

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI

**RÜZGÂR HIZININ FARKLI YÖNTEMLERLE TAHMİNLENMESİ İLE
İLGİLİ ÖRNEK BİR UYGULAMA**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN : Muhammed Cihat ALTIN
DANIŞMAN : Doç. Dr. Rıdvan SARAÇOĞLU

VAN-2019

T.C.
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ
ANABİLİM DALI

**RÜZGÂR HIZININ FARKLI YÖNTEMLERLE TAHMİNLENMESİ İLE İLGİLİ
ÖRNEK BİR UYGULAMA**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Muhammed Cihat ALTIN

VAN-2019

KABUL VE ONAY SAYFASI

Elektrik-Elektronik Mühendisliği Anabilim Dalı'nda Doç. Dr. Rıdvan SARAÇOĞLU danışmanlığında, Muhammed Cihat ALTIN tarafından sunulan "Rüzgâr Hızının Farklı Yöntemlerle Tahminlenmesi İle İlgili Örnek Bir Uygulama" isimli bu çalışma Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili hükümleri gereğince 04/11/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile başarılı bulunmuş ve Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan: Prof. Dr. Mehmet Emin MERAL

İmza:

Üye: Doç. Dr. Rıdvan SARAÇOĞLU

İmza:

Üye: Dr. Öğr. Üyesi Behçet KOCAMAN

İmza:

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 06/12/2019 tarih ve 2019/63-E sayılı kararı ile onaylanmıştır.

İmza
Enstitü Müdürü



TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atf yapıldığını bildiririm.

(İmza)

Muhammed Cihat ALTIN

ÖZET

RÜZGÂR HIZININ FARKLI YÖNTEMLERLE TAHMİNLENMESİ İLE İLGİLİ ÖRNEK BİR UYGULAMA

ALTIN, Muhammed Cihat
Yüksek Lisans Tezi, Elektrik-Elektronik Mühendisliği Anabilim Dalı
Tez Danışmanı: Doç. Dr. Rıdvan SARAÇOĞLU
Aralık 2019, 69 sayfa

Dünyada elektrik enerji talebini karşılamak için öncelikli olarak kullanılan fosil kökenli yakıtlar elektrik enerji üretiminde aşırı miktarlarda sera gazlarının salınımını oluşturduğundan dolayı insanlar sağlık problemleri ile karşı karşıya kalmaktadır. Fosil kökenli kaynakların gelecek yıllarda rezervleri azalarak tükenecek olmasından dolayı temin edilmesi daha pahalı olacaktır. Yenilenebilir enerji kaynakları temiz, çevreye zararsız ve üretim için herhangi bir hammadde ihtiyacı olmayan enerji kaynaklarıdır. Yenilebilir enerji kaynakları üretiminde ön plana çıkan rüzgâr enerjisi üretim sistemleri, ülkemizin var olan rüzgâr enerjisi potansiyeli göz önünde alındığında, önem kazanmaktadır. Rüzgâr enerjisinden elektrik üretimi artmasına rağmen, elektrik şebekesi için halen güvenli bir enerji kaynağı olarak görülmemektedir. Rüzgâr değişken (istikrarsız ve düzensiz) bir kaynak olduğu için tahmin edilmesi zordur. Üretilen enerjinin şebekeye uyum sorunları olmaması için ve üretilen enerjiden etkin bir şekilde faydalanmak için rüzgâr üretim tahminlerine ihtiyaç vardır. Bu çalışmada Mardin Bölgesi için 2000-2010 yılları arasındaki on bir yıllık rüzgâr ve meteorolojik değerleri kullanarak yapay sinir ağları, radyal tabanlı sinir ağları, tekrarlı sinir ağları ve regresyon analizi yöntemleri kullanılarak geleceğe yönelik rüzgâr hız tahmini yapılmaya çalışılmıştır. Kullandığımız yöntemler en iyi Ortalama Mutlak Yüzde Hata değerleri bulunarak karşılaştırılmıştır. Bunun sonucunda Regresyon ve Tekrarlı Sinir Ağlarının yıllık Ortalama Mutlak Yüzde Hata değerlerine göre karşılaştırdığımızda bu yöntemlerin diğer yöntemlere daha iyi sonuç verdiği görülmüştür.

Anahtar kelimeler: Rüzgâr hızı, Regresyon analizi, Sinir ağları, Tahmin

ABSTRACT

A SAMPLE PRACTICE ABOUT ESTIMATION OF WIND SPEED WITH DIFFERENT METHODS

ALTIN, Muhammed Cihat
M.Sc.Thesis, Electrical-Electronics Engineering
Supervisor: Assoc. Prof. Dr. Rıdvan SARAÇOĞLU
December 2019, 69 pages

Since fossil fuels, which are used primarily in the world to meet the demand for electric energy, generate excessive amounts of greenhouse gases in the production of electricity, people face health problems. Procuring of fossil-based resources will be more expensive as their reserves will decrease and deplete in the next years. Renewable energy sources are clean, harmless to the environment and do not require any raw material for production. Wind power generation systems, which come to the forefront in the production of renewable energy sources, gain importance when our country's existing wind energy potential is taken into consideration. Although electricity generation from wind energy has increased, it is still not seen as a safe energy source for the electrical grid. Since wind is a volatile (unstable and erratic) resource, it is difficult to predict. Wind generation estimates are needed to ensure that the generated energy does not have grid adaptation problems and to benefit from the generated energy effectively. In this study, the future wind speed estimation has been tried to be made by using eleven-year wind and meteorological values between 2000 and 2010 for the Mardin Region by using artificial neural networks, radial based neural networks, recurrent neural networks and regression analysis methods. The methods we used were compared by finding the best Mean Absolute Percent Error values. As a result, when we compare the Regression and Recurrent Neural Networks according to the annual Mean Absolute Percent Error values, it is seen that this method gives better results than other methods.

Keywords: Estimation, Neural networks, Regression analysis, Wind speed



ÖN SÖZ

Benim tezimin tüm aşamalarında hiç bir desteğini esirgemeyen danışmanım Doç. Dr. Rıdvan SARAÇOĞLU'na, yürekten şükranlarımı sunmak istiyorum. Ayrıca ebeveynlerime, özellikle eşime ve bir şekilde bana yardım eden tüm diğer arkadaşlarıma teşekkür etmek istiyorum.

2019

M.Cihat ALTIN



İÇİNDEKİLER

	Sayfa
ÖZET	i
ABSTRACT	iii
ÖN SÖZ	v
İÇİNDEKİLER	vii
ÇİZELGELER LİSTESİ	x
ŞEKİLLER LİSTESİ	xii
KISALTMALAR	xiv
1. GİRİŞ	1
1.1. Tezin Amaç ve Önemi	2
2. KAYNAK BİLDİRİŞLERİ	5
3. Materyal ve Yöntem	15
3.1. Regresyon Analizi	15
3.1.1. Doğrusal Çoklu Regresyon	16
3.2. Yapay Sinir Ağları	17
3.2.1. Biyolojik Sinir Ağları	20
3.2.2. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağları	23
3.2.3. Yapay Sinir Ağlarının Temel Elemanları	24
3.3. Radyal Tabanlı Sinir Ağları	24
3.4. Genelleştirilmiş Regresyon Sinir Ağları	27
3.5. Tekrarlı sinir ağları	30
3.6. Değerlendirme Yöntemleri	31
3.6.1. Aritmetik Ortalama Hata (AOH)	31
3.6.2. Ortalama Karesel Hata	31
3.6.3. Ortalama Mutlak Yüzde Hata	31
3.6.4. Determinasyon katsayısı (R^2)	32
3.6.5. Kök Ortalama Karesel Hata	33

	Sayfa
3.6.6. Standart Sapma.....	33
4. BULGULAR	35
4.1. Regresyon Sonuçları.....	36
4.2. İleri Beslemeli Yapay Sinir Ağları Sonuçları.....	39
4.3. Radyal Tabanlı Sinir Ağları Sonuçları	42
4.4. Kesin Radyal Tabanlı Sinir Ağları Sonuçları	45
4.5. Genelleştirilmiş Regresyon Sinir Ağları Sonuçları	48
4.6. Tekrarlı Sinir Ağları Sonuçları	52
4.7. Genel Değerlendirme.....	55
5. TARTIŞMA VE SONUÇ.....	57
KAYNAKLAR.....	61
ÖZ GEÇMİŞ.....	69

ÇİZELGELER LİSTESİ

Çizelge	Sayfa
Çizelge 4.1. Veri Kümesinde yeralan nitelikler.....	35
Çizelge 4.2. Regresyon OMYH değerleri.....	36
Çizelge 4.3. Regresyon katsayıları.....	37
Çizelge 4.4 İBYSA OMYH değerleri.....	39
Çizelge 4.5. Matlab İBYSA parametreleri.....	40
Çizelge 4.6. RTSA OMYH değerleri.....	42
Çizelge 4.7. Matlab RTSA parametreleri.....	44
Çizelge 4.8. KRTSA OMYH değerleri.....	46
Çizelge 4.9. Matlab KRTSA parametreleri.....	49
Çizelge 4.10. GRSA OMYH değerleri.....	49
Çizelge 4.11. Matlab GRSA parametreleri.....	50
Çizelge 4.12. TSA OMYH değerleri.....	52
Çizelge 4.13. Matlab TSA parametreleri.....	53
Çizelge 4.14. Yıllık OMYH değerleri karşılaştırılması.....	55
Çizelge 5.1. Farklı rüzgâr hızı tahmin teknolojileri kullanan araştırmacılar.....	59

ŞEKİLLER LİSTESİ

Şekil	Sayfa
Şekil 3.1 Basit Bir Yapay Nöron.....	19
Şekil 3.2 Basit bir Yapay Sinir Ağı	20
Şekil 3-3 Biyolojik nöronun yapısı.....	21
Şekil 3.4 Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı	23
Şekil 3.5 Radyal Tabanlı Sinir Ağı.....	25
Şekil 3.6 Genelleştirilmiş Regresyon Sinir Ağı.....	29
Şekil 3.7 Tekrarlı Sinir Ağları.....	30
Şekil 4.1 Temmuz Ayı Regresyon Yöntemi ile Test Verilerinin Karşılaştırılması.....	38
Şekil 4.2 Temmuz Ayı Regresyon Yöntemi ile Eğitim Verilerinin Karşılaştırılması	38
Şekil 4.3 Ağustos Ayı YSA Yöntemi Test ile Verilerinin Karşılaştırılması.....	41
Şekil 4.4 Ağustos Ayı YSA Yöntemi ile Eğitim Verilerinin Karşılaştırılması	41
Şekil 4.5 Temmuz Ayı RTSA Yöntemi ile Test Verilerinin Karşılaştırılması	44
Şekil 4.6 Temmuz Ayı RTSA Yöntemi ile Eğitim Verilerinin Karşılaştırılması	45
Şekil 4.7 Temmuz Ayı KRTSA Yöntemi ile Test Verilerinin Karşılaştırılması.....	48
Şekil 4.8 Temmuz Ayı KRTSA Yöntemi ile Eğitim Verilerinin Karşılaştırılması.....	48
Şekil 4.9 Temmuz Ayı GRSA Yöntemi ile Test Verilerinin Karşılaştırılması.....	51
Şekil 4.10 Temmuz Ayı GRSA Yöntemi ile Eğitim Verilerinin Karşılaştırılması	51
Şekil 4.11 Ağustos Ayı TSA Yöntemi ile Test Verilerinin Karşılaştırılması	54
Şekil 4.12 Ağustos Ayı TSA Yöntemi ile Eğitim Verilerinin Karşılaştırılması	54
Şekil 4.13 Ağustos ayı Regresyon ve TSA Yöntemlerinin Karşılaştırılması.....	55



SİMGELER VE KISALTMALAR

Bu çalışmada kullanılan bazı kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
ANFİS	Uyarlanır Bulanık Sinir Sistemi
ARİMA	Otoregresif Entegre Hareketli Ortalama
ARMA	Otoregresif Hareketli Ortalama
BP	Geri Yayılma
BPNN	Geri Yayılma Sinir Ağı
CEEMDAN	Bütünleşik Deneysel Mod Ayrıştırma
EHS	Uyum Arama Algoritması
FIS	Bulanık Çıkarım Sistemi
GRNN	Genelleştirilmiş Regresyon Sinir Ağı
KNN	Ken yakın Sınıflandırıcı
MOFA	Ateş Böceği Algoritması
RBFN	Radyal Temelli Fonksiyon Ağı
SVM	Destek Vektör Makinesi
SVR	Destek Vektör Regresyonu
TCMS	Türkiye Cumhuriyeti Meteoroloji Servisi
YSA	Yapay Sinir Ağı
TSA	Tekrarlı Sinir Ağı
GRSA	Genelleştirilmiş Regresyon Sinir Ağı
RTSA	Radyal Tabanlı Sinir Ağı
KRTSA	Kesin Radyal Tabanlı Sinir Ağı
OMYH	Ortalama Mutlak Hata
DSA	Dalgacık Sinir Ağı
İBYSA	İleri Beslemeli Yapay Sinir Ağı
EMD	Ampirik Mod Ayrıştırma
AR	Otoregresif
GP	Genetik Programlama

Kısaltmalar**Açıklama****SUNA**

İran Yenilenebilir Enerji Kurumu

EHS

Uyum arama algoritması

CLSFP

Çiçek tozlaşma algoritması kaotik yerel arama

NNCT

Olumsuz kısıtlama teorisi

PSO

Kısmi bir sürü optimizasyon algoritması

CSO

Cuckoo arama algoritması

TPSD

Üç fazlı ayrıştırma tekniği

WRELM

Ağırlıklı düzenli aşırı uç öğrenme makinesi

MLP

Çok Katmanlı algılayıcı

DWT

Ayrık dalgacık dönüşümü

LSTM

Uzun kısa süreli bellek ağları

1. GİRİŞ

Teknolojinin ilerlemesine baęlı olarak; hızlanan endüstrileşme, şehirleşme politikaları, yükselen yaşam şartları ve çoęalan nüfus nedeniyle elektrik enerjisi ihtiyacı artmaktadır. Bu gereksinim büyük oranda fosil kökenli kaynaklardan elde edilmektedir. Bu kaynaklar çevreye ve saęlığa büyük zararlar vermektedir (Güler, 2005). Yenilenebilir enerji teknolojileri, fosil yakıtların neden olduęu sera gazları yayılımına baęlı olarak düzensiz iklim deęişimleri, kaynakların tükenmesi, dış ülkelere baęımlılık ve cari açık gibi olumsuz özelliklere sahip deęildir. Bu sebeplerden dolayı yenilenebilir enerji teknolojinde yönelimler artmakta teknolojinin hızla gelişimi ve desteklenmekte olan temiz enerji politikalarıyla yenilenebilir enerji sistemlerinin maliyetlerinde fosil yakıtlarla rekabet edebilecek düzeyde düşüşler gerçekleşmektedir (Akataş, 2015). Dünya geneli incelendiğinde fosil tabanlı enerji kaynaklarının rezervlerinin sınırlı olması, sadece dünyanın belirli kesimlerinde yoğunlaşmış olması ve tabiata olan olumsuz etkileri nedeniyle yenilenebilir enerji kaynaklarına olan ilginin gün geçtikçe arttığı görülmektedir. Ülkeler rüzgârdan elektrik enerjisi üretimini saęlamak amacı ile teknolojik, ekonomik ve kurumsal olarak gerekli yapıyı kurmaya çalışmaktadırlar. Türkiye rüzgâr enerjisi potansiyeli açısından zengin bir ülkedir. Bu açıdan önümüzdeki yıllarda rüzgâr enerjisi alanına olan yatırımların artarak, toplam enerji üretimindeki payının yükseleceęi öngörülmektedir. Bu alanda potansiyeli tespit etmek amacıyla rüzgâr ölçümleri yapılmakta, çeşitli teşvik programları ile rüzgâr enerjisine yatırımlar özendirilmeye çalışılmaktadır (Şenol, 2017). Yenilenebilir Enerji teknolojileri arasında en hızlı büyüyen enerji türü rüzgârdır. Son yıllarda, elektrik enerji şebekelerine rüzgâr enerjisi üretimini entegre etmenin önemi hızla artmaktadır. Elektrik şebekesi içine rüzgâr enerjisini entegre etmenin en büyük zorluğu, rüzgâr enerjisinin deęişkenlięi ve süreksizlięidir. Bu durumla başa çıkmak için en iyi yaklaşım, rüzgâr enerjisi üretiminin gelecekteki deęerlerini tahmin etmektir. Düşük hatalar ile rüzgâr hızı tahmin sistemleri bu sorunları en aza indirmek için kullanılırlar. Rüzgâr enerjisinden elektrik üretimi hızlı büyümesine rağmen, elektrik şebekesi için halen güvenli bir enerji kaynaęı olarak görülmemektedir. Düzensiz rüzgâr hızı yapıları enerji sorununun en önemli nedenlerinden biridir. Bu yüzden rüzgâr santrallerini daha güvenilir bir yapıya sokmak için doęru rüzgâr hızı tahminleri yapmak şarttır. Rüzgâr hızının tahmin yöntemleri de önem arz

etmektedir. Rüzgâr hızlarının oluşumuna yol açan önemli girdilerden bazıları, atmosferik basınç, sıcaklık ve nemdir (Şenkal, 2014).

Rüzgâr hızının özelliklerinden biri, doğrusal olmayan dalgalanan bir fonksiyondur. Bu, rüzgâr hızındaki tahmin için normal tahmin yöntemlerinin uygulanamamasına neden olur. Bu noktada, gelecekteki rüzgâr hızı hakkında öngörde bulunmak için doğrusal olmayan bir yöntem uygulanmalıdır. Yapay sinir ağları doğrusal olmayan tahmin yöntemlerinden biridir. Doğrusal olmayan bir problemi çözme tekniği, sinir ağı, genetik algoritma, kaos fraktal, vb. İle temsil edilen akıllı mühendislik kullanma yöntemidir. (Öğüt, 2014) Rüzgâr enerjisi konusunda yapılan çalışmalara bakıldığında rüzgâr potansiyelinin belirlenmesi ve bu potansiyelin nasıl kullanılacağına yönelik uygulamalı, istatistiksel ve fiziksel yapıya bağlı çalışmaların olduğu görülmektedir. Bu çalışmaların bir kısmı her ülkenin ilgili kurumlarınca ya da uluslararası bazı organizasyonlarca desteklenmektedir. Bir kısmı ise bilimsel niteliği ve veri analizi ağırlıklı tezlerden ve makalelerden oluşmaktadır. Özellikle Türkiye merkezli bilimsel çalışmaların farklı yörelerdeki rüzgâr hızı tahminleriyle ilişkilendirildiği söylenebilir. Zira yöresel olarak rüzgâr hızı, potansiyeli ve kullanımı farklılaşmaktadır. Söz konusu çalışmalar açısından en büyük sorun verilerin elde edilmesi ve farklı analiz yöntemlerinin uygulanmasıdır. Konuyla alakalı verilerin genellikle Devlet Meteoroloji İşleri Genel Müdürlüğü'nden temin edildiği anlaşılmaktadır. Rüzgâr enerjisi üretimi rüzgâr hızı ile doğru orantılıdır. Rüzgâr hızı ise arazi yapısına bağlıdır. Bunun dışında çok değişik meteorolojik etkenler de bulunmaktadır.

1.1. Tezin Amaç ve Önemi

Ülkelerin gelişmişlik düzeylerini belirleyen en önemli kıstaslardan biri elektrik enerjisi kullanımınıdır. İlerlemekte olan teknoloji ile birlikte elektrik enerjisi kullanımı artmaktadır ve bu artış yeni elektrik enerjisi üretim kaynakları arayışını da beraberinde getirmektedir. Enerji, sanayinin olduğu kadar günlük yaşamın da önemli girdilerinden biridir. Bilindiği gibi enerji; fosil kökenli yakıtlardan ve yenilenebilir enerji kaynaklarından elde edilmektedir. Kaynakları giderek tükenen fosil kökenli yakıtlar ve bu yakıtların çevreye geri döndürülemez zararlar vermesi ve temininde artan maliyetler nedeniyle dikkatleri yenilenebilir enerji kaynaklarına yöneltmektedir. Bu

enerji kaynaklarından rüzgâr enerjisi, dünyada yaklaşık 150 ülkenin elektrik üretiminde tercih ettiği bir durum haline gelmiştir. Son yıllarda Türkiye’de de fosil kökenli yakıtların yerine tercih edilen rüzgâr enerjisi, elektrik üretiminde en çok yatırım yapılan alanlar arasında yer almaktadır.

