



J-EDUCAT: Journal of Educational Studies

J-EDUCAT: Eğitim Araştırmaları Dergisi

(ISSN: 3023-8145)

<http://www.jeducat.com>

Received: 11.03.2026, **Accepted:** 19.05.2026, **Early Published:** 30.05.2026,

Published: 01.05.2026

Article Type: Research Article

Doi: <https://doi.org/10.5281/zenodo.20445515>

Creative Commons Attribution 4.0 International (CC BY) License

Futbol Oyun Görüntülerinde Otomatik Faul Tespiti için SqueezeNet Tabanlı Bir Derin Öğrenme Modeli

*Ahmet DÜZGÜNCE**

Öz

Son yıllarda derin öğrenme tabanlı bilgisayarlı görü yöntemleri, görüntü analizi ve sınıflandırma problemlerinde önemli başarılar elde etmiştir. Özellikle spor analitiği alanında geliştirilen otomatik analiz sistemleri, maç görüntülerinin incelenmesi ve hakem kararlarının desteklenmesi açısından önemli bir araştırma konusu haline gelmiştir. Futbol karşılaşmalarında faul kararları çoğu zaman hızlı gelişen pozisyonlara bağlı olarak verilmekte ve bu durum bazı hatalı değerlendirmelere yol açabilmektedir. Bu nedenle futbol görüntülerinden faul durumlarının otomatik olarak tespit edilmesi hem hakem destek sistemleri hem de spor analitiği çalışmaları açısından önemli bir araştırma alanı oluşturmaktadır. Bu çalışmada futbol görüntülerinde faul tespitini gerçekleştirmek amacıyla derin öğrenme tabanlı bir yaklaşım önerilmiştir. Önerilen yöntemde, düşük parametre sayısı ve yüksek doğruluk performansı ile bilinen SqueezeNet mimarisi kullanılmıştır. Çalışmada toplam 716 futbol görüntüsünden oluşan bir veri kümesi kullanılmış olup bu görüntülerin 461'i faul, 255'i ise faul olmayan pozisyonlardan oluşmaktadır. Veri kümesi %70 eğitim ve %30 test olacak şekilde ikiye ayrılmıştır. Modelin eğitim sürecinde görüntüler derin evrimsel sinir ağına aktarılıp ve sınıflandırma performansı değerlendirilmiştir. Elde edilen sonuçlar, önerilen modelin futbol görüntülerinde faul tespitinde yüksek başarı sağladığını göstermektedir. Deneysel sonuçlara göre SqueezeNet modelinin ortalama eğitim doğruluğu %97,21, doğrulama doğruluğu ise yaklaşık %96 seviyesinde elde edilmiştir. Elde edilen bulgular, derin öğrenme tabanlı yöntemlerin futbol görüntülerinin otomatik analizinde etkili bir şekilde kullanılabileceğini göstermektedir. Önerilen yaklaşımın gelecekte video tabanlı analiz sistemleri, hakem destek teknolojileri ve spor analitiği uygulamaları için önemli bir altyapı sağlayabileceği değerlendirilmektedir.

Anahtar Kelimeler: Derin Öğrenme, Futbol Görüntü Analizi, Faul Tespiti, SqueezeNet

A SqueezeNet-Based Deep Learning Model for Automatic Foul Detection in Soccer Game Images

Abstract

In recent years, deep learning-based computer vision methods have achieved significant success in image analysis and classification problems. Especially, automated analysis systems developed in the field of sports analytics have become an important research topic for reviewing match images and supporting referee decisions. In football matches, foul decisions are often made based on rapidly evolving situations, which can lead to some erroneous assessments. Therefore, the automatic detection of foul situations from football images constitutes an important research area for both referee support systems and sports analytics studies. This study proposes a deep learning-based approach to detect fouls in football images. The proposed method utilizes the SqueezeNet

* Dr. Ahmet Düzgünce, Atatürk Üniversitesi Kış Sporları ve Spor Bilimleri Enstitüsü, Erzurum, ahmetduzgunce@gmail.com, ORCID: orcid.org/0000-0003-2603-5554

architecture, known for its low number of parameters and high accuracy performance. A dataset of 716 football images was used in the study, 461 of which were foul situations and 255 were non-foul situations. The dataset was divided into two parts: 70% training and 30% testing. During the training process, the images were fed into a deep convolutional neural network, and the classification performance was evaluated. The results show that the proposed model achieves high success in detecting fouls in football image. According to experimental results, the average training accuracy of the SqueezeNet model was 97.21%, and the validation accuracy was approximately 96%. These findings demonstrate that deep learning-based methods can be effectively used in the automated analysis of football image. It is considered that the proposed approach could provide a significant infrastructure for future video-based analysis systems, referee support technologies, and sports analytics applications.

