

**T.C.
SİİRT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

RÜZGÂR GÜÇ YOĞUNLUĞUNUN YAPAY SİNİR AĞI İLE TAHMİNİ

YÜKSEK LİSANS TEZİ

**Muhammed Yusuf AKTAÇ
(143103003)**

Elektrik-Elektronik Mühendisliği Anabilim Dalı

**Danışman : Doç. Dr. Mehmet ŞAHİN
II. Danışman : Doç. Dr. Rıdvan SARAÇOĞLU**

**Ocak-2016
SİİRT**

TEZ KABUL VE ONAYI

Muhammed Yusuf AKTAÇ tarafından hazırlanan “**Rüzgâr Güç Yoğunluğunun Yapay Sinir Ağı İle Tahmini**” adlı tez çalışması 22/01/2016 tarihinde aşağıdaki jüri tarafından **oybirliği/oyçokluğu** ile Siirt Üniversitesi ve Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Yrd. Doç. Dr. Ahmet GÜNDOĞDU

Danışman

Doç. Dr. Mehmet ŞAHİN

Üye

Yrd. Doç. Dr. Yılmaz KAYA

İmza

.....

.....

.....

Yukarıdaki sonucu onaylarım.

Doç. Dr. Koray ÖZRENK
Fen Bilimleri Enstitüsü Müdürü

TEZ BİLDİRİMİ

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdiği yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan ederim.

Muhammed Yusuf AKTAÇ

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge, şekil ve fotoğrafların kaynak gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

TEŐEKKÜR

Bu tez alıőması esnasında sürekli yol gsteren, bilgi ve tecrbe anlamında deęerli katkılarıyla beni ynlendiren, ilgi ve hoőgrsn esirgemeyen danıőman hocalarım Do. Dr. Mehmet ŐAHİN'e ve Do. Dr. Rıdvan SARAOęLU'na teőekkrlerimi sunarım.

Hayattaki bazı sıkıntılı ve zor anlarda omuzlarını her zaman yanında hissettięim ve hakkını asla deyemeyeceęim bugne gelmemde desteklerini her an yanımda hissettięim anneme ve babama Őkranlarımı sunar ve sz konusu ben olunca hibir fedakrlıktan kaınmayacak olan aęabeyime ve ablama Őkran duygularımı sunar, teőekkrlerimi bir bor bilirim.

Muhammed Yusuf AKTA
SIIRT-2016

İÇİNDEKİLER

TEZ BİLDİRİMİ	iii
TEŞEKKÜR	iv
TABLolar LİSTESİ	vii
ŞEKİLLER LİSTESİ	vii
KISALTMALAR VE SİMGELER LİSTESİ	viii
ÖZET	x
ABSTRACT	xi
1.GİRİŞ	1
2.LİTERATÜR ARAŞTIRMASI	4
3. ÇALIŞMA BÖLGESİ VE DATA KAYNAKLARI	13
3.1. Türkiye'nin İklim Tipleri.....	15
3.1.1. Karasal iklim.....	15
3.1.2. Akdeniz iklimi	15
3.1.3. Karadeniz iklimi	15
4.RÜZGÂR ENERJİSİ METODOLOJİSİ	17
4.1.Rüzgârdaki Enerji	17
4.2. Sıcaklığın Hava Yoğunluğuna Etkisi.....	20
4.3. Rakımın Hava Yoğunluğuna Etkisi	22
4.4. Kule Yüksekliğinin Etkisi	26
4.5. Rüzgâr Hızı Güç Denklemi	26
4.6. Hız ve Güç Oranının Yükseklikle İlişkisi	27
5. YAPAY SİNİR AĞLARI	29
5.1.YSA'nın Tanımı	29
5.2.YSA'nın Tarihçesi.....	30
5.3.Yapay Sinir Ağlarının Genel Tanımı.....	32
5.4.Yapay Sinir Ağlarının Temel Görevi	33
5.5.Yapay Sinir Ağlarının Genel Özellikleri	34
5.6. Biyolojik Sinir Ağları	37
5.7. YSA Hücresi.....	39
5.7.1. Girişler.....	40
5.7.2. Ağırlıklar	40
5.7.3.Toplama fonksiyonu	41

5.7.4. Aktivasyon fonksiyonları	42
5.7.5.Hücrenin Çıktısı	45
5.8. Yapay Sinir Ağları Modelleri.....	45
5.9. Öğrenme Algoritmaları	46
5.9.1. Geriye yayılım öğrenme algoritması.....	46
5.9.2. Levenberg - Marquardt öğrenme algoritması.....	48
5.10. Bir YSA Modellemesinde Dikkat Edilecek Hususlar.....	51
5.11. YSA'nın Üstünlükleri ve Dezavantajları	51
5.11.1. Üstünlükleri	51
5.11.2. Yapay sinir ağlarının dezavantajları	52
5.12. Yapay Sinir Ağları Modeli Oluşturma Adımları.....	53
5.13.Verilerin Analizi	54
6. BULGULAR VE TARTIŞMA	56
7. SONUÇ VE ÖNERİLER.....	63
8. KAYNAKLAR.....	64
ÖZGEÇMİŞ.....	71

TABLolar LİSTESİ

	<u>Sayfa</u>
Tablo 3.1. Eğitim ve test için kullanılan şehirler.....	13
Tablo 4.1. 15°C 1 atm. 'de rüzgar hızının güç yoğunluğuna bağlı değişimi.....	20
Tablo 4.2. 1 atm basıncı altında hava yoğunluğunun hava sıcaklığı ile değişimi	21
Tablo 4.3. 15° C' de hava basıncının ve yoğunluğunun rakım ile olan değişimi.....	25
Tablo 4.4. Farklı yüzeylerin α rüzgar kesme üs değerleri.....	27
Tablo 5.1. Biyolojik sinir sistemi ve YSA'nın karakteristiği.....	39
Tablo 5.2. Toplama fonksiyonu türleri	42
Tablo 5.3. Eğitim algoritmaları.....	50
Tablo 6.1. Geliştirilen YSA modelleri.....	57
Tablo 6.2. İl bazlı MBE, RMSE, R değerleri.....	59

ŞEKİLLER LİSTESİ

	<u>Sayfa</u>
Şekil 4.1. Kütlesi m , v hızıyla hareket eden bir hava paketi.....	17
Şekil 4.2. A alanı içerisinde v hızıyla hareket eden bir hava kütlesi	18
Şekil 4.3. Rüzgâr hızı güç ilişkisi.....	19
Şekil 4.4. 1 atm basıncı altında hava yoğunluğunun hava sıcaklığı ile değişimi	22
Şekil 4.5. Yükseklik ile basınç arasındaki ilişkiyi bulmak amacı ile dikkate alınan hava koridoru.....	23
Şekil 4.6. α değerlerine bağlı olarak farklı yükseklikler için rüzgâr hız ve güç oranları arasındaki ilişki.....	28
Şekil 5.1. Biyolojik sinir ağının şeması.....	37
Şekil 5.2. Biyolojik sinir ağının basitleştirilmiş yapısı.....	38
Şekil 5.3. Basit bir yapay sinir hücresi (nöron)yapısı	40
Şekil 5.4. YSA'ların çıkış katmanında kullanılan lineer aktivasyon fonksiyonu	43
Şekil 5.5. Logaritma sigmoid aktivasyon fonksiyonu.....	44
Şekil 5.6. Hiperbolik tanjant sigmoid transfer fonksiyonu	45
Şekil 5.7. İleri beslemeli yapı	46
Şekil 5.8. Geri beslemeli yapı	46
Şekil 5.9. İleri ve geri beslemeli çok katmanlı sinir ağı	48
Şekil 6.1. YSA' da kullanılan mimari.....	56
Şekil 6.2. Kastamonu iline ait güç yoğunluğu değerleri.....	60
Şekil 6.3. Bursa iline ait güç yoğunluğu değerleri.....	61

KISALTMALAR VE SİMGELER LİSTESİ

<u>Kısaltma</u>	<u>Açıklama</u>
AB	: Avrupa Birliği
ANFIS	: Yapay Sinir Ağı Tabanlı Bulanık Çıkarım Sistemi
BPM	: Değişkenli Bir Olasılık Modeli
BPN	: Geri Yayılım Ağı
CG	: Eşlenik Gradyan
EİE	: Elektrik İşleri Etüt İdaresi Genel Müdürlüğü
EKK	: En Küçük Kareler
ELM	: Aşırı Öğrenme Makinesi
EYO	: En Yüksek Olabilirlik
FFNN	: İleri Beslemesi Sinir Ağı
GA	: Genetik Algoritma
GP	: Genetik Programlama
GYA	: Geri Yayılım Algoritması
LM	: Levenberg-Marquardt Algoritması
MAPE	: Ortalama Mutlak Yüzde Hata
MATLAB	: Matrix Laboratuvarı
MBE	: Ortalama Sapma Hatası
MLP	: Çok Katmanlı Algılayıcı
MY	: Moment Yöntemi
OLS	: En küçük Ortogonal Kareler
R	: Korelasyon Katsayısı
RBF	: Radyal Tabanlı Fonksiyon
RMSE	: Hataların Karelerinin Ortalamasının Karekökü
RMSE	: Kök Ortalama Kare Hatası
SOM	: Kendi Kendini Düzenleyen Nitelik Haritası
SVM	: Destek Vektör Makinesi
UPMs	: Tek Değişkenli Olasılık Modelleri
WASP	: Rüzgâr Atlas Analiz ve Uygulama Programı
WD	: Weibull Dağılımı
WECS	: Rüzgâr Enerjisi Dönüşüm Sistemi
WEPF	: Rüzgâr Enerjisi Desen Faktörü
YSA	: Yapay Sinir Ağı

<u>Simge</u>	<u>Açıklama</u>
J(x)	: Jacobian Matrisi
Out(o)	: Çıkışlar Matrisi
G	: Yerçekimi İvmesi
Π	: Net Girişi Belirleyen Çarpım Fonksiyonu
°C	: Derece
F	: Fahrenheit
r	: Doğrusal İlişkinlik Katsayısı
β	: Eğim Sabiti
m	: Kütle
μ	: Momentum
o(k)	: Sinir Ağı Çıkışı
y(k)	: Gerçek Çıkış
Σ	: Net Girişi Belirleyen Toplama Fonksiyonu

NET	: Ağa Gelen Net Girdi
P_A	: A Alanı Boyunca Akan Güç
ρ	: Hava Yoğunluğu
A	: Pürüzlülük Katsayısı (Hellman Katsayısı)
MA	: Gazın Moleküler Ağırlığı
T	: Mutlak Sıcaklık
V	: Hacim
W_{KE}	: Havanın Kinetik Enerjisi
ṁ	: Kütleli Debi
P	: Basınç
N	: Mol Sayısı
R	: İdeal Gaz Sabiti
N₂	: Azot
O₂	: Oksijen
Ar	: Argon
CO₂	: Karbon Dioksit
Ne	: Neon
P₀	: Referans Basınç(1 atm)
K_T	: Sıcaklık Düzeltme Faktörü
K_A	: Rakım (Altitude) Düzeltme Faktörü
Km	: Kilometre
V	: <i>H</i> Yüksekliğindeki Rüzgâr Hızı
V₀	: <i>H₀</i> Referans Yükseklikteki Rüzgâr Hızı
b	: Eşik Değeri (Bias)
X₁	: Girdiler
W₁	: Ağırlıklar
H	: Rüzgâr Hızının Ölçüldüğü Yükseklik
H₀	: Rüzgâr Hızının Ölçüldüğü Referans Yükseklik
e(k)	: Hata
v_i	: Gerçek Değerler
e_i	: Tahmin Edilen Değerler
v̄	: Gerçek Değerlerin Ortalaması
ē	: Tahmin Edilen Değerlerin Ortalaması
σ_v	: Gerçek Değerlerin Standart Sapması
σ_e	: Tahmin Edilen Değerlerin Standart Sapması

ÖZET

YÜKSEK LİSANS TEZİ

RÜZGÂR GÜÇ YOĞUNLUĞUNUN YAPAY SİNİR AĞI İLE TAHMİNİ

Muhammed Yusuf AKTAÇ

**Siirt Üniversitesi Fen Bilimleri Enstitüsü
Elektrik-Elektronik Mühendisliği Anabilim Dalı**

Danışman : Doç. Dr. Mehmet ŞAHİN

II. Danışman : Doç. Dr. Rıdvan SARAÇOĞLU

2016, 71 Sayfa

Sanayi ve teknoloji her geçen gün hızla gelişmektedir. Sanayi ve teknoloji gelişmelerini sürdürmek için enerjiye ihtiyaç duymaktadır. Enerji ihtiyacı çoğunlukla fosil yakıtlardan sağlanmaktadır. Ne yazık ki bunların rezervleri gün geçtikçe azalmaktadır. Bu nedenle, enerji ihtiyacının karşılanabilmesi için alternatif enerji kaynaklarının kullanılmasına ihtiyaç duyulmaktadır. Alternatif enerji kaynakları; güneş, rüzgâr, dalga, biyokütle, jeotermal ve hidroelektrik enerjisi olarak sıralanabilir. Ülkemiz, rüzgâr enerjisi bakımından önemli bir potansiyele sahiptir. Rüzgâr potansiyelini belirlemek için rüzgâr güç yoğunluğunun tahmin edilmesi gereklidir. Bu çalışmada, rüzgâr güç yoğunluğu yapay sinir ağı (YSA) metodu kullanılarak tahmin edilmiştir. Kırk meteorolojik istasyon YSA'nın eğitimi için kullanılırken, on sekiz meteorolojik istasyon eğitilmiş ağı test etmek için kullanılmıştır. Ağ sırasıyla trainlm, trainbfg, trainscg, traincgp, traincgb, traincgf ve trainoss öğrenme algoritmalarına göre eğitilmiştir. Geliştirilen en iyi modelin korelasyon katsayısı (R) ve ortalama sapma hatası (MBE) sırasıyla 0,9767 ve -0,3124 W/m² olarak hesaplanırken, kök ortalama kare hatası (RMSE) 1,4786 W/m² olarak hesaplanmıştır. Elde edilen sonuçlar, geliştirilen modelin rüzgâr güç yoğunluğu tahmin etmek için kullanılabileceğini göstermektedir.

Anahtar Kelimeler: Alternatif enerji kaynakları, rüzgâr güç yoğunluğu, rüzgâr hızı, yapay sinir ağları

ABSTRACT

MS SEMINAR

ESTIMATION OF WIND POWER DENSITY WITH ARTIFICIAL NEURAL NETWORK

Muhammed Yusuf AKTAÇ

The Graduate School of Natural and Applied Science of Siirt University

The Degree of Master of Science

In Electrical-Electronics Engineering

Supervisor : Doç. Dr. Mehmet ŞAHİN

Co-Supervisor : Doç. Dr. Rıdvan SARAÇOĞLU

2016, 71 Pages

Industry and technology are rapidly developing with each passing day. They need energy to sustain this evolution. The demand of energy is mainly provided from fossil fuels. Unfortunately, this kind of energy reserves are consumed away day by day. Therefore, there is a need to use alternative energy sources to supply energy needs. Alternative energy sources can be listed as; solar, wind, wave, biomass, geothermal and hydro-electric power. Our country has significant potential for wind energy. Wind power density estimation is required to determine the wind potential. In this study, the wind power density was estimated by using artificial neural network (ANN) method. Forty meteorological stations were used for ANN training, while eighteen meteorological stations were used to test the trained network. Network has trained according to, respectively; trainlm, trainbfg, trainscg, traincgp, traincgb, traincgf ve trainoss learning algorithms. The correlation coefficient (R) and Mean bias error (MBE) of the best developed model were calculated as 0,9767 and -0,3124 W/m² respectively. Root Mean Square Error (RMSE) was calculated as 1,4786 W/m². In conclusion, the obtained results demonstrate that the developed model can be used to estimate the wind power density.

Keywords: Alternative energy sources, wind power density, wind speed, artificial neural networks

1.GİRİŞ

İnsanlar tarih boyunca enerjiye ihtiyaç duymuşlardır. Diğer canlı varlıklar gibi sadece besinler yoluyla aldıkları enerjiyle yetinmemişler ve besin kaynakları dışında çeşitli enerji kaynakları keşfederek bu kaynakları çeşitli teknolojiler sayesinde ısı, mekanik ve elektrik enerjisine çevirmeyi öğrenmişlerdir (Aslan ve Yamak, 2006). Enerji, esas olarak iş yapabilme yeteneği demektir. İş, kuvvet ile kuvvetin etki ettiği yönde meydana gelen yer değiştirmenin çarpımına eşittir. Dolayısıyla, yapılan bir işten söz edilebilmesi için bir kuvvetin varlığı ve bu kuvvetin etki noktasının hareket ediyor olması gerekir. Yani ne kadar kuvvetli olursanız olun ve ne kadar büyük bir kuvvet uygularsanız uygulayın, eğer bu kuvvet uyguladığınız noktayı hareket ettirmiyorsa, fiziksel anlamda hiç iş yapmıyorsunuz demektir (Altın, 2002).

Günümüzde dünya çapında gerçekleşen hızlı nüfus artışı, kentleşme ve sanayileşme olguları ile küreselleşme sonucu artan ticaret olanakları gibi gelişmeler doğal kaynaklara ve enerjiye olan talebi giderek arttırmaktadır (Yıldız, 2011). Bu durum insanlığın en büyük problemlerinden biri haline gelmiştir. Diğer yandan kullanılan fosil kaynaklar, dünya üzerinde küresel ısınmaya neden olmakta ve bunun oluşturduğu sera etkisi alışılmadık iklimsel değişiklikler meydana getirmektedir. Diğer taraftan, enerji kaynaklarının meydana getirdiği çevresel kirlilik de doğaya ve dolaylı olarak insan sağlığına zarar vermeye başlamıştır (Kjaerland, 2007).

Fosil yakıt kaynaklarının sınırlı oluşu ve hava kirliliği, asit yağmurları ile sera etkisi şeklinde ortaya çıkan çevresel sorunlar nedeni ile yenilenebilir enerji kaynakları tüm dünyada giderek artan bir ilgi ile karşılanmakta ve enerji gereksiniminin karşılanmasında önemli bir kaynak olarak görülmektedir (Özerdem, 2003). Bu nedenle Türkiye'nin de içinde bulunduğu gelişmekte olan ülkeler, sanayileşmiş ülkelerin düzeyine yetişmek için daha çok enerji yatırımı yapmak zorundadır. Bu bağlamda, konvansiyonel güç santrallerinden enerji üretimi sonucu ortaya çıkan küresel ve yerel düzeydeki çevresel kirlilik ve bunların küresel ısınma ile ilişkisinin açıkça görülmesi, neredeyse sıfır emisyonu neden olan yenilenebilir enerji kaynaklarını oldukça önemli bir konuma getirmiştir (Köse ve Özgür, 2003).

Yenilenebilir enerji kaynaklarının kullanım oranının sürekli artırılması gerekmektedir. Böylelikle, fosil yakıtların durdurulamayan fiyat artışlarını ve çevreye olumsuz etkilerini azaltmak ve hatta durdurmak bile mümkündür. Bilindiği üzere dünyada pek çok kez petrol krizi meydana gelmiştir. Örneğin 1973 krizi, 1978, 1990 ve

1999 krizlerinde petrol varil fiyatlarında ani artışlar dünyadaki dengeleri alt üst etmiştir. Özellikle 1990'ların başından itibaren gelişmiş ülkeler, yenilenebilir enerji kaynaklarına olan ilgilerini artırmışlardır. 1992 yılında Rio Sözleşmesi, 1994 yılında Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi, 1997 yılındaki Kyoto Protokolü, Avrupa Birliği (AB)'nin direktifleri yenilenebilir enerjilere verilen önemi arttırmıştır (Akdağ, 2008).

Bütün bu nedenlerden dolayı dünya ülkeleri temiz, sağlıklı, sürdürülebilir enerji kaynakları olarak nitelendirilen yenilenebilir enerji kaynaklarına doğru hızlı bir yönelişe geçmek durumunda kalmıştır. Yenilenebilir enerji kaynakları kalıcı, çevre dostu, temiz ve çevreyi korumada büyük rol oynamaktadır. Aynı zamanda, ülkelerin ekonomik kalkınmalarına da büyük katkı sağlamaktadır (Lee, 2011).

Dünya nüfusunun hızla artmasına paralel olarak enerjiye olan ihtiyaçta, her geçen gün daha da fazlalaşmaktadır (Hepbaşlı ve Özgener, 2004). Bu durum insanların yenilenebilir enerji kaynaklarına olan ilgisini arttırmıştır (İlkılıç, 2012). Yenilenebilir enerji kaynakları içerisinde dünyanın her yerinde bolca bulunabilen, düşük maliyetli, temiz, en gelişmiş ve ticari açıdan en elverişli enerji türlerinden birisi de rüzgâr enerjisidir (Köse ve ark., 2004). Bu nedenle rüzgâr enerjisinin kullanımı son yıllarda hem dünyada hem de Türkiye'de giderek artan oranda ilgi görmektedir (Bayraç, 2011; Öner ve ark., 2013).

Rüzgâr enerjisi, yenilenebilir enerjiler arasında en gelişmiş olanı ve ticari açıdan en ucuz enerji türüdür. Rüzgârın insan sağlığı ve çevreyle uyumlu yerli bir enerji kaynağı olması, tükenmez olması, fosil yakıtlardan tasarruf sağlaması, teknolojiye ilerlemeler sonucu kurulum ve işletim maliyetinin her geçen gün düşmesi gibi nedenlerle, giderek daha çok tercih edilen bir enerji kaynağı haline gelmiştir (Bayraç, 2011).

Günümüzde ülkelerin karşı karşıya kaldıkları en önemli sorunların başında enerji ihtiyacı ve bunun giderilmesi gelmektedir. Böyle bir sorunun çözümünde, temiz enerjinin üretilmesi, depolanması, dağıtılması ulusal ve uluslararası düzeyde çok önemli bir konu olarak yer almaktadır. Dünya ülkelerinin bugünkü enerji ihtiyacının yaklaşık %50'si petrole bağlıdır. Önümüzdeki yıllarda bu oranın daha da artacağı tahmin edilmektedir. Bu bakımdan rüzgâr enerjisinin kullanımı, çevresel kaygılar da dikkate alındığında oldukça önemlidir. Rüzgâr enerjisi alternatif enerjiler arasında en ucuz maliyetli ve önemi her geçen gün artan bir enerjidir. Artık tüm ülkeler bu enerjiden en üst seviyede yararlanmak için bu alanda yapılan tüm çalışmalarını desteklemektedir.

Önümüzdeki yıllar, bu enerjinin atılım yaparak zirveye yerleşeceği yıllar olacaktır (Nurbay, 2005).

Türkiye’de enerjinin; maliyeti, yeterli ölçüde sağlanması ve çevreye etkileri halen tartışılmaktadır. Bu durum, incelenmesi gereken sorunlar olduğunu açıkça göstermektedir. Bir sorunun aşılması için problemin doğru olarak tanımlanması ve uygulanabilir çözümler bulunması gerekmektedir. Bunun için, doğru ve taze bilgiye ulaşılması, en gelişmiş karar destek araçlarının kullanılması ve toplumdaki bu konuda deneyimli kişilerle görüş alış-verişi içinde olunması gerekmektedir (Uyar, 2001).

Türkiye'deki enerji profili gözden geçirildiğinde yenilenebilir enerji kaynaklarının yeri ve önemi açıkça görülmektedir. Ancak yenilenebilir enerji kaynaklarının kullanımı oldukça düşük düzeydedir (%1 ve altında) ve bu enerji türleri ile yeterince ilgilenilmemektedir. Özellikle, güneş ve rüzgar enerjisinin kullanımı, Türkiye 'nin enerji bütçesine ciddi katkılar sağlayacaktır (Öztürel ve ark., 2001). Enerji açığının kapatılması amacıyla yenilenebilir doğal enerji kaynaklarından yararlanılması bir yöntem olarak düşünülebilir (Stout ve ark., 1979).

Türkiye; Avrupa’da rüzgâr enerjisi potansiyeli bakımından en zengin ülkelerden biridir. Üç tarafı denizler ile çevrili olan ve yaklaşık 3500 km kıyı şeridi olan Türkiye’de özellikle Marmara ile Ege kıyı şeritleri; sürekli ve düzenli rüzgâr almaktadır. Bu nedenle enerji kaynakları bakımından dışa bağımlı durumda olan Türkiye’nin, bu potansiyeli kullanması çok önem taşımaktadır. Günümüzde enerji ihtiyacının arttığı, temiz enerji kaynaklarının önem kazandığı bir zamanda, rüzgâr enerjisi potansiyelinin değerlendirilmesi önemli bir hale gelmiştir.