Rüzgâr enerjisinin en önemli bileşenlerinden olan rüzgâr hızının tahmin edilmesi için, o bölgede rüzgâr hızı ve yönün belirli bir süre boyunca kaydedilmesi gerekmektedir. Elde edilen bu kayıtların analizi bölgede bir rüzgâr santralinin kurulup kurulamayacağı konusunda önemli fikirler verir. Hatta uzun vadeli kurulan büyük güçlü rüzgâr santrallerinin planlanmasında geçmişe dönük çok uzun yılları kapsayan kapsamlı analizleri yapmak gereklidir. Bu analizler gelecek yıllardaki rüzgâr enerji potansiyelinin belirlenmesinde önemli bilgiler içermektedir. Başka bir deyişle, kısa bir gelecekte (birkaç yıl) rüzgâr santraline herhangi bir nedenle yatırımın yapılamayacağı bilinen bölgeler için uzun vadede rüzgâr hızlarının (en az beş yıl sonrası için) öngörülebilmesi gerekmektedir. Mardin için detaylı bir araştırma olma özelliği taşıyan bu çalışmada bölgede kurulması düşünülecek rüzgâr enerjisi üretim sistemlerinden temin edilecek enerjinin önceden hesaplanarak, enerji güvencesinin yükselişi ve sistemi etkileyebilecek rüzgâr kaynaklı arıza ve yıpranmaları önceden tespit edilecektir. Bu sayede türbinlerin çalışma güvenliği artırılarak olası kazaların önüne geçilebilecek, sistem sağlamlığı sağlanmaya çalışılacak, sistem daha güvenilir enerji arzı yapılabilebilmesiyle enerji piyasasında oluşabilecek en üst seviyede ani iniş çıkışların öngörülebilmesine imkân sağlayacaktır.



2. KAYNAK BİLDİRİŞLERİ

Minaz (2011), Bilecik İlinin 2000-2009 yılları arası rüzgâr hızı, basınç ve sıcaklık verilerini kullanarak 2010 yılı değerlerini Uyarlanır Bulanık Sinir Sistemi (ANFIS) ve doğrusal çoklu regresyon modelleriyle tahmin etmiş ve bu iki modelin tahmin değerlerini gerçek değerlerle karşılaştırmıştır.

Kani ve Ardehali (2011), çok kısa zaman rüzgâr hız tahmininde yapay sinir ağı ve markov zinciri modellerini birlikte kullandılar ve etkinliğini kanıtladılar. Tahmin hatalarının azaltılabileceği, tahminlerin belirsizliğinin ve hesaplama süresinin azaldığını tespit etmişlerdir.

Taşcıkaraoğlu ve Uzunoğlu (2011), Dalgacık dönüşümü ve yapay sinir ağı kullanarak rüzgâr hızı tahmini yapmışlardır.

Chen ve ark. (2011), Çin'in Hubei eyaletindeki bir rüzgâr parkından elde ettikleri rüzgâr verilerini, saatlik rüzgâr hızını bir ila dört saat önceden tahmin etmek için otoregresif entegre hareketli ortalama (ARIMA) modelini ve yapay sinir ağını (YSA) kullanmışlardır.

Akıncı (2011), Batman bölgesinin YSA yöntemiyle kısa vadeli rüzgâr hızı tahmin etmiştir. Veriler, Türkiye Cumhuriyeti Meteoroloji Servisi (TCMS) tarafından on yıl boyunca, ilgilenilen yerdeki ölçüm istasyonları ağı aracılığıyla toplanmıştır. Türkiye Devlet Meteoroloji Servisi'nden alınan 10 yıllık veri ölçümlerini kullanarak Batman, Türkiye'deki kısa vadeli rüzgâr hızı tahminleri için farklı YSA modelleri geliştirmiştir.

Zhang ve ark. (2011) kaotik teori ve faz uzayı rekonstrüksiyonu teknolojisine dayalı rüzgâr hızı tahmin yöntemi geliştirmişlerdir. Faz uzayı rekonstrüksiyonu ve tahmin metodu için en uygun parametreleri incelemişlerdir.

Guo ve ark. (2011), geri yayılma (BP) sinir ağına ve mevsimsel üstel ayarı kullanarak gerçek rüzgâr hızı veri setlerinden mevsimsel etkileri ortadan kaldırma fikrine dayanan yeni bir hibrit rüzgâr hızı tahmin yöntemi önermişlerdir. Bu yöntem, 2001-2006 yılları arası Çin Minqin bölgesinden alınan rüzgâr hızı veri seti kullanılarak bir yıl öncesinden günlük ortalama rüzgâr hızını, önceki çalışmalara kıyasla daha düşük ortalama mutlak hatalarla tahmin edebilmiştir.

Liu ve ark. (2012), EMD-ANN melez yönteminin ve ARİMA yöntemlerinin rüzgâr hız tahmin sonuçlarını karşılaştırmışlardır.

Liu ve ark. (2012), Zaman serisi, YSA ve Kalman Filtresi yöntemlerini tekil ve birleşik şekilde rüzgâr hız tahmin sonuçlarını karşılaştırmışlardır.

Assareh ve ark. (2012), İran Manjii istasyonundan 1993-2004 yılları arasında toplanan hava sıcaklığı, bağıl nem ve buhar basıncı verileri yapay sinir ağları kullanarak gelecekteki bir zaman diliminde rüzgâr hızı tahminleri için kullanmışlardır.

Lee ve ark. (2012), Jeju bölgesi için YSA kullanarak rüzgâr hızı tahmin modelini geliştirmişlerdir. 10 yıl boyunca toplanan geçmiş veriler için, aylık hız değişimi esas olarak izleme ve sonuçlanan hata kalıpları üzerindeki mevsimsel etkiyi bulmak için modelleme yapmışlardır. 3 katmanlı bir model, deneysel olarak gizli düğüm sayısını 10 seçerek ve her biri giriş ve bir tahmin çıktısı olarak 5 ardışık hız değerinden oluşan 115 örüntüden oluşmuştur.

Akıncı ve Nogay (2012), Güneydoğu Anadolu bölgesinde bulunan altı farklı rüzgâr ölçüm istasyonundan aldıkları verileri kullanarak komşu istasyonların rüzgâr hızını tahmin etmek için YSA kullanarak rüzgâr hızı korelasyonunu belirleme yöntemi sunmuşlardır.

Ramesh Babu ve ark. (2012), kısa konvansiyonel istatistiksel yöntem ve yapay sinir ağları kullanarak rüzgâr hızı tahmini terimi geri yayılma ağı (BPN), genelleştirilmiş regresyon sinir ağı (GRNN) ve radyal temelli fonksiyon ağları (RBFN) kullanarak rüzgâr hız tahmini yapmışlardır.

Lee ve ark. (2012), rüzgâr hızının GRNN kullanarak tahmin performansını değerlendirmek için 2006'dan 2008'e kadar üç yılın 5 günü (120 saat), bir örnek olarak seçmişlerdir.

Şenkal ve Özgönel (2013), On Dokuz Mayıs Üniversitesinde Bulunan Meteoroloji İstasyonlarından elde ettikleri onar dakikalık rüzgâr verilerinden YSA ve Dalgacık Sinir Ağları (DSA) yöntemleriyle rüzgâr hız tahmini yapmışlar elde edilen bulguları karşılaştırmışlardır.

Minaz ve ark. (2013), Bilecik ili rüzgâr hızı, sıcaklık ve basınç tahmini için Uyarlanabilir Bulanık Sinir Sistemi (ANFIS) ve doğrusal çoklu regresyon analizi yöntemlerini karşılaştırmışlardır.

Sheela ve Deepa (2013), Rüzgâr hız tahmini için Kendi Kendini Düzenleyen özellik Haritaları ve Çok Katmanlı Perceptron ağını bütünleştiren önerilen hibrit hesaplama modeli kullanmışlar. Bu yöntemin avantajları arasında daha yüksek doğruluk, hassasiyet ve minimum hata sayılabilir. Sonuçlar, eğitim ve test metodolojileri ile hesaplanmaktadır. Deneysel sonuç, geleneksel sinir ağı modelleriyle karşılaştırıldığında, önerilen hibrit modelin hataların en aza indirilmesi açısından daha iyi performans gösterdiğini görmüşlerdir.

Douak ve ark. (2013), Cezayir'deki Alger, Djelfa, Bechar, Oran, Sétif ve In Aménas' ölçüm istasyonlarından elde ettikleri 2001 ve 2010 yılları arası rüzgâr hızı verileriyle çok bloklu bir GRNN yöntemiyle rüzgâr hızı tahmin etmişlerdir.

Chen ve Yu (2014), Massachusetts Amerika'daki üç bölgede toplanan kısa süreli rüzgâr hızı dizilerini tahmin etmek için Yeni SVR-UKF (destek vektör regresyonu- kokusuz kalman süzgeci) yöntemi, YSA, SVR, otoregresif (AR) ve Kalman filtresi ile bütünleşmiş otomatik ilerletici (AR-Kalman) yaklaşımları ile karşılaştırmışlardır.

Chang (2014), Rüzgâr hız tahmini üzerine literatür çalışması yaparak farklı yöntemlerin güvenilirliğini karşılaştırmıştır

An ve ark. (2014), Bulanık bölüm, bulanık yaklaşım ve regresyon değerlerinin tahmininden oluşan bulanık kaba kümelere dayanan bir regresyon algoritması kullanarak rüzgâr hız tahmini yapmışlardır.

Salas ve ark. (2014), Rüzgâr Hız tahmin yöntemleri olan YSA ve otoregresif bütünleşmiş hareketli ortalama metotlarının sonuçları detaylıca karşılaştırmışlardır.

Olaofe (2014), Rüzgâr istasyonları için levenberg marquardt geri yayılma (BP) algoritmasını kullanan katman tekrarlayan sinir ağı modeliyle uzun süreli rüzgâr güç ve hız tahmini yapmıştır.

Azad ve ark. (2014), Malezya'daki iki meteoroloji istasyonundan (Kuala Terengganu ve Mersing) elde edilen rüzgâr hızı ölçüm numunesi, veri setini eğitmek ve test etmek için kullanmışlardır. Ertesi yıl saatlik rüzgâr hızı verilerini tahmin etmek için temelde iki farklı yaklaşım olan istatistiksel ve sinir ağı temelli yaklaşımlar geliştirmişlerdir.

Kılıç ve Arabacı (2015), Burdur ilinin gelecekteki rüzgâr hızlarını YSA yöntemiyle tahmin etmişlerdir.

Maatallah ve ark. (2015), İki farklı bölgeden elde ettikleri 2006-2009 yılları rüzgâr verilerinden 1-24 saat arası rüzgâr hız tahminini YSA ve ARIMA yöntemleriyle yapmışlar, elde ettikleri bulguları karşılaştırmışlardır.

Abdel-Aal ve ark. (2015), Sinir ağları içeren modern makine öğrenme teknikleri ile 1994-2005 yılları mayıs ayı rüzgâr verilerine dayanarak önümüzdeki yıllar için rüzgâr hız tahmini yapmışlardır.

Koo ve ark. (2015), Rüzgâr istasyonlarından elde ettikleri rüzgâr verilerinden YSA yöntemiyle rüzgâr hızı tahmini yapmışlar ve elde edilen bulguları gerçek değerlerle karşılaştırmışlardır.

Duran ve ark. (2015), yaklaşık kısa vadeli rüzgâr hızı tahmini için, Türkiye'nin Eskişehir bölgesindeki gerçek üç yıllık saatlik ortalama rüzgâr hızı değerleri ile eğitilmiş / test edilmiştir. İleri beslemeli geri yayılım ağı ve Levenberg-Marquardt algoritmaları analiz için kullanılmış ve tanımlanan dört ağ modeli ortalama karesel hata değerleri açısından karşılaştırılmıştır.

Ramasamy ve ark. (2015), Himalayalarda 11 bölge için sıcaklık, hava basıncı, güneş radyasyonu ve rüzgâr hızı değerleriyle YSA yöntemiyle rüzgâr hız tahmini yapmışlardır.

Tagliaferri ve ark. (2015), YSA ve SVM modellerinin rüzgâr hız tahminleri karşılaştırmışlardır.

Mohammadi ve ark. (2015), Rüzgâr enerjisi yoğunluğunu tahmin etmek aşırı öğrenme makinesi tekniği kullanmışlar ve bu tekniği SVM, YSA ve GP (Genetik Programlama) teknikleriyle karşılaştırarak doğrulamışlardır.

Bilgiç ve ark. (2016), Hatay bölgesinde ölçülen basınç ve sıcaklık verilerine dayalı olarak oluşturulan istatistik veriler ile günlük maksimum, minimum ve ortalama rüzgâr hızı verileri YSA ve doğrusal çoklu regresyon analizi yöntemi ile tahmin etmeye çalışmışlardır.

Moustris ve ark. (2016), Hibrit enerji sistemleri (rüzgâr ve güneş enerji tabanlı) için geçmiş rüzgâr ve hava basıncı verilerinden YSA yöntemiyle 24 saatlik rüzgâr hız tahmini yapmışlardır.

Noorallahi ve ark. (2016), İran'da bulunan üç gözlemevinden elde edilen saat rüzgâr hızı verilerinden YSA kullanarak hem zamansal hem de mekânsal boyutlar içinde rüzgâr hız tahmini yapmışlardır.

Kirbaş ve ark. (2016), Mehmet Akif Ersoy Üniversitesi kampüsünde yapılan farklı yüksekliklerde / irtifalarda rüzgâr hızı, rüzgâr yönü, sıcaklık, basınç ve nem gibi meteorolojik verileri içeren 25777 veri dosyasıyla çok katmanlı algılayıcı ve radyal tabanlı fonksiyon yöntemleriyle 61 m'de rüzgâr hızı tahmini yapmışlardır.

Savita ve ark. (2016), Hindistan'daki büyük rüzgâr enerjisi potansiyel durumlarının uzun vadeli rüzgâr hızı tahmini için GRNN kullanmışlardır. Giriş sıcaklığı olarak hava sıcaklığı, toprak sıcaklığı, bağıl nem, günlük güneş radyasyonu, yükseklik, enlem, ısıtma derecesi günleri, soğutma derecesi günleri, don günleri, boylam ve atmosferik basınç verilerinden faydalanmışlardır.

Fazelpour ve ark. (2016), İran Yenilenebilir Enerji Kurumu (SUNA) tarafından sağlanan 1 saatlik aralıklarla ölçülen rüzgâr hızı verileri giriş olarak kullanılarak radyal temel fonksiyonlu YSA, uyarlanabilir nöro-bulanık çıkarım sistemi, YSA-GP hibrit ve YSA parçacık sürüsü optimizasyonu yöntemlerini kullanarak rüzgâr hızı tahmin etmişlerdir.

Kumar ve ark. (2016), Boylam, Enlem, günlük güneş ışınımı yatay, hava sıcaklığı, bağıl nem, toprak sıcaklığı, yükseklik, soğutma derecesi günleri, ısıtma derecesi günleri, atmosferik basınç değerlerini kullanarak Hindistan'ın 67 şehrinde GRNN ve Çok Katmanlı algılayıcı (MLP) yöntemleriyle rüzgâr hızı tahmin etmişler ve iki modelin ortalama karesel hatalarını karşılaştırmışlardır.

Azeem ve ark. (2017), Hindistan Rajashtan bölgesi için maksimum sıcaklık, ortalama sıcaklık, minimum sıcaklık, ortam sıcaklığı, çiğlenme noktası sıcaklığı, atmosferik basınç, hava basıncı, buhar basıncı, güneş ışınımı, rakım, boylam, rüzgâr yönü, ortalama deniz seviyesi, bağıl nem, günün saati, su buharı, rüzgâr enerjisi verilerini kullanarak YSA yöntemini kullanarak rüzgâr hız tahmini yapmışlardır.

Chang ve ark. (2017), Tayvan yakınlarında rüzgâr çiftliği gücünü tahmin için bir hata geri bildirim düzeni ile geliştirilmiş radyal tabanlı sinir ağı modeli (IRBFNN-EF) önermişler. Önerilen model tarafından elde edilen sonuçlar bu üç diğer YSA tabanlı (Geri beslemeli sinir ağları, Radyal tabanlı sinir ağları, Uyarlamalı ağ tabanlı bulanık çıkarım sistemi) tahmin yöntemlerinin sonuçları ile karşılaştırmışlardır.

Ayodele ve Ogunjuyigbe (2017), Güney Afrika'nın Batı Cape bölgesinde Noupoot'un rüzgâr hızları, geri besleme eğitim yöntemiyle ileri beslemeli YSA kullanarak iklim verilerinden tahmin etmişlerdir.

Petković ve ark. (2017), yumuşak hesaplama yöntemleri ile rüzgâr hızı dalgalanma tahmini geliştirmek için fraktal enterpolasyon kullanılmıştır. Fraktal enterpolasyona dayalı rüzgâr hızı dalgalanmasını tahmin etmek için farklı eğitim algoritmalarına sahip YSA kullanmışlardır.

Yeşilbudak ve ark. (2017), rüzgâr hızı, rüzgâr yönü, baro metrik basınç ve hava sıcaklığı verilerinden faydalanılarak, k-en yakın komşu sınıflandırıcısına (k-NN) dayanan çok kısa vadeli rüzgâr enerjisi tahmin modeli kullanmışlardır.

Lu ve ark. (2017), çok amaçlı bir ateş böceği algoritması (MOFA) kullanarak bir GRNN ağında parametreleri optimize ederek rüzgâr hızının kısa vadeli tahmini için yüksek doğruluk ve güçlü kararlılıkla yeni bir hibrit model sunmuşlardır. Bu hibrit algoritmanın etkinliğini değerlendirmek için, Çin Penglai, bölgesindeki dört rüzgâr santralinden elde edilen verilerle rüzgâr hızını kısa vadeli olarak tahmin etmek için kullanmışlar, bunun yanı sıra geri yayılan sinir ağı (BPNN), radikal olan dört tipik YSA tabanlı model temel fonksiyon sinir ağı, dalgacık sinir ağı (DSA) ve GRNN yöntemleriyle karşılaştırmışlardır.

Zhang ve ark. (2017), Çin'in doğu kıyı bölgelerindeki dört rüzgâr santralinden elde ettikleri 15 dakikalık rüzgâr hızı verileriyle bütünleşik deneysel mod ayrıştırma uyarlanabilir gürültüyü (CEEMDAN), çiçek tozlaşma algoritması kaotik yerel arama (CLSFP), beş sinir ağı ve olumsuz kısıtlama teorisi (NNCT) ile birleştiren yeni bir birleştirilmiş model kullanarak rüzgâr hızı tahmini yapmışlardır.

Han ve ark. (2017), rüzgâr hızını doğru bir şekilde tahmin etmek için Parametrik olmayan modelleri benimseyerek iki hibrit model, yani hibrit otoregresif hareketli ortalama / parametrik olmayan ve hibrit parametrik olmayan / otoregresif hareketli ortalama modeller önerilmiş ve performansları karşılaştırılmıştır. Karşılaştırmalar için, hibrit modelleme için BPNN, SVM ve rastgele orman modelleri de tanıtılmıştır. Gerçek saatlik rüzgâr hızı zaman serileri üzerinde çeşitli testler uygulanarak, hem tekli hem de hibrit modellerin tahmin performansı karşılaştırılarak ve ayrıntılı olarak değerlendirilmiştir.

Akçay ve ark. (2017), yeni bir rüzgâr hızı tahmin çerçevesi sunarak önerdikleri çerçevenin performansı, Türkiye'nin Marmara bölgesindeki beş meteoroloji istasyonundan toplanan rüzgâr hızı ölçümleri ile değerlendirilmektedir. Deneysel sonuçlar, günlük, haftalık, aylık ve ölçümlerdeki yıllık modellerin kesilmesinin tahmin

doğruluğunu önemli ölçüde arttırdığını göstermektedir. Önerilen çerçeve, son zamanlarda geliştirilen bir alt uzay yöntemi ile verilerin eğilimini azaltma, kovaryans faktoringi ve bir adım önde ve / veya çok adım önde Kalman filtresi tahmin fikirleri üzerine kurulmuştur.

Yuan ve ark. (2017), Kısa vadeli rüzgâr enerjisini tahmin etmek için hibrit otoregresif fraksiyonel olarak entegre hareketli ortalama ve en küçük kare SVM modeli önermişlerdir. Önerilen hibrit model, ilk olarak, otomatik korelasyon fonksiyonu analizi, rüzgâr enerjisi serisinin uzun hafıza özelliklerini tespit etmek için kullanmışlar ve otoregresif kesirli bütünlük hareketli ortalama modeli, rüzgâr enerjisi serisinin doğrusal bileşenini tahmin etmek için uygulamışlar. Ardından, rüzgâr hızı, rüzgâr yönü ve otoregresif fraksiyonel olarak entegre hareketli ortalama modelinin artık hata serisini kullanarak rüzgâr enerjisi serisinin doğrusal olmayan bileşenlerini tahmin etmek için en küçük kare SVM modeli oluşturmuşlar. Son olarak, iki modelin tahmin sonuçlarının birleştirilmesiyle rüzgâr gücünün tahmini elde etmişlerdir.

