

BÖLÜM 1

ORTODONTİDE YAPAY ZEKA UYGULAMALARI

Özge MÜFTÜOĞLU¹

GİRİŞ

Hızla gelişen teknoloji ve bilim günlük yaşantımızda pek çok değişime sebebiyet vermektedir. Bu değişime neden olan en büyük gelişmelerden biri, yapay zeka teknolojisinin artık hemen hemen her alanda karşımıza çıkıyor olmasıdır (1,2).

Tıp ve diş hekimliği gibi sağlık alanlarında dijital veriyi işleyebilen teknolojilerin kullanılması ise yaklaşık son yirmi yılda dikkat çekmiştir. Dijital teknolojinin, özellikle yapay zeka uygulamalarının bu alanlarda kullanılması tedavi maliyeti ve süresini, insan deneyimine duyulan ihtiyacı ve tıbbi hata vakalarının sayısını azaltmaya yardımcı olabilmektedir (3). Ayrıca, tanı ve tedavi süreci haricinde, anamnez kaydı ve hasta randevularını düzenleme gibi işlemler için kullanılabilir. Bu özellikler sayesinde hasta ile ilgili tüm bilgiler kayıt altına alınabilmekte ve gerekli görüldüğü durumlarda elde edilen büyük veriler ile sınıflandırıcı yapay zeka modelleri yapılabilmektedir (4). Tüm sağlık alanında olduğu gibi diş hekimliği alanında da büyük verilerin oluşması hastalıkların erken teşhis edilmesi ve önlenmesi açısından büyük katkı sağlayacaktır.

YAPAY ZEKA NEDİR?

Yapay zeka, McCarthy tarafından 1956 yılında karmaşık ortamları algılayabilme, öğrenebilme ve tepki verebilme kapasitesine sahip biyolojik olmayan varlıkların davranışları olarak tanımlanmıştır. Bu teknolojide amaç, makinelere transfer edilen veriler yardımıyla makinelere problem çözebilme kabiliyetinin kazandırılmasıdır (5). Yapay zeka, insan beynini taklit etme zorunluluğu olmayan daha çok kendi kuralları olan bir problem çözme aracıdır. İnsan benzeri sonuçlar elde etmek için yapılan çalışmalarda, bilgisayarların birçok parametrede insan sonuçlarına üstün geldiği tespit edilmiştir (6). Yapay zekanın insan zekasını taklit edebilmesi için çözümlenme, anlamlandırma, genelleme yapabilme, öğrenebilme gibi yeteneklerin modellenen örneğe tanımlanması gerekmektedir (7).

¹ Dr. Öğr. Üyesi, Ankara Medipol Üniversitesi, Diş Hekimliği Fakültesi, Ortodonti AD., ozge.muftuoglu@ankaramedipol.edu.tr

Yapay zekayı anlamlandırabilmek için makine öğrenimi, derin öğrenme ve yapay sinir ağları terminolojilerini kavramış olmak gerekmektedir. Makine öğrenimi, karmaşık kalıpları tanıma ve verilere dayalı uygun kararlar verme becerilerini amaçlayan yapay zekanın alt sınıfını oluşturan bir işlem sistemidir. Makine öğreniminde ilk adım, bir veri birikimi oluşturmaktır. Bilgisayar bu verileri gözlemleyerek verilere dayalı bir model oluşturur. Daha sonra bu verileri kullanarak tahmin yapabilen sınıflandırma algoritmaları oluşturmaktadır. Böylece bilgisayarlar, deneyimlerden ve önceki verilerden öğrenme yeteneği kazanmaktadır. Makine öğreniminin bir alt alanı olan derin öğrenme, görüntü sınıflandırma, nesne tanıma, ses tanıma ve dil çevirisi gibi çeşitli karmaşık görevleri kapsamaktadır. Derin öğrenme sistemleri birden fazla veri türünü girdi olarak kabul edebilmektedir. Bu nedenle, verilere dayalı çıkarımsal tahmin yapabilen sistemler, makine öğrenmesi ve derin öğrenme yöntemleriyle oluşturulabilir. Yapay sinir ağı ise insan beynindeki nöronları temel alan bir teknolojidir. Bu sinir ağı, insan beynindeki nöronlara benzer şekilde birbirine bağlı, veri aktarımı sağlayan bir ağ içermektedir. Böylece biyolojik sinir sisteminin çalışma şeklini taklit etmektedir (8).

