

T.C.  
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
MAKİNA MÜHENDİSLİĞİ ANABİLİM DALI

**VAN VE HAKKARİ BÖLGELERİNDE RÜZGAR POTANSİYELİNİN  
BELİRLENMESİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Emrah HARMANCI  
DANIŞMAN: Doç. Dr. Sedat YAYLA

VAN-2018



T.C.  
VAN YÜZÜNCÜ YIL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ  
MAKİNA MÜHENDİSLİĞİ ANABİLİM DALI

**VAN VE HAKKARİ BÖLGELERİNDE RÜZGAR POTANSİYELİNİN  
BELİRLENMESİ**

YÜKSEK LİSANS TEZİ

HAZIRLAYAN: Emrah HARMANCI

Bu çalışma Van YYÜ Bilimsel Araştırma Projeleri Başkanlığı tarafından FLY-2017-6004 No'lu proje olarak desteklenmiştir.

VAN-2018



## KABUL VE ONAY SAYFASI

Makine Mühendisliği Anabilim Dalı'nda Doç. Dr. Sedat YAYLA danışmanlığında, Emrah HARMANCI tarafından sunulan "Van ve Hakkâri Bölgelerinde Rüzgâr Potansiyelinin Belirlenmesi" isimli bu çalışma Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin ilgili hükümleri gereğince 12/11/2018 tarihinde aşağıdaki jüri tarafından oy birliği ile başarılı bulunmuş ve Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan: Prof.Dr. Beşir ŞAHİN

İmza:

*Beşir Şahin*

Üye: Doç.Dr. Sedat YAYLA

İmza:

*Sedat Yayla*

Üye: Dr.Öğr.Üyesi Murat  
CANAYAZ

İmza:

*Murat Canayaz*

Üye:.....

İmza:

Üye:.....

İmza:

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 12/11/2018 tarih ve 2018/61-I sayılı kararı ile onaylanmıştır.







## TEZ BİLDİRİMİ

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

Emrah HARMANCI







## ÖZET

### VAN VE HAKKARİ BÖLGELERİNDE RÜZGAR POTANSİYELİNİN BELİRLENMESİ

HARMANCI, Emrah  
Yüksek Lisans Tezi, Makine Mühendisliği Anabilim Dalı  
Tez Danışmanı: Doç. Dr. Sedat YAYLA  
Kasım 2018, 139 Sayfa

Bu çalışmada Türkiye'nin Doğu Anadolu bölgesinde yer alan Van ve Hakkari illerindeki rüzgar potansiyeli, YSA(Yapay Sinir Ağları), Derin Öğrenme ve WASP (Wind Atlas Application Program) programı kullanılarak belirlenmeye çalışılmıştır. YSA ve WASP hesaplamalarında MGM (Meteoroloji Genel Müdürlüğü)'nden alınan 5 yıllık istasyon ölçüm verileri kullanılmıştır. Derin Öğrenme aşamasında ise, Meteosat 7 uydusuna ait Doğu Avrupa uydu görüntüleri kullanılmıştır. Uydudan elde edilen görüntüler ve MGM'nden alınan veriler kullanılarak, Derin Öğrenme ve YSA üzerinden hedef istasyon verileri tahmin edilmeye çalışılmıştır. Tahmin edilen hedef istasyona ait gerçek değerler ve tahminlemeler ile bulunan sonuç değerleri arasında genel olarak 1 m/s 'nin altında farklar gözlemlenmiştir. Bu değerler 3-25 m/s aralığında çalışan türbinler için, potansiyel tahmini açısından iyi sonuçlar oluşturmaktadır. Çalışmada YSA ve Derin Öğrenme Yöntemleri için, hata oranı belirlemek amacıyla, veri setindeki her bir tahminin ağırlıklı etkisine göre toplam hata oranını belirleyen yeni bir sına yöntemi MCE (Kategorize Edilmiş Ortalama Sınama) sunulmuştur. MGM'den alınan ölçüm verileri, WASP programında, SRTM (Shuttle Radar Topography Mission) Database'den alınmış olan bölgelere ait halihazır haritalar ile birlikte simüle edilmiş ve incelenen bölgelere ait rüzgar potansiyelleri belirlenmiştir.

**Anahtar Kelimeler:** Derin Öğrenme, Kategorize Edilmiş Ortalama Sınama, Konvolüzyon, Performans Hesaplama, Rüzgar Hızı, Rüzgar Potansiyeli, WASP, Yapay Sinir Ağları.



## ABSTRACT

### DETERMINATION OF WIND POTENTIAL IN VAN AND HAKKARI REGIONS

HARMANCI, Emrah  
MSc., Mechanical Engineering  
Supervisor: Assoc. Dr. Sedat YAYLA  
November 2018, 139 Pages

In this study, ANN (Artificial Neural Networks), Deep Learning and WASP (Wind Atlas Application Program) have been used to determine wind potentials of Van and Hakkari provinces located in eastern Anatolia region of Turkey. Data measured for 5 years period by GDM (General Directorate of Meteorology) were used for predictions of the ANN method and WASP. In the Deep Learning phase, Eastern European satellite images of the Meteosat 7 satellite were used. Using images obtained from the satellite and the data obtained from the GDM, it was attempted to estimate the target station data by the Deep Learning and ANN methods. The differences between the measured values and the estimated values of the target station are generally less than 1 m/s. It is worth to mention that, these values have excellent results for potential turbines operating under the wind speed ranging from 3 m/s to 25 m/s.

A new test method, MCE (Mean Categorized Error), was presented to determine the error rate for ANN and Deep Learning Methods in the study, which determines the total error rate according to the weighted effect of each estimation of the data set. The measured data of the GDM were simulated using the WASP with the existing maps of the regions taken from the SRTM (Shuttle Radar Topography Mission) database and hence the wind potentials of the evaluated regions were determined.

**Key words:** Artificial Neural Networks, Convolution, Deep Learning, Mean Categorized Error, Performance Calculation, WASP, Wind Speed, Wind Potential.



## ÖN SÖZ

Tez çalışmam süresince büyük bir özveri ve ilgi ile her türlü destek ve yardımlarını esirgemeyen danışman ve hocam Sayın Doç.Dr. Sedat YAYLA'ya teşekkürlerimi sunarım. İşledikleri dersler sayesinde tez çalışmamı büyük bir temele oturtmuş olan hocalarım Doç.Dr. M.Emin Meral, Prof.Dr. Cemil TUNÇ, Doç.Dr. Burak DİKİCİ ve Dr.Öğr. Üyesi Özkan ATAN'a, çalışmam boyunca yardımlarını esirgemeyen bölüm hocalarıma ve çalışmada kullanılan verilere akademik çalışmalar için ücretsiz olarak erişim imkanı sağlayan Eumetsat ve Meteoroloji Genel Müdürlüğü teşkilatları ile çalışmam için maddi desteklerini esirgemeyen Van Yüzüncü Yıl Üniversitesi Bilimsel Araştırma Projeleri Başkanlığı'na (BAP) teşekkürlerimi bir borç bilirim. Ayrıca tez çalışmam boyunca yardım ve desteklerini hiçbir zaman esirgemeyen, maneviyatları ile bana güç veren eşime, oğluma ve aramıza yeni katılan kızıma sonsuz teşekkür ederim.

2018

Emrah HARMANCI



## İÇİNDEKİLER

	<b>Sayfa</b>
ÖZET .....	i
ABSTRACT .....	iii
ÖN SÖZ.....	v
İÇİNDEKİLER.....	vii
ÇİZELGELER LİSTESİ .....	ix
ŞEKİLLER LİSTESİ.....	xi
SİMGELER VE KISALTMALAR .....	xvii
1. GİRİŞ .....	1
2. KAYNAK BİLDİRİŞLERİ.....	9
3. MATERYAL ve YÖNTEM.....	61
3.1. Bölge İşlem Verileri .....	61
3.2. Yapay Sinir Ağları Ve Derin Öğrenme .....	76
3.3. Potansiyel Analizi (WAsP) .....	95
4. BULGULAR VE TARTIŞMA .....	103
4.1. Yapay Sinir Ağları Metodolojisi İle Rüzgar Hızı Tahmini .....	103
4.2. Potansiyel Analizi .....	110
4.3. Derin Öğrenme .....	120
5. SONUÇ .....	127
5.1. Yapay Sinir Ağları.....	128
5.2. Derin Öğrenme .....	129
5.3. Çalışılan İstasyonlara Ait Rüzgar Potansiyeli .....	131
KAYNAKLAR.....	133
ÖZGEÇMİŞ.....	139





## ÇİZELGELER LİSTESİ

Çizelge	Sayfa
Çizelge 3.1 MGM ölçüm istasyonları.....	62
Çizelge 3.2. Çalışılan bölgelere ait coğrafik koordinatlar ve resimler üzerindeki piksel karşılıkları. ....	66
Çizelge 3.3. Önerilen yönteme ait performans aralık sınırları .....	82
Çizelge 3.4. Önerilen yöntemin sık kullanılan bazı yöntemler ile karşılaştırması .....	86
Çizelge 4.1. Çalışmada elde edilen 31904 test çıktısının örnek bir bölümü. ....	109
Çizelge 5.1 Çalışmadaki tüm istasyonlara ait rüzgar gülü ve potansiyel hesap sonuçları.....	131