Keywords: Deep Learning, Football Image Analysis, Foul Detection, SqueezeNet

Giriş

Futbol, literatürde birçok farklı şekilde ifade edilmektedir. Futbol, karşılıklı 11'er kişiden oluşan iki takımın karşı kaleye ayak ve kafa ile topu sokmaya çalıştıkları ayak topu oyunudur (TDK, 2023). Başka bir tanıma göre, rekabete dayalı olarak iki farklı takım arasında belirli bir amaç doğrultusunda hava basılmış top ile kaleci hariç eli kullanmadan rakip kaleye topu sokmaya çalıştıkları bir spor dalıdır (Acet, 2001). Zaman içerisinde futbol dünyanın her bölgesinde yayılmış, izlenme olarak en çok izlenen, en yüksek miktarda katılımcı kitlesine ulaşmış ve son olarıktan dünya üzerinde en popüler spor branşlarından biri haline gelmeyi başaran bir spor branşıdır (Akgeyik, 2018). Futbolun ilk olarak İngilizler tarafından icat edildiği bilgisinin aksine ilk örnekleri Uzak Doğu'da görülmektedir. FIFA tarafından futbolun erken biçimi olarak M.Ö. 3. Yüzyıl'da Çin'de ortaya çıkan "Cuju" oyunu kabul edilmektedir. Çinli askerlerin savunma becerilerini geliştirmek için, iki asker takımı arasında tapınağın havlusunda içi tüy dolu topa yukarıda bulunan kaleden ayak ve kafalarıyla geçirmeye çalıştıkları antrenmandır (Bozdemir, 1998). Türklerde ilk resmi futbol kulübü 1894 yılında İzmir Bornova'da İngilizler tarafından "Futbol Clup Smyrna" adıyla kurulmuştur (Dağ, 2019). İngilizlerin ilk spor kulübünü kurmalarının sebebi İzmir, Selanik ve İstanbul gibi liman yerleşkelerine gelirken beraberlerinde futbolu da getirmeleridir. Türkiye'de Türkler tarafından ilk futbol kulübü Reşat Danyal Bey ve Fuat Hüsnü Bey tarafından 1901 yılında İstanbul'da "Black Stocking" adıyla kurulmuş ve Türkler ve Rumlar arasında Papaz Çay'ında oynanan maç olarak resmi kayıtlara geçmiştir. Kısa bir süre sonra Türkiye'de birden fazla spor kulübü kurulmuştur. 1903 yılında "Beşiktaş Jimnastik Kulübü", 1905 yılında "Galatasaray Spor Kulübü", 1907 yılında "Fenerbahçe Spor Kulübü" kurulmuştur (Aycan, 2022). Türkiye'de futbolun örgütlenmesi üç dönem içinde incelenir. 1903-1922 Cumhuriyet öncesi dönem, 1922-1951 Federasyonun kurulmasıyla profesyonelliğin kabulü dönemi, 1951 sonrası profesyonellik dönemi sonrası dönem olarak kabul edilmiştir (Terlemez ve Kumcu, 2024). Türkiye'de Futbol Federasyonu 1923 yılında kurulmuştur. Federasyonun FIFA üyeliğine kabulü 21 Mayıs 1923'te gerçekleşmiştir. Aynı sene içerisinde ilk resmi lig müsabakaları oynanmaya başlamıştır (Terlemez ve Kumcu, 2024). 1950-1960 yılları arasında Türkiye'nin birçok illerinde örneğin İzmir, Ankara'da profesyonel liglerin kurulmasıyla Türkiye'de kulüp sayısında önemli artış olmuştur. 1962 yılında Türkiye UEFA'ya tam üyeliği kabul

edilmiştir (Devecioğlu vd., 2014). FIFA 21 Mayıs 1904'te 7 Avrupa ülkesi tarafından kurulmuştur. Kuruluş amacı futbolu düzenlemek, ortak kuralları oluşturmak, turnuvaları organize etmektir. FIFA dünyada futbol organizasyonlarını, etkinliklerini düzenleyen kurum haline gelmiştir (Arık, 2004). Bu kurumun en büyük organizasyon 1930 yılından itibaren 4 yılda bir düzenlenen Dünya Kupası turnusudur. İlk dünya kupası turnusası 1930'da Uruguay'da düzenlenmiştir. Tüm bu gelişmeler ile birlikte futbol oyunu tüm dünyaya yayılmış, milyonlarca insanın fanatik olarak takip ettiği, popülerlik ile birlikte sporcuların kariyer için daha çok çabaladığı ve toplumları ortak bir çatı altında bir araya getiren fenomen bir spor haline gelmiştir (Göksel vd., 2016). Futbolun kurumsal yapısı, kuralları geçmişten günümüze kadar sürekli olarak gelişerek değişimler geçirmiştir. Uluslararası Futbol Birliği Kurulu (International Association Board- IFAB), oyun kurallarını belirlemek, kuralları güncellemek, oyunun evrensel standartları korumak, adil ve güvenli oyun ortamı sağlamak olarak ifade edilir. Kurallar adil ve güvenli oyun ortamının sağlanması ile birlikte oyundan zevk alınması ve futbola olan katılımı arttırarak futbolun gelişimine katkı sağlamıştır (IFAB, 2025).

Futbolda kuralların sahada uygulanmasını yürüten otorite hakem olarak isimlendirilmektedir. Hakem, kelimesi Arapça kökenli bir kelime olup Türkçe'de hüküm veren/karar veren anlamına gelmektedir. Futbol hakemi, futbol karşılaşmasını yönetmekle görevli, kuralları uygulama yetkisine sahip ve maçın zaman kontrolünü sağlayan kişidir (Sunay, 1992). Hakem, karşılaşan iki takım arasında düzeni sağlayan, sporcular ve seyircilerle etkileşimi yöneten ve oyun kurallarına göre karar verme yetkisine sahip olan görevlidir (Orta, 2000). Hakem her yönüyle örnek tarafsız bir bireydir. Müsabaka hakemlerinin oyun kurallarını eksiksiz bir şekilde bilerek karşılaşmayı kurallara uygun bir biçimde yönetmeleri zorunludur (Collina, 2004). Hakem sadece kuralları iyi bilmesine ek olarak fiziksel olarak formda olmak zorundadır çünkü müsabaka sırasında pozisyonlara en uygun yerde olması gerekmektedir. Futbol hakemlerinin diğer özellikleri etkili iletişim becerilerine ve liderlik vasıflarına sahip, psikolojik baskıları iyi bir şekilde yönetebilen bireyler olmalarıdır. Futbol hakemi, birer kaleci ile birlikte 11'er oyuncudan oluşan iki takım arasında yaklaşık 700 metre karelik bir oyun alanında gerçekleştiren müsabakayı yöneten, karşılaşmanın süresini kontrol eden ve önceden belirlenmiş futbol oyun kuralları çerçevesinde oyunun fair-play (adil oyun) ilkelerine uygun biçimde yürütülmesini ve sonuçlandırılmasını sağlamakla yetkilendirilmiş resmi görevlidir (Cengiz ve Pulur, 2004). Hakem sayısı ve tarihçesi futbol kurallarının gelişimine bağlı olarak değişmektedir (Şimşek, 1999). Futbol hakemlerine tam yetki 1890 yılında verilmiştir (Arıpınar, 1992). Hakem sayısı 1 hakemden 3 hakeme, daha sonra çizgi hakemleri ile 5 hakeme ve günümüzde VAR hakemleri ile sayıları futbol kurallarının adil icra edilebilmesi için artmıştır. Tüm yetkilerin hakemlere verilmesine rağmen olumsuz durumların devam etmesi üzerine orta hakem sahada tek yetkili kişi olarak atanmışlardır. Futbolda en çok karşılaşılan ve oyun kurallarına uymayan pozisyonlardan bir tanesi futbolcuların topa sahip olma noktasındaki mücadelesinde oyun kurallarının dışına çıkılıp çıkılmadığının tespit edilmesidir. Bu tespit

