

## 3D Ağız İçi Taramalarına Ait Nokta Bulutu Verileri ile Derin Öğrenme Kullanılarak Diş Tipi Sınıflandırması

Furkan Şenyurt<sup>1\*</sup>, İsmail İşeri<sup>2+</sup>

<sup>1</sup> Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Samsun, Türkiye, furkan.senyurt@bil.omu.edu.tr

<sup>2</sup> Ondokuz Mayıs Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Samsun, ismail.iseri@omu.edu.tr

\*Sorumlu yazar: ismail.iseri@omu.edu.tr

+Konuşmacı: furkan.senyurt@bil.omu.edu.tr

**Özet** – Son yıllarda üretim teknolojilerindeki gelişmeler, daha düşük maliyetli gelişmiş ağız içi tarayıcıların ortaya çıkmasını ve kısa sürede diş hekimliğinde kullanılmasına neden olmuştur. Literatüre bakıldığında ağız içi taramalarından elde edilen ham verinin doğrudan kullanımına yönelik veya farklı 3 boyutlu veri temsil modellerine dönüştürülerek bireysel diş tanımlama, diş damak ayrımı, diş segmentasyonu ve dişlerin sınıflandırılması konusunda çalışmaların yapıldığı görülmektedir. Bu çalışmada ağız içi tarayıcılar ile elde edilen örgü (mesh) verileri 3 boyutlu nokta bulutu ağız içi diş modellerine dönüştürülmüştür. Bu 3 boyutlu diş modelleri PointNet modeli kullanılarak sınıflandırılmıştır. Çalışmada nokta sayıları kademeli olarak artırılarak ve farklı optimizasyon fonksiyonlarına göre sınıflandırma modelinin performans metrikleri incelenmiştir. Yapılan denemeler ve elde edilen sınıflandırma metrikleri açısından incelendiğinde, çalışma için en iyi sonucun 2048 nokta sayısında Doğruluk %55, Kesinlik %55, Duyarlılık %55 ve F1 skoru %54 olarak bulunmuştur. Ayrıca Adam fonksiyonu, farklı optimizasyon fonksiyonları arasında en iyi performansa sahip optimizasyon fonksiyonu olduğu anlaşılmıştır.

**Anahtar kelimeler** 3B Derin Öğrenme, 3B Ağız-İçi Tarayıcıları, Diş Sınıflandırma, 3B Dental Model, Nokta Bulutu

## Tooth Type Classification Using Deep Learning with Point Cloud on 3D Intraoral Scanners

**Abstract** – In recent years, developments in production technologies have led to the emergence of lower cost advanced intraoral scanners and their use in dentistry in a short time. When the literature is examined, it is seen that the raw data obtained from intraoral scans are converted into different 3D data representation models for direct use or by converting them into individual tooth identification, tooth-gingiva separation, tooth segmentation and tooth classification. In this study, the mesh data obtained with intraoral scanners were converted into 3D point cloud intraoral tooth models. These 3D tooth models were classified using the PointNet model. In the study, the performance analyzes of the classification model were examined by increasing the sample of points gradually. When the results were analyzed in terms of trials and the classification metrics obtained, the best result for the study was found to be Accuracy 55%, Precision 55%, Recall 55%, and F1 score 54% in sample 2048 points. Also, Adam was the optimization function with the best performance among the different optimization functions.

**Keywords** – 3D Deep Learning, 3D Intra Oral Scanners, Tooth Classification, 3D Dental Models, Point Cloud

### I. GİRİŞ

3B derin öğrenme kavramı son yılların önemli araştırma konularından olmasıyla birlikte araştırmacıların farklı

alanlarda bu yöntemleri kullandığı ve birçok başarılı uygulamaya imza attığı görülmektedir. 3B modellerin artan kullanımı bu modeller üzerinde sınıflandırma, segmentasyon ve 3B şekil analizi görevlerini gerçekleştirmek için etkili

algoritmalar ile ve 3Shape, Implant3D, OrthoCAD gibi birçok ticari yazılımların ortaya çıkmasıyla derin öğrenme uygulamaları büyük atılımlara sebep olmuştur.

Derin öğrenmenin manuel yöntemlere göre görüntü öznetelik çıkarmadaki başarısı, basitliği ve esnekliği nedeniyle nokta bulutları gibi ham 3B verilere olan ilgiyi arttırmıştır. Referansla belirtilen çalışmalarda 3B nokta bulutu veri temsiliyle oluşturulmuş verileri, diğer formatlara herhangi bir dönüşüm uygulamaksızın doğrudan işlemektedir [1], [2]. Bu yaklaşımlar 3B nesne sınıflandırma ve segmentasyon görevlerinde etkili olduklarını kanıtlamaktadır. Ancak nokta bulutlarının permütasyonu değişmemesinden dolayı bu durumun, çıktı kalitesini etkilemeden nasıl işlenebileceği konusunda belirsizlik vardır. 3B veriler, 2B uzaya yansıtılabilir ve orijinal 3B verilerin bazı temel özellikleri korunabilir [3],[4]. Ancak 3B nesnelere çok karmaşık olduğunda bilgi kaybı oluşabilir. 3B veri temsilleri üzerinde etkili bir derin öğrenme modeline sahip olmak için 3B veri temsillerinin temel özelliklerini yani verimliliğini, basitliğini ve kullanılabilirliğini dikkate almaya ihtiyaç vardır. 3B nesnelere sınıflandırılması ve segmentasyonu için derin öğrenme yöntemlerinde kullanılan 3B veri temsili, son zamanlarda hızla büyümeye devam etmiştir.