## ŞEKİLLER LİSTESİ

Şekil	Sayfa
Şekil 2.1. Biyolojik sinir hücresi yapısı.....	10
Şekil 2.2. Yapay sinir ağları işlem modülü .....	11
Şekil 2.3. Önerilen tümleşik sinir ağı modeli. ....	13
Şekil 2.4. Cedros da hibrit ve ARIMA modellerininin gerçekleşen veriler ile karşılaştırılması.....	14
Şekil 2.5. Birleştirilmiş tüm istasyon verilerini kullanarak G'nin mevsimsel tahmini için ANN, MLR ve ARIMA model performans dağılımı. ....	15
Şekil 2.6. Sakarya için YSA tahminleri ile fiili sonuçların karşılaştırılması.....	15
Şekil 2.7. İstatistiksel ve tahmini modelin şematik gösterimi .....	16
Şekil 2.8. 2 girişli ve 4 kurallı bir FIS'in yapısı.....	17
Şekil 2.9. Kullanılan genelleştirilmiş regresyon sinir ağ yapısı. ....	18
Şekil 2.10. Önerilen ve geleneksel sinir ağı yöntemleri için rüzgar hızı tahmin hataları. ....	19
Şekil 2.11. 1. Sütun (yalnız rüzgar hızı kullanımı), 2. Sütun (rüzgar hızı ve hava sıcaklık verilerinin kullanımı), 3.Sütun (rüzgar hızı, hava sıcaklığı ve hava basıncının kullanımı).....	21
Şekil 2.2.12. Girdi sayısının belirlenmesi için, ağda kullanılan rüzgar gülü grafiği. ....	22
Şekil 2.13. EMD–ENN akış diyagramı. ....	22
Şekil 2.14. Ölçüm değerleri ile MLP ve GRNN model sonucu karşılaştırması.....	23
Şekil 2.15. Dört aydan dört aya kadar bir süre boyunca ölçülen ve simüle edilen günlük ortalama hızlar için YSA'nın ve gerçek sonuçların karşılaştırılması.....	24
Şekil 2.16. Sabah verilerinin yüzey sıcaklığının tahmininde sinir ağı sonuçlarının ve regresyon analizinin karşılaştırılması. ....	25
Şekil 2.17. Gizli katmandaki düğüm sayısının eğitime hatasına etkisi. ....	26
Şekil 2.18. Eğitim hatasının iterasyon sayısına göre değişimi. ....	26

<b>Şekil</b>	<b>Sayfa</b>
Şekil 2.19. YSA tahmini ile gerçek sonuç arasındaki karşılaştırma.....	27
Şekil 2.20. (a) Dağlarda hedef bölgenin gerçek rüzgar hızı verileri, (b) Ref olarak kullanılan hedef bölgenin simülasyonlu rüzgar hızı verileri 1. grup, (c) Referans olarak kullanılan hedef bölgenin rüzgar hızı verilerini 2. grup, (d) Hedef bölgenin rüzgar hızı.....	28
Şekil 2.21. Derin öğrenme paylaşımlı gizli katman mimarisi. ....	29
Şekil 2.22. Olasılıksal rüzgar enerjisi tahmini için önerilen yaklaşımın genel mimarisi. ....	30
Şekil 2.23. 6 adımlı rüzgar hızı tahmin sonucu. ....	31
Şekil 2.24. Tam bağlı tabakalar, çekirdek boyutları 5 x 5 ve atlama faktörleri 1 olan konvolusyonel sinir ağı mimarisi.....	33
Şekil 2.25. Boltzman makinesi eğitim prosedürü.....	35
Şekil 2.26. R-CNN algoritması akış şeması. ....	37
Şekil 2.27. Standart ve dropout yöntemi temel işlemlerinin karşılaştırılması.....	39
Şekil 2.28. Kullanılan rüzgar ölçüm cihazları. ....	44
Şekil 2.29. 10 m’de pürüzlülüğün 0.00 m olması durumunda Weibull grafiği ve rüzgar gülü. ....	45
Şekil 2.30. 20 m ve altı için Gökçeada rüzgar tarlası yerleşimi. ....	46
Şekil 2.31. Seçilen bölgeler için topografik haritaları ve rüzgar türbinleri konumu. ....	47
Şekil 2.32. Ölçüm verileri kullanılarak elde edilen üretim değerleri ve santralin gerçek üretimi [MWh]. ....	48
Şekil 2.33. Rüzgar hızlarının yönlere göre değişimi ve Weibull dağılımı ile modellenmesi.....	49
Şekil 2.34. 50 m merkez yüksekliği için seçilen bölgenin rüzgar hızı ve güç yoğunluğu haritaları.....	50
Şekil 2.35. 2004 ve 2005 yılları için rüzgar hızlarının mevsimsel kümülatif olasılık dağılımları.....	51
Şekil 2.36. Rüzgar enerjisi potansiyel atlası.....	51

<b>Şekil</b>	<b>Sayfa</b>
Şekil 2.37. Meteoroloji istasyonları için ortalama rüzgar hızlarının aylık varyasyonu.....	52
Şekil 2.38. Alandaki AEP rüzgar gülleri (a): Ölçülmüş, (b): Sanal rüzgar ölçüm istasyonu metodolojisi, (c): WRF arazi veri bağlama tekniği, (d): Jeostrofik rüzgar kuplaj tekniği).....	53
Şekil 2.39. 10 m a.g.l yükseklikte seçilen alanda rüzgar hızı haritası ve rüzgar türbinlerinin düzeni.....	54
Şekil 2.40. Antakya bölgesinde ortalama rüzgar enerjisi potansiyelinin bölgesel dağılımı.....	55
Şekil 2.41. İskenderun bölgesinde ortalama rüzgar enerjisi potansiyelinin bölgesel dağılımı.....	55
Şekil 2.42. VAS ve WindAtlas tarafından hesaplanan rüzgar hızlarının karşılaştırması.....	56
Şekil 2.43. Tindouf istasyonunda yıllık ortalama akı yoğunluğu.....	57
Şekil 2.44. Çalışılan bölgenin rüzgar haritası.....	58
Şekil 2.45. Seçilen bölge ve Ngaoundere kasabasının doğusundaki varsayımsal rüzgar çiftliği. ....	59
Şekil 2.46. Kadavu adası WASP yüksek çözünürlüklü rüzgar haritası.....	59
Şekil 3.1. Kayıp sra elemanlar için Matlab sinüs fonksiyonu. ....	63
Şekil 3.2. 01.01.2013 tarihli doğu avrupa uydu görüntüsü (tam görüntü). ....	65
Şekil 3.3. 01.01.2013 tarihli Doğu Avrupa uydu görüntüsü (sınırlandırılmış görüntü).....	65
Şekil 3.4. 01.01.2013 tarihli renkli Doğu Avrupa görüntüsünün 3 boyutlu veri matrisi.....	67
Şekil 3.5. 01.01.2013 tarihli Doğu Avrupa uydu görüntüsü (Van merkez yerel bölgesi).....	68
Şekil 3.6. Konvolüsyon katmanı işlem modeli.....	71
Şekil 3.7. Derin mimari akış şeması.....	72
Şekil 3.8. Maksimum havuzlama.....	72

<b>Şekil</b>	<b>Sayfa</b>
Şekil 3.9. YSA ağ mimarisi .....	77
Şekil 3.10. Logsigmoid fonksiyonu.....	78
Şekil 3.11. Purelin fonksiyonu .....	78
Şekil 3.12. Matlab ortalama karesel hata grafiği .....	81
Şekil 3.13. Matlab NN Toolox'da kullanılan 6 adet algoritmanın aynı veri seti ile lara katman ve nöron sayısına göre tahmin başarısının karşılaştırılması. ...	94
Şekil 3.14. Matlab NN Toolox'da kullanılan 6 adet algoritmanın aynı veri seti ile 2 ara katman ve nöron sayısına göre tahmin başarısının karşılaştırılması. ....	94
Şekil 3.15. Zaman serilerine sahip Başkale ölçüm istasyonu gözlemlenmiş ham istasyon verileri (A: tarih, B: rüzgar hızı, C: rüzgar yönü).....	96
Şekil 3.16. WASP programında veri setlerinin girilmesi.....	96
Şekil 3.17. WASP programında veri setlerinden OMWC oluşturulması .....	97
Şekil 3.18. SRTM Database'den topoğrafik veri oluşturulması.....	98
Şekil 3.19. SRTM Database'den elde edilen Başkale istasyonu'na ait vektörel yüzey haritası. ....	98
Şekil 3.20. WASP 11 'de omwc ve vektör haritası verilerinin import edilmesi. ....	99
Şekil 3.21. WASP 11 'de Vektör Map üzerinde potansiyel yoğunluğuna bağlı olarak oluşan gözlem istasyonu ve rüzgar tarlasına ait rüzgar gülü modelleri. ....	100
Şekil 3.22. WASP 11 'de Başkale ölçüm istasyonuna ait potansiyel yoğunluğu haritası.....	101
Şekil 4.1. Tahminlenen Van istasyonu algoritma karşılaştırma ve sapma değerleri grafığı.....	104
Şekil 4.2. Eğitim aşamasına ait matlab ortalama karesel hata grafiği .....	107
Şekil 4.3. Tahminlenen Van istasyonuna ait YSA regresyon grafikleri.....	108
Şekil 4.4. Ağ oluşturulduktan sonra Van istasyonu için MGM ölçüm verileri ve YSA tahmin verileri karşılaştırması .....	110