sahadaki tek yetkili olan orta hakem tarafından yapılmaktadır. Futbolda faul oyuncuların oyun kurallarına aykırı bir şekilde rakip oyuncuya karşı gerçekleştirdiği ve hakem tarafından cezalandırılması gereken fiziksel ve fiziksel olmayan müdahaleleri ifade etmektedir. IFAB tarafından yayımlanan oyun kurallarına göre faul rakibe tekme atmak veya tekme atmaya teşebbüs etmek, çelme takmak, sıçramak, itmek, vurmak, ya da vurma girişiminde bulunmak veya rakibi tutmak gibi eylemleri kapsayan kural ihlalleridir. Bu tür ihlaller oyunun güvenliğini sağlamak ve sportif rekabetin adil bir şekilde sürdürülmesini sağlamak amacıyla sahadaki yerine göre serbest vuruş veya penaltı vuruşu ile cezalandırılmaktadır (IFAB, 2023). Futbolda faul olmayan durumlar, temiz müdahale, kurala uygun oyun, faulsüz oyun olmak üzere üç farklı şekilde ifade edilmiştir. Temiz müdahale, oyuncunun rakibe yönelik müdahalesinin öncelikli olarak topa yönelmesi ve müdahale sırasında rakibe zarar verme potansiyeli taşıyan dikkatsiz, kontrolsüz ya da aşırı güç içeren bir hareketin bulunmaması durumunu ifade etmektedir. Bu tür müdahaleler, oyunun güvenliğini korumak ve adil rekabet ortamını sürdürmek açısından futbol kurallarının temel prensipleriyle uyumludur. Kurallara uygun oyun ise oyuncuların müsabaka süresince oyunu uluslararası futbol kuralları çerçevesinde sürdürmelerini ve rakip oyuncuların güvenliğini tehlikeye atacak davranışlardan kaçınmalarını kapsamaktadır. Bu yaklaşım, sporun etik değerlerini temsil eden ve futbolun temel ilkelerinden biri olarak kabul edilen fair play anlayışıyla doğrudan ilişkilidir. Buna ek olarak faulsüz oyun, oyuncuların rakiplerine karşı herhangi bir kural ihlali gerçekleştirmeden mücadele etmeleri ve oyunun hakem tarafından durdurulmasını gerektirecek bir ihlalin ortaya çıkmaması durumunu ifade etmektedir. Bu tür oyun davranışları, oyunun sürekliliğinin korunmasına, müsabakanın akıcılığının sürdürülmesine ve rekabetin adil bir şekilde yürütülmesine önemli ölçüde katkı sağlamaktadır (IFAB, 2023). Bununla birlikte hakem sayısının artması, hızlı ve akıcı oyunlarda karmaşık müdahalelerin ortaya çıkması, hakemin fiziksel formunun oyun hızına yetişememesi gibi durumlar faul tespitini zorlaştırmaktadır. Son yıllarda futbola giren VAR uygulaması oyundaki rekabeti temelden etkileyen kırmızı kart, penaltı ve gol durumlarının incelenmesi için otomatik olarak yapılmaktadır. Bununla birlikte VAR uygulaması ceza sahası dışı faullü müdahalelerde devreye girmemekte ve bu kararların verilmesi orta hakemin yetkisine bırakılmaktadır. Her ne kadar VAR teknolojisi / uygulaması ve gol çizgisi teknolojileri sahada günümüzde yoğun olarak kullanılmasına rağmen oyun devam ederken yapay zekâ çözümlerinden henüz faydalanılmamaktadır. Yapay zekâ uygulamaları genellikle oyun öncesi ve sonrası paydaşlar tarafından kullanılmaktadır. Bununla birlikte futbolda bilişim ve yapay zekâ uygulamaları günden güne de artmaktadır. VAR teknolojisi, gol çizgisi teknolojisi bilişim uygulamalarının sporda aktif kullanımlarına örnek olarak verilebilir. Oyun öncesi ve sonrası kullanılan yaklaşımlar arasında bireylerin hangi spora yatkın olduklarının belirlenmesi (Tang vd., 2026), sporcu performans analizlerinin oluşturulması (Habibi vd., 2025), sakatlık risk tahmini (Van Eetvelde vd., 2021) gibi alanlarda yapay zekâ yöntemleri kullanılmaktadır. Bu çalışmada bir pozisyonda futbol oyun kurallarında yasaklanmış bir eylem olan

faulün olup olmadığının tespit edilebilmesi için derin öğrenme yöntemlerinden biri olan SqueezeNet mimarisi çalışılmıştır.