Yapay zeka tabanlı yazılım sistemleri, birçok alanda olduğu gibi ortodonti alanında da önemli, yenilikçi ve dental uygulamaların geleceği olarak kabul edilmektedir. Hasta iletişiminden, tanıya ve tedavi süreçlerine kadar ortodontinin her alanında yapay zekanın kullanıldığı görülmüştür (9). Bu nedenle, ortodonti alanında yapay zeka teknolojisi uygulamalarına ilişkin literatürlerin gözden geçirilmesi gerektiği düşünülmüştür.

SEFALOMETRİK ANALİZ NOKTALARININ BELİRLENMESİ

Sefalometrik radyografiler üzerinde yapılan çizimler manuel olarak veya bilgisayar yardımı ile dijital olarak yapılabilir. Sefalometrik çizim için bilgisayar programlarının kullanılması hata oranını azaltmakta ve sefalometrik analizin tanılabilirliğini artırarak zamandan tasarruf etmeyi amaçlamaktadır. Ancak, anatomik yer işaretlerini belirlemedeki tutarsızlıklar analiz sonuçlarında görülen hatanın önemli bir kaynağını oluşturmaktadır (10). Bu gibi sorunların üstesinden gelebilmek, hata payını ve analiz için gereken süreyi azaltabilmek için sefalometrik analizleri otomatikleştirmeye yönelik çabalar araştırmacılar tarafından gösterilmiştir (11).

Yapılan son araştırmalar ise derin öğrenme algoritmalarını içeren yaklaşımların, tecrübeli bir ortodonti uzmanı ile karşılaştırıldığında doğruluk payının yüksek olduğunu ve sefalometrik tanı aşamasını hızlandırmak için kullanılabilirliğini göstermiştir (12-15).

Sefalometrik noktaları otomatik belirlemeye yönelik yapılan ilk girişim Cohen ve ark. tarafından 1984 yılında sella ve menton noktaları referans alınarak yapılmıştır (16). İlerleyen yıllarda, noktaların otomatik olarak belirlenmesi için farklı yapay zeka teknikleri kullanılarak üç grupta sınıflandırılmıştır. Bunlar; bilişim tabanlı sistemler, şablon eşleştirme ve istatistiksel modelleme yöntemleridir. Bu yöntemlerden istatistiksel modelleme, görüntü kalitesindeki değişimi dikkate aldığı için sefalogramlardaki değişikliklerin değerlendirilmesi için uygun seçeneklerden biri olarak kabul edilmiştir (17). Bu yöntemi kullanan araştırmaların birinde, anatomik yapıların tanımlanabileceği en düşük çözünürlüklü görüntüler ile otomatik ve manuel olarak anatomik nokta seçimi karşılaştırılmıştır. Araştırmacılar, manuel ve bilgisayarlı otomatik işaretleme sistemleri arasında 15 anatomik nokta arasında istatistiksel olarak anlamlılık olmadığını bildirmişlerdir (18).

Hye-Won Hwang ve ark.'nın son dönemde yaptığı araştırmalardan birinde yeni bir derin öğrenme yöntemi kullanılarak sefalometrik noktaların analizi çalışılmıştır. Araştırmada, test verisi olarak 200 sefalogram kullanılmış ve referans noktaları ortodonti uzmanı tarafından manuel olarak belirlenmiştir. Ardından, aynı noktalar başka bir ortodonti uzmanı ve yapay zeka tarafından değerlendirilmiştir. Yapay zeka başarı oranının %81,3 olduğu ve 19 anatomik noktanın 3'ünün belirlenmesinde ortodonti uzmanından daha başarılı sonuç gösterdiği bildirilmiştir. Bu sonucun daha önce yapılan yapay zeka çalışmalarından daha yüksek başarı oranı gösterdiği ve gözlemcilerle karşılaştırıldığında yapay zekanın bazı sefalometrik nokta tespitlerinde daha başarılı olduğu bildirilmiştir (19).

