

BÖLÜM 8

ORTODONTİDE YAPAY ZEKA VE DİJİTAL TEDAVİLER

Esra GENÇ¹

GİRİŞ

Yapay zeka (AI), genel olarak “bir sistemin dış verileri doğru şekilde yorumlama, bu verilerden öğrenme ve bu öğrenimleri esnek uyarlama yoluyla belirli hedeflere ve görevlere ulaşmak için kullanma yeteneği” olarak tanımlanır (1). AI temelinde, toplanan devasa veri kümelerini makinelerin öğrenim algoritmasını eğitmekte kullanmak yatar. Böylece giderek daha verimli programlar elde edilir. Büyük veri artışına bağlı olarak bilgisayar gücündeki çarpıcı artış, yapay zeka uygulamalarını çok daha yeni alanlara yönlendirmiştir. Evrişimli sinir ağları gibi onlarca yıl önce geliştirilen makine öğrenimi teknikleri, sonunda çok çeşitli alanlarda uygulamalar bulmuştur. Günümüzde yapay zeka araştırmaları matematik, bilgisayar bilimleri ve bilişsel bilim gibi çeşitli uzmanlık alanlarını içermektedir (2).

Günlük yaşamın bir parçası olan yapay zeka uygulamalarının çok çeşitli örneklerini birçok alanda olduğu gibi sağlık alanında da görmek mümkündür. Yapay zekanın bu konudaki en büyük üstünlüğü, makinelerin binlerce vaka ile eğitilebilmesi ve sağlık verilerinin her bir birey için oldukça kompleks ve multidisipliner olduğu bu zamanda kişiselleştirilmiş sağlık hizmeti için iyi bir avantaj sağlamasıdır. Bununla birlikte değişimin artan ivmesi ileri zamanlarda doktorların yerini makinelerin alabileceği gibi bir endişeyi ortaya çıkarsa da şuan için teşhis ve tedavi açısından oldukça yararlı bir işbirlikçi olduğu da oldukça açıktır (2).

Diş hekimliği de diğer pek çok sağlık alanında olduğu gibi, tedavi standartlarını yükseltmek için teknolojiyi kullanarak daha yüksek kaliteli teşhis ve terapötiklerin avantajının sağlandığı dijital bir yaklaşıma doğru ilerlemektedir (3). Diş hekimliğinde dijitalleşme son 10-20 yılda önemli ölçüde artmıştır. Dijital görüntüleme ve 3D görüntüleme rekonstrüksiyonu, tıp ve diş hekimliği alanlarındaki çeşitli disiplinlerde ve uygulamalarda hem teşhis hem de tedavi planlamasında her zamankinden daha büyük bir rol oynamaktadır (4,5).

¹ Dt., Ortodonti Uzmanı, Özel Klinik, dtegencc@gmail.com

Teşhis sürecini daha doğru ve verimli hale getirmek için, ortodontide yapay zekanın kullanımı son yıllarda önemli ölçüde artmıştır. Bununla birlikte, sağlık profesyonellerinin, uzmanlık eğitimi ve yılların deneyimiyle kazandıkları kendi bilgileriyle eninde sonunda teşhis ve en iyi tedavi planını belirlemesi gereken kişiler olduğu gerçeğini değiştirmez. Yine de yapay zeka, sınırlı bir süre içinde belirli klinik kararlar verirken faydalı olabilir. Yapay zeka uygulamaları, klinisyenleri daha iyi kararlar almaları ve daha iyi performans göstermeleri için yönlendirebilir, çünkü yapay zekadan elde edilen sonuçlar son derece doğrudur ve bu nedenle bazı durumlarda insan hatalarını önleyebilir (6).

Konik ışınlı bilgisayarlı tomografi (CBCT) ve 3D görselleştirmeler, ağız içi tarayıcılar, yüz tarayıcıları, dental modelleme yazılımı ve robotik ve 3D baskı kullanan yeni cihaz geliştirmeleri dahil olmak üzere ortodonti alanındaki son teknolojik yenilikler ortodontik tedaviye hızla entegre olmaktadır (7). Bu araçlar hastanın anatomisinin daha iyi anlaşılmasını sağlar ve spesifik hasta için dinamik anatomik rekonstrüksiyonlar oluşturabilir ve bu nedenle 3D tedavi planlamasında oldukça kullanışlı olabilir. Evrişimli sinir ağları (CNN), tıbbi görüntü teşhisi için, çoğunlukla anatomik yapıların tespiti, segmentasyonu veya sınıflandırılması için giderek daha fazla uygulanmaktadır. Derin öğrenme, son zamanlarda geometrik özellik öğrenme ve sınıflandırma için de kullanılmaktadır (8). Genetik, teknoloji, yapay zeka ve kraniyofasiyal ortopedi ile ilgili araştırmalar, tedavileri kişiselleştirmek ve ortodontiyi daha verimli ve etkili hale getirmek için büyük fırsatlar sunmaktadır (9). Yapay zekanın ortodontik teşhis ve tedavilerde edinmeye başladığı yer bugün literatürde birçok çalışmaya araştırma konusu olmuştur (10-14). Bu makale, yapay zeka ve dijital uygulamaların ortodontik teşhis ve tedavi uygulamalarındaki yeri hakkında bilgi vermek amacıyla hazırlanmıştır.

ORTODONTİK UYGULAMALARDA AI

Yapay zeka ve dijital girişimlerin ortodontik tedavilerde kullanım alanları (15,16):

- Nöral network (NN) makine öğrenimi ile ekstraksiyonların teşhisi
- Ortodontik diş çekimi kararlarının hesaplamalı formülasyonu
- Otomatik sefalometrik film analizleri
- Sürmemiş kanin ve premolar dişlerinin boyutlarını tahmin etmek için hibrit bir genetik algoritma (GA) ve yapay nöral network (ANN) sisteminin tasarımı ve uygulanması
- Ortodontik tedaviden önce çekimlerin gerekli olup olmadığına karar vermek için ANN modellemesi
- Gömülü maksiller kaninlere klinik yaklaşımı etkileyen faktörler
- Sefalometrik tanıda yardımcı olarak ANN

- İskelet sınıfı I, II ve III de mandibular morfolojiyi tahmin etmek için otomatik öğrenme tekniklerinin kullanımı
- Ortognatik cerrahi vakaları için hasta seçimi,
- Büyüme ve gelişimin belirlenmesi ve iskelet olgunlaşma evrelerinin tahmini, pubertal gelişimin zamanının tahmini
- Kraniomaksiller değişkenleri kullanan iskelet paternleri sınıflandırması için otomatik bir yöntem

ORTODONTİK TEDAVİ PLANLAMASINDA ÇEKİM GEREKLİLİĞİ DEĞERLENDİRMESİNDE AI

Doğru teşhis, tedavi planlaması ve prognoz tahmini, başarılı ortodontik tedavi için kilit faktörlerdir. Araştırmacılar bazı tahmin yöntemlerini kullanarak ortodontik tedavi planlama işlemlerini daha objektif hale getirmeye çalışmışlardır. Yapay sinir ağı (ANN), son on yılda hızla ilerlemiş olup bugün ortodontik tedavi planlamasında diş çekiminin gerekli olup olmadığına belirlenmesinde faydalı olmaktadır (17). Xie ve ark. (18) tarafından yapılan bir çalışmada, lateral sefalometrik radyograflar kullanılarak çekimin gerekli olup olmadığına karar vermek için yapay sinir ağı (ANN) modeli uygulanmıştır. Jung ve ark. (19), lateral sefalometrik radyografiler kullanarak kalıcı diş çekimine karar vermek için AI uzman sistemini kullanarak %92 doğruluk bildirdiler. Her iki çalışmanın sonuçları, AI modellerinin ekstraksiyon ihtiyacını tahmin etmede etkili ve doğru olduğunu düşündürmektedir. Bu modeller, klinik uygulamada karar vermek için bir araç olarak kullanılabilir. Ortodontik tedavi ihtiyacını değerlendirmek için Bayes ağına (BN) dayalı AI modeli öneren Thanathornwong (20) tarafından yapılan çalışmada yüksek doğruluk görülmüştür. Li ve ark (21) katmanlı algılayıcı ANN kullanarak ortodontik tedavi planlamasını, çekim gerekliliğini, çekim ve ankraj paternini öngörmeye çalıştıkları çalışmalarında nöral network modelin çekim gerekliliği tahmininde %94, çekim paterni ve ankraj paterninde ise sırayla %84 ve %92 doğruluk gösterdiğini bildirmişlerdir. Ayrıca nöral network tahmini için en önemli özelliklerin çapraşıklık, maksiller ark, ANB ve spee eğrisi olduğu bildirilmiştir. Xie ve ark (18)'nin çalışmasında ise ilk dikkate alınması gereken özellikler inkompetent dudaklar tarafından desteklenmeyen anterior dişler ile IMPA değerleridir.

