



T.C.  
OSMANIYE KORKUT ATA  NİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**Hakan DEMİRKIRAN**

**BORU HATTI SİSTEMİNDE  ALIŐAN POMPA  
TİTREŐİMİNİN YAPAY SİNİR AĐI METODU  
İLE MODELLENEREK  NG R LEN  
TİTREŐİM DEĐERLERİ  ZERİNDEN ARIZA  
TESPİTİ**

**MAKİNE M HENDİSLİĐİ ANABİLİM DALI**

**OSMANIYE – 2019**

**T.C.  
OSMANIYE KORKUT ATA ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
YÜKSEK LİSANS TEZİ**

**BORU HATTI SİSTEMİNDE ÇALIŞAN POMPA  
TİTREŞİMİNİN YAPAY SINIR AĞI METODU İLE  
MODELLENEREK ÖNGÖRÜLEN TİTREŞİM  
DEĞERLERİ ÜZERİNDEN ARIZA TESPİTİ**

**Hakan DEMİRKİRAN**

**MAKİNE MÜHENDİSLİĞİ  
ANABİLİM DALI**

**OSMANIYE  
HAZİRAN-2019**

## TEZ ONAYI

BORU HATTI SİSTEMİNDE ÇALIŞAN POMPA TİTREŞİMİNİN YAPAY SİNİR AĞI METODU İLE MODELLENEREK ÖNGÖRÜLEN TİTREŞİM DEĞERLERİ ÜZERİNDEN ARIZA TESPİTİ

Hakan DEMİRKIRAN tarafından Dr. Öğr. Üy. Kerimcan ÇELEBİ danışmanlığında Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü **Makine Mühendisliği** Anabilim Dalı'nda hazırlanan bu çalışma aşağıda imzaları bulunan jüri üyeleri tarafından oy birliği/çokluğu ile **Yüksek Lisans Tezi** olarak kabul edilmiştir.

**Danışman:** Dr. Öğr. Üy. Kerimcan ÇELEBİ .....  
Makine Mühendisliği Anabilim Dalı, OKÜ

**Üye:** Prof. Dr. Mehmet BİLGİLİ .....  
Makine Mühendisliği Anabilim Dalı, ÇÜ

**Üye:** Doç. Dr. Ertuğrul CİHAN .....  
Makine Mühendisliği Anabilim Dalı, OKÜ

Yukarıdaki jüri kararı Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun ...../...../..... tarih ve ..... /..... sayılı kararı ile onaylanmıştır.

Doç. Dr. Coşkun ÖZALP .....  
Enstitü Müdürü, **Fen Bilimleri Enstitüsü**

*Bu tezde kullanılan özgün bilgiler, şekil, çizelge ve fotoğraflardan kaynak göstermeden alıntı yapmak 5846 sayılı Fikir ve Sanat Eserleri Kanunu hükümlerine tabidir.*

## TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, bu çalışma sonucunda elde edilmeyen her türlü bilgi ve ifade için ilgili kaynağa eksiksiz atıf yapıldığını ve bu tezin Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Hakan DEMİRKIRAN



## ÖZET

### BORU HATTI SİSTEMİNDE ÇALIŞAN POMPA TİTREŞİMİNİN YAPAY SINIR AĞI METODU İLE MODELLENEREK ÖNGÖRÜLEN TİTREŞİM DEĞERLERİ ÜZERİNDEN ARIZA TESPİTİ

Hakan DEMİRKIRAN  
Yüksek Lisans, Makine Mühendisliği Anabilim Dalı  
Danışman: Dr. Öğr. Üy. Kerimcan ÇELEBİ

Haziran 2019, 71 sayfa

Bu çalışmada, gerçek bir boru hattı sisteminde farklı lokasyonlardaki pompa istasyonlarında bulunan eşdeğer santrifüj pompaların çalışma verileri ile titreşim değerini tahmin edecek bir yapay sinir ağı oluşturulmuştur. Bunun için deney düzeneği olarak ele alınan gerçek sistemde çalışan pompaların işletilmesini sağlayan SCADA sisteminde saat başı otomatik olarak kayıt altına alınan 18 farklı veri toplanarak bu verilerden hedef çıktı olan titreşim ile bağıntısı en yüksek olan 7'si yapay sinir ağı eğitiminde kullanılmıştır. Eğitim için yapay sinir ağına sunulan veri sayısının YSA başarısına etkisini incelemek adına 7 verinin her birinden, kullanılan veriler bir diğer matriste tekrar kullanılmayacak şekilde 250, 500 ve 1000'er veriden oluşan matrisler oluşturulmuştur. En uygun sinir ağı modeli belirlenerek, titreşim ortalama % 4,95 hata oranı ile tespit edilmiş ve bu değer ile gerçek değer karşılaştırılmak suretiyle, iki değer arasındaki sapmanın muhtemel bir arızanın erken tespitinde kullanılabileceği gösterilmiştir.

**Anahtar Kelimeler:** Yapay Sinir Ağı, Durum İzleme, Bakım Teknikleri, Kestirimci Bakım

## ABSTRACT

### MODELLING THE VIBRATION OF A PUMP WORKING ON A PIPELINE SYSTEM WITH ARTIFICIAL NEURAL NETWORK AND FAULT DETECTION BY USING PREDICTED VIBRATION VALUE

Hakan DEMİRKIRAN  
M.Sc., Department of Mechanical Engineering  
Supervisor: Dr. Öğr. Üy. Kerimcan ÇELEBİ

June 2019, 71 pages

In this study, an artificial neural network is modelled for estimating the vibration of pump with the working data of equivalent centrifugal pumps running at different locations of a pipeline system. For this purpose, hourly collected 18 different working data of a pumps running on a real pipeline system which is controlled by SCADA system, which is handled as an experimental setup, are collected. 7 of these working data, which have a higher correlation with target output vibration, are used for training of artificial neural network. In order to observe the effect of the number of data given to ANN for training, data matrixes of 250, 500 and 1000 from each value of 7 data are created by taking into consideration that not to use same data in each matrix. The best neural network model is determined for these pumps and vibration is estimated with % 4,95 MAPE value. It is shown that the deviation between the actual vibration and estimated vibration can be used for early fault detection.

**Key Words:** Artificial neural network, Condition Monitoring, Maintenance Techniques, Predictive Maintenance



Çok kıymetli aileme...

## TEŐEKKÜR

Yüksek Lisans tez konumun belirlenerek tez çalışmamın yürütülmesini üstlenen, çalışmalarım süresince değerli bilgi ve tecrübeleriyle katkılarını esirgemeyen ve her zaman beni motive ederek çalışmamın tamamlanmasına büyük katkı sağlayan danışman hocam Sayın Dr. Öğr. Üy. Kerimcan ÇELEBİ'ye teşekkürlerimi sunarım.

Ayrıca bölümdeki çalışmalarım süresince beni destekleyen diğer bölüm hocalarıma, her zaman kendimi geliştirmem yönünde bana örnek ve destek olan çalışma arkadaşım ve abim Onur ALTUNTAŐ'a, tezime başladığımda beraber mühendis ünvanı ile çalışmaktayken şuan yöneticim konumundaki birlikte çalışmaktan ve arkadaş olmaktan gurur duyduğum Arif ATAMAN'a, son olarak en önemli destekçim olan ve ben bu çalışmayı yoğun çalışma hayatı ile birlikte sürdürürken iki çocuğumuza benim payıma düşen ilgi ve alakayı da göstererek çalışmamın tamamlanmasında en büyük paya sahip eşim, hayat arkadaşım, meslektaşım Münire ÖZTÜRK DEMİRKIRAN'a gönülden teşekkür ederim.



## İÇİNDEKİLER

TEZ ONAYI	
TEZ BİLDİRİMİ	
ÖZET.....	i
ABSTRACT .....	ii
TEŞEKKÜR.....	iv
İÇİNDEKİLER .....	v
ÇİZELGELER DİZİNİ .....	vii
ŞEKİLLER DİZİNİ.....	viii
SİMGELER VE KISALTMALAR.....	x
1. GİRİŞ.....	1
2. ÖNCEKİ ÇALIŞMALAR .....	4
3. BAKIM YÖNTEMLERİ .....	11
3.1. Arıza Sonrası Bakım (Run to failure) .....	13
3.2. Periyodik (Önleyici) Bakım.....	14
3.3. Kestirimci Bakım .....	15
4. MALZEME VE YÖNTEM .....	18
4.1. Yapay Sinir Ağları .....	18
4.2. Yapay Sinir Ağlarının Matematiksel İfadesi.....	22
4.3. Geri Yayılım (Backpropagation) Algoritması Matematiksel İfadesi .....	24
4.4. Yapay Sinir Ağı Eğitim Algoritmaları .....	31
4.4.1. Levenberg-Marquardt .....	32
4.4.2. Resilient Backpropagation .....	33
4.4.3. Scaled Conjugate Gradient.....	33
4.5. Ham Petrol Boru Hattı Sistemi .....	33
4.6. Verilerin Ölçümünde Kullanılan Enstrümanlar .....	38
4.6.1. Termo Elemanlar (Termokupl) .....	39
4.6.2. Basınç Sensörü .....	40
4.6.3. Titreşim Sensörü .....	41
4.6.4. Devir Sensörü.....	42
4.6.5. Çalışmada kullanılan veriler.....	43
4.7. Matlab ve Yapay Sinir Ağı Modeli .....	46
4.7.1. Matlab .....	46
4.7.2. Matlab Yapay Sinir Ağı Araç Kutusu (Neural Network Toolbox) .....	47
4.8. Oluşturulan Yapay Sinir Ağı Modeli .....	49

5. BULGULAR ve TARTIŞMA .....	51
6. SONUÇLAR VE ÖNERİLER.....	62
7. KAYNAKLAR .....	64
ÖZGEÇMİŞ .....	71



## ÇİZELGELER DİZİNİ

Çizelge 4.1. Pompa üzerinden SCADA sistemi tarafından izlenen veriler ve bu verilerin istatistiksel değerleri.....	37
Çizelge 4.2. Yapay sinir ağına girdi olarak kullanılacak verilerin tespiti için parametrelerin titreşim ile korelasyonları.....	44
Çizelge 4.3. ISO 10816 Standardına göre makine titreşimi limit değerleri tablosu	45
Çizelge 4.4. En uygun YSA modelinin tespiti için oluşturulması planlanan YSA'lar .....	50
Çizelge 5.1. Farklı YSA modellerinin test performans (RMSE) değerleri .....	57
Çizelge 5.2. 500 veri ile çalışılan YSA performanslarının 250 veri ile çalışılan YSA'lar ile karşılaştırması.....	58
Çizelge 5.3. Scg714tansig modeli ile yapılan ilave çalışmalar ve performans sonuçları .....	58
Çizelge 5.4. En iyi YSA modeli performans .....	59

## ŞEKİLLER DİZİNİ

Şekil 1.1. Tasarımdan arızaya giden süreçte bakım stratejileri ve onarım maliyeti ....	2
Şekil 3.1. Sektörlere göre plansız duruş maliyetleri .....	11
Şekil 3.2. Sektörel bazlı yıllık beklenmedik duruş günleri .....	12
Şekil 3.3. Arıza sonrası bakım stratejisi maliyet-zaman grafiği .....	13
Şekil 3.4. Periyodik (Önleyici) bakım stratejisi maliyet-zaman .....	14
Şekil 3.5. Kestirimci bakım stratejisi maliyet-zaman grafiği.....	15
Şekil 3.6. Kestirimci bakım stratejisinde takip edilen parametreler ve bu parametrelerin kullanım yüzdeleri .....	16
Şekil 3.7. Çeşitli kestirimci bakım yöntemleri ile arıza tespit .....	17
Şekil 4.1. Biyolojik sinir hücresinin.....	18
Şekil 4.2. Yapay sinir ağı hücresi .....	20
Şekil 4.3. İleri beslemeli 3 katmanlı yapay sinir ağı modeli.....	21
Şekil 4.4. Lineer olmayan nöron modeli .....	22
Şekil 4.5. Bias sayısının sabit bir girdi olarak gösterildiği .....	23
Şekil 4.6. İki gizli katmana sahip sinir ağı modeli şematik gösterimi .....	24
Şekil 4.7. İki temel sinyal akışının gösteren çok katmanlı sinir ağı.....	24
Şekil 4.8. Çıktı katmanındaki hata sinyalini de gösteren şematik .....	25
Şekil 4.9. Çıktı katmanının gizli katmana bağlı olduğu ve hata .....	29
Şekil 4.10. Örnek bir boru hattı hidrolik diyagramı ve pompa istasyonu P&I diyagramı .....	35
Şekil 4.11. SCADA sistemi ile kontrol edilen pompaya ait enstrümantasyon diyagramı .....	36
Şekil 4.12. Örnek bir beslemeli ölçüm enstrümanı şematik.....	38
Şekil 4.13. Termokupl şematik gösterimi ve termokupl kısımları .....	39
Şekil 4.14. Termokupl .....	39
Şekil 4.15. ABB266GSH Basınç sensörü .....	40
Şekil 4.16. Basınç sensörü kesit görünümü .....	40
Şekil 4.17. İvme sensörü şematik görünümü ve .....	41
Şekil 4.18. Pepperl+Fuchs .....	42
Şekil 4.19. Endüktif yaklaşım sensörü şematik .....	42
Şekil 4.20. MATLAB Yapay sinir ağı araç kutusu.....	47

Şekil 4.21.Yapay sinir ağı araç kutusu sinir ağı tipi .....	48
Şekil 4.22. MATLAB Yapay sinir ağı araç kutusu ile oluşturulan.....	48
Şekil 5.1.Doğru YSA modeli tespiti için incelenen en iyi regresyon grafikleri .....	54
Şekil 5.2. Farklı öğrenme fonksiyonlarıyla modellenen çeşitli YSA'ların performansı .....	56
Şekil 5.3. Yapılan çalışmalar neticesinde tespit edilen .....	60
Şekil 5.4. Gerçek titreşim-YSA titreşim tahmin dağılımı.....	61
Şekil 5.5 Gerçek Titreşim Eğrisi - YSA Sonuçları Eğrisi.....	61



## SİMGELER VE KISALTMALAR

ANFIS	: Adaptive Neuro Fuzzy Interference.
b	: Bias değeri.
d	: Hedef çıktı.
e	: Hata sinyal değeri.
EMD	: Empiric Model Decomposition.
FFT	: Fast Fourier Transform.
GA	: Genetic Algorithm.
HOS	: High Order Statistics.
MAE	: Ortalama Mutlak Hata.
MAPE	: Ortalama Mutlak Bağlı Hata.
N	: Eğitim veri sayısı.
PSO	: Particle Swarm Optimization.
PSVM	: Proximal Support Vector Machine.
R	: Korelasyon katsayısı.
RMSE	: Root Mean Square Error.
RRMSE	: Relative Root Mean Square Error.
SCADA	: Supervisory Control And Data Acquisition.
SVM	: Support Vector Machine.
u	: Giriş değerleri ve bağlantı ağırlıkları çarpımı toplamı.
w	: YSA nöronlar arası bağlantı ağırlık değeri.
x	: YSA girdisi.
y	: YSA çıktısı.
YSA	: Yapay Sinir Ağı.
$\delta$	: Nöronlar arası bağlantı ağırlığı kısmi değişim derecesi.
$\varepsilon$	: Hata enerjisi.
$\eta$	: Geri yayılım algoritması öğrenme oranı.
$\varphi$	: Aktivasyon fonksiyonu.

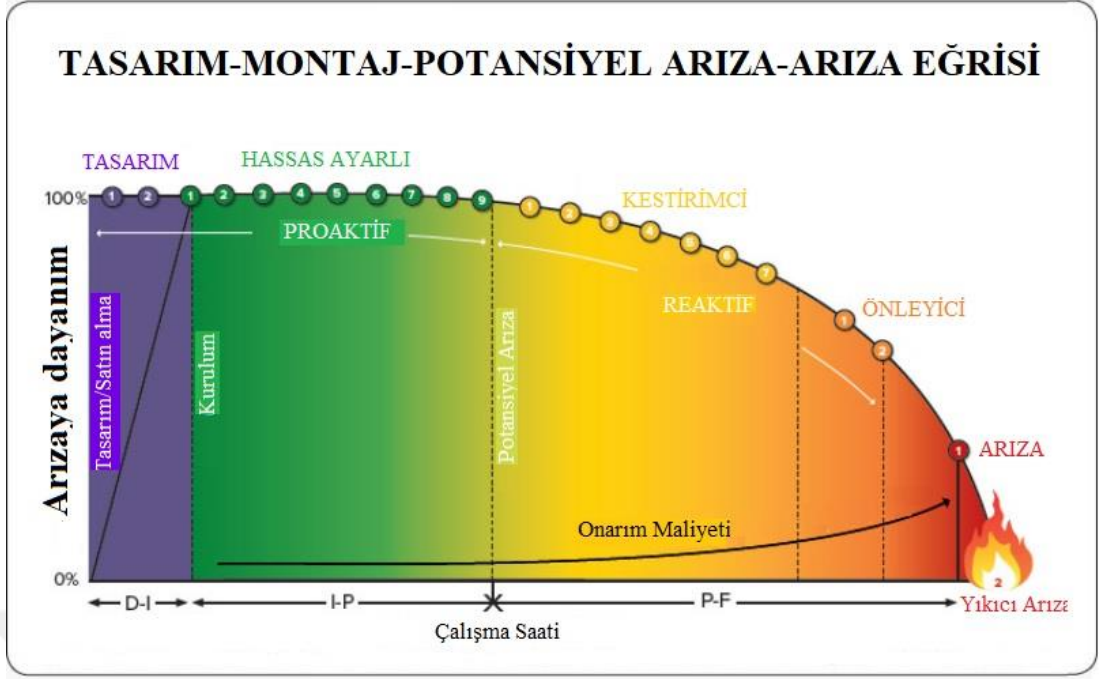
## 1. GİRİŞ

Endüstriyel tesisler tasarlanırken yürütülecek faaliyetin önem seviyesine göre ekipman seçimleri ve yedekli tasarım gibi faktörlerin en ideal kesişimini yakalamak üzere çalışmalar yapılmıştır. Yedekli tasarım yapılırken, bir yandan ilk yatırım maliyetleri ve sistem karmaşıklığı artarken diğer yandan da artan ekipman ve parça sayısına bağlı olarak sistem güvenilirliği azaldığı göz önünde bulundurulmalıdır (Ross, 2001). Başta petro-kimya tesisleri, demir çelik haddehaneleri, termik santralleri olmak üzere birçok endüstriyel tesislerde duruş ve kalkışlar, kritik, yüksek maliyetli ve riskli bir süreçtir. Böylesine zorlayıcı bir durumun bir de beklenmedik bir arıza sonucu ortaya çıkması günümüzde kabul edilebilir bir durum olmanın çok uzağında kalmıştır.

Duruş kalkışlar haricinde dahi oluşan arızalar, ürün kalitesi, tesis güvenliği ve bakım maliyetleriyle birlikte bir bütün olarak değerlendirildiğinde, toplam ürün maliyetinin %15-%70'ini oluşturmaktadır (Bevilacqua ve Braglia, 2000). Bu nedenle yöneticilerin yürüttükleri faaliyete en uygun bakım stratejisini belirlemeleri çok büyük bir öneme sahiptir. En uygun bakım stratejisinin belirlenmesi üzerine de çalışmalar yapılmış ve metodoloji geliştirilmiştir (Zaim, vd., 2012). Bir ekipmanın tasarım ve kurulum aşamasından itibaren arızaya giden süreç ve bu süreç evrelerine göre bakım stratejileri Şekil 1.1'de gösterilmiştir.

Bunun yanı sıra uzay ve havacılık, askeri araç ve ekipmanlarda, nükleer tesislerde de beklenmedik arızaların oluşması geri dönüşü olmayacak durumlara sebep olacağından bu uygulamalarda da arızanın takibi ve erken teşhisi hayati önem arz etmektedir.

Gerek duruş kalkış maliyetlerinin çok yüksek olduğu sektörlerde, gerek maliyetlerin ön planda olmamasına rağmen beklenmedik arızanın hayati öneme haiz olduğu sektörlerde ve gerekse üretim maliyetindeki en ufak tasarrufun bile rekabetçi piyasada çok büyük avantaja dönüştüğü sektörlerde olsun, günümüzde hemen her endüstriyel tesis ekipmanlarını Şekil 1.1'deki eğrinin olabildiğince solunda tutmak üzere kestirimeci bakım teknikleri uygulamaktadır.



Şekil 1.1. Tasarımdan arızaya giden süreçte bakım stratejileri ve onarım maliyeti (Riddell, 2017)

Kestirimci bakım başlığı altında çalışma verilerinin izlenmesi, yağ analizleri, belirli aralıklarla sıcaklık ölçümleri gibi çeşitli uygulamalar olsa da titreşim analizi bunlar içerisinde en bilineni ve iyi sonuçlar vermesi dolayısı ile yaygın olarak kullanılanı olmasına rağmen ilk yatırım maliyetleri ve kalifiye personel ihtiyacı dezavantaj olarak ortaya çıkmaktadır.

Gelişen bilgisayar teknolojisiyle beraber ortaya çıkan ve bankacılıktan, havacılık sektörüne, tıptan meteorolojiye kadar birçok farklı uygulamada başarılı olarak günlük hayatımızda yer edinen yapay zeka kavramı, yapay sinir ağı modellemesiyle makine durum değerlendirmesi ve arıza teşhisi yapmak üzere birçok araştırmaya konu olmaktadır.

Yapay sinir ağı modeli ile makine arıza teşhisi konusunda literatürde yapılan çalışmalar incelendiğinde hemen hepsinin test düzeneği üzerinde ve yapay arızalar ile gerçekleştirildiği görülmektedir.