Mori ve ark. (2017), YSA yöntemiyle RBFN'nin performansını arttırmak için, RBFN'ye iki teknik uygulamışlardır. Bunlardan biri, giriş değişkenlerinin özellik çıkarımı için S-Transform'un ön filtreleme tekniğini kullanmaktır. Diğer ise rüzgâr hızı zaman serisine iki aşamalı bir tahmin yöntemi uygulamaktır. Önerilen yöntem Japonya'daki rüzgâr hızının gerçek verilerine başarıyla uygulanmıştır.

Filik ve ark. (2017), çalışmalarında, rüzgâr hızı, sıcaklık ve basınç değerleri gibi farklı yerel meteorolojik ölçümleri farklı bir şekilde kullanan YSA tabanlı modeller önermişler ve YSA tabanlı çok değişkenli modelin rüzgâr hızı tahminlerinin çeşitli durumlar için iyileştirilebileceği göstermişlerdir.

Huang ve ark. (2017), Tayvan Merkez Hava Bürosu'ndan elde edilen rüzgâr gücü kapasitesi ve rüzgâr hızı tahminlerine dayanarak, çoklu destek vektör regresyon (SVR) modelleri kullanan belirleyici bir rüzgâr enerjisi tahmin yöntemi kullanmışlardır. Daha sonra her bir SVR modeli için parametreleri tahmin etmek için geliştirilmiş bir uyum arama (EHS) algoritması kullanmışlar. Bir elektrik şebekesinde rüzgâr enerjisi tahminleriyle ilişkili riski değerlendirmek için, rüzgâr enerjisi tahminlerine ilişkin güven aralıklarını doğru şekilde yansıtan bir EHS tabanlı nicelik regresyon yöntemi sunmuşlar. Önerilen yaklaşım, 15 dakikalık adımlar halinde gelecek 3 saat boyunca rüzgâr enerjisi tahminlerini ve ilgili tahmin belirsizliğini sağlamaktadır. Üç pratik rüzgâr enerjisi

üretim sistemi üzerinde test sırasında, önerilen yöntem daha iyi tahmin doğruluğu sağlamış ve mevcut yöntemlerden daha makul güven aralıkları sağladığı gözlemlenmiştir.

Wang ve ark. (2018), çok aşamalı rüzgâr hızı tahmini için, üç fazlı bir sinyal ayırıştırma tekniğine (TPSD), özütleme özelliğine (FE) ve ağırlıklı düzenli aşırı uç öğrenme makinesine (WRELM) dayanan yeni bir karma strateji geliştirdiler.

Luna ve ark. (2018), süper kısa vadeli (30 saniyenin altında) rüzgâr hızı tahminleri için YSA metodolojisi sunmuşlardır.

Khosravi ve ark. (2018), rüzgâr hızını, rüzgâr yönünü ve rüzgâr türbininin çıkış gücünü tahmin etmek için üç makine öğrenme algoritması modeli uygulamışlar. İlk model, farklı veri eğitim algoritmaları ile eğitilmiş, çok katmanlı ileri beslemeli sinir ağıdır. İkinci model, radyal temel işlevli (SVR-RBF) destek vektör regresyonudur. Üçüncü model, kısmi bir sürü optimizasyon algoritması (ANFIS-PSO) ile optimize edilmiş ANFIS'tir.

Huang ve ark. (2018), rüzgâr hızı tahminindeki zorlukların üstesinden gelmek için, bu makale kısa vadeli tahminler için yeni bir evrimsel sinir ağı algoritması önermişler, önerilen algoritmanın tahmin performansı, rüzgâr hızı tahmininde yaygın olarak kullanılan dört yapay zekâ algoritmasıyla karşılaştırmışlardır.

Liu ve ark. (2018), EEMD ve SVM 'den oluşan yeni bir kısa vadeli rüzgâr hızı tahmin yöntemi kullanmışlar, parametreler, geliştirilen Cuckoo arama algoritması (CSO) ile optimize edilmiştir.

Yu ve ark. (2018), rüzgâr hızı sekansı için Ampirik Mod Ayırıştırma (EMD) ve Otomatik-Regresyonlu Hareketli Ortalama modeline (ARMA) dayalı bir hibrit tahmin yöntemi önermişlerdir. İlk olarak, yöntem orijinal rüzgâr hızı dizisini bir dizi İçsel Mod İşlevine (IMFS) ve orijinal dizilerden daha kararlı olan bir tortuya ayırmak için EMD'yi kullanmışlar. Ardından, ARMA modeli, sıraları tahmin etmek için kullandılar Rüzgâr hızının tahmin sonucu, alt sonuçların öngörülen sonuçları eklenerek elde etmişler.

Khosravi ve ark. (2018), çok katmanlı ileri beslemeli sinir ağı (İBYSA), (SVR), bulanık çıkarım sistemi (FIS), ANFIS, grup veri işleme tipi sinir ağı, ANFIS-PSO ve zaman serisi rüzgâr hızı verilerini tahmin etmek için genetik algoritma ile optimize edilmiş ANFIS-GA geliştirmişlerdir.

Zhang ve ark. (2018), rüzgâr hız tahmini için Lorenz bozukluđuna dayanan IPSO-BP sinir ađını test etmişlerdir.

Moreno ve ark. (2018), rüzgâr hızı tahmini ile ilgili literatürde nadiren uygulama sunan Tekil Spektrum Analizini ve ANFIS'i birleştiren karma bir yaklaşım önermişlerdir.

Chen ve ark. (2018), kısa vadeli rüzgâr enerjisi tahminleri için ARMA, YSA adı verilen bir zaman serisi temelli yöntem ve YSA ve ANFIS olarak adlandırılan Bulanık Mantık'ı hibritlemeye dayalı üç yöntemi karşılaştırmışlardır.

Prema ve ark. (2018), rüzgâr hız tahmini için YSA kullanan hibrit modeller sunmuşlardır.





3. MATERYAL VE YÖNTEM

Bu bölümde çalışmada kullanılan matematiksel, istatistiksel yöntemler ve uygulama adımları hakkında bilgiler verilmiştir.

3.1. Regresyon Analizi

Regresyon analiz yöntemi tek ölçüt parametresi ile tek ya da daha fazla kestirim parametreleri arası bağı sayısal duruma çevirmede yönlendirilen istatistiksel analiz biçimidir. Regresyon analizi genelinde parametreler arası bağıntının özelliğini anlamayı amaçlar. Kestirim parametresi olarak tek parametre kullanıldığında basit regresyon, kestirim parametreleri olarak iki veya daha çok parametre kullanıldığında çoklu regresyon analizini çözümlenmek olanaklıdır. Amaç her tahmin parametresinin ölçüt parametresindeki toplam değişimdeki payının bulunması ve dolayısıyla tahmin parametrelerinin düzenli birleşiminin değerinden hareketle ölçüt değerinin bulunmasıdır. İki ya da daha fazla parametre arasında bağı bulunup bulunmadığı, bağı bulunuyorsa yönünü ve seviyesini araştıran “korelasyon analizi” ile parametrelerden birisinde belirli bir kısım değişirse diğerine nasıl bir fark oluşturduğunu araştıran “regresyon analizi” sayısal bilimlerde yaygınlıkla önerilen istatistiksel yöntemdir. Regresyon analizi, belirtilerden, bilmediğimiz gelecekteki olgulara dair kestirimler yapılmasını sağlar. Regresyon, bağımlı ve bağımsız parametre(ler) arası bağı ve doğrusal eğri kavramı yardımıyla kestirime dair denklem arar. Parametreler arası ilgi düzeyi belirlenirse, bağımsız parametre(ler) in değeri bilinirse bağımlı parametrenin değeri bulunabilir. Bağımlı Parametre (y), regresyon yönteminde yanıtlanan ya da kestirilen Parametredir. Bu Parametrenin bağımsız parametre ile bağı olduğu düşünülür. Bağımsız Parametre (x), regresyon yönteminde açıklayan parametredir; bağımlı parametrenin karşılığını bulmak amacıyla kullanılır. Parametreler arasında düzenli ilişki olabileceği gibi, düzensiz bir ilişkide olabilir. Bundan dolayı, dağılım grafiği çizilmeden (bağılantı yok/düzenli bağılantı var/düzensiz bağılantı var) ve parametreler arası korelasyon durumuna karşılaşılmadan regresyon analizi düşünülmemelidir. Bu

doğrultuda, tek/çok parametrelili düzenli regresyon çözümlerinin yanı sıra, tek/çok parametrelili düzensiz regresyon çözümlerini bulmaktadır. Bağımlı parametre ile bağımsız parametre arasındaki düzenli ilişkiyi tanımlayan tek parametrelili regresyon modeli " Eş. 3.1" deki gibidir:

$$Y=a+b.x \quad (3.1)$$

Denkleminde; y = Bağımlı parametre değeri a = Regresyon doğrusunun kesişim değeri (Sabit değer) b = Regresyon doğrusunun eğimi x = Bağımsız parametrenin sonucunu vermektedir (Kılıç, 2013).

3.1.1 Doğrusal çoklu regresyon

Doğrusal çoklu regresyon birden çok parametre (X_1, X_2, \dots, X_n) ile bağımlı tek parametre (Y) arasındaki ilişkiyi gösterir. Bu durumda bağımsız parametrelerin bağımlı parametreyle ilişkisi " Eş. 3.2", deki gibidir.

$$Y=a+b_1.X_1 + b_2.X_2 + b_3.X_3 + \dots + b_n .X_n \quad (3.2)$$

Denkleminde doğrusal bir katsayısı (b) yerine n tane net ya da kısmi regresyon katsayısı bulundurulur. Bu katsayılar her bir katsayı ile ilgili bağımsız parametrede oluşabilecek bir değişikliğin bağımlı parametre üzerine yansımalarını gösterir. Temel regresyon çözümlerinde görüldüğü üzere çoklu regresyon fonksiyonu elde etmek için en küçük kareler yöntemi " Eş. 3.3" deki gibi kullanılabilir.

$$Y =a+b_1.X_1 +b_2.X_2 \quad (3.3)$$

" Eş. 3.2 " deki gibi çoklu regresyon modelinde aşağıdaki doğrusal denklemlerin birlikte çözümü gerekir.

$$\sum Y = n.a + b_1.\sum X_1 + b_2 .\sum X_2 \quad (3.4)$$

$$\sum X_1.Y = a. \sum X_1 + b_1 \sum X_1^2 + b_2\sum X_1 X_2 \quad (3.5)$$

$$\sum X_2 \cdot Y = a \cdot \sum X_2 + b \cdot \sum X_1 \cdot X_2 + b_2 \cdot \sum X_2^2 \quad (3.6)$$

İki bağımsız parametrenin bulunduğu regresyon modelinde parametrelerin bulunmasında matris yöntemleri kullanıldığında genellikle yaygın karşılaşılan hataları tespit etmekte avantajlı olur. Tek bağımsız parametrenin bulunduğu doğrusal regresyon modelinde β_0 ve β_1 parametre tahminleri olan b_0 ve b_1 istatistikleri;

$$b \cdot (X^T \cdot X)^{-1} X^T \cdot Y = \quad (3.7)$$

Çözümüyle bulunur. Bu denklem iki ve daha çok bağımsız parametrenin bulunduğu sistemlerde de kullanılır (Unver ve Gamgam, 2008).

3.2. Yapay Sinir Ağları

YSA, merkezi sinir sistemimizin yönetim organizasyonunun benzetimini yaparak öğrenme stratejileriyle yeni bilgiler çıkarabilme ve bulma gibi kabiliyetleri, hiç destek almadan kendiliğinden yapabilmek amacı ile ilerletilen mantık programlamalarıdır. YSA; insan sinir sisteminden özümseyerek, öğrenebilme kuramının sayısal olarak modellenmesi amacıyla oluşturulmuştur. Buna bağlı olarak konuyla ilgili araştırmalar ilk önce sinir sistemini meydana getiren biyolojik nöronların modellenmesi ve bilgi sistemlerine uyarlanması ile başlamış, daha sonraları bilgi sistemlerinin ilerlemesiyle akabinde benzeri değişik sektörler kullanmaktadır. Sinir Sisteminin yönetme yöntemini özümseyerek kullanan bu metotlar, zamanımızda nano teknolojiler hızlı bir ilerleme göstermiş, işlem hızları nano saniyeler seviyesine düştüğünde bile, değil sinir sistemimizi, basit tek hücrelinin sinir sistemini bile taklit edememektedir. Nano saniyeler süresinde inen bilgi işleme hızları ile YSA'lar, saniyenin binde bir sürelerindeki işleme hızları ile iş yapan sinir sisteminin işlevselliğine çok yaklaşamamaktadır. Sinir sistemimizde yaklaşık 10^{11} sinir hücresi olduğu düşünülmeyle birlikte, bu sayının sayısal olarak modellenmesinin hiçbir teknolojiyle imkânı yoktur. Ancak tepki süresi bakımından sinir sistemimize rakip olamasalar da, YSA'lar

işlevsellikler ve hassas denkleşmelerin başarılı yapabilmeleri ile zamanla artarak tercih edilmektedir.

YSA yoğun olarak; sınıflandırma, modelleme ve Kestirim uygulamaları ve değişik birçok sektörde denenmektedir. Başarılı durumlar incelenirse, çoğunlukla YSA'lara fazla boyutlu, yüksek harmonikli, kompleks, istikrarsız, noksan, kusurlu, hata ihtimali fazla duyarlı verilerinin olması ve sorunun çözümünde sayısal modelin ve yazılımların olmadığı, sadece örneklerin bulunduğu durumlar için rağbet edilmektedir. Buna bağlı olarak geliştirilen ağlar genelde bu görevler için kullanılmaktadırlar; olabilecek fonksiyon tahminleri, Gruplama, İlişki kurma ya da örüntü eşleştirme, Zaman serisi çözümlenmeleri, Sinyal süzme, Bilgi sıkıştırma, Örüntü algılama, Düzensiz işaret işleme, Düzensiz sistem modelleme, Uygun hale getirme ve Kontrol (Öztemel, 2003).


YSA, nöron, kısım, hücre ya da birleşme noktası diye isimlendirilen değişik sayıda temel işlem kısımlarından oluşmaktadır. Her bir nöron, diğer bir nörona sabit ağırlıklı iletişim ağlarıyla buluşur. Ağırlıklar, YSA'nın bir sorunun çözümünde gereken girdiyi sağlamaktadır. YSA çok çeşitli sorunların çözümlemesinde kullanılırlar. Örneğin, verileri ve örnekleri depolamada ve daha sonra tekrar denemede, örnekleri gruplandırmada, giriş örneklerinin çıkış örneklerine çevrilmesinde, benzer örneklerin sınıflandırılmasında ya da doğal olmayan en uygun şekle sokma sorunlarının çözümünde ve değişik alanlarda YSA kullanılabilir.

Her nöronun bir iç durumu vardır ve bu iç durum etkinleşme ya da etkinleşme düzeyi olarak adlandırılır. Bu düzey, alınan giriş değerlerinin bir fonksiyonudur. Herhangi bir nöron, kendi aktivasyonun, genelde sinyal şeklinde diğer nöronlara gönderir. Ama bu sinyal birden fazla nörona aynı anda gönderilebilir.

Örneğimiz şekil 3.1'de bulunan bir Y nöronunun durumunu düşünersek buradaki nöron X_1 , X_2 ve X_3 nöronlarından giriş işaretlerini alır. Etkinleşen nöronların çıkış işaretleri, sırayla x_1 , x_2 ve x_3 'tür. Bağlantıların ağırlıklar X_1 , X_2 ve X_3 nöronlarından Y nöronuna doğru sırasıyla w_1 , w_2 ve w_3 'tür. Ağ girişi olan y_{in} değeri X_1 , X_2 ve X_3 'den Y'ye giden ağırlıklandırılmış işaretlerin toplamından oluşur. y_{in} elde edilen değeri " Eş. 3.8" deki gibi bulunur.

$$y_{in}=w_1.X_1+ w_2.X_2+ w_3.X_3$$

(3.8)



Şekil 3.1. Basit bir yapay nöron.

Y nöronunun etkinleşmesi y , ağırlıkların giriş fonksiyonu olarak " Eş. 3.9" gibi açıklanır.

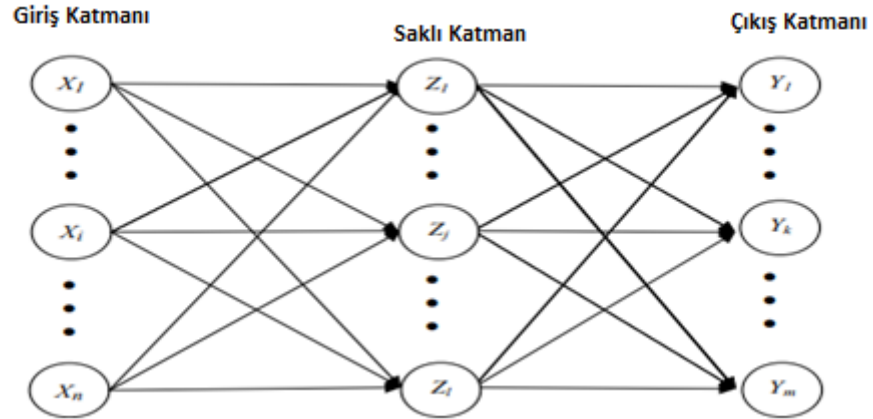
$$y = f(y_{in}) \quad (3.9)$$

Bu fonksiyon için, S-biçiminde sigmoid fonksiyon düşünülebilir. Sigmoid fonksiyonun şekli " Eş. 3.10" da verildiği gibidir.

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (3.10)$$

Buradaki fonksiyon, öteki etkinleşme fonksiyonlarından biri de olabilir, Y nöronunun Z_1 ve Z_2 nöronlarına v_1 ve v_2 ağırlıklarına bağlı olarak varsayılırsa Bu durum, şekil 3.2'de görülmektedir. Y nöronu y işaretini öteki kısımlara iletir. Bu durumda, genelde Z_1 ve Z_2 nöronları aracılığıyla gelen işaretler farklıdır; çünkü her bir işaret iletiliği bağıntıda olan v_1 ve v_2 ağırlıkları ile orantılıdır. Z_1 ve Z_2 'nin etkinleşme fonksiyonları olan z_1 ve z_2 verileri, yalnızca tek nörona bağımlı olmaz. Kendileri birbirinden değişik bir veya daha çok nörondan gelen işaretlere bağlanmışlardır.

Şekil 3.2' deki YSA karmaşık olmamasına karşın, saklı katmanın görüntüsü ve düzensiz etkileşimi nedeniyle birden çok sorunu çözümleyebilir. Değişik taraftan saklı bir kısma sahip YSA'nın eğitimi yani ağırlıkların en iyi değerleriyle hesaplanması fazlasıyla sıkıntılıdır (Yazıcı ve ark., 2007).



Şekil 3.2. Basit bir yapay sinir ağı.

3.2.1. Biyolojik Sinir Ağları

Bir biyolojik nöronun üç tip bileşeni vardır. Bu bileşenler, dentritler, soma ve aksondur. Birçok dentrit, sinyalleri diğer nöronlardan alır. Alınan bu sinyaller, dentritler arasındaki sinaptik boşluklardan iletilen elektrik tepkileridir. Kimyasal vericilerin hareketi, giren sinyalleri değiştirmektedir. Bunlar, YSA'daki ağırlıklara benzemektedir (Akpınar, 1993).

Biyolojik bir nöronun yapısı şekil 3.3'de gösterilmiştir. YSA işlem elemanlarının birkaç önemli özelliği, biyolojik nöronların özelliklerini akla getirmektedir.

Bu özellikler aşağıdaki gibidir:


- Her bir işlem elemanı yani her bir nöron, farklı sinyaller alabilir;
- Alınan sinyaller sinaptaki ağırlıklar tarafından değiştirilebilir;
- İşlem elemanları yani nöronlar, ağırlıklı girdileri toplar;
- Uygun koşullar altında yani yeterli girdi sağlandığında, işlem elemanı çıkış sinyalini aktarır;
- Belirli bir nöronun çıkışı diğer birçok nörona gidebilir.

YSA'nın biyolojik nöronlardan aldığı önemli diğer özellikler aşağıda verilmiştir:

- Bilgi işleme yereldir;
- Bellek ikiye ayrılmıştır:

- a) Uzun dönemli bellek, nöronun sinapslarındaki ağırlık değerlerine bağımlı olur
- b) Kısa dönemli bellek, nöronlar tarafından gönderilmiş daha hızlı sinyallere uymaktadır.
 1. Bir sinapsın gücü deneyimlerle değiştirilebilir;
 2. Nöro aktarıcılar, sinapslar için hızlandırıcı ya da yavaşlatıcı olabilir.