ORTODONTİK ARK TELİNİ BÜKMEK İÇİN ROBOTİK SİSTEM

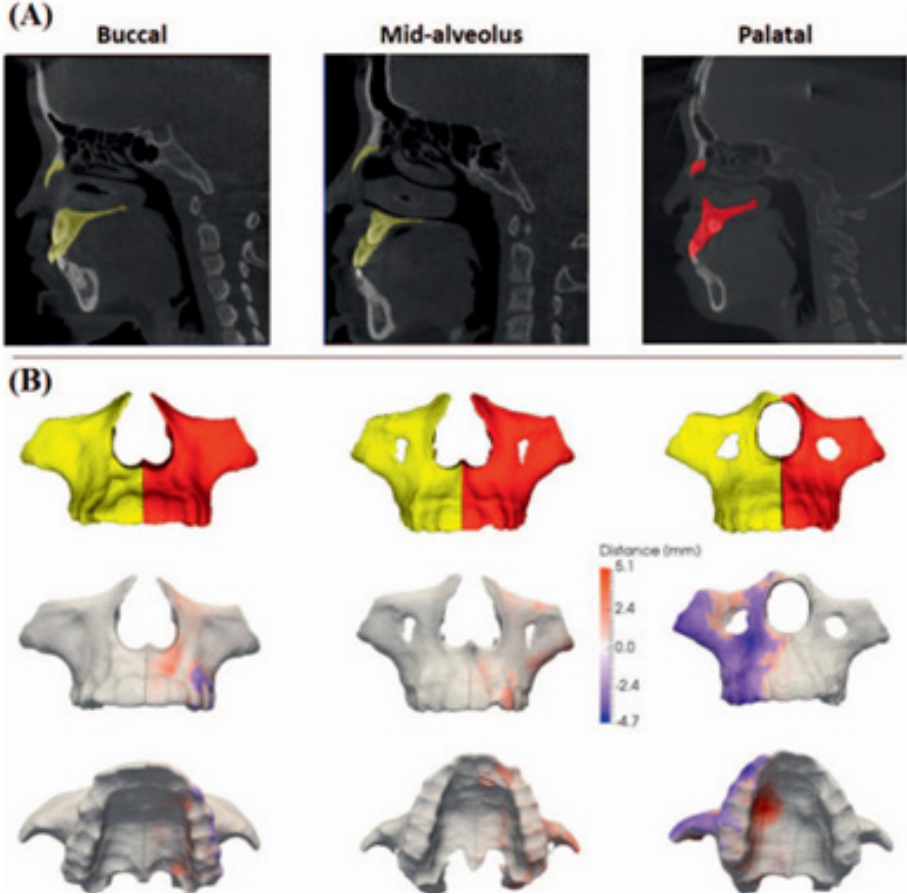
Ortodontik ark telinin bükümü için çeşitli robotik sistemler geliştirilmiştir. Bunlardan biri olan SureSmile ortodontik ark teli büküm robotu, masaya veya taban destek yüzeyine monte edilmiş bir robottan oluşur (22). Bir kavrama aracı tarafından ark teli veya diğer tıbbi cihazlar sıkıca tutulur ya da kola entegre edilir.

İkinci bir kavrama aracı hareketli robotik kolun çevresine, ayrıca tabana monte edilmiş bir proksimal parçanın yanı sıra, hareketsiz kavrama aracına göre 3 dönme ve 3 öteleme eksenini etrafında dönebilen bir uzak uca monte edilir. Kavrama aletlerine dahil edilen kuvvet sensörleri, ark telinin nihai morfolojisini elde etmek için gereken aşırı bükülmeleri tanımlamak için kullanılır ve ayrıca elektriğin tel üzerinden geçtiği bir ısıtma sistemine de sahip olabilir. SureSmile cihazı, tedaviyi teşhis etmek ve planlamak için çağdaş 3D bilgisayar ve görüntüleme tekniklerini kullanır ve sabit ortodontik cihazları kişiselleştirmek için robotik sistemi kullanır. Öngörülü olarak tedavi simüle edilerek detaylı tedavi planlaması yapılabilir. CAD/CAM kullanmanın temel amacı, ortodontik tedavinin kalitesini, verimliliğini ve tekrarlanabilirliğini geliştirmektir (23). Gilbert, ark telinin hızlı ve doğru bükülmesi için LAMDA'yı (lingual ark teli üretimi ve tasarım yardımı) tanıttı. Bu sistem ile sadece xy düzlemindeki hareket gerçekleştirilebilir, bu nedenle closed looplu ark teli bükemez (24). Bir başka robotik ark teli büküm sistemi, MOTOMAN UP6 sistemidir (25). Ark telinin kenetlenmesi ve bükülmesi, MOTOMAN robot ucuna takılan ark teli bükme aktüatörü tarafından yapılır. Ark telinin bükülme özellikleri, robotun kinematığı, açılı optimizasyonu ve ark telinin bükülme noktasının konumu incelenir ve simüle edilir. Solidworks yazılımının kullanıldığı Cartesian tip robotik ark teli büküm sistemi ise 3. düzen saf büküm robotu olan hassas kontrole sahiptir (26,27).

GÖMÜLÜ MAKSİLLER KANİN CBCT'LERİNİN DEĞERLENDİRİLMESİNDE AI

Maksiller kaninler, mandibular üçüncü molarlardan sonra en sık gömülü kalan dişlerdir (28). Kesin etiyojoloji bilinmemekle birlikte, lokalize, sistemik veya genetik etiyojolojik faktörlerin maksiller kanin gömüklüğüne katkıda bulunduğu öne sürülmüştür (29). Bununla birlikte literatüre bakıldığında çok sayıda çalışmanın maksillanın anatomik yapısı ve boyutlarının etiyojolojik sebeple ilişkisi olup olmadığını araştırdığı görülür (30,31). Chen ve ark. (32) tek taraflı gömülü maksiller kanine sahip bireylerin maksiller yapılarını değerlendirmek için CBCT görüntülerinde 3 boyutlu otomatik segmentasyon ve otomatik Landmark belirleyici bir machine learning metodu geliştirmişlerdir. Bunun için gömülü maksiller kanine sahip hastaların CBCT görüntüleriyle birlikte öğrenme tabanlı çok kaynaklı Segmentasyon Entegrasyon çerçevesini (LINKS) kullanan bir makine öğrenimi algoritması kullanmışlardır. 2016 yılında Wang ve arkadaşlarının (33) geliştirdiği gelişmiş makine öğrenimi görüntüleme tekniklerine dayanan LINKS, maksillayı otomatik segmentlere ayırmak için kullanıldı. Segmentlere ayrılan sağ ve sol

maksiller parçalar sonrasında superimpozisyon ile hacim, derinlik, yükseklik ve genişlik gibi çeşitli açılardan karşılaştırılmıştır (Şekil 1). Bu hızlı ve verimli CBCT görüntü segmentasyonu, büyük klinik veri setlerinin etkin bir şekilde analiz edilmesini sağlayacaktır.



