





Derin Evrişimsel Sinir Ağ Mimarisi ve Zaman Frekans Gösterimini Kullanılarak Büyük Güçlü Motor Arızalarının Tespiti

Diagnosis of Large Power Motor Faults Using Deep Convolutional Neural Network Architecture and Time Frequency Representation

 İlhan AYDIN¹,  Emrullah AYDIN²,  Erhan AKIN¹,  Seyfullah KANER¹

¹Bilgisayar Mühendisliği Bölümü, Fırat Üniversitesi, Elazığ, Türkiye

²Elektrik-Elektronik Mühendisliği Bölümü, Malatya Turgut Özal Üniversitesi, Malatya, Türkiye

iyadin@firat.edu.tr, emrullah.aydin@ozal.edu.tr, eakin@firat.edu.tr, seyfullah.kaner49@gmail.com

Öz

Asenkron motorlar endüstride iş gücünün sağlanması açısından birçok uygulamada kullanılmaktadır. Asenkron motorlarda oluşan arızalar mil yatağı, stator ve rotor bileşenleri ile ilgilidir. Bu bileşenlerden mil yatağı arızaları en çok karşılaşılan problemlerden biridir. Bu arızaların tespiti için genellikle titreşim sinyalleri kullanılmaktadır. Endüstriyel ortamda çalışan motor ile aynı özelliklerde bir motor bulmak zor olduğundan karşılaştırma yapılarak arızaların tespiti yapılamamaktadır. Bu çalışmada titreşim sinyallerinin zaman frekans görüntüleri oluşabilecek mil yatağı arızaları için toplanarak transfer öğrenme tabanlı bir model ile eğitilmiştir. Daha sonra endüstriyel mil arızası olan bir motordan aynı şartlarda ve benzer bir konumda alınan sinyaller kullanılarak endüstrideki büyük güçlü motordaki arıza belirlenmiştir. Yapılan testler sonucunda endüstrideki motorda oluşan kusurların %96.05 doğruluk oranı ile tespit edildiği ispatlanmıştır.

Anahtar Kelimeler: Asenkron motor, mil yatağı arızaları, arıza tespiti, derin öğrenme, transfer öğrenme.

Abstract

Induction motors are used in many applications to provide a workforce in the industry. Faults in induction motors are related to bearing, stator, and rotor components. Among these components, bearing faults are one of the most common problems. Vibration signals are generally used to diagnose these faults. Since finding a motor with the same features as the motor operating in an industrial environment is difficult, faults cannot be detected by comparison. In this study, time-frequency images of vibration signals were collected for possible bearing failures and trained with a transfer learning-based model. Then, the fault in the large-power motor in the industry was determined using the signals received from a motor with industrial bearing fault under the same conditions and in a similar location. As a result of the tests, it has been proven that the faults in the induction motor are detected with a 96.05% accuracy rate.

Keywords: Induction motor, bearing faults, fault diagnosis, deep learning, transfer learning.

1. Giriş

Karmaşık endüstriyel sistemler birçok bileşene sahip olup bu sistemlerin güvenilirliği ve kesintisiz çalışması bu bileşenlerin durumuna bağlıdır. Asenkron motorlar endüstride en çok kullanılan motorlar olup bu bileşende oluşacak bir arıza tüm sistemin durmasına neden olur [1]. Asenkron motorlarda mil yatağı ile ilgili arızalar %40'lık bir paya sahip olup en çok karşılaşılan arıza türüdür [2]. Bu arızaların tespiti için genellikle akım ve titreşim sinyalleri

kullanılmaktadır. Özellikle mil yatağı arızalarının titreşim sinyalleri üzerinde oluşturduğu örüntüler bu arıza türünü belirlemek için önemli bilgiler içermektedir.

Son yıllarda sensör teknolojisindeki gelişmeler ile büyük miktarda veri toplanmakta ve elde edilen verilerin analizi evrişimsel sinir ağı yöntemleri için oldukça uygundur. Literatürde mil yatağı arızalarının tespiti için akım ve titreşim sinyallerini temelde kullanan yöntemler önerilmiştir. Hoang ve Kang [3] mil yatağında oluşan arızaları belirlemek için akım sinyallerini derin öğrenme teknikleri ile değerlendiren bir füzyon yaklaşımı önermiştir. Önerilen yaklaşım akım sinyallerini iki boyutlu bir görüntüye dönüştürerek evrişimsel sinir ağı modeline vermekte ve arıza türü belirlenmektedir. Asenkron motorlarda oluşan dış halka, iç halka, yanlış hizalama ve kırık rotor çubuğu gibi arızaların belirlenmesi için sürekli dalgacık analizi ve dikkat mekanizması kullanan bir evrişimsel sinir ağı modeli önerilmiştir [4]. Titreşim sinyallerinden elde edilen scalogram görüntüleri ile beş farklı durum yüksek doğrulukta tespit edilmektedir. Shao ve ark. [5] farklı motor arızalarını tespit etmek amacıyla VGG16 tabanlı derin transfer öğrenme yöntemini önermişlerdir. Geliştirilen sistemde motor arızalarını tespit etmek için titreşim sinyalleri zaman-frekans görüntüsüne dönüştürülmüştür. Asenkron motorlarda oluşan mil yatağı arızalarının tespiti için dalgacık analizi ve frekans spektrumundan elde edilen özellikler destek vektör makineler, rastgele orman ve XGBoost ile sınıflandırılmıştır [6]. Önerilen yöntemin temel katkısı daha az veri kullanılarak arızaların belirlenebilmesidir. Asenkron motor arızalarının gömülü bir nesnelerin interneti modülü ile bulut ortamında belirlenmesi için makine öğrenmesi tabanlı bir yaklaşım önerilmiştir [7]. Önerilen yaklaşımda gömülü kartta bulunan işlemci programlanarak arıza durumu belirlenmekte ve bulut ortamında motor durumu iletilmektedir. Motor mil yatağı arızalarının benzerlik tabanlı tespiti için hızlı Fourier dönüşümü, istatistiksel zaman analizi ve kısa süreli Fourier dönüşümü ile özellik çıkarımı yapılarak farklı benzerlik ölçüm yöntemleri ile arızalar teşhis edilmiştir [8]. Önerilen yöntem makine öğrenmesi yaklaşımlarına göre daha az veri kullanması nedeni ile endüstride kullanılabilir yapıdadır.

