





Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Skolyoz İçin Kapsül Ağları Tabanlı Otomatik Ölçüm Sistemi

 Sena GORAL ^a,  Utku KÖSE ^{b,*}

^a *Bilgisayar Teknolojisi ve Programlama Bölümü, Ağlasun Meslek Yüksekokulu, Mehmet Akif Ersoy Üniversitesi, Burdur, TÜRKİYE*

^b *Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Süleyman Demirel Üniversitesi, Isparta, TÜRKİYE*

* Sorumlu yazarın e-posta adresi: utkukose@sdu.edu.tr

DOI:10.29130/dubited.919890

ÖZ

Skolyoz, omurganın eğrilmesi ile birlikte omurga genel yapısını deforme eden bir hastalıktır. Skolyoz tanısı ve tedavi aşamasında çeşitli yöntemler olmakla birlikte, temel amaç Cobb açısı adı verilen eğrilik açısını azaltarak Skolyoz seviyesini düşürme çerçevesinde şekillenmektedir. Cobb açısı ölçümü esnasında uzman tarafından, omurga röntgen filmleri üzerinde manuel olarak gerçekleştirilmektedir. Ancak bu sürecin derin öğrenme gibi bir Yapay Zeka yaklaşımıyla otomatikleştirilmesi hem hasta hem de uzman açısından büyük kolaylık ve kesinlik sağlayacaktır. Açıklamalardan hareketle bu çalışmada, öncelikli olarak Skolyoz ve derin öğrenme odaklı çalışmalar açısından literatürün güncel durumu ele alınmış, ardından Kapsül Ağları (CapsNet) tabanlı bir çözüm ile Cobb açısı ölçümlerinin otomatik bir hale getirilmesi sağlanmıştır. CapsNet çözümünün, ConvNet, BoostNet, RFR ve ResNet-50 modelleri ile karşılaştırılması neticesinde en iyi bulguları CapsNet modelinin verdiği tespit edilmiştir.

Anahtar Kelimeler: Skolyoz, Omurga eğriliği, Cobb açısı, Kapsül ağları, CapsNet, Derin öğrenme

Capsule Networks Based Automatic Measurement System for Scoliosis

ABSTRACT

Scoliosis is a disease that deforms the general spine structure as a result of curvature of the spine. Although there are various methods in the diagnosis and treatment of the Scoliosis, the main purpose is to reduce the curvature angle, which is called as Cobb angle, within the framework of reducing the level of Scoliosis. Cobb angle measurement is essentially performed manually on the spine x-rays by the expert. However, automating this process with an Artificial Intelligence approach such as deep learning will provide great convenience and precision for both patient and the expert. Based on the explanations, the current status of the literature in terms of Scoliosis and deep learning-focused studies was firstly discussed in this study, and then the Cobb angle measurements were automated with a Capsule Network (CapsNet)-based solution. As a result of the comparison of the CapsNet solution with the ConvNet, BoostNet, RFR and ResNet-50 models, it was determined that the CapsNet model gave the best findings.

Keywords: Scoliosis, Spinal curvature, Cobb angle, Capsule networks, CapsNet, Deep learning

*Bu çalışma 'Scroth Yöntemiyle Skolyoz Tedavisi İçin Derin Öğrenme Tabanlı Bir Sistem Geliştirilmesi' isimli doktora tezinden türetilmiştir.

I. GİRİŞ

Skolyoz hastalığı, günümüzde pek çok insanda görülmesine rağmen, hakkında yeterli düzeyde bilincin sağlanamadığı; omurgadaki 'S' ya da 'C' şeklinde eğrilmeler neticesinde omurga yapısının deforme olması olarak bilinmektedir [1-4]. Omurgada meydana gelen söz konusu eğrilikler birçok olumsuz sonucu beraberinde getirmektedir. Skolyoz tanısı alan kişilerde genellikle sırtta eğrilik, kamburluk, dik duruşta zorluk, omuz düşüklükleri gibi şikayetlerin söz konusu olması ve yine vücut görünüşünde asimetric bozukluklar / deformasyon gibi görsel durumlar da yaygın durumdadır [5, 6]. Uzmanlar Skolyoz teşhisi aşamasında, hiçbir testi gerçekleştirmeden açık bir şekilde tanıyı koyabilmekte ya da manuel olarak değerlendirmeler neticesinde sırt bölgesindeki eğriliğin, öne ya da arkaya doğru yönelmesinden fark edebilmektedir. Ancak bazı bireylerde Skolyoz durumu bu denli açık bir şekilde görülememektedir. Bu bağlamda uzmanlar Skolyoz hastalığının olup olmadığını çeşitli kontroller ve röntgen filmlerinin incelenmesi sonucunda kesin olarak anlayabilmektedir. Ancak uzman odaklı teşhis aşamalarında da sonuçların uzmandan uzmana farklılıklar göstermesi yaygın bilinen bir dezavantajdır.

Skolyoz'un tedavisi hakkında yorum yapabilmek ve hastalığın seviyesini anlayabilmek için omurga eğriliğini belirleyen derecenin Cobb yöntemi ya da Ferguson yöntemi kullanılarak tespit edilmesi oldukça önemlidir [7]. Bu noktada, günümüzde genellikle Cobb açısı yönteminin kullanıldığını söylemek mümkündür. Skolyoz'un teşhis ve tedavi aşamasında farklı yöntemler olsa da öncelikli amaç bu açıya bağlı olarak gerekli cerrahi ya da cerrahi olmayan müdahaleyi yapabilmektir. Literatürde Skolyoz'un teşhis ve tedavi aşamalarında çeşitli yöntemler geliştirilmiştir. Bunlardan bazıları Schroth, Dobomed, Lyonnaise, Side Shift gibi isimler almıştır [8]. Geliştirilen tekniklere bakıldığında birçoğu bu alanda özel eğitim ve sertifikasyonlara gerek duymaktadır. Skolyoz'un teşhisi aşamasında uzmanın manuel kontrolü, skolyometre ile derece ölçümleri üzerinden yapılmaktadır. Ancak kesin tanı röntgen görüntülerinden anlaşılmaktadır. Bu görüntülerden eğriliğin bölgesi ve derecesi değerlendirilmektedir. Dolayısıyla özellikle teşhis süreci genel olarak manuel müdahaleleri gerekli kılmaktadır. Ancak bütün bu teşhis süreçlerin bilgisayar destekli gerçekleştirilmesi, sayısal algoritmaların ve sağlık alanının uzun yıllardan söz konusu olan etkin birlikteliğinin bir gerekliliği olarak gün yüzüne çıkmaktadır. Hali hazırda Yapay Zeka ve görüntü işleme taraflı çözümlerin zaman ve kaynaktan sağladığı kazançlar, Skolyoz hastalığı için de teşhisin otomatikleştirilmesi yaklaşımını zamanında bir çözüm olarak desteklemektedir. Bu bağlamda, açı ölçümünün derin öğrenme gibi bir Yapay Zeka yaklaşımıyla otomatikleştirilmesi hem hasta hem de uzman açısından büyük kolaylık ve kesinlik sağlayacaktır. Yapay Zeka'nın tarihsel süreci incelendiğinde, özellikle 2000'li yıllarda etkinliği giderek artan derin öğrenme tekniklerinin en kritik sağlık teşhis uygulamalarında bile başarılı sonuçlar ortaya koyduğu görülebilmektedir [9-12]. Özellikle görüntü verilerinin hassas analizi noktasında geleneksel makine öğrenmesi çözümlerine göre daha başarılı bulgular ortaya koyan derin öğrenme tabanlı çözümler, tümör tespiti, beyin kanaması teşhisi, göz hastalıklarının erken tahmini ve daha birçok farklı sorunun otomatik bir biçimde ele alınması aşamalarında etkin yaklaşımlar tasarlanmasına olanak sağlamaktadır [13-18].