YSA' nın biyolojik sinir sistemiyle paylaştığı diğer bir karakteristik de hata toleransıdır. Biyolojik nöral sisteminde iki hata toleransı olabilir. Birincisinde, giriş sinyallerinde daha önce hiç görülmemiş bir sinyal ile karşılaşılabilir. Buna bir örnek olarak, daha önceden hiç görülmemiş ya da çok uzun süre önce görülmüş bir insanı, bir fotoğrafın içinde hemen tanıma yeteneği verilebilir. İkincisinde, sinir sisteminin kendisine zarar vermesine izin verilebilir. İnsan 100 milyardan fazla nöronla dünyaya gelir. Nöronların büyük bir kısmı beyindedir ve bu nöronlar öldüğü takdirde, onların birçoğu artık yenilenmez. İnsan beyni birçok nöronunu kaybetmesine rağmen öğrenmesine devam etmektedir. Travmatik nöron kayıplarında bile, diğer nöronlar, ölen nöronların fonksiyonlarını yerine getirmek için eğitilebilir. Benzer şekilde, YSA da, ağdaki küçük hasarlara karşı duyarsız şekilde tasarlanabilir ve sinir ağı önemli hasarlar sonucunda dahi tekrar eğitilebilir (Ocakoğlu, 2006).



Şekil 3.3. Biyolojik nöronun yapısı.

YSA modelleri, canlı birimlerinde mevcut biyolojik sinir sistemi modellenerek oluşturulmuşlardır. Özümseven yapay sinir elemanları birbirleriyle değişik biçimlerde birleşerek YSA'yı oluştururlar ve genellikle kısım kısım oluşturulurlar. Bu kısımlar öğrenme, hafızaya kaydetme, hatırlama, sonuç çıkarma kabiliyetindedirler. YSA

hesaplamalarının gücü, toplam iş yükünü paylaşan işlem elemanlarının yani nöronların aralarındaki sıkı bağlardan dolayıdır. Sayısal olarak modellenmiş bir biyolojik nöron Şekil 3.3'te görülmektedir. Bu nöronlar Mc Culloch-Pits nöronu olarak bilinirler. Birbirleriyle birleşerek ağı oluştururlar. Nöron karşı nörondan işaretleri alır, bunları harmanlar, çevirir ve sayısal bir sonuç meydana getirir. Her bir nöron şiddetine göre gelen işareti ya durdur ya da yollar. Girişteki değerler her biri bir bağlantı değeriyle çarpılır. Nöronlar giriş bilgilerini ağırlıklandırma yapılmasından sonra, düzenli şekilde toplar ve eşik bu bilgiyi düzenli veya bir düzensiz fonksiyon olarak işlenerek çıkış verisine çevirir. Bu çıkış verisi hücreye bağlantısı olan diğer nöronlar girdi olarak alırlar. YSA'ya uyan ağırlık setinin belirlenmesi için yapılan ağ hesaplamaları 2 aşamadan oluşur:

1. Öğrenme: Ağlar örneklerle eğitilirler. İki öğrenme stratejisi söz konusudur:

- a. Danışmanlı öğrenme: Ağa girdi-çıkış vektörleri şeklinde ayrıntılı eğitim örnekleri verilmektedir. Örneğe ait hem girdi hem de çıkış verileri ağa gönderilir ve her ardışık örneğe ait çıkış değerleri ile ağı çıkış değerleri değerlendirilerek ağı hata hesaplanır. Bu hata en az oluncaya dek ağ, nöronlar arası ağırlıkları yaklaştırarak ardışık işlemlere devam eder. YSA'da en kullanılan öğrenme yöntemidir.
- b. Danışmansız öğrenme: Ağa sadece girdiler gönderilir ve bu girdi veri grubuna uyumlu bir çıkış verisi üretebilecek durumda ağı kendisine uyan ağırlıkları düzeltilmesi beklenir.

2. Hatırlama (Test etme): Ağı eğitimi durumunda bulunan ağırlıklardan yararlanılarak ağı benzer bir soruna ait giriş değerleri yüklenir ve bu sorunun çözülmesi beklenir. YSA, ağı kullanıldığı veri grubuna göre sınıflandırılabilir. Temelde veriler kalitatif (kategorik) ve kantitatif (sayısal) olarak 2 ana gruba ayrılır. Kalitatif veriler ile çalışan ağlar ister danışmanlı ister danışmansız öğrenme kullanılsın, sınıflandırma ağları olarak tanınmaktadırlar. Kantitatif bilgileri kullanan, danışmanlı eğitim almış YSA ise genellikle regresyon analizi amaçlıdır. YSA, yapısal olarak da sınıflandırılabilir. Yapısal olarak YSA, verinin akma yönüne bağlı olarak, nöronlar arasındaki bağıntıların yapı durumundan ileri beslemeli ve geri beslemeli olarak 2 ana sınıfta toplanır.


1. İleri beslemeli YSA: Arada bulunan sinirleri geçerek girdi katmanından çıktı katmanına düzenli veri akışında tek yönde ilerleyen ağlardır. Giriş kısmı, gizli kısım ve çıkış kısmı olarak 3 katmandan oluşurlar. Ağ üzerinde bilgi akışı giriş kısmından çıkış kısmına doğru giderler. Böylelikle nöronlar sıralı bir şekilde besleme yaparlar
2. Geri beslemeli YSA: Rastgele bir sinir çıkışından girişine doğru bilgi akışının yöneldiği ağlardır. Böyle bir ağ yapısında geri besleme bağıntıları önceliklidir. Ayrıca hem ileri besleme hem de geri yayılım şeklinde adlandırılabilir ağ sistemleride bulunur.

Tüm YSA modelleri arasında yaygın tercih edilen ağlar geri yayılım ile eğitilmiş çok katmanlı ileri beslemeli ağlar (Back Propagation Network), radyal tabanlı ağlar, Hopfield ve Kohonen gösterilebilir. Geri yayımlı YSA hem kullanışlı hem de güvenilir olmasından dolayı en çok kullanılan ağ türüdür. Belirgin özelliği tahmin (prediction) ve gruplama işleri için rahatlıkla uyarlanması ve düzensiz yapıdaki sistemlerde genelde elverişlidir (Yazıcı ve ark., 2007).

3.2.2. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı

Temel ağ yapısı, tek girişe ve tek çıkışa sahip olan, iki katmanlı, ileri beslemeli ağ çeşididir. Çıktı verilerinin bulunduğu kısımda bulunan her bir nöron, ağırlıklandırılmış veriler yardımıyla, giriş nöronlarının hepsinden sinyal alır. Genellikle rastlanan karmaşık fonksiyonların hesaplanması için basit ağlar yerine aralarda saklı katmanlar bulunan çok katmanlı İBYSA'lar tercih edilir.

Şekil 3.4 'de görülen ileri beslemeli yapay sinir ağının (İBYSA) temel yapısında giriş, saklı ve çıkış katmanı vardır. İleri beslemeli ağda, sinyaller girişten çıkışa bir ya da daha çok gizli katman üstünden dağılır. YSA, giriş vektörünü bir kez gördükten sonra, ağırlıkları öğrenme yeteneğiyle hesaplanır. Burada, öğrenme yönteminde geriye yayılım algoritmasından faydalanılmıştır (Bolat ve ark., 2004).



Şekil 3.4. Çok katmanlı ileri beslemeli yapay sinir ağı.

3.2.3. Yapay Sinir Ağlarının Temel Elemanları

Biyolojik ağlardaki sinir hücrelerine karşılık, YSA'da da yapay sinir sistemleri vardır. Şekil 3.2 aynı zamanda bir yapay sinir hücrelerini de göstermektedir. Her yapay sinir hücrelerinin 4 ana elemanı vardır. Bu elemanlar; girdiler, ağırlıklar, transfer fonksiyonu ve hücrenin çıktısıdır. Girdiler ($x_1, x_2, x_3, \dots, x_n$) bir yapay sinir ağına dışarıdan gelen bilgilerdir. Yapay sinir hücrelerine dışarıdan olduğu gibi başka elemanlardan veya kendisinden de veriler gelebilir. Ağırlıklar, yapay sinir sistemine iletilen verinin önemini ve hücreye tesirini bildirir (Öztemel 2003). Bir işlem elemanı, genellikle eşzamanlı olarak birçok girdi almaktadır. Her girdi ($x_1, x_2, x_3, \dots, x_n$) = gizli katmandaki işlem elemanına ($y_1, y_2, y_3, \dots, y_h$); bağlanırken bir bağlantı ağırlığına ($w_1, w_2, w_3, \dots, w_n$) sahip olmaktadır. Gizli katmandaki gizli işlem elemanları diğer bir gizli katmandaki gizli işlem elemanlarına ya da başka bir gizli katman bulunmuyorsa çıktı katmanındaki işlem elemanlarına ($z_k; k=1, \dots, p$) bağlanırken de bir bağlantı ağırlığına ($v_{jk}; j=1, \dots, h; k= 1, \dots, p$); sahip olmaktadır. Girdi katmanından gizli katmana gelen girişlerin bu bağlantı ağırlıkları ile çarpılması ile gerekli değerler elde edilir (Anderson ve McNeill, 1992).

3.3. Radyal Tabanlı Sinir Ağları

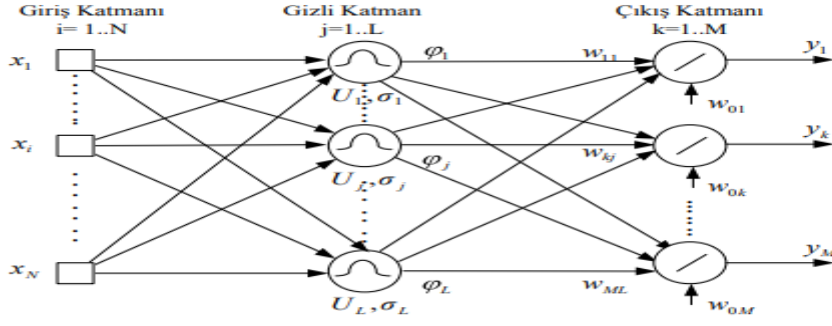
Çok parametrelili model ve yaklaşımlarda kullanılan YSA yapılarından olan Radyal tabanlı sinir ağları (RTSA) canlı sinir sistemlerinde gözlenen yerel tepki

yansımaları özümseyerek 1988 yılında geliştirilmiş ve filtreleme sorununa uygulanarak Broomhead ve Lowe (1988) tarafından YSA dünyasına kaydedilmiştir. Yerel tepki karakteristiği, sinir sisteminin farklı kısımlarında, örneğin görme sinirlerinin tepkilerinde görülebilir (Poggio ve Girossi, 1990). Bu sinirler görme alanında bulunan farklı seviyelerdeki resimlere karşı hassastır ve her an tepki vermeye odaklanmıştır. Bunlar girdi uzayını sınırlı küçük bir kısmına tepki verebilmektedir (Aslan, 2008). Bir RTSA'nın çalışma düşüncesi, giriş bilgisine bağlı olarak gizli katmana uyan genişlik ve merkez ölçülerinde RTSA'ları bularak, çıkış katmanında bu fonksiyonların meydana getirdiği çıkış verilerinin uygun ağırlık ölçüleriyle doğrusal şekilde bir araya getirilerek giriş-çıkış arası bağıntıyı belirleme süreci olarak yanıtlanabilir (Kaynar ve ark., 2016).

ÇKYSA'ya göre az sürede eğitimi ve yerel düşüklere takılmaksızın en iyi çözüme yaklaşmaları gibi nedenlere bağlı olarak RTSA kestirim, eğri benzetme ve fonksiyon yaklaştırma gibi sorunların çözümlerinde ÇKYSA'ya benzer biçimde sinir ağı olarak kullanılmaya başlanmıştır (Bianchini ve ark., 1995). Giriş katmanındaki giriş değerleri MLP den değişik şekilde ağırlıklar ile çarpım yapılmadan doğrudan gizli katmana ulaştırılırlar. Gizli katmandaki radyal fonksiyon merkezlerini hesaplayan U_j referans vektörleri ile giriş vektörü arası mesafe ölçüsüne bağlı olarak gizli katman çıkışına " Eş. 3.11" görüldüğü üzere bir değer türetilir.

$$\varphi_j(x) = \exp\left(-\frac{\|x-U_j\|^2}{2\sigma^2}\right) \quad (3.11)$$

Değişik uzaklık ölçüleri varlığına karşın mesafe birimi olarak çoğunlukla Öklid uzaklığı kullanılmaktadır. Giriş vektörü, referans vektörüne ne kadar çok yakınsıyorsa fonksiyonun oluşturacağı değer o kadar büyük olur. Gizli katman için kullanılmasında fazlaca radyal tabanlı fonksiyon (Gaussian, Multi-Quadric, Generalized Multi-Quadric, Thin Plate Spline) yönlendirilmesine rağmen uygulama kısımlarında genellikle Gaussian fonksiyonu kullanılır. Chen ve ark. 1991 yılında yaptıkları çalışmada ağda tercihen radyal sinir ağının seçilmesinin ağın başarısı üzerine güçlü bir etki göstermediğini söylemişlerdir.



Şekil 3.5. Radyal tabanlı sinir ağı.

Denklemden görünen X_i sonucu o zaman ağa iletilen giriş vektörünü U_j referans vektörünü, $\| \cdot \|$ mesafe fonksiyonu σ ise standart sapma ölçüsünü sembolize etmektedir. σ değeri RTSA modelinin başarısını yüksek oranda etkileyen dağılma (spread) parametresi (s) olarak da bilinmektedir. Gizli katman çıkışında elde edilen φ_j hesaplamaları ardında w_{kj} ağırlık ölçüleri çarpılarak toplandığında " Eş. 3.12" de verildiği gibi ağın çıktısı bulunur.

$$y_k = \sum_{j=1}^L \varphi_j w_{kj} + w_{k0} \quad (3.12)$$

RTSA yöntemlerinin eğitilmesi, hücre merkezlerinin belirlenmesi ve çıkış tabakasındaki ağırlık değerlerini uygun hale getirmek üzere iki aşamada gerçekleştirilmektedir. Kaynaklarda hücre merkez noktalarını (U_j) ve çıkış ağırlık değerlerinin (w_{kj}) hesaplanması için değişik metotlar denenmektedir. Hücre merkez noktalarını hesaplanmasında için tercih edilen metotlar K ortalamalar (K-means) ve Kohonen gruplama metotlarıdır. Çıkıştaki ağırlıkları hesaplamak için tercih edilen metotlarsa En Küçük Ortalamalı Kareler (LMS) ve Moore-Penrose Sözde Ters (Pseudo-inverse) metotlarıdır. Dağılma parametresi ise tercihen elemanların tamamı için değişmez kabul edilir. RTSA modellerinde dağılma parametresi için tahmini eşitlikler olmasına rağmen, bu parametrenin hesaplanmasında deneme-yanılma tekniği de kullanılmaktadır.

Bu yöntemde RTSA modelinin hücre merkez noktaları (U_j) K-ortalama metodu ile hesaplanmıştır. Hücre merkez noktalarının hesaplanmasından sonra, belirli

bir Q eğitim seti için ağıın çıktı değeri (y) Denklemdesine yakın şekilde bulunabilmektedir (" Eş. 3.13").

$$y(q) = \sum_{k=1}^N w_{ik} \varphi_k(x(q), c_k), q = 1, 2, \dots, Q \quad (3.13)$$

Bu durumun ardından, ağıın türettiğı çıkış verileriyle belirlenen çıkış verileri arasındaki farklar değerlendirilmekte ve (" Eş. 3.14") devrilen performans fonksiyonunun en aza indirilmesi amaçlanmaktadır.

$$E(w) = 12 \sum [b(q) - y(q)]^2, q = 1, 2, \dots, Q = 12(b - \varphi w)^T (b - \varphi w) = 12(b^T b - 2b^T \varphi w + w^T \varphi^T \varphi w) \quad (3.14)$$

Burada, E(w) başarı fonksiyonunu, b ağıın istenen çıkışları (beklenen yada hesaplanmış ölçümleri), y ağıın ürettiğı çıkış verileri, Q eğitim setini ve T ise serinin transpozunu simgelemektedir. Denklemden E(w)'nin ağırlık değerlerine göre 1.dereceden türevi alınarak 0'a eşitlenir ($\partial E(w) = -2\varphi^T b + 2w^T \varphi^T \varphi w = 0$) elde edilen (" Eş. 3.15") Moore-Penrose Sözdere Ters (Pseudo-inverse) yaklaşımı ile hesaplanmış, ağıın çıkıştaki ağırlık değerleri bulunmuştur (Okkan ve ark., 2012).

$$w = (\varphi^T \varphi)^{-1} \varphi^T b = \varphi^+ b \quad (3.15)$$

3.4. Genelleştirilmiş Regresyon Sinir Ağları

Genelleştirilmiş regresyon sinir ağları (GRSA), RTSA'nın değiştirilmiş bir durumudur. Sistem olarak tek radyal tabanlı tabaka ile değişik bir doğrusal tabakadan meydana gelmiştir. RTSA'da ana düşünce, bir grup radyal tabanlı işlevi istenen işleve yakınlaşacak biçimde ağırlıklandırılarak toplanmasıdır. GRSA'da ise RTSA'nın merkez ve bant genişliklerinin eğitim girişlerinin sabit işlevleri olarak belirtilir ve böyle sistemlerin eğitilmesi için tekrarlı metotlar denenmez (Bolat ve ark., 2004).

GRSA dört kısımdan oluşur. İlk kısım ikinci kısma doğrudan bağlanan giriş kısmıdır. İkinci kısımda her bir girdiyi temsil eden bir nöron vardır. Bu kısım GRSA sistemlerindeki giriş kısmının özelliğine yakın bir görev gerçekleştirir; girişler ve

saklanmış bilgiler arasındaki uzaklık ölçütünü hesaplayarak çıkış üretirler. Üçüncü kısım toplama kısmı olarak adlandırılır, S-toplama ve D-toplama nöronlarından oluşur. S-toplama nöronları ikinci kısmın çıkışlarının ağırlıklı toplamını yapar. D-toplama nöronları ise bu çıkış verilerini ağırlıksız olarak toplar. Son kısımdaki çıkış nöronlarının her birine bağlı sadece bir S-toplama nöronu ve tamamına ortak bağlantıyla bir adet D-toplama nöronu bulunur. İkinci kısımda gauss fonksiyonları kullanılır. Üçüncü kısımda ise toplama kısmında ağırlıklı toplama olarak gösterilecek D-toplamı yapılır. Son kısımda ise her bir S-toplam D-toplamına bölünerek çıkışlar bulunur. GRSA'nın temelinde standart bir istatistiksel metot olan Kernel yaklaşımı kullanılmaktadır (Specht, 1991; Ekmen, 2006).

Şekil 3.16'da bir GRSA ağ yapısı gösterilmektedir. Regresyon, x ve eğitim seti verilirse bir y bağımlı parametresine uyan değeri bağımsız x parametresine bağımlı şekilde tahminler. Regresyon metodu ortak kare hatasını en düşüğe azaltacak biçimde y çıkışını tahmin eder. GRSA, bir eğitim seti verildiğinde x ve y'nin ortak olasılık yoğunluk fonksiyonunu (OYF) kestiren yöntemdir. OYF girişlerden ön değerlendirme olmadan bulunduğundan sistem genel de uygundur (Şahin, 2007).

$f(x,y)$ OYF'nin binmesi sırasında, bağımsız x parametresine göre bağımlı y parametresinin regresyonu (" Eş. 3.16") ile gösterilir;

$$E([y]|x) = \frac{\int_{-\infty}^{\infty} yf(x,y)dy}{\int_{-\infty}^{\infty} f(x,y)dy} \quad (3.16)$$

Eğer olasılık yoğunluk fonksiyonu bildirilmemişse gözlenen x_i ve y_i değerlerinden (" Eş. 3.17") ile bu fonksiyon tahmin edilir.

$$f(x, y) = \frac{1}{(2\pi)^{(p+1)/2} \sigma^{p+1}} \frac{1}{n} \sum_{i=1}^n \exp \left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2} \right] \exp \left[-\frac{(y-y_i)^2}{2\sigma^2} \right] \quad (3.17)$$

Bu denklemde p, x vektörünün boyutunu, n, gözlenen veri sayısını, σ yumuşatma Parametresidir (Alp ne ark., 2004).