<b>Şekil</b>	<b>Sayfa</b>
Şekil 4.5. İstasyonlara ait rüzgar iklim verileri ve rüzgar hızı histogramı. ....	114
Şekil 4.6 İstasyonlara ait çevresel engel bilgileri. ....	115
Şekil 4.7 İstasyonlara ait rüzgar potansiyeli haritaları. ....	119
Şekil 4.8 Uydu verileri kullanılarak yapılan tahminlemelerde kullanılan algoritmalar için nöron sayısına bağlı tahmindeki sapma yüzdeleri. ....	121
Şekil 4.9 Uydu verileri kullanılarak oluşturulan modelin eğitim performans grafiği. .	123
Şekil 4.10 Ağ oluşturulduktan sonra uydu verileri kullanılarak Van istasyonu için tahmin edilen hızların gerçek hızlarla karşılaştırması. ....	124
Şekil 5.1 MGM verilerinin ilişki durumları.....	128





## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı kısaltmalar açıklamaları ile birlikte aşağıda sunulmuştur.

<b>Simgeler</b>	<b>Açıklama</b>
$\delta$	Sapma
<b>b</b>	Bias
<b>ds</b>	Ölçüm değerleri
<b>Pmax</b>	Maksimum basınç
<b>Pmin</b>	Minimum basınç
<b>Port</b>	Ortalama basınç
<b>Pst</b>	Basınç standart sapması
<b>Pçarp</b>	Basınç çarpıklık katsayısı
<b>Pbas</b>	Basınç basıklık katsayısı
<b>R</b>	Rule
<b>R<sup>2</sup></b>	Belirlilik katsayısı
<b>Tmax</b>	Maksimum sıcaklık
<b>Tmin</b>	Minimum sıcaklık
<b>Tort</b>	Ortalama sıcaklık
<b>Tst</b>	Sıcaklık standart sapması
<b>Tçarp</b>	Sıcaklık çarpıklık katsayısı
<b>Tbas</b>	Sıcaklık basıklık katsayısı
<b>Os</b>	Tahmin değeri
<b>Vmax</b>	Maksimum hız
<b>Vmin</b>	Minimum hız
<b>Vort</b>	Ortalama hız
<b>W</b>	Ağırlıklar
<b>Zx</b>	Bölgesel x koordinatı
<b>Zy</b>	Bölgesel y koordinatı

**Kısaltmalar****Açıklama**

<b>ANFIS</b>	Uyarlamalı nöro-bulanık çıkarım sistemi
<b>AIS</b>	Annealed importance sampling
<b>AR</b>	Auto regressive
<b>ArcGIS</b>	Geographic information service
<b>BPNN</b>	Back propagation neural network
<b>CWET</b>	Uluslararası Rüzgar Enerjisi Teknolojileri Merkezi
<b>ÇLRM</b>	Çoklu lineer regresyon modeli
<b>DBN</b>	Deep belief network
<b>DNN</b>	Deep neural network
<b>DNN-MRT</b>	Deep neural network based meta regression and transfer learning
<b>ENN</b>	Elman sinir ağı
<b>GRNN</b>	Genelleştirilmiş regresyon sinir ağı
<b>GWC</b>	Generalised wind conditions
<b>IMF</b>	İntrensik mod işlevleri
<b>IOA</b>	Index of agreement
<b>LIDAR</b>	Light detection and ranging
<b>LST</b>	Land surface temperature
<b>MAE</b>	Mean absolute error
<b>MAPE</b>	Mean absolute percentage error
<b>MAWEEE</b>	Maximum available wind energy estimation error
<b>MCDA</b>	Çok ölçütlü karar analizi
<b>MCE</b>	Kategorize edilmiş ortalama sınaama
<b>MGM</b>	Meteoroloji Genel Müdürlüğü
<b>MLP</b>	Çok katmanlı algılayıcı
<b>MNIST</b>	Modified national institute of standards and technology database
<b>MRH</b>	Aylık ortalama bağıl nem
<b>MSE</b>	Mean square error

<b>MTP</b>	Aylık toplam çökeltme
<b>NASA</b>	National aeronautics and space administration
<b>NORB</b>	New York University object recognition benchmark
<b>OMWC</b>	Gözlemlenmiş rüzgar iklim dosyası
<b>RBFNN</b>	Radial basis function neural network
<b>RMSE</b>	Root mean square error
<b>RNN</b>	Recurent neural network
<b>RSC</b>	Relative sensitivity coefficient
<b>SSE</b>	Sum square error
<b>SAGA</b>	System for automated geo-scientific analysis
<b>SRTM</b>	Shuttle radar topography mission
<b>UTM</b>	Universal transverse mercator
<b>VAS</b>	Visual analogue scale
<b>WOS</b>	Wind observation site
<b>WRF</b>	Weather research and forecasting
<b>WSHE</b>	Wind speed histogram error
<b>WSP</b>	Wind speed probability
<b>YSA</b>	Yapay sinir ağları



## 1. GİRİŞ

Ünlü fizikçi ve astronom Hawking (2017), insanların önümüzdeki 50 yıl içerisinde, dünyayı terk etmek için kaçış planı yapması gerektiği söylemiştir. Bunun yapılmaması durumunda insan ırkının tamamen veya kısmen yok olma tehlikesiyle karşı karşıya kalabileceğini söylemiştir. Dünyada süregelen açlık ve savaşların kaynağının enerji probleminden ileri geldiği söylenmektedir. Bu soruna yeterli ölçekte çözümler bulunamadığı takdirde diğer tüm çalışma ve sorunların önemsiz kalacağı, insanoğlunun yok olma veya büyük bir yıkım ile karşı karşıya kalacağı bilim çevrelerince kabul edilmektedir. Gates (2010), TED'de yaptığı bir konuşmada günümüzün en önemli problemlerinin kaynağının enerji sorunundan ileri geldiğini ve gelişmiş en üst düzey teknolojileriyle öncelikle bu sorunu çözmeye çalıştıklarını söylemişlerdir.

18 yy. 'da İngiltere'de başlayıp Avrupa ve Amerika'ya yayılan Sanayi Devrimi uygarlıkların devamı için enerjinin vazgeçilmez bir unsur olduğunu göstermiştir. Enerji alanında güçlü olan ülkelerin, ekonomik anlamda da güçlü olacağı, geçerliliğini günümüzde de sağlamaktadır. Diğer yandan ekonomik açıdan güçlü olan ülkeler dünya siyasetine de yön vermektedir.

Enerji sorununun bu kadar büyük problemlere yol açtığı günümüzde insanoğlunun halen doğal enerji kaynaklarından çok az yararlanıyor olması büyük bir eksikliktir. Doğada hali hazırda bulunan yenilenebilir enerji kaynakları günümüzde insanoğlunun tüm ihtiyacını karşılayabilecek miktarlardadır. Ancak insanoğlu bu potansiyelden yararlanmak için gerekli altyapıyı hazırlamak yerine, hızlıca enerji arzını karşılayabileceği yöntemlere başvurmakta ve dünyadaki enerji stoğunu tüketerek, insan ırkının yok olmasına neden olabilecek çevresel sorunlar yaratmaktadır. İnsanoğlunun doğaya verdiği bu zararın önüne geçebilmek için enerji arzının hızlıca alternatif kaynaklardan karşılanması gerekmektedir. Bunun yolu doğru strateji ve planlamalardan geçmektedir.

Bu planlamaları yapabilmek için enerji potansiyeli belirlemede çeşitli istatistik, ölçüm, benzetim ve tahminleme yöntemleri olmasına rağmen bu yöntemlerin günümüzde en çok öne çıkanı, birçok alanda olduğu gibi yapay zeka teknikleri olmuştur. Yapay zeka teknikleri günümüzde hemen her alanda çeşitli yöntemlerle

uygulanmakta ve devrim niteliğinde gelişmelere sebep olmaktadır. Günümüzde yapay zeka ile, insanlığın bilime yönelmesinden günümüze kadar birikmiş tüm bilimsel yöntem ve gelişmeler ile insanlık tarihi boyunca tutulan tüm verileri saniyeler içerisinde yorumlayabilen ve çözümler üretebilen sistemler kurulmuştur.