Bu çalışmada ise gerçek bir boru hattı sistemi çalışma düzeneği olarak ele alınmış ve bu boru hattındaki pompalara ait geçmiş çalışma verilerinden yararlanılarak pompanın



sađlıklı alıřma durumunu simule edebilecek en uygun yapay sinir ađı modeli tespit edilmiřtir.

Oluřturulan yapay sinir ađının ıktısı olan titreřim deđeri ile gerekte pompa zerinden anlık olarak llen titreřim deđeri arasında oluřabilecek fark zerinden muhtemel arızanın erken tespitinin yapılması hedeflenmiřtir. Yapılan alıřma kapsamında oluřturulan arıza tespit sisteminde pompalar zerine ilave bir enstrman takılmamakta ve kalifiye personel ihtiyaı olmamaktadır.



## 2. ÖNCEKİ ÇALIŞMALAR

Yapay zeka, insan beyni modeli oluşturma, öğrenen, öğrenmeye devam eden ve yorum yapabilen bilgisayar, robot v.b. gibi düşünceler bilgisayarın ilk ortaya çıktığı dönemden bu yana bazı bilim insanlarının ilgisini çekmiştir.

İlk olarak McCulloch ve Pitts (1943), özellikle insan sinir sisteminin çalışma prensibi ve bunun matematiksel olarak modellenmesi üzerine teoriler geliştirmiştir. İleriki dönemlerde teknolojinin gelişmesi ve bilgisayarın insanlığın hizmetine sunulması ile yapay zeka ve yapay sinir ağı gibi kavramlar ortaya çıkmış ve özellikle 1980 lerin ortalarından itibaren yapay sinir ağı modeli üzerine hemen her alanda çeşitli çalışmalar yapılmıştır. Yapay sinir ağı, gerçekleştirilen çalışmalarda önemli sonuçlar elde edilmiş ve hala gelişmekte olan bir alan olarak gün geçtikçe önemi artmaktadır.

Ülkemizde de 1990'lı yıllardan itibaren yapay sinir ağları üzerinde çeşitli alanlarda birçok çalışma yapılmıştır. Bu çalışmalardan ulusal ve uluslararası nitelikte olan ve yakın zamanda gerçekleştirilmiş birkaç örnek verecek olursak;

Ravinesh, vd. (2017), rüzgar türbini kurulumu için hedef olarak belirlenmiş ve rüzgar hızı verileri mevcut olmayan 8 bölgenin fizibilitesinin yapılabilmesi adına oluşturdukları, firefly algoritması ile geliştirilmiş hibrit yapıdaki yapay sinir ağını bu bölgelere komşu nitelikteki 7 bölgenin aylık ölçüm verileriyle eğitmiştir. Bu hibrit sinir ağı modeliyle söz konusu 8 bölgenin 5'inde bu tarz çalışmalarda başarılı olarak kabul edilen RRMSE (Relative Root Mean Square Error) < %10 hedefine ulaşılmış ayrıca bu 5 bölgenin birinde RMSE=3,98% gibi çok hassas bir sonuç elde etmiştir.

Ghorbani, vd. (2012), oluşturdukları yapay sinir ağı modeli ile 4 farklı meteoroloji parametresi ile aylık rüzgar hızı tahminini gerçekleştirmiş ve aynı zamanda da yapay sinir ağlarında girdi parametrelerinin ağın yapısındaki bağıl önemini tespit etmiştir.

İbrikçi, vd. (2010), dairesel kesitli helisel yayların kritik burulma yüklerini tespit etmek üzere karmaşık nümerik hesap sonuçları ile yapay sinir ağı modellemesi sonuçlarını kıyaslamış ve çok hassas sonuç elde etmişlerdir. Böylece nümerik bir

açıklaması olmayan dörtgen ya da boru kesitli helisel yayların da kritik burulma yüklerinin yapay sinir ağı modeli ile tespit edilebileceğini ifade etmiştir.

Çelebi, vd. (2017), geleneksel dizel yakıt ile biyodizel yakıtın motor üzerindeki ses ve titreşim etkilerini karşılaştırmış, biyodizel yakıtla beraber emilen havaya farklı oranda doğal gaz karıştırarak da sonuçlar üzerindeki etkisini incelemişlerdir. Ayrıca deneysel olarak yapılan tüm bu çalışma yapay sinir ağı ile de modellenerek test edilmiş ve yapay sinir ağının hassas bir şekilde ses ve titreşimi tahmin ettiği gösterilmiştir.

Bu çalışmanın da konusu olan yapay sinir ağı ile makine durum analizi ve arıza teşhisi özelinde inceleyecek olursak;

Chow, vd. (1991), 100 hp altındaki güçlerde elektrik motorlarının endüstride yaygın olarak kullanılmasına karşın bu motorlarda durum izleme amacıyla cihaz yerleştirilmesi için alan sıkıntısı ve ekonomik nedenlerden dolayı uygulanmamasına çözüm olarak oluşturulan test düzeneği üzerinden alınan sadece akım ve rotor devir hızı ve bunların türevleri ( $I$ ,  $w$ ,  $I^2$ ,  $w^2$ ,  $I*w$ ) ile normal durum, sargı izolasyon hatası ve rulman arızası tespitini yapay sinir ağı modeliyle gerçekleştirmişlerdir.

Knapp ve Wang (1992), deneysel düzenek olarak ele aldıkları 3 eksenli masa üstü CNC tezgahından farklı durumlar (normal çalışma, körelmiş kesici uç, limit switch arızası, yetersiz yağlama veya partikül birikmesi sonucu arıza) için kasıtlı olarak oluşturulan hasarlar ve bunun sonucunda alınan vibrasyon sinyallerini FFT ile frekans eksenine dönüştürmüşlerdir. Daha sonra bu frekanslar 15 aralığa bölünerek her bir aralık yapay sinir ağına bir girdi olarak verilmiştir. Oluşturulan 15 giriş nöronu, 7 nöronlu bir ara katman ve 3 nöronlu çıkış katmanı olan yapay sinir ağı modeli eğitilmiş ve çıkış nöronlarında normal durum için herhangi bir sonuç yokken diğer üç durum için ayrı ayrı çıkışlar alınmış, eğer bunlardan hiçbirisi değil ise durum normal olarak değerlendirilmiştir .

Alguindigue, vd. (1993), ele aldıkları bir rulmanda iç bilezik, dış bilezik ve bilye her birinde lokal ve genel arıza teşhisi için vibrasyon analizi olarak adlandırılan vibrasyon sinyallerinin spektral grafiklerini oluşturdukları yapay sinir ağını eğitmek için

kullanmış ve konusunda uzman birinin bile geleneksel spektrum analizi ile ayırt etmekte zorlanacağı birden fazla hasarın aynı anda gelişme durumunu teşhis etmeyi başarmışlardır.

McCormick ve Nandi (1997), elektrik motoru, bu motora bağlı yataklanmış bir mil, mil üzerinde ağırlık bağlanabilecek delikleri olan bir volan ve yine mil üzerinde yataklama şeklindeki olan fakat içerisinde rulman olmayan bir deney düzeneği üzerinde çalışmışlardır. Yataklama olmayan bu kısımdan monte edilecek bir pirinç çubuğun sürtünme etkisi yapacak şekilde oluşturdukları deneysel düzenden değişik durumlar için veri toplanmış, bu verilerle HOS (high order statistics) ve YSA ile yapılan arıza sınıflandırması üzerinden her iki yöntemi kıyaslamışlardır. Genel olarak YSA'nın üstünlüğü kanıtlanırsa da sürtünme durumunda istenilen başarıya ulaşamamıştır.

Li, vd. (2000), endüstride önemli bir yeri olan elektrik motorlarının rulman arızalarını yapay sinir ağı ile teşhis etmeye çalışmıştır. Oluşturulan YSA'nın eğitim ve testi için gerekli olan verileri Matlab-Simulink tabanlı Motorsim yazılımı ile oluşturulan bir simülasyon ile elde etmişlerdir. Elde edilen titreşim sinyalleri FFT ile frekans eksenli hale dönüştürülmüş ve bu şekilde eğitilen YSA ile rulman durumu tespit edilmiştir. Daha sonra oluşturulan gerçek bir test düzeneğinden elde edilen veriler ile YSA yeniden eğitmiştir.

Wang ve Too (2002), oluşturdukları deneysel bir düzenek üzerinde kasıtlı olarak oluşturulan 8 farklı durum (a.normal, b1.balans ayarsızlığı (başlangıç), b2.balans ayarsızlığı (kötü), b3.balans ayarsızlığı(çok kötü), c1.kaplin ayarı bozukluğu (başlangıç), c2.kaplin ayarı bozukluğu(kötü), b1+c1 ve b1+c2) neticesinde elde edilen verileri önce HOS (High order statistic) ile değerlendirilip hata frekanslarını ve bunların devrin katsayılarına göre oluştuğu yerleri değerlendirildikten sonra karar verme kabiliyetinden dolayı YSA modelleyerek arıza tespiti yapmışlardır.

Samanta ve Al-Balushi (2003), başka bir çalışmadaki pompa elektrik motoru düzeneği titreşim sinyallerini oluşturdukları YSA'nın eğitim ve test çalışmalarında kullanmış ve

bu yöntemle balans ayarı bozukluğu, dişli hasarı, kaplin ayarı bozukluğu, rulman hasarı ve rotor sürtmesi gibi arızaları sınıflandırabilmişlerdir.

Kong ve Chen (2004), dalgacık dönüşüm (wavelet transform) metoduyla elde edilen verileri, bulanık mantık (fuzzy logic) yöntemi ile değerlendirerek karakteristik parametreler tespit etmişler ve YSA modeli ile arıza teşhisi gerçekleştirmişlerdir.

Samanta (2004), elektrik motoru tarafından sürülen bir pompa ve motor ile pompa arasında iki kademeli bir dişli kutusu bulunan deneysel düzenek üzerinden elde edilen veriler ile YSA ve SVM (Support Vector Machine) yöntemleri ile arıza teşhisi yapmaya çalışmış, çalışmayı çeşitlendirmek açısından kullanılan sinyalleri ön işleme tabi tutarak ve Genetik Algoritma ile beraber yahut Genetik Algoritma olmaksızın elde edilen sonuçlar üzerinden karşılaştırma yapmıştır. Neticede birçok açıdan az farkla da olsa SVM daha iyi sonuç verdiği tespit edilmiş ayrıca ayırt edici özellik olarak SVM öğrenme süresinin çok kısa olması dolayısıyla gelecekte online olarak bu değerlendirmeyi yapabileceğine dikkat çekmiştir.

Huang, vd. (2004), yalnızca tek ara katmanlı ve ileri beslemeli YSA'larda kullanılabilir ve eğitim algoritmasının hızını geliştirmek üzere çalışmışlardır. Extreme Learning Machine olarak adlandırdıkları bu eğitim algoritmasının yapılan karşılaştırmalarda sinir ağını 1000-2000 kat daha hızlı eğittiği ve daha iyi sonuçlar elde edildiği görülmüştür. Bu algoritmadaki mantık en düşük hata oranına inmenin yanı sıra en düşük ağırlık ve bias değerlerini elde etmektir. Bu değerlerin küçük olması sonucu YSA'nın genelleme yeteneğinin daha iyi olacağı tespit edilmiştir.

Arabacı (2005), elektrik motorunun akım değerlerindeki sapmalardan rotor arızası tespit etmeye çalışmış, bunun için oluşturulan deneysel düzenekte kasıtlı olarak oluşturulan hasarlar sonucu elde edilen verilerle oluşturmuş olduğu YSA'yı eğitmiştir.

Rafiee, vd. (2007), elektrik motoru, dişli kutusu ve yük bileşenlerinden oluşan bir deneysel düzenekte kasıtlı hasarlar ile elde edilen titreşim sinyalleri, oluşturulan YSA'nın eğitiminde kullanılarak YSA çıkışında sağlam, hafif aşınmış diş, aşınmış diş, kırık diş ve rulman hatası olarak 5 sonuçtan biri elde etmeye çalışmış ve başarılı olmuştur.

Su ve Chong (2007), bir elektrik motoru ve bir dinamometreden oluşan düzeneden toplanan sağlıklı veriler neticesinde elde edilen frekans spektrumu oluşturulan YSA'ya tanıtılmış ve spektrumda oluşan sapmalar üzerinden arıza tespiti yapmışlardır.

Wang ve Chen (2007), 3000 dev/dk 19 m<sup>3</sup>/h debili pompa motor düzeneğine yerleştirilmiş olan titreşim sensörleri ile farklı durumlar için elde edilen verilerle YSA eğitilmiş ve sonuçta normal, kavitasyon, fan hasarı, balans ayarı bozukluğu ve bilinmeyen arıza olarak sınıflandırma yapmışlardır.

Saxena ve Saad (2007), döner ekipmanların durumu hakkında genel bir değerlendirme yapmak üzere 1 rulmanda 8 adet farklı hasar ve 1 adet normal durum için elde edilen veriler toplanmıştır. Bu verilerden hangi data setinin kullanılacağına Genetik algoritma ile karar vermişlerdir.

Martins, vd. (2007), deneysel düzener olarak ele aldıkları elektrik motorunun statör akımlarının alfa ve beta vektörleri ile arıza teşhisi yapılmıştır. Bu sayede kasıtlı hasar verilerek veri toplanan çalışmalara alternatif olarak sadece arızanın varlığı değil aynı zamanda arızanın çeşidinin de tespit edilebileceği bir yöntem ortaya koymuşlardır.

Rajakarunakaran, vd. (2008), santrifüj pompalarda arıza teşhisi için oluşturulan birileri beslemeli, geriye yayılım algoritması ile eğitilmiş, diğeri Binary adaptive resonans sinir ağı olmak üzere iki farklı sinir ağı deneysel bir düzeneden elde edilen verilerle eğitilmiş ve test edilmiştir.

Lei, vd. (2008), arkadaşları, 2 hp gücündeki 3 fazlı elektrik motoru ve bu motor mili ucuna bağlanmış dinamometre ile değişken durumlar neticesinde, elektrik motoru sürücü ucundaki rulman hasarı (Normal, İç bilezik, dış bilezik ve bilye) teşhis edilmiştir. Bunun için YSA'ların adaptasyon özelliği ile Fuzzy Logic (bulanık mantık) yönteminin niteliksel yaklaşımının bir araya getirilmiş hali olan Adaptive Neuro Fuzzy Interference System (ANFIS), EMD (Empiric Model Decomposition) Enerji Entropi ile karşılaştırılmış ve ANFIS'in üstünlüğü gösterilmiştir.

Saravanan, vd. (2010), elektrik motoru, motor ucunda bağı rulman ile askıya alınmış rotor, bu rotor ucuna kayış kasnak mekanizması ile bağlanmış bir dişli kutusu ve bu dişli kutusu çıkışında yay yüklemeli elektromanyetik bir disk fren den oluşan karmaşık bir düzenek üzerinden yüklü, yüksüz, kuru, yarım yağlı, yağlı, sağlam diş, kırık diş, dişli gövdesinde çatlak ve aşınma durumları için veriler toplamıştır. Bu verilerle YSA ve PSVM (Proximal Support Vector Machine) yöntemlerinin sınıflandırma performansı karşılaştırılmış ve sınıflandırma özelliği bakımından PSVM'nin daha iyi olduğu tespit edilmiştir.

Bin, vd. (2012), deneysel düzenek olarak elektrik motoru ve rotor düzeneğinden elde edilen 5 farklı titreşim spektrumu ile 10 farklı arıza tespiti yapabilmek üzere bir YSA modellemişlerdir. Arıza değerlendirmesi için ilgili parçaların genel arıza frekansları kullanılmıştır.

Azadeh, vd. (2013), ve arkadaşları, santrifüj pompa çalışma verileri olan debi, sıcaklık, emme basıncı, basma basıncı ve titreşim değerleri ile arıza teşhisi yapabilmek üzere YSA ve SVM karşılaştırması yapılmıştır. SVM ayrıca SVC+GA (Genetic Algorithm) ve SVC+PSO ( Particle Swarm Optimization) olarak çeşitlendirilmiştir. Yapılan incelemede SVC nin hata tespitinde daha üstün olduğu tespit edilse de normal ortam ile dış etkenli (noisy) ortam arasındaki doğruluk sapmalarında YSA'nın daha az etkilendiği görülmüştür.

Zhang ve Wang (2014), bir rüzgar türbini çiftliğinde sistemin kontrollü bir şekilde çalışması için SCADA sisteminde toplanan ve zaten var olan veriler ile ilave hiçbir yatırım, yazılım gerektirmeksizin arıza teşhisi yapılmıştır. Bu yönüyle çalışma, yapmış olduğumuz tez çalışmasına oldukça benzemektedir.

Jia, vd. (2016), YSA'na alternatif olarak daha stabil bir yapıda olan Deep Neural Network adı verilen ve giriş verilerini önce encoder sonra decoderdan geçiren bir katmanı olan yapıdaki bir YSA ile 10 farklı arızayı teşhis etmeye çalışmışlardır.

Waqar (2015), Karınca kolonisi optimizasyonu ile optimize edilmiş YSA'lar ile sonsuz dişlide oluşan 4 farklı hasar teşhis edilmeye çalışmıştır. Yaklaşımın etkinliğini

arttırmak için titreşim, ses ve kızılötesi sıcaklık görüntüleri kullanılan durum izleme tekniği kullanılmıştır.

Yapay sinir ağlarının, makine durum izleme ve arıza tespiti konusundaki uygulamaları çeşitlenerek artmakla beraber şuna kadar yapılan çalışmaların neredeyse tamamı deneysel düzenek üzerinde ve kasıtlı hasarlar üzerinden yapılmış çalışmalar olarak görülmektedir.

Bu çalışmadaki ayırt edici husus ise, yapay sinir ağı ile makine durum değerlendirmesinin çalışmakta olan gerçek bir boru hattı sistemindeki pompalardan alınan değerlerle, en uygun sinir ağı yapısının tespit edilerek eğitilmesidir.

Çalışılan yapay sinir ağı modelindeki mantık, halihazırda SCADA sisteminde kayıt altına alınmakta olan on sekiz parametreden titreşim ile bağıntısı en yüksek olan yedi adedinin tespiti ve bu yedi parametre ile normal çalışma anında olması gereken titreşimi tahmin etmek, şayet gerçekte ölçülen titreşim YSA ile tahmin edilenden  $\pm\%10$  farklı ise bunun oluşabilecek bir arızanın göstergesi olarak değerlendirilmesidir.

Çalışma neticesinde yapay sinir ağına girdi olarak verilen anlık değerler ile titreşim ortalama mutlak bağıl hata (MAPE) = % 4,95 gibi bir yakınlıkla tahmin edilmiş ve her ne kadar eşdeğer olsa da her pompa için ayrı ayrı sahadan veri toplayarak herbir pompaya özel yapay sinir ağı modellenerek hata oranının daha da düşürülebileceği ve yapay sinir ağı performansının daha da geliştirilebileceği tespit edilmiştir.



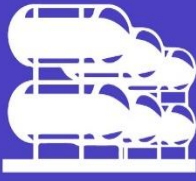


### 3. BAKIM YÖNTEMLERİ

Günümüzde bakım onarım faaliyetleri, rekabetçi üretim ve hizmet sektörlerinde çok kritik önem arz eden bir husustur. Öyle ki makine arızaları, teslimat tarihinin kaçırılması sonucu oluşan maddi kayıpların yanı sıra firmanın imaj kaybı ve yeni fırsatların kaçırılması gibi doğrudan ve dolaylı olarak daha çok kayıplara yol açabilen bir durumdur (Zaim, vd., 2012). Bu nedenle yürütülen faaliyet, tesisin durumu ve piyasa koşulları göz önünde bulundurularak en uygun bakım stratejisinin belirlenmesi bu konudaki yöneticilerin doğru tercih yapması gereken en önemli husustur.

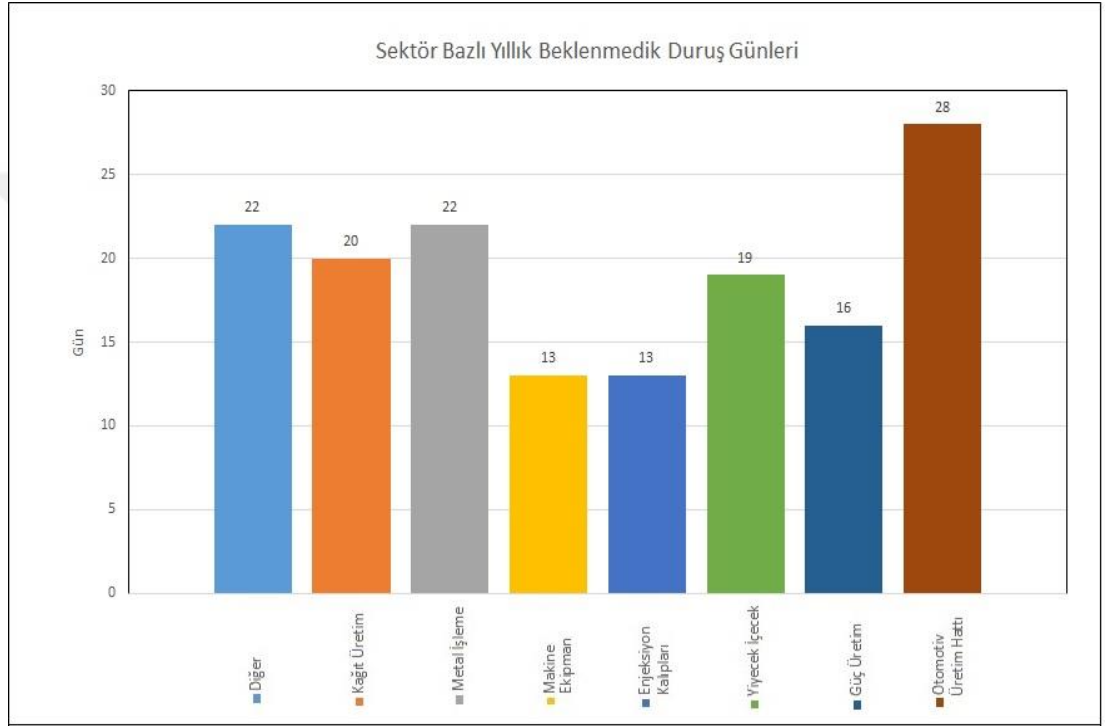
Yapılan araştırmaya göre beklenmedik duruşlar üretim kapasitesinin en az %5 düşmesine sebep olmakta ve bazı durumlarda bu düşüşün %20'ye kadar yükseldiği değerlendirilmiştir. Buna karşın üreticilerin %80'inin duruş maliyetlerini ölçmek için bir modeli olmadığı görülmüştür (Presenso, 2018).