Bu çalışmanın amacı, Türkiye üzerindeki rüzgâr enerji potansiyelini belirlemede YSA’nın etkinliğini ve uygulanabilirliğini incelemektir. Daha önceki çalışmalarda; Türkiye’de YSA yöntemlerinin bir arada kullanıldığı, geniş girdi parametrelerine bağlı olarak uzun dönem çalışmaların yapıldığı gözlenmemiştir. Çalışmanın bu açıdan kendine özgü yönü bulunmaktadır. Çalışmada Türkiye’nin farklı iklim şartlarını temsil eden, 58 il merkezlerinde bulunan meteorolojik istasyonlardan elde edilen ay, enlem, boylam, yükseklik, toprak sıcaklığı (5cm), buhar basıncı, nisbi nem, ortalama sıcaklık, ortalama maksimum sıcaklık, ortalama minimum sıcaklık gibi parametreler girdi (input) parametreleri olarak kullanılırken; rüzgâr güç yoğunluğu (W/m^2) çıktı parametresi olarak elde edilecektir. Çalışmada 1980-2010 yılları arasındaki veriler eğitim verisi olarak kullanılırken, 2011-2013 yılları arasındaki veriler ise test amaçlı kullanılacaktır. Çalışmada yazılım olarak, Matlab 2010a programı kullanılmıştır.

2.LİTERATÜR ARAŞTIRMASI

Rüzgâr güç yoğunluğu tahmini hususunda yapılan akademik çalışmalar aşağıda tarihsel gelişim süreci içerisinde verilmiştir.

Auwera ve arkadaşları, yaptıkları çalışmada ortalama rüzgâr enerji yoğunluklarını tahmin etmek için üç parametrelili Weibull modelini kullanmışlardır. Rüzgâr enerjisi tahminlerinin, ayrıntılı olarak hazırlanmış rüzgâr hızı istatistiklerine dayalı olması gerektiğini vurgulamışlardır. Deneysel rüzgâr hızı frekans verileri ve rüzgâr hızı gözlemleri kullanarak bu modelin genellikle bir veya iki parametrelili yoğunluk fonksiyonlarından daha güvenilir bir sonuç verdiğini ortaya koymuşlardır (Van Der Auwera ve ark., 1980).

Lu ve arkadaşları yaptıkları çalışmada, rüzgâr enerjisi potansiyeli ve rüzgâr türbini özelliklerinin analizini, Hong Kong adalarında yapmışlardır. Bu çalışmada araştırmacılar, yerel hava durumu verileri ve tipik rüzgâr türbini özelliklerinin analizi yoluyla Hong Kong adalarındaki elektrik üretim potansiyelini değerlendirmişlerdir. Çalışmada rüzgâr hızı ve rüzgâr güç yoğunluğu incelenmiş, farklı göbek yükseklikleri kullanılarak rüzgâr türbini tarafından üretilen yıllık enerji simüle edilmiştir. Simülasyon, Hong Kong çevresindeki adalarda rüzgâr enerjisi üretimi için yeterli potansiyel olduğunu göstermiştir (Lu ve ark., 2002).

Çelik yaptığı çalışmada rüzgâr güç yoğunluğuna dayalı rüzgâr hızı olasılık dağılım fonksiyonlarının uygunluğunu değerlendirmiştir. Üç fonksiyon, ağırlıklı olarak genellikle aylık veya yıllık bir zaman diliminde, belirli bir süre boyunca, belirli bir yerde ölçülen rüzgâr hızı olasılık dağılımının uygunluğunu ayarlamak için kullanılmıştır. Bu karşılaştırma işlemi sırasında, gerekli parametrelerin uyum uygunluğu değerlendirilmiştir. Çoğunlukla kullanılan parametrelerde ortalama rüzgâr hızı veya toplam rüzgâr enerjisi üretimi bulunmaktadır. Bununla birlikte, tek başına bu parametrelere dayalı fonksiyonların uygunluğunun hâkim olamadığı bu çalışmada gösterilmiştir (Çelik, 2003a).

Çelik yaptığı çalışmada, Türkiye'nin Güney Bölgesinde, Weibull ve Rayleigh modellerine dayalı rüzgâr güç yoğunluğunun istatistiksel analizini yapmıştır. Çalışma, Akdeniz kıyısında yer alan İskenderun'un ($36^{\circ} 35'N$; $36^{\circ} 10'E$), olası rüzgâr enerjisi üretim bölgeleri arasında olduğunu göstermektedir. Ayrıca çalışmada, bölgenin rüzgâr enerjisi potansiyeli istatistiksel bir yıllık zaman diliminde ölçülen saatlik zaman serisi

rüzgâr hızı verilerine dayanarak analiz edilmiştir. Konumun rüzgâr enerjisi potansiyeli, Weibull ve Rayleigh modellerine dayalı olarak çalışılmıştır (Çelik, 2003b).

Karslı ve Geçit, Nurdağı-Gaziantep'te rüzgâr enerjisi potansiyeli üzerinde bir araştırma yapmışlardır. Son yıllarda üretilen enerji kaynakları arasında rüzgâr enerjisi üretimi zaman geçtikçe artmaktadır. Bu çalışmada, gelecekte yapılacak rüzgâr enerjisi üretim projeleri için Türkiye'nin güneyindeki Nurdağı-Gaziantep ilçesinde rüzgâr enerjisi potansiyelinin belirlenmesi için araştırma yapmışlardır. Rüzgâr verilerinin değerlendirilmesi, Nurdağı ilçesindeki bulunan Türk Elektrik İşleri İdaresi tarafından yapılmıştır. Ölçülen rüzgâr hızı 10 m yükseklikte 7,3 m/s ortalama rüzgâr hızına sahipken, maksimum rüzgâr hızı ise 23,3 m/s olarak ölçülmüştür. Alanın güç yoğunluğu ortalama 222 W/m² olarak bulunmuştur. Sonuç olarak bu alanda rüzgâr enerji üretimi için yatırımcıların teşvik edilmesi önerilmektedir (Karslı ve Geçit, 2003).

Çam ve arkadaşları yaptıkları çalışmada, yapay sinir ağını kullanarak Türkiye'nin çeşitli bölgelerinde ortalama rüzgâr hızını ve gücünü belirlemek için bir sınıflandırma mekanizması oluşturmuşlardır. Bu çalışmada, ortalama rüzgâr hızı ve rüzgâr güç değerleri yapay sinir ağları (YSA) kullanılarak tahmin edilmiştir. Türkiye'nin yedi bölgesindeki rüzgâr verileri, Devlet Meteoroloji İşleri Genel Müdürlüğü'nden alınmıştır. Yazılım olarak, Matlab 6.0 programı kullanılmıştır. Rüzgâr hızı ve ilgili güç değerleri çıkış katmanından elde edilirken, girdi katmanında boylam, enlem ve yükseklik kullanılmıştır. Çalışma neticesinde, YSA kullanılarak ortalama rüzgâr hızı ve bölgenin rüzgar enerji potansiyelinin güvenilir bir şekilde tahmin edilebileceği ortaya çıkmıştır (Çam ve ark., 2005).

Al-Nassar ve arkadaşları yaptıkları çalışmada, Kuveyt Devleti'nin rüzgâr enerjisi üretim potansiyelini analiz etmişlerdir. Çeşitli konumlar için yıllık ortalama rüzgâr hızı 3,7- 5,5 m/s ve 10 m standart yükseklikte 80-167 W/m² ortalama rüzgâr güç yoğunluğunun değiştiğini ifade etmişlerdir. Her istasyonun Weibull parametreleri, güç yoğunluğunun Weibull dağılımı kullanılarak tespit edilmiştir. 15, 20, 25 ve 30 m yükseklikteki rüzgâr verileri, güç yasası kullanarak 10 m yükseklikleri rüzgâr verilerinden elde edilmiştir. Farklı yüksekliklerde rüzgâr potansiyel enerjisi, Weibull parametreleri kullanılarak tahmin edilmiştir. Maksimum güç yoğunluğu özellikle ülkenin kuzey kesiminde 130-275 W/m² arasında değiştiği istatistiksel açıdan gözlenmiştir (Al-Nassar ve ark., 2005).

Carta ve Mentado yaptıkları çalışmada, rüzgâr güç yoğunluğu için sürekli iki değişkenli bir olasılık modelini (BPM) kullanarak, rüzgâr türbini enerji çıkış analizini

tahmin etmişlerdir. Çalışmalarında, rüzgâr enerjisi olasılık yoğunluk fonksiyonunun kullanılması rüzgâr türbininin potansiyel konumda bulunan rüzgâr kaynaklarının değerlendirme ve tasarım sürecinde faydalı olacağını ortaya koymuşlardır. Önerilen BPM modelini meydana getirmek için Kanarya Adaları Teknolojik Enstitüsü (İspanya) tesislerinde bulunan hava istasyonundaki bir yıllık süre içinde kaydedilen meteorolojik veriler (sıcaklık, basınç, bağıl nem, rüzgâr hızı) kullanılmıştır. Elde ettikleri sonuçlar göstermiştir ki BPM modeli, bilimsel literatürde kullanılan tek değişkenli olasılık modellerinden (UPMs) daha başarılıdır (Carta ve Mentado, 2007).

Bilgili yaptığı çalışmada, Türkiye'nin güney ve güneybatı bölgesindeki rüzgâr gücü potansiyelini hesaplamak için Weibull, Rayleigh olasılık yoğunluğu fonksiyonları ve "Wind Atlas Analysis and Application" (WAsP) Programını kullanmıştır. Saatlik aralıklarla alınan rüzgâr hızı dataları, Elektrik İşleri Etüt İdaresi (EİE) tarafından Akhisar, Belen, Datça, Gelendost, Söke, Gökçeada, Foça, Gelibolu ve Bababurnu gibi 9 ayrı rüzgâr ölçüm istasyonlarından elde edilmiştir. Saatlik rüzgâr hızları ve yön bilgilerini içeren datalar 1998 ile 2003 yılları arasında kapsamaktadır. Rüzgâr hızı dataları ve diğer meteorolojik parametreler oluşturulan yapay sinir ağının giriş katmanında kullanılırken, hedef istasyon olarak kabul edilen istasyonun rüzgâr hızı değeri, yapay sinir ağının çıkış katmanında kullanılmıştır. Farklı yapay sinir ağı öğrenme algoritmaları kullanılarak bir tahmin modeli oluşturulmuş ve elde edilen sonuçlar ile gerçek değerler karşılaştırılmıştır. Bu çalışma sonucunda görülmüştür ki bulunan hata değerlerinin kabul edilebilir sınırlar içerisinde (Bilgili, 2007).

Carolin Mabel ve Fernandez yaptıkları çalışmada, rüzgâr enerjisi üretiminin hesaplanması ve tahmini için YSA'yı kullanarak değerlendirme yapmışlardır. Hindistan gibi pek çok gelişmekte olan ülkeler, yıl boyunca yüksek ortalama rüzgâr hızları yaşandığı bölgelerde rüzgâr enerjisi programları üzerinde çalışmışlardır. Muppandal ve Tamil Nadu rüzgâr çiftliklerinde, rüzgâr enerjisi üretiminin değerlendirilmesi yapılmıştır. Saha verileri, Nisan 2002-Mart 2005 tarihleri arasında 3 yıllık bir süre içinde bu alanda yedi adet rüzgâr çiftliklerinden toplanan verilerle, rüzgâr çiftliklerinin analizi ve enerji üretimi tahmini için kullanılmıştır. Model, YSA sayesinde geliştirilmiştir. Modelleme, Matlab yazılımı kullanılarak yapılmıştır. Model doğruluğu, rüzgâr çiftliklerinden ölçülen değerlerle simüle edilen sonuçlarla karşılaştırılarak değerlendirilmiş ve aralarında iyi bir uyum olduğu tespit edilmiştir (Carolin Mabel ve Fernandez, 2008).

Almalı ve Ete yaptıkları çalışmada, ortalama rüzgâr hızı ve güç yoğunluğunun hesaplanmasını değerlendirmişlerdir. Bu çalışmada iki parametrelili Weibull dağılışı, parametre tahminlerin elde edilmesinde en yüksek olabilirlik yöntemini (Maximum Likelihood) kullanmışlardır. Çalışmada Yüzüncü Yıl Üniversitesi yerleşkesinde standartlara uygun şekilde 10 m ve 30 m yükseklikte ölçülmüş rüzgâr hızı dataları kullanılmıştır. Rüzgâr hızı verileri, Nisan 2004-Mart 2005 tarihleri arasındaki bir yıllık dönemde, 10'ar dakika arayla kaydedilmiştir. Yıllık veriler ile aylık veriler kullanılarak yapılan hesaplamalarda, aylık ortalama rüzgâr hızı ve güç yoğunlukları ortalaması değerleri ile yıllık verilerden elde edilen ortalama rüzgâr hızı ve güç yoğunluğu değerlerinin birbirlerine çok yakın olduğu gözlenmiştir (Almalı ve Ete, 2009).

Fadare yaptığı çalışmada, Nijerya'da enerji uygulaması için rüzgâr hızı profilinin haritalamasını, YSA uygulamasını kullanarak değerlendirmiştir. Üç katmanlı YSA modeli, ileri beslemeli ve geri yayımlı farklı konfigürasyonları MATLAB programı yardımıyla tasarlamıştır. Aylık ortalama günlük rüzgâr hızı verileri, Nijerya Meteoroloji İşlerinin tarafından işletilen 28 yer istasyonlarında, 1983-2003 tarihleri arasında, 20 yıl süreyle zemin seviyesinden 10 m yükseklikte elde edilmiştir. Eğitim için 18 istasyon ve test içinse de 10 istasyonun veri seti kullanılmıştır. Tahmin edilen aylık rüzgâr hızı 4,7 m/s'dir. Yıllık ortalama rüzgâr hızı ise 0,9-13,1 m/s arasında değişmektedir. Geliştirilen model, Nijerya'nın farklı bölgelerine uygulanmıştır. Oldukça başarılı sonuçlar elde edilmiştir (Fadare, 2010).

Deshmukh ve arkadaşları, genetik algoritma ile sinir ağı modelini, rüzgâr enerji potansiyelinin tahmini için uygulamışlardır. Çalışmada ileri beslemeli sinir ağı (FFNN), rüzgâr enerjisi potansiyelinin tahmini için önerilmiştir. Model, rüzgâr enerjisi dönüşüm sisteminin (WECS) güç çıkışı tahmin etmek için kullanılmıştır. Modelde, rüzgâr hızı ve sayısı girdi parametreleri olarak alınırken, WECS tarafından üretilen elektrik enerjisi modelinin çıktısı olarak tahmin edilmiştir (Deshmukh ve ark., 2010).

Velázquez ve Carta yaptıkları çalışmada, yapay sinir ağları kullanarak rüzgâr enerji yoğunluğu tahmin etmişlerdir. Bu çalışmada, YSA yöntemiyle tahmin edilmiş uzun vadeli rüzgâr güç yoğunlukları, kısa vadeli rüzgâr hız verilerinin vasıtasıyla hesaplanmıştır. Kanarya Takımadalarında bulunan, altı farklı adadaki meteorolojik hava istasyonlarında, 1999-2008 yılları arasındaki 10 yıllık sürede hesaplanan ortalama saatlik rüzgâr hızları ve yönleri, bu çalışmada kullanılmıştır. Çalışma sonucunda, YSA'ya dayalı rüzgâr kaynak tahmininin kısa süreli rüzgâr verilerine bağlı olarak iyi sonuç verdiğini görmüşlerdir (Velázquez ve Carta, 2010).

De Giorgi ve arkadaşları yaptıkları çalışmada, istatistiksel yöntemlere dayalı sayısal hava tahminlerinin rüzgâr enerjisi tahminine etkisini incelemişlerdir. Yapay sinir ağlarına dayalı çeşitli tahmin sistemleri; coğrafi etkileri de hesaba katarak rüzgâr hızını bulmak, farklı zaman dilimlerinde karmaşık bir arazi içinde yer alan bir rüzgâr çiftliğinin elektrik üretimini tahmin etmek için geliştirilmiştir. Farklı tahmin sistemlerinin hataları incelenmiş ve hataların istatistiksel dağılımları hesaplanmış ve bilim dünyasına sunulmuştur (De Giorgi ve ark., 2011).

Chang yaptığı çalışmada, kısa süreli rüzgâr enerjisi tahmin için en küçük ortogonal kareler algoritması (OLS) ve genetik algoritma (GA) ile birlikte radyal tabanlı fonksiyonel (RBF) sinir ağını kullanmıştır. Ayrıca Chang, rüzgâr enerjisi dönüşüm sisteminin (WECS) güç üretimi için doğru bir tahmin yöntemi olduğunu ve rüzgâr enerjisi ile ilişkilendirilmiş başka alanlarda da değerlendirmesinin yapılabileceğini çalışmasında ifade etmiştir. Chang çalışmasında, RBF sinir ağından faydalanarak kısa süreli rüzgâr enerjisi tahmini için OLS ve GA'yı birleştiren melez bir yöntem önermektedir. Önerilen yöntemin başarısını test etmek için, Tayvan Taichung kıyısında kurulu bir WECS rüzgâr enerji üretiminin pratik bilgileri yöntemde kullanılmıştır. Gerçeğe uygun değerlerle tahmin değerleri arasındaki iyi sonuçlar elde edilmiştir; test sonuçları, önerilen tahmin yönteminin doğru ve güvenilir olduğunu göstermiştir (Chang, 2012).

Çelik ve Kolhe yaptıkları çalışmada, yeni matematiksel fonksiyonları bir dizi rüzgâr hızı olasılık yoğunluk dağılımlarını modellemek için kullanmışlardır. Rüzgâr yoğunluğu hesaplamada en yaygın olarak kullanılan Weibull fonksiyonu kullanılmıştır. Çalışmalarında, Weibull fonksiyonunun parametrelerini YSA'da kullanarak yıllık rüzgâr hızı olasılık yoğunluk dağılımını tahmin etmişlerdir. Rüzgâr hızı dağılımı tahmin sonuçları, analitik model sonuçları ile karşılaştırılmıştır. Sonuç olarak, YSA tabanlı rüzgâr hızı dağılım tahminleri, ticari rüzgâr türbini jeneratörleri enerji çıkışını hesaplamak için daha iyi sonuçlar verdiğini göstermiştir (Çelik ve Kolhe, 2013).

Rüzgâr güç miktarı, rüzgârın hızına bağlıdır. Rüzgâr gücü, rüzgâr hızının küpü ile orantılı olduğundan, rüzgâr hızındaki küçük farklılıklar rüzgâr gücünde büyük bir fark oluşturabilir. Rüzgâr hızında % 10 fark, gücünde % 33 değişim yapar. Bu durum, rüzgâr kaynağının yerinin belirlenmesinde önemli bir yer tutmaktadır. Diğer bir deyişle, rüzgâr enerjisi potansiyelini tahmin etmek için rüzgâr hızı ve bir bölgenin rüzgâr rejiminin ve diğer özellikleri doğru anlaşılmalıdır. Bu düşünceden yola çıkılarak, Sardar Maran ve Ponnusamy yaptıkları çalışmada, meteorolojik kule verilerini kullanarak

rüzgâr enerjisi yoğunluğunu tahmin etmişlerdir. Veri elde edebilmek için Sathyabama Üniversitesi ve Chennai bulunan 50 metrelik yükseklikteki meteorolojik kulelerden rüzgâr hızı 2010-2012 yılları arasında üç yıllık bir sürede ölçülmüştür (Sardar Maran ve Ponnusamy, 2013).

Almalı ve arkadaşları yaptıkları çalışmada, Weibull Dağılım (WD) parametrelerinin tahmini için en yüksek olasılık (EYO), en küçük kareler (EKK) ve moment yöntemini (MY) kullanmışlardır. Yöntemleri karşılaştırmak için log olasılık işlevinin istatistiği kullanılmıştır. Bu çalışmada Nisan-2004 ile Mart-2005 tarihleri arasında bir yıllık süreyle ölçülmüş olan, 30 m yükseklikte 10 dakika ortalamalara ait rüzgâr hızı verileri kullanılmıştır. Yapılan değerlendirmede en düşük rüzgâr 0,4 m/s olarak ölçülmüştür. En yüksek rüzgâr hızı değerleri Nisan ve Kasım aylarında 17,6 m/s olduğu görülmektedir. EYO ile ortalama rüzgâr hızının 3,78 m/s ve güç yoğunluğunun da 77,72 W/m² olarak hesaplanmıştır. Ortalama rüzgâr hızı ve güç yoğunluğunun hesaplanması için EYO yönteminin dağılım parametrelerinin tahmin edilmesinde kullanılmasının uygun olacağını belirtmişlerdir (Almalı ve ark., 2013).

Peng ve arkadaşları yaptıkları çalışmada, kısa dönemli rüzgâr enerji tahmini için hibrid stratejisini değerlendirmişlerdir. İki farklı tahmin yöntemi, bir rüzgâr çiftliğinin kısa dönemli rüzgâr enerjisi tahmini için incelenmiştir. Benimsenen stratejilerde, yapay sinir ağlarına fiziksel ve istatistik yöntemlere dayalı karma modeller uygulanmıştır. Tahmin yöntemlerinin performansı, kapsamlı olarak karşılaştırılmıştır. Hibrid modellerin tahmin sürelerinin normal YSA modellerine göre daha fazla zaman aldığı tespit edilmiştir (Peng ve ark., 2013).

Ersöz ve arkadaşları yaptıkları çalışmada, 10 m yükseklikte Kırklareli Devlet Meteoroloji İşleri Genel Müdürlüğü tarafından kurulan ölçüm istasyonunda üç yıl süreyle (2007, 2008 ve 2009) ve birer saat arayla veriler alınmış, alınan verilerden ortalama hız ve yön verileri çalışmada kullanılmıştır. Kırklareli'nde rüzgâr enerjisi potansiyeli hesaplanmasını yapmışlardır. Ayrıca çalışmada, ayrıntılı olarak Türkiye'nin batı bölgesinde rüzgâr potansiyelini inceleyerek, analizini yapmışlardır. Kırklareli bölgesinde 7,8 MW rüzgâr santrali üretilen enerji uyarlamalı ağ tabanlı bulanık mantık çıkarım sistemi (ANFIS) aracılığıyla bir model oluşturmuşlardır. Ardından, Rüzgâr Atlas Analiz ve Uygulama Programı (WASP) ve kapasite kullanım oranları kullanılarak, rüzgâr enerjisi potansiyeli incelenmiştir. Araştırmada elde edilen veriler ışığında bu yöntemin oldukça başarılı ve Kırklareli rüzgâr santrali yatırımı için uygun olduğu sonucuna ulaşılmıştır (Ersöz ve ark., 2013).

Gnana Sheela ve Deepa yaptıkları çalışmada, rüzgâr hızı tahmini için sinir ağı tabanlı hibrit bilgisayar modelini incelemişlerdir. Rüzgârda dalgalanma ve rüzgârın doğrusal olmaması sebebiyle, rüzgâr hızının doğru tahmin edilebilmesi, yenilenebilir enerji sistemlerinde önemli bir rol tutmaktadır. Rüzgâr hızı tahmininin doğruluğunu artırmak için bir sinir ağı tabanlı melez modeli önerilmiştir. Önerilen model, gerçek zamanlı rüzgâr verisi üzerinde test edilmiştir. Nisan 2011-Mart 2012 tarihleri arasındaki gerçek zamanlı veriler, Hindistan rüzgâr çeşitliğinden elde edilmiştir. Rüzgâr ölçümleri, 50 m yükseklikte yapılmıştır. Alınan veri sayısı 2000'dir. Önerilen melez modelin; geleneksel MLP, BPN ve RBF modellerine göre daha başarılı olduğu istatistiksel açıdan gözlenmiştir (Gnana Sheela ve Deepa, 2013).

Özgür yaptığı çalışmada, Kütahya'da rüzgâr enerjisi üretiminin YSA tabanlı değerlendirmesini yapmıştır. Bu çalışmada, Türkiye'de rüzgâr enerjisi potansiyeli araştırılmış ve Kütahya bölgesinde rüzgâr enerjisi potansiyeli üzerinde durulmuştur. Rüzgâr ölçüm istasyonu, rüzgâr enerjisi potansiyelini ortaya çıkarmak için Dumlupınar Üniversitesi Merkez Kampüsünde kurulmuştur. Çalışmada, Temmuz 2001 ve Haziran 2004 tarihleri arasındaki 36 aylık rüzgâr ölçümü yapılan istasyonlardan elde edilen rüzgâr verileri, bölgenin enerji potansiyelini belirlemek amacıyla kullanılmıştır. Bu enerji potansiyeli değerleri kullanarak, Kütahya ilinin elektrik üretim kapasitesi 17 farklı rüzgâr türbini için araştırılmıştır. Bu analizde YSA tabanlı model, Weibull ve Rayleigh dağılım modelleri enerji üretimi belirlemek için kullanılmıştır. YSA modelinde, farklı ileri beslemeli geriye yayılım öğrenme algoritmaları uygulanmıştır (Özgür, 2014).

Maran ve arkadaşları çalışmalarında, YSA' yı kullanarak, meteorolojik istasyonlar arasındaki rüzgâr enerjisinin tahminini yapmışlardır. YSA yöntemi ile rüzgâr hızı kullanarak, rüzgâr enerjisi potansiyelini tahmin etmişlerdir. Rüzgâr enerjisi üretimi için Tamil Nadu bölgesi, en uygun alan olduğu görülmüştür. Tirunelveli, Thoothukudi, Kanyakumari, Theni, Coimbatore ve Dindigul bazı bölgelerinin de rüzgâr enerji üretimi için elverişli olduğu tespit edilmiştir (Maran ve ark., 2014).