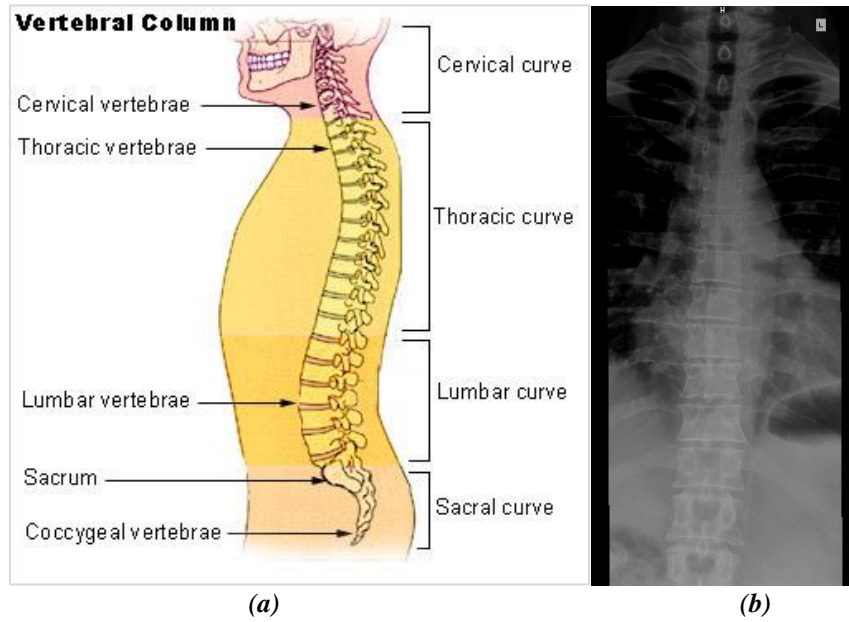
Açıklamalardan hareketle bu çalışmada öncelikli olarak Skolyoz ve derin öğrenme odaklı çalışmalar açısından literatürün güncel durumu ele alınmış, ardından Kapsül Ağları (CapsNet: Capsule Network) tabanlı bir çözüm ile Cobb açısı ölçümlerinin otomatik bir hale getirilmesi amaçlanmıştır. Yapay Zeka ve günümüzde etkinliği nedeniyle en çok tercih edilir makine öğrenmesi alt-alanı olan derin öğrenme, özellikle görüntü tabanlı sağlık verilerinde oldukça başarılı sonuçlar ortaya koymaktadır [19-22]. Verileri entegre özellik çıkartım mekanizmalarıyla ve detaylı analiz süreçleriyle ele aldıkları için oldukça yaygınlaşmış durumdaki derin öğrenme teknikleri arasında özellikle görüntü tabanlı sınıflandırma, nesne tespiti ve segmentasyon (görüntü bölütleme) problemlerinde başarılı sonuçlarıyla tanınan Evrişimsel Sinir Ağları (CNN: Convolutional Neural Networks) modellerine alternatif olarak tanıtılan CapsNet, CNN modellerinde ortaklama (pooling) taraflı ortaya çıkan ve görüntüdeki yer değiştiren unsurlardan dolayı çıktılarda uzun vadede tanınma problemlerine yol açan sıkıntıları kapsül adı verilen yapılar üzerinden çözmesi nedeniyle CNN tekniğine göre daha etkin bir çözüm olarak kabul görmüştür [23, 24]. Bu durumdan hareketle CapsNet'in literatürde Skolyoz için henüz kullanılmamış olması nedeniyle omurga röntgen filmleri üzerinden otomatik Cobb açısı ölçümü için

etkin bir çözüm olacağı düşünülmüştür. Böylelikle etkili bir alternatif çözüm ile açı ölçüm çözümlerine yönelik güncel bir katkı sağlanması çalışma açısından önemli bir motivasyon kaynağı olmuştur.

II. SKOLYOZ (OMURGA EĞRİLİĞİ)

A. İNSANLARDA OMURGA YAPISI

İnsan vücudu bir sistem olarak çok çeşitli bileşenlerin birbiriyle eşgüdümlü çalışmasına ihtiyaç duymaktadır. Sistem içerisindeki farklı organlar hayati süreçlerin sürmesinden sorumlu iken, iskelet yapının da vücudun fiziksel eylemleri yerine getirmesini, iç organların korunmasını ve vücudun belli bir formda kalmasını sağlama konusunda görevlere odaklanmaktadır. Dolayısıyla iskelet sisteminin sağlıklı olması insan vücudu için hayati olmakla beraber, özellikle vücudun dik durmasını ve hassas eylemlerin yerine getirilmesini sağlayan omurga da iskelet yapının özelinde ayrı bir kritik öneme sahiptir. İnsan vücudu incelendiği zaman omur sayısının 33 adet olduğu görülmektedir. Bu omurlar insanın kafatasının altından başlayarak, kuyruk sokumuna kadar devam etmektedir. İnsanın dik bir gövdeye sahip olmasını sağlayan bu omurlar birbiriyle bağlantılı olarak devamlı ve bütün bir yapıyı da oluşturmaktadır.




Şekil 1. İnsanda omurga yapısı: (a) genel anatomik görünüm [25] ve (b) 57 yaşında bir erkeğe ait omurga röntgeni [26].

Söz konusu omurga yapısı daha detaylı olarak incelendiğinde 7 adet boyun omurunun olduğu, 12 adet sırt omurunun olduğu ve 5 adette bel omurunun olduğu görülmektedir. Bel omurlarının devamında da yine omurlar birleşerek omurganın en alt kısımları olarak kabul edilen kuyruk sokumu ve büyük üçgen şekilli kemik olan sakrum kemiklerini oluşturmaktadır. Tüm bu birleşimler sonucunda omurga sağa ya da sola frontal ve sagittal düzlemde 'S' şekline gelmektedir. Normal koşullar altında omurganın ideal konumlanması söz konusu doğrultuda olması gerekirken, bu aşamada varsayılan eşikleri geçen çeşitli eğrilikler de görülebilmektedir. Omurgada aşırıya kaçan bu eğriliklerin oluşması halk arasında omurga eğriliği olarak da bilinen Skolyoz hastalığının göstergesi olmaktadır. Skolyoz omurga ve iskelet sisteminin sağlığını doğrudan tehdit eden bir hastalık olarak bilinmektedir. Kendi içerisinde çeşitli türlere ve dolayısıyla farklı teşhis ve tedavi süreçlerine tekabül eden Skolyoz hastalığının detaylıca irdelenmesi bu nedenle oldukça önemlidir.

B. SKOLYOZ HASTALIĞI

Günümüzde ciddi fiziksel rahatsızlıklardan biri olan Skolyoz, farklı nedenlerden kaynaklanabilmektedir. Bununla birlikte Skolyoz'a sahip bireylere bakıldığında yaklaşık yüzde sekseninin nedeni bulunamamakta ve bu durumdaki Skolyoz haline de İdiyopatik Skolyoz denilmektedir [5, 8, 27]. Geri kalan kısmında problem ise genel olarak duruş bozukluklar, nörolojik ve ortopedik problemlerden kaynaklı oluşmaktadır. Risk faktörleri de genetik yatkınlık, uzun süreli hareketsizlik ve tek taraflı aktiviteler sayılabilmektedir [5, 6, 28]. Skolyoz tanısı alan kişilerin doktora başvuru nedeni genelde sırtta eğrilik, dik durmakta zorlanma, kamburluk, kaburga kemiklerinin bir tarafta çıkıntılı olması, dik durulduğunda kolların gövdenin iki yanında eşit sarkmaması, bir omuzun düşük olması, bir taraf kürek kemiğinin çıkıntılı olması gibi dış görünüşteki asimetridir. İlk saptama için omuz ve pelvis eşitsizliği bir ölçüt olarak kabul edilir. Daha sonra test için kol eşitsizliğine bakılır, bununla birlikte scapulanın omurgaya olan uzaklığı ölçülmektedir[29]. Buradaki Skolyoz'un tespitinde yön gösterici olmaktadır. Buna Kipler Testi de denilmektedir. Ancak yapılan testler tam olarak kesin sonucu verememektedir. Kesin tanı ve omurga eğrilik açısı röntgen görüntülerinin detaylı incelenmesi sonucunda belirlenebilmektedir.




Şekil 2. Skolyoz hastalığı olan bir omurgaya dair röntgen görüntüleri [30].

Skolyoz tedavi aşamalarını bireyi belirli aralıklarla gözlemlemek, korse kullanımı, fizik tedavi ve rehabilitasyon uygulamaları ve ameliyat olarak gruplandırmak mümkündür. Skolyoz tedavisinde asıl amaç eğrilik ilerlemesini engellemektir. Erken dönemde korse kullanılması ya da fizik tedavi ve egzersiz yöntemleri uygulanabilmektedir. Skolyoz'u ilerleyen hastalarda, omurganın hareketiyle akciğer daralabilmekte ve nefes alımı zorlaşabilmektedir. Bu tür hastalarda ameliyat gerekmektedir [31,32]. Cerrahi müdahale haricinde uzman eşliğinde gerçekleştirilen çeşitli egzersizlerle Skolyoz'un ilerlemesi durdurulabilmekte ya da derecesi azaltılabilmektedir. Her birey için uygulanan egzersizler ayrı ve özel olması gerekmektedir. Bunun sebebi her bireydeki deformasyonun farklılık göstermesidir.

