

**T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**VERİ MADENCİLİĞİ YÖNTEMİYLE RÜZGÂR ENERJİ
POTANSİYELİNİN İNCELENMESİ**

YÜKSEK LİSANS TEZİ

Rafael BEKİROV

**Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı**

EKİM, 2022

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



VERİ MADENCİLİĞİ YÖNTEMİYLE RÜZGÂR ENERJİ
POTANSİYELİNİN İNCELENMESİ

YÜKSEK LİSANS TEZİ

Rafael BEKİROV
(Y1913.010001)

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Zafer ASLAN

EKİM, 2022

ONAY FORMU

ONUR SÖZÜ

Yüksek Lisans tezi olarak sunduğum “Veri Madenciliği Yöntemiyle Rüzgâr Enerji Potansiyelinin İncelenmesi” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (29/09/2022)

Rafael BEKİROV

ÖNSÖZ

Tez çalışmamda planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteğini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren sayın hocam Prof. Dr. Zafer ASLAN'A sonsuz teşekkürlerimi sunarım. Bilgisayar Mühendisliği Anabilim Dalı Başkanı Prof.Dr. Ali GÜNEŞ ve İstanbul İstinye Üniversitesi, Dr. Öğretim Üyesi Ali HAMİTOĞLUN'a desteklerinden dolayı teşekkürü borç bilirim. Veri desteği ile ilgili olarak İTÜ Öğretim Üyesi Prof. Dr. Sibel MENTEŞ'E, veri işlem aşamasındaki desteklerinden dolayı Y. Müh. Uğur AKBULUT'a teşekkürü borç bilirim ve projenin yazılımındaki desteği için arkadaşım Efecan KUTLUK'a tesekkürlerimi iletirim.

Eylül, 2022

Rafael BEKİROV

VERİ MADENCİLİĞİ YÖNTEMİYLE RÜZGÂR ENERJİ POTANSİYELİNİN İNCELENMESİ

ÖZET

Rüzgâr enerjisi, güvenilir ve uygun maliyetli elektrik sağlama kapasitesi nedeniyle önde gelen yenilenebilir enerji kaynakları arasında yer almaktadır. Rüzgâr enerjisi dönüşüm sistemlerinin karmaşıklığı, ileriye dönük analizlere dayalı yeni tekniklerin geliştirilmesini zorunlu kılmaktadır. Bu çalışmada, Yapay Sinir Ağları (YSA) yöntemi kullanarak Çanakkale İli Baba Burnu bölgesinde 2001, 2002 ve 2003 yıllarına ait rüzgâr enerji potansiyelinin hesaplanmasına yönelik, rüzgâr şiddeti tahmini ile ilgili bir çalışma yapılmış ve gelecekte Çanakkale Baba Burnu civarında rüzgâr enerjisi üretimine yönelik ön bilgi elde edilmiştir. Araştırma çalışması sonucunda, YSA model çıktıları ile gözlenen rüzgâr şiddeti değerleri arasındaki ilişki katsayısının %91 olduğu, $\alpha=0,001$ güven seviyesinde anlamlı bir ilişki bulunduğu saptanmıştır. 2003 test dönemi için ANN modelinin başarısı irdelenmiş, 10 m yükseklikte rüzgâr şiddeti tahmini ile ilgili RMSE 2,12m/s ve MSE, 4,12 olarak hesaplanmıştır. Araştırma sonucunda, gözlem ve model sonuçları arasında yeterli bir uyum olduğunu göstermektedir. Rastgele Orman ve Karar Ağaçları yöntemlerine göre tahmin sonuçları hesaplanmış, üç yöntemin başarı performansları karşılaştırılmıştır. RMSE ve MSE değerleri Karar Ağaçları yöntemine göre 2,02m/s ve 4,08 olarak belirlenmiştir. Benzer hata değerleri Rastgele Orman yöntemine göre sırası ile 2,13m/s ve 4,56m/s olarak saptanmıştır. Üç tahmin yönteminin genel olarak karşılaştırılmasından, rüzgâr şiddetinin ve enerji potansiyelinin zamansal değişiminin tahmininde her üç yöntemin başarı oranlarının birbirine yakın olduğu, ancak, Yapay Sinir Ağları Yönteminin başarı performansının diğer iki yöntemle göre %4 daha yüksek olduğu saptanmıştır.

Anahtar Kelimeler: Rüzgâr Enerjisi, Yapay Sinir Ağları, Karekök Hata, Ortalama Karekök Hata, Karar Ağacı, Rastgele Orman.

INVESTIGATION OF WIND ENERGY POTENTIAL BY DATA MINING METHOD

ABSTRACT

Wind energy is among the leading renewable energy sources due to its capacity to provide reliable and cost-effective electricity. The complexity of wind energy conversion systems necessitates the development of new techniques based on forward-looking analysis. In this study, a study was carried out to calculate the wind energy potential for the years 2001, 2002 and 2003 in the Baba Cape region of Çanakkale by using Artificial Neural Networks (ANN) method, and preliminary information about wind energy production around Çanakkale Baba Cape in the future was obtained. has been done. As a result of the research study, it was determined that the correlation coefficient between the ANN model outputs and the observed wind intensity values was 91%, and there was a significant relationship at the $\alpha=0.001$ confidence level. The success of the ANN model for the 2003 test period was examined, and the RMSE was calculated as 2.12m/s and the MSE as 4.12 for the wind force prediction at 10 m height. As a result of the research, it shows that there is a sufficient agreement between the observation and model results. The estimation results were calculated according to the Random Forest and Decision Tree methods, and the success performances of the three methods were compared. RMSE and MSE values were determined as 2.02m/s and 4.08 according to the Decision Trees method. Similar error values were determined as 2.13m/s and 4.56m/s, respectively, according to the Random Forest method. Comparing the general comparison of the three estimation methods, the success performance of the Artificial Neural Networks was found to be 4% higher than the other two methods in estimating the temporal variation of wind intensity and energy potential.

Keywords: Wind energy, Artificial Neural Network, Root Square Error, Root Mean Square Error of Approximation, Decision Tree, Random Forest

İÇİNDEKİLER

Sayfa

ONUR SÖZÜ	i
ÖNSÖZ.....	ii
ÖZET.....	iii
ABSTRACT	iv
İÇİNDEKİLER	v
ÇİZELGELER LİSTESİ.....	vii
ŞEKİLLER LİSTESİ.....	viii
I. GİRİŞ	1
II. LİTERATÜR TARAMASI	6
III. YÖNTEM VE VERİ	7
A. İnceleme bölgesi ve veri	7
B. Yapay Sinir Ağları.....	9
C. Karar Ağaçları (Decision tree).....	12
D. Rastgele Orman (Random Forest)	15
E. Rastgele Orman Algoritması Nedir?	16
IV. BULGULAR.....	18
A. İstatistiksel analiz.....	18
B. YSA ile rüzgâr şiddeti tahmini	21
C. KA ile rüzgâr şiddeti tahmini	28
D. RO ile rüzgâr şiddeti tahmini.....	32
V. SONUÇ VE ÖNERİLER.....	39

A. Teşekkür	46
VI. KAYNAKÇA	47
EKLER.....	52
ÖZGEÇMİŞ.....	60

ÇİZELGELER LİSTESİ

	<u>Sayfa</u>
Çizelge 1. Zaman aralıklarına göre rüzgâr şiddeti tahmini	3
Çizelge 2. Veri Bilgisi	9
Çizelge 3. Rüzgâr Şiddeti İstatistiksel büyüklükleri (Baba Burnu, 2001)	18
Çizelge 4. Rüzgâr Şiddeti İstatistiksel büyüklükleri (Baba Burnu, 2002)	19
Çizelge 5. Rüzgâr Şiddeti İstatistiksel büyüklükleri (Baba Burnu, 2003)	20
Çizelge 6. Mevsimsel model uygulaması hata oranları.....	25
Çizelge 7. Mevsimsel model uygulaması hata oranları.....	30
Çizelge 8. Mevsimsel model uygulaması hata oranları.....	35
Çizelge 9. Modellerin hata değerleri	37

ŞEKİLLER LİSTESİ

Sayfa

Şekil 1. Türkiye yıllık ortalama rüzgâr şiddeti.....	4
Şekil 2. Çanakkale ilinin rüzgâr şiddeti değişimi.....	4
Şekil 3. Yapay Sınır Ağının Yapısı.....	10
Şekil 4. Karar Ağacı,.....	13
Şekil 5. Rastgele Orman.....	17
Şekil 6. 2001 yılı için rüzgâr şiddeti kutu diyagramı	20
Şekil 7. 2002 yılı için rüzgâr şiddeti kutu diyagramı	21
Şekil 8. 2003 yılı için rüzgâr şiddeti kutu diyagramı	21
Şekil 9. Model işlem adımları ile ilgili akış şeması	22
Şekil 10. (a) YSA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yıllık)	22
Şekil 11. (b) YSA yöntemiyle gözlem ve model verileri ilişkisi (yıllık)	23
Şekil 12. (a) YSA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (kış mevsimi)	23
Şekil 13. (b) YSA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (ilkbahar mevsimi)	23
Şekil 14. (c) YSA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yaz mevsimi)	23
Şekil 15. (d) YSA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (sonbahar mevsimi).....	24
Şekil 16. (a) YSA yöntemiyle gözlem ve model verileri ilişkisi (kış mevsimi).....	25

Şekil 17.	. (b) YSA yöntemiyle gözlem ve model verileri ilişkisi (ilkbahar mevsimi)	26
Şekil 18.	(c) YSA yöntemiyle gözlem ve model verileri ilişkisi (yaz mevsimi)...	26
Şekil 19.	(d) YSA yöntemiyle gözlem ve model verileri ilişkisi (sonbahar mevsimi)	27
Şekil 20.	(a) KA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yıllık)	28
Şekil 21.	(b) KA yöntemiyle gözlem ve model verileri ilişkisi (yıllık).....	28
Şekil 22.	. (a) KA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (kış mevsimi)	28
Şekil 23.	(b) KA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (ilkbahar mevsimi)	29
Şekil 24.	(c) KA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yaz mevsimi)	29
Şekil 25.	(d) KA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (sonbahar mevsimi).....	29
Şekil 26.	KA yöntemiyle gözlem ve model verileri ilişkisi (kış mevsimi)	30
Şekil 27.	(b) KA yöntemiyle gözlem ve model verileri ilişkisi (ilkbahar mevsimi)	31
Şekil 28.	(c) KA yöntemiyle gözlem ve model verileri ilişkisi (yaz mevsimi).....	31
Şekil 29.	. (d) KA yöntemiyle gözlem ve model verileri ilişkisi (sonbahar mevsimi)	32
Şekil 30.	(a) RO modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yıllık)	32
Şekil 31.	(b)RO yöntemiyle gözlem ve model verileri ilişkisi (yıllık).....	33
Şekil 32.	(a) RO modeliyle gözlem-tahmin değerlerinin zamansal değişimi (kış mevsimi)	33
Şekil 33.	. (b)RO modeliyle gözlem-tahmin değerlerinin zamansal değişimi (ilkbahar mevsimi)	33
Şekil 34.	(c) RO modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yaz mevsimi)	34

Şekil 35. (d) RO modeliyle gözlem-tahmin değerlerinin zamansal değişimi (sonbahar mevsimi).....	34
Şekil 36. (a) RO yöntemiyle gözlem ve model verileri ilişkisi (kış mevsimi).....	35
Şekil 37. (b) RO yöntemiyle gözlem ve model verileri ilişkisi (ilkbahar mevsimi)	36
Şekil 38. (c) RO yöntemiyle gözlem ve model verileri ilişkisi (yaz mevsimi)	36
Şekil 39. (d) RO yöntemiyle gözlem ve model verileri ilişkisi (sonbahar mevsimi)	37
Şekil 40. Gözlenen ve tahmin edilen rüzgâr şiddeti ilişkisi, korelasyon kat sayısı çubukları.	37
Şekil 41. ROC diyagramı , burada mavi YSA, yeşil KA, sarı RO olarak tanımlanıyor.	38

I. GİRİŞ

Günümüz enerji ihtiyacının büyük bir kısmını petrol, doğalgaz ve kömür gibi fosil yakıtlar oluşturmaktadır. Ancak bu enerji kaynaklarının tükenmesi ve çevreye verdikleri zararlar nedeniyle yenilenebilir enerji kaynaklarına olan ilgi her geçen gün artmaktadır. Artan enerji talebine ek olarak, petrol ve doğal gaz gibi fosil yakıtların üretiminin çevresel etkileri (Moss, 2010; Robertson ve Krauss, 2010) ozon tabakasının incilmesi ve aşırı karbondioksit tüketimi (Olah, Goepfert, ve Prakash, 2009) fosil yakıtların çevreye verdiği başlıca zararlardır. Bu zararları önlemek ve iklim değişikliğini önlemek için yenilenebilir enerji kaynaklarına yapılan yatırımlar her geçen gün artmaktadır. Yenilenebilir enerji kaynakları arasında yer alan güneş, rüzgâr, hidro ve jeotermal enerji kaynakları, çevreye verdiği zararın minimum düzeyde olması ve kolay üretimi nedeniyle dünyada yaygın olarak kullanılan alternatif, çevre dostu enerji kaynaklarıdır.

Rüzgâr enerjisi üretimi, rüzgârın kinetik enerjisinin elektriğe dönüştürülmesi ilkesine dayanmaktadır. Bu amaçla rüzgâr türbinleri kullanılmaktadır. Rüzgâr enerjisi potansiyeli açısından Türkiye, İrlanda, İspanya vb. diğer yenilenebilir kaynaklarla karşılaştırıldığında, Ülkeler enerji potansiyeline sahiptir (Tolun ve ark, 1995). Türkiye enerji ihtiyacını genel olarak fosil yakıtlardan karşılamaktadır. Türkiye'nin petrol ve doğalgaz gibi sınırlı yeraltı kaynakları, ülke ekonomisinin enerjide dışa bağımlı hale gelmesine neden oluyor. Sonuç olarak, artan enerji talebini ve ekonomik bağımlılığı azaltmak için yenilenebilir enerji yatırımları verimli bir şekilde kullanılmalıdır. Ayrıca maliyeti düşürmek ve çevreye verilen zararı en aza indirmek için yenilenebilir enerji üretiminin artırılması gerekmektedir. Bu ihtiyaçların karşılanması için devreye alınan santrallerin artması ile Türkiye'de bugünkü rüzgâr enerjisi stoku yaklaşık 11 GW'a ulaşmıştır. 2023 yılına kadar rüzgâr enerjisi kapasitesinin 20 GW'a ulaşması beklenmektedir (Erdemir ve ark, 2021; İlkılıç, 2016).

Yenilenebilir enerji kaynaklarının yaygınlaştırılması ile karbondioksit (CO_2) emisyonlarını 2050 yılına kadar %70 oranında azaltmak için küresel bir hareket başlatılmıştır. Verimlilik analizleri ve çeşitli uygulamalarda yeni teknolojiler en önemli konuların başında gelmektedir. Kentleşme genişledikçe, şehirler ve hatta binalar için yerel enerji verimliliği standartlarını düzenleyen entegre yeni enerji sistemlerine yönelik önemli bir talep oluşmaktadır. Binaların enerji kullanımını azaltmak için kentsel planlama esastır. Türkiye, stratejik yeşil enerji planlarına dayanarak 34 GW hidroelektrik, 20 GW rüzgâr enerjisi, 5 GW güneş enerjisi ve 1 GW jeotermal veya biokütle enerjisi inşa etmeyi planlamaktadır. Bu stratejiye dayalı olarak, 2023 yılına kadar Türkiye'nin toplam enerji talebinin yaklaşık %30'unun yenilenebilir enerji kaynaklarından karşılanması hedeflenmektedir (Erdemir ve ark., 2021).