Şekil 1: (A) Maksilla için segmentasyon sonuçları. (B) Üç farklı gömüklük tipinin (bukkal, alveoler ve palatal) süperimpozisyon sonuçları, geometrik fark belirlemeye izin vererek gösterilmiştir (32).

DİJİTAL MODELLEME VE OTOMATİK LANDMARK BELİRLEME

Dijital ölçüler üretmek için yapılan optik tarama, geleneksel ölçülerle karşılaştırıldığında hasta için çok daha rahat olması, ölçülerin zamanla distorsiyona uğramaması, dijital ortamda iletilebilir olması gibi avantajları nedeniyle tercih sebebidir (3). Dijital modellerin önemli bir özelliği, bilgisayar manuplasyonuna izin verme-

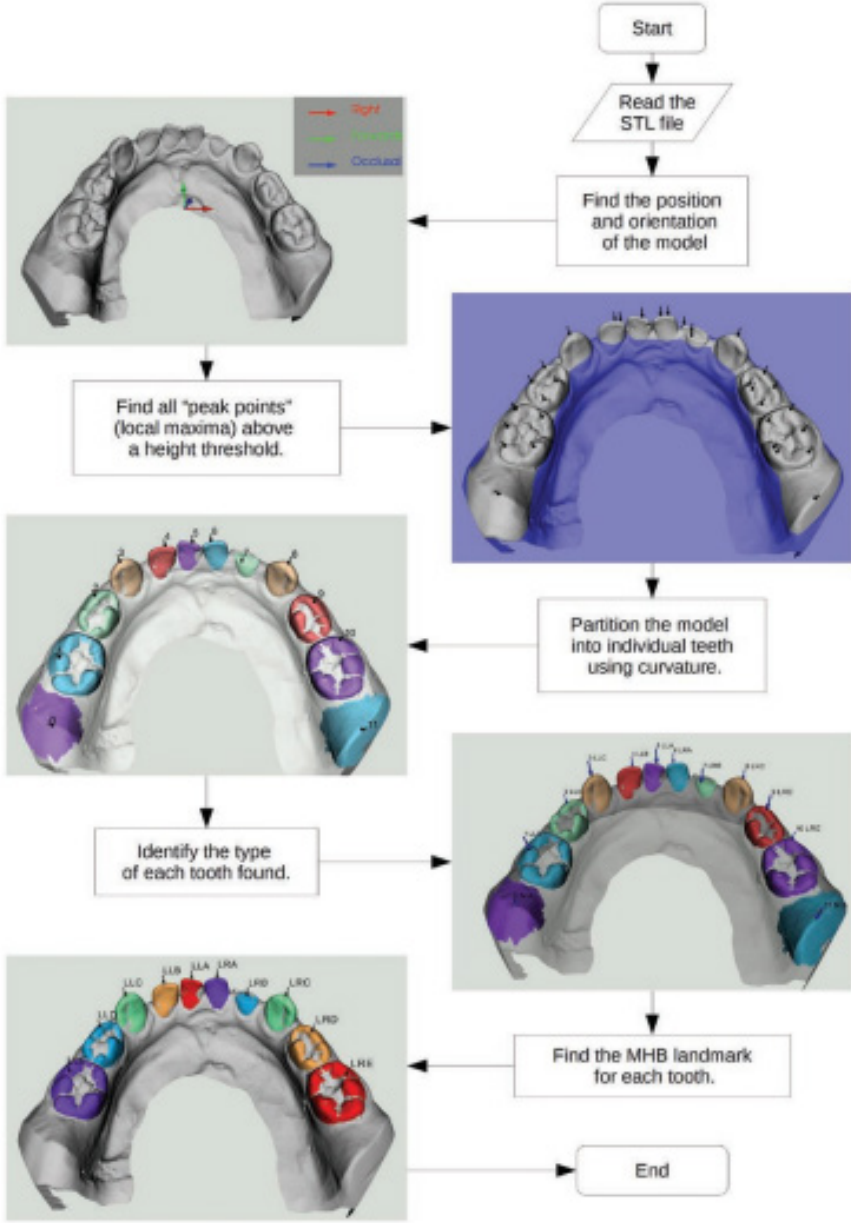
si ve daha objektif bir skorlamaya imkan sağlayan otomatik veri analizi tekniklerini içermeleridir.

Otomatik skorlama yazılımında doğru landmark tanımı büyük önem taşır. Birçok avantajına rağmen veri yakalama, veri işleme, zaman ve emek tasarrufundaki verimlilik gibi zorlukları da beraberinde getirmektedir (34). Bu durum özellikle birden fazla vakanın analizinde söz konusudur. Bununla birlikte manuel işaretlemede farklı uygulayıcılardan kaynaklanan değişkenleri ve bireysel hataları en aza indirmek gibi avantajlara sahiptir (35).

İntraoral tarama veya çalışma modeli taraması ile elde edilen dijital modeller, otomatik landmark belirleme (ALR) yazılımı tarafından işlenerek, yaygın bir açık kaynaklı 3D dosya formatı olan STL formatında kaydedilir. STL dosyaları genellikle ölçek bilgisi içermez ve birimler isteğe bağlı olup taranan dental arklar milimetre olarak ölçülür. Tipik olarak, görüntülenen nesnenin yüzeyi bir ağ olarak adlandırılır. Bu ağın içi boştur ve küçük üçgenlerden oluşur. Ağın bileşenleri, 3D (x, y ve z) değerleri ile tanımlanır.

3D uzayda ALR tarafından tanımlanan yer işaretlerini maksiller ve mandibular dental arklar arasındaki ilişkinin yatay ölçümüne dönüştürmek için bir algoritma geliştirilmiştir. Ağız içi tarayıcının bir özelliği, iki arkın ayrı ayrı taranmasından sonra, modellerin oklüzyonda taranması ve taramalardan birindeki koordinatların oklüzyona uyacak şekilde otomatik olarak ayarlanmasıdır. Maksiller ve mandibular STL dosyalarının aynı görüntüleyicide açılmasıyla, bunlar doğru oklüzyonda görüneceklerdir. Sonrasında yazılım, süt/daimi dentisyon belirlendikten sonra STL dosya adındaki bilgileri kullanarak dişlerin otomatik olarak tanınmasını sağlar.

Farklı tarayıcılar farklı oryantasyon kuralları kullandığından, doğru analizin sağlanması için ağ yönlendirmesinin yazılım tarafından kaydedilmesi gerekir. Uygun yönlendirme, öncelikle Temel Bileşen Analizi (PCA) yöntemi kullanılarak hesaplanır. PCA, kütle merkezinden tüm yönlerde kovaryansı kontrol eder. Basit bir ifadeyle, PCA nesnenin en kısa, orta ve en uzun boyutlarını bulur. PCA'nın en önemli avantajı, modelin herhangi bir yere konumlandırılabilmesi ve yönlendirilebilmesi olup PCA'nın, modeli ideal olarak konumlandırılmış gibi kolayca takip edebilmesidir.



Şekil 2: Otomatik yer işareti tanıma (ALR) için kullanılan adım adım süreç (4).

Sonraki adım, yerel maksimum olarak adlandırılan ve en üst seviye olan dişlerin insizal kenar ve tüberkül tepelerinin belirlenmesidir. Daha sonra yazılımda modeller her bir diş bireysel olacak şekilde bölünürler. Bireysel diş sınırlarının tanımlanması kurvaturlere dayanır ve her biri dişin sınırı düz bir yüzeyden sap-


manın nicel bir ölçüsüdür. ALR yazılımındaki eğrilik tanımı, dış köşeler için pozitif değerler ve iç köşeler için negatif değerler kullanır. Yazılım, taramayı bir dişin tepesinde başlatır ve diş ile diş eti arasındaki sınırı gösteren önemli bir negatif eğrilik kenarı tespit edilene kadar bitişik ağ üçgenlerini özyinelemeli olarak devam ettirir. Kapsanan bölge başlangıç noktası alanı olarak anılacaktır. Önceki adımda bulunan her bir tepe noktası, eğrilik analizi için bir başlangıç noktası olarak kullanılır. Aynı dişte bulunan tepe noktaları, örtüşen alanlara sahip olacaktır. Örtüşen alanları test ederek ve birleştirerek, bir diş tanımlanır ve yazılımda dişlerin tekrarlanması önlenir.

