

Uçuşa Elverişlilik İçin Derin Öğrenme Tabanlı Pist Yüzeyi Çatlak Tespiti Yaklaşımı

Nurcan Sarıkaya Baştürk^{*1}, Fatmanur Güven²

*¹ Erciyes Üniversitesi, Havacılık ve Uzay Bilimleri Fak., Havacılık Elektrik ve Elektronik Bölümü, KAYSERİ
² Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Sivil Havacılık ABD, KAYSERİ

(Alınış / Received: 19.06.2023, Kabul / Accepted: 17.07.2023, Online Yayınlanma / Published Online: 31.08.2023)

Anahtar Kelimeler

Uçuşa Elverişlilik,
Pist Yüzey Denetimi,
Derin Öğrenme,
Evrişimli Sinir Ağları

Öz: Uçuş emniyeti, havacılık endüstrisindeki önemli konulardan biridir. Uçuş emniyetini doğrudan etkileyen hususlardan biri ise uçuş pistlerinin yüzey şartlarıdır. Pistlerin yüzey şartlarının denetim ve kontrolleri güvenli bir uçuş için büyük önem arz eder. Pist yüzeylerinde denetlenen başlıca durumlar, çatlama, kırılma, kopma, açılma ve kabarma gibi zemin hasarlarıdır. İlgili denetimsel işlemler zaman alıcı süreçler olup, alanında eğitim almış uzman personel tarafından yapılmaktadır. Derin öğrenme, son yıllarda popülerliği oldukça artan bir makine öğrenmesi yaklaşımıdır. Bu çalışmada, uçuş pistlerinin yüzeylerindeki çatlaklıkların tespitini yapmak amacıyla iki farklı derin öğrenme modeli geliştirilmiştir. İlk model bu çalışmaya yönelik baştan tasarlanan ve sıfırdan eğitilen özgün bir evrişimli sinir ağı iken; ikinci model AlexNet mimarisinin öğrenme aktarımı yoluyla bu çalışmaya özgü eğitilmiş sürümüdür. Modeller, veriler üzerinde test edilmiş ve elde ettikleri başarı oranları raporlanmıştır.

Deep Learning Based Runway Surface Crack Detection Approach For Airworthiness

Keywords

Airworthiness,
Runway Surface Inspection,
Deep Learning,
Convolutional Neural Networks

Abstract: Flight safety is one of the important issues in the aviation industry. One of the issues that directly affects flight safety is the surface conditions of the runways. Inspection and control of runway surface conditions are of great importance for a safe flight. The main conditions inspected on runway surfaces are ground damages such as cracking, breaking, rupture, opening and heaving. The related inspection procedures are time-consuming processes and are carried out by specialized personnel trained in the related field. Deep learning is a machine learning approach that has become increasingly popular in recent years. In this study, two different deep learning models are developed to detect cracks on the surface of runways. The first model is a pure convolutional neural network designed and trained from scratch for this study, while the second model is a version of the AlexNet architecture trained for this study through transfer learning. The models were tested on the data and their success rates were reported.

*İlgili Yazar, email: nurcanb@erciyes.edu.tr

1. Giriş

Uçuşa elverişlilik, hava araçlarının ve bu araçların uçuş güvenliklerini etkileyecek koşulların uçuşa uygun olup olmadığının kontrolüdür. Yapılan test, bakım ve gözetimlerin ardından hava aracının uçuşa elverişli olup olmadığı belirlenir. Uçuşa elverişlilik için belirlenen temel bazı kurallar vardır. Ülkemizde bu kuralların sorumluluğu Sivil Havacılık Genel Müdürlüğü'ne bağlıdır.

Uçuşa elverişlilikteki eksiklikler, bir olay ya da kazaya sebebiyet verebilirler. Uçuşa elverişlilik için can ve mal güvenliğini sağlamak adına en önemli faktörlerden birisi pist yüzey şartlarıdır. Pist yüzeyi, daimî olarak denetim ve kontrol altında tutulmalıdır. Pist yüzeyi kontrollerindeki yüzey çatlakları uçuşa elverişlilik için büyük önem arz eder. Tespit edilen çatlaklar ilgili birimlerce en kısa sürede onarılmalı ve kayıt altına alınarak muhafaza edilmelidir. Uçuş pistleri, yüzey yapısı, kullanılan malzeme vb. gibi çeşitli açılardan uçuş güvenliğini doğrudan

etkiler. Yüzey pürüzleri, uçak manevraları ya da kontrolleri esnasında aşırı sallanmaya, titremeye veya sair zorluklara sebep olabilir, kalkışı ve inişi olumsuz yönde etkileyebilirler [1]. Pist yüzeyleri, frenleme kaybına ve bahsedilen olumsuzluklara sebebiyet vermeyecek biçimde inşa edilmelidir.

Yapay zekâ, günümüzde gelişimini hızlı bir şekilde sürdürmektedir. Yapay zekânın bir alt dalı olan derin öğrenme, girdi olarak beslenen görüntü ya da farklı türden işaretler için efektif sonuçlar üreten etkili bir yöntemdir. Derin öğrenme, diğer modellerle karşılaştırıldığında en büyük farkı kullanıcının girdi verilerini belirlemesinin ardından, çalışma, kontrol, sonuç üretme kısımlarının çoğunlukla modele ait olmasıdır. Bundan dolayı görüntü sınıflandırma, ses tanıma, nesne tanıma ve nesne takibi gibi birçok alanda başarılı sonuçlar vermektedir. Bu özelliklerinden faydalanarak, uçuş pistleri ve diğer farklı yüzeylerin kusurlarını tespit etmek ve sınıflandırmak için kullanılabilirler mümkündür [2].

Yazgan ve Yılmaz [3]; insan faktörü risklerini yönetmeye bağlı olarak havayollarının sürdürülebilir uçuşa elverişlilik stratejileri hakkında bilgi vermişlerdir. Aktif yönetim teknolojisi (AMT) hatasını etkileyen alt kriterlerin önceliklendirilmesi için geliştirilen analitik ağ süreci (ANP) modeli oluşturmuşlardır. AMT hatasına katkıda bulunan toplam 15 önemli kriter ANP modeline dahil edilmek üzere üç ana kümede seçilmiştir. Sonuçlar, bağımlılıklar dikkate alındığında AMT hatasını etkileyen kriterlerin teknisyen performansı üzerindeki etkisini göstermekte ve çok kriterli karar verme analizinde insan performansını etkilemede karşılıklı bağımlılıklarını dikkate almanın önemini vurgulamıştır.

Tatlı [4]; meteorolojik açıdan uçuşa elverişlilik ölçütlerini saptamış ve günlük uçuşa elverişli saatleri ele alarak zaman serileri elde etmiştir. Elde ettiği zaman serilerini, yapay sinir ağı (YSA) yönteminde kullanarak uçuşa elverişli saat miktarı tahminini gerçekleştirmiştir.

Wang vd. [5]; güvenli olmayan olaylar için uçuş oranı tahminini, büyük verinin özelliklerini göz önünde bulundurarak derin öğrenme temelinde önermişlerdir. Önerilen yöntemin, gri sinir ağı yöntemi, destek vektörü regresyonu, derin inanç ağları ile karşılaştırıldığında uçuş oranını tahmin etmekte daha üstün olduğu belirtilmiştir.

Inacio vd. [6]; bir havaalanının gözetimi için tespit edilen nesnelere sınıflandırmışlardır. Tüm süreç, bir nesne algılama aşaması ve ardından bir sınıflandırma aşamasını içermiştir. Algoritma verimliliğini göstermek amacıyla deneysel sonuçları da paylaşmışlardır.

Tsai vd. [7]; havaalanı pisti banketlerinde çatlak sızdırmazlık maliyetini doğru bir şekilde tahmin etmek için, 3D çizgi lazer görüntüleme teknolojisi, otomatik çatlak tespiti ve genişlik ölçüm algoritmalarını kullanan otomatik bir yaklaşım önermişlerdir. Önerilen yöntem kullanılarak, Hartsfield Jackson Atlanta Uluslararası Havalimanı'nda 30,5 m (100 ft) bir pist omzu üzerinde bir vaka çalışması gerçekleştirilmiştir. Sonuçta önerilen yöntemin, maliyet etkin ve güvenilir bir şekilde otomatik bir yaklaşım sağlamak için çok umut verici olduğunu belirtmişlerdir.