3B modellerin sayısının artmasıyla birlikte 3B şekil arama ve sınıflandırma görevleri, tıbbi görüntüleme daha birçok alanda ilgi görmeye devam etmektedir. Diş hekimliği alanı da araştırmacılar tarafından ilgi çekici alanlardan biridir. Özellikle 3B dental modeller üzerinde diş segmentasyonu, bilgisayar destekli ortodontik sistemlerde önemli bir tekniktir ve bu teknik klinik ortodontik tanıda önemli bir rol oynamaktadır. Diş segmentasyonu üzerine kapsamlı araştırmalara rağmen, diş morfolojisinin yapısı, diş ve diş eti birleşimindeki çizgilerin sıkı olması ayrıca dişlerin füzyon (birleşmesi) olması gibi nedenlerle otomatik ve doğru diş segmentasyonu son derece zorlu bir çalışma konusudur. Poonsri ve diğerleri yaptığı çalışmada panoramik diş röntgeni görüntülerinden diş alanı tanımlama ve şablon eşleştirme yoluyla dişleri segmentlere ayırmak için yöntemler önerdi [5]. Ancak bu yöntemler düzensiz diş dizilimleri ve belirsiz diş sınırları açısından dişlerin üç boyutlu şeklini doğru bir şekilde ifade edemediği için dişleri segmentlere ayırmada güvenilir sonuç elde edememişlerdir. Bu nedenle üç boyutlu diş modeline dayalı birçok diş segmentasyonu yöntemi ortaya çıkmıştır

Bir diğer zorlu çalışma konusu ise üç boyutlu modelde diş tipinin sınıflandırılmasıdır. Aynı diş tipine sahip bireyler arasında bazı ortak morfolojik özellikler olmasına rağmen, dişlerin yüzey görünümünde büyük farklılıklar vardır. Son zamanlarda derin öğrenme, görüntülerden ayırt edici özellikleri çıkarma konusunda öğrenme yeteneğini kanıtlamıştır. Tian ve diğerleri yapmış oldukları çalışmada 3B dental modelin segmentasyonu ve sınıflandırılması için octree veri temsillerinden yararlanmışlardır [6]. 3B octree tabanlı CNN aracılığıyla 3B dental model için otomatik bir segmentasyon ve sınıflandırma yöntemi sunmuşlardır. Yüksek benzerliğe sahip dişlerin yanlış sınıflandırma problemini çözmek için octree modeli ile temsil edilen segmentlere ayrılmış dişler için iki seviyeli hiyerarşik ağ mimarisi kullanmışlardır. Seviye-1 ağı ile tüm diş kategorilerinden genel öznetelikler çıkarılmış, Seviye-2 ağı ile çok benzer diş kategorilerinden spesifik öznetelikler çıkarılmıştır. Geliştirdikleri bu yöntemle yüksek sınıflandırma doğruluklarına ulaşmışlardır. Benzer çalışma için Xu ve

diğerleri farklı ölçekli geometrik öznetelikleri çıkarmak için mesh veri temsiliyi kullanarak  $20 \times 30$  boyutunda CNN'i besleyen 600 boyutlu vektör oluşturmuşlardır [7]. Etiketleme ve diş sınır iyileştirmelerinden sonra, üst ve alt çene diş modelleri için 8 etiketli yüksek sınıflandırma doğruluğu elde etmişlerdir.

Bu çalışmada IOS' lardan elde edilen 3B dental modeller üzerinde nokta bulutu veri temsili ile PointNet mimarisi kullanılarak dişlerin sınıflandırılması yapılmıştır. Çalışmada literatürdeki çalışmalardan farklı olarak 3B dental modellerden dişler bireysel olarak damaktan manuel olarak ayrılıp farklı nokta sayıları ile diş tiplerinin sınıflandırılması amaçlanmıştır. Ayrıca nokta sayıları kademeli olarak artırıldığındaki performansları ve farklı optimizasyon fonksiyonlarına göre karşılaştırılması yapılmıştır. Çalışmanın ilerleyen bölümleri şu şekilde düzenlenmiştir. II. bölümde nokta bulutu veri temsili ile 3B nesne sınıflandırma derin öğrenme çalışmaları ve 3B dental modeller üzerinde derin öğrenme yöntemleri kullanılarak diş sınıflandırılması, segmentasyon çalışmaları ve kullanılan yöntemler literatürde incelenmiştir. III. bölümünde veri ön işleme ve kullanılan yöntemin parametreleri ve yapısı açıklanmıştır. IV. bölümünde farklı nokta sayıları ve optimizasyon fonksiyonlarına göre performans metrikleri açısından karşılaştırılmıştır. V. bölümde çalışmamızın çıkan sonuçları değerlendirilmiş ve sınırlamaları tartışılmıştır. Son olarak VI. bölümünde sonuç kısmı ve gelecekte yapılması planlananlar anlatılmaktadır.