Skolyoz söz konusu olduğunda gerçekleşmesi gereken en önemli aksiyonlardan biri de eğriliğin tanımlanmasıdır. Bunun için açı ölçümü yapılmaktadır. Bu uygulama için de bazı bilgilerin tespiti gerekmektedir. Eğriliğin olduğu bölge, yönü, tek ya da çift olma durumu, tepe noktası, başlangıç ve bitiş seviyeleri belirtilmelidir. Bu kapsamda Skolyoz derecesini ölçmek için röntgen filmi en etkin bulgu aracı olarak bilinmektedir. Normal bir bireyde omurga, kuyruk kemiğinden kafatasına kadar düz bir hat izlemelidir. Düz bir çizgi şeklinde olması gereken omurga sağa ya da sola doğru bir yönelme gösteriyorsa bu anormal bir durumdur. Söz konusu omurganın röntgen filminde görülen en küçük bir eğrilik Skolyoz anlamına gelmemektedir. Bu nedenle teşhis süreci oldukça kritik bir aşama olarak bilinmektedir.

B. 1. Cobb Açısı Ölçümü

Skolyoz derecesi olarak ifade edilen terim genellikle Cobb açısı olarak adlandırılmıştır. Bu ölçüm yöntemi alternatif süreçlerle de desteklenmiş olsa da genel olarak şöyle açıklanabilmektedir [33-35]: Öncelikli olarak, omurgada eğriliğin üst ve alt ucunu oluşturan kemikler tespit edilmektedir. Bunlar yatay düzleme göre en fazla eğim yapmış kemiklerdir. Tespit sonrasında, üst uçtaki omurun üst kenarından ve alt uçtaki omurun alt kenarından bu kenarlara paralel çizgiler çizilmektedir. Daha sonra bu çizgilere dik açı yapan çizgiler çizilerek iki dik arasındaki açı ölçülmektedir. Cobb açısı denilen bu açı Skolyoz derecesini göstermektedir. Kişide birden fazla eğrilik varsa her eğrilik için ayrı ayrı Cobb açısı ölçülmesi gerekebilmektedir. Bu bağlamda, derecesi büyük olana major eğrilik, küçük olana ise minör eğrilik adı verilmektedir. Orta hattan en fazla uzaklaşmış omur kemiği apeks (tepe) olarak tanımlanmaktadır. Skolyoz eğriliği tanımlanırken net olmak için alt ve üst uç omurlar, tepe omur seviyesi, eğriliğin yönü ve derecesi belirtilmelidir. Cobb açısı ölçümü yaygın düzeyde uzmanların incelemeleri sonucu belirlendiği için ölçüm yapan uzmanlar arasında farklılıkların olması muhtemeldir. Bu nedenle uzman ölçümü mükemmel hassasiyete sahip bir yöntem değildir. Dolayısıyla ölçümün sayısal sistemler ve algoritmalarla desteklenmesi ideal bir alternatif olarak dikkat çekmektedir.



Şekil 3. Skolyoz teşhisinde Cobb açısı ölçümü: (a) Genel ölçüm prensibi [36] ve (b) Röntgen üzerinde yapılmış bir ölçüm [37].

Anlaşılacağı üzere bilgisayar destekli ölçüm süreçleri birtakım özel yazılımlar ortamında yapılabilmektedir. Ancak bu tür yazılımlar yine uzman tarafından kullanılmakta ve hali hazırda görüntü işleme taraflı çözümlerle karşılaştırıldığında manuel müdahaleler gerektiren araçlar olarak kabul edilmektedir. Bu durum zamanın etkin kullanımı açısından düşünüldüğünde uzmanlar açısından dezavantaj oluşturabilmekte, yine hastalar açısından da hızlı ve objektif teşhise olan ihtiyaca tam anlamıyla cevap verememektedir. Bu sebeplerden ötürü literatürde çeşitli otomatik çözümler geliştirilmesi yönünde çalışmalar gerçekleştirilmiş ve görüntü işleme süreçlerinde etkin çözüm üreten derin öğrenme teknikleri, Yapay Zeka literatüründen gelen bir çözüm olarak yaygın kabul görmüştür.

III. SKOLYOZ HASTALIĞINA KARŞI DERİN ÖĞRENME

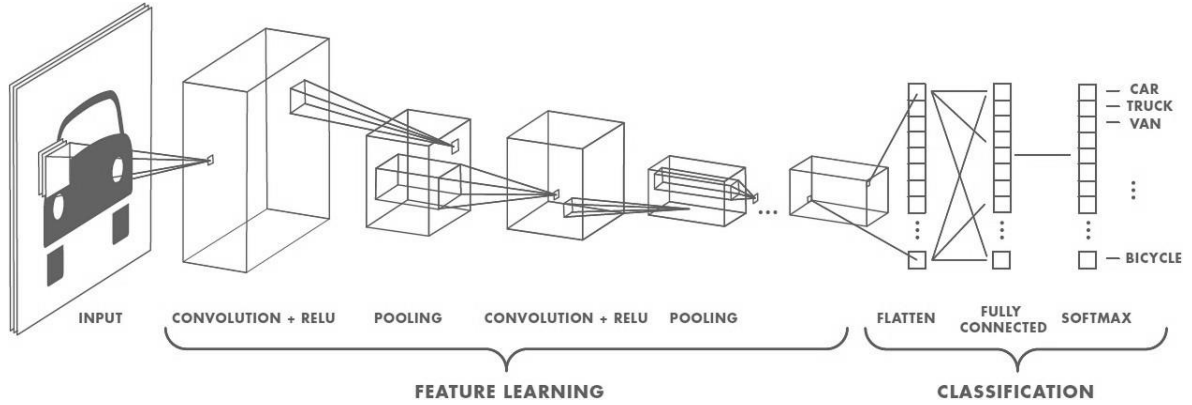
Literatür incelendiğinde Skolyoz üzerine derin öğrenme temelli farklı çalışmalarında yapıldığı görülmektedir. Horng vd. çalışmasında omurga röntgenlerini kullanarak omurga eğriliğini ölçmek için otomatik bir sistem gerçekleştirmişlerdir. Evrişimsel Sinir Ağları (CNN) tekniği kullanarak omurları bölümlere ayırmışlar ve Cobb açısı kriterine göre omurga eğriliğini ölçmüşlerdir. Sonuçlar uzmanların ölçümleriyle karşılaştırılmış ve büyük farkların olmadığı görülmüştür. Sistem Skolyoz şiddetinin daha iyi anlaşılabilmesi ve klinik tedaviler için doktorlara yardımcı olmak için tanı aşamasında kullanılabilmesi için gerçekleştirilmiştir[36]. Söz konusu çalışma Skolyoz tespitinde CNN ve uzman karşılaştırılmasının gösterilmesi bakımından oldukça önemlidir. Diğer yandan, Pan vd. çalışmalarında röntgen görüntüleri üzerinde otomatik ölçüm yaklaşımı izleyen iki mask R-CNN modelinin yer aldığı bir çözüm önermişlerdir [38]. Çalışmalarını genel olarak 248 görüntü üzerine yoğunlaşan bir uygulama çerçevesinde gerçekleştirmişlerdir. Çalışma, R-CNN ile etkin otomatik ölçüm yaklaşımı sunmuştur. Zhang vd. çalışmasında Skolyoz'un değerlendirilmesi için Cobb açısı ölçümünün değişkenliğini azaltabilmek adına bilgisayar destekli bir sistem geliştirmek için yöntem geliştirmişlerdir. Derin sinir ağını eğiterek açısı hesabını gerçekleştirmişler; bu kapsamda 40 model radyografilerin incelenmesi sağlanmıştır. Derin sinir ağının eğitilmesi sonucunda görüntüler üzerindeki tespitler ve manuel ölçümler kontrol edilmiş ve aralarındaki farkın azaltılabileceği belirtilmiştir [39]. Choi vd. ise ergen İdiyopatik Skolyoz üzerine görüntülerin harelisi olması durumunda Evrişimsel Sinir Ağı modeli (CNN) kullanarak omurga konumlarını tahmin edebilen ve daha sonra tahmini omurga deformasyonunu otomatik olarak tarayabilen bir sistem geliştirmek için çalışmışlardır. Söz konusu çalışma alternatif veri yapıları üzerine olması bakımından kritiktir. Çalışmada Skolyoz tanısı için Cobb açısı hesaplanmış ve sonuçlar daha önce yapılmış çalışmalarla ve manuel sonuçlarla karşılaştırılmış ve düşük hata oranının olduğu görülmüştür. Oluşturulan sistem sadece tarama yapmakla kalmamış, aynı zamanda tedavi için ayrıntılı bilgileri de sunmuştur[40]. Zhang vd. İdiyopatik Skolyoz için Cobb açısı ölçümünün cerrahi planlama ve tıbbi tedavi için oldukça önemli olduğunu belirtmişlerdir. Şu an doktorlar tarafından ölçülen bu açıyı Evrişimsel Sinir Ağı modeli (CNN) kullanarak alan sınırlamasıyla ölçümünü yapmışlardır[41]. Thong vd. ergen İdiyopatik Skolyoz için mevcut sınıflandırma sistemlerinin omurganın üç boyutlu deformasyonu hakkında detaylı bilgilendirme sunmadığını ve bu durum ilerleyen tedavi sürecinde yeterli olmadığını belirtmişlerdir. Bu sorunun çözümü için üç boyutlu (3D) omurga rekonstrüksiyonlarının sınıflandırılması için derin öğrenme yöntemleriyle bir sistem gerçekleştirmişlerdir. Bu sistemi Skolyoz yöntemlerinden Lenke yönteminde Tip-1 Torasik Spinal deformasyona sahip 155 hasta üzerinde analiz etmişlerdir. Kümeleme algoritmaları ile alt gruplar oluşturulmuştur. Sonuçların sistem öncesi hesaplamalarla farklılık gösterdiği belirtilmiştir [42]. Tan vd. derin öğrenmeye dayalı otomatik Skolyoz tanı ve ölçüm sistemi geliştirmişlerdir. Ergen İdiyopatik Skolyoz tanısı doktorlar tarafından manuel olarak yapılan omurga radyografilerinde Cobb açısının ölçülmesine bağlı olması sebebiyle gözlemci içi ve gözlemciler arası varyasyonlar tanıda hatalara sebep olmaktadır. Çalışmanın amacı da ölçüm doğruluğunu artırmak ve doktorların tanı aşamasında yardımcı olmak için derin öğrenmeye dayalı otomatik bir Skolyoz tanı ve ölçüm sistemi tasarlamaktır. Omurga radyografilerini segmentlere ayırmak için U-net segmentasyon ağı kullanılmıştır. Daha sonra, Cobb açıları olan üst omurların uç plakaları ile alt omurların uç plakaları arasındaki açılar ölçülmüştür. Sonuç olarak çalışma Cobb açısının otomatik ölçümü için tasarlanan sistemin doktorlara tanıda yardımcı olması planlanmıştır. Bu çalışmada sadece Cobb açısı tespiti ile Skolyoz hastalığının olup olmadığını üzerine çalışılmıştır. Herhangi bir tespitte bulunulmamıştır. Otomatik Cobb açısı ölçümlerinin uzmanlara yardımcı olması amacıyla yapılan bir çalışmadır[43]. Sabri vd. derin öğrenme ile Skolyoz Lenke sınıflandırmasının görüntüsü üzerinde çalışmışlardır. Buna göre, bir Evrişimsel Sinir Ağı (CNN) modeli, Lenke Tip 1 veya diğer Lenke tiplerini sınıflandırmak için incelenmiştir. Görüntünün farklı boyutları ile Lenke sınıflandırma doğruluğu ile en uygun katman sayısı arasındaki ilişkiyi belirlemek için deneyler yapılmıştır. Bu deneyler için kırk beş görüntü üzerinde yapılmıştır. Görüntü boyutlarının değişiminin doğruluk değerlerindeki etkisi üzerinde durulmuştur[44]. Anitha çalışmasında Lenke yöntemiyle sınıflandırma işlemi üzerine çalışmıştır. Cobb açısının ölçümüyle Lenke yöntemine göre eğri tipinin belirlenmiş ve böylece sınıflandırma sisteminin verimliliği artırılmıştır. Önerilen sistemde gözlemci hatalarının ortadan kaldırılması planlanmıştır[45]. Ramirez vd. insan omurgalarındaki İdiyopatik