Yang vd. [8]; derin öğrenmedeki son gelişmelerden esinlenerek, yeni bir ağ mimarisi önermişlerdir. Önerilen ağ, bir özellik piramidinde çatlak tespiti için bağlam bilgisini düşük seviyeli özelliklere entegre etmiştir. Ağın üstünlüğünü ve genellenebilirliğini, üzerinde çalıştıkları birbirinden farklı beş çatlak veri setiyle desteklemiştir.

Xie vd. [9]; havalimanı pist denetimi için gereken maliyeti ve zamanı azaltmak için drone ile yakalanan görüntülere dayalı olarak kaplama çatlak segmentasyonu için U-Net derin sinir ağını kullanmışlardır. Massachusetts'teki Fitchburg Municipal Havalimanı'ndan pist kaplama görüntülerini çeşitli yüksekliklerde drone kullanarak elde etmişler ve yakalanan drone görüntülerini, U-Net modelinin çatlak segmentasyon performansını değerlendirmek için kullanmışlardır. Sonuçlar, U-Net'in sınırlı eğitim görüntüleri ile bile test verileri üzerinde iyi performans gösterdiğini ve bunun iyi bir genelleme kabiliyetine sahip olduğunu göstermiştir.

Peng vd. [10]; havaalanı pist kaplaması çatlak tespitinde, pist kaplamasındaki işaretlemenin genellikle çatlak tespitini bozacağını ifade ederek iki eşikli bölütleme teknolojisine dayanan çatlak tespitini sunmuşlardır. İlk olarak, geliştirilmiş Otsu eşik segmentasyon algoritması kullanılarak pist görüntüsündeki yol işaretleri kaldırılmış, ardından çatlak görüntüsünü elde etmek için geliştirilmiş uyarlanabilir yinelemeli eşik bölütleme algoritması tarafından bölümlere ayrılmıştır. Yöntemin, yol işaretlemesi içeren pist görüntülerindeki çatlak etkili bir şekilde tespit edebildiğini, simülasyon deneyleri ile kanıtlamışlardır.

Jo ve Jadidi [11]; herhangi bir otonom araçta kullanılabilir yeni bir otonom çatlak tespit sistemi önermişlerdir. Otonom çatlak tespit sistemi, görüntü elde etme, görüntü işleme ve sınıflandırma şeklinde üç aşamadan oluşturulmuştur. Uygulama için çatlaklı veya çatlaksız 15000 RGB ve kızılötesi görüntü kullanmışlardır. Sonuçlar, önerilen sistemin yüksek hassasiyetli olduğunu göstermiştir.

Gopalakrishnan vd. [12]; milyonlarca görüntü içeren ImageNet veri tabanı üzerinde eğitilmiş bir evrişimli sinir ağı (CNN) kullanarak sıcak karışım asfalt ve portland çimento betondaki çatlakları otomatik olarak algılamayı hedeflemişlerdir. Farklı yüzey özelliklerine sahip sıcak karışım asfalt yüzeyli ve portland çimento beton yüzeyli birleşik görüntüler üzerine bir sınıflandırıcı eğitmeye çalışılmıştır. ImageNet, VGG16 CNN özellikleri üzerinde eğitilmiş tek katmanlı bir sinir ağı sınıflandırıcısı olarak iyi bir performans vermiştir.

Qurishee vd. [13]; çatlak ve çatlak olmayan tip yapıyı otomatik olarak tespit etmek için bir CNN geliştirmişlerdir. Bridge Kirder'da derin öğrenmeyi uygulamaya yönelik bir pilot çalışma olarak, UTC kampüsü eski garaj beton tavan döşemesinin yapısındaki çatlağın tanınmasını, uzunluğunu ve yerini incelemişlerdir. UTC Old Library otopark tavanından toplam 2086 çatlak ve çatlak olmayan görüntü alınmıştır. Model, çatlaklı ve çatlaksız yapı türlerinde %98 doğruluk göstermiştir.

Gopalakrishnan [14]; derin öğrenme konusunda yakın zamanda yayınlanmış çalışmalarını incelemişlerdir. Derin öğrenme yazılım çerçeveleri, ağ mimarisi, her çalışma tarafından kullanılan hiper parametreler ve çatlak algılama performansı üzerinde durarak kaldırım veya kaplama bağlamında daha fazla araştırma yapmak isteyenler için iyi bir temel oluşturmasını beklediğini dile getirmiştir.

Gopalakrishnan vd. [15]; sivil altyapının çatlak hasarı tespiti için öğrenme aktarımlı önceden eğitilmiş derin öğrenme modellerinin İHA görüntülerine yönelik kullanımını önermişlerdir. Önerilen yaklaşımın sağlamlığını, eğitim ve doğrulama sırasında kullanılmayan karmaşık UAV kaynaklı altyapı görüntüleri üzerinde test etmişlerdir. Sonuçlar, önerilen yöntemin herhangi bir büyütme ve ön işleme gerek duymadan gerçekçi durumlarda çatlakları bulmada hızlı ve kolay bir şekilde %90'a varan doğruluk elde edebileceğini göstermiştir.

Cha vd. [16]; kusur özelliklerini hesaplamadan beton çatlaklarını tespit etmek için CNN tabanlı bir yöntem önermişlerdir. Tasarlanmış CNN, 256×256 piksel çözünürlükteki 40K görüntü üzerinde eğitilmiş ve sonuç olarak yaklaşık %98 doğruluk sağlamıştır. Geleneksel Canny ve Sobel kenar algılama yöntemleri kullanılarak önerilen CNN'nin performansını incelemek için karşılaştırmalı çalışmalar yapılmıştır.

Coca vd. [17]; binalarda ulaşılması zor veya insan hayatını tehlikeye atacak çatlakları tespit eden bir uygulama sunmuşlardır. Uygulama mimarisi CNN üzerine kuruludur. İnsan performansını iyileştirmek ve çatlak algılama sürecini otomatikleştirmek için bu uygulamanın geliştirildiği belirtilmiştir.

Ha vd. [18]; derin öğrenme tabanlı nesne algılama tekniklerinden olan Mobilenet-SSD'nin, çatlak türlerinin ve çatlak alanlarının eş zamanlı algılanmasını etkili bir şekilde otomatikleştirmek için kullanıldığı bir yöntemi ele almışlardır. Yol çatlakları için nesne algılamanın doğruluğunu artırmak amacıyla, girdi görüntüsünün otomatik bölümlenmesi ve nesne algılama modeli için U-Net'i birleştirmek üzere birkaç deney yapılmıştır. U-Net ile görüntü maskeleyen, 0,9315 mAP değeri ile nesne algılama performansını en üst düzeye çıkarabileceği vurgulanmıştır.

CNN tabanlı çatlak tespit teknikleri temel olarak iki gruba ayrılır. İlk grup olan blok düzeyinde algılama, çatlak yamalarının algılanmasına ve üzerlerinde sınırlayıcı kutular sağlanmasına dayanır. İkinci grup olan piksel düzeyinde algılama ise çatlakların piksel düzeyinde algılanmasını temel alan çatlak segmentasyonuna (delineation) dayanır. Yang vd. [19] ve Ni ve Zhang [20] gibi piksel düzeyinde algılama kategorisinde görece yeni çalışmalar ve Ronneberger vd. [21] gibi daha önce yapılan çalışmalar literatürde mevcuttur. Ni ve Zhang [20] tarafından yapılan çalışmada, bir çatlak tanımlama ağının kombinasyonu ile bir GoogLeNet mimarisi kullanılmıştır. GoogLeNet, başarılı bir özellik çıkarıcı olarak ardışık düzende özellik çıkarma ve algılama sağlamıştır. Araştırmadaki veri seti görüntü boyutu, maksimum çözünürlüğe sahip 1200×2000 piksel olan veri seti aksine yüksek çözünürlüklü bir veri seti olarak kabul edilen 4000×6000 pikseldir. Ronneberger'de [21] benzer piksel düzeyinde çatlak tanımlama yaklaşımlarını kullanmıştır. Bu çalışmalarda çatlak açıklıkları segmente edilmiştir.