Yapay zeka ilk olarak 1956 yılında Dartmouth College’de düzenlenen bir konferansta dile getirilmiştir. İlk yapay zeka kitabı ise, Feigenbaum ve Feldman (1963) tarafından 21 makalenin derlenmesi sonucu basılan “Bilgisayar ve Düşünce” adlı eserdir. Turing testi ile ilgili ifadeleri de içeren bu çalışmalar yapay zekanın klasikleri olarak görülmektedir.

Elde edilmeye çalışılan makine öğrenmesi sağlanarak insani zaafpların ortadan kaldırılmaya çalışılması ve bilginin daha hızlı analiz edilmesiyle günümüz problemlerine daha kesin ve hızlı cevaplar üretebilmektir. Ancak oluşturulmaya çalışılan sistem, insan taklidi bir yapı oluşturmaktan çok, insan soyut düşünce zekasının bir benzerinin oluşturulmasıdır. Günümüzde bilgisayarlar insani birçok davranışı taklit edebilmektedirler, ancak sadece ön tanımlı olan bu davranışları geliştirmek, karşılına çıkan önceden programlanmamış yeni sorunlara çözüm bulmak konusunda pek başarılı olamamaktadırlar. Halbuki insanı diğer canlılardan ayıran en büyük yeteneği, karşısına çıkan sorunlar için beyinde soyut çözümler üreterek bu sorunlara uygun çözüm yöntemleri geliştirmektir. Diğer canlılar aynı bilgisayar programlarının yaptığı gibi önceden kodlanmış bazı içgüdüsel davranışlarıyla sorunlara çözüm bulurken insanoğlu bu konuda son derece özelleşmiş vasıflara sahiptir.

Nabiyev (2016), zekadan bahsedilebilmesi için, gerçekleştirilen uyarlamanın bütün soya özgü kalıtsal bir mekanizmanın basit uygulaması değil de yeni olması, bunun bir birey ya da bir gruba mal edilecek bir buluştan kaynaklanması gerektiğini belirtmiştir.

IBM şirketinin üretmiş olduğu Deep Blue isimli bilgisayarı dünyanın en iyi satranç oyuncusu olan, eski dünya şampiyonu Kasparov’u yenerek yapay zekanın yapabileceklerini göstermiştir. Deep Junior programı eski dünya şampiyonları Kramnik ve Kasparov’la berabere kalmıştır.

Günümüzde derin öğrenme yöntemi çerçevesinde yürütülen yapay zeka algoritmaları NVIDIA şirketinin geliştirmiş olduğu paralel işlemcilerin de katkısıyla

analizlerin zaman sorununu ortadan kaldırmıştır. Dünya Go şampiyonlarını tek tek dize getiren AlphaGo yazılımı, bu yöntemle çalışmaktadır. Sistem Google şirketi tarafından DeepMind departmanında GoogleTranslate'e adapte edilmiş ve günümüzde gerek yazı, gerekse de görüntü ve ses ortamında dil çevirisinde devrim niteliğinde bir gelişme sağlanmıştır. Belli kalıp ve yöntemlerin uygulanmasıyla elde edilen dil çevirme sistemleri, yerini hiçbir kalıba bağlı olmadan yalnızca bağlı olduğu web'deki bilgileri değerlendirerek kendi ağını güncelleyen ve bunun neticesinde sonuçlar üreten bir sisteme bırakmıştır. Bu sistem Youtube tarafından videolardaki anlık çevirilerde de kullanılmaya başlanmıştır. Ayrıca benzer yazılımlar dudak okuma, yüz tanıma, plaka tanıma, kanser teşhisi ve robotik uygulamalar gibi pek çok alanda da yer edinmeye başlamıştır.

Rüzgar enerjisi üretimi için, rüzgar türbinlerinin konumlandırılacağı alanlar ile ilgili olarak daha önce çok çeşitli yöntemler kullanılmıştır. Bunlardan bazılarını, arazi yapısına göre yapılan simülasyonlar ve istatistik hesap yöntemleri oluşturmaktadır. Arazi yapısı ve istatistik yöntemler temel alınarak yapılan simülasyon veya hesaplamalar, doğrusal parametrelere göre sonuçlar ürettiklerinden dolayı çeşitli durumlarda yanıltıcı olabilmektedir. Oysaki doğa olaylarının gerçekleşme zamanı ve yerleri çoğunlukla öngörülemez durumdadır. Başka bazı etkiler altında rastgele oluşurlar ve incelediğimiz durum için bir istatistik oluştururlar. Böyle bir durumda yapmamız gereken aslında tüm bu etkileri ve onlara sebep olan etkilerin tümünü hesaplayacak bir benzetim sistemi oluşturmak olacaktır. Bu çok karmaşık ve uzun süreli ölçüm veya hesaplamalar gerektirecektir. Böyle bir sistemin her alanda oluşturulması imkansızdır. Ancak genellemelere giderek bunların kısmen göz ardı edileceği genel hesaplama yöntemleri oluşturabiliriz. Ancak bu genelleme yöntemleri de kritik durumlarda yanıltmamıza sebebiyet verebilecektir. Aslında önemli bazı etkilerin göz ardı edilebileceği bu genel sistemler, bu ve benzer etkilerin olduğu zamanlarda yüksek oranda hatalı sonuçlar vereceklerdir.

Mculloch ve Pitts (1943), tarafından yayınlanan makalede bir YSA modeli sunulmuştur. Bu tarihten sonra Minsky ve Papert isimli iki bilim adamının öncülüğünde yöntem üzerine çeşitli bazı çalışmalar yapılsa da, önemli bazı problemlerin çözümlerini sağlayamadığı için (XOR vb.) bilim alanında yöntemin pek bir önemi olmamıştır. 1969



yılından sonra bilgisayar teknolojisinin gelişiminin etkisiyle önceki modelin gelişmiş çeşitli birçok varyasyonları oluşturulmuştur. Bu çalışmalar, ara katmansız olarak oluşturulmuş sistemlerin gelişimi için önemli bir dönüm noktası olmuştur (Meral, 2016).

Yapay Sinir Ağları doğrusal olmayan sistemleri de rahatlıkla çözebilen çok basit bir ağ mimarisine sahip hızlı ve kullanışlı bir yöntem olarak karşımıza çıkmıştır. Basit ve yalın bir mimariye sahip olması çalıştığımız hemen her sisteme adapte edilebilmesini sağlamıştır. Ayrıca yüksek hızlı çözümlere ihtiyaç duyulduğu durumlarda diğer bütün sistemlere oranla çok daha hızlı çözümler üretebiliyor olması tercih edilme sebebi olmuştur. Yapay sinir ağı modeli, sistem parametrelerini çözerken, bunların etki değerlerini ve doğrusal olmayan durumları da kendi içinde bir ağırlık olarak tuttuğunda dolayı beklenmeyen etkilerin oluşabileceği durumları da tahmin edebilmektedir. Her hangi bir olayın diğer bir olay üzerindeki etkisi tek başına tahmin edilemese de çeşitli varyasyonların çözümlenmesi sonucu bu etkinin durumu gözlemlenebilir. Yapay sinir ağının oluşturduğu çözümlerde bu şekilde olmaktadır. Her bir verinin kendine has durumunu bir ağırlık olarak tutarak bunların birbirleri ile olan ilişkileri için mantıksal bir ağ oluşturulmaktadır. Bu ağ, verilerin şekillendirdiği ağırlıklar ve bunların bağlantılarından oluşmaktadır.

YSA modelleri günümüzde hemen her alanda (sanayi, istatistik, akademik, tıpta, uzay araştırmaları v.b.) üretim öncesi tahminleme ve üretim aşamasında müdahale durumları için kullanılmaktadır. Daha önce sadece modellemeler üzerinden giden insanoğlu, insan beyninin gelecek hakkındaki öngörme yeteneğini taklit ederek bu modeller üzerinde takip edilemeyecek rastgele oluşan varyasyonları sistemin çözümü için kullanma imkanı bulmuş ve hem sonuca götürecek çeşitli model için gereken masraflardan kurtulmuş hem de sistemin çözümünde gecikmelerin yaşanmasının önüne geçmiştir. İncelenen konular YSA yöntemlerinin bilgisayar programları yardımıyla işlenmesi sonucu hızlıca çözüme götürülmüş ve yıllarca sürece modelleme ve araştırma sonuçları saniyeler içerisinde elde edilebilmesi imkanı sağlanmıştır.

Derin öğrenme ilk olarak, Stanford Üniversitesinden bir grup araştırmacının birisi resim tanıma diğeri doğal dil işleme olmak üzere iki sinir ağını birleştirmesiyle ön plana çıkmıştır. Bu sayede resim içerisindeki objelerin sınıflandırılmasından öte, tüm

nesnelerin birbiriyle olan ilişkisinde sağlanabilmiştir. Bu çalışma insanların analiz imkanı bulamadığı, gittikçe artan sayıdaki kameralara ait veri yığınının bilgisayarlar tarafından analiz edilebilmesi imkanı sağlamaktadır. Savaş alanlarından elde edilen görüntülerin analizi, aranan şahıslar, nesnelere veya araçların tespiti bu yolla gerçekleştirilebilmektedir.

