Doganer A. Assessment of Subjective and Objective Voice Analysis According to Types of Sulcus Vocalis. *Journal of Voice*. 2021.
8. Sampieri C, Baldini C, Azam MA, Moccia S, Mattos LS, Vilaseca I, et al. Artificial Intelligence for Upper Aerodigestive Tract Endoscopy and Laryngoscopy: A Guide for Physicians and State-of-the-Art Review. *Otolaryngology–Head and Neck Surgery*. 2023;169(4):811-29.
9. Crowson MG, Ranisau J, Eskander A, Babier A, Xu B, Kahmke RR, et al. A contemporary review of machine learning in otolaryngology–head and neck surgery. *The Laryngoscope*. 2020;130(1):45-51.
10. Yao P, Usman M, Chen YH, German A, Andreadis K, Mages K, et al. Applications of artificial intelligence to office laryngoscopy: a scoping review. *The Laryngoscope*. 2022;132(10):1993-2016.
11. Alter IL, Chan K, Lechien J, Rameau A. An introduction to machine learning and generative artificial intelligence for otolaryngologists—head and neck surgeons: a narrative review. *European Archives of Oto-Rhino-Laryngology*. 2024:1-9.
12. Hirano M. Phonosurgery. Basic and clinical investigation. *Otologia*. 1975;21(1):299-303.
13. Hirano M. Morphological structure of the vocal cord as a vibrator and its variations. *Folia phoniatica et logopaedica*. 1974;26(2):89-94.
14. Hirano M. Cover-body theory of vocal cord vibration. *Speech science*. 1985:1-46.
15. Sataloff R, Gullane P, Goldstein D. Sataloff's comprehensive textbook of otolaryngology. *Head & neck surgery*. 2015;5.

16. Holmberg EB, Doyle P, Perkell JS, Hammarberg B, Hillman RE. Aerodynamic and acoustic voice measurements of patients with vocal nodules: variation in baseline and changes across voice therapy. *Journal of Voice*. 2003;17(3):269-82.
17. Kiliç MA, Okur E, Yildirim I, Güzelsoy S. The prevalence of vocal fold nodules in school age children. *International Journal of Pediatric Otorhinolaryngology*. 2004;68(4):409-12.
18. Pedersen M, McGlashan J. Surgical versus non-surgical interventions for vocal cord nodules. *The Cochrane database of systematic reviews*. 2012;2012(6).
19. Pontes P, Kyrillos L, Behlau M, De Biase N, Pontes A. Vocal nodules and laryngeal morphology. *Journal of Voice*. 2002;16(3):408-14.
20. Johns MM. Update on the etiology, diagnosis, and treatment of vocal fold nodules, polyps, and cysts. *Current opinion in otolaryngology & head and neck surgery*. 2003;11(6):456-61.
21. Solis-Cohen J. *Diseases of the Throat: A Guide to the Diagnosis and Treatment*. William Wood, New York. 1872.
22. Sm Z. Phonomicrosurgery in Singers & Performing Artists: Treatment Outcomes, Management Theories, & Future Directions. *Annals of Otolaryngology, Rhinology, & Laryngology*. 2002;111(190):21-40.
23. Kambič V. Epithelial hyperplastic lesions—a challenging topic in laryngology. *Acta Oto-Laryngologica*. 1997;117(sup527):7-11.
24. Courey MS, Scott MA, Shohet JA, Ossoff RH. Immunohistochemical characterization of benign laryngeal lesions. *Annals of Otolaryngology, Rhinology & Laryngology*. 1996;105(7):525-31.
25. *An Atlas of Otolaryngic Pathology*. *AMA Archives of Otolaryngology*. 1957;65(1):102-.
26. Arnold GE. Dysplastic dysphonia: minor anomalies of the vocal cords causing persistent hoarseness. *The Laryngoscope*. 1958;68(2):142-58.
27. Kashima H, Leventhal B, Mounts P, Hruban RH. Sites of predilection in recurrent respiratory papillomatosis. *Annals of Otolaryngology, Rhinology & Laryngology*. 1993;102(8):580-3.
28. Gale N, Zidar N, Cardesa A, Nadal A. *Benign and potentially malignant lesions of the squamous epithelium and squamous cell carcinoma*: Springer; 2016.
29. Sataloff RT, Lalwani AK, Fried MP, Tabae A, Benninger MS, Hartnick CJ. *Sataloff's Comprehensive Textbook of Otolaryngology: Head & Neck Surgery: Rhinology/Allergy and Immunology*: JP Medical Ltd; 2015.
30. Ford CN, Inagi K, Khidr A, Bless DM, Gilchrist KW. Sulcus vocalis: a rational analytical approach to diagnosis and management. *Annals of otology, rhinology & laryngology*. 1996;105(3):189-200.
31. Selleck AM, Moore JE, Rutt AL, Hu A, Sataloff RT. Sulcus vocalis (type III): prevalence and stroboscopy characteristics. *Journal of Voice*. 2015;29(4):507-11.

