

## Otonom Taşıyıcı Araçlardaki Hataların Teşhisi için Evrişimli Sinir Ağları Tabanlı Çoklu Heterojen Sensörlerin Füzyon Yöntemi

Sergen AŞIK<sup>1</sup>, Emine DENİZ<sup>2</sup>, Eyüp ÇİNAR<sup>3\*</sup>

<sup>1</sup> Yazılım Mühendisliği Bölümü, Mühendislik Mimarlık Fakültesi, Eskişehir Osmangazi Üniversitesi, Eskişehir, Türkiye

<sup>2</sup> Bilgisayar Mühendisliği Bölümü, Mühendislik Mimarlık Fakültesi, Eskişehir Osmangazi Üniversitesi, Eskişehir, Türkiye

<sup>3</sup> Bilgisayar Mühendisliği Bölümü, Mühendislik Mimarlık Fakültesi, Eskişehir Osmangazi Üniversitesi, Eskişehir, Türkiye

<sup>1</sup> sergen.asik@ogu.edu.tr, <sup>2</sup> denzemine@gmail.com <sup>3</sup> eyup.cinar@ogu.edu.tr

(Geliş/Received: 01/10/2021;

Kabul/Accepted: 07/12/2021)

**Öz:** Siber fiziksel sistemler, akıllı fabrikalardaki üretim süreçlerini izlemek için kullanılmaktadır. Üretimdeki lojistiğe katkı sağlayacak en önemli teknolojilerden birisi otonom taşıyıcı araçlardır. Otonom taşıyıcı araçların görevlerini gerçekleştirmesi esnasında beklenmeyen bir problem veya aksama durumu yaşanmasının veriler üzerinden tespiti önemlidir. Bu çalışma, çok sensörlü veri füzyonu ve darboğaz katmanı ile optimize edilmiş evrişimli sinir ağı tabanlı otonom taşıyıcı araçlar için yeni bir hata tespit yöntemi sunmaktadır. Daha zengin öznitelikler elde etmek için tek sensörden gelen sinyal verileri yerine çoklu heterojen sensörlerden gelen sinyal verilerini görüntülere dönüştüren bir dönüştürme yönteminden yararlanılmıştır. Önerilen evrişimli sinir ağı mimarisi, akım ve titreşim sensörlerinden alınan verilerin dönüşümü ile elde edilen görüntüleri girdi verisi olarak kullanmaktadır. Önerilen yaklaşımın etkinliğini doğrulamak için otonom taşıyıcı araç kullanılarak sensörlerden veriler toplanmış ve gerçek bir fiziksel ortamda çeşitli hata senaryoları oluşturulmuştur. Tek sensör kullanılarak ortalama %85 ve çoklu heterojen sensörler kullanılarak ortalama %93 hata tespit doğruluğu önerilen yöntemde elde edilmiştir.

**Anahtar Kelimeler:** Hata teşhisi, evrişimli sinir ağları, çoklu sensör veri füzyonu, otonom taşıyıcı araç

### Fusion Method of Multiple Heterogeneous Sensors Based on Convolutional Neural Networks for Fault Diagnosis in Autonomous Transport Vehicles

**Abstract:** Cyber-physical systems are used to monitor production processes in smart factories. One of the most important technologies that will contribute to logistics in production is autonomous transport vehicles. It is important to detect an unexpected problem or malfunction during the task of autonomous transportation vehicles through data. This paper proposes a novel fault detection method for autonomous transport vehicles based on multi-sensor data fusion and bottleneck layer optimized convolutional neural network. In order to obtain enhanced features, a transformation method is utilized that converts data from multiple heterogeneous sensors into images. The proposed convolutional neural network architecture uses images obtained by transforming data from current and vibration sensors as input data. A use-case is implemented to verify the effectiveness of the proposed approach. The datasets are created from sensors available on an autonomous transport vehicle in a real physical environment during various operational fault scenarios. An average of 85% fault detection accuracy using a single sensor and an average of 93% using multiple heterogeneous sensors was obtained in the proposed method.

**Keywords:** Fault diagnosis, convolutional neural networks, multi-sensor data fusion, autonomous transport vehicle

## 1. GİRİŞ

Akıllı fabrikada fiziksel süreçleri izlemek için siber fiziksel sistemler gibi bazı son teknolojiler kullanılmaktadır. Günümüzde bu teknolojilerin kullanımı ile üretim otomasyonu daha verimli hale getirilebilmektedir. Siber fiziksel sistem teknolojisini kullanan üretim cihazları, üretim faaliyetinden gelen ilgili tüm bilgileri izlemektedir. Akıllı fabrikada üretim sahasındaki bulunan malzemelerin verimli bir şekilde teslim edilmesini sağlayan lojistik otomasyon üretim sürecini hızlandırmaktadır [1]. Akıllı fabrikalarda lojistik otomasyon, insan müdahalesi olmadan malzemeleri hareket ettirebilen otonom taşıyıcı araç (OTA) ile gerçekleştirilebilmektedir [2].

OTA'lar, akıllı fabrikalardaki malzemeleri taşımak için yaygın olarak kullanılan mobil robotlardır [3, 4]. Endüstriyel operasyonu otomatikleştirmek ve maliyetini düşürmek için üretim sahasında OTA'lar konuşlandırılır. İnsanlar tarafından yapılması zor ve tehlikeli olan lojistik görev için OTA uygundur [5]. OTA'ların fabrika ortamındaki görevlerini gerçekleştirmesi esnasında beklenmeyen bir problem veya aksama durumu yaşanmasının insan müdahalesi olmadan gelen veriler üzerinden tespit edilmesi ise işletmeler adına oldukça önem arz edebilmektedir [6]. OTA üzerinde bulunan sensörlerden gelen veriler ile OTA'nın mekanik ve elektronik aksamındaki hata tespiti veya OTA'ya zarar verebilecek operasyonel anomalilerin tespiti yapılabilir.

\* Sorumlu yazar: [eyup.cinar@ogu.edu.tr](mailto:eyup.cinar@ogu.edu.tr). ORCID Numaraları: <sup>1</sup> 0000-0002-3388-4047, <sup>2</sup> 0000-0003-1617-2483, <sup>3</sup> 0000-0003-3189-7247