Bu adımın başarılı bir şekilde tamamlanması, her dişin herhangi bir kopya olmadan ve neredeyse diş olmayan tüm yapılar kaldırılarak bölünmesiyle sonuçlanır. Bir sonraki adım diş atamasıdır. Ağ içinde yazılım tarafından tanımlanan bölümler, bloblar olarak anılacaktır. Her blob ya bir bütün diş, bir azı dişinin mezial ya da distal yarısını ya da nadir durumlarda diş olmayan bir özelliği temsil eder. Yazılım, blobları çenenin etrafında soldan sağa doğru sıralar ve numaralandırır. Dişler belirlendikten sonra, ALR sistemi hangi sisteme uygulanırsa uygulansın kullanıma hazır hale getirilir (4) (Şekil 2).

MİNİ VİDA UYGULAMALARI İÇİN GÜDE KULLANIMI

İskeletsel ankraj amaçlı kullanılan mini vidalar, günümüzde ortodontik tedavilerin en önemli parçalarından biridir. Uygulama sırasındaki en önemli sorun uygulama bölgesindeki anatomik yapıların tam olarak konum ve sınırlarının bilinmemesidir. Özellikle uygulama bölgesine komşu diş kökleri en büyük başarısızlık nedenlerinden biridir (36,37). Bunun yanında operatörün tecrübe ve yeteneği de stabiliteyi oldukça etkiler.

Mini vida yerleştirmede hassasiyeti artırmak için çeşitli yöntemler mevcuttur. Bu amaçla periapikal radyografi ve bir tel parçasının kullanıldığı geleneksel tel kılavuz yöntemi kullanılmıştır. Bir başka yöntemde mini vidalar alçı model kullanılarak rezin-splint guide içerisine yerleştirilmiştir (38,39). Daha güncel bir yöntemlerden biri riskli veya anatomik yapının uygulamayı zorlaştıracak nitelikte olduğu durumlarda kullanılan cerrahi guide uygulamasıdır. Yerleştirme alanları, maksiller dijital model görüntüleri ve konik ışınli bilgisayarlı tomografi görüntülerini birleştirerek 3 boyutlu bir cerrahi planlama programı kullanılarak seçilir. Dijital model ile CBCT destekli tasarım ve üretim teknikleri ile yapılan cerrahi guide uygulamalarında mini vida yerleşimi çok daha doğru şekilde gerçekleştirilir (40) (Şekil 3).



Şekil 3:Mini vida uygulamasında kullanılacak cerrahi guide için 3 boyutlu planlama ve cerrahi guide (40).

ORTOGNATİK CERRAHİ

Ortognatik cerrahide tanı ve tedavi planlamasının doğru yapılması başarılı tedavi için en önemli adımdır. Nitelikli ve tecrübeli hekimler için bu karar aşaması hızlı ve doğru olur. Fakat bu tür uzun süreli deneyime sahip olunmaması durumunda bu aşamaya gelmek için iyi bir zaman gerekir. Teşhis ve tedavi planını destekleyebilecek bir yapay zeka sistemi yeterli deneyime sahip olmayan hekimler için iyi bir yardım seçeneği olabilir. Yapay zekalı sistem kurma yöntemlerinden machine learning, bilgisayarın tekrarlı öğrenme yoluyla girdi değerleri ile çıktı değerleri arasında kurallar oluşturmasını sağlayan bir yöntemdir. Bu, insanların yinelemeli öğrenme yoluyla kuralları kendi kendilerine öğrenmelerine benzer. Ayrıca, bilgisayarlar bunu önemli ölçüde daha hızlı oranda yapabilir. Birçok makine öğrenimi yöntemi arasında, neural network machine learning (NNML), insanların formüle edilemeyen veya ölçülemeyen sorunları nasıl analiz ettiğine ve çözdüğüne dayanan bir sistemdir (41,42). Choi ve ark.'nın NNML'yi kullanarak geliştirdikleri yapay zeka modelinde başarı oranı, cerrahi karar teşhisi için %96, ameliyat tipinin ayrıntılı teşhisi ve çekim kararı için %91 gibi yüksek değerlerdedir (43).

Dijital tekniklerin cerrahi-ortodontik protokoller üzerindeki etkisi (2):

- AI ile geliştirilmiş maksillofasial görüntüleri kullanarak gelişmiş tanı hassasiyeti;
- 3D modeller kullanılarak tedavi planlaması;
- CAD/CAM (Bilgisayar Destekli Tasarım, Bilgisayar Destekli İmalat) özel ortodontik ve cerrahi alet ve ekipmanların imalatı;
- Görüntü süperimpozisyonunu kullanılarak iyileştirilmiş terapötik takip.

1. TEŞHİS VE GÖRÜNTÜLEME

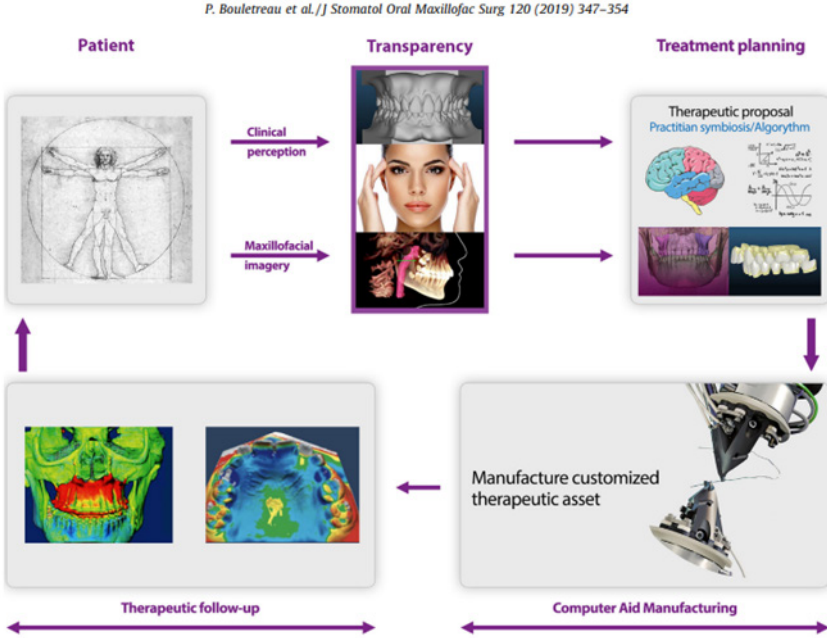
Yapay zeka, maksillofasial görüntülerin ön analizinin yanı sıra verilerin alınmasını ve işlenmesini optimize etmek için farklı seviyelerde müdahale eder. Analiz edilebilen çeşitli çözünürlük seviyeleri, uygulayıcıya hastanın fiziksel özelliklerine ilişkin daha şeffaf ve küresel bir görünüm sunar. Bu girdi, doğru terapötik seçeneği belirlemek için gereklidir. AI'nın ağız içi tarayıcı yazılımında kullanılması, daha hızlı ve daha verimli bir kazanım sağlar. Ayrıca, üç boyutlu radyolojide AI kullanımı, sinyal-gürültü oranını optimize eder ve daha düşük doz radyasyon kullanarak daha kaliteli görüntüler sağlar. Machine learningde kullanılan teknikler, verimliliği hızla artan 3D rekonstrüksiyonlara izin verir. Üst solunum yollarının boyutlarını belirlemek ve hesaplamak için çeşitli tanı araçlarının (CBCT, dijital fotoğraf ve ağız içi tarayıcılar) süperimpozisyonuna izin verirler (44). Bu veriler özellikle obstrüktif uyku apne sendromlarının tedavisinde geçerlidir. Sefalometrik analizleri otomatikleştirmek için yapay zeka ve makine öğrenimi teknolojilerini birleştiren çeşitli yazılımlar mevcuttur. Ayrıca, AI'nın faydası 2D analiz kapasitesinin çok ötesine uzanır (45). Uygulayıcının belirli bir hastanın dentofasial özelliklerinin gerçek ve nesnel üç boyutlu algısını elde etmesini sağlar. Bu nedenle, önemli ölçüde güçlü bir teşhis aracı olabilir. Çalışmalar, yüzün 3D görüntüsünün biyometrik analizi için minimum 100-200 kraniyometrik noktanın gerekli olduğunu göstermektedir (46). Yapay zekaya olan ihtiyaç, aynı anda bu kadar çok parametreyi kısa ve öz bir şekilde analiz etme ve yorumlama kapasitesinde yatmaktadır.