Cha vd. [22] somut görüntülerdeki çatlakları tespit etmek için bir derin öğrenme yaklaşımı önermiştir. Bu çalışmada sonuçlar Canny ve Sobel kenar algılama algoritmaları ile karşılaştırılmıştır. Önerilen CNN'nin doğruluğu iyileştirdiği gösterilmiştir. CNN'lerin kullanılmasının genellemeyi arttırdığı ve verilerdeki gürültünün etkisinin azaltıldığı vurgulanmıştır. Yazar, veri setlerinde %97'nin üzerinde test doğruluğu sağlamıştır.

Benzer şekilde, Zhang vd. [23]'de bir CNN modeli uygulanmıştır. Önerilen CNN mimarisinin yapısında dört evrişim katmanı, bir maksimum havuzlama katmanı ve iki tam bağlantılı katman kullanılmıştır. SVM gibi klasik makine öğrenme metotlarıyla karşılaştırıldığında, önerilen mimari üstyapı çatlak tespit etme veri setinde başarılı bir doğruluk (0.925) sağlamıştır.

Yol hasar incelemesi çalışmasında Maeda vd. [24], yol yüzeyinden veri toplamak için akıllı telefonlar kullanmıştır. Önerilen yöntem, kendi alanı üzerinde bir sınırlayıcı kutu sağlayarak sekiz sınıfı tespit edebilmektedir.

Diğer bir çalışmada Makantasis vd. [25], CNN'nin ilk katmanı olarak düşük seviyeli özneliklerin çıkarılmasını ve verinin ileri beslenmesini önermiştir. Bu uygulama %88,6 doğruluk sağlamıştır.

Sivil altyapıların denetimine ilişkin bir araştırmada Stentoumis vd. [26], bilgisayarlı görme teknikleri ve CNN'leri kullanarak beton tünel çatlaklarının tespiti üzerine bir araştırma yapmıştır. Bu çalışmada, gürültü giderme, düz çizgilerin kaldırılması, eğri tespiti, Hough dönüşümü yoluyla şekil filtreleme ve morfolojik yeniden yapılandırma dahil olmak üzere CNN'ler için ön işleme adımları olarak birkaç akıllı ürün etiketleme (IPT) kullanılmıştır. Çalışma, IPT'lerin CNN'lerle birlikte kullanılmasının daha yüksek sınıflandırma doğruluğu sağladığı göstermiştir.


Ülkemizde yapılan bir çalışmada ise Orta Doğu Teknik Üniversitesi'ndeki binaların beton yüzeylerinden derlenen ve 20000 çatlaklı ve 20000 çatlaksız görüntüden oluşturulan bir veri seti kullanılmıştır. Veri seti, ResNet-50, VGG-16, Inception-V3, Xception, MobileNet, ShuffleNet, EfficientNet mimarilerinin eğitimlerinde kullanılmış ve görece az ya da çok sayıdaki ağ parametresinin doğruluğu etkileme durumları araştırılmıştır [27].

Bu çalışmada, uçuşa elverişlilik için pist yüzeyi çatlak tespiti amacıyla farklı derin öğrenme modelleri eğitilmiştir. İkinci bölümde, derin öğrenme hakkında genel bilgi verilmiştir. Derin yapay sinir ağlarının imge verileri gibi çok boyutlu veriler için özelleştirilmiş hali olan CNN detaylı bir şekilde ele alınarak veri sınıflandırmada nasıl kullanıldığı hakkında bilgi verilmiştir. Üçüncü bölümde geliştirilen modeller ve elde ettikleri başarı oranları sunulmuştur. Son bölümde ise sonuç ve öneriler sunulmuştur.

2. Materyal ve Metot


2.1. Yapay Sinir Ağları

YSA'ları canlı beyni taklit eden bir yaklaşımdır. Bu konuda ilk çalışma matematikçi Pitts ve nörofizyolog McCulloch tarafından 1943 yılında insan beyindeki nöronların çalışma prensibinin bir sinir ağı oluşturularak matematiksel olarak modellenmesiyle yapılmıştır [28]. Daha sonraki zamanlarda makine öğrenme çalışmalarında başarılı sonuçlar elde edebilmek amacıyla YSA'ları mühendisliğin bir konusu olmuştur. YSA'nın çalışma mantığını kavrayabilmek için ilk olarak biyolojik sinir sistemi hücre yapısını incelemek gerekir.



Şekil 1. Biyolojik sinir hücresi

Biyolojik bir sinir hücresi nöron olarak adlandırılır. Nöronlar Şekil 1'de görüldüğü üzere üç temel yapıdan oluşur. Başka nörondan gelen bir bilgi dendritler aracılığıyla hücre gövdesine, hücre gövdesinden de akson ve akson kollarına iletilir. Bir nöronun akson ucu ile diğer nöronun dendriti arasında sinaptik bir boşluk bulunmaktadır. Burada akson kolları diğer nöronların dendritlerine sinapslar ile bağlanmaktadır. Öğrenme sürecinde ise bilgi elektriksel sinyallerle diğer nörona iletilmektedir [29].



Şekil 2. Yapay sinir hücresine ait matematiksel model

Bir sinir hücrelerinin matematiksel modeli Şekil 2'de gösterilmiştir. Akson boyunca ilerleyen sinyallerden biri olan x_0 ele alınır. İlgili sinaps ağırlığı w_0 'dır ve hücre gövdesine bu girişten gelen katkı çarpımsal (ağırlıklandırılmış) biçimde w_0x_0 olmaktadır. Ağırlıklar öğrenilebilir (ayarlanabilir) değerlerdir ve böylece bir nöronun diğer nörona etkisi kontrol edilebilir. Burada b parametresi ise sabit bir bias değeridir. YSA modellerinde w ve b parametreleri değiştirilerek en iyi doğruluk sonucu elde edilmeye kadar model eğitilir. Hücre gövdesinde toplanan sinyaller aktivasyon fonksiyonundan geçirilerek elde edilen çıktı diğer nörona iletilir. Çıkışta hesaplanan sonuçtan yola çıkarak w ve b değerleri sürekli bir biçimde en iyilenecek YSA modelinden olabilecek en düşük hataya sahip çıkış değerleri elde edilmeye çalışılır [30].

2.2. Derin Öğrenme

Derin öğrenme, insan zekâsından esinlenerek ortaya çıkarılmış yapay zekânın bir alt dalıdır. Biyolojik nöronların taklit edilmesiyle YSA'ları tasarlanmış, beraberinde insanın öğrenme davranışları incelenerek derin öğrenme yaklaşımları geliştirilmiştir. Derin öğrenme yaklaşımlarının temeli, hiyerarşik bir düzende birbiri üzerine yığılan çeşitli katmanlardan oluşan sinir ağlarına dayanmaktadır [31].

Bir makine öğrenmesi alt sınıfı olan derin öğrenme, özellik çıkarma ve dönüştürme işlemleri için çok sayıda doğrusal olmayan işlem birimi katmanı kullanır. Birbiri ile ardışık her katman, kendinden önceki katmandaki çıktıyı girdi olarak alarak senkron şekilde ilerler [32].