Bazı sektörler için plansız duruş maliyetleri hakkında istatistikler Şekil 3.1'de gösterilmiştir.

SEKTÖR	DURUŞ MALİYETİ
Otomotiv Endüstrisi 	1.3 milyon \$/saat \$\$\$
Termik Santral Türbinleri 	1 milyon \$/gün \$\$
LNG Tesisleri 	150 milyon \$/yıl (Orta ölçekli LNG Tesisi) \$

Şekil 3.1. Sektörlere göre plansız duruş maliyetleri (Presenso, 2018)

Üreticilerin % 42'si makineleri olması gerekenden daha zorlu koşullarda çalıştırdıklarını kabul ederken %40'ı ise beklenmedik duruşları gelirlerini arttırmaya karşı en büyük tehdit olarak görmektedir. Amerika verilerine göre bir rafinerinin günlük duruş ortalaması 1.2 kez iken bunların %23'ü bakım ile ilişkili nedenlerden kaynaklanmakta ve bakım ile duruşların da %92'si beklenmedik duruş şeklinde ortaya çıkmaktadır. Yapılan araştırmalara göre sektörel bazlı yıllık beklenmedik duruş günleri Şekil 3.2'de gösterilmiştir (Presenso, 2018).



Şekil 3.2. Sektörel bazlı yıllık beklenmedik duruş günleri (Presenso, 2018)

Endüstriyel tesislerin bakım ve onarım stratejileri genel olarak proaktif (önleyici) ve reaktif (düzeltici) şeklinde iki kategoride değerlendirilir (Li, vd., 2006). Onarım başlığı açık bir şekilde arızanın meydana geldiğini ve bu arızanın giderilmesi anlamını taşıdığı için doğrudan reaktif bir durum olarak görülmektedir. Diğer yandan proaktif tarafta olan bakım faaliyetlerini ise reaktife yakın proaktif ve proaktif olarak kendi içerisinde ayırabiliriz.


Her kurumun kendi faaliyet alanı, makine ve tesis güvenliği kültürü, üretimde çalışan makinenin arızasının oluşturacağı maliyet, risk gibi faktörleri ile ulusal ve uluslararası standartları göz önünde bulundurarak benimsediği bir bakım yöntemi vardır. Her

stratejinin kendine özgü avantaj ve dezavantajları vardır (Wang, 2002). Genel olarak endüstride uygulanan bakım yöntemleri aşağıda açıklanmıştır.

### 3.1. Arıza Sonrası Bakım (Run to failure)

Arıza sonrası bakım (run to failure) yöntemi, her ne kadar reaktif bir yaklaşım olarak görünse de bakım ekibinin tekniğinin bu olması herhangi bir anda meydana gelebilecek arızaya karşı hazırlıklı olmak adına yedek parça bulundurması, ekibin deneyim düzeyine göre hangi ekipmanlarda ne sıklıkta arıza meydana geldiği ve kritiklik seviyesi göz önünde bulundurularak, arıza meydana geldiğinde nasıl bir reaksiyon göstereceklerini önceden planlamayı gerektirmesi bakımından proaktif yaklaşımlar içeren bir reaktif yöntemdir.

Bu yöntem en ilkel bakım anlayışı olarak değerlendirilmekte ve her ne kadar arıza sonucu oluşan onarım masrafları ve olası duruş maliyetleri günümüz koşullarında kabul edilebilir bir yaklaşım gibi görünmese de arızaya kadar olan süreçte herhangi bir takip, insan gücü gerektirmemekle beraber kar majının yüksek olduğu sektörlerde hala kullanılabilir bir strateji olarak görülebilmektedir (Sharma, vd., 2005). Bu stratejisinde ortaya çıkan zaman-maliyet grafiği Şekil 3.3’de gösterilmiştir.



Şekil 3.3. Arıza sonrası bakım stratejisi maliyet-zaman grafiği (Pro-Plan, 2004)


Arıza beklenmedik bir anda meydana geleceğinden birçok yedek parçayı hazır bulundurmak, oluşan arızanın boyutuna göre bazen onarmaktansa ekipmanı komple

yenilemeye varan maliyetler ve tesis güvenilirliği üzerindeki olumsuz etkiler bu yöntemin dezavantajları olarak ön plana çıkmaktadır.

### 3.2. Periyodik (Önleyici) Bakım

Proaktif bir teknik olan koruyucu (periyodik) bakım, ekipman üreticilerinin tavsiye ettiği bakım periyotları ve her bakım kapsamında değişimi yapılacak parçalar hususundaki tavsiyelerini, üreticilerin ticari stratejilerinin, var ise söz konusu ekipman hakkındaki ulusal ve uluslar arası standartların ve kurumun bu konudaki deneyimlerinin optimum noktada kesişimi sağlanarak iyi bir planlama süreci gerektiren yöntemdir.

Bu yöntemde ekipmanın mevcut durumundan bağımsız olarak haftalık, aylık ve yıllık gibi önceden planlanan süre aralıkları ile parça değişimi, temizlik, yağlama gibi uygulamalar ile beklenmedik arızaların oluşmasının engellenmesi hedeflenmektedir (Sharma, vd., 2005). Periyodik bakım en geleneksel bakım stratejisi olmasına karşı günümüzde gelişen teknolojinin beraberinde getirdiği yenilikçi tekniklerin başarılı sonuçları ve rekabetçi piyasa koşulları neticesinde en küçük tasarrufun bile ciddi önem kazandığı ortamda gereksiz sayılabilecek iş gücü ihtiyacı ve parça değişimleri sayesinde gün geçtikçe geçerliliğini yitirmektedir. Bu bakım stratejisinde ortaya çıkan zaman-maliyet grafiği Şekil 3.4'de gösterilmiştir.



Şekil 3.4. Periyodik (Önleyici) bakım stratejisi maliyet-zaman grafiği (Pro-Plan, 2004)

Ayrıca her ne kadar parçalar yenisi ile değiştirilmek suretiyle makine durumunun iyileşmesi amacı güdülse de, bir ekipman üzerinde gereksiz yere yapılan her montaj demontajın sonucunda işin doğası ve çalışma ortamı koşulları gereği bir takım toleransların kaybedilmesi sonucu daha erken arıza oluşması ihtimalini de beraberinde getirmektedir.

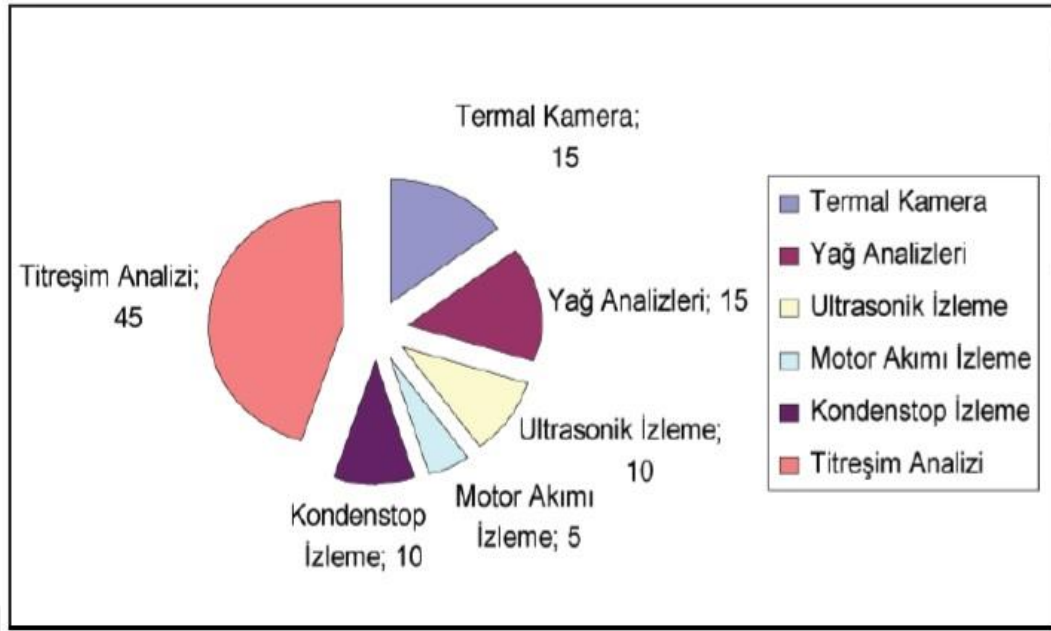
### 3.3. Kestirimci Bakım

Proaktif yaklaşım tekniği ifadesini tam olarak karşılayan ve günümüzde hızla uygulama alanı genişlemekte olan yöntem kestirimci bakım tekniğidir. Kestirimci bakımın da kendi içinde çeşitleri olmakla beraber genel olarak, çalışmakta olan bir makinenin durumunu takip etmek için sürekli veya belirli aralıklarla yapılan ölçüm, izleme, kontrol neticesinde oluşabilecek bir arızayı mümkün olan en erken aşamada tespit etmek ve en uygun zamanda makineyi planlı bir şekilde durdurarak henüz arıza gerçekleşmeden gerekli düzeltmeyi yapmayı hedefleyen tekniktir. Bu stratejiye ait zaman-maliyet grafiği Şekil 3.5’de gösterilmiştir.



Şekil 3.5. Kestirimci bakım stratejisi maliyet-zaman grafiği  
(Pro-Plan, 2004)

Kestirimci bakım için bir makinede genel olarak izlenen parametreler aşağıdaki Şekil 3.6’da verilmiş olup, her işletme kendine özgü kestirimci bakım planını oluştururken bu parametrelerden bir ya da birkaçının takip ve analizini içeren bir yöntem belirleyebilir. Bu parametrelerin endüstride kestirimci bakım amacıyla kullanılma yüzdeleri Şekil 3.6’da verilmiştir.




Şekil 3.6. Kestirimci bakım stratejisinde takip edilen parametreler ve bu parametrelerin kullanım yüzdeleri (Yaman ve Karadayı, 2014)

Titreşim analizi tekniği döner durum izlemesi için en çok tercih edilen yöntemdir. Makine durum izlemeye dayalı bakım stratejisi kağıt üreticileri, rafineriler, termik santraller gibi tesislerde yaygın olarak kullanılmaktadır. Makine durumunun takibi ve muhtemel arızaların teşhisi için izlenen parametreler aynı zamanda arızanın kök nedeninin belirlenmesini sağlaması bakımından da muhtemel arızalara karşı kalıcı çözümler üretilerek arıza ihtimali asgari düzeye indiren sıfır hata stratejisine hizmet etmektedir (Sharma, vd., 2005).

Öte yandan halen üzerine çalışmalar devam eden ve gittikçe popüler hale gelen yapay zeka, yapay sinir ağı ile makine durum izleme ve erken uyarı sistemleri ise geleceğin en tercih edilen bakım stratejisi olmaya aday görülmektedir. Yapılan araştırmalara göre yapay zeka tabanlı kestirimci bakım metotları bakım maliyetlerinde %10-40 arasında ve toplam makine duruşlarında %30-50 arasında düşüş sağlarken, üretimde %3-5 arası bir artış sağladığı değerlendirilmiştir (McKinsey, 2015).

Makinelerde arızaya giden süreçte kestirimci ve önleyici bakım yöntemleri ile arıza teşhis edilebilme evrelerini ve buna karşın ortaya çıkan tamir bakım maliyetleri Şekil 3.7'de gösterilmiştir (Presenso, 2018).



Şekil 3.7. Çeşitli kestirimci bakım yöntemleri ile arıza tespit evreleri ve onarım maliyetleri (Presenso, 2018)

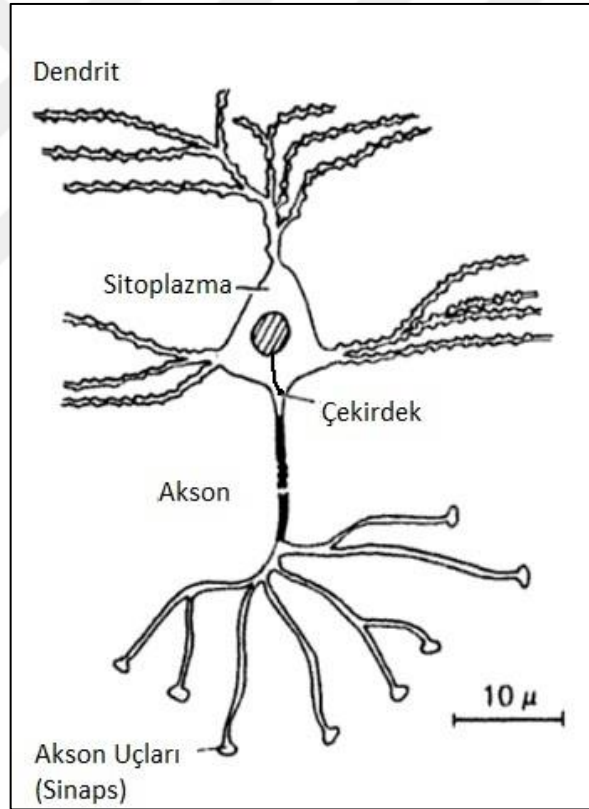


## 4. MALZEME VE YÖNTEM

### 4.1. Yapay Sinir Ağları

Yapay sinir ağları, insan sinir hücresinden esinlenerek oluşturulmuş matematiksel modeller olup, bu yapıyı anlamak için öncelikle biyolojik sinir hücresi yapısının anlaşılması gereklidir.

Her ne kadar çok fazla çeşitte, boyutlarda ve çok farklı fonksiyonlar için sinir hücreleri olsa da, Şekil 4.1'de görüldüğü gibi bir sinir hücresi temel olarak dendrit, hücre gövdesi( sitoplazma ve çekirdek), akson ve akson uçlarından oluşmaktadır (Amit, 1989).



Şekil 4.1. Biyolojik sinir hücresinin yapısı (Amit, 1989)

Biyolojik bir sinir hücresi dendritler vasıtasıyla sinyalleri (uyarı) alır, uygun tepkiyi verir ve ilgili yerlere iletir. Sinir hücreleri sinapslar ile birbirlerine bağlanarak sinir ağını oluştururlar.



Biyolojik sinir hücresinin matematiksel olarak ifade edilmesi fikrini ilk olarak Warren S. ve arkadaşları ortaya atarak bugünkü yapay sinir ağı yapısının temellerini atmışlardır (McCulloch, vd., 1943).

McCulloch ve Pitts tarafından yapılan matematiksel modellemeden sonraki süreçte bir sinir hücresinden yapay sinir ağlarına giden çalışmalara ilk olarak perceptron adı verilen tek katmanlı algılayıcılar ile başlanmıştır. Bu algılayıcıların en önemli özelliği problem uzayını bir doğru veya bir düzlem ile sınıflara ayırmalarıdır. Tek katmanlı algılayıcılarda girdiler ile ilgili ağırlıkların çarpımlarının toplamının bir eşik değerden büyük veya küçük olmasına göre girdiler sınıflandırılır. Tek katmanlı algılayıcıda eşik değer ünitesi çıktısı 1 sabit değerinin vermekte olup yapay sinir ağının eğitilmesi sırasında hem girdilerin hem de eşik değer bağlantı ağırlıkları değiştirilmektedir. Bilinen en önemli tek katmanlı algılayıcılar şunlardır (Öztemel, 2012).

- Basit tek katmanlı algılayıcılar (perceptron)
- Adaline/Madaline üniteleri


Yukarıda belirtilen basit tek katmanlı algılayıcılar ile Adaline/Madaline üniteleri arasındaki fark öğrenme kurallarıdır. Basit tek katmanlı algılayıcılarda ağın ürettiği çıktı ve ağ çıktısı olarak beklenen değer karşılaştırılarak buna göre bağlantı ağırlıkları artırılır veya azaltılır. Bunun için girdi değerleri öğrenme katsayısı ( $\lambda$ ) olarak adlandırılan sabit bir değer ile çarpılarak ağırlıklara eklenmekte ya da çıkarılmaktadır (Öztemel, 2012).

Adaline ünitesinde ağırlıklar ağ çıktısı ile beklenen çıktı arasındaki fark değerine göre güncellenmektedir. Bunun için fark (hata) değeri öğrenme katsayısı ( $\alpha$ ) olarak adlandırılan değer ile çarpılarak önceki ağırlıklara eklenmekte ve yeni ağırlıklar belirlenmektedir. (Öztemel, 2012).

Adaline ünitelerinin bir araya gelmesi ile Madaline ağı oluşur. ADALINE üniteleri bir araya gelerek MADALINE ağının oluştururlar. Madaline ağı Adaline üniteleri ile aynı öğrenme kuralına sahip olmakla beraber, Adaline ünitelerinin birbirlerine ve/veya operatörleri ile bağlanması ile Adaline ünitesi çıktıları Madaline ağı çıktısı haline gelmektedir (Öztemel, 2012).

Tek katmanlı algılayıcıların en önemli problemi doğrusal olmayan olayları öğrenememeleridir. O nedenle bunlar geliştirilmiş ve yeni modeller oluşturulmuştur (Öztemel, 2012).

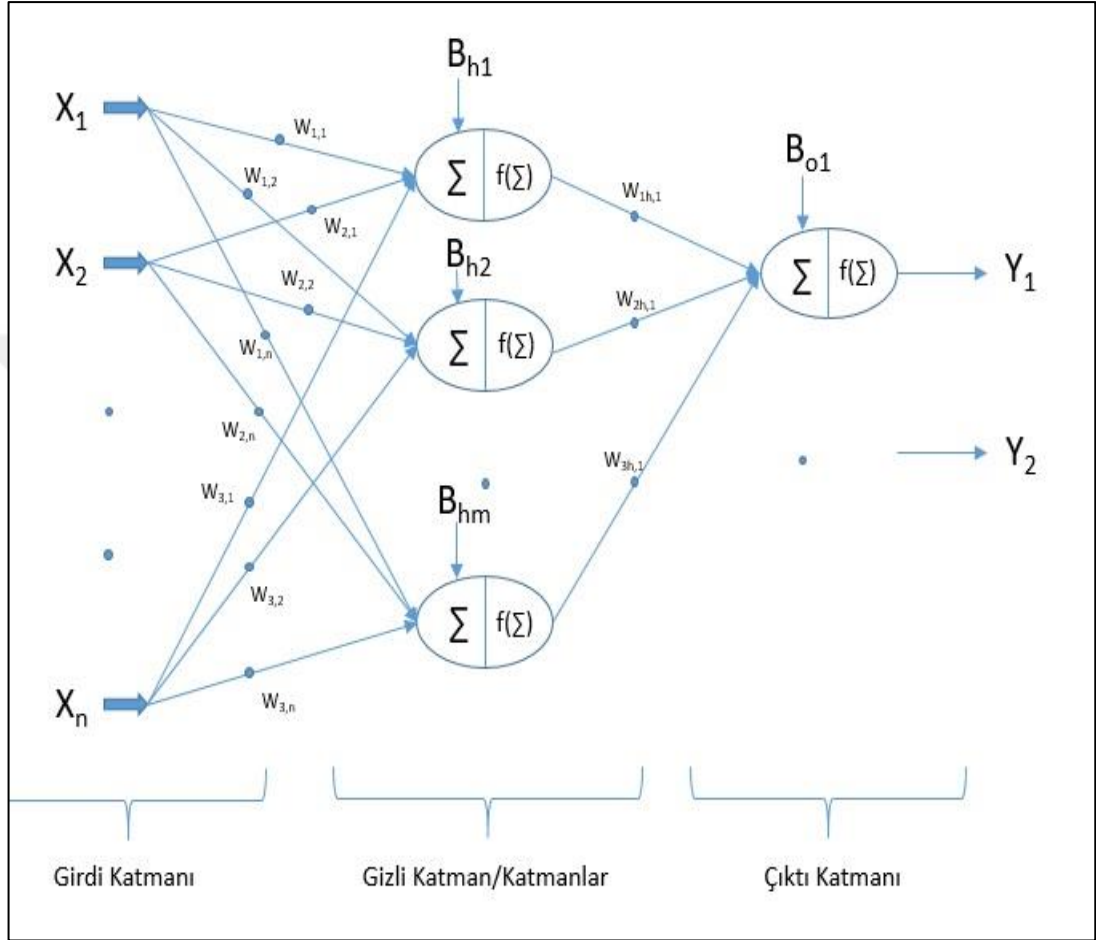
Tek katmanlı algılayıcı olarak ifade edilen perceptronlar girdilerin toplanması sonucu çıkan değer pozitif ya da negatif olmasına göre 1 veya 0 çıktısının vermekten, girdilerin ağırlıklarla çarpılarak toplanması neticesinde çıkış değerinin 1,0 veya -1 gibi değerler almasına ve uzun dönemde yapılan çalışmalar neticesinde nöron adı verilen yapay sinir ağı hücresine dönüşerek Şekil 4.2’de gösterilen halini almıştır.



