



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



YAPAY SİNİR AĞLARI YÖNTEMİYLE
RÜZGAR TÜRBİN GENERATÖRLERİNDE
HİDROLİK ARIZA TESPİTİ

Tacettin Ahmet DÖNDÜREN

YÜKSEK LİSANS TEZİ

Elektrik ve Elektronik Mühendisliği Anabilim
Dalı

06-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Tacettin Ahmet DÖNDÜREN tarafından hazırlanan “Yapay Sinir Ağları Yöntemiyle Rüzgar Türbin Generatörlerinde Hidrolik Arıza Tespiti” adlı tez çalışması 28.06.2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Elektrik ve Elektronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Prof. Dr. Salih GÜNEŞ

Danışman

Doç. Dr. Mustafa YAĞCI

Üye

Dr. Öğr. Üyesi Ali Osman ÖZKAN

İmza

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun .../.../2024 gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Şerife Yurdağül KUMCU
FBE Müdürü

Bu tez çalışması Necmettin Erbakan Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından 23YL19008 nolu proje ile desteklenmiştir.

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Tacettin Ahmet DÖNDÜREN

ÖZET

YÜKSEK LİSANS TEZİ

YAPAY SINIR AĞLARI YÖNTEMİYLE RÜZGAR TÜRBİN GENERATÖRLERİNDE HİDROLİK ARIZA TESBİTİ

Tacettin Ahmet DÖNDÜREN

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Mustafa YAĞCI

2024, 65 Sayfa

Jüri

Doç. Dr. Mustafa YAĞCI

Prof. Dr. Salih GÜNEŞ

Dr. Öğr. Üyesi Ali Osman ÖZKAN

Dünyada fosil kaynakların azaldığı ve karbon emisyonlarının günden güne arttığı bu süreçte yeşil enerjinin önemi, özellikle rüzgar enerjisinin önemi her geçen gün artmaktadır. Rüzgar türbinlerinin yaygınlaşması hem karbon ayak izini azaltacak hem de dış kaynaklara olan bağımlılığı azaltacaktır.

Rüzgar türbinlerinin kurulu gücünün artması için sadece kurulum maliyetlerinin değil aynı zamanda işletme maliyetlerinin de azalması oldukça önemlidir. İşletme maliyetleri içerisindeki en büyük oran servis bakım maliyetlerine aittir. Servis bakım maliyetlerinin azaltılmasındaki en önemli yaklaşımlardan biri ise önleyici bakım faaliyetleri olmaktadır. Önleyici bakım faaliyetleri ile arıza gelmeden yapılacak türbin duruşları ile üretim kayıplarının mümkünse olmaması ya da en alt seviyede sınırlandırılması hedeflenir.

Bu çalışmada işletme süresinde oluşabilecek hidrolik arızaları önceden tahmin eden yapay sinir ağları tabanlı algoritmalar kullanılmıştır. Bu amaçla hidrolik sistemlerin bağlantılı olduğu ekipmanlar ve sensörler göz önünde bulundurularak türbin SCADA sistemi üzerinden 2 senelik veriler derlenmiştir. Çalışma WEKA programı ile yürütülmüş olup Multilayer Perceptron (MLP), Radial Basis Function Classifier (RBF Classifier), SMOreg (Support Vector Machines for Regression) algoritmaları mukayese edilerek yürütülmüştür. Çalışma neticesinde MLP algoritması verilerin yüzdesel olarak ayrılması metodu ile %66 eğitim, %33 test olarak ayrılmıştır ve yüzde 96,32 oranında başarılı tahminler yaptığı görülmüştür.

Anahtar Kelimeler: Arıza Tahmini, Önleyici Bakım, Rüzgar Türbini, Yapay Sinir Ağları, WEKA

ABSTRACT

MS THESIS

HYDRAULIC FAULT DETECTION OF WIND TURBINE GENERATORS USING ARTIFICIAL NEURAL NETWORKS

Tacettin Ahmet DÖNDÜREN

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTİN ERBAKAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN ELECTRICAL AND ELECTRONICS ENGINEERING

Advisor: Assoc. Prof. Mustafa YAĞCI

2024, 65 Pages

Jury

Assoc. Prof. Dr. Mustafa YAĞCI

Prof. Dr. Salih GÜNEŞ

Dr. Ali Osman ÖZKAN

In the current context where fossil resources are diminishing globally and carbon emissions are increasing daily, the importance of green energy, particularly wind energy, is growing significantly. The increasing of wind turbines will not only reduce the carbon footprint but also decrease dependence on external resources.

To increase the installed capacity of wind turbines, it is crucial to reduce not only installation costs but also operational costs. The largest proportion of operational costs is service and maintenance costs. One of the most critical approaches to reducing service and maintenance costs is preventive maintenance activities. The objective of preventive maintenance activities is to minimize or ideally eliminate production losses through scheduled turbine shutdowns before failures occur.

In this study, artificial neural network-based algorithms that predict potential hydraulic failures during the operational period was utilized. For this purpose, data from the turbine SCADA system over a period of two years, considering the equipment and sensors connected to hydraulic systems, were compiled. The study was conducted using the WEKA program, comparing Multilayer Perceptron (MLP), Radial Basis Function Classifier (RBF Classifier), SMOreg (Support Vector Machines for Regression) algorithms. Result of the study, the MLP algorithm was applied with a percentage split of 66% for training and 33% for testing, achieving a prediction accuracy of 96.32%

Keywords: Artificial Neural Networks, Faults Detection, Predictive Maintenance, WEKA, Wind Turbine

ÖNSÖZ

Bu tezin hazırlanmasında bana her daim destek olan ve sevgileriyle yanımda olan aileme ve biricik kızıma sonsuz teşekkürlerimi sunuyorum. Onların sabrı, anlayışı ve sevgisi, bu çalışmanın arkasındaki en büyük güç kaynağı oldu.

Bu süreçte bilgi ve rehberlikleriyle bana ışık tutan ve eğitimimi tamamlamam için sürekli destek veren değerli hocam Doç. Dr. Mustafa YAĞCI'nın katkıları da çok büyüktür.

Tez çalışmam süresince bana anlayış ve destek gösteren iş yerimdeki çalışma arkadaşlarımla ve yöneticilerimin de desteğini özellikle vurgulamak isterim. İş yerimde sağlanan esneklik ve destek, bu çalışmayı tamamlamamda büyük rol oynadı.

Hepsine ayrı ayrı minnettarlığımı ifade etmek isterim.

Tacettin Ahmet DÖNDÜREN
KONYA-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ŞEKİLLER LİSTESİ	iv
ÇİZELGELER LİSTESİ	v
SİMGELER VE KISALTMALAR.....	vi
1. GİRİŞ	1
1.1. Rüzgar Türbinin Temel Çalışma Prensibi, Parçaları ve Arızaları	1
1.1.1. Gölge etkisi	2
1.1.2. Kanat hasarları ve arızaları	3
1.1.3. Rulman hasarları	4
1.1.4. Dişli sistemler ve dişli kutusu hasarları.....	5
1.1.5. Hidrolik arızalar	5
1.1.6. Haberleşme arızaları.....	6
1.1.7. Generatör, konverter ve diğer elektrik arızaları.....	6
1.2. Yapay Sinir Ağları ve Genel Özellikleri.....	8
2. KAYNAK ARAŞTIRMASI.....	10
3. MATERYAL VE METOD.....	15
3.1. Veri Kaynakları	15
3.2. Doğru Olarak Sınıflandırılmış Örnekler ve Karışıklık Matrisi	16
3.3. Sınıflandırma Doğruluğu, Duyarlılık, Seçicilik ve F Ölçütü	16
3.4. Kappa İstatistikleri.....	17
3.5. Diğer Yaklaşımlar	18
3.6. WEKA Üzerinde Kurgulanan Model Özellikleri ve Kullanılan Yöntemler ve Algoritmaların Karşılaştırılması.....	19
3.7. Multilayer Perceptron (MLP)	20
3.7.1. MLP’de parametre ayarları.....	20
3.7.2. MLP’de K parçalı çapraz doğrulama	21
3.7.3. MLP’de verilerin yüzdesel olarak ayrılması.....	23
3.8. Radyal Tabanlı Fonksiyon Sınıflandırıcı (Radial Basis Function Classifier-RBFC) 24	
3.8.1. RBFC’de parametre ayarları.....	25
3.8.2. RBFC’de K parçalı çapraz doğrulama	25
3.8.3. RBFC’de verilerin yüzdesel olarak ayrılması.....	26
3.9. Sıralı Minimal Optimizasyon (Sequential Minimal Optimization - SMO).....	27
3.9.1. SMO’da parametre ayarları	27

3.9.2.	SMO'da K parçalı çapraz doğrulama.....	28
3.9.3.	SMO'da verilerin yüzdesel olarak ayrılması	29
4.	ARAŞTIRMA BULGULARI VE TARTIŞMA	30
5.	SONUÇLAR VE ÖNERİLER.....	35
5.1.	Sonuçlar.....	35
5.2.	Öneriler	35
6.	KAYNAKLAR.....	37
EKLER		40



ŞEKİLLER LİSTESİ

Şekil 1.1. SCADA sistemi genel görünüm	2
Şekil 1.2. Gölge etkisinin bilgisayar ortamında simüle edilmesi [4]	3
Şekil 1.3. Rulman arızalarının titreşim frekansı [8]	4
Şekil 1.4. Sıcaklık ölçümü ile rulman arızasının belirlenmesi-hasarlı	4
Şekil 1.5. Sıcaklık ölçümü ile rulman arızasının belirlenmesi-sağlam	5
Şekil 1.6. ÇBAG (DFIG) Genel şeması [11]	7
Şekil 1.7. Çeşitli aktivasyon fonksiyonları (Sarıkaya, 2023)	9
Şekil 3.1. MLP yapısı	21
Şekil 4.1. J48 Karar ağacı	31
Şekil 4.2. Hidrolik ünite yağ sıcaklığı-arıza tahmini ilişkisi	32
Şekil 4.3. Hidrolik ünite basıncı-arıza tahmini ilişkisi	33
Şekil 4.4. Yaw fren basıncı-arıza tahmini ilişkisi	34



ÇİZELGELER LİSTESİ

Çizelge 3.1. Veri değişkenleri.....	15
Çizelge 3.2. Karışıklık matrisi	16
Çizelge 3.3. Kappa katsayı uyuma oranı [35]	18
Çizelge 3.4. Algoritmaların karşılaştırılması	20
Çizelge 3.5. MLP K=24 için karışıklık matrisi.....	22
Çizelge 3.6. MLP K=10 için karışıklık matrisi.....	22
Çizelge 3.7. MLP K=4 için karışıklık matrisi.....	22
Çizelge 3.8. MLP'de K-kat çapraz doğrulama değerlendirme sonuçları.....	22
Çizelge 3.9. MLP'de K-kat çapraz doğrulama için istatistiksel değerlendirmeler	22
Çizelge 3.10. Verilerin %80 eğitim ve %20 test şeklinde ayrılması.....	23
Çizelge 3.11. Verilerin %66 eğitim ve %33 test şeklinde ayrılması.....	23
Çizelge 3.12. Verilerin %50 eğitim ve %50 test şeklinde ayrılması.....	23
Çizelge 3.13. MLP'de verilerin yüzdesel ayrılmasının değerlendirme sonuçları	23
Çizelge 3.14. MLP'de verilerin yüzdesel ayrılmasının istatistiksel değerlendirmeleri.....	24
Çizelge 3.15. RBFC K=24 için karışıklık matrisi.....	25
Çizelge 3.16: RBFC K=10 için karışıklık matrisi.....	25
Çizelge 3.17: RBFC K=4 için karışıklık matrisi.....	25
Çizelge 3.18. RBFC'de K-kat çapraz doğrulama değerlendirme sonuçları.....	26
Çizelge 3.19. RBFC'de K-kat çapraz doğrulama için istatistiksel değerlendirmeler	26
Çizelge 3.20. RBFC'de verilerin %80 eğitim ve %20 test şeklinde ayrılması	26
Çizelge 3.21. RBFC'de verilerin %66 eğitim ve %33 test şeklinde ayrılması	26
Çizelge 3.22. RBFC'de verilerin %50 eğitim ve %50 test şeklinde ayrılması	26
Çizelge 3.23. RBFC'de verilerin yüzdesel ayrılmasının değerlendirme sonuçları	27
Çizelge 3.24. RBFC'de verilerin yüzdesel ayrılmasının istatistiksel değerlendirmeleri.....	27
Çizelge 3.25. SMO K=24 için karışıklık matrisi	28
Çizelge 3.26. SMO K=10 için karışıklık matrisi	28
Çizelge 3.27. SMO K=4 için karışıklık matrisi	28
Çizelge 3.28. SMO'da K-kat çapraz doğrulama değerlendirme sonuçları	28
Çizelge 3.29. SMO'da K-kat çapraz doğrulama için istatistiksel değerlendirmeler	28
Çizelge 3.30. SMO'da verilerin %80 eğitim ve %20 test şeklinde ayrılması.....	29
Çizelge 3.31. SMO'da verilerin %66 eğitim ve %33 test şeklinde ayrılması.....	29
Çizelge 3.32. SMO'da verilerin %50 eğitim ve %50 test şeklinde ayrılması.....	29
Çizelge 3.33. SMO'da verilerin yüzdesel ayrılmasının değerlendirme sonuçları.....	29
Çizelge 3.34. SMO'da verilerin yüzdesel ayrılmasının istatistiksel değerlendirmeleri	29
Çizelge 4.1. Verilerin yüzdesel olarak ayrılması yaklaşımı ile doğruluk oranları.....	30
Çizelge 4.2. Verilerin yüzdesel olarak ayrılması yaklaşımı ile F ölçütü.....	30
Çizelge 4.3. Verilerin K parçalı çapraz doğrulaması yaklaşımı ile doğruluk oranları.....	30
Çizelge 4.4. Verilerin K parçalı çapraz doğrulaması yaklaşımı ile F ölçütü.....	31

SİMGELER VE KISALTMALAR

Simgeler

P_0 : Gözlemciler arasındaki uyumun yüzdesi

P_e : Gözlemciler arasındaki rastgele uyumun yüzdesi

Kısaltmalar

SCADA: Supervisory Control and Data Acquisition

WEKA: Waikato Environment for Knowledge Analysis, isimli yazılımdır.

YSA: Yapay Sinir Ağları

ANFIS: Uyarlamalı ağ tabanlı bulanık çıkarım sistemi, Adaptive-Network Based Fuzzy Inference Systems

PLC: Programlanabilir Mantıksal Denetleyici, programmable logic controller

PC: Kişisel bilgisayar

MATLAB: Matrix laboratory, isimli yazılımdır.

MAE: Ortalama Mutlak Hata (Mean Absolute Error)

RAE: Göreceli Mutlak Hata (Relative Absolute Error)

RMSE: Kök Ortalama Kare Hata (Root Mean Square Error)

RRSE: Kök Göreceli Kare Hata (Root Relative Squared Error)

MLP: Çok Katmanlı Sinir Ağları (Multilayer Perceptron)

RBF Classifier: Radyal Tabanlı Sınıflandırıcı (Radial Basis Function Classifier)

SMOreg: Regresyon için Destek Vektör Makinaları Support Vector Machines for Regression

1. GİRİŞ

Dünyada fosil kaynakların azaldığı ve karbon emisyonlarının günden güne arttığı bu süreçte yeşil enerjinin önemi, özellikle rüzgar enerjisinin önemi her geçen gün artmaktadır. Rüzgar türbinlerinin yaygınlaşması hem karbon ayak izini azaltacak hem de dış kaynaklara olan bağımlılığı azaltacaktır.

Rüzgar türbinlerinin kurulu gücünün artması için sadece kurulum maliyetlerinin değil aynı zamanda işletme maliyetlerinin de azalması oldukça önemlidir. İşletme maliyetleri içerisindeki en büyük oran servis bakım maliyetleridir. Servis bakım maliyetlerinin azaltılmasındaki en önemli yaklaşımlardan biri ise önleyici bakım faaliyetleri olmaktadır. Önleyici bakım faaliyetleri ile arıza gelmeden yapılacak türbin duruşları, üretim kayıplarını oldukça azaltacaktır.

Bu çalışma içerisinde rüzgar türbininin temel ekipmanlarından ve çalışma prensiplerinden bahsedilmiştir. Sıklıkla karşılaşılan arızalar incelenmiş ve yapay sinir ağlarının (YSA) temel özelliklerine değinilmiştir. YSA ile hidrolik arızaları önceden tahmin edebilen bir yapı kurulmuş ve performansı değerlendirilmiştir.

1.1.Rüzgar Türbinin Temel Çalışma Prensibi, Parçaları ve Arızaları

Rüzgar türbinleri genel olarak kule, kanatlar, rotor mili, dişli kutusu, generatör, konverter, transformatör ve diğer yardımcı ekipmanlardan oluşan bir yapıdır. Rüzgarın kinetik enerjisi kanatlara çarparak döndürme hareketi oluşturur (Yavuz & Özbay, 2020).

Büyük güçlü türbinlerde 3 kanatlı yapılar, en yüksek kanat güç katsayısına sahiptir. Rüzgar türbinlerindeki temel prensip kanat alanından geçen rüzgar kütlelerinin hızının azaltılarak sahip olduğu kinetik enerjiyi önce mekanik enerjiye ardından elektrik enerjisine dönüştürmektir (Karabacak vd., 2017).

SCADA sistemleri geniş lokasyonları yayılmış cihazların merkezi bir bilgisayar sistemi ile denetlenmesi, önceden tasarlanmış bir biçimde işletilmesi ve geçmiş verilerin depolandığı bilgisayar tabanlı yapılardır(Çelikpençe & Zaim, 2016).