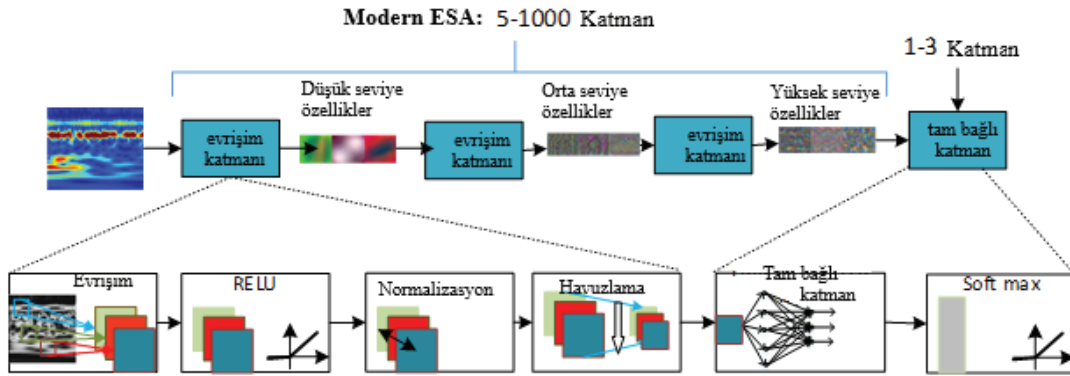
Literatürde mil yatağı arızalarının tespiti için birçok yöntem önerilmiş olmasına rağmen bu çalışmaların çoğu kıyaslama veri setleri üzerinde test edilmiştir. Bu amaçla Case Western Reserve University (CWRU) bearing dataset [9], the Paderborn University (PU) bearing dataset [10] ve the University of Ottawa (uOttawa) bearing dataset [11] gibi veri setleri kullanılmıştır. Fakat her bir veri ayrı ayrı değerlendirilmiş ve geliştirilen yöntemler farklı veriler üzerinde ayrıca test edilmiştir. Bu çalışmada literatürden farklı olarak kıyaslama veri seti için oluşturulan derin sinir ağı modeli farklı çalışma hızlarında çalışan büyük güçlü bir motordaki arızaları belirlemek için uygulanmıştır. Asenkron motorlarda en çok oluşan arıza tiplerinden biri olan mil yatağı arızalarının tespiti için transfer öğrenme algoritması ile birlikte derin evrişimsel sinir ağı modeli kullanılmıştır. Önerilen yöntem ilk olarak okunan ham titreşim sinyallerine dalgacık analizi uygulayarak zaman frekans dağılımını

elde etmekte ve bu dağılım görüntü olarak kaydedilmektedir. Bu amaçla GoogleNet mimarisi tabanlı transfer öğrenme yaklaşımı kullanılmıştır. Önerilen yöntem hem literatürde kullanılan kıyaslama veri kümeleri üzerinde test edilmiş hem de gerçek bir büyük güçlü endüstriyel motordan alınan veriler ile test edilmiştir. Elde edilen sonuçlar önerilen yöntemin arıza teşhisi konusunda oldukça başarılı olduğunu göstermektedir.

2. Evrişimsel Sinir Ağları ve Sınıflandırma


Derin sinir ağları yapay zeka alanının bir alt bölümü olup insanlar gibi hedeflere ulaşma yeteneğine sahip akıllı sistemler oluşturmak için kullanılan bir bilim dalıdır [12]. Evrişimsel sinir ağları görüntü işleme ile ilgili alanlarda oldukça fazla kullanılmıştır. Çok katmanlı

ağ mimarileri ile sınıflandırma, nesne tespiti ve bölütleme gibi birçok alanda uygulanmıştır. Bu ağ mimarisinde üst katmandaki özellikler alt katmandakilerine göre daha soyuttur. Alınan giriş görüntülerinden hiyerarşik özellikler otomatik olarak öğrenilir. Bu özellikler doğru şekilde sınıflandırma için oldukça önemlidir. Bu ağlarda her katmada giriş görüntüsünü ardışık olarak işleyip özellik haritası olarak isimlendirilen daha yüksek düzete bir soyutlama oluşturur. Modern evrişimsel sinir ağları çok derin bir katman yapısını kullanarak iyi bir performans elde edebilirler. Evrişimsel sinir ağları temelde üç tür katman içermektedir: evrişim katmanı, havuzlama ve tam bağlı katmandır. Evrişim ve havuzlama katmanları ardışık bir şekilde bağlanarak evrişim bloklarını oluştururlar. Tam bağlı katman ise genelde bir veya iki seviyeli olup sınıflandırma veya regresyon için kullanılmaktadır. Şekil 1’de evrişimsel sinir ağının yapısı verilmiştir.



Şekil 1: Evrişimsel Sinir Ağı Mimarisi

Şekil 1’de evrişimsel sinir ağında evrişim katmanlarından her biri yüksek boyutlu evrişim katmanlarından oluşmaktadır. Her bir katmanın giriş aktivasyonları, her biri kanal olarak isimlendirilen 2 boyutlu özellik haritası olarak ifade edilmektedir. Her kanal 2 boyutlu filtreler ile evrişim işlemine tabii tutulur. Evrişim sonuçları tüm kanallarda toplanır ve yeni özellik haritası oluşturulur. Şekil 2’de basit bir şekilde evrişim işlemi gösterilmiştir.