Anatomik noktaların belirlenmesi ve sefalometrik analiz yöntemleri yapay zeka yardımı ile iki boyutlu görüntüler üzerinde değerlendirilebildiği gibi üç boyutlu görüntüler üzerinde de çalışılabilmektedir. Lee ve ark. araştırmalarında kullandığı 7 anatomik nokta için ortalama sapmanın 1,5 mm olduğunu ve ortalama sapmanın üç boyutlu görüntülerde iki boyutlu görüntülerden daha düşük olduğunu bildirmişlerdir (20).

İSKELETSEL MATURASYONUN BELİRLENMESİ

Büyüme ve gelişim yönlendirilerek yapılan ortodontik tedaviler ile başarılı sonuçlar elde edebilmek için hastanın tedavi zamanlaması oldukça önemlidir. Bu hastaların büyüme durumuna, kronolojik ve iskelet yaşının beraber değerlendirilmesi ile karar verilebilir. Kronolojik yaşın ise her zaman iskelet yaşı ile tutarlı olmadığı görülmüştür. Bu nedenle, büyüme döneminin belirlenebilmesi için el-bilek radyografileri veya lateral sefalometrik radyografilerden sıklıkla faydalanılmaktadır (21,22).

Derin öğrenme ve yapay zeka teknolojilerinin iskelet yaşı tahmini yapabilmek için el-bilek radyografilerinin değerlendirilmesinde kullanıldığı görülmüştür. Derin öğrenme özelliği ile ırk, yaş, cinsiyet gibi büyük bir veri tabanı oluşturulmasının ardından radyografiler değerlendirilebilmektedir. Araştırmacılar, yapay zeka sistemlerinin iskeletsel maturasyonu radyoloji uzmanları kadar başarılı değerlendirebildiğini göstermiştir (23,24).

Çelik ve ark., el-bilek radyografilerinde kemik yaşını belirlemek için geliştirdikleri yapay sinir ağı sisteminde hata payını 0,52 yıl olarak bulmuşlardır. Sistem sayesinde uzmana ihtiyaç olmadan ve yüksek kaliteli görüntüler kullanılmadan kemik yaşı tayini yapılabildiğini bildirmişlerdir (25). İskeletsel maturasyonun değerlendirilmesi için servikal vertebraların kullanıldığı bir çalışmada yapay zeka algoritması ile bireylerin büyüme ve gelişim dönemleri tahmin edilmiştir. Araştırmacılar, 300 lateral sefalometrik radyografi üzerinde yedi farklı yapay zeka algoritmasını karşılaştırmıştır. Yapay sinir hücrelerinin oluşturduğu insan sinir sisteminin matematiksel modeli olan yapay sinir ağları algoritmasının daha iyi sonuçlar verdiğini ve gelecekteki uygulamalarda servikal vertebralar ile maturasyon evresini belirlemek için kullanılabilirliğini bildirmişlerdir (26). Başka bir çalışmada, Amasya ve ark. servikal maturasyon aşamalarını belirlemek için yapay zeka sistemi geliştirmiş ve sistemi gözlemci ile karşılaştırmışlardır. Ayrıca, aşamalandırmalar arasındaki başarıyı belirleyebilmek için 5 farklı makine öğrenme algoritmasını kullanmışlardır. Araştırmacılar, servikal vertebraları sınıflandırmada yapay sinir ağlarının gözlemciye daha yakın bir performans gösteren en başarılı model olduğunu bildirmişlerdir (27).