WINDTURBINE													
NAME	STATE	POWER	Q	WS	COS PHI	PITCH	NAME	STATE	POWER	Q	WS	COS PHI	PITCH
		kW	kVar	m/s		°			kW	kVar	m/s		°
WTG08		-8.3	-2.6	3.5	0.992	88.0	WTG20		534.1	-148.8	5.6	0.973	-0.5
WTG09		287.3	-149.1	4.6	0.915	-0.4	WTG21		956.3	-147.1	6.9	0.990	-0.5
WTG10		644.5	-148.7	6.5	0.980	-0.5	WTG22		412.2	-149.3	4.6	0.954	-0.5
WTG11		386.2	-148.9	5.1	0.949	-0.5	WTG23		1,486.9	-142.9	8.2	0.997	-0.5
WTG12		323.0	-149.4	5.4	0.922	0.2	WTG24		740.7	-148.2	6.9	0.986	-0.5
WTG13		381.2	-149.5	4.8	0.951	-0.5	WTG25		-171	-146.3	1.9	-0.017	2.5
WTG14		206.7	-146.0	4.1	0.853	0.3	WTG26		-35.3	-147.2	1.8	-0.019	25.2
WTG15		610.9	-149.8	5.7	0.978	-0.5	WTG27		46.0	-145.5	2.4	0.399	1.9
WTG16		560.2	-149.0	6.9	0.974	-0.5	WTG28		340.5	-165.9	4.6	0.905	-0.1
WTG17		1,134.5	-144.2	6.8	0.994	-0.5	WTG29		344.8	-137.2	4.4	0.945	-0.3
WTG18		232.4	-148.4	4.3	0.879	0.6	WTG30		312.2	-149.8	5.4	0.922	-0.5
WTG19		242.8	-147.7	3.9	0.904	0.5	WTG31		18.4	-145.6	2.2	0.216	2.6

24 Device(s) - 0 Selected

Şekil 1.1. SCADA sistemi genel görünüm

SCADA sisteminde arıza analizi yapmak için arızalar belirli başlıklar altında toplanır. Örneğin, ortam koşulları kaynaklı arızalar, hidrolik sistem kaynaklı arızalar veya şebeke kalitesi (enerji kalitesi) ile ilgili arızalar gibi. Buradaki veriler ile arıza analizi yapılarak önleyici bakım faaliyetleri yürütülür. SCADA sistemleri türbin markalarına ve modellerine göre farklılık gösterse dahi temel prensip olarak benzer şekilde çalışmaktadır.

Bu bölümde gölge etkisi, kanat hasarları, rulman hasarları, dişli sistemlerdeki hasarlar ve hidrolik arızalar gibi başlıklar incelenmiştir.


1.1.1. Gölge etkisi

Rüzgar santrallerinin yerleşim problemlerinin çözümlenmesindeki en önemli etki gölge etkisidir. Santral içindeki her türbin hakim rüzgar yönüne göre yerleştirilmesine rağmen, türbinler birbirlerini etkiler ve arkada kalan türbinlerin dönme hızları azalır. Bu sebeple gölge etkisi ile enerji kayıpları ile hesaplama yapılması gereklidir (Karasu & Yüksel, 2018).

Gölge etkisi bilinerek kurulum yapılabilir. Gölge etkisinden türbinler kaçırılabilirse tercih edilen çözüm budur ancak gölge etkisinden kaçınılmıyorsa saha kurulmadan önce olası üretim kayıpları hesaplanır ve yatırım hesaplanmasında göz önünde bulundurulmalıdır.

Gölge etkisi işletme esansında müdahale edilebilecek, etkisi azaltılabilecek bir husus değildir ancak işletmeyi ilgilendiren kısım SCADA tarafından türbinin gölge etkisi

altında kaldığına dair bir bildiri geldiğinde türbine uzaktan müdahale etmeye çalışmamak olacaktır.



Şekil 1.2. Gölge etkisinin bilgisayar ortamında simüle edilmesi [4]

1.1.2. Kanat hasarları ve arızaları

Kanat hasarları ve erozyonu üretimi azaltır. Kanatlar akla gelebilecek en olumsuz koşullarda çalışmaktadır. Bütün hava olaylarına maruz kalırken çok yüksek hızlarda çalışmaktadırlar. Rutin kontroller ve bakımlarla yatırımın daha uzun süre faal kalmasını sağlayacaktır (*Wind Turbine Blade Repair - Fair Wind LLC, t.y.*).

Kanat üzerinde, kanadın uç taraflarına yerleştirilmiş, 4-6 adet bakır plakalar halinde sıralanmış yıldırım yakalama uçları bulunabilir. Yakalama uçları bir iletken ile türbin gövdesinden toprağa bağlantılıdır. Bu sistem yıldırımdan korunma sistemi (LPS- Lightning Protection System) olarak adlandırılır. Yıldırım arızaları, yıldırımdan korunma sistemlerinde hasarlara sebep olabilir. Periyodik bakım kapsamında bu iletkenlerin dirençleri düzenli olarak ölçülür ve direnç değerine göre hasarlı olup olmadığı anlaşılabilir.

Rüzgâr hızı nominal hızın üzerindeyken rüzgâr türbininin aerodinamik torkunu ayarlamak için pitch açısı kontrolü en yaygın araçtır. Pitch açısı kontrolü için en yaygın çalışılan kontrolör orantısal-integral-türev (PID) kontrolördür (Sougueh & Görel, 2022). Pitch açısının ayarlanmasıyla yüksek hızlarda türbinin nominal üretim seviyesinde üretim yapmasını sağlamaktır (Fidan & Çimen, 2021). Pitch sistemleri elektrik motorlarıyla ya da hidrolik sistemlerle çalışabilir. Bu iki farklı çalışma prensibi için motor arızaları, sürücü arızaları, hidrolik arızalar (hidrolik pompa, valf arızaları, hortum, yardımcı röle vs.) ve yazılımsal arızalar en sık karşılaşılan arızalardır.

Türbinlerin rüzgarı doğru şekilde alabilmesi ve üretimini sağlıklı seviyede yapabilmesi için kanatlarına açı yaptırması gereklidir. Kanatların rüzgara göre uygun açı yapmaması, 3 kanadın aynı açığa ulaşmaması veya 3 kanadın açılarını senkron


yapmaması yahut gerçekte yaptığı açı ile SCADA yaptığı açı arasında fark olması gibi arızalar görülebilir. Kanat üzerinde kar birikmesi ise dönerek çalışan sistemlerde istenmeyen bir durumdur. 3 kanadın ağırlık dengesi bozulmuş olur. Bu durumda SCADA sistemine uyarı vererek türbin duruşa geçebilir. Kanat açı hataları mekanik sebepler, yazılımsal hatalar veya kanat üzerine kar birikmesi gibi dış etkenlerden kaynaklı olabilir.

1.1.3. Rulman hasarları


Rulmanlar dönen makinelerde yaygın olarak kullanılmaktadır. Rulmanların iç yapısı ile ilgili bilgi edinebilmek için makine yataklarından titreşim ölçülebilir.

Rulman hasarlanması durumunda ilk önce dış bilezikte kabarma şeklinde kendini gösterir. Kabarma derinleştikçe oluşan titreşimlerin genliği artar (Orhan vd., 2003).


Yanlış montaj, yanlış hizalama, zayıf yağlama aşırı ısınma rulman hasarlarına sebep olabilir (Öztürk, 2020).



Şekil 1.3. Rulman arızalarının titreşim frekansı [8]



Şekil 1.4. Sıcaklık ölçümü ile rulman arızasının belirlenmesi-hasarlı



Şekil 1.5. Sıcaklık ölçümü ile rulman arızasının belirlenmesi-sağlam

Şekil 1.4 ve Şekil 1.5'te görülen çizimler rulman sıcaklarının SCADA'dan alınan verilere göre karşılaştırılmasıdır. Şekil 1.4'te görülen rulmanda yeşil çizgilerin zaman zaman mavi çizgilerin üzerinde seyrettiği gözükmemektedir. Buradaki verilere göre Şekil 1.4'teki rulmanın değişmesi sonucuna varılmıştır. Şekil 1.5'te ise zaman zaman yeşil çizginin mavi çizgileri geçtiği görülmüş bu verilere göre ise türbinin sağlıklı ancak düzenli takip edilmesi gerektiği sonucuna varılmıştır.

Yeşil çizgiler NDE ve mavi çizgiler DE tarafındaki sensörlerden alınan verilerdir.

1.1.4. Dişli sistemler ve dişli kutusu hasarları

Dişlilerdeki olası hatalar mil (eksen kaçıklığı, dengesizlik, gevşeklik) problemleri ve diş (aşınma, çizilme, çatlak) ile ilgili problemler olarak sınıflandırılabilir. Diğer makine elemanlarında olduğu gibi titreşim analizi ile dişli hataları belirlenebilir. Hata türüne göre titreşim frekansı özgün olmaktadır. Bu hatalar üretim ve montaj kaynaklı olabileceği gibi malzeme yorulmasına bağlı olarak da oluşabilir (Orhan & Aktürk, 2003).

Yaw dişlilerinde kırılma, dişli kutusunun dişlilerinde kırılma, dişli kutusunun zemine sabitlenen ayaklarının az veya fazla torklanması gibi montaj hataları karşımıza çıkmaktadır.

1.1.5. Hidrolik arızalar

Türbin modellerine göre farklılık göstermekle birlikte hidrolik sistemler kanat açıları ayarlamak, yaw mekanizmasının çalışması, rotor kilitlemeleri veya frenleme gibi sistemlerde kullanılır. Hidrolik sistemler yüksek bir basınçla çalıştığı için sistem dahilinde olan pompalar, hidrolik hortumlar, valfler, sensörler ve yardımcı röleler

arızalanabilir. Bu işlevler için hidrolik ünite sistemi kullanılan türbinlerde bu tarz arızalarla fazlaca karşılaşılabilir.

1.1.6. Haberleşme arızaları

MTU: Master Terminal Unit, SCADA sistemlerinde ana kontrol görevini üstlenen bilgisayar veya bilgisayar ağlarıdır.

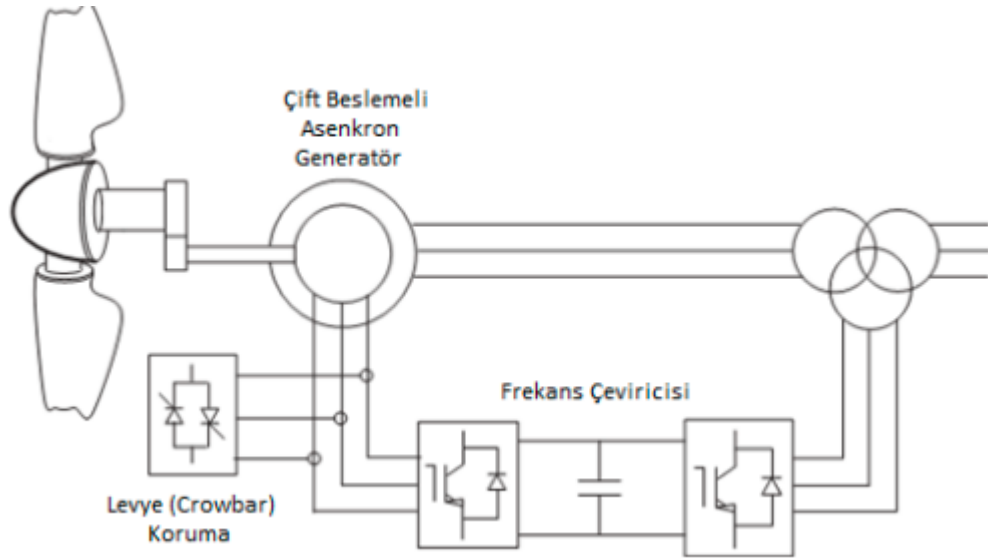
RTU: Remote Terminal Unit, şebekede bulunan sistem değişkenlerini toplayan ve bunu belirli iletişim protokolleri ile MTU'ya aktaran yapılardır.

İletişim Sistemi: RTU ile MTU arasında ve RTU ile diğer PLC, sensörler arasındaki bilgi alışverişini sağlayan sistemlerdir (Çelikpençe & Zaim, 2016).

İletişim sistemlerinde görülen arızalar, fiber kablolarında kopukluk, fiber sonlandırma kutusundaki arızalar, PLC, RTU, sensör ya da yazılımsal hatalardan kaynaklı olabilir. Haberleşme arızalarında genellikle türbin duruşu yaşanmaz ancak SCADA ile kontrolü ve verilerinin okunabilmesi de mümkün değildir ancak bazı haberleşme arızaları önemli bilgileri taşıdığı için bu haberleşmenin kesilmesi türbin duruşuna sebep olabilir.

1.1.7. Generatör, konverter ve diğer elektrik arızaları

Generatörün stator sargı uçları şebekeye doğrudan bağlanırken, rotor sargı uçları bir frekans çeviricisi aracılığı ile bağlanmaktadır. IGBT tabanlı 3 faz tam dalga akım kontrollü gerilim kaynağı (AKGK) olarak tasarlanan frekans çeviricisi, alt çeviricinin bir kondansatör bloğu üzerinde sırasıyla art arda AA-DA-AA dönüşümünü yapacak biçimde bağlanmasıyla oluşturulmaktadır. Mekanik hıza bağlı olarak rotorda endüklenen gerilimin frekansı ile şebekenin frekansını birbirinden ayırıştırarak enerji akışını sağlamaktadır.



Şekil 1.6. ÇBAG (DFIG) Genel şeması [11]

Rotor tarafı konverter ve şebeke tarafındaki konverter ardışık olarak bir kondansatör ile bağlanmıştır. Sistemdeki bu iki dönüştürücünün kontrol edilmesi bağımsız ve ayrı ayrı olmaktadır. Aktif ve reaktif gücü rotor tarafındaki konverterden, şebeke tarafındaki konverterden ise DA bara gerilimini kontrol ederek sistem çalışır (İnal, 2012).

Konverter yapısının, soğutma sistemlerinde görülen arızalar (radyatör arızaları, conta eskimeleri, montaj hataları, hortum hasarları), sensör arızaları, IGBT kartları arızası veya DC bara arızaları görülebilir.

Generatör tarafında fırça arızaları, sensör, rulman, sıcaklık arızaları, sargı yalıtımlarının bozulması, mekanik arızalar görülebilir.

Rotor ve stator sargılarında yalıtımın bozulması, yaşlanma, ısı etkileri, titreşim gerilmeleri, gerilim yükselmeleri, çevresel koşullar (nem, sıcaklık) yalıtım hatalarının kaynağını oluşturur (Öztürk, 2020).

Diğer elektrik arızaları kapsamında ise yardımcı röle arızaları, kontaktör ve sigorta arızaları, aydınlatma arızaları gibi genel elektriksel arızalar sıklıkla karşımıza çıkarken nadiren iç ihtiyaç transformatörlerinde ve step-up transformatörlerinde de arızalar görülebilir.

1.2.Yapay Sinir Ağları ve Genel Özellikleri

YSA ilk olarak Rosenblatt tarafından perceptron adı ile oluşturulmuştur. YSA'nın amacı optimum parametre değerlerini belirleyerek verilerin doğru şekilde sınıflandırılmasını sağlamaktır. Her döngü sonrası (iterasyon, epoch) hata oranını güncellemekte ve bu oranlar ağırlık parametrelerine dağıtılarak her düğümün aldığı değerlerin yenilenmesi sağlanmaktadır (Tezer, 2024).

Yapay sinir ağları (YSA) biyolojik nöronların yapısından etkilenerek oluşturulmuş bir makine öğrenmesi yöntemidir. Ağın giriş katmanında girdi değerleri tanımlanır sonrasında veriler katmanlardan geçer. Her katmandaki farklı sayıdaki düğüm noktasından geçerek, bu noktalara nöron ismi verilir, verinin sayısal değeri hesaplanmakta ve önceki değeri ile karşılaştırılmaktadır. Karşılaştırma neticesinde aradaki fark sıfıra yaklaştırılmak istenir ve böylelikle ağın öğrenmesi gerçekleştirilmiş olur. Ağın başarısı doğruluk fonksiyonları ile ölçülmektedir. Ağın yapısı temelde, girdi katmanı, gizli katman ve çıkış katmanından oluşur.

Yapay sinir ağının birçok türü bulunmaktadır. Tiplerine, katman sayılarına, öğrenme yöntemlerine göre birçok farklı şekilde sınıflandırılabilir.


İleri beslemeli ağlar: Girdi katmanından çıktı katmanına doğru ilerleyen ağlardır.

Geri beslemeli ağlar: Girdi verilerinin sadece ileri yönlü değil geri yönlü de olabildiği ağlardır. Çıktılar, girdi olarak kullanılabilir.

Öğretmenli öğrenme: Ağ eğitiminde çıktıların istenilen değerleri ağa tanıtılabiliyorsa öğretmenli öğrenme gerçekleşmiş olmaktadır. Girdiler ve çıktılar ağa verilir, öğrenme sürecinin ardından test yapılır ve gerçek sonuçlar ile kıyaslanmakta ve hataların en aza indirgenmesi sağlanmaktadır.

Öğretmensiz öğrenme: Ağ eğitiminde çıktıların istenilen değeri ağa tanıtılmadan öğrenme işlemi gerçekleşiyorsa öğretmensiz öğrenme gerçekleşmiş olur. Veriler içindeki istatistiksel dağılımdan yararlanır (Yüksel, 2023).

Yapay sinir ağları matematiksel olarak girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı katmanlarından oluşur. Girdiler, yapay sinir ağlarının öğrenmesi için girilen verilerdir. Ağırlık değeri ise girdi verilerinin bir çarpan ile değerlendirilmesidir. Ağırlık değerinin büyüklüğü ve küçüklüğü verinin önemi hakkında bir şey ifade etmez. Toplam fonksiyonu, girdilerden gelen bilgileri birleştirerek hesaplama yapmak için kullanır. Aktivasyon fonksiyonu, çıktıların belirlenmesinde yardımcı olur. Lineer, Step, Sigmoid gibi aktivasyon fonksiyonları kullanılır (Korkmaz, 2022).



Şekil 1.7. Çeşitli aktivasyon fonksiyonları (Sarıkaya, 2023)

Sigmoid fonksiyonu en çok kullanılan aktivasyon fonksiyonu türüdür. Veriler 0 ile 1 arasında sınırlandırılır. Tanh fonksiyonu ise verileri -1 ile 1 arasında sınırlar bu da fonksiyonun çalışma yönünü değiştirdiği için sigmoid fonksiyonuna göre daha iyi bir performans sağlar (Sarıkaya, 2023).

Girdiler ile ağırlıkların çarpılması sonucunda NET girdiler bulunur. NET ifadesi Network (Ağ) ifadesinin kısaltmasıdır. NET değerinin hesaplanmasında çeşitli yöntemler vardır. Toplama yöntemi ile hesaplama aşağıdaki denklemde görülebilir (Yüksel, 2023).

$$NET = \sum_{i=1}^n x_i \cdot w_i \quad (1.1)$$

Buradan anlaşıldığı kadarıyla ilk veriden n. veriye kadar olan veriler ağırlıklarla çarpılır ve toplanarak NET girdiler bulunur. X değerleri girdileri ve w ise ağırlıkları temsil etmektedir. YSA modelinin tamamında aynı hesaplama yöntemi kullanılmak zorunda değildir. Yapay nöronlarda elde edilen NET değeri aktivasyon fonksiyonlarına iletilmektedir. Aktivasyon fonksiyonu NET değerini işleyerek çıktıya dönüştürür. Ara katmandaki nöron sayılarının artması YSA sistemini karmaşık hale getirebilir ancak daha iyi çıktılar üretir (Yüksel, 2023).