Şekil 2: Evrişimsel Sinir Ağında Konvülyasyon İşlemi

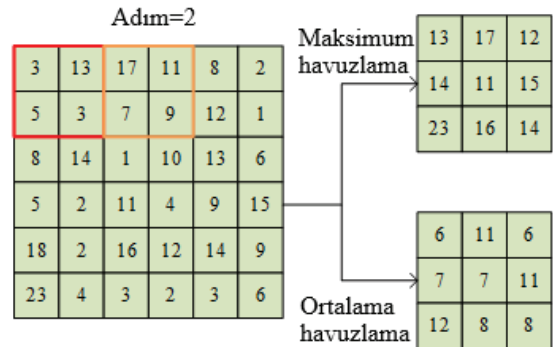
Şekil 2’de gösterildiği gibi bir görüntü için birden fazla kanal elde edilmekte ve her bir kanal için farklı filtreler kullanılarak yeni özellik haritası oluşturulmaktadır. Son yıllarda geliştirilen evrişimsel sinir ağlarında 5 evrişim katmanından 1000 evrişim katmanına kadar evrişim katmanı kullanılmıştır. Konvülyasyon işleminden sonra genellikle sınıflandırma problemleri için 1 ile 3 arasında tam bağlı katman kullanılır. Her bir kanala konvülyasyon işlemi uygulandıktan sonra doğrusal olmayan bir aktivasyon fonksiyonu uygulanır. Aktivasyon sonucu elde edilen değerler ölçeklenip normalleştirildiğinde öğrenme hızı artırılabilir. Bu amaçla batch normalizasyonu kullanılmaktadır. Bu normalizasyon yöntemi her katmanın diğer katmanlardan biraz bağımsız olarak kendi kendine öğrenbilmesine izin verir. Batch normalizasyonu her katmana iki tane eğitilebilir parametre olan ortalama (μ) ve standart sapma parametrelerini (σ) ekler. Böylece normalize edilen çıkış standart sapma ile çarpılır ve ortalama ile toplanır. Normalleştirilen değerler

ölçekleme ve kaydırma işlemine tabii tutulur. Denklem (1)’de bu normalleştirme verilmiştir

$$\hat{y}_i = \gamma \frac{x_i - \mu\beta}{\sqrt{\sigma^2 + \epsilon}} + \beta \quad (1)$$

Denklemde γ ve β parametreleri eğitimden öğrenilmekte ve ϵ parametresi ise sıfıra bölme hatasından kurtulmak için eklenen küçük bir değerdir.

Normalizasyon işleminden sonra evrişim ile elde edilen özellik haritasının uzaysal boyutunu düşürmek için havuzlama işlemi uygulanır. Bu işlem önceki katmanda üretilen özellik haritalarının yeniden alt örneklenmesidir. Konvülyasyon işlemi sonrası elde edilen her bir kanaldaki görüntü birkaç alt bölgeye ayrılır. Daha sonra havuzlama işlemi bu bölgeler üzerinde uygulanarak yeni değerler elde edilir. Genellikle maksimum veya ortalama havuzlama kullanılır. Şekil 3’te havuzlama işleminin bir görüntü üzerinde uygulaması verilmiştir.



Şekil 3: Maksimum ve ortalama havuzlama işlemi

Şekil 3’te adım (stride) boyutu 2 olarak alınmıştır. Havuzlama işlemi birbiri ile örtüşmeyen bloklar üzerinde gerçekleşir ve stride

boyutu havuzlama boyutunu da göstermektedir. Adım boyutu 2 ve üzeri seçildiğinde özellik haritasının boyutunda bir azalma olur. Derin evrişimsel sinir ağlarının oluşturulmasında temel yapıyı evrişimsel katmanlar ile havuzlama katmanı oluşturur. Düşük katmanlardaki evrişimsel katmanlar kenar ve eğri gibi özellikleri çıkarırken daha yüksek seviyedeki katmanlar daha soyut bilgileri çıkarmaktadır. Evrişimsel sinir ağlarında havuzlama, evrişim ve normalizasyon işlemleri ardışık olarak birkaç kez uygulandıktan sonra elde edilen özellikler tam bağlı katmana verilir. Tam bağlı katman girişlerini önceki katmandan alarak yüksek seviyeli muhakeme için faydalanılır. Literatürde son yıllarda önerilen evrişimsel sinir ağları genellikle farklı ağ mimarilerine sahiptir. Evrişimsel sinir ağlarında bu farklılığı sağlayan temel faktörler katman sayısı, filtre boyutu, filtre ve kanal sayısı ve katmanlar arasındaki bağlantılardır. İlk evrişimsel sinir ağlarından biri LeNet olup 1989'da dijital sınıflandırma için önerilmiştir. Bu ağın giriş görüntüleri 28x28 piksel boyutunda olup, ağ iki adet konvolüsyon ve iki tam bağlı katmandan oluşur. Her evrişim katmanında kanal başına 5x5'lik filtreler kullanılmıştır. 2x2 boyutunda ortalama havuzlama her evrişim katmanından sonra uygulanmış ve sigmoid aktivasyon fonksiyonu seçilmiştir.

Alexnet [13] 2012 yılında ImageNet yarışması için önerilmiş bir evrişimsel sinir ağı modelidir. Bu model 5 evrişim, 3 tam bağlı katman içermektedir. Her evrişim katmanında boyutları 3x3 ten 11x11 boyutunda filtreler uygulanmaktadır. Alexnet'te toplam 60 milyon parametrenin ayarlanması gerekir. Diğer bir popüler evrişimsel sinir ağı GoogLeNet [14] 22 katmana sahiptir. Bu ağ mimarisinde paralel bağlantılara sahip başlangıç modülü bulunmaktadır. Farklı boyutlarda filtreler (1x1, 3x3, 5x5) ve takip eden 3x3'lük havuzlama katmanı her bir paralel bağlantı için kullanılır ve çıkışları modül çıkışı için bağlanır. ResNet [15] daha derine inmek için artık bağlantılar kullanır ve toplamda 34 katmandan daha fazla katmana sahiptir. ImageNet veri setinde %5'in altında bir başarımla sağlamıştır. Farklı evrişimsel sinir ağlarının ImageNet üzerindeki başarımları ve kullanılan katman, filtre ve havuzlama parametreleri ile tam bağlı katman sayıları Tablo 1'de verilmiştir.


Tablo 1: Önerilen indüksiyon ısıtma sistemine ait indüksiyon sargısı ve çalışma parçasının boyutları

Metrik	AlexNet	GoogLeNet	ResNet50
İlk 5 hata	16.4	6.7	5.3
Giriş boyutu	227x227	224x224	224x224
Evrişim katman sayısı	5	57	53
Filtre boyutları	3, 5, 11	1,3,5,7	1,3,7
Kanal sayısı	3-256	3-832	3-2048

Tablo 1'de gösterildiği gibi her bir evrişimsel sinir ağı farklı boyutlarda ve sayıda evrişim katmanı, filtre ve tam bağlı katman kullanabilmektedir.