Bilindiği üzere sürdürülebilir enerji kaynaklarının en önemlilerinden biri rüzgârdan elde edilen enerjidir. Rüzgâr türbini kurulması planlanan bölgelerde rüzgâr enerjisi dönüşüm sistemlerinin verimliliğinin artırılması ve ekonomik olarak faydalı olabilmesi için ön analizler, istatistiksel yorumlar ve rüzgâr şiddetinin belirlenmesi önemli faktörlerdir. Rüzgâr enerjisi günümüzün en önemli yenilenebilir enerji kaynaklarından biridir.

Rüzgâr enerjisi performansının tahmini karmaşık topoğrafyaya sahip bölgelerde, dinamik özelliklerden dolayı zor tahmin edilebilmektedir. Rüzgâr enerjisi piyasası katılımcıları, rüzgâr çiftliği sahipleri ve operatörler, bakım ekipleri vb. için etkili planlama esastır. Örneğin, enerji tedarikçileri, enerji depolama sistemlerini göz önünde bulundurarak veya tahmini rüzgâr enerjisi üretimi ve talebini koordine ederek aşırı üretimi önleyebilir. Üreticiler elektrik piyasalarına teklif vermek için stratejiler benimseyebilirler.

Rüzgâr şiddeti, rüzgâr türbinlerinin işlevi için önemli bir parametredir. Rüzgâr hızı tahmini için en önemli modeller, sayısal hava tahmini (SHT) gibi fiziksel yöntemlerdir; örneğin, ARIMA modelinin en popüler olduğu istatistiksel yöntemler; en popülerleri yapay sinir ağlarına (YSA) dayalı olan akıllı modeller ve farklı algoritma türlerini birleştiren hibrit tahmin modelleri bunlar arasında sayılabilir. Fiziksel yaklaşımlardan elde edilen uzun vadeli rüzgâr şiddeti tahmin çalışmaları büyük önem taşımaktadır. Rüzgâr şiddeti kısa vadeli tahmini, istatistiksel yaklaşımlar ve yapay zekâ modelleri ile daha kolay ve daha güvenilir

hale getirilmektedir. Oluşan belirsizlikleri belirlemek ve diğer tahmin aralıklarını ölçmek için (Quan, Srinivasan ve Khosravi, 2014) tarafından sinir ağı tabanlı bir yöntem geliştirilmiştir. Daha sonra bulunan bu tahminlerle ilgili belirsizlikler (Ak, Vitelli ve Zio, 2015) tarafından MLP (çok katmanlı algılayıcı) kullanılarak yeniden ölçülmüştür. Çizelge 1’de, farklı dönemlere göre yapılan tahmin çalışmaları, zaman aralıkları sınıflandırmıştır.

Çizelge 1. Zaman aralıklarına göre rüzgâr şiddeti tahmini

Zaman	Aralık
Çok kısa süre	30dk
Kısa süre	30dk-6saat
Orta süre	6 saat-1 gün
Uzun süre	1gün-1 hafta


Kaynak: (Lawan, Abidin, Chai, Baharun ve Masri, 2014)

Dalgacık tabanlı ağları ve parçacık sürüsü optimizasyonunu kullanılarak, önemli hesaplama çabasıyla da olsa, bir MLP kullanmaktan daha doğru sonuçlar elde edilmiştir (PES, 2007).

Pourmousavi ve ark., (2011) tarafından MLP'nin Markov zincirleriyle birleştirilmesi önerilmiştir. Bu strateji, tahmin hatalarını ve belirsizlikleri makul bir hesaplama maliyetiyle azaltmaktadır. Metodoloji bu nedenle çevrimiçi çalışmalarda uygulanabilir.

Bu araştırma çalışmasında, rüzgâr enerji potansiyeli, kullanılan teknolojiler ve Türkiye’de ve dünyada rüzgâr enerjisinin durumu incelenmiştir. Daha sonra Çanakkale ilinin Babakale Köyü içerisinde yer alan Baba Burnu Bölgesinde yapay sinir ağları (YSA) modeli kullanılarak rüzgârın şiddeti, yönü, ortalama yer seviyesinden 10m yukarıda hava sıcaklığı, değerleri göz önüne alınmış ve gelecekte o bölgedeki rüzgâr şiddeti/enerjisi potansiyeli tahmin edilmiştir.


Şekil 1’de Türkiye genelinde yer seviyesinden 100 m yukarıda yıllık ortalama rüzgâr şiddeti değerlerinin değişimi görülmektedir. Genel olarak Türkiye’nin batısı ve güneyinin yüksek rüzgâr şiddetine, rüzgâr enerji potansiyeline sahip olduğu belirtilebilir.



Şekil 1. Türkiye yıllık ortalama rüzgâr şiddeti

Kaynak: (URL7-REPA-Türkiye, 26.09.2022)

Yenilenebilir Enerji Genel Müdürlüğü tarafından yayınlanan REPA'ya göre, Çanakkale ilinin rüzgâr potansiyeli haritası Şekil 2'de gösterilmiştir. Söz konusu kaynağa göre Çanakkale, rüzgâr şiddeti ve enerji potansiyel açısından en yüksek değere sahip ildir.



Şekil 2. Çanakkale ilinin rüzgâr şiddeti değişimi

Kaynak: (URL8-Çanakkale-REPA, 26.09.2022)

Şekil 1 ve 2, İnceleme bölgesi 100 m civarında yüksekte rüzgâr şiddetinin ayrıntılı değişimini göstermektedir. Özellikle bölgenin batısını yüksek enerji potansiyeline sahip olduğu vurgulanabilir.

II. LİTERATÜR TARAMASI

Kaotik faz uzayının yeniden yapılandırılmasına ve SHT genel regresyonu SA (sinir ağları)'ye dayanan bir hibrit model (Gao, Dong, Liao ve Gao, 2013) tarafından sunulmuştur. Bu strateji, hatalı meteorolojik verilerin etkisini azaltır. Yukarıdaki model çalışmaları, YSA'ları ile birlikte hibrit modellerin son derece kısa vadeli rüzgâr şiddetini tahmin etmek için daha iyi sonuçlar verdiğini göstermiştir.

Li ve ark., (2011) kısa vadeli tahminle ilgili olarak, 1 saat sonrasına ait tahminler için BPNN (geri yayılma sinir ağı) ve RBFNN (radyal tabanlı sinir ağı) çalışmışlardır. Bu çalışma, tüm durumlarda en iyi sonuçları sağlayan başka bir YSA yöntemi olmadığı sonucuna varmaktadır.

Palomares ve ark., (2014) tarafından geliştirilen BPNN'in 1 saat sonrasına ait tahminler için de kullanılabilir olduğunu göstermişlerdir. Bu yöntem, kalıcılık modelinin sonuçlarını iyileştirmiş ve geleneksel tarımsal ölçümlerden elde edilen verilerin, kabul edilebilir sonuçlarla rüzgâr şiddetini tahmin etmede faydalı olabileceğini göstermiştir.

Philippopoulos ve Deligiorgi (2012), son derece karmaşık araziye sahip bir kıyı alanı için ileri beslemeli bir YSA yaklaşımı önermiştir. YSA'ların rüzgârın topoğrafyaya bağlı olarak kararsız özelliklerini hesaba katma yeteneği nedeniyle bu modelin doğru olduğunu kanıtlamışlardır.

III. YÖNTEM VE VERİ

A. İnceleme bölgesi ve veri

Hem Avrupa hem de Asya kıtasında yer alan Çanakkale ili 9.933 km^2 bir alana sahiptir. Marmara Bölgesi'nin en batı ucunda yer alan Çanakkale İli gerek kendi dinamikleri gerekse bulunduğu bölge nedeniyle enerji tüketimi en yüksek olan illerden biridir. Baba Burnu Anadolu'nun en batı ucunda, Ege Denizi'nde yer almaktadır. Koordinatları $39^\circ 28' 45''$ kuzey enlemi, $26^\circ 03' 50''$ doğu boylamıdır. İnceleme bölgesinin deniz seviyesinden ortalama yüksekliği 3m ile 275m arasında Türkiye'nin kurulu rüzgâr gücü 48 ildeki santrallerle yaklaşık 11 bin MW'a ulaşmış bulunmaktadır. Türkiye'nin mevcut kurulu elektrik gücü 100 bin 334 MW'a, rüzgâr enerjisinin payı da %10,8'e yükselmiştir. Türkiye'de en yüksek rüzgâr enerji kapasitesi bulunan 5 il İzmir, Balıkesir, Çanakkale, İstanbul ve Manisa olarak sıralanmaktadır, (URL1-URL3, 2022).

Türbülans, sıcaklık, nem ve diğer değişkenleri izlemek için rüzgâr türbinlerinin içine çok çeşitli sensörler yerleştirilmiştir. Tüm değişkenler, veri toplama sistemleri ile kaydedilmektedir. Sağlanan verilerden en fazla bilgiyi elde etmek için veri işleme algoritmalarına ihtiyaç vardır. Çok büyük miktarda veriyi değerlendirme kapasitesi nedeniyle, makine öğrenimi algoritmaları yaygın olarak kullanılmaktadır ve YSA en çok kullanılan yöntemlerden biridir (Marugán ve ark., 2018).

Makine öğrenmesi algoritmalarını kullanarak zaman serisi tahmini son zamanlarda popülerlik kazanmıştır. Rastgele orman, zaman serisi tahmininde uygulanan bir makine öğrenme algoritmasıdır; ancak, tahmin özelliklerinin çoğu keşfedilmemiş olarak kaldı. Burada, optimal bir tahmin değişkenleri seti önermek için iki büyük kısa zaman serisi veri setini kullanarak tek adımlı tahminde rastgele ormanların performansını değerlendirmeye odaklanıyoruz. Ayrıca performansını kıyaslama yöntemleriyle karşılaştırıyoruz. İlk veri seti, çeşitli Otoregresif Kesirli Entegre Hareketli Ortalama (ARFIMA) modellerinden 16.000

simüle edilmiş zaman serisinden oluşur. İkinci veri seti, 135 yıllık ortalama sıcaklık zaman serisinden oluşmaktadır. RO'nin en yüksek tahmin performansı, düşük sayıda nihai gecikmeli tahmin değişkeni kullanıldığında gözlemlenir. Bu sonuç, daha yüksek tahmin doğruluğu elde etme olasılığı ile ilgili gelecekteki uygulamalarda faydalı olabilir (Tyralis ve Papacharalampous, 2017).

Karar ağacı sınıflandırıcıları, sınıflandırıcıların veri sınıflandırma temsilinin en iyi bilinen yöntemlerinden biri olarak kabul edilir. Çeşitli alanlardan ve geçmişlerden farklı araştırmacılar, bir karar ağacını mevcut olanlardan genişletme sorununu ele aldılar. Makine çalışması, desen tanıma ve istatistik gibi veriler. Tıbbi hastalık analizi, metin sınıflandırması gibi çeşitli alanlarda, Kullanıcı akıllı telefon sınıflandırması, resimler ve daha birçok Karar ağacı sınıflandırıcısı birçok yönden önerilmiştir. Bu makale, karar ağaçlarına ayrıntılı bir yaklaşım sağlar. Ayrıca kullanılan algoritmalar/yaklaşımlar gibi kağıt özellikleri, veri setleri ve elde edilen sonuçlar kapsamlı bir şekilde değerlendirilir ve özetlenir. Ayrıca, analiz edilen tüm yaklaşımlar, yazarların temalarını göstermek ve en doğru sınıflandırıcıları belirlemek için tartışıldı. Sonuç olarak, farklı türlerin kullanımları veri kümeleri tartışılır ve bulguları analiz edilir (Charbuty ve Abdulazeez, 2021).

Türkiye geneli rüzgâr şiddeti değişim haritasından da görüldüğü gibi, en yüksek rüzgâr potansiyeli kaynakları Türkiye'nin en batı kıyılarında Marmara denizi çevresinde ve Antakya çevresinde görülmektedir. Türkiye'nin rüzgâr potansiyeli haritasında da gösterildiği gibi, Marmara ve Ege bölgelerindeki rüzgâr şiddeti diğer bölgelere göre daha fazladır. Bu nedenle rüzgâr santralinden toplanacak enerji miktarının saptanmasında rüzgâr potansiyeli hesapları esas alınmaktadır. Kapasite faktörü, RES'in konuşlandırılacağı yerlerin saptanması, yatırım yapmadan önce dikkate alınması gereken bir diğer önemli konudur (Çalışkan, 2010). Genel olarak özellikle kuzey ege bölgesi rüzgâr enerji potansiyeli açısından yüksek potansiyele sahiptir.

Bu araştırma çalışmasında, Çanakkale ilinin Babakale Köyü içerisinde yer alan Baba Burnu bölgesinde 2001-2003 yılları arasında kaydedilmiş, saatlik rüzgâr şiddeti değerleri (m/s) göz- önüne alınmıştır.

Çizelge 2. Veri Bilgisi

Başlıklar	Ayrıntı
Araştırma Bölgesi	Çanakkale, Baba Burnu
Dönemi	01.01.2001-31.12.2003
Veri örnekleme periyodu	1 saat
Veri	Rüzgâr Şiddeti (<i>m/s</i>)
Giriş Verileri	Hava Sıcaklığı, 10m °C,

Çizelge 2’de bu araştırmada göz önüne alınan verilerle ilgili ayrıntılar sunulmaktadır.

Bu tez çalışmasında YSA(Yapay sinir ağları), KA(Karar Ağaçları), RO(Rastgele Orman) yöntemleri göz önüne alınmıştır.

2001-2003 yılları arasında saatlik ortalama rüzgâr şiddeti verileri (*m/s*) göz önüne alınmıştır. Çok az sayıdaki eksik veriler, en yakın değerlerin aritmetik ortalaması alınarak tamamlanmıştır. İnceleme dönemi, tarih, saat formatları revize edilmiştir.


B. Yapay Sinir Ağları

Yapay sinir ağları (YSA) üzerine yapılan araştırmalar, YSA'nın güçlü örüntü sınıflandırmasına ve bu sınıflandırmanın tanınmasına olanak sağladığını göstermektedir. İnsan beyninin incelenmesi yoluyla geliştirilen yapay sinir ağları, verilerden elde edilen deneyimlerle genellemeler ve sonuçlar sağlar. YSA birçok farklı alanda kullanılmaktadır (Gündüz ve Aslan, 2020).

Nöronlar sinir ağının temel yapı taşlarıdır. Bir nöron, bir işlem birimi olarak düşünülebilir. Bir sinir ağında, nöronlar birbirine sinaptik ağırlıklar veya kısaca ağırlıklar ile bağlanır. Bir ağdaki her nöron, bağlı olduğu nöronlardan sinaptik bağlantıları aracılığıyla 'ağırlıklı' bilgi alır ve giriş sinyallerinin ağırlıklı toplamına bir 'aktivasyon işlevi' uygulayarak bir çıktı üretir (Sazlı, 2006).