2. KAYNAK ARAŞTIRMASI

Yapay sinir ağlarının ve makine öğrenmesi kullanarak güneş ışınımı verilerini tahmin etmek üzere yapılmış bir çalışma “Bursa ve Çanakkale illerine ait 2015-2019 yılları arasındaki günlük/saatlik güneş ışınım verileri kullanılarak yapay sinir ağları ile tahminleme, makine öğrenmesi algoritması ile sınıflama analizi yapılmıştır (Korkmaz, 2022).”

Güneş santralinin üretim verilerini tahmin etmek üzere yapılan çalışmada santralin fizibilite yazılımını geliştirmek amaçlanmıştır, “Bu çalışmada yenilenebilir enerji kaynaklarından olan güneş ve rüzgâr enerji santrallerinin meteorolojik ve jeolojik verilere bağlı olarak üretim verilerinin tahmini yapılarak Güneş Enerji Santrali Fizibilite Yazılımı geliştirilmiştir. Üretim tahmininin yapılabilmesi için yapay zekâ uygulamalarından olan doğrusal olmayan modellerin tahminindeki başarısı nedeniyle ileri beslemeli geri yayımlı Yapay Sinir Ağı (YSA), Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ve derin öğrenme modeli Uzun Kısa Süreli Bellek (Long/Short Term Memory-LSTM) kullanılmıştır (Geçmez, 2022).”

Rüzgar hızının tahmin ederek planlı çalışmaların yönlendirilmesi amaçlanmış farklı yapay sinir ağları ve modelleri kullanılarak karşılaştırılmaları yapılmıştır, “Çalışmada Türkiye’nin Yalova ilinde bulunan bir istasyondan elde edilen veriler ile YSA yöntemleri kullanılarak kısa süreli rüzgar hızı tahmini yapılmıştır. Analizde 1 saat sonrasını tahmin ederek oluşacak ani arıza ve bakım planlamalarına müdahale edilmesi amaçlanmıştır (Kiriş, 2021).”

Endüstride indüksiyon yöntemi ile ısıtma, eritme, sertleştirme uygulamalarının yapıldığından ve değişen sıcaklık ile sisteminin toplam endüktansının değişmesi, rezonans noktasının kayması ve verimin düşmesinden bahsedilmektedir. YSA kullanarak sistemin değişen sıcaklığa göre değişecek endüktansını tahmin edip kontrolcüye doğru sinyallerin gitmesi ve verimin artması hedeflenmiştir, “CENOS programında hesaplanan veriler MATLAB ortamında yapay sinir ağları kullanılarak, sistemin doğal rezonans frekansı tahmin edilmiştir. PLC ile PC’yi MATLAB içinde MODBUS protokolü kullanarak haberleştirilmiştir. PLC’nin gönderdiği input verisi ile yapay zeka algoritması istenilen çıkışı doğru tahmin ederek tekrar PLC’ye istenilen veriyi göndererek sistemi kontrol etmiştir (Toprak, 2021).”

“Tahmin modellerinde çoklu regresyon analizi (ÇRA) ve yapay sinir ağı (YSA) yöntemleri uygulanmıştır. Çoklu regresyon analizinde regresyon varsayımlarının sağlanarak analizlerin yapılmasına dikkat edilmiş ve stepwise metodu ile modeller

oluşturulmuştur. Yapay sinir ağı modellerinde ise gerekli normalizasyon işlemleri yapılmış ve ileri beslemeli geri yayılım algoritması kullanılarak denemeler sonucunda en iyi modeller oluşturulmuştur (Kotan, 2022).”

Enerji iletim hatları üzerinde de YSA kullanılarak enerji iletim hatlarında meydana gelen arızaları tanımlama, algılama ve konumlarını tespit etme üzerine bir çalışma yapılmıştır. Çalışmada ileri beslemeli sinir ağları, evrişimli sinir ağları ve genel regresyon sinir ağları kullanılmıştır (Shakiba, 2022).

Rüzgar türbinlerinin yapısı lineer ve lineer olmayan kısımlarına ayrıştırılarak incelenmiş, çevresel şartlar ve sensörlerden elde edilen bilgilerdeki kirliliklerden arındırmak için arttırılmış gerçeklik önerilmiştir, ardından YSA arttırılmış gerçeklik verilerine göre güncellenmiştir. Rüzgar türbinlerinde arıza sınıflandırılması evrişimsel sinir ağları-convolutional katmanlar ile arızaların sınıflandırılması sağlanmıştır (Rahimilarki vd., 2021).

Rüzgar türbini uygulamalarında YSA ve destek vektör makinası (Support Vector Machine) algoritmaları kullanarak arızaların tespiti ve sınıflandırılması yapılmış olup 4320 farklı arızada yüzde 99’a varan doğrulukta tahmin gerçekleştirmiştir. Ayrıca çalışmada DVM’nin YSA’dan daha iyi sonuç verdiği görülmüştür (Shah vd., 2022).

Rüzgar enerjisindeki taleplerin göz önüne alındığında arıza teşhisinin önemli hale geldiği, arıza teşhisi için ileri makine öğrenmesi ile arıza teşhisinin yapılmaya çalışıldığı anlatılmıştır. İleri makine öğrenmesi, arıza ve rüzgar gibi anahtar kelimeler ile seçilen 14 makale Engineering Villae and IEEE gibi kütüphanelerden alınmıştır. Bu makaleler incelendiğinde ise sadece 8 tanesinin titreşim sensörlerden direk verileri toplayarak çalışmayı yaptığı görülmüştür. Tek-çok katmanlı ve hibrit olmak üzere 2 farklı tip ileri makine öğrenmesi tasarlanmış ve sonuçlarının doğruluk oranının diğer algoritmalarından üstün olduğu görülmüştür (Yaw vd., 2022).

Arızanın erken tespiti için evrişimli sinir ağları ve uzun-kısa süreli yapay sinir ağları kullanılmıştır. Geri yayılım algoritmaları ve vektör makinelerine göre yüzde 99,77 daha başarılıdır (Wei vd., 2022).

Makine öğrenmesi ve yapay sinir ağları kullanılarak arızaların sınıflandırılması incelenmiştir. Daha spesifik olarak, kirlenme, gölgeleme, bozulma, kısa devreler ve standart test şartlarını içeren arızaların tespiti ve sınıflandırılması için bir dizi özelleştirilmiş sinir ağının geliştirilmesi düşünülmektedir. Karışıklık matrisi ve RPN kullanarak hata tespiti ve sınıflandırmayı değerlendirilmiştir (Srinivasa vd., 2021).

Rüzgar türbinlerinde YSA ile arıza teşhisi yapılmıştır, “Küresel boyuttaki artan enerji ihtiyacı ve azalan enerji kaynakları yenilenebilir enerji kaynakları kullanımının artmasına yol açmıştır. Enerjinin sürekliliği ve ulaşılabilirliği bakımından rüzgar enerjisi bu kaynaklar arasından en büyük paya sahip olmuştur. Enerji ihtiyacının büyüklüğü türbin boyutlarını da arttırmaktadır. Büyüyen türbin boyutları ve artan elektriksel güç, güvenlik ve verim faktörleri sebebi ile sistemde arızalara karşı tespit yapısı gerektirmektedir. Bu çalışmada üç kanatlı, yatay eksenli, yunuslama kontrollü, 4.8MW gücündeki türbinde arıza tespiti yapılmıştır. Sistem üzerinden alınan çeşitli veriler bir karar yapısı tarafından işlenerek sistem durumu hakkında karar vermektedir. Ölçülen veya hesaplanan giriş verileri yapay sinir ağı (YSA) ile arıza teşhisinde kullanılmıştır (Yılmaz & Yuksel, 2022).”

Deniz üstü rüzgar türbinleri için yapılan çalışmada, bu türbinlerin karadan uzak ve çalışma ortamının zor-kötü olduğu için generatör arızalarında ciddi bir sorun oluşturduğundan bahsedilmektedir. Yapay zeka teknolojisinin araştırma sonuçlarına dayanan bu çalışma, deniz üstü türbinleri için arıza tahminine odaklanmaktadır (Han vd., 2020).

Rüzgar türbini modelleri üzerinde, YSA temelli arıza bulma uygulaması yapmışlardır. Rüzgar türbinini dönüştürme sistemleri, dişli kutusu ve konverter üzerinde geri yayılım algoritmali YSA çalışması yapılmış. Çalışma MATLAB temelli Simulink ve M-Files ile yapılmış ve tablolaştırılmıştır. Bütün rüzgar modelinde bu eğitim algoritması ve testi uygulanmış, test edilmiştir (Rekha vd., 2019).

Makine öğrenmesi temelli arıza teşhis yöntemleri hem teorik açıdan hem de endüstriyel uygulamalar açısından gözden geçirilmiştir. Çalışma geleneksel makine öğrenmesi, yapay sinir ağları, derin öğrenme, transfer öğrenmenin avantajı ve dezavantajından bahsetmiştir (Sun vd., 2021).

Rüzgar türbinleri için çok yönlü bir arıza tespiti sunmaktadır bunu yaparken de sensörlerden yararlanmaktadır. Özellikle, yüksek verimliliğe sahip hafif ağırlıklı bir model ile oylamaya dayalı yapay sinir ağları ile %96.5 arıza yakalama oranı ile yapılandırılmıştır. Bu modelin sağlamlığı çeşitli sayısal denemeler ile onaylanmıştır. Ayrıca diğer yöntemlerle de kıyaslanmıştır ve çalışan modelin daha yüksek doğruluğa sahip olduğu görülmüştür (Zhang vd., 2022).

YSA ile iletim-dağıtım hatlarında meydana gelen arızalar ve arızaların yerini tahmin etmek üzerine yapılmış bir çalışmadır. İletim hatları üretilen enerjinin kaynaktan yüke doğru gitmesi için kullanılırken dağıtım hatları iletilen gücün yüklerle doğru

dağılması için kullanılır. Bu çalışmada rüzgar türbinlerinin uzun bir iletim hattına bağlanması incelenmiştir. Hatlardaki karmaşıklık arttıkça arıza ihtimali de artmaktadır ve bu durum tüketicilerin hizmet almasını engellemektedir. Müşteri memnuniyetini ilk olarak arızanın temizlenmesi sağlar. Arızayı temizlemek için arıza doğru ve akıllı şekilde tespit edilmelidir. Yapay sinir ağları ise hatayı gidermekte akıllı bir araçtır. Bu çalışmada yapay sinir ağları kullanılarak arızaların sınıflandırılması yapılmıştır. Modelle MATLAB-Simuling ile yapılmış olup gerilim bilgisi input olarak sisteme verilmiştir (Nanda vd., 2019).

Rüzgar türbin generatörlerindeki rulman arızaları için yapay sinir ağı destekli erken arıza tespiti üzerinde çalışmışlardır. Dişli kutusu arızalarının rüzgar türbinlerinde büyük duruşa sebep olduğunu belirterek, dişli kutusu arızaların büyük bir kısmı ise dişli kutusu yataklarından kaynaklandığı ifade edilmektedir. Dişli kutusu yataklarında aşınma ve yıpranmaların erkenden fark edilmesi etkili bir önleyici bakım olacaktır ve bu bakım genel bakım maliyetini azaltacaktır. Bu çalışmada kontrol ve veri toplama sisteminden gelen verileri kullanarak yapay sinir ağları temelli izleme sistemi önerilmiştir. Bu uygulama İsveç'in güneyinde yer alan karasal tip 2MW'lık türbinlerde uygulanmıştır. Sonuçlar, önerilen yapay sinir ağı temelli durum izleme sisteminin ciddi hasarları gösterebildiğini göstermektedir (Bangalore & Tjernberg, 2015).

Türkçe karşılığı artık ağlar olan bir uygulama ile arıza tahmini üzerinde çalışma yapmışlardır. Rüzgar türbinlerinin çalışması sırasında SCADA sistemi tarafından büyük miktarda veri üretilecektir. Bu verilerin hacimlerinin aşırı büyük olması, arıza özelliklerini çıkarmanın zor olması, sinyaller birbirleri ile ilişkili olması ve bir arıza için birden fazla sensörün alarm vermesi sebebiyle ayrıca SCADA'da yaşanan dalgalanmaların alarmların kaçırılmasına ya da yanlış alarmlara neden olabileceği belirtilmektedir. Bu yanlışlıkları çözmek için derin ağ adı verilen (DRN) yeni bir yöntem önerilmiştir. Önerilen DRN, SCADA üzerindeki verileri kullanmaktadır ve yayınlanmış bazı hata tespit yöntemlerinden daha iyi performans gösterdiği görülmektedir (Liu vd., 2023).

Hava yolu iç hat yolcu tahminleri yapmak üzere bir yaklaşım yapılmıştır. "Havayolu yolcu taleplerin tahmini, hava taşımacılığı operasyonlarının planlanmasındaki en önemli konudur. Bu çalışmada; Türkiye'nin iç hat havayolu taşımacılığı talebini tahmin edebilmek için iki yapay zeka tabanlı model yaklaşımı ile bir ekonometrik model yaklaşımı önerilip, test edilip karşılaştırılmıştır. Yapay zeka tabanlı tahmin yöntemi

olarak Uyarlanabilir Ağ Tabanlı Bulanık Çıkarım Sistemi ve Yapay Sinir Ağları yaklaşımları, ekonometrik model olarak ise geleneksel Çoklu Doğrusal Regresyon analizi kullanılmıştır (Yüksel, 2023).”



3. MATERYAL VE METOD

Önleyici bakım faaliyetleri ile arıza gelmeden yapılacak türbin duruşları ile üretim kayıplarının mümkünse olmaması ya da en alt seviyede sınırlandırılması hedeflenir.

Bu çalışmada işletme süresinde oluşabilecek hidrolik arızaları önceden tahmin eden yapay sinir ağları tabanlı algoritmalar kullanılmıştır. Böylelikle önleyici faaliyetler ile rüzgarsız zamanlarda olası arızaları değerlendirilecektir.

Bu amaçla hidrolik sistemlerin bağlantılı olduğu ekipmanlar ve sensörler göz önünde bulundurularak türbin SCADA sistemi üzerinden 2 senelik veriler derlenmiştir.

Türbin üzerinde ilgili bölgelerde bulunan sensörler veriler çeşitli haberleşme protokolleri ile SCADA'ya taşınmaktadır. SCADA sisteminde konu ile alakalı veriler analiz edilmiş ve derlenmiştir. Hidrolik arızaların geldiği tarih ve saat SCADA sisteminde arıza kaydı olarak kayıtlıdır. Buradaki yaklaşım arıza geldiği andan önceki ilk 60 saniyenin arızalı olarak kabul edildiği ikinci 60 saniyelik kısmın ise arızasız olarak kabul edilmesi varsayımı ile veri setleri oluşturulmuştur.

3.1. Veri Kaynakları

Modellerde 2020-2022 yılları arasındaki gerçekleşen hidrolik arızaların verileri kullanılmıştır. Değişken olarak hidrolik yağ sıcaklığı, rüzgar hızı, hidrolik ünite basıncı, yaw fren basıncı, iç ortam sıcaklığı, dış ortam sıcaklığı, üretim verisi ve kanat açıları değerlendirilmiştir. Çizelge 3.1 'de çalışmaya dahil edilen veriler ve ölçü birimlerinin özeti sunulmuştur.

Çizelge 3.1. Veri değişkenleri

Değişkenler	Veri Birimi
Hidrolik Yağ Sıcaklığı	Santigrat Derece
Rüzgar Hızı	m/sn
Hidrolik Ünite Basıncı	bar
Yaw Fren Basıncı	bar
İç Ortam Sıcaklığı	Santigrat Derece
Dış Ortam Sıcaklığı	Santigrat Derece
Üretim	kW
Kanat Açısı-1	Derece
Kanat Açısı-2	Derece
Kanat Açısı-3	Derece

3.2. Doğru Olarak Sınıflandırılmış Örnekler ve Karışıklık Matrisi

Doğru olarak sınıflandırılmış örnekler: Modelin doğru şekilde sınıflandırdığı örnek sayısının toplam veri sayısına oranının yüzdelik olarak ifadesidir. Sınıflandırmanın genel olarak ne kadar iyi bir performans verdiğini göstermektedir (Samawi vd., 2022).

$$\text{Doğruluk (\%)} = \frac{DN + DP}{DN + DP + YN + YP} \times 100 \quad (3.1)$$

Karışıklık matrisi: Gerçek ve tahmin edilmiş sınıflamalar hakkındaki bilgilerin derlendiği matristir.

Çizelge 3.2. Karışıklık matrisi

		Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	DN (Doğru Negatif)	YN (Yanlış Negatif)
	POZİTİF	YP (Yanlış Pozitif)	DP (Doğru Pozitif)

Doğru sınıflandırılmış veriler DN ve DP kısımlarıdır.

Modelin performansı doğru sınıflandırılmış verilerin sayısı ile orantılıdır ve sınıflandırmanın ne kadar iyi olduğunu gösterir (Işık, 2024).

Karışıklık matrisinde kullanılan terimler şu şekilde ifade edilmektedir,

DN (Doğru Negatif): Bir örneğin negatif olduğu doğru tahminlerin sayısıdır.

YP (Yanlış Pozitif): Bir örneğin pozitif olduğu yanlış tahminlerin sayısıdır.

YN (Yanlış Negatif): Bir örneğin negatif olduğu yanlış tahminlerin sayısıdır.

DP (Doğru pozitif): Bir örneğin pozitif olduğu doğru tahminlerin sayısıdır.

3.3. Sınıflandırma Doğruluğu, Duyarlılık, Seçicilik ve F Ölçütü

Duyarlılık ve seçicilik, veri testinin sonuçlarını yorumlamak ve açıklamak için sıklıkla kullanılan bir istatistiksel yöntemdir. Sınıflandırma duyarlılık ve seçicilik aşağıda gösterilen eşitliklerle bulunmaktadır.

$$Duyarluluk(\%) = \frac{DP}{DP + YN} \times 100 \quad (3.2)$$

$$Seçicilik(\%) = \frac{DN}{DN + YP} \times 100 \quad (3.3)$$

$$Hata Oranı (\%) = \frac{YN + YP}{DN + DP + YN + YP} \times 100 \quad (3.4)$$

Duyarlılık: Tüm veriler içerisindeki gerçek pozitiflerin, pozitif tahmin edilen bütün verilere oranıdır. Modelin, pozitif örneklerinin doğru bir şekilde tasnif edilme yeteneğini ölçer. Duyarlılık oranı yüksekse bu az sayıda yanlış negatif olduğu anlamına gelir.

Seçicilik: Tüm veriler içerisindeki gerçek negatiflerin, negatif tahmin edilen bütün verilere oranıdır. Modelin, negatif örneklerinin doğru bir şekilde tasnif edilme yeteneğini ölçer. Seçicilik oranı yüksekse bu az sayıda yanlış pozitif olduğu anlamına gelir.