3. Mil Yatağı Arıza Teşhisi İçin Evrişimsel Sinir Ağı Topluluklarının Birleştirilmesi

Bu çalışmada asenkron motorlarda oluşan mil yatağı arızalarının tespit ve teşhisi için çoklu derin öğrenme yöntemlerinin birleştirilmesine dayalı bir teknik önerilmiştir. Önerilen yöntem ilk olarak titreşim sinyallerinin zaman frekans dağılımını elde etmektedir. Daha sonra bu dağılım görüntü olarak kaydedilmektedir. Her bir arıza durumu için elde edilen görüntüler derin evrişimsel sinir ağı modellerine verilerek arıza sınıfı belirlenmektedir. Son aşamada bu model çıktıları birleştirilerek arızalar belirlenmektedir. Şekil 4'te önerilen sistemin blok şeması verilmiştir.

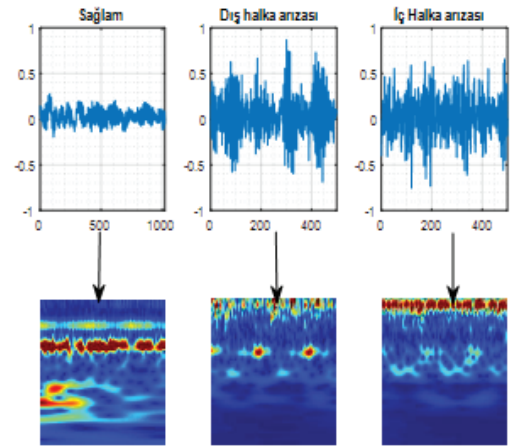


Şekil 4: Önerilen transfer öğrenme tabanlı yöntemin akış diyagramı

a. Zaman Frekans Görüntüsü

Motordan okunan titreşim sinyalleri zaman-frekans dağılım yöntemi ile görüntüye dönüştürülmüştür. Zaman frekans dağılımı zaman frekansında alınan zaman serisi sinyallerini zaman ve frekans bilgisi ile gösterilecek biçimde zaman frekans alanına dönüştürür [16]. Bu dağılım bir sinyalin farklı zamanlarda farklı frekans bileşenleri için izlemeye yardımcı olur. Zaman-frekans dağılımını elde etmek için kısa zamanlı Fourier dönüşümü, sürekli dalgacık analizi ve S- dönüşümü gibi teknikler kullanılabilir. Bu yöntemler içerisinde çoklu çözünürlüklerde sinyali en iyi şekilde modellemek için kullanılacak teknik sürekli dalgacık analizidir. Dalgacık türü olarak ölçekleme ve dönüşümü sağlayan mother dalgacığı kullanılır. Bu dönüşüm denklem (2)'de verilmiştir. Şekil 5'te, farklı durumlar için titreşim sinyalleri ve zaman frekans görüntüleri verilmiştir.

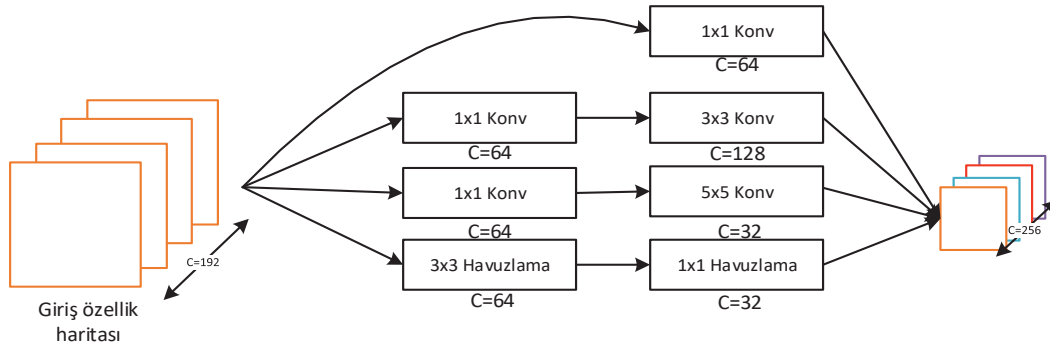
$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \Psi\left(\frac{t-b}{a}\right) \quad (2)$$



Şekil 5: Farklı durumlar için titreşim sinyalleri ve zaman frekans görüntüleri

b. Transfer Öğrenme


Modern evrişimsel sinir ağı modelleri çok büyük veri kümeleri üzerinde eğitilerek bir sonuç elde etmişlerdir. Bu modellerden en çok kullanılanı ImageNet olup veri kümesi 1000 sınıflı ve boyutu yaklaşık bir milyon örnekten oluşmaktadır. Fakat sınırlı bir veri kümesine sahip olduğunda bu evrişimsel sinir ağı modellerini eğitmek ve parametrelerini optimize etmek pek mümkün olmamaktadır. Bu yüzden sınırlı veri kümesi için transfer öğrenme yöntemi kullanılmaktadır. Bir evrişimsel sinir ağının daha düşük katmanları genel özellik çıkarımını sağlarken daha yüksek katmanlar orijinal sınıflandırma görevi için daha spesifik bilgi taşırlar. Bu özellik bir evrişimsel sinir ağındaki genelleştirilmiş özellik çıkarımının ve düşük katmanlardaki gösterimin yeniden kullanımını kolaylaştırırken daha yüksek katmanların orijinal problem ile ilgili özelliklere sahip ikincil problem alanına doğru ayarlanır. Böylece 1000 sınıflı bir sınıflandırma problemi için elde edilen parametreleri belirli bir problem için bir başlangıç noktası olarak seçebiliriz. Rastgele ağırlık başlatma özelliğine sahip bir



Şekil 6: GoogLeNet başlangıç modül

4. Deneysel Sonuçlar

Önerilen yöntemin doğruluğunu ispatlamak için iki farklı deney üzerinde uygulamalar yapılmıştır. İlk olarak Case Western Üniversitesi Rulman veri merkezinde farklı arıza türleri için alınan titreşim verileri ile bir derin öğrenme modeli oluşturulmuş ve mil yatağı arızaları ile ilgili farklı arıza türleri ve şiddetleri veri kümesinde kullanılmıştır. Titreşim verileri, manyetik tabanlar ile mahfazaya bağlanan ivmeölçerler kullanılarak toplanmıştır. İvmeölçerler, motor gövdesinin hem tahrik ucunda hem de fan ucunda saat 12 pozisyonuna yerleştirildi. Bazı deneyler sırasında, motor destek taban plakasına bir ivmeölçer takıldı. Titreşim sinyalleri 16 kanallı bir veri toplama kartı kullanılarak toplandı ve bir Matlab ortamında sonradan işlendi. Veriler 12 kHz örnekleme hızı ile alınmıştır. Hız ve beygir gücü verileri tork dönüştürücü kodlayıcı kullanılarak toplanmış ve elle kaydedilmiştir. Şekil 7'de deney düzeneği verileri gösterilmiştir.