## II. Literatür

3B nesne sınıflandırması, bilgisayarla görü alanında popüler olan araştırma konularındandır. Geleneksel 3B veri analizi ve işleme yöntemleri, ağırlıklı olarak manuel işlemler gerektirir. Bu durum yüksek seviyeli anlamsak özellik çıkarmada ve yüksek sınıflandırma performanslarının elde edilmesinde zorluklara neden olur. Bunun için görüntü öznetelik çıkarmadaki başarısı, basitliği ve esnekliği nedeniyle farklı 3B veri temsilleri ile çalışmalar yapılmaktadır. Nokta bulutu da nesnelere geometrisinden yararlanan popüler 3B veri temsillerinden biridir. Nokta bulutları, noktaların bazı istatistiksel bilgilerini şifrelemek için nokta özellikleri olarak kullanılır. Çoğunlukla içsel ve dışsal olarak sınıflandırılırlar. Vinyals ve diğerleri çalışmasında, nokta bulutları farklı boyutlarda kümelerin bir kombinasyonu olarak kullanılmıştır. Bu yöntemde, temel bir model öğrenirken, girdi / çıktı verilerinin düzenlendiği sıraların önemli olduğunu göstermişlerdir [8]. Ravanbakhsh ve diğerleri çalışmasında yapı setleri ile derin öğrenme için basit bir permütasyon eşdeğer katmanı tanıtmıştır. Katmanlar parametrik paylaşım ile elde edilir ve her setin boyutunda doğrusal bir zaman karmaşıklığına sahiptir. Nokta bulutu sınıflandırması ve MNIST-rakam toplamı yapmak için derin permütasyon değişmez ağlarını başarıyla kullanırlar. Her bir kümenin boyutunda ağlarının doğrusal bir zaman karmaşıklığına sahip olmasına ve nispeten basit olmasına rağmen, ağır ModelNet veri seti üzerindeki performansı düşüktür [9]. Zaheer ve diğerleri çalışması veri setleri üzerinde çalışan ve hem denetimli hem de denetimsiz görevlerde farklı senaryolarda kullanılabilen DeepSet'i önermiştir. Yöntemlerinin uygulanabilirliği, popülasyon tahmini, küme genişletme, aykırı değer tespiti ve nokta bulutu sınıflandırması üzerinde gösterildi [10]. Qi ve diğerleri çalışmasında, sırasız nokta bulutlarını kullanan ve voksel ızgaralarından daha az bellek

gereksinimi duyan ve 2D görüntü temsillerinden olası bilgi kaybıyla uçtan uca sınıflandırmalar sağlayan bir ağ mimarisi olan PointNet'i önermişlerdir [1]. PointNet, diğer yöntemlerle yaygın olarak kullanılan özellikleri çıkarmak için evrişim işlemlerini kullanmaz. Bunun yerine Öklid uzayındaki her noktayı temsil etmek için tam bağlantılı katmanlar kullanır. Özellikleri oluşturmak için Çok Katmanlı Algılayıcıları (MLP) kullanırlar ve bunları sonra maksimum havuzlama ve simetrik tek fonksiyon kullanarak birleştirirler. PointNet'in en büyük zorluğu, metrik uzay tarafından kullanılan noktaların neden olduğu yerel yapıları yakalayamamasıdır. Başka bir çalışmada, özelliklerin çoklu çözünürlüklü bir hiyerarşi aracılığıyla giderek daha büyük bir ölçekte yakalandığı 2D-CNN fikrini kullanan hiyerarşik bir sinir ağı olan PointNet++ önerilmiştir [2]. Bu ağ daha fazla özellik yakalamasına rağmen, çok karmaşık ve hesaplama hızı çok düşüktür. Yine de ModelNet40 veri kümesindeki PointNet++ performansı %90,7'dir ki bu PointNet'ten %2,7 daha yüksektir ve aynı zamanda başarılıdır [11]. Yang ve diğerleri nokta bulutlarındaki denetimsiz öğrenme sorunlarını giderebilmek için yeni bir uçtan uca derin otomatik kodlayıcı FoldingNet ağını önermiştir. Önerdikleri ağ, PointNet'in üzerinde yerel yapılar oluşturmak için kodlayıcı üzerinde graf tabanlı bir uygulama kullanmış ve bir katlama kod çözümü ile kurallı bir 2B ızgara başarıyla deforme edilmiştir [12]. Ayrıca 3B sınıflandırma için kullanılan FoldingNet ile bir SVM de kullanmışlardır. Bu ağ, yüksek sınıflandırma doğruluğu elde eden ModelNet40 veri seti üzerinde iyi bir performans göstermiştir. Son çalışmalardan birinde, Li ve diğerleri, SoNet'i önermişlerdir [13]. Düzensiz nokta bulutlu permütasyon değişmez mimarisi için denetimsiz model kullanan SO-Net'in ana fikri, nokta bulutlarının uzamsal dağılımını modellemek için Kendi Kendini Düzenleyen Harita (SOM) oluşturmaktır. Ağ, girdi nokta bulutunu temsil etmektedir. SO-Net, her noktada ve SOM düğümlerinde hiyerarşik özellik çıkarımı gerçekleştirmek için SOM'u kullanarak tek bir özellik vektörü yardımıyla ModelNet üzerinde daha yüksek sınıflandırma doğruluğu göstermiştir.