Akıllı hata tespiti, günümüzdeki modern üretim sistemlerinde sıklıkla kullanılmaya başlanmıştır. Edinilen hatalı tespitler, üretim cihazının güvenilirliğini ve kullanım ömrünü önemli ölçüde arttırmak ile beraber işletmelere bakım maliyetleri açısından da avantajlar sağlamaktadır [7]. Hata tespiti, model tabanlı ve veri odaklı olmak üzere temelde iki farklı yaklaşım kullanılarak gerçekleştirilir. Model tabanlı yaklaşım, izlenen sistemin karmaşık fiziksel modellenmesine dayanır ve sistem hakkında ileri seviye uzmanlık bilgisi gerektirir. Son zamanlarda gittikçe yaygınlaşan veri odaklı yaklaşım, makine öğrenmesi algoritmalarını kullanır ve hata tespiti modelinin veriden yararlanarak geliştirilmesine olanak sağlar. Makine öğrenmesi algoritmaları arasında derin öğrenme algoritmaları, geleneksel makine öğrenimi algoritmalarına kıyasla herhangi bir sistem uzmanlığı gerektirmeden gelen verilerdeki öznitelikleri tam olarak keşfedebilmektedir [8]. Bazı çalışmalarda derin öğrenme, araca takılmış kameralardaki görüntülerden hataları tespit etmek ve tanımlamak için kullanılmıştır [9, 10]. Son zamanlardaki bir araştırmada aracın ilgili ekipmanlarına sensörler eklenerek hata tespiti üzerine çalışılmıştır [11]. Akıllı hata tespitindeki zorluklar arasında geliştirilmiş modelin sağlamlığı (robustness) ile birden fazla hatanın gerçek zamanlı olarak belirlenmesi yer almaktadır. Hata tespitinde sağlamlık birden fazla ve farklı sensörlerden gelen bilgilerin birleştirilmesi ile artırılabilir.

OTA'lar, genelde kendisi ve çevresi hakkında bilgi toplamak için birden fazla farklı sensör ile donatılmış bir şekilde üretilirler. Üzerindeki sensörler çevreyi algılama, performans ve durum izleme gibi işlevleri etkinleştirir. Bu sensörlerden toplanan veriler aynı zamanda nesnelere interneti ve siber fiziksel sistem teknolojilerini kullanarak bir üretim tesisinde uzaktan izlenip gerçek zamanlı olarak bir veri tabanında kayıt altına alınabilir. Sensörlerden toplanan bu ham veriler, çeşitli sinyal işleme yöntemleri ile işlenerek hata veya anomali tespiti için değerli bilgiler elde edilebilir. Genel anlamda zaman serisi verileri olarak da adlandırılan sensör verileri zaman alanında, frekans alanında veya zaman-frekans alanında analiz edilmektedir. Ham olarak elde edilmiş zaman alanında bulunan verilerdeki özniteliklerinin çıkarılması frekans alanında yer alan verilerdeki özniteliklerinin çıkarılmasının aksine daha az işlem kapasitesi ile gerçekleştirilir [12, 13].

Birbirinden farklı sensörlerin, ekipmandaki hataları tespit etmek için kendilerine göre avantajları bulunur. Titreşim sensörü ekipmandaki mekanik hataları tespit etmekte iyi iken akım sensörü ise ekipmandaki elektronik hataları tespit etmekte daha iyidir. Aynı zamanda sensörler farklı çevresel çalışma koşullarına göre de duyarlılık göstermektedir. Heterojen sensörleri birleştirmek ve analiz etmek, karmaşık sistemlerin hatalarını tespit etmek için uygun bir yaklaşım olabilir. Bu yaklaşıma çoklu sensör füzyonu denir. Tek sensörlü hata tespit yaklaşımlarına kıyasla daha doğru ve güvenilir sonuçlar elde edilebilmektedir [14-16].

Bu makalede OTA'lar için çoklu heterojen sensör verilerinin füzyonuna dayalı Evrişimli Sinir Ağı (ESA) tabanlı yeni bir hata tespit yöntemi önerilmiştir. Bu makalenin başlıca katkıları şunlardır:

- OTA için üç tip yol anomali endüstriyel bir ortam perspektifinden belirlenmiştir.
- Homojen sensör verileri, görüntülere dönüştürülerek füzyonunun gerçekleştirilmesini sağlayan bir metot kullanılmıştır. Bu çalışma, heterojen sensör verilerine de uygulanabileceğini göstermiştir.
- Füzyon edilmiş çoklu heterojen sensör verilerinin özniteliklerini çıkarabilmek için darboğaz katmanı ile geliştirilmiş bir ESA modeli sunulmuştur.

Bu makalenin geri kalanı şu şekilde organize edilmiştir: Bölüm 2'nin altında ilgili çalışmalar hakkındaki literatürler gözden geçirilmiştir; Bölüm 3'te çoklu heterojen sensör verileri, görüntülere dönüştürülerek yapılan füzyon yöntemi ve darboğaz katmanı ile geliştirilmiş ESA modelinin mimarisi sunulmuştur; Verilerin toplanma ortamı ve veri setinin oluşturulma süreci Bölüm 4'te anlatılmıştır; Tek sensör ve çoklu heterojen sensörlerin birleşiminin sonuçlara olan etkisi Bölüm 5'in altında gösterilmiştir; Bölüm 6'da yöntemden elde edilmiş sonuçlar değerlendirilmiş ve gelecek çalışmalar hakkında bilgi verilmiştir.

## 2. LİTERATÜR TARAMASI

OTA'lar, robotik ve otomotiv teknolojisi üzerine yapılan son araştırmalarda artan bir ilgi görmektedir. İlerleyen teknolojik gelişmeler ile birlikte lojistik otomasyonda kullanılan OTA'lar üzerindeki donanımlar ve yararlanılan yapay zeka algoritmalarıyla daha akıllı hale gelmektedir. Aynı zamanda bu araçlar için kullanılan elektronik ve mekanik parçaların yapı ve işlevselliğindeki karmaşıklık, yoğun kullanımları vb. operasyonel nedenlerle de zamanla hataların oluşması kaçınılmazdır. Hatalar, sistemlerin yanlış bir şekilde çalışmasına veya beklenen verimliliği sağlayamamasına neden olabilmektedir. Bu nedenle hataların, sistemi kötü etkileyecek sonuçlara sebep olmasını önlemek için erkenden tespiti yapılabilir. Bu tür bir erken tespit, ilgili parçanın ömrünün uzatılması ve bakım maliyetinin düşürülmesi açısından önemlidir.

V. Chandola ve arkadaşları, hata tespiti için olağan dışındaki verilerden örüntüler bulmaya odaklanan kapsamlı bir genel bakış sunmuşlardır [17]. Otonom araçlar için hata tespitinde bazı araştırmacılar, çoklu sensör füzyonu perspektifini uygulamışlardır. M. Realpe ve arkadaşları, KITTI veri setindeki sensör hatalarını bulmak için bir sensör füzyon mimarisini Destek Vektör Makinesi (DVM) modeline uygulamışlardır. Bu mimari, veriler