ÇEKİMLİ VEYA ÇEKİMSİZ TEDAVİ KARARI

Ortodontik tedavinin planlama aşaması tedavinin en önemli ve kritik aşamalarından biridir. Diş çekimli/çekimsiz tedavi kararı ve çekilecek dişin belirlenmesi tedavi planlamasının kilit noktasıdır. Çekim planlaması tüm tedavinin seyrini değiştireceğinden dikkatli bir şekilde yapılmalıdır. Diş çekimi kararı klinik muayene, teşhis fotoğrafları, dental modeller ve radyografilerin bütün olarak değerlendirilmesinin ardından klinisyenlerin tecrübeleri ile verilmektedir (3,8). Karar verme süreci için standart bir yaklaşımın olmaması farklı bir arayış gerektirmiştir. Son dönemlerde, tedavi planlamasını objektif bir şekilde yapabilmek için klinisyenlerin ortodontik diş çekimi kararını taklit etmeyi amaçlayan yapay sinir ağlarını kullandıkları görülmüştür.

Xie ve ark. araştırmalarında, ortodontik tedavi amacıyla diş çekiminin gerekli olup olmadığına karar vermek için yapay sinir ağı tabanlı bir yapay zeka modeli kullanmışlardır. Bu modelde, diş çekimi kararı verebilmek için 25 parametrenin

değerlendirilmesi yapılmıştır. Bu araştırmada oluşturulan yapay sinir ağının, 11-15 yaş arası bireylerde malokluzyonun çekimli/çekimsiz tedavi edilmesi kararını vermede %80 oranında başarılı olduğu görülmüştür. İlave olarak araştırmacılar, çekim kararını vermede etkili olan parametrelerin, yetersiz dudak kapanışına sahip ön dişler ve kesici mandibular plan açısı olduğunu, en az katkının ise Frankfurt horizontal düzlem-mandibular düzlem açısı olduğunu belirtmişlerdir (28).

Yapılan benzer bir araştırmada ise yapay zeka modelinin diş çekimli/çekimsiz tedavi kararını vermede %93 başarı gösterdiği bildirilmiştir. Araştırmacılar veri girişi için vakaların sagittal ve vertikal yön ilişkilerini, keser eksen eğimlerini, yumuşak doku özelliklerini, maksiller ve mandibular ark boyu sapmalarını ve molar dişlerin ilişkisini kullanmışlardır. Ayrıca araştırmacılar, maksiller/mandibular ve birinci/ikinci premolar dişlerden hangisinin çekiminin yapılacağına karar verme sürecinde başarı oranının %84 olduğunu bildirmişlerdir (29).

Li ve ark. çekimli/çekimsiz ortodontik tedavi kararı, çekimli tedavilerde hangi dişin çekim için uygun olduğu kararı ve nasıl bir ankrajın uygun olduğu kararını verebilmek için yapay sinir ağlarını kullanarak bir araştırma yapmışlardır. Araştırmacılar, her karar için verileri gruplandırmış ve üç aşamalı sinir ağı oluşturmuşlardır. İlk aşamada çekim ihtiyacını belirleyen ağ, eğer çekim gerekli ise aşamalı olarak ikinci ve üçüncü ağlara geçiş yapmıştır. Bu şekilde hastanın çekim modeli belirlenmiştir. Araştırma sonucunda, diş çekimli/çekimsiz ortodontik tedavi kararında başarı oranının %94, hangi dişin çekim için uygun olduğu kararında başarı oranının %84,3 ve ankraj kararının doğruluk oranının ise %92,8 olduğu bildirilmiştir. (30).

Mevcut araştırmalar, yapay zeka modellerinin ortodontik tedavi planlaması için yeni bir yaklaşım olarak kullanılabileceğini ve bu modellerin henüz klinik deneyimi az olan ortodonti uzmanlarının karar verme süreçlerinde referans olabileceğini göstermiştir.