Nöronal bağlantıların doğasına bağlı olarak, iki ana ağ mimarisi türü vardır: ileri beslemeli sinir ağları ve tekrarlayan sinir ağları. Nöronların çıkışlarından girişlere herhangi bir geri bildirim yoksa ağ, ileri beslemeli bir sinir ağı olarak kabul edilir. Geri bildirim varsa, yani çıktılarından girdilere (kendi girdileri veya diğer nöronların girdileri) sinaptik bir bağlantı varsa, ağ tekrarlayan bir sinir ağı olarak adlandırılır. Tipik olarak, sinir ağları katmanlar halinde yapılandırılmıştır. Katman sayısına bağlı olarak, ileri beslemeli sinir ağları iki kategoriden birine

girer; tek katmanlı veya çok katmanlı (Sazlı, 2006). Dört katmanlı YSA örneği Şekil 2.1'de gösterilmektedir.



Şekil 3. Yapay Sinir Ağının Yapısı

Kaynak: (IBM, 2020)

Şekil 3, bir "gizli katman" a sahip çok katmanlı ileri beslemeli bir sinir ağını göstermektedir. Tek katmanlı bir ağına aksine, giriş ve çıkış katmanları arasında (en az) bir "gizli nöron" katmanı vardır. Gizli nöronların rolü, harici girdi ile ağ çıktısı arasında faydalı bir aracı olarak hizmet etmektir (Haykin, 1999). Bir veya daha fazla gizli katmanın varlığı, ağdan daha yüksek dereceli istatistiksel bilgilerin elde edilmesine olanak verir. Şekil 2.1'de gösterilen örnekte sadece bir gizli katman vardır ve ağ 4 giriş nöronu, 6 gizli nöron ve 2 çıkış nöronundan oluştuğu için 4-6-2 ağı olarak anılır.

Bir yapay sinir hücresinin çıkış sinyali aşağıda tanımlayacağımız denklemler ile gösterilir (Haykin, 1999):

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

$$y_k = f(u_k + b_k) \quad (2)$$

Burada x_1, x_2, \dots, x_m giriş sinyalleridir; $w_{k1}, w_{k2}, \dots, w_{km}$ k nöronunun ilgili sinaptik ağırlıklarıdır; u_k , giriş sinyallerinden kaynaklanan lineer birleştirici; b_k

sapma; f aktivasyon fonksiyonudur ve y_k , nöronun çıkış sinylidir. Sapma b_k 'nin kullanılması, lineer birleştiricinin u_k çıkışına bir afin dönüşüm uygulama etkisine sahiptir (Haykin, 1999).

Denetimli öğrenme yoluyla, YSA'lar bir veri kümesi içindeki kalıpları tanımlayabilir. Denetimsiz öğrenme kullanılarak verilerdeki benzerlikler ve farklılıklar belirlenebilir. Ağ, karşılaştırılarak veriler gruplaştırılabilir. Matematiksel bir modelin uygulanmadığı sorunları çözmek için bir YSA kullanılabilir. Belli bir kesinlik derecesiyle, girdi verilerini bir fonksiyona yaklaştırabilirler. Bir YSA'da, zaman serileri kullanılarak gelecekteki davranışı tahmin edilebilir. Çeşitli kısıtlamalara tabi olan fonksiyonları maksimize eden veya minimize eden bir çözüm bulmak mümkündür. Bir ilişkilendirme modeli oluşturarak, bir ilişkisel ağ, bozuk verilerin yeniden oluşturulmasına yardımcı olabilir. İstenen sonuca yol açacak bileşenleri belirlemek mümkündür (Marugán ve ark., 2018).

YSA dört temel değişkenle karakterize edilir: topoloji, eğitim tekniği, girdi ve çıktı verileri arasındaki ilişki türü ve bilgi gösterimi. Bundan başka 50'den fazla YSA türü ayırt edilebilir, örneğin: MLP; radyal tabanlı fonksiyon sinir ağı (RBFNN); geri yayılım ağları (BPNN); sinirsel dalgacık ağı (Dalgacık SA); kendi kendini organize eden harita sinir ağı (SOM NN); tekrarlayan sinir ağı, zaman gecikmeli sinir ağı; Hopfield ağı, oto-ilişkisel sinir ağı; evrişimli sinir ağı, vektör kuantizasyon ağlarını öğrenme; uyarlanabilir sinir ağı rezonans teorisi (ART); nöro bulanık ağlar, dinamik sinir ağı vb.

Eğitim yoluyla, (teaching process) YSA'lar bilgiyi temsil etmek için kendi yapılarını oluşturabilirler. YSA, yapısı bozulduğunda (bozulma toleransı) ve veriler gürültü nedeniyle bozulduğunda veya eksik olduğunda (veriye tolerans) çalışmaya devam edebilir. Aynı anda ve verimli bir şekilde uygulanabilirler. Bu nedenle, çevrimiçi görevleri gerçekleştirmek için özel olarak tasarlanmıştır.

Denetimli YSA'lar bir veri kümesindeki kalıpları tanıyabilir. Denetimsiz öğrenme yoluyla verilerdeki benzerlikler ve farklılıklar saptanabilir. Ayrıca teorik bir modelin kullanılmadığı durumlarda bile YSA'lar kullanılarak yaklaşımlar yapılabilir. Bir fonksiyon için girdi verileri belirli bir doğruluk derecesi ile tahmin edilebilir. Bir YSA'na zaman verilerini kullanarak gelecekteki davranışı


tahmin etmesi öğretilir. Bir fonksiyonu farklı kısıtlara göre maksimize eden veya minimize eden bir çözüm bulmak mümkündür. Bir ilişkilendirme modeli oluşturularak, bir ilişkisel ağ kullanılarak bozuk veriler yeniden oluşturulabilir. Sistemin amaçlanan davranışına yol açan girdileri belirlemek mümkündür.

C. Karar Ağaçları (Decision tree)

Karar Ağaçları (DT'ler), hem sınıflandırma hem de regresyon görevleri için çok popüler ve başarılı bir makine öğrenme yöntemidir. Sundukları avantajlardan bazıları şunlardır: öznitelikler ve hedef değişken arasındaki doğrusal olmayan ilişkileri modelleyebilirler, öznitelik ölçeklendirme gerektirmezler ve sonuçta ortaya çıkan ağacın (eğer-o zaman kuralı) yorumlanması ve kullanılması kolaydır. Son kullanıcının karar vermesi için.

Bir KA, özellik alanının özyinelemeli bir ikili bölümü aracılığıyla oluşturulur. Ağaçtaki bir düğüm, bir özneliğin değeri için bir teste karşılık gelir ve bir yaprak düğüm, bir gerileme işlevine karşılık gelir. Ağacı oluştururken, her adımda en yüksek bilgi kazancına sahip öznelik seçilir. Ağacı bölmek için değeri için bir test kullanılır ve olası sonuçlar için bir dal oluşturulur. Test, öznelik değerine göre örnekleri birkaç alt kümeye böler. İşlem, durma koşulu sağlanana kadar her alt küme için tekrarlanır, bu durumda bir yaprak düğüm oluşturulur. Yeterince yüksek bilgi kazancına sahip bölünmüş aday olmadığında veya önceden belirlenmiş maksimum ağaç derinliğine ulaşıldığında ağaç büyümesi durur.

Yeni bir örneğin değerini tahmin etmek için ağacın kökünden başlar ve bir yaprak düğüme ulaşılan ve tahmin elde edilene kadar örneğin değerlerine karşılık gelen yolu izleriz. MLib, hem sınıflandırma hem de regresyon için KA'leri destekler ve hem sürekli hem de ayrık niteliklerle kullanılabilir. Ağaç tabanlı öğrenme algoritmaları, en çok kullanılan denetimli öğrenme algoritmaları arasındadır. Genel olarak, ele alınan tüm problemlerin (sınıflandırma ve regresyon) çözümüne uyarlanabilirler. Karar ağaçları, rastgele orman, gradyan artırma gibi yöntemler her türlü veri bilimi probleminde yaygın olarak kullanılmaktadır. Bu nedenle veri analistlerinin bu algoritmaları öğrenmesi ve kullanması oldukça önemlidir.



Şekil 4. Karar Ağacı,

Kaynak: [URL-5]

Karar ağacı algoritması, veri madenciliği sınıflandırma algoritmalarından biridir.

Önceden tanımlanmış bir hedef değişkene sahiptirler. Nitelikleri gereği yukarıdan aşağıya bir strateji sunarlar (Çelik, 2017).

Karar ağacı, birçok kayıt içeren bir veri kümesini, bir dizi karar kuralı uygulayarak daha küçük kümelere bölmek için kullanılan bir yapıdır. Başka bir deyişle, basit karar verme adımları uygulanarak çok miktarda kaydın çok küçük kayıt gruplarına bölünmesiyle kullanılan bir yapıdır.

- **Karar Ağaçlarının avantajları aşağıda listelenmiştir.**
- Anlaması ve yorumlaması kolaydır. Kullanılan ağaç yapıları görselleştirilebilir.
- Çok az veri hazırlığı gerektirir. Ancak bu modelin eksik değerleri desteklemediğine dikkat edilmelidir.

- Kullanılan ağacın maliyeti, ağacı eğitmek için kullanılan veri noktalarının sayısına göre logaritmiktir.
- Hem sayısal hem de kategorik verileri işleyebilir.
- Çoklu çıktı problemlerini çözebilirler.
- İstatistiksel testler kullanarak bir modeli doğrulamak mümkündür.
- Karar ağaçları parametrik olmayan bir yöntem olarak düşünülebilir. Yani uzay dağılımı ve sınıflandırma yapısı hakkında bir yaklaşımı yoktur.
 - **Karar Ağaçlarının dezavantajları aşağıda listelenmiştir.**
- Verileri iyi açıklamayan aşırı karmaşık ağaçlar üretilebilir. Bu durumda ağaç dallanması takip edilemeyebilir.
- Ezbere öğrenme deneyimlenebilir (“fazla uydurma”). Model parametrelerine kısıtlamalar ve budama gibi yöntemler bu sorunu çözmek için kullanılabilir. Budama, karar ağacı grafiğinden birkaç nesne içeren yaprak düğümlerinin çıkarılmasını ifade eder (Çelik, 2017).
- Karar ağacı algoritmalarında bölmenin nasıl gerçekleştiği, ağacın doğruluğunu etkileyen faktörlerden biridir. Sınıflandırma ve regresyon problemleri için bölme kriterleri genellikle farklıdır.
- Karar ağaçları, bir düğümün iki veya daha fazla alt düğüme bölünüp bölünmeyeceğine karar vermek için birden çok algoritma kullanır. Alt düğümler oluşturmak, alt düğümlerin homojenliğini artırır. Yani hedef değişkenlere göre düğümün saflığının arttığını söyleyebiliriz.
- Algoritma seçimi, hedef değişkenin türüne bağlıdır. Karar ağaçlarında en sık kullanılan algoritmalar; Kategorik Değişkenler İçin Entropi, Gini, Sınıflandırma Hatası; Sürekli değişkenler için En Küçük Kareler yöntemidir.
- Entropi, verilerimiz hakkındaki belirsizliğin bir ölçüsüdür. Sezgisel olarak, bir veri kümesinin yalnızca bir etiketi varsa (örneğin, her yolcu hayatta kaldı), daha düşük bir entropiye sahip olduğunu düşünebiliriz. Bu nedenle, verilerimizi entropiyi en aza indirecek şekilde bölmemiz gerekiyor. Bölmeler ne kadar iyi olursa, tahminimiz o kadar iyi olur.

$$H = -\sum p(x) \log p(x) \quad (3)$$

(Entropi Denklemi, Claude Shannon, 1948.)

Burada $p(x)$, belirli bir sınıfa ait grubun yüzdesini, H ise entropiyi ifade eder.

Karar ağacımızın entropi değerini en aza indiren bölmeler yapmasını istiyoruz. En iyi ayrımı belirlemek için bilgi kazancını kullanırız. Bilgi kazancı aşağıdaki denklemle hesaplanır:

$$Gain(S, D) = H(S) - \sum \frac{|V|}{|S|} H(V) \quad (4)$$

Burada S , orijinal veri kümesidir ve D , kümenin bölünmüş bir parçasıdır. Her V , S 'nin bir alt kümesidir. V 'nin tümü ayrıdır ve S 'yi oluşturur. Bu durumda, bilgi kazancı, bölünmeden önceki orijinal veri kümesinin entropisi ile her bir özelliğin entropi değeri arasındaki fark olarak tanımlanır.

Karar ağacı algoritmasının kullanıldığı sınıflandırma problemlerinde kullanılacak veri seti iki ana bölüme (tren-tren ve test) ayrılmalıdır. Algoritma, eğitim verilerini kullanarak modeli oluşturur. Bu model test verilerine uygulanmakta ve modelin problem çözmedeki başarısı hesaplanmaktadır.

D. Rastgele Orman (Random Forest)

Rastgele Orman (RO) aynı zamanda bir KA topluluğudur. Ağaçların yinelemeli olarak oluşturulduğu Gradyan Güçlendirme Ağacı(GBT)'nin aksine, RO birden fazla ağacı paralel olarak eğitir. Her ağaç, eğitim verilerinden bir önyükeme örneği oluşturarak oluşturulan farklı bir eğitim seti kullanır. Ek olarak, her bir düğümde en iyi özneliği seçerken, KA'lerde olduğu gibi tüm özellikler yerine düğümde mevcut tüm özneliklerin yalnızca bir alt kümesi dikkate alınacaktır. Böylece, RO hem rastgele örnek hem de özellik seçimini kullanır. Yeni bir örnek için bir tahmin yapmak için RO, her ağaçtan elde edilen tahminlerin ortalamasını alır.

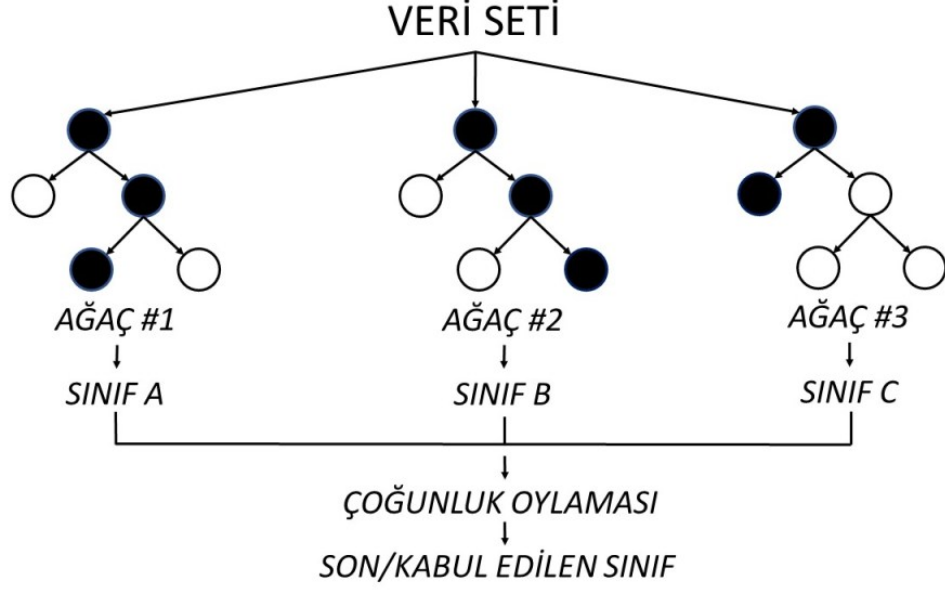
Özetle, hem GBT hem de RO karar ağaçlarını temel model olarak kullanır, ancak eğitim süreci farklıdır ve iki yöntemin her birinin avantajları ve dezavantajları vardır. MLib, hem GBT hem de RO'yi destekler.