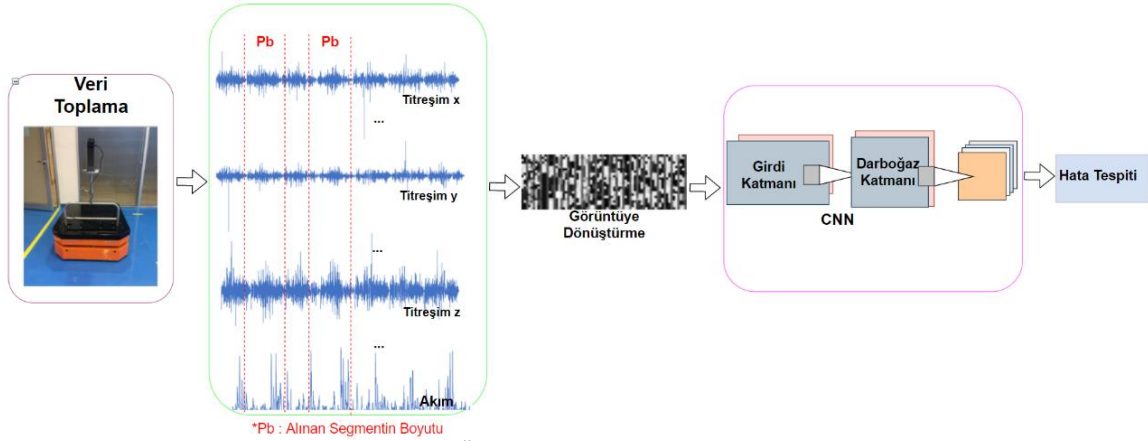
tüm sisteme entegre edilmeden önce hatalı sensörleri izole etmektedir [18]. N. D. Gingras Pous ve D. Gruyer, çoklu sensör verilerini işlemeye yönelik analitik artıklık ve doğrusal olmayan bir dönüşüm ölçümünü kullanan arıza tespit mimarisini önermişlerdir [19]. Fang ve arkadaşları, otonom aracın durum hatalarını tespit etmek için güvenli alanı ve güvenli olmayan alanı ayıran sınır eğrisini bulmaya yönelik DVM yöntemini sunmuşlardır [20]. D. Kwon ve arkadaşları, günümüzde derin öğrenmeye artan ilginin nedeniyle hata tespitinde kullanılan derin öğrenme tekniklerini araştırmışlardır. Yapılan çalışma, geleneksel makine öğrenimi algoritmalarına kıyasla derin öğrenme modellerinin anomalileri tespit etmekteki etkinliğini göstermiştir [21]. Derin öğrenme, verileri bir sinir ağının katmanları içinde iç içe geçmiş kavramlar hiyerarşisi olarak temsil edilmeyi öğrenerek iyi performans ve esneklikler sağlamaktadır [22]. Çoklu doğrusal olmayan dönüşüm katmanlarıyla öğrenmeyi ifade eden derin öğrenme [23], farklı uygulamalar için hata tespiti sorunlarını çözmek için de uygulanabilmiştir. Derin öğrenme modelinin karmaşıklığının dengelenmesi ve genelleme yeteneğinin geliştirilmesi için büyük miktarda veriye ihtiyaç vardır [24]. Çeşitli araştırmalardaki hata tespiti uygulamalarında Otomatik Kodlayıcı (OK), Derin Boltzmann Makinaları (DBM) ve Tekrarlayan Sinir Ağları (TSA) gibi derin öğrenme algoritmalarının başarıları gösterilmiştir [25-27]. G.Baldini ve arkadaşları, bir araca monte edilmiş ataletsel ölçüm biriminden toplanan verileri özellikle de ivmeölçerler ve jiroskopların bileşenleri tarafından oluşturulan verileri kullanarak yoldaki anomaliliklerin tespitini ve tanımlanmasını değerlendirmişlerdir. Zaman-frekans alanındaki gösteriminin orijinal zaman alanındaki verinin yerine ESA'ya girdi olarak kullanıldığı bir yaklaşım önerilmiştir. Z. Chen ve W. Li, çoklu sensör verilerinin özneliklerini birleştirmek için Seyrek Otomatik Kodlayıcıları (SOK) ve Derin İnanç Ağları (DIA) tercih etmişlerdir [28]. Zaman alanı ve frekans alanındaki öznelikleri farklı sensörden gelen verilerden çıkarmışlardır. Pan ve arkadaşları, rulmandaki hata çeşitlerini sınıflandırmak için ESA'nın çıktısını Uzun Kısa Vadeli Hafıza Ağları (UKVHA) girdi olarak kullanmıştır [29].

ESA, derin öğrenmede temsili bir grafik tanıma ağıdır. İnce ve arkadaşları, motor arıza tespitinin öznelik çıkarma ve sınıflandırma aşamalarını tek bir öğrenme gövdesinde birleştirmek için içsel bir uyarlamalı tasarıma sahip tek boyutlu ESA kullanmışlardır. Hızlı ve doğru bir motor durumu izleme ile erken arıza tespit sistemi gerçekleştirilmiştir [30]. C. Liu ve arkadaşları, dişliler için değişken mod ayrıştırmasını ESA tabanlı hata teşhis yönteminde öznelik çıkarmak için kullanmışlardır [31]. Ding ve arkadaşları dalgacık paket enerji görüntülerini ESA kullanarak iş mili yataklarının enerji dalgalanması için çok ölçekli bir öznelik madenciliği yöntemi önermişlerdir [32]. O. Janssens ve arkadaşları, ESA'yı öznelik öğrenme için kullanmışlardır. Yöntem, verilerin kendisinden hata tespiti için öznelikleri bağımsız olarak öğrenmektir. İncelenen birçok çalışmada zaman eksenindeki ham titreşim verileri iki boyutlu görüntülere dönüştürülür. Görüntüler, ESA'ya girdi olarak kullanılmıştır [33, 34]. Bununla birlikte, yukarıdaki makalelerin tümü, özellikleri oluşturmak için uzman deneyimine dayanır ve bazıları tek tip bir sensörden gelen verileri analiz etmek ile sınırlıdır.

Bu makale literatürdeki diğer makalelere göre farklı olarak heterojen sensör verilerini zaman alanında ele alarak bir füzyon yöntemi önermekte ve yeni bir kullanım senaryosu olarak OTA sistemleri üzerinde sonuçlar sunmaktadır.

### 3. YÖNTEM

Bu bölümde, OTA'nın üzerinde bulunan heterojen sensörlerin füzyonu ve darboğaz katmanı ile geliştirilmiş ESA tabanlı hata teşhis yöntemi açıklanmıştır. Çoklu heterojen sensör verilerinin görüntülere dönüştürülme metodu bölüm 3A'da anlatılmıştır. Füzyon edilmiş verilere uygulanan darboğaz katmanı ile geliştirilmiş ESA modelinin mimarisi bölüm 3B'nin altında sunulmuştur. Önerilen yöntemin akış şeması Şekil 1'de gösterilmiştir.