Son yıllarda bilgisayarlı görü alanında en önemli gelişmelerden biri derin öğrenme tabanlı yöntemlerin yaygınlaşmasıdır. Özellikle Evrimsel Sinir Ağları (Convolutional Neural Networks – CNN) görüntü sınıflandırma, nesne tespiti ve video analizi gibi görevlerde oldukça başarılı sonuçlar elde etmiştir (Khan vd., 2020; LeCun vd., 2015). CNN mimarileri, görüntülerdeki uzamsal özellikleri otomatik olarak öğrenebilme yeteneğine sahip olup klasik makine öğrenmesi yöntemlerine göre daha yüksek doğruluk oranlarına ulaşabilmektedir. Bu alandaki önemli dönüm noktalarından biri, büyük ölçekli görüntü veri seti üzerinde eğitilen derin CNN mimarilerinin yüksek performans gösterdiğini ortaya koyan AlexNet (Krizhevsky vd., 2017) çalışmasıdır. Bu çalışma, derin öğrenmenin görüntü işleme alanında geniş çapta kullanılmasının önünü açmış ve sonraki yıllarda birçok gelişmiş mimarinin geliştirilmesine katkı sağlamıştır. Derin öğrenme modelleri yüksek doğruluk sağlamakla birlikte genellikle çok sayıda parametre içermekte ve bu durum hesaplama maliyetini artırmaktadır. Bu sorunu azaltmak amacıyla geliştirilen SqueezeNet (Iandola vd., 2016), AlexNet seviyesinde doğruluk sağlayabilen ancak çok daha az parametre içeren kompakt bir CNN mimarisidir. SqueezeNet mimarisi, özellikle Fire modülü adı verilen yapı üzerinden çalışır ve bu modül “squeeze” ve “expand” katmanlarından oluşur. Bu mimari, 1×1 filtrelerin yoğun kullanımı, kanal sayısının azaltılması ve geç downsampling stratejileri sayesinde parametre sayısını önemli ölçüde azaltırken doğruluk performansını korumayı hedeflemektedir. Yapılan çalışmalar SqueezeNet’in AlexNet ile benzer doğruluk seviyesine ulaşabildiğini ancak yaklaşık 50 kat daha az parametre içerdiğini göstermektedir. Bu nedenle çalışmamızda SqueezeNet mimarisi ile toplanan görüntüler sınıflandırılmış ve elde edilen sonuçlar raporlanmıştır.

Yöntem

SqueezeNet Tabanlı Derin Öğrenme Modeli

Bu çalışmada görüntülerdeki faul olup olmadığının sınıflandırılması için derin öğrenme tabanlı bir evrimsel sinir ağı mimarisi olan SqueezeNet kullanılmıştır (Iandola vd., 2016). SqueezeNet, parametre sayısını önemli ölçüde azaltırken yüksek doğruluk seviyesini korumayı amaçlayan hafif bir konvolüsyonel sinir ağı mimarisidir ve Şekil-1’de ağın genel mimarisi verilmiştir. Bu derin öğrenme modeli ilk olarak 1943 yılında Warren McCulloch ve Walter Pitts tarafından önerilmiş olup, model boyutunu küçültmek amacıyla üç temel tasarım stratejisine dayanmaktadır (Iandola vd., 2016). Birinci strateji, 3×3 konvolüsyon filtrelerinin mümkün olduğunca 1×1 filtrelerle değiştirilmesidir. Bu yaklaşım ağı eğitilecek toplam parametre sayısını azaltmaktadır. İkinci strateji, 3×3 filtrelerin giriş kanal sayısını azaltmak amacıyla “squeeze” katmanlarının kullanılmasıdır. Bu katmanlar, genişletme (expand) katmanlarından önce gelen daraltma işlemini gerçekleştirir. Üçüncü strateji ise aşağı örnekleme

(downsampling) işlemlerinin ağına daha ileri katmanlarına ertelenmesidir. Bu sayede erken katmanlarda daha yüksek çözünürlüklü özellik haritaları korunarak sınıflandırma performansı artırılmaktadır.

SqueezeNet mimarisinin temel yapı taşı Fire modülü olarak adlandırılan özel bir bloktur. Fire modülü iki ana bileşenden oluşmaktadır: squeeze katmanı ve expand katmanı. Squeeze katmanı 1×1 konvolüsyon filtreleri kullanarak giriş özellik haritalarının kanal sayısını azaltırken, expand katmanı hem 1×1 hem de 3×3 konvolüsyon filtreleri kullanarak özellik temsilini genişletmektedir. Bu yapı sayesinde model hem hesaplama maliyetini düşürmekte hem de temsil gücünü korumaktadır.