Makine öğrenimi (ML) yöntemleri, rüzgar enerjisi sektöründe, özellikle rüzgar hızı/güç tahmini için giderek daha popüler hale geliyor (J. Feng, 2019). Tahmin amacıyla ML'nin artan kullanımı ve genel olarak istatistiksel modelleme, diğer geleneksel tekniklerin kullanımındaki bir zaman ölçeği boşluğundan kaynaklanmaktadır.

Rastgele orman (RO), rüzgar tahmini amaçları için büyük umut vaat eden bir ML modelleme metodolojisidir (Lahouar ve Ben Hadj Slama, 2017). RO modellemenin gürültülü veya alakasız girdilere karşı sağlam olduğunu gösteren 18 adede kadar girdi değişkeni kullanarak bir saat ileri rüzgâr gücü tahmininde bulundu. Feng (2017) RO'yi derin öznitelik seçimine sahip bir topluluk modelleme çerçevesi içinde bir bileşen olarak kullandı ve tek bir algoritma modeline göre saatlik rüzgar gücü tahmin doğruluğunu %30'a kadar artırdı. (Niu, Pu ve Dai, 2018) ultra kısa vadeli rüzgâr gücünü tahmin etmek için niş bağışık aslan algoritması tarafından optimize edilmiş bir hibrit dalgacık ayrıştırma ağırlıklı RO modeli kullanmıştır. Geliştirilen model, tipik bir RO modeli, bir sinir ağı ve bir destek vektör makinesinden daha iyi performans gösterdi. Burada, ağı (rüzgar hızını tahmin etmek için) ve rüzgar gücünü tahmin etmek için optimize edilmiş bir RO'yi birleştiren bir hibrit model kullandı. (Shi ve diğerleri, 2018) geliştirilmiş modelin orijinal RO, bir sinir ağı ve bir destek vektör makinesinden daha iyi performans gösterdiğini göstererek, 15 dakikalık rüzgâr gücünü tahmin etmek için 2 aşamalı özellik seçimi ve karar ağacı yeniden düzenlemesini kullanan gelişmiş bir RO modeli oluşturdu. Son olarak, Vassallo ve ark., (2021) rüzgar hızı tahmini için bir RO modelinde kullanılan çok sayıda atmosferik girdi özelliğinin faydasını test etmiştir.

E. Rastgele Orman Algoritması Nedir?

Rastgele Orman algoritması; Her bir karar ağacını birden çok karar ağacında farklı bir gözlem örneğinde eğiterek çeşitli modeller oluşturmanıza ve sınıflandırmalar oluşturmanıza olanak tanır. Kullanım kolaylığı ve esneklik hem sınıflandırma hem de regresyon problemlerini ele aldığı için benimsenmesini ve yaygın kullanımını hızlandırmıştır. Algoritma ile ilgili en beğenilen nokta ise; Veri kümeniz üzerinde çeşitli modeller oluşturarak, veri kümenizi her geçen gün daha fazla yeniden keşfetme olanağı sağlar.



Şekil 5. Rastgele Orman

Kaynak: [URL-6]

• **Gerekli Algoritma:**

- Analiz edilecek veri seti hazırlanır, (Analiz edilecek küme oluşturulur, gerekirse veri temizliği yapılır.)
- Algoritma, her örnek için bir karar ağacı oluşturur ve her bir karar ağacının tahmini değeri elde edilir,
- Tahmin sonucunda oluşan her değer için oylama yapılır, (Sınıflandırma problemi modu, Regresyon problemi için ortalama)
- Son olarak, algoritma, son tahmin için en çok oylanan değeri seçerek sonucu üretir. Adım adım analiz edilir.

IV. BULGULAR

Bu çalışmanın uygulama aşamasında Çanakkale Baba Burnu bölgesine ait 2001, 2002, 2003 yıllarında elde edilmiş rüzgâr şiddeti verilerinin aylık ve yıllık değerleri kullanılmıştır. Her yıl için veri boyu, ortalama, standart sapma, Q1, Q2 ve Q3, maksimum, minimum, değişinti (varyans), çarpıklık ve basıklık değerleri hesaplanmıştır. Başlangıç ayını temsilen Ocak bitiş ayı ise Aralık ayı olarak seçilmiştir.

A. İstatistiksel analiz

İnceleme bölgesinde kaydedilen rüzgâr şiddeti verilerinin aylık ve yıllık değişimine göre istatistiksel özellikleri (veri boyu, ortalama, standart sapma, Q1, Q2 ve Q3, maksimum, minimum, değişinti, çarpıklık ve basıklık değerleri) Çizelge 3, 4 ve 5'te sunulmaktadır. En yüksek ortalama rüzgâr şiddeti 8.22m/s olarak Ağustos ayında kaydedilmiştir. Yıllık ortalama rüzgâr şiddeti 15.23 m/s olarak belirlenmiştir.

Çizelge 3. Rüzgâr Şiddeti İstatistiksel büyüklükleri (Baba Burnu, 2001)

Ay	Veri Boyu	Ort	St. Sap.	mi n	25 %	50 %	75 %	max	Medyan	mod	Değişinti	Çarpıklık	Basıklık
Ocak	744	6.01	3.07	0.00	3.51	5.80	8.50	14.84	5.80	[3.56]	9.40	0.26	-0.79
Şubat	672	6.01	3.11	0.00	3.68	5.78	7.97	21.19	5.78	[4.65]	9.68	0.81	2.05
Mart	744	5.95	3.26	0.00	3.39	5.86	8.22	22.51	5.86	[8.45]	10.66	0.53	0.96
Nisan	720	6.01	2.72	0.33	3.91	5.84	8.02	15.39	5.84	[5.73]	7.40	0.24	-0.62
Mayıs	744	4.91	2.68	0.43	2.86	4.33	6.50	16.61	4.33	[3.05]	7.16	1.03	1.22
Haziran	720	5.37	2.43	0.02	3.41	5.13	7.00	13.84	5.13	[5.3]	5.90	0.51	-0.23
Temmuz	744	6.22	2.74	0.60	4.29	5.66	8.00	14.49	5.66	[4.53]	7.50	0.57	-0.14
Ağustos	744	6.47	3.09	0.02	3.98	6.28	8.52	15.82	6.28	[5.23, 7.47]	9.54	0.38	-0.47
Eylül	720	4.56	2.24	0.00	2.84	4.32	6.10	11.12	4.32	[2.27, 3.77, 5.54]	5.01	0.38	-0.42
Ekim	744	5.77	3.44	0.07	2.77	5.37	8.28	14.84	5.37	[2.43]	11.84	0.41	-0.75

Çizelge 3. (devamı) Rüzgâr Şiddeti İstatistiksel büyüklükleri (Baba Burnu, 2001)

Ay	Veri Boyu	Ort	St. Sap.	min	25 %	50 %	75 %	max	Medyan	mod	Değişinti	Çarpıklık	Basıklık
Kasım	720	5.95	3.36	0.00	3.46	5.35	7.48	17.18	5.35	[2.84, 3.13, 3.96, 4.89, 5.32]	11.29	0.93	0.53
Aralık	744	8.22	3.86	0.00	5.66	7.67	10.75	24.41	7.67	[7.49]	14.94	0.71	1.07
Ortalama		5.95	3.00	0.12	3.65	5.62	7.94	16.85	5.62	0.00	9.19	0.56	0.20

Çizelge 3, 4 ve 5'te sırasıyla 2001, 2002 ve 2003 yıllarına ait rüzgâr şiddeti değerlerine ait istatistiksel (ortalama, minimum, maksimum, median, mod, standart, sapma, varians, çarpıklık, basıklık, Q1 Q2 ve Q3) büyüklükler sunulmaktadır.

2001 yılında en yüksek ve en düşük ortalama rüzgâr şiddeti değerleri sırası ile Aralık ve Eylül aylarında, 8, 22 ve 4, 56m/s olarak saptanmıştır. Maksimum rüzgar şiddeti değerleri ise, yine Aralık ve Eylül aylarında sırası ile 24,41 ve 11, 12m/s olarak ölçülmüştür.

Çizelge 4. Rüzgâr Şiddeti İstatistiksel büyüklükleri (Baba Burnu, 2002)


Ay	Veri boyu	Ort	St. Sap	min	25 %	50 %	75 %	max	Medyan	mod	Değişinti	Çarpıklık	Basıklık
Ocak	744	5.16	3.17	0.00	2.86	4.70	6.71	19.31	4.70	[4.22, 4.51]	10.04	1.09	1.71
Şubat	672	4.94	2.57	0.12	3.13	4.43	6.48	13.75	4.43	[3.44, 4.01]	6.59	0.70	0.13
Mart	737	6.03	2.92	0.00	3.96	5.88	8.07	16.63	5.85	[4.3, 7.28]	8.55	0.37	0.17
Nisan	720	4.99	2.51	0.24	3.10	4.61	6.52	13.20	4.61	[4.3]	6.32	0.66	0.12
Mayıs	744	4.79	2.26	0.21	3.13	4.58	6.18	12.03	4.51	[4.68]	5.09	0.55	-0.12
Haziran	720	6.28	2.91	0.45	4.06	5.97	8.50	14.46	5.97	[5.18]	8.44	0.30	-0.67
Temmuz	744	5.01	2.34	0.26	3.15	4.76	6.56	12.36	4.75	[3.77, 3.89]	5.48	0.47	-0.35
Ağustos	744	5.67	2.57	0.69	3.72	5.25	7.45	13.94	5.25	[3.51, 4.46]	6.59	0.55	-0.18
Eylül	720	4.19	2.22	0.02	2.58	3.98	5.20	13.70	3.98	[2.46]	4.94	0.82	1.04
Ekim	744	5.04	2.41	0.02	3.22	4.82	6.69	13.89	4.82	[5.85]	5.79	0.41	0.03
Kasım	720	4.38	2.55	0.10	2.61	3.97	5.76	17.06	3.91	[1.89]	6.52	1.01	1.84
Aralık	744	6.40	3.52	0.21	3.77	5.83	8.03	21.03	5.82	[5.92]	12.42	1.22	2.13
Ort,		5.24	2.66	0.19	3.27	4.85	6.85	15.11	4.88	0.00	7.23	0.68	0.49

2002 yılında en yüksek ve en düşük ortalama rüzgâr şiddeti değerleri sırası ile Aralık ve Eylül aylarında, 6, 40 ve 4, 19 m/s olarak saptanmıştır. Maksimum rüzgar şiddeti değerleri ise, yine Aralık ve Mayıs aylarında sırası ile 21,03 ve 12, 03 m/s olarak ölçülmüştür.


Çizelge 5. Rüzgâr Şiddeti İstatistiksel büyüklükleri (Baba Burnu, 2003)

Ay	Veri boyu	Or t.	St. Sap	mi n	25 %	50 %	75 %	max	Medyan	mod	De-ğişinti	Çarpıklık	Ba-sıklık
Ocak	744	6.2	3.53	0.1	3.5	5.5	8.1	19.	5.54	[2.84, 4.18, 4.82]	12.43	0.88	0.48
Şubat	672	7.3	3.77	0.1	4.4	6.6	9.6	19.	6.68	[9.28]	14.20	0.62	-0.13
Mart	744	6.0	3.83	0.1	3.1	5.0	8.1	17.	5.06	[2.82, 3.15, 3.25, 3.7]	14.69	0.87	0.08
Nisan	720	5.1	3.06	0.3	2.6	4.3	7.4	14.	4.32	[3.44, 3.84]	9.38	0.73	-0.23
Mayıs	744	3.9	2.29	0.2	2.3	3.5	4.7	12.	3.53	[3.1]	5.26	1.14	1.05
Haziran	720	5.4	2.58	0.4	3.3	5.1	7.2	13.	5.11	[2.98, 3.13]	6.67	0.53	-0.39
Temmuz	744	5.8	2.76	0.6	3.6	5.5	7.9	13.	5.54	[3.2, 5.51]	7.61	0.48	-0.51
Ağustos	744	6.4	3.11	0.4	4.0	6.1	8.8	15.	6.18	[2.86]	9.68	0.32	-0.76
Eylül	720	5.5	2.83	0.0	3.2	4.9	7.4	13.	4.96	[3.29, 3.53, 4.94]	7.98	0.54	-0.44
Ekim	744	5.6	2.79	0.4	3.5	5.1	7.5	15.	5.17	[3.22, 3.72, 4.32, 5.82]	7.76	0.75	0.14
Kasım	720	5.1	3.80	0.0	2.2	3.7	7.2	18.	3.77	[2.29]	14.43	1.01	0.26
Aralık	744	5.7	3.23	0.0	3.2	5.3	8.0	14.	5.30	[4.7]	10.46	0.45	-0.51
Ort.		5.7	3.13	0.2	3.2	5.1	7.7	15.	5.10		10.05	0.69	-0.08

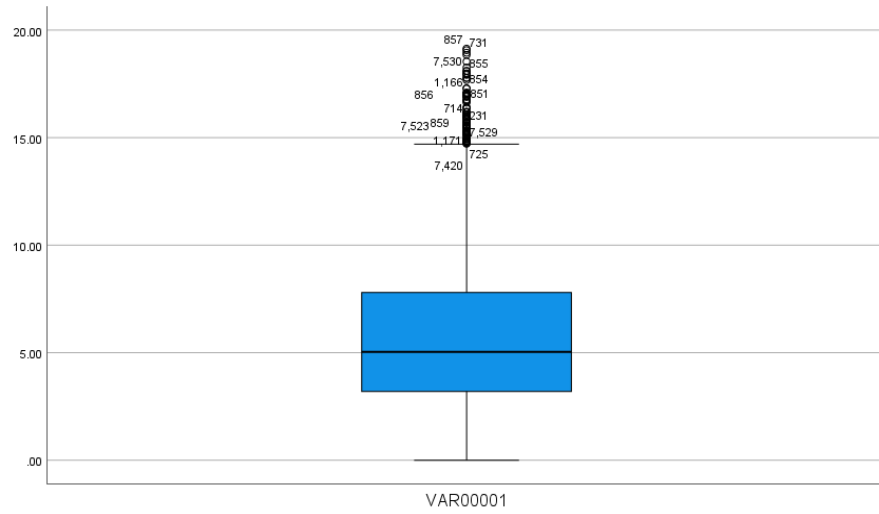
2003 yılında en yüksek ve en düşük ortalama rüzgâr şiddeti değerleri sırası ile Ağustos ve Mayıs aylarında, 6, 49 ve 3, 95 m/s olarak saptanmıştır. Maksimum rüzgâr şiddeti değerleri ise, yine Ocak ve Mayıs aylarında sırasıyla 19,14 ve 12,12 m/s olarak ölçülmüştür. Tablo değerlerine göre, inceleme dönemlerinde, rüzgâr şiddetinin norma dağılıma yakın bir dağılım veya pozitif çarpıklık gösterdiği saptanmıştır.