3B dental modelde diş tipinin sınıflandırılması ile ilgili Miki ve diğerleri yaptıkları çalışmada diş röntgeni görüntülerini kullanarak diş dosyalama sürecini otomatik hale getirmişlerdir [14]. Bu çalışmada, dental koni ışınli bilgisayarlı tomografi (Cone Beam Computed Tomography- CBCT) görüntülerinde diş tiplerini sınıflandırmak için Derin Evrişimli Sinir Ağı (Deep Convolutional Neural Network- DCNN) uygulamasını kullanmışlardır. Tuzoff ve diğerleri yapmış oldukları çalışmada, panoramik radyograflardan diş tespiti ve numaralandırmayı otomatik olarak gerçekleştirmek için CNN'e dayalı çözüm önermişlerdir [15]. Sistemi eğitmek için yetişkinlerden rastgele seçilmiş 1352 panoramik radyografтан oluşan bir veri seti kullanmışlardır. Kullandıkları diş algılama modülü ile her dişin sınırlarını belirlemek için radyografıyı kullanmışlardır. Bu modül Faster R-CNN (Regions Based Convolutional Neural Network) mimarisine dayanmaktadır. [16]. Kumar ve diğerleri diş etlerini ve dişleri tek tek diş modellerinden ayırmak için en kısa yol arama algoritmasını (shortest path search algorithm) ve yüzey eğrilik alanını kullanmışlar [17]. Ancak bu yöntemin diş kaybı veya kayma durumları açısından uygun olmadığını ortaya koymuşlardır. Li ve Wang yaptıkları çalışmalarda ciddi derecede bozuk diş yapısına ve belirsiz diş sınırlarına sahip karmaşık diş modelleri için harmonik alanlara dayalı interaktif bir diş segmentasyon yöntemi önerdiler [18]. Lian ve diğerleri çalışmasında diş

yüzeylerinde otomatik diş etiketleme için MeshSegNet adı verilen uçtan uca bir derin öğrenme yöntemi önerdiler [19]. MeshSegNet mimarisi, IOS tarafından elde edilen üst çene modellerinden oluşan gerçek hasta veri seti kullanarak değerlendirilmiş ve oldukça başarılı sonuçlar elde etmişlerdir.

### III. MATERYEL VE YÖNTEM


#### A. Veri Seti ve Veri Ön İşleme

Üzerinde çalıştığımız veri seti, bir 3B ağız içi tarayıcıdan (örn. iTero Element®) 37 farklı denekten elde edilen 3B dental modellerdir. Bu modeller STL (Standart Triangle Language) dosya formatında ve etiketlenmemiş 3B üst çene modellerini içermektedir. STL dosya formatı 3B modellerin üçgenler ile tanımlanmasıdır. Bu üçgenlerin köseleri ve normalleri, modelin geometrisini kodlamak için dosyada saklanır. STL dosya formatının temel amacı bir 3B modelin renk, doku veya malzemeleri hakkında bilgisi olmadan sadece yüzey geometrisini kodlamaktır. Bu bilgiyi mozaikleme (tessellation) adı verilen veya mesh olarak da tanımlanan basit bir kavram kullanarak kodlar [20]. Veri setindeki modeller incelendiğinde bazılarının dişin tüm yapısını göremeyeceğimiz Şekil 1' deki gibi ısırma modelleri veya dişlerin olmadığı modeller olduğu görülmüştür. Bu yüzden bazı modeller üzerinde etiketleme zorluğu nedeniyle eliminasyon işlemi gerçekleştirilmiştir. Bu elemeler sonucunda elimizde sadece 10 adet 3B üst çene diş modeli kalmıştır.



Şekil 1 İsırma ve dişin olmadığı 3B modeller

Daha sonra elimizdeki 10 adet 3B dental modeller üzerinde MeshLabeler3 programıyla simetrik dişler etiketlenmiş ve damaktan ayrılmıştır. Etiketlendirme işlemi, deneyimli diş hekimleri gözetiminde manuel olarak yapılmıştır. Şekil 2' de etiketlenmiş üst çene diş modeli merkezi kesici (T1), yanal kesici (T2), köpek (T3), birinci küçük azı (T4), ikinci küçük azı (T5), birinci büyük azı (T6), ve ikinci büyük azı (T7), diş olarak etiketlenmiş hali görülmektedir.