F ölçütü: Daha anlamlı karşılaştırma sonuçları için hem duyarlılık hem de seçiciliğin beraber kullanıldığı F Ölçütü tanımlanmıştır. F ölçütü duyarlılık ve seçiciliğin harmonik ortalamasıdır.

$$F \text{ Ölçütü} = \frac{2 \times Duyarluluk \times Seçicilik}{Duyarluluk + Seçicilik} \quad (3.5)$$

3.4.Kappa İstatistikleri

Aynı kategoriye dayalı sınıflandırma arasındaki uyumu ölçen istatistiksel bir yöntemdir. Basit bir yüzde hesabından daha güvenilir bir ölçümdür. Değerlendiriciler veya değerlendirici içi güvenilirliğini test etmek için kullanılan güçlü bir yöntemdir. -1 ile 1 arasında değişen oranlar olabilir. 0 şans eseri gerçekleşen bir uyumu 1 ise mükemmel bir uyumu ifade etmektedir. Çizelge 3.3'te detayları belirtilmiştir (Syahrini vd., 2023).

Kappa, benzer verilmiş cevaplar içerisinde rastgele olmuş olabilecekleri çıkarıyor.

$$\kappa = \frac{P_0 - P_e}{1 - P_e} \quad (3.6)$$

P_0 : Gözlemciler arasındaki uyumun yüzdesi

P_e : Gözlemciler arasındaki rastgele uyumun yüzdesi

Çizelge 3.3. Kappa katsayı uyuşma oranı [35]

Kappa Katsayısı	Uyuşma Oranı
< 0.00	Hiç uyuşma olmaması
0.01 – 0.02	Önemsiz uyuşma olması
0.21 – 0.40	Orta derecede uyuşma olması
0.41 – 0.60	Eksriyetle uyuşma olması
0.61 – 0.80	Önemli derecede uyuşma olması
0.81 – 1.00	Neredeyse mükemmel uyuşma olması

3.5. Diğer Yaklaşımlar

Ortalama Mutlak Hata (Mean Absolute Error-MAE): Gerçek değerler ile tahmin edilen değerler arasındaki mutlak farkların ortalaması olarak ifade edilebilir. Ortalama mutlak hatanın düşük olması, modelin performansının iyi olduğunu gösterir (Işık, 2024).

$$A = \frac{1}{n} \sum_{i=1}^n |x_i - x'_i| \quad (3.7)$$

Göreceli Mutlak Hata (Relative Absolute Error -RAE): Modelin performansını ölçmek için kullanılan bir hata metriğidir. Modelin mutlak hatalarının toplamının, modelin gerçek değerlerinin gerçek değer ortalamalarından sapmasının toplamına oranıdır. Göreceli mutlak hatanın düşük olması, modelin performansının iyi olduğunu gösterir.

$$RAE = \frac{\sum_{i=1}^n |x_i - x'_i|}{\sum_{i=1}^n |x_i - \bar{x}|} \quad (3.8)$$

\bar{x} : Gerçek değerlerin ortalaması

x_i : Gerçek değerler

x'_i : Tahmin edilen değerler

n: Verideki örnek sayısı

Kök Ortalama Kare Hata (Root Mean Square Error-RMSE): Modelin performansını ölçmek için kullanılan bir hata metriğidir. Tahmin edilen değerler ile gerçek değerler arasındaki farkın karelerinin ortalamasının kareköküdür (Işık, 2024).

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - x'_i)^2} \quad (3.9)$$

RMSE'nin küçük olması modelin tahminlerinin doğru olduğunu gösterir.

Kök Göreceli Kare Hata (Root Relative Squared Error - RRSE): Gerçek değerler ile tahmin edilen değerler arasındaki farkın karelerinin toplamının, gerçek değerler ile gerçek değerlerin ortalama arasındaki farkın kareleri toplamının oranının kareköküdür (Işık, 2024).

$$RRSE = \sqrt{\frac{\sum_{i=1}^n (x_i - x'_i)^2}{\sum_{i=1}^n (x_i - \bar{x}_i)^2}} \quad (3.10)$$

RRSE'nin küçük olması modelin tahminlerinin doğru olduğunu gösterir.

3.6.WEKA Üzerinde Kurgulanan Model Özellikleri ve Kullanılan Yöntemler ve Algoritmaların Karşılaştırılması

Veri setleri üzerinde Multilayer Perceptron (MLP), Radial Basis Function Classifier (RBF Classifier), SMOreg (Support Vector Machines for Regression) algoritmaları kullanılmıştır. Programdaki parametre ayarları varsayılan ayarlardır.

Algoritmalarının temel karşılaştırılması Çizelge 3.4'teki gibidir.

Çizelge 3.4. Algoritmaların karşılaştırılması

Özellik/Algoritma	Multilayer Perceptron (MLP)	Radial Basis Function Classifier (RBF Classifier)	SVMreg
Model Türü	Yapay Sinir Ağı	Radial Basis Fonksiyonlu Sinir Ağı	Destek Vektör Makinesi (SVR)
Kullanım Amacı	Sınıflandırma ve Regresyon	Sınıflandırma	Sınıflandırma ve Regresyon
Temel Prensip	Katmanlı yapılar ile veriyi öğrenme	Radial Basis fonksiyonları kullanarak öğrenme	Destek Vektör Makinesi algoritmasına dayalı
Aktivasyon Fonksiyonları	Sigmoid, Tanh, ReLU	Gaussian, Multiquadric	Linear (kernel bazlı)
Parametreler	Gizli katman sayısı, öğrenme hızı, momentum	RBF sayısı, öğrenme hızı	Kernel tipi, C parametresi
Eğitim Süresi	Genellikle uzun	Genellikle kısa	Orta derecede
Güçlü Yönler	Karmaşık veri yapılarında iyi performans	Hızlı eğitim, non-linear problemlerde etkili	Non-linear regresyonda güçlü performans

3.7. Multilayer Perceptron (MLP)

Doğrusal veya doğrusal olmayan veriler arasındaki ilişkiyi belirler. Giriş katmanları, çıkış katmanlar ve gizli katmanlar MLP sınıflandırıcısının temelini oluşturur. Çoğunlukla tek bir gizli katman problemin çözümü için yeterli olmaktadır. Bazı durumlarda bulguları arttırmak için ek gizli katmanlar eklenebilir ancak bu katmanlar veri işleme süresini arttıracaktır (Samawi vd., 2022).

Giriş katmanı giriş verilerini işler. Tahmin ve sınıflama gibi işlemler çıkış katmanına aittir. MLP’de girişten çıkışa kadar ileri beslemeli bir yapı kurulur (Femi & Thylashri, 2022).

Ağdaki düğümlerin tamamı sigmoid fonksiyonudur. Sigmoid fonksiyonu verilerin 0 ile 1 arasında kalmasını sağlar.

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (3.11)$$

3.7.1. MLP’de parametre ayarları

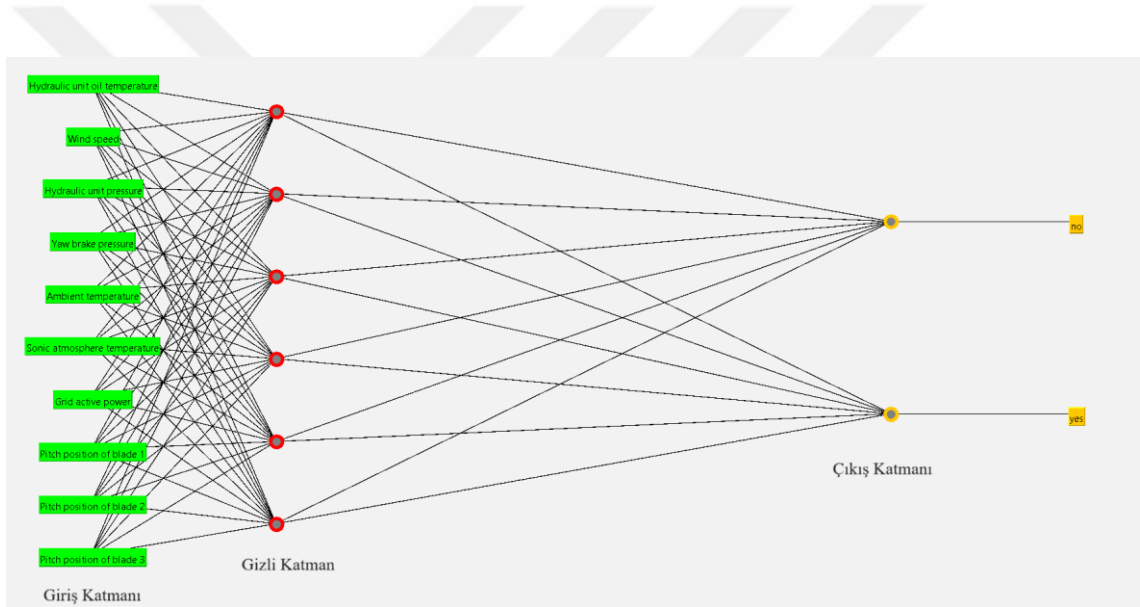
Öğrenme Oranı (Learning Rate): Ağırlıkların güncellenme hızını belirler.

Yüksek olması modelin kararsız olmasına neden olurken düşük olması modelin yavaş öğrenmesine neden olabilir.

Momentum: Ağırlıkların daha dengeli bir şekilde güncellenmesini ve modelin yerel minimum noktalardan kaçınmasını sağlar. Yüksek olması öğrenme sürecini hızlandırabilir ancak kararsızlık riski de artar. Düşük olması öğrenme sürecini yavaşlatır ancak kontrollü bir model olabilir.

Gizli Katmanlar (Hidden Layers): Gizli katman sayısını ve her katmandaki nöron sayısı belirlenir. Gizli katmanın az olması daha anlaşılır bir model sunar, aşırı öğrenme riski azalır ancak doğrusal olmayan ilişkilerin incelenmesi için yetersiz kalabilir, karmaşık ilişkileri yakalayamaz ve doğru tahmin olasılığı azalır.

Eğitim Süresi (Training Time): Modelin eğitilmesi için gereken iterasyon (epoch) sayısını belirler. Kısa bir eğitim süresi modelin veriyi tam olarak öğrenmemesine sebep olurken, uzun bir eğitim süresi aşırı öğrenmeye sebep olur.



Şekil 3.1. MLP yapısı

3.7.2. MLP’de K parçalı çapraz doğrulama

Veri seti k parçaya bölünür. K-1 adet veri öğrenme için kalan veri test için kullanılır. Test kümesi her defasında değiştirilir ve veri k kadar eğitilmiş olur (Korkmaz, 2022).

K-kat çaprazlama örneğinin yapılan çalışmada K=4,10 ve 24 için değerlendirilmeleri görülebilir.

Çizelge 3.5. MLP K=24 için karışıklık matrisi

K=24		Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	221	19
	POZİTİF	26	214

Çizelge 3.6. MLP K=10 için karışıklık matrisi

K=10		Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	227	13
	POZİTİF	17	223

Çizelge 3.7. MLP K=4 için karışıklık matrisi

K=4		Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	212	28
	POZİTİF	26	214

Çizelge 3.8. MLP'de K-kat çapraz doğrulama değerlendirme sonuçları

MLP	Doğruluk	Duyarlılık	Seçicilik	Hata Oranı	F Ölçütü	Zaman Skoru [sn]
K=24	90,63%	91,85%	89,47%	9,38%	90,64%	8
K=10	93,75%	94,49%	93,03%	6,25%	93,76%	3
K=4	88,75%	88,43%	89,08%	11,25%	88,75%	1

Çizelge 3.9. MLP'de K-kat çapraz doğrulama için istatistiksel değerlendirmeler

MLP	Kappa İstatistiği	Ortalama Mutlak Hata	Kök Ortalama Kare Hata	Göreceli Mutlak Hata	Kök Göreceli Kare Hata
K=24	0,8125	0,1172	0,2403	23%	48%
K=10	0,875	0,1003	0,2227	20%	44%
K=4	0,775	0,1496	0,2856	29%	57%

K değerinin yüksek seçilmesi modelin doğruluğunu artırırken, düşük seçilmesi daha hızlı eğitim sağlar. Çizelge 3.7 ve 3.8'de görüleceği üzere her zaman k değerinin

arttırılması en iyi sonucu vereceği anlamına gelmez çalışılan model için en optimum değer parametrelerden ayarlanmalıdır.

3.7.3. MLP’de verilerin yüzdesel olarak ayrılması

Program verilerin yüzdesel olarak test ve eğitim setine ayrılmasına olanak sağlar. Bu seçenek eğitim setiyle modelin eğitilmesini ve test setiyle de modelin test edilmesini temsil etmektedir. Eğitim seti ile test seti arasındaki oranı anlayabilmek için 3 farklı seçenek ile model eğitilmiş ve test edilmiştir. Verilerin yüzde 50, 66, 80 oranında eğitim setine ayrıldığı farklı senaryolar kıyas edilmiştir.

Çizelge 3.10. Verilerin %80 eğitim ve %20 test şeklinde ayrılması

80% (384veri test-96 veri eğitim)		Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	43	4
	POZİTİF	1	48

Çizelge 3.11. Verilerin %66 eğitim ve %33 test şeklinde ayrılması

66% (317veri test-163 veri eğitim)		Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	70	3
	POZİTİF	3	87

Çizelge 3.12. Verilerin %50 eğitim ve %50 test şeklinde ayrılması

50% (240 veri test-240 veri eğitim)		Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	101	17
	POZİTİF	13	109

Çizelge 3.13. MLP’de verilerin yüzdesel ayrılmasının değerlendirme sonuçları

MLP Eğitim Seti Oranı	Doğruluk	Duyarlılık	Seçicilik	Hata Oranı	F Ölçütü	Zaman Skoru [sn]
80%	94,79%	92,31%	97,73%	5,21%	94,94%	1
66%	96,32%	96,67%	95,89%	3,68%	96,28%	1
50%	87,50%	86,51%	88,60%	12,50%	87,54%	1

Çizelge 3.14. MLP'de verilerin yüzdesel ayrılmasının istatistiksel değerlendirmeleri

MLP Eğitim Seti Oranı	Kappa İstatistiği	Ortalama Mutlak Hata	Kök Ortalama Kare Hata	Göreceli Mutlak Hata	Kök Göreceli Kare Hata
80%	0,89	0,1167	0,2251	23%	45%
66%	0,925	0,0878	0,1683	17%	33%
50%	0,749	0,1639	0,2874	33%	57%

Eğitim seti oranının artması daima daha doğru sonuca ulaşacağımızı ya da azalması daha kötü sonuca götüreceği anlamına gelmediği Çizelge 3.12 ve 3.13'te görülmektedir. MLP'de verilerin yüzdesel olarak ayrılmasında eğitim seti oranı ile test seti oranının optimum şekilde belirlenmesi gerekir. Genel bir yaklaşım olarak eğitim setinin test setinden daha yüksek oranda tutulması beklenir. Çalışılan model için eğitim seti oranının değişmesi zaman skorunu değiştirmemiştir.

3.8. Radyal Tabanlı Fonksiyon Sınıflandırıcı (Radial Basis Function Classifier-RBFC)

RBFC yapay sinir ağlarında ileri beslemeli bir modeldir. RBFC sınıflandırıcısının yapısı girdi katmanı, gizli katman ve çıktı katmanıdır. Giriş katmanı verilerin toplandığı kısımdır. Gizli katmanda hesaplamalar gerçekleşir (Aryan vd., 2022). Gizli katman ile çıktı katmanı arasındaki bağlantı ağırlıkları MLP'ye kıyasla hızlı ve yerel minimumlardan bağımsız olarak belirlenebilir. Gizli katman Gaussian fonksiyonuna sahiptir. Girdi vektörü ile gizli katmanın merkez vektörü arasındaki mesafe bu fonksiyon ile belirlenir (Fu & Wang, 2003).

$$\varphi(x) = \exp\left(-\frac{\|x - c\|^2}{2\sigma^2}\right) \quad (3.12)$$

$\varphi(x)$: Çıktı

x : Girdi vektörü

c : RBF'nin merkez vektörü

σ : Standart sapma

$\|x - c\|^2$: Öklid mesafesini temsil eder

3.8.1. RBFC’de parametre ayarları

Number of Function: Bu parametre modelin Gaussian fonksiyon sayısını belirler. Sayısı arttıkça modelin karmaşıklığı artar ve artması aşırı öğrenmeye sebep olabilir.

Scale Optimization Option: Ölçek optimizasyon seçeneğini belirler. 1 numaralı seçenek bütün model için tek bir faktör belirler, 2 numaralı seçenek her Gaussian fonksiyonu için ayrı bir ölçek belirler, 3 numaralı seçenek her Gaussian fonksiyonu ve her öznelik kombinasyonu için ayrı ölçek sunar. 1 numaralı seçenek daha hızlı çözüm sağlarken 3 numaralı seçenek daha iyi performans sunabilir.

3.8.2. RBFC’de K parçalı çapraz doğrulama

K-kat çaprazlama örneğinin yapılan çalışmada K=4,10 ve 24 için değerlendirilmesi Çizelge 3.18 ve Çizelge 3.19’da görülebilir.

Çizelge 3.15. RBFC K=24 için karışıklık matrisi

K=24	Tahmin Edilen Değerler		
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	165	75
	POZİTİF	57	183

Çizelge 3.16: RBFC K=10 için karışıklık matrisi

K=10	Tahmin Edilen Değerler		
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	164	76
	POZİTİF	41	199

Çizelge 3.17: RBFC K=4 için karışıklık matrisi

K=4	Tahmin Edilen Değerler		
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	156	84
	POZİTİF	42	198

Çizelge 3.18. RBFC'de K-kat çapraz doğrulama değerlendirme sonuçları

RBFC	Doğruluk	Duyarlılık	Seçicilik	Hata Oranı	F Ölçütü	Zaman Skoru [sn]
K=24	72,50%	70,93%	74,32%	27,50%	72,59%	1
K=10	75,63%	72,36%	80,00%	24,38%	75,99%	1
K=4	73,75%	70,21%	78,79%	26,25%	74,25%	1

Çizelge 3.19. RBFC'de K-kat çapraz doğrulama için istatistiksel değerlendirmeler

RBFC	Kappa İstatistiği	Ortalama Mutlak Hata	Kök Ortalama Kare Hata	Göreceli Mutlak Hata	Kök Göreceli Kare Hata
K=24	0,45	0,36	0,41	74%	82%
K=10	0,51	0,36	0,4	73%	81%
K=4	0,475	0,36	0,4	73%	81%

3.8.3. RBFC'de verilerin yüzdesel olarak ayrılması

Verilerin yüzde 50, 66, 80 oranında eğitim setine ayrıldığı farklı senaryolar kıyas edilmiştir.