Şekil 7: Titreşim sinyallerini toplamak için kullanılan deney düzeneği

evrişimsel sinir ağı tasarlamak yerine genelleştirilmiş nesne tanıma için önceden optimize edilmiş ve ön eğitimi yapılmış bir ağ modeli kullanılarak bu ağırlıklar belirli bir sınıflandırma alanına göre ince ayar ile düzenlenir. Bu çalışmada ön eğitilmiş ağ olarak GoogleNet seçilmiştir. Bu ağ yapısında toplamda 22 katman bulunup ilk versiyonu 2014'te önerilmiştir. Toplamda 22 katmanın 3 katmanı evrişim, 9 katmanı başlangıç katmanı olup her biri 2 evrişim katmanından oluşur. Ağ bir tane tam bağlı katmana sahiptir. Şekil 7'de GoogleNet evrişimsel sinir ağındaki başlangıç modülü gösterilmiştir.

Şekil 7'de Inception modüllerindeki genişleme etkisi evrişim katmanlarındaki 1×1 , 3×3 , 5×5 filtrelerin ve 3×3 maksimum ortalama işleminin paralel olarak gerçekleştirilmesiyle oluşturulmaktadır. Ancak burada önemli bir sorun vardır: İşlem karmaşıklığı, çıkış boyutunun büyüklüğü ve parametre sayısının paralel işlemler yüzünden çok büyümesidir. Bu problemin üstesinden 1×1 evrişim katmanları paralel Naif Inception evrişim katmanlarının öncesine eklenerek boyut azaltma işlemi gerçekleştirilmektedir.


Şekil 7'de gösterildiği gibi deney düzeneği 2 HP motor, tork dönüştürücü ve yüklemeye için bir dinamometre ile kontrol elektroniklerinden oluşmaktadır. Test yatakları motor şaftını desteklemektedir. Test rulmanlarına 7, 14 ve 21 mil (1 mil=0.001 inç) arıza çaplarına sahip elektro deşarj yöntemi ile arızalar oluşturulmuştur. Motor 1720-1797 rpm hızlarında çalıştırılmıştır. Tablo 2'de oluşturulan arıza bilgileri verilmiştir.

Tablo 2: Mil yatağı arıza türleri

Arıza Yeri	Arıza çapı(mils)	Veri boyutu	Motor Yüğü
İç Halka	7	1024	0, 1, 2, 3 HP
	14	1024	
	21	1024	
Dış Halka	7	1024	
	14	1024	
	21	1024	
Bilye arızası	7	1024	
	14	1024	
	21	1024	
Sağlam durum	-	1024	1,3,7

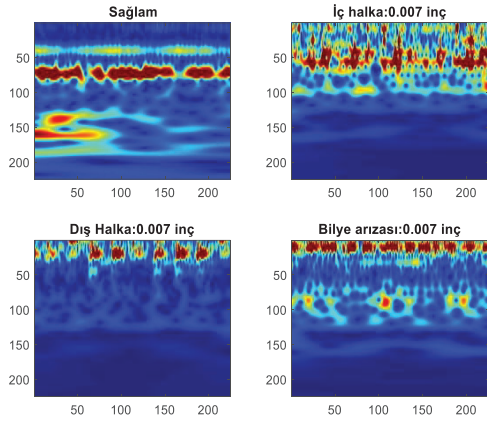
Tablo 2'de gösterildiği gibi her bir arıza durumu için üç arıza şiddeti bulunmaktadır. Ayrıca sağlam durum için de üç farklı yük durumu göz önüne alınmıştır. Dolayısıyla toplam 10 sınıflı bir veri

kümesi oluşturulmuştur. Şekil 8’de farklı arıza türleri ve sağlam durum için titreşim sinyalleri verilmiştir.



Şekil 8: Sağlam durum ve farklı arıza türleri için motor titreşim sinyalleri

Şekil 8’de gösterildiği gibi özellikle sağlam durum ile bilye arızaları birbirine oldukça benzemektedir. Titreşim sinyalleri elde edildikten sonra sürekli dalgacık analizi ile zaman frekans dağılımı elde edilmektedir. Şekil 9’da farklı arıza türleri ve sağlam durum için zaman-frekans görüntüleri verilmiştir.



Şekil 9: Sağlam durum ve farklı arıza durumları için zaman-frekans görüntüleri


Şekil 9’da gösterildiği gibi farklı arıza durumları için motor zaman-frekans dağılımları farklı çıkmaktadır. Sağlam durumda 100-50 Hz arasında bir değişim olurken, iç halka arızasında 100-0 Hz arasında, dış halka arızasında 50-0 Hz arasında ve bilye arızasında 25-0 arasında bir belirginlik oluşmaktadır. Bu amaçla zaman serisi 1024’lük parçalara bölünmektedir. Her bir parça arasındaki örtüşme sıfır olarak seçilmiştir. Bu bilgi arıza tespiti için kullanılabilir. Elde edilen zaman-frekans görüntüleri 5.808 görüntüden oluşmaktadır. Görüntü boyutları 224x224 pikselden oluşmaktadır. Oluşturulan GoogleNet modelinin parametreleri Tablo 3’te verilmiştir

Tablo 3: Kullanılan GoogleNet modelinin parametreleri

Özellik	Değer
Eğitim kümesi örnek sayısı	4066
Doğrulama örnek sayısı	1742
Mini yığın boyutu	32
Maksimum adım sayısı	7
Başlangıç öğrenme oranı	1e-4

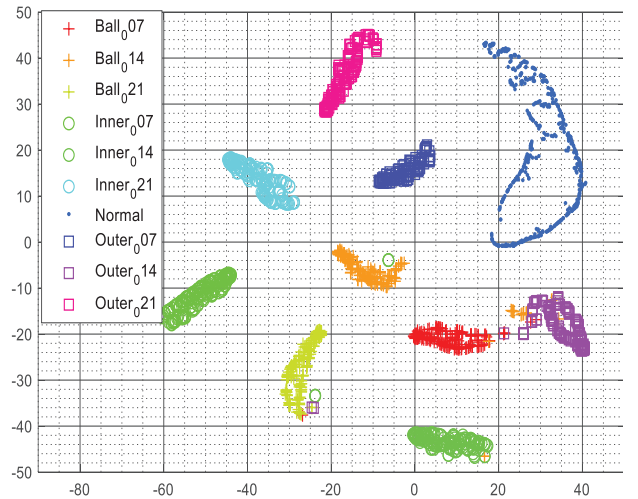
Doğrulama frekansı	50
--------------------	----

Derin evrişimsel sinir ağı için parametre ayarları yapıldıktan sonra GoogleNet ağı eğitilmiştir. Verilen adım sayısı boyunca eğitim, doğrulama veri setinin doğruluğu ve kayıp parametresinin eğitim ve doğrulama için değişimi Şekil 10’da verilmiştir.