Şekil 4.2. Yapay sinir ağı hücresi

Yapay sinir ağı en az iki fiziksel bileşene sahip olmalıdır. Bunlar nöronlar ve nöronlar arası bağlantılardır. Tek katmanlı algılayıcı olarak tanımlanan nöronların bir ya da daha fazlasının sıralanarak bir katman oluşturması ve birden çok katmanın, katmanlardaki nöronlar arası bağlantılar ile bir araya gelerek oluşturduğu yapı yapay sinir ağı olarak adlandırılmış ve bugün birçok farklı alandaki çalışmaya konu olmaktadır. En yaygın kullanılan yapay sinir ağı yapısı ileri beslemeli yapıdır. Bu yapıda bilgi girdi katmanından çıktı katmanına doğru taşınırken nöronlar arası bağlantı yalnızca katmanlar arasında kurulmakta ve bir katmandaki nöronlar kendi aralarında bir bağlantı kurmamaktadır (Zhang, vd., 2003).

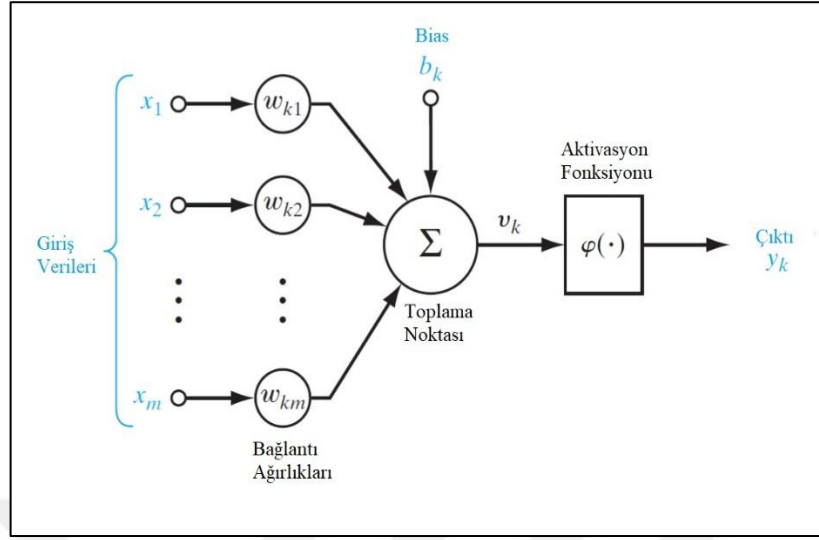
Şekil 4.3’de gösterilen ileri beslemeli yapıdaki yapay sinir ağı modeli hemen her çalışmada aynı yapıda olup, problemin türüne göre değişen unsurlar girdi sayısı, ara katman sayısı, ara katmandaki nöron sayısı, çıkış katmanındaki nöron sayıları, transfer fonksiyonları ve öğrenme algoritmalarıdır.



Şekil 4.3. İleri beslemeli 3 katmanlı yapay sinir ağı modeli

Girdi sayısı ve çıktı sayısı yapay sinir ağı ile modellenmek istenilen durum için elde edilen verilere göre belirlenmekle beraber, gizli katmandaki nöron sayısı hakkında girdi ve çıktı sayılarıyla orantılı bir takım genellemeler olsa da gerek gizli katmandaki nöron sayısı, gerekse gizli katman sayısı ve transfer fonksiyonlarının tespiti için en geçerli yöntem deneme yanılma yöntemidir. Buradaki önemli unsur, gizli katmandaki nöron sayısı ve gizli katman sayısını gereğinden fazla seçmek yapay sinir ağının yapısını gereksiz yere karmaşık hale getirerek işlem süresinin uzaması gibi durumlara yol açarken, gizli katmandaki nöron sayısının az olması da yeterli hassasiyeti elde edilememesine sebep olmasındır (Arslan ve İnce, 1996).

## 4.2. Yapay Sinir Ağlarının Matematiksel İfadesi



Şekil 4.4. Lineer olmayan nöron modeli (Haykin, 2009)

Şekil 4.4 teki yapay sinir hücresi modelinde aktivasyon fonksiyonu giriş değerini, pozitif ya da negatif olmasına bağlı olarak arttıran ya da azaltan Bias sayısı  $b_k$  olarak gösterilmiştir.

$k$  hücresini matematiksel olarak:

$$u_k = \sum_{j=1}^m \omega_{kj} x_j \quad (4.1)$$

$$y_k = \varphi(u_k + b_k) \quad (4.2)$$

$$v_k = u_k + b_k \quad (4.3)$$

denklemleri ile ifade edebiliriz.

Burada;

$x_1, x_2, \dots, x_m$  : girdi değerlerini,

$\omega_{k1}, \omega_{k2}, \dots, \omega_{km}$ : girdi değerleri ile  $k$  nöronu arasındaki bağlantı ağırlıklarını,

$u_k$ : giriş değerleri ve bağlantı ağırlıklarının çarpımlarının toplamını,


bk: bias katsayısını,  
 $\phi$ : aktivasyon fonksiyonunu,  
 $y_k$ : k nöronunun çıktı değerini,  
 ifade etmektedir.

Şekil 4.4'te gösterilen sinir hücresine girdi değeri  $x_0 = +1$  ve bağlantı ağırlığı  $\omega_{k0} = b_k$  olan yeni bir sinaptik bağlantı ekleyerek denklem 4.1'i denklem 4.4'deki, denklem 4.2'yi de denklem 4.5'teki şekilde ifade edebiliriz.

$$v_k = \sum_{j=0}^m \omega_{kj} x_j \quad (4.4)$$

$$y_k = \phi(v_k) \quad (4.5)$$


Denklem 4.4 ve denklem 4.5'te oluşan yeni matematiksel ifade ile ortaya çıkan sinir hücresi yapısı şekil 4.5'de gösterilmiştir.



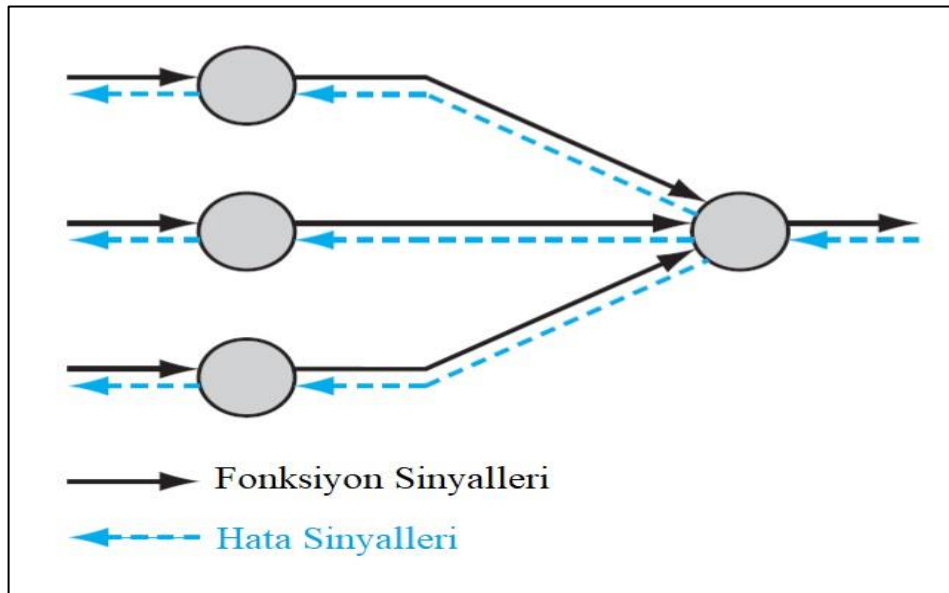
Şekil 4.5. Bias sayısının sabit bir girdi olarak gösterildiği nöron modeli (Haykin, 2009)

### 4.3. Geri Yayılm (Backpropagation) Algoritması Matematiksel İfadesi

Şekil 4.6'da iki gizli katman ve bir çıkış katmanından oluşan, her katmandaki her bir nöronun bir önceki katmandaki her nöronla ayrı ayrı bağlantısının olduğu, veri akışının soldan sağa doğru (ileri beslemeli) katman katman olduğu çok katmanlı bir yapay sinir ağı modeli gösterilmiştir (Haykin, 2009).



Şekil 4.6. İki gizli katmana sahip sinir ağı modeli şematik gösterimi (Haykin, 2009)



Şekil 4.7. İki temel sinyal akışının gösteren çok katmanlı sinir ağı modeli: ileri yönde fonksiyon sinyalleri ve geri yönde hata sinyalleri (Haykin, 2009)


Şekil 4.7’de ise Şekil 4.6’da gösterilen çok katmanlı yapay sinir ağına benzer bir yapay sinir ağı modelinin bir kısmı ele alınarak veri akışı gösterilmiştir. Şekil 4.7’de gösterildiği gibi ileri beslemeli bir yapay sinir ağında fonksiyon sinyalleri soldan sağa doğru yani ileri yönde taşınırken, sinir ağı çıktı değerleri ile eğitim aşamasında yapay sinir ağına tanıtılan gerçek çıktı değerleri arasındaki farka göre oluşturulan hata sinyalleri sağdan sola doğru yani geri yönde iletilerek nöronlar arası bağlantıların ağırlıkları değiştirilerek yapay sinir ağı eğitilmektedir (Haykin, 2009).

Şekil 4.6’daki yapay sinir ağının  $x(n)$  girdisine karşılık  $d(n)$  hedef çıktı değerlerinden oluşan bir veri matrisi ile eğitildiğini düşünürsek ve yine  $x(n)$  girdisine karşı yapay sinir ağının  $j$  nöronunda ürettiği çıktıyı  $y_j(n)$  olarak nitelendirirsek,  $e_j(n)$  olarak tanımlanan hata sinyali denklem 4.7’deki gibi ifade edilebilir (Haykin, 2009).

$$\mathcal{F} = \{x(n), d(n)\}_{n=1}^N \quad (4.6)$$

$$e_j(n) = d_j(n) - y_j(n) \quad (4.7)$$

Denklem 4.7’deki matematiksel ifade ile hesaplanan hata sinyalinin oluşumu şematik olarak Şekil 4.8’de gösterilmektedir.



Şekil 4.8. Çıktı katmanındaki hata sinyalini de gösteren şematik sinyal akışı (Haykin, 2009)

Elde edilen bu hata sinyali doğrultusunda oluşan ani hata enerjisi denklem 4.8'deki şekilde ifade edilir.

$$\mathcal{E}_j(n) = \frac{1}{2} e_j^2(n) \quad (4.8)$$

Çıktı katmanındaki herbir nöron için denklem 4.8'deki şekilde hesaplanan ani hata enerjileri denklem 4.9'daki matematiksel ifadede gösterildiği gibi toplanarak bütün sinir ağının toplam ani hata enerjisi elde edilir (Haykin, 2009).

$$\mathcal{E}(n) = \sum_{j \in C} \mathcal{E}_j(n) = \frac{1}{2} \sum_{j \in C} e_j^2(n) \quad (4.9)$$

Burada C çıktı katmanındaki tüm nöronları kapsamaktadır.

N adet eğitim veri serisinden oluşan bir sinir ağı modelinin ortalama hata enerjisi denklem 4.10'deki şekilde ifade edilir.

$$\mathcal{E}_{av}(N) = \frac{1}{N} \sum_{n=1}^N \mathcal{E}(n) = \frac{1}{2N} \sum_{n=1}^N \sum_{j \in C} e_j^2(n) \quad (4.10)$$

Geri yayılma algoritmasını matematiksel olarak ifade etmek için Şekil 4.8'deki nöronu ele aldığımızda, bias hariç m adet girdi değerinin ilgili sinaptik bağlantı ağırlıklarının çarpımları toplamına, bias sayısını ifade  $y_0=+1$  ve  $\omega_{j0}$  değerleri çarpımı da eklenerek j nöronunda aktivasyon fonksiyonu girişinde oluşan  $v_j(n)$  değeri denklem 4.11'deki şekilde ifade edilir (Haykin, 2009).

$$v_j(n) = \sum_{i=0}^m \omega_{ji}(n) y_i(n) \quad (4.11)$$

j nöronu çıktısı olarak elde edilen  $y_j(n)$  değeri denklem 4.12'deki şekilde ifade edilir.

$$y_j(n) = \varphi_j(v_j(n)) \quad (4.12)$$



Geri yayılma algoritmasında her bir  $\omega_{ji}(n)$  sinaptik bağlantı ağırlık değerine,  $\partial \mathcal{E}(n) / \partial \omega_{ji}(n)$  kısmi türeviyle orantılı olan bir  $\Delta \omega_{ji}(n)$  değeri uygulanarak yapay sinir ağı çıktı değerindeki hata minimize edilir. Bu değişim oranı zincir kuralı yardımıyla denklem 4.13'deki gibi ifade edilir.

$$\frac{\partial \mathcal{E}(n)}{\partial \omega_{ji}(n)} = \frac{\partial \mathcal{E}(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial \omega_{ji}(n)} \quad (4.13)$$

$\partial \mathcal{E}(n) / \partial \omega_{ji}(n)$  kısmi türevi hassasiyet faktörü olarak adlandırılır ve  $\omega_{ji}$  sinaptik bağlantı ağırlıklarının artı ya da eksi yönde ne kadar değiştirileceğinin belirlenmesini sağlar.

Denklem 4.9'daki matematiksel ifadenin  $e_j(n)$ 'e göre türevi alındığında denklem 4.14'deki ifade,

$$\frac{\partial \mathcal{E}(n)}{\partial e_j(n)} = e_j(n) \quad (4.14)$$

denklem 4.7'deki matematiksel ifadenin  $y_j(n)$ 'e göre türevi alındığında denklem 4.15'deki ifade,

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (4.15)$$

denklem 4.12'deki matematiksel ifadenin  $v_j(n)$ 'e göre türevi alındığında denklem 4.16'daki ifade,

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi_j'(v_j(n)) \quad (4.16)$$

denklem 4.11'deki matematiksel ifadenin  $\omega_{ji}(n)$ 'e göre türevi alındığında denklem 4.17'deki ifade elde edilir.

$$\frac{\partial v_j(n)}{\partial \omega_{ji}(n)} = y_j(n) \quad (4.17)$$

Denklem 4.14 ve denklem 4.17'deki ifadeleri denklem 4.13'de yerine koyduğumuzda denklem 4.18'deki ifadeyi elde ederiz.

$$\frac{\partial \mathcal{E}(n)}{\partial \omega_{ji}(n)} = -e_j(n) \phi'_j(v_j(n)) y_j(n) \quad (4.18)$$

Delta kuralı ile  $\omega_{ji}$ 'ye uygulanacak  $\Delta \omega_{ji}(n)$  düzeltme faktörünü denklem 4.19'daki şekilde ifade edebiliriz.

$$\Delta \omega_{ji}(n) = -\eta \frac{\partial \mathcal{E}(n)}{\partial \omega_{ji}(n)} \quad (4.19)$$

Burada  $\eta$  geri yayılım algoritmasındaki öğrenme oranını ifade etmektedir.

Denklem 4.18'deki ifadeyi denklem 4.19'da kullanarak denklem 4.20'deki ifade elde edilir.

$$\Delta \omega_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (4.20)$$


Buradan sinaptik bağlantıların ağırlıklarına uygulanması gerekli değişikliği ifade eden kısmi değişim derecesi  $\delta_j(n)$ , denklem 4.21'deki şekilde ifade edilir.

$$\delta_j(n) = \frac{\partial \mathcal{E}(n)}{\partial v_i(n)} = \frac{\partial \mathcal{E}(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = e_j(n) \phi'_j(v_j(n)) \quad (4.21)$$

Denklem 4.20 ve 4.21'den anlaşılacağı üzere ağırlık düzeltme  $\Delta \omega_{ji}(n)$  değerinin hesabında en önemli unsur hata sinyali  $e_j(n)$ 'dir. Bu nedenle  $j$  nöronunun nerede olduğuna bağlı olarak iki farklı durum ortaya çıkmaktadır (Haykin, 2009).

Birinci durumda  $j$  nöronunun çıktı katmanında olduğunu kabul edersek, eğitim verileri içerisinde olan hedef çıktı değeri ve denklem 4.7 ile hata sinyali kolaylıkla hesaplanırken, denklem 4.21 ile de kısmi değişim derecesi  $\delta_j(n)$  hesaplanarak bağlantı ağırlıkları değiştirilir (Haykin, 2009).

İkinci durum ise  $j$  nöronunun gizli katmanda olduğu durumdur ki bu durumda,  $j$  nöronu için doğrudan tanımlanmış bir çıktı değeri olmadığından çıktı katmanındaki nöronda oluşturularak Şekil 4.7’de gösterildiği gibi geriye doğru  $j$  nöronu ile doğrudan bağlantılı tüm nöronlar üzerinden taşınan hata sinyali ve bu sinyale bağlı olarak hesaplanan kısmi değişim derecesi  $\delta_j(n)$  tespiti karmaşık bir hal alacağından yapay sinir ağının geliştirilmesi daha zordur (Haykin, 2009).



Şekil 4.9. Çıktı katmanının gizli katmana bağlı olduğu ve hata sinyalini de gösteren şematik sinyal akışı (Haykin, 2009)

Durum ikiye örnek olarak Şekil 4.9’daki ağ yapısı ele alındığında, denklem 4.21 ve 4.16 yardımıyla gizli katmandaki  $j$  nöronunun kısmi değişim derecesi  $\delta_j(n)$ ,

$$\delta_j(n) = \frac{\partial \mathcal{E}(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = - \frac{\partial \mathcal{E}(n)}{\partial y_j(n)} \varphi'_j(v_j(n)) \quad (4.22)$$

olarak hesaplanır.

Sinir ağının toplam ani hata enerjisini  $\mathcal{E}(n)$ ,

$$\mathcal{E}(n) = \frac{1}{2} \sum_{k \in C} e_k^2(n) \quad (4.23)$$

Olduğuna göre bu denklemin  $y_j(n)$ 'e göre türevini alarak,

$$\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)} \quad (4.24)$$

denklemini elde ederiz.

$\partial e_k(n)/\partial y_j(n)$  kısmi türevine göre zincir kuralı uygulandığında denklem 4.24'ü denklem 4.25'deki şekilde ifade edebiliriz.

$$\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (4.25)$$

Çıktı katmanındaki  $k$  nöronu için hata sinyali  $e_k(n)$ ,

$$e_k(n) = d_k(n) - y_k(n) = d_k(n) - \varphi_k(v_k(n)) \quad (4.26)$$

ve denklem 4.15 ve 4.16'den yararlanılarak zincir kuralına göre denklem 4.27'dek ifade yazılır.

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi'_k(v_k(n)) \quad (4.27)$$

Aynı zamanda Şekil 4.9'daki  $k$  nöronu için,

$$v_k(n) = \sum_{j=0}^m \omega_{kj}(n) y_j(n) \quad (4.28)$$

Denklemleri yazılabilir. Denklem 4.28'in  $y_j(n)$ 'e göre türevi alındığında,

$$\frac{\partial v_k(n)}{\partial y_j(n)} = \omega_{kj}(n) \quad (4.29)$$

Denklem 4.27 ve 4.29'u denklem 4.25'de kullanarak,

$$\frac{\partial \mathcal{E}(n)}{\partial y_j(n)} = - \sum_k e_k(n) \varphi'_k(v_k(n)) \omega_{kj}(n) = - \sum_k \delta_k(n) \omega_{kj}(n) \quad (4.30)$$

İfadesi elde edilir.

Sonuç olarak denklem 4.30'u denklem 4.22'de kullanarak gizli katmandaki  $j$  nöronunun kısmi değişim derecesi  $\delta_j(n)$  için geri yayılım formülü denklem 4.30'daki şekilde ifade edilir.

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) \omega_{kj}(n) \quad (4.31)$$

#### 4.4. Yapay Sinir Ağı Eğitim Algoritmaları

Dik iniş (Steepest descent) algoritması aynı zamanda hata geriye yayılım algoritması olarak da bilinmekte olup, geçmişten bu yana yaygın bir kullanımı olsa da bağlantı sayısının yüksek olduğu durumlarda sinir ağını eğitmek çok uzun bir süreç gerektirmekte hatta bazı durumlarda uygulanabilir olmaktan çıkmaktadır. Aynı zamanda bu algoritma düşük yakınsama hızından dolayı yetersiz algoritma olarak bilinmektedir (Johansson, vd., 1992).

Bu sorunu gidermek adına, verileri ön işlemde geçirerek problemin boyutunu azaltmak, bazı yansıma ve ön tahminlerde bulunmak gibi yöntemlerin yanı sıra çok güçlü bilgisayarlar kullanmak da hata geriye yayılım algoritmasının yavaş olan öğrenme hızına karşı bir çözüm olarak kullanılmıştır (Johansson, vd., 1992).

Hata geriye yayılım algoritmasının dezavantajını ortadan kaldırmak adına uygulanan bir diğer ve en önemli yöntem ise nümerik optimizasyon teorisi uygulanarak geri yayılım algoritmasının öğrenme hızının iyileştirilmesidir (Johansson, vd., 1992).

#### 4.4.1. Levenberg-Marquardt

Dik iniş (Steepest descent) algoritmasının öğrenme hızının düşük olduğu yukarıda ifade edilmiştir. Bir diğer algoritma olan Gauss-Newton algoritmasını değerlendirmek adına, hata fonksiyonunun ikinci dereceden türevleri alınarak oluşan bir hata yüzeyini ele aldığımızda, Gauss-Newton algoritması bu hata yüzeyinde her istikamette uygun değişim oranını belirleme kabiliyetine sahiptir. Hatta Gauss-Newton algoritması ikinci dereceden değişim oranı belirlemenin anlamlı olduğu yani hata yüzeyinin konveks olduğu ve 2.dereceden türevinin alınabildiği durumdaki hata fonksiyonlarında çok hızlı yakınsama özelliğine sahipken diğer durumlarda genellikle ıraksatır (Yu ve Wilamowski, 2011).