ORTOGNATİK CERRAHİ KARARI

Ortognatik cerrahi ile kombine yapılan ortodontik tedavi prosedürleri, büyüme ve gelişimi tamamlanmış hastalarda iskeletsel bozuklukları düzeltmek amacıyla yapılan cerrahi yardımcı ortodontik tedavilerdir. Ortognatik cerrahi endikasyonu uygun görülen hastalarda sabit ortodontik tedavi ile var olan dental kompanzasyon dekompanse edilir. Bu şekilde, var olan malokluzyon daha şiddetli hale getirilmiş olur ve cerrahi operasyon ile elde edilen sonuç daha ideale yaklaşır. Bu sebeplerden ötürü ortognatik cerrahiye karar vermede tedavi planlaması önemli bir yere sahiptir (8).

Choi ve ark., yapay zeka teknolojisini kullanarak ortognatik cerrahi kararı ve diş çekimi belirleme yeteneği olan bir yapay zeka modeli geliştirmiş ve bu modelin performansını değerlendirmişlerdir. Araştırmada kullanılan örneklem bir ortodonti uzmanı tarafından oluşturulmuştur. Yapay sinir ağının girdi değerleri lateral sefalometrik film üzerinden ve overjet, overbite, ark boyu sapmaları, molar kapanışı, hastanın başlıca şikâyeti, yumuşak doku profili gibi parametrelerin değerlendirilmesi ile oluşturulmuştur. Oluşturulan modelin başarısı ortognatik cerrahi kararı için %96, operasyon tipi ve diş çekimi kararı için %91 oranında bulunmuştur. Araştırmacılar elde ettikleri verilere bakarak ortognatik cerrahi vakalarının teşhisi için yapay sinir ağı makine öğrenmesi modelinin uygulanabileceğini bildirmişlerdir (31).

Lee ve ark. sefalometrik radyografiler kullanarak derin öğrenme algoritması ile ortognatik cerrahi ve ortodontik tedavinin ayırıcı tanısı için bir yapay zeka modellemesi yapmışlardır. Ayrıca, üç farklı derin öğrenme modelinin performansını değerlendirmeyi amaçlamışlardır. Ortognatik cerrahi endikasyonu için sefalometrik radyografi tabanlı ayırıcı tanıya yönelik derin evrişimli sinir ağları %95,4-%96,4 gibi yüksek bir başarı oranı göstermiştir. Bu araştırma, sefalometrik radyografilerin derin evrişimli sinir ağları tabanlı analizinin ortognatik cerrahi endikasyonu ayırıcı tanısı için başarıyla uygulanabileceğini düşündürmektedir (32).

YÜZ ORANLARININ DEĞERLENDİRİLMESİ

Yüz analizi oluşturulması, yüz yapıları arasındaki oranların ve doğrusal uzunlukların ölçülmesine dayanır. Lateral sefalometrik filmler ve profil fotoğrafları doğrusal değerlendirmeler için yaygın olarak kullanılmasına rağmen büyütme farklılıklarının olmasından dolayı hassas ölçüm yapılması zordur (3). Bununla birlikte, ideal yüz estetiği algısının öznel bir kavram olması ve geçerli bir kurallar dizisinin olmaması nedeniyle toplumun güzellik algısını yansıtmada bazı eksikliklere sahip olduğu görülmüştür (33,34). Günümüzde ise yapay zeka uygulamalarının yüz verilerinin analizi ve yorumlanması gibi karmaşık görevleri simüle edebilecek kadar olgunlaştığı görülmüştür (34,35).

Ortodonti alanında, tanı evresini kolaylaştırabilmek amacıyla yapılan bir araştırmada derin öğrenme yapay zeka modeli kullanılarak yüz ve maksillomandibular oran değerlendirmeleri için hastaların yüz görünümüne dayalı bir yapay zeka veri tabanı oluşturulmuştur. Oluşturulan modelde hastaların mandibula ve yüz değerlendirmesi için etiketlemeler kullanılmıştır. Araştırmacılar, yüz özelliklerinin objektif olarak değerlendirilmesini sağlayan tanısal görüntülemeyi otoma-

tikleştirmeyi amaçlamışlar ve otomatik tanısal görüntüleme sisteminin değerlendirme için gereken süreyi önemli ölçüde azalttığını, objektif teşhis sağlanmasına yardımcı olduğunu bildirmişlerdir (36).