Öte yandan, hesaplamalardaki son ilerlemeyle birlikte, makine öğreniminde 3 boyutlu tahmin ile ilgili iki önemli yöntem olan tabanlı geometrik morfometrik yöntemler (GMM'ler) ve derin öğrenme kullanılabilir hale geldi. Hedef nesnelere şekil ve boyutunda (fenotipik varyasyon) bazı istatistiksel varyasyonları ortaya çıkaran GMM'ler yakın zamanda ortaya çıkmıştır. GMM ve derin öğrenme kombinasyonuna dayalı AI sistemleri üzerindeki bir çalışmada (47) bu kombinasyonun ortognatik cerrahiden sonra 3 boyutlu yüz topografisi öngörüsünde başarılı olduğu bildirilmiştir.

2. TEDAVİ PLANLAMASI

3D dijital tedavi planlaması, dinamik bir sanal kurulum (Clin Check, Insignia, Orthoanalyser, vb.) kullanılarak aktif şekilde yapılabilmektedir. Bu yazılımlar, makine öğrenimi ile geliştirilmiştir (48). Bugün algoritmalar, alçı modeller ve lateral sefalogramların uzun ve titiz görevinin yerini almıştır. Dinamik görsel setup, çene cerrahı ve ortodontist arasında iyi bir diyalog aracıdır. Uygulayıcıların her bir terapötik hedefin diyagramlarını ve her bir müdahalenin genel sonuç üze-

rindeki rolünü görselleştirmelerine olanak tanır. Ayrıca ortognatik cerrahi protokollerinde, multidisipliner bir yaklaşımın gerekli olduğu durumlarda ortognatik cerrahi protokollerinin teknik özelliklerine aşına olmayan alan dışı uzmanlarla diyalog ve planlamada çok etkili bir araçtır. Sanal kurulum yazılımı, ortognatik cerrahi protokoldeki prosedürleri hastaya açıklamak ve tartışmak için de harika araçlardır (49)(Şekil 4).



Şekil 4: Cerrahi-ortodontik protokollerde dijital iş akışı (2).

3. ÖZEL ORTODONTİK VE CERRAHİ ALET VE EKİPMANLARIN İMALATI

Kemik segmentlerinin yerini belirledikten sonra, programda transoperatif aşamada kullanılacak cerrahi splintleri oluşturmak mümkündür. Kombine ameliyatlarda iki splint kullanılır: ara ve son splintler. Ara splint, hareket ettirilecek ilk segmentin son konumunu ve son splint ise son oklüzyonu gösterecektir. Bu cerrahi splintler Bilgisayar Destekli Tasarım ve Bilgisayar Destekli İmalat (CAD/CAM) teknolojisi kullanılarak üretilmektedir. Bu amaçla, dosyalar Standard Triangle Language (STL) formatında dışa aktarılır. Bu dosya formatı, sanal olarak tasarlanan splintleri gerçekleştirerek 3D izlenime izin verir. Splintler hastanın dişlerine büyük bir hassasiyetle oturur ve kemik segmentlerinin tam olarak planlanan yerde konumlandırılmasına olanak tanır (50).

4. GÖRÜNTÜLERİN ÇAKIŞTIRILMASI VE HASTA TAKİBİ

AI, çeşitli dijital görüntülerin süperimpozisyonuna izin verdiği için tedavi takibinde iyi bir araç olabilmektedir. Örneğin, aynı ağız içi tarayıcıda kullanılacak farklı makine öğrenimi türleri ile tasarlanmış yazılım, tek bir hastada yan yana iki dijital modelin dental ark hareketlerinin süperimpozisyonuna ve görselleştirilmesine olanak tanır (51,52). Diğer AI tabanlı çözümler, gerçek dental fotoğrafları kullanarak dental ark modellerinin 3D görüntüsünü elde etmek için dijital fotoğrafçılığı ve “3D Eşleştirme” adı verilen 3D modelleri birleştirme olanağı sunar. Bu model, tedavinin zaman içindeki gelişimine göre dinamik olarak ayarlanır (53). Doğal olarak, ortognatik cerrahide, X ışını görüntülemesinin süperimpozisyonu yeteneği özellikle yararlıdır (54). Yapay zekanın 3 boyutlu radyolojideki yetenekleri sayesinde, bir uygulayıcının zahmetli ve yoğun müdahalesi olmadan geometrik morfometrik araçların kullanımını otomatikleştirmek mümkündür. Oluşturulan görüntülerin süperimpozisyonu bütünsel veya belirlenmiş bir alanla sınırlı olabilir. Özellikle mandibular ilerletme cerrahisinde, osteotomi alanının posteriorundaki sagittal ramustan oluşan bir “belirlenmiş alan” ın süperimpozisyonu büyük önem taşır (2).

DUDAK DAMAK YARIĞI VAKALARI

Dudak ve damak yarıkları (DDY), birçok farklı alt gruba ve değişen şiddete sahip orofasiyal anomalilerdir. Alt fenotiplere, beslenme ve yutma güçlükleri, konuşma bozukluğu, iştirme sorunları ve dentofasiyal büyüme ve gelişmeyi içeren konjenital komplikasyonlar eşlik eder (55). Yarık dudak ve/veya damaklı bireylerin tanı, tedavi veya planlamasına yardımcı olmak için yapay zekanın kullanımı günümüz ortodonti tedavilerinde kendine yer edinmeye başlamıştır. Bugün, yarık dudak ve/veya damak için yapay zeka kullanımına yönelik aktif bir ilgi ve büyük bir potansiyel bulunmaktadır. Modern teknoloji, yarık dudak ve/veya damak sorunu olan bireylere yardımcı olma konusunda muazzam bir potansiyele sahiptir. Bilgiyi dağıtmaya, bireylere ve bakıcılarına destek sağlamaya ve uzmanlar ile bakıma ihtiyacı olan bireyler arasındaki iletişim engellerini kaldırmaya yardımcı olabilir. Son literatür, dijital nazoalveolar molding (NAM) tedavisinin kullanılması gibi dijital teknolojilerin kullanımını açıklar. Bu şekilde enfeksiyon oranını düşürürken standart bakıma izin verir (56). Çok sayıdaki vaka raporları, bebekler ve ebeveynleri üzerindeki yarık yükünü hafifletebilecek dijital iş akışlarının kullanımını tanımlamaktadır (57,58).

1. YARIK DUDAK VE DAMAK GELİŞİMİ RİSKİNDE AI

DDY gelişim riskini değerlendirmede yapay zeka desteği artık birçok ülkede yaygın olarak kullanılmaktadır. Kimi çalışmalar ToxRef toksikoloji veritabanı üzerinden ailesel geçmişi ve genetik bilgi edinimi sağlayarak, kimileri Tek Nükleotid Polimorfizmlerini (SNP) değerlendirerek, kimileri ise genotip etkileşimlerini inceleyerek bunu gerçekleştirmişlerdir. Bunun yanında ebeveyn geçmişi üzerinden multiple yapay zeka ile yarık oluşum ihtimalini değerlendirme de mevcuttur (59).