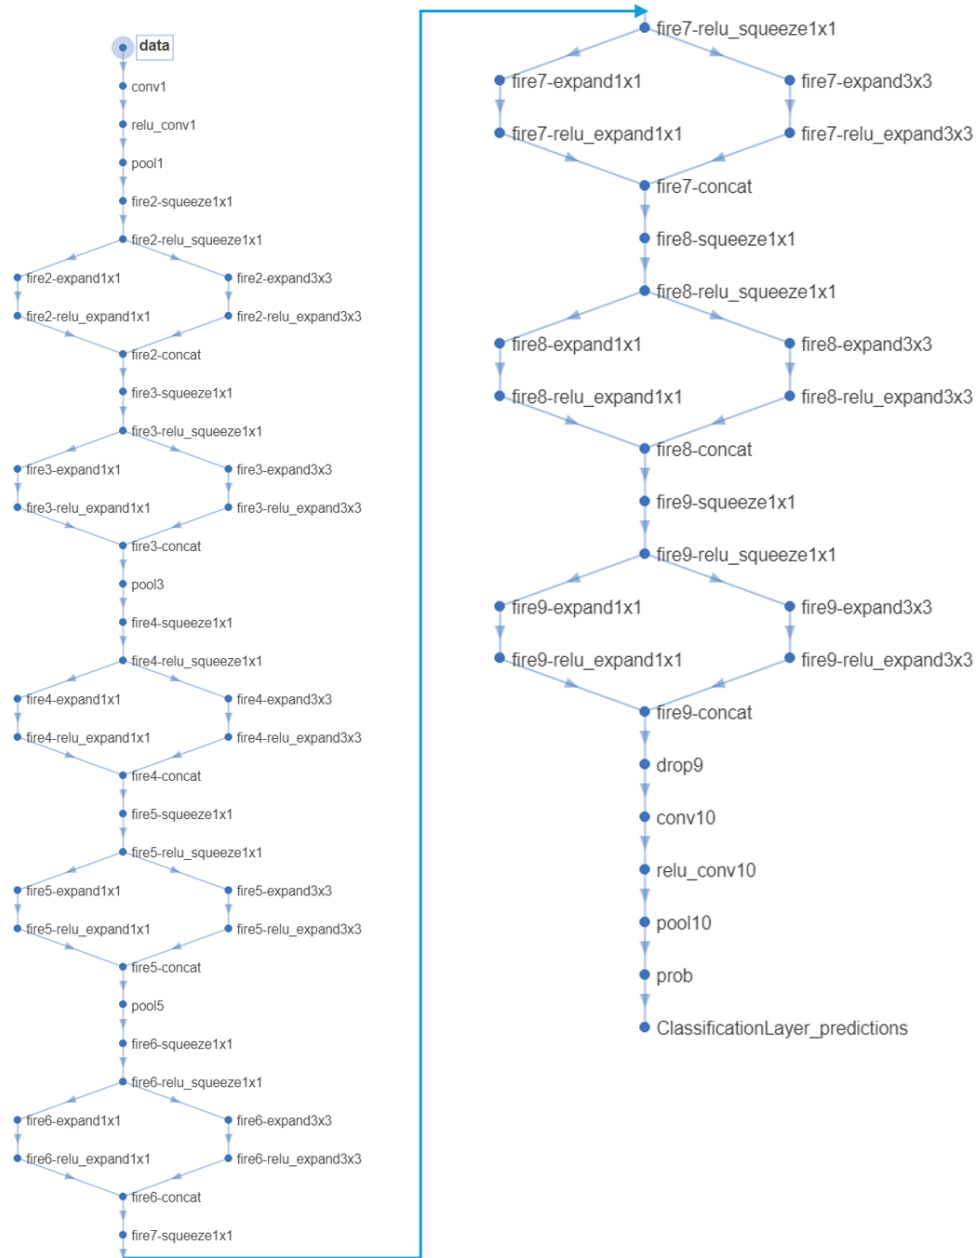
Çalışmada kullanılan SqueezeNet modeli, büyük ölçekli görüntü veri kümesi olan ImageNet üzerinde önceden eğitilmiş ağırlıklar ile başlatılmıştır (Anonim, 2012). Bu yaklaşım transfer öğrenme (transfer learning) olarak bilinmektedir ve özellikle sınırlı veri setlerinde modelin daha hızlı yakınsamasını ve daha yüksek doğruluk elde edilmesini sağlamaktadır. Önceden eğitilmiş ağına son sınıflandırma katmanı, çalışmada kullanılan veri setindeki sınıf sayısına uygun olacak şekilde (faul var veya yok) yeniden düzenlenmiştir.

SqueezeNet mimarisi yaklaşık 1.2 milyon parametre içermekte olup, bu değer geleneksel derin ağı mimarilerine kıyasla oldukça düşüktür. Örneğin AlexNet mimarisine göre yaklaşık 50 kat daha az parametre içermesine rağmen benzer doğruluk seviyesine ulaşabilmektedir (Krizhevsky vd., 2017). Bu nedenle SqueezeNet, özellikle sınırlı hesaplama kaynaklarına sahip sistemlerde ve hızlı prototipleme için tercih edilen bir derin öğrenme mimarisidir.

Bu çalışmada model eğitimi ve uygulaması MATLAB ortamında gerçekleştirilmiş olup görüntü verileri uygun boyutlara yeniden ölçeklendirilerek ağa giriş olarak verilmiştir. Eğitim sürecinde veri kümesi eğitim, doğrulama ve test alt kümelerine ayrılmış ve model performansı doğruluk (accuracy) metriği kullanılarak değerlendirilmiştir.