Şekil 10: GoogleNet modelinin eğitim, doğrulama başarımı ve kayıp fonksiyonunun değişimi

Şekil 10’da görüldüğü gibi hem eğitim hem de doğrulama başarımı 700 adım sonrasında maksimum değer olan %98.9’a ulaşmaktadır. Ayrıca derin öğrenme ile görüntülerden çıkarılan özelliklerin her bir katmanda gösterimi yapılabilmektedir. Şekil 11’de, ince ayarlanmış GoogleNet’ten çıkarılan dahili özellik uzayının özellik haritalarının t-SNE (dağıtık stokastik komşuluk gömülmesi) görselleştirmesini göstermektedir.



Şekil 11: Farklı arıza türleri için GoogleNet’in son katmanının t-SNE görselleştirmesi


Şekil 11’de gösterildiği gibi doğrulama verilerininin GoogleNet’in son katmanında bir birinden doğru bir şekilde ayırt edilebildiği görülmektedir. Şekil 11’de Inner Race (iç halka), Outer race (Dış halka) ve Ball (Bilye) arızaları ile sağlam durum (normal) t-SNE gösterimleri verilmiştir. Arızalar 0.007, 0.014 ve 0.021 inç hata çaplarına sahip elektro-erozyon işleme kullanılarak test rulmanlarına tek nokta hataları uygulanarak elde edilmiştir. Sadece bazı arızalar

örneklerin diğer arıza sınıfları ile karıştığı görülmektedir. Sınıflandırma başarımını ölçmek için karmaşıklık kullanılmıştır. Şekil 12'de doğrulama verileri için karmaşıklık matrisi gösterilmiştir.

		Karmaşıklık Matrisi											
Tahmin Edilen Sınıf	Bilye_007	142 8.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	2 0.1%	0 0.0%	98.6% 1.4%	
	Bilye_014	0 0.0%	142 8.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.1%	0 0.0%	99.3% 0.7%	
	Bilye_021	0 0.0%	0 0.0%	140 8.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	İçhalka_007	0 0.0%	0 0.0%	0 0.0%	143 8.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	İçhalka_014	0 0.0%	0 0.0%	1 0.1%	0 0.0%	142 8.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	99.3% 0.7%	
	İçhalka_021	0 0.0%	0 0.0%	0 0.0%	0 0.0%	142 8.2%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	Normal	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	497 28.5%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	Dışhalka_007	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	107 6.1%	0 0.0%	0 0.0%	0 0.0%	100% 0.0%	
	Dışhalka_014	0 0.0%	0 0.0%	1 0.1%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	139 8.0%	0 0.0%	0 0.0%	99.3% 0.7%	
	Dışhalka_021	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	143 8.2%	0 0.0%	100% 0.0%	
		100% 0.0%	100% 0.0%	98.6% 1.4%	100% 0.0%	100% 0.0%	100% 0.0%	100% 0.0%	97.9% 2.1%	100% 0.0%	99.7% 0.3%		
		Bilye_007	Bilye_014	Bilye_021	İçhalka_007	İçhalka_014	İçhalka_021	Normal	Dışhalka_007	Dışhalka_014	Dışhalka_021		
		Gerçek Sınıf											

Şekil 12: Mil yatağı arızası için elde edilen karmaşıklık matrisi

Şekil 12'de 10 sınıf için hatalı sınıflandırma oranının oldukça düşük olduğu görülmektedir. Toplamda 4 adet test verisi yanlış sınıflandırılmıştır. Sınıflandırma başarımı %99.7 olarak elde edilmiştir. Bir önceki aşamada 9 farklı arıza durumu ve sağlam durum için elde edilen model kullanılarak gerçek bir tren motorundan alınan titreşim sinyalleri ile test edilmiştir. Bu amaçla motorun dört farklı noktasına titreşim sensörleri yerleştirilmiştir. Bu titreşim sensörleri ile saniyede 12.000 örnek örnekleme oranı ile veriler üç eksende toplanmıştır. Şekil 13'te kullanılan motorun üzerine sensörlerin yerleşimi gösterilmiştir.



Şekil 4: Tren motoruna sensörlerin yerleşimi


Şekil 13'te gösterildiği gibi farklı noktalara titreşim sensörleri yerleştirilerek veriler alınmıştır. Deneysel sonuçlardan eğitim için kullanılan veri setinde sürücü sonuna ve fan sonuna titreşim sensörü eklenerek veriler alınmıştır. Eğitim aşamasında fan sonuna eklenen sensörden gelen titreşim sinyalleri kullanılarak model eğitimi yapılmıştır. Motora 4 farklı sensör yerleştirilmesine rağmen model motorda alınan sinyallere benzer şekilde aynı sürücü tarafına yerleştirilmiş olan 73 nolu sensörün x ekseninden gelen titreşim sinyalleri kullanılmıştır. Motorun milinde arıza olduğu bilinmekte fakat

arızanın ne olduğu ile ilgili herhangi bir bilgi bulunmamaktadır. Veriler farklı çalışma hızları ve yük altında alınmıştır. Verilerin alınma biçimleri Tablo 4'te verilmiştir.