Daha sonraları yöntemin yalnızca resimlerde değil, büyük ölçekli verilerin analizinde de kullanılabileceği anlaşılmış ve günümüzde birçok alanda üstün çözümlene sistemleri geliştirilebilmesine olanak sağlamıştır. İnsanoğlu 2018 yılı başlarında bu yöntemi kullanarak insan beyin düşünce aktivitesini bilgisayarların izlemesini sağlayarak, düşüncelerin anlık kelime karşılıklarını bilgisayarlarda ekranda okumayı başarmıştır.

Yöntem basitçe yakın alandaki veri kümelerinin sentezi şeklinde çalışmaktadır. Küme içerisindeki veriler basit bir matematiksel işlem ile sadeleştirilerek bir havuzlama katmanı oluşturulmaktadır. Verilerin sayısı ve analiz edecek sistem özelliklerine bağlı olarak katman sayısı ardışık işlemlerle artmaktadır. En son havuzlama işleminden sonra elde edilen veriler tamamen bağlı katmanlardan geçirildikten sonra bir karşılaştırma prosedürüne bağlanır. Bu işlem daha önce eğitilmiş olan YSA'nın veri kümesi üzerinde değerlendirme yaparak sonuçlar üretmesini sağlar. İşlem sonucu ağın hızlıca ve çeşitli alanları birbirinden ayırt ederek sonuçlar üretmesi sağlanır.

Ayrıca derin öğrenme giriş verisi sayısını düşürdüğü için YSA'nın eğitim aşamasında ağ yapısını daha hızlı oluşturmasını sağlar. Çalışmada her biri 341x225 piksele sahip 35881 adet uydu görüntüsü analiz edilmiştir. Bu veriler derin öğrenme sistemi olmadan YSA'da analiz edilmeye çalışılsa, günümüzdeki en iyi sistemlerle dahi sonuçlanmayacak bir sürecin içerisine girilmiş olacaktı. Sistemin optimize edilmesi gereği de düşünüldüğünde böyle bir çalışmanın sonuç bulması imkansızdır.

Oluşturulan model bölgeye ait uydu görüntüleri içerisindeki birçok alan üzerinde analiz imkanı tanımıştır. Ayrıca bu verilerin birbirleri ile olan etkileşimlerinin de analiz edilmesi mümkün olmuştur. Doğa olaylarının gelişigüzel gerçekleşen birçok etkileşimin sonucu oluşması, ölçüm sonuçlarının değerlendirilmesinde hata oranının yükselmesine sebebiyet vermektedir. Oysaki bütün bu olayları görüntüleyen bir gözün YSA ile analiz

edilmesi bütün etkilerin ve birbirleriyle olan ilişkilerinin değerlendirmede işleme alınabilmesini sağlar.

İnsanoğlunun varoluşundan itibaren, çevresini anlamaya çalışması üzerine geliştirdiği bütün yol ve yöntemler kuşkusuz insanlık tarihi için büyük bir birikimdir. Her bir olayı açıklamak için mantıksal bazı matematiksel işlemler geliştirmeye çalışmış olan insanoğlu, doğal olayların birçoğuna genel yaklaşımlar sağlamıştır. Yapılan çalışmalar etrafımızda gerçekleşen birçok olayı açıklamakta yeterli gelmektedir. Mühendislik alanında kullanılan birçok sistem bu genel yaklaşımlarla analiz edilerek hayata geçirilmektedir. Çevresel faktörler, emniyet faktörleri ile birlikte belli oranlarda etki ettirilerek sisteme ait çözümler daha iyi bir şekilde sağlanmaya çalışılmaktadır. Her ne kadar sapmalara sebebiyet verse de bu tür genellenmiş yaklaşımlar modern çağda teknolojik çalışmaların büyük bir bölümünün altyapısını oluşturmuştur. Hastanelerden nükleer santrallere, uzay araçlarından elektrik üretim santrallerine, kullandığımız araçlardan ürettiğimiz besin kaynaklarına kadar tüm teknolojik sistemlerimizin işleyişi, insanlık tarihi ile birlikte geliştirilmiş bu genel yaklaşımlar üzerinden gerçekleştirilmektedir. Bu genel yaklaşımların hayatımızdaki yeri göz ardı edilemeyecek kadar büyüktür. Ancak doğal olaylar neticesinde gerçekleşen sapmalar bazen göz ardı edilemeyecek derecede önemli olmaktadır. Günümüzde bu sapmaların, oluşturulan kabullere dahil edilerek, bunları bir etki olarak değerlendiren sistemler yapay zeka altında işlem görmektedir.

Çalışmada bölge potansiyel analizi için WASP programı kullanılmıştır. WASP İklim Analisti rüzgar kaynağı değerlendirmesi için gözlemlenen ortalama rüzgar verilerinin oluşturulmasını ve IEC yer değerlendirmesi için aşırı rüzgar datalarını gözlemlemeyi de içeren rüzgar verileri zaman serilerinin içe aktarma, seçme ve analizleri için tasarlanmış, genelleşmiş bir araçtır. Troen ve Petersen (1989), tarafından hazırlanan Avrupa Rüzgar Atlası, Danimarka'nın Risø National Laboratory'de üretilmiş olan WASP programı üzerinden gerçekleştirilmiştir. WASP incelenen bölgenin tomografik yapısı, yüzey pürüzlülüğü ve bölgeye ait belirli noktalarındaki ölçülmüş iklim verilerine bağlı olarak bölgenin genel potansiyelinin zaman serisi yaklaşımı ve simülasyonlar sonucu elde edilmesine dayanarak çalışan bir analiz programıdır.

WAsP programı, simülasyonları, rüzgar hızı değerlerinin 2 değişkenli Weibull dağılımına paralel bir dağılım gösterdiğini varsayarak yapmaktadır. Program, dört giriş değerini (rüzgar hızı, pürüzlülük, çevre engel bilgileri, topoğrafya) değerlendirerek, incelenen alandaki rüzgar potansiyeli değerlerini hesaplamaktadır.

Yapılan çalışmada rüzgar tarlası kurulması açısından süreklilik arz eden elverişli bölgelerin tespiti ile bu bölgelerin potansiyellerinin belirlenmesine yönelik çalışmalar yer almaktadır. Bu kapsamda, Meteoroloji Genel Müdürlüğünden, Van ve Hakkari illerine ait sekiz ölçüm istasyonundan alınmış veriler (Bağıl nem, sıcaklık, basınç, rüzgar hızı, rüzgar yönü ve rakım) ile birlikte Eumetsat sitesindeki DataCenter bölümünden elde edilmiş Meteosat 7 uydusuna ait Doğu Avrupa uydu görüntüleri kullanılarak bölge rüzgar potansiyeli YSA, Derin Öğrenme ve WAsP programı kullanılarak tespit edilmeye çalışılmıştır.



## 2. KAYNAK BİLDİRİŞLERİ


İnsan, sahip olduđu zekasının bir sonucu olarak, veriler içerisindeki etkileşimi gözlemleyerek, birbiri ile olan ilişkilerine göre sonuçlar üretebilen ve bu yönde davranışlarını geliştiren fiziksel dünyada bildiğimiz tek varlıktır. İnsan zekası her ne kadar bu etkileşimleri inceleyip belli başlı konularda standart yaklaşımlar oluşturmaya çalışmış olsa da, birçok faktör oluşturulan standartlarda göz ardı edilmektedir. Oluşturulan her standart yol ve yöntem, bir başka ortamda farklı koşullara maruz kaldığından, çoğunlukla yetersiz kalmaktadır.

Çalışmada hatalı verilerin ayrıştırılmasının ardından, 244311 veri seti incelenmiştir. Her bir veri seti içerisindeki girdilerin birbiriyle olan ilişkisi üzerinden, sisteme ait bir mantıksal ağ oluşturulmuştur. Bu insan biyolojik sinir ağının hafıza olarak adlandırdığımız bölgede, kalıcı olarak biriktiremeyeceği bir bilgi yoğunluğudur. Bu büyüklükte bir bilgi yoğunluğu içerisinde analiz yaparak, bunların birbirleri ile olan ilişkilerini belirlemek ise organik yapıdaki sinir sistemi için imkansızdır.

İnsan beyninin tüm yapısında yaklaşık olarak 100 milyar hücre bulunmaktadır. Bu hücrelerin her biri, bir YSA modülü gibi işlev görmekte ve her bir modülde de 15.000 YSA nöronuna karşılık dentrit bulunmaktadır. 100 milyar hücrelik organik beyin düzeni, insanoğluna üstün bir zeka yeteneği kazandırmaktadır. Ancak bu sistemin zafiyeti unutkanlıkla başlamaktadır. Beyin kendini korumak için reseptörlerden gelen bilgiyi veya işlem yeteneğini kısıtlamaktadır. Aracımızla yolda seyir halindeyken etraftaki her türlü detayı incelemeyiz. Gözlerimiz, kulaklarımız bunların tümünü görüp işitmesine rağmen bu bilgiler beyinde işlenmez. Bunu yapmasına rağmen beynimiz vücudumuza aldığımız enerjinin dörtte birini kendisi harcar. Bu nedenle bu denli büyük verilerin analizinde bu tür bir biyolojik yapının kullanılması imkansızdır.