Şekil 1. Önerilen yöntemin akış şeması

### A. Çoklu Heterojen Sensör Verilerinin Görüntüleme Dönüştürülmesi (Veri Füzyonu)

Veri ön işleme makine öğrenmesi ve derin öğrenme algoritmaları için temel adımlardan biridir. Veri kümesine henüz model uygulanmadan önce veri kalitesinin artırılması, ham verideki gürültünün azaltılması ve dolayısıyla algoritmanın daha verimli çalışması hedeflenir. Normalleştirme (normalization) ile veri dönüşümü, kayıp verilerin tamamlanması (imputation) ve aykırı verilerin temizlenmesi en bilindik veri ön işleme yöntemleridir. Wang ve arkadaşları, homojen titreşim sensöründen gelen üç eksenli verileri görüntüleme dönüştürerek transformasyonu ve füzyonu bir veri ön işleme metodu olarak önermişlerdir [35]. Sunulan çalışmadaki bu transformasyonun etkili yönü; kullanıcılar için birden fazla ham sensör verisinin kolay ve hızlı bir şekilde, uzman deneyimi ve aynı zamanda çeşitli parametre ayarları gerektirmeyen bir öznetelik haritası oluşturma kabiliyetinin kazandırılabilmesidir. Referans alınan bu metod bizim çalışmamızda farklı olarak, titreşim ve akım sensörleri gibi heterojen kaynaklardan gelen verilerin ön işlenmesi için uyarlanmıştır. Çoklu heterojen sensör verilerinin uzman deneyimi gerektirmeyen bir şekilde füzyonun sağlanabilmesi için yararlanılan griölçek görüntü dönüşüm yöntemi aynı zamanda ileriki çalışmamızda robot üzerinde bir uç birim donanımında gerçek zamanlı gömülü olarak çalıştırılması planlanan algoritmamızın limitli hesaplama ve hafıza kaynaklarına sahip bileşenleri için de bir avantaj olabileceği öngörülmektedir. Bu bağlamda literatürde gerek girdi verilerinde gerekse derin öğrenme modelindeki ağırlıkların tam sayı aritmetiği kullanarak, modelin de sınıflandırma performansını etkilemeden, elde edilen gerçek zamanlı performans kazanımlarının avantajlarını inceleyen çalışmalar da mevcuttur [36].

Üç eksenli titreşim ve akım verilerinin görüntüleme dönüştürme yöntemi Şekil 2’de gösterilmiştir. Çoklu heterojen sensör verilerinin birlikte kullanımının anlamlı olabilmesi, her sensör sinyalinin zaman eksenindeki örneklerinin eş zamanlı olmasını gerektirir. Üç eksenli titreşim sinyali ve akım sinyali için toplamda 4 kanal kullanılmıştır.  $4M \times N$  boyutlu öznetelik haritasını elde etmek için; ham sinyaller  $s(k, i)$  şeklinde segmentlere ayrılmıştır. Burada ‘k’ kanal sayısını ve ‘i’ de kullanılmak istenen segment boyutunu temsil eder. Üç eksenli titreşim ve akım sinyallerinden  $M \times N$  uzunluğundaki boyutlarda segmentler alınmıştır. M ve N parametreleri elde edilmek istenilen görüntünün boyutuna göre ayarlanmaktadır. Örneğin, 4 sinyal verisinin (3 eksenli titreşim ve akım) her birinden 576 boyutunda segmentler alınarak  $96 \times 24$  boyutunda görüntüler elde edilmektedir. Denklem 1 ile sinyaller, segmentlere ayrılmıştır.

$$S(k, i) = s(k, i) \quad (1)$$

$$k = 1, 2, 3, 4; i = 1, 2, 3, \dots, M \times N$$

uint8, görüntünün piksel değerini 8 bitlik işaretli tam sayı değerine dönüştürmek için görüntü işleme yaygın olarak kullanılır. Denklem 2’deki veri ön işleme yöntemi, görüntü verilerinin piksel değeri aralığını gri tonlamalı olan  $[0, 255]$  içinde sınırlar. Bu veri seviyesindeki füzyon yönteminin avantajı, farklı karakteristik özelliklere sahip verilerin birlikte kullanılmasını sağlamasıdır.

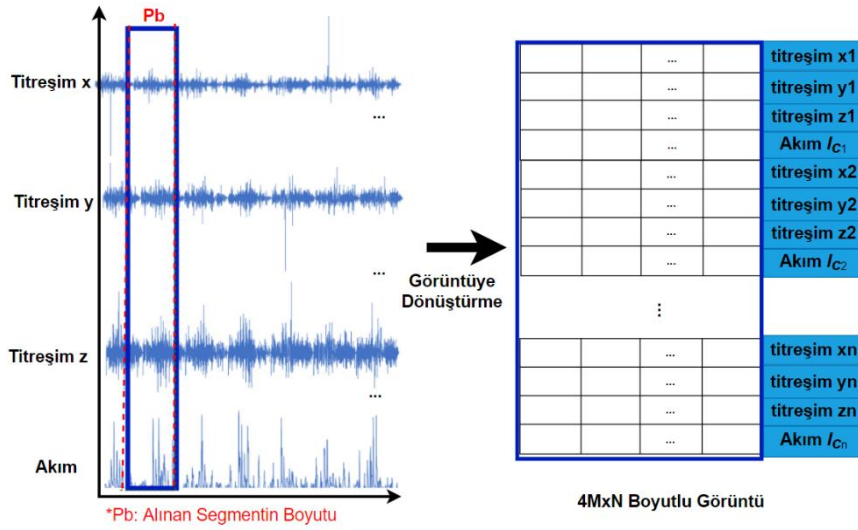
$$F(m, n) = \text{uint8} \left( 255 \times \frac{S\{k, (m-k) \times N / 4 + n\}}{\text{Max}S\{k\}} \right)$$

$$m = 1, 2, \dots, 4M; n = 1, 2, \dots, N$$

(2)

$$k(m) = \begin{cases} 1, & m = 1, 5, 9, \dots, 4M - 3 \\ 2, & m = 2, 6, 10, \dots, 4M - 2 \\ 3, & m = 3, 7, 11, \dots, 4M - 1 \\ 4, & m = 4, 8, 12, \dots, 4M \end{cases}$$

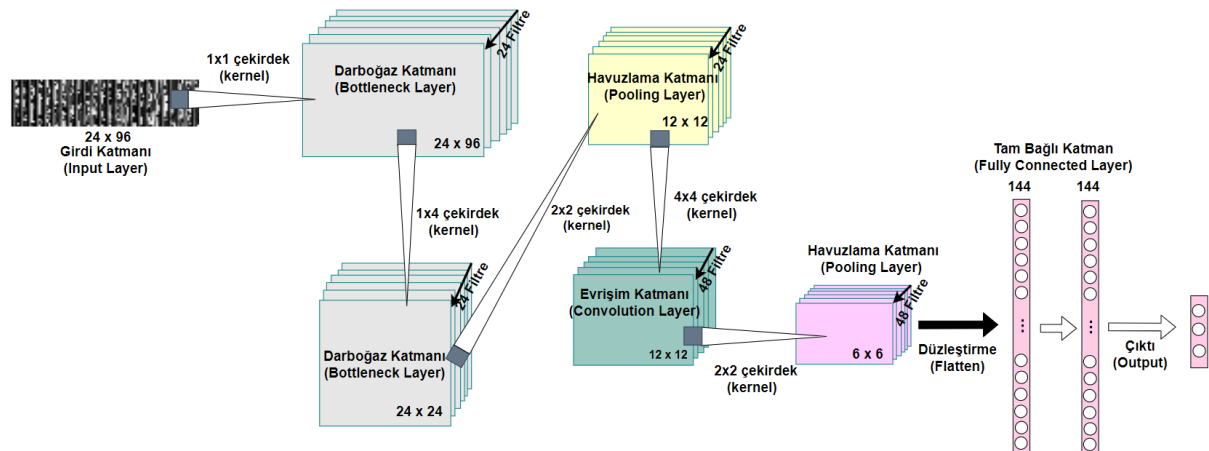
Bu çalışmada Şekil 2’de gösterildiği gibi Pb boyutunda 3 eksenli titreşim ve akım sinyallerinden segmentler alınarak görüntülere dönüştürülmüştür. Segmentler, kontrollü veri toplanırken OTA’nın başlama ve durma zamanları dışındaki hareketlerini içermektedir.