Şekil 1

SqueezeNet Derin Öğrenme Mimarisi



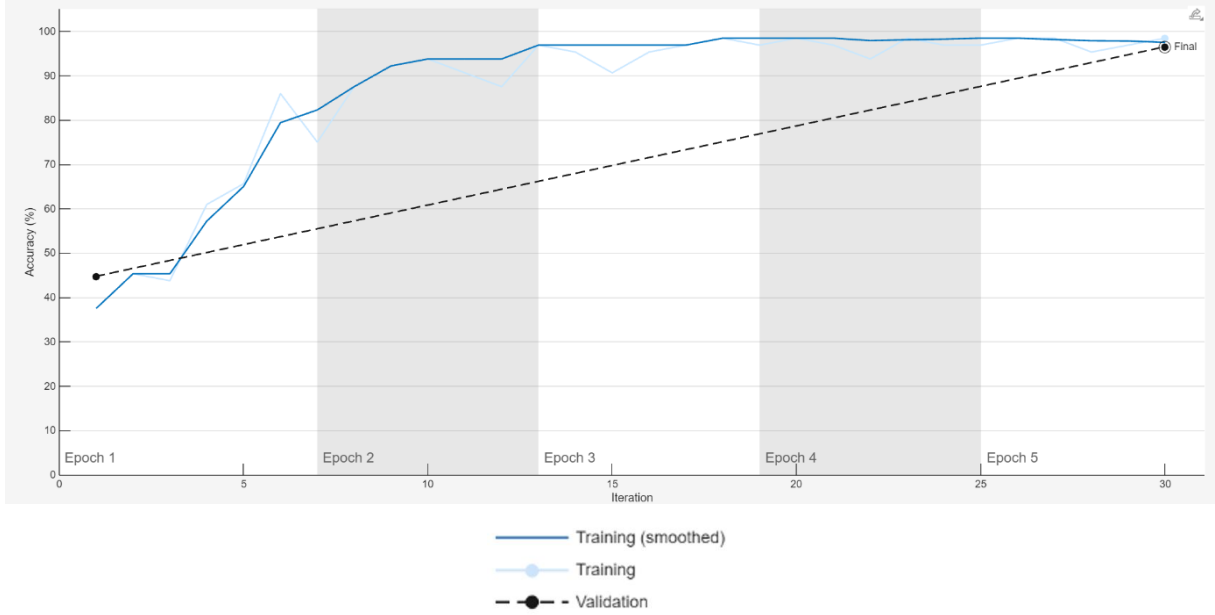
Bulgular

Görüntü veri setimiz 716 görüntüden oluşmaktadır. Bu görüntülerden 461 tanesinde faul varken, 255 tanesinde faul yoktur. Veri seti %70 ve %30 olarak iki bölüme ayrılmıştır. Kullanılan derin öğrenme modeli veri setinin %70'lik kısmında eğitim sürecine tabi tutulmuştur. Ağ eğitimi tamamlandıktan sonra geri kalan %30 veri seti ile eğitilmiş ağ test edilmiştir. Matlab ortamında ağın

varsayılan modeli kullanılmıştır ve epok sayısı 5 (her epokta 6 iterasyon) ve yığın boyutu (batch size) 64 olarak ayarlanmıştır. Aynı şartlarda model 10 defa çalıştırılmış ve elde edilen sonuçlar raporlanmıştır. Matlab'de yapılan eğitimlerden birinin eğitim-doğrulama grafiği Şekil-2'de verilmiştir.

Şekil 2

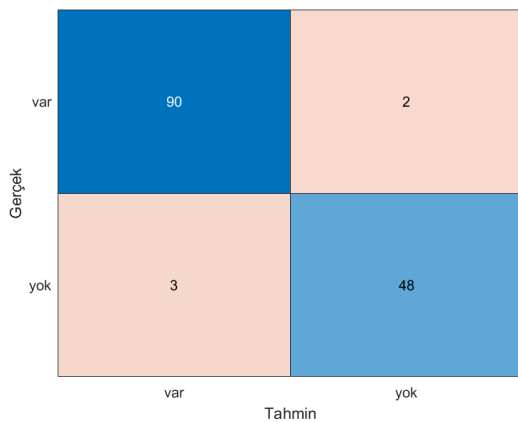
Derin Öğrenme Modelinin Veri Seti Üzerinde Eğitim ve Doğrulama Grafiği



SqueezeNet modelinin veri seti üzerinde eğitimlerinin ortalaması %97.21 olarak; doğrulama ise %96.57 olarak elde edilmiştir. Ağın ortalama test doğruluğu ise %95.42 olarak bulunmuştur. Testlerden bir tanesinin konfüzyon matrisi Şekil-3'te verilmiştir.

Şekil 3

Konfüzyon Matrisi



Konfüzyon matrisinden görüldüğü üzere ağ test veri kümesi üzerinde sınıflar için benzer başarılar elde etmektedir ve herhangi bir sınıfa karşı yanlılığı olmadığı görülmektedir. Bununla birlikte hassasiyet (precision) %96.77, hatırlama (recall) %97.83 ve f1 skoru %97.3 olarak Şekil 3'te verilen

konfüzyon matrisi değerleri ile hesaplanmıştır. Bu durumda modelin faul tespitinde yüksek başarımlı gösterdiğini doğrulamaktadır.

Tartışma ve Sonuç

Bu çalışmada futbol müsabakalarında faul durumlarının otomatik olarak tespit edilmesi amacıyla derin öğrenme tabanlı bir yaklaşım uygulanmıştır. Bu kapsamda, SqueezeNet mimarisi kullanılarak internetten toplanan görüntüler üzerinde bir sınıflandırma modeli geliştirilmiştir. Veri seti toplam 716 görüntüden oluşmakta olup bunların 461'i faul, 255'i ise faul olmayan görüntülerden meydana gelmektedir. Modelin eğitimi için veri kümesi %70 eğitim ve %30 test olacak şekilde ayrılmıştır. Elde edilen sonuçlar, kullanılan modelin veri seti üzerinde oldukça başarılı bir performans gösterdiğini ortaya koymaktadır. Eğitim sürecinde modelin ortalama eğitim doğruluğu %97.21, doğrulama doğruluğu ise %96.57 olarak elde edilmiştir. Test veri kümesi üzerinde yapılan değerlendirme sonucunda modelin ortalama test doğruluğu %95.42 olarak hesaplanmıştır. Literatürdeki çalışmalar incelendiğinde benzer sonuçlar elde edildiği görülmektedir. Rabee ve diğerleri (2025) EfficientNetV2, ResNet50, VGG16, Xception, InceptionV3, MobileNetV2, InceptionResNetV2, DenseNet121 derin öğrenme mimarilerini futbol faullerinin belirlenmesinde kullanmışlardır. Bu çalışmada en yüksek hassasiyet değeri 0.9786 ile DenseNet121, en yüksek hatırlama ise 0.8396 InceptionResNetV2, en yüksek f1 skoru 0.8966 InceptionResNetV2, ortalama doğruluk 0.9641 DenseNet121 mimarisi ile elde edilmiştir (Rabee vd., 2025). Bir başka çalışmada YOLO ve Faster R-CNN gibi tek atışlı derin öğrenme mimarileri uygulanmış ve ortalama hassasiyet metriği üzerinden karşılaştırma yapılmıştır. YOLOv5 modeli ile %96.6, YOLOv8 modeli ile %97.2, YOLO-NAS modeli ile %94.4 ve Faster R-CNN modeli ile %89.85 hassasiyet değeri elde edilmiştir (Siddiqui vd., 2024). Bizim çalışmamızdan elde edilen sonuçlarla benzer olduğu görülmektedir. Literatür ile uyumlu olarak önerilen modelin test doğruluğunun %95'in üzerinde olması, modelin yalnızca eğitim verileri üzerinde değil, daha önce görmediği veriler üzerinde de başarılı sonuçlar üretebildiğini göstermektedir. Eğitim ve doğrulama doğrulukları arasındaki farkın düşük olması ise modelin aşırı öğrenme (overfitting) problemini büyük ölçüde engellediğini ortaya koymaktadır. Ayrıca elde edilen sonuçlar, önerilen yaklaşımın farklı derin öğrenme mimarileriyle gerçekleştirilen güncel çalışmalarla rekabet edebilecek düzeyde olduğunu ve ilgili problem alanında güvenilir bir çözüm sunduğunu göstermektedir. Bu değerler, modelin yalnızca eğitim verisini öğrenmekle kalmayıp aynı zamanda daha önce görmediği veriler üzerinde de başarılı bir genelleme yeteneğine sahip olduğunu göstermektedir.