Skolyoz'un şiddetini ölçen bir Destek Vektör Makineleri (SVM) sınıflandırıcısı üzerine çalışmışlardır. Yüzey topografisi ve klinik verilerin Destek Vektör Makineleri (SVM) kullanılarak birleştirilmesinin daha iyi değerlendirme sonuçları üreteceği düşünülerek, 111 İdiyopatik Skolyoz hastasının veri kümesini kullanarak bir çalışma gerçekleştirmişlerdir. Veri kümesi üzerinde yapılan test sonucu, sistemin testte %69 ile %85 aralığında doğruluk elde edildiği görülmüştür[46]. Mezghani vd. bilgisayar destekli Lenke sınıflandırması üzerine çalışmışlardır. Cobb açısı ölçümleri kullanılarak Skolyoz görülen omurgalarda Lenke sınıflandırmasını gerçekleştirmişlerdir. Bu doğrultuda, sınıflandırma sürecinde uzmanlara yardımcı olmak için kural tabanlı bir diyagram tasarlamak ve sınıflandırma süresini ve doğruluğunu artıran bir çözüm geliştirilmesini amaçlamışlardır. Bilgisayar sınıflandırıcısı radyografik ölçümle 603 hastanın veri tabanında test edilmiş ve doğruluğu kural tabanlı diyagram üzerinde %93 ve bilgisayar sınıflandırıcısı için %99 olduğu görülmüştür. Söz konusu çalışma hem bilgisayar sınıflandırıcısı hem de kural tabanlı diyagram uzmanlara Skolyoz'un Lenke sınıflandırmasında etkili bir şekilde yardımcı olabileceğinin gösterilmesi bakımından dikkate değerdir [47]. Zhang vd. Hough dönüşümü tekniğine dayalı bilgisayarlı bir yöntem geliştirmişlerdir. Bu yöntem, daha sonra Cobb açısını otomatik olarak hesaplamak için kullanılan vertebral uç plakaları tespit etmiştir. Çalışmaya göre, bir omur 45 dereceden fazla eğilirse yanlış algılama oluşabilmektedir [48]. Okashi vd. farelerin düşük kaliteli röntgen görüntülerinden omurga segmentasyonu ve eğrilik ölçümü için otomatik bir yöntem geliştirmişlerdir. Ayrıca yöntemlerinin bir insan omurgasının X ışını görüntüsüne uygulanabilirliğini araştırmışlar ve yöntemlerinin, düşük kaliteli insan röntgen görüntüleri için iyi bir çözüm olabileceğini düşünmüşlerdir. Omurga eğriliği ölçmek için 100 farklı görüntüde altı farklı ölçüm yapılarak incelenmiştir. Elde edilen sonuçlar ile en iyi manuel ölçümlerin birbirine çok yakın olduğu belirtilmiştir[49]. Samuvel vd. otomatik Cobb açısı ölçümü için maske tabanlı bir segmentasyon algoritması önermişlerdir. Belirtilen algoritma ve manuel yöntem altı vakada Cobb açısını ölçmek için kullanılmıştır. Söz konusu yöntemle elde edilen sonuçlar ile manuel yöntemle elde edilen sonuçlar arasında 4 derece fark tespit edilmiştir[50]. Kusuma vd. radyografilerin alt bölümlerinde şablon eşleştirme tekniğini uygulayarak vertebral konumlarını tahmin etmişlerdir. Teknik karelerin farklılıklarının toplamına dayanmaktadır. Polinom eğrisi ile omurga eğriliğini tahmin etmişlerdir. Yöntemlerinde son ölçüm polinom düzeninden ve alt bölümlerinin sayısından etkilenmiştir. Ortalama %86,01 doğruluk elde etmişlerdir[51]. Toan vd. Skolyoz'un radyografik değerlendirme aşamasındaki gözlemci değişkenliğini azaltmak amacıyla, sağlık hizmetleri ve bireyler tarafından kolaylıkla kullanılabilir ve geliştirilebilecek yarı otomatik bir yöntem geliştirmişlerdir. [52]. Giannoglu vd. Cobb açısı hesaplaması ve görüntü tabanlı modelleme teknikleri hakkında bir çalışma yapmışlardır. Omurganın üç boyutlu (3D) modellenmesi için geliştirilen sistem, omurun köşe noktalarını tespit ederek omurga eğriliğini tahmin edilmesi amaçlanmıştır [53]. Yang vd. gerçekleştirdikleri çalışmada 3240 hastadan alınan görüntü üzerinde farklı derin öğrenme modellerini uygulamış ve elde ettikleri bulgular, ölçümlerin derin öğrenme modelleri tarafından uzmanlara göre daha etkin düzeyde yapıldığını göstermiştir [54]. Kim vd. tarafından gerçekleştirilen güncel bir çalışmada ölçüm alanlarının tespiti noktasında 'vertebral-tilt' olarak isimlendirilen bölge kullanılmış ve kullanılan derin öğrenme çözümleri ile ortalama 3,51'lik bir açı hatası ve %7,84'lük bir yüzde hatası ile etkin olduğu düşünülen bir yaklaşım elde edilmiştir [55]. Diskriminant Analizi ile birleştirilen bir CNN modelinin Skolyoz teşhisi noktasında kullanıldığı bir başka çalışmada, geniş veri tabanlarının teşhis noktasında otomatik işaretlenebileceği düşünülen bir yaklaşım ortaya konulmuştur [56]. He vd. tarafından gerçekleştirilen çalışmada, Bilateral CNN modeli kullanılarak %87,92 doğrulukla Skolyoz teşhisi gerçekleştiren bir çözüm elde edilmiştir [57]. Röntgen görüntülerine alternatif olması bakımından ultrason tabanlı Skolyoz teşhisine odaklanan dikkate değer bir başka çalışma ise üç boyutlu (3D) omurga görüntüleme ve CNN tabanlı bir çözüm ile otomatik teşhis çözümü elde edilmesi bakımından benzeri çalışmalara göre oldukça yenilikçi bir yaklaşım ortaya koymuştur [58].