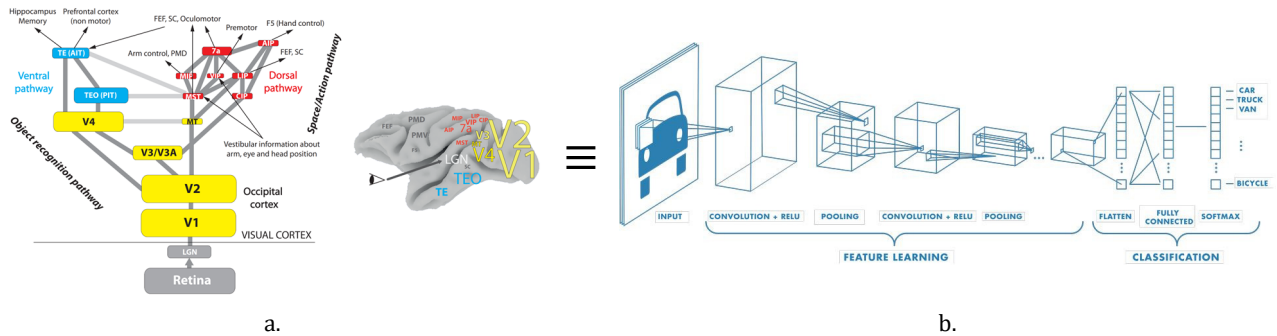
Her biri daha güçlü seviyedeki temsilleri ile sınıflandırma işlemini gerçekleştirmek için mühim olan ve alakasız çeşitlemeleri bastıran yönlerini güçlendirerek girdinin ayrımını yapar. Örnek olarak bir görüntü girdisinin ilk katmanındaki öğrenilen özelliği, girdinin belirli yönlerde ve pozisyonlardaki kenarların varlığı veya yokluğudur. İkinci katman kenar konumlarındaki ufak değişimlere bakılmaksızın belli kenar dizilişlerini saptayarak örüntü ve desenleri algılar. Üçüncü katman, desenleri, bilinen parçalara karşılık gelecek şekilde daha büyük kombinasyonlar oluşturarak birleştirebilir ve sonrasındaki katmanlar, bu parçaların birleşimleri olarak nesnelere kavrayabilir. Derin öğrenmenin en büyük avantajı, bu katmanların kullanıcı tarafından tasarlanmayıp genel bir öğrenme yöntemiyle verilerden öğrenilmesidir [33].

Derin öğrenmede giriş verilerinin metin, ses veya piksel verileri gibi analog olması daha başarılı sonuçlar ortaya koyar [34]. Yüz tanımda, parmak izi okuyucularda, ses tanımda, sürücüsüz arabalarda ve güvenlik kameraları gibi birçok alanda derin öğrenme yaygın olarak kullanılmaktadır. Ayrıca günümüzde kamera sayılarının artışıyla birlikte sayısal veride fazlaca bir birikim olduğunu söylemek gerekir. Nesnelere ait görüntülerin bilgisayarlar nezdinde anlamlı hale gelmesi bizlere oldukça kolaylık sağlayacaktır.

Beynimiz görüntüleri hızlı ve kolay bir şekilde idrak edebilirken bilgisayarlar için anlamlandırılması güç problemlerdir. Son yıllarda, bu güç problemleri çözümleme başarılı bir ilerleme gösterilmiştir. Özellikle, derin CNN mimarileri ile görsel tanımlama işlevlerinde yeterli seviyelerde başarımlar elde edilmiştir [35]. Bu nedenle CNN mimarileri en çok tercih edilen derin öğrenme tekniklerinden biridir ve bilgisayarlı görüş çalışmalarında yaygın bir biçimde kullanılmaktadırlar [36].

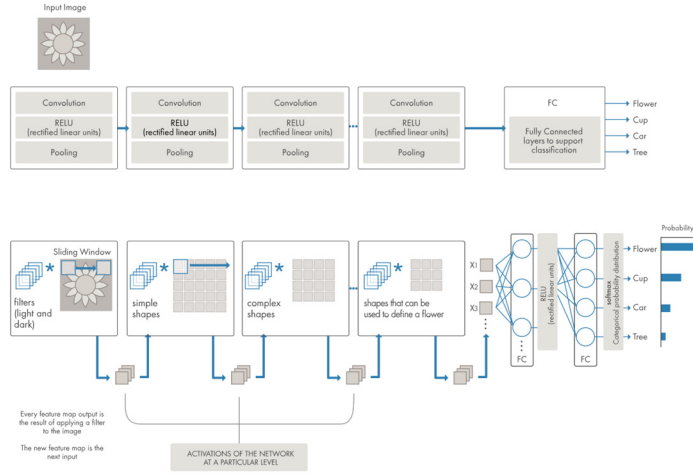
2.3. Evrişimli Sinir Ağları

CNN, YSA'larının çoğunlukla çok boyutlu ve büyük hacimli veriler için kullanılan özelleştirilmiş şeklidir. CNN'ler ile insan beynindeki görüntüyü işleme merkezinin (visual cortex) çalışma mekanizması betimlenmektedir. Şekil 3'te bu durum temsil edilmektedir [37, 38]. CNN çok sayıda ara katmana sahiptir. Her katman girdi olarak verilen görüntüden özellik çıkararak bir sonraki katmana iletir. Teknolojinin gelişmesiyle birlikte bu tip ağlara duyulan ihtiyaç artmıştır. Bu nedenle, uygulamalara yönelik birçok farklı CNN mimarisi geliştirilmiştir.



a. Şekil 3. a.) İnsan visual cortex yapısı, b.) Eşdeğer CNN benzerlik modeli

CNN mimarisi, Şekil 3'te ifade edildiği gibi özellik öğrenme (feature learning) ve sınıflandırma (classification) kısımlarından oluşmaktadır [38]. Yapının işleyişine ilişkin bir illüstrasyon ise Şekil 4'te verilmektedir.




Şekil 4. CNN mimarisinin işleyişi

Giriş görüntüsü, özellik öğrenme kısmına uygulanır. Çıkarılan özellikler, sınıflandırma kısmına iletilir. Sınıflandırma katı görüntünün özellikleri kullanılarak çalışır ve bir çıkış üretir. Özellik öğrenme katı, peş peşe tekrarlayan evrişim ve havuzlama katman çiftlerinden oluşur. Evrişim katında evrişim işlemi ile görüntü filtrelenir. Bu katman çok sayıda sayısal filtrenin birleşiminden oluşmuş gibi düşünülebilir. Bu filtreler sayesinde, girdi verisinden özellik haritaları çıkarır. Havuzlama katı ise komşu pikselleri tek piksele birleştirir. Böylece görüntünün boyutları azalmış olur. Bu temel yapıya ek olarak aralarda düzleştirme, normalizasyon, seyreltme ve softmax gibi işlemler de uygulanmaktadır. Konvolüsyon ve havuzlama katmanlarından sonra sınıflandırma işleminin gerçekleştirilebilmesi için girdinin düzleştirme katmanı ile tek boyutlu vektör haline çevrilmesi gerekmektedir. Tam bağlantılı katmanın işlevi, önceki katmanın çıktısına (özellik haritasına) göre hangi özelliklerin belirli bir sınıfla en ilişkili olduğunu tespit etmektir. Bu katman hangi yüksek seviyeli özelliklerin belirli bir sınıfa daha güçlü bağlandığını ortaya çıkararak farklı sınıflar için uygun olasılıklar üretir. Seyreltme katmanı (dropout layer), derin sinir ağında aşırı öğrenme (ezberleme, overfitting) sorununu engellemek amacıyla kullanılır. Aşırı öğrenme, ağır eğitim verilerinde yüksek bir başarı sağlarken test verilerinde başarı gösterememesi anlamına gelir. Seyreltme katmanının görevi derin sinir ağının eğitimi sırasında gizli katmanlarda var olan bazı yapay nöronları etkisiz hale getirmektir [39]. Bu katmanın kullanıldığı derin öğrenme uygulamalarında başarımın çoğu zaman arttığı tespit edilmiştir.

2.4. Evrişimli Sinir Ağları ile Sınıflandırma

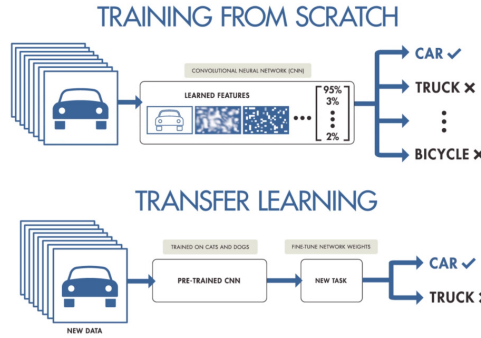
Bir CNN ağı tasarımında ağın en iyi şekilde eğitilmesi için yukarıda bahsedilen birçok katman kullanılmaktadır. Bu katmanlarla birlikte ağın eğitimi için girdi verisi olarak nitelikli ve hacimli veriye ihtiyaç duyulur. Bu durum büyük bir emek ve zaman gerektirir. Öğrenme aktarımlı ağın eğitilmesi esnasında kolaylık ve zaman tasarrufu sağlamaktadır. Şekil 5'te öğrenme aktarımı yaklaşımına ilişkin görsel verilmiştir.