Çizelge 3.20. RBFC'de verilerin %80 eğitim ve %20 test şeklinde ayrılması

	80% (384veri test-96 veri eğitim)	Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	39	8
	POZİTİF	10	39

Çizelge 3.21. RBFC'de verilerin %66 eğitim ve %33 test şeklinde ayrılması

	66% (317veri test-163 veri eğitim)	Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	58	15
	POZİTİF	30	60

Çizelge 3.22. RBFC'de verilerin %50 eğitim ve %50 test şeklinde ayrılması

	50% (240 veri test-240 veri eğitim)	Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	88	30
	POZİTİF	37	85

Çizelge 3.23. RBFC'de verilerin yüzdesel ayrılmasının değerlendirme sonuçları

RBFC Eğitim Seti Oranı	Doğruluk	Duyarlılık	Seçicilik	Hata Oranı	F Ölçütü	Zaman Skoru [sn]
80%	81,25%	82,98%	79,59%	18,75%	81,25%	1
66%	72,39%	80,00%	65,91%	27,61%	72,27%	1
50%	72,08%	73,91%	70,40%	27,92%	72,11%	1

Çizelge 3.24. RBFC'de verilerin yüzdesel ayrılmasının istatistiksel değerlendirmeleri

RBFC Eğitim Seti Oranı	Kappa İstatistiği	Ortalama Mutlak Hata	Kök Ortalama Kare Hata	Göreceli Mutlak Hata	Kök Göreceli Kare Hata
80%	0,62	0,3434	0,3839	69%	77%
66%	0,4524	0,3562	0,392	71%	78%
50%	0,4421	0,3922	0,4227	78%	84%

3.9.Sıralı Minimal Optimizasyon (Sequential Minimal Optimization - SMO)

SMO WEKA'da bulunan Destek Vektör Makinalarına (Support Vector Machine-SVM) ait bir makine öğrenmesi algoritmasıdır. SVM'ler sınıflandırma ve regresyon problemlerinde kullanılır.

3.9.1. SMO'da parametre ayarları

C (Complexity Parameter): Modelin esnekliği ile hata oranı arasında denge kurar. Yüksek bir c değeri daha esnek bir model sunarken aşırı öğrenme riskini de beraberinde getirir. Düşük bir c değeri aşırı öğrenme riskini azaltırken daha hatalı sonuçları beraberinde getirebilir.

Kernel Tipi: Veri noktaları arasındaki ilişkiyi belirlemek için kullanılır. WEKA'da çeşitli seçenekler mevcuttur.

Epsilon Parametresi: Gerçek değer ile tahmin değeri arasındaki tolerans değerini ifade eder. Değeri ne kadar küçükse o kadar hassas bir model oluşur.

Tolerans: Optimizasyon süresi boyunca kullanılan toleransları belirler.

3.9.2. SMO'da K parçalı çapraz doğrulama

K-kat çaprazlama örneğinin yapılan çalışmada K=4,10 ve 24 için değerlendirilmesi Çizelge 3.28 ve Çizelge 3.29'da görülebilir.

Çizelge 3.25. SMO K=24 için karışıklık matrisi

K=24		Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	164	76
	POZİTİF	162	78

Çizelge 3.26. SMO K=10 için karışıklık matrisi

K=10		Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	144	96
	POZİTİF	140	100

Çizelge 3.27. SMO K=4 için karışıklık matrisi

K=4		Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	126	114
	POZİTİF	107	133

Çizelge 3.28. SMO'da K-kat çapraz doğrulama değerlendirme sonuçları

SMO	Doğruluk	Duyarlılık	Seçicilik	Hata Oranı	F Ölçütü	Zaman Skoru [sn]
K=24	50,42%	50,65%	50,31%	49,58%	50,48%	1
K=10	50,83%	51,02%	50,70%	49,17%	50,86%	1
K=4	53,96%	53,85%	54,08%	46,04%	53,96%	1

Çizelge 3.29. SMO'da K-kat çapraz doğrulama için istatistiksel değerlendirmeler

SMO	Kappa İstatistiği	Ortalama Mutlak Hata	Kök Ortalama Kare Hata	Göreceli Mutlak Hata	Kök Göreceli Kare Hata
K=24	0,0083	0,4958	0,7042	99%	140%
K=10	0,0167	0,4917	0,7012	98%	140%
K=4	0,0792	0,4604	0,6785	92%	135%

3.9.3. SMO'da verilerin yüzdesel olarak ayrılması

Verilerin yüzde 50, 66, 80 oranında eğitim setine ayrıldığı farklı senaryolar kıyas edilmiştir.

Çizelge 3.30. SMO'da verilerin %80 eğitim ve %20 test şeklinde ayrılması

	80% (384 veri test-96 veri eğitim)	Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	39	8
	POZİTİF	10	39

Çizelge 3.31. SMO'da verilerin %66 eğitim ve %33 test şeklinde ayrılması

	66% (317 veri test-163 veri eğitim)	Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	58	15
	POZİTİF	30	60

Çizelge 3.32. SMO'da verilerin %50 eğitim ve %50 test şeklinde ayrılması

	50% (240 veri test-240 veri eğitim)	Tahmin Edilen Değerler	
		NEGATİF	POZİTİF
Gerçek Değerler	NEGATİF	88	30
	POZİTİF	37	85

Çizelge 3.33. SMO'da verilerin yüzdesel ayrılmasının değerlendirme sonuçları

SMO Eğitim Seti Oranı	Doğruluk	Duyarlılık	Seçicilik	Hata Oranı	F Ölçütü	Zaman Skoru [sn]
80%	81,25%	82,98%	79,59%	18,75%	81,25%	1
66%	72,39%	80,00%	65,91%	27,61%	72,27%	1
50%	72,08%	73,91%	70,40%	27,92%	72,11%	1

Çizelge 3.34. SMO'da verilerin yüzdesel ayrılmasının istatistiksel değerlendirmeleri

SMO Eğitim Seti Oranı	Kappa İstatistiği	Ortalama Mutlak Hata	Kök Ortalama Kare Hata	Göreceli Mutlak Hata	Kök Göreceli Kare Hata
80%	0,62	0,3434	0,3839	69%	77%
66%	0,4524	0,3562	0,392	71%	78%
50%	0,4421	0,3922	0,4227	78%	84%

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Program sonuçlarının bütüncül karşılaştırması yapılmıştır, en iyi sonuç veren algoritmanın J48 karar ağacına göre en önemli 3 parametresi belirlenmiş ve hata yaptığı noktalar program çıktısı olarak paylaşılmıştır.

Verilerin yüzdesel olarak ayrılmasının ve K-kat çapraz doğrulamanın karşılaştırmalı sonuçları çizelgeler halinde verilmiştir. Karşılaştırma doğruluk oranları ve F ölçütü üzerinde yapılmıştır.

Çizelge 4.1 ve Çizelge 4.2’de MLP algoritmasının %66 oranında eğitim ve %33 oranında test setine ayrılması yaklaşımı en iyi sonucu vermiştir.

Çizelge 4.1. Verilerin yüzdesel olarak ayrılması yaklaşımı ile doğruluk oranları

Verilerin Yüzdesel Olarak Ayrılması Yaklaşımı ile Doğruluk Oranları	Multilayer Perceptron (MLP)	Radial Basis Function Classifier (RBF Classifier)	SMOreg
50%	87,50%	72,08%	57,08%
66%	96,32%	72,39%	56,44%
80%	94,79%	81,25%	50,00%

Çizelge 4.2. Verilerin yüzdesel olarak ayrılması yaklaşımı ile F ölçütü

Verilerin Yüzdesel Olarak Ayrılması Yaklaşımı ile F Ölçütü	Multilayer Perceptron (MLP)	Radial Basis Function Classifier (RBF Classifier)	SMOreg
50%	87,54%	72,11%	61,99%
66%	96,28%	72,27%	63,59%
80%	94,94%	81,25%	50,94%

Çizelge 4.3 ve Çizelge 4.4’te MLP algoritmasının K-kat çapraz doğrulama yaklaşımında K=10 için en iyi sonucu verdiği görülmektedir.

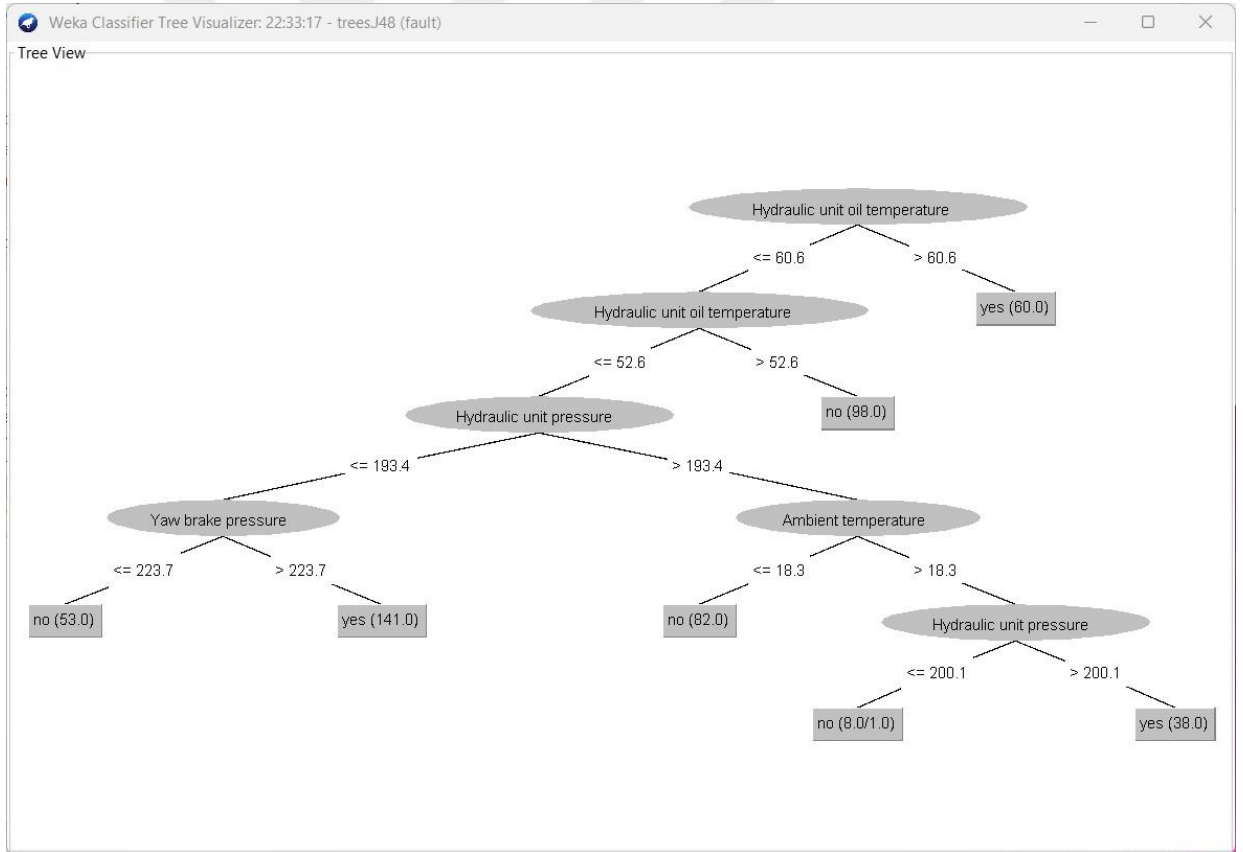
Çizelge 4.3. Verilerin K parçalı çapraz doğrulaması yaklaşımı ile doğruluk oranları

Verilerin k Parçalı Çapraz Doğrulaması Yaklaşımı ile Doğruluk Oranları	Multilayer Perceptron (MLP)	Radial Basis Function Classifier (RBF Classifier)	SMOreg
K=24	91,00%	73,00%	50,00%
K=10	94,00%	76,00%	51,00%
K=4	89,00%	74,00%	54,00%

Çizelge 4.4. Verilerin K parçalı çapraz doğrulaması yaklaşımı ile F ölçütü

Verilerin k Parçalı Çapraz Doğrulaması Yaklaşımı ile F Ölçütü	Multilayer Perceptron (MLP)	Radial Basis Function Classifier (RBF Classifier)	SMOreg
K=24	90,64%	72,59%	50,48%
K=10	93,76%	75,99%	50,86%
K=4	88,75%	74,25%	53,96%

Veri setimizdeki özelliklere dayanarak bir kurallar silsilesi oluşturulmak istendiğinde karar ağaçlarından faydalanabiliriz. Buradaki yaklaşım karar ağacı metodu ile en önemli veri başlıklarını analiz etmektedir. Böylelikle önemli başlıklarda yapılan hataların hangi bölgelerde kaldığı analiz edilebilir ve daha iyi sonuçlara gitmek için fikir verebilir. Karar ağacı yöntemi ile sınıflandırma yapılarak hidrolik ünite yağ sıcaklığı, hidrolik ünite basıncı, yaw fren basıncı en önemli kriterler olduğu görülmüştür.



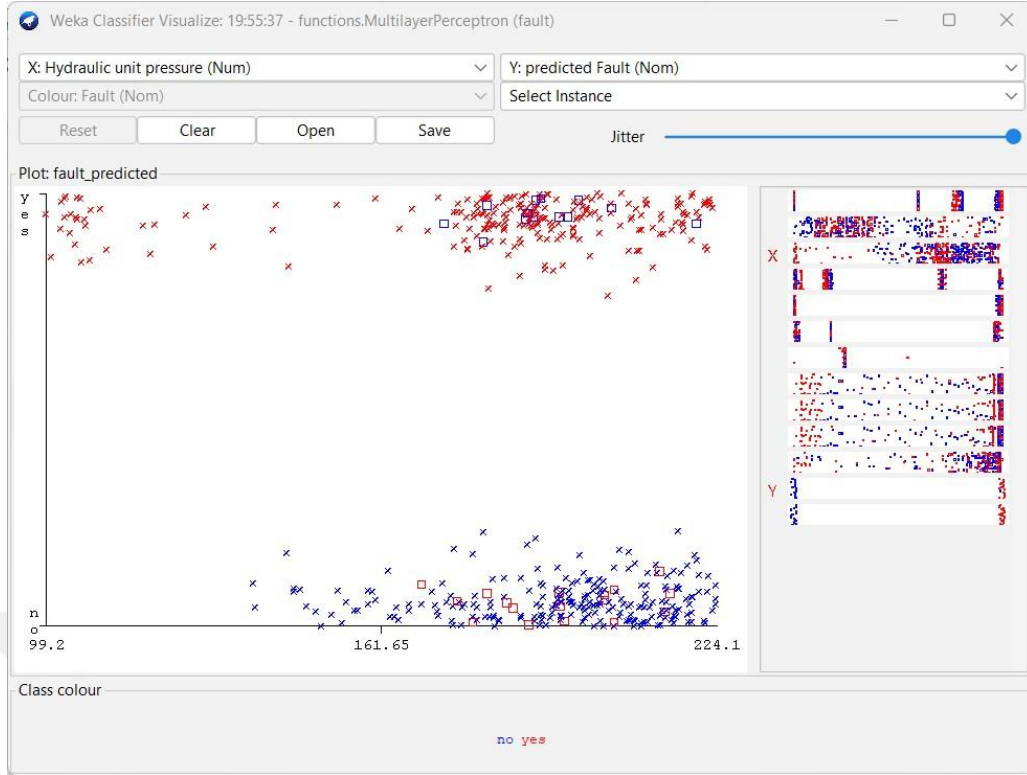
Şekil 4.1. J48 Karar ağacı

Hidrolik ünite yağ sıcaklığı, hidrolik ünite basıncı, yaw fren basıncı en önemli kriterler olduğu Şekil 4.1’de J48 karar ağacı sınıflandırma yöntemine göre görülmüştür.



Şekil 4.2. Hidrolik ünite yağ sıcaklığı-arıza tahmini ilişkisi

Şekil 4.2’de hidrolik ünite yağ sıcaklığında tahmin edilen verilerin yaklaşık 38 derece ve 60 derece arasında hata yaptığı WEKA programındaki sınıflandırma hataları çıktılarında görülmektedir.



Şekil 4.3. Hidrolik ünite basıncı-arıza tahmini ilişkisi

Şekil 4.3'te hidrolik ünite basıncında tahmin edilen verilerin yaklaşık 162 bar ile 220 bar arasında hata yaptığı WEKA programındaki sınıflandırma hataları çıktılarından görülmektedir.



Şekil 4.4. Yaw fren basıncı-arıza tahmini ilişkisi

Şekil 4.4'te yaw fren basıncının tahmin edilen verilerin yaklaşık 223 bar ile 228 bar arasında hata yaptığı WEKA programındaki sınıflandırma hataları çıktılarında görülmektedir.

5. SONUÇLAR VE ÖNERİLER

5.1.Sonuçlar

Elektrik üretiminin kesintiye uğramaması, elektrik piyasa işlemlerini, üretim ve dağıtım süreçlerini etkileyen önemli bir husustur ayrıca yatırımcı için maddi kayıplara sebep vermektedir. Elektrik kesintisini önleyici bakımlar ile engellemek en ekonomik yaklaşımdır. Bu tez çalışmasında hidrolik arızaları önceden tahmin ederek önleyici bakım faaliyetleri oluşturmak hedeflenmiştir. Türbin SCADA'sından okunan 2020-2022 yılları arasındaki verilerin yapay sinir ağı ve diğer algoritmalar ile değerlendirilmesi yapılmıştır. Veri setleri üzerinde Multilayer Perceptron (MLP), Radial Basis Function Classifier (RBF Classifier), SMOreg (Support Vector Machines for Regression) algoritmaları kullanılmıştır. Kullanılan algoritmaların parametreleri WEKA programında varsayılan olarak belirlenmiş haliyle işleme alınmıştır. Algoritmalar verilerin yüzdesel olarak ayrılması ve K-kat çapraz doğrulama yaklaşımları ile çalıştırılmıştır. Verilerin yüzdesel olarak ayrılmasında %50, %60 ve %80 oranları seçilmiştir, K kat çapraz doğrulama yaklaşımında ise K değerinin 4, 10 ve 24 olarak seçilmiştir ve neticeleri kaydedilmiştir. Sonuçlar Kappa İstatistiği, Ortalama Mutlak Hata, Kök Ortalama Kare Hata, Göreceli Mutlak Hata, Kök Göreceli Kare Hata istatistiksel yaklaşımları ve Duyarlılık, Seçicilik, Hata Oranı ve F Ölçütü kriterleri ile değerlendirilmiş ve karşılaştırmalı olarak sunulmuştur. Çalışma kapsamında MLP algoritmasının %66 eğitim, %33 test olarak yüzdesel dağılımı ile yapılan çalışmanın %96,32'lik doğruluk oranı ile en başarılı sonucu verdiği görülmüştür.