Şekil 6. 2001 yılı için rüzgâr şiddeti kutu diyagramı



Şekil 7. 2002 yılı için rüzgâr şiddeti kutu diyagramı




Şekil 8. 2003 yılı için rüzgâr şiddeti kutu diyagramı

Şekil 6, 7 ve 8’de sırası ile 2001, 2002 ve 2003 yılına ait rüzgâr şiddeti değerlerinin kutu diyagramları sunulmaktadır. 2001 ve 2002 yılı verilerinde rüzgâr şiddeti değişiminin daha çok normal dağılım fonksiyonuna benzer bir dağılım göstermiştir. Ancak, 2003 yılında pozitif çarpıklık artış göstermiştir. Mod değerleri yıllara göre azalmıştır.

B. YSA ile rüzgâr şiddeti tahmini

Şekil 9’da görüldüğü gibi bu çalışmada, veri akışı ve değerlendirme aşamaları 4 adımda gerçekleştirilmiştir. Bu adımlar kısaca şu şekildedir: Baba Burnu bölgesindeki rüzgâr şiddetinin ölçümünden elde edilen veriler YSA,


Karara Ağacı ve Rastgele Orman yöntemi kullanılarak tahmin edilmiştir. Daha sonra alınan veriler doğrultusunda model performans değerlendirilmesi yapılmıştır.




Şekil 9. Model işlem adımları ile ilgili akış şeması

2001-2002 verilerine dayalı olarak YSA modeli ile 2003 yılı günlük rüzgâr şiddeti tahmini sonuçları Şekli 11’de sunulmaktadır.


- **Yapay Sinir Ağı grafikleri;**




Şekil 10. (a) YSA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yıllık)




Şekil 11. (b) YSA yöntemiyle gözlem ve model verileri ilişkisi (yıllık)




Şekil 12. (a) YSA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (kış mevsimi)



Şekil 13. (b) YSA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (İlkbahar mevsimi)



Şekil 14. (c) YSA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yaz mevsimi)




Şekil 15. (d) YSA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (sonbahar mevsimi)

Şekil 12-15: Rüzgâr şiddeti ve YSA model sonuçları a) Kış, b) İlkbahar, c) Yaz, d) Sonbahar (Mavi, gözlenen rüzgâr şiddeti, turuncu, model sonucu)


Kış mevsimi için gözlenen ve YSA yöntemine dayalı tahmin edilen rüzgâr şiddeti arasındaki ilişki katsayısı $R=0,83$ olarak saptanmıştır. İlkbahar, yaz ve sonbahar mevsimlerinde bu değerler sırası ile, 0,79; 0,74 ve 0,79 olarak hesaplanmıştır. Model başarı performansı kış mevsimi için diğer mevsimlere göre daha yüksektir, (Çizelge 6)

Çizelge 6. Mevsimsel model uygulaması hata oranları

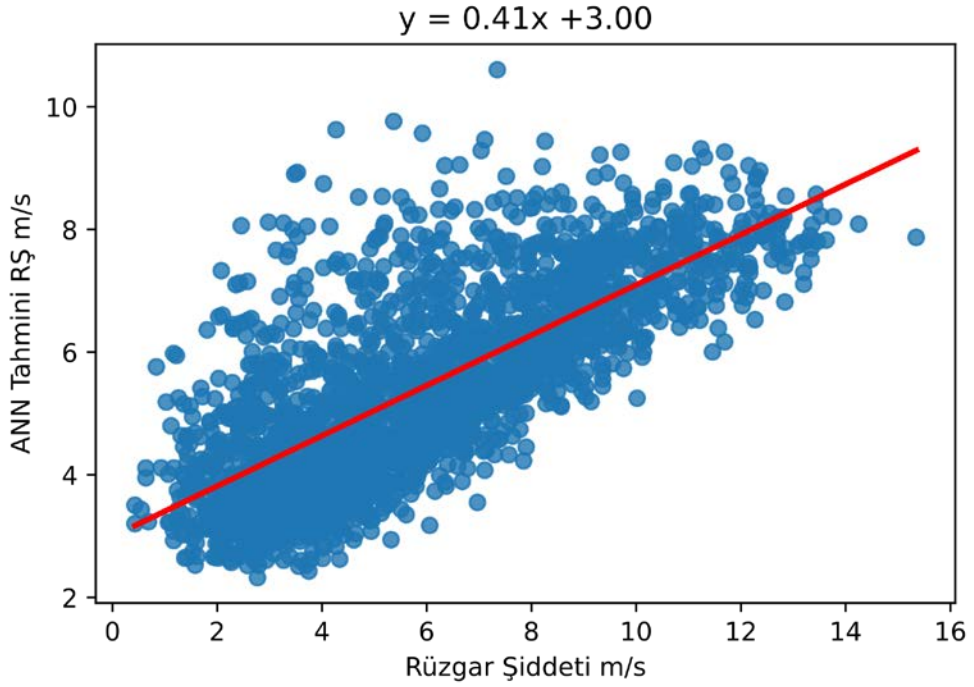
Yapay Sinir Ağları	KIŞ	İLKBAHAR	YAZ	SONBAHAR	YILLIK
R	0.83	0.79	0.74	0.79	0.79
R ²	0.69	0.62	0.54	0.62	0.63
MSE	5.15	4.43	4.24	4.49	4.52
RMSE	2.27	2.10	2.05	2.11	2.12




Şekil 16. (a) YSA yöntemiyle gözlem ve model verileri ilişkisi (kış mevsimi)



Şekil 17.. (b) YSA yöntemiyle gözlem ve model verileri ilişkisi (İlkbahar mevsimi)



Şekil 18. (c) YSA yöntemiyle gözlem ve model verileri ilişkisi (yaz mevsimi)




Şekil 19. (d) YSA yöntemiyle gözlem ve model verileri ilişkisi (sonbahar mevsimi)

Şekil 16-19: Rüzgâr şiddeti ve YSA model sonuçları a) Kış, b) ilkbahar, c) Yaz, d) Sonbahar (Saçılma grafiği mevsimsel değişim).


Gözlemlere Dayalı Tahmin aşamasında, Şekil 3.6, araştırmada göz önüne alınan 2003 yılı için YSA model sonuçları ve gözlem verilerinin ilişkisini göstermektedir. Bu grafikler bize, YSA modelinin rüzgâr şiddetini $\alpha=0,001$ güven seviyesinde tahmin ettiğini göstermektedir. Çalışmada oluşturulan YSA modelleri temel alınarak rüzgâr türbini deęişintileri için erken uyarı sistemleri oluşturulabilir. Bu araştırmadan elde edilen bilgilerin, Çanakkale'nin Baba Burnu bölgesindeki rüzgâr türbinlerinin enerji verimliliğinin yanı sıra gelecekteki türbinlerin kurulum ve işletme aşamalarında da yararlı olması beklenmektedir. YSA modellerinin dağılım grafikleri ve zaman grafikleri yıllık (a) ve (b) de sunulmaktadır. Tablo 3.1, 3.2 ve 3.3 inceleme bölgesi rüzgâr şiddeti deęerlerinin istatistiksel büyüklüklerini göstermektedir. En yüksek ve en düşük rüzgâr şiddeti deęerleri sırası ile 8,22 ve 4.56m/s olarak, sırası ile, 2001 yılı Aralık ve Eylül aylarında kaydedilmiştir.

C. KA ile rüzgâr şiddeti tahmini


- Karar Ağacı tahmin grafikleri:




Şekil 20. (a) KA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yıllık)




Şekil 21. (b) KA yöntemiyle gözlem ve model verileri ilişkisi (yıllık)




Şekil 22. (a) KA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (kış mevsimi)



Şekil 23. (b) KA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (ilkbahar mevsimi)



Şekil 24. (c) KA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yaz mevsimi)



Şekil 25. (d) KA modeliyle gözlem-tahmin değerlerinin zamansal değişimi (sonbahar mevsimi)


Şekil 22-25: Rüzgâr şiddeti ve KA model sonuçları a) Kış, b) İlkbahar, c) Yaz, d) Sonbahar (Mavi, gözlenen rüzgâr şiddeti, turuncu ise model sonucunu belirtmektedir)

Kış mevsimi için gözlenen ve KA yöntemine dayalı tahmin edilen rüzgâr şiddeti arasındaki ilişki katsayısı $R=0,81$ olarak saptanmıştır. İlkbahar, yaz ve sonbahar mevsimlerinde bu değerler sırası ile, 0,78; 0,73 ve 0,79 olarak


hesaplanmıştır. Model başarı performansı kış mevsimi için diğer mevsimlere göre daha yüksektir. (Çizelge 7)

Çizelge 7. Mevsimsel model uygulaması hata oranları


Karar Ağacı	KIŞ	İLKBAHAR	YAZ	SONBAHAR	YILLIK
R	0.81	0.78	0.73	0.79	0.78
R ²	0.67	0.61	0.54	0.63	0.61
MSE	5.16	4.21	3.75	3.71	4.08
RMSE	2.27	2.05	1.93	1.92	2.02




Şekil 26. KA yöntemiyle gözlem ve model verileri ilişkisi (kış mevsimi)



Şekil 27. (b) KA yöntemiyle gözlem ve model verileri ilişkisi (ilkbahar mevsimi)



Şekil 28. (c) KA yöntemiyle gözlem ve model verileri ilişkisi (yaz mevsimi)




Şekil 29.. (d) KA yöntemiyle gözlem ve model verileri ilişkisi (sonbahar mevsimi)


Şekil 26-29: Rüzgâr şiddeti ve KA model sonuçları a) Kış, b) İlkbahar, c) Yaz, d) Sonbahar (Saçılma grafiği **mevsimsel değişim**)

D. RO ile rüzgâr şiddeti tahmini


- **Rastgele Orman tahmin grafikleri:**




Şekil 30. (a) RO modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yıllık)




Şekil 31. (b)RO yöntemiyle gözlem ve model verileri ilişkisi (yıllık)




Şekil 32. (a) RO modeliyle gözlem-tahmin değerlerinin zamansal değişimi (kış mevsimi)



Şekil 33. (b)RO modeliyle gözlem-tahmin değerlerinin zamansal değişimi (ilkbahar mevsimi)



Şekil 34. (c) RO modeliyle gözlem-tahmin değerlerinin zamansal değişimi (yaz mevsimi)



Şekil 35. (d) RO modeliyle gözlem-tahmin değerlerinin zamansal değişimi (sonbahar mevsimi)


Model sonuçlarının ekstrem (min, maks) dönemler dışında daha başarılı olduğu söylenebilir.

Şekil 32-35: Rüzgâr şiddeti ve RO model sonuçları a) Kış, b) İlkbahar, c) Yaz, d) Sonbahar (Mavi, gözlenen rüzgâr şiddeti, turuncu, model sonucu)


Kış mevsimi için gözlenen ve RO yöntemine dayalı tahmin edilen rüzgâr şiddeti arasındaki ilişki katsayısı $R=0,78$ olarak saptanmıştır. İlkbahar, yaz ve sonbahar mevsimlerinde bu değerler sırası ile, 0,74; 0,71 ve 0,76 olarak hesaplanmıştır. Model başarı performansı kış mevsimi için diğer mevsimlere göre daha yüksektir. (Çizelge 8)

Çizelge 8. Mevsimsel model uygulaması hata oranları


Rastgele Orman	KIŞ	İLKBAHAR	YAZ	SONBAHAR	YILLIK
R	0.78	0.74	0.71	0.76	0.76
R ²	0.61	0.56	0.50	0.59	0.58
MSE	5.69	4.65	4.12	4.45	4.56
RMSE	2.38	2.15	2.03	2.11	2.13




Şekil 36. (a) RO yöntemiyle gözlem ve model verileri ilişkisi (kış mevsimi)



Şekil 37. (b) RO yöntemiyle gözlem ve model verileri ilişkisi (ilkbahar mevsimi)



Şekil 38. (c) RO yöntemiyle gözlem ve model verileri ilişkisi (yaz mevsimi)




Şekil 39. (d) RO yöntemiyle gözlem ve model verileri ilişkisi (sonbahar mevsimi)

Şekil 36-39: Rüzgâr şiddeti ve RO model sonuçları a) Kış, b) İlkbahar, c) Yaz, d) Sonbahar (Saçılma grafiği **mevsimsel değişim**).


Çizelge 9. Modellerin hata değerleri

Yıllık Tablo Model	RMSE	MSE	R^2	R
ANN	2.12	4.52	0.63	0.79
DT	2.02	4.08	0.61	0.78
RF	2.13	4.56	0.58	0.76

Genel olarak, her üç yöntemin yıllık tahmin başarı performansı Tablo (No3.7) de sunulmaktadır.



Şekil 40. Gözlenen ve tahmin edilen rüzgâr şiddeti ilişkisi, korelasyon kat sayısını çubukları.



Şekil 41. ROC diyagramı , burada mavi YSA, yeşil KA, sarı RO olarak tanımlanıyor.

Tablo 6, 7 ve 8'e göre, her üç yöntemin başarı performansı karşılaştırıldığında, genel olarak en yüksek başarı gösteren model sıralaması YAPAY SINIR AĞLARI, KARAR AĞACI ve RASTGELE ORMAN, şeklinde sıralanabilir.

Mevsimsel analizler karşılaştırıldığında, YSA; kış, ilkbahar ve yaz mevsimlerinde KA ve RO yöntemlerine göre daha başarılı sonuçlar vermiştir. Sonbahar mevsiminde YSA ve KA yöntemlerinin başarı performansları yaklaşık olarak aynıdır. Sonuç olarak, YSA yönteminin inceleme bölgesi için rüzgâr şiddetinin zamansal tahmininde güvenle kullanılabileceği vurgulanmaktadır.

V.SONUÇ VE ÖNERİLER

Bu tez çalışmasında Baba Burnu ve civarı için saatlik rüzgâr şiddeti değerlerinin tahmininde YSA, KA ve RO yöntemlerinin uygulanmasına yer verilmiştir. Model bulguları ile gözlem verileri karşılaştırılmış, hata analizleri, modellerin farklı mevsimlerdeki başarı performansları irdelenmiştir.

Bu tez çalışmasında inceleme bölgesinde otomatik istasyonda birer dakika aralıkla ölçülen rüzgâr şiddeti değerlerinin saatlik ortalama $V(m/s)$ değerlerinin tahmini için üç ayrı model uygulanmıştır.

Model uygulamasında bir saat boyunca ölçülen rüzgâr şiddeti değerlerinin standart sapması (sd, m/s) ve bir saat boyunca ölçülen ortalama rüzgâr yönü (derece) değerleri modelin girdi verileri olarak göz önüne alınmıştır. Model çıktısı olarak, $V(m/s)$ saatlik ortalama rüzgâr şiddetinin tahminine çalışılmıştır. Dolayısı ile bu uygulamada, modele standart sapma ve yön değerlerinin katılması, özellikle enerji potansiyeli hesabına yönelik olarak, rüzgâr şiddetinin bölgesel değişimi, türbülanslı yapısı da hesaplamalara katılmış olmaktadır. Bu uygulama ile modelin başarısı yükseltilmiş olmaktadır.