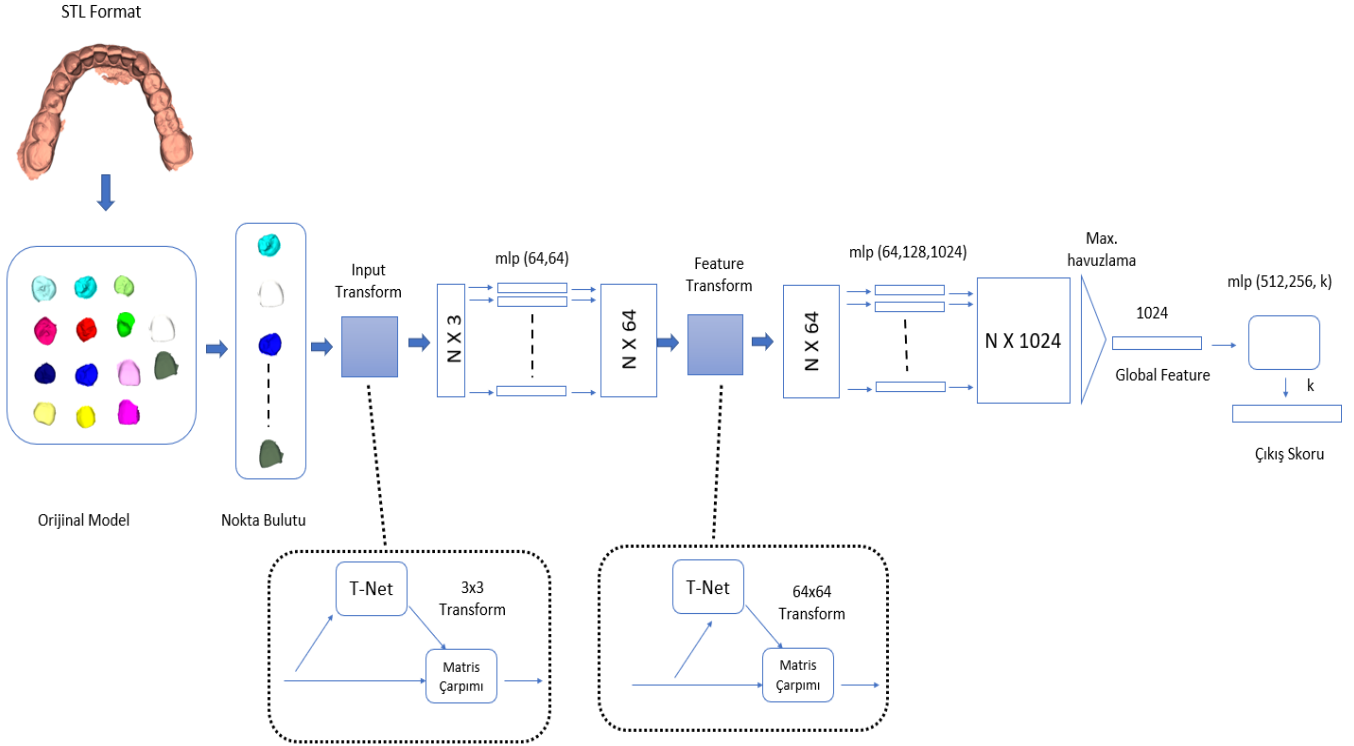
Şekil 2 Manuel olarak etiketlenmiş 3B dental model

Veri kümesinde yer alan toplam 10 adet 3B dental modelimizden her bir diş için damaktan ayrımı yapıldığında toplam 140 adet (elimizdeki her üst çenede 14 adet diş olduğundan) bireysel dişler oluşturulmuştur. Daha sonra 140 adet diş veri setimiz eğitim ve test için yetersiz olduğundan veri artırımı gerçekleştirilmiştir. Veri artırımı işlemi için her bir

diş x, y, z eksenlerinde rastgele açılarla döndürülerek her bir diş için 9 tane sanal veri artırımı işlemi gerçekleştirilmiştir. Sonuç olarak elimizde 140 gerçek ve 1260 sanal olmak üzere toplam 1400 adet diş modelinden oluşan veri seti oluşturulmuştur. Modelin eğitimi için her bir veri kümesi %70 eğitim ve %30 test olarak ayrılmıştır. Veri setimizin dağılımı özet olarak Tablo 1’de görülmektedir.

Tablo 1. Veri Seti Özet Tablosu

	Eğitim	Test
SANAL	882	378
GERÇEK	98	42
TOPLAM	980	420



Şekil 3. Nokta bulutu modeli

### B. Diş Tipi Sınıflandırma

3B veri temsillerinden olan nokta bulutu veri gösterimi ile IOS'lardan elde edilen 3B diş modellerinin PointNet modeli kullanılarak sınıflandırılması gerçekleştirilmiştir. Modelin genel yapısı Şekil 3’de gösterilmiştir. Bu modelde 3B üst çene dental modellerinden elde edilen dişler merkezi kesici, yan kesici, köpek, birinci küçük azı, ikinci küçük azı, birinci büyük azı ve ikinci büyük azı diş olarak sınıflandırılır. Üçüncü büyük azı dişlerinin az sayıda numune sebebiyle diş sınıflandırma çalışmalarından hariç tutulmuştur. Diş bu şekilde kategori edildiğinde toplam yedi sınıf oluşmaktadır. Her bir kategori için 140 adet eğitim ve 60 adet test kümesi olacak şekilde ayrılmıştır. Toplam eğitim veri setimiz 980, test veri setimiz ise 420 addir. Modelin eğitim aşamasında iyileştirmeler yapılabilmesi için eğitim veri seti %80’i eğitim ve %20’ si validasyon olacak şekilde rastgele ayrılmıştır.