32. Welham NV, Dailey SH, Ford CN, Bless DM. Voice handicap evaluation of patients with pathologic sulcus vocalis. *Annals of Otolaryngology, Rhinology & Laryngology*. 2007;116(6):411-7.
33. Varelas EA, Paddle PM, Franco Jr RA, Husain IA. Identifying Type III sulcus: patient characteristics and endoscopic findings. *Otolaryngology–Head and Neck Surgery*. 2020;163(6):1240-3.
34. Cakir ZA, Yigit O, Kocak I, Sunter AV, Dogan M. Sulcus vocalis in monozygotic twins. *Auris Nasus Larynx*. 2010;37(2):255-7.
35. Husain S, Sulica L. Familial sulcus vergeture: further evidence for congenital origin of type 2 sulcus. *Journal of Voice*. 2016;30(6):761. e19-. e21.
36. Lee A, Sulica L, Aylward A, Scognamiglio T. Sulcus vocalis: a new clinical paradigm based on a re-evaluation of histology. *The Laryngoscope*. 2016;126(6):1397-403.
37. Hirano M, Bless DM. *Videostroboscopic examination of the larynx: Singular*; 1993.
38. Behrman A. Common practices of voice therapists in the evaluation of patients. *Journal of Voice*. 2005;19(3):454-69.
39. Woo P, Colton R, Casper J, Brewer D. Diagnostic value of stroboscopic examination in hoarse patients. *Journal of voice*. 1991;5(3):231-8.
40. artificial intelligence.
41. Esteva A, Robicquet A, Ramsundar B, Kuleshov V, DePristo M, Chou K, et al. A guide to deep learning in healthcare. *Nature medicine*. 2019;25(1):24-9.
42. Paderno A, Holsinger FC, Piazza C. Videomics: bringing deep learning to diagnostic endoscopy. *Current opinion in otolaryngology & head and neck surgery*. 2021;29(2):143-8.
43. FDA. FDA Authorizes Marketing of First Device that Uses Artificial Intelligence to Help Detect Potential Signs of Colon Cancer: FDA; 2021 [Available from: <https://www.fda.gov/news-events/press-announcements/fda-authorizes-marketing-first-device-uses-artificial-intelligence-help-detect-potential-signs-colon#:~:text=Today%2C%20the%20U.S.%20Food%20and,real%20time%20during%20a%200colonoscopy>].
44. Xiong H, Lin P, Yu J-G, Ye J, Xiao L, Tao Y, et al. Computer-aided diagnosis of laryngeal cancer via deep learning based on laryngoscopic images. *EBioMedicine*. 2019;48:92-9.
45. Moccia S, Vanone GO, De Momi E, Laborai A, Guastini L, Peretti G, et al. Learning-based classification of informative laryngoscopic frames. *Computer methods and programs in biomedicine*. 2018;158:21-30.
46. Araujo T, Santos CP, De Momi E, Moccia S. Learned and handcrafted features for early-stage laryngeal SCC diagnosis. *Medical & Biological Engineering & Computing*. 2019;57:2683-92.
47. Gelzinis A, Vaiciukynas E, Kelertas E, Bacauskiene M, Verikas A, Virgilijus U, et al., editors. Categorizing sequences of laryngeal data for decision support. *Electrical and Control*

Technologies: proceedings of the 4th international conference, ECT 2009, May 7-8, Kaunas, Lithuania; 2009: IFAC Committee of National Lithuanian Organisation.

48. Bethanigtyas H, Anggraini CD, editors. Classification system vocal cords disease using digital image processing. 2019 IEEE International Conference on Industry 40, Artificial Intelligence, and Communications Technology (IAICT); 2019: IEEE.
49. Turkmen HI, Karsligil ME, Kocak I, editors. Classification of vocal fold nodules and cysts based on vascular defects of vocal folds. 2013 IEEE International Workshop on Machine Learning for Signal Processing (MLSP); 2013: IEEE.
50. Huang C-C, Leu Y-S, Kuo C-FJ, Chu W-L, Chu Y-H, Wu H-C. Automatic recognizing of vocal fold disorders from glottis images. Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine. 2014;228(9):952-61.
51. Ilgner JF, Palm C, Schütz AG, Spitzer K, Westhofen M, Lehmann TM. Colour texture analysis for quantitative laryngoscopy. *Acta oto-laryngologica*. 2003;123(6):730-4.
52. Unger J, Schuster M, Hecker DJ, Schick B, Lohscheller J, editors. A multiscale product approach for an automatic classification of voice disorders from endoscopic high-speed videos. 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC); 2013: IEEE.
53. Turkmen HI, Karsligil ME, Kocak I. Classification of laryngeal disorders based on shape and vascular defects of vocal folds. *Computers in biology and medicine*. 2015;62:76-85.
54. Unger J, Lohscheller J, Reiter M, Eder K, Betz CS, Schuster M. A noninvasive procedure for early-stage discrimination of malignant and precancerous vocal fold lesions based on laryngeal dynamics analysis. *Cancer research*. 2015;75(1):31-9.
55. Dunham ME, Kong KA, McWhorter AJ, Adkins LK. Optical biopsy: automated classification of airway endoscopic findings using a convolutional neural network. *The Laryngoscope*. 2022;132:S1-S8.
56. Luan B, Sun Y, Tong C, Liu Y, Liu H, editors. R-fcn based laryngeal lesion detection. 2019 12th International Symposium on Computational Intelligence and Design (ISCID); 2019: IEEE.
57. Ren J, Jing X, Wang J, Ren X, Xu Y, Yang Q, et al. Automatic recognition of laryngoscopic images using a deep-learning technique. *The Laryngoscope*. 2020;130(11):E686-E93.
58. Wang P, Fan E, Wang P. Comparative analysis of image classification algorithms based on traditional machine learning and deep learning. *Pattern Recognition Letters*. 2021;141:61-7.
59. Azam MA, Sampieri C, Ioppi A, Africano S, Vallin A, Mocellin D, et al. Deep learning applied to white light and narrow band imaging videolaryngoscopy: toward real-time laryngeal cancer detection. *The Laryngoscope*. 2022;132(9):1798-806.
60. Dallari V, Sacchetto A, Saetti R, Calabrese L, Vittadello F, Gazzini L. Is artificial intelligence ready to replace specialist doctors entirely? ENT specialists vs ChatGPT: 1-0, ball at the center. *European Archives of Oto-Rhino-Laryngology*. 2024;281(2):995-1023.