Yenilenebilir enerji kaynakları tüm dünya ülkelerinde iklim değişimi uyum çalışmaları açısından büyük önem taşımaktadır. Yenilenebilir enerji kaynaklarının başında gelen güneş ve rüzgâr enerjisi projelerinin uygulanması için en ideal bölgenin saptanması enerji verimliliği ön çalışmaları arasında yer almaktadır. Yeni enerji kaynaklarının kullanımı ile, iklim emisyon senaryolarının güneş ve rüzgâr enerjisi kurulu güç sistemleri ile birlikte değerlendirilmesi, iklim değişimi çalışmalarına önemli katkı sağlamaktadır. Bölgesel iklim senaryolarında tahminler iki döneme odaklanmaktadır: (i) yakın gelecek (2021–2040) ve yüzyıl ortası geleceği (2041–2060). Yeni enerji kaynaklarının kullanımının yaygınlaştırılması ile emisyon senaryolarında geri dönüşümün ortalama %2 oranında olması beklenmektedir, (Sawadogo ve ark., 2021). Ek olarak yenilenebilir enerji potansiyeli değerlendirmesi için yüksek zamansal çözünürlüklü (saatlik) model çıktıları gereklidir. Bu amaçla, güneş ve rüzgârla

ilgili deęişkenler için önemli olan farklı parametrelerin günlük deęişimlerinin göz önüne alınması gerekir. Böylece örneğin güneş enerjisi kaynağına dayalı, güneş ve rüzgâr enerji potansiyelinin daha doğru tahmini mümkün olmaktadır. Yenilenebilir enerji kaynaklarının planlamasını için daha gelişmiş bilgi üretmek ve iklim deęişimine uyum stratejileri oluşturmalarına yardımcı olmak için gelecek çalışmalarda bu model belirsizliklerinin azaltılması gerekmektedir. Bu tez çalışmasına üç ayrı modele göre (YSA, KA ve RO), günlük ortalama rüzgâr şiddeti deęerlerinin deęişimi tahmin edilmiş, modellerden elde edilen bulguların hataları ve model başarıları karşılaştırılmıştır.

Bu araştırma çalışması sonucunda, YSA model çıktıları ile gözlenen rüzgâr şiddeti deęerleri arasındaki ilişki katsayısının %91 olduğu saptanmıştır. Modelin başarısı irdelenmiş olup, 10 m yükseklikte rüzgâr şiddeti tahmini ile ilgili, kare kök ortalama hata (RMSE) 2,12 m/s ve ortalama kare hatası (MSE) 4,12 m/s, olarak hesaplanmıştır. Günlük ortalama rüzgâr şiddeti deęerlerinin tahmininde her üç yöntemin başarı oranları karşılaştırıldığında, genel olarak en yüksek başarı gösteren model sıralaması Yapay Sinir Ağları, Karar Ağaçları ve Rastgele Orman Yöntemleri şeklinde sıralanabilir.

Mevsimsel analizler karşılaştırıldığında, YSA yöntemi ile; kış, ilkbahar ve yaz mevsimlerinde KA ve RO yöntemlerine göre rüzgâr şiddeti deęerlerinde daha başarılı sonuçlar elde edilmiştir. Sonbahar mevsiminde YSA ve KA yöntemlerinin günlük ortalama rüzgâr şiddeti tahminlerindeki başarı performansları yaklaşık olarak aynıdır. Sonuç olarak, YSA yönteminin inceleme bölgesi için rüzgâr şiddetinin zamansal tahmininde %1 anlamlılık seviyesinde güvenle kullanılabileceęi vurgulanmaktadır.

Bu alandaki son araştırma çalışmalarında genel olarak, meteorolojik verileri tahmin etmek için yapay sinir aęı (YSA) modellerini kullanmaktır. Meteorolojik verileri tahmin etmek için çok katmanlı algılayıcı (MLP) ve radyal temel işlevli (RBF) yapay sinir aęı modelleri kullanılır. Modellerin performansını doğrulamak için, deęişkenlerin saatlik ve aylık tahminleri, meteoroloji istasyonları tarafından kaydedilen gözlemler çoklu lineer regresyon modeli ile elde edilen sonuçlarla karşılaştırılmıştır. MLP ve RBF, tüm vakaların tahminleri için %91-96 doğruluk vermiştir. Ayrıca tahminler, 0.61 ile 0.94 arasında deęişen, kaydedilen gözlem verileri ile model bulguları arasında yüksek bir lineer korelasyon olduğunu

göstermiştir. Bu araştırma, Hindistan'da bulunan iki meteoroloji istasyonundaki uygulamalarla ilgilidir, (Rajendra, Murthy, Subbarao, Boadh. 2019). Bu araştırma sonuçlarına göre ilişki katsayılarının değişim aralığı, bu tez çalışmasındaki KA ve RO bulguları ile örtüşmektedir. Tezdeki YSA modelinin bulguları ile gözlem verilerinin karşılaştırılması, YSA performansının günlük ortalama rüzgâr şiddeti değerlerinin tahmininde daha başarılı olduğunu göstermektedir.

Akıllı enerji sistemlerinde arz ve talebi dengeleme zorluklarını azaltmak için rüzgâr enerjisi üretiminin daha hassas tahmini çok önemlidir. Bununla birlikte, rüzgâr enerjisi modelleme çalışmalarında karşılaşılan en önemli sorun, tahmin çalışmalarını zorlaştıran yüksek çalkantıların bulunmasıdır. Bu araştırma, rüzgâr enerjisi üretimini doğru bir şekilde tahmin etmek için verimli veriye dayalı modeller geliştirmeyi amaçlamaktadır. En önemlisi, bu çalışmanın ana katkıları aşağıdaki gibi listelenmiştir. Spesifik olarak, Gauss süreç regresyonunun (GPR), farklı çekirdeklerle Destek Vektör Regresyonunun (SVR) hiper parametrelerini en iyi şekilde ayarlamak için Bayes optimizasyonunu (BO) kullanılmıştır. Topluluk öğrenme (ES) modelleri. Ve tahmin performansı üzerinde durulmaktadır. İkinci olarak, dinamik bilgiler, tahmin performansını daha da iyileştirmek için incelenen modellere dahil edilmektedir. Spesifik olarak, dikkate alınan modellerin tasarımında zaman değişiminin hesaplanması hedeflenmektedir. . Ayrıca, rüzgâr şiddeti tahmininde model performansını daha da iyileştirmek için daha fazla girdi değişkeni (örneğin, rüzgâr şiddeti ve rüzgâr yönü) birlikte kullanılır. Fransa, Türkiye ve Kaggle'daki üç rüzgâr türbininden alınan gerçek ölçümler, göz önüne alınan modellerin verimliliğini doğrulamak için kullanılmıştır. Sonuçlar, rüzgâr gücünü daha iyi tahmin etmek için girdi değişkenlerinin artırılmasının faydasını göstermektedir. Sonuçlara göre, ayrıca optimize edilmiş GPR ve topluluk modellerinin diğer makine öğrenimi modellerinden daha iyi performans sağlamaktadır, (Aleksileri , Harrou , Sun 2022)

Rüzgâr endüstrisinde, rüzgâr çiftliğinde güç tahmini için genellikle düşük maliyetli analitik modeller uygulanır. Ancak oldukça türbülanslı yapıda, modellerin başarı performansını düşmektedir. Bu çalışmada, rüzgâr santrallerinin güç tahminini iyileştirmek için makine öğrenmesine dayalı yeni bir izleme modeli

geliştirilmiştir. Sunulan model ile iyi bir hesaplama simülasyonları ile orantılı olarak türbin raylarındaki rüzgâr şiddeti ve türbülans yapısı yeniden oluşturulabilmektedir. Büyük CFD simülasyon veri kümesi tarafından yönlendirilen girişler ve izleme akışları arasındaki ilişki, geri yayılım algoritmasına dayalı Yapay Sinir Ağları (YSA) tekniği kullanılarak oluşturulmuştur. Azaltılmış sıralı yöntem Döner Aktüatör Disk Modeli (ADM-R) ve değiştirilmiş $k-\epsilon$ türbülans modeli, izleme akışlarının büyük verilerini oluştururken hesaplama maliyetlerinden önemli ölçüde tasarruf etmek için RANS simülasyonlarına uygulanmıştır. ANN izleme modeli, Horn Rev rüzgâr çiftliğinde kurulmuştur ve LES, yerinde ölçüm ve analitik izleme modellerine göre bulgular karşılaştırılmıştır. Sonuçlar, ANN modelinin mevcut analitik modellere kıyasla güç tahminlerini önemli ölçüde iyileştirebileceğini ve LES ve ölçüm verileriyle iyi bir şekilde eşleşebileceğini göstermektedir. Doğrulanmış model, rüzgâr çiftliklerinin güç üretimi üzerindeki rüzgar yönü ve türbin yerleşiminin etkisini araştırmak için de uygulanabilmektedir, (Deng, Zhang, Energy 2021)

Rüzgârın türbülanslı yapısı, parametrelerinden birinin doğru bir şekilde tahmin edilmesi, sağlam ve güvenilir bir model gerektirdiğinden, uygulamayı zorlaştırmaktadır. Bu araştırma çalışmasında doğru tahmin sonuçları gerektiren çok hassas rüzgâr enerjisi üretimi için rüzgâr şiddetinin tahmini üzerinde durulmaktadır. Rüzgâr şiddeti tahmin çalışmalarında Tekrarlayan Sinir Ağı (RNN) modellerinin, Fast Fourier Dönüşüm Filtresi ve Encoder-Decoder-LSTM modeline (FFT-Encoder-Decoder-LSTM) dayalı bir saatlik rüzgâr şiddeti tahmin modeli önerilmektedir. Verideki gürültü terimlerini giderme işlemi için FFT Filtresi kullanılmıştır. Maks-Min normalizasyon yöntemi, verileri standartlaştırmak için uygulanmıştır ve son olarak rüzgar şiddeti tahmini için Encoder-Decoder-LSTM modeli kullanılmıştır. Karşılaştırmalı model olarak geleneksel MPL, Single-layer-LSTM, Encoder-Decoder-LSTM, FFT-MLP ve FFT-Single Layer LSTM modelleri kullanılmıştır. FFT-EncoderDecoder-LSTM'nin en iyi ve daha tutarlı sonuçlar verdiği, 1 – 3 saate kadar rüzgâr şiddeti tahmini için başarılı olduğu vurgulanmaktadır, (Khoulood, Salim, Saber 2021)

Rüzgâr şiddeti tahmin modelleri ve bunların rüzgâr çiftliği operasyonlarına uygulanması, temiz bir enerji kaynağı olarak faydaları nedeniyle literatürde önemli yer almaktadır. Bu araştırmada rüzgâr şiddeti değişikliklerini tahmin

etmek için rastgele orman regresyonu adı verilen bir zaman serisi makine öğrenme yaklaşımı önerilmektedir. Hesaplanan karşılıklı bilgi ve otomatik korelasyon değerleri, rüzgâr şiddetinin değerlerinin 12 saate kadar tahminlerde geçmiş verilere büyük ölçüde bağlı olduğunu göstermektedir. Rastgele orman modeli, her bir değer için girdi olarak önceki 12 saatlik rüzgâr şiddeti değerleri ile iki haftalık veri topluluğu eğitime tabi tutulmuştur. Hesaplanan ortalama karekök hatası, iki haftalık verilerle eğitilen modelin güvenilir kısa vadeli tahminler yapmak için kullanılabileceğini göstermektedir, (Drisyaa, Asokanb , Kumara 2017).

Yenilenebilir enerji kaynaklarının kullanımının son yıllarda enerji sektöründeki stratejileri değiştirdiği kanıtlanmıştır. Rüzgâr enerji potansiyelinin dünya genelinde yaygın oluşu, çevre dostu yapısı iklim değişikliği çalışmaları açısından büyük önem taşımaktadır. Rüzgâr enerjisinin depolanması, aktarılması zordur. Çevre dostu yenilenebilir enerji kaynaklarından yararlanma çalışmaları daha da önem kazanmaktadır. Makine öğrenimi yaklaşımları, tahmin çalışmalarında yaygın olarak kullanılmaktadır. Bu çalışmada, öngörücü etkinliğe sahip olması için denetimsiz bir makine öğrenmesi algoritması olarak rastgele orman seçilmiştir. Eğitim amacıyla Sayısal Hava Tahmini (NWP) modeline dayalı veriler girdi olarak göz önüne alınmış, modelin kriterlerine göre işleme tabi tutuldu. Eğitim sonrasında tahmin sonuçlarının hatası, Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Hata (MAE) ile değerlendirilmiştir. RMSE ve MAE, rastgele ormanın yönteminin tahmin çalışmalarında yüksek doğruluk göstermiştir. Önerilen model ayrıca güneş, biyokütle ve hidroelektrik gibi diğer geleneksel olmayan kaynaklar için de kullanılabilir. (Jahangir ve Babbar, 2020).

İklim olayları ve etkileri mevsimlere göre değişiklik gösterdiğinden, rüzgâr enerjisi tahmin çalışmalarına daha güvenilir bilgiler sağlamak için modellerin mevsimsel olarak ve aylık olarak uygulanması ve karşılaştırılması daha yararlı olmaktadır. Bu tez çalışmasında oluşturulan YSA modellerinden yola çıkarak rüzgâr enerji sistemlerine ek olarak, kuvvetli rüzgâr şiddeti olasılığı ve değişimleri için erken uyarı sistemleri kurulabilir. Bu çalışmanın sonuçlarının, kurulum ve işletme aşamasında Çanakkale İlçesi ve çevresinde kurulu rüzgâr enerjisi sistemlerinin yanı sıra gelecekte oluşturulacak yeni rüzgâr enerjisi sistemlerin yer seçim ve kurulum projelerine katkı sağlaması beklenmektedir.

Yenilenebilir enerji, örneğin yenilenebilir kaynaklar nedeniyle dünyada giderek daha popüler hale geliyor. Güneş, jeotermal, rüzgâr enerjisi gibi temiz, tükenmez ve doğal kaynaklardan gelir. Rüzgâr Yenilenebilir enerji kaynaklarının en önemlilerinden biri olan enerji ve elektrik üretimi. Bu nedenle, zorlukların üstesinden gelmek için doğru rüzgâr enerjisi tahmini çok önemlidir. Enerji ticareti, planlama, çizelgeleme kararları ve rüzgâr enerjisi üretim stratejilerinin dengelenmesi. Bu çalışma, yenilenebilir enerji sektöründe gerçek hayattaki bir sorunu çözmek için bir tahmin modeli önermektedir.