2. DDY TEŞHİSİNDE AI

DDY'li bireylerde yarık bölgesi ve morfolojik özelliklerini belirlemede yapay zeka kullanımı oldukça dikkat çekicidir. Fetüste frontal fotoğraf kullanımı ve ultrason kullanımlarının yanı sıra dijital kamera görüntülerinden faydalanılabilmektedir. Bunun yanında sadece normal ve yarığa sahip vakaları ayırt etmekte kalmayıp ayrıca yarığın tek/çift taraflı olmasının da teşhis edilebildiği destek vektör makinesi (SVM) ve evrimsel nöral network (CNN) kombinasyonu da oldukça iyi sonuçlar vermektedir (60). Yine nöral network kullanımı ile sekonder alveolar graftleme öncesi yarık hacminin hesaplanması da bugün için mümkündür. Bu amaçla hacimsel kayıt tabanlı bir çerçeve ile defekt rekonstrüksiyonu yolu ile hacim tahmini de kullanılmaktadır (61).

3. CERRAHİ ÖNCESİ ORTOPEDİK TEDAVİDE AI

Yarık defektinin şiddetini azaltmak için nazoalveolar molding (NAM) gerektiren bilateral dudak ve damak yarığı olan bebeklerde sıralı plaklar geliştirmek için AI kullanılabilmektedir. Böyle bir durumda ardışık plakaların üretimi, yapıyı bölümlere ayırarak, boşluğu sanal olarak aşamalı kapatan plakalar üreterek yapılır. Yapay zeka ile fetal dokuların moldingi, maksiller arkın büyümesi dikkate alınarak sonraki aşamalarda yapılabilir ve böylece NAM için 3D olarak basılıp teslim edilebilecek bir seri plak üretimi gerçekleştirilir (62).

4. KONUŞMA ETKİNLİĞİNİN DEĞERLENDİRİLMESİNDE AI

DDY vakalarında konuşmadaki en büyük problem hipernazal fonasyondur. Yapay zeka ile bu durumun tespitinin yanında şiddetinin de belirlenmesi mümkündür. Bunun için konuşmanın çıkarılan özellikleri girdi olarak kullanılır. Ayrıca konuşma kalitesinin belirlenmesinde fonem tespit ve analizleri de yapılan çalışmalar arasındadır (63,64).

5. DDY CERRAHİSİNDE AI

Yarık dudak ve damağı olan bebeklerde yarık dudağın cerrahi olarak düzeltilmesinde cerrahi belirteçleri belirlemek amaçlı ayrıntılı frontal fotoğraflar kullanılmıştır. Bu şekilde operatörün tecrübesinden bağımsız olarak işlemin sonucundaki varyasyonlar azaltılabilmektedir (65). Erken radyografilerde daha sonra ameliyat ihtiyacını gösterebilecek özellikleri tespit etmek için de kullanılan AI modelleri olduğu bilinmektedir (66).

HAVAYOLU DEĞERLENDİRMESİNDE AI

Uyku sırasında üst hava yolunun tekrarlayan tam veya kısmi kollapsı olarak tanımlanan obstrüktif uyku apnesi (OSA), yaygın bir uyku solunum bozukluğudur. Polisomnografi (PSG) OSA teşhisi için altın standart olup aynı zamanda şiddet seviyesini de belirleyebilmektedir. CT ve MRI ise havayolu anatomisini incelemek için yararlıdır fakat teşhis ve problem şiddeti hakkında yeterli veri sağlamazlar. OSA semptomlarının derecesini belirlemede çeşitli machine learning teknikleri kullanılmıştır. Liu et al. (67), vücut şekli profiline ve yaş bilgisine dayalı olarak OSA semptomlarının şiddetini tahmin etmek için makine öğrenimi tekniklerini kullanmıştır. Kim et al. (68), solunum seslerinden elde edilen akustik biyobelirteç temelinde hastaların OSA semptomlarını belirlemek için derin bir sinir ağı kullanmıştır. Urtnasan et al. (69) kalp atışı sinyallerine dayalı olarak hastaların OSA semptomlarını belirlemek için çeşitli makine öğrenme algoritmaları olan sınıflandırma modelleri gerçekleştirmiştir. Bu yöntemler hastanın semptomlarını hızlı bir şekilde belirlemeye odaklanmış olsa da OSA'nın temel mekanizması veya ortaya çıkış nedeni hakkında bilgi verememiştir. Yeom ve ark (70) Computational fluid Dynamics (CFD) tekniği kullanarak hava yolu geometrisi ve aerodinamik özellikler arasındaki ilişkinin araştırılmasına dayalı olarak doğru tanı ve etkili cerrahi için nicel bir standart sağlamayı amaçlamışlardır. Çalışmalarında normal geometriye sahip hastalardan alınan bilgisayarlı tomografi verilerine dayanarak 4 ana geometrik parametre seçip, toplam 160 idealize vaka modellemiş ve simüle etmişlerdir. Sayısal yöntemle elde edilen bir veri seti ile Gauss süreç regresyonunu (GPR) kullanarak tahmine dayalı bir model oluşturmuşlardır. Çalışma sonunda gerçekçi üst solunum yolu modeli için CFD sonuçlarına göre genel GPR modelinin ortalama doğruluğunun ~%72 olduğunu görülmüştür. Hastalarda OSA semptomlarının derecesini normal-hafif ve orta ve şiddetli olarak belirlemek için ayrıca bir destek vektör makinesi modeli de kullanılmış olup eğitim veri seti ile %82,5, test veri seti ile %80 doğruluk bildirilmiştir. Bu şekilde BT görüntülerine dayalı olarak denenen ilk modelin, OSA hastalarında tanı ve tedavi seçeneklerini

hızlı ve verimli bir şekilde seçme sürecini desteklemek için kullanılabileceğini düşünmüşlerdir. Böylece PGS testi ihtiyacı en aza indirgenebilecek ve daha hızlı ve ekonomik bir süreç sağlanacaktır. Yöntemin daha iyi sonuçlar vermesi içinse GPR tahmin modeli, hastanın uykusu sırasında hava akımı dinamiğinin ölçülmesiyle karşılaştırılarak geliştirilebilir.

SONUÇ

AI teknolojisi ortodontik teşhis ve tedavilerin doğruluğunu artırmaya yardımcı olabilir, bu nedenle ortodontistlerin daha verimli çalışmasına yardımcı olur. Bununla birlikte, yapay zekanın iyileştirilmesi ortodontistler ve diğer sağlık profesyonelleri için kesinlikle büyük bir yardım olsa da, sağlık konularındaki nihai kararlar her zaman klinisyenlerin sorumluluğunda olacaktır.