Verilerin ön işleme aşamasında 3B dental modellerden elde edilen bireysel dişler nokta bulutuna dönüştürülür. Oluşturulan dişler üç boyutlu (x, y, z) uzayda noktalar halinde temsil edilir ve N x 3 boyutlarında giriş verisi elde edilir. Daha sonra bu giriş verisi PointNet mimarisinin sınıflandırma modeli kullanılarak sınıflandırma gerçekleştirilir. PointNet mimarisi Qi ve diğerleri tarafından önerilen mimaridir [1]. PointNet sırasız nokta bulutlarını kullanan ve uçtan uca sınıflandırmalar sağlayan bir ağ mimarisidir. PointNet, diğer yöntemlerle yaygın olarak kullanılan özellikleri çıkarmak için evrişim

işlemlerini kullanmaz. Bunun yerine Öklid uzayındaki her noktayı temsil etmek için tam bağlantılı katmanlar kullanır. Özellikleri oluşturmak için Çok Katmanlı Algılayıcılar (MLP) kullanılır. Bunları sonra maksimum havuzlama ve simetrik tek fonksiyon kullanarak birleştirirler.

### IV. BULGULAR


Çalışmamız 3B dental modellerden elde edilen bireysel dişleri temsil için 512, 1024, 2048 nokta sayısı kullanılmış ve boyutların sınıflandırma performanslarına etkisi incelenmiştir. Nokta bulutu çalışmasında ise PointNet mimarisi kullanılmıştır. PointNet mimarisindeki parametreler değiştirilmemiştir. 3B CNN modelini ve PointNet mimarisini eğitmek için Adam, AdaDelta ve SGD (Stochastic Gradient Descent) olmak üzere üç farklı optimizasyon algoritmaları kullanılmıştır. Ayrıca aynı anda işlenen görüntü sayısı (batch size) değeri 32, epoch değerleri 100 ve öğrenme katsayısı her optimizasyon fonksiyonları için 0.001 olacak şekilde oluşturulmuştur. Çalışmada ve seçilen nokta sayılarının ve optimizasyon fonksiyonlarının modele olan etkisini inceleyebilmek için nokta sayılarını kademeli olarak artırıp farklı optimizasyon fonksiyonları denenmiştir.

Çıkan sonuçlar Tablo 2’de PointNet mimarisi ile farklı nokta sayılarıyla ve optimizasyon fonksiyonlarına göre sınıflandırma performanslarının özeti oluşturulmuştur. Kullanılan Adam, AdaDelta ve SGD optimizasyon fonksiyonları için öğrenme oranı 0.001 olarak belirtilmiştir.

Bireysel olarak dişlerin, tüm nokta sayıları için modelin ürettiği en iyi sonucun Adam optimizasyon fonksiyonu olduğu hesaplanmıştır. Adam fonksiyonundan sonra en iyi sonuçların sırasıyla SGD ve AdaDelta optimizasyon fonksiyonları izlenmektedir. Yine aynı şekilde en iyi sonucun Adam fonksiyonuna ait olmasına rağmen aralarında çok büyük farkların olmadığı görülmektedir. Sonuçlar incelendiğinde 512 nokta sayısında en iyi sonucun doğruluk %48, keskinlik %49, duyarlılık %48, ve F1-skor%48; 1024 nokta sayısında en iyi sonucun doğruluk %52, keskinlik %52, duyarlılık %52 ve F1-skor %51; 2048 nokta sayısında en iyi sonucun doğruluk %55, keskinlik %55, duyarlılık %55 ve F1-skor %54 tüm optimizasyon fonksiyonları ve sınıflandırma metrikleri için

sonuçlarda iyileşme olduğu anlaşılmaktadır. Buna göre en iyi sonucun 2024 nokta sayısında olduğu görülmektedir. En iyi sonucun 2048 nokta sayısında Adam optimizasyon fonksiyonuna ait model doğruluğu ve eğitim kayıp grafiği Şekil 4' te gösterilmiştir.

Çıkan sonuçlar değerlendirildiğinde, 3B dişlerin nokta bulutu ile başarılı bir şekilde sınıflandırıldığını söylemek zordur. Her ne kadar nokta sayıları artırıldığında performans metrikleri artmasına rağmen, sonuçlar diğer çalışmaya göre kötüdür. Dişlerin etiketlenme süreçlerinin manuel olması sebebiyle etiketlenmenin efektif bir şekilde yapılamaması ve yetersiz veriye sahip olunması sınıflandırma performansı düşüren etkenlerdendir.



Şekil 4. Nokta Bulutu modeli performans grafikleri a) model doğruluğu grafiği b) eğitim kayıp grafiği

Tablo 2. Nokta bulutu çalışması performans tablosu

Hacim	Opt. Fonk.	Doğruluk	Keskinlik	Duyarlılık	F1- Skor
512	Adam	<b>0,48</b>	<b>0,49</b>	<b>0,48</b>	<b>0,48</b>
	AdaDelta	0,41	0,44	0,41	0,40
	SGD	0,47	0,47	0,47	0,47
1024	Adam	<b>0,52</b>	<b>0,52</b>	<b>0,52</b>	<b>0,51</b>
	AdaDelta	0,43	0,47	0,43	0,42
	SGD	0,49	0,50	0,49	0,49
2048	Adam	<b>0,55</b>	<b>0,55</b>	<b>0,55</b>	<b>0,54</b>
	AdaDelta	0,46	0,50	0,46	0,45
	SGD	0,53	0,53	0,53	0,52