Chandel ve arkadaşları yaptıkları çalışmada, Hindistan'ın batı Himalaya bölgesinde 12 yerde rüzgâr enerjisi potansiyel değerlendirmesini yapmışlardır. Araştırmacıların bu çalışmadaki amacı, rüzgâr enerjisi üretimi ve mekanik uygulamaları için bölgenin rüzgâr potansiyelinin kullanılması yönünde politika belirleyerek, Hint devletinin rüzgâr kaynak potansiyelini değerlendirmektir. Rüzgâr Enerjisi Desen Faktörü (WEPF) yöntemi, 2008-2012 tarihleri arasındaki dönemde, rüzgâr verileri

kullanarak farklı arazilerde ve iklimsel bölgelerde 12 noktadan rüzgâr potansiyelini değerlendirmek için kullanmışlardır. Bölgedeki, en yüksek günlük ortalama rüzgâr hızları yaz aylarında, en düşük ise kış aylarında gözlenmiştir (Chandel ve ark., 2014).

Ramasamy ve arkadaşları yaptıkları çalışmada, YSA modelini kullanarak Hindistan'ın rüzgâr hızı tahminini yapmışlardır. Rüzgâr enerjisi potansiyelini tespit etmek için Himachal Pradesh bölgesinde 11 noktadan rüzgâr hızları tahmin edilmiştir. YSA modelinin eğitim ve testi için Hamirpur bölgesindeki ölçülen rüzgâr verilerini kullanılmıştır. Öngörülen ve ölçülen rüzgâr hızları arasında ortalama mutlak yüzde hata (MAPE) ve korelasyon katsayısı sırasıyla 4,55% ve 0,98 olarak bulunmuş, sonuçlar geliştirilen YSA modelinin yüksek doğruluğunu göstermiştir. Öngörülen rüzgâr hızı 1,27- 3,78 m/s arasında değişmektedir. Bir mikro rüzgâr türbini, küçük aydınlatma uygulamaları için uygun bulunmuştur (Ramasamy ark., 2015).

Ayodele ve Ogunjuyigbe yaptıkları çalışmada, YSA'yı kullanarak ve bölgenin iklimsel verilerini de hesaba katarak, rüzgâr hızı ve rüzgâr türbini güç çıkışını tahmin etmişlerdir. Çalışma, Güney Afrika Western Cape-Noupoort bölgesinde gerçekleştirilmiştir. Rüzgâr hızı, geri yayılım eğitim yöntemi ile ileri beslemeli YSA kullanılarak tahmin edilmiştir. Tahmin edilen rüzgâr hızları, gerçek ölçülen rüzgâr hızlarında ile karşılaştırılmıştır. 363 gün boyunca 52272 veriye karşılık, 28 Ekim 2010-Eylül 2011 tarihleri arasında toplanan on dakikalık ortalama veriler; eğitim, deneme ve YSA'yı doğrulamak için kullanılmıştır. R değeri 0,96 olarak hesaplanırken RMSE değeri 0,56 m/s olarak hesaplanmıştır (Ayodele ve Ogunjuyigbe, 2015).

Mohammadi ve arkadaşları yaptıkları çalışmada, aşırı öğrenme makinesine (ELM) dayalı rüzgâr güç yoğunluğunu tahmin etmişlerdir. Rüzgâr enerjisi yoğunluğunun hassas bir düzeyde tahmin edilmesi, rüzgâr enerjisinden yararlanma uygulanabilirliğini belirlemede önemli bir rol tutmaktadır. Bu çalışmada, ELM'ye dayalı yeni bir model rüzgâr enerji yoğunluğunu tahmin etmek için sunulmuştur. Genellikle iki parametrelili Weibull fonksiyonu, en rüzgârlı bölgelerde rüzgâr enerjisi tahminlerinde güvenilir bir yöntem olarak kabul edilmiştir. ELM yönteminin geçerliliği; SVM (Destek Vektör Makinesi), YSA ve GP yöntemlerinin tahminleriyle karşılaştırılarak ispatlanmıştır. Simülasyon sonuçlarına dayanarak, ELM rüzgâr enerjisi tahminleri ve uygulamalarında etkin bir şekilde kullanılabileceği gösterilmiştir. Özetle, etüt sonuçları önerilen ELM yönteminin rüzgâr enerjisi yoğunluğunu tahmin etmek için uygun, hassas ve bu çalışmada incelenen diğer yaklaşımlardan çok daha yüksek performansa sahip olduğunu göstermiştir (Mohammadi ve ark., 2015).

Nikolic' ve arkadaşları yaptıkları çalışmada, sensörsüz rüzgâr hızı tahmini için aşırı öğrenme makinesi yaklaşım analizini yapmışlardır. Rüzgâr hızında hassas tahminler, rüzgâr enerjisinden yararlanma fizibilite belirlenmesinde önemli bir rol oynadığını vurgulamışlardır. Bu çalışmada aşırı öğrenme makinesine (ELM) dayalı yeni bir modelden bahsetmişlerdir. Yapılan incelemede simülasyon sonuçları ve üç istatistiksel testler kullanılarak, modelin güvenilirliği analiz edilmiştir. Simülasyon sonuçları, açıkça ELM'nin sensörsüz rüzgâr hızı tahminlerin uygulamalarında etkin bir şekilde kullanılabileceğini göstermektedir. Kısacası, önerilen ELM modeli sensörsüz rüzgar hızı öngörülerini için uygun, hassas ve bu çalışmada incelenen diğer yaklaşımlardan çok daha yüksek performansa sahip olduğunu göstermektedir (Nikolic' ve ark., 2015).



3. ÇALIŞMA BÖLGESİ VE DATA KAYNAKLARI

Türkiye iklim şartlarına bağlı olarak 7 coğrafi bölgeye ayrılmıştır. Bu bölgeler; Akdeniz bölgesi, Ege bölgesi, Marmara bölgesi, Karadeniz bölgesi, İç Anadolu bölgesi, Doğu Anadolu bölgesi, Güneydoğu Anadolu bölgesidir. Her bölgenin kendine has iklim özellikleri bulunmaktadır. Çalışmada kontrol noktası olarak seçilen 58 lokasyonun, 7 coğrafi bölge üzerinde düzgün dağılımı sağlanmıştır.

Tablo 3.1. Eğitim ve test için kullanılan şehirler

Şehir	Yükseklik(m)	Enlem (°N)	Boylam (°E)	Coğrafi Bölge*
Adana	27	37	35,19	1
Adıyaman	679	37,45	38,16	2
Afyonkarahisar	1034	38,44	30,34	6
Aksaray	961	38,22	34	4
Amasya	412	40,39	35,5	5
Ankara	891	40,04	32,34	4
Antalya	47	36,53	30,4	1
Artvin	615	41,1	41,49	5
Aydın	58	37,5	27,5	6
Balıkesir	100	39,36	27,55	7
Bartın	23	41,38	32,2	5
Batman	610	37,53	41,07	2
Bilecik	539	40,09	29,58	7
Bitlis	1794	38,28	42,09	3
Bolu	737	40,44	31,36	5
Burdur	957	37,43	30,17	1
Bursa	100	40,13	29	7
Çanakkale	5	40,08	26,33	7
Çorum	776	40,32	34,56	5
Denizli	450	37,46	29,06	6
Edirne	51	41,4	26,33	7
Elazığ	1093	38,4	39,13	3
Erzincan	1218	39,42	39,31	3
Erzurum	1757	39,53	41,16	3
Eskişehir	801	39,46	30,33	4
Gümüşhane	1219	40,27	39,27	5
Hatay	100	36,15	36,08	1
Isparta	997	37,47	30,34	1
İstanbul-Göztepe	28	40,54	29,09	7
İzmir	20	38,23	27,04	6
Kahramanmaraş	572	37,35	36,55	1

Tablo 3. 1. (Devam ediyor) Eğitim ve test için kullanılan şehirler

Karaman	1023	37,12	33,13	5
Kars	1775	40,35	43,04	3
Kastamonu	800	41,22	33,46	7
Kırklareli	232	41,44	27,13	4
Kırşehir	1007	39,09	34,1	4
Kilis	638	36,43	37,05	2
Konya	1031	37,52	32,28	4
Malatya	947	38,21	38,18	3
Manisa	70	38,36	27,24	6
Mersin	3	36,48	34,38	1
Muğla	646	37,17	28,22	6
Niğde	1211	37,28	34,41	4
Ordu	4	40,58	37,53	5
Rize	8	41,02	40,3	5
Samsun	4	41,21	36,14	5
Siirt	896	37,55	41,56	2
Sinop	32	42,01	35,09	5
Sivas	1285	39,45	37,01	4
Tekirdağ	4	40,59	27,29	7
Tokat	608	40,18	36,33	5
Trabzon	40	40,59	39,46	5
Tunceli	979	39,06	39,32	3
Uşak	929	38,68	29,47	6
Van	1670	38,29	43,23	3
Yalova	4	40,39	29,16	7
Yozgat	1298	39,39	34,48	4
Zonguldak	154	41,27	31,47	5

* Akdeniz Bölgesi (1), Güneydoğu Anadolu Bölgesi (2), Doğu Anadolu Bölgesi (3), İç Anadolu Bölgesi (4), Karadeniz Bölgesi (5), Ege Bölgesi (6), Marmara Bölgesi (7).

Rüzgâr güç yoğunluğunu tahmin etmek için YSA'a girdi parametresi olarak kullanılan yükseklik, enlem, boylam değerleri ile lokasyonların bölgeleri tablo 3.1'de gösterilmiştir. Adana, Antalya, Burdur, Hatay, Isparta, Kahramanmaraş, Mersin Akdeniz bölgesindeki çalışma lokasyonlarıdır. Adıyaman, Batman, Kilis, Siirt illeri Güneydoğu Anadolu bölgesindeki çalışma lokasyonlarıdır. Bitlis, Elazığ, Erzincan, Erzurum, Kars, Malatya, Tunceli, Van illeri Doğu Anadolu Bölgesindeki çalışma lokasyonlarıdır. Aksaray, Ankara, Eskişehir, Kırklareli, Kırşehir, Konya, Niğde, Sivas, Yozgat illeri İç Anadolu Bölgesindeki çalışma lokasyonlarıdır. Amasya, Artvin, Bartın, Bolu, Çorum, Gümüşhane, Karaman, Ordu, Rize, Samsun, Sinop, Tokat, Trabzon, Zonguldak illeri Karadeniz Bölgesindeki çalışma lokasyonlarıdır. Afyonkarahisar, Aydın, Denizli, İzmir, Manisa, Muğla, Uşak illeri Ege Bölgesindeki çalışma

lokasyonlarıdır. Balıkesir, Bilecik, Bursa, Çanakkale, Edirne, İstanbul-Göztepe, Kastamonu, Tekirdağ, Yalova illeri Marmara Bölgesi bölgesindeki çalışma lokasyonlarıdır. Gerek eğitim gerekse test amaçlı kullanılan veriler 1980-2013 tarihleri arasında Devlet Meteoroloji İşleri Genel Müdürlüğünden alınmıştır.

3.1. Türkiye'nin İklim Tipleri

Türkiye'de 3 çeşit iklim bulunmaktadır. Bunlara Karasal iklim, Akdeniz iklimi ve Karadeniz iklimidir.

3.1.1. Karasal iklim

Bu iklim tipi; İç Anadolu, Doğu Anadolu, Güneydoğu Anadolu'nun büyük bir kısmı ve Trakya'nın iç kısımlarında görülür. Bitki örtüsü bozkuşaktır. Yazları sıcak ve kurak, kışları soğuk ve kar yağışlıdır (Şensoy ve ark., 2008).

3.1.2. Akdeniz iklimi

Bu iklim tipi; Akdeniz, Ege ve Güney Marmara'da görülür. Ancak Marmara'da görülen Akdeniz ikliminin özellikleri daha serttir. Yazları sıcak ve kurak, kışları ılık ve yağışlıdır. Turunçgillerin tarımı için elverişlidir. Güney enlemlerde görüldüğünden don olayı ve kar yağışı kıyı kuşağında ender görülür. Torosların yükseklerinde kışlar kar yağışlı ve soğuktur. En soğuk ay 6,4°C ortalama ile Ocak ayı, en sıcak ay 26,8°C ortalama ile Temmuz ayıdır. Yıllık ortalama sıcaklık 16,3°C'dir. En yağışlı mevsim kış, yıllık yağış ortalaması 725,9 mm'dir. Sıcak olan yaz mevsimi aynı zamanda kuraktır, yağışın %5,7'si bu mevsimde düşer. Yıllık bağıl nem ortalaması %63,2'dir. Bitki örtüsü doğal alanlarda kızılçam, ormanın tahrip edildiği alanlarda makidir. Genellikle 0-800 metreler arası maki hâkimdir. Yüksek alanlarda karaçam, köknar ve sedir ağaçları hakimdir (Şensoy ve ark., 2008).

3.1.3. Karadeniz iklimi

Bu iklim tipi, Karadeniz kıyıları ve kuzey Marmara'da görülür. Her mevsim yağışlıdır. Yazlar serin, kışları kıyılarda ılık, yükseklerde soğuk ve kar yağışlıdır. Yağış yıla dağılmıştır, kurak mevsim görülmez. En soğuk ay Ocak (4,2°C), en sıcak ay Temmuz (22,2°C) ayıdır. Yıllık sıcaklık ortalaması 13,0°C'dir. Yıllık yağış ortalaması 842,6 mm'dir. Yıllık bağıl nem ortalaması %71, yaz yağışlarının oranı %19,4'dür. Bitki


örtüsü kıyılarda geniş yapraklı, kışın yaprak döken, nemcil türlerden (kayın, gürgen, kestane, kızılğaç vb.) oluşan orman, yükseklerde, nemli soğuk şartlara uymuş iğne yapraklılar hakimdir (Şensoy ve ark., 2008).



4.RÜZGÂR ENERJİSİ METODOLOJİSİ

4.1.Rüzgârdaki Enerji

Kütlesi m , hızı v olan hareket halindeki bir hava paketini ele alalım. Hava paketinin kütlesi ve hızına bağlı olarak bir kinetik enerjisi olacaktır. Kinetik enerji aşağıdaki formülle gösterilir (Şekil 4.1).



Şekil 4.1. Kütlesi m , v hızıyla hareket eden bir hava paketi

$$W_{KE} = \frac{1}{2}mv^2 \quad (4.1)$$


Buradaki W_{KE} kinetik enerjidir. Şekildeki gibi hareket halinde olan hava akışındaki güç, birim zamanda akan kinetik enerji akışı olacağından;

$$P = \frac{d}{dt} \left(\frac{1}{2}mv^2 \right) = \frac{1}{2} \frac{dm}{dt} v^2 \quad (4.2)$$

sonucu elde edilir. Buradaki P hava akışındaki güçtür. Eşitlikteki $\frac{dm}{dt}$, birim zamanda akan kütle olarak tanımlanırsa, bu ifade kütleli debiye karşılık gelmektedir. Kütleli debi, \dot{m} şeklinde gösterime sahiptir. Son haliyle güç, eşitlik 4.3'deki gibi olur.

$$P = \frac{1}{2}\dot{m}v^2 \quad (4.3)$$

Güç; birim zaman başına akan enerji olduğundan, hava kütlelerinin A yüzeyinden geçtiği varsayılırsa, A alanı boyunca akan güç P_A gösterilir ve P yerine P_A yazılabilir (Şekil 4.2).



Şekil 4.2. A alanı içerisinde v hızıyla hareket eden bir hava kütlesi

$$P_A = \frac{1}{2} \dot{m} v^2 \quad (4.4)$$

Diğer taraftan yoğunluk ile hacmin çarpımı kütleyi vereceğinden,

$$m = \rho V \quad (4.5)$$

Formülü yazılabilir. Buradaki ρ havanın yoğunluğu, V ise havanın hacmidir.

Eşitlik 4.5'deki akışkan kütlesi m 'in zaman göre türevi alınırsa kütleli debi formülüne ulaşılır.

$$\dot{m} = \rho \cdot \frac{d}{dt}(V) = \rho \cdot \frac{d}{dt}(A \cdot \ell) = \rho \cdot A \cdot \frac{d}{dt}(\ell) = \rho \cdot A \cdot v \quad (4.6)$$

Eşitlik 4.4'de tekrar dönersek;

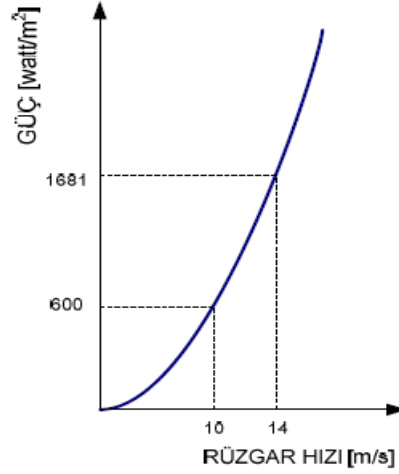
$$P_A = \frac{1}{2} \dot{m} v^2 = \frac{1}{2} (\rho \cdot A \cdot v) v^2 = \frac{1}{2} \cdot \rho \cdot A \cdot v^3 \quad (4.7)$$

Kısaca, denklemi A alanı boyunca oluşan rüzgâr gücü açısından yazarsak;

$$P_w = \frac{1}{2} \cdot \rho \cdot A \cdot v^3 \text{ (Watt)} \quad (4.8)$$

olur. Buradaki P_w hareket halindeki havanın mekanik gücü, ρ havanın yoğunluğu (deniz seviyesinde ve 15°C sıcaklık için 1,225 kg/m³ olarak kullanılmaktadır), A rotor kanatlarının süpürdüğü alan (m²)'dir.

Güç ifadesi, rüzgârın hızına bağlı olarak hızın küpü ile orantılı olarak aşağıdaki gibi değişir (Şekil 4.3).



Şekil 4.3. Rüzgâr hızı güç ilişkisi

Burada verilen güç, birim m^2 başına karşılık gelen güç olup, bu büyüklük bir bölgenin spesifik (özel) gücü veya güç yoğunluğu olarak adlandırılır. Bir bölgenin güç yoğunluğu aşağıdaki formülle hesaplanır.

$$\frac{P_w}{A} = \frac{1}{2} \rho v^3 \quad (4.9)$$

Buradaki $\frac{P_w}{A}$, güç yoğunluğu olup, birimi W/m^2 'dir (Masters, 2004).

İki bölgenin rüzgâr potansiyeli, spesifik rüzgâr güçleri cinsinden karşılaştırılır ve dönen kanatların süpürdüğü alana bağlı olarak, W/m^2 birimiyle verilir. Söz konusu güç, rüzgâr hızının küpü ile orantılı olarak değiştiğinden, örneğin rüzgâr hızının iki katına çıkması gücün 8 kat artması anlamına gelir. Aşağıdaki tabloda, $15^\circ C$ 'de ve 1 atm. basınçta rüzgâr hızının güç yoğunluğuna bağlı değişimi gösterilmiştir (Tablo 4.1).

Tablo 4.1. 15 °C 1 atm.'de rüzgâr hızının güç yoğunluğuna bağlı değişimi (Masters, 2004).

Rüzgâr hızı (m/s)	Güç Yoğunluğu (W/m ²)
0	0
1	1
2	5
3	17
4	39
5	77
6	132
7	210
8	314
9	447
10	613
11	815
12	1058
13	1356
14	1681

4.2. Sıcaklığın Hava Yoğunluğuna Etkisi

Rüzgâr enerjisi verileri sunulduğu zaman, genellikle hava yoğunluğu 1,225 kg/m³ olduğu varsayılmaktadır; başka bir deyişle, hava sıcaklığı 15°C ve basınç 1 atmosfer basınç olduğu varsayılmıştır. İdeal gaz yasasını kullanarak, kolayca diğer koşullarda hava yoğunluğunu hesaplanabilmektedir (Masters, 2004).

$$P.V=n.R.T \quad (4.10)$$

Eşitlik 4.10' de P(atm) basınç, V(m³) hacim, n Mol Sayısı, T(K) Mutlak sıcaklık, R(K⁻¹ . mol⁻¹ .8,2056.10⁻⁵ m³ . atm) ise ideal gaz sabitidir.

Eğer gazın moleküler ağırlığını (g/mol) MA ile gösterirsek, hava yoğunluğu $\rho(kg / m^3)$;

$$\rho = \frac{n.MA.10^{-3}}{V} \quad (4.11)$$

olarak hesaplanır. Eşitlik 4.10'daki V hacmi çekilip eşitlik 4.11 kullanılırsa, eşitlik 4.12 ifadesi elde edilir.

$$\rho = \frac{P.MA.10^{-3}}{RT} \quad (4.12)$$

Güç yoğunluğu bulunması için havanın molekül ağırlığı hesaplanmalıdır. Buda en son elde edilen eşitlik 4.12'nin kullanılmasıyla gerçekleştirilir. Bilindiği gibi hava


moleküllerin karışımı; çoğunlukla azot (78,08%) ve oksijen (20,95%), biraz argon (% 0,93) ile karbondioksit (% 0,035), neon (0,0018%) ve benzeri bileşenlerden oluşmaktadır. Bileşenlerin molekül ağırlıklarını ($N_2= 28,02$ g/mol; $O_2= 32,00$ g/mol; $Ar=39,95$ g/mol; $CO_2= 44,01$ g/mol; $Ne=20,18$ g/mol) kullanarak, hava eşdeğer moleküler ağırlığı hesaplanabilir.

Havanın eşdeğer moleküler ağırlığı= $0,7808 \cdot 28,02 + 0,2095 \cdot 32,00 + 0,0093 \cdot 39,95 + 0,00035 \cdot 44,01 + 0,000018 \cdot 20,18 = 28,97$ g/mol olarak elde edilmiştir (Masters, 2004). Bu sonuç, eşitlik 4.12'de MA yerine yazılır. Rüzgâr hız ölçümü yapılan noktada, havanın basıncı ve sıcaklığı da aynı eşitlikte kullanılmasıyla ilgili lokasyonun hava yoğunluğu hesaplanır.

$15^\circ C$ ve 1 atm' deki hava yoğunluğuna göre ($1,225$ kg/m³), $0^\circ C$ ' de ki hava yoğunluğu yaklaşık %5 daha fazladır. Rüzgâr gücü hava yoğunluğu ile doğru orantılı olduğundan, P_w gücü de %5 oranında daha fazla olacaktır. 1 atm basınç altında, çeşitli sıcaklıktaki hava yoğunluğu değerleri tablo 4.2 ve şekil 4.4'de gösterilmiştir (Masters, 2004).

Tablo 4.2. 1 atm basıncı altında hava yoğunluğunun hava sıcaklığı ile değişimi (Masters, 2004).

Sıcaklık ($^\circ C$)	Yoğunluk (kg/m ³)	Sıcaklık Değişim için Yoğunluk Oranı (K_T)
-15	1,368	1,12
-10	1,342	1,10
-5	1,317	1,07
0	1,293	1,05
5	1,269	1,04
10	1,247	1,02
15	1,225	1
20	1,204	0,98
25	1,184	0,97
30	1,165	0,95
35	1,146	0,94
40	1,127	0,92




Şekil 4.4. 1 atm basıncı altında hava yoğunluğunun hava sıcaklığı ile değişimi

Gerek şekil gerekse tablo incelendiğinde sıcaklık arttıkça hava yoğunluğu azalmaktadır.

4.3. Rakımın Hava Yoğunluğuna Etkisi

Hava yoğunluğu ve dolayısıyla rüzgâr gücü atmosferik basınca ve sıcaklığa bağlıdır. Hava basıncı ise rakımın bir fonksiyonu olduğundan deniz seviyesinin üzerindeki bölgelerde rüzgâr gücü tahmin edilirken bir düzeltme faktörü kullanılmalıdır (Masters, 2004).

Şekil 4.5' de gösterildiği üzere düşey ekseninde statik bir hava kesitini A dikkate alalım. Verilen düşey kolondaki dz kalınlığa sahip ρ yoğunluklu havanın kütlesi $\rho.A.dz$ ile verilir. $z + dz$ yüksekliğindeki yüzeyde hava basıncı $P(z + dz)$ olarak verilir ise hava diliminin alt yüzeyindeki $P(z)$ basıncı, $P(z + dz)$ basıncı ile ilgili hava diliminin birim alan ağırlığı toplamına eşittir (Masters, 2004).