Ortodonti ve ortognatik cerrahi uygulamalar ile fonksiyonel ve estetik bozukluklar giderilebilmektedir. Ortognatik cerrahi ile yapılan tedavinin estetik sonuçlarını ve yumuşak doku oranlarında görülen değişimleri değerlendiren araştırmalarda uzman hekimlerin veya hastaların subjektif değerlendirmeler ile puanlama yaptıkları görülmüştür. Son dönemlerde, yapay zeka teknolojisinin insan algısını taklit ederek değerlendirmeler yapabilme ve karmaşık bilişsel görevleri yerine getirmede ilerleme kaydettiği görülmüştür. Yapay zeka uygulamaları, ilgili kavramları ve görüşleri yansıtan algoritmalar üzerinden yüz görünümünü, çekiciliğini nesnel ve tekrarlanabilir bir şekilde değerlendirmeye olanak sağlayabilmektedir. Bu nedenle özellikle cerrahi operasyon geçiren hastalarda tedavinin klinik sonuçlarını yapay zeka ile değerlendirme düşüncesi oluşmuştur (35,37).

Patcas ve ark. araştırmalarında ortognatik cerrahinin yüz çekiciliği ve bireylerin yaş görünümü üzerindeki etkisini yapay zeka kullanarak değerlendirmişlerdir. Araştırma algoritması olarak büyük bir veri kümesinde doğrulanmış bilgiler kullanılmıştır. Retrospektif olarak, tek bir merkezde ortognatik cerrahi ile tedavi edilmiş hastaların tedavi öncesi, sonrası fotoğrafları ve her hasta ile ilgili veriler toplanmıştır. Her görüntü için yüz çekiciliği, görünen yaş değerlendirmesi tedavi öncesi ve sonrası olarak yapılmıştır. Algoritmaya göre, ortognatik cerrahi ile hastaların %66,4'ünün görünümünün iyileştiği, ortalama 0,93 yıl daha genç bir görünüme sahip olduğu ve çekicilik üzerinde %74,7 oranında faydalı bir etkiye sahip olduğu sonucuna varılmıştır (35).

SONUÇ

Yapay zeka teknolojisinin son dönemde hızlı bir ilerleme göstermesi ile yeni ve farklı alanlarda kullanılmaya başlandığı görülmüştür. Sağlık alanında ise çok fazla işlenebilir hazır verinin olması, bu teknolojideki ilerlemeyi hızlandıran etkenlerden biri olmuştur. Diş hekimliği ve ortodonti alanında teşhis ve tedavi planlaması aşamasında yapay zeka uygulamaları kullanılmıştır. Yapay zeka modellerinin ortodontik tedavinin tanı, tedavi planlama ve tedavi takip aşamalarında uzman hekimler tarafından harcanan yükü, zamanı azaltması ve ikinci bir görüş sağlama açısından oldukça başarılı olduğu görülmüştür. Ayrıca araştırmalar ile oluşturulan algoritmalar sayesinde ileride yapay zeka uygulamalarının sağlık alanında daha yaygın ve işlevsel şekilde kullanılabileceği düşünülmektedir.