5.2.Öneriler

Tez çalışmasının sonuçlarına dayanarak yapay sinir ağı algoritmalarından MLP algoritmasının başarı oranını gerçek veriler ile test etmek için SCADA sistemine doğrudan entegre edilmesi ve verilerin canlı olarak sürekli okunur hale gelmesi sağlanarak arızanın önceden tahmin edilmesi sağlanabilir.

Geçmiş yıllarda yaşanan arıza kaynaklı duruş sürelerinin gelecek aylar için tahmin edilmesi ve operasyon giderleri ile gelir arasında bir tahminler ile finansal öngörü sağlanması.

WEKA'da kullanılan algoritmaların parametrelerinin en uygun değerinin belirlenmesi için optimizasyon algoritmalarının kullanılarak neticeye ulaşılması düşünülebilir.

Veri çeşitliliğini ve sayısını arttırarak farklı ilişkideki verilerin ortaya çıkarılması sağlanabilir. Bununla birlikte Çeşitli karar ağaçları algoritmaları ile çalışılarak arıza sınıflaması için en doğru verilerin seçilmesi neticesinde o verilerin algoritmaya kazandırılması sağlanabilir.

Önleyici bakım kapsamında tez çalışması içerisinde yer alan arızalar değerlendirilip önleyici faaliyetler oluşturulabilir.

Sınıflandırma hatalarına bakarak programın en çok hata yaptığı aralık belirlenebilir. Bu aralıktaki hata sebepleri araştırılabilir.



6. KAYNAKLAR

- Aryan, B. K., Sobhana, O., Prabhakar, G. C., & Reddy, N. A. (2022). Fault Detection and Classification in Micro Grid Using AI Technique. *Proceedings - 2022 International Conference on Recent Trends in Microelectronics, Automation, Computing and Communications Systems, ICMACC 2022*, 517-522. <https://doi.org/10.1109/ICMACC54824.2022.10093359>
- Bangalore, P., & Tjernberg, L. B. (2015). An Artificial Neural Network Approach for Early Fault Detection of Gearbox Bearings. *IEEE Transactions on Smart Grid*, 6(2), 980-987. <https://doi.org/10.1109/TSG.2014.2386305>
- Çelikpençe, M., & Zaim, S. (2016). Farklı Lokasyonlardaki RES ve HES SCADA Sistemlerinden Alınan Verilerin Merkezileştirilerek Ortak Platformdan Raporlanması.
- Femi, D., & Thylashri, S. (2022). Human Voice Emotion Recognition Using Multilayer Perceptron. *Proceedings of the 2022 International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems, ICSES 2022*. <https://doi.org/10.1109/ICSES55317.2022.9914336>
- Fidan, Ş., & Çimen, H. (2021). Rüzgar Türbinlerinde Tork ve Kanat Eğim Açısı Kontrolü.
- Fu, X., & Wang, L. (2003). Data Dimensionality Reduction with Application to Simplifying RBF Network Structure and Improving Classification Performance. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, 33(3), 399-409. <https://doi.org/10.1109/TSMCB.2003.810911>
- Geçmez, A. (2022). Güneş ve Rüzgar Enerji Santrallerinde Üretim Değerlerinin İklim Parametrelerine Bağlı Olarak Yapay Zekâ Yöntemleri ile Tahmini ve Güneş Enerjisi Fizibilite Yazılımının Geliştirilerek Üretim Tahmininin Yapılması.
- Han, H., Liu, X. W., & Bian, J. Y. (2020). The Application of Artificial Intelligence Technology in The Fault Diagnosis of Floating Wind Turbine Generator. *Proceedings - 2020 5th International Conference on Electromechanical Control Technology and Transportation, ICECTT 2020*, 305-307. <https://doi.org/10.1109/ICECTT50890.2020.00074>
- İşık, M. A. (2024). Hata İçeren Yazılım Modüllerinin Tespitinde Kullanılan Makine Öğrenmesi Algoritmalarının Çok Kriterli Karar Verme Yöntemleriyle Sıralanması.
- İnal, T. T. (2012). Üç Faz IGBT Köprü Doğrultucunun Tasarımı ve Çift Beslemeli Asenkron Generatör Tabanlı Rüzgar Türbin Sistemlerindeki Kontrolü.
- Karabacak, M., Kılıç, F., Cantaş, Y., Atmaca, Ö., & Küçük, T. V. (2017). Değişken Hızlı Rüzgar Türbinlerinde Kanat Ucu Hız Oranı Tabanlı Maksimum Güç İzleme Denetimi; Kapsamlı Bir Tasarım. *SAÜ Fen Bilimleri Enstitüsü Dergisi*. <https://doi.org/10.16984/saufenbilder.327114>
- Karasu, M. S., & Yüksel, B. (2018). Bir Rüzgar Enerji Santralindeki Rüzgar Türbinlerinin Yerleşimlerinden Kaynaklanan Güç Kayıplarının Hesaplanması. *Balıkesir Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 20(2), 482-494. <https://doi.org/10.25092/baunfbed.485820>
- Kiriş, Z. N. (2021). Rüzgar Hızı Yük Tahmin Modelleri ve Yalova Bölgesinde Bir Uygulama.
- Korkmaz, E. (2022). Yapay Sinir Ağları ve Makine Öğrenmesi ile Güneş Işınımının Analizi: Bursa ve Çanakkale Örneği.
- Kotan, B. (2022). Hava Kirliliği Parametrelerinin Yapay Sinir Ağı (YSA) ve Çoklu Regresyon Algoritması İle Modellenmesi: Kocaeli Örneği.

- Liu, J., Wang, X., Wu, S., Wan, L., & Xie, F. (2023). Wind Turbine Fault Detection Based on Deep Residual Networks. *Expert Systems with Applications*, 213. <https://doi.org/10.1016/j.eswa.2022.119102>
- Nanda, R. P., Bisoi, D., Behera, A., Panigrahi, B. K., & Satapathy, A. K. (2019). Classification of Faults in A Wind Connected Power System Using Artificial Neural Network.
- Orhan, S., & Aktürk, N. (2003). Aktarma Organı Dişlilerinde Oluşan Fiziksel Hataların Titreşim Analizi ile Belirlenmesi. *İçinde Fak. Der. J. Fac. Eng. Arch. Gazi Univ. Cilt (C. 18, Sayı 3)*.
- Orhan, S., Arslan, H., & Aktürk, N. (2003). Titreşim Analiziyle Rulman Arızalarının Belirlenmesi. *İçinde Fak. Der. J. Fac. Eng. Arch. Gazi Univ. Cilt (C. 18, Sayı 2)*.
- Öztürk, H. K. (2020). Rüzgar Tübinlerinde İşletme Ve Bakım. *Mühendis ve Makina*. <https://doi.org/10.46399/muhendismakina.747092>
- Rahimilarki, R., Gao, Z., & Jin, N. (2021). Fault Diagnosis for Wind Turbine Systems by Using Neural Network and Deep Learning Techniques.
- Rekha, S. N., Jeyanthi, P. A., & Devaraj, D. (2019). Fault Prediction Model for Wind Energy Conversion Systems – A Neural Network Approach.
- Samawi, V. W., Yousif, S. A., & Al-Saidi, N. M. G. (2022). Intrusion Detection System: An Automatic Machine Learning Algorithms Using Auto- WEKA. 2022 IEEE 13th Control and System Graduate Research Colloquium, ICSGRC 2022 - Conference Proceedings, 42-46. <https://doi.org/10.1109/ICSGRC55096.2022.9845166>
- Sarıkaya, T. A. (2023). FPGA Based Artificial Neural Network Motor Control of PM Assisted Synchronous Reluctance Motor in Washers.
- Shah, H., Chothani, N., & Chakravorty, J. (2022). Fault Detection and Classification in Interconnected System with Wind Generation Using ANN and SVM. *Advances in Electrical and Electronic Engineering*, 20(3). <https://doi.org/10.15598/aeec.v20i3.4483>
- Shakiba, F. M. (2022). Artificial Neural Networks and Their Applications to Intelligent Fault Diagnosis of Power Transmission Lines.
- Sougueh, İ. M., & Görel, G. (2022). PI, PID ve GA-PID Kontrolör ile Rüzgar Türbinin Kanat Hatve Açısı Kontrolü. *Uluslararası Muhendislik Arastirma ve Gelistirme Dergisi*, 14(2), 502-513. <https://doi.org/10.29137/umagd.1036461>
- Srinivasa, S., Rao, M., & Srinivasan, D. (2021). Fault Detection and Classification in Photovoltaic Arrays Using Machine Learning.
- Sun, T., Yu, G., Gao, M., Zhao, L., Bai, C., & Yang, W. (2021). Fault Diagnosis Methods Based on Machine Learning and Its Applications for Wind Turbines: A Review. *IEEE Access*, 9, 147481-147511. <https://doi.org/10.1109/ACCESS.2021.3124025>
- Syahrini, Z., Priyadi, Y., & Herdiani, A. (2023). Validity of Cosine Similarity Measurement of Functional Requirements and Steps Performed Using Cohen Kappa on SRS Scenery Artifacts. *International Conference on Electrical Engineering, Computer Science and Informatics (EECSI)*, 631-636. <https://doi.org/10.1109/EECSI59885.2023.10295586>
- Tezer, D. (2024). Yapay Sinir Ağı Faktör Analizi Hibrit Modeli ile Yapay Sinir Ağı Modellerinin Sınıflama Başarılarının Karşılaştırılması.
- Toprak, M. (2021). PLC Kontrollü İndüksiyonlu Isıtma Sistemleri İçin YSA İle Farklı Çalışma Frekanslarında Sıcaklığa Bağlı Endüktans Değerinin Tahmini.

- Wei, W., Ruiqing, K., & Yu, Z. (2022). Overtemperature fault diagnosis of front bearing for main spindle based on CNN + LSTM. *Journal of Physics: Conference Series*, 2295(1). <https://doi.org/10.1088/1742-6596/2295/1/012004>
- Wind Turbine Blade Repair - Fair Wind LLC. (t.y.). Geliş tarihi 04 Eylül 2022, gönderen <https://fairwindres.com/wind-industry-maintenance/blade-repair/>
- Yavuz, İ., & Özbay, H. (2020). Rüzgar Türbinlerinde Kurulum ve Bakım Süreçleri: Bandırma Örneği.
- Yaw, C. T., Teoh, S. L., Koh, S. P., Yap, K. S., Chong, K. H., & Low, F. W. (2022). Fault Diagnosis in Wind Energy Management System using Extreme Learning Machine: A Systematic Review. *Journal of Physics: Conference Series*, 2319(1). <https://doi.org/10.1088/1742-6596/2319/1/012014>
- Yılmaz, O., & Yuksel, T. (2022). Artificial Neural Network Based Fault Diagnostic System for Wind Turbines. 2022 30th Signal Processing and Communications Applications Conference, SIU 2022. <https://doi.org/10.1109/SIU55565.2022.9864803>
- Yüksel, F. Ş. (2023). Türkiye'nin Havayolu Taşıyıcı Modellerine Göre Yolcu Talebinin Çoklu Doğrusal Regresyon, ANFIS ve YSA Teknikleri ile Tahminlenmesi.
- Zhang, Y., Liu, Q., Liu, W., & Zheng, W. (2022). Deployable Lightweight ANN-based Approach for Wind Turbine Fault Detection. 13th International Conference on Reliability, Maintainability, and Safety: Reliability and Safety of Intelligent Systems, ICRMS 2022, 28-34. <https://doi.org/10.1109/ICRMS55680.2022.9944585>

EKLER**EK-1** Analizde Kullanılan Veriler

Hydraulic unit oil temperature,Wind speed,Hydraulic unit pressure,Yaw brake pressure,Ambient temperature,Sonic atmosphere temperature,Grid active power,Pitch position of blade 1,Pitch position of blade 2,Pitch position of blade 3,Fault

16.9,8.3,204.2,241.1,-3.9,-3.9,0,90.5,90,90.4,0
 16.9,8,204,241,-3.9,-3.8,0,90.5,90,90.4,0
 16.9,7.4,203.7,241,-3.9,-3.8,0,90.5,90,90.4,0
 16.9,7.4,203.5,241.1,-3.9,-3.8,0,90.5,90,90.4,0
 16.9,7.1,203.3,241,-3.9,-3.6,0,90.5,90,90.4,0
 16.9,7.1,203.1,241,-3.9,-3.9,0,90.5,90,90.4,0
 16.9,7.6,202.9,241.1,-3.9,-3.8,0,90.5,90,90.4,0
 16.9,7.6,202.7,241,-3.8,-3.8,0,90.5,90,90.4,0
 16.9,7.7,202.5,241.1,-3.8,-3.9,0,90.5,90,90.4,0
 16.9,7.7,202.5,241.1,-3.9,-3.9,0,90.5,90,90.4,0
 16.9,7.8,202.3,241.1,-3.9,-3.9,0,90.5,90,90.4,0
 16.9,8,202.1,241.1,-3.9,-3.8,0,90.5,90,90.4,0
 16.9,7.7,201.7,241,-3.8,-3.7,0,90.5,90,90.4,0
 16.9,7.1,201.4,241,-3.8,-3.8,0,90.5,90,90.4,0
 16.9,6.1,201.2,241,-3.8,-3.7,0,90.5,90,90.4,0
 16.9,6,201.1,241,-3.8,-3.9,0,90.5,90,90.4,0
 16.9,5.3,200.9,241.1,-3.8,-3.7,0,90.5,90,90.4,0
 16.9,5.6,200.6,241,-3.8,-3.6,0,90.5,90,90.4,0
 16.9,5.7,200.4,241,-3.8,-3.5,0,90.5,90,90.4,0
 16.9,6.5,200.4,241.1,-3.8,-3.7,0,90.5,90,90.4,0
 16.9,6.2,200.1,241,-3.8,-3.6,0,90.5,90,90.4,0
 16.9,6.6,199.9,241,-3.8,-3.8,0,90.5,90,90.4,0
 16.9,6.6,199.7,241.1,-3.8,-3.6,0,90.5,90,90.4,0
 16.9,5.7,199.6,241.2,-3.8,-3.6,0,90.5,90,90.4,0
 16.9,6.1,199.3,241.2,-3.8,-3.8,0,90.5,90,90.4,0
 16.9,6.1,199.1,241.1,-3.8,-3.8,0,90.5,90,90.4,0
 16.9,4.9,199,241,-3.8,-3.5,0,90.5,90,90.4,0

16.9,5.6,198.8,241,-3.8,-3.8,0,90.5,90,90.4,0
16.9,5.6,198.8,241,-3.8,-3.8,0,90.5,90,90.4,0
16.9,5.6,198.8,241,-3.8,-3.8,0,90.5,90,90.4,0
16.9,5.6,198.8,241,-3.8,-3.8,0,90.5,90,90.4,0
16.9,5.6,198.8,241,-3.8,-3.8,0,90.5,90,90.4,0
16.9,5.2,197.9,241,-3.8,-3.6,0,90.5,90,90.4,0
16.9,4.8,197.7,241,-3.8,-3.5,0,90.5,90,90.4,0
16.9,5,197.5,241.1,-3.8,-3.6,0,90.5,90,90.4,0
16.9,5.7,197.3,240.9,-3.8,-3.8,0,90.5,90,90.4,0
16.9,6.4,197.2,241,-3.8,-3.8,0,90.5,90,90.4,0
16.9,6.1,196.9,241,-3.8,-3.9,0,90.5,90,90.4,0
16.9,5.4,196.8,241,-3.8,-3.6,0,90.5,90,90.4,0
16.9,5.4,196.6,241,-3.8,-3.7,0,90.5,90,90.4,0
16.9,5.3,196.4,241.1,-3.8,-3.6,0,90.5,90,90.4,0
16.9,5.8,196.3,241,-3.8,-3.9,0,90.5,90,90.4,0
16.9,6.2,196.1,241,-3.8,-4.1,0,90.5,90,90.4,0
16.9,5.7,195.9,241.1,-3.8,-3.5,0,90.5,90,90.4,0
16.9,5.2,195.9,241.1,-3.8,-3.8,0,90.5,90,90.4,0
16.9,4.6,195.6,241,-3.8,-3.7,0,90.5,90,90.4,0
16.9,4.2,195.5,241,-3.8,-3.6,0,90.5,90,90.4,0
16.9,4.2,195.3,241.1,-3.8,-3.8,0,90.5,90,90.4,0
16.9,4.3,195.1,241.1,-3.8,-3.7,0,90.5,90,90.4,0
16.9,4.6,194.9,241.1,-3.8,-3.8,0,90.5,90,90.4,0
16.9,4.6,194.8,241.1,-3.8,-3.9,0,90.5,90,90.4,0
16.9,4,194.6,241.1,-3.8,-3.7,0,90.5,90,90.4,0
16.9,4,194.4,241,-3.8,-3.7,0,90.5,90,90.4,0
16.9,4.1,194.4,241.2,-3.8,-3.6,0,90.5,90,90.4,0
16.9,4,194.2,241.1,-3.8,-3.8,0,90.5,90,90.4,0
16.9,3.3,194.2,241,-3.8,-3.6,0,90.5,90,90.4,0
16.9,3.8,194.1,241,-3.8,-3.6,0,90.5,90,90.4,0
16.9,4.3,193.8,241,-3.8,-3.8,0,90.5,90,90.4,0
16.9,5.4,193.6,241,-3.8,-3.8,0,90.5,90,90.4,0
16.9,5.6,193.5,241,-3.8,-3.7,0,90.5,90,90.4,0