Genel regresyon ağlarında bir x_j girişi, ağdaki Gauss çekirdeklerinden birinin merkez noktası olarak belirlenir. Herhangi bir giriş vektörü x için i. Radyal tabanlı

kısmın çıkış verisi (" Eş. 3.18") gösterildiği gibi hesaplanır.

$$\beta_i = \exp \left[-\frac{(x-x_i)^T(x-x_i)}{2\sigma^2} \right] \quad (3.18)$$

σ kullanıcı tarafından tercih edilen yumuşatma parametresidir. Herhangi bir x girişi için ağıın y çıkış değeri (" Eş. 3.19") gibi hesaplanır.


$$y = \sum_{i=1}^K \alpha_i y_i \quad (3.19)$$

(" Eş. 3.19") da kullanılan α katsayıları (" Eş. 3.20") deki gibi hesaplanır:

$$\alpha_i = \frac{\beta_i}{\sum_{i=1}^k \beta_i} \quad (3.20)$$

Eğer giriş vektörü x , herhangi bir x_i eğitim vektörüne yakın ise x_i 'ye ilişkin α_i en yüksek olur ve belirlenen çıkış y , x_i 'ye ilgili y_i çıkış değerine yaklaşır. (Bolat ve ark. 2004; Asma ve ark. 2012).


GRSA'nın yapısı Şekil 3.6'da görülmektedir. Şekilde gösterildiği gibi örnek kısmı, giriş verilerinin alınarak örneklendiği yani sınıflandırıldığı kısım, toplama kısmı girdi verilerinin toplanarak oluşturduğu kısımdır. Çıkış kısmı ise çıkış değerinin bulunduğu kısımdır.



Şekil 3.6. Genelleştirilmiş regresyon sinir ağı.

3.5. Tekrarlı Sinir Ağları

İçinde döngüler bulunan ve bilginin devam etmesine izin veren ağlar olan Tekrarlı Sinir Ağları (TSA) Başlangıçta Jeff Elman tarafından denenmiştir. TSA'da gizli katman kendisine geri besler. Her nöronun çıktısı tekrarlı olarak tutulmaktadır. Tekrarlı tutulan çıktılar yeni girdiler ile işlemek amacıyla kullanılır. Ardışık girdilerin önceki girdilere bağlı işlenmesinde genel olarak kullanılmaktadır. Elman bu yöntemi cümle simülasyonlarında deneyerek her bir söz grubu için saklı düzeneklerin üstünde ortalama örüntü sınıflandırma sırasında isim ve fiil grupları olarak ayırmıştır. TSA kısımlar arası bağıntıların yönlendirilmiş bir döngü oluşturan YSA sınıfıdır. Ardışık bilgileri kullanan, gizli kısmın çıktısını yine gizli kısma giriş olarak bağlayan bir derin öğrenme yazılımıdır. İleri beslemeli sinir ağların aksine, TSA'lar kendi giriş belleğini giriş verilerinin rastgele dizilerini işlemek için kullanmaktadırlar. TSA'da ana fikir düzenli verileri kullanmaktır. Görüntü tabanlı verilerde tüm giriş verilerinin (veya çıkış verilerinin) birbirine bağlı olmaması düşünülür. Fakat NLP gibi zaman parametresi olan kısım için bu durum uygun olmamaktadır. Örneğin, bir cümledeki sözcüğü tahmin etmek için, o anki sözcükten önce hangi sözcüklerin geldiğini bilmeliyiz. TSA mimarisinin tekrarlı (recurrent) olarak isimlendirilmesinin nedeni, bir dizinin her ögesi için (cümledeki sözcükler gibi) aynı görevi önceki çıkışlara bağlı olarak yerine gerçekleştirmesidir (Şeker ve ark., 2017).



Şekil 3.7 Tekrarlı sinir ağları

Standart TSA, aşağıdaki şekilde formülleştirilir: giriş vektörlerinin dizisi (x_1, \dots, x_T) gizli katmanların dizilimi (h_1, \dots, h_T) ve çıkışların dizilimi ($\sigma_1, \dots, \sigma_T$) $t = 1$ ile T arasında aşağıdaki denklemlere göre tekrarlanarak hesaplanır (Sutskever ve ark., 2011).

$$h_t = \tanh(W_{hx}x_t + W_{hh}h_{t-1} + b_h) \quad (3.21)$$

$$o_t = W_{oh}h_t + b_o \quad (3.22)$$

Bu denklemlerde, W_{hx} giriş katmanı-gizli kısım arası ağırlık matrisi, W_{hh} gizli kısımlar arası (veya tekrarlı) ağırlık matrisidir, W_{oh} gizli kısım çıkış kısmı arası ağırlık matrisidir ve b_h ve b_o vektörleri sapmalardır. Tanımlanmamış ifade $W_{hh}h_{t-1}$ $t = 1$ zamanı için özel bir başlangıç sapma vektörü ile değiştirilir, h_{init} , ve \tanh doğrusal olmayan koordinat bilgisine uygulanır (Sutskever ve ark., 2011).

3.6. Değerlendirme Yöntemleri

Yaptığımız tahminlerdeki hata miktarlarının kabul edilebilir olup olmadığını belirlemek için kullandığımız formüller aşağıda verilmiştir.

3.6.1. Aritmetik Ortalama Hata (AOH)

EŞ. 3.23'te hesaplanması için gerekli formül verilmiştir.

$$AOH = \frac{1}{n} \sum_{i=1}^n (\text{ÖLÇÜM} - \text{TAHMİN}) \quad (3.23)$$

$$\text{ÖLÇÜM} - \text{TAHMİN} = \text{HATA}$$

$$AOH = \frac{1}{n} \sum_{i=1}^n \text{HATA}$$

n: tahmin hatalarının sayısı

3.6.2. Ortalama Karesel Hata (OKH)

Karesel Ortalama Hata denklem EŞ. 3.24'te verilen formül ile hesaplanır.

$$OKH = \frac{1}{n} \sum_{i=1}^n (\text{ÖLÇÜM} - \text{TAHMİN})^2 \quad (3.24)$$

OKH değerinin 2. dereceden kökü alınarak ortalama (KOKH) elde edilir. Genelde tahmin ve ölçülen değerler arası değişimi tespit etmeye yarar. KOKH değerleri oluşturulan sistemlerin başarısını kestirilecek zaman kısmı için değerlendirmek ve her bir sistemin başarısını birbirine göre durumunu öğrenmek amacıyla tercih edilir.

3.6.3.Ortalama Mutlak Yüzde Hata (OMYH)

Ortalama mutlak yüzde hata Eş 3.25’ da verilen formül ile hesaplanır.

$$OMYH = \frac{1}{n} \sum_{i=1}^n \left(\frac{\text{ÖLÇÜM-TAHMİN}}{\text{ÖLÇÜM}} 100 \right) \quad (3.25)$$

3.6.4. Determinasyon katsayısı (R^2)

Korelasyon katsayısı oluşturulan modeldeki değişkenlerin arasında olan ilişkinin anlaşılması için kullanılır. R Eş 3.27. ile gösterilir. Determinasyon katsayısı ise uyumu yüzde olarak açıklamaya yaramaktadır ve korelasyon katsayısının karesi (R^2) ile ifade edilir. Determinasyon katsayısı (R^2) Eş 3.26. ve Eş 3.27. kullanılarak elde edilir. Bu değer bire yaklaştıkça başarı oranı artmaktadır. Ayrıca determinasyon analizinde vektör yön problemleri de yoktur (Cohen, 1988).

$$\sum (y_i - y_{ort})^2 = \sum (y_i - y_i^{\wedge})^2 + \sum (y_i^{\wedge} - y_{ort})^2 \quad (3.26)$$

SST SSR SSE

SST: Toplam Sapma (değerlerinin ortalamadan farkının kareleri toplamı)

SSR: Açıklanan Sapma (y değerlerinin ortalamadan sapma değeri)

SSE: Açıklanamayan Sapma (hata karelerinin toplam değeri)

$$R^2 = \frac{\sum (y_i^{\wedge} - y_{ort})^2}{\sum (y_i - y_i^{\wedge})^2 + \sum (y_i^{\wedge} - y_{ort})^2} \quad (3.27)$$

$$R = \frac{\sum (y_i^{\wedge} - y_{ort})}{\sqrt{\sum (y_i - y_i^{\wedge})^2 + \sum (y_i^{\wedge} - y_{ort})^2}} \quad (3.28)$$

Burada R^2 determinasyon katsayısını ifade etmektedir. Bu değer sıfır ile bir arasında değişmekte olup bire yaklaştıkça oluşturulan modelin başarı oranı artmaktadır. yi bağımlı değişkeni, yort analiz sonucu bağımlı değişkenin aldığı beklenen değerlerin ortalamasını, gözlemlenen değerleri ifade etmektedir.

3.6.5.Kök Ortalama Karesel Hata (KOKH)

Gerçek değer tahmin edilen değerlere mutlak uzaklıklarının ortalamasının kareköküdür. Determinasyon katsayısı ve KOKH arasında ters orantı vardır. Determinasyon katsayısı bire yaklaştıkça model başarısı artar ve buna bağlı olarak KOKH düşer, sıfıra yaklaşır. KOKH değeri için verilen denklem Eşitlik 3.29.'da verilmiştir (Emeksiz ve ark., 2016). Burada, X_i gözlenen değerleri, N terim sayısını ifade ederken, Y_i tahmin edilen değerleri ifade etmektedir.

$$KOKH = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - X_i)^2} \quad (3.29)$$

3.6.6 Standart Sapma

Veri değerlerinin aritmetik ortalamasından farkının kareleri ile toplam değerlerinin toplam veri sayısının bir eksiğine bölünmesiyle elde sonucun ikinci dereceden köküdür.

Eşitlik 3.30.'deki gibi hesaplanır.

$$\text{Standart sapma} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (X_i - X_{ORT})^2} \quad (3.30)$$



4. BULGULAR

Bu çalışmada Mardin meteoroloji müdürlüğünden alınan veriler kullanılmıştır. Bu verilerden denemelerde rüzgâr hızını en fazla etkileyen ortalama nem, ortalama sıcaklık ve ortalama basınç olmuştur. 2000-2010 yıllarına ait verilerin nitelik sınıflandırması ve istatistiksel değerlendirilmesi aşağıdaki tablodaki gibidir.

Çizelge 4.1. Veri kümesinde bulunan nitelikler

Nitelik Adı	Birimi	En Küçük Değer	En Büyük Değer	Ortalama
Gün Süresi	Dakika	583	904,6	743,5214832
Günlük Ortalama Basınç	Atm	880,8	911,5	897,1744
Günlük Ortalama Nem	(%)	2,7	98	44,87731
Toprak Sıcaklığı 50 Cm	(°C)	3,5	32,3	17,93933954
Toprak Sıcaklığı 20 Cm	(°C)	-1,8	36,3	17,85681504
Toprak Sıcaklığı 5 Cm	(°C)	-3,3	42,3	19,34383848
Toprak Sıcaklığı 10 Cm	(°C)	-3,7	39,8	18,5050414
Ortalama Sıcaklık	(°C)	-10,1	37,3	18,92082983
Günlük Toplam Güneşlenme Süresi	Saat	0	13,8	8,400750476
Günlük Yağış Toplamı	(mm)	0	75,7	1,402570689
Ortalama Rüzgâr Hızı	m/s	0,925	10,4625	3,735912662

Çizelgeden görüldüğü üzere ortalama rüzgâr hızı yavaş ve yağış az gerçekleşmektedir. Diğer meteorolojik verilerin ortalamasında minimum ve maksimum değerlerin ortasında görülmektedir.

Günümüzde Sinir Ağları ve Regresyon Analizi uygulamaları özellikle formülize edilmeyen, deneme yanılma çalışmalarıyla sonuca gidilen problemler için farklı çözümler oluşturmuştur. Uygulamalarda MATLAB programlama dilinde yazılmış kodlarla, ÇDR, İBYSA, RTSA, GRSA, KRTSA, TSA yöntemleri uygulanmıştır.

Çalışmada verilerin 9/11 'i eğitime 2/9'u teste ayrılmıştır. Yöntemlerin tahmin ölçümleri Ortalama Mutlak Yüzde Hata (OMYH), Karekök Ortalama Karesel Hata

(KOKH) ve Determinasyon Katsayısı (R^2), Korelasyon Katsayısı (R) deęerleri hesaplanmış OMYH sonuçlarına göre başarı analizleri karşılaştırılmıştır.

4.1.Regresyon Sonuçları

Çizelge 4.2’de regresyon yöntemiyle tahmin edilen sonuçların eğitim ve test OMYH ’ları tabloda aylık olarak sıralanmış şekilde görölmektedir.

Çizelge 4.2. Regresyon test OMYH sonuçları

AYLAR	ORTALAMA MUTLAK YÜZDE HATA	
	EĞİTİM	TEST
Ocak	36.3685	38.4066
Şubat	32.5936	34.1826
Mart	30.9165	31.6064
Nisan	30.8569	33.1167
Mayıs	26.4026	27.7952
Haziran	23.0931	23.8323
Temmuz	20.2201	20.2140
Ağustos	20.7658	21.3487
Eylül	21.8387	22.4971
Ekim	26.7009	27.2090
Kasım	32.2302	32.8426
Aralık	35.1092	34.3388
Yıllık	28,0913	28,9492

Regresyon analizinde günlük ortalama nem, sıcaklık ve basınç deęerleri kullanılmıştır. Beşli çapraz doğrulama yapılarak yöntemin güvenilirliği kanıtlanmıştır. Çizelge 4.3’de regresyon analizinde bulduğumuz regresyon katsayıları görölmektedir.


Çizelge 4.3. Regresyon Katsayıları

AYLAR	B0	B1	B2
Ocak	-0,125123834566669	-0,00505663157935765	0,00555552451368338
Şubat	-0,113785790324501	-0,00972378131468563	0,00565508472307626
Mart	-0,0929357984630052	-0,0255105946188351	0,00658877209617287
Nisan	-0,0588042448648438	-0,0146408886491757	0,00559019775759397
Mayıs	-0,00941366948571741	-0,00441083270198641	0,00432140987924212
Haziran	-0,0474705332490677	0,0120414137336968	0,00533563865514927
Temmuz	-0,0478575230161452	-0,0143983888699933	0,00607492224807700
Ağustos	0,00911434661202919	-0,00557443715294542	0,00346000722484950
Eylül	-0,0932576583374551	-0,00481670827063195	0,00621724222087993
Ekim	-0,0658097924568722	-0,00691320252786694	0,00520619753934548
Kasım	-0,141228979674913	-0,00827471593719755	0,00605306733405430
Aralık	-0,104616419523926	-0,00844478080004104	0,00575202654678520


Çizelge 4.2’den görüldüğü üzere en düşük test tahmin OMYH Temmuz ayına ait olup % 79,79 oranında doğru tahmin yapmıştır. Ayların tamamı $20\% \leq \text{OMYH} \leq 50\%$ aralığında olduğundan Ramasamy ve ark. (2015)’e göre kabul edilebilir tahmin doğruluğunda ve Rüzgâr Hızı tahmin yöntemlerinde OMYH % 25 ile % 40 arasında değişmektedir (Wang ve ark., 2014; Wang ve ark., 2015; Zhang ve ark., 2013; Guo ve ark., 2012; Su ve ark., 2014) düşüncelerini desteklemektedir.

Şekil 4.1’te görüldüğü üzere en iyi tahmin sonucu olan Temmuz ayında gerçek test değerleri 1,91-6,89 aralığında değişirken tahmin test değerleri 3,22-3,74 aralığında değişmekte dolayısıyla tahmin test eğrisi gerçek test eğrisine çok yaklaşmamaktadır. Bu durumda bile Test OMYH % 20.2140 oranında kabul edilebilir tahmin doğruluğu vermektedir.

Şekil 4.2’de Temmuz ayı gerçek eğitim değerleri ile tahmin eğitim değerlerinin karşılaştırılması görülmektedir. Gerçek eğitim verileri 1,78-7,72 arasında değişirken tahmin eğitim verileri 2,97-3,95 değerleri aralığında değişmekte test değerlerinde olduğu gibi tahmin eğitim eğrisi gerçek eğitim eğrisine çok yaklaşmamaktadır.



Şekil 4.1. Temmuz ayı regresyon yöntemi test verilerinin karşılaştırılması.



Şekil 4.2. Temmuz ayı regresyon yöntemi eğitim verilerinin karşılaştırılması.

4.3. İleri Beslemeli Yapay Sinir Ağları Sonuçları

Çizelge 4.4'te YSA ile yapılan tahmin sonuçları görülmektedir.

Çizelge 4.4. YSA OMYH değerleri


Aylar	Ortalama Mutlak Yüzde Hata	
	Eğitim	Test
Ocak	43.9031	39.1421
Şubat	30.6648	35.4532
Mart	31.8973	33.9900
Nisan	27.6954	29.1477
Mayıs	28.0358	24.1304
Haziran	23.9027	29.7176
Temmuz	19.6605	25.2861
Ağustos	22.9535	18.1101
Eylül	20.4049	26.2858
Ekim	27.6303	25.8842
Kasım	33.4901	42.6346
Aralık	38.2109	35.2927
Yıllık	29,0374	30,4229

YSA uygulaması MATLAB Neural Network Toolbox kullanılarak yapılmıştır. Verilerin eğitiminde, saklı katman sayıları ve saklı katmanlardaki nöron sayıları, eğitim ve transfer fonksiyonları en iyi hata sonucunu verecek şekilde deneme yanılma yoluyla belirlenmiştir. Mardin Meteoroloji Enstitüsünden alınan 11 yıllık verinin % 81,6'sı eğitim , % 18,4'si test amacıyla rastgele seçilmiştir. Oluşturulan ağda 3 adet giriş değişkeni (Günlük Ortalama Nem, Günlük Ortalama Basınç, Günlük Ortalama Sıcaklık) ile çıkış değişkeni olarak Mardin ili ortalama rüzgâr hızı kullanılmıştır. Oluşturulan ağda her bir model için en iyi sonuç veren eğitim ve transfer fonksiyonları seçilmiştir. Yapılan denemelerde tekrar sayısı olarak 5000 değeri kullanılmıştır. Her bir ayın sonucunu istatistiksel doğrulama yapmak için matlab programı 30 defa çalıştırılmış elde ettiğimiz değerlerin ortalaması alınmıştır. Çizelge 4.5'de görüldüğü üzere her ay için MATLAB Neural Network Toolbox'ta kullandığımız parametreler farklıdır.


Çizelge 4.5. Matlab YSA parametreleri

Aylar	Katman sayısı	Nöron sayıları	Transfer fonksiyonları	Eğitim fonksiyonu
Ocak	2	5,2	logsig, tansig, purelin	traingda
Şubat	1	11	tansig, purelin	traingda
Mart	2	9,10	tansig,tansig, purelin	traingda
Nisan	1	8	tansig, purelin	traingda
Mayıs	1	6	tansig, purelin	traingda
Haziran	2	2,5	tansig,tansig,purelin	traingd
Temmuz	2	2,42	purelin,tansig,tansig,	traingda
Ağustos	2	5,15	purelin, tansig,tansig	traingd
Eylül	1	4	logsig, tansig	traingda
Ekim	1	5	logsig, purelin	traingda
Kasım	2	4,3	Logsig,tansig,purelin	traingda
Aralık	2	6,5	logsig, tansig	traingda

Çizelge 4.4’de görüldüğü üzere regresyon yönteminde benzer şekilde en iyi sonuç ağustos ayında % 81,89 doğrulukla elde edilmiş ve diğer aylara göre daha üstün bir tahmin sonucu olduğu görülmektedir. Ağustos ayı test verisi şekilde görüldüğü üzere rüzgâr hızı değişimleri diğer aylara göre daha dar aralıkta değişmektedir. Kullandığımız tahmin yöntemleri yaz aylarında kış aylarına nazaran daha iyi sonuçlar vermektedir. Daha önce bahsettiğimiz üzere yaz kış aylarında mevsimsel değişimlere bağlı olarak kış aylarına nazaran daha doğrusal değişen sıcaklık, Basınç, Nem değerlerindeki değişimler rüzgâr hız tahmini için önemli etkenler arasına girmektedir. Tahmin $OMYH < \%10$ ise Yüksek tahmin doğruluğunda, $10\% \leq OMYH \leq 20\%$ aralığında iyi tahmin doğruluğunda, $20\% \leq OMYH \leq 50\%$ arası makul tahmin doğruluğunda, $OMYH \geq 50\%$ ise yetersiz tahmin doğruluğunda yorumlanır (Ramasamy ve ark., 2015). Bu kritere göre Ağustos ayı iyi tahmin doğruluğunda diğer aylar kabul edilebilir (makul) tahmin doğruluğundadır.



Şekil 4.3. Ağustos ayı YSA Yöntemi ile test verilerinin karşılaştırılması.



Şekil 4.4. Ağustos ayı YSA yöntemi ile eğitim verilerinin karşılaştırılması.

Şekil 4.3 de en iyi tahmin sonucu olan ağustos ayında test rüzgâr hızı gerçek değerleri 1,96-4,9 aralığında değişirken tahmin değerleri 2,51-3,54 aralığında değişmekte dolayısıyla tahmin eğrisi gerçek eğrisine çok yaklaşmamaktadır. Bu durumda bile Test OMYH % 18.1101 oranında iyi tahmin doğruluğu vermektedir.