KAYNAKLAR

1. Russell S, Norvig P. (2010). Artificial Intelligence A Modern Approach. (3rd ed.). New Jersey: Pearson Education.
2. Wong S, Al-Hasani H, Alam Z, Alam A. Artificial intelligence in radiology: how will we be affected? *European Radiology*, 2019; 29(1), 141-143.
3. Akdeniz BS, Tosun ME. A review of the use of artificial intelligence in orthodontics. *Journal of Experimental and Clinical Medicine*, 2021; 38(2), 157-162.
4. Shan T, Tay F, Gu L. Application of artificial intelligence in dentistry. *Journal of Dental Research*, 2021; 100(3), 232-244.
5. Nilsson NJ, Nilsson NJ. (1998). Artificial intelligence: A new synthesis. (1st ed.). Morgan Kaufmann Publishers.
6. Faber J, Faber C, Faber P. Artificial intelligence in orthodontics. *Journal of the Asian Pacific Orthodontic Society*, 2016; 9, 201-205.
7. Yılmaz A. 2020. Yapay zeka nedir? Aksan G, (Ed.), *Yapay Zeka* (1-22). İstanbul: KODLAB.
8. Küçük EB, Akdoğan EG. (2021). Up-to-Date Artificial Intelligence In Orthodontics. Cem Evereklioğlu (Ed.), *Research & Reviews in Health Sciences-II*, (69-92). Ankara: Gece Publishing.
9. Kattadiyil MT, Mursic Z, AlRumaih H, Goodacre CJ. Intraoral scanning of hard and soft tissues for partial removable dental prosthesis fabrication. *Journal of Prosthetic Dentistry*, 2014; 112, 444-448.
10. Miller R, Dijkman D, Riolo M, Moyers R. Graphic computerization of cephalometric data. *Journal of Dental Research*, 1971; (50)5, 1363.
11. Hutton TJ, Cunningham S, Hammond P. An evaluation of active shape models for the automatic identification of cephalometric landmarks. *European Journal Orthodontics*, 2000; 22(5), 499-508.
12. Park J, Hwang H, Moon J, Yu Y, Kim H, Her S. Automated identification of cephalometric landmarks: part 1-comparisons between the latest deep-learning methods YOLOV3 and SSD. *Angle Orthodontist*, 2019; 89(6), 903-909.
13. Montúfar J, Romero M, Scougall-Vilchis RJ. Automatic 3-dimensional cephalometric landmarking based on active shape models in related projections. *American Journal of Orthodontics and Dentofacial Orthopedics*, 2018; 153, 449-458.
14. Montúfar J, Romero M, Scougall-Vilchis RJ. Hybrid approach for automatic cephalometric landmark annotation on cone-beam computed tomography volumes. *American Journal of Orthodontics and Dentofacial Orthopedics*, 2018; 154, 140-150.
15. Kunz F, Stellzig-Eisenhauer A, Zeman F, Boldt J. Artificial intelligence in orthodontics: Evaluation of a fully automated cephalometric analysis using a customized convolutional neural network. *Journal of Orofacial Orthopedics*, 2020; 81, 52-68.
16. Cohen AM, Ip HH, Linney AD. A preliminary study of computer recognition and identification of skeletal landmarks as a new method of cephalometric analysis. *British Journal of Orthodontics*, 1984; 11(3), 143-154.
17. Rueda S, Alcañiz M. An approach for the automatic cephalometric landmark detection using mathematical morphology and active appearance models. *Medical Image Computing and Computer-Assisted Intervention: MICCAI International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2006; 9(1), 159-166.
18. Rudolph DJ, Sinclair PM, Coggins JM. Automatic computerized radiographic identification of cephalometric landmarks. *American Journal of Orthodontics and Dentofacial Orthopedics*, 1998; 113(2), 173-179.
19. Hwang HW, Moon JH, Kim MG, Donatelli RE, Lee SJ. Evaluation of automated cephalometric analysis based on the latest deep learning method. *The Angle Orthodontist*, 2021; 91(3), 329-335.
20. Lee SM, Kim HP, Jeon K, Lee SH, Seo JK. Automatic 3D cephalometric annotation system using shadowed 2D image-based machine learning. *Physics in Medicine and Biology*, 2019; 64(5).