Önümüzdeki 24 saat içinde saat başına rüzgar enerjisi üretim miktarını doğru bir şekilde tahmin ederek geçmiş rüzgar enerjisi üretim verilerini kullanarak makine öğrenimi (ML) tekniklerini uygulamak ve hava Durumu. Önerilen yaklaşımda, ilk olarak, denetimsiz bir ML yöntemi (yani, K-Means kümeleme algoritması), verileri anlamlı kümeler halinde gruplamak için uygulanır; o zaman bu setler yeni özellik değerleri olarak ele alınır ve onu büyütme için veri kümesine eklenir; Son olarak, denetimli bir makine öğrenimi tahmin için yöntem (yani regresyon) gerçekleştirilir. Bu çalışma, dokuz denetimli öğrenmeyi karşılaştırır algoritmalar: K-En Yakın Komşular, Destek Vektör Regresyonu, Rastgele Orman, Ekstra Ağaçlar, Gradyan Artış, Ridge Regresyon, En Küçük Mutlak Büzülme ve Seçim Operatörü, Karar Ağacı ve Evrişimsel Sinir Ağı. Bu çalışmanın amacı, farklı MO'ların başarısını araştırmaktır. Rüzgâr enerjisi üretimi için en doğru nihai modeli seçmek için makine öğrenimi algoritmaları tahmini, rüzgâr türbinlerinin gerçek dünya verileri üzerinde algoritmalar ve çeşitli karşılaştırmalar için bir metodoloji önermektedir. (D.Yürek 2021)

Enerji tahmin modelleri, binalarda gelişmiş kontrol ve optimizasyon için bir performans değerlendirme motoru olarak ve iyileştirilmiş enerji verimliliği için bilinçli kararlar vermek üzere tesis yöneticileri ve kamu hizmetleri tarafından kullanılır. Basitleştirilmiş ve veriye dayalı modeller, ayrıntılı simülasyon için ilgili bilgilerin bulunmadığı ve hızlı yanıtların gerekli olduğu durumlarda genellikle tercih edilen seçenektir. Madrid'deki bir otelin saatlik HVAC enerji tüketimini tahmin etmek için yaygın olarak kullanılan bir ileri beslemeli geri yayımlı yapay sinir ağının (YSA) performansını, tahminde popülerlik kazanan topluluğa dayalı bir yöntem olan rastgele orman (RO) ile karşılaştırılmıştır.

İspanya. Misafir sayısı gibi sosyal parametreleri dahil etmek, her iki durumda da tahmin doğruluğunu marjinal olarak iyileştirdi. Genel olarak, YSA, sırasıyla 4.97 ve 6.10'luk ortalama karekök hatası (RMSE) ile RO'den marjinal olarak daha iyi performans gösterdi. Bununla birlikte, kategorik değişkenlerle ayarlama ve modelleme kolaylığı, topluluk tabanlı algoritmalara, binalara özgü çok boyutlu karmaşık verilerle başa çıkmak için bir avantaj sağlar. RO, dahili çapraz doğrulama gerçekleştirir (yani, torbadan çıkan numuneleri kullanarak) ve yalnızca birkaç ayar parametresine sahiptir. Her iki model de karşılaştırılabilir tahmin gücüne sahiptir ve bina enerji uygulamalarına neredeyse eşit derecede uygulanabilir. Y. Rezgui, (2017).

Makine öğrenimi (ML) modelleri, verimli içten yanmalı motorların geliştirilmesini hızlandırabilir. Bu çalışma, sınırlı sayıda deneye dayalı olarak doğal gaz (NG) kıvılcım ateşlemeli (SI) modifiye bir dizel motorun performansını tahmin etmek için veriye dayalı yöntemlerin uygulanabilirliğini değerlendirdi. En iyi ML tekniği önceden seçilemediğinden, böyle bir motor uygulaması için farklı ML algoritmalarının uygulanabilirliği değerlendirildi. Spesifik olarak, yaygın olarak kullanılan iki ML algoritmasının, rastgele orman (RO) ve yapay sinir ağının (YSA), silindir içi yanma olayıyla ilgili motor tepkilerini tahmin etmedeki performansı karşılaştırılmıştır. Sonuçlar, model girdileri olarak kıvılcım zamanlaması (ST), karışım eşdeğerlik oranı ve motor hızına sahip her iki algoritmanın da motor performansını, yanma fazını ve motor çıkış emisyonlarını tahmin etme açısından kabul edilebilir sonuçlar verdiğini göstermiştir. Hiperparametre optimizasyonunda daha fazla çaba gerektirmesine rağmen, ANN modeli, daha büyük R-kare, daha küçük kök-ortalama-kare hataları (RMSE) ve etkilerin daha gerçekçi tahminleriyle kanıtlandığı gibi, özellikle motor emisyonları için RO modelinden daha iyi performans gösterdi. Bununla birlikte, yanma davranışı bilgisinin sınırlı olduğu uygulamalarda, uygun sayıda model girişinin hızlı bir şekilde belirlenmesi için bir RO modelinin kullanılması tavsiye edilir. Sonuç olarak, model yapısını tanımlamak için RO modelini kullanmak ve ardından modelin tahmin yeteneğini geliştirmek için ANN modelini kullanmak, veriye dayalı motor yanma modellerinin hızla oluşturulmasına yardımcı olabilir. J. Liu (2022)

A. Teşekkür

Tez çalışmamda planlanmasında, araştırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteğini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren sayın hocam Prof. Dr. Zafer ASLAN'A sonsuz teşekkürlerimi sunarım. Bilgisayar Mühendisliği Anabilim Dalı Başkanı Prof. Dr. Ali GÜNEŞ ve İstanbul İstinye Üniversitesi, Dr. Öğretim Üyesi Ali HAMİTOĞLUN'a desteklerinden dolayı teşekkürü borç bilirim. Veri desteği ile ilgili olarak İTÜ Öğretim Üyesi Prof. Dr. Sibel MENTEŞ'E, veri işlem aşamasındaki desteklerinden dolayı Y. Müh. Uğur AKBULUT'a teşekkürü borç bilirim Projenin yazılımındaki desteği için arkadaşım Efecan KUTLUK'a teşekkürlerimi sunarım.

VI. KAYNAKÇA

MAKALELER

- AK, R., VİTELLİ, V. VE ZİO, E. (2015). An Interval-Valued Neural Network Approach for Uncertainty Quantification in Short-Term Wind Speed Prediction. **IEEE Transactions on Neural Networks and Learning Systems**, 26(11). doi:10.1109/TNNLS.2015.2396933
- ÇALIŞKAN, M., ŞUBESİ, E.-Y. E. K. VE VEKİLİ, M. (2010). Türkiye rüzgar enerjisi potansiyeli. Devlet Meteoroloji İşleri Genel Müdürlüğü ve Türkiye Rüzgar Enerjisi Birliği (TÜREB)-**Rüzgar Enerjisi Semineri**.
- ÇELİK, U. (2017). Rapidminer ile veri madenciliği. Pusula.
- CHARBUTY, B. VE ABDULAZEEZ, A. (2021). Classification Based on Decision Tree Algorithm for Machine Learning. **Journal of Applied Science and Technology Trends**, 2(01). doi:10.38094/jastt20165
- ERDEMİR, G., AKİNCİ, T. C. VE ASLAN, Z. (2021). ANALYSES AND FORECASTING OF SOLAR ENERGY POTENTIAL BY USING ANN A CASE STUDY OF CENTRAL ANATOLIA-TURKEY. **Fresenius Environmental Bulletin**.
- FENG, C., CUI, M., HODGE, B. M. VE ZHANG, J. (2017). A data-driven multi-model methodology with deep feature selection for short-term wind forecasting. **Applied Energy**, 190. doi:10.1016/j.apenergy.2017.01.043
- FENG, J. (2019). Artificial Intelligence for Wind Energy (AI4Wind): **A state of the art report**.
- GAO, S., DONG, L., LIAO, X. VE GAO, Y. (2013). Very-short-term prediction of wind speed based on chaos phase space reconstruction and NWP. **Chinese Control Conference, CCC içinde** .

- HAYKİN, S. (1999). Neural networks: a comprehensive foundation by Simon Haykin. **The Knowledge Engineering Review**.
- İLKILIÇ, Z. (2016). Türkiye’de Rüzgar Enerjisi ve Rüzgar Enerji Sistemlerinin Gelişimi. **Batman Üniversitesi Yaşam Bilimleri Dergisi**, 6(2/2).
- LAHOUAR, A. VE BEN HADJ SLAMA, J. (2017). Hour-ahead wind power forecast based on random forests. **Renewable Energy**, 109. doi:10.1016/j.renene.2017.03.064
- LAWAN, S. M., ABİDİN, W. A. W. Z., CHAI, W. Y., BAHARUN, A. VE MASRİ, T. (2014). Different Models of Wind Speed Prediction; A Comprehensive Review. **International Journal of Scientific & Engineering Research**, 5(1).
- Lİ, G., SHİ, J. VE ZHOU, J. (2011). Bayesian adaptive combination of short-term wind speed forecasts from neural network models. **Renewable Energy**, 36(1). doi:10.1016/j.renene.2010.06.049
- MARUGÁN, A. P., MÁRQUEZ, F. P. G., PEREZ, J. M. P. VE RUIZ-HERNÁNDEZ, D. (2018). A survey of artificial neural network in wind energy systems. **Applied Energy**. doi:10.1016/j.apenergy.2018.07.084
- MOSS, L. (2010). The 13 largest oil spills in history. Mother Nature Network.
- NİU, D., PU, D. VE DAI, S. (2018). Ultra-short-term wind-power forecasting based on the weighted random forest optimized by the niche immune lion algorithm. **Energies**, 11(5). doi:10.3390/en11051098
- OLAH, G. A., GOEPPERT, A. VE PRAKASH, G. K. S. (2009). Chemical recycling of carbon dioxide to methanol and dimethyl ether: From greenhouse gas to renewable, environmentally carbon neutral fuels and synthetic hydrocarbons. **Journal of Organic Chemistry**. doi:10.1021/jo801260f
- PALOMARES-SALAS, J. C., AGÜERA-PÉREZ, A., GONZÁLEZ DE LA ROSA, J. J. VE MORENO-MUÑOZ, A. (2014). A novel neural network method for wind speed forecasting using exogenous measurements from agriculture stations. Measurement: **Journal of the**

PHILIPPOPOULOS, K. VE DELIGIORGI, D. (2012). Application of artificial neural networks for the spatial estimation of wind speed in a coastal region with complex topography. **Renewable Energy**, 38(1). doi:10.1016/j.renene.2011.07.007

POURMOUSAVI KANI, S. A. VE ARDEHALI, M. M. (2011). Very short-term wind speed prediction: A new artificial neural network-Markov chain model. **Energy Conversion and Management içinde** (C. 52). doi:10.1016/j.enconman.2010.07.053

Proceedings of the 9th IASTED International Conference on Power and Energy Systems, PES 2007. (2007). **Proceedings of the IASTED International Conference on Energy and Power Systems.**

QUAN, H., SRINIVASAN, D. VE KHOSRAVI, A. (2014). Short-term load and wind power forecasting using neural network-based prediction intervals. **IEEE Transactions on Neural Networks and Learning Systems**, 25(2). doi:10.1109/TNNLS.2013.2276053

ROBERTSON, C. VE KRAUSS, C. (2010). Gulf Spill Is the Largest of Its Kind, Scientist Say. **The New York Times.**

SAWADOGO, W., REBOITA, M. S., FAYE, A., DA ROCHA, R. P., ODOULAMI, R. C., OLUSEGUN, C. F., ... GIORGI, F. (2021). Current and future potential of solar and wind energy over Africa using the RegCM4 CORDEX-CORE ensemble. **Climate Dynamics**, 57(5–6). doi:10.1007/s00382-020-05377-1

SAZLI, M. H. (2006). A brief review of feed-forward neural networks. Communications, Faculty Of Science, **University of Ankara.** doi:10.1501/0003168

SHI, K., QIAO, Y., ZHAO, W., WANG, Q., LIU, M. VE LU, Z. (2018). An improved random forest model of short-term wind-power forecasting to enhance accuracy, efficiency, and robustness. **Wind Energy**, 21(12). doi:10.1002/we.2261

- TOLUN, S., MENTEŞ, S., ASLAN, Z. VE YÜKSELEN, M. A. (1995). The wind energy potential of Gökçeada in the Northern Aegean Sea. **Renewable Energy**, 6(7). doi:10.1016/0960-1481(95)00089-3
- TYRALİS, H. VE PAPACHARALAMPOUS, G. (2017). Variable selection in time series forecasting using random forests. **Algorithms**, 10(4). doi:10.3390/a10040114
- VASSALLO, D., KRİSHNAMURTHY, R. VE FERNANDO, H. (2021). Utilizing physics-based input features within a machine learning model to predict wind speed forecasting error. **Wind Energy Science**, 6(1). doi:10.5194/wes-6-295-2021
- YÜREK, Ö.E., BIRANT, D., YÜREK, İ. (2021). Wind Power Generation Prediction Using Machine Learning Algorithms. **DEUFMD**, 23(67), 107-119.
- M.W.AHMAD, M.MOURSHED, Y.REZGUİ. (2017). Trees vs Neurons:Comparison between random forest and ANN for hight-resolution prediction of building energy consumption.BRE Centre for Sustainable Engineering, School of Engineering, **Cardiff University, Cardiff CF24 3AA,United Kingdom.**
- J.LİU, Q.HUANG, C.ULİSHNEY,C.E.DUMİTRESCU (2022). Comparison of Random Forest and Neural Network in Modeling the Performance and Emissions of a Natural Gas Spark Ignition Engine.

ELEKTRONİK KAYNAKLAR

URL1-<https://www.tureb.com.tr/> (27.06.2022)

URL2- <https://enerji.gov.tr/eigm-yenilenebilir-enerji-kaynaklar-ruzgar>
(27.06.2022)

URL3- <https://temizenerji.org/2022/04/15/turkiyenin-ruzgar-kurulu-gucu-48-ildeki-santrallerle-yaklasik-11-bin-mwa-ulasti/> (15 Nisan 2022).