Şekil 4.5. Yükseklik ile basınç arasındaki ilişkiyi bulmak amacı ile dikkate alınan hava koridoru

$$P(z) = P(z + dz) + \frac{g \cdot \rho \cdot A \cdot dz}{A} \quad (4.13)$$

$$P(z) = P(z + dz) + g \cdot \rho \cdot dz \quad (4.14)$$

Burada g , yerçekimi ivmesi olup değeri yaklaşık olarak $9,806 \text{ m/s}^2$ 'dir. Böylece artımsal dP basıncı, yükseklikteki dz artımsal değişimi için yazarsak;

$$dP = P(z + dz) - P(z) = -g \cdot \rho \cdot dz \quad (4.15)$$

$$dP = -g \cdot \rho \cdot dz \Rightarrow \frac{dP}{dz} = -g \cdot \rho \quad (4.16)$$

ρ hava yoğunluğu eşitlik 4.12 ile verildiği üzere, atmosferik basıncın bir fonksiyonudur. Eşitlik 4.12'deki ρ çekilip eşitlik 4.16'daki kullanılırsa;

$$\frac{dP}{dz} = -\left(\frac{g \cdot P \cdot M \cdot A \cdot 10^{-3}}{RT}\right) \Rightarrow \frac{dP}{dz} = -\left(\frac{g \cdot M \cdot A \cdot 10^{-3}}{RT}\right) \cdot P \quad (4.17)$$

sonucuna ulaşılır. Burada rakımın sıcaklık üzerindeki etkisi önemsenmemektedir. Rakımdaki her bir km'lik artış, sıcaklıkta yaklaşık $6,5^\circ\text{C}$ 'lik bir azalmaya neden olmaktadır. Kabullerimizi kolaylaştırmak için hava sıcaklığını dikkate alınan koridor boyunca sabit kabul edilebilir. Bu ihmal çok ufak bir hataya neden olur.

Yukarıdaki formülde bulunan parantez içindeki birimi ise sabit ve birim dönüştürme faktörlerini yerine yazarsak elde edilebilir (Masters, 2004).

$$\frac{dP}{dz} = - \left[\frac{9,806(m/s^2) \cdot 28,97(g/mol) \cdot 10^{-3}(kg/g)}{8,2056 \times 10^{-5}(m^3 \cdot atm / K \cdot mol) \cdot 288,15K} \right] \cdot \left(\frac{atm}{101,325Pa} \right) \cdot \left(\frac{1Pa}{N/m^2} \right) \cdot \left(\frac{1N}{kg \cdot m/s^2} \right) \cdot P \quad (4.18)$$

$$\frac{dP}{dz} = -1,18575 \cdot 10^{-4} P \left[\frac{1}{m} \right] \quad (4.19)$$

Parantez içindeki birim $\frac{1}{m}$ 'dir. Eşitlik 4.19'da diferansiyel denklemin çözümü yapılırsa;

$$\int \frac{dP}{P} = \int -1,18575 \cdot 10^{-4} dz \quad (4.20)$$

$$\ln P \Big|_{P_0}^P = -1,18575 \cdot 10^{-4} \cdot z$$

$$\ln P - \ln P_0 = -1,18575 \cdot 10^{-4} \cdot z$$

$$\ln \frac{P}{P_0} = -1,18575 \cdot 10^{-4} \cdot z$$

$$e^{-1,18575 \cdot 10^{-4} \cdot z} = \frac{P}{P_0}$$

$$P = P_0 \cdot e^{-1,18575 \cdot 10^{-4} \cdot z} \quad (4.21)$$

Buradaki P_0 referans basıncıdır. P ise z yüksekliğindeki basınçtır. Referans basıncı 1 atm değerinde alınır, z yerine h rakım yüksekliği yazılabilir. Bu durumda 4.21 eşitliği aşağıdaki forma dönüşür.

$$P = P_0 \cdot e^{-1,18575 \times 10^{-4} \cdot h} = e^{-1,18575 \times 10^{-4} \cdot h} \quad (4.22)$$

Aşağıdaki tablo 4.3'te 15°C' de hava basıncının ve yoğunluğunun rakım ile olan değişimi özetlenmiştir (Masters, 2004). Tablo incelendiğinde rakım arttıkça basıncın azaldığı, hava yoğunluğunun ise basınca paralel olarak azaldığı görülmektedir.

Tablo 4.3. 15° C' de hava basıncının ve yoğunluğunun rakım ile olan değişimi (Masters, 2004).

Rakım (m)	Basınç (atm)	Hava Yoğunluğu (kg/m ³)	Yükseklik Değişimi İçin Basınç Oranı(K _A)
0	1,000	1,225	1,000
100	0,988	1,211	0,988
200	0,977	1,197	0,977
300	0,965	1,182	0,965
400	0,954	1,168	0,954
500	0,942	1,155	0,942
600	0,931	1,141	0,931
700	0,920	1,128	0,920
800	0,910	1,114	0,910
900	0,899	1,101	0,899
1000	0,888	1,088	0,888
1100	0,878	1,075	0,878
1200	0,867	1,063	0,867
1300	0,857	1,050	0,857
1400	0,847	1,038	0,847
1500	0,837	1,026	0,837
1600	0,827	1,014	0,827
1700	0,817	1,002	0,817
1800	0,808	0,990	0,808
1900	0,798	0,978	0,798
2000	0,789	0,967	0,789
2100	0,780	0,955	0,780

Eğer belirli bir hava yoğunluğu için sıcaklık ve basınç düzeltme faktörleri birleştirilir ise;

$$\rho = 1,225 \cdot K_T \cdot K_A \quad (4.23)$$

elde edilir. Buradaki K_T sıcaklık düzeltme faktörü, K_A rakım düzeltme faktörüdür. Örnek olarak kombine (birleşik) sıcaklık ve rakım düzeltmeleri kullanarak, 2000 m rakımda ve 5°C bir sıcaklıkta 10 m/s hızda rüzgâr güç yoğunluğu bulalım. Tablo 4.2 ve 4.3 ile birlikte gelen K_T ve K_A faktörler kullanılarak gerekli hesaplama yapılabilir.

$$\rho = 1,225 \cdot K_T \cdot K_A = 1,225 \cdot 1,04 \cdot 0,789 = 1,00 \text{ kg/m}^3$$

Bulduğumuz sonuca istinaden 10 m/s rüzgâr hızlarında güç yoğunluğu;

$$\frac{P_w}{A} = \frac{1}{2} \rho v^3 = \frac{1}{2} \cdot 1 \cdot 10^3 = 500 \text{ W / m}^2$$

4.4. Kule Yüksekliğinin Etkisi

Rüzgâr gücü, rüzgâr hızının küpü ile doğru orantılı olduğundan, rüzgâr hızındaki ufak bir değişiklik bile ekonomik açıdan oldukça önemlidir. Yer seviyesinin ilk birkaç yüz metre yüksekliklerinde, rüzgâr hızı yeryüzü ile olan sürtünme ve etkileşiminden dolayı oldukça fazla etkilenir. Pürüzsüz yüzeyler örneğin; durgun deniz yüzeyi rüzgâra karşı oldukça düşük bir direnç gösterir. Rüzgâr hızındaki değişim oranı yüksekliğin artmasıyla birlikte daha düşük seviyelerde kalacaktır. Diğer yandan yüzey rüzgârları oldukça tümsekli arazilerde, orman ve bina alanlarında oldukça düşük olacaktır.

Rüzgâr hızı, yükseklikle değişir. Rüzgâr hızı yer seviyesinde düşük ve dengesizdir, daha yükseklerde, örneğin; 1000 m civarında, daha yüksek ve düzgündür. Bunun nedeni, rüzgârın geçişi sırasında yeryüzü ile yaptığı sürtünmeden kaynaklanmaktadır. Yer yüzeyinin değişkenliği nedeniyle, rüzgâr hızı ile yükseklik arasında bir ilişki kurmak zorunludur.

Rüzgâr yüksekliğe bağlı olduğu kadar yüzey şekillerine göre de farklı özelliklere sahip olacaktır. Yüksek tepelerin önündeki rüzgâr hızı ve şekli ile tepelerin arkasındaki şekil aynı olmayacaktır. Yerden 5 km yükseklikte ise rüzgâr hızı artık yüzey şekilleri ve hareketlerinden etkilenmemektedir.

Enerji şirketlerinin kabul ettiği rüzgâr ölçüm yüksekliği 10, 30 ve 50 m ve en az 1 senelik saatlik ortalamalar şeklindedir. Bunun nedeni, ölçümleri standartlaştırmak ve ölçüm maliyetlerini düşürmektir.

Özetle rüzgâr hızı, yükseklik arttıkça arazi pürüzlülüğüne (sürtünme katsayısı) bağlı olarak logaritmik şekilde artmaktadır. Belirli bir yükseklikte (10 m, 30 m vb.) ölçülmüş rüzgâr hızları kullanılarak, istenilen herhangi bir yükseklikteki (göbek yüksekliği vb.) rüzgâr hızları hesaplanmaktadır. Rüzgâr hızının yükseklikle değişimi Hellman bağıntısı ile verilir (Bansal ark., 2002; Masters, 2004; Patel, 2006).

4.5. Rüzgâr Hızı Güç Denklemi

Rüzgâr hızının yüksekliğe bağlı denklemi aşağıdaki şekilde verilmiştir.

$$\left(\frac{v}{v_0}\right) = \left(\frac{H}{H_0}\right)^\alpha \quad (4.24)$$

Burada v , H yüksekliğindeki rüzgâr hızı, v_0 ise H_0 referans yükseklikteki rüzgâr hızıdır. α ise sürtünme katsayısıdır. Sürtünme katsayısı α , rüzgâra maruz kalan yer yüzeyinin topolojisine bağlı bir katsayıdır. α , Hellman katsayısını ifade etmektedir. Bu

katsayı tablo 4.4.'de farklı yeryüzü topolojileri için verilmiştir (Bansal ark., 2002; Masters, 2004; Patel, 2006).

Rüzgâr gücü rüzgâr hızının küpü ile değiştiğinden 4.24 eşitliği kullanılarak H yüksekliğindeki rüzgâr bağıl gücü, H_0 referans yüksekliğindeki gücün bir fonksiyonu olarak bulunabilir.

Rüzgâr hızı, ölçüm yapılan noktanın coğrafi koşullarına ve yüksekliğine bağlı olarak değişkenlik göstermektedir. Bir rüzgâr türbininde istenen kule yüksekliğindeki rüzgâr hızı aşağıdaki gibi tanımlanır;

$$\frac{P}{P_0} = \left(\frac{V}{V_0}\right)^3 = \left[\left(\frac{H}{H_0}\right)^\alpha\right]^3 \rightarrow \frac{P}{P_0} = \left(\frac{V}{V_0}\right)^3 = \left(\frac{H}{H_0}\right)^{3\alpha} \quad (4.25)$$

Tablo 4.4. Farklı yüzeylerin α rüzgar kesme üs değerleri (Boztepe, 2009).


Arazi Açıklaması	Rüzgâr Kesme Üs Değerleri
Pürüzsüz, sert zemin, göl ya da okyanus yüzeyi	0,10
İşlenmemiş toprak üzerinde kısa çim	0,14
Ayak seviyesinde çim ile kaplı zemin	0,16
Maki, fundalık ağaçlarla kaplı zemin	0,20
Birçok ağaç ve ara sıra bina ile kaplı zemin	0,22 – 0,24
Ağaçlık ve küçük kasabanın kenar mahallesi	0,28 – 0,30
Yüksek binaların olduğu şehir merkezleri	0,4

Yer seviyesinden oldukça fazla yükseklerde rüzgâr yerdeki engellerden etkilenmez. Atmosferin düşük katmanlarında rüzgâr hızı yeryüzüne sürtünmeden dolayı etki eder. Yeryüzünde birçok keskin engelin olduğu yerlerde rüzgârın hızı azalır. Ormanlar ve büyük binalar rüzgâr hızını azaltır. Buna karşılık hava alanlarının pistleri gibi (beton zeminler) yerlerde rüzgâr hızı çok az düşer. Su yüzeyleri (denizler vb.) beton zeminler gibi daha pürüzsüz olduğu için rüzgâr hızına daha az etki yapar. Buna karşılık çimlerle veya çalılarla kaplı zeminler rüzgâr hızını önemli oranda azaltır. Yeryüzü ne kadar çok pürüzlü veya engebeli ise rüzgâr hızı da o oranda azalacaktır (Boztepe, 2009).

4.6. Hız ve Güç Oranının Yükseklikle İlişkisi

Rüzgâr hızları zemine yakın yerlerde yükseklikle değişmektedir. Herhangi bir yükseklikte ölçülen rüzgâr hızı ile farklı bir noktadaki yükseklikte rüzgâr hızı tahmin edilebilmektedir. Bu tahminin yapılabilmesi için en yaygın olarak kullanılan bağıntı Hellmann bağıntısıdır. Yeryüzüne yaklaştıkça sürtünme nedeniyle rüzgâr hızı düşer.

Yüzeyden 10 m yükseklikteki rüzgâr hızı 4 m/s ise 50 metre yüksekteki hız yaklaşık 5m/s'dir. Yani hız yaklaşık % 25 oranında artmıştır. Bu sebepten rüzgâr hızı ölçümleri genellikle yerden 10 m yükseklikte ölçüm yapılarak, farklı yüksekteki rüzgâr hızları buna göre tahmin edilir. Daha net bilgi edinmek için yerinde ölçülen bilgiler her zaman daha gerçekçidir. Şekil 4.6' da rüzgâr hız oranı ve rüzgâr güç oranının yükseklikle ilişkisi gösterilmiştir. Referans yüksekliği olarak 10 m alınmıştır. Adım adım hesaplama yapılarak 100 m'ye kadar rüzgâr hız oranları ve rüzgâr güç oranları hesaplanmıştır. Daha sonra oranlara bağlı yükseklik grafikleri oluşturulmuştur.



Şekil 4.6. α değerlerine bağlı olarak farklı yükseklikler için rüzgâr hız ve güç oranları arasındaki ilişki (Masters, 2004).

5. YAPAY SINİR AĞLARI

Bu bölümde, Yapay Sinir Ağları (YSA) teknolojisinin gelişimindeki kilometre taşları, YSA' nın temel unsurları, öğrenme algoritmaları çeşitli ağ yapıları ve YSA' nın özellikleri üzerinde durulmuştur.

5.1.YSA'nın Tanımı

YSA'nın evrensel bir tanımı olmamakla beraber çoğu bilim adamının, “birçok küçük bilgi işleme biriminin, bir araya gelmesiyle oluşturulan ağlar” olduğu üzerinde uzlaştıkları görülmüştür. YSA'nın neredeyse her yayında farklı bir özelliği ya da uygulaması öne çıkarılarak yeniden tanımlanmaktadır. YSA'nın genel kabul gören ve literatürde sıklıkla rastlanan üç farklı tanımına yer verilmiştir.

Yapay sinir ağının işleyiş özelliklerine dayanan ikinci tür tanımı ise ilk ticari yapay sinir ağının geliştiricisi olan Dr. Robert Hecht-Nielsen' e ait bir tanımdır; “Yapay sinir ağı dışarıdan gelen girdilere dinamik olarak yanıt oluşturma yoluyla bilgi işleyen, birbiriyle bağlantılı basit elemanlardan oluşan bilgi işlem sistemidir.” (Caudill, 1987).

Bu tanıma yakın bir tanımda Teuvo Kohonen' e ait bir tanımdır. Bu tanıma göre, “Yapay sinir ağları paralel olarak bağlantılı ve çok sayıdaki basit elemanın, gerçek dünyanın nesnelereyle biyolojik sinir sisteminin benzeri yolla etkileşim kuran hiyerarşik bir organizasyonudur.” (Kohonen, 1987). Başka bir tanıma göre ise YSA; paralel olarak çalışan birçok basit işlem elemanından oluşan ve fonksiyonu, ağ yapısı, bağlantı ağırlıkları ve hesaplama elemanları ya da düğümlerde gerçekleştirilen işlemler tarafından belirlenen bir sistemdir (Widrow, 1988).

Simon Haykin' e göre YSA; basit işlem birimlerinden oluşan, deneyimsel bilgi biriktirmeye yönelik doğal bir eğilimi olan ve bunların kullanımına imkân veren, yoğunlukla paralel dağıtılmış bir işlemcidir. Bu işlemci iki şekilde beyne benzer;

1. Bilgi, ağ tarafından bir öğrenme süreciyle çevreden kazanılır.
2. Bilgi biriktirmek için sinaptik ağırlıklar olarak da bilinen nöronlar arası bağlantı güçleri kullanılır (Haykin, 1999).

Kısaca YSA, insan beynini model alan, nöron olarak adlandırılan basit işlem elemanlarından oluşan, doğrusal olmayan ve yüksek karmaşıklığa sahip bir bilgi işleme sistemidir.

5.2.YSA'nın Tarihçesi

İnsan beyninin ve düşünme yeteneğinin taklit edilmesi isteği sanıldığı gibi aksine çok eski zamanlarda var olmuş bir istektir. İnsan beyni ve düşünebilme yeteneğine ilişkin ilk açıklayıcı teori geliştirme denemeleri Antik Yunan düşünürleri olan Plato (İ.Ö. 427-327) ve Aristoteles'e (İ.Ö. 384-322) kadar uzanmaktadır. Daha sonra ise Descartes (1596-1650) insanın düşünme yeteneğiyle ilgilenen 18. yüzyıl düşünürü olmuştur (Pankaj, 1992).

Beynin üstün özellikleri, bilim adamlarını üzerinde çalışmaya zorlamış ve beyin nöro-fiziksel yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Beynin bütün davranışlarını modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesi ile çeşitli yapay hücre ve ağ modelleri geliştirilmiştir. Böylece, YSA adı verilen ve günümüz bilgisayarlarının algoritmik hesaplama yöntemlerinden farklı bir bilim alanı ortaya çıkmıştır (Pankaj, 1992). Genel anlamda YSA, beynin bir işlevini yerine getirme yöntemini modellemek için tasarlanan bir sistem olarak tanımlanabilir. Bir YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasında oluşur. YSA'lar öğrenme algoritmaları ile öğrenme sürecinden geçtikten sonra bilgiyi toplama, hücreler arasındaki bağlantı ağırlıkları ile bu bilgiyi saklama ve genelleme yeteneğine sahip olurlar. YSA'lar yapılarına göre farklı öğrenme yaklaşımları kullanırlar (Pankaj, 1992).

YSA'ların temeli olan işlemci elemanların bir ağ yapısı oluşturacak şekilde birbirlerine bağlanma şekli, biyolojik sinir sisteminin işleyiş yönteminden taklit edilerek ortaya atılmıştır. Yapay sinir ağlarının dayandığı ilk hesaplama modelinin temelleri 1943 yılında bir sinir hekimi olan Warren McCulloch ile bir matematikçi olan Walter Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, bir biyolojik nöronun temel fonksiyonlarının basit bir eşik elemanı olarak modellenebileceği gösterilmiştir (McCulloch ve ark., 1943)

1949' da Donald Hebb ise "The Organization of Behaviour" adlı kitabında hücresele seviyede beyin öğrenme mekanizmasından bahsetmiştir (Hebb, 1949).

Hızlı hesaplama yönelik ilk YSA çalışmaları 1950'lerde başlamıştır. Bu yıllarda Frank Rosenblatt tarafından basit nöron modellerine dayalı bir hesaplama modeli, önerilmiş ve ardından "Perseptron" diye bilinen tek katmanlı bir YSA modeli ortaya çıkmıştır (Rosenblatt, 1962).

1954 yılında Farley ve Clark tarafından, rassal ağlar ile uyarlamalı tepki üretme kavramı ortaya atılmıştır. Bu kavram 1958 yılında Rosenblatt ve 1961 yılında Caianiello tarafından geliştirilerek yapay sinir ağlarında önemli gelişmeler sağlanmıştır (Öztemel, 2003).

1958 yılında Rosenblatt tarafından bugünkü makine öğrenme algoritmasının da temeli sayılan, doğrusal çok boyutlu düzlem ile ayrılabilen sorunların çözümünde kullanılan almaçlar geliştirilmiştir (Şen, 2004).

1959 yılında ise Bernard Widrow ve Marcian Hoff basit nöron benzeri elemanlardan oluşan ve Adaline (Adaptive Linear Neuron) ve Madaline (Multiple Adaline) olarak adlandırılan adaptif doğrusal bir eleman gerçekleştirmiştir. Bu modeller ses tanıma, karakter tanıma gibi değişik tahmin işlemlerinde kullanılmıştır (Widrow ve Hoff, 1960).

1969'da Minsky ve Papert, Perceptron isimli kitapta, basit Perceptron modelinin, yalnızca örnek sınıflarının doğrusal bir sınırla ayrılabilmediği örneklemeleri sınıflandırabildiğini; ancak bu modelle, klasik EXOR probleminin çözülmediğini ispatlamışlardır. Fakat 2 katmanlı ileri beslemeli ağ yapılarında kullanılabileceğini öne sürmüşlerdir. Çalışmalarında YSA yardımı ile öğrenme ve hesaplamada aşılması zor engeller olduğunu iddia etmişler ve bu iddiaları ile YSA konusundaki çalışmalarını önemli derecede yavaşlatmışlardır (Minsky ve Papert, 1969).

1969-1982 yılları arasındaki çalışmalarda ise teori, artık oturmuş ve 1982'de Hopfield moleküler biyolojiden beynin daha iyi anlaşılmasına geçişi sağlayan "Neural Network and Physical Systems" adlı çalışması ile çağdaş YSA devrini başlatmıştır (Hopfield, 1982). Bu çalışmada Hopfield, nöronların karşılıklı etkileşimlerine dayanan bir nöral hesaplama modeli önermiştir. Bu model; bir enerji fonksiyonunun alabileceği en az değere indirgen, 1. mertebe lineer olmayan diferansiyel denklemlerden oluşmuştur. Hopfield, ağ seviyesinde ve tek tek nöron seviyesinde var olmayan, hesaplama kapasitesinin bulunduğunu öne sürmüştür. Bu tür YSA, "Hopfield Ağı" olarak isimlendirilmiş ve bu yapı pek çok alanda kullanılmaya başlanmıştır. Bu çalışmaların pratik optimizasyon problemlerinde kullanılabilirliğinin olması YSA konusundaki çalışmalarını hızlandırmıştır.

1986'da Grossberg, ART yani Uyarlanabilir Rezonans Teorisi (Adaptive Resonance Theory) adında bir YSA yapısını geliştirmiştir (Grossberg, 1986). ART çok gelişmiş YSA modeli olmakla beraber henüz çok fazla probleme uygulanmamıştır. O sıralarda Kohonen de "kendi kendini düzenleyen nitelik haritasını (self-organizing

maps-SOM) ” geliřtirmiřtir (Kohonen, 1986). Bu YSA modeli, nümerik aerodinamik akıř hesaplamaları için çoęu algoritmik yöntemden daha etkili olmuřtur. 1986 yılında Rumelhart ve arkadaşlarının geri yayılım algoritmasını geliřtirmesi ile doęrusal olmayan problemlere de yanıt vermeye ve dolayısıyla daha fazla akademisyenin ilgisini çekmeye bařlamıřtır.

1986’da Rumelhart ve McClelland “Paralel Distributed Processing (Paralel Daęılımlı İřleme)” adlı kitaplarında, ileri beslemeli (feed-forward) aęlarda yeni öęrenme modeli olan hatanın geriye yayılması algoritmasını (back propagation algorithm) geliřtirerek, daha önce bu konuda Minsky ve arkadaşları tarafından iddia edilen aksaklıkların ařılabileceęini göstermiřlerdir (Rumelhart ve Mc Clelland, 1986). Geri yayılım algoritması yapay sinir aęlarında oldukça yaygın olarak kullanılan bir algoritmadır. Bu tür öęrenme algoritmalarına da eęitici öęrenme algoritmaları adı verilmektedir. Bugün endüstride birçok YSA uygulamasında bu öęrenme yöntemi ile bunun deęiřik türleri kullanılmaktadır. Bu çalıřmalarla birlikte yapay sinir aęlarında yeni bir dönem bařlamıř ve çalıřmalar hızlanmıřtır. 1988’de Broomhead ve Lowe, özellikle filtreleme problemlerinde oldukça bařarılı sonuçlar alabildikleri Radyal Tabanlı Fonksiyonlar (Radial Basis Functions- RBF) modelini geliřtirmiřlerdir (Öztemel, 2003).

5.3.Yapay Sinir Aęlarının Genel Tanımı

İnsan beyninin en temel parçası, hatırlama, düşünme, her harekette daha önceki deneyimlere bařvurma yeteneęini saęlayan kendine özgü sinir hücreleridir. Sinir hücrelerine nöron denir. İnsan beyinde yaklaşık 10^{11} sinir hücresi vardır. Her bir biyolojik sinir hücresinin yaklaşık 10000 kadar komřu baęlantısı bulunmaktadır. Bu sinirlerden uyarı alır. İnsan beyninin çalıřma frekansı 100 Hz’dir. İnsan beyninin yetiřkin bir insanda aęırlıęı yaklaşık 1,3 kg’dır (Elmas, 2007).

Yapay sinir aęları, insan beyninin özelliklerinden olan öęrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluřturabilme ve keřfedebilme gibi yetenekleri herhangi bir yardım almaksızın otomatik olarak gerçekteřirmek amacı ile geliřtirilen bilgisayar sistemleridir. Bu yetenekleri geleneksel programlama yöntemleri ile gerçekteřirmek oldukça zordur. Bu nedenden, yapay sinir aęlarının programlanması çok zor veya mümkün olmayan olaylar için geliřtirilmiř adaptif bilgi iřleme ile ilgilenen bir bilgisayar bilim dalı olduęu söylenebilir (Öztemel, 2003). Yapay sinir aęları, insan beyninden esinlenerek geliřtirilmiř, aęırlıklı baęlantılar aracılıęıyla birbirine baęlanan

ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. Yapay sinir ağları diğer bir deyişle, biyolojik sinir ağlarını taklit eden bilgisayar programlarıdır.