Şekil 2. Üç eksenli titreşim sensörü ve akım sensörü verilerinin görüntülere dönüştürülmesi (veri füzyonu)

## B. Hata Tespitinde Kullanılan Darboğaz Katmanı ile Geliştirilmiş ESA Modeli

Hata tespiti için önerilen ESA modelinin yapısında girdi katmanı (input layer), darboğaz katmanı (bottleneck layer), evrişim katmanı (convolution layer), havuzlama katmanı (pooling layer) ve tam bağlı katman (fully connected layer) olarak adlandırılan beş tür katman bulunmaktadır. Önerilen ESA modelinin mimarisi Şekil 3’te gösterilmiştir.



Şekil 3. Önerilen ESA modeli

Girdi katmanına bölüm 3.A'da sinyallerden dönüştürülmüş görüntülerin transpozesi (parametre  $M = N = 24$ ) girer. Darboğaz katmanı,  $1 \times 1$  ve  $1 \times 4$  boyutlarındaki evrişimli çekirdeklerin (convolution kernel) evrişim işlemi görüntülere uygulayarak özneliklerini çıkarmaktadır. Bu yöntemde kullanılan darboğaz katmanı veri füzyonunda elde edilmiş görüntülerdeki öznelikleri çıkarmak için kullanılmıştır.

Darboğaz katmanının çıktısı, dört kanallı veri füzyonu için kullanılmıştır. Evrişimli çekirdeğin boyutu  $1 \times k$  ve adım boyutu (stride)  $1 \times k$ 'dir. Veri füzyonu için kullanılan sinyal sayısını 'k' ( $k = 4$ ) temsil eder. Darboğaz katmanı sayesinde birbirinden farklı sinyallerin füzyon işlemi gerçekleşmektedir. Derin öğrenmede algoritmaların optimizasyonu yakınsama oranını etkilemektedir. Bu çalışmada "Adam" optimizasyon algoritması kullanılmıştır. Adam optimizasyonun hiper parametreleri sırasıyla: Öğrenme oranı ( $\alpha$ ) 0.001, aynı anda alınan girdi sayısı (batch size) 8 ve iterasyon (epochs) 120 olarak ele alınmıştır. ESA modelinde, evrişimli katman ya da havuzlama katmanından sonraki çıktı boyutunun sabit kalmasını sağlamak için marjinal sıfır doldurma (zero padding) yöntemi kullanılmıştır. Kullanılan ESA modelinin ayrıntıları Tablo 1'de açıklanmıştır.

**Tablo 1.** ESA modelinin ayrıntıları


Katman	Filtre Boyutu (Filter Size)	Çekirdek Boyutu (Kernel Size)	Adım Sayısı (Stride Size)	Çıktı Boyutu
Girdi (Input)	-	-	-	-
Darboğaz (Bottleneck)	24	(1, 1)	(1, 1)	(24, 96, 24)
Darboğaz (Bottleneck)	24	(1, 4)	(1, 4)	(24, 24, 24)
Havuzlama 1 (Pooling 1)	-	(2, 2)	(2, 2)	(12, 12, 24)
Seyreltme 1 (Dropout 1)	-	-	-	(12, 12, 24)
Evrişim 1 (Conv. 1)	48	(4, 4)	(1, 1)	(12, 12, 48)
Havuzlama 2 (Pooling 2)	48	(2, 2)	(2, 2)	(6, 6, 48)
Seyreltme 2 (Dropout 2)	-	-	-	(6, 6, 48)
Düzleştirme (Flatten)	-	-	-	(1728)
Seyreltme 3 (Dropout 3)	-	-	-	(1728)
Tam Bağlı 1 (Fully Connected 1)	-	-	-	(144)
Seyreltme 4 (Dropout 4)	-	-	-	(144)
Tam Bağlı 2 (Fully Connected 2)	-	-	-	(144)
Seyreltme 5 (Dropout 5)	-	-	-	(144)
Çıktı (Output)	-	-	-	(3)

#### 4. VERİ SETİ

Önerilen yöntemin hata tespitindeki başarısı OTA üzerinde doğrulanmıştır. OTA test ortamı; stres testleri için bir test yatağı, bir test laboratuvar ortamı, veri toplamak için sensör sistemi, kontrol ve görselleştirme test yazılımını sağlamaktadır.

Normal, engel ve parça gibi üç farklı çalışma koşulu belirlenmiş ve bu koşullar altında OTA belirlenen bir görevi yerine getirirken veriler toplanmıştır. Üç çalışma koşulunun her biri için OTA, aynı test ortamında 3.5 metre düz hareket ederek görev altında tekrar tekrar çalışırken sensör verileri toplanmıştır. Öncelikle herhangi bir engel

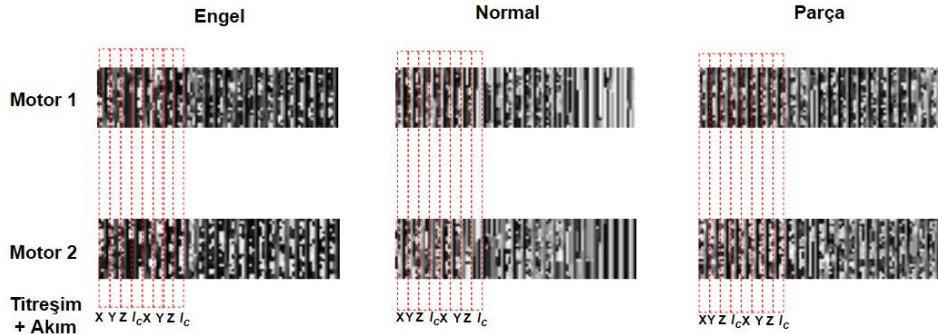
veya müdahalenin olmadığı ortamda 80 adet ölçüm kaydedilmiştir. İkinci koşulda dört adet özdeş metal engel 40 cm aralıklarla yere sabitlenmiş ve OTA aynı görev altında çalışırken 80 adet ölçüm daha alınmıştır. Son olarak her iki ana tekerleğe de 120 derecelik açı ile üçer adet 4 mm bakır kablo bantlanarak 80 adet daha ölçüm kaydedilmiştir. Sonuçta üç farklı çalışma koşulu sınıfı oluşturulmuş ve etiketlenmiştir. Simüle edilmiş test ortamı ve operasyonel hata sınıfları Şekil 4'te gösterilmiştir. Her görevin sonunda sensörlerden toplanan veriler ayrı csv dosyalarında saklanmıştır. Titreşim sensörü üç eksende 1.2 kHz örnekleme yaparken akım sensörü 100 Hz örnekleme yapmaktadır. Üç eksenli titreşim ve akım verilerini füzyon edebilmek için 1 akım verisine karşılık gelen 12 adet titreşim verisinin ortalaması alınmıştır.