Ancak beyin sinir sistemini örnek alarak oluşturulan bir yapay sinir birimi bunu gerçekleştirebilmektedir. Egrioglu ve ark. (2009), YSA'nın, biyolojik sinir ağları taklit eden sentetik ağlar olduğunu belirtmişlerdir.

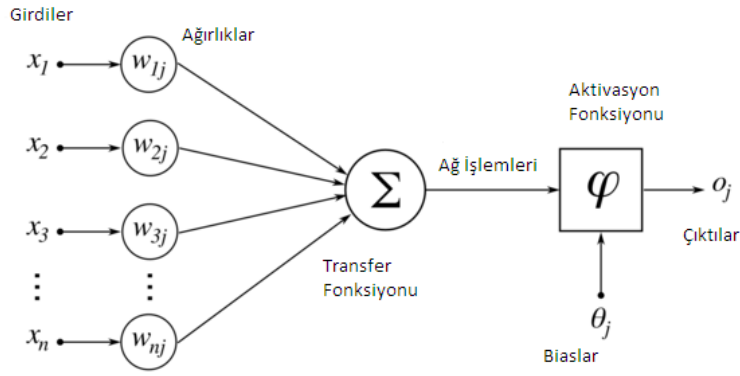
İnsan beyin hücreleri, bilgi toplamak için Şekil 2.1'de görülen, dendrit denilen reseptörleri kullanırlar.



Şekil 2.1. Biyolojik sinir hücresi yapısı (Anonim, 2016).

Hücre reseptörlerinin dendritler aracılığıyla elde ettiği bu bilgiler hücre çekirdeğine sahip gövde bölgesinde değerlendirmekte ve hücreye ait sonuçları akson denilen gövde uzantısı bir yapı üzerinden sinyal olarak tekrar reseptörler aracılığıyla dışarı vermektedir. Bu sistem sayesinde sinir sistemi kararlarını verebilmektedir. Beyin her bir kararı almak için bu yapılardan binlercesini özelleştirmiştir. İnsan vücudunun oluşmaya başlamasından hemen sonra doğuma kadar geçen zaman içerisinde beynin %99'luk bölümü yapısal olarak tamamlanır ve bu işlevleri yapan bölümler özelleşmiş olur. Sistem erkeklerde 100 milyara yakın bir hücre yapısıyla tüm vücut fonksiyonlarını kontrol altında tutmaya başlar. Çevresel etkiler ile ihtiyaç duyulan strateji ve karar mekanizmalarının tümü vücut tarafından bu ağ sistemi üzerinden yürütülür.

YSA modülü de Şekil 2.2'de görüldüğü üzere, biyolojik sinir hücresinde olduğu gibi, girdilerin sisteme dahil edildiği bir giriş katmanına sahiptir. Bu giriş katmanı elemanları MATLAB ve benzeri programların tümünde yalnızca sayısal olarak işlenebilmektedir. Sayısal bir değer olarak işleme alınan ölçüm verileri ağırlıklar ve transfer fonksiyonları üzerinden birbirleri ile ilişkilendirilir. İlişkilendirilen verilerden, bir sonraki katmandaki nöron sayısı kadar sonuç üretilir. Bu sonuçlar daha sonra istenirse yeni ağırlıklar üzerinden aktivasyon fonksiyonu yardımı ile çıktılara dönüştürülebileceği gibi, ikinci veya daha fazla ara katmanlı bir şekilde de çıktı katmanına aktarılabilir. Bu düzen ağın üstündeki eğitilmiş veri tutma ihtiyacına göre değişiklik gösterebilir. İnsan sinir hücreleri, ihtiyacı olmayan reseptörlerde yıkıma gitmektedir. Daha sonra ihtiyaç duyduğu noktalarda bunları tekrar oluşturmaktadır. Bu şekilde kendisi için önemsiz olan bilgilerin depolanmasını da önlemekte ve enerji kaybının da önüne geçmektedir.



Şekil 2.2. Yapay sinir ağları işlem modülü (Anonim, 2016).

İnsan doğasındaki bu uygulama Srivastava ve ark., (2014), geliştirmiş olduğu “dropout” yönteminde oluşturularak sistemin hızlı cevaplar üretmesi sağlanmaya çalışılmıştır. Yöntem ağ mimarisi içerisinde oluşturulmuş olan ağırlıkların bir kısmını başlangıçta etkisiz kılarak sistemin daha hızlı döngüler gerçekleştirmesini sağlamaktadır. Döngülerdeki bu iptal işlemleri rastlantısal olarak gerçekleştirilmektedir. Bir döngü içerisinde etkisiz kılınan ağırlıklar etkilerine göre bir sonraki aşamada değerlendirmeye alınmaktadır.

Çalışmada oluşturulan ağ sisteminde de, ağ yapısı benzer biçimde yapılan çalışmalara has özelliklere sahip olabilmektedir. Bu özellikler veri sayısı ve veri çeşitliliğine göre değişiklik göstermektedir. Bununla ilgili literatürde herhangi bir standart uygulama olmamasına karşın çoğunlukla giriş verisi sayısının iki katı kadar nöronun ilk katmanda bulunmasının başarılı sonuçlar verdiği kabul edilmektedir. Ancak her sistemin kendine özgü optimum çözümleri bulunmaktadır. Bu optimizasyon çalışma içerisinde çeşitli yollarla uygulanmaya çalışılmıştır. Ancak bu tür bir optimizasyonun nihai sonuçla sonuçlanabilmesi için oldukça gelişmiş bir donanım gerekmektedir. Çalışılan sistem donanımları bu tür bir durum karşısında çok yetersiz kaldığından dolayı bu yöndeki çalışmalar kısıtlı bir şekilde devam ettirilmiştir. Bu tür bir optimizasyonu, biyolojik sinir hücrelerinin, ne tür bir veriye dayanarak yaptığının bilimsel bir açıklamasına literatürde rastlanmamıştır. Derin öğrenmede olduğu gibi bu tür bir optimizasyonun sisteme uyarlanabilecek duruma getirilmesinin yapay zeka alanında büyük bir eşiğin aşılması anlamına geleceği düşünülmektedir. Bu durum insan beyninin

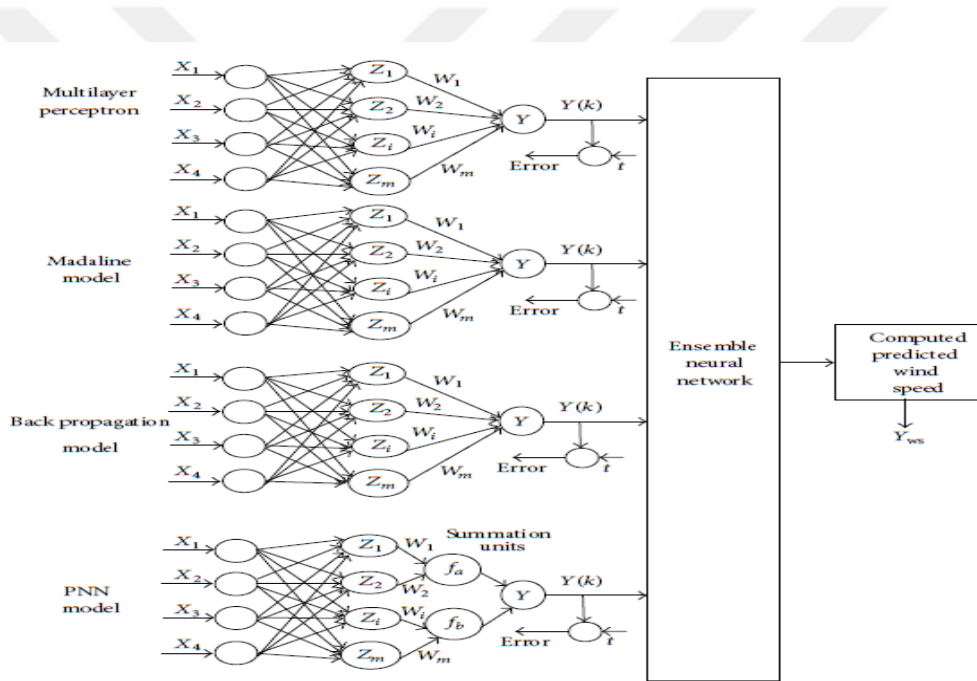


yaptığı optimum düzey sağlamlasının, yapay zeka alanında gerçekleştirilebilmesini sağlayacaktır.