Şekil 5. Geleneksel öğrenme ve öğrenme aktarımı temsilleri

Öğrenme aktarımı, makine öğrenmesi yöntemlerinin de tıpkı insanlarda olduğu gibi bir problemi çözerken elde ettiği bilgiyi özümseyip, başka bir problem ile karşılaştığında edinilen bilgiyi kullanmasını temel almaktadır. Öğrenme aktarımı ile önceki bilgiler kullanılarak daha az eğitim verisi ile daha yüksek başarı gösteren ve daha hızlı

öğrenen modeller elde edilebilmektedir. Makine öğrenmesi ve öğrenme aktarımı yöntemlerinin çalışma prensiplerini birlikte ifade eden bir illüstrasyon Şekil 6'da verilmektedir.



Şekil 6. Makine öğrenmesi ve öğrenme aktarımı yöntemleri prensip çalışma biçimleri

Öğrenme aktarımı yöntemi, girdi verileri ile önceden eğitilmiş olan ağıın yeni tasarlanan CNN üzerine uyumlandırılması işlemidir [40]. Buradaki amaç, gerekli iş gücünü indirgemek ve zamandan tasarruf ederek önceden eğitilen ağıın model performansının geliştirilmesidir. Günümüzde farklı zorluklardaki karmaşık problemlerin çözümü için öğrenme aktarımı yöntemi büyük ölçüde tercih edilmektedir. Öğrenme aktarımı sayesinde daha önce öğrenilen bilgiler yeni model için yol gösterici olmakta, böylece daha kısa sürede daha başarılı modeller elde edilebilmektedir.

3. Bulgular

3.1. Veri Seti

Bu çalışmada geliştirilen CNN'lerin eğitim, doğrulama ve test işlemleri için CRACK500, CFD, Cracktree200, GAPS384 ve AEL olmak üzere 5 farklı veri seti kullanılmıştır. Bu veri setlerine ilişkin bilgiler aşağıda verilmiştir.

CRACK500: Cep telefonları kullanılarak Temple Üniversitesi ana kampüsünde elde edilmiş 2000×1500 piksel boyutundaki 500 görüntüyü içeren bir yüzey çatlakları veri setidir. Bu veri seti CRACK500 olarak adlandırılmıştır. Her çatlak görüntüsü, piksel düzeyinde açıklamalı bir ikili haritaya sahiptir. Bu veri kümesi şu anda piksel bazında açıklama içeren, kamuya açık en büyük yüzey çatlakları veri kümesidir [8]. Veri seti 250 eğitim verisi görüntüsüne, 50 doğrulama verisi görüntüsüne ve 200 test verisi görüntüsüne bölünmüştür. Sınırlı sayıda görüntü, görüntülerin büyük boyutluluğu ve kısıtlı hesaplama kaynağı nedeniyle, her görüntü örtüşmeyen 16 alt görüntü bölgesine kırılmış ve yalnızca 1.000 pikselden fazla çatlak içeren bölgeler muhafaza edilmiştir. Böylelikle eğitim verisi 1.896 görüntüden, doğrulama verisi 348 görüntüden, test verisi 1124 görüntüden oluşur hale getirilmiştir.

CFD: Shi ve diğerleri [41], The Crack Forest Dataset (CFD) adı verilen açıklamalı bir yol çatlakları veri seti önermiştir. Veri seti, 480×320 piksel boyutunda 118 görüntüden oluşmaktadır. Her görüntü elle etiketlenmiş çatlak konturlarına sahiptir. Görüntüleri almak için kullanılan cihaz, 4 mm odaklı, f/2.4 diyafram açıklığına ve 1/135s pozlama süresine sahip bir iPhone5 akıllı telefondur.

Cracktree200: Zou ve diğerleri [42], önerdikleri yöntemi değerlendirmek için bu veri setini geliştirmişlerdir. Veri seti, çeşitli çatlak türlerine sahip 800×600 boyutunda 206 yüzey görüntüsü içermektedir. Bu nedenle bu veri seti Cracktree200 olarak adlandırılmıştır. Veri kümesi, gölgeler, tıkanıklıklar, düşük kontrast, gürültü vb. gibi zorlukları içermektedir.

GAPS384: Alman Asfalt Kaplama Problemi (GAPs) veri seti, büyük ölçekli standartlaştırılmış yüksek kaliteli bir veri setidir. GAPS veri seti, çatlaklar, çukurlar, işlemeli yamalar vb. gibi çeşitli sınıflarda toplam 1.969 gri değerli görüntü içermektedir. Görüntü çözünürlüğü 1920×1080 pikseldir. Görüntülerdeki hasar, sınırlayıcı bir kutuyla çevrelenmiştir. Bu tür bir açıklama, piksel bazında bir çatlak tahmin görevi için derin modeli eğitmek için yeterince iyi değildir. Bu sorunu çözmek için, GAPS veri setinden sadece çatlak sınıfını içeren 384 görüntü manuel olarak seçilerek piksel bazında açıklama yapılmıştır. Piksel bazında açıklama içeren yeni crack veri seti GAPS384 olarak adlandırılmıştır ve CRACK500 üzerinde eğitilen modelin genelleme kabiliyetini test etmek için kullanılmıştır. Görüntünün büyük boyutu ve GPU'nun sınırlı belleği nedeniyle, her görüntü 640×540 piksel boyutunda örtüşmeyen 6 görüntü bölgesine kırılmıştır. Yalnızca 1000'den fazla piksele sahip görüntü bölgeleri muhafaza edilmiştir. Böylece test için 509 görüntü elde edilmiş durumdadır [8, 43].

AEL: Aigle-RN, [44]'de, piksel seviyesi açıklamaları ile 38 görüntü içeren bir veri seti olarak önerilmiştir. Veri seti, Fransız kaplama yüzeyinin durumunu periyodik olarak izlemek için trafikte elde edilmiştir. ESAR adı verilen veri

seti, kontrollü aydınlatma olmadan statik bir toplama sistemi ile elde edilmiştir. ESAR, 15 adet tam açıklamalı crack görüntüsüne sahiptir. LCMS adı verilen veri seti 5 piksel düzeyinde açıklamalı çatlak görüntüsü içermektedir. Üç veri seti az sayıda görüntüye sahip olduğundan, model değerlendirmesi için AEL adlı bir veri kümesinde birleştirilmiştir.

Bu çalışmada yukarıda bahsedilen CRACK500, CFD, cracktree200, GAPs384 ve AEL veri setlerinden elde edilen ve 10000 adet (5000 adet çatlak içermeyen, 5000 adet çatlak içeren) görüntü bulunduran yeni bir veri seti oluşturulmuştur. Bu yeni veri setinin, %70'i eğitim, %15'i doğrulama ve %15'i test verisi olarak kullanılmıştır. Çalışmadaki benzetimler Matlab ortamında gerçekleştirilmiştir.

3.2. Yüzey Çatlak Tespiti İçin Geliştirilen Modeller

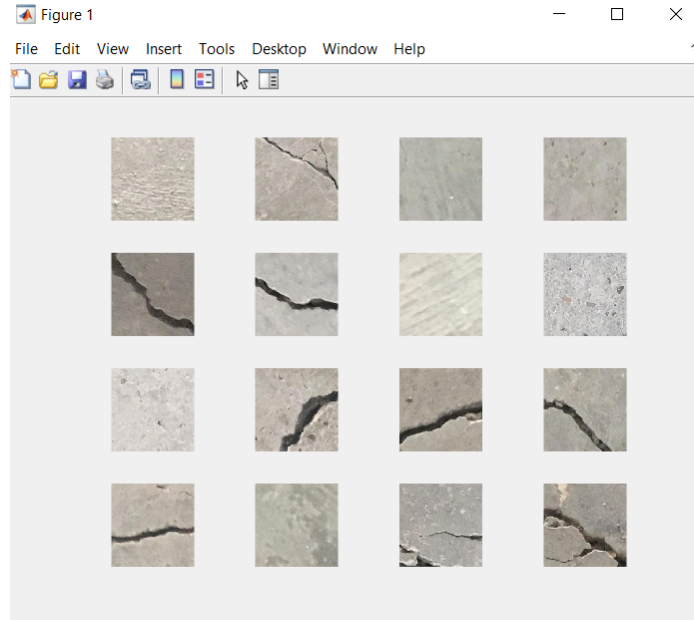
Bu çalışmada, uçuşa elverişlilik için pist yüzeyi çatlak tespiti yaklaşımı için iki farklı model ile MATLAB üzerinde çalışılmıştır. İlk model için sıfırdan CNN eğitimi gerçekleştirilmiş ve sınıflandırma yapılmıştır. İkinci modelde ise önceden eğitilmiş bir CNN modeli olan AlexNet mimarisi probleme uygun olarak öğrenme aktarımı yoluyla probleme uyarlanmış ve sınıflandırma gerçekleştirilmiştir.