Yapay sinir ağları bir programcının geleneksel yeteneklerini gerektirmeyen, kendi kendine öğrenme düzenekleridir. Bu ağlar öğrenmenin yanı sıra, ezberleme ve bilgiler arasında ilişkiler kurma yeteneklerine de sahiptir (Elmas, 2003).

Yapay sinir ağları; öğrenme yeteneği, kolayca farklı problemlere uyarlanabilirliği, genelleme yapabilmesi, paralel yapılarından dolayı hızlı çalışabilme yeteneği ve kullanıcının giriş ile çıkış arasındaki ilişkiyi tarif etme mecburiyetinin olmayışı gibi üstünlüklerinden dolayı, pek çok uygulamada tercih edilmektedir (Sağiroğlu ve ark., 2003).

Gerçek zamanda öğrenme, uyarılma ve genelleme yeteneği ile birlikte yapısı gereği çok girişli, çok çıkışlı sistemlere de uygulanabilmesi sebebiyle kontrol alanında tercih edilmektedir. Ayrıca paralel yapısı nedeniyle hatayı azaltma ve hızlı bilgi işleme yeteneği de istenilen bir özelliktir. Günümüzde sistemlerin modellenmesi ve kontrolü için YSA uygulamaları üzerine birçok araştırma yapılmaktadır. YSA alanında en çok kullanılan yazılımlardan birisi, Mathworks Inc. tarafından geliştirilen MATLAB ve bunun YSA araçlarıdır.

5.4.Yapay Sinir Ağlarının Temel Görevi

Yapay sinir ağları, insan beyninin fonksiyonel özelliklerine benzer şekilde,

- öğrenme
- ilişkilendirme
- sınıflandırma
- genelleme
- özellik belirleme ve
- optimizasyon,

gibi konularda uygulanmaktadır. Örneklerden elde ettikleri bilgiler ile kendi deneyimini oluşturur ve daha sonra benzer konularda benzer kararları verirler. YSA, günümüzde birçok probleme çözüm üretebilecek yeteneğe sahiptir. Farklı şekillerde tanımlanmaktadır. Tanımların ortak noktaları bulunmaktadır. Bunların başında gelen ifade ise, yapay sinir ağlarının birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden oluşmaları gelmektedir (Kohonen, 1987).

İnsan beyni dünyanın en karmaşık makinesi olarak kabul edilebilir. İnsan beyni sayısal bir işlemi birkaç dakikada yapabilmesine karşın, idrak etmeye yönelik olayları da çok kısa bir sürede yapabilir. Bilgisayarlar çok karmaşık sayısal işlemleri anında çözümleyebilmelerine karşın idrak etme ve deneyimlerle kazanılmış olan bilgileri kullanabilme noktasında yetersiz kalmaktadırlar. Bu nedenden dolayı, insan beynini bilgisayardan üstün kılan en temel özellik sinirsel algılayıcılar vasıtası ile kazanılmış ve görelî olarak sınıflandırılmış bilgileri kullanabilmesidir. Bu durumda akla gelen soru şu olmaktadır. Bilgisayarlar da insan beyni gibi idrak ve algı yeteneği noktasında geliştirilebilir mi? Bu amaçla uzman sistemler, bulanık mantık, genetik algoritma ve yapay sinir ağları gibi yapay zekâ alt dalları özellikle son yıllarda geniş bir araştırma ve uygulama alanı bulmaktadır (Elmas, 2003).

Yapay sinir ağları bir anlamda paralel bilgi işleme sistemi olarak düşünülebilir. Yapay sinir ağlarına bu bilgiler ilgili olaya ait örnekler üzerinde eğitilerek verilir. Böylelikle örnekler sayesinde açığa çıkan özellikler üzerinde çeşitli genellemeler yapılarak daha sonra ortaya çıkacak ya da o ana kadar hiç rastlanmamış olaylara da çözümler üretmektedir.

Yapay sinir ağları; basit biyolojik sinir sisteminin çalışma şeklini simüle etmek için tasarlanan programlardır. Simüle edilen sinir hücreleri, nöronlar içerirler ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak ağı oluştururlar. Bu ağlar; hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma yeteneğine sahiptirler (Kocabaş, 1999).

5.5.Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağları uygulanan ağ modeline göre farklı karakteristik özellikler gösterir. Bütün modeller için temel olarak, karakteristik özellikten bahsetmek mümkündür. Bu özellikler aşağıdaki gibi sıralanmıştır

- **Yapay sinir ağları makine öğrenmesi gerçekleştirirler:** Yapay sinir ağları bilgisayarların öğrenmesi üzerine yoğunlaşır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar verir.

- **Programları çalışma stili bilinen programlama yöntemlerine benzememektedir:** Geleneksel programlama ile yapay zekâ yöntemlerinin uygulandığı bilgi işleme yöntemleri, birbirinden farklıdır.

- **Bilginin saklanması:** Yapay sinir ağlarında bilgi, ağı bağlantı değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlarda olduğu gibi veriler bir

veri tabanında veya program içinde gömülü değildir. Bilgiler ağın üzerinde saklı olup ortaya çıkartılması ve yorumlanması oldukça zordur.

• **Yapay sinir ağları örnekleri kullanarak öğrenirler:** Yapay sinir ağlarının olayları öğrenebilmesi için o olayla ilgili örneklerin tespit edilmesi gerekmektedir. Örnekleri kullanarak ilgili olay hakkında genelleme yapabilecek kapasiteye kavuşturulurlar. Bunu kısaca adaptif öğrenme olarak adlandırılır. Örnekler olmadan yapay sinir ağının eğitilmesi mümkün değildir. Örnekler ise gerçekleşmiş olaylardır. Ağa olay bütün yönleriyle gösterilemez ve ilgili örnekler sunulmaz ise başarılı sonuçlar elde edilemez. Bunun asıl sebebi, ağın sorunlu olduğundan değil olayın ağa iyi gösterilmediğindendir. Bu nedenle örneklerin oluşturulması ve toplanması yapay sinir ağı biliminde büyük bir öneme sahiptir.

• **Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir:** Yapay sinir ağlarının eğitilmesi demek, örneklerin tek tek ağa gösterilmesi ve ağın kendi mekanizmalarını çalıştırarak örnekteki olaylar arasındaki ilişkileri belirlemesidir. Her ağı eğitmek için elde bulunan örnekler iki ayrı bölümde incelenir. Bunların birincisi(eğitim seti) ağı eğitmek için, diğeri(test seti) ise ağın performansını değerlendirmek için kullanılır. Her ağ ilk olarak eğitim seti ile eğitilir. Ağ bütün örneklere doğru cevaplar vermeye başlayınca eğitim işi tamamlanmış kabul edilir. Daha sonra ağın hiç görmediği test setindeki örnekler ağa gösterilerek ağın verdiği cevaplara bakılır. Eğer ağ hiç görmediği örneklere kabul edilebilir bir hassasiyetle cevap veriyor ise o zaman eğitilen ağ kullanılır. Eğer ağın performansı yetersiz olursa o zaman ağı yeniden eğitmek veya yeni örnekler ile eğitmek gibi bir çözüme gidilir. Bu işleme ağın performansı kabul edilebilir bir seviyeye gelinceye kadar devam eder.

• **Algılamaya yönelik olaylarda kullanılabilirler:** Ağlar daha çok algılamaya yönelik bilgileri işlemede kullanırlar. Bu konuda başarılı oldukları yapılan uygulamalarda görülmektedir. Bilgiye dayalı çözümlerde uzman sistemler kullanılmaktadır. Bazı durumlarda yapay sinir ağı ve uzman sistemleri birleştirmek daha başarılı sistemler oluşturmaya neden olmaktadır.

• **Şekil (örüntü) ilişkilendirme ve sınıflandırma yapabilirler:** Genel olarak ağların çoğunun amacı kendisine örnekler halinde verilen örüntülerin kendisi veya diğerleri ile ilişkilendirilmesini yapmaktır. Diğer bir amaç ise sınıflandırma yapmaktır. Örneklerin sınıflandırılması, verilen örnekleri belirli sınıflara ayırarak daha sonra gelen bir örneğin hangi sınıfa gireceğine karar verilmesi işlemidir.

• **Örüntü tamamlama gerçekleştirilebilir:** Bazı durumlarda ağa eksik bilgileri içeren bir örüntü (pattern) veya bir şekil verilir. Ağın bu eksik bilgileri bulması istenir. Örneğin yırtık bir resmin kime ait olduğunu belirlemesi ve tam resim vermesi gibi bir sorumluluk ağdan istenebilmektedir. Bu tür olaylarda yapay sinir ağlarının çok etkin çözümler ürettiği bilinmektedir.

• **Kendi kendini organize etme ve öğrenebilme yetenekleri vardır:** Yapay sinir ağlarının örnekler ile kendisine gösterilen yeni durumlara adapte olması ve sürekli yeni olayları öğrenebilmesi mümkündür.

• **Eksik bilgi ile çalışabilmektedirler:** Yapay sinir ağları kendileri eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilirler. Eksik bilgiler ile de çalışmaya devam ederler. Hâlbuki geleneksel sistemler bilgi eksik olunca çalışmazlar. Yapay sinir ağlarının eksik bilgiler ile çalışması performanslarının düşüreceği anlamına gelmez. Performansın düşmesi eksik olan bilginin önemine bağlıdır. Hangi bilginin önemli olduğuna, ağ kendisi eğitim sırasında öğrenmektedir. Kullanıcıların bu konuda bir bilgisi yoktur. Eğer, ağ performansı düşük olursa, eksik bilginin önemli olduğu kararına varılır.

Ağın eksik bilgilerle çalışması, yapay sinir ağlarının hatalara karşı toleranslı olmalarına olanak sağlamaktadır.

• **Hata toleransına sahiptirler:** Yapay sinir ağlarının eksik bilgilerle çalışabilme kapasiteleri hatalara karşı toleranslı olmalarını sağlamaktadır.

• **Belirsiz, tam olmayan bilgileri işleyebilmektedirler:** Yapay sinir ağlarının belirsiz bilgileri işleyebilme yeteneğine sahiptir. Olayları öğrendikten sonra belirsizlikler altında ağlar öğrendikleri olaylar ile ilgili ilişkiler kurarak, kararlar verebilirler.

• **Dereceli bozulma gösterirler:** Hatalara karşı toleranslı olmaları yapay sinir ağlarının bozulmaları dereceli (göreceli) olmasına neden olmaktadır. Ağ zaman içerisinde eksik bilgi veya bozuk hücre kaynaklanmasından yavaş yavaş bozulur. Ağlar her hangi bir problem ortaya çıktığında hemen anında bozulmazlar.

• **Dağınık belleğe sahiptirler:** Yapay sinir ağlarında bilgi ağa yayılmış durumdadır. Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir. Tek bir bağlantının bir anlamı yoktur. Ağın bilgilerinin açıklanamamasının sebeplerinden biriside budur. Bu ağlarda, ağın tamamı öğrendiği olayın bütünü karakterize etmektedir. O nedenle bilgiler ağa dağıtılmış durumdadır. Bu ise dağınık bir belleğin doğmasına neden olmaktadır.


- **Sadece nümerik bilgiler ile çalışabilmektedir:** Yapay sinir ağıları sadece nümerik bilgiler ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin nümerik gösterime çevrilmeleri gerekmektedir. Sembolik bilgilerin nümerik değerler ile ifade edilmesinde bilgilerin yorumlanmasını ve üretilen çözümlerin açıklanmasını zorlaştırmaktadır. Yukarıda belirtilen özelliklere ek olarak geliştirilmiş olan her modelin kendisine özgü özellikleri olabilmektedir (Ergezer ve ark., 2003; Öztemel, 2006).

Burada açıklanan özellikler dikkatlice incelendiğinde, yapay sinir ağlarının bilgisayar bilimine oldukça önemli katkıları vardır. Geleneksel bilgisayar yazılım teknolojisi ile çözülemeyen birçok problemi yapay sinir ağları ile çözülebileceği görülebilir. Yapay sinir ağı; eksik ve belirsiz bilgileri işleyebilen en güçlü ve avantajlı problem çözme tekniğidir.

5.6. Biyolojik Sinir Ağları

- **Biyolojik Sinir Ağlarının Yapısı**

Biyolojik sinir sistemi, merkezde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beyin bulunduğu üç katmanlı bir yapıdır. Bunlar; çevreden gelen girdileri elektriksel sinyallere dönüştürerek beyne ileten Alıcı Sinirler (Receptor), beyin ürettiği elektriksel sinyalleri çıktı olarak uygun tepkilere dönüştüren Tepki Sinirleri ile alıcı ve tepki sinirleri arasında ileri ve geri besleme yaparak uygun tepkiler üreten merkezi sinir ağlarıdır. Şekil 5.1'de biyolojik sinir ağının şeması verilmiştir. (Çolak ve ark., 2005).



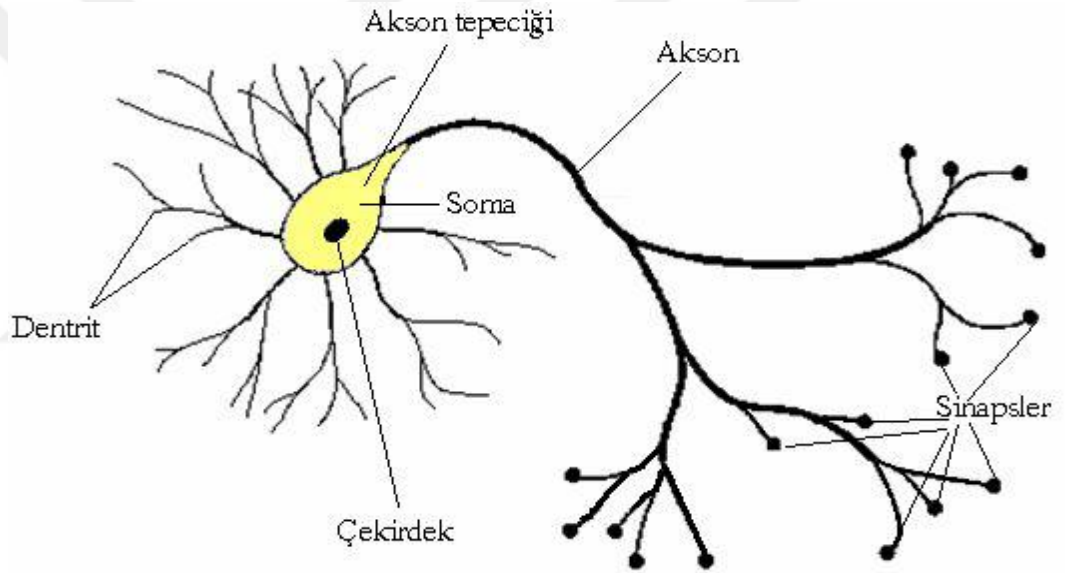
Şekil 5.1. Biyolojik sinir ağının şeması.

Biyolojik sinir sisteminin temel yapı taşı olan nöronların yapısı şekil 5.2'de görüldüğü gibi dört ana bölümde incelenebilir;

- sinapslar

- soma
- akson
- dentritlerden,

oluşmaktadır. Sinapslar sinir hücrelerinin birbiri arasındaki bağıntılardır. Bunlar fiziksel bağlantılar olmayıp bir hücreden diğerine elektrik sinyallerinin geçmesini sağlayan sistemdir. Daha sonra sinyaller somaya gider. Çekirdek bunları işleme tabi tutar. Sinir hücresi kendi elektrik sinyalini oluşturur ve akson aracılığı ile dentritlere iletir. Dentritlerde bu sinyalleri sinapslara göndererek diğer hücelere gönderir. Kısaca özetlersek, dendritler üzerinden girişler alınır, soma tarafından girişler işlenir. Nörondaki sinyalleri taşıyan uzun bir sinirsel bağlantı halindeki akson ise işlenen girişleri çıkışa gönderir (Kulkarni, 1994; Öztemel, 2006).



Şekil 5.2. Biyolojik sinir ağının basitleştirilmiş yapısı (Öztemel, 2003)

YSA, çalışma mantığını canlıların sinir sisteminden alır. Temel yapıtaşı, canlılarda olduğu gibi nöronlardır. YSA birbirine bağlanmış ve hiyerarşik yapıda olan basit işlem elemanlarının yoğun bir paralel dizisi ve verilen girdilere karşı çıktı üretebilen bir kara kutu olarak ta bilinmektedir (Toktaş, 2003). Bu kara kutunun basitçe açıklaması, matematiksel bir fonksiyonu temsil etme şeklindedir. YSA, bu fonksiyonun tam olarak bir matematiksel karşılığına gereksinim duymaz.

YSA'ların beyin ile biyolojik eşitlikleri de aynıdır. YSA, nöron işlem elemanlarından ve sinaptik kümeyi temsil eden ağırlıklardan ibarettir. Nöronlar; giriş, çıkış ve gizli olmak üzere üç tipi vardır. Giriş ve çıkış nöronları ağa veri girişini ve çıkışını sağlayan nöronlardır. Gizli nöronlar ise ağın içerisinde bulunur ve veri giriş ve

çıkışını sağlar. Nöronlar arasında yer alan bağlantı yolları aracılığıyla sinyaller bir nörondan diğerine iletilir. Dolayısıyla nöronların bağlantı yolları, bağlantı yapısına göre ağırlık değerlerinin hesaplanma yöntemi ve aktivasyon fonksiyonunun türü YSA'nın karakterini belirlemektedir. Tablo 5.1'de biyolojik sinir sistemine karşılık YSA'da kullanılan tanımlamalar özetlenmiştir.

Tablo 5.1. Biyolojik sinir sistemi ve YSA'nın karakteristiği

Biyolojik Sinir Ağı	YSA
Nöron	İşlem Elemanı
Sinaps	Ağırlıklar
Dentrit (mesaj algılayıcı)	Toplama İşlevi
Hücre Gövdesi	Transfer Fonksiyonu
Akson (mesaj nakledici)	Çıkış


Kısaca YSA; nöron, hücre, düğüm olarak adlandırılan çok sayıda eleman içerir, bu birimler birbirlerine iletişim hatları ile bağlanır ve her bir iletim hattı ağırlık değeri ile ifade edilir. Ağırlık, aynı zamanda ağına uygulandığı problemin çözüm yöntemine ilişkin bilgiyi de içerir. Nöronların her birinin kendi iç durumu aynı zamanda aktivasyon durumunu belirler. Bu da nöronun almış olduğu giriş sinyallerine göre bir çıkış fonksiyonu üretmesini sağlar. Bir nöron, bir anda bir tek çıkış fonksiyonu üretebilir. Üretilen sinyal ise aynı anda birçok nöron tarafından alınabilir (Kirik, 2010).

5.7. YSA Hücresi

Temel YSA hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahip bilgi işleme sistemleridir. Biyolojik sinir ağlarında olduğu gibi yapay sinir ağlarında da temel unsur, yapay sinir hücresidir. Yapay sinir hücresi, YSA'nın çalışmasına esas teşkil eden en küçük ve temel bilgi işleme birimidir. Ağ içinde yer alan tüm nöronlar bir veya birden fazla girdi alırlar ve tek bir çıktı verirler. Bu çıktı yapay sinir ağının dışına verilen çıktılar olabileceği gibi başka nöronlara girdi olarak da kullanılabilirler. Bir yapay hücre modeli 5 bileşenden oluşmaktadır. Bunlar; girdiler, ağırlıklar, birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıktıdır (Saraç, 2004).

Dış ortamdan alınan veri ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar, ilgili girişin etkisini belirler. Toplam fonksiyonu ise net girişi hesaplar. Net giriş, girişlerle ve bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur. Aktivasyon fonksiyonu işlem süresince net çıkışını hesaplar ve bu işlem aynı zamanda nöron çıkışını verir. Şekilde görülen bias bir b sabiti ile ifade edilebilir. Kavram olarak bias,

aktivasyon fonksiyonunun eşik değeri olarak adlandırılır. Şekil 5.3'te basit bir yapay sinir hücresi (nöron) yapısı gösterilmiştir (Chand ve Lan, 1990).



Şekil 5.3. Basit bir yapay sinir hücresi (nöron) yapısı (Chand ve Lan, 1990)

5.7.1. Girişler

$$\text{Çıkış, } out(o) = f(W \cdot X + b) \quad (5.1)$$

şeklinde nöron çıkışı hesaplanır. Buradaki ağırlıklar matrisi $W = W_1, W_2, W_3 \dots W_n$ 'dir. $X = X_1, X_2, X_3 \dots X_n$ ise girişler matrisidir. n giriş sayısını göstermektedir. Girişlerin ağırlıklarına ve eşik değerine bağlı yeni bir Net fonksiyonu aşağıdaki gibi tanımlanırsa;

$Net = \sum_{i=1}^n W_i X_i + b$ olur. o , çıkış fonksiyonu olmak üzere;

$$o = f(net) \quad (5.2)$$

yazılabilir. Bu durumda eşitlik 5.1 daha genel bir tanımlama ile eşitlik 5.3'deki gibi gösterilebilir.

$$o = f(\sum_{i=1}^n W_i X_i + b) \quad (5.3)$$

Yukarıdaki formülde görülen f aktivasyon fonksiyonudur. Genelde doğrusal olmayan aktivasyon fonksiyonunun çeşitli tipleri vardır. Girişler ($X_1, X_2, X_3, \dots X_n$) çevreden aldığı bilgiyi yapay sinir hücresine (işlem elemanına) getirir. Bunlar ağırlık öğrenmesi istenen örnekler tarafından belirlenir (Elmas, 2003).

5.7.2. Ağırlıklar

Ağırlıklar ($W_1, W_2, \dots W_i$) bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini belirleyen uygun katsayılardır. Her bir giriş kendine ait bir ağırlığa sahiptir. Şekil 5.3' deki W_1 ağırlığı, X_1 girişinin hücresi üzerindeki etkisini

göstermektedir. Ağırlıkların büyük ya da küçük olması önemli ya da önemsiz olduğu anlamına gelmez. Bir ağırlığın değerinin sıfır olması, o ağ için en önemli olay olabilir. Eksi değerler önemsiz demek değildir. O nedenle, artı veya eksi olması etkisinin pozitif veya negatif olduğunu gösterir. Sıfır olması ise herhangi bir etkisinin olmadığını gösterir. Ağırlıklar değişken veya sabit değerler olabilirler (Elmas, 2003).

5.7.3. Toplama fonksiyonu

Birleştirme fonksiyonu olarak da adlandırılan bu fonksiyon bir hücreye gelen net girişi hesaplar. Bunun için farklı fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamı bulmaktır. Genellikle deneme-yanılma yolu ile toplama fonksiyonu belirlenir. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır, ağa giren net girdi bulunmuş olur. Bu durum aşağıdaki gibi formülize edilmektedir (Hamzaçebi, 2011).

$$NET = \sum_i^n X_i \cdot W_i \quad (5.4)$$

Eşitlik 5.4'te X girdileri, W ağırlıkları, n ise bir hücreye gelen toplam girdi sayısını göstermektedir.

Yapay sinir ağları için farklı toplama fonksiyonları zaman içinde yapılan çalışmalarda ortaya çıkmıştır. Yalnız yapay sinir ağlarında daima bu formülün kullanılması şart değildir. Uygulanan yapay sinir ağı modellerinden bazıları kullanılacak toplama fonksiyonunu belirleyebilmektedir. Literatürde yapılan araştırmalarda toplama fonksiyonu olarak değişik formüllerin kullanıldığı görülmektedir. Bazı durumlarda toplama fonksiyonu bu kadar basit bir işlem yerine, en az (min), en çok (max), çoğunlukla veya birkaç normalleştirme algoritması gibi çok daha karmaşık olabilir. Sıklıkla kullanılan bu toplama fonksiyonların bazıları tablo 5.2.'de gösterilmektedir.

Tablo 5.2. Toplama fonksiyonu türleri (Öztemel, 2006)

Net Giriş	Açıklama
Çarpım NET Girdi = $\prod_i X_i.W_i$	Ağırlık değerleriyle ile girdiler çarpılır, elde edilen değerler birbiri ile çarpılarak net değer bulunur.
Maksimum Net Girdi= (Max $X_i.W_i$), i= 1.....N	N adet girdi içerisinde, ağırlıkları ile girdiler çarpıldıktan sonra değerler birbiriyle kıyaslanır ve en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
Minimum Net Girdi= (Min $X_i.W_i$), i= 1..... N	N adet girdi içerisinde, ağırlıkları ile girdiler çarpıldıktan sonra değerler birbiriyle kıyaslanır ve en küçüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
Çoğunluk Net Girdi= $\sum_i \text{sgn}(X_i.W_i)$	Ağırlıkla çarpılmış olan girdilerin işaret fonksiyonu alınır, bu değerler toplanır ve net girdi olarak kabul edilir.
Kümülatif Toplam NET Girdi = Net(eski)+ $\sum_i^n (X_i.W_i)$	Hücreye gelen bilgiler, ağırlıklarıyla çarpılır ve çarpım sonuçlarının toplamı yapılır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.