Tablo 4: Tren motoru için alınan verilerin özellikleri

Verinin Alındığı Hız	Yük Durumu
50 RPM	Boşta 150Nm
250 RPM	Boşta 150Nm
500 RPM	Boşta 150Nm
1000 RPM	Boşta 150Nm
2000 RPM	Boşta 150Nm

Fakat burada sınıf sayısı önceki modeldeki gibi 10 olarak alınmamıştır. Sadece arızanın türü belirlenmektedir. Çünkü gerçek bir motor olduğu için arızanın şiddeti ve mil yatağında ne kadarlık bir arızanın olduğu bilgisi elimizde yoktur. Dolayısıyla sağlam, iç halka, dış halka ve bilye arızası olmak üzere toplamda 4 sınıf göz önüne alınmıştır. Şekil 14'te 50 RPM'de çalışan motor için boşta çalışma durumunda titreşim sinyali ve zaman frekans görüntüsü verilmiştir.




(a) Titreşim sinyali




(b) Zaman Frekans dağılım görüntüsü

Şekil 14: Tren motorundan alınan titreşim sinyali ve zaman-frekans görüntüsü

Şekil 14'ten de görüldüğü gibi titreşim sinyali ve elde edilen zaman frekans görüntüsü 0.007 inç iç halka arızasına oldukça benzemektedir. Her bir çalışma hızı ve yük durumu için testler yapılmıştır. Önerilen yöntemin görsel olarak test edilmesi amacıyla hem model veriler hem de gerçek verilerin test edilebileceği bir arayüz hazırlanmıştır. Bu arayüz içerisinde eğitilmiş derin öğrenme modeli kullanılmaktadır. Derin öğrenme ağ yapısı 10 sınıf için Case Western üniversitesi Bearing Data Center'dan alınan veriler ile eğitilmiştir. Şekil 15'da eğitilen model ile ara yüzde elde edilen sonuçlar verilmiştir.



(a) Referans model sağlam durum



(a) Gerçek motor 250 RPM boşta çalıştırma

Şekil 5: Farklı arıza türleri için model üzerinde sonuçların gösterimi a) sağlam, b) iç halka arızası

Şekil 16'da toplam 10 sınıftan oluşan veri kümesi kullanılarak farklı arıza türleri için elde edilen sonuçlar gösterilmiştir. Her bir durum için 4 farklı yük durumu mevcuttur. Pencere boyutu 1024 olarak alınmış ve örtüşme sıfır olarak seçilmiştir. Veri başlangıcı ve segment sayısı(okunacak pencere sayısı) kullanıcı tarafından belirlenmektedir. Buna göre sistem performansı elde edilmektedir.

Eğitim aşamasında elde edilen model büyük güçlü motorda toplanan ve arızalı olduğu bilinen motordan elde edilen titreşim verileri ile test edilmiştir. Büyük güçlü motor verilerinde yüklü ve yüksüz durumlar mevcuttur. Bu yük durumları için 6 farklı hızda veriler okunmuştur. Tablo 5'te yapılan test sonuçları verilmiştir.

Tablo 5: Ölçümlerden elde edilen test sonuçları

Veri Seti	Yük durumu	Bilye			İç Halka			Sağlam	Dış Halka			Tespit edilen arıza	Doğruluk oranı (%)
		1	2	3	1	2	3		0	1	2		
50 RPM	Boşta	0	6	4	66	5	370	1	0	0	0	İç Halka	96.46
	150 Nm	0	2	3	36	0	254	0	0	0	0	İç Halka	98.31
250 RPM	Boşta	1	1	3	53	5	248	0	0	0	0	İç Halka	96.78
	150 Nm	0	1	9	32	2	249	0	0	0	0	İç Halka	95.90
500 RPM	Boşta	1	0	13	4	1	273	0	0	0	0	İç halka	94.86
	150 Nm	1	2	11	4	1	275	0	0	0	0	İç Halka	94.90
	Boşta	3	1	17	127	0	141	0	0	0	0	İç Halka	92.66

1000 RPM	150 Nm	1	1	27	135	2	143	0	0	0	0	İç Halka	89.97
2000 RPM	Boşta	0	2	4	17	1	275	0	0	0	0	İç Halka	97.66
	150 Nm	0	1	3	20	1	267	0	0	0	0	İç Halka	98.29
2700 RPM	Boşta	0	1	3	32	0	256	0	0	0	0	İç Halka	98.63
	150 Nm	0	1	3	52	1	235	0	0	0	0	İç halka	98.29

Tablo 5'te gösterildiği gibi toplam 10 sınıflı bir model ile elde edilen veriler test edilmiştir. Tablo 5'teki 1, 2 ve 3 değerleri sırasıyla her bir durum için 0.007, 0.014, 0.021 inç arıza şiddetlerini göstermektedir. Sağlam durum sıfır etiketi ile gösterilmiştir. Tablo 5'te görüldüğü gibi bütün durumlarda iç halka arızası olduğu tespit edilmiştir. Örneğin ilk satırda 370 tane örnek 0.021 inçlik iç halka arızası olarak sınıflandırılmış ve 66 tanesi 0.007 inç iç halka arızası olarak tespit edilmiştir.

5. Sonuç

Bu çalışmada iki farklı boyuttaki asenkron motorda oluşan kusurların tespiti ve birbiri ile olan ilişkisi için derin öğrenme tabanlı bir yaklaşım önerilmiştir. Küçük güçlü motor için öğrenilen model transferi büyük güçlü motorda kullanılarak arıza türü belirlenmeye çalışılmıştır. İki motor türü için verilerin doğru alınabilmesi için örneklem oranı ve sensör yerleşiminin benzer olmasına dikkat edilmiştir. Böylece arızaların aynı titreşim noktası üzerindeki etkileri incelenmiştir. Önerilen yaklaşımda Case Western Üniversitesindeki motordan alınan sinyaller 10 farklı arıza türü için derin öğrenme ağı ile eğitilmiştir. Daha sonra mil yatağında problem olduğu bilinen büyük güçlü motordan aynı koşullarda veriler alınmış ve farklı yük ve hızlarda titreşim sinyalleri aynı örnekleme oranı ile toplanmıştır. Testler sonucunda büyük güçlü motorda da iç halka arızası olduğu %96,05'lik bir doğruluk ile belirlenmiştir. Dolayısıyla bir model transferi yapılarak farklı tipte motorlara uygulanabilirlik sağlanmıştır.

Teşekkür

Bu çalışma Türkiye Bilimsel Ve Teknolojik Araştırma Kurumu (TUBITAK) tarafından 122E412 nolu proje ile desteklenmiştir.