Levenberg-Marquardt algoritması ise, Kenneth Levenberg ve Donald Marquardt tarafından birbirinden bağımsız iki çalışma ile dik iniş (Steepest descent) algoritmasının kararlılığı ve Gauss-Newton algoritmasının hızını birleştiren bir eğitim algoritması olarak geliştirilmiş ve doğrusal olmayan fonksiyonların nümerik çözümü için yaygın olarak kullanılan bir algoritmadır. Bu algoritmaya ait güncelleme 1'de verilmiştir. (Çavuşlu, vd., 2012)

$$\Delta w = (J^T J + \mu I)^{-1} J^T e \quad (4.32)$$

Burada;

w: ağırlık vektörünü,

I: birim matrisi,

$\mu$ : kombinasyon katsayısını,

J: (PXM)XN boyutunda Jacobian matrisini,

e: (PXM)XI boyutunda hata vektörünü,

P: eğitim örnek sayısını,

M: çıkış sayısını,

N: ağırlık sayısını göstermektedir.

$\mu$  ayarlanabilir bir parametredir ve eğer bu parametre çok büyükse Levenberg-Marquardt algoritması dik iniş metodu gibi, çok küçükse Newton metodu gibi işlevini yapmaktadır.

#### 4.4.2. Resilient Backpropagation

Ağırlık değerlerinin güncellenmesi için önerilen bir diğer yöntem Esnek Geri-yayılım (Resilient Backpropagation) algoritmasıdır. Birinci dereceden türevleri kullanan bir algoritmadır. Adım boyutunun iyi belirlenemediği durumlardaki kötü etkileri önlemek için geliştirilmiştir. Algoritma güncelleme yönü olarak o noktadaki türevin işaretini, güncelleme adım boyutu için o noktadaki büyüklüğünü değil algoritmanın belirlediği iki katsayıdan birini ( $n^-$ ,  $n^+$ ) kullanmaktadır. Eğer türevin işareti bir önceki adıma göre değiştiyse, bir tepe atlandığını anlamakta ve adım boyutunu  $n^-$  ile çarparak azaltmakta, değişmediyse  $n^+$  ile çarparak arttırmaktadır. Pratikte  $n^-$  için 0.5,  $n^+$  için 1.2 değerleri kullanılmaktadır. (Amasyalı, 2015).

#### 4.4.3. Scaled Conjugate Gradient

Scaled Conjugate Gradient, eşlenik eğim (Conjugate Gradient) algoritmasının geliştirilmiş bir halidir (Amasyalı, 2015). Bu algoritmada da yukarıda anlatılanlar gibi bir optimizasyon stratejisi izlerken, diğerlerinden farklı olarak arama yönünü (artış-azalış) ve adım boyutunu 2'deki 2. Dereceden yaklaşım denkleminde gelen bilgiler sayesinde daha dikkatli yapmaktadır (Moller, 1990).

$$E(w + y) \approx E(w) + E'(w)^T y + \frac{1}{2} y^T E''(w) y \quad (4.33)$$

#### 4.5. Ham Petrol Boru Hattı Sistemi

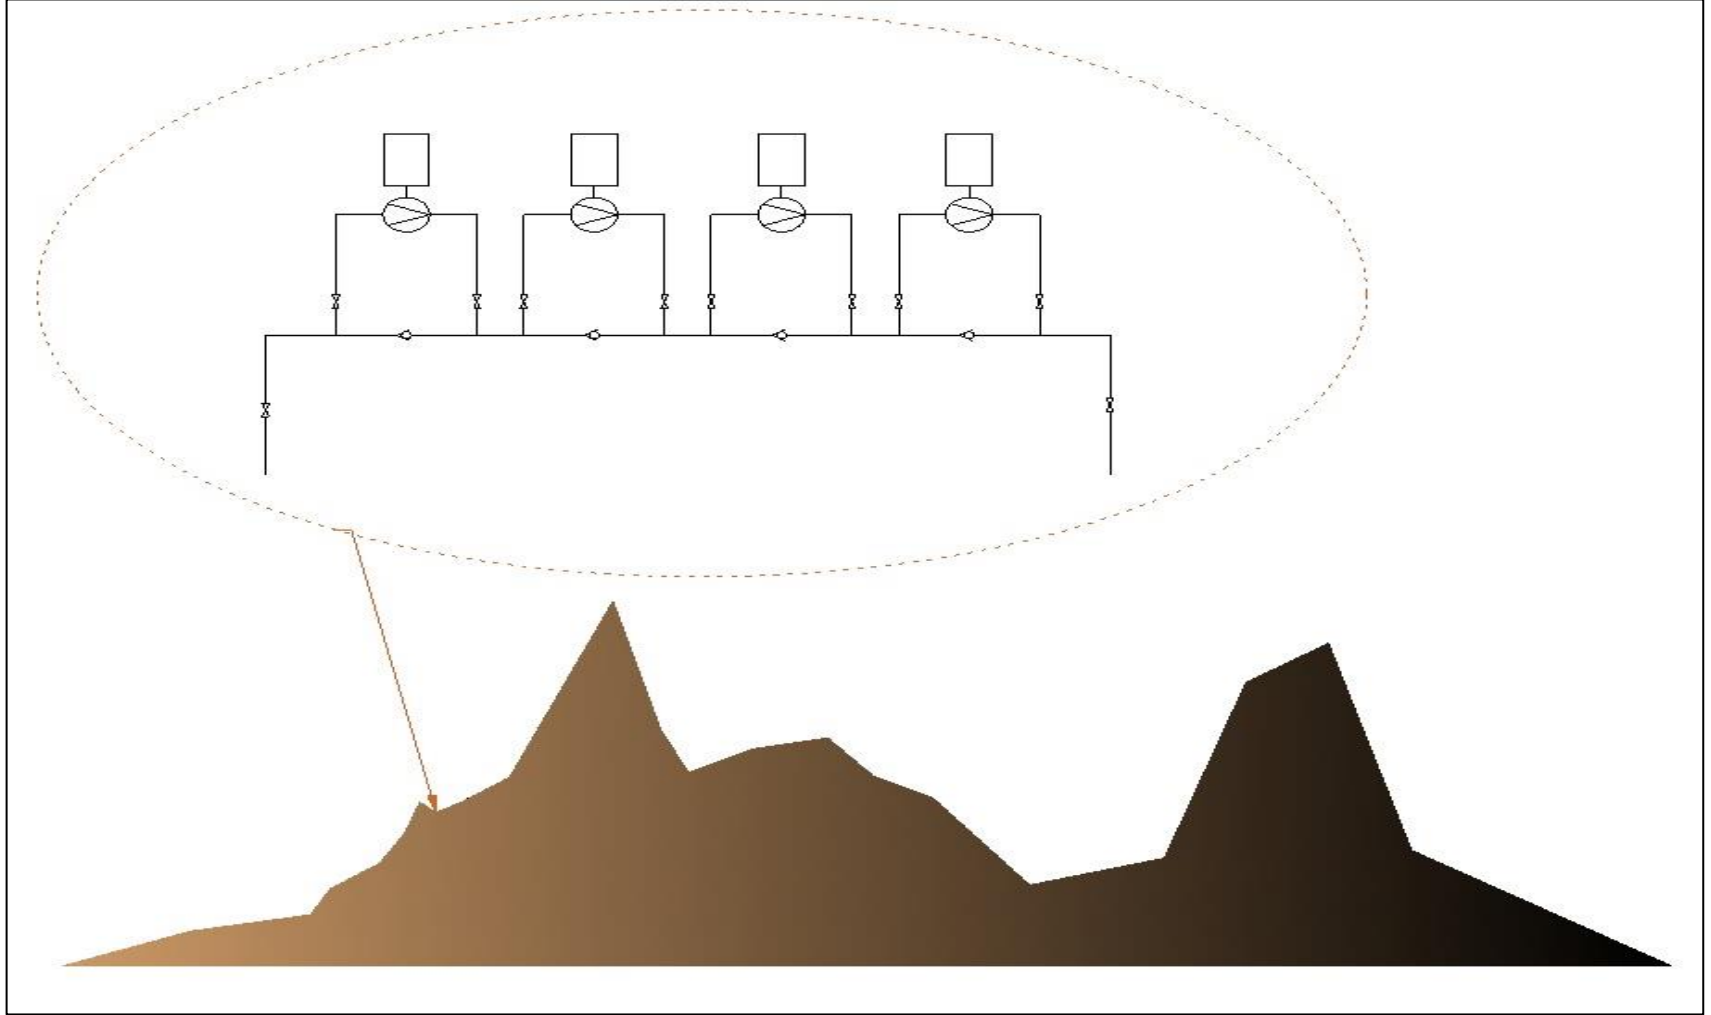
Tez konusu olarak gerçek bir ham petrol boru hattı sistemi ele alınmış olup, boru hattı üzerinde hidrolik profilde farklı konumlardaki eşdeğer santrifüj pompalar ve bu pompaların çalışma verileri kullanılmıştır. Bir pompa istasyonuna ait borulama ve

enstrümantasyon diyagramı (P&I D) Şekil 4.10'da gösterilmiştir. Hidrolik profilde farklı kotlarda bulunan her bir pompa istasyonunda Şekil 4.10'da görüldüğü gibi dört adet seri bağlı pompa bulunmakta olup, genel olarak bu dört pompanın eşit yaşlanma mantığıyla herhangi ikisi çalışmakta diğer ikisi de yedek olarak kullanılmaktadır.

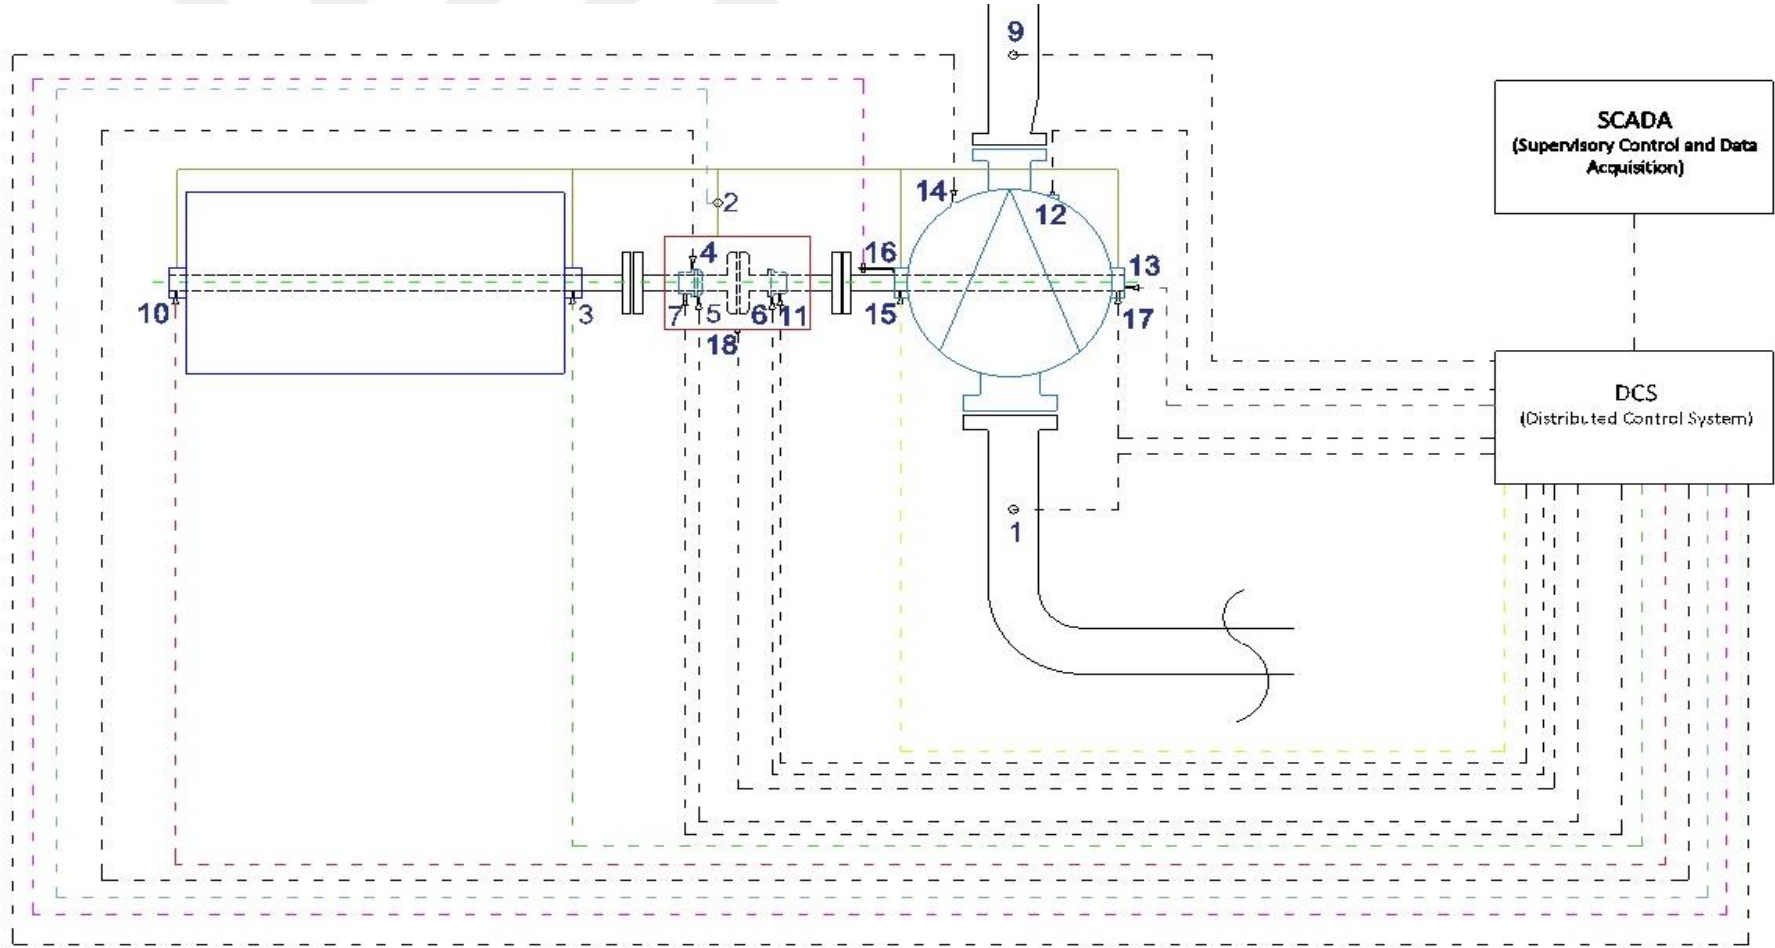
Sistem bütün istasyonları aynı anda kontrol eden uzak bir kontrol merkezi tarafından komuta edilmekte olup, tüm işlemler SCADA (Supervisory Control And Data Acquisition) sistemi üzerinden yürütülmektedir. Pompa istasyonlarında bulunan operatörler sadece sahadaki fiziki durumları ve saha şartları ile SCADA sistemindeki verileri karşılaştırarak merkeze raporlamakta, komuta merkezindeki operatörün (Dispatcher) manuel olarak yapılmasını istediği bir operasyon olması durumunda bu işlemleri yapmaktadır.

SCADA sistemi bir pompa özelinde incelenirse, Şekil 4.11'de görüldüğü gibi pompa ve elektrik motoru üzerinden sıcaklık, devir, titreşim, basınç gibi birçok değer anlık olarak izlenmekte ve her bir değer gerek üretici tavsiyeleri gerekse ulusal ve uluslararası standartlara göre belirlenmiş limit değerler arasında tutulması sağlanmaktadır. SCADA sistemi, değerlerin alt ve üst limitleri geçmesi durumunda kritiklik durumuna göre uyarı vermekten bütün boru hattını durdurmaya kadar önceden tanımlanmış yaptırımları otomatik olarak uygulamak üzere kurgulanmıştır. Çizelge 4.1'de verildiği üzere Şekil 4.11'de gösterilen parametrelerden daha fazlası takip edilmesine rağmen yalnızca çalışma kapsamında ele alınan veriler şematik olarak gösterilmiştir.





Şekil 4.10. Örnek bir boru hattı hidrolik diyagramı ve pompa istasyonu P&I diyagramı



Şekil 4.11. SCADA sistemi ile kontrol edilen pompaya ait enstrümantasyon diyagramı

\*Çizelge 4.1’de verilen 8 nolu elektrik motoru çıkış gücü elektrik panosu üzerinden ölçülmektedir.

Çizelge 4.1 Pompa üzerinden SCADA sistemi tarafından izlenen veriler ve bu verilerin istatistiksel değerleri

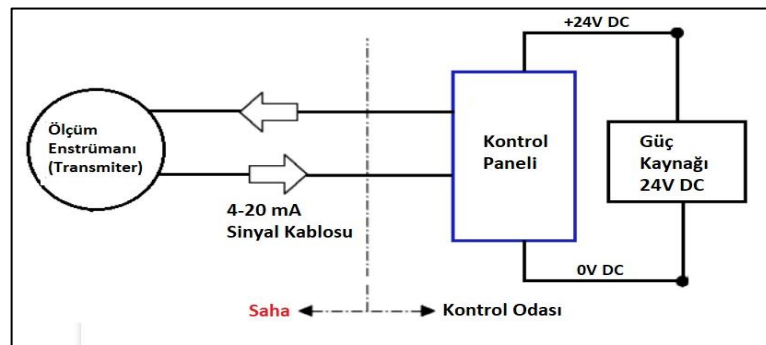
Sıra No	Ölçülen Veri	Birimi	Sembol	Ortalama	Minimum	Maksimum	Standart Sapma
1.	Pompa Emme Basıncı	Bar	P <sub>s</sub>	34,65	18,21	49,19	4,67
2.	Yağlama Basıncı	Bar	P <sub>1</sub>	60,81	37,49	95,45	12,37
3.	Elektrik Motor Yatak Sıcaklığı (Sürücü Ucu)	°C	T <sub>Md</sub>	48,12	33,94	69,69	8,75
4.	Hidrolik Kaplin Eksenel Yatak 1 Sıcaklığı	°C	T <sub>HC1</sub>	55,39	46,99	65,97	4,26
5.	Hidrolik Kaplin Eksenel Yatak 2 Sıcaklığı	°C	T <sub>HC2</sub>	55,11	44,42	61,79	3,15
6.	Hidrolik Kaplin Eksenel Yatak 3 Sıcaklığı	°C	T <sub>HC3</sub>	48,77	39,79	65,41	5,64
7.	Hidrolik Kaplin Radyal Yatak Sıcaklığı (Motor Tarafı)	°C	T <sub>HC4</sub>	44,79	36,69	54,11	4,34
8.	Elektrik Motoru Çıkış Gücü	MW	MP	2,68	0,44	3,62	0,48
9.	Pompa Çıkış Basıncı	Bar	P <sub>D</sub>	55,65	37,17	64,59	4,36
10.	Elektrik Motor Yatak Sıcaklığı (Sürücü olmayan Ucu)	°C	T <sub>Mn</sub>	44,45	33,94	63,71	7,36
11.	Hidrolik Kaplin Radyal Yatak Sıcaklığı (Pompa Tarafı)	°C	T <sub>HC5</sub>	45,89	40,18	57,12	4,41
12.	Pompa Titreşimi	mm/sn	V <sub>P</sub>	4,49	1,10	7,36	1,64
13.	Pompa Eksenel Yatak Sıcaklığı	°C	T <sub>P1</sub>	37,12	28,67	49,26	5,78
14.	Pompa Gövde Sıcaklığı	°C	T <sub>Pc</sub>	36,58	27,96	46,66	3,72
15.	Pompa Radyal Yatak Sıcaklığı (Sürülen Uç)	°C	T <sub>P2</sub>	45,22	37,88	56,37	5,08
16.	Devir	rpm	n	2697,29	1155,86	2887,08	297,19
17.	Pompa Radyal Yatak Sıcaklığı (Sürülmeyen Uç)	°C	T <sub>P3</sub>	46,42	37,23	56,93	5,21
18.	Hidrolik Kaplin Titreşimi	mm/sn	V <sub>HC</sub>	5,06	2,84	6,31	0,67

Her bir ölçüm noktasındaki ilgili enstrüman (termokupl, basınç sensörü, devir sensörü v.b.) ölçüm sonucu oluşan elektrik sinyalini istasyonda bulunan DCS'e (Distributed Control System) iletir. DCS bu sinyali sayısal değere çevirerek, verileri operatör kontrol ekranlarına yansıtır ve aynı zamanda her bir verinin kendisi için tanımlanmış limitler arasında olup olmadığını anlık olarak kontrol eder, bu değerler karşılığında yapılması gereken tanımlanmış bir işlem var ise yapar ve tüm değerleri, var ise uyarı, alarm v.b. ile komutları ana kontrol merkezinde bulunan SCADA sistemine iletir. Tüm bu komutlar, alarm, uyarı ve anlık değerler merkezde kayıt altına alınmaktadır.

#### 4.6. Verilerin Ölçümünde Kullanılan Enstrümanlar

Sistem üzerindeki otomasyon enstrümanları olarak nitelendirdiğimiz bütün ölçüm cihazları, 4-20 mA aralığında çalışmakta olup, bundaki amaç kabloların diğer elektrik kabloları ile etkileşime girerek yanlış sinyal taşınmasını engellemek ve 0 mA yerine 4 mA'den başlama sebebi ise 0 mA değer okunması halinde arızanın kablo hasarı olduğunun hızlı bir şekilde tespit edilebilmesi içindir.