KAYNAKLAR

1. Kaplan A, Haenlein M. Siri, Siri, in my hand: who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Bus Horiz* 2019;62(1):15-25.
2. Bouletreau P, Makaremi M, Ibrahim B, et al. Artificial Intelligence: Applications in orthognathic surgery. *J Stomatol Oral Maxillofac Surg.* 2019;120(4):347-354. doi:10.1016/j.joramas.2019.06.001
3. Chalmers EV, McIntyre GT, Wang W, et al. Intraoral 3D Scanning or Dental Impressions for the Assessment of Dental Arch Relationships in Cleft Care: Which is Superior?. *Cleft Palate Craniofac J.* 2016;53(5):568-577. doi:10.1597/15-036
4. Woodsend B, Koufoudaki E, Lin P, et al. Development of intra-oral automated landmark recognition (ALR) for dental and occlusal outcome measurements. *Eur J Orthod.* 2022;44(1):43-50. doi:10.1093/ejo/cjab012
5. Jyothikiran H, Shanthara JR, Subbiah P, et al. Craniofacial imaging in orthodontics--past present and future. *Int J Orthod Milwaukee.* 2014;25(1):21-26.
6. Monill-González A, Rovira-Calatayud L, d'Oliveira NG, et al. Artificial intelligence in orthodontics: Where are we now? A scoping review. *Orthod Craniofac Res.* 2021;24 Suppl 2:6-15. doi:10.1111/ocr.12517
7. Nayyar N, Ojcius DM, Dugoni AA. The Role of Medicine and Technology in Shaping the Future of Oral Health. *J Calif Dent Assoc.* 2020;48(3):127-130.
8. Schwendicke F, Golla T, Dreher M, et al. Convolutional neural networks for dental image diagnostics: A scoping review. *J Dent.* 2019;91:103226. doi:10.1016/j.jdent.2019.103226
9. Buschang PH, Asiri SN. The present, past and future of orthodontic research. In *Seminars in Orthodontics.* 2019;25:326-338.
10. Kunz F, Stellzig-Eisenhauer A, Zeman F, et al. Artificial intelligence in orthodontics: Evaluation of a fully automated cephalometric analysis using a customized convolutional neural network. *Künstliche Intelligenz in der Kieferorthopädie: Evaluierung einer vollständig automatisierten Fernröntgenseitenanalyse unter Anwendung eines individualisierten convolutional neural network". J Orofac Orthop.* 2020;81(1):52-68. doi:10.1007/s00056-019-00203-8
11. Bichu YM, Hansa I, Bichu AY, et al. Applications of artificial intelligence and machine learning in orthodontics: a scoping review. *Prog Orthod.* 2021;22(1):18. Published 2021 Jul 5. doi:10.1186/s40510-021-00361-9
12. Vaid NR. Digital technologies in orthodontics--An update. *Seminars in Orthodontics* 2018;24(4):373-375. doi: <https://doi.org/10.1053/j.sodo.2018.10.001>

13. Ghafari JG. “Medically necessary” orthodontic care: challenges and applications. *Seminars in Orthodontics* 2016;22(3):167-176.
14. Tarraf NE, Ali DM. Present and the future of digital orthodontics. *Seminars in Orthodontics* 2018;24(4):376-385.
15. Machoy ME, Szyszka-Sommerfeld L, Vegh A, et al. The ways of using machine learning in dentistry. *Adv Clin Exp Med*. 2020;29(3):375-384. doi:10.17219/acem/115083
16. Khanagar SB, Al-Ehaideb A, Maganur PC, et al. Developments, application, and performance of artificial intelligence in dentistry—A systematic review. *Journal of dental sciences*, 2021;16(1):508-522.
17. Jia F, Lei Y, Lin J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data. *Mechanical systems and signal processing*, 2016;72:303-315.
18. Xie X, Wang L, Wang A. Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment. *Angle Orthod*. 2010;80(2):262-266. doi:10.2319/111608-588.1
19. Jung SK, Kim TW. New approach for the diagnosis of extractions with neural network machine learning. *Am J Orthod Dentofacial Orthop*. 2016;149(1):127-133. doi:10.1016/j.ajodo.2015.07.030
20. Thanathornwong B. Bayesian-Based Decision Support System for Assessing the Needs for Orthodontic Treatment. *Health Inform Res*. 2018;24(1):22-28. doi:10.4258/hir.2018.24.1.22
21. Li P, Kong D, Tang T, et al. Orthodontic Treatment Planning based on Artificial Neural Networks. *Sci Rep*. 2019;9(1):2037. doi:10.1038/s41598-018-38439-w
22. Rigelsford J. Robotic bending of orthodontic archwires. *Ind. Robot*. 2004;31:331-335.
23. Alford TJ, Roberts WE, Hartsfield JK Jr, et al. Clinical outcomes for patients finished with the SureSmile™ method compared with conventional fixed orthodontic therapy. *Angle Orthod*. 2011;81(3):383-388. doi:10.2319/071810-413.1
24. Gilbert A. An in-office wire-bending robot for lingual orthodontics. *J Clin Orthod*. 2011;45(4):230-236.
25. Du H, Jia Y, Zhang Y, et al. Trajectory planning of archwire bending robot. *China Mech. Eng*. 2010;21:1605-1608.
26. Zhang Y, Wei C, Jiang J, et al. Motion Planning for Archwire Bending Robot in Orthodontic Treatments. *Int. J. Control. Autom*. 2014;7:287-298.
27. Ahmad P, Alam MK, Aldajani A, et al. Dental Robotics: A Disruptive Technology. *Sensors (Basel)*. 2021;21(10):3308. doi:10.3390/s21103308
28. Ngan P, Hornbrook R, Weaver B. Early timely management of ectopically erupting maxillary canines. *Semin Orthod*. 2005;11:152-163.
29. Bedoya MM, Park JH. A review of the diagnosis and management of impacted maxillary canines. *J Am Dent Assoc*. 2009;140(12):1485-1493. doi:10.14219/jada.archive.2009.0099
30. Al-Khateeb S, Abu Alhaja ES, Rwaite A, et al. Dental arch parameters of the displacement and nondisplacement sides in subjects with unilateral palatal canine ectopia. *Angle Orthod*. 2013;83(2):259-265. doi:10.2319/031612-229.1
31. Yan B, Sun Z, Fields H, et al. Etiologic factors for buccal and palatal maxillary canine impaction: a perspective based on cone-beam computed tomography analyses. *Am J Orthod Dentofacial Orthop*. 2013;143(4):527-534. doi:10.1016/j.ajodo.2012.11.021
32. Chen S, Wang L, Li G, et al. Machine learning in orthodontics: Introducing a 3D auto-segmentation and auto-landmark finder of CBCT images to assess maxillary constriction in unilateral impacted canine patients. *Angle Orthod*. 2020;90(1):77-84. doi:10.2319/012919-59.1
33. Wang L, Gao Y, Shi F, et al. Automated segmentation of dental CBCT image with prior-guided sequential random forests. *Med Phys*. 2016;43(1):336-346. doi:10.1118/1.4938267
34. Gupta A, Kharbanda OP, Sardana V, et al. A knowledge-based algorithm for automatic detection of cephalometric landmarks on CBCT images. *Int J Comput Assist Radiol Surg*. 2015;10(11):1737-1752. doi:10.1007/s11548-015-1173-6