- URL4- <https://zenodo.org/record/3240040#.YrcFIHZByUk>, Menteş, S., T. Kaytancı, Y. Ezber, Assessment of surface wind from the long term production run over Turkey, (27.07.2022).
- URL5- <https://medium.com/@k.ulgen90/makine-%C3%B6%C4%9Frenimi-b%C3%B6l%C3%BCm-5-karar-a%C4%9Fa%C3%A7lar%C4%B1-c90bd7593010> – E. Kaan Ulgen (Nov 12, 2017)
- URL6- <https://miracozturk.com/python-ile-siniflandirma-analizleri-rastgele-orman-random-forest-algoritmasi/> - Miraç ÖZTÜRK (13 Nisan 2022)
- URL7 -TURKIYE-<https://repa.enerji.gov.tr/REPA/bolgeler/TURKIYE-GENELI.pdf>
- URL8-CANAKKALE-<https://repa.enerji.gov.tr/REPA/iller/CANAKKALE-REPA.pdf>

EKLER

Ek 1: Yapay Sinir Ağları tahmin modeliyle ilgili kodlar

Ek 2. Karar Ağacı tahmin modeliyle ilgili kodlar

Ek 3. Rastgele Orman tahmin modeliyle ilgili kodlar

Ek 1: Yapay Sinir Ağları tahmin modeliyle ilgili kodlar

```
In [ ]: # Tablo ve veri işlem kütüphaneleri
import pandas as pd
import numpy as np

In [ ]: # Veri ön işleme fonksiyonları
from preprocessor import *

In [ ]: # Düzenlenmiş ana veri
df = rafael_preprocess()

In [ ]: df.head(5)

In [ ]: # Parametreler
feature_names = ["s/d", "YÖN", "hour", "day", "month", "year"]

# Parametre kolonları
X_all = df[feature_names]
# Hedef kolon
y_all = df["10M Hız m/sn"]

# Test verisi satır sayısı
N_test = 365 * 24

# Eğitim ve test verilerinin ayrılması
X, y = X_all[:-N_test], y_all[:-N_test]
X_test, y_test = X_all[-N_test:], y_all[-N_test:]

In [ ]: # Doğrulama verileri satır sayısı
N_vld = 181 * 24

# Eğitim ve doğrulama verileri
X_train, y_train = X[:-N_vld], y[:-N_vld]
X_vld, y_vld = X[-N_vld:], y[-N_vld:]

In [ ]: # Hazır Derin Öğrenme kütüphaneleri
from tensorflow import keras
from tensorflow.keras import layers
from tensorflow.keras.callbacks import EarlyStopping
```

Ek 1: Yapay Sinir Ağları tahmin modeliyle ilgili kodlar (devam)

```
In [ ]: ▶ # ANN hiper-parametreleri

n_neurons = 512
n_layer_groups = 1
abbr_activation = "relu"
drop_ratio = 0.3

# Katman ayarları

lst_layers = [
    layers.BatchNormalization(),
    layers.Dense(n_neurons, activation=abbr_activation, input_shape=[len(feature_names)]),
    layers.Dropout(drop_ratio),
]

if n_layer_groups > 0:
    for i in range(n_layer_groups):
        lst_layers.append(layers.BatchNormalization())
        lst_layers.append(layers.Dense(n_neurons, activation=abbr_activation))
        lst_layers.append(layers.Dropout(drop_ratio))

# Çıkış katmanları
lst_layers.append(layers.BatchNormalization())
lst_layers.append(layers.Dense(1))

model = keras.Sequential([
    *lst_layers
])

In [ ]: ▶ # Modelin kurulması
model.compile(
    optimizer='adam',
    loss='mae',
    metrics=['mse', 'mape']
)
EPOCHS = 300
# batch: her turda kaç satır beslenecek
S_BATCH = 32

# Eğitim durdurucu (doğrulama değerleri belirli bir turdan sonra ilerleme göstermezse eğitim durdurulur)
stopper = EarlyStopping(min_delta=0.0001, patience=50, restore_best_weights=True)

# Modelin eğitilmesi
history = model.fit(
    X_train, y_train,
    validation_data=(X_vld, y_vld),
    # batch_size=S_BATCH,
    epochs=EPOCHS,
    verbose=1,
    callbacks=[stopper]
)
```

Ek 1: Yapay Sinir Ağları tahmin modeliyle ilgili kodlar (devam)

```
In [ ]: # Modelin Eğitim sonuçları
import matplotlib.pyplot as plt
df_history = pd.DataFrame(history.history)

plt.figure()
df_history.loc[:, ['loss', 'val_loss']].plot()
val_loss = format(df_history['val_loss'].min(), "0.4f")
# val_mae = format(history_df['val_mae'].min(), "0.4f")
val_mse = format(df_history['val_mse'].min(), "0.4f")
val_rmse = format(np.sqrt(df_history['val_mse'].min()), "0.4f")
val_mape = format(df_history['val_mape'].min(), "0.4f")

print(("val_loss: {val_loss}, val_mape: {val_mape}, val_rmse: {val_rmse}, val_mse: {val_mse}, neurons: {n_neurons}, batch_si

In [ ]: # Eğitim ve test veri satırlarının indexleri
train_idx = df.index <= "12/31/2002 23:00"
test_idx = df.index > "12/31/2002 23:00"

In [ ]: # Eğitim ve Test tahmin verileri
res_tr=model.predict(X)
res_ts=model.predict(X_test)

In [ ]: # Eğitim ve test tahmin verilerinin tabloya yerleştirilmesi
model_name = "ANN"
df.loc[train_idx, f"{model_name} Train Prediction"] = res_tr
df.loc[test_idx, f"{model_name} Test Prediction"] = res_ts

In [ ]: # Ortalama kare hata fonksiyonu
from sklearn.metrics import mean_squared_error

# Eğitim tahmin verileri alt-tablosu
dftr = df[df.index < "1/1/2003 00:00"]
dftr.loc[dftr.index, "Rüzgar Şiddeti m/s"] = dftr["10M Hız m/sn"]
dftr.loc[dftr.index, f"{model_name} Tahmini RŞ m/s"] = dftr[ f"{model_name} Train Prediction"]

# Test tahmin verileri alt-tablosu
dfst = df[df.index >= "1/1/2003 00:00"]
dfst.loc[dfst.index, "Rüzgar Şiddeti m/s"] = dfst["10M Hız m/sn"]
dfst.loc[dfst.index, f"{model_name} Tahmini RŞ m/s"] = dfst[ f"{model_name} Test Prediction"]

In [ ]: # Puanlama fonksiyonu
import score_metrics as sm

In [ ]: # yıllık sonuçlar
sm.write_year(dftr, dfst, model_name)

In [ ]: # mevsimsel sonuçlar
sm.write_seasonal(dftr, dfst, model_name)
```

Ek 2. Karar Ağacı tahmin modeliyle ilgili kodlar

```
In [ ]: # veri işleme kütüphaneleri
import pandas as pd
import numpy as np

In [ ]: # veri ön işleme fonksiyonları
from preprocessor import *

In [ ]: # düzenlenmiş verilerin tümü
df = rafael_preprocess()

In [ ]: df.head(5)

In [ ]: # parametreler
feature_names = ["s/d", "hour", "day", "month", "year"]

# Tüm veri - Parametreler
X_all = df[feature_names]
# Tüm veri - Hedef kolon
y_all = df["10M Hız m/sn"]

# 365 gün * 24 saat kadar test verisi ayırma (1 yıl)
N_test = 365 * 24
# Eğitim verileri
X, y = X_all[:-N_test], y_all[:-N_test]
# Test verileri
X_test, y_test = X_all[-N_test:], y_all[-N_test:]
```

```
In [ ]: # Eğitim verisi içerisinde doğrulama kısmı (0.25)
N_vld = 181 * 24

# Eğitim ve doğrulama verileri
X_train, y_train = X[:-N_vld], y[:-N_vld]
X_vld, y_vld = X[-N_vld:], y[-N_vld:]

In [ ]: # Karar Ağacı hazır kütüphanesi
from sklearn.tree import DecisionTreeRegressor
# Ortalama pozitif hata fonksiyonu
from sklearn.metrics import mean_absolute_error

# Karar ağacı deneme parametreleri
# Deneysel Max yaprak sayıları
candidate_max_leaf_nodes = [3, 9, 27, 81, 243, 324, 351, 378, 405, 432, 459, 486, 729, 2187, 6561, 19683, 59049, 177147, 531461]
# Deneysel max ağaç derinliği
candidate_max_levels = list(range(1,100))

def get_mae(max_leaf_nodes, train_X, val_X, train_y, val_y):
    model = DecisionTreeRegressor(max_leaf_nodes=max_leaf_nodes, random_state=0)
    model.fit(train_X, train_y)
    preds_val = model.predict(val_X)

    mae = mean_absolute_error(val_y, preds_val)
    return(mae)

def get_rsq(max_leaf_nodes, train_X, val_X, train_y, val_y):
    model = DecisionTreeRegressor(max_leaf_nodes=max_leaf_nodes, random_state=0)
    model.fit(train_X, train_y)
    preds_val = model.predict(val_X)
    return(model.score(val_X, val_y))

def get_score(max_level, train_X, val_X, train_y, val_y):
    model = DecisionTreeRegressor(max_depth=max_level, random_state=0)
    model.fit(train_X, train_y)
    preds_val = model.predict(val_X)
    return(model.score(val_X, val_y))
```

Ek 2. Karar Ağacı tahmin modeliyle ilgili kodlar

```
In [ ]: # Max yaprak sayısına göre deneme (mae)
bmae = float('inf')
bmn = float('inf')
for max_node in candidate_max_leaf_nodes:
    mae = get_mae(max_node, X_train, X_vld, y_train, y_vld)
    if mae < bmae:
        bmae = mae
        bmn = max_node

best_tree_size = bmn
print(f"Best tree size: {bmn}, mae: {bmae}")

In [ ]: # Max yaprak sayısına göre deneme (R^2)
br2 = 0
best_max_node = 0
for max_node in candidate_max_leaf_nodes:
    r2 = get_rsqr(max_node, X_train, X_vld, y_train, y_vld)
    if r2 > br2:
        best_max_node = max_node
        br2 = r2
    print(f"Tree size: {max_node}, R^2: {r2}")

best_tree_size = best_max_node
print(f"Best tree size: {best_max_node}, Best R^2: {br2}")

In [ ]: # Max derinliğe göre deneme
br2 = 0
best_max_level = 0
for max_level in candidate_max_levels:
    r2 = get_score(max_level, X_train, X_vld, y_train, y_vld)
    if r2 > br2:
        best_max_level = max_level
        br2 = r2
    print(f"Tree depth: {max_level}, R^2: {r2}")

best_tree_size = best_max_level
print(f"Best tree depth: {best_max_level}, Best R^2: {br2}")

In [ ]: # En iyi hiper-parametrelerle modelin oluşturulması
dt_model = DecisionTreeRegressor(max_depth=best_max_level, random_state=0)
dt_model.fit(X, y)

# Eğitim verileri ile tahmin
res_tr=dt_model.predict(X)
# Gözlem verileri ile tahmin
res_ts=dt_model.predict(X_test)

# Eğitim, Doğrulama ve Test tahmin skorları
print(f"Train score: {dt_model.score(X_train, y_train)}, Validation score: {dt_model.score(X_vld, y_vld)}, Test score: {dt_model.score(X_test, y_test)}")

In [ ]: # Eğitim ve test indexleri
train_idx = df.index <= "12/31/2002 23:00"
test_idx = df.index > "12/31/2002 23:00"

In [ ]: # Tahmin verilerinin tabloya yerleştirilmesi
df.loc[train_idx, "Decision Tree Train Prediction"] = res_tr
df.loc[test_idx, "Decision Tree Test Prediction"] = res_ts

In [ ]: # df.tail(5)

In [ ]: # Hazır ortalama kare hata fonksiyonu
from sklearn.metrics import mean_squared_error

# Eğitim tahmin verilerinin tabloya alınması
dftr = df[df.index < "1/1/2003 00:00"]
dftr.loc[dftr.index, "Rüzgar Siddeti m/s"] = dftr["10M Hız m/sn"]
dftr.loc[dftr.index, "Decision Tree Tahmini RŞ m/s"] = dftr["Decision Tree Train Prediction"]

# Test tahmin verileri
dfst = df[df.index >= "1/1/2003 00:00"]
dfst.loc[dfst.index, "Rüzgar Siddeti m/s"] = dfst["10M Hız m/sn"]
dfst.loc[dfst.index, "Decision Tree Tahmini RŞ m/s"] = dfst["Decision Tree Test Prediction"]

In [ ]: # puanlama fonksiyonu
import score_metrics as sm

In [ ]: # tahmin sonuçlarının yıllık çıktıları
sm.write_year(dftr, dfst, "Decision Tree")

In [ ]: # tahmin sonuçlarının mevsimsel çıktıları
sm.write_seasonal(dftr, dfst, "Decision Tree")
```

Ek 3. Rastgele Orman tahmin modeliyle ilgili kodlar

```
In [ ]: # veri işleme kütüphaneleri
import pandas as pd
import numpy as np

In [ ]: # veri ön işlem fonksiyonları
from preprocessor import *

In [ ]: # düzenlenmiş verilerin tamamı
df = rafael_preprocess()

In [ ]: df.head(5)

In [ ]: # Parametreler
feature_names = ["s/d", "hour", "day", "month", "year"]

# Parametre kolonları
X_all = df[feature_names]
# Hedef kolonlar
y_all = df["10M Hız m/sn"]

# Test verisi satır sayısı (1 yıllık)
N_test = 365 * 24

# Eğitim ve Test verilerinin ayrılması
X, y = X_all[:-N_test], y_all[:-N_test]
X_test, y_test = X_all[-N_test:], y_all[-N_test:]

In [ ]: # Doğrulama verileri satır sayısı (0.25)
N_vald = 181 * 24

# Eğitim ve doğrulama verilerinin ayrılması
X_train, y_train = X[:-N_vald], y[:-N_vald]
X_vald, y_vald = X[-N_vald:], y[-N_vald:]

In [ ]: # Hazır rastgele orman kütüphanesi
from sklearn.ensemble import RandomForestRegressor

def get_score(estimator_count, train_X, val_X, train_y, val_y):
    model = RandomForestRegressor(n_estimators=estimator_count)
    model.fit(train_X, train_y)
    preds_val = model.predict(val_X)
    return(model.score(val_X, val_y))
```

Ek 3. Rastgele Orman tahmin modeliyle ilgili kodlar

```
In [ ]: # Deneysel random forest max ağaç sayıları
candidate_max_trees = list(range(2,100))

br2 = 0
bec = 0
for n_est in candidate_max_trees:
    r2 = get_score(n_est, X_train, X_vld, y_train, y_vld)
    print(f"Validation score: {r2}")
    if r2 > br2:
        br2 = r2
        bec = n_est

print(f"Best validation score: {br2}, Best estimator count: {bec}")

In [ ]: # En iyi hiperparametrelerle modelin kurulması
dt_model = RandomForestRegressor(n_estimators=bec)
dt_model.fit(X, y)

# Eğitim tahmin verileri
res_tr=dt_model.predict(X)
# Test tahmin verileri
res_ts=dt_model.predict(X_test)

print(f"Train score: {dt_model.score(X_train, y_train)}, Validation score: {dt_model.score(X_vld, y_vld)}, Test score: {dt_model.score(X_test, y_test)}")

In [ ]: # Eğitim ve test tahminlerinin satır numaraları
train_idx = df.index <= "12/31/2002 23:00"
test_idx = df.index > "12/31/2002 23:00"

In [ ]: # Eğitim ve test tahminlerinin tabloya yerleştirilmesi
df.loc[train_idx, "Random Forest Train Prediction"] = res_tr
df.loc[test_idx, "Random Forest Test Prediction"] = res_ts

In [ ]: # Ortalama kare hata fonksiyonu
from sklearn.metrics import mean_squared_error

# Eğitim tahmin sonuçları alt tablosu
dftr = df[df.index < "1/1/2003 00:00"]
dftr.loc[dftr.index, "Rüzgar Şiddeti m/s"] = dftr["10M Hız m/sn"]
dftr.loc[dftr.index, "Random Forest Tahmini RŞ m/s"] = dftr["Random Forest Train Prediction"]

# Test tahmin sonuçları alt tablosu
dfst = df[df.index >= "1/1/2003 00:00"]
dfst.loc[dfst.index, "Rüzgar Şiddeti m/s"] = dfst["10M Hız m/sn"]
dfst.loc[dfst.index, "Random Forest Tahmini RŞ m/s"] = dfst["Random Forest Test Prediction"]

In [ ]: # Puanlama fonksiyonu
import score_metrics as sm
model_name = "Random Forest"

In [ ]: # Yıllık sonuçlar
sm.write_year(dftr, dfst, model_name)

In [ ]: # Mevsimlik sonuçlar
sm.write_seasonal(dftr, dfst, model_name)
```


ÖZGEÇMİŞ

Ad-Soyad : Rafael BEKİROV

Öğrenim Durumu

Yüksek Lisans: : İstanbul Aydın Üniversitesi
: Bilgisayar Mühendisliği 2016-2022

Lisans: : Azerbaycan Devlet Petrol Ve Sanayi Üniversitesi
Petrol Mühendisliği 2012-2016

Lise: : Özel Türk Liseyi
2007-20012