Enstrümanların yapacağı ölçüme özgü iç yapısı ve çalışma şekilleri farklılık gösterse de ölçüm sonucunda elde edilen elektriksel sinyal ve bu sinyalin elde edilme şekli aynıdır. Vericiye (transmitter) güç kaynağından gönderilen 24 V DC 20mA akım, aşağıda herbir ölçüm tekniğinde detayları verildiği şekilde, enstrüman içerisindeki direnç değişikliğine orantılı olarak 4-20 mA arasında bir değer ile geri dönerek kontrol panelinde ilgili akım değerine karşılık kalibre edilmiş sayısal değere dönüştürülür. Tipik bir enstrüman besleme (loop) hattı şematik olarak Şekil 4.12'da gösterilmiştir.



Şekil 4.12. Örnek bir beslemeli ölçüm enstrümanı şematik gösterimi (4-20 mA Transmitter Wiring Types, 2018)


#### 4.6.1. Termo Elemanlar (Termokupl)

Boru hattı sisteminde sıcaklık ölçüm enstrümanı olarak termokupllar seçilmiştir. Kullanılan termokupl Elimko PT 100 modelidir. Termokupl iki farklı metalin birer uçlarının birbirine kaynatılması (sıcak nokta) ve diğer uçlarının (soğuk nokta) ise referans olarak serbest bırakılması prensibiyle çalışmaktadır. Sıcaklık değişimlerinde sıcak nokta ve soğuk nokta olarak adlandırılan kısımlar arasında mV seviyesinde bir voltaj üretilmekte olup, bu voltajın değerine göre standart tablodan kalibre edilen çeviriciler termokupllardan gelen elektriksel sinyali sayısal değer olarak DCS'e iletmektedir. DCS var ise gerekli yaptırımı uygular ve SCADA sistemine rapor eder. Bir termokuplın şematik görünümü ve termokupl setinin kısımları Şekil 4.13'de gösterilmiştir.



Şekil 4.13. Termokupl şematik gösterimi ve termokupl kısımları (Elimko, 2016)

Termokupllar (Şekil 4.14),  $-200^{\circ}\text{C}$ 'den  $+2350^{\circ}\text{C}$ 'ye kadar geniş bir ölçüm aralığına sahip olması ve uzun dönem stabilitesini muhafaza eden bir yapıda olması gibi özellikleri dolayısı ile endüstride çok yaygın kullanılmaktadır.



Şekil 4.14. Termokupl (Elimko, 2016)


#### 4.6.2. Basınç Sensörü

Boru hattı sisteminde basınç sensörü olarak, ABB 266GSH (Şekil 4.15) Gauge basınç vericisi (transmitter) kullanılmaktadır.



Şekil 4.15. ABB266GSH Basınç sensörü (ABB Data Sheet, 2012).

Basınç sensörünün kesit görünümü Şekil 4.16’da verilmiştir.



1. Referans basınç
2. Sensör gövdesi
3. Ölçüm hattı bağlantısı
4. Diyafram
5. Tampon sıvı
6. Bağıl basınç sensörü

$P_e$  Giriş basıncı

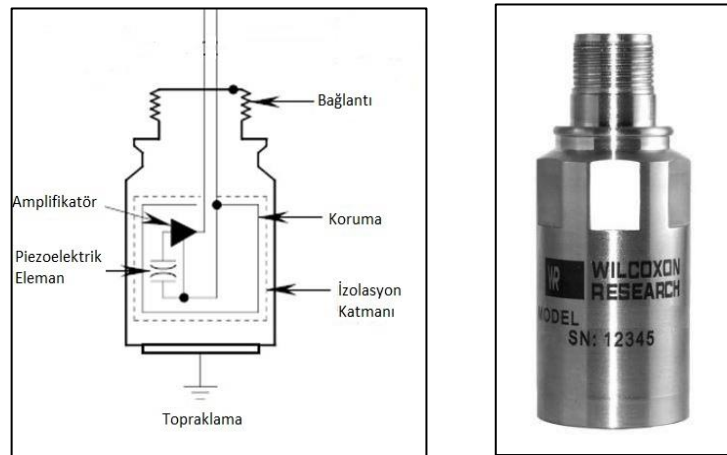
Şekil 4.16. Basınç sensörü kesit görünümü (Gauge and Absolute Pressure Transmitters Principle).

Ölçüm hattına yapılan bağlantıdan giren ham petrol basıncı diyafram vasıtasıyla tampon sıvıya taşınmakta, tampon sıvıda oluşan basınç ile bağıl basınç sensörünün diğer tarafındaki referans basınç arasındaki farka göre bağıl basınç sensörünün içindeki piezoelektrik elemanlarının direnci değişir. Bu direnç değişimine göre vericiye dışarıdan beslenen 20 mA akımın değeri değişerek vericiden çıkar, daha önceden ilgili enstrümandan gelecek bu elektriksel sinyalin sayısal karşılığına göre kalibre edilmiş DCS bu akımı sayısal değere çevirir ve var ise gerekli yaptırım uygular ve SCADA sistemine rapor eder.

#### 4.6.3. Titreşim Sensörü

Boru hattı sistemindeki pompalar ve titreşim ölçümü yapılan diğer ekipmanlarda ölçüm için Wilcoxon marka PC420AR model ivme sensörü kullanılmaktadır. Enstrüman ivme sensörü olarak adlandırılmış olsa da çıkan sinyal hız olarak da çevrilebilmekte olup, sistemde ölçülen titreşim değeri olarak hız birimi (mm/sn) kullanılmaktadır.

Titreşim ölçümü için kullanılan sensörün içerisinde bulunan piezoelektrik eleman, oluşan titreşime orantılı olarak direncini değiştirmekte ve sensöre dışarıdan beslenen 20 mA akımın değeri değişerek DCS'e gitmekte, burada sayısal değere dönüşmekle beraber var ise bu değere karşılık gelen yaptırım uygulanır ve SCADA sistemine rapor edilir. Tipik bir ivme sensörünün şematik görünümü Şekil 4.17'de gösterilmiştir.



Şekil 4.17. İvme sensörü şematik görünümü ve Wilcoxon PC420AR sensör (SKF, 1999)


#### 4.6.4. Devir Sensörü

Boru hattı sistemindeki pompaların ve elektrik motorlarının devir ölçümü için Pepperl+Fuchs marka NCB5-18GM40-N0 (Şekil 4.18) model endüktif yaklaşım sensörü kullanılmaktadır.



Şekil 4.18. Pepperl+Fuchs NCB5-18GM40-N0 yaklaşım sensörü (Pepperl+Fuchs, 2018)

Tipik bir endüktif yaklaşım sistemi şematik olarak Şekil 4.19’da gösterilmiştir. Sensörün ölçüm ucunda oluşan manyetik alana giriş çıkış yapan metalik hedef dişlinin, girdap akımı (Eddy current) etkisiyle kendi manyetik alanı oluşur. Daha sonra ölçümü yapılan bu metalik dişlinin manyetik alanı, sensörün ucunda oluşan manyetik alanı saptırır. Sensörün manyetik alanındaki bu sapma sensör çıkışındaki elektriksel sinyalin değerini değiştirir. Bu değişim DCS’de sayısal değere dönüştürülerek devir ölçümü yapılır.



Şekil 4.19. Endüktif yaklaşım sensörü şematik gösterimi (Electrical Engineering Blog, 2012)



#### 4.6.5. Çalışmada kullanılan veriler

Bu çalışmada yukarıda açıklanan boru hattı sistemindeki otomasyon enstrümanları ile anlık olarak izlenen ve sistemi her parametre için tanımlanmış değer aralıklarında kontrol etmek üzere programlanmış bir SCADA sisteminde kayıt altına alınmış olan veriler kullanılmıştır. Her pompa için saat başı otomatik olarak kayıt altına alınmış olan 18 farklı ölçümün iki yıllık bir süre boyunca toplanan ve her birinden 17545 adet olmak üzere toplam 350900 veri ele alınmıştır.

Veriler pompanın çalışmakta olmasından bağımsız olarak saat başı otomatik olarak kayıt altına alındığından öncelikle pompanın çalışmadığı (motor akım değerinin 0 olduğu) veriler elenmiştir. Böylece geriye her bir parametreden 5572 adet olmak üzere toplam 100296 adet çalışma anına ait veri kalmıştır.

Çalışmanın hedefi, pompadaki titreşim değerinin oluşturulan yapay sinir ağı ile tespit edilmesi ve bu değer ile gerçekte ölçülen değer arasında oluşabilecek sapmalardan arıza tespiti yapmak olduğundan, kullanılacak verilerin titreşim değeri ile olan bağıntılarını değerlendirmek adına her değerden maksimum ve minimum aralığında 78 adet olmak üzere 1404 veriden oluşan bir matris, yapay sinir ağı modelinin oluşturulacağı MATLAB programına aktarılarak incelenmiş ve Çizelge 4.2'deki sonuç elde edilmiştir.

Doğru bir yapay sinir ağı modellemesinde girdi olarak kullanılacak verilerin çıktı değeri ile olan korelasyon değerinin 0,6'dan büyük olması gerektiği değerlendirilmiştir (Bechrakis ve Sparis, 2004 , Bilgili ve Sahin, 2010). Ancak bu çalışma kapsamında modellenecek yapay sinir ağı modeline girdi sayısının etkisini de incelemek adına eldeki 17 farklı ölçümün çıktı olarak elde etmek istediğimiz titreşim değeri ile 0,55 ve üzeri bağıntı görülen ve bu nedenle anlamlı olduğu değerlendirilen 7 adedi ile yapay sinir ağı modelinin oluşturulması hedeflenmiştir.

Çizelge 4.2 Yapay sinir ağına girdi olarak kullanılacak verilerin tespiti için parametrelerin titreşim ile korelasyonları

	<b>P<sub>s</sub></b>	<b>P<sub>1</sub></b>	<b>T<sub>Md</sub></b>	<b>T<sub>HC1</sub></b>	<b>T<sub>HC2</sub></b>	<b>T<sub>HC3</sub></b>	<b>T<sub>HC4</sub></b>	<b>MP</b>	<b>P<sub>D</sub></b>	<b>T<sub>Mn</sub></b>	<b>T<sub>HC5</sub></b>	<b>T<sub>P1</sub></b>	<b>T<sub>Pc</sub></b>	<b>T<sub>P2</sub></b>	<b>n</b>	<b>T<sub>P3</sub></b>	<b>V<sub>HC</sub></b>	<b>V<sub>P</sub></b>
<b>P<sub>s</sub></b>	1,00	0,39	-0,17	0,07	0,12	0,37	0,15	-0,34	0,50	-0,12	0,14	0,02	0,11	-0,07	-0,53	0,00	-0,30	-0,41
<b>P<sub>1</sub></b>	0,39	1,00	-0,06	0,25	0,16	0,66	0,22	-0,44	-0,25	-0,03	0,31	0,07	0,03	-0,06	-0,58	-0,09	0,27	-0,55
<b>T<sub>Md</sub></b>	-0,17	-0,06	1,00	0,53	0,54	0,25	0,33	-0,05	0,18	0,65	0,49	0,63	-0,01	0,55	0,31	0,57	-0,06	0,65
<b>T<sub>HC1</sub></b>	0,07	0,25	0,53	1,00	0,95	0,73	0,92	-0,06	0,31	0,64	0,94	0,93	0,47	0,90	0,22	0,90	0,17	0,39
<b>T<sub>HC2</sub></b>	0,12	0,16	0,54	0,95	1,00	0,72	0,85	0,06	0,44	0,59	0,91	0,87	0,36	0,86	0,32	0,90	0,17	0,41
<b>T<sub>HC3</sub></b>	0,37	0,66	0,25	0,73	0,72	1,00	0,73	-0,34	0,06	0,26	0,83	0,57	0,30	0,50	-0,26	0,51	0,26	-0,13
<b>T<sub>HC4</sub></b>	0,15	0,22	0,33	0,92	0,85	0,73	1,00	-0,17	0,22	0,52	0,93	0,87	0,61	0,88	0,04	0,84	0,09	0,23
<b>MP</b>	-0,34	-0,44	-0,05	-0,06	0,06	-0,34	-0,17	1,00	0,26	0,04	-0,19	-0,12	-0,39	-0,01	0,78	0,01	0,14	0,15
<b>P<sub>D</sub></b>	0,50	-0,25	0,18	0,31	0,44	0,06	0,22	0,26	1,00	0,27	0,22	0,31	0,14	0,34	0,41	0,46	-0,17	0,37
<b>T<sub>Mn</sub></b>	-0,12	-0,03	0,65	0,64	0,59	0,26	0,52	0,04	0,27	1,00	0,56	0,72	0,26	0,66	0,31	0,67	-0,05	0,59
<b>T<sub>HC5</sub></b>	0,14	0,31	0,49	0,94	0,91	0,83	0,93	-0,19	0,22	0,56	1,00	0,88	0,45	0,85	0,07	0,85	0,18	0,30
<b>T<sub>P1</sub></b>	0,02	0,07	0,63	0,93	0,87	0,57	0,87	-0,12	0,31	0,72	0,88	1,00	0,49	0,91	0,23	0,93	-0,04	0,56
<b>T<sub>Pc</sub></b>	0,11	0,03	-0,01	0,47	0,36	0,30	0,61	-0,39	0,14	0,26	0,45	0,49	1,00	0,58	-0,11	0,51	-0,07	0,22
<b>T<sub>P2</sub></b>	-0,07	-0,06	0,55	0,90	0,86	0,50	0,88	-0,01	0,34	0,66	0,85	0,91	0,58	1,00	0,35	0,96	0,11	0,57
<b>n</b>	-0,53	-0,58	0,31	0,22	0,32	-0,26	0,04	0,78	0,41	0,31	0,07	0,23	-0,11	0,35	1,00	0,39	0,22	0,65
<b>T<sub>P3</sub></b>	0,00	-0,09	0,57	0,90	0,90	0,51	0,84	0,01	0,46	0,67	0,85	0,93	0,51	0,96	0,39	1,00	0,07	0,61
<b>V<sub>HC</sub></b>	-0,30	0,27	-0,06	0,17	0,17	0,26	0,09	0,14	-0,17	-0,05	0,18	-0,04	-0,07	0,11	0,22	0,07	1,00	-0,07
<b>V<sub>P</sub></b>	-0,41	-0,55	0,65	0,39	0,41	-0,13	0,23	0,15	0,37	0,59	0,30	0,56	0,22	0,57	0,65	0,61	-0,07	1,00

Daha önce pompanın çalışma anı verileri olarak filtrelenen ve her parametre için 5572 adede indirgenen veriler, bağıntı incelemesi sonrası tekrar filtrelenerek ölçüm hatası, arıza ve diğer parametrelerde veri alınmasına rağmen parametrelerden birini ölçen enstrümanın değer almadığı ve çalışmayı olumsuz etkileyeceği değerlendirilen veriler de elenerek her bir parametre için 5270 veri olmak üzere toplam 42160 veriye düşürülmüştür.

Geriye kalan verilerden de pompanın kararlı (stabil) çalışma aralığında olmadığı, devreye girme ve devreden çıkma anlarındaki değerler elemine edilerek, titreşim değerinin maksimum ve minimum aralığında olacak şekilde her bir değer için 250, 500 ve 1000 adet veriden oluşan matrisler oluşturulmuştur. Bu matrisler yapay sinir ağı modeli oluşturulurken veri sayısının yapay sinir ağının başarısına olan etkisi değerlendirilmek amacıyla oluşturulmuştur.

Boru hattı sistemindeki pompa titreşim limit değerleri ISO 10816-3 standardı doğrultusunda belirlenmiştir. ISO 10816-3 standardı makine türüne göre sınıflandırılmış titreşim şiddeti değerleri Çizelge 4.3’de gösterilmiştir.

Çizelge 4.3 ISO 10816 Standardına göre makine titreşimi limit değerleri tablosu

								Titreşim Hızı (mm/sn)	
									11
									7.1
									4.5
									3.5
									2.8
									2.3
									1.4
									0.71
Esnek Olmayan	Esnek	Esnek Olmayan	Esnek	Esnek Olmayan	Esnek	Esnek Olmayan	Esnek		<b>Temel</b>
Pompa > 15 kW				Orta Ölçekli Makineler 15 kW < P < 300 kW		Büyük Ölçekli Makineler 300 kW < P < 50 MW		<b>Makine Tipi</b>	
Bütünleşik		Harici Sürücü		Motor 160 mm ≤ H ≤ 315 mm		Motor 315 mm ≤ H			
Grup 4		Grup 3		Grup 2		Grup 1		<b>Grup</b>	
								Kısa dönem çalışmasına müsaade edilebilir	
								Kabul edilemez	

Pompanın sağlıklı olarak değerlendirilebileceği, kabul edilebilir titreşim hızı limiti olarak belirlenen 7 mm/sn'ye kadar olan titreşim değerleri ve bu değerlere karşılık gelen diğer parametre verileri çalışmada kullanılmıştır. Böylece pompanın sağlıklı çalışma koşullarına göre eğitilmiş bir yapay sinir ağı elde edilmeye çalışılmış ve kabul edilebilir aralık olmasına rağmen 0-7 mm/sn titreşim değer aralığında titreşim değerinde oluşabilecek bir sapma neticesinde arıza tespiti hedeflenmiştir. Titreşim üst limiti olan 7 mm/sn değerinin üzerindeki durumlar zaten sağlıklı çalışma koşulları ya da arıza durumu olarak değerlendirildiğinden bu çalışma kapsamı dışında tutulmuştur.

## 4.7. Matlab ve Yapay Sinir Ağı Modeli

### 4.7.1. Matlab

Matlab ismi Matrix Laboratory (matriks laboratuvarı) ifadesinden gelmektedir. Matlab, teknik hesaplamalar için oluşturulmuş, hesaplama, görselleştirme ve programlama bir araya getirilerek, matematiksel olarak ifade edilebilen problemleri kolay kullanılabilir şekilde çözebilen yüksek performanslı bir programlama dilidir.

Matlab'ın temel kullanım alanları;

- Matematik ve hesaplama,
- Algoritma geliştirme,
- Veri toplama,
- Modelleme, simülasyon ve prototipleme,
- Veri analizi, araştırma ve görselleştirme,
- Bilimsel ve mühendislik grafikleri
- Kullanıcı ara yüz grafiği dahil uygulama geliştirmedir.

Matlab yazılımı içerisinde özel uygulamalar için geliştirilmiş araç kutusu (toolbox) adı verilen eklentileri mevcuttur. Konuya özel araç kutularına örnek verecek olursak;

- Sinyal işleme,
- Kontrol sistemleri,
- Yapay sinir ağları,


➤ Bulanık mantık,

Gibi birçok örnek verebiliriz (Matlab, 2005)

#### 4.7.2. Matlab Yapay Sinir Ağı Araç Kutusu (Neural Network Toolbox)

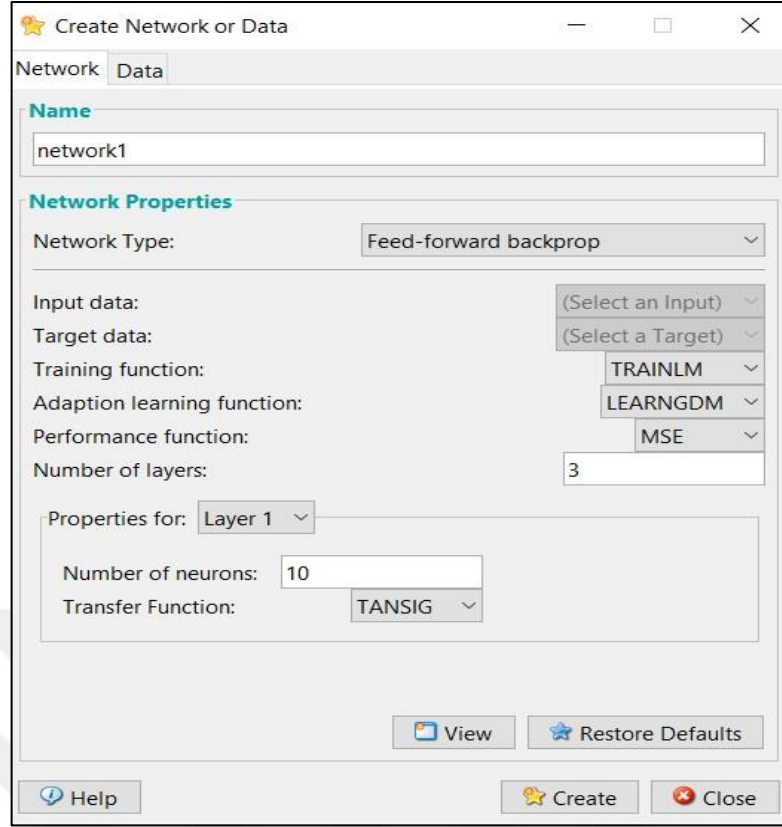
Matlab yazılımında yapay sinir ağı doğrudan komut sayfasına kod yazılarak oluşturulabileceği gibi, kullanım kolaylığı için oluşturulmuş yapay sinir ağı araç kutusu (neural network toolbox) ara yüzü yardımı ile de hızlı bir şekilde oluşturulmak istenen yapay sinir ağının yapısı ve öğrenme algoritması, öğrenme fonksiyonu, katman sayısı, gizli katmandaki nöron sayısı ve transfer fonksiyonu gibi seçeneklerden uygun olanları seçerek yapay sinir ağının oluşturulmasına olanak sağlamaktadır.

Bu arayüzü kullanmak için komut penceresine nntool yazıp enter tuşuna basıldığında Şekil 4.20’de ekran görülmektedir.




Şekil 4.20. MATLAB Yapay sinir ağı araç kutusu

Bu pencerede import seçeneği ile yapay sinir ağı için oluşturulan eğitim ve test verileri input (girdi) ve target (hedef,çıktı) alanlarına yüklendikten sonra new seçeneği ile Şekil 4.21’deki pencere ekrana gelmektedir. Bu pencereden de oluşturulmak istenen ağın yapısı ve özelliklerine göre tercihler seçilerek create seçeneği ile yapay sinir ağı modeli tamamlanmaktadır.