IV. CAPSNET İLE OTOMATİK COBB AÇISI ÖLÇÜMÜ

Literatürde gerçekleştirilen çalışmalar incelendiğinde genellikle Evrişimsel Sinir Ağları (CNN: Convolutional Neural Networks) ve benzeri görüntü işleme odaklı derin öğrenme çözümlerinin

yaygınlığı dikkat çekmektedir. Bununla birlikte bir alternatif olarak Kapsül Ağları (CapsNet: Capsule Networks) taraflı bir çözüm göze çarpmamış olmakla birlikte CapsNet modellerinin kapsül adı verilen yapılar sayesinde sağladığı daha başarılı sonuçlar, ilgili tekniğin bu çalışmadaki Cobb açısı ölçüm probleminde uygulanmasını da cazip hale getirmiştir. CapsNet modelleri, görüntü üzerinde yer alan önemli bileşenlerin yer değiştirmesi durumunda bocalayan CNN modellerindeki söz konusu sorunu kapsül adı verilen alternatif yapılar sayesinde; girdi görüntüsündeki unsurlarla alakalı konum, ölçek gibi durumları ‘routing-by-agreement’ (anlaşmayla yönlendirme) ile öğrenerek çözmeyi başarmaktadır [59]. Her ne kadar CNN modelleri ortaklama (pooling) katmanları ile görüntü üzerinde analiz süreçlerinde önemli bir boyut azaltma süreci işletiyor olsa da, bu durum bazı problemlerde görüntüdeki unsurlara dair bilinmesi gereken bazı detayların da süreçte kaybolmasına yol açmaktadır [59, 60]. Söz konusu sorun, CapsNet ile başarılı bir şekilde çözülebildiği ve bu çalışmadaki Skolyoz Cobb açısı ölçüm süreci de omurga yapılarındaki konum, ölçek özelliklerine karşı hassas bir noktada yer aldığı için alternatif bir CapsNet modeliyle otomatik ölçüm sistemi geliştirilmesi yoluna gidilmiştir.



Şekil 4. Tipik bir CapsNet model mimarisi [61].

A. GELİŞTİRİLEN CAPSNET MODEL YAPISI

Çalışma kapsamında geliştirilen CapsNet model yapısı, önceki bölümlerde bahsedilen çalışmalardan elde edilen bilgi ve beceriler (tecrübeler) bağlamında tasarlanmıştır. Ayrıca, CapsNet konusunda farklı problemler için geliştirilen modellerde elde edilen bulgular da bu çalışmadaki modelin şekillenmesinde önemli roller üstlenmiştir. Tasarlanan CapsNet modelindeki katman yapıları genel hatlarıyla şu şekildedir:

- Cobb açısının otomatik ölçümü için omur sınırlarının belirlenmesi gerekmektedir. Bunun için CapsNet modelinde giriş verisi omurga röntgen görüntüleri, çıkış verisi ise omurları temsil eden nokta tespitleri olarak belirlenmiştir.
- Ağ yapısı toplamda 4evrişimsel (convolutional) katman ve 3 kapsül (capsule) katmanından oluşmuştur.
- Birinci evrişimsel katmanından sonra, söz konusu katmanı takip eden bir batch-normalization katmanı konumlandırılmıştır.
- İkinci katman olan diğer evrişimsel katman ardına averagepooling katmanı konumlandırılmıştır.
- Üçüncü evrişimsel katmanı takip eden dördüncü evrişimsel katman birinci kapsül katmanını oluşturacak şekilde revize edilmiştir.
- Geriye kalan kapsül katmanları routing-by-agreement sürecini destekleyecek şekilde modele entegre edilmiştir.

Geliştirilen modelin Cobb açısı ölçüm sürecine geçmeden önce açılı ölçümüne temel teşkil edecek omurları tespit etmesi amaçlanmıştır. Bu noktada, Wu vd. tarafından ortaya konulan ve bu çalışmaya konu olan veri seti için de uygulanan ‘torasik ve lomber omurgaları kapsayan 17 omur köşelerinin 4’er

noktayla temsil edildiği' dolayısıyla ağ yapısının '68 noktalı omur tespit çıktısı ürettiği' [62] çözüm yolu izlenmiştir. Böylelikle görüntü giriş verisine karşılık, omurları temsil eden noktalar bağlamında çıkış verilerinin elde edilmesi yaklaşımı sağlanmıştır. CapsNet çıkışında elde edilen omur temsilleri, yine Alharbi vd. tarafından ifade edilen ölçüm algoritmaları [63] kullanılmak suretiyle Cobb açısı ölçümünün otomatik bir biçimde gerçekleştirilmesi sağlanmıştır.

B. VERİ SETİ VE UYGULAMA DÜZENİ

Skolyoz ve alternatif omurga taraflı problemlere yönelik araştırma çalışmaları dikkate alındığında, röntgen görüntülerinin temel girdi verileri olarak görülmektedir (En azından teşhis çalışmaları bunu gerekli kılmaktadır). Bu noktada, çalışmada geliştirilen CapsNet sisteminin değerlendirilmesi ve otomatik ölçüm süreçlerinin gerçekleştirilmesi için '2019 MICCAI Workshop on Computational Methods and Clinical Applications for Spine Imaging' etkinliği kapsamına da konu olan 'dataset-16' başlıklı Skolyoz röntgen veri seti tercih edilmiştir. Söz konusu veri seti omurga araştırmalarına odaklanan Spine Web platformunda da erişilebilir durumda olan ve ilk olarak 2017 yılında Wu vd. tarafından literatüre kazandırılan [62]; 609 anterior-posterior omurga röntgen görüntüsünden meydana gelen bir araştırma verisi olarak bilinmektedir.

Çalışma için seçilen veri seti özellikle Cobb açısı ölçümleri için hazırlanmış durumdadır. Böylelikle CapsNet uygulaması sonrası ölçümlerin tutarlılığı değerlendirmeye konu olabilmektedir. Uygulamanın genel değerlendirme sürecinin nispeten daha kısa zaman alması adına 609 görüntü verisinden 400 tanesi eğitim süreci için kullanılırken 100 tanesi de test süreci için seçilmiştir. Söz konusu görüntü veri setlerinin, modelin ayırt edebilirliğini kanıtlayacak ölçüde; uzman seçimi eşliğinde kolay-normal-zor düzeyde harmanlanmasına ve önceki alt-başlıkta ifade edilen, omurga nokta tespitine uyumlu bir biçimde ön-hazırlık sürecinden geçirilmesine özen gösterilmiştir. İlgili veri seti anonimleştirilmiş ancak farklı bireylerden alındığı pekala tahmin edilebilen farklı tanı düzeylerinde görüntüler içeriyor olsa da, cinsiyet ya da yaş gibi hastaya özgü farklılıkları dikkate alan ya da algılayan bir çözüm geliştirilmesi söz konusu olmamaktadır (Veri seti bu yönde düzenlemeler içermemektedir). Bu bağlamda CapsNet modelinin odak noktası sadece otomatik Cobb ölçümü sağlamaktır.

C. BULGULAR VE DEĞERLENDİRME

Geliştirilen CapsNet modeli, aynı veri setinin kullanıldığı ve yine güncel bağlamda dikkat çeken farklı çalışmalarda toplamda dört farklı model: ConvNet [62], BoostNet [62], RFR [62] ve ResNet-50 [63] modelleri ile karşılaştırılmıştır (Modellerin ilgili çalışmalarda tasarımılarına sadık kalınmıştır). İlgili çalışmalarda Cobb ölçümü yapmayan modellere çalışmada kullanılan ölçüm algoritmaları entegre edilerek, sadece omurga tespitleri konularında değil, aynı zamanda ölçüm doğruluklarına sağladıkları katkılar bakımından da karşılaştırmalar yapılmıştır.