## V. TARTIŞMA

Bu makalede ağız içi tarayıcılar tarafından (IOS) elde edilen 3B diş modellerini nokta bulutu yapılarına dönüştürerek dişlerin bireysel olarak sınıflandırılması amaçlanmıştır. Diş sınıflandırılması için literatüre bakıldığında derin öğrenme modelleri kullanarak bireysel diş tanımlama, diş segmentasyonu veya dişlerin sınıflandırma alanlarında

çalışmalar yapıldığı görülmektedir. Ancak buradaki çalışmalar 3B diş modellerini, dişlerin birbirleriyle olan komşuluklarını ve dişin damaktaki pozisyon bilgilerini koruyarak yaptıkları çalışmalarıdır. Bu çalışmaların yanı sıra 3B farklı veri temsilleri kullanarak nesne sınıflandırması çalışmaları oldukça fazladır ve bu çalışmalara bakıldığında halka açık veri setleri ile nesne tanıma (object recognition), sınıflandırma (object classification) gibi 3B şekil analizleri görevlerinde iyi sonuçlar

elde eden modeller geliştirilmiştir. Bu çalışma kapsamında ağız içi tarayıcılarından elde edilen 3B üst çene diş modelleri kullanılmıştır. Model eğitiminden önce veriler incelediğimizde bazı 3B modellerin ısırma modeli veya dişlerin olmadığı modeller görülmüştür. Bu sebeple bu tür modeller elenerek veri seti sadeleştirilmiştir. Bu elemeler sonucunda modelimizde kullanacağımız 10 adet diş modeli belirlenmiştir. Daha sonra bu modeller MeshLabeler3 yazılımı kullanılarak 140 adet bireysel diş modeli elde edilmiştir. Veri artırma yöntemiyle 140 adet diş 1400 'e çıkarılarak dişlerin geometrik temsili için 3 farklı nokta sayılarına dönüştürülmüştür. Son olarak veri seti rastgele olacak şekilde %70 'i eğitim ve %30 'u test olarak ayrılmıştır. Oluşturulan veri setimizin son hali Tablo 1' de özetlenmiştir. Daha sonra nokta bulutu tabanlı sınıflandırma çalışmalarımızda bireysel dişlerin nokta bulutu boyutları artırıldığında diş sınıflandırması üzerine etkisini incelemek adına farklı boyutlar üzerinde çalışılmıştır. Çalışmalarımızda Adam, AdaDelta ve SGD olmak üzere 3 farklı optimizasyon fonksiyonu kullanılarak optimizasyon fonksiyonlarının performans metriklerine göre karşılaştırılması yapılmıştır. Nokta bulutu tabanlı çalışmamız için 3 farklı nokta sayısı 3 farklı optimizasyon fonksiyonu ve sınıflandırma metrikleri ile toplam 36 adet sonuç ortaya çıkmıştır. Ortaya çıkan sonuçlar Tablo 2' de özetlenmiştir. Sonuçlar değerlendirildiğinde nokta sayısı kademeli olarak artırıldığında tüm optimizasyon fonksiyonları ve sınıflandırma metrikleri için sonuçlarda iyileşme olduğu anlaşılmaktadır. Ancak dişlerin manuel olarak etiketlememiz, kullanılan programların yetersizliği, deneyim eksikliği ve etiketleme işleminin zorlu bir süreç olması sebebi gibi nedenler sınıflandırma performansını olumsuz etkilemesinin temel nedenleridir. Dişler arasında benzerlikler olmasına rağmen dişlerin aynı olmaması, nokta veri temsiliyle dişlerin arasındaki küçük farkları ayırt etmede yetersiz olduğunu ortaya çıkarmıştır.

## VI. SONUÇ

Sonuç olarak, elde edilen başarımların değerleri incelendiğinde, nokta bulutu tabanlı çalışmalar nesneyi temsil eden nokta sayıları artırıldığında performans metriklerinin arttığı görülmektedir. Ancak dişlerin başarılı bir şekilde sınıflandırıldığını söylemek zordur. Buna ilave olarak başarısız sayılabilecek sınıflandırma performanslarına bakıldığında, bellek hatası problemlerinden kaçınmak için çok yüksek boyutlarda işlem yapılamaması ve komşu dişlerin benzer görünüşleri olması sebebiyle dişler arasındaki komşuluk ilişki bilgisinin kullanılmasının önemini ortaya çıkarmıştır. Ayrıca 3B bireysel diş modellerinin sadece Öklid uzayında noktalar ile diş sınıflandırma yetersiz olduğu ve diş tanımlayan farklı bilgilere de ihtiyaç olduğu anlaşılmıştır. Nokta bulutu tabanlı çalışma için en iyi sonucun 2048 nokta sayısında olduğu anlaşılmıştır. Ayrıca nokta sayıları artırıldığında modelin sınıflandırma başarısına olumlu etki ettiği belirlenmiş ve en iyi optimizasyon fonksiyonunun Adam fonksiyonu olduğu anlaşılmıştır.