Şekil 4. Deneysel test ortamı ve görev koşulları; a) Normal, b) Engel ve c) Parça

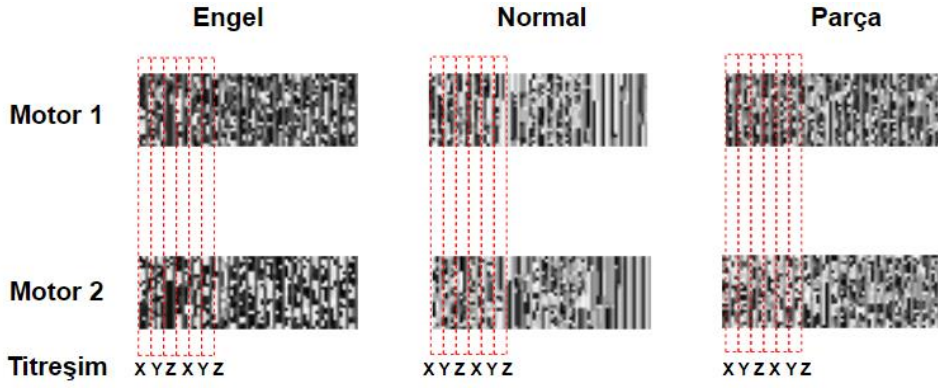
## 5. DENEYSEL ANALİZ VE SONUÇLARI

Bu deneyde OTA üzerinde bulunan titreşim ve akım sensörlerinden kaydedilen veriler kullanılmıştır. Üç eksenli titreşim ve akım verilerinden eş zamanlara denk gelen 596 boyutunda segmentler alınarak Bölüm 3A'daki metot ile 24 x 96 boyutunda görüntüler oluşturulmuştur. OTA'nın 3 farklı çalışma koşulu için birbirinden bağımsız 2 farklı motora ait üç eksenli titreşim ve akım verileri kullanılarak oluşturulmuş görüntüler Şekil 5'te gösterilmiştir.



Şekil 5. Üç eksenli titreşim ve akım verilerinden elde edilen görüntüler

OTA üzerindeki akım sensörüne ait veriler eklemeyen homojen sensör üzerindeki sonuçları göstermek için üç eksenli titreşim sensörü verilerinden 24 x 72 boyutundaki görüntüler Bölüm 3A'daki yöntem ile oluşturulmuştur. Şekil 6'da OTA'nın 3 farklı çalışma koşulu için birbirinden bağımsız 2 farklı motora ait üç eksenli titreşim verileri kullanılarak oluşturulmuş görüntüler gösterilmiştir.



Şekil 6. Üç eksenli titreşim verilerinden elde edilen görüntüler

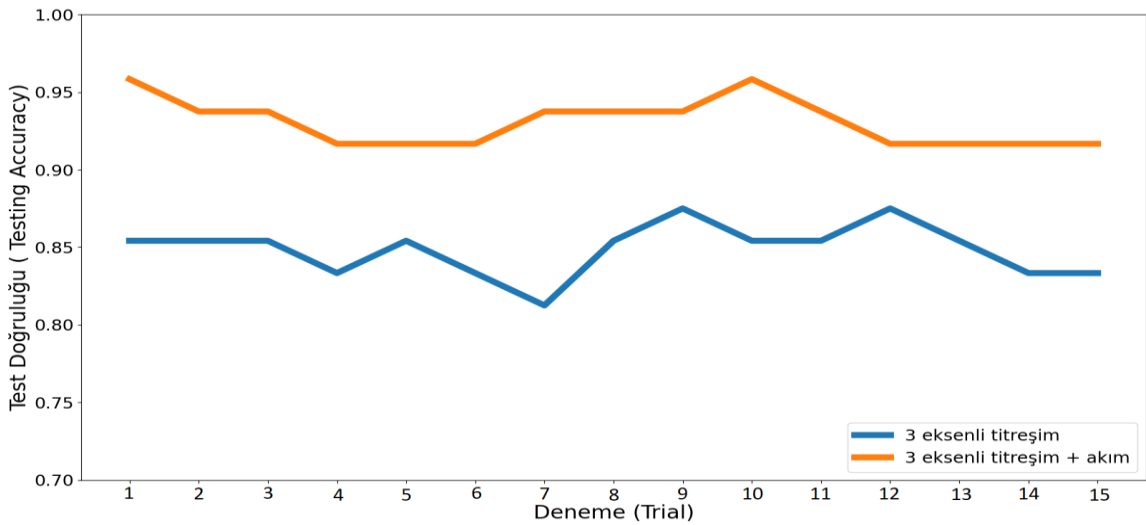
Bölüm 3B’de önerilen ESA modeli ile elde edilen görüntüler eğitilmiştir. Üç eksenli titreşim verilerinden elde edilen görüntüler ve üç eksenli titreşim ve akım verilerinin füzyonu ile elde edilen görüntüler önerilen model kullanılarak oluşturulan rassal veri kümeleri ile tekrar tekrar toplamda 15 kez çalıştırılarak deney sonuçlanmıştır. 3 farklı durum için toplam 240 adet görüntü elde edilmiştir. 240 adet görüntü içerisinde %60 eğitim (train), %20 test, ve %20 doğrulama (validation) olacak şekilde her seferinde rastgele ayrılmıştır.

Üç eksenli titreşim sensör verilerinin füzyonu için ortalama doğruluk %85’tir. Üç eksenli titreşim sensörü ve akım sensör verilerinin füzyonu için ortalama doğruluk ise %93’tür. Elde edilen sonuçlara göre önerilen yöntemin çoklu heterojen sensör verilerdeki füzyon başarısı, tek sensör verisinin başarısından daha yüksek doğruluğa sahip olduğu gözlemlenmiş ve Tablo 2’de detaylandırılmıştır.