Şekil 4.4 de en iyi tahmin sonucu olan ağustos ayında rüzgâr hızı eğitim gerçek değerleri 1,75-6,2 aralığında değişirken eğitim tahmin değerleri 2,33-4,36 aralığında değişmekte dolayısıyla eğitim tahmin eğrisi eğitim gerçek eğrisine çok yaklaşmamaktadır.

4.4. Radyal Tabanlı Sinir Ağları Sonuçları

Çizelge 4.6'ta Radyal Tabanlı sinir ağlarıyla yapılan tahmin sonuçları görülmektedir.

Çizelge 4.6. RTSA OMYH değerleri

Aylar	Ortalama Mutlak Yüzde Hata	
	Eğitim	Test
Ocak	44.9461	45.3311
Şubat	36.8775	38.8746
Mart	33.7461	31.2961
Nisan	31.9897	34.1854
Mayıs	27.7260	29.3939
Haziran	24.0299	26.0236
Temmuz	20.7718	21.5441
Ağustos	22.3835	22.2190
Eylül	21.3867	24.1544
Ekim	29.6684	30.0681
Kasım	40.7672	42.5065
Aralık	43.5577	46.0676
Yıllık	31,4876	32,6387

RTSA uygulaması MATLAB Neural Network Toolbox faydalanılarak yapılmıştır. Mardin Meteoroloji Enstitüsünden alınan 11 yıllık verinin % 81,6'sı eğitim , % 18,4'ü test amacıyla rastgele seçilmiştir. Oluşturulan ağda 3 adet giriş değişkeni (Günlük Ortalama Nem, Günlük Ortalama Basınç, Günlük Ortalama Sıcaklık) ile çıkış değişkeni olarak Mardin ili ortalama rüzgâr hızı değerleri kullanılmıştır. Oluşturulan ağda her bir model için en iyi sonuç veren eğitim fonksiyonları seçilmiştir. Yapılan denemelerde tekrar sayısı olarak 5000 değeri kullanılmıştır. Yayılma katsayısı (spread) deneme yanılma yoluyla en iyi sonuç veren değer seçilmiştir. Katmanda kullanılan nöron sayısı en düşük hatayı verecek şekilde seçilmiştir. Her bir ağ verilerin tamamını çapraz doğrulama yapabilmek için 5'er kez çalıştırılmıştır.


Çizelge 4.6'da görüldüğü üzere önceki yöntemlerde farklı olarak en iyi Temmuz ayında % 78,45 doğrulukla diğer aylara göre daha üstün tahmin sonucu görülmektedir. Temmuz ayı test verisi şekilde görüldüğü üzere rüzgâr hızı değişimleri diğer aylara göre daha dar aralıkta değişmektedir. Kullandığımız tahmin yöntemleri Yaz aylarında kış aylarına nazaran daha iyi sonuçlar vermektedir. Daha önce bahsettiğimiz üzere Yaz Kış aylarında mevsimsel değişimlere bağlı olarak kış aylarına nazaran daha doğrusal değişen sıcaklık, Basınç, Nem değerlerindeki değişimler rüzgâr hız tahmini için önemli etkenler arasına girmektedir. Çizelge 4.7'de Matlab toolbox'ta kullandığımız nöron sayısı, yayılma katsayısı ve eğitim fonksiyonları görülmektedir.

Şekil 4.5'te görüldüğü üzere en iyi tahmin ay sonucu olan Temmuz ayında gerçek değerler 1,91-6,89 aralığında değişirken tahmin değerleri 1,94-3,74 aralığında değişmekte dolayısıyla tahmin eğrisi gerçek eğrisine çok yaklaşmamaktadır. Bu durumda bile Test OMYH % 21,5441 oranında kabul edilebilir tahmin doğruluğu vermektedir.

Çizelge 4.7'de RTSA'da kullanılan parametreler görülmektedir. Her ay için kullanılan parametreler farklı olmak üzere nöron sayıları genelde giriş veri sayısı kadar verildiğinde en düşük hata sonucunu vermektedir. Yayılma değerleri çok yüksek belirlenmiş olup en iyi hata değeri verene kadar denenmiştir. Eğitim fonksiyonlarında deneme yanılma yoluyla tespit edilmiştir.

Çizelge 4.7. Matlab RTSA parametreleri


AYLAR	Yayıma Değeri	Nöron Sayısı	Eğitim fonksiyonu
Ocak	30900	279	trainlm
Şubat	36539	255	trainlm
Mart	31960	230	trainbfg
Nisan	11451	250	trainlm
Mayıs	15500	279	trainbr
Haziran	30409	270	traingda
Temmuz	14400	230	trainr
Ağustos	10000000000	235	traincgb
Eylül	3550.21	243	trainlm
Ekim	27555.001	279	traingda
Kasım	700059	270	trainlm
Aralık	27037.21	279	-



Şekil 4.5. Temmuz ayı RTSA yöntemi ile test verilerinin karşılaştırılması..

Şekil 4.6'ta görüldüğü üzere en iyi tahmin ay sonucu olan temmuz ayında eğitim gerçek değerleri 1,78-7,72 aralığında değişirken eğitim tahmin değerleri 1,67-4,58

aralığında değişmekte dolayısıyla eğitim tahmin eğrisi eğitim gerçek eğrisine çok yaklaşmamaktadır.



Şekil 4.6. Temmuz ayı RTSA Yöntemi ile eğitim verilerinin karşılaştırılması.

4.5. Kesin Radyal Tabanlı Sinir Ağları Sonuçları

Çizelge 4.8’de Kesin Radyal Tabanlı sinir ağlarıyla yaptığımız tahmin sonuçları görülmektedir. RTSA’nın Matlab tarafından daha geliştirilmiş türü olan KRTSA, Normal RTSA’ya göre daha hızlı ve birbirine benzer sonuçlar vermektedir. KRTSA MATLAB Neural Network Toolbox kullanılarak yapılmıştır. Mardin Meteoroloji Enstitüsünden alınan 11 yıllık verinin % 81,6’sı eğitim , % 18,4’ü test amacıyla rastgele seçilmiştir. Oluşturulan ağda 3 adet giriş değişkeni (Günlük Ortalama Nem, Günlük Ortalama Basınç, Günlük Ortalama Sıcaklık) ile çıkış değişkeni olarak Mardin ili ortalama rüzgâr hızı değerleri kullanılır Yapılan denemelerde tekrar sayısı olarak 5000 değeri kullanılmıştır. Yayılma katsayısı (spread) deneme yanılma yoluyla en iyi sonuç veren değer seçilmiştir. Bu yöntem nöron sayısı kullanıcı tarafından belirlenmeden ve eğitim fonksiyonu tanımlanmadan çalışmaktadır. Her bir ağ verilerin tamamını çapraz doğrulama yapabilmek amacıyla 5'er kez çalıştırılmıştır.

Çizelge 4.8. KRTSA OMYH değerleri

Aylar	Ortalama Mutlak Yüzde Hata	
	Eğitim	Test
Ocak	44.1459	45.2665
Şubat	37.0919	38.8268
Mart	34.0119	28.7663
Nisan	32.0844	33.8375
Mayıs	28.4312	29.2783
Haziran	24.2497	25.4426
Temmuz	20.7685	21.5033
Ağustos	22.0056	22.3975
Eylül	21.6272	23.5654
Ekim	30.8122	32.0716
Kasım	39.2822	41.7113
Aralık	42.5746	46.1326
Yıllık	31,4238	32,4000


Çizelge 4.8’de görüldüğü üzere önceki yöntemlerde farklı olarak en iyi Temmuz ayında % 78,49 doğrulukla diğer aylara göre daha üstün tahmin sonucu görülmektedir. Temmuz ayı test verisi şekilde görüldüğü üzere rüzgâr hızı değişimleri diğer aylara göre daha dar aralıkta değişmektedir. Kullandığımız tahmin yöntemleri yaz aylarında kış aylarına nazaran daha iyi sonuçlar vermektedir. Daha önce bahsettiğimiz üzere yaz kış aylarında mevsimsel değişimlere bağlı olarak kış aylarına nazaran daha doğrusal değişen sıcaklık, Basınç, Nem değerlerindeki değişimler rüzgâr hız tahmini için önemli etkenler arasına girmektedir. OMYH $< 10\%$ ise Yüksek tahmin doğruluğu, $10\% \leq \text{OMYH} \leq 20\%$ aralığında iyi tahmin doğruluğu, $20\% \leq \text{OMYH} \leq 50\%$ arası makul tahmin doğruluğu, OMYH $\geq 50\%$ ise yetersiz tahmin doğruluğunda yorumlanır (Ramasamy ve ark., 2015). Çizelge 4.9’de her ay için kullandığımız yayılma değerleri görülmektedir. RTSA yönteminde olduğu gibi yayılma değerleri çok yüksektir.

Çizelge 4.9. KRTSA Yayılma değerleri


AYLAR	Yayılma Değeri
Ocak	12989
Şubat	31000000
Mart	40000
Nisan	29700
Mayıs	19219990
Haziran	23100000
Temmuz	20100
Ağustos	64999895
Eylül	3550.21
Ekim	86902000
Kasım	23100
Aralık	9810

Şekil 4.7’de görüldüğü üzere en iyi tahmin ay sonucu olan temmuz ayında test gerçek değerleri 1,91-6,89 aralığında değişirken test tahmin değerleri 2,05-3,74 aralığında değişmekte RTSA ya göre tahmin aralığı daha dar aralıktadır. Bu durumda bile Test OMYH % 21,5033 oranında kabul edilebilir tahmin doğruluğu vermektedir.

Şekil 4.8’de görüldüğü üzere en iyi tahmin ay sonucu olan temmuz ayında eğitim gerçek değerleri 1,91-6,89 aralığında değişirken eğitim tahmin değerleri 2,05-3,74 aralığında değişmekte RTSA ya göre tahmin aralığı daha dar aralıktadır. Bu durumda bile Test OMYH % 21,5033 oranında kabul edilebilir tahmin doğruluğu vermektedir.



Şekil 4.7. Temmuz Ayı KRTSA yöntemi ile test verilerinin karşılaştırılması.



Şekil 4.8. Temmuz ayı KRTSA yöntemi ile eğitim verilerinin karşılaştırılması.

4.6. Genelleştirilmiş Regresyon Sinir Ağları Sonuçları

Çizelge 4.10'da GRSA ile yapılan tahmin sonuçları görülmektedir. GRSA uygulaması MATLAB Neural Network Toolbox kullanılarak yapılmıştır. Mardin Meteoroloji Enstitüsünden alınan 11 yıllık verinin % 81,6'sı eğitim , % 18,4'ü test amacıyla rastgele seçilmiştir. Oluşturulan ağda 3 adet giriş değişkeni (Günlük Ortalama Nem, Günlük Ortalama Basınç, Günlük Ortalama Sıcaklık) ile çıkış değişkeni olarak Mardin ili ortalama rüzgâr hızı değerleri kullanılmıştır. Yapılan denemelerde tekrar sayısı olarak 5000 değeri kullanılmıştır. Yayılma katsayısı (spread) deneme yanılma

yoluyla en iyi sonuç veren deęer seilmiřtir. Her bir aę verilerin tamamını apraz doęrulama yapabilmek amacıyla 5'er kez alıřtırılmıřtır. izelge 4.11'de her ay iin kullandıęımız yayılma deęerleri grlmektedir. Haziran ve Aęustos aylarının yayılma deęerleri ok yksek olup dięer ayların yayılma deęerleri 3,86-6,19 arasında olup birbirine yakındır.

izelge 4.10. GRSA OMYH deęerleri

Aylar	Ortalama Mutlak Yzde Hata	
	Eęitim	Test
Ocak	41.7061	46.3790
řubat	33.0913	44.8909
Mart	31.2549	34.7513
Nisan	31.4517	34.6211
Mayıs	27.4096	28.9074
Haziran	25.6236	27.2773
Temmuz	19.8102	20.8553
Aęustos	22.6991	22.4870
Eyll	21.3551	24.1880
Ekim	27.7609	29.5333
Kasım	38.5698	41.7473
Aralık	39.8874	46.0254
Yıllık	30,0516	33,4719

izelge 4.1'de GRSA iin kullanılan yayılma deęerleri grlmektedir. RTSA ve KRTSA yntemlerinin yayılma deęerleri ile karřılařtırıldıęında GRSA 'da byk oranda dřř gstermektedir. En yksek yayılma deęerleri haziran ve aęustos aylarında 7093 ve 1408 olup dięer ayların yayılma deęerleri 3,86-6,19 arasındadır.


Çizelge 4.11. GRSA Yayılma değerleri

AYLAR	Yayımla Değeri
Ocak	4.7
Şubat	4.6
Mart	4.4
Nisan	6.19
Mayıs	5.1
Haziran	7093
Temmuz	3.86
Ağustos	1408
Eylül	4.5
Ekim	4.617
Kasım	5.51
Aralık	4.4


Çizelge 4.10'da görüldüğü üzere önceki yöntemlerde farklı olarak en iyi Temmuz ayında % 79,15 doğrulukla diğer aylara göre daha üstün tahmin sonucu görülmektedir. Temmuz ayı test verisi şekilde görüldüğü üzere rüzgâr hızı değişimleri diğer aylara göre daha dar aralıkta değişmektedir. Kullandığımız tahmin yöntemleri Yaz aylarında kış aylarına nazaran daha iyi sonuçlar vermektedir. Daha önce bahsettiğimiz üzere yaz kış aylarında mevsimsel değişimlere bağlı olarak kış aylarına nazaran daha doğrusal değişen sıcaklık, basınç, nem değerlerindeki değişimler rüzgâr hız tahmini için önemli etkenler arasına girmektedir.

Şekil 4.9'dan görüldüğü üzere en iyi tahmin sonucu olan temmuz ayında test gerçek değerleri 1,91-6,89 aralığında değişirken test tahmin değerleri 2,56-3,71 aralığında değişmekte önceki radyal tabanlı yöntemlere göre tahmin aralığı daha dar aralıktadır. Bu durumda bile Test OMYH % 20.8556 oranında kabul edilebilir tahmin doğruluğu vermektedir.

Şekil 4.10'da görüldüğü üzere en iyi tahmin sonucu olan temmuz ayında test gerçek değerleri 1,78-7,72 aralığında değişirken test tahmin değerleri 2,31-4,23 aralığında değişmekte önceki radyal tabanlı yöntemlere göre tahmin aralığı daha dar aralıktadır.



Şekil 4.9. Temmuz ayı GRSA yöntemi ile test verilerinin karşılaştırılması.



Şekil 4.10. Temmuz ayı GRSA yöntemi ile eğitim verilerinin karşılaştırılması.

4.7. Tekrarlı Sinir Ağları Sonuçları

Çizelge 4.12’de TSA yöntemiyle yapılan tahmin sonuçları görülmektedir. TSA uygulaması MATLAB Neural Network Toolbox kullanılarak yapılmıştır. Verilerin eğitiminde, gizli katmanlar, gizli katmanlardaki nöron sayıları, nöronların ağırlık katsayıları, eğitim ve transfer fonksiyonları her ay için farklılık göstermektedir. Bu parametreler deneme yanılma yoluyla aylık verilerde en iyi hata oranına göre seçilmiştir. Mardin Meteoroloji Enstitüsünden alınan 11 yıllık verinin % 81,6’sı eğitim , % 18,4’ü test amacıyla rastgele seçilmiştir. Oluşturulan ağda 3 adet giriş değişkeni (Günlük Ortalama Nem, Günlük Ortalama Basınç, Günlük Ortalama Sıcaklık) ile çıkış değişkeni olarak Mardin ili ortalama rüzgâr hızı değerleri kullanılmıştır. Yapılan denemelerde tekrar sayısı olarak 5000 değeri kullanılmıştır. Her bir ağ istatistiksel doğrulama amacıyla 30’ar kez çalıştırılmıştır. Çizelge 4.13’te TSA için matlab toolbox’da kullandığımız parametreler görülmektedir.

Çizelge 4.12 TSA OMYH değerleri


Aylar	Ortalama Mutlak Yüzde Hata	
	Eğitim	Test
Ocak	41.6426	39.8372
Şubat	31.1983	30.5659
Mart	30.7430	30.4711
Nisan	29.2182	25.0437
Mayıs	28.0708	23.6064
Haziran	24.5527	26.2418
Temmuz	21.4600	24.7067
Ağustos	25.7166	17.8679
Eylül	21.6657	24.8331
Ekim	27,8408	26,4651
Kasım	31.7093	38.5837
Aralık	38.4240	34.7518
Yıllık	29,3535	28,5812

Çizelge 4.13 Matlab TSA parametreleri

AYLAR	Katman sayısı	Nöron sayıları	Ağırlık katsayısı	Eğitim fonksiyonu
Ocak	1	9	1:127	traingda
Şubat	1	9	1	traingda
Mart	1	9	1:22	traingda
Nisan	1	9	1:487	traingda
Mayıs	1	9	1:2	trainlm
Haziran	1	15	1:2	traingda
Temmuz	71	9:79	1	traincgb
Ağustos	1	7	122	Traingd
Eylül	1	35	1	Trainbr
Ekim	17	11:27	1	traingda
Kasım	4	7:10	3:10	traingda
Aralık	1	7	1	traingda


Çizelge 4.12’de görüldüğü üzere regresyon yönteminde benzer şekilde en iyi ağustos ayında % 82,13 doğrulukla diğer aylara göre daha üstün tahmin sonucu görülmektedir. Ağustos ayı test verisi şekilde görüldüğü üzere rüzgâr hızı değişimleri diğer aylara göre daha dar aralıkta değişmektedir. Kullandığımız tahmin yöntemleri Yaz aylarında kış aylarına nazaran daha iyi sonuçlar vermektedir. Daha önce bahsettiğimiz üzere Yaz Kış aylarında mevsimsel değişimlere bağlı olarak kış aylarına nazaran daha doğrusal değişen sıcaklık, Basınç, Nem değerlerindeki değişimler rüzgâr hız tahmini için önemli etkenler arasına girmektedir. Rüzgâr Hızı tahmin yöntemlerinde OMYH % 25 ile % 40 arasında değişmektedir (Wang ve ark., 2014; Wang ve ark., 2015; Zhang ve ark., 2013; Guo ve ark., 2012; Su ve ark., 2014).

Şekil 4.11 den görüldüğü üzere en iyi tahmin ay sonucu olan ağustos ayında gerçek değerler 1,96-4,9 aralığında değişirken tahmin değerleri 2,83-3,59 aralığında değişmekte önceki radyal tabanlı yöntemlere göre tahmin aralığı daha dar aralıktadır. Bu durumda bile Test OMYH % 17.8679 oranında iyi tahmin doğruluğu vermektedir.



Şekil 4.11. Ağustos ayı TSA yöntemi ile test verilerinin karşılaştırılması.

Şekil 4.12 den görüldüğü üzere en iyi tahmin ay sonucu olan Ağustos ayında gerçek değerler 1,75-6,72 aralığında değişirken tahmin değerleri 3,33-3,53 aralığında değişmekte önceki radyal tabanlı yöntemlere göre tahmin aralığı daha dar aralıktadır.



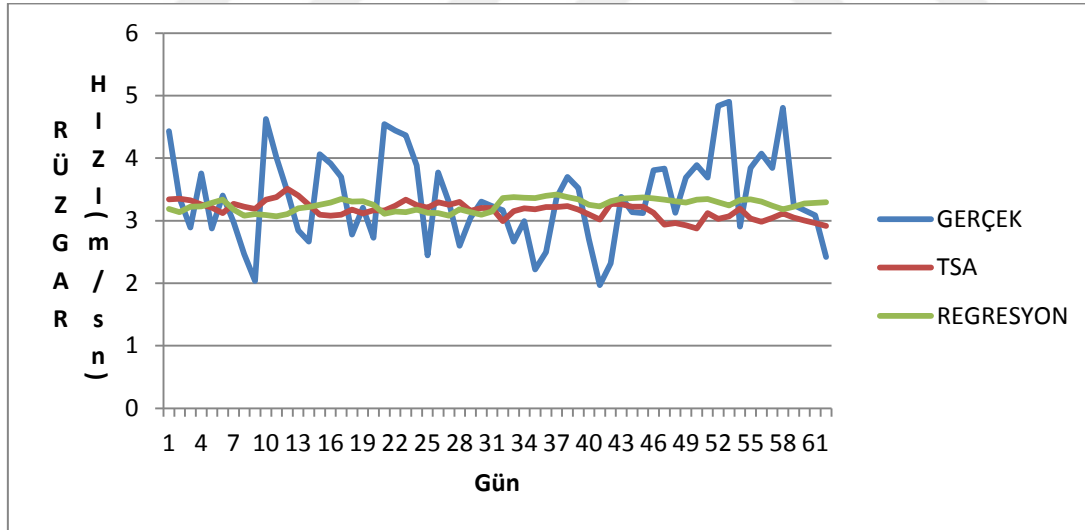
Şekil 4.12. Ağustos ayı TSA yöntemi ile eğitim verilerinin karşılaştırılması.