Konfüzyon matrisi incelendiğinde modelin faul olan görüntüleri büyük ölçüde doğru sınıflandırdığı görülmektedir. Toplam 90 faul görüntüsü doğru şekilde tespit edilirken, yalnızca 2 faul görüntüsü yanlış şekilde faul değil olarak sınıflandırılmıştır. Benzer şekilde, faul olmayan 48 görüntü doğru sınıflandırılırken 3 görüntü yanlışlıkla faul olarak tahmin edilmiştir. Bu sonuçlar modelin hem

duyarlılık hem de özgülük açısından yüksek bir performansa sahip olduğunu göstermektedir. Özellikle spor analizlerinde kritik olan faul tespiti için kaçırılma oranının düşük olması, modelin pratik uygulamalar açısından umut verici olduğunu göstermektedir.

Eğitim sürecinde elde edilen öğrenme eğrileri incelendiğinde, modelin ilk epoklardan itibaren hızlı bir şekilde öğrenme gerçekleştirdiği ve doğruluk değerlerinin kısa sürede yüksek seviyelere ulaştığı gözlemlenmiştir. Bu durum modelin eğitim sürecinde kararlı bir şekilde yakınsadığını ve aşırı öğrenme probleminin sınırlı seviyede olduğunu göstermektedir. Eğitim ve doğrulama doğruluklarının birbirine oldukça yakın olması da bu durumu desteklemektedir.

Bu çalışmada tercih edilen SqueezeNet mimarisi, diğer derin evrimsel sinir ağı modellerine kıyasla oldukça düşük parametre sayısına sahip olmasına rağmen yüksek doğruluk elde edebilmesiyle dikkat çekmektedir. Özellikle yaklaşık 1.2 milyon parametreye sahip olması, modeli hem hızlı hem de hesaplama maliyeti açısından verimli hale getirmektedir. Bu özellikler, modelin gerçek zamanlı spor analizi sistemlerinde kullanılabilmesi açısından önemli bir avantaj sağlamaktadır. Bununla birlikte çalışmanın bazı sınırlılıkları da bulunmaktadır. Öncelikle veri seti nispeten sınırlı büyüklükte olup görüntüler internet ortamından toplanmıştır. Bu durum veri setinde farklı kamera açıları, çözünürlükler ve sahne koşulları gibi heterojen özelliklerin bulunmasına neden olabilir. Ayrıca veri setindeki sınıf dağılımı da tamamen dengeli değildir. Daha geniş ve dengeli veri setleri kullanılarak modelin performansı daha kapsamlı biçimde değerlendirilebilir. Bunun yanında farklı derin öğrenme mimarileri (örneğin ResNet veya EfficientNet) ile karşılaştırmalı çalışmalar yapılması model performansının daha iyi analiz edilmesine katkı sağlayabilir.

Gelecekte yapılacak çalışmalarda veri setinin genişletilmesi, veri artırma tekniklerinin kullanılması ve video tabanlı analizlerin gerçekleştirilmesi önemli araştırma yönleri olarak değerlendirilebilir. Özellikle video akışları üzerinde çalışan gerçek zamanlı sistemler geliştirilerek hakem destek sistemleri veya spor analitiği uygulamalarında otomatik faul tespiti gerçekleştirilebilir.

Sonuç olarak, bu çalışmada geliştirilen derin öğrenme tabanlı modelin spor görüntülerinde faul tespiti için yüksek doğruluk oranlarına ulaşabildiği görülmüştür. Elde edilen sonuçlar, derin öğrenme yöntemlerinin spor analizi alanında etkili bir araç olabileceğini göstermekte ve otomatik hakem destek sistemlerinin geliştirilmesi açısından önemli bir potansiyel sunmaktadır.

Araştırma ve Yayın Etiği

Bu çalışmada “Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesi” kapsamında uyulması belirtilen tüm kurallara uyulmuştur. Yönergenin ikinci bölümü olan “Bilimsel Araştırma ve Yayın Etiğine Aykırı Eylemler” başlığı altında belirtilen eylemlerden hiçbiri gerçekleştirilmemiştir.

Etik kurul izin bilgileri

Çalışmada etik kurul izni gerektirmediği için etik beyan formu kullanılmıştır.