Tablo 2. Önerilen yöntemin 15 kez çalıştırılmasından elde edilen sonuçlar

	Minimum	Maksimum	Ortalama	Standart Sapma
3 eksenli titreşim verisi	%81	%87	%85	%1.7
3 eksenli titreşim ve akım verileri	%92	%96	%93	%1.3

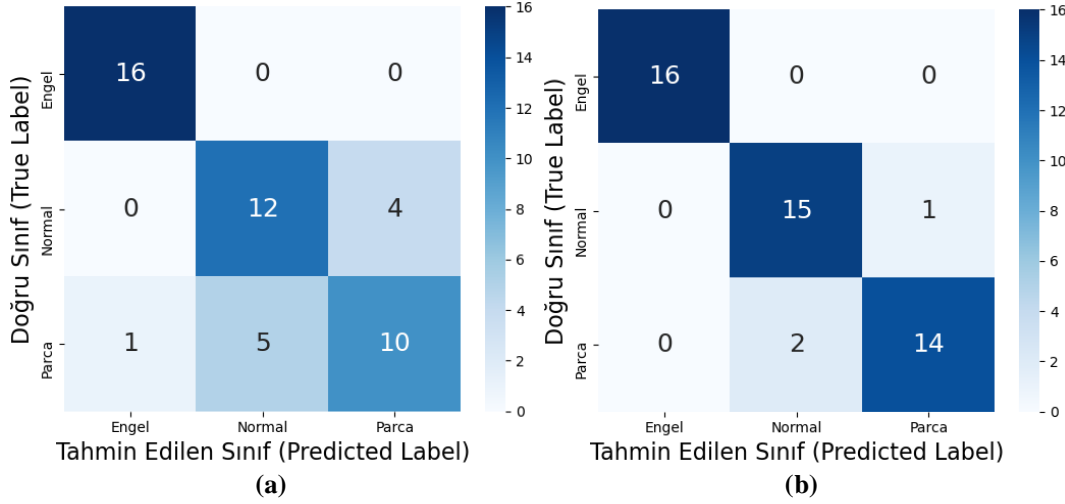
Tablo 2’de bulunan minimum, maksimum ve ortalama değerleri, modelin 15 kez çalıştırılma sonucunda elde edilmiş istatistiksel verilerdir. Modelin 15 kez çalıştırılması sonucunda elde edilen başarı doğrulama grafiği Şekil 7’de gösterilmiştir.



Şekil 7. Önerilen yöntemin 15 kez çalıştırılmasından elde edilen başarı doğruluk grafiği



Karmaşıklık matrisi, makine öğrenimi sınıflandırması için bir performans ölçümüdür. Doğru sınıf ile tahmin edilen sınıf arasındaki benzerliğin görselleştirilmesine izin verir [37]. Üç eksenli titreşim verilerinin füzyonu sonucunda elde edilen karmaşıklık matrisi Şekil 8a'da gösterilmiştir. Şekil 8b'de üç eksenli titreşim ve akım verilerinin füzyonu sonucunda elde edilen karmaşıklık matrisi gösterilmiştir.



Şekil 8. Karmaşıklık matrisi; (a) Üç eksenli titreşim sinyali, (b) Üç eksenli titreşim ve akım sinyalleri

Üç eksenli titreşim ve akım verileri ile üç eksenli titreşim verisinin, önerilen yöntemdeki başarı doğruluk sonuçları verilmiştir. Elde edilmiş sonuçlara göre heterojen sensör verilerinin füzyonu, homojen sensör verilerinin füzyonuna göre daha yüksek başarı doğruluğuna sahiptir. Belirlenmiş üç farklı çalışma koşulu için OTA görevlerini yerine getirirken sensörlerden gelen veriler, sistem üzeri bir ekipmanda oluşan anomali durumunun sadece mekanik aksam veya elektronik aksama değil her iki aksama da yansiyabildiğini göstermektedir. Şekil 8'deki karmaşıklık matrislerine göre heterojen sensör verileri, üç farklı çalışma koşulu için sınıflandırmada homojen sensör verilerinden daha yüksek başarı doğruluğuna sahiptir. Ayrıca Tablo 2'deki standart sapma değerlerinde gösterildiği gibi heterojen sensör verilerinin kullanımı ile eğitilmiş modelin dayanıklılığı, homojen olana göre daha yüksektir. Sonuç olarak çoklu ve heterojen sensör verileri ile füzyon yönteminin kullanılması, sistem üzerindeki hem mekanik hem de elektronik aksamındaki hataları daha yüksek bir başarı doğruluğunda tespit etmek ile beraber daha dayanıklı bir modele de katkı sağladığı gözlemlenmektedir.

## 6. SONUÇLAR

Heterojen sensörlerdeki verilerin füzyonu ve darboğaz katmanı ile geliştirilmiş yeni ESA tabanlı hata tespit yöntemi ve özgün bir kullanım senaryosu bu çalışmada sunulmuştur. ESA'daki darboğaz katmanı, füzyon edilmiş verilerin özneliklerini başarıyla çıkarabilmektedir. Bu diğer makine öğrenmesi yöntemlerine nazaran öznelik mühendisliği için kullanıcıya avantajlar sağlayabilir. Önerilen metod laboratuvar ortamındaki bir OTA üzerinde test edilmiştir. Elde edilen test sonuçlarına göre çoklu heterojen sensör verilerinin füzyonuna dayalı yöntemi, tek bir sensör verisinin kullanımına göre hata tespitinde daha yüksek başarı doğruluğu verdiği gözlemlenmiştir. Yöntem, veri setinden rassal olarak seçilen veri kümeleri ile toplamda 15 kez çalıştırılmış olup model başarısının her seferinde minimum, maksimum ve ortalama değerleri kayıt altına alınmıştır. Deneysel sonuçlar incelendiğinde çoklu heterojen sensör verileri kullanıldığında hata tespiti modelinin sınıflandırma performansında artış olduğu gözlemlenmiştir.

Gelecekteki çalışmalarda, kullanılan sensör tipleri ve hata sınıfları çeşitlendirilerek yöntemin ve modelin performansı farklı senaryolarda test edilecektir. Ayrıca bu çalışmada kullanılan OTA üzerinde NVIDIA Jetson TX2 GPU modülü bulunmaktadır. Modül, gerçek zamanlı olarak verilerin işlenmesi ve hataların tespiti için derin öğrenme modellerinin OTA üzerinde çalıştırılabilmesine olanak sağlamaktadır. İlerleyen çalışmalarda bu makalede önerilen modelin OTA üzerine transfer edilerek gerçek zamanlı hata tespitinin bir gömülü sistem olarak gerçekleştirilmesi üzerine de çalışılacaktır.

## TEŞEKKÜR

Bu çalışma, Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'nun (TÜBİTAK) 118C252 numaralı 2232 Uluslararası Lider Araştırmacılar Programı projesi tarafından desteklenmiştir.