4.8. Genel Değerlendirme

Çizelge 4.14 Yıllık OMYH değerlerinin karşılaştırılması

Yöntem	Yıllık Ortalama Mutlak Yüzde Hata	
	Eğitim	Test
İBYSA	29,0374	30,4229
Regresyon	28,0913	28,9492
RTSA	31,4876	32,6387
KRTSA	31,4238	32,4000
GRSA	30,0516	33,4719
TSA	29,3535	28,5812

Kullanılan yöntemlerin Yıllık ortalamalara göre hata performanslarını incelediğimizde OMYH değerlerinin birbirine yakın olduğu gözlenmektedir. En iyi iki yöntemin Regresyon ve TSA yöntemi olduğu görülmektedir.



Şekil 4.13. Ağustos ayı regresyon ve TSA yöntemlerinin karşılaştırılması.

Şekil 4.13’de görüldüğü üzere kullandığımız yöntemlerden en iyi sonuç veren aylardan olan ağustos ayı rüzgâr hızı değişimi çok istikrarsızdır. Rüzgâr Hızını tahmin etmek için kullandığımız yöntemlerden en iyi iki tanesi olan TSA ve Regresyon Analizinde bulunan rüzgâr hızı değerleri gerçek rüzgâr hızı değerleriyle tam olarak

örtüşmemekte ve tahmin etmekte zorlanmaktadır. Radyal tabanlı yöntemler olan RTSA, KRTSA ve GRSA'da verinin tamamı eğitim olarak verildiğinde uygun yayılma değerleriyle eğitim ve test hataları sıfıra yaklaşırken, yöntemlerden bilinmeyen bir veri tahmin etmesi istendiğinde eğitim ve test hataları % 70'lerin üzerine çıkmakta sağlıklı bir tahmin yapamamaktadır.



5. TARTIŞMA VE SONUÇ

Bu çalışmada Regresyon, İBYSA, GRSA, RTSA, KRTSA ve TSA modelleri uzun vadeli rüzgâr hızını tahmin etmek için denenmiştir. Bu modellerin eğitim, test ve tahmin aşaması için gerekli veriler Mardin Meteoroloji istasyonundan alınmıştır. Bu veriler Gün Süresi, Günlük Ortalama Basınç, Günlük Ortalama Nem, Toprak Sıcaklığı 50 Cm, Toprak Sıcaklığı 20 Cm, Toprak Sıcaklığı 5 Cm, Toprak Sıcaklığı 10 Cm, Ortalama Sıcaklık, Sıcaklık Farkı, Günlük Toplam Güneşlenme Süresi, Günlük Yağış Toplamıdır. Bu veriler değişik gruplamalarda denenerek rüzgâr hızını tahmin etmek için en etkili faktörler olarak Günlük ortalama sıcaklık, bağıl nem ve basınç verileri seçilmiştir. Veriler 2000 ve 2010 yılları arasında 11 yıllık bir süreyi kapsamaktadır. 2000-2008 verileri referans alınarak 2009-2010 yılı rüzgâr hızları tahmin edilmeye çalışılmıştır. Her yılın aynı ayları gruplandırılmıştır. Veriler 9/11'i eğitim kalan 2/11'i test için ayrılmıştır. Regresyon analizinde giriş ve çıkış değişkenleri 5 katlı çapraz doğrulamaya tabi tutularak yöntemin güvenilirliği denenmiş test ve eğitim en küçük OMYH değerleri hesaplanmıştır. YSA'da en iyi sonuç veren gizli katman sayısı, gizli katmanlarda bulunan nöron sayısı, eğitim ve transfer fonksiyonları seçilerek rüzgâr hızı tahmin edilmeye çalışılmış, tahmin yönteminin istatistiksel doğrulaması için YSA yöntemi otuz defa tekrarlanarak test ve eğitim en küçük OMYH değerleri hesaplanmıştır. RTSA da en düşük hatayı verecek şekilde nöron tanımlanarak, uygun spread (yayılma) katsayısı belirlenerek ve en uygun eğitim fonksiyonu belirlenmiş ve 5 katlı çapraz doğrulamaya tabi tutularak en küçük OMYH değerleri bulunmuştur. GRSA ve KRTSA yöntemlerinde nöron sayısı belirlenmeden yalnızca en uygun spread (yayılma) parametresi belirlenerek ve 5 katlı çapraz doğrulamaya tabi tutularak yöntemin güvenilirliği denenmiş test ve eğitim en küçük OMYH değerleri bulunmuştur. TSA'da en iyi sonuç veren gizli katman sayısı, gizli katmandaki nöron sayısı, nöronların ağırlık katsayıları ve eğitim fonksiyonları seçilerek rüzgâr hızı tahmin edilmeye çalışılmış, tahmin yönteminin istatistiksel doğrulaması için TSA yöntemi otuz defa tekrarlanarak test ve eğitim en küçük OMYH değerleri bulunmuştur. Akademik dünyada çok iyi rüzgâr hızı tahmin başarısı elde edenler olduğu gibi yaptığımız çalışmaya benzer sonuçta olan ve literatürde kabul edilmiş çalışmalar mevcuttur. Örneğin Wang ve ark. (2015)

yaptıkları çalışmada ARİMA, en küçük kare destek vektör makinesi (LSSVM), en küçük kare destek vektör makinesi-benzetilmiş tavlama dayanan bir parçacık sürüsü optimizasyonu modeli (LSSVM-POSA) ve Dalgacık Paket Dönüşümü-en küçük kare destek vektör makinesi-benzetilmiş tavlama dayanan bir parçacık sürüsü optimizasyonu modeli (WT-LSSVM-POSA) metotlarıyla OMYH değerleri % 18,42 ile % 32,59 arasında bulmuşlardır. Palomares-Salas ve ark. 2013'te yaptıkları çalışmada kullandıkları YSA, RTSA, ANFİS ve elman sinir ağı (ELM) rüzgâr hızı tahmin metotlarıyla hesapladıkları OMYH değerleri % 36,96 ile % 49,84 arasında değişmektedir. Songlin ve ark., 2010'da yaptıkları çalışmada dalgacık –destek vektör makinesi (W-SVM) analizi ve destek vektörü makinesi (SVM) rüzgâr hızı tahmin metotlarıyla buldukları OMYH değerleri % 4,28 ile % 74,85 arasında değişmektedir. Zhou ve ark. 2012 de yaptıkları çalışmada parametrik olmayan çekirdek yoğunluğu tahminine dayalı rüzgâr hızı tahmin metoduyla hesapladıkları OMYH değerleri % 27,240 ile % 35,20 arasında değişmektedir. Zhang ve ark. 2012'de yaptıkları çalışmada birinci dereceden uyarlanırlı katsayılı (FAC), ikinci dereceden uyarlanırlı katsayılı (SAC), Parçacık Sürü Optimizasyonu birinci dereceden uyarlanırlı katsayılı (PFAC), Parçacık Sürü Optimizasyonu ikinci dereceden uyarlanırlı katsayılı (PSAC), Mevsimsel üstel ayar birinci dereceden uyarlanırlı katsayılı (SPFAC) ve Mevsimsel üstel ayar ikinci dereceden uyarlanırlı katsayılı (SPSAC) rüzgâr hız tahmin yöntemleriyle hesapladıkları OMYH değerleri % 17,11 ile % 52,63 arasında değişmektedir. Qin ve ark. 2016 yılında yaptıkları çalışmada yumuşak geçiş periyodik otoregresif (SPT)-elman sinir ağı (ESA) hibrit rüzgâr hızı tahmin metoduyla hesapladıkları OMYH değerleri % 19,25 ile % 33,4 arasında değişmektedir. Liu ve arkadaşları 2019 yılında yaptıkları çalışmada Ayrık dalgacık dönüşümü (DWT)-uzun kısa süreli bellek ağları (LSTM) hibrit rüzgâr hızı tahmin metoduyla hesapladıkları OMYH değerleri % 11,73 ile % 45,57 arasında değişmektedir. Çizelge 5.1'de bu araştırmacıların yaptıkları çalışmaların bilgileri gösterilmektedir.

Çizelge 5.1 Farklı rüzgâr hızı tahmin teknolojileri kullanan araştırmacılar

Yayın (Araştırmacılar)	Veri Boyutu	Veri Bölgesi	Kullanılan Yöntemler	OMYH Aralığı
A hybrid wind speed forecasting model based on phase space reconstruction theory and Markov model: A case study of wind farms in northwest China (Wang ve ark., 2015)	6 yıl	Zhangye, Wuwei, Jiuquane, Mazong dağı	ARİMA, LSSVM, LSSVM- POSA,WT- LSSVM-POSA	% 18,42-% 32,59
A novel neural network method for wind speed forecasting using exogenous measurements from agriculture stations (Palomares-Salas ve ark., 2013)	1 yıl	Kuzey Endülüs (Peñaflor, Sevilla, İspanya)	YSA, RTSA, ANFİS, ELM	% 36,96- % 49,84
Forecasting of wind speed based on waveletanalysis and support vector machine (Songlin ve ark., 2010)	1 ay	Rüzgâr çiftliği	Parametrik olmayan çekirdek tahmin yöntemi	% 4,28 - % 74,85
Short-term wind speed forecasting based on non-parametric kernel density estimation (Zhou ve ark., 2012)	285 gün	Belirtilmemiş	W-SVM, SVM	% 27,24 - %35,2
Performance analysis of four approaches for wind speed forecasting (Zhang ve ark., 2012)	6 yıl	Jiuquan, Mazongshan, Wuwei ve Zhangye	FAC, SAC, PFAC PSAC, SPFAC SPSAC	% 17,11-%52,63
A hybrid model based on smooth transition periodic autoregressive and Elman artificial neural network for wind speed forecasting of the Hebei region in China (Qin ve ark.,2016)	9 yıl	Çin Hebei bölgesi	SPT-ESA	% 19,25- % 33,4
Wind Power Short-Term Prediction Based on LSTM and Discrete Wavelet Transform (Liu ve ark., 2019)	1 yıl	Moğolistan, Hollanda ve Çin'in Yunnan'daki rüzgâr çiftlikleri	DWT)-uzun kısa süreli bellek ağları (LSTM) hibrit	% 11,73-% 45,57

Bu çalışmada rüzgâr hızının gelecek yıllardaki değerlerinin tespiti için bir model oluşturulmuştur. Bu model kullanılarak rüzgâr üretim sistemlerinden temin edilecek enerjinin önceden hesaplanması, enerji güvenilirliğinin yükselmesi ve sistemi etkileyebilecek rüzgâr kaynaklı arıza ve yıpranmaların önceden tespit edilmesi, böylece sistem sağlamlığının arttırılabilmesi sağlanabilecektir. Rüzgâr enerjisi endüstrisi bu ve benzeri çalışmalar sayesinde daha güvenilir enerji arzı yapılabilecek, rüzgâr üretim tesislerindeki türbinlerin çalışma güvenliği arttırarak olası kazaların önüne geçilebilecek ve ayrıca en üst seviyede enerji piyasasında oluşabilecek ani iniş çıkışların öngörülebilmesine imkân sağlanacaktır.

Çalışmada Mardin ilinin basınç, sıcaklık, nem değerleri rüzgâr hız tahmininde kullanılmasına rağmen aynı metot ile değişik bir bölgenin günlük ortalama basınç, sıcaklık, nem değerleriyle rüzgâr hız tahmini yapılabilir. Ayrıca rüzgâr enerjisini kullanan teknolojilere, değişmekte olan atmosferik şartlara hızla uyumun sağlanması hedeflenmektedir. Bununla beraber, rüzgâr gibi düzensiz ve değişken bir veri yapısı için regresyon ve sinir ağı modellerinin kullanım alanları açısından herhangi bir kısıtlama görülmemektedir. Daha kararlı yapılara sahip meteorolojik verilerin kullanılmasıyla, veri grupları için iyi bir sınıflandırma yapılarak, geliştirilen hibrit tahmin metotları, günümüzde dikkatle izlenen ve her geçen gün geliştirilmekte olan yapay zekâ teknolojileri ve daha hızlı algoritmalarla çalışan bilgisayar sistemleriyle çok daha başarılı rüzgâr hızı tahmin sonuçları elde edilebileceği düşünülmektedir. Bu bulgular, rüzgâr hızı tahmini ile ilgili araştırmalar için önemli olabilir ve gelecekte takip eden çalışmaları motive edecektir.

KAYNAKLAR

- Akataş, N. 2013., *Kısa Süreli Rüzgâr Tahmini için WRF Model Performansının Analizi ve Rüzgâr Gücü Uygulamaları* (Yüksek Lisans tezi). İTÜ, Fen Bilimleri Enstitüsü, İstanbul
- Akçay, H., & Filik, T. 2017. Short-term wind speed forecasting by spectral analysis from long-term observations with missing values. *Applied Energy*, **191**:653-662.
- Akinci, T. C., 2011. Short term wind speed forecasting with ANN in Batman, *Turkey Elektronika ir Elektrotehnika*, **107**(1): 41-45.
- Akinci, T. C., & Nogay, H. S., 2012. Wind speed correlation between neighboring measuring stations. *Arabian Journal for Science and Engineering*, **37**(4): 1007-1019.
- Akyazı Ö., Zenk H., Akpınar A. S., 2011. Farklı bulanık üyelik fonksiyonları kullanarak sürekli miknatıslı da motorunun hız denetiminin gerçekleşmesi, *6th International Advanced Technologies Symposium*, 16-18 May 2011, Elazığ, Türkiye,.
- Alcı, M., & Karatepe, E., 2002. *Bulanık Mantık ve MATLAB Uygulamaları*. 1.Baskı, İzmir, Bornova,
- Alp, M., Cıgızoğlu, H. K., 2004. Farklı yapay sinir ağı metotları ile yağış-akış ilişkisinin modellenmesi, *İTÜ Dergisi/d Mühendislik*, **3** (1): 80-88.
- Altaş, İ. H., 1999. Bulanık Mantık: Bulanıklık Kavramı. *Enerji, Elektrik, Elektromekanik-3e*, 62: 80-85.
- Akpınar, Haldun, 1993. “*Yapay Sinir Ağları ve Kredi Taleplerinin Değerlendirilmesinde Bir Uygulama*”, İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul
- Altuntaş, Y., Kocamaz, A. F., Cengiz, R., & Esmeray, M., 2018. Classification Of haploid and diploid maize seeds by using image processing techniques and support vector machines. *In 2018 26th Signal Processing and Communications Applications Conference (SIU)* .1-4. May 2018.
- An, S., Shi, H., Hu, Q., Li, X., & Dang, J., 2014. Fuzzy rough regression with application to wind speed prediction. *Information Sciences*, **282**: 388-400.
- Assareh, E., Behrang, M. A., Ghalambaz, M., Noghrehabadi, A. R., & Ghanbarzadeh, A., 2012. An analysis of wind speed prediction using artificial neural networks: a case study in Manjil, Iran. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, **34**(7): 636-644.
- Ata, R. And Kocyigit, Y., 2010. An adaptive neuro-fuzzy inference system approach for prediction of tip speed ratio in wind turbines. *Expert Systems with Applications*. **37** (7): 4725-5532
- Ayodele, T. R., & Ogunjuyigbe, A. S. O., 2017. Prediction of wind speed for the estimation of wind turbine power output from site climatological data using artificial neural network. *International Journal of Ambient Energy*, **38**(1): 29-36.
- Azad, H. B., Mekhilef, S., & Ganapathy, V. G., 2014. Long-term wind speed forecasting and general pattern recognition using neural networks. *IEEE Transactions on Sustainable Energy*, **5**(2):546-553.
- Azeem, A., Kumar, G., & Malik, H., 2016. Application of Waikato environment for knowledge analysis based artificial neural network models for wind speed

- forecasting. *In 2016 IEEE 7th Power India International Conference (PIICON)* November 2016. 1-6.
- Bilgiç HH., Mert İ., Karakuş C., Yapıcı A., 2016. Antakya Bölgesi rüzgâr hızı verisinin yapay sinir ağı ve çoklu lineer regresyon yaklaşımı yöntemleri ile tahmini, *Elektrik-Elektronik ve Bilgisayar Sempozyumu*, 11 - 13 Mayıs 2016
- Bhatia, N. and Vandana., 2010. Survey of nearest neighbor techniques. *International Journal of Computer Science and Information Security*. **8**(2):302-305.
- Bianchini, M., Frasconi, P., Gori, M., 1995. Learning without local minima in radial basis function networks. *IEEE Transactions on Neural Networks*, **6** (3): 749-755.
- Bolat, S., Kalenderli, Ö. ve Önal, E., 2004, “Yapay sinir ağı ile gaz karışımında elektrot açıklığına ve karışım yüzdelere bağlı olarak delinme gerilimlerinin belirlenmesi”, *Akıllı Sistemlerde Yenilikler ve Uygulamaları Sempozyumu*, Yıldız Teknik Üniversitesi Elektrik-Elektronik Fakültesi
- Broomhead, D., Lowe, D., 1988. Multivariable Functional Interpolation and Adaptive Networks, *Complex Systems*, **2**(6): 568-576.
- Cetişli, B., 2005. *El Yazısı Karakter Tanıma: Dalgacık Moment Özniteliklerinin Yenilenen ANFIS İle Sınıflandırılması.*, Doktora Tezi, EOÜ, Fen Bilimleri Enstitüsü, Eskişehir
- Chang, W. Y., 2014. A literature review of wind forecasting methods. *Journal of Power and Energy Engineering*, **2**(4).
- Chang, G. W., Lu, H. J., Chang, Y. R., & Lee, Y. D., 2017. An improved neural network-based approach for short-term wind speed and power forecast. *Renewable energy*, **105**: 301-311.
- Chen, L., & Lai, X., 2011. Comparison between ARIMA and ANN models used in short-term wind speed forecasting. *In 2011 Asia-Pacific Power and Energy Engineering Conference*. March 2011, 1-4
- Chen, Q., & Folly, K. A., 2018. Comparison of three methods for short-term wind power forecasting. *In 2018 International Joint Conference on Neural Networks (IJCNN)*, 1-8. 2018 July, IEEE.
- Chen, K., & Yu, J., 2014. Short-term wind speed prediction using an unscented Kalman filter based state-space support vector regression approach. *Applied Energy*, **113**: 690-705.
- Cover, T.M. and Hart, P.E., 1967. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*. IT, **13**(1):21–27.
- Douak, F., Benoudjit, N., & Melgani, F., 2013. Design of a multiblock general regression neural network for wind speed prediction in Algeria. *In 2013 8th International Workshop on Systems, Signal Processing and their Applications (WoSSPA)*. 2013 May. 390-395. IEEE
- Duran, M. A., & Filik, Ü. B., 2015. Short-term wind speed prediction using several artificial neural network approaches in Eskişehir. *In 2015 International Symposium on Innovations in Intelligent Systems and Applications (INISTA)* 1-4., 2015 September. IEEE.
- Esandal H, 2007. *Eğirdir Gölü Su Seviyesi Mevsimsel Değişiminin Bulanık Mantık Metoduyla Modellenmesi*, Yüksek Lisans Tezi, SDÜ, Fen Bilimleri Enstitüsü, Isparta,