5.7.4. Aktivasyon fonksiyonları

Yapay nöronun davranışını belirleyen önemli etkenlerden biri de aktivasyon fonksiyonudur Aktivasyon fonksiyonu, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıkışı belirler. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu olarak çıktıyı hesaplamak için de değişik formüller kullanılmaktadır. Bazı modeller bu fonksiyonun türevinin alınabilir bir fonksiyon olmasını şart koşturmaktadır. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonunda da ağırlık işlem elemanlarının hepsinin aynı fonksiyonu kullanması gerekmez. Bazı elemanlar aynı fonksiyonu, diğerleri farklı fonksiyonları kullanabilirler. En uygun aktivasyon fonksiyonunu belirlemek için geliştirilmiş bir yöntem yoktur. Hangi problemlerde hangi fonksiyonun kullanılacağı, YSA'nın çözmeye çalışacağı problemin şartlarına bağlıdır ve etkin bir şekilde deneme yanılma yoluyla tespit edilebilir (Mandic ve Chambers, 2001). Hücre modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli aktivasyon fonksiyonları kullanılabilir. Aktivasyon fonksiyonları sabit parametrelili ya da

uyarlanabilir parametrelili seçilebilir (Haykin, 1999; Aygören ve ark., 2012). Aşağıda, tez çalışmamızda kullandığımız aktivasyon fonksiyonları ifade edilmiştir.

5.7.4.1. Lineer aktivasyon fonksiyonu

Lineer aktivasyon fonksiyonunun çıkışı, girişine eşittir. Sürekli çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonunun lineer aktivasyon fonksiyonu olmasına dikkat edilmelidir. Şekil 5.4'te ise lineer aktivasyon fonksiyonu görülmektedir.



Şekil 5.4. YSA'ların çıkış katmanında kullanılan lineer aktivasyon fonksiyonu


Doğrusal bir problemi çözmek amacıyla kullanılan doğrusal hücre ve YSA' da ya da genellikle katmanlı YSA' nın çıkış katmanında kullanılan lineer aktivasyon fonksiyonu, hücrenin net girdisini doğrudan hücre çıkışı olarak verir. Doğrusal aktivasyon fonksiyonu $f(x) = x$ şeklinde ifade edilir (Ham ve Kostanic, 2001).

5.7.4.2. Sigmoid aktivasyon fonksiyonu

Sigmoid fonksiyonu doğrusal olmayan problemleri çözümünde kullanılan YSA'larda tercih edilir. Türev bilgisine ihtiyaç duyan algoritmalar için avantajlıdır. Sigmoid fonksiyonu tek yönlü ve çift yönlü olmak üzere iki şekilde gösterilir. Logaritmik sigmoidal olarak da adlandırılan tek yönlü sigmoid fonksiyonu [0 1] aralığında çıkış üretmektedir. Sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle doğrusal olmayan problemlerin çözümünde kullanılan YSA'larda tercih edilir. Sigmoid aktivasyon fonksiyonu eşitlik 5.5'deki gibi ifade edilmektedir.

$$f(x) = \text{logsig}(x) = \frac{1}{1+e^{-x}} \quad (5.5)$$

Bu fonksiyon, aynı zamanda lojistik fonksiyon olarak da adlandırılmaktadır. Bu fonksiyonunun lineer olmamasından dolayı türevi alınabilmekte; böylece geri yayımlı ağlarda kullanmak mümkün olabilmektedir. Eşitlik 5.5'in grafiksel gösterimi şekil 5.5'de gösterilmiştir.




Şekil 5.5. Logaritma sigmoid aktivasyon fonksiyonu (Vogl ve ark., 1988).

Tanjant hiperbolik olarak da adlandırılan çift yönlü sigmoid fonksiyonu, [-1 1] aralığında çıkış üretmektedir. Tanjant hiperbolik sigmoid fonksiyonu için gerekli matematiksel ifade eşitlik 5.6' da, matematiksel ifadeye karşılık gelen şekil ise şekil 5.6'daki gibi gösterilmektedir.

$$f(x) = \text{tansig}(x) = \frac{2}{1+e^{-2x}} - 1 \quad (5.6)$$

Bu fonksiyonunda yine türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle doğrusal olmayan problemlerin çözümünde kullanılan YSA'ların tahmininde tercih edilir (Ham ve Kostanic, 2001 ; Sağiroğlu ve ark., 2003).



Şekil.5.6. Hiperbolik tanjant sigmoid transfer fonksiyonu

Bu aktivasyon fonksiyonlarından farklı, fonksiyonlar da bulunmaktadır. YSA'da hangi aktivasyon fonksiyonunun kullanılacağı probleme göre değişmektedir (Vogl ve ark., 1988).

5.7.5.Hücrenin Çıktısı


Hücrenin çıktısı aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. “o” simgesi ile ifade edilmektedir. Üretilen çıktı dışarıya veya başka bir hücreye gönderilir. Hücre kendi çıktısını kendisine girdi olarak da gönderebilir. Bir işlem elemanının birden fazla girişi olmasına rağmen genelde tek çıkışı olmaktadır. Aynı değer birden fazla işlem birimine girdi olarak gitmektedir.

Çıktı, transfer fonksiyonunun sonuçlarını alarak bu sonuçları bağlantılı olduğu işlem elemanına veya ağ dışı kaynaklara gönderir. Bir işlem elemanının çıkışındaki değerlerin genelde [0 1] veya [-1 1] arasında olması istenir.

5.8. Yapay Sinir Ağları Modelleri

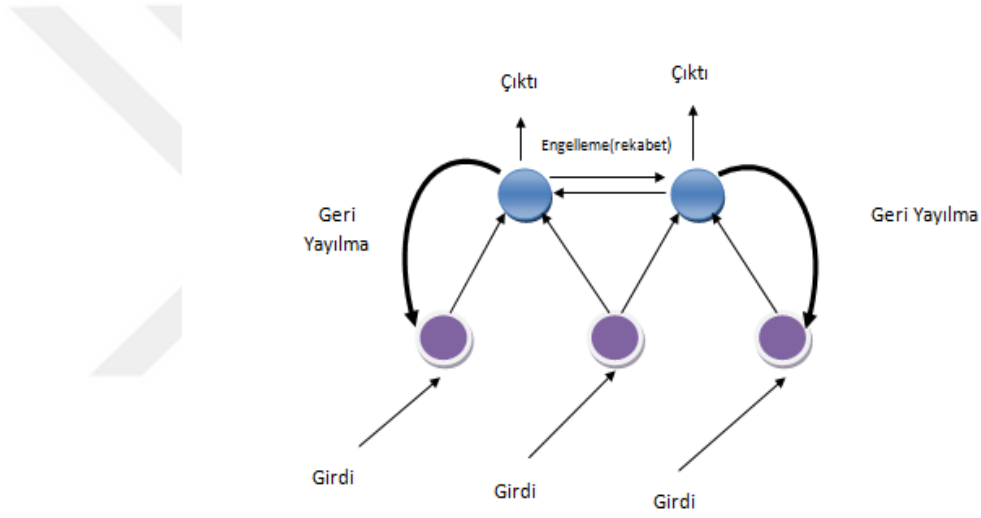
En basit ve en genel yapay sinir ağları, tek yönlü sinyal akışını kullanırlar. YSA modelleri genel olarak iki bölümde toplanmaktadır. Bunlar; ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağlarıdır. Şekil 5.7'de ileri beslemeli yapay sinir ağları, şekil 5.8'de ise geri beslemeli yapay sinir ağlarının yapıları gösterilmiştir. İleri beslemeli yapay sinir ağlarında gecikmeler yoktur, işlem girişlerden çıkışlara doğru

ilerler. Çıkış değerleri öğreticiden alınan istenen çıkış değeriyle karşılaştırılarak bir hata sinyali elde edilerek ağ ağırlıkları güncellenir.



Şekil 5.7. İleri beslemeli yapı (Yurtoğlu, 2005).

Geri beslemeli yapay sinir ağlarında ise tıpkı kontrol uygulamalarında olduğu gibi gecikmeler söz konusudur. Geri beslemeli YSA'da çıkışlar, girişlere bağlanarak ileri beslemeli bir ağ elde edilir.



Şekil 5.8. Geri beslemeli yapı (Yurtoğlu, 2005).

5.9. Öğrenme Algoritmaları

Literatürde bulunan birçok öğrenme algoritması bulunmaktadır. Bu öğrenme algoritmalarının arasında oldukça başarılı olan geri yayımlı öğrenme algoritması, Levenberg-Marquardt öğrenme algoritması aşağıda açıklanmıştır.

5.9.1. Geriye yayılım öğrenme algoritması

Geri yayılım ile öğrenen ağlar hiyerarşik yapıdadır. Giriş, çıkış ve en az bir gizli katman olmak üzere üç katmandan oluşurlar. Gizli katman ve gizli katmandaki düğüm sayısı değiştirilebilir. Düğüm sayısının artması ağın hatırlama yeteneğini artırmakla birlikte öğrenme işleminin süresini uzatmaktadır. Düğüm sayısının azaltılması eğitim

süresini kısaltmakta fakat hatırlama yeteneğini azaltmaktadır. Giriş katmanındaki her bir düğüm gizli katmandaki her düğüme, gizli katman birden fazla ise bu katmandaki her bir düğüm kendisinden sonra gelen katmandaki her düğüme ve gizli katman çıkışındaki her düğüm çıkış katmanındaki her düğüme bağlıdır. Bir katmandaki hiçbir düğüm kendi katmanındaki diğer bir düğüme bağlı değildir. Her katmanın çıkış değerleri bir sonraki katmanın giriş değerleridir. Bu şekilde giriş değerlerinin ağırlık girişinden çıkışına doğru ilerlemesine ileri besleme denir. Geri yayılım ağırlıkta hatalar, ileri besleme aktarım fonksiyonunun türevi tarafından, ileri besleme mekanizması içinde kullanılan aynı bağlantılar aracılığıyla, geriye doğru yayılmaktadır. Öğrenme işlemi, bu ağırlıkta basit çift yönlü hafıza birleştirmeye dayanmaktadır. İleri beslemeli ağırlıkta bilgi akışının girişten çıkışa doğru tek yönde olduğu, birbirine bağlı nöronlardan oluşur. Bu ağırlıkta, ileri yönde olan bilgi akışı başlangıç noktasına geri gönderilmez ve böyle bir bilgi akış döngüsü oluşturulmaz. Bu ağırlıkta girdi ile çıktıyı birleştiren bilginin ileriye doğru aktığı ve herhangi bir geri beslemenin olmadığı ağırlıkta (Dreyfus, 2005).

Geril yayılım öğrenme yöntemi, türevi alınabilir aktivasyon fonksiyonlarını çok katmanlı herhangi bir ağırlıkta uygulayabilir. Bu işlem sistem hatasını veya maliyet işlevini azaltma esasına dayanan bir optimizasyon işlemidir. Bu yöntemde ağırlık ayarlamaları yapıldığı için ‘geril yayılım’ ismi kullanılmıştır. Öğrenme fazında, giriş örnekleri ağırlıkta belli bir sırada sunulur. Her bir çalışma örneği, çıkış örneği hesaplanana kadar katman katman ileri yayılır. Hesaplanan çıktı daha sonra olması beklenenle karşılaştırılıp arasındaki fark ‘hata’ olarak bulunur. Hatalar, katman katman sinaptik ayarlamaların yapıldığı geril besleme bağlantılarında ‘girişler’ olarak kullanılır. Geriye doğru olan bağlantılar sadece ‘öğrenme fazı’ için kullanılırken, ileri doğru olan bağlantılar hem öğrenme amacıyla hem de işlemsel fazlar için kullanılır (Dreyfus, 2005).


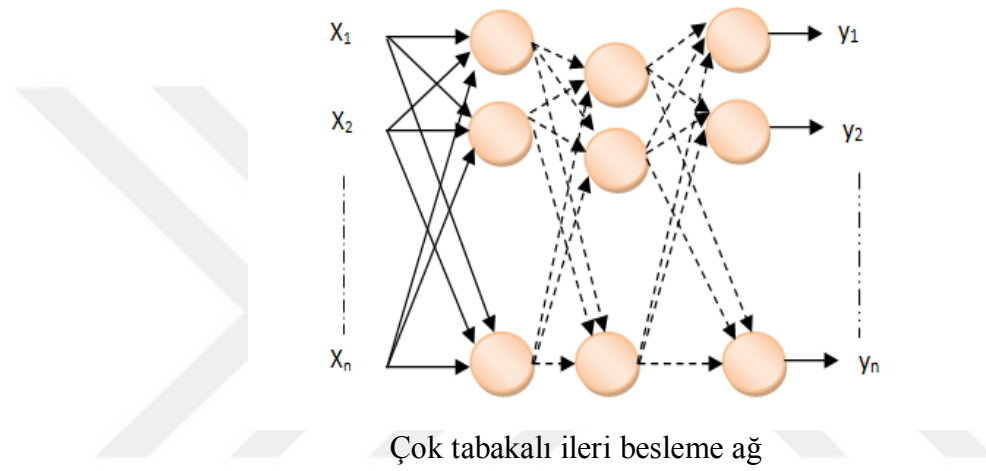
Geril yayımlı öğrenme kullanıldığında, sonraki katmanların hataları kullanılarak gizli katmanın ağırlıkları ayarlanır. Böylece çıkış katmanında hesaplanan hatalar son gizli katman ile çıkış katmanı arasındaki ağırlıklar ayarlanır. Aynı biçimde, bu işlemler ilk gizli katmana kadar tekrarlanır. Bu yolla hatalar katman katman, ilgili katmanın ağırlık düzeltmeleri yapılarak geriye doğru yayılır. Tamamlanan çalışma süresi içinde ‘toplam hata’ en aza indirilinceye kadar bu işlemler tekrarlanır.

Geril yayılım algoritması, sinir ağının eğitimci sınıfına giren genel bir algoritmadır. Daha öncede belirtildiği gibi girişlerle çıkışlar arasındaki hata sinyali bulunarak, ağırlıklar bu hata sinyaliyle güncellenmektedir. Hata yani $e(k)$, arzu edilen

çıkış (*gerçek çıkış* – $y(k)$) ile sinir ağının çıkışı ($o(k)$) arasındaki fark eşitlik 5.7'deki gibi gösterilir.

$$e(k) = y(k) - o(k) \quad (5.7)$$

Şekil 5.9' da birçok sinir hücresinin bir birine bağlandığı ileri yönlü ve geri yönlü çok katmanlı YSA görülmektedir. Giriş katmanı ile çıkış katmanı arasındaki katman veya katmanlar gizli katman olarak adlandırılır. Sinir ağlarında kaç tane gizli katman kullanılacağı ve her bir gizli katmanda kaç nöron olacağı bugüne kadar belirlenememiştir, probleme göre değişen bu nitelikler deneme-yanılma yoluyla bulunur (Martin ve Mohammad, 1994; Yurtoğlu, 2005).



Şekil 5.9. İleri ve geri beslemeli çok katmanlı sinir ağı (Yurtoğlu, 2005).

5.9.2. Levenberg - Marquardt öğrenme algoritması

Geri yayılım algoritması (GYA) çok kullanılmasına rağmen bazı dezavantajları bulunmaktadır. GYA, sonuca çok yavaş olarak yaklaşmaktadır. Geri yayılım, bir adım düşme algoritmasıyken, Levenberg - Marquardt (LM) algoritması Newton metoduna bir

yaklaşımıdır. LM algoritması, Newton metodunun hızıyla, adım düşme metodunun sağlamlığının bileşkesidir (Yurtoğlu, 2005).

Her bir iterasyon adımında hata yüzeyine parabolik yaklaşımla yaklaşılır ve parabolün minimumu o adım için çözümü oluşturur. $E(x)$ fonksiyonuna sahip olduğumuzu ve x parametresine göre minimize etmek istediğimizi düşünelim. Newton metodunda şöyle olacaktır.

$$\Delta x = (\Delta^2 E(x))^{-1} \Delta E(x) \quad (5.8)$$

Burada $\Delta^2 E(x)$ ifadesi Hessian matrisidir ve $\Delta E(x)$ ise eğimdir. $E(x)$, e_i 'in karelerin toplamı fonksiyonu olduğundan;

$$E(x) = \sum_{i=1}^N e_i^2(x) \quad (5.9)$$

yazılabilir. Bundan sonra $\Delta E(x)$ ve $\Delta^2 E(x)$ aşağıdaki gibi gösterilebilir.

$$\Delta E(x) = J^T(x) \cdot e(x) \quad (5.10)$$

$$\Delta^2 E(x) = J^T(x) \cdot J(x) + S(x) \quad (5.11)$$

burada $J(x)$ Jacobian matrisi olup aşağıdaki gibi gösterilir.

$$J(x) = \begin{bmatrix} \frac{\partial e_1(x)}{\partial x_1} & \frac{\partial e_1(x)}{\partial x_2} & \dots & \frac{\partial e_1(x)}{\partial x_n} \\ \frac{\partial e_2(x)}{\partial x_1} & \frac{\partial e_2(x)}{\partial x_2} & \dots & \frac{\partial e_2(x)}{\partial x_n} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_N(x)}{\partial x_1} & \frac{\partial e_N(x)}{\partial x_2} & \dots & \frac{\partial e_N(x)}{\partial x_n} \end{bmatrix} \quad (5.12)$$

$$S(x) \text{ ise } S(x) = \sum_{i=1}^N e_i(x) \nabla^2 e_i(x) \quad (5.13)$$

şeklinde ifade edilir. Bundan sonra, Gauss-Newton metodu için $S(x)$ yaklaşık olarak kabul edilir ve Δx aşağıdaki biçimde gösterilir.

$$\Delta x = (J^T(x) \cdot J(x))^{-1} \cdot J^T(x) \cdot e(x) \quad (5.14)$$

Levenberg-Marquardt modifikasyonu ile Gauss-Newton metodu şöyle olur.

$$\Delta x = (J^T(x) \cdot J(x) + \mu I)^{-1} \cdot J^T(x) \cdot e(x) \quad (5.15)$$

μ parametresi bir adımda $E(x)$ artımı sonucunda bir faktörle (β) ile çarpılır, bir adım $E(x)$ azaltışında, μ parametresi β 'ya bölünür. μ büyükse algortmada adım düşümü ($1/\mu$ adımı ile) olur, küçük μ parametresi için algortmada Gauss-Newton yaklaşımı oluşturulur. Bu algortmadaki anahtar adım Jacobian matrisinin hesaplanmasıdır. Sonuç olarak Levenberg-Marquardt algortması çok hızlı olarak çözüme ulaşmasına rağmen çok fazla bellek gerektirmektedir. Geri yayılım algortması ise sonuca yavaş ulaşmakta ve daha az bellek gerektirmektedir.

YSA'ların eğitimi için problemin türüne en uygun algoritmanın seçilmesi gerekmektedir. Rumelhard'nın hata geri yayılım algoritmasının sinir ağlarını etkili bir şekilde eğittiğini göstermesinden bu yana birçok eğitim algoritması geliştirilmiş, fakat bunlardan sadece birkaçının verimli olarak bir sinir ağını eğittiği gözlenmiştir (Rumelhart ark., 1985). Buna rağmen, en iyi eğitim algoritmasının bile nöron sayısı azaltılmış bir sinir ağının eğitiminde güçlük çektiği bilinmektedir. Bu çalışmada, rüzgar güç yoğunluğu hesaplanmasında kullandığımız öğrenme algoritması Levenberg-Marquardt (trainlm) yanında; trainbfg, trainscg, traincgp , traincgb, traincgf ve trainoss öğrenme algoritmaları da kullanılmıştır. İlgili öğrenme algoritmaları için gerekli bilgiler tablo 5.3' de açıklanarak gösterilmiştir (Dennis ve Schnabel, 1983; Battiti, 1992; Yu ve Wilamowski, 2011).

Tablo 5.3. Eğitim algoritmaları

Fonksiyon	Açıklama
traincgf	Fletcher-Reeves tekniğini kullanan “Conjugate Gradient: Eşlenik Gradyan (CG) ” algoritmasıdır. Standart CG algoritmasına göre daha az işlem gerektirir. Standart geriye yayılım algoritması ağırlıkları “steepest descent” yönünde, yani hatanın azaldığı yönün tersine doğru ayarlamaya çalışır. Böylece hızlı çalışmış olur. Fakat gerçek değere yakınsamada çok başarılı olmaz. Eşlenik azaltmada ise ağırlıkların ayarlanması işlemi, eşlenik yönünde yani hata azaltmasının olduğu yöne doğru yapılır. Bu sebeple standart geriye yayılma algoritmasına göre gerçek değere daha fazla yakınsar. Çok az hafıza alanı ve işlem yükü gerektirdiği için büyük ağlarda tercih edilebilir.
traincgp	Polak-Ribiere tarafından geliştirilen CG algoritmasıdır. traincgf'ye göre daha fazla hafıza ve işlem gücü gerektirir. Fakat bazı problemlerin çözümünde, çözüme daha hızlı yakınsar.
traincgb	Powell-Beale Eşlenik Gradyan algoritmasıdır. traincgp'den daha fazla hafıza ve işlem gücü gerektirir ama genellikle çözüme daha hızlı yakınsar.
trainscg	Ölçeklendirilmiş CG algoritmasıdır. Genel amaçlı bir eğitim algoritması olarak kullanılabilir.
trainbfg	BFGS (Broyden, Fletcher, Goldfarb ve Shanno) Quasi-Newton yöntemidir. CG algoritmasına göre daha fazla işlem gerektir. Ancak sonuca daha az devirde (iterasyonda) ulaşır.
trainoss	One Step Secant (Tek Adım Sekant) yöntemidir. CG algoritması ile Quasi-Newton algoritmasını birleştiren bir yöntemdir.

5.10. Bir YSA Modellemesinde Dikkat Edilecek Hususlar

Bir problemin çözümünü yapay sinir ağı kullanarak bulmak istediğimiz zaman aşağıdaki süreci uygulamamız gerekir.

1. Ağın eğitiminde ve testinde kullanılacak olan veriler toplanır. Kaç değişkenin girdi ve kaçının çıktı olacağına karar verilmelidir. Böylece giriş ve çıkış katmanında kaçar hücre olacağı da belirlenmiş olur.
2. Elde edilen veriler problemin türüne verilere de bağlı olarak eğitim ve test için ayrıştırılır. Belirli bir oran olmamasına rağmen veriler genellikle %70, %20 ve %10'luk paketlere ayrılır (Yao ve Tan, 2001). Eğer veri dizisinde sıra önemli değilse ayrıştırma rastgele yapılırsa yani örnekler veri setinin her yerinden alınırsa eğitim daha başarılı olur.
3. Problemin türüne göre ağın yapısına karar verilir.
4. Problemin türüne göre öğrenme yöntemi seçilir.
5. Ağa uygulanacak ilk değerler verilir.
6. Veriler ağa verilecek şekilde uyarlanır ve ağın giriş katmanına uygulanır.
7. Eğitime başlanır, hatayı en aza indirmek için ağırlıklar sürekli gözden geçirilir.
8. Hata kabul edilebilir sınırlar geldiğinde eğitim durdurulur ve ağ test edilir. Ayrıştırılan verinin ilk paketi ile eğitim gerçekleştirildikten sonra elde edilen ağırlıklar ile ikinci paket veri ağa uygulanır. Eğer ikinci eğitimden sonra ağırlıklardaki değişimler ihmal edilebilir düzeyde ise ağ test edilmeye hazır demektir.

Eğer testlerde kabul edilebilir sonuçları elde edilmediyse;

- a) Eğitim için daha fazla ve daha uygun veriler toplanarak ağa uygulanabilir.
- b) Eğitim ve test için ayrılan veriler yeniden düzenlenebilir.
- c) Ağın yapısı değiştirilebilir ya da başka bir model YSA kullanılabilir.
- d) Öğrenme algoritması değiştirilebilir.
- e) Başlangıç değerleri yenilenerek ağ yeniden eğitilebilir.

5.11. YSA'nın Üstünlükleri ve Dezavantajları

5.11.1. Üstünlükleri

1. YSA öğrenmenin bir modeli olarak düşünülebilir. Örneklerden faydalanarak öğrenme işlemi gerçekleştirirler. YSA yardımıyla bir kararın verilebilmesi için önce ağın eğitilmesi ve performansının test edilmesi gerekmektedir.

2. YSA eksik bilgileri işleyerek sonuca varabilir. Yapay sinir ağları eğitildikten sonra eksik bilgiler ile çalışabilir ve sonuç üretebilirler.
3. YSA hatalara karşı toleranslıdır. Hatalara karşı toleranslı olmalarını, YSA'nın eksik bilgiler ile çalışabilme kapasitesinden bir varlığıdır (Öztemel, 2003).