İstatistik ve analize dayalı hesap yöntemlerinde, önceden belirlenmiş belli kurallar çerçevesinde çözümler üretiliyor olması sebebiyle, verilerin birbirlerine göre etkileşimi göz ardı edilmektedir. Bu durum veri kaybına sebep olmaktadır. Yapay Sinir Ağları Yöntemi bu standartların dışına çıkarak, verileri kendi içlerindeki ilişkilere göre değerlendirmektedir. Bu durum tüm etkilerin hesaba dahil edilmesini sağlar. Çünkü sonuçlar belli formüllerin kullanılması sonucu değil, tüm etkenlerin belli ağırlıkta değerlendirmeye katılması sonucu oluşmaktadır. Bu sonuçların yeterli büyüklükte bir ağ sistemi üzerinde biriktirilerek analiz edilmesi, doğrusal ve doğrusal olmayan tüm etkenlerin gizli katmanlarda çözüme dahil edilmesini sağlar.

Bilgiç ve ark. (2016), yaptıkları çalışmada, Türkiyenin güneyinde yer alan Hatay bölgesine ait rüzgar hızını tahmin etmek için YSA ve ÇLRM yöntemlerini kullanmışlardır. Çalışmada YSA performans değerlendirmesi  $R^2$ , RMSE ve MAE üzerinden gerçekleştirilmiştir. Yapılan çalışmada Hatay bölgesine ait bir yıllık olarak ölçülmüş meteorolojik veriler kullanılarak yıllara ait 365'er adet veri seti oluşturulmuştur. Bu veri setlerinde YSA giriş elemanı olarak 12 bağımsız değişken ( $T_{max}$ ,  $T_{min}$ ,  $T_{ort}$ ,  $T_{st}$ ,  $T_{çarp}$ ,  $T_{bas}$ ,  $P_{max}$ ,  $P_{min}$ ,  $P_{ort}$ ,  $P_{st}$ ,  $P_{çarp}$  ve  $P_{bas}$ ) ve 3 adet ( $V_{max}$ ,  $V_{min}$ ,  $V_{ort}$ ) çıkış elemanı kullanılmıştır. Kullanılan veri setlerinin %69'u eğitim geri kalanlar ise test için kullanıldığı belirtilmiştir. Çalışmada eğitim algoritması olarak Levenberg-Marquardt kullanılmıştır. Eğitim aşamasındaki en iyi performans değerlerinin 1 ara katmanlı,  $V_{max}$  ve  $V_{ort}$  için 20 ve  $V_{min}$  için 15 nörona sahip yapılardan elde edildiği belirtilmiştir. Elde edilen sonuçlara göre ÇLRM yöntemi ile elde edilen sonuçlarda etkin parametrelere dayalı yapının ortalama hız tahmininde başarılı olduğu tespit edilmiştir. Ancak etkin parametrelere bakılmaksızın elde edilen tüm verilerle yapılan analizlerde YSA'nın ÇLRM'ye göre daha başarılı olduğu belirtilmiştir. Kaya ve ark. (2016), Kastamonu ili rüzgar enerjisi potansiyelini YSA ile ölçmeye çalışmışlardır. Program olarak Matlab YSA ara yüzü kullanılmıştır. Eğitim aşamasında öğrenme algoritması olarak 'traingd' seçilmiştir. YSA modelinde Kastamonu il merkez istasyonu rüzgar verileri giriş değeri olarak kullanılarak 6 adet türbin için çıkış gücü değerleri elde edilmiştir. Bu türbinlerin Kastamonu'da belirtilen alanlarda kullanılması durumunda


1921 MW enerji üretilebileceği tespit edilmiştir. Ranganayaki ve Deppa (2016), yapay sinir ağları modellerinde gizli nöronların sayısını belirlemek amacıyla Multi Layer Perceptron, Madaline, Back Propagation Network ve PNN modelleri üzerinde çalışmışlardır (Şekil 2.3). YSA içerisindeki nöron sayısının gelişigüzel seçilmesinin, yetersiz sonuçlar ürettiğini belirtmişlerdir. Çalışmalarında bu sorunların ortaya çıkmasını önlemeyi amaçlamışlardır. Kıstaslar, giriş katmanı nöronlarının sayısına bağlı olarak geliştirilmiştir. Yakınsama teoreminde elde edilen en düşük hataya ulaşan kıstas, kullanılan modelde uygulanması gereken nöron sayısını belirlemektedir. Yöntem literatürde daha önce önerilen yaklaşımlarla karşılaştırıldığında diğerlerine nazaran en düşük MSE oranını sağlamaktadır.



Şekil 2.3. Önerilen tümleşik sinir ağı modeli (Ranganayaki ve Deppa, 2016).

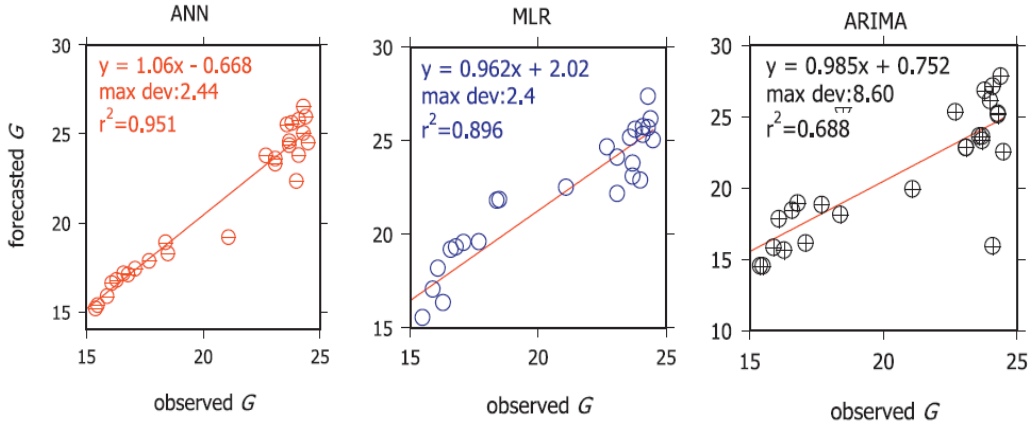
Cadenas ve Rivera (2010), bir ay boyunca farklı bölgelerde (California Cedros, Zacatecas ve Holbox'ta) ölçümlerden elde edilen ortalama saatlik rüzgar hızı verilerini kullanarak rüzgar hızı tahminini için, ARIMA ve YSA modellerinden oluşan hibrit yöntemler geliştirmişlerdir. Zaman serilerinin rüzgar hızı tahminini yapmak için ARIMA modeli kullanılmıştır. YSA, ARIMA tekniğine bağlı olarak doğrusal olmayan

eğilimleri dikkate alarak inşa edilmiş ve bu da hata oranını düşürmüştür. Hibrit modeller ile ilgili çalışmalar tamamlandıktan sonra sonuçlar ayrı olarak çalışan ARIMA ve YSA modelleriyle karşılaştırılmıştır. Üç yöntem sonuçlarının karşılaştırılması için MSE, MSE ve MAE hata hesaplama yöntemleri kullanılmıştır. Sonuç olarak hibrit modellerin diğer yöntemlere göre daha başarılı sonuçlar ürettiği tespit edilmiştir (Şekil 2.4).



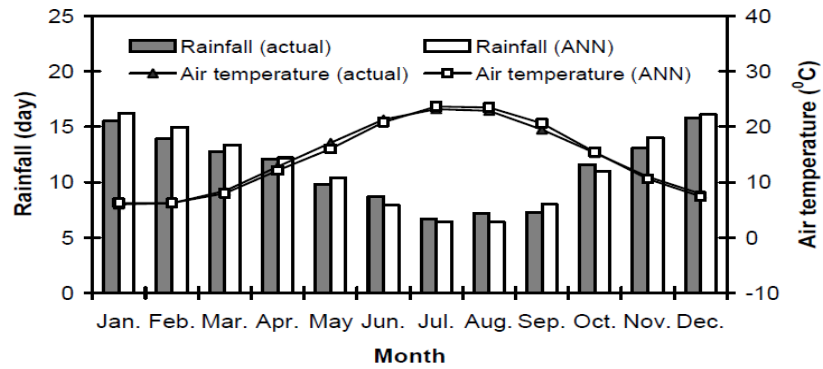
Şekil 2.4. Cedros da hibrit ve ARIMA modellerininin gerçekleşen veriler ile karşılaştırılması (Cadenas ve Rivera, 2010).

Deo ve Şahin (2017), Avustralyanın Queensland bölgesinde yüzey güneş ışınımı değerlerini, LST uydu verilerini kullanarak tespit etmeye çalışmışlardır. Çalışmada kullanılan veriler NASA uydularının MODIS Terra sensörü ve Bilimsel Bilgi (SILO) arşivlerinden elde edilmiştir. 2012-2014 yılları arasında ölçülmüş olan LST verilerinin %69'u eğitim, geri kalanları ise doğrulama aşamasında kullanılmıştır. Çalışmada ARIMA, MLR ve YSA modelleri kullanılmıştır. Çalışmada 9 adet modele göre 1 ara katman ve bu modellere ait değişken sayılı nöron sayıları ile tahminlemeler yapılmıştır. YSA modelinin ARIMA ve MLR modellerine kıyasla yüksek oranda daha iyi sonuçlar ürettiği belirtilmiştir. Çalışmada YSA algoritması olarak Levenberg-Marquardt kullanılmıştır. Çalışmada YSA tahminin ARIMA ve MLR modellerine göre %5.85 oranında daha iyi performans gösterdiği belirtilmiştir (Şekil 2.5).