Takip eden bölümlerde, sırasıyla geliştirilen modellerin tasarımı, bu modellerin eğitim / test aşamaları ve başarı oranları sunulmuştur.

3.2.1 Sıfırdan CNN Tasarımı ile Sınıflandırma

Uçuşa elverişlilik için pist yüzeyi çatlak tespitinde ilk geliştirilen model CNN'in sıfırdan eğitilmesiyle elde edilmiştir. Bu amaçla katedilen adımlar sırasıyla şu şekildedir: 1. Görüntü verilerini yükleme ve alt veri setlerinin belirlenmesi, 2. Ağ mimarisinin tanımlanması, 3. Eğitim seçeneklerinin belirlenmesi, 4. Ağın eğitilmesi, 5. Test verilerinin etiketlerinin kestirimi ve sınıflandırma doğruluğunun hesaplanması. Çalışmada kullanılan 10000 etiketli veriden oluşan veri setinin %70'i (7500 resim) eğitim, %15'i (1500 resim) doğrulama ve kalan %15'i (1500 resim) test veri seti olarak ayrılmıştır. Veri setlerinin yüzde olarak ayrımı seed (tohum) değerine bağlı olarak rasgele bir biçimde gerçekleştirilmiştir.

Veri setinden rasgele seçilen bazı örnekler Şekil 7'de verilmiştir:




Şekil 7. Veri setindeki görüntülerden bazı örnekler

Çalışmada baştan tasarlanan ve eğitilen CNN'in yapısı aşağıdaki gibidir ve Şekil 8'deki gibi görselleştirilebilir:

1	Resim girdi katmanı	giriş boyutu 227×227×3 ve 'zerocenter' normalizasyonu
2	Evrişim	16 adet 3×3 evrişim, stride [1 1], veri doldurma 'same'
3	Toplu normalizasyon	
4	ReLU aktivasyon	
5	Max havuzlama	2×2 max havuzlama, stride [2 2], veri doldurma [0 0 0 0]


6	Evrşim	16 adet 3×3 evrşim, stride [1 1], veri doldurma 'same'
7	Toplu normalizasyon	
8	ReLU aktivasyon	
9	Max havuzlama	2×2 max havuzlama, stride [2 2], veri doldurma [0 0 0 0]
10	Evrşim	32 adet 3×3 evrşim, stride [1 1], veri doldurma 'same'
11	Toplu normalizasyon	
12	ReLU aktivasyon	
13	Tam bağlantılı katman	2'li tam bağlı katman
14	Softmax	
15	Sınıflandırma çıkışı	crossentropyex



Şekil 8'de, mavi renk girdi katmanını, turuncu renk evrşim katmanını (ya da son kısımda tam bağlantılı katmanı,), yeşil renk toplu normalizasyonu, bordo renk ReLU aktivasyonu, mor renk max havuzlamayı ve kırmızı renk softmax ve sınıflandırma çıkışını temsil etmektedir.


Ağın eğitimi 5 epok boyunca sürdürülmüştür. Doğrulama verileri ve doğrulama sıklığı belirtilerek eğitim sırasında ağ doğruluğu izlenmiştir. Her epokta veriler karıştırılmıştır. Ağ eğitim verileri kullanılarak eğitilmiş ve bu esnada düzenli aralıklarla doğrulama verileri ile ağın doğrulama başarımını doğrulama verileri kullanılarak hesaplanmıştır. Doğrulama verileri ağ ağırlıklarını güncellemek için kullanılmamıştır.

Şekil 9'da eğitim ilerleme grafiği mini batch kaybı ile doğruluğunu ve doğrulama kaybı ile doğrulama başarımını verilmektedir. Kayıp, çapraz entropi kaybıdır. Doğruluk, ağın doğru sınıflandırdığı görüntülerin yüzdesini gösterir. Çalışmada geliştirilen CNN için eğitim ve validasyon grafikleri yine Şekil 9'da verilmiştir.



Şekil 9. Ağın eğitim süreci ve ilgili grafikler

Eğitilmiş ağı kullanarak doğrulama verileri için doğrulama başarımını hesaplanmıştır. Doğruluk, ağın doğru tahmin ettiği etiketlerin oranını ifade etmektedir. Geliştirilen CNN, doğrulama veri seti için %98.53 oranında doğru öngörü üretmiştir. Yani üretilen etiketler %98.53 oranında gerçek etiketler ile eşleşmiştir. Test veri kümesine ait doğruluk oranı ise %98.33 olarak elde edilmiş olup, test hata matrisi diyagramı Şekil 10'da verilmiştir.




Şekil 10. Baştan geliştirilen ağın test verileri için sunduğu başarıma ait test hata matrisi

3.2.2 Önceden Eğitilmiş AlexNet Mimarisi ile Sınıflandırma

Öğrenme aktarımı, derin öğrenme uygulamalarında yaygın olarak kullanılır. Önceden hazırlanmış bir ağ yeni bir görev öğrenmek için kullanılabilir. Öğrenme aktarımı ile bir ağın ince ayarının yapılması, rasgele başlatılan ağırlıklara sahip bir ağın sıfırdan eğitilmesine göre genellikle daha hızlı ve sade bir süreçtir. Daha az sayıda eğitim görüntüsü kullanılarak öğrenilen özellikler hızlı bir şekilde yeni bir göreve aktarılabilir.

Çalışmada, önceden eğitilmiş bir AlexNet evrişimli sinir ağına ince ayar yapılarak ağın yeni bir görüntü koleksiyonu için sunacağı sınıflandırma başarımı de incelenmiştir. AlexNet, bir milyondan fazla görüntü üzerinde eğitilmiş derin bir model olup, görüntüleri 1000 nesne kategorisine sınıflandırabilmektedir. Ağa, çok çeşitli görüntüler için zengin özellik temsilleri öğretilmiştir. Çalışmada öğrenme aktarımı ile ince ayarı yapılan AlexNet yapısı aşağıdaki gibidir ve Şekil 11'deki gibi görselleştirilebilir:

1	Resim girdi katmanı	giriş boyutu $227 \times 227 \times 3$ ve 'zerocenter' normalizasyonu
2	Evrişim	96 adet $11 \times 11 \times 3$ evrişim, stride [4 4], veri doldurma [0 0 0 0]
3	ReLU aktivasyonu	
4	Çapraz kanal normalizasyonu	eleman başına 5 kanal ile kanallar arası normalleştirme
5	Max havuzlama	3×3 max havuzlama, stride [2 2], veri doldurma [0 0 0 0]
6	Gruplanmış evrişim	2 grup 128 adet $5 \times 5 \times 48$ evrişim, stride [1 1], veri doldurma [2 2 2 2]
7	ReLU aktivasyonu	
8	Çapraz kanal normalizasyonu	eleman başına 5 kanal ile kanallar arası normalleştirme
9	Max havuzlama	3×3 max havuzlama, stride [2 2], veri doldurma [0 0 0 0]
10	Evrişim	384 adet $3 \times 3 \times 256$ evrişim, stride [1 1], veri doldurma [1 1 1 1]
11	ReLU aktivasyonu	
12	Gruplanmış evrişim	2 grup 192 adet $3 \times 3 \times 192$ evrişim, stride [1 1], veri doldurma [1 1 1 1]
13	ReLU aktivasyonu	
14	Gruplanmış evrişim	2 grup 128 adet $3 \times 3 \times 192$ evrişim, stride [1 1] veri doldurma [1 1 1 1]
15	ReLU aktivasyonu	
16	Max havuzlama	3×3 max havuzlama, stride [2 2], veri doldurma [0 0 0 0]
17	Tam bağlantılı katman	4096'lı tam bağlı katman
18	ReLU aktivasyonu	
19	Dropout	%50 terk edilen bağlantı
20	Tam bağlantılı katman	4096'lı tam bağlı katman
21	ReLU aktivasyonu	
22	Dropout	%50 terk edilen bağlantı
23	Tam bağlantılı katman	64'lü tam bağlı katman
24	ReLU aktivasyonu	
25	Tam bağlantılı katman	2'li tam bağlı katman
26	Softmax	
27	Sınıflandırma çıkışı	crossentropyex