Kaynakça

- [1] G. Niu, X. Dong, Y. Chen, "Motor Fault Diagnostics Based on Current Signatures: A Review", *IEEE Transactions on Instrumentation and Measurement*, 72, 1-9, 2023.
- [2] S. Zhang, S. Zhang, B. Wang, T. G. Habetler, "Deep learning algorithms for bearing fault diagnostics—A comprehensive review", *IEEE Access*, 8, 29857-29881, 2020.
- [3] D.T. Hoang, H. J. Kang, "A motor current signal-based bearing fault diagnosis using deep learning and information fusion", *IEEE Transactions on Instrumentation and Measurement*, 69 (6), 3325-3333, 2019
- [4] M. Q. Tran, M. K. Liu, Q.V. Tran, T. K. Nguyen, "Effective fault diagnosis based on wavelet and convolutional attention neural network for induction motors", *IEEE Transactions on Instrumentation and Measurement*, 71, 1-13, 2020.
- [5] S. Shao, S. McAleer, R. Yan, P. Baldi, "Highly accurate machine fault diagnosis using deep transfer learning", *IEEE Transactions on Industrial Informatics*, 15(4), 2446-2455, 2018.
- [6] S. A., Aburakhia, R. Myers, A. Shami, "A hybrid method for condition monitoring and fault diagnosis of rolling bearings with low system delay", *IEEE Transactions on Instrumentation and Measurement*, 71, 1-13, 2022.
- [7] A. Bapir, I. Aydin, "Cloud based bearing fault diagnosis of induction motors", *Computer Science*, (Special), 141-146, 2021.
- [8] S. Aburakhia, T. Tayeh, R. Myers, A. Shami, "Similarity-Based Predictive Maintenance Framework for Rotating Machinery", In: *2022 IEEE 5th International Conference on Communications, Signal Processing, and their Applications (ICCSPA)*, 1-6, 2022.
- [9] CWRU, Case Western Reserve University Bearing Data Center Website, Cleveland, OH, USA. Available online: <https://engineering.case.edu/bearingdatacenter>
- [10] C. Lessmeier, J. K. Kimotho, D. Zimmer, W. Sextro, "Condition Monitoring of Bearing Damage in Electromechanical Drive Systems by Using Motor Current Signals of Electric Motors: A Benchmark Data Set for Data-Driven Classification", *European Conference of the Prognostics and Health Management Society, Bilbao (Spain)*, 1-17, 2016.
- [11] M. Sehri, P. Dumond, M. Bouchard, "University of Ottawa constant load and speed rolling-element bearing vibration and acoustic fault signature datasets", *Data in Brief*, 49, 1-10, 2023.
- [12] S. Dong, P. Wang, K. Abbas, "A survey on deep learning and its applications", *Computer Science Review*, 40, 1-22, 2021.
- [13] A. Krizhevsky, I. Sutskever, G. E. Hinton, "Imagenet classification with deep convolutional neural networks", *Advances in Neural Information Processing Systems* 25(2), 84-90, 2012.
- [14] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, A. Rabinovich, "Going deeper with convolutions", In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1-9, 2015.
- [15] K. He, X. Zhang, S. Ren, J. Sun, "Deep residual learning for image recognition", In: *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778, 2016.
- [16] S.G.A. Mallat, "Wavelet Tour of Signal Processing: The Sparse Way", 3rd ed. Amsterdam, Boston: Elsevier/Academic Press, 2009.

Özgeçmişler



İlhan Aydın, 1981 yılında Elâzığ'da doğdu. Lisans ve Yüksek Lisans derecelerini Fırat Üniversitesi Bilgisayar Mühendisliğinde 2001 ve 2006 yıllarında aldı. Doktora derecesini 2011 yılında Fırat Üniversitesi, Elektrik ve Elektronik Mühendisliği bölümünden aldı. Halen Fırat Üniversitesi'nde Bilgisayar Mühendisliği bölümünde Profesör Doktor olarak görev yapmaktadır. Araştırma alanları arasında optimizasyon, gerçek zamanlı sistemler, hata teşhisi ve durum izleme, sinyal ve görüntü işleme ve derin öğrenme bulunmaktadır.



Emrullah Aydın, 1986 yılında Elazığ'da doğdu. Lisans eğitimini 2009 yılında Fırat Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nde tamamladı. 2014 ve 2020 yıllarında Gazi Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü'nde sırasıyla Yüksek Lisans ve Doktora eğitimlerini tamamlamıştır. Doktora eğitimini tamamladıktan sonra Malatya Turgut Özal Üniversitesi Elektrik-Elektronik Mühendisliği Bölümü'nde Dr. Öğretim Üyesi olarak çalışmaya başlamış ve halen burada çalışmaya devam etmektedir. İlgili çalıştığı araştırma alanları arasında Kablosuz Güç Aktarımı, Elektrik Makinaları, Güç Elektroniği ve İndüksiyon Isıtma Sistemleri yer almaktadır.



Erhan Akin, lisans derecesini Elazığ Fırat Üniversitesi'nden elektrik mühendisliği bölümünden 1984 yılında, yüksek lisans derecesini Elazığ Fırat Üniversitesi'nden bilgisayar mühendisliği bölümünden 1987 yılında ve doktora derecesini 1994 yılında Fırat Üniversitesi elektrik mühendisliği alanından almıştır. Halen Fırat Üniversitesi Bilgisayar Mühendisliği Bölümü'nde Profesör Doktordur. Fırat Üniversitesi Bilgisayar Mühendisliği bölüm başkanıdır. Araştırma ilgi alanları arasında yumuşak bilgi işlem, elektrik motoru sürücüleri, bulanık kümeler ve sistemler, doğrusal olmayan kontrol sistemleri, hata teşhisi ve bilgisayar görüşü yer almaktadır.



Seyfullah Kaner, 1992 yılında Muş'ta doğdu. Lisans Eğitimini 2015 yılında Yalova Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümünde tamamladı. Yüksek Lisans Eğitimini 2021 yılında Fırat Üniversitesi Bilgisayar Mühendisliği Bölümünde tamamladı. Halen Muş Alparslan Üniversitesinde Öğretim Görevlisi olarak çalışmaktadır. Araştırma ilgi alanları Derin öğrenme, görüntü işleme, arıza teşhisi ve rastgele sayı üreteçleri üzerinedir.