Şekil 4.21. Yapay sinir ağı araç kutusu sinir ağı tipi ve diğer fonksiyonların seçimi

Örnek bir yapay sinir ağı modeli Şekil 4.22’de gösterilmiştir. Bu aşamadan sonra ağ istenilen hassasiyet elde edilinceye kadar birkaç kez eğitim komutu (train network) ile eğitilir ve ağın yapısında yapılmak istenen değişiklikler var ise aynı işlemler tekrar edilerek en iyi sonuç elde edilebilir.



Şekil 4.22. MATLAB Yapay sinir ağı araç kutusu ile oluşturulan örnek bir sinir ağı modeli

#### 4.8. Oluşturulan Yapay Sinir Ağı Modeli

Gizli katmanı olmayan, yalnızca girdi ve çıktı katmanlarından oluşan bir yapay sinir ağının nonlinear problemlerde başarılı olmadığı bilinmektedir. Bununla beraber, dört ya da daha fazla katmandan oluşan yapay sinir ağı modeli de çok nadiren kullanılmıştır. Çıktı katmanındaki transfer fonksiyonunun lineer ya da nonlinear olmasından bağımsız olarak, en az üç katmandan oluşan bir sinir ağının gizli katmandaki nöronların transfer fonksiyonları nonlinear olmaktadır. İleri beslemeli yapıda ve üç katmandan oluşan yapay sinir ağları literatürdeki her uygulamada başarılı olmuştur (Scarselli ve Tsoi, 1998). Bu çalışmadaki yapay sinir ağı yapısı da ileri beslemeli olarak seçilmiştir.

Geriye yayılım (Backpropagation) öğrenme algoritması, Werbos (Werbos, 1974), Parker (Parker, 1982) ve Rumelhart ve arkadaşları (Rumelhart, vd., 1986) tarafından birbirinden bağımsız üç çalışma ile geliştirilmiş bir algoritma modeli olup, günümüzde birçok alanda yapılan yapay sinir ağı çalışmalarında en çok kullanılan algoritma olmuştur (Kang ve Yoon, 1994).

Her ne kadar farklı öğrenme algoritma modelleri olsa da, gerek yapay sinir ağı çalışmalarında en çok tercih edilen model olması gerekse bu çalışmada planlanan sinir ağı yapısına en uygun öğrenme algoritması modeli olması dolayısıyla geriye yayılım (backpropagation) modeli tercih edilmiştir. Geriye yayılım öğrenme algoritmasında, bu çalışmada da hedeflediğimiz şekilde, eğitim aşamasında verilen girdilere karşın sinir ağına verilen çıktı değerleri sinir ağı tarafından hesaplanan değerler ile karşılaştırılarak aradaki hatayı en aza indirgeyecek şekilde geriye doğru nöronlar arasındaki ağırlıkların değiştirilerek iterasyona devam edilmektedir (Fırat ve Güngör, 2004).

Bu çalışmada, yukarıda anıldığı üzere en uygun yapay sinir ağı yapısının ileri beslemeli (feedforward) ve öğrenme algoritmasını geriye yayılım (backpropagation) modeli olduğu değerlendirilmiştir. Bunun haricinde girdi sayısı, ara katmandaki nöron sayısı, transfer fonksiyonu, öğrenme fonksiyonu gibi değişkenlerden en iyi kombinasyonun tespiti için Çizelge 4.3'deki kombinasyonlar ile ayrı ayrı yapay sinir

ağları oluşturulmuş ve her bir sinir ağından elde edilen sonuçlar ile gerçek değerler arasındaki farkların RMSE (root mean square error) değeri baz alınarak bütün sinir ağı modelleri değerlendirilmiştir. Elde edilen en iyi sinir ağı modelleri ile veri sayısı ve gizli katmandaki nöron sayısı artırılarak tekrar bir değerlendirme yapılmış ve en iyi yapay sinir ağı modeli belirlenmiştir.

Çizelge 4.4 En uygun YSA modelinin tespiti için oluşturulması planlanan YSA'lar

			250 VERİ								
Öğrenme Algoritması			Levenberg Marquardt			Resilient Backpropagation			Scaled Conjugate Gradient		
Ara Katman Transfer Fonksiyonu			Tansig	Purelin	Logsig	Tansig	Purelin	Logsig	Tansig	Purelin	Logsig
Girdi Sayısı	Ara Katman Sayısı	Nöron Sayısı									
2	1	1	YSA 1	YSA 19	YSA 37	YSA 55	YSA 73	YSA 91	YSA 109	YSA 127	YSA 145
2		7	YSA 2	YSA 20	YSA 38	YSA 56	YSA 74	YSA 92	YSA 110	YSA 128	YSA 146
2		14	YSA 3	YSA 21	YSA 39	YSA 57	YSA 75	YSA 93	YSA 111	YSA 129	YSA 147
3	1	1	YSA 4	YSA 22	YSA 40	YSA 58	YSA 76	YSA 94	YSA 112	YSA 130	YSA 148
3		7	YSA 5	YSA 23	YSA 41	YSA 59	YSA 77	YSA 95	YSA 113	YSA 131	YSA 149
3		14	YSA 6	YSA 24	YSA 42	YSA 60	YSA 78	YSA 96	YSA 114	YSA 132	YSA 150
4	1	1	YSA 7	YSA 25	YSA 43	YSA 61	YSA 79	YSA 97	YSA 115	YSA 133	YSA 151
4		7	YSA 8	YSA 26	YSA 44	YSA 62	YSA 80	YSA 98	YSA 116	YSA 134	YSA 152
4		14	YSA 9	YSA 27	YSA 45	YSA 63	YSA 81	YSA 99	YSA 117	YSA 135	YSA 153
5	1	1	YSA 10	YSA 28	YSA 46	YSA 64	YSA 82	YSA 100	YSA 118	YSA 136	YSA 154
5		7	YSA 11	YSA 29	YSA 47	YSA 65	YSA 83	YSA 101	YSA 119	YSA 137	YSA 155
5		14	YSA 12	YSA 30	YSA 48	YSA 66	YSA 84	YSA 102	YSA 120	YSA 138	YSA 156
6	1	1	YSA 13	YSA 31	YSA 49	YSA 67	YSA 85	YSA 103	YSA 121	YSA 139	YSA 157
6		7	YSA 14	YSA 32	YSA 50	YSA 68	YSA 86	YSA 104	YSA 122	YSA 140	YSA 158
6		14	YSA 15	YSA 33	YSA 51	YSA 69	YSA 87	YSA 105	YSA 123	YSA 141	YSA 159
7	1	1	YSA 16	YSA 34	YSA 52	YSA 70	YSA 88	YSA 106	YSA 124	YSA 142	YSA 160
7		7	YSA 17	YSA 35	YSA 53	YSA 71	YSA 89	YSA 107	YSA 125	YSA 143	YSA 161
7		14	YSA 18	YSA 36	YSA 54	YSA 72	YSA 90	YSA 108	YSA 126	YSA 144	YSA 162



## 5. BULGULAR ve TARTIŞMA

Çalışmada hedeflenen yapay sinir ağı modellenmesi için en uygun seçeneklerin (girdi sayısı, ara katmandaki nöron sayısı, transfer fonksiyonu, eğitim fonksiyonu) belirlenmesi için Çizelge 4.3'deki yapay sinir ağı kombinasyonları tek tek modellenmiş, ilk olarak her parametreden 250 adet olmak üzere toplam 2000 verilik bir matris ile eğitim ve test edilmiştir.

Çizelge 4.3'de de görüldüğü üzere MATLAB yazılımının yapay sinir ağı modellenmesi için sunduğu her üç transfer fonksiyonu (tan sigmoid, log sigmoid ve purelin) ile bütün yapay sinir ağı modelleri oluşturulması planlanmıştır. Fakat yapısı gereği purelin fonksiyonu lineer bir fonksiyon olduğundan ve modellenmeye çalışılan yapay sinir ağı yapısı non lineer olduğundan, ara katmandaki transfer fonksiyonunun purelin olduğu YSA'lar başlangıçtan itibaren anlamlı sonuçlar vermemiş ve değerlendirme dışı bırakılmıştır.

Yapay sinir ağlarının başarı kriteri olarak, bu tarz çalışmalarda yaygın kullanımı olan hata karelerinin ortalamasının kare kökü (root mean square error) değeri baz alınmıştır (Barnston, 1992). Hata karelerinin ortalamasının karekökü, iki veri serisi arasındaki farkı ya da sapma miktarını değerlendirmekte kullanılmaktadır. Bu çalışma özelinde değerlendirecek olursak gerçek titreşim değerleri ve bu değerler karşılığında yapay sinir ağının tahmin ettiği değerler arasındaki farklar hata olarak 5.1, 5.2, 5.3 ve 5.4'teki formüller ile hesaplanmıştır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - O_i)^2} \quad (5.1)$$

$$MAPE (\%) = \frac{1}{n} \left( \sum_{i=1}^n \frac{|O_i - P_i|}{|O_i|} \right) \times 100 \quad (5.2)$$

$$MAE = \frac{1}{n} \left( \sum_{i=1}^n |O_i - P_i| \right) \quad (5.3)$$

$$R = \frac{\sum(O_i - \bar{O}_i)(P_i - \bar{P}_i)}{\sqrt{\sum(O_i - \bar{O}_i)^2(P_i - \bar{P}_i)^2}} \quad (5.4)$$

Burada;

P: Tahmin edilen deęer,

$\bar{P}$ : Tahmin edilen deęerlerin ortalaması,

O: Gerçek deęer,

$\bar{O}$ : Gerçek deęerlerin ortalaması,

n: Veri sayısıdır.

Modellenen her yapay sinir aęının en iyi performansını gormek iin birkaç kez eęitim tekrar edilmiř, her eęitim ve test alıřmasının ardından aęın bařarisını gosteren grafikler incelenmiř, mevcut yapay sinir aęı modeliyle daha iyi bir sonu elde edilemedięine ikna olunduęunda soz konusu yapay sinir aęı modeli iin en iyi durum kayıt altına alınmıřtır.

Her bir yapay sinir aęı modelini kayıt altına almak iin bir kodlama sistemi oluřturulmuř ve son halleri 5.5'de verilen ornekteki kodlama mantıęıyla adlandırılarak kayıt edilmiřtir.

Lm250714tansig (5.5)

Burada;

Lm :Eęitim fonksiyonunu


250 :Eęitim verileri sayısını

7 :Girdi sayısını


14 :Gizli katmandaki noron sayısını

tansig :Transfer fonksiyonunu ifade etmektedir.


Eęitim sırasında incelenen grafiklerden en iyi sonu alınan u tanesi řekil 5.1'de gosterilmiřtir.



a) Lm250714logsig YSA modeli



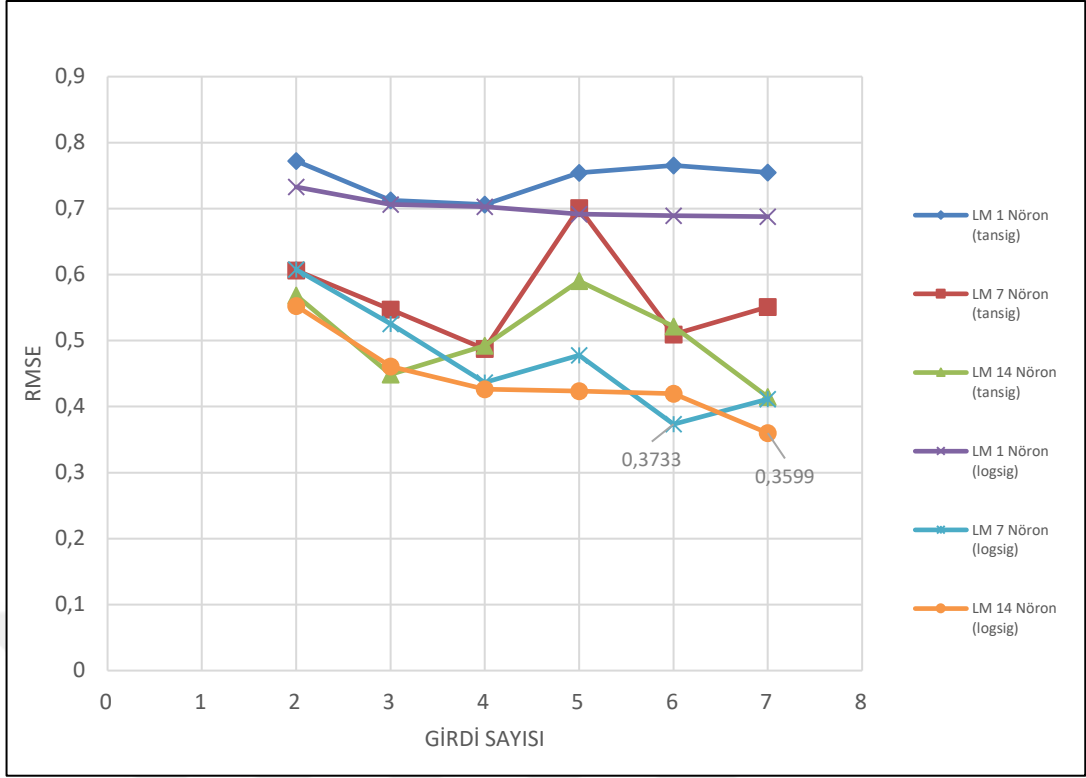
b) Rp250614tansig YSA modeli




c) Scg250714tansig YSA modeli

Şekil 5.1.Doğru YSA modeli tespiti için incelenen en iyi regresyon grafikleri


Her öğrenme fonksiyonu ile modellenen yapay sinir ağlarının gizli katmandaki nöron sayısı, transfer fonksiyonu ve girdi sayısına göre başarı eğrileri Şekil 5.2'de grafiksel olarak gösterilmiştir.



a) LM öğrenme fonksiyonu



b) RP öğrenme fonksiyonu



### c) SCG öğrenme fonksiyonu

Şekil 5.2. Farklı öğrenme fonksiyonlarıyla modellenen çeşitli YSA'ların performansı

Çizelge 5.1'de ve Şekil 5.2'de de görüldüğü üzere yapılan çalışmalarda yapay sinir ağı modelinde girdi sayısının ve ara katmandaki nöron sayısının artırılmasının yapay sinir ağı başarısını genel olarak arttırmaktadır.

Her bir öğrenme fonksiyonu ve transfer fonksiyonu kombinasyonu için elde edilen en başarılı model ile eğitim ve test veri sayısı, gizli katmandaki nöron sayısı ve gizli katman sayısını arttırarak en iyi modeli tespit etmek üzere yapay sinir ağlarının başarı kriteri olan RMSE değerleri Çizelge 5.1'de verilmiştir. Levenberg Marquardt ve Scaled Conjugate Gradient öğrenme fonksiyonları ile eğitilen yapay sinir ağlarında en iyi sonuçlar girdi sayısı 7 ve gizli katmandaki nöron sayısı 14 olan modellerde elde edilirken, Resilient Backpropagation öğrenme fonksiyonu ile eğitilen yapay sinir ağlarında en iyi sonuç girdi sayısı 6 ve gizli katmandaki nöron sayısı 14 olan modelde elde edilmiştir.

Resilient Backpropagation ve Scaled Conjugate Gradient eğitim fonksiyonları ile eğitilen yapay sinir ağlarında en iyi sonuçlar transfer fonksiyonu tan-sigmoid olan modellerde elde edilirken, Levenberg Marquardt eğitim fonksiyonları ile eğitilen yapay sinir ağlarında en iyi sonuç log-sigmoid transfer fonksiyonu ile eğitilen modelde elde edilmiştir.

Çizelge 5.1. Farklı YSA modellerinin test performans (RMSE) değerleri

			250 VERİ					
			Levenberg Marquardt		Resilient Backpropagation		Scaled Conjugate Gradient	
Ara Katman Transfer Fonksiyonu			Tansig	Logsig	Tansig	Logsig	Tansig	Logsig
Girdi Sayısı	Gizli Katman Sayısı	Nöron Sayısı						
2	1	1	0,7722	0,7328	0,7776	0,7862	0,7305	0,7315
2		7	0,6066	0,6076	0,6420	0,6230	0,6075	0,6085
2		14	0,5686	0,5526	0,5842	0,5961	0,5866	0,5687
3	1	1	0,7128	0,7064	0,7068	0,7104	0,7073	0,7075
3		7	0,5470	0,5252	0,5064	0,5386	0,5377	0,5201
3		14	0,4486	0,4607	0,4941	0,4736	0,4806	0,5056
4	1	1	0,7062	0,7029	0,7145	0,7143	0,7047	0,7021
4		7	0,4873	0,4364	0,4644	0,4601	0,4550	0,5157
4		14	0,4925	0,4265	0,4398	0,5469	0,4694	0,5046
5	1	1	0,7542	0,6917	0,7034	0,7635	0,6980	0,6927
5		7	0,7010	0,4779	0,4617	0,4366	0,4599	0,4863
5		14	0,5902	0,4234	0,4374	0,4786	0,4344	0,4232
6	1	1	0,7654	0,6891	0,7132	0,7116	0,6903	0,6906
6		7	0,5095	0,3733	0,4197	0,5117	0,3949	0,4555
6		14	0,5216	0,4196	0,3762	0,3844	0,4144	0,3791
7	1	1	0,7549	0,6878	0,7067	0,7546	0,6873	0,6863
7		7	0,5510	0,4113	0,4021	0,4641	0,3887	0,3991
7		14	0,4146	0,3599	0,4178	0,4888	0,3682	0,3897

Her bir parametreden 250 veri alınarak eğitilen yapay sinir ağları ile yapılan ön çalışma sonrasında en iyi performans elde edilen üç model olan Lm250714logsig, Rp250614tansig ve Scg250714tansig ile 250 verilik çalışmada kullanılan verilerden ve birbirlerinden farklı veriler olmak üzere her bir veriden 500 ve 1000 adet olan veri matrisleriyle tekrar eğitim ve test çalışmaları yapılmıştır.

Öncelikle 500 veri ile tekrar edilen yapay sinir ağı eğitimlerinde veri sayısının yapay sinir ağı başarısına olan etkisi RMSE bazlı olarak Çizelge 5.2’de verilmiştir.

Çizelge 5.2. 500 veri ile çalışılan YSA performanslarının 250 veri ile çalışılan YSA'lar ile karşılaştırması

	RMSE (Test)	
	250 Veri	500 Veri
Lm714logsig	0,3599	0,3706
Rp614tansig	0,3762	0,4043
Scg714tansig	0,3682	0,3000

Çizelge 5.2'de görüldüğü üzere veri sayısının artması Lm714logsig ve Rp614tansig modellerinde olumlu bir etki oluşturmamasına karşın Scg714tansig modelinden daha iyi sonuç alınmasını sağlamıştır.

Son olarak çalışmanın bu aşamasına kadar en iyi performans elde edilen yapay sinir ağı modeli olan Scg714tansig modeli, yine 500 veri ile gizli katman sayısı ve gizli katmandaki nöron sayıları artırılarak eğitilmiştir. Scg714tansig modeli ayrıca 1000 verilik veri paketi ile de yeniden eğitilmiş, gizli katman sayısı ve gizli katmandaki nöron sayıları da artırılarak bu durumun yapay sinir ağının performansına olan etkisi incelenmiştir. Scg714tansig modeli ile yapılan ilave çalışmalara ait sonuçlar RMSE bazlı olarak Çizelge 5.3'de verilmiştir.

Çizelge 5.3. Scg714tansig modeli ile yapılan ilave çalışmalar ve performans sonuçları

Scg714tansig	RMSE (Test)	
	500 Veri	1000 Veri
Gizli katman: 1 Gizli katman nöron sayısı: 14	0,3000	0,3768
Gizli katman: 2 Gizli katman nöron sayısı: 14	0,3636	0,3683
Gizli katman: 2 Gizli katman nöron sayısı: 21	0,3515	0,3252

Çizelge 5.3'den de anlaşıldığı üzere veri sayısının, gizli katman sayısının ve gizli katmandaki nöron sayısının artırılmasının Scg714tansig yapay sinir ağı modelinin




performansına olumlu bir etkisi olmadığı tespit edilmiş ve çalışma neticesinde en başarılı yapay sinir ağı modeli Çizelge 5.4'te verilen performans değerleri ile her bir veriden 500 adet olan matrisle eğitilen **Scg714tansig** olarak belirlenmiştir.

Çizelge 5.4 En iyi YSA modeli performans değerlendirme test sonuçları


RMSE	0,3000
MAPE (%)	4,9484
MAE	0,0495
R	0,9526

Boru hattı sistemindeki pompanın titreşim değeri üzerinden arıza tespiti yapmak üzere modellenen yapay sinir ağı modeli Şekil 5.3'de gösterilmiştir.