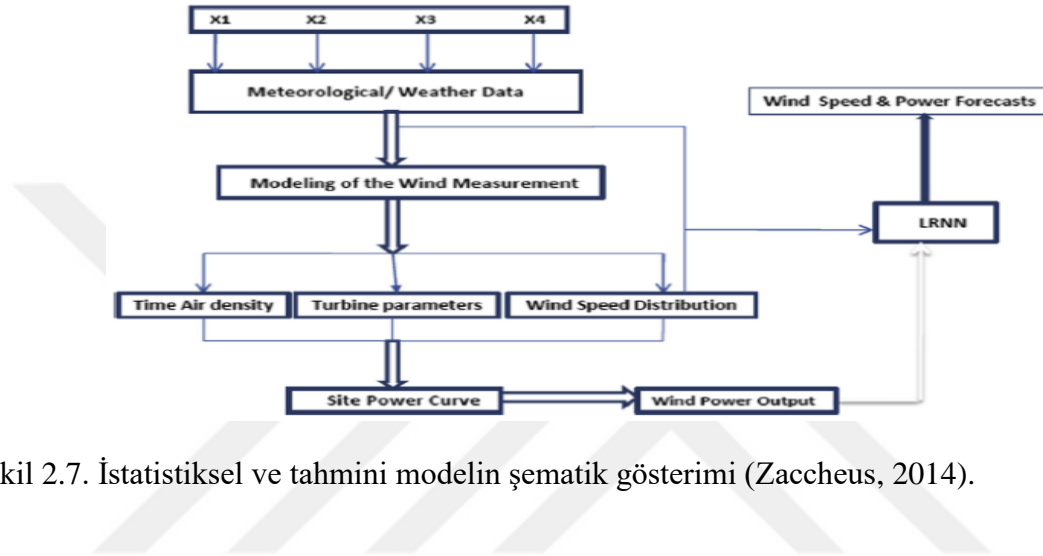
Şekil 2.5. Birleştirilmiş tüm istasyon verilerini kullanarak G'nin mevsimsel tahmini için ANN, MLR ve ARIMA model performans dağılımı (Deo ve Şahin, 2017).

Bilgili (2007), doktora çalışmasında Akhisar, Belen, Datça, Gelendost, Söke, Gökçeada, Foca, Gelibolu ve Bababurnu bölgelerinde referans ölçüm istasyonlarının verilerini kullanarak hedef istasyon verilerini tahminlemeye çalışmıştır. Bu çalışma sonucunda YSA sonuçlarındaki sapmaların kurulacak sistemler açısından kabul edilebilir sınırlar içerisinde kaldığını, haftalık veya günlük hız tahminlerinin, aylık hız tahminlerine göre daha kötü sonuçlar verdiğini tespit edilmişlerdir. Çalışmada en iyi performans %3.24 oranla Gelibolu istasyonunda sağlanmıştır. Çalışma alanı ile ilgili bir potansiyel değerlendirilmesi yapılmış ve Belen gibi bazı alanlarda rüzgar tarlarının kurulabileceği ön görülmüştür (Şekil 2.6).



Şekil 2.6. Sakarya için YSA tahminleri ile fiili sonuçların karşılaştırılması (Bilgili, 2007).

Zaccheus (2014), Olaofe Paarl ve Vredenburg bölgeleri ölçüm istasyonu verilerini kullanarak RNN ile rüzgar potansiyelini belirlemeye çalışmışlardır. Tahmin modeli olarak 'trainlm' algoritmasını kullanılmıştır. Aynı yükseklikte 10 dakikalık veriler kullanılarak hedef istasyondaki rüzgar hızını tahmin etmeye çalışmıştır. Elde edilen sentetik numuneler ile ölçüm verileri arasında çok küçük sapmalar olduğu tespit edilmiştir (Şekil 2.7).

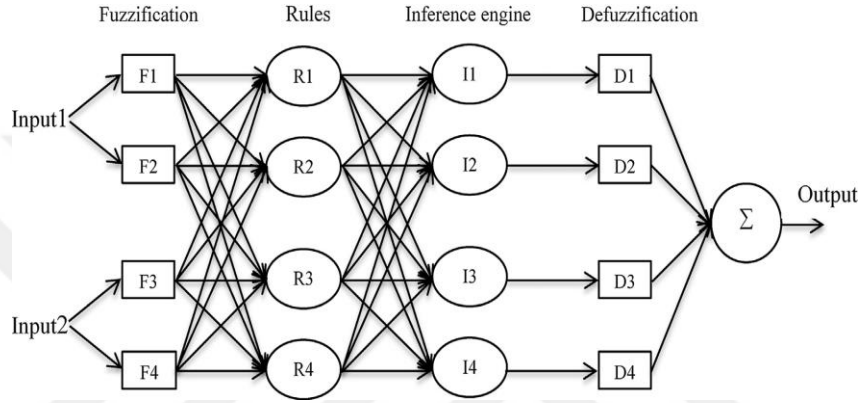


Şekil 2.7. İstatistiksel ve tahmini modelin şematik gösterimi (Zaccheus, 2014).

Cao ve ark. (2012), tek değişkenli ve çok değişkenli ARIMA modellerinin RNN ile karşılaştırılması ve rüzgar hızı sonuçlarının tutarlılığının karşılaştırmalı bir analizini yapmışlardır. Analiz, aynı noktada yerden beş farklı yükseklikte alınan aynı zamandaki ölçüm verilerini içermektedir. Çalışmada çok değişkenli ARIMA yapılarının tek değişkenli yapılardan daha iyi sonuçlar ürettiği tespit edilmiş ve RNN yapılarının ARIMA yapılarından daha iyi sonuçlar ürettiği tespit edilmiştir.

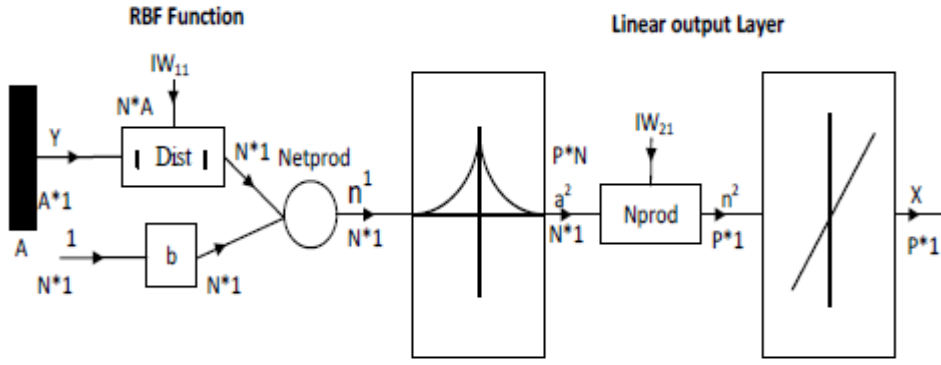
Noorollahi ve ark. (2016), yapay sinir ağları kullanılarak rüzgar hızı tahmini için hem zamansal hem de mekansal boyutlarda olmak üzere iki bölümde incelenme yapmışlardır. İran'da üç ölçüm istasyonundan bir saat aralıklarla ölçülmüş verilerle rüzgar hızının zamanla değişimini tahminlemeye çalışmış, bir sonraki bölümde birbirine yakın bazı istasyonlardan alınan verileri kullanılarak referans istasyonlardan hedef istasyon verilerini tahminlemeye çalışmışlardır. Çalışmada BPNN, RBFNN ve ANFIS modelleri kullanılmıştır. Çalışmada modellerin kısa süreli performans ölçütlerini karşılaştırmak için MAPE, RMSE ve MAE kullanılmıştır. Mekansal rüzgar hızının

performans değerlendirmesinde ise WSHE ve MAWEEE yöntemleri kullanılmıştır. Elde edilen modellerin her istasyona göre farklı sonuçlar ürettiği ve buna bağlı olarak doğruluk oranının değiştiği belirtilmiştir. Bu durumun işlenen rüzgar verilerinin özelliklerine bağlı olduğu belirtilmiştir. Bu performans değerlendirme yöntemlerine ait hesap yöntemleri çalışmada açıklanmıştır. BPNN ve ANFIS modellerinden elde edilen sonuçların benzer olduğu ve rüzgar hızı tahmin hatasının ortalama olarak % 2.6 olduğunu tespit etmişlerdir (Şekil 2.8).



Şekil 2.8. 2 girişli ve 4 kurallı bir FIS'in yapısı (Noorollahi ve ark., 2016).

Kumara ve Malik (2016), Hindistan'ın 67 ilinde GRNN ve MLP kullanılarak rüzgar hızı tahminlemesi yapmışlardır. Çalışmada eğitim giriş verisi olarak boylam, enlem, günlük güneş radyasyonu, hava sıcaklığı, bağıl nem, toprak sıcaklığı, yükselme, soğutma derecesi, ısıtma derecesi