## Kaynaklar

- [1] Lu, S., et al., A RFID-enabled positioning system in automated guided vehicle for smart factories. *Journal of Manufacturing Systems*, 2017. 44: p. 179-190.
- [2] De Ryck, M., M. Versteheyhe, and F. Debrouwere, Automated guided vehicle systems, state-of-the-art control algorithms and techniques. *Journal of Manufacturing Systems*, 2020. 54: p. 152-173.
- [3] Stetter, R., M. Witczak, and M. Pazera, Virtual diagnostic sensors design for an automated guided vehicle. *Applied Sciences*, 2018. 8(5): p. 702.
- [4] Sabattini, L., et al., *Advanced Automated Guided Vehicle Systems for Industrial Logistics*. 2017.
- [5] Dares, M., et al. Development of AGV as Test Bed for Fault Detection. in *2020 6th International Conference on Control, Automation and Robotics (ICCAR)*. 2020. IEEE.
- [6] ÖRNEK, Ö., E. GÜLBANDILAR, and A. YAZICI, AKILLI FABRİKALARDAKİ OTONOM TAŞIYICILAR İÇİN BULANIK MANTIK TABANLI ANOMALİ TESPİTİ. *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi*. 28(1): p. 53-61.
- [7] Zhang, X., et al., Multi-model ensemble deep learning method for intelligent fault diagnosis with high-dimensional samples. *Frontiers of Mechanical Engineering*, 2021: p. 1-13.
- [8] Hoang, D.-T. and H.-J. Kang, A survey on deep learning based bearing fault diagnosis. *Neurocomputing*, 2019. 335: p. 327-335.
- [9] Maeda, H., et al., Road damage detection and classification using deep neural networks with smartphone images. *Computer-Aided Civil and Infrastructure Engineering*, 2018. 33(12): p. 1127-1141.
- [10] Yang, X., et al., Automatic pixel-level crack detection and measurement using fully convolutional network. *Computer-Aided Civil and Infrastructure Engineering*, 2018. 33(12): p. 1090-1109.
- [11] Baldini, G., R. Giuliani, and F. Geib, On the Application of Time Frequency Convolutional Neural Networks to Road Anomalies' Identification with Accelerometers and Gyroscopes. *Sensors*, 2020. 20(22): p. 6425.
- [12] Yoo, Y.-J., Fault detection of induction motor using fast fourier transform with feature selection via principal component analysis. *International Journal of Precision Engineering and Manufacturing*, 2019. 20(9): p. 1543-1552.
- [13] Hendrickx, K., et al., A general anomaly detection framework for fleet-based condition monitoring of machines. *Mechanical Systems and Signal Processing*, 2020. 139: p. 106585.
- [14] Wang, X., D. Mao, and X. Li, Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network. *Measurement*, 2021. 173: p. 108518.
- [15] Gong, W., et al., A novel deep learning method for intelligent fault diagnosis of rotating machinery based on improved CNN-SVM and multichannel data fusion. *Sensors*, 2019. 19(7): p. 1693.
- [16] Jing, L., et al., An adaptive multi-sensor data fusion method based on deep convolutional neural networks for fault diagnosis of planetary gearbox. *Sensors*, 2017. 17(2): p. 414.
- [17] Chandola, V., A. Banerjee, and V. Kumar, Anomaly detection: A survey. *ACM computing surveys (CSUR)*, 2009. 41(3): p. 1-58.
- [18] Realpe, M., B. Vintimilla, and L. Vlacic. Sensor fault detection and diagnosis for autonomous vehicles. in *MATEC Web of Conferences*. 2015. EDP Sciences.
- [19] Pous, N., D. Gingras, and D. Gruyer, Intelligent vehicle embedded sensors fault detection and isolation using analytical redundancy and nonlinear transformations. *Journal of Control Science and Engineering*, 2017. 2017.
- [20] Fang, Y., et al., A Fault Detection and Diagnosis System for Autonomous Vehicles Based on Hybrid Approaches. *IEEE Sensors Journal*, 2020. 20(16): p. 9359-9371.
- [21] Kwon, D., et al., A survey of deep learning-based network anomaly detection. *Cluster Computing*, 2019. 22(1): p. 949-961.
- [22] Chalapathy, R. and S. Chawla, Deep learning for anomaly detection: A survey. *arXiv preprint arXiv:1901.03407*, 2019.
- [23] LeCun, Y., Y. Bengio, and G. Hinton, Deep learning. *nature*, 2015. 521(7553): p. 436-444.
- [24] Zhao, R., et al., Deep learning and its applications to machine health monitoring. *Mechanical Systems and Signal Processing*, 2019. 115: p. 213-237.
- [25] Tang, G., Y. Zhang, and H. Wang, Multivariable LS-SVM with moving window over time slices for the prediction of bearing performance degradation. *Journal of Intelligent & Fuzzy Systems*, 2018. 34(6): p. 3747-3757.
- [26] Yuan, M., Y. Wu, and L. Lin. Fault diagnosis and remaining useful life estimation of aero engine using LSTM neural network. in *2016 IEEE international conference on aircraft utility systems (AUS)*. 2016. IEEE.
- [27] Shao, H., et al., Rolling bearing fault detection using continuous deep belief network with locally linear embedding. *Computers in Industry*, 2018. 96: p. 27-39.
- [28] Chen, Z. and W. Li, Multisensor feature fusion for bearing fault diagnosis using sparse autoencoder and deep belief network. *IEEE Transactions on Instrumentation and Measurement*, 2017. 66(7): p. 1693-1702.

- [29] Pan, H., et al., An Improved Bearing Fault Diagnosis Method using One-Dimensional CNN and LSTM. *Strojnicki Vestnik/Journal of Mechanical Engineering*, 2018. 64.
- [30] Ince, T., et al., Real-time motor fault detection by 1-D convolutional neural networks. *IEEE Transactions on Industrial Electronics*, 2016. 63(11): p. 7067-7075.
- [31] Liu, C., et al., Planetary gears feature extraction and fault diagnosis method based on VMD and CNN. *Sensors*, 2018. 18(5): p. 1523.
- [32] Ding, X. and Q. He, Energy-fluctuated multiscale feature learning with deep convnet for intelligent spindle bearing fault diagnosis. *IEEE Transactions on Instrumentation and Measurement*, 2017. 66(8): p. 1926-1935.
- [33] Lu, C., Z. Wang, and B. Zhou, Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification. *Advanced Engineering Informatics*, 2017. 32: p. 139-151.
- [34] Janssens, O., et al., Convolutional neural network based fault detection for rotating machinery. *Journal of Sound and Vibration*, 2016. 377: p. 331-345.
- [35] Wang, H., et al., A novel convolutional neural network based fault recognition method via image fusion of multi-vibration-signals. *Computers in Industry*, 2019. 105: p. 182-190.
- [36] Zhao, R., et al. Accelerating binarized convolutional neural networks with software-programmable fpgas. in *Proceedings of the 2017 ACM/SIGDA International Symposium on Field-Programmable Gate Arrays*. 2017.
- [37] Elmrabit, N., et al. Evaluation of machine learning algorithms for anomaly detection. in *2020 International Conference on Cyber Security and Protection of Digital Services (Cyber Security)*. 2020. IEEE.