Karşılaştırma süreçlerinin bilinen metriklerle karşılanması oldukça önemlidir. Bu nedenle omurgaların tespitini anlamlandırabilecek; Ortalama Kare Hatası (MSE: MeanSquareError) ve Pearson Korelasyon Katsayısı (ρ) kullanılmıştır. Ölçüm sonuçlarının karşılaştırılmasında ise dört farklı açı farklılıkları (sistemlerin ölçtüğü ile olması gereken değer arası farklar) dikkate alınmıştır. Açı farklılıklarının modellerin karşılaştırılmasına kolaylık sağlaması adına toplamda 100 puanın paylaştırıldığı bir ağırlıklı toplam ile Ölçüm Başarım Puanı hesaplanması (Eş. 1) tercih edilmiştir (Her açı farklılığı birer harf ile temsil edilmektedir. Daha fazla açı farkı daha düşük ağırlıkla karşılanmıştır). Tablo 1 5-fold crossvalidation süreci ile birlikte eğitim ve test veri setlerine dair omurga tespit bulgularını, Tablo 2 ise test verileri kapsamındaki açı ölçüm farklılıklarına göre karşılaştırmayı göstermektedir (Tablolarda karşılaştırmalı bulgular arasında en iyi olanlar kalın-bold yazı stili ile belirtilmiştir).

$$\text{Ölçüm Başarım Puanı} = (A * 0,60) + (B * 0,25) + (C * 0,10) + (D * 0,05) \quad (1)$$

Tablo 1. Omurga tespitinde eğitim ve test veri setlerine göre karşılaştırma bulguları.

Model	Eğitim Seti MSE	Eğitim Seti ρ	Test Seti MSE	Test Seti ρ
<i>CapsNet</i>	0.00053 \pm 0.0031	0.96 \pm 0.0071	0.0038	0,93
ConvNet	0.01411 \pm 0.0082	0.84 \pm 0.0209	0.0138	0.87
BoostNet	0.00076 \pm 0.0053	0.93 \pm 0.0053	0.0049	0.92
RFR	0.00259 \pm 0.0049	0.91 \pm 0.0057	0.0061	0.91
ResNet-50	0.00059 \pm 0.0041	0.95 \pm 0.0041	0.0043	0.93

Tablo 2. Cobb ölçüm bulgularında farklılıklara göre karşılaştırma.

Model	A: < 3°	B: < 5°	C: 5° - 10°	D: 10° - 15°	Ölçüm Başarım Puanı
<i>CapsNet</i>	3	59	21	17	19,50
ConvNet	0	23	40	37	11,60
BoostNet	1	46	28	25	16,15
RFR	0	39	34	27	14,50
ResNet-50	2	53	25	20	17,95

Elde edilen bulgular, geliştirilen CapsNet modelinin benzeri modellere göre daha başarılı sonuçlar ürettiğini göstermektedir. Genel başarımlarını dikkate alındığında CapsNet modelini ResNet-50 modelinin takip ettiği, ardından üçüncü sırada BoostNet modelinin yer aldığı görülmektedir. Söz konusu üç model, sırasıyla RFR ve ConvNet modellerine nispeten açık ara bulgularla üstünlük kurmuş durumdadır. Karşılaştırılan bütün modeller tekil ölçekte incelendiğinde, Skolyoz veri setine karşı derin öğrenmenin etkinliği de ayrıca dikkat çekmektedir. Bulgular CapsNet modelinin, sayıca daha çok katmanlı ya da ek çabalar gerektirebilen modellere göre daha tercih edilebilir olduğunu işaret etmektedir. Yine Cobb ölçümü algoritması sayesinde, görsel tespit sürecinin otomatik ölçüm yaklaşımıyla desteklenmesi sayesinde uzmanlar için verimli bir çözüm ortaya konulmuştur.

Gerçekleştirilen çalışmada elde edilen sonuçlar literatürdeki mevcut yaklaşımlara yönelik önemli bir alternatif çözümü işaret etmektedir. Bununla birlikte çalışmada dikkate alınan veri setinin bir tür kısıt faktörü olduğu, aynı CapsNet modelinin yeni Skolyoz verileriyle test edilmesinin çözüme yönelik güven faktörünü de destekler nitelikte olacağı düşünülmektedir. Yine çalışmadaki CapsNet modeli sadece Cobb ölçüm sürecine tekabül etmekte, tedavi ekseninde herhangi bir fikir vermemektedir. Bu kısıta karşı hibrit bir sistem oluşturularak teşhis-tedavi tabanlı komple bir çözüm elde edilmesi mümkün olacaktır. Bu noktada modelin bir tür Nesnelere İnterneti (IoT) mimarisine dahil edilmesinin, E-Sağlık uygulamalarının ve cihazlar arası akıllı iletişim-çözüm süreçlerinin artan surette önem kazandığı günümüzde ideal bir yaklaşım olacağı düşünülmektedir. Bu bağlamda, mobil cihazlar ve hastane içi sistemlerin iletişim halinde olduğu bir IoT düzeneği verimli ve yenilikçi bir araç olacaktır. Diğer yandan hedef Skolyoz tanı ve ölçüm süreçleri literatürde yer alan birçok alternatif derin öğrenme teknikleriyle değerlendirilmek suretiyle, aynı veya benzer veri setleri üzerinden Skolyoz'un otomatik ölçümü bağlamında literatürü destekleyici çalışmalar ortaya konulabilecektir. Örneğin, Derin İnanç Ağları'nın (DBF: Deep Belief Networks) alternatif bir model olması bakımından değerlendirmeye değer bir teknik olarak dikkate alınabilecektir. Diğer yandan Otokodlayıcı Ağlar (AEN: Autoencoder Networks) Skolyoz görüntülerinin çeşitli ön-işlemlere tabi tutularak analizi kolay hale getirilmesi bakımından kullanılabilir. Doğrudan görüntü taraflı bir çözüm olmasa da, zaman içerisinde çok sayıda bireyden elde edilen ölçüm değerlerinden Skolyoz'un kitlesel durumunu tahmin edebilecek Uzun Kısa Vadeli Hafıza (LSTM: Long Short Term Memory) tekniği de alternatif bir bakış açısı sunabilecektir.

V. SONUÇ

Skolyoz hastalığı omurga sağlığı ile bağlantılı olduğu için insanlar açısından oldukça kritik ve farklı sağlık sorunlarını da tetikleyebilecek nitelikte bir sorun olarak karşımıza çıkmaktadır. Sağlık alanında bilgisayar desteğinin kullanımı görüntü verileri üzerinden bu tür hastalıkların tespit edilmesini kolaylaştırmış olsa da temel sorun her zaman için hız konusunda kısıtları olan insanın bir şekilde otomatik çözümlerle desteklenmesi haline gelmektedir. Benzer şekilde Skolyoz teşhisinde önemli bir yer tutan Cobb açısı ölçümü de bilgisayar ortamındaki özel yazılımlar üzerinde uzmanlar tarafından gerçekleştirildiği için gerek objektiflik gerekse zamanın verimli kullanılması açısından görüntü işleme yönelimli esnek çözümlere ihtiyacı beraberinde getirmiştir. Bu ihtiyaç, literatürde derin öğrenme yönelimli çözümlerle ölçümü otomatikleştiren alternatif çalışmalarla birlikte giderilmeye çalışılmaktadır. Benzer şekilde bu çalışmada literatürdeki mevcut duruma ilişkin genel bir analiz sunmuş, ardından Kapsül Ağları (CapsNet: Capsule Networks) tabanlı alternatif bir model önermiştir. Ortaya konulan CapsNet modeli, özellikle omurgadaki sıra dışı yer değişikliklerinin daha etkin değerlendirilmesi ve mümkün olduğunca objektif bir çözümün elde edilmesi noktasında, yaygın kullanılan Evrişimsel Sinir Ağları (CNN: Convolutional Neural Networks) modellerine göre tercih sebebi olmuştur. CapsNet odaklı bir çözümün literatürde ortaya henüz ortaya konulmamış olması, bu yönde alternatif bir çözümün tasarlanması açısından çalışmaya önemli bir özgünlük katmıştır. Çalışmada geliştirilen CapsNet modelinin değerlendirilmesi aşamasında ‘2019 MICCAI Workshop on Computational Methods and Clinical Applications for Spine Imaging’ etkinliği kapsamında kullanılan ve ilk olarak 2017 yılında Wu vd. tarafından literatüre kazandırılan Skolyoz veri seti seçilmiştir. Yapılan değerlendirmelerde modelin ConvNet, BoostNet, RFR ve ResNet-50 modellerine göre daha başarılı sonuçlar verdiği, yine açılı ölçümlerinde etkin düzeyde bulgular ortaya koyduğu görülmüştür.