21. Baccetti T, Franchi L, McNamara JAJ. An improved version of the cervical vertebral maturation (CVM) method for the assessment of mandibular growth. *The Angle Orthodontist*, 2002; 72(4), 316-323.
22. Franchi L, Baccetti T, De Toffol L, Polimeni A, Cozza P. Phases of the dentition for the assessment of skeletal maturity: a diagnostic performance study. *American Journal of Orthodontics and Dentofacial Orthopedics*, 2008; 133(3), 392-395.
23. Lee H, Tajmir S, Lee J, Zissen M, Yeshiwias BA, Alkasab TK, Choy G, Do S. Fully automated deep learning system for bone age assessment. *Journal of Digital Imaging*, 2017; 30(4), 427-441.
24. Larson DB, Chen MC, Lungren MP, Halabi SS, Stence NV, Langlotz CP. Performance of a deep-learning neural network model in assessing skeletal maturity on pediatric hand radiographs. *Radiology*. 2018; 287(1), 313-322.
25. Çelik H, İçer S. Çocuklarda Yaş Tayini İçin Yapay Sinir Ağlarının Kullanıldığı Yeni Bir Yöntem. *24th Signal Processing and Communication application Conference (SIU)*, 2016; 1189-1192.
26. Kök H, Acilar AM, İzgi MS. Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. *Progress in Orthodontics*, 2019; 20(1), 41.
27. Amasya H, Cesur E, Yıldırım D, Orhan K. Validation of cervical vertebral maturation stages: Artificial intelligence vs human observer visual analysis. *American Journal of Orthodontics and Dentofacial Orthopedics*, 2020; 158(6), 173-179.
28. Xie X, Wang L, Wang A. Artificial neural network modeling for deciding if extractions are necessary prior to orthodontic treatment. *The Angle Orthodontist*, 2010; 80(2), 262-266.
29. Jung SK, Kim TW. New approach for the diagnosis of extractions with neural network machine learning. *American Journal of Orthodontics and Dentofacial Orthopedics*, 2016; 149(1), 127-133.
30. Li P, Kong D, Tang T, Su D, Yang P, Wang H. Orthodontic treatment planning based on artificial neural networks. *Scientific Reports*, 2019; 9, 2037.
31. Choi, HI, Jung SK, Baek SH, Lim WH, Ahn SJ, Yang IH, Kim TW. Artificial Intelligent Model With Neural Network Machine Learning for the Diagnosis of Orthognathic Surgery. *The Journal of Craniofacial Surgery*, 2019; 30(7), 1986-1989.
32. Lee KS, Ryu JJ, Jang HS, Lee DY, Jung SK. Deep Convolutional Neural Networks Based Analysis of Cephalometric Radiographs for Differential Diagnosis of Orthognathic Surgery Indications. *Applied Sciences*, 2020; 10(6), 2124.
33. Knight H, Keith O. Ranking facial attractiveness. *European Journal Orthodontics*, 2005; 27, 340-348.
34. Yu X, Liu B, Pei Y, Xu T. Evaluation of facial attractiveness for patients with malocclusion: A machine-learning technique employing Procrustes. *Angle Orthodontics*, 2014; 84, 410-416.
35. Patcas R, Bernini DAJ, Volokitin A, Agustsson E, Rothe R, Timofte R. Applying artificial intelligence to assess the impact of orthognathic treatment on facial attractiveness and estimated age. *International Journal of Oral Maxillofacial Surgery*, 2019; 48, 77-83.
36. Murata S, Lee C, Tanikawa C, Date S. Towards a Fully Automated Diagnostic System for Orthodontic Treatment in Dentistry. *2017 IEEE 13th International Conference on e-Science (e-Science)*, 2017; 1-8.
37. Soğancı B, Tağrikulu B. (2021). Yapay zekânın ortodontideki kullanım alanları ve güncel yaklaşımlar. Cura N, (Ed.), *Pandemi Sürecinde Ortodonti: "Dijital Ortodonti" ve "Tele Ortodonti"* (66-74). Ankara: Türkiye Klinikleri.