5.11.2. Yapay sinir ağlarının dezavantajları

Bir önceki başlık altında bahsedilen avantajlarının yanı sıra YSA'lar da kusursuz değildirler. YSA'ların da önemli dezavantajları bulunmaktadır (Swingler,1994).

- YSA'lar donanıma bağlı olarak çalışırlar ve ağ paralel işlemciler üzerinde çalışabilir. Özellikle paralel işlem yapmalarından dolayı çok hızlı çalışan paralel işlemcilere ihtiyaç duyarlar. Paralel işlemleri seri makinelerde yapmak, zaman kaybına neden olabilir.
- YSA'lar her türlü problemin çözülmesi için hemen kullanılabilir bir yöntem değildirler. Problemin yapısına göre, verilerin girilmesinde değişikliğe gitmek gerekebilir.
- Probleme uygun ağ yapısının belirlenmesi genellikle deneme yanılma yöntemi ile yapılmaktadır. Dolayısı ile doğru ağ modeli kullanılmazsa performansı düşük sonuçlar elde edilebilir. Bundan sebepten dolayı bulunan çözümün en iyi çözüm olduğunu garanti etme problemi ortaya çıkacağından, YSA'lar kabul edilebilir sonuçlar üretebilirler. Ancak en iyi çözümü garanti edemezler.
- İstatistiksel çözümlerle fazla yoruma ve açıklamaya ihtiyaç bırakmayan sonuçlar elde edilebilmesine rağmen YSA'nın ürettiği sonuçlardan ağırlıkların yorumlanması o kadar kolay değildir. Dolayısıyla YSA ile ulaşılan sonuçlarda model kapalı bir kara kutu gibi düşünülebilir (Yıldız, 2001).
- Ağın eğitiminin ne zaman bitirileceğine karar vermek içinde geliştirilmiş bir yöntem yoktur. Ağın örnekler üzerindeki hatasının belirli değerin altına indirilmesi eğitimin tamamlanması için yeterli görülmektedir. Fakat sonuçta optimum öğrenmenin gerçekleştiği söylenememektedir. Sadece iyi çözümler üreten bir ağ olduğundan bahsedilebilir.
- YSA'ların sadece nümerik değerlerle çalışması, problemin ağa gösterilmesinde önemli bir eksiklik oluşturmaktadır. Problemin nümerik gösterime dönüştürülmesi gerekir. Uygun bir gösterim mekanizmasının kurulamamış olması problemin çözümünü engelleyeceğinden düşük performanslı bir öğrenme elde edilecektir.

- Bilgiler ağa “gömülü” olmasından dolayı yorumlanması ve çözümün elde edilmesinde YSA'nın davranışının takibi zordur. Ağın davranışı açıklanamaz. Bir probleme çözüm üretildiği zaman bunun nasıl ve neden üretildiği konusunda bir bilgi bulmak mümkün değildir. Bu ise ağın sonucuna olan güveni azaltmaktadır (Şen 2004; Öztemel 2006).
- Ağ oluşturulurken ağın parametre değerlerinin (öğrenme katsayısı, proses elemanı sayısı vb.) belirlenmesinde kullanılan bir kural olmaması önemli bir eksikliklerdir. Bu parametrelerin bulunması, kullanıcı tecrübesine bağlıdır. Bu parametre değerleri için belirli standartların oluşturulması çok zor olduğundan her problem için ayrı ayrı değerlendirmeler yapılmalıdır (Şen, 2004; Öztemel, 2006).

5.12. Yapay Sinir Ağları Modeli Oluşturma Adımları

YSA modeli oluşturma işlemi; YSA veri tabanı tasarımı, YSA'da eğitime/öğrenme, test ve kullanma olmak üzere dört ana başlıkta incelenebilir (Toktaş, 2003).

YSA veritabanı tasarımı: Geliştirilmekte olan uygulama çok iyi bilinmelidir. Problem çözümü için, YSA öğrenme yöntemlerinden en uygun öğrenme yöntemi seçilir. Problemin giriş ve çıkış katmanlarında yer alacak nitelik ve miktar bildiren parametreler net olarak tanımlanmalıdır. Başarılı bir YSA geliştirmek için yeterli miktarda iyi veriye sahip olunmalıdır. YSA tecrübe ederek öğrenir. Bu tecrübenin esası geçmişteki verilere dayanmaktadır. Bu veriler ne kadar çok, çeşitli ve sağlam olursa öğrenme ve sonuçta karar verme o kadar etkin olur. Test verileri ile eğitime verileri ayrılır. Bu adımlar sonucunda, YSA veri tabanı tasarlanmıştır. Artık problem eğitime hazırdır.

YSA'da eğitime/öğrenme: Bir sinir ağında öğrenmenin anlamı, ağın belirli bir probleme ait giriş ve çıkış verileri arasında doğru çıktıları üretmesini sağlayacak YSA içindeki tüm bağlantı ağırlıklarının optimum değerlerinin bulunmasıdır. Bu işlem, öngörülen çıkış ile istenilen çıkış arasındaki hata belli bir değerin altına düşene ya da eğitime işlemi belli bir tekrar sayısına ulaşana kadar devam eder. Dolayısıyla öğrenilen bilgi, işlem elemanları arasındaki bağlantı hatları üzerinde saklanır ve ağırlıklar vasıtasıyla gösterilir. Bu ağırlıklar ilgili problemin belirli özelliklerini hafızada saklayan elemanlar gibi düşünülebilir. Bilgi işleme ise bir olay gösterildiğinde hafızadan ilgili

özellikleri çağırarak ve bunlar ile ilgili girdileri birlikte analiz ederek karar vermek şeklinde yorumlanabilir. Girdi ve çıktı katmanlarındaki işlem elemanları bilindiğine göre, YSA'nın en iyi performans gösterdiği, yani ağ hatasını minimum, öğrenme hızını maksimum yapan optimum veya optimuma yakın gizli katman sayısı ve her bir gizli katmandaki işlem elemanı sayıları deneme-yanılma ile belirlenir. Öğrenme işlemi için genellikle bir eğitime algoritması kullanılır ve bir öğrenme örneğine göre ağırlıkların nasıl düzeleceği, bu algoritma tarafından belirlenir. Bu stratejileri uygulayan çeşitli öğrenme kuralları bulunmaktadır (Toktaş, 2003).

Test: YSA'nın iyi eğitilip eğitilmediğini anlamak için, YSA'ya eğitim verileri dışında daha önce hiç bilmediği veriler (test verileri) sunulur ve doğru sonuçlar verip vermediği kontrol edilir. Karşılaştırma amacıyla istatistiksel hata hesaplanır. Eğer büyük bir hata oluşuyorsa, deneme-yanılma yoluyla değişik eğitime algoritmaları, ağ yapısı (gizli katman sayısı, gizli katman işlem elemanları) değiştirilir. Eğitime ve test işlemleri tekrarlanır. Çok az işlem elemanı sayısı öğrenme oranını düşürdüğü gibi çok fazla işlem elemanı veya gizli katman sayısı da öğrenmeyi yavaşlatmakta veya bazı durumlarda zorlaştırmaktadır. Probleme göre uygun eğitim algoritması ve ağ yapısı seçimi genelde deneme-yanılma ile yapılabilmektedir (Toktaş, 2003).

Kullanma: YSA başarılı bir şekilde eğitilip test edildikten sonra artık kullanılmaya hazır hale gelmiştir. YSA aslında, eğitime sırasında edindiği bilgileri, eğitime sırasında kullanılmamış (daha önce karşılaşmadığı) durumlar için çözümler üreterek "genelleme" yapar. Eğitime aşamasında hesaplanan ağırlık değerleri, daha sonra sadece girişlerin verilip çıkışların hesaplanmasının istenildiği kullanma aşamasında işe yararlar. Eğitime aşamasının bir basamağı hem ilerleme hem de geri yayılma safhalarını içerirken, kullanma aşamasında sadece ilerleme işlemi uygulanır.

5.13.Verilerin Analizi

Hesaplanan her büyüklük, temel alındığı bir birimin kaç katı olduğuna göre ifade edilerek sayısal özellik kazanır. Hesaplanan değerlerin, standart ölçütlere göre kritiği yapılarak değerlendirilmeleri yapılır. Değerlendirme neticesine göre hesaplanan değerlerin, ölçüm yapılan disiplinin niteliğine göre istenilen amaca ulaşmış olup olmadığına kararına varılır.

Çalışmalarda tahmin edilen değerler, denetleme ve doğrulama amaçlı olarak, gerçek değerler ile karşılaştırılır. Karşılaştırma yapmak için çeşitli istatistiksel kurallar geliştirilmiştir. Bu kuralları aşağıdaki gibi sıralamak mümkündür:

1. $i = 1, \dots, n$, olmak üzere v_i gerçek değerlerin, e_i tahmin edilen değerlerin oluşturduğu küme, \bar{v} gerçek değerlerin ve \bar{e} tahmin edilen değerlerin ortalaması, σ_v gerçek ve σ_e tahmin edilen değerlerin standart sapmaları olmak üzere \bar{v} ile \bar{e} arasındaki fark ‘eğilim’ (kayma) olarak adlandırılır. Kısaca tahmin edilen değerle gerçek değeri arasındaki farktır (Laurent ve ark., 1998).
2. Doğrusal İlişkinlik Katsayısı (linear correlation coefficient) r , denklem(5.16)’daki gibi verilir (Kendall ve Stuart, 1963).

$$r = \frac{\sum_{i=1}^n (v_i - \bar{v})(e_i - \bar{e})}{n\sigma_v\sigma_e} \quad (5.16)$$

r , tahmin edilen değerle gerçek değer arasındaki ilişkiyi gösterir. Bu ilişkiye göre yeni formüller türetilir. Fakat bunlar hesaplamada başarımın değerlendirilmesi için yeterli değildir. Çünkü birinci hesaplamada elde edilen hata oranı oldukça yüksek olsa da, diğer hesaplamalarda da benzer hata oranı ile karşılaşılıyorsa, korelasyon katsayısı oldukça başarılı sonuç verir.

3. Kök ortalama kare hatası (RMSE), eşitlik 5.17’de verilen matematiksel formülle hesaplanır. RMSE’ye, tahmin edilen değer ile gerçek değer arasındaki farklılaşmanın kesin ölçümü olarak bakılır. Aşağıdaki formülde elde edilen değerlerin küçük olması tahmin edilen değerlerin doğruluğunun ve başarımının kanıtıdır.


$$RMSE = \left[\frac{1}{n} \sum_{i=1}^n (e_i - v_i)^2 \right]^{\frac{1}{2}} \quad (5.17)$$

4. Elde edilen tahminlerin gerçek değerlerle karşılaştırılmasında neticesinde Ortalama Sapma Hatasının(MBE) düşük değerde olması arzu edilir. İdeal MBE’nin sifira yaklaşması beklenir. MBE değeri pozitif veya negatif çıkabilir. Bunun bir önemi yoktur. MBE değeri, eşitlik 5.18 ile hesaplanmaktadır (Katiyar ark., 2010).

$$MBE = \frac{1}{n} \sum_{i=1}^n [e_i - v_i] \quad (5.18)$$

6. BULGULAR VE TARTIŞMA

Bu çalışmada yapay sinir ağı yöntemi, rüzgâr güç yoğunluğunu tahmin etmek için kullanılmıştır. Çalışmada yazılım olarak Matlab 2010a programı kullanılmıştır. Öncelikli olarak yerleşim yerlerine bağlı olarak Devlet Meteoroloji İşleri Genel Müdürlüğünden 2 m yükseklikten alınan rüzgâr hızları ve tablo 4.4 'teki Hellman katsayı değerleri, eşitlik 4.24'te kullanılarak 50 m yükseklikteki rüzgar hızları hesaplanmıştır. Daha sonra eşitlik 4.12 kullanılarak ilgili lokasyondaki hava yoğunlukları elde edilmiştir. Hesaplamalar neticesinde elde edilen rüzgâr hızları ve hava yoğunlukları eşitlik 4.9'da kullanılarak rüzgar güç yoğunluğu değerleri hesaplanmıştır. Daha genel bir ifadeyle 1980-2013 yılları arasında Türkiye'nin 58 yerleşim yeri merkezine ait rüzgâr güç yoğunluğu verileri YSA çalışması için hesaplanmıştır. 1980-2010 yıllarına ait veriler modellerin eğitimi için kullanılırken, 2011-2013 yılı verileri ile de oluşturulan modellerin doğrulukları test edilmiştir. Çalışmada kullanılan YSA modelleri, giriş katmanı (input layer), gizli katman (hidden layer) ve bir adet çıktı katmanından (output layer) oluşmaktadır. Giriş katmanında ay, enlem, boylam, yükseklik, toprak sıcaklığı (5cm), buhar basıncı, nisbi nem, ortalama sıcaklık, ortalama maksimum sıcaklık, ortalama minimum sıcaklık parametreleri girdi (input) olarak kullanılırken rüzgâr güç yoğunluğu (W/m^2) çıkış (output) katmanından elde edilmiştir (Şekil 6.1).



Şekil 6.1. YSA' da kullanılan mimari

YSA da, gizli katmandaki optimum sinir hücre (neuron) sayısını belirlemek için bir matematiksel formül bulunmamaktadır. Gizli katmandaki hücre (neuron) sayısına, ağın eğitilmesi sonucunda karar verilmektedir. Çalışmada kullanılan en uygun yapay

sinir ağ modelini elde etmek için gizli katmandaki nöron sayıları 2-50 arasında ikişer artırılarak değiştirilmiştir. Bununla birlikte, YSA'nın başlangıç ağırlıklarının rastgele oluşturulmasından dolayı, uygun YSA modeline, yapılan denemeler sonucunda karar verilmiştir. Ayrıca ağı eğitilmesi sırasında trainlm, trainbfg, trainscg, traincgp, traincgb, traincgf ve trainoss öğrenme algoritmaları kullanılmıştır. Öğrenme algoritmalarına, transfer fonksiyonlarına ve gizli katmandaki nöron sayılarına göre geliştirilen modellerin en iyileri tablo 6.1' de gösterilmiştir.

Tablo 6.1. Geliştirilen YSA modelleri

Model no	Öğrenme algoritması	Gizli katmandaki nöron sayısı	Gizli katmandaki transfer fonk.	Çıkış katmanındaki transfer fonk.	MBE (W/m ²)	RMSE (W/m ²)	R
1	trainbfg	28	logsig	Lineer	0,5113	10,8182	0,9771
2	trainbfg	18	logsig	Lineer	-0,1150	2,9495	0,9797
3	trainbfg	14	logsig	Lineer	-0,1169	5,0279	0,9787
4	trainbfg	24	logsig	Lineer	0,0123	3,1924	0,9796
5	trainbfg	30	logsig	Lineer	-0,1662	6,8756	0,9780
6	trainbfg	34	logsig	Lineer	0,3137	5,9796	0,9783
7	trainbfg	46	logsig	Lineer	-0,4566	9,9558	0,9773
8	trainbfg	4	tansig	Lineer	0,8176	6,1507	0,9783
9	trainbfg	10	tansig	Lineer	0,0245	3,6149	0,9793
10	trainbfg	16	tansig	Lineer	-0,2064	4,4629	0,9789
11	trainbfg	26	tansig	Lineer	-0,2388	6,8440	0,9781
12	trainbfg	32	tansig	Lineer	-0,0199	1,8917	0,9806
13	trainbfg	38	tansig	Lineer	0,7217	10,9121	0,9771
14	trainbfg	46	tansig	Lineer	-0,1635	5,2155	0,9786
15	trainbfg	50	tansig	Lineer	0,1025	7,1261	0,9780
16	trainscg	10	logsig	Lineer	-0,6243	13,5523	0,9767
17	trainscg	34	logsig	Lineer	0,6217	10,1680	0,9773
18	trainscg	4	tansig	Lineer	0,0139	1,8315	0,9807
19	trainscg	10	tansig	Lineer	-0,2112	12,1571	0,9769
20	traincgb	4	tansig	Lineer	-0,1224	3,1267	0,9796
21	traincgb	28	tansig	Lineer	0,0391	1,7932	0,9807
22	traincgb	36	tansig	Lineer	0,0006	2,7593	0,9799
23	traincgb	48	tansig	Lineer	0,0373	10,8742	0,9771
24	traincgb	18	logsig	Lineer	0,0226	6,4407	0,9782
25	traincgb	28	logsig	Lineer	-0,3687	10,3832	0,9772
26	traincgf	44	logsig	Lineer	-0,1637	12,9639	0,9768
27	traincgf	8	tansig	Lineer	-0,1527	4,5020	0,9789
28	traincgf	42	tansig	Lineer	0,6421	10,0440	0,9773
29	traincgp	10	tansig	Lineer	-0,1394	4,5163	0,9789
30	traincgp	34	tansig	Lineer	0,0158	3,6885	0,9793

Tablo 6.1. (Devam ediyor) Geliştirilen YSA modelleri

31	traincgp	32	logsig	Lineer	-0,0459	12,9233	0,9768
32	trainoss	44	logsig	Lineer	0,5177	12,6459	0,9768
33	trainoss	6	tansig	Lineer	-0,0939	8,9504	0,9775
34	trainlm	12	tansig	Lineer	0,1768	3,2174	0,9796
35	trainlm	16	tansig	Lineer	-0,3124	1,4786	0,9899
36	trainlm	24	tansig	Lineer	0,0047	1,5942	0,9881
37	trainlm	28	tansig	Lineer	-0,0895	2,0861	0,9804
38	trainlm	36	tansig	Lineer	0,1818	4,8224	0,9788
39	trainlm	40	tansig	Lineer	-0,2368	2,2365	0,9803
40	trainlm	44	tansig	Lineer	0,0598	2,5095	0,9801
41	trainlm	4	logsig	Lineer	0,1684	4,4591	0,9789
42	trainlm	10	logsig	Lineer	-0,2579	4,7216	0,9788
43	trainlm	16	logsig	Lineer	-0,1629	2,0144	0,9805
44	trainlm	28	logsig	Lineer	0,0478	3,0477	0,9797
45	trainlm	34	logsig	Lineer	-0,0941	1,7957	0,9807
46	trainlm	38	logsig	Lineer	0,1813	4,0297	0,9791
47	trainlm	42	logsig	Lineer	-0,0771	2,5495	0,9800
48	trainlm	48	logsig	Lineer	0,0075	1,8633	0,9807

Tablo 6.1 incelendiğinde en küçük korelasyon katsayısı 0,9767 olarak hesaplanırken, en büyük korelasyon katsayısı 0,9899 hesaplanmıştır. En büyük korelasyon katsayısında, öğrenme algoritması trainlm, gizli katmandaki transfer fonksiyonu tansig ve çıkış katmanındaki transfer fonksiyonu ise lineerdir. Söz konusu ağ, gizli katmanda 16 nöron kullanılarak geliştirilmiştir. En küçük korelasyon katsayısında, öğrenme algoritması trainscg, gizli katmandaki transfer fonksiyonu logsig ve çıkış katmanındaki transfer fonksiyonu ise lineerdir. Söz konusu ağ, gizli katmanda 10 nöron kullanılarak geliştirilmiştir. Tablo 6.1’de en küçük RMSE değeri 1,4786 W/m^2 olarak elde edilirken, en büyük RMSE değeri 13,5523 W/m^2 olarak elde edilmiştir.

En büyük RMSE değerlerinin elde edilmesinde etkili olan öğrenme algoritması trainscg, gizli katmandaki transfer fonksiyonu logsig ve çıkış katmanındaki transfer fonksiyonu lineerdir. Söz konusu ağ, gizli katmanda 10 nöron kullanılarak geliştirilmiştir. En küçük RMSE değerlerinin elde edilmesinde etkili olan öğrenme algoritması trainlm, gizli katmandaki transfer fonksiyonu tansig ve çıkış katmanındaki transfer fonksiyonu lineerdir. Söz konusu ağ, gizli katmanda 16 nöron kullanılarak geliştirilmiştir. Geliştirilen modellerin MBE değerleri de hesaplanmıştır. Tablodaki MBE değerlerinin pozitif veya negatif olmasının bir önemi yoktur. Önemli olan değerlerin sıfıra yakın olmasıdır. En iyi MBE değeri 0,0006 W/m^2 iken, en kötü MBE

değeri 0,8176 W/m²'dir. En iyi MBE değerinde öğrenme algoritması traincgb, gizli katmandaki transfer fonksiyonu tansig, çıkış katmanındaki transfer fonksiyonu ise lineerdir. Gizli katmanda ise 36 nöron bulunmaktadır. En kötü MBE değerinde öğrenme algoritması trainbfg, gizli katmandaki transfer fonksiyonu tansig, çıkış katmanındaki transfer fonksiyonu ise lineerdir. Gizli katmanda ise 4 nöron bulunmaktadır.

Çalışmada, her ne kadar 1980-2010 yılı verileri kullanılarak YSA ağı eğitilse de ağın başarısı 2011-2013 verileri ile test edilmiştir. Üç yıllık çalışmaların başarısı RMSE değerlerine göre değerlendirilmektedir. Tablo 6.1 incelendiğinde en düşük RMSE değeri, önceden de bahsedildiği gibi değeri 1,4786 W/m²'dir ve geliştirilen en başarılı modeldir. Denemeler sonucunda, YSA yönteminde en doğru sonuçlar YSA (10:16:1) yapıdaki modelden elde edilmiştir. Bu değeri sağlayan modelin özellikleri sıralanırsa; girdi katmanında 10 nöron (ay, enlem, boylam, yükseklik, toprak sıcaklığı (5cm), buhar basıncı, nisbi nem, ortalama sıcaklık, ortalama maksimum sıcaklık, ortalama minimum sıcaklık), gizli katmanda ise 16 nöron bulunmaktadır. Ayrıca çıkış katmanında 1 nöron (rüzgâr güç yoğunluğu) vardır. Ağın öğrenme algoritması tarinlm, gizli katmandaki transfer fonksiyonu tansig, çıkış katmanındaki transfer fonksiyonu ise lineerdir.


Elde edilen modele bağlı olarak il bazında MBE, RMSE ve R değerleri hesaplanmış ve tablo 6.2'de gösterilmiştir.

Tablo 6.2. İl bazlı MBE, RMSE, R değerleri.

İller	MBE(W/m ²)	RMSE(W/m ²)	R
Sinop	0,5257	1,4874	0,9787
Rize	-0,5688	0,8506	0,8972
Artvin	0,3273	1,0048	0,9685
Kırklareli	-0,3320	0,8282	0,9969
Tekirdağ	-0,4424	0,9504	0,9895
Bolu	-0,3560	0,8420	0,9797
Kastamonu	0,0517	0,5725	0,9977
Tokat	-0,1439	0,9409	0,9997
Gümüşhane	-0,5850	0,8336	0,9991
Çanakkale	-0,3624	0,7544	0,9999
Bursa	0,0067	4,2642	0,9703
Van	-0,6140	2,3471	0,9971
Afyonkarahisar	-0,5810	1,2458	0,9893
Aksaray	-0,4324	1,1126	0,9968
Isparta	-0,4976	0,9532	0,9996
Muğla	-0,3458	0,7247	0,9934
Adana	-0,4064	0,8041	0,9993
Batman	-0,9634	1,4034	0,9881


Çalışmada en küçük korelasyon katsayısı 0,8972 ile Rize iline aitken, en büyük korelasyon katsayısı 0,9999 ile Çanakkale ili için elde edilmiştir. Tablodaki MBE değerlerinin pozitif veya negatif olmasının bir önemi yoktur. En iyi MBE değeri 0,0067 W/m² ile Bursa ilinden elde edilmiştir. En kötü MBE değeri 0,9634 W/m² olup Batman iline aittir. En iyi RMSE değeri 0,5725 W/m² ile Kastamonu ilinden elde edilmiştir. En kötü RMSE değeri 4,2642 W/m² olup, Bursa iline aittir. Diğer lokasyonların korelasyon katsayıları 0,8972 - 0,9999 arasında, RMSE değerleri ise 0,5725-4,2642 W/m² arasında değerler almaktadır. MBE değerlerinin ise sifıra yaklaşımı 0,0067-0,9634 W/m² arasında değişmektedir.

Çalışmada istatistiksel sonuçlardan da anlaşılacağı üzere çalışma bölgesinde rüzgâr güç yoğunluğu, YSA yöntemi kullanılarak en iyi Kastamonu ilinde tahmin edilirken en kötü Bursa ilinde tahmin edilmiştir. Kastamonu ve Bursa illerinin tahmin ve gerçek datalarının ortalama değerlerinin aylık değişimi sırasıyla şekil 6.2. ve şekil 6.3.'de gösterilmiştir.



Şekil 6.2. Kastamonu iline ait güç yoğunluğu değerleri

Kastamonu lokasyonunda gerçek datalar ile YSA yönteminden elde edilen tahmin datalarının birbiri ile uyumlu olduğu görülmektedir. Aylara göre Kastamonu lokasyonunda gerçek datalarla, tahmin dataları arasındaki hata farkı $0,021-1,437 \text{ W/m}^2$ arasında değişmektedir. Kastamonu lokasyonunda, 2013 yılının 12. ayında (Aralık), rüzgâr güç yoğunluğu minimum hata ile tahmin edilmiş olup; 2011 yılı 5. ayında (Mayıs) rüzgâr güç yoğunluğu tahmini maksimum hata ile yapılmıştır.