Katman numarası : 1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16 17 18 19 20 21 22 23 24 25 26 27

Şekil 11. Öğrenme aktarımı tabanlı AlexNet CNN yapısı

Önceden eğitilmiş ağın son üç katmanı 1000 sınıf için yapılandırılmıştır. Çalışmada iki sınıf bulunduğu için orijinal son üç katman kaldırılmış yerine yeni 2'li çıkış barındıran üç katman yerleştirilmiştir. Son üç katman, tam bağlı bir katman, bir softmax katman ve bir sınıflandırma çıkışı ile değiştirilip önceden eğitilmiş ağdan alınan son 3 katman haricindeki katmanlar ile tümelştirilmiş ve yeni sınıflandırma görevi gerçekleştirilmiştir.


Ağın eğitimi 5 epok boyunca sürdürülmüştür. Her epokta veriler karıştırılmıştır. Ağ eğitim verileri kullanılarak eğitilmiş ve bu esnada düzenli aralıklarla doğrulama verileri ile ağın doğrulama başarımı doğrulama verileri kullanılarak hesaplanmıştır. Doğrulama verileri ağ ağırlıklarını güncellemek için kullanılmamıştır.

Şekil 12'de eğitim ilerleme grafiği mini batch kaybı ile doğruluğunu ve doğrulama kaybı ile doğrulama başarımını gösterir. Kayıp, çapraz entropi kaybıdır. Doğruluk, ağın doğru sınıflandırdığı görüntülerin yüzdesini gösterir. Çalışmada öğrenme aktarımı uygulanan AlexNet için eğitim ve validasyon grafikleri Şekil 12'de verilmiştir.



Şekil 12. AlexNet için eğitim süreci ve ilgili grafikler

Çalışmada ele alınan problem için uyarılan AlexNet doğrulama veri seti için %99.73 oranında doğru öngörü üretmiştir. Yani üretilen etiketler %99.73 oranında gerçek etiketler ile eşleşmiştir. Test veri kümesine ait doğruluk oranı ise %99.93 olarak elde edilmiş olup, test hata matrisi diyagramı Şekil 13'te verilmiştir.



Şekil 13. Öğrenme aktarımı uygulanan AlexNet mimarisinin test verileri için sunduğu başarıma ait test hata matrisi

4. Tartışma ve Sonuç

Bu çalışmada, uçuşa elverişlilik için havalimanı pistinde yüzey çatlak tespiti için CNN mimarilerinin kullanımı incelenmiştir. Geliştirilen CNN mimarileri, sıfırdan tasarlanmış bir model ve ayrıca önceden eğitilmiş AlexNet modelidir. Pist üzerindeki zemin hasarı, kabarma veya kırık yüzeyler (çatlama, kırılma, kopma, açılma vb.) uçuş emniyetini tehdit etmektedir. Bunların kontrolü, görevi ile ilgili eğitimi almış personeller tarafından yapılır ancak zaman kaybına yol açar. Geliştirilen modeller ile tespit işlemlerine yönelik incelemeler hızlı bir şekilde gerçekleştirilebilecektir.

Günümüzde görüntü sınıflandırma alanında, derin öğrenme modelleri diğer bütün yöntemlere göre daha başarılı sonuçlar vermektedir. Geliştirilen CNN modelleri, güvenli uçuş için pist yüzeyindeki çatlakları algılayabilecek

şekilde eğitilmiştir. Beş farklı veri setinden derlenen test verileri ile test edilen modeller yüksek başarı oranları sağlamıştır.

İlk geliştirilen modelde CNN sıfırdan eğitilerek sınıflandırma işlemi gerçekleştirilmiştir. CNN ağ mimarisi en optimum düzeyde tasarlanmaya çalışılmıştır. Model 5000 çatlaklı, 5000 çatlaksız görüntü içeren bir veri seti kullanılarak eğitilmiştir. CNN'e ait en yüksek test doğruluk değeri %98,33 olarak elde edilmiştir. Bu uygulamada tasarlanan modelde kullanılan aktivasyon fonksiyonları, öğrenme hızı ve seyreltme değişkenleri gibi özelliklerin en uygun şekilde belirlenmesi gerekir. Bu değişkenlerin en doğru şekilde belirlenebilmesi için belli bir araştırma ve deneyim gerekmektedir.

İkinci geliştirilen modelde ise önceden eğitilmiş ve yaygın olarak kullanılan AlexNet mimarisi ile sınıflandırma yapılmıştır. AlexNet evrişimli sinir ağına eğitim yoluyla ince ayar yapılarak ağın yeni bir görüntü koleksiyonu ile başarılı bir sınıflandırma yapması sağlanmıştır. Model 5000 çatlaklı ve 5000 çatlaksız görüntüden oluşan aynı veri seti ile eğitilmiştir. Görüntü verileri AlexNet modeline uygun olacak şekilde boyutlandırılmıştır. Ağın son üç katmanı, tam bağlı bir katman, bir softmax katman ve bir sınıflandırma çıktı katmanıyla değiştirilip önceden eğitilmiş ağdan alınan katmanlar ile yeni katmanlar tümleştirildikten sonra sınıflandırma işlemi gerçekleştirilmiştir. Yeni katmanlarda aktarılan katmanlara göre daha hızlı öğrenme sağlamak için, tamamen bağlı katmanın ağırlık öğrenme oranı ve bias öğrenme oranı değerleri artırılmıştır. Aktarılan katmanlardaki öğrenmeyi yavaşlatmak için ilk öğrenme hızı küçük bir değere ayarlanmıştır. Yeni son katmanlardaki öğrenmeyi hızlandırmak için ise tam bağlı katmanın öğrenme oranı faktörleri artırılmıştır. Öğrenme hızı ayarlarının bu kombinasyonu sadece yeni katmanlarda hızlı öğrenmeyi ve diğer katmanlarda daha yavaş öğrenmeyi sağlamıştır. Geliştirilen modelin en yüksek test doğruluk değeri %99,93 olarak elde edilmiştir. Bu sonuç, Alexnet mimarisinin CNN tabanlı çatlak tespitine göre daha başarılı bir sonuç verdiğini göstermiştir.