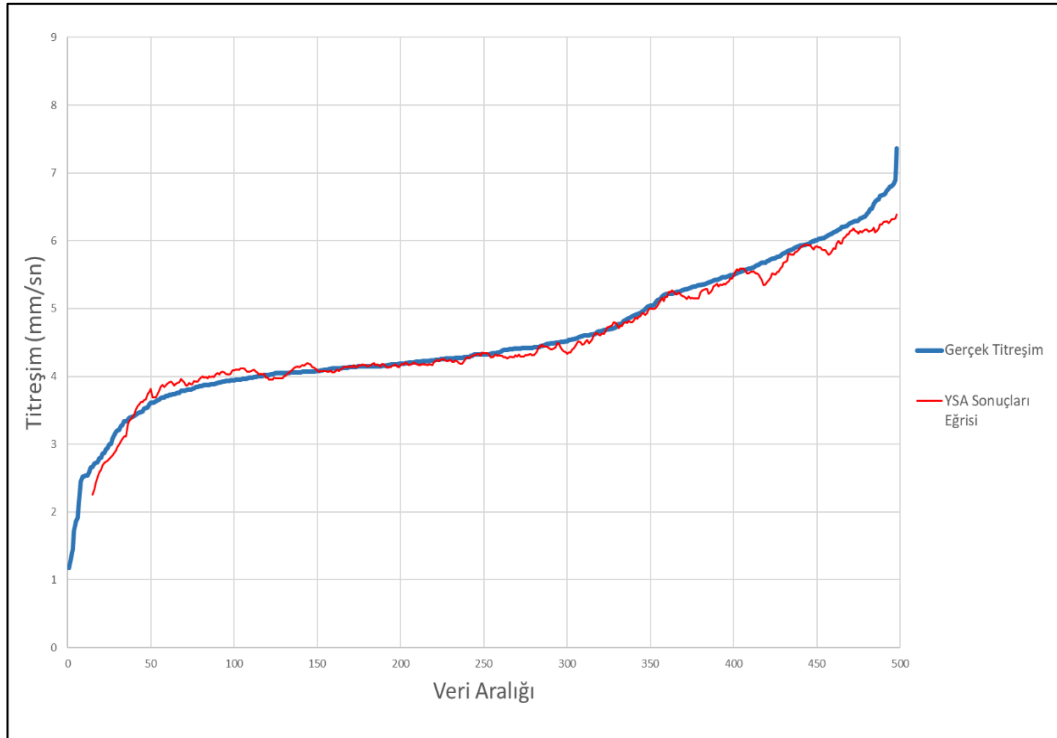
Şekil 5.3. Yapılan çalışmalar neticesinde tespit edilen en uygun YSA yapısı

Oluşturulan yapay sinir ağı modelinin gerçek titreşime göre tahmin başarısının Şekil 5.4'te gösterilmiştir. Şekil 5.4'te yapay sinir ağının tahmin ettiği titreşim değerlerinin büyük bir kısmının gerçek titreşime göre  $\pm \%10$  aralığında kaldığı görülmektedir.



Şekil 5.4. Gerçek titreşim-YSA titreşim tahmin dağılımı

Gerçek titreşim değerlerine karşı YSA tarafından tahmin edilen noktalarla oluşturulan eğriler Şekil 5.5’de gösterilmiştir.



Şekil 5.5 Gerçek Titreşim Eğrisi - YSA Sonuçları Eğrisi

## 6. SONUÇLAR VE ÖNERİLER

Yapay sinir ağı yöntemiyle, en genel anlamıyla makine durum izleme ve arıza teşhisi üzerine yapılan bu çalışmada elde edilen sonuçlar ve bu sonuçlar ile çalışma boyunca elde edilen deneyimler doğrultusunda ortaya çıkan öneriler aşağıda maddeler halinde verilmiştir.

- Yapılan çalışma neticesinde, modellenmek istenen duruma özgü olarak en uygun yapay sinir ağı yapısını bulmak üzere 162 farklı YSA modeli oluşturulması planlanmış fakat ara katman nöronlarında purelin transfer fonksiyonu ile oluşturulan YSA modelleri anlamlı sonuçlar vermediğinden çalışma dışı bırakılarak 108 YSA modeli ile yapılan değerlendirme neticesinde en iyi sonuç veren model olarak 7 girdi ile 14 nöronlu 1 gizli katmanı olan ve her parametreden 500 adet veri ve Scaled Conjugate Gradient öğrenme fonksiyonu ile eğitilen, ara katman nöronları transfer fonksiyonu tan-sigmoid olan YSA tespit edilmiştir.
- Yapay sinir ağı modeli ile ele alınan boru hattı sistemindeki pompaların sağlıklı durum modellemesi ile çalışma şartlarına göre olması gereken titreşim değeri yaklaşık % 4,95 ortalama mutlak bağıl hata (MAPE) ve RMSE değeri 0,30 olarak tahmin edilebilmiştir.
- Literatürde benzer nitelikte gerçek bir sistem üzerinde Z.Y. Zhang ve K.S. Wang tarafından yapılmış olan çalışmada rüzgar türbini rulman arızası tespiti için oluşturulan YSA'da RMSE değeri 0.20 olmasına karşın söz konusu çalışma YSA yapısı bakımından değerlendirildiğinde makine dairesi sıcaklığı, türbin hızı ve aktif çıkış gücü girdi olarak verilmek suretiyle tahmin edilen rulman sıcaklığı ile arıza tespiti problemi bu çalışmaya kıyasla daha doğrusal bir denklem olarak görülmektedir (Zhang ve Wang, 2014).
- Yapay sinir ağları ile yapılan çalışmalarda %10 altındaki hataların kabul edilebilir olması bakımından bu çalışmada elde edilmek istenen YSA başarısı sağlanmıştır (Altinkaya, vd., 2014).

- Çalışmada kullanılmak üzere toplanan 350900 veriden oluşan matris malzeme ve yöntem bölümünden açıklandığı üzere filtrelenerek sağlıklı veriler ile çalışmak üzere çaba gösterilse de her bir parametre ayrı bir enstrümanla ve aynı yapıda olmasına rağmen farklı pompalar üzerinden toplanmış olup, aynı enstrümanlarla ve her bir pompa üzerinde yapılacak ayrı ayrı ölçümler sonucu elde edilen verilerle her pompaya özgü YSA modeli oluşturulmasının çok daha iyi sonuç vereceği değerlendirilmiştir.
- Lei ve arkadaşları tarafından yapılan çalışma göz önünde bulundurularak, boru hattı sistemindeki pompaların sağlıklı çalışma durumunun modellendiği bu çalışmayı, pompaların arızalı durum verileri de toplanarak adaptive neuro-fuzzy inference system (ANFIS) tekniği ile birleştirerek doğrudan arızanın ne olduğuna dair sonuç elde edilebileceği değerlendirilmiştir (Lei, vd., 2008).

## 7. KAYNAKLAR

- Alguindigue, I. E., Loskiewicz-Buczak, A. ve Uhrig, Robert E., Monitoring and Diagnosis of Rolling Element Bearings Using Artificial Neural Networks, IEEE Transactions On Industrial Electronics, 40(2), 209-217, 1993.
- Altinkaya, H., Orak, İ.M. ve Esen, İ., Artificial Neural Network Application For Modeling The Rail Rolling Process, Expert Systems with Applications, 41(16), 7135-7146, 2014.
- Amasyalı, M.F., Yapay Sinir Ağlarında Parçalı Eğitim, Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi, 8(1), 25 – 34, 2015.
- Amit, D.J., Modeling Brain Function, The World of Attractor Neural Networks, Cambridge University Press, 1989.
- Arabacı, H., Asenkron Motorlarda Kırık Rotor Çubuğu Arızalarının Yapay Sinir Ağları ile Teşhisi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Konya, 70, 2005.
- Arslan, A. ve İnce, R., The Neural Network Approximation to The Size Effect in Fracture of Cermetitious Materials, Engineering Fracture Mechanics, 54(2), 249-261, 1996.
- Azadeh, A., Saberi, M., Kazem, A., Ebrahimipour, V., Nourmohammadzadeh, A. ve Saberi, Z., A flexible algorithm for fault diagnosis in a centrifugal pump with corrupted data and noise based on ANN and support vector machine with hyper-parameters optimization, Applied Soft Computing, 13, 1478-1485, 2013.
- Barnston, A. G., Correspondance among the Correlation, RMSE, and Heidke Forecast Verification Measures; Refinement of the Heidke Score, Notes and Correspondance, 699-709, 1992.
- Bechrakis, D.A. ve Sparis, P.D., Correlation of Wind Speed Between Neighboring Measuring Stations, IEEE Transactions On Energy Conversion, 19(2), 400-406, 2004.
- Bevilacqua, M. ve Braglia, M., The analytic hierarchy process applied to maintenance strategy selection, Reliability Engineering and System Safety, 70, 71–83, 2000.
- Bilgili, M. ve Sahin, B., Comparative analysis of regression and artificial neural network models for wind speed prediction, Meteorology and Atmospheric Physics, 109, 61–72, 2010.

- Bin, G.F., Gao, J.J., Li, X.J. ve Dhillon, B.S., Early fault diagnosis of rotating machinery based on wavelet packets-Empirical mode decomposition feature extraction and neural network, *Mechanical Systems and Signal Processing*, 27, 969-711, 2012.
- Chow, M.Y., Mangum, Peter M. ve Yee, Sui Oi, A Neural Network Approach to Real-Time Condition Monitoring of Induction Motors, *IEEE Transactions On Industrial Electronics*, 38(6), 448-453, 1991.
- Çelebi, K., Uludamar, E., Tosun, E., Yıldızhan, Ş., Aydın, K. ve Özcanlı, M., Experimental and artificial neural network approach of noise and vibration characteristic of an unmodified diesel engine fuelled with conventional diesel and biodiesel blends with natural gas addition, *Fuel (Elsevier)*, 197, 159-173, 2017.
- Çavuşlu, M.A., Becerikli, Y. ve Karakuzu, C., Levenberg-Marquardt Algoritması ile YSA Eğitiminin Donanımsal Gerçeklenmesi, *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5(1), 2012.
- Fırat, M. ve Güngör, M., Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi, *İMO Teknik Dergi*, Yazı 219, 3267-3282, 2004.
- Ghorbani, M. A., Khatibi, R., Hosseini, B. ve Bilgili, M., Relative importance of parameters affecting wind speed prediction using artificial neural networks, *Springer Published Online*, 2012.
- Haykin, S., *Neural Networks and Learning Machines*, Pearson Education, Inc. (11-12, 124-134), 2009.
- Huang, G.B., Zhu, Q.Y. ve Siew, C.K., Extreme Learning Machine: A New Learning Scheme of Feedforward Neural Networks, 2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH37541), 985-990, 2004.
- İbrikçi, T., Saçma, S., Yıldırım, V. ve Koca, T., Application of Artificial Neural Networks in the Prediction of Critical Buckling Loads of Helical Compression Springs, *Journal of Mechanical Engineering*, 56(6), 409-417, 2010.
- Jia, F., Lei, Y., Lin, J., Zhou, X. ve Lu, N., Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data, *Mechanical Systems and Signal Processing*, 72-73, 303-315, 2016.

- Johansson, E.M., Dowla, F.U. ve Goodman, D.M., Backpropagation Learning For Multilayer Feed-Forward Neural Networks Using The Conjugate Gradient Method, *International Journal of Neural Systems*, 2(4), 291-301, 1992.
- Kang, H.T. ve Yoon, C.J., Neural Network Approaches to Aid Simple Truss Design Problems, *Microcomputers in Civil Engineering*, 9, 211-218, 1994.
- Knapp, G. M. ve Wang, Hsu-Pin, Machine fault classification: a neural network approach, *International Journal of Production Research*, 30(4), 811-823, 1992.
- Kong, F. ve Chen, R., A combined method for triplex pump fault diagnosis based on wavelet transform, fuzzy logic and neuro-networks, *Mechanical Systems and Signal Processing*, 18, 161–168, 2004.
- Lei, Y., He, Z. ve Zi, Y., A new approach to intelligent fault diagnosis of rotating machinery, *Expert Systems with Applications*, 35, 1593-1600, 2008.
- Li, B., Chow, M.Y., Tipsuwan, Y. ve Hung, J.C., Neural-Network-Based Motor Rolling Bearing Fault Diagnosis, *IEEE Transactions On Industrial Electronics*, 47(5), 1060-1069, 2000.
- Li, J.R., Khoo, L.P. ve Tor, S.B., Generation of possible multiple components disassembly sequence for maintenance using a disassembly constraint graph, *International Journal of Production Economics*, 102, 51–65, 2006.
- Martins, J. F., Fernão Pires, V. ve Pires, A. J., Unsupervised Neural-Network-Based Algorithm for an On-Line Diagnosis of Three-Phase Induction Motor Stator Fault, *IEEE Transactions On Industrial Electronics*, 54(1), 259-264, 2007.
- McCulloch, W. S. ve Pitts, W. H., A Logical Calculus of The Ideas Immanent in Nervous Activity, *Bulletin of Mathematical Biophysics*, 5, 115-133, 1943.
- McCormick, A.C. ve Nandi, A.K., Classification of the rotating machine condition using artificial neural networks, *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, 211(Part C), 439-450, 1997.
- Møller, M.F., A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning, *Neural Networks*, 6, 525-533, 1993.
- Öztemel, E., *Yapay Sinir Ağları*, Papatya Yayıncılık Eğitim, 2012.
- Parker, D. B., Learning logic, Stanford University Office of Technology Licensing Invention report, 1, 81-64, 1982.



- Rafiee, J., Arvani, F., Harifi, A. ve Sadeghi, M.H., Intelligent Condition Monitoring of a Gearbox Using Artificial Neural Network, *Mechanical Systems and Signal Processing*, 21, 1746-1754, 2007.
- Rajakarunakaran, S., Venkumar, P., Devaraj, D. ve Rao, K.S.P., Artificial neural network approach for fault detection in rotary system, *Applied Soft Computing*, 8, 740-748, 2008.
- Ravinesh, C.D., Ghorbani, M.A., Samadianfrad, S., Maraseni, T., Bilgili, M. ve Biazar, M., Multi-layer perceptron hybrid model integrated with the firefly optimizer algorithm for windspeed prediction of target site using a limited set of neighboring reference station data, *Renewable Energy (Accepted)*, 2017.
- Ross, R.G. Jr., Cryocooler Reliability and Redundancy Considerations for Long-Life Space Missions, Kluwer Academic/Plenum Publishers, 637-648, 2001.
- Rumelhart, D. E., Hinton, G. E. ve Williams, R. J., Learning internal representations by error propagation, In *Parallel Distributed Processing*, 1, MIT Press, 318-362, 1986.
- Samanta, B. ve Al-Balushi, K.R., Artificial Neural Network Based Fault Diagnostics of Rolling Element Bearings Using Time-Domain Feature, *Mechanical Systems and Signal Processing*, 17(2), 317–328, 2003.
- Samanta, B., Gear fault detection using artificial neural networks and support vector machines with genetic algorithms, *Mechanical Systems and Signal Processing*, 18, 625–644, 2004.
- Saravanan, N., Siddabattuni, V.N.S.K. ve Ramachandran, K.I., Fault diagnosis of spur bevel gear box using artificial neural network (ANN) and proximal support vector machine (PSVM), *Applied Soft Computing*, 10, 344-360, 2010.
- Saxena, A. ve Saad, A., Evolving an artificial neural network classifier for condition monitoring of rotating mechanical systems, *Applied Soft Computing*, 7, 441-454, 2007.
- Scarselli, F. ve Tsoi, A.C., Universal Approximation Using Feedforward Neural Networks: A Survey of Some Existing Methods, and Some New Results, *Neural Networks*, 11(1), 15–37, 1998.

- Sharma, R. K., Kumar, D. ve Kumar, P., Methodology And Theory FLM to select suitable maintenance strategy in process industries using MISO model, *Journal of Quality in Maintenance Engineering*, 11(4), 359-374, 2005.
- Su, H. ve Chong, K.T., Induction Machine Condition Monitoring Using Neural Network Modeling, *IEEE Transactions On Industrial Electronics*, 54(1), 241-249, 2007.
- Wang, H., A survey of maintenance policies of deteriorating systems, *European Journal of Operational Research*, 139, 469–489, 2002.
- Wang, C.C. ve Too, G.P.J., Rotating Machine Fault Detection Based On HOS and Artificial Neural Network, *Journal of Intelligent Manufacturing*, 13, 283-293, 2002.
- Wang, H. ve Chen, P., Sequential Condition Diagnosis for Centrifugal Pump System Using Fuzzy Neural Network, *Neural Information Processing – Letters and Reviews*, 11(3), 41-50, 2007.
- Waqar, T., Yapay Sınır Ağı Ve Karınca Koloni Algoritmaları İle Dişlilerde Arıza Tespiti, Marmara Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 64, 2015.
- Werbos, P. J., Beyond regression: New tools for prediction and analysis in the behavioral sciences. Masters thesis, Harvard University, Cambridge, Mass., 1974.
- Yaman, G. ve Karadayı, H.M., Titreşim Analizi ile Pompalarda Arıza Tesbiti ve Kestirimci Bakım İçin Örnek Bir Çalışma, *Tesisat Mühendisliği*, 140, 36-51, 2014.
- Yu, H. ve Wilamowski, B.M., Levenberg Marquardt Training, *Industrial Electronics Handbook*, 5, Intelligent Systems, 2nd Edition, Chapter 12, 12-1 to 12-15, CRC Press, 2011.
- Zaim, S., Türkyılmaz, A., Al-Turki, U. ve Demirel, Ö.F., Maintenance strategy selection using AHP and ANP algorithms: a case study, *Journal of Quality in Maintenance Engineering*, 18(1), 16-29, 2012.
- Zhang, Q.J., Gupta, K.C. ve Devabhaktuni, V.K., Artificial Neural Networks for RF and Microwave Design—From Theory to Practice, *IEEE Transactions On Microwave Theory And Techniques*, 51(4), 1339-1350, 2003.

- Zhang, Z.Y. ve Wang, K.S., Wind turbine fault detection based on SCADA data analysis using ANN, *Advances in Manufacturing*, 2(1), 70-78, 2014.
- “ABB Data sheet DS/266GSH/ASH-EN Rev. C, 2600T Series Pressure Transmitters Engineered solutions for all applications, 2012.” Eriřim Adresi: [https://library.e.abb.com/public/385855ba1007ee90c1257b0c00547436/DS\\_266GSH\\_ASH-EN-C-03\\_2012.pdf](https://library.e.abb.com/public/385855ba1007ee90c1257b0c00547436/DS_266GSH_ASH-EN-C-03_2012.pdf) Eriřim Tarihi: 09.11.2018.
- “Electrical Engineering Blog, Inductive & magnetic type electrical speed sensor complete concept, 2012.” Eriřim Adresi: <http://eblogbd.com/types-of-speed-sensor-and-their-comparison/> Eriřim Tarihi: 09.11.2018.
- “Elimko, Termokupllar Genel Bilgiler, 135-149, 2016” Eriřim Adresi: <http://www.elimko.com.tr/files/TermokupllarGenelBilgiler.pdf> Eriřim Tarihi: 09.11.2018.
- “Gauge and Absolute Pressure Transmitters Principle” Eriřim Adresi: <https://instrumentationtools.com/gage-and-absolute-pressure-transmitters-principle/> Eriřim Tarihi: 09.11.2018.
- “MATLAB, The Language of Technical Computing, Getting Started with MATLAB, The MathWorks, Inc., Version 7,2005.” Eriřim Adresi: <https://www.mn.uio.no/astro/english/services/it/help/mathematics/matlab/getst-art.pdf> Eriřim Tarihi: 03.08.2015.
- “McKinsey Global Institute, The Internet Of Things: Mapping The Value Beyond The Hype, 2015” Eriřim adresi: <https://www.mckinsey.com/~media/mckinsey/business%20functions/mckinsey%20digital/our%20insights/the%20internet%20of%20things%20the%20value%20of%20digitizing%20the%20physical%20world/the-internet-of-things-mapping-the-value-beyond-the-hype.ashx> Eriřim Tarihi: 09.11.2018
- “Pepperl+Fuchs, Inductive Sensor, 2018.” Eriřim Adresi: [https://files.pepperl-fuchs.com/webcat/navi/productInfo/edb/181108\\_eng.pdf?v=20190111000208](https://files.pepperl-fuchs.com/webcat/navi/productInfo/edb/181108_eng.pdf?v=20190111000208) Eriřim Tarihi: 09.11.2018.

“Pro-Plan Proje Müh. San. ve Tic. Ltd. Şti. Eğitim Seminer Notları: Titreşim Ölçümüne Dayalı Erken Uyarıcı Bakım Sistemleri, İstanbul, 2004.” Erişim adresi:

<http://proplan.com.tr/Content/files/titresimolcumunedayalibakimrev01.pdf>

Erişim Tarihi: 13.12.2018.

“Presenso, INFOGRAPHIC: The Business Case for Predictive Maintenance” Erişim adresi: <https://www.presenso.com/download-infographic-pdf/> Erişim Tarihi: [20.10.2018.](https://www.presenso.com/download-infographic-pdf/)

“Riddell R., The Reliability Impact Within The P-F Curve, Uptime Online Magazine” Erişim adresi: <https://reliabilityweb.com/uptime/details/june-july-2017>, Erişim Tarihi: 20.08.2017.

“SKF, Condition Monitoring Inc., Vibration Sensors, 5, 1999.” Erişim Adresi: [http://www.exvalos.cz/soubory/File/SKF/SNIMACE\\_VIBRACI.pdf](http://www.exvalos.cz/soubory/File/SKF/SNIMACE_VIBRACI.pdf) Erişim Tarihi: 09.11.2018.

“4-20 mA Transmitter Wiring Types : 2-Wire, 3-Wire, 4-Wire” Erişim Adresi: <https://instrumentationtools.com/4-20-ma-transmitter-wiring/> Erişim Tarihi: 09.11.2018.

## ÖZGEÇMİŞ

**1. Adı Soyadı** : Hakan DEMİRKIRAN

**2. Doğum Tarihi** : 01.01.1987

**3. Ünvanı** : Makine Mühendisi

**4. Öğrenim Durumu** :

Derece	Bölüm/Program	Okul/Üniversite	Bitirme Yılı
Lise	Fen Bilimleri	Ç.E.A.Ş Seyhan Anadolu Lisesi	2004
Lisans	Makine Mühendisliği	Çukurova Üniversitesi	2009

**5. İş Tecrübesi:**

Görev Unvanı	Görev Yeri	Yıl
Mekanik Mühendisi	BOTAŞ Petrol İşletmeleri Bölge Müdürlüğü-Bakım Onarım Müdürlüğü.	2010 -