16.9,6.1,193.4,241.1,-3.7,-3.7,0,90.5,90,90.4,1
16.9,6,193.2,241,-3.7,-3.6,0,90.5,90,90.4,1
16.9,6.2,193.1,241,-3.7,-3.7,0,90.5,90,90.4,1
16.9,6.3,192.8,241.1,-3.7,-3.8,0,90.5,90,90.4,1
16.9,6.6,192.7,241,-3.7,-3.6,0,90.5,90,90.4,1
16.9,6.3,192.6,241,-3.7,-3.5,0,90.5,90,90.4,1
16.9,6.5,192.3,241.1,-3.7,-3.7,0,90.5,90,90.5,1
16.9,6.6,192.2,241.1,-3.7,-3.9,0,90.5,90,90.4,1
16.9,6.4,192,241,-3.7,-3.8,0,90.5,90,90.4,1
16.9,6.2,191.9,241,-3.7,-3.7,0,90.5,90,90.4,1
16.9,6.4,191.7,241,-3.7,-3.8,0,90.5,90,90.4,1
16.9,6.4,191.6,241.1,-3.7,-3.8,0,90.5,90,90.4,1
16.9,6.2,191.5,241.1,-3.7,-3.8,0,90.5,90,90.4,1
16.9,7.3,191.3,241,-3.7,-3.9,0,90.5,90,90.4,1
16.9,7.3,191.2,241.2,-3.7,-3.9,0,90.5,90,90.4,1
16.9,7.5,190.9,241,-3.8,-3.8,0,90.5,90,90.4,1
16.9,6.9,190.8,241,-3.8,-3.8,0,90.5,90,90.4,1
16.9,7.1,190.6,241.2,-3.8,-3.7,0,90.5,90,90.4,1
16.9,6.9,190.4,241.1,-3.8,-3.8,0,90.5,90,90.4,1
16.9,6,190.3,241,-3.8,-3.8,0,90.5,90,90.4,1
16.9,5.7,190.1,241.1,-3.8,-3.7,0,90.5,90,90.4,1
16.9,5.7,190,241,-3.8,-3.7,0,90.5,90,90.4,1
16.9,5.1,189.8,241.1,-3.7,-3.7,0,90.5,90,90.4,1
16.9,5.7,189.8,241.1,-3.8,-4,0,90.5,90,90.4,1
16.9,5.2,189.6,241.1,-3.8,-3.9,0,90.5,90,90.4,1
16.9,5.5,189.5,241,-3.8,-3.9,0,90.5,90,90.4,1
16.9,5.2,189.4,241,-3.8,-3.8,0,90.5,90,90.4,1
16.9,5.3,189.2,241,-3.8,-3.7,0,90.5,90,90.4,1
16.9,5.3,189,241,-3.8,-3.9,0,90.5,90,90.4,1
16.9,5.2,188.9,241,-3.8,-3.7,0,90.5,90,90.4,1
16.9,5.1,188.7,241.1,-3.8,-3.5,0,90.5,90,90.4,1
16.9,5.2,188.6,241,-3.7,-3.5,0,90.5,90,90.4,1
16.9,5.7,188.5,241.1,-3.7,-3.7,0,90.5,90,90.4,1

16.9,5.7,188.4,241.1,-3.7,-3.7,0,90.5,90,90.4,1
16.9,5.9,188.2,241,-3.7,-3.9,0,90.5,90,90.4,1
16.9,5.8,188,241,-3.7,-3.8,0,90.5,90,90.4,1
16.9,5.8,188,241,-3.8,-3.9,0,90.5,90,90.4,1
16.9,6,187.7,241.1,-3.8,-3.9,0,90.5,90,90.4,1
16.8,5.9,187.6,241,-3.8,-3.7,0,90.5,90,90.4,1
16.8,6,187.5,241,-3.8,-3.7,0,90.5,90,90.4,1
16.8,5.2,187.3,241,-3.8,-3.5,0,90.5,90,90.4,1
16.8,5,187.2,241,-3.7,-3.4,0,90.5,90,90.4,1
16.8,4.9,187.1,241,-3.7,-3.6,0,90.5,90,90.4,1
16.8,5.1,187,241.2,-3.7,-4,0,90.5,90,90.4,1
16.8,5.2,186.8,241.1,-3.7,-4.1,0,90.5,90,90.4,1
16.8,5.3,186.7,241.2,-3.8,-3.9,0,90.5,90,90.4,1
16.8,4.5,186.6,241.1,-3.8,-3.4,0,90.5,90,90.4,1
16.8,4.3,186.5,241,-3.7,-3.5,0,90.5,90,90.4,1
16.8,5,186.3,241,-3.7,-3.8,0,90.5,90,90.4,1
16.8,5.4,186.3,241.1,-3.7,-3.8,0,90.5,90,90.4,1
16.8,5.4,186.1,241,-3.7,-3.8,0,90.5,90,90.4,1
16.8,6,186,241.1,-3.7,-3.9,0,90.5,90,90.4,1
16.8,6.1,186,241.1,-3.7,-3.8,0,90.5,90,90.4,1
16.8,6.1,185.7,241,-3.8,-3.8,0,90.5,90,90.4,1
16.8,5.4,185.6,241.1,-3.8,-3.8,0,90.5,90,90.4,1
16.8,5.5,185.4,241.1,-3.8,-3.8,0,90.5,90,90.4,1
16.8,4.9,185.3,241.1,-3.8,-3.6,0,90.5,90,90.4,1
16.8,4.7,185.2,241,-3.7,-3.7,0,90.5,90,90.4,1
16.8,5.4,185,241,-3.8,-4,0,90.5,90,90.4,1
16.8,5.6,184.9,241.1,-3.8,-4.1,0,90.5,90,90.4,1
52.1,12.5,216.1,236.2,18.1,0,0,90.2,90.1,90.1,0
52.1,12.7,216.9,236.2,18.1,0,0,90.2,90.1,90.1,0
52.1,12.9,217.3,236.2,18.1,0,0,90.2,90.1,90.1,0
52.1,13,217.9,236.2,18.1,0,0,90.2,90.1,90.1,0
52.1,13.1,218.5,236.2,18.1,0,0,90.2,90.1,90.1,0
52.1,13.2,219,236.2,18.1,0,0,90.2,90.1,90.1,0

52.1,13.2,219.7,236.2,18.1,0,0,90.2,90.1,90.1,0
52.2,13.1,220.3,236.2,18.1,0,0,90.2,90.1,90.1,0
52.2,12.9,221,236.2,18.1,0,0,90.2,90.1,90.1,0
52.2,12.8,221.4,236.2,18.2,0,0,90.2,90.1,90.1,0
52.3,12.7,222.1,236.2,18.2,0,0,90.2,90.1,90.1,0
52.3,12.8,220.8,236.2,18.2,0,0,89.8,89.3,88.8,0
52.4,12.1,217.8,236.1,18.2,0,0,87.6,88,87.4,0
52.4,11.2,217.9,236.1,18.2,0,0,87,87.1,87,0
52.4,10.5,217.4,236.2,18.2,0,0,86.3,86.3,86.2,0
52.4,10.1,216.9,236.2,18.2,0,0,85.3,85.3,85.2,0
52.4,9.9,216.2,236.2,18.2,0,0,84.4,84.4,84.2,0
52.5,9.7,215.6,236.2,18.2,0,0,83.3,83.4,83.1,0
52.5,9.5,214.7,236.2,18.2,0,0,82.2,82.2,81.9,0
52.5,9.4,214,236.2,18.2,0,0,81,81,81.1,0
52.6,9.3,213.2,236.2,18.2,0,0,79.8,79.8,79.8,0
52.6,9.2,212.1,236.2,18.2,0,0,78.6,78.6,78.5,0
52.7,9.1,211.1,236.1,18.2,0,0,77.2,77.2,77.2,0
52.7,9.1,209.9,236.2,18.2,0,0,75.8,75.8,75.8,0
52.7,9.1,208.8,236.2,18.2,0,0,74.7,74.7,74.7,0
52.7,9.3,207.2,236.2,18.2,0,0,72.9,72.9,72.9,0
52.7,9.5,206.3,236.2,18.2,0,0,71.7,71.7,71.7,0
52.8,9.7,204.8,236.1,18.2,0,0,70.2,70.2,70.2,0
52.8,9.9,203.4,236.2,18.2,0,0,68.5,68.5,68.5,0
52.8,9.9,201.7,236.2,18.3,0,0,66.8,66.8,66.9,0
52.9,9.8,200.3,236.1,18.3,0,0,65.1,65.1,65.2,0
52.9,9.8,198.4,236.1,18.3,0,0,63.3,63.3,63.4,0
52.9,9.5,196.7,236.2,18.3,0,0,61.4,61.5,61.5,0
52.9,9.4,196.7,236.1,18.3,0,0,59.6,59.6,59.7,0
52.9,9.3,193.1,236.1,18.3,0,0,57.7,57.7,57.8,0
52.9,9.2,191.2,236,18.3,0,0,55.7,55.8,55.9,0
52.9,9.1,189.2,236,18.3,0,0,53.8,53.9,54,0
53,8.9,187,236.1,18.3,0,0,51.8,51.9,52,0
53,8.7,185.2,236.1,18.3,0,0,49.9,50,50.1,0

53,8.6,184.2,236.1,18.3,0,0,48.6,48.7,48.8,0
53,8.8,183.2,236.2,18.3,0,0,47.3,47.4,47.4,0
53,8.8,182.4,236.2,18.3,0,0,46,46.1,46.2,0
53,9,181.6,236.1,18.3,0,0,44.8,44.9,44.9,0
53,9.2,180.7,236.1,18.3,0,0,43.6,43.7,43.7,0
53,9.4,180,236,18.3,0,0,42.5,42.6,42.6,0
53,9.6,179.2,236.1,18.3,0,0,41.3,41.4,41.4,0
53,9.9,178.4,236.1,18.3,0,0,40.2,40.4,40.3,0
52.9,10,177.7,236.1,18.3,0,0,39.2,39.3,39.2,0
52.9,10.2,177.2,236.1,18.3,0,0,38.1,38.3,38.2,0
52.9,10.2,176.7,236.1,18.3,0,0,37.1,37.2,37.2,0
52.8,10.1,176.2,236.1,18.3,0,0,36.2,36.3,36.2,0
52.8,10,175.8,236.1,18.3,0,0,35.3,35.4,35.3,0
52.8,9.8,175.4,236,18.3,0,0,34.4,34.5,34.5,0
52.8,9.8,175.1,236,18.3,0,0,33.6,33.7,33.7,0
52.8,9.7,174.7,236.1,18.3,0,0,32.8,32.8,32.9,0
52.7,9.8,174.5,236,18.3,0,0,32,32,32.1,0
52.7,9.9,174.3,236.1,18.3,0,0,31.2,31.2,31.3,0
52.7,10.1,174.1,236,18.3,0,0,30.3,30.5,30.5,0
52.7,10,173.9,236.1,18.3,0,0,29.7,29.8,29.9,0
52.7,9.9,174,236,18.3,0,0,29.1,29.2,29.2,0
52.6,9.8,173.8,236,18.3,0,0,28.5,28.6,28.6,1
52.6,9.9,173.8,236,18.3,0,0,27.9,28,27.9,1
52.5,10.1,174,236.1,18.3,0,0,27.4,27.4,27.4,1
52.5,10.4,174.1,236,18.3,0,0,26.9,27,26.9,1
52.5,10.5,174.2,236.1,18.3,0,0,26.6,26.6,26.6,1
52.5,10.7,174.6,235.9,18.3,0,-5.7,26.1,26.1,26.1,1
52.5,10.7,174.8,236.1,18.3,0,-3.6,25.8,25.8,25.8,1
52.3,10.6,175.2,236,18.3,0,-1.9,25.5,25.5,25.5,1
52.3,10.6,175.4,236,18.3,0,-1.1,25.1,25.1,25.1,1
52.3,10.6,175.8,236,18.3,0,-0.8,24.7,24.7,24.8,1
52.2,10.5,176.1,235.9,18.3,0,-0.5,24.5,24.5,24.5,1
52.2,10.5,176,236,18.3,0,-0.4,24,24,24,1

52,10.2,176.4,235.9,18.3,0,-1.6,23.6,23.7,23.7,1
52,10.1,176.7,236,18.3,0,-1.1,23.4,23.4,23.4,1
52,9.9,177.1,236,18.3,0,-1.4,23.1,23.1,23.1,1
52,9.7,177.5,235.8,18.3,0,-2.1,23,23,23,1
52,9.7,178,236,18.3,0,-1,22.6,22.6,22.6,1
51.9,9.8,178.1,236,18.3,0,-1.2,22.5,22.5,22.5,1
51.9,9.8,178.1,236,18.3,0,-1.4,22.3,22.3,22.3,1
51.9,9.9,178.9,235.9,18.3,0,-1.3,22.3,22.3,22.3,1
51.8,10,179.4,236,18.3,0,-1.2,22.2,22.2,22.2,1
51.8,10.1,180.1,235.9,18.3,0,-0.8,22.3,22.3,22.3,1
51.7,10.3,180.8,235.8,18.3,0,-1.3,22.2,22.2,22.2,1
51.7,10.4,181.3,235.9,18.3,0,-0.8,22.2,22.2,22.2,1
51.7,10.6,181.5,236,18.3,0,-49.4,21.6,21.7,21.6,1
51.5,10.8,180.5,235.8,18.3,0,59,20.5,20.6,20.5,1
51.5,10.9,179.3,235.9,18.3,0,147.1,19.3,19.3,19.3,1
51.5,11.6,172.8,235.8,18.3,0,0,21.5,21.6,21.6,1
51.5,12.5,164.5,236,18.3,0,0,24.9,25.1,24.9,1
51.5,13.3,158.4,236.1,18.3,0,0,28.3,28.9,28.5,1
51.4,13.6,150.3,236.4,18.3,0,0,31.7,32.4,32.5,1
51.4,13.5,144.4,236.4,18.3,0,0,35.6,36.1,35.5,1
51.3,13.3,138.4,236,18.3,0,0,39,40.2,39.2,1
51.3,13.3,133.6,236.4,18.3,0,0,42.9,43.6,43.2,1
51.3,13.3,128.3,236.3,18.3,0,0,46.5,48,46.5,1
51.2,13,123.6,236.2,18.3,0,0,50.4,51.9,50.9,1
51.2,12.6,120.2,236.2,18.3,0,0,54.7,55.8,54.5,1
51.2,12.4,116.4,236.4,18.3,0,0,58.8,60.7,59.1,1
51.2,12.4,113,236.4,18.3,0,0,63.1,65.2,63.8,1
51.2,12.7,109,236.2,18.3,0,0,67.7,70.3,68.2,1
51.1,12.5,106.7,236.1,18.3,0,0,73,75.6,73.6,1
51.1,12.4,103.7,236.2,18.3,0,0,78.3,81.3,79.2,1
51.1,12.5,101.5,236.1,18.3,0,0,83.4,85.9,85,1
51.1,12.5,99.6,236.1,18.3,0,0,87.6,88.5,90.1,1
51.1,12.5,99.2,236.1,18.3,0,0,90,90.1,90.1,1

51.1,12.4,99.3,236.2,18.3,0,0,90.2,90.1,90.1,1
51.1,12.3,99.4,236.1,18.3,0,0,90.2,90.1,90.1,1
51,12.3,99.7,236.2,18.3,0,0,90.2,90.1,90.1,1
51,12.3,100,236.2,18.3,0,0,90.2,90.1,90.1,1
51,12,100.2,236.3,18.3,0,0,90.2,90.1,90.1,1
50.9,11.9,100.3,236.1,18.3,0,0,90.2,90.1,90.1,1
50.9,11.8,100.6,236.1,18.3,0,0,90.2,90.1,90.1,1
50.8,11.6,100.7,236.2,18.3,0,0,90.2,90.1,90.1,1
50.8,11.4,101,236.2,18.3,0,0,90.2,90.1,90.1,1
50.8,11.1,101.1,236,18.3,0,0,90.2,90.1,90.1,1
50.7,10.8,101.2,236.1,18.3,0,0,90.2,90.1,90.1,1
50.7,10.6,101.3,236.1,18.3,0,0,90.2,90.1,90.1,1
50.7,10.5,101.5,236.2,18.3,0,0,90.2,90.1,90.1,1
50.7,10.4,101.6,236.2,18.3,0,0,90.2,90.1,90.1,1
50.7,10.4,101.8,236.2,18.3,0,0,90.2,90.1,90.1,1
59.9,5.3,201.3,226.6,18.5,18.4,0,90.1,90.5,90.9,0
59.9,5.2,201.6,226.7,18.5,18.4,0,90.1,90.5,90.9,0
59.9,5.3,202.1,226.6,18.5,18.4,0,90.1,90.5,90.9,0
59.9,5.2,202.3,226.6,18.5,18.4,0,90.1,90.5,90.8,0
59.9,5.5,202.7,226.5,18.4,18.4,0,90.1,90.5,90.8,0
59.9,5.3,203.1,226.5,18.4,18.4,0,90.1,90.5,90.9,0
60,5.1,203.5,226.6,18.4,18.4,0,90.1,90.5,90.8,0
60,5.3,203.8,226.6,18.4,18.4,0,90.1,90.5,90.9,0
60,5.4,204.2,226.6,18.4,18.4,0,90.1,90.5,90.9,0
60,5.7,204.6,226.7,18.4,18.4,0,90.1,90.5,90.9,0
60,6,204.8,226.6,18.4,18.4,0,90.1,90.5,90.9,0
60,6.1,205.2,226.6,18.4,18.4,0,90.1,90.5,90.9,0
60,6,205.8,226.5,18.4,18.4,0,90.1,90.5,90.9,0
60.1,5.9,205.9,226.5,18.4,18.6,0,90.1,90.5,90.9,0
60.1,5.1,206.2,226.6,18.4,18.6,0,90.1,90.5,90.9,0
60.1,5.1,206.6,226.6,18.4,18.4,0,90.1,90.5,90.9,0
60.1,5.9,207,226.4,18.5,18.6,0,90.1,90.5,90.9,0
60.1,6.1,207.3,226.6,18.5,18.4,0,90.1,90.5,90.9,0

60.1,6.5,207.7,226.5,18.5,18.4,0,90.1,90.5,90.9,0
60.1,6.7,207.9,226.4,18.5,18.4,0,90.1,90.5,90.9,0
60.2,6.9,208.4,226.6,18.4,18.4,0,90.1,90.5,90.9,0
60.2,6.9,208.6,226.5,18.4,18.4,0,90.1,90.5,90.9,0
60.2,7.1,209,226.4,18.4,18.4,0,90.1,90.5,90.9,0
60.2,7.1,209.4,226.5,18.4,18.4,0,90.1,90.5,90.9,0
60.2,7.2,209.8,226.5,18.4,18.5,0,90.1,90.5,90.9,0
60.2,6.8,210.1,226.5,18.4,18.5,0,90.1,90.5,90.8,0
60.2,6.2,210.4,226.5,18.4,18.4,0,90.1,90.5,90.8,0
60.2,6.1,210.8,226.4,18.4,18.4,0,90.1,90.5,90.9,0
60.2,6.3,211.2,226.4,18.4,18.4,0,90.1,90.5,90.9,0
60.2,6.5,211.6,226.6,18.4,18.4,0,90.1,90.5,90.8,0
60.3,6.7,211.7,226.5,18.4,18.5,0,90.1,90.5,90.8,0
60.3,6.8,212.1,226.5,18.4,18.4,0,90.1,90.5,90.9,0
60.3,6.8,212.5,226.5,18.4,18.4,0,90.1,90.5,90.9,0
60.3,6.8,212.7,226.5,18.4,18.5,0.1,90.1,90.5,90.9,0
60.3,6.7,213.2,226.3,18.4,18.6,0,90.1,90.5,90.8,0
60.3,6.2,213.5,226.5,18.5,18.6,0,90.1,90.5,90.9,0
60.4,6.1,214,226.3,18.5,18.6,0,90.1,90.5,90.8,0
60.4,5.5,214.2,226.3,18.5,18.5,0,90.1,90.5,90.9,0
60.4,5.6,214.6,226.3,18.5,18.6,0,90.1,90.5,90.9,0
60.4,5.6,214.8,226.4,18.5,18.6,0,90.1,90.5,90.9,0
60.4,5.8,215.2,226.3,18.5,18.6,0,90.1,90.5,90.8,0
60.4,5.7,215.7,226.3,18.5,18.6,0,90.1,90.5,90.9,0
60.4,5.9,216,226.3,18.5,18.7,0,90.1,90.5,90.9,0
60.5,5.8,216.2,226.4,18.5,18.8,0,90.1,90.5,90.9,0
60.5,5.6,216.5,226.3,18.5,18.7,0,90.1,90.5,90.9,0
60.5,5.7,216.8,226.4,18.5,18.6,0,90.1,90.5,90.9,0
60.5,5.9,217.2,226.2,18.5,18.8,0,90.1,90.5,90.9,0
60.5,5.8,217.6,226.3,18.5,18.8,0,90.1,90.5,90.9,0
60.5,5.4,217.8,226.4,18.5,18.5,0,90.1,90.5,90.9,0
60.5,5.7,218.2,226.3,18.5,18.5,0,90.1,90.5,90.9,0
60.5,5.8,218.5,226.3,18.5,18.4,0,90.1,90.5,90.9,0