Şekil 6.3. Bursa iline ait güç yoğunluğu değerleri

Bursa lokasyonunda gerçek datalar ile YSA yönteminden elde edilen tahmin datalarının birbiri ile uyumluluğu konusunda aynı hassasiyetten söz etmek mümkün değildir. Aylara göre Bursa lokasyonunda gerçek datalarla tahmin dataları arasındaki fark $0,222-12,858 \text{ W/m}^2$ arasında değişmektedir. Bursa lokasyonunda 2013 yılında 1. ayında (Ocak) rüzgâr güç yoğunluğu minimum hata ile tahmin edilmiş olup, 2013 yılı 3. ayında (Mart) rüzgâr güç yoğunluğu tahmini maksimum hata ile yapılmıştır.

Yapılan çalışma, literatürdeki çalışmalarla kıyaslanabilir. Al-Nassar ve arkadaşları (2005) çalışmalarında rüzgâr güç yoğunluğunu; $2,79-8,78 \text{ W/m}^2$ arasında değişen hata ile tahmin etmişlerdir. Çelik ve Kolhe (2013) çalışmalarında güç yoğunluğunu; $1,97-2,05 \text{ W/m}^2$ arasında değişen RMSE değerleri ile tahmin etmişlerdir. Peng ve arkadaşları (2013) rüzgâr güç yoğunluğunu; $\%2,01-10,67 \text{ W/m}^2$ arasında

değişen RMSE değerleri ile tahmin etmişlerdir. Chandel ve arkadaşları (2014) ise yaptıkları çalışmada yerleşim yerleri farklılığına bağlı olarak rüzgâr güç yoğunluğunu, %94,55 ile %99,89 arasında değişen başarı ile tahmin etmişlerdir. Özgür (2014) yaptığı çalışmada rüzgâr güç yoğunluğunu 0,6475-3,7239 W/m² arasında değişen hata ile tahmin etmiştir. Mohammadi ve arkadaşları (2015) yaptıkları çalışmada ise rüzgâr güç yoğunluğunu %93,2 başarı ile tahmin etmişlerdir. Yapılan tez çalışmada ise rüzgâr güç yoğunluğu %98,99 başarı ile tahmin edilmiştir. Yerleşim yerlerine bağlı olarak RMSE değer aralığı ise 0,5725-4,2642 W/m² arasında değerler almaktadır. Elde edilen istatistiksel sonuçlar, literatür çalışmaları ile uyum içinde olduğunu göstermektedir. Hatta bazı çalışmalardan daha başarılı sonuçlar elde edilmiştir. Bu nedenle geliştirilen (10:16:1) modelinin, rüzgâr güç yoğunluğunu hesaplamak için kullanılabileceğini ortaya çıkarmıştır.

7. SONUÇ VE ÖNERİLER

Çalışmada 58 lokasyonun Meteorolojik verileri kullanılarak YSA yardımıyla rüzgâr güç yoğunluğu tahmini yapılmıştır. 40 lokasyonun değerleri YSA modellerini eğitmek için kullanılırken, 18 lokasyonun değerleri modellerin doğruluğunu test etmek için kullanılmıştır. YSA modellemesinde ay, enlem, boylam, yükseklik, toprak sıcaklığı (5cm), buhar basıncı, nisbi nem, ortalama sıcaklık, ortalama maksimum sıcaklık, ortalama minimum sıcaklık girdi parametreleri olarak kullanılırken; rüzgâr güç yoğunluğu çıkış parametresi olarak elde edilmiştir. Modellerin eğitiminde; trainlm, trainbfg, trainscg, traincgp, traincgb, traincgf ve trainoss öğrenme algoritmaları kullanılmıştır. Gizli katmanında kullanılan transfer fonksiyonları tansig ve logsig'dir. Çıkış katmanında kullanılan transfer fonksiyonu ise lineer'dir. Yapılan modellemeler sonucunda, (10:16:1) modelinin en iyi sonuç verdiği görülmüştür. Bu modele göre korelasyon katsayısı 0,9899 olarak bulunmuştur. RMSE değeri ise 1,4786 W/m² iken MBE değeri 0,3124 W/m² olarak tahmin edilmiştir. Bu model yerleşim yerlerine bağlı olarak en iyi sonucu Kastamonu lokasyonunda verirken, en kötü sonucu Bursa lokasyonunda istatistiksel olarak vermiştir. Yapılan çalışmanın literatür ile uyumlu olduğu görülmüştür.

Öneri olarak ise girdi parametrelerinin değişik kombinasyonu yapılarak YSA modellerinin geliştirilmesi ve doğruluklarının test edilmesi ileri sürülmüştür.

Bu çalışmada, rüzgâr enerji potansiyelinin Türkiye için önemi vurgulanmıştır. Ülkemizin coğrafik şartlarının rüzgâr enerjisi üretimine uygun olması nedeniyle, sahip olduğu potansiyeli en verimli şekilde değerlendirilmeli, bunun için de rüzgâr enerjisi kullanım oranının artmasına yönelik somut adımlar atılmalıdır. Türkiye'nin sürdürülebilir bir kalkınmayı sağlayabilmesi için enerjide dışa bağımlı kalınmamalı, teknolojisi gelişmiş, istihdam yaratma potansiyeline sahip, ucuz, güvenli ve sürdürülebilir enerjiyi sağlayabilmek amacıyla rüzgâr enerjisine gerekli yatırımlar ve teşvikler yapılmalıdır. Üniversite, özel sektör ve sanayi işbirliği sağlanarak yenilenebilir enerji kaynaklarına yönelik Ar-Ge çalışmaları yapılmalıdır. Ayrıca kurulacak olan bu işbirliği sayesinde toplumun her kesimine rüzgâr enerjisinin önemini ve ülkeye sağlayabileceği getirileri açıkça anlatacak projeler yapılmalıdır. Türkiye, sahip olduğu rüzgâr enerjisi potansiyelini verimli kullanabilmesi için uzun vadeli hedefler koymalı, rüzgâr enerjisi kapasite artırımına yönelik sağlıklı planlar yapmalıdır. Yenilenebilir enerji kaynaklarına yapılacak her yatırım, geleceğe yatırım yapmak demektir.

8. KAYNAKLAR

- Akdağ, S.A, 2008. Rüzgâr Enerjisi Potansiyeli ve Ekonomik Analizinde Weibull Dağılımının Kullanımı, Yüksek Lisans Tezi, *İstanbul Teknik Üniversitesi Enerji Enstitüsü*, İstanbul.
- Almalı, M, N., Ete, T., 2009. Ortalama rüzgar hızı ve güç yoğunluğunun hesaplanması, *V. Yenilenebilir Enerji Kaynakları Sempozyumu*, Diyarbakır.
- Almalı, M. N., Rüstemli, S., Gürçam, K., 2013. Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi, *Iğdır University Journal of the Institute of Science and Technology*, Cilt: 3, Sayı: 1, Sayfa: 73-78.
- Al-Nassar, W., Alhajraf, S., Al-Enizi, A., Al-Awadhi, L., 2005. Potential wind power generation in the State of Kuwait, *Renewable Energy*, 30 2149- 2161.
- Altın, V., 2002. “Yeni Ufuklara-Enerji”, Boğaziçi Üniversitesi, *Bilim ve Teknik Dergisi Eki*, İstanbul, Sayfa: 23.,
- Aslan, N., Yamak T., 2006. Türkiye'nin Enerji Sorununun Alternatif Enerji Kaynakları açısından değerlendirilmesi” Marmara Üniversitesi İ.İ.B.F. Dergisi, Cilt XXI, Sayı 1, Sayfa:53, İstanbul.
- Aygören, H., Sarıtaş, H., Moralı, T. 2012. “İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini”. *Uluslararası Alanya İşletme Fakültesi Dergisi*. 4 (1), ss. 73-78.
- Ayodele, T.R., Ogunjuigbe, A.S.O., 2015. 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*.
- Bansal, R., Bati, T.S., Kothari, D.P., 2002. On Some of the Design Aspects of Wind Energy Conversion Systems, *Energy Conversion and Management*, Vol. 43, N° 16, pp. November, 2175–2187.
- Battiti, R., 1992. First and second order methods for learning: Between steepest descent and Newton's method, *Neural Computation*, Vol. 4, No. 2, pp. 141–166.
- Bayraç, H.N., 2011. Küresel Rüzgar Enerjisi Politikaları ve Uygulamaları, *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, Cilt. XXX, No.1, Bursa, 37-57.
- Bilgili, M., 2007. Yapay Sinir Ağları ile rüzgar hızı ve rüzgar gücü potansiyeli tahminleri, Doktora Tezi, *Çukurova Üniversitesi Fen Bilimleri Enstitüsü Makina Mühendisliği Anabilim Dalı*, Adana.
- Boztepe M., 2009. Rüzgardan Yakalanan Güç (Mekanik Güç), *Rüzgâr ve Güneş Enerjili Güç Sistemleri*, İzmir 9-19.

- Carolin Mabel M., Fernandez E., 2008. Analysis of wind power generation and prediction using ANN: A case study, *Renewable Energy*, 33 986–992.
- Carta, J., A., Mentado D., 2007. A continuous bivariate model for wind power density and wind turbine energy output estimations, *Energy Conversion and Management*, 48, 420-432.
- Caudill, M., 1987. Neural Network Primer Part 1 AI Expert, December, pp47.
- Chand, S. Lan, M., 1990. Neural Network Augmented Control for Nonlinear Systems, Proc. of the 29th Conf. CDC, Honolulu, HI, 1732-1734.
- Chandel, S. S., Ramasamy, P., Murthy K.S.R., 2014. Wind power potential assessment of 12 locations in western Himalayan region of India, *Renewable and Sustainable Energy Reviews*, 39 530–545.
- Chang, W., 2012. An RBF neural network combined with OLS algorithm and genetic algorithm for short-term wind power forecasting, *Department of Electrical Engineering, St. John's University*, 499, Section 4, Tam King Road, Tamsui District, New Taipei City 25135, Taiwan Computational Abilities, Proc. Nat. Acad. Sci., 79, 2554-2558.
- Çam, E., Arcaklıoğlu, E., Cavusoğlu, A., Akbıyık, B., 2005. A classification mechanism for determining average wind speed and power in several regions of Turkey using artificial neural Networks, *Renewable Energy*, 30 227–239.
- Çelik, A., N., 2003a. Assessing the suitability of wind speed probability distribution functions based on wind power density, *Renewable Energy*, 28 1563–1574.
- Çelik, A., N., 2003b. A statistical analysis of wind power density based on the Weibull and Rayleigh models at the southern region of Turkey, *Renewable Energy*, 29 593–604.
- Çelik, A.N., Kolhe, M., 2013. Generalized feed-forward based method for wind energy prediction, *Applied Energy*, 101 582–588.
- Çolak, İ., Bayındır, R., Sefa, İ., Demirbaş, Ş. ve Ergen, H., 2005. Alternatif Enerji Kaynaklarının Kullanımı, *III. Yenilenebilir Enerji Kaynakları Sempozyumu*, Mersin, 19-25.
- De Giorgi, M.G., Ficarella, A., Tarantino, M., 2011. Assessment of the benefits of numerical weather predictions in wind power forecasting based on statistical methods, *Energy*, 36 3968-3978.
- Dennis, J.E., Schnabel, R.B., 1983. *Numerical Methods for Unconstrained Optimization and Nonlinear Equations*, Englewood Cliffs, NJ: Prentice-Hall.
- Deshmukh, M., K., Balakrishna Moorthy, C., 2010. Application of genetic algorithm to neural network model for estimation of wind power potential, *Journal of Engineering, Science and Management Education*/Vol. 2, 42-48.

- Dreyfus, G., 2005, Neural networks methodology and applications, Springer-Verlag, Berlin, Heidelberg, 497 p.
- Elmas, Ç., 2003. Yapay Sinir Ağları, *Seçkin Yayıncılık*, Ankara. Sayfa: 192.
- Elmas, Ç., 2007. Yapay zeka uygulamaları, *Seçkin Yayıncılık San ve Tic Aş*, Sayfa: 425.
- Ergezer, H., Dikmen, M., ve Özdemir, E., 2003. Yapay sinir ağları ve tanıma sistemleri, *Pivolka*, 6, 14-17.
- Ersöz, S., Akıncı, T. C., Nogay, H.,S., Doğan, G., 2013. Determination of wind energy potential in Kırklareli-Turkey, *International Journal of Green Energy*, 10:1, 103-116, DOI: 10.1080/15435075.2011.641702.
- Fadare, D. A., 2010. The application of artificial neural networks to mapping of wind speed profile for energy application in Nigeria, *Applied Energy*, 87 934–942.
- Gnana Sheela., K., Deepa, S.N., 2013. Neural network based hybrid computing model for wind speed prediction, *Neurocomputing*, 122 425–429.
- Grossberg, S., 1986. The Adaptive Brain I: Cognition, Learning, Reinforcement and Rhythm, and The Adaptive Brain II: Visions, Speech, Language and Motor Control, Elsevier, Amsterdam.
- Ham, M., F., Kostanic, I., 2001. Principles of Neurocomputing for Science and Engineering, *Mcgraw – Hill Companies*, New York, USA.
- Hamzaçebi, C., 2011. Yapay Sinir Ağları: tahmin amaçlı kullanımı Matlab ve Neurosolutions uygulamalı, *Ekin Basım Yayın Dağıtım*, Bursa, Sayfa:133.
- Haykin, S., 1999. Neural networks: A comprehensive foundation, *Prentice-Hall Inc.* (2nd ed.), Englewood Cliffs, NJ.
- Hebb, D.O., 1949. The Organization of Behaviour, *John Wiley Sons*, New York-USA.
- Hepbaşlı, A. , Özgener, O., 2004. A review on the development of wind energy in Turkey, *Renewable and Sustainable Energy Reviews*, Volume: 8, pp.: 257–276.
- Hopfield, J. J., 1982. Neural Networks and Physical Systems with Emergent Collective.
- İlkılıç, C., 2012. Wind energy and assessment of wind energy potential in Turkey, *Renewable and Sustainable Energy Reviews*, Volume: 16, pp.: 1165– 1173.
- Karsli V., M., Geçit, C., 2003. An investigation on wind power potential of Nurdağı-Gaziantep, Turkey, *Renewable Energy*, 28 823–830.
- Kartalopoulos, S.V., 1996. Understanding neural networks and fuzzy logic basic concepts and applications, *IEEE Pres*, 205 p.

- Katiyar, K., Kumar, A., Pandey, C. K., Das, B., 2010. A comparative study of monthly mean daily clear sky radiation over India, *International Journal of Energy and Environment* 1: 177–182.
- Kendall, M. G., Stuart, A., 1963. *The Advanced Theory of Statistics*, Griffin Pres., London.
- Kirik, A., 2010. Tornalamada kesme parametrelerindeki deęişime göre yüzey pürüzlülüęünün tahmini için model geliştirme, Yüksek Lisans Tezi, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara.
- Kjærland, F., 2007. A real option analysis of investments in hydropower the case of Norway, *Energy Policy*, 35, 5901-5908.
- Kocabaş, Ş., 1999. Yapay Zekâ Ders Notları, İstanbul Teknik Üniversitesi, İstanbul.
- Kohonen, T., 1987. State of the art in neural computing, *IEEE First International Conference on Neural Networks*, Vol. 1, pp. 79-90.
- Kohonen, T., 1986. *Self organization and associative memory*, Springer Verlag- Berlin.
- Köse, R., Özgür, M. A., 2003. Dumlupınar Üniversitesi kampus alanında rüzgâr enerjisi potansiyelinin araştırılması, *DPÜ Fen Bilimleri Dergisi*, Sayı 5, 187-196.
- Köse, R., Özgür, M., Arif, E. O. , Tugcu, A., 2004. The analysis of wind data and wind energy potential in Kutahya, Turkey, *Renewable and Sustainable Energy Reviews*, Volume: 8, pp.: 277–288.
- Kulkarni, A.D., 1994. Artificial neural networks for image understanding, *Van Nostrand Reinhold*, New York, 210 p.
- Laurent, H., Jobard, I., Toma, A., 1998. Validation of satellite and ground based estimates of precipitation over the Sahel, *Atmospheric Research*, 47-48, 651-670.
- Lee, S. C., 2011. Using real option analysis for highly uncertain technology investments: The case of wind energy technology, *Renewable and Sustainable Energy Reviews*, doi:10.1016/j.rser.2011.07.107 London-UK.
- Lu, L., Yang, H., Burnett, J., 2002. Investigation on wind power potential on Hong Kong islands an analysis of wind power and wind turbine characteristics, *Renewable Energy*, 27 1–12.
- Maran P. S., Ponnusamy R., Venkatesan R. and Bing A.B., 2014. Wind energy location prediction between meteorological stations using ANN, *Global NEST Journal*, 16(X), XX-XX.
- Martin T. H., Mohammad, B. M. 1994. Training Feedforward Networks with the Marquardt Algorithm, *IEEE Transactions on neural networks*.

- Masters, G. M., 2004. Renewable and efficient electric power systems, *John Wiley and Sons*, ISBN 0471280607, USA, 312-319.
- Mandic, D.P., Chambers, J. A., 2001. Recurrent Neural Networks for Prediction - Learning Algorithms Architectures and Stability, John Wiley & Sons Ltd.
- Mc Culloch, W. S., Pitts, W.H., 1943. A logical calculus of the ideas immanent in neural nets, *Bull., Math., Biophys., Mechanisms*, Spartan Boks, Washington DC-USA, 5, 115-133.
- Minsky, M.L., Papert, S.A., 1969. Perceptron, Expanded Edition, Cambridge, MIT Pres.
- Mohammadi, K., Shamshirband, S., Yee, L., P., Petkovic, D., Zamani, M., Ch, S., 2015. Predicting the wind power density based upon extreme learning machine, *Energy*, 86 232-239.
- Nikolic', V. , Motamedi, S., Shamshirband, S., Petkovic', D., Ch, S., Arif, M., 2015. Extreme learning machine approach for sensorless wind speed estimation *Mechatronics* [http:// dx.doi.org/10.1016/j.mechatronics.2015.04.007](http://dx.doi.org/10.1016/j.mechatronics.2015.04.007).
- Nurbay, N., Çınar, A., 2005. Türkiye'de Rüzgar Enerjisi ve Teknik Eğitim Fakültelerindeki Yeri, *Kocaeli Üniversitesi Teknik Eğitim Fakültesi Makine Eğitimi Bölümü*, Kocaeli.
- Öner, Y., Özçira, S., Bekiroğlu, N., Şenol, İ., 2013. A comparative analysis of wind power density prediction methods for Çanakkale, Intepe region, Turkey, *Renewable Sustainable Energy Reviews*, Volume: 23, Issue: 2, pp.: 491-502.
- Özerdem, B., 2003. Türkiye'de rüzgâr enerjisi uygulamalarının gelişimi ve geleceği, *Türkiye 9. Enerji Kongresi*, Dünya Enerji Konseyi Türk Milli Komitesi, İzmir, 65-73.
- Özgür , M., A., 2014. ANN based evaluation of wind power generation: A case study in Kutahya, Turkey, *Journal of Energy*, in Southern Africa Vol: 25 No: 4 November, 11-22.
- Öztemel, E., 2006. Yapay Sinir Ağları, *Papatya Yayıncılık Eğitim*, İstanbul.
- Öztemel, E., 2003. Yapay Sinir Ağları, *Papatya Yayıncılık*, İstanbul.
- Öztürel, N., Zilan R., Ecevit, A., 2001. Türkiye'de yenilenebilir enerji kaynakları için izlenmesi gereken strateji, planlama politikaları ve bunların sosyal ve siyasi etkileri, *Yenilenebilir Enerji Kaynakları Sempozyumu*, İzmir, 28-32.
- Pankaj, M., Benjamin, W.W., 1992. Artificial Neural Networks Concepts and Theory, *IEEE Computer Society Press*, Washington.
- Patel, M. R., 2006. Wind and solar power systems: design analysis, and operation, 2nd ed. CRC Press, ISBN 0849315700, Florida USA.

- Peng, H., Liu, F., Yang, X., 2013. A hybrid strategy of short term wind power prediction, *Renewable Energy*, 50 590-595.
- 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.
- Rosenblatt, F., 1962. Principles of Neuradynamics: Perceptrons and The Theory of Brain.
- Rumelhart, D., Hinton, G., Williams, R., 1985. Learning internal representations by error propagation, ICS Report 8506.
- Rumelhart, D. E., Mc Clelland, J.L., 1986. PDP Research Group, Paralel Distributed Processing: Explorations in the Microstructure of Cognition, MIT Pres, Cambridge.
- Sađırođlu, Ő., BeŐdok, E. ve Erler, M., 2003. Mühendislikte Yapay Zeka Uygulamaları-I Yapay Sinir Ağları, *Ufuk Kitap Kırtasiye-Yayınıcılık Tic. Ltd. Őti.*, Kayseri.
- Saraç, T., 2004. Yapay Sinir Ağları, Gazi Üniversitesi Endüstri Mühendisliđi Anabilim Dalı Seminer Projesi, Ankara.
- Sardar Maran, P., Ponnusamy, R., 2013. Wind power density estimation using meteorological tower data, *International Journal of Renewable and Sustainable Energy*. Vol. 2, No. 3, pp. 110-114. doi: 10.11648/j.ijrse.20130203.15.
- Stout, B. A., Myers, C. A., Hurand, A., Faidley, LW., 1979. Energy for World Agriculture, Food and Agriculture Organization of the United Nations, FAO Agriculture Rome Series, 7.
- Swingler, K., 1994. Financial Prediction, Some Pointers, Pitfalls, and Common Errors, Center for Cognitive and Computational Neuroscience, Stirling University, Temmuz.
- Ően, Z., 2004. Yapay sinir ağları ilkeleri, *Su Vakfı yayınları*.
- Őensoy, S., Demircan, M., Ulupınar, Y., Balta, İ., 2008. Türkiye İklimi Devlet Meteoroloji İşleri Genel Müdürlüđü, P.O.Box: 401, Ankara, Türkiye,
- ToktaŐ, İ., 2003. Mekanik sistemler için bir kavramsal tasarım modelinin geliştirilmesinde yapay sinir ağlarının kullanılması, Doktora Tezi, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara, 24-26.
- Uyar, T. S., 2001. Türkiye enerji sektöründe karar verme ve rüzgar enerjisinin entegrasyonu, *Rüzgar Raporu*, 1-8.
- Van Der Auwera, L., De Meyer, F., Malet, L. M., 1980. The use of the Weibull three parameter model for estimating mean wind power densities, *Journal of Applied*

Meteorology, Royal Meteorological Institute of Belgium, Brussels (Manuscript received 29 June 1979, in final form 15 February 1980)/819-825.

- Velázquez, S., Carta, J. A., 2010. Comparison between the short-term observed and long-term estimated wind power density using Artificial Neural Networks, A case study, University of Las Palmas de Gran Canaria, Campus de Tafira s/n, 35017 Las Palmas de Gran Canaria, Canary Islands Spain.
- Vogl, T. P., Mangis, J. K., Rigler, A. K., Zink, W. T., Alkon, D. L., 1988. Accelerating the convergence of the backpropagation method, *Biological Cybernetics*, Vol. 59, 1988, pp. 257–263.
- Widrow, B., 1988. DARPA Neural Network Study, *AFCEA International Press*.
- Widrow, B., Hoff, M., 1960. Adaptive Switching Circuits, *Ire Wescon Convention Record*, 4, 96-104.
- Yao J. T., Tan C. L., 2001. Guidelines for Financial Forecasting with Neural Networks, Nisan.
- Yıldız B., 2001. Finansal başarısızlığın öngörülmesinde YSA kullanımı ve halka açık şirketlerde ampirik bir uygulama, *İMKB Dergisi*, Cilt 5, Sayı:17.
- Yıldız, T., 2011. *Enerji ve Tabii Kaynaklar Bakanlığı*, Türkiye enerji politikalarımız Ankara, Türkiye, Kasım 1.
- Yu, H., Wilamowski, B., 2011. Levenberg-marquardt training, *The Industrial Electronics Handbook*, 1–16.
- Yurtoğlu, H., 2005. Yapay Sinir Ağları metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği, *DPT Uzmanlık Tezleri*, DPT 2683.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Muhammed Yusuf AKTAÇ
Doğum Yeri ve Tarihi : Siirt - 23.05.1987
Telefon : 90 (484) 223 22 55 /1136
E-posta : yusufaktac@gmail.com

EĞİTİM

Derece		Bitirme Yılı
Lise	: Yabancı Dil Ağırlıklı Süper Lise, SİİRT	2005
Üniversite	: Fatih Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği, İSTANBUL	2012

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
2013-Devam Ediyor	Siirt DEDAŞ İl Müdürlüğü	Elektrik Mühendisi

UZMANLIK ALANI: Yenilenebilir Enerji Kaynakları ve Otomasyon Sistemleri

YABANCI DİLLER: İngilizce