İleri çalışmalar için farklı 3B veri temsilleri ile sınıflandırma yapılması ve ayrıca daha fazla veri artırımı yapılarak 3B temsiller açısından sınıflandırma başarımlarının incelenmesi düşünülmektedir. Bununla birlikte farklı 3B veri temsilleri ile 3B dental modeller doğrudan kullanılarak dişlerin sınıflandırılması ve segmentasyon çalışması yapılması planlanmaktadır.

## REFERENCES

- [1] R. Q. Charles, H. Su, M. Kaichun, and L. J. Guibas, "PointNet: Deep learning on point sets for 3D classification and segmentation," in Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR), Jan. 2017, pp. 77–85.
- [2] C. Qi, L. Yi, H. Su, and L. Guibas, "PointNet++: Deep hierarchical feature learning on point sets in a metric space," in Proc. Adv. Neural Inf. Process. Syst., Dec. 2017, pp. 5100–5109.
- [3] P. Papadakis, I. Pratikakis, S. Perantonis, and T. Theoharis, "Efficient 3D shape matching and retrieval using a concrete radialized spherical projection representation," Pattern Recognit., vol. 40, no. 9, pp. 2437–2452, Sep. 2007.
- [4] Q. Huang, Y. Wang, and Z. Yin, "View-based weight network for 3D object recognition," Image Vis. Comput., vol. 93, Jan. 2020, Art. no. 103828.
- [5] Poonsri, A., Aimjirakul, N., Charoenpong, T., & Sukjamsri, C. (2016). Teeth segmentation from dental x-ray image by template matching. 2016 9th Biomedical Engineering International Conference (BMEiCON), 1-4.
- [6] Tian, S., Dai, N., Zhang, B., Yuan, F., Yu, Q., & Cheng, X. (2019). Automatic Classification and Segmentation of Teeth on 3D Dental Model Using Hierarchical Deep Learning Networks. IEEE Access, 7, 84817-84828.
- [7] Xu, X., Liu, C., & Zheng, Y. (2019). 3D Tooth Segmentation and Labeling Using Deep Convolutional Neural Networks. IEEE Transactions on Visualization and Computer Graphics, 25, 2336-2348.
- [8] O. Vinyals, S. Bengio, and M. Kudlur, "Order matters: Sequence to sequence for sets," 2015, arXiv:1511.06391. [Online]. Available: <http://arxiv.org/abs/1511.06391>
- [9] S. Ravanbakhsh, J. Schneider, and B. Poczos, "Deep learning with sets and point clouds," 2016, arXiv:1611.04500.
- [10] M. Zaheer, S. Kottur, S. Ravanbakhsh, B. Poczos, R. R. Salakhutdinov, and A. J. Smola, "Deep sets," in Proc. Adv. Neural Inf. Process. Syst., Dec. 2017, pp. 3392–3402.
- [11] P. Daras and A. Axenopoulos, "A 3D shape retrieval framework supporting multimodal queries," Int. J. Comput. Vis., vol. 89, nos. 2–3, pp. 229–247, Sep. 2010.
- [12] Y. Yang, C. Feng, Y. Shen, and D. Tian, "FoldingNet: Point cloud autoencoder via deep grid deformation," in Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit., Jun. 2018, pp. 206–215.
- [13] J. Li, B. M. Chen, and G. H. Lee, "SO-net: Self-organizing network for point cloud analysis," in Proc. IEEE/CVF Conf. Comput. Vis. Pattern Recognit., Salt Lake City, UT, USA, Jun. 2018, pp. 9397–9406.
- [14] Miki, Y., Muramatsu, C., Hayashi, T., Zhou, X., Hara, T. Katsumata, A. & Fujita, H. (2017). Classification of teeth in cone-beam ct using deep convolutional neural network. In Computers in biology & medicine, vol. 80, pp. 24–29
- [15] Tuzoff, D. V., Tuzova, L. N., Bornstein, M. M., Krasnov, A. S., Kharchenko, M. A., Nikolenko, S. I., Sveshnikov, M. M. Bednenko, & G. B. (2019). Tooth detection & numbering in panoramic radiographs using convolutional neural networks. In Dentomaxillofacial Radiology, vol. 48, no. 4, p. 20180051
- [16] Wu, K., Chen, L., Li, J. & Zhou, Y. (2014). Tooth segmentation on dental meshes using morphologic skeleton. In Comput. Graph., vol. 38, no. 1, pp. 199–211
- [17] Kumar, Y., Janardan, R., Larson, B. & Moon, J. (2011). Improved segmentation of teeth in dental models. In Comput.-Aided Des. Appl., vol. 8, no. 2, pp. 211–224
- [18] Li, Z. & Wang, H. (2016). Interactive tooth separation from dental model using segmentation field. In PLoS ONE, vol. 11, no. 8, Art. no. e0161159.
- [19] Lian, C., Wang, L., Wu, T., Liu, M., Durán, F., Ko, C., & Shen, D. (2019). MeshSNet: Deep Multi-scale Mesh Feature Learning for End-to-End Tooth Labeling on 3D Dental Surfaces. MICCAI.
- [20] Ibáñez, L. (2014). STL file format MeshIO class for ITK. The Insight Journal.