Çalışmada elde edilen olumlu bulgular, çalışmaların yine alternatif çözümlerle devamında motivasyon oluşturmuştur. Buna göre halihazırda zaten doktora tez çalışması sürecinin bir parçası olan araştırmancının, Skolyoz teşhis-tedavi sürecinde Schroth yöntemiyle desteklenmesi ve hatta güvenli, sınırları anlaşılır, daha transparan bir derin öğrenme modelinin elde edilmesi için Açıklanabilir Yapay Zeka (XAI) taraflı eklentilerin de modele eklenerek uygulanması yönünde ilerletilmesi söz konusu olacaktır. Böylelikle sonuçlarının güvenilirliği anlaşılan ve teşhisten tedaviye sürecin tümünü hedefleyen yenilikçi bir yaklaşımın elde edilmesi söz konusu olacaktır. Uzun vadede yine alternatif derin öğrenme modellerinin uygulanması da gelecek çalışmalar arasında yer alabilecektir. Son olarak, üretilen çözümün güvenilirliğinin desteklenmesi noktasında alternatif Skolyoz veri setleriyle ek çalışmaların tertiplenmesi, hatta uzman görüşlerinin irdelenmesine devam edilerek, Yapay Zeka ile doktorlar arası performans ve muhakeme süreçlerine yönelik bulguların elde edilmesi yönünde uygulamalar da planlanmaktadır.

VI. KAYNAKLAR

- [1] J. Jin, “Screening for scoliosis in adolescents,” *JAMA: The Journal of the American Medical Association*, vol. 319, no. 2, pp. 202–202, 2018.
- [2] D. Sevimli, M. Sanrı and M. Altuğ, “The effect of corrective exercises on the treatment of a scoliosis patient: Acase report,” *International Congress on Education (ERPA-2016)*, 2016, pp. 40–42.
- [3] M. Aebi, “The adult scoliosis,” *European Spine Journal*, vol. 14, no. 10, pp. 925-948, 2005.
- [4] M. T. Hresko, “Idiopathic scoliosis in adolescents,” *New England Journal of Medicine*, vol. 368, no. 9, pp. 834-841, 2013.
- [5] Y. U. İbişoğlu ve F. A. Çalış, “İzmir ili Bornova ilçesi ilköğretim kurumlarında okuyan 12-14 yaş grubu çocuklarda skolyoz prevalansı,” *Türkiye Fiziksel Tıp ve Rehabilitasyon Dergisi*, c. 58, s. 2, ss. 109–113, 2012.

- [6] C. Varol, "Skolyozlu olgularda egzersizin solunum fonksiyonlarına ve yaşam kalitesine etkisi," Yüksek lisans tezi, Kardiyopulmoner Fizyoterapi ve Rehabilitasyon, Marmara Üniversitesi, İstanbul, Türkiye, 2019.
- [7] A. C. Kittleson and L. W. Lim, "Measurement of scoliosis," *American Journal of Roentgenology*, vol. 108, no. 4, pp. 775–777, 1970.
- [8] H. G. Yılmaz, "İdiyopatik skolyozda egzersiz reçeteleme," *Türkiye Fiziksel Tıp ve Rehabilitasyon Dergisi*, c. 60, s. özel sayı 2, ss. S31–S35, 2014.
- [9] M. Bakator and D. Radosav, "Deep learning and medical diagnosis: A review of literature," *Multimodal Technologies and Interaction*, vol. 2, no. 3, pp. 47, 2018.
- [10] O. Deperlioglu, "Classification of segmented phonocardiograms by convolutional neural networks," *BRAIN: Broad Research in Artificial Intelligence and Neuroscience*, vol. 10, no. 2, pp. 5–13, 2019.
- [11] D. Ravi, C. Wong, F. Deligianni, M. Berthelot, J. Andreu-Perez, B. Lo and G. Z. Yang, "Deep learning for health informatics," *IEEE Journal of Biomedical and Health Informatics*, vol. 21, no. 1, pp. 4–21, 2016.
- [12] G. E. Guraksin, S. Barin, E. Ozgul and F. Kaya, "COVID-19 diagnosis using deep learning," *Düzce University Journal of Science & Technology*, vol. 9, no. 3, pp. 8–23, 2021.
- [13] J. Hemanth, U. Kose, O. Deperlioglu and V. H. C. de Albuquerque, "An augmented reality-supported mobile application for diagnosis of heart diseases," *The Journal of Supercomputing*, vol. 76, no. 2, pp. 1242–1267, 2020.
- [14] A. B. Levine, C. Schlosser, J. Grewal, R. Coope, S. J. Jones and S. Yip, "Rise of the machines: Advances in deep learning for cancer diagnosis," *Trends in Cancer*, vol. 5, no. 3, pp. 157–169, 2019.
- [15] A. Helwan, G. El-Fakhri, H. Sasani and D. Uzun Ozsahin, "Deep networks in identifying CT brain hemorrhage," *Journal of Intelligent & Fuzzy Systems*, vol. 35, no. 2, pp. 2215–2228, 2018.
- [16] J. Hemanth, O. Deperlioglu and U. Kose, "An enhanced diabetic retinopathy detection and classification approach using deep convolutional neural network," *Neural Computing and Applications*, vol. 32, no. 3, pp. 707–721, 2020.
- [17] U. M. Prakash, K. Kottursamy, K. Cengiz, U. Kose and B. T. Hung, "4x-Expert systems for early prediction of osteoporosis using multi-model algorithms," *Measurement*, vol. 180, no. 8, pp. 109543, 2021.
- [18] J. Alzubi, B. Bharathikannan, S. Tanwar, R. Manikandan, A. Khanna and C. Thaventhiran, "Boosted neural network ensemble classification for lung cancer disease diagnosis," *Applied Soft Computing*, vol. 80, no. 7, pp. 579–591, 2019.
- [19] M. I. Razzak, S. Naz and A. Zaib, "Deep learning form edical image processing: Overview, challenges and the future," in *Classification in BioApps*, 1st ed., vol. 26, Cham, Germany: Springer, 2018, pp. 323–350.
- [20] S. Zhou, H. G. Kevin and S. Dinggang, *Deep Learning for Medical Image Analysis*, 1st ed., vol. 81, London, UK: Elsevier Academic Press, 2017, pp. 11–24.

- [21] A. Esteva, K. Chou, S. Yeung, N. Naik, A. Madani, A. Mottaghi, Y. Liu, E. Topol, J. Dean and R. Socher, "Deep learning-enabled medical computer vision," *Digital Medicine*, vol. 4, no. 1, pp. 1–9, 2021.
- [22] I. Castiglioni, L. Rundo, M. Codari, G. DiLeo, C. Salvatore, M. Interlenghi, F. Gallivanone, A. Cozzi, N. C. D'amico and F. Sardanelli, "AI applications to medical images: From machine learning to deep learning," *Physica Medica*, vol. 83, no. 1, 9–24, 2021.
- [23] E. Xi, S. Bing and Y. Jin, "Capsule network performance on complex data," 2017, arXiv:1712.03480.
- [24] P. Afshar, A. Mohammadi and K. N. Plataniotis, "Brain tumor type classification via capsule networks," in *2018 25th IEEE International Conference on Image Processing (ICIP)*, 2018, pp. 3129–3133.
- [25] Wikipedia. (2006, November 23). *Omurga / Vertebral column*. (Author: Arcadian) [Online]. Available: <https://tr.wikipedia.org/wiki/Omurga>
- [26] Wikipedia. (2017, November 5). *Thoracic vertebrae / A thoracic spine X-ray of a 57-year-old male*. (Author: Who is johngalt). [Online]. Available: https://en.wikipedia.org/wiki/Thoracic_vertebrae
- [27] S. Bilgiç ve Ö. Erşen, "Adolesanidiyopatik skolyoz konservatif tedavisi," *Türkiye Klinikleri Journal of Orthopaedics and Traumatology Special Topics*, c. 10, s. 2, ss. 118–123, 2017.
- [28] A. A. Süzen, Z. Yıldız, K. Kayaalp, O. Ceylan ve E. Arabacı, "Skolyoz hastalığının tespiti için taşınabilir cihaz tasarımı," *Avrupa Bilim ve Teknoloji Dergisi*, c. 15, s. 1, ss. 483–490, 2019.
- [29] P. Patias, E. Stylianidis, M. Pateraki, Y. Chrysanthou, C. Contozis and T. Zavitsanakis, "3D digital photogrammetric reconstructions for scoliosis screening," in *ISPRS Commission Symposium on Image Engineering and Vision Metrology*, 2006, pp. 1214–1218.
- [30] Molinaspine. (2020, December 26). *Adolescent Scoliosis. Domingo Molina IV, M.D. Spine Surgeon* [Online]. Available: <https://molinaspine.com/spine-deformity>
- [31] M. A. Asher and D. Burton, "Adolescent idiopathic scoliosis: natural history and long term treatment effects," *Scoliosis*, vol. 1, no. 2, pp. 1–10, 2006.
- [32] Ö. Aydıngöz, "Adolesan omurga sorunları," *İstanbul Üniversitesi Cerrahpaşa Tıp Fakültesi Sürekli Tıp Eğitimi Etkinlikleri Adolesan Sağlığı Sempozyumu*, İstanbul, Türkiye, 2005, ss. 125–133.
- [33] S. Langensiepen, O. Semler, R. Sobottke, O. Fricke, J. Franklin, E. Schönau and P. Eysel, "Measuring procedures to determine the Cobb angle in idiopathic scoliosis: a systematic review," *European Spine Journal*, vol. 22, no. 11, pp. 2360–2371, 2013.
- [34] R. T. Morrissy, G. S. Goldsmith, E. C. Hall, D. Kehl, and G. H. Cowie, "Measurement of the Cobb angle on radiographs of patients who have scoliosis. Evaluation of intrinsic error," *The Journal of Bone and Joint Surgery*, vol. 72, no. 3, 320–327, 1990.
- [35] T. A. Sardjono, M. H. Wilkinson, A. G. Veldhuizen, P. M. van Ooijen, K. E. Purnama and G. J. Verkerke, "Automatic Cobb angle determination from radiographic images," *Spine*, vol. 38, no. 20, pp. E1256–E1262, 2013.
- [36] M. H. Horng, C. P. Kuok, M. J. Fu, C. J. Lin and Y. N. Sun, "Cobb angle measurement of spine from X-ray images using convolutional neural network," *Computational and Mathematical Methods in Medicine*, vol. 2019, no. 1, pp. 1–18, 2019.