Kaynakça

- [1] Sivil Havacılık Genel Müdürlüğü. 2016. Havaalanı Pistleri, HAD/T-283-37.
- [2] Zhang, J., Qian, S., Tan, C., 2022. Automated Bridge Surface Crack Detection And Segmentation Using Computer Vision-Based Deep Learning Model, *Engineering Applications of Artificial Intelligence*, 115(1-13).
- [3] Yazgan, E., Yılmaz, A.K., 2019. Prioritization of Factors Contributing to Human Error for Airworthiness Management Strategy with ANP. *Aircraft Engineering and Aerospace Technology*, 91(78-93).
- [4] Tatlı, A., 2016. Uçuşa Elverişliliğin Meteorolojik Açından İncelenmesi ve Kısa Vadeli Kestirim Modeli İçin Zaman Serilerinde Yapay Sinir Ağları Yaklaşımı: Hasan Polatkan Havaalanı Örneği. Anadolu Üniversitesi, Yüksek Lisans Tezi, Eskişehir.
- [5] Wang, H., vd., 2019. Civil Aviation Safety Evaluation Based on Deep Belief Network and Principal Component Analysis. *Elsevier Safety Science*, 112(90-95).
- [6] Inacio, F.R., vd., 2008. Object Detection and Identification Applied to Planes and Aircraft for Airport Surveillance, 2008 23rd International Conference Image and Vision Computing New Zealand.
- [7] Tsai, Y. vd., 2015. Innovative Crack Sealing Analysis and Cost Estimation for Airport Runway Shoulders Using 3D Laser Technology and Automatic Crack Detection Algorithms. *Airfield and Highway Pavements*, 652-661.
- [8] Yang, F., Zhang, L., Yu, S., 2019. Feature Pyramid and Hierarchical Boosting Network for Pavement Crack Detection. *IEEE Transactions on Intelligent Transportation Systems*, 21(1525-1535).
- [9] Jiang, L., Xie, Y., Ren, T., 2020. Deep Neural Networks Approach for Pixel-Level Runway Pavement Crack Segmentation Using Drone-Captured Images, arXiv, 2001.03257.
- [10] Peng, L. vd., 2015. Research on Crack Detection Method of Airport Runway Based on Twice-Threshold Segmentation. 2015 Fifth International Conference on Instrumentation and Measurement, Computer, Communication and Control, 1716-1720.
- [11] Jo, J., Jadidi, Z., 2020. A High Precision Crack Classification System Using Multi-Layered Image Processing and Deep Belief Learning. *Structure And Infrastructure Engineering*, 16(297-305).
- [12] Gopalakrishnan, K. vd., 2017. Deep Convolutional Neural Networks with Transfer Learning For Computer Vision-Based Data-Driven Pavement Distress Detection. *Construction and Building Materials*, 157(322-330).
- [13] Qurishee, M.A. vd., 2020. Bridge Girder Crack Assessment Using Faster RCNN Inception V2 and Infrared Thermography. *Journal of Transportation Technologies*, 10(110-127).
- [14] Gopalakrishnan, K., 2018. Deep Learning in Data-Driven Pavement Image Analysis and Automated Distress Detection: A Review, *Data*, 3(28), 2-19.
- [15] Gopalakrishnan, K. vd., 2018. Crack Damage Detection in Unmanned Aerial Vehicle Images of Civil Infrastructure Using Pre-Trained Deep Learning Model. *International Journal for Traffic and Transport Engineering*, 8(1-14).
- [16] Cha, Y.-J., Choi, W., Büyüköztürk, O., 2017. Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 32(361-378).

- [17] Coca, Georgiana Lucia vd., 2020. Crack Detection System in AWS Cloud Using Convolutional Neural Networks. *Procedia Computer Science*, 176(400-409).
- [18] Ha, J., Park, K. ve Kim, M., 2021. A Development of Road Crack Detection System Using Deep Learning-based Segmentation and Object Detection. *The Journal of Society for e-Business Studies*, 26(93-106).
- [19] Yang, X., Li, H., Yu, Y., Luo, X., Huang, T. and Yang, X., 2018. Automatic Pixel-Level Crack Detection and Measurement Using Fully Convolutional Network, *Computer-Aided Civil and Infrastructure Engineering*, 33(12), 1090-1109.
- [20] Ni, F. and Zhang, J., 2018. Pixel-Level Crack Delineation in Images with Convolutional Feature Fusion, *Structural Control and Health Monitoring*, e2286, 26(1-18).
- [21] Ronneberger, O., Fischer, P. and Brox, T., 2015. U-net: Convolutional Networks for Biomedical Image Segmentation, *International Conference on Medical image computing and computer-assisted intervention*, 234-241.
- [22] Cha, Y.J., Choi, W., Büyüköztürk, O., 2017. Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 5(361-378).
- [23] Zhang, L., Yang, F., Daniel Zhang, Y., Zhu, Y.J., 2016. Road Crack Detection Using Deep Convolutional Neural Network, 2016 IEEE International Conference on Image Processing (ICIP), 3708-3712.
- [24] Maeda, H., Sekimoto, Y., Seto, T., Kashiya, T., Omata, H., 2018. Road Damage Detection Using Deep Neural Networks with Images Captured Through a Smartphone, arXiv preprint, arXiv:1801.09454
- [25] Makantasis, K., Protopapadakis, E., Doulamis, A., Doulamis, N., Loupos, C., 2015. Deep Convolutional Neural Networks for Efficient Vision Based Tunnel Inspection, *Proceedings-2015 IEEE 11th International Conference on Intelligent Computer Communication and Processing, ICCP 2015*, 335-342.
- [26] Stentoumis, C., Protopapadakis, E., Doulamis, A. and Doulamis, N., 2016. A Holistic Approach for Inspection of Civil Infrastructures Based on Computer Vision Techniques, *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences- ISPRS Archives*, 131-138.
- [27] Sevinç, A., Özyurt, F., 2022. Beton Yüzey Çatlaklarının Tespitinde Derin Öğrenme Mimarilerin Kullanılması, *International Journal of Innovative Engineering Applications*, 6(318-325).
- [28] McCulloch, W.S., Pitts, W. 1943. A Logical Calculus of The Ideas Immanent in Nervous Activity. *The Bulletin of Mathematical Biophysics*, 5(115-133).
- [29] Yakıt, O., Özkan, Y., 2017. Kurumsal Kaynak Planlama Sistemlerinde Yapay Sinir Ağlarının Değerlendirilmesi Yaklaşımı. *Siyaset, Ekonomi ve Yönetim Araştırmaları Dergisi*, 5(287-296).
- [30] Karpathy, A., Stanford University CS231n Convolutional Neural Networks for Visual Recognition Course Notes, 2019, (<http://cs231n.github.io/>), (Ağustos 2022)
- [31] Bengio, Y., 2009. Learning deep architectures for AI. *Foundations and Trends in Machine Learning*, 2(1-127).
- [32] Deng, L., Yu, D. 2013. Deep Learning: Methods and Applications. *Found. Trends Signal Process.* 7(197-387).
- [33] LeCun, Y., Bengio, Y., Hinton, G., 2015. Deep Learning. *Nature*. 521(436-444).
- [34] Brownlee, J., 2019, What is Deep Learning?, (<https://machinelearningmastery.com/what-is-deep-learning/>), (Mayıs 2022)
- [35] Akmeşe, Ö.F., Erbay, H., Kör, H., 2018. Derin Öğrenme ile Görüntü Kümeleme. 5th International Management Information Systems Conference, 108-110.
- [36] Ferentinos, K.P. 2018. Deep Learning Models for Plant Disease Detection and Diagnosis. *Computers and Electronics in Agriculture*, 145(311-318).
- [37] N. Kruger vd., 2013. Deep Hierarchies in the Primate Visual Cortex: What Can We Learn for Computer Vision?, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(1847-1871).
- [38] Introducing Deep Learning with MATLAB, <https://www.mathworks.com/campaigns/offers/next/deep-learning-ebook.html>, (Erişim Tarihi: Ağustos 2022).
- [39] Brownlee, J., A Gentle Introduction to Dropout for Regularizing Deep Neural Networks, 2018, (<https://machinelearningmastery.com/dropout-for-regularizing-deep-neural-networks/>) (Erişim Tarihi: Ağustos 2022)
- [40] Geetharamani, G., Arun Pandian, J., 2019. Identification of Plant Leaf Disease Using A Nine Layer Deep Convolutional Neural Network. *Computers and Electrical Engineering*, 76(323-338).
- [41] Shi, Y., Cui, L., Qi, Z., Meng, F. and Chen, Z., 2016. Automatic Road Crack Detection Using Random Structured Forests. *IEEE Transactions on Intelligent Transportation Systems*, 17(3434-3445).
- [42] Zou, Q., Cao, Y., Li, Q., Mao, Q. and Wang, S., 2012. Cracktree: Automatic Crack Detection from Pavement Images. *Pattern Recognition Letters*, 33(227-238).
- [43] Eisenbach, M., Stricker, R., Seichter, D., Amende, K., Debes, K., Sesselmann, M., Ebersbach, D., Stoeckert, U., Gross, H.-M., 2017. How to Get Pavement Distress Detection Ready for Deep Learning? A Systematic Approach, *International Joint Conference on Neural Networks*, 2039-2047.
- [44] Amhaz, R., Chambon, S., Idier, J. and Baltazart, V., 2016. Automatic Crack Detection on Two-Dimensional Pavement Images: An Algorithm Based on Minimal Path Selection, *IEEE Transactions on Intelligent Transportation Systems*, 17(2718-2729).