- Erkmen, B., 2006. *Bir Bölgenin Elektromagnetik Alan Şiddeti Haritasının Yapay Sinir Ağları Kullanılarak Çıkarılması*, Yüksek Lisans Tezi, YTÜ, Fen Bilimleri Enstitüsü, İstanbul,
- Ertuğrul, İ., 2006. Akademik Performans Değerlendirme Bulanık Mantık Yaklaşımı, *Atatürk Üniversitesi İktisadi İdari Bilimler Fakültesi*, **20**(1): 155-176,
- Fazelpour, F., Tarashkar, N., & Rosen, M. A., 2016. Short-term wind speed forecasting using artificial neural networks for Tehran, Iran. *International Journal of Energy and Environmental Engineering*, **7**(4), 377-390.
- Filik, Ü. B., & Filik, T., 2017. Wind speed prediction using artificial neural networks based on multiple local measurements in Eskisehir. *Energy Procedia*, **107**: 264- 269.
- Guo, Z. H., Wu, J., Lu, H. Y., & Wang, J. Z., 2011. A case study on a hybrid wind speed forecasting method using BP neural network. *Knowledge-based systems*, **24**(7): 1048-1056
- Guo, Z., Zhao, W., Lu, H., & Wang, J., 2012. Multi-step forecasting for wind speed using a modified EMD-based artificial neural network model. *Renewable Energy*, **37**(1):241-249.
- Güler O. 2005. Dünyada ve Türkiye’ de Rüzgâr Enerjisi. *V. Enerji Sempozyumu*, 161-167, Ankara, Turkey
- Gün, A., 2007. *Yetersiz Uyarımlı Bir Elektromekanik Sistem Gerçeklenmesi ve Denetimi*, Doktora Tezi, EOÜ, Fen Bilimleri Enstitüsü, Eskişehir
- Han, J. and Kamber, M., 2006. Data mining: concepts and techniques. *Morgan Kaufmann Publishers*, Burlington.
- Han, Q., Meng, F., Hu, T., & Chu, F., 2017. Non-parametric hybrid models for wind speed forecasting. *Energy Conversion and Management*, **148**: 554-568.
- Hu, Q., Zhang, R., & Zhou, Y., 2016. *Transfer learning for short-term wind speed prediction with deep neural networks*. *Renewable Energy*, **85**: 83-95.
- Huang, C. M., Kuo, C. J., & Huang, Y. C., 2017. Short-term wind power forecasting and uncertainty analysis using a hybrid intelligent method. *IET Renewable Power Generation*, **11**(5): 678-687.
- Huang, C. J., & Kuo, P. H., 2018. A short-term wind speed forecasting model by using artificial neural networks with stochastic optimization for renewable energy systems. *Energies*, **11**(10):2777.
- Karmakar, S., Kowar, M. K., VE Guhat- Hakurta, P., 2009. Long- Range Mon-Soon, *Rainfall Pattern Recognition and Prediction for the Subdivision EPMB*, IEEE Computer Society, 367-370
- Kani, S. P., & Ardehali, M. M., 2011. Very short-term wind speed prediction: A new artificial neural network–Markov chain model. *Energy Conversion and Management*, **52**(1):738-745.
- Kaynar, O, Zontul, M Demirkoporan, F., 2016. Som Destekli Rbf Yapay Sinir Ağları İle Ankara İlinin Doğalgaz Tüketim Tahmini. *Trakya Üniversitesi Fen Bilimleri Dergisi*, **11** (1), 41-49.
- Khosravi, A., Koury, R. N. N., Machado, L., & Pabon, J. J. G., 2018. Prediction of wind speed and wind direction using artificial neural network, support vector regression and adaptive neuro-fuzzy inference system. *Sustainable Energy Technologies and Assessments*, **25**: 146-160.
- Kılıç, B, Arabacı, E ., 2016. Burdur İli Gelecekteki Rüzgâr Hızı Değerlerinin Yapay Sinir Ağları Metodu İle Tahmini. *Dumlupınar Üniversitesi Fen Bilimleri*

- Enstitüsü Dergisi*, (2015 Özel Sayısı):45- 50.
- Kılıç, S., 2013. Doğrusal Regresyon Analizi. *Journal of Mood Disorders*, 3(2), 90-92.
- Kirbas, I., & Kerem, A., 2016. Short-term wind speed prediction based on artificial neural network models. *Measurement and Control*, 49(6):183-190.
- Koo, J., Han, G. D., Choi, H. J., & Shim, J. H., 2015. Wind-speed prediction and analysis based on geological and distance variables using an artificial neural network: A case study in South Korea. *Energy*, 93: 1296-1302.
- K.P. Moustris, D. Zafirakis, K.A. Kavvadias, J.K. Kaldellis, 2016. "Wind power forecasting using historical data and artificial neural networks modeling", *10th Mediterranean Conference on Power Generation Transmission Distribution and Energy Conversion (MedPower)*, 6–9 November 2016.
- Kresse, W. and Danko, D.M., 2012. *Springer Handbook of Geographic Information*. Springer-Verlag, Berlin.
- Kumar, G., & Malik, H., 2016. Generalized regression neural network based wind speed prediction model for western region of India. *Procedia Computer Science*, 93:26- 32.
- Lee, C. Y., & He, Y. L., 2012. Wind prediction based on general regression neural network. *In 2012 Second International Conference on Intelligent System Design and Engineering Application*, 617-620. 2012 January. IEEE.
- Lee, J., Park, G. L., Kim, E. H., Kim, Y. C., & Lee, I. W., 2012. Wind speed modeling based on artificial neural networks for Jeju area. *International Journal of Control and Automation*, 5(2): 81-88.
- Li, G., & Shi, J., 2010. *On comparing three artificial neural networks for wind speed forecasting*. *Applied Energy*, 87(7): 2313-2320.
- Maatallah, O. A., Achuthan, A., Janoyan, K., & Marzocca, P., 2015. Recursive wind speed forecasting based on Hammerstein Auto-Regressive model. *Applied energy*, 145: 191-197.
- Liu, Y., Guan, L., Hou, C., Han, H., Liu, Z., Sun, Y., & Zheng, M., 2019. Wind Power Short-Term Prediction Based on LSTM and Discrete Wavelet Transform. *Applied Sciences*, 9(6): 1108.
- Liu, H., Tian, H. Q., & Li, Y. F., 2012. Comparison of two new ARIMA-ANN and ARIMA-Kalman hybrid methods for wind speed prediction. *Applied Energy*, 98:415-424.
- Liu, H., Chen, C., Tian, H. Q., & Li, Y. F., 2012. A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks. *Renewable Energy*, 48: 545-556.
- Liu, T., Liu, S., Heng, J., & Gao, Y., 2018. A new hybrid approach for wind speed forecasting applying support vector machine with ensemble empirical mode decomposition and cuckoo search algorithm. *Applied Sciences*, 8(10):1754.
- Lu, H., Heng, J., & Wang, C. , 2017. An AI-Based Hybrid Forecasting Model for Wind Speed Forecasting. *In International Conference on Neural Information Processing*. 221-230. 2017 November. Springer, Cham.
- Luna, J., Gros, S., Geisler, J., Falkenberg, O., Noga, R., & Schild, A., 2018. Super-short Term Wind Speed Prediction based on Artificial Neural Networks for Wind Turbine Control Applications. *In IECON 2018-44th Annual Conference of the IEEE Industrial Electronics Society*, 2018 October, 1952-1957, IEEE.

- Minaz.,M.R., 2011. *Bilecik İlinin Uyarlanırsinir Bulanık Çıkarım Sistemi İle Basınç, Sıcaklık ve Rüzgâr Hızı Tahmini*, Yüksek Lisans tezi, BŞEÜ. Fen Bilimleri Enstitüsü, Bilecik.
- Minaz, M. R., Ayhan, G. Ü. N., Kurban, M., & Nazım, İ. M. A. L., 2011. Bilecik İlinin Farklı Yöntemler Kullanılarak Basınç, Sıcaklık ve Rüzgâr Hızı Tahmini. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, **3**:100-111.
- Mitchell, T., 1997. *Machine Learning*, McGraw Hill, New York.
- Mohammadi, K., Shamsirband, S., Yee, L., Petković, D., Zamani, M., & Ch, S., 2015. Predicting the wind power density based upon extreme learning machine. *Energy*, **86**: 232-239.
- Moreno, S. R., & dos Santos Coelho, L., 2018. Wind speed forecasting approach based on singular spectrum analysis and adaptive neuro fuzzy inference system. *Renewable energy*, **126**:736-754.
- Mori, H., & Okura, S., 2017. Application of S-transform-based artificial neural network to wind speed forecasting. *In 2017 IEEE Manchester PowerTech*. 1-6. 2017 June. IEEE.
- Noorollahi, Y., Jokar, M. A., & Kalhor, A., 2016. Using artificial neural networks for temporal and spatial wind speed forecasting in Iran. *Energy Conversion and Management*, **115**: 17-25.
- Ocakoğlu, G., 2006. *Lojistik regresyon analizi ve yapay sinirağları tekniklerinin sınıflama özelliklerinin karşılaştırılması ve bir uygulama*.(Yayınlanmış yüksek lisans tezi), UÜ, Sağlık Bilimleri Enstitüsü, Bursa.
- Okkan, U , Dalkılıç, H ., 2012. Radyal Tabanlı Yapay Sinir Ağları ile Kemer Barajı Aylık Akımlarının Modellenmesi. *Teknik Dergi*, **23** (112), 5957-5966.
- Olaofe, Z. O., 2014. A 5-day wind speed & power forecasts using a layer recurrent neural network (LRNN). *Sustainable Energy Technologies and Assessments*, **6**:1-24.
- Öğüt, V., 2014. *Rüzgâr Hızının Sinirsel Bulanık Yöntemle Tahmini* (Yüksek Lisans tezi, basılmamış). İTÜ, Fen Bilimleri Enstitüsü, İstanbul.
- Öztemel, E., 2003. *Yapay sinir ağları*. İstanbul: Papatya Yayıncılık.
- Paksoy, T., Pehlivan, N. Y. ve Özceylan, E., 2013. *Bulanık Küme Teorisi*, Nobel Yayın, 1.Baskı, Ankara.
- Palomares-Salas, J. C., Agüera-Pérez, A., de la Rosa, J. J. G., & Moreno-Muñoz, A , 2014. A novel neural network method for wind speed forecasting using exogenous measurements from agriculture stations. *Measurement*, **55**: 295-304.
- Palomares-Salas, J., Agüera-Pérez, A., Rosa, J., Sierra-Fernández, J., & Moreno-Munoz, A., 2013. Exogenous measurements from basic meteorological stations for wind speed forecasting. *Energies*, **6**(11):5807-5825.
- Paredes, V. ve Vidal, E., 2000. A Class-Dependent Weighted Dissimilarity Measure for Nearest Neighbor Classification Problems, *Pattern Recognition Letters*, **21**:1027-1036.
- Petković, D., Nikolić, V., Mitić, V. V., & Kocić, L., 2017. Estimation of fractalrepresentation of wind speed fluctuation by artificial neural network with different training algorithms. *Flow Measurement and Instrumentation*, **54**: 172-176.
- Prema, V., & Rao, K. U., 2018. Interactive Graphical User Interface (GUI) for Wind Speed Prediction Using Wavelet and Artificial Neural Network. *Journal of*

- The Institution of Engineers (India): Series B*, **99**(5): 467-477.
- Qin, S., Wang, J., Wu, J., & Zhao, G., 2016. A hybrid model based on smooth transition periodic autoregressive and Elman artificial neural network for wind speed forecasting of the Hebei region in China. *International journal of green energy*, **13**(6): 595-607.
- Ramasamy, P., Chandel, S. S., & Yadav, A. K., 2015. Wind speed prediction in the mountainous region of India using an artificial neural network model. *Renewable Energy*, **80**: 338-347.
- Ramesh Babu, N., & Arulmozhivarman, P., 2012. Forecasting of wind speed using artificial neural networks. *International Review on Modelling and Simulations*, **5** (5): 2276-2280.
- Sarı, M., Murat, Y., Kırabalı, M., 2005. Bulanık Modelleme Yaklaşımı ve Uygulamaları. *Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, **009**: 77-92.
- Ansari, M. A., Nidhi Singh Pal, and Hasmat Malik, 2016. "Wind speed and power prediction of prominent wind power potential states in India using GRNN." *2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)*. IEEE.
- Senkal S, Ozgonenel O., 2013. Performance analysis of artificial and wavelet neural networks for short term wind speed prediction. *In: Proceedings of the 8th international conference on electrical and electronics engineering (ELECO)*, 196–8.
- Songlin, Zhou, and Mao Meiqin., 2010. "Forecasting of wind speed based on wavelet analysis and support vector machine." *The 2nd International Symposium on Power Electronics for Distributed Generation Systems*. IEEE.
- Sutskever, I., Martens, J., and Hinton, G., 2011. Generating text with recurrent neural networks. *In Proceedings of the 28th International Conference on Machine Learning, ICML '11*:1017–1024
- Şahin, M., 2007. *Karadeniz Bölgesindeki Yağış-Akış İlişkisinin Farklı Yapay Sinir Ağları Metotlarıyla Belirlenmesi*. İTÜ, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Şenol, Ü., 2017. *Rüzgâr enerjisi ve rüzgâr enerjisi potansiyelinin yapay sinir ağları yöntemiyle tahmini* (Yüksek Lisans tezi, basılmamış). BÜ, Fen Bilimleri Enstitüsü, Yozgat.
- Şenkal, S., 2014. *Rüzgâr hızı tahmin yöntemleri – örnek bir uygulama* (Yüksek Lisans tezi, basılmamış). OMÜ, Fen Bilimleri Enstitüsü, Samsun
- Sheela, K. G., & Deepa, S. N., 2013. Neural network based hybrid computing model for wind speed prediction. *Neurocomputing*, **122**: 425-429.
- Silahtaroglu, G., 2013. *Veri Madenciliği Kavram ve Algoritmaları*. Papatya Yayıncılık, İstanbul, Türkiye.
- Specht, D. F., 1991. A general regression neural network. *IEEE Transactions on Neural Networks*, **2**(6): 568-576.
- Su, Z., Wang, J., Lu, H., & Zhao, G., 2014. A new hybrid model optimized by an intelligent optimization algorithm for wind speed forecasting. *Energy conversion and management*, **85**: 443-452.
- Şeker, A., Diri, B., Balık, H.H., 2017, Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, *Gazi Mühendislik Bilimleri Dergisi*, **3**(3): 47-64.

- Tagliaferri, F., Viola, I. M., & Flay, R. G. J., 2015. Wind direction forecasting with artificial neural networks and support vector machines. *Ocean Engineering*, **97**: 65-73.
- Taşcıkaraoğlu, A., Uzunoğlu M., 2011. Dalgacık dönüşümü ve yapay sinir ağları ile rüzgâr hızı tahmini. *Elektrik Elektronik Bilgisayar Sempozyumu*, 5- 7.
- Tao, J., Zhang, H., Zhu, G., Zhao, M., & Zhang, Q., 2011. Wind power prediction based on technology of advanced phase space reconstruction. *InZhongguo Dianji Gongcheng Xuebao (Proceedings of the Chinese Society of Electrical Engineering)* **31**(28):9-14.
- Xie, W., Noble, A., & Zisserman, A., 2016. Layer Recurrent Neural Networks. *Unpublished*
- Unver, Ö. ve Gamgam H., “*Uygulamalı Temel İstatistik Yöntemleri*”, Seçkin Yayıncılık, Ankara, 2008.
- Wang, L., Li, X., & Bai, Y., 2018. Short-term wind speed prediction using an extremelearning machine model with error correction. *Energy conversion and management*, **162**: 239-250.
- Wang, J., Zhang, W., Wang, J., Han, T., & Kong, L., 2014. A novel hybrid approach for wind speed prediction. *Information Sciences*, **273**: 304-318.
- Wang, J. Z., Wang, Y., & Jiang, P., 2015. The study and application of a novel hybrid forecasting model A case study of wind speed forecasting in China. *Applied energy*, **143**: 472-488.
- Wang, Y., Wang, J., & Wei, X., 2015. A hybrid wind speed forecasting model based on phase space reconstruction theory and Markov model: A case study of wind farms in northwest China. *Energy*, **91**: 556-572.
- Yazıcı, A. C., Ögüş, E., Ankaralı, S., Canan, S., Ankaralı, H., & Akkuş, Z., 2007. Yapay Sinir Ağlarına Genel Bakış. *Türkiye Klinikleri Journal of Medical Sciences*, **27**(1):6571.
- Yesilbudak, M., Sagioglu, S., & Colak, I., 2017. A novel implementation of kNN classifier based on multi-tupled meteorological input data for wind power prediction. *Energy conversion and management*, **135**: 434-444.
- Yıldırım, E., Doğan, E., Karavul, C., Aşçı, M., Özçep, F., Arman, H., 2007. Bulanık Mantık Modeli ile Zeminlerin Sınıflandırılması. *International Earthquake Symposium*, 22-26 Ekim 2007, Kocaeli, Türkiye,
- Yu, C., Li, Y., Bao, Y., Tang, H., & Zhai, G. 2018. A novel framework for wind speed prediction based on recurrent neural networks and support vector machine. *Energy conversion and management*, **178**: 137-145.
- Yuan, X., Tan, Q., Lei, X., Yuan, Y., & Wu, X., 2017. Wind power prediction using hybrid autoregressive fractionally integrated moving average and least squaresupport vector machine. *Energy*, **129**: 122-137.
- Yurdusev, M. A., Ata, R., & Çetin, N. S., 2006. Assessment of optimum tip speed ratio in wind turbines using artificial neural networks. *Energy*, **31**(12): 2153-2161.
- Zhang, W., Wu, J., Wang, J., Zhao, W., & Shen, L., 2012. Performance analysis of four modified approaches for wind speed forecasting. *Applied Energy*, **99**: 324-333.
- Zhang, W., Wang, J., Wang, J., Zhao, Z., & Tian, M., 2013. Short-term wind speed forecasting based on a hybrid model. *Applied Soft Computing*, **13**(7):3225-3233.

- Zhang, W., Qu, Z., Zhang, K., Mao, W., Ma, Y., & Fan, X., 2017. A combined modelbased on CEEMDAN and modified flower pollination algorithm for wind speed forecasting. *Energy conversion and management*, **136**:439-451.
- Zhang, Y., Chen, B., Zhao, Y., & Pan, G., 2018. Wind speed prediction of IPSO-BP eural network based on lorenz disturbance. *IEEE Access*, **6**:53168-53179.
- Zhou, J., Hongjie, J., Tian, Z., & Hu, L., 2012. Short-term wind speed forecasting based on non-parametric kernel density estimation. *In IEEE PES Innovative Smart Grid Technologies*:1-5.
- Zorlu, E., 2015, *İç Anadolu Bölgesi İçin Modern Kontrol Yöntemleri İle Rüzgâr Hızı Tahmini: Kırşehir Bölgesi Örneği* (Yüksek Lisans tezi, basılmamış). KKÜ Fen Bilimleri Enstitüsü, Kırıkkale.



ÖZ GEÇMİŞ

M. Cihat ALTIN, 1981 Siirt doğumludur 1985 yılından bu yana Van'da ikamet etmekte olup 1999 yılında Van Gölü Anadolu Lisesi'nden mezun olmuştur. Aynı yıl Malatya İnönü Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği bölümünü kazanmış ve 2004 yılında Elektrik Elektronik Mühendisi olarak üniversiteden mezun olmuştur. 2004 yılında Askerlik görevini tamamlayan M. Cihat ALTIN serbest Mühendis Müşavir olarak ve Van İl Özel İdaresinde çalışmıştır. 2006 Nisan ve 2008 Aralık ayları arasında Van Et A.Ş de Elektrik mühendisi olarak görev yapmış ve ardından Şubat 2009 - Şubat 2012 yılları arasında Mardin Artuklu Üniversitesi Midyat Meslek Yüksekokulu Elektrik programında Öğretim görevlisi olarak görev yapmıştır. Şubat 2012 den itibaren Van Yüzüncü Yıl Üniversitesi, Van Meslek Yüksekokulu Elektrik programında Öğretim görevlisi olarak görev yapmaktadır.

T.C
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
LİSANSÜSTÜ TEZ ORJİNALLİK RAPORU

Tarih:/...../20.....

Tez Başlığı / Konusu:

.....Rüzgar Hızının Farklı Yöntemlerle İle İlgili Örnek
Bir Uygulama.....

Yukarıda başlığı/konusu belirlenen tez çalışmamın Kapak sayfası, Giriş, Ana bölümler ve Sonuç bölümlerinden oluşan toplam ...206.... sayfalık kısmına ilişkin, ...04.../...12.../2018... tarihinde şahsım/tez danışmanım tarafından ...TMMOB... intihal tespit programından aşağıda belirtilen filtreleme uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % ...5..... (Beş.....) dir.

Uygulanan filtreler aşağıda verilmiştir:

- Kabul ve onay sayfası hariç,
- Teşekkür hariç,
- İçindekiler hariç,
- Simge ve kısaltmalar hariç,
- Gereç ve yöntemler hariç,
- Kaynakça hariç,
- Alıntılar hariç,
- Tezden çıkan yayınlar hariç,
- 7 kelimedenden daha az örtüşme içeren metin kısımları hariç (Limit inatch size to 7 words)

Van Yüzüncü Yıl Üniversitesi Lisansüstü Tez Orijinallik Raporu Alınması ve Kullanılmasına İlişkin Yönergeyi inceledim ve bu yönergede belirtilen azami benzerlik oranlarına göre tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim.

04.12.2018

Tarih ve İmza

Adı Soyadı: ...Muhammed Cihat ALTIN.....

Öğrenci No:.....

Anabilim Dalı: ...Elektrik-Elektronik Mühendisliği

Programı: ...Elektrik-Elektronik Mühendisliği

Statüsü: Y. Lisans Doktora

DANIŞMAN ONAYI
UYGUNDUR

Doç. Dr. Ridvan Sarıoğlu

(Unvan, Ad Soyad, İmza)

ENSTİTÜ ONAYI
UYGUNDUR



(Unvan, Ad Soyad, İmza)