Yazarların Katkı Oranı

Çalışma tek yazarlı olarak yayınlanmıştır. Yazar katkısı % 100'dür.

Çıkar Çatışması

Çalışmada çıkar çatışması teşkil edebilecek bir husus bulunmamaktadır.

Kaynaklar

- Acet, M. (2001). *Futbol seyircisini fanatik ve saldırgan olmaya yönelten sosyal faktörler* [Yayınlanmamış doktora tezi], Gazi Üniversitesi.
- Akgeyik, T. (2018). Futbolda başarıyı etkileyen faktörler (Türkiye süper lig takımları üzerine ampirik bir araştırma). *Hak İş Uluslararası Emek ve Toplum Dergisi*, 7(18), 396-413.
- Arık, B. (2004). *Top ekranda: medya çağında futbol ve televizyon arasındaki kaçınılmaz ilişki*. Salyangoz Yayınları.
- Arıpınar, E. (1992). *Türk futbol tarihi*. Türkiye Futbol Federasyonu Yayınları.
- Aycan, İ. (2022). *Life kinetik antrenmanlarının futbolcu performansları üzerindeki etkilerinin incelenmesi*. [Yayınlanmamış yüksek lisans tezi], Ondokuz Mayıs Üniversitesi.
- Bozdemir, M. (1998). *Futbol fanatizminin sosyolojik açıdan tahlili* Marmara Üniversitesi (Türkiye).
- Cengiz, R., ve Pulur, A. (2004). *Hakemlerin fair play olaylarına bakış açıları*. Celal Bayar Üniversitesi Spor Felsefesi ve Sosyal Bilimleri Sempozyumu, Manisa. Türkiye.
- Anonim. (2012). Imagenet <http://www.image-net.org/challenges.LSVRC/2012/results.html>.
- Collina, P. (2004). *Le mie regole del gioco - benim oyun kurallarım*. Altın Kitaplar Yayınevi.
- Dağ, Ü. (2019). *Futbolda parasallaşma ve futbol rekabetine olan etkilerinin çeşitli açılardan incelenmesi* [Yayınlanmamış yüksek lisans tezi], Çanakkale Onsekiz Mart Üniversitesi.
- Devecioğlu, S., Çoban, B., ve Karakaya, Y. (2014). Futbol yönetimi ve organizasyonlarının görünümü. *Spor ve Performans Araştırmaları Dergisi*, 5(1), 35-48.
- Göksel, A., Pala, A., ve Caz, Ç. (2016). Futbol hakemlerinin boş zamanlarını değerlendirme tercihleri ile iletişim becerileri arasındaki ilişkinin incelenmesi. *Uluslararası Hakemli İletişim ve Edebiyat Araştırmaları Dergisi (UHIVE)*, 11(7), 15-28.
- Habibi, M., Nourani, M., ve Nourani, M. M. (2025). *AI-based performance analysis for track and field athletes*. Presented at 47th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Copenhagen, Denmark
- Iandola, F. N., Han, S., Moskewicz, M. W., Ashraf, K., Dally, W. J., ve Keutzer, K. (2016). SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. *arXiv preprint arXiv:1602.07360*.
- IFAB. (2023). International Football Association Board Laws of the Game.
- IFAB. (2025). The IFAB Organisation. <https://www.theifab.com/organisation/>
- Khan, A., Sohail, A., Zahoor, U., ve Qureshi, A. S. (2020). A survey of the recent architectures of deep convolutional neural networks. *Artificial intelligence review*, 53(8), 5455-5516.
- Krizhevsky, A., Sutskever, I., ve Hinton, G. E. (2017). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84-90.
- LeCun, Y., Bengio, Y., ve Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444.
- Orta, L. (2000). Dünya'da ve Türkiye'de futbol hakemliğinin başlangıcı ve gelişimi semineri. *Onsekiz Mart Üniversitesi Beden Eğitimi ve Spor Bölümü, Çanakkale. Türkiye*.
- Rabee, A., Anwar, Z., AbdelMoety, A., Abdelsallam, A., ve Ali, M. (2025). Comparative analysis of automated foul detection in football using deep learning architectures. *Scientific Reports*, 15(1), 14236.
- Siddiqui, B. S., Mridul, Z. A., Habib, Z., Sakib, I., ve Chowdhury, M. A. I. (2024). *Real-time foul detection in football matches using machine learning techniques*. [Doctoral Dissertation], Brac University.
- Sunay, H. (1992). Ankara bölgesi futbol hakemlerinin hakemliğe yönelmelerine etki eden motivasyonel etkenler üzerine bir araştırma. *Futbol Bilim ve Teknoloji Dergisi*, 2(2), 18-23.
- Şimşek, M. (1999). Futbolun Prensleri. *Nadir Yayınevi, İstanbul*.
- Tang, Q., Wei, X., ve Tan, B. (2026). The role of machine learning in talent identification for team sports: A systematic review. *Journal of Sports Science and Medicine*, 25(1), 58-83.
- TDK. (2023). Türk Dil Kurumu Güncel Türkçe Sözlük. <https://sozluk.gov.tr>
- Terlemez, M., ve Kumcu, S. (2024). Osmanlı döneminde futbolun doğuşu ve kurulan futbol kulüpleri. *Kafkas Üniversitesi Spor Bilimleri Dergisi*, 4(2), 24-62.
- Van Eetvelde, H., Mendonça, L. D., Ley, C., Seil, R., ve Tischer, T. (2021). Machine learning methods in sport injury prediction and prevention: a systematic review. *Journal of experimental orthopaedics*, 8(1), 27.

Copyrights

Copyright for this article is retained by the author(s), with first publication rights granted to the Journal. This is an open-access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY) License.



Canonical URL <https://creativecommons.org/licenses/by/4.0/>