- [37] H. Kim, H. S. Kim, E. S. Moon, C. S. Yoon, T. S. Chung, H. T. Song, J. S. Suh, Y. H. Lee and S. Kim, "Scoliosis imaging: What radiologists should know—erratum," *Radiographics*, vol. 35, no. 4, pp. 1316–1335, 2015.
- [38] Y. Pan, Q. Chen, T. Chen, H. Wang, X. Zhu, Z. Fang and Y. Lu, "Evaluation of a computer-aided method for measuring the Cobb angle on chest x-rays," *European Spine Journal*, vol. 28, no. 12, pp. 3035–3043, 2019.
- [39] J. Zhang, H. Li, L. Lv and Y. Zhang, "Computer-aided Cobb measurement based on automatic detection of vertebral slope using deep neural network," *International Journal of Biomedical Imaging*, vol. 2017, no. 1, pp. 1–6, 2017.
- [40] R. Choi, K. Watanabe, H. Jinguji, N. Fujita, Y. Ogura, S. Demura, T. Kotani, K. Wada, M. Miyazaki, H. Shigematsu, and Y. Aoki, "CNN-based spine and Cobb angle estimator using moiré images," *IEEE Transactions on Image Electronics and Visual Computing*, vol. 5, no. 2, pp. 135–144, 2017.
- [41] K. Zhang, N. Xu, G. Yang and J. Wu, "An automated Cobb angle estimation method using convolutional neural network with area limitation," in *MICCAI 2019: Medical Image Computing and Computer Assisted Intervention*, 1st ed., vol. 11769, Cham, Germany: Springer, 2019, pp. 775–783.
- [42] W. E. Thong, H. Labelle, J. Shen, S. Parent and S. Kadoury, "Stacked auto-encoders for classification of 3D spine models in adolescent idiopathic scoliosis," in *Recent Advances in Computational Methods and Clinical Applications for Spine Imaging*, 1st ed., vol. 20, Cham, Germany: Springer, 2018, pp. 13–25.
- [43] Z. Tan, K. Yang, Y. Sun, B. Wu, H. Tao, Y. Hu and J. Zhang, "An automatic scoliosis diagnosis and measurement system based on deep learning," in *2018 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, 2018, pp. 439–443.
- [44] N. Sabri, H. N. A. Hamed, Z. Ibrahim and K. Ibrahim, "2D photogrammetry image of scoliosis Lenke type classification using deep learning," in *IEEE 9th International Conference on System Engineering and Technology*, 2019, pp. 437–440.
- [45] H. Anitha, "Lenke's scoliosis classification using image processing techniques," *International Journal of Advanced Research in Computer and Communication Engineering*, vol. 3, no. 9, pp. 56–71, 2014.
- [46] L. Ramirez, N. G. Durdle, V. J. Raso and D. L. Hill, "A support vector machine classifier to assess the severity of idiopathic scoliosis from surface topography," *IEEE Transactions on Information Technology in Biomedicine*, vol. 10, no. 1, pp. 84–91, 2006.
- [47] N. Mezghani, P. Phan, H. Labelle, C. E. Aubin and J. D. Gui, "Computer-aided Lenke classification of scoliotic spines," *World Academy of Science Engineering and Technology*, vol. 53, no. 1, pp. 722–725, 2009.
- [48] J. Zhang, E. Lou and X. Shi, "A computer-aided Cobb angle measurement method and its reliability," *Journal of Spinal Disorders and Techniques*, vol. 23, no. 6, pp. 383–387, 2010.
- [49] O. Al Okashi, H. Du and H. Al-Assam, "Automatic spine curvature estimation from X-ray images of a mouse model," *Computer Methods and Programs in Biomedicine*, vol. 140, no. 1, pp. 175–184, 2017.

- [50] B. Samuvel, V. Thomas and M. G. Mini, “A mask based segmentation algorithm for automatic measurement of cobbangle from scoliosis x-ray image,” in *International Conference on Advances in Computing and Communications*, 2012, pp. 110–113.
- [51] B. A. Kusuma, H. A. Nugroho and S. Wibirama, “Spinal curvature determination from scoliosisx-ray image using sum of squared difference template matching,” in *2nd International Conference on Science and Technology-Computer (ICST '16)*, 2016, pp. 29–34.
- [52] N. B. Toan, T. Q. D. Khoa and V. Van Toi, “Computer-aid cobb measurement of scoliosis using deformable model with fuzzy spatial relations,” in *4th International Conference on Biomedical Engineering in Vietnam*, 2013, pp. 350–353.
- [53] V. Giannoglou and E. Stylianidis, “Review of advances in cobbangle calculation and image-based modeling techniques for spinal deformities,” *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, vol. 3, no. 5, pp. 12–19, 2016.
- [54] J. Yang, K. Zhang, H. Fan, Z. Huang, Y. Xiang, J. Yang, L. He, L. Zhang, Y. Yang, R. Li, Y. Zhu, C. Chen, F. Liu, H. Yang, Y. Deng, W. Tan, N. Deng, X. Yu, X. Xuan, X. Xie, X. Liu and H. Lin, “Development and validation of deeplearning algorithms for scoliosis screening using backimages,” *Communications Biology*, vol. 2, no. 1, pp. 1-8, 2019.
- [55] K. C. Kim, H. S. Yun, S. Kim and J. K. Seo, “Automation of spine curve assessment in frontal radiographs using deep learning of vertebral-tiltvector,” *IEEE Access*, vol. 8, no. 1, pp. 84618-84630, 2020.
- [56] C. Vergari, W. Skalli and L. Gajny, “A convolutional neural network todetect scoliosis treatment in radiographs,” *International Journal of Computer Assisted Radiology and Surgery*, vol. 15, no. 6, pp. 1069-1074, 2020.
- [57] Z. He, Y. Wang, X. Qin, R. Yin, Y. Qiu, K. He and Z. Zhu, “Classification of neurofibromatosis-related dystrophicornondystrophic scoliosis based on image features using bilateral CNN,” *Medical Physics*, vol. 48, no. 4, pp. 1571-1583, 2021.
- [58] T. Ungi, H. Greer, K. R. Sunderland, V. Wu, Z. M. Baum, C. Schlenger, M. Oetgen, K. Cleary, S. R. Aylward and G. Fichtinger, “Automatic spine ultrasound segmentation for scoliosis visualization and measurement,” *IEEE Transactions on Biomedical Engineering*, vol. 67, vol. 11, pp. 3234-3241, 2020.
- [59] S. Sabour, N. Frosstand G. E. Hinton, “Dynamic routing between capsules,” 2017, arXiv:1710.09829.
- [60] M. K. Patrick, A. F. Adekoya, A. A. Mighty and B. Y. Edward, “Capsule networks—a survey,” *Journal of King Saud University-Computer and Information Sciences*, 2019, doi: 10.1016/j.jksuci.2019.09.014.
- [61] D. De. (2017, November 1). *What is a Caps Netor Capsule Network?* [Online]. Available: <https://medium.com/hackernoon/what-is-a-capsnet-or-capsule-network-2bfbe48769cc>
- [62] H. Wu, C. Bailey, P. Rasoulinejad and S. Li, “Automatic land mark estimation for adolescent idiopathic scoliosis assessment using boostnet,” in *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2017, pp. 127–135.
- [63] R. H. Alharbi, M. B. Alshaye, M. M. Alkanhal, N. M. Alharbi, M. A. Alzahrani and O. A. Alrehaili, “Deeplearning based algorithm for automatic scoliosis angle measurement,” in *3rd International Conference on Computer Applications & Information Security (ICCAIS)*, 2020, pp. 1–5.