60.5,5.7,218.7,226.3,18.5,18.6,0,90.1,90.5,90.9,0
60.5,5.8,219,226.4,18.5,18.5,0,90.1,90.5,90.9,0
60.6,5.8,219.3,226.2,18.5,18.5,0,90.1,90.5,90.9,0
60.6,5.9,219.5,226.2,18.5,18.4,0,90.1,90.5,90.9,0
60.6,5.5,219.8,226.1,18.5,18.5,0,90.1,90.5,90.9,0
60.6,5.4,220.2,226.3,18.5,18.4,0,90.1,90.5,90.9,0
60.6,5.6,220.6,226.3,18.5,18.4,0,90.1,90.5,90.8,0
60.6,5.8,220.9,226.2,18.5,18.3,0,90.1,90.5,90.8,0
60.6,6,221.3,226.2,18.5,18.4,0,90.1,90.5,90.8,0
60.7,5.7,219.2,226.5,18.5,18.4,0,88.4,90,90.9,1
60.7,5.6,216.3,226.3,18.5,18.4,0,88,88,87.6,1
60.7,5.6,216.4,226.5,18.5,18.4,0,88.1,88,87.9,1
60.7,5.9,216.8,226.3,18.5,18.4,0,88,88.1,88,1
60.7,5.8,217,226.3,18.5,18.6,0,88,88.1,88.1,1
60.7,5.5,217.2,226.3,18.5,18.4,0,88,88.1,88.1,1
60.7,5.7,217.3,226.4,18.5,18.5,0,88,88,88,1
60.7,6.1,217.5,226.4,18.5,18.4,0,88,88,88,1
60.7,6.4,217.6,226.4,18.5,18.6,0,88,88,88,1
60.7,6.4,217.9,226.4,18.5,18.5,0,88,88,88,1
60.8,6.1,218.2,226.2,18.5,18.4,0,88,88,88,1
60.8,5.7,218.3,226.3,18.5,18.7,0,88,88,88,1
60.8,5.5,218.5,226.3,18.5,18.6,0,88,88,88,1
60.8,5.6,218.6,226.3,18.5,18.5,0,88,88,88,1
60.8,5.7,218.8,226.3,18.5,18.4,0,88,88,88,1
60.8,5.9,218.9,226.2,18.5,18.4,0,88,88,88,1
60.9,6.1,219.1,226.3,18.5,18.4,0,88,88,88,1
60.9,6.1,215.1,226.2,18.5,18.4,0,90.2,89.7,89.6,1
60.9,6.1,210.7,226.2,18.5,18.3,0,90.1,90.5,90.8,1
60.9,6.1,209.5,226.2,18.5,18.4,0,90.1,90.5,90.8,1
60.9,6.1,208.6,226.3,18.5,18.4,0,90.1,90.5,90.8,1
60.9,6.2,207.9,226.2,18.5,18.4,0,90.1,90.5,90.8,1
60.9,6.1,207,226.2,18.5,18.4,0,90.1,90.5,90.8,1
60.9,5.9,206.2,226.3,18.5,18.4,0,90.1,90.5,90.8,1

60.9,5.8,205.4,226.2,18.5,18.5,0,90.1,90.5,90.8,1
60.9,5.5,204.6,226.1,18.5,18.4,0,90.1,90.5,90.8,1
61,5.6,204,226.2,18.5,18.4,0,90.1,90.5,90.8,1
61,5.3,203.1,226.3,18.5,18.4,0,90.1,90.5,90.8,1
61,5,202.4,226.1,18.5,18.4,0,90.1,90.5,90.8,1
61,4.7,201.8,226.3,18.5,18.4,0,90.1,90.5,90.8,1
61,4.4,201.2,226.2,18.5,18.5,0,90.1,90.5,90.8,1
61,4.1,200.6,226.1,18.5,18.6,0,90.1,90.5,90.8,1
61,4.8,199.7,226.1,18.5,18.4,0,90.1,90.5,90.8,1
61,5.6,198.9,226.1,18.5,18.4,0,90.1,90.5,90.8,1
61,6.1,198.3,226.2,18.5,18.4,0,90.1,90.5,90.8,1
61,6.4,197.8,226.1,18.5,18.4,0,90.1,90.5,90.9,1
61.1,6.7,197,226.1,18.5,18.4,0,90.1,90.5,90.8,1
61.1,6.9,196.3,226.1,18.5,18.4,0,90.1,90.5,90.8,1
61.1,7.1,195.6,226.1,18.5,18.5,0,90.1,90.5,90.8,1
61.1,7,194.9,226.1,18.5,18.5,0,90.1,90.5,90.8,1
61.1,7,194.4,226,18.5,18.4,0,90.1,90.5,90.8,1
61.1,6.9,193.9,226,18.5,18.6,0,90.1,90.5,90.8,1
61.1,6.8,193.2,226.1,18.5,18.5,0,90.1,90.5,90.8,1
61.1,6.9,192.6,226.1,18.5,18.4,0,90.1,90.5,90.8,1
61.1,6.9,192,226.1,18.5,18.5,0,90.1,90.5,90.9,1
61.1,6.8,191.5,226.1,18.5,18.5,0,90.1,90.5,90.8,1
61.1,6.7,190.8,226,18.5,18.5,0,90.1,90.5,90.8,1
61.1,6.5,190.3,226.1,18.5,18.5,0,90.1,90.5,90.8,1
61.1,6.3,189.7,226,18.5,18.5,0,90.1,90.5,90.8,1
61.1,6.5,189.1,226.1,18.5,18.6,0,90.1,90.5,90.8,1
61.1,6.5,188.5,226,18.5,18.5,0,90.1,90.5,90.8,1
61.1,6.6,188,226,18.5,18.5,0,90.1,90.5,90.8,1
61.1,6.7,187.4,226,18.5,18.5,0,90.1,90.5,90.8,1
61.1,6.7,187,226,18.5,18.5,0,90.1,90.5,90.8,1
61.1,6.7,186.3,225.9,18.5,18.4,0,90.1,90.5,90.8,1
61.1,6.6,185.9,225.9,18.5,18.4,0,90.1,90.5,90.9,1
61.1,6.7,185.3,226,18.5,18.4,0,90.1,90.5,90.8,1

61.1,6.8,184.8,226,18.5,18.4,0,90.1,90.5,90.8,1
61.1,6.9,184.4,225.9,18.5,18.4,0,90.1,90.5,90.8,1
61,7,183.7,226,18.5,18.4,0,90.1,90.5,90.8,1
43.3,3.8,147.3,223.5,18.5,18.5,0,89.5,89.9,89.9,0
43.3,4.2,148.1,223.5,18.5,18.3,0,89.5,89.9,89.9,0
43.3,4.1,148.8,223.4,18.5,18.4,0,89.5,89.9,89.9,0
43.3,4.3,149.6,223.4,18.5,18.4,0,89.5,89.9,89.9,0
43.3,4.1,150.6,223.4,18.5,18.4,0,89.5,89.9,89.9,0
43.3,4.1,151.3,223.3,18.5,18.4,0,89.5,89.9,89.9,0
43.3,4.3,152,223.5,18.5,18.5,0,89.5,89.9,89.9,0
43.3,4.2,152.9,223.3,18.5,18.5,0,89.5,89.9,89.9,0
43.3,4.1,153.9,223.5,18.5,18.3,0,89.5,89.9,89.9,0
43.3,4.1,154.7,223.5,18.5,18.5,0,89.5,89.9,89.9,0
43.3,3.9,155.4,223.6,18.5,18.7,0,89.5,89.9,89.9,0
43.3,3.7,156.2,223.5,18.5,18.6,0,89.5,89.9,89.9,0
43.3,3.5,157.2,223.5,18.5,18.6,0,89.5,89.9,89.9,0
43.3,3,158.1,223.5,18.5,18.8,0,89.5,89.9,89.9,0
43.3,3.4,158.8,223.5,18.5,18.5,0,89.5,89.9,89.9,0
43.3,3.9,159.6,223.5,18.5,18.5,0,89.5,89.9,89.9,0
43.3,4.1,160.6,223.5,18.5,18.5,0,89.5,89.9,89.9,0
43.3,4.2,161.5,223.4,18.5,18.5,0,89.5,89.9,89.9,0
43.4,4.5,162.3,223.5,18.5,18.4,0,89.5,89.9,89.9,0
43.4,4.6,162.9,223.4,18.5,18.3,0,89.5,89.9,89.9,0
43.4,4.4,164,223.4,18.5,18.5,0,89.5,89.9,89.9,0
43.4,4.1,164.7,223.5,18.5,18.5,0,89.5,89.9,89.9,0
43.3,3.6,165.7,223.4,18.5,18.4,0,89.5,89.9,89.9,0
43.3,3.7,166.4,223.5,18.5,18.5,0,89.5,89.9,89.9,0
43.3,3.8,167.4,223.6,18.5,18.5,0,89.5,89.9,89.9,0
43.3,3.9,168.1,223.6,18.5,18.4,0,89.5,89.9,89.9,0
43.3,4,169.1,223.4,18.5,18.5,0,89.5,89.9,89.9,0
43.3,4,170,223.4,18.5,18.3,0,89.5,89.9,89.9,0
43.3,4.2,171,223.6,18.5,18.4,0,89.5,89.9,89.9,0
43.4,4.1,171.8,223.6,18.5,18.5,0,89.5,89.9,89.9,0

43.4,3.6,172.6,223.5,18.5,18.6,0,89.5,89.9,89.9,0
43.4,3.3,173.8,223.6,18.5,18.5,0,89.5,89.9,89.9,0
43.3,3.6,174.4,223.6,18.5,18.5,0,89.5,89.9,89.9,0
43.3,3.7,175.3,223.7,18.5,18.4,0,89.5,89.9,89.9,0
43.3,3.5,176.2,223.6,18.5,18.6,0,89.5,89.9,89.9,0
43.3,3.4,177.3,223.5,18.5,18.6,0,89.5,89.9,89.9,0
43.3,3.4,178,223.6,18.5,18.5,0,89.5,89.9,89.9,0
43.3,3.6,179.2,223.6,18.5,18.5,0,89.5,89.9,89.9,0
43.4,3.7,180.1,223.4,18.5,18.4,0,89.5,89.9,89.9,0
43.4,3.7,180.8,223.5,18.5,18.4,0,89.5,89.9,89.9,0
43.4,3.8,182,223.5,18.5,18.6,0,89.5,89.9,89.9,0
43.4,3.8,182.9,223.6,18.5,18.7,0,89.5,89.9,89.9,0
43.4,4.1,183.8,223.6,18.5,18.7,0,89.5,89.9,89.9,0
43.4,4.2,184.4,223.6,18.5,18.5,0,89.5,89.9,89.9,0
43.4,4.2,185.6,223.6,18.5,18.4,0,89.5,90,89.9,0
43.4,4.3,186.3,223.6,18.5,18.4,0,89.5,89.9,89.9,0
43.4,4.4,187.3,223.6,18.5,18.4,0,89.5,89.9,89.9,0
43.4,4.2,188.4,223.7,18.5,18.4,0,89.5,89.9,89.9,0
43.4,3.9,189.2,223.7,18.5,18.4,0,89.5,89.9,89.9,0
43.4,3.7,190.6,223.6,18.5,18.5,0,89.5,89.9,89.9,0
43.4,3.4,191.3,223.6,18.5,18.5,0,89.5,89.9,89.9,0
43.4,3.3,192.2,223.6,18.5,18.7,0,89.5,89.9,89.9,0
43.4,2.9,193.2,223.6,18.5,18.8,0,89.5,89.9,89.9,0
43.4,2.9,194.2,223.6,18.5,19.1,0,89.5,89.9,89.9,0
43.4,3.1,195.1,223.6,18.5,18.7,0,89.5,90,89.9,0
43.4,3.5,195.9,223.6,18.5,18.8,0,89.5,89.9,89.9,0
43.4,3.8,196.9,223.4,18.5,18.9,0,89.5,89.9,89.9,0
43.4,4.2,197.9,223.3,18.6,18.8,0,89.5,90,89.9,0
43.4,4.3,198.8,223.6,18.6,18.6,0,89.5,90,89.9,0
43.4,4.4,199.6,223.4,18.6,18.8,0,89.5,89.9,89.9,0
43.4,4.6,200.8,223.6,18.6,18.6,0,89.5,90,89.9,1
43.4,4.8,201.6,223.4,18.6,18.6,0,89.5,89.9,89.9,1
43.4,5,202.9,223.6,18.6,18.6,0,89.5,89.9,89.9,1

43.4,5.1,203.4,223.5,18.6,18.5,0,89.5,89.9,89.9,1
43.4,5,204.5,223.5,18.6,18.6,0,89.5,89.9,89.9,1
43.4,4.8,205.3,223.6,18.6,18.9,0,89.5,90,89.9,1
43.4,4.6,206.4,223.6,18.6,18.9,0,89.5,90,89.9,1
43.4,4.4,207.6,223.6,18.6,19,0,89.5,90,89.9,1
43.4,4.3,208.3,223.3,18.6,19.1,0,89.5,90,89.9,1
43.4,4.3,209.3,223.4,18.6,19,0,89.5,90,89.9,1
43.4,4.4,210.3,223.6,18.6,18.9,0,89.5,90,89.9,1
43.4,4.5,211.1,223.5,18.6,18.3,0,89.5,90,89.9,1
43.4,4.9,212.2,223.5,18.6,18.3,0,89.5,90,89.9,1
43.4,5.2,213.3,223.5,18.6,18.3,0,89.5,90,89.9,1
43.4,5.2,214.1,223.6,18.6,18.4,0,89.5,90,89.9,1
43.4,5.3,215.1,223.4,18.6,18.4,0,89.5,90,89.9,1
43.4,5.2,216.2,223.4,18.6,18.4,0,89.5,90,89.9,1
43.4,5,217.1,223.4,18.6,18.4,0,89.5,90,89.9,1
43.4,4.7,218,223.4,18.6,18.5,0,89.5,90,89.9,1
43.4,4.6,219.2,223.5,18.6,18.4,0,89.5,90,89.9,1
43.4,4.6,219.8,223.5,18.6,18.4,0,89.5,90,89.9,1
43.4,4.6,221.1,223.6,18.6,18.4,0,89.5,90,89.9,1
43.4,4.8,222.2,223.4,18.6,18.4,0,89.5,90,89.9,1
43.4,4.8,223.1,223.4,18.6,18.4,0,89.5,90,89.9,1
43.4,4.8,224.1,223.4,18.5,18.4,0,89.5,90,89.8,1
43.4,4.9,222.2,224,18.5,18.5,0,88.5,87.7,87.3,1
43.4,4.7,222,224,18.5,18.4,0,87.6,87.6,87.5,1
43.4,4.4,222,224,18.5,18.6,0,86.8,86.8,86.7,1
43.4,4.1,222.2,224.1,18.5,18.5,0,85.9,85.9,85.8,1
43.4,4,221.8,224,18.5,18.4,0,85,85,84.9,1
43.4,4.2,221.4,224,18.5,18.4,0,83.9,83.9,83.8,1
43.4,4.5,221.1,224,18.5,18.4,0,82.8,82.8,82.7,1
43.4,4.5,220.6,224,18.5,18.4,0,81.6,81.6,81.5,1
43.4,4.5,220,224.1,18.5,18.4,0,80.3,80.3,80.3,1
43.4,4.5,219.3,224,18.5,18.5,0,79,79,78.9,1
43.4,4.2,218.6,223.9,18.5,18.4,0,77.6,77.5,77.5,1

43.4,4.3,217.6,224,18.5,18.4,0,76.2,76.1,76,1
43.4,4.5,207.8,224,18.5,18.4,0,79.7,79.7,80.5,1
43.4,4.7,198.1,224,18.5,18.4,0,85.6,84.5,85,1
43.4,4.5,188.6,224,18.5,18.4,0,89.5,90,89.5,1
43.4,4.4,187.2,223.8,18.5,18.4,0,89.5,90,89.9,1
43.4,4.4,187,223.9,18.5,18.4,0,89.5,90,89.9,1
43.4,4.2,186.7,224,18.5,18.4,0,89.5,90,89.9,1
43.4,4,186.4,224,18.5,18.4,0,89.5,90,89.9,1
43.4,4.1,186.1,223.9,18.5,18.3,0,89.5,90,89.9,1
43.4,4.2,185.7,224,18.5,18.3,0,89.5,90,89.9,1
43.4,4.2,185.4,224,18.5,18.3,0,89.5,90,89.9,1
43.4,4.3,185.1,224,18.5,18.3,0,89.5,90,89.9,1
43.4,4.2,184.8,224,18.5,18.3,0,89.5,90,89.9,1
43.4,4.1,184.5,224,18.5,18.3,0,89.5,90,89.9,1
43.4,4.1,184.2,224,18.4,18.3,0,89.5,90,89.9,1
43.4,4,183.8,224,18.4,18.3,0,89.5,90,89.9,1
43.4,4,183.6,224,18.4,18.3,0,89.5,90,89.9,1
43.4,4,183.4,223.9,18.4,18.4,0,89.5,90,89.9,1
43.4,4.2,182.9,224,18.4,18.3,0,89.5,90,89.9,1
43.4,4.3,182.6,223.9,18.4,18.3,0,89.5,90,89.9,1
43.4,4.3,182.4,223.9,18.4,18.3,0,89.5,90,89.9,1
43.4,4.2,182,224,18.4,18.3,0,89.5,90,89.9,1
43.4,4.1,181.7,224,18.4,18.3,0,89.5,90,89.9,1
43.4,4.1,181.4,224,18.4,18.3,0,89.5,90,89.9,1