35. Chen YJ, Chen SK, Chang HF, et al. Comparison of landmark identification in traditional versus computer-aided digital cephalometry. *Angle Orthod.* 2000;70(5):387-392. doi:10.1043/0003-3219(2000)070<0387:COLIIT>2.0.CO;2
36. Chen YH, Chang HH, Chen YJ, et al. Root contact during insertion of miniscrews for orthodontic anchorage increases the failure rate: an animal study. *Clin Oral Implants Res.* 2008;19(1):99-106. doi:10.1111/j.1600-0501.2007.01418.x
37. Motoyoshi M, Ueno S, Okazaki K, et al. Bone stress for a mini-implant close to the roots of adjacent teeth--3D finite element analysis. *Int J Oral Maxillofac Surg.* 2009;38(4):363-368. doi:10.1016/j.ijom.2009.02.011
38. D'haese J, Van De Velde T, Komiyama A, et al. Accuracy and complications using computer-designed stereolithographic surgical guides for oral rehabilitation by means of dental implants: a review of the literature. *Clin Implant Dent Relat Res.* 2012;14(3):321-335. doi:10.1111/j.1708-8208.2010.00275.x
39. Horwitz J, Zuabi O, Machtei EE. Accuracy of a computerized tomography-guided template-assisted implant placement system: an in vitro study. *Clin Oral Implants Res.* 2009;20(10):1156-1162. doi:10.1111/j.1600-0501.2009.01748.x
40. Bae MJ, Kim JY, Park JT, et al. Accuracy of miniscrew surgical guides assessed from cone-beam computed tomography and digital models. *Am J Orthod Dentofacial Orthop.* 2013;143(6):893-901. doi:10.1016/j.ajodo.2013.02.018
41. Su MC, Chang HT. A new model of self-organizing neural networks and its application in data projection. *IEEE Trans Neural Netw.* 2001;12(1):153-158. doi:10.1109/72.896805
42. Yamamoto Y, Nikiforuk PN. A new supervised learning algorithm for multilayered and interconnected neural networks. *IEEE Trans Neural Netw.* 2000;11(1):36-46. doi:10.1109/72.822508
43. Choi HI, Jung SK, Baek SH, et al. Artificial Intelligent Model With Neural Network Machine Learning for the Diagnosis of Orthognathic Surgery (published correction appears in *J Craniofac Surg.* 2020 Jun;31(4):1156). *J Craniofac Surg.* 2019;30(7):1986-1989.
44. Cevidanes LH, Styner MA, Proffit WR. Image analysis and superimposition of 3-dimensional cone-beam computed tomography models. *Am J Orthod Dentofacial Orthop.* 2006;129(5):611-618. doi:10.1016/j.ajodo.2005.12.008
45. Nishimoto S, Sotsuka Y, Kawai K, et al. Personal Computer-Based Cephalometric Landmark Detection With Deep Learning, Using Cephalograms on the Internet. *J Craniofac Surg.* 2019;30(1):91-95. doi:10.1097/SCS.0000000000004901
46. Zamora N, Llamas JM, Cibrián R, et al. A study on the reproducibility of cephalometric landmarks when undertaking a three-dimensional (3D) cephalometric analysis. *Med Oral Patol Oral Cir Bucal.* 2012;17(4):e678-e688. Published 2012 Jul 1. doi:10.4317/medoral.17721
47. Tanikawa C, Yamashiro T. Development of novel artificial intelligence systems to predict facial morphology after orthognathic surgery and orthodontic treatment in Japanese patients. *Sci Rep.* 2021;11(1):15853. Published 2021 Aug 4. doi:10.1038/s41598-021-95002-w
48. Hennessy J, Al-Awadhi EA. Clear aligners generations and orthodontic tooth movement. *J Orthod.* 2016;43(1):68-76. doi:10.1179/1465313315Y.0000000004
49. Pagani R, Signorino F, Poli PP, et al. The Use of Invisalign® System in the Management of the Orthodontic Treatment before and after Class III Surgical Approach. *Case Rep Dent.* 2016;2016:9231219. doi:10.1155/2016/9231219
50. Faber J, Miranda L, Faber C et al. Surgery-first orthognathic surgery with computer assisted three-dimensional planning. In: *Seminars in Orthodontics.* WB Saunders, 2018. p. 430-442.
51. José Viñas M, Pie de Hierro V, M Ustrell-Torrent J. Superimposition of 3D digital models: A case report. *Int Orthod.* 2018;16(2):304-313. doi:10.1016/j.ortho.2018.03.017
52. Ganzer N, Feldmann I, Liv P, et al. A novel method for superimposition and measurements on maxillary digital 3D models-studies on validity and reliability. *Eur J Orthod.* 2018;40(1):45-51. doi:10.1093/ejo/cjx029
53. Roisin L-C, Bre`zulier D, Sorel O. Contro`le a` distance en orthodontie: fondements et description de la solution Dental MonitoringTM. *Rev Orthop Dento Faciale* 2016;50(3):303-313.

54. Cevidanes LH, Bailey LJ, Tucker GR Jr, et al. Superimposition of 3D cone-beam CT models of orthognathic surgery patients. *Dentomaxillofac Radiol.* 2005;34(6):369-375. doi:10.1259/dmfr/17102411
55. Mossey PA, Clark JD, Gray D. Preliminary investigation of a modified Huddart/Bodenham scoring system for assessment of maxillary arch constriction in unilateral cleft lip and palate subjects. *Eur J Orthod.* 2003;25(3):251-257. doi:10.1093/ejo/25.3.251
56. Chaudhari PK, Dhingra K, Zere E. Digital Presurgical Infant Orthopedics in COVID-19 Crisis. *Cleft Palate Craniofac J.* 2021;58(10):1331-1334. doi:10.1177/1055665620980230
57. Shanbhag G, Pandey S, Mehta N, et al. A Virtual Noninvasive Way of Constructing a Nasoalveolar Molding Plate for Cleft Babies, Using Intraoral Scanners, CAD, and Prosthetic Milling. *Cleft Palate Craniofac J.* 2020;57(2):263-266. doi:10.1177/1055665619886476
58. Batra P, Gribel BF, Abhinav BA, et al. OrthoAligner "NAM": A Case Series of Presurgical Infant Orthopedics (PSIO) Using Clear Aligners. *Cleft Palate Craniofac J.* 2020;57(5):646-655. doi:10.1177/1055665619889807
59. Dhillon H, Chaudhari PK, Dhingra K, et al. Current Applications of Artificial Intelligence in Cleft Care: A Scoping Review. *Front Med (Lausanne).* 2021;8:676490. doi:10.3389/fmed.2021.676490
60. Agarwal S, Hallac RR, Mishra R, et al. Image based detection of craniofacial abnormalities using feature extraction by classical convolutional neural network. In: 2018 IEEE 8th International Conference on Computational Advances in Bio and Medical Sciences (ICCABS). Las Vegas, NV 2018;1-6. doi: 10.1109/ICCABS.2018. 8541948
61. Zhang Y, Pei Y, Chen S, et al. Volumetric registration based cleft volume estimation of alveolar cleft grafting procedures. In: 2020 IEEE 17th International Symposium on Biomedical Imaging (ISBI). Iowa City, IA 2020;99-103. doi: 10.1109/ISBI45749.2020. 9098407
62. Schiebl J, Bauer FX, Grill F, et al. RapidNAM: Algorithm for the Semi-Automated Generation of Nasoalveolar Molding Device Designs for the Presurgical Treatment of Bilateral Cleft Lip and Palate. *IEEE Trans Biomed Eng.* 2020;67(5):1263-1271. doi:10.1109/TBME.2019.2934907
63. Wutiwiwatchai C, Chootrakool P, Kasuriya S, et al. Naso-articulometry speech database for cleft-palate speech assessment. In: 2018 Oriental COCODA - International Conference on Speech Database and Assessments. Miyazaki 2018;32-36. doi: 10.1109/ICSDA.2018.8693008
64. Bocklet T, Riedhammer K, Eysholdt U, et al. Automatic phoneme analysis in children with Cleft Lip and Palate. In: 2013 IEEE International Conference on Acoustics, Speech and Signal Processing. Vancouver, BC 2013;7572-7576. doi: 10.1109/ICASSP.2013.6639135
65. Li Y, Cheng J, Mei H, et al. CLPNet: cleft lip and palate surgery support with deep learning. In: 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). 2019;3666-3672. doi: 10.1109/EMBC.2019.8857799
66. Lin G, Kim PJ, Baek SH, et al. Early Prediction of the Need for Orthognathic Surgery in Patients With Repaired Unilateral Cleft Lip and Palate Using Machine Learning and Longitudinal Lateral Cephalometric Analysis Data. *J Craniofac Surg.* 2021;32(2):616-620. doi:10.1097/SCS.00000000000006943
67. Liu WT, Wu HT, Juang JN, et al. Prediction of the severity of obstructive sleep apnea by anthropometric features via support vector machine. *PLoS One.* 2017;12(5):e0176991. doi:10.1371/journal.pone.0176991
68. Kim T, Kim JW, Lee K. Detection of sleep disordered breathing severity using acoustic biomarker and machine learning techniques. *Biomed Eng Online* 17: 16, 2018.
69. Urtnasan E, Park JU, Lee S, et al. Optimal classifier for detection of obstructive sleep apnea using a heartbeat signal. *Int J FUZZY Log Intell Syst* 2017;17:76-81 doi:10.5391/IJFIS.2017.17.2.76.
70. Yeom SH, Na JS, Jung HD, et al. Computational analysis of airflow dynamics for predicting collapsible sites in the upper airways: machine learning approach. *J Appl Physiol (1985).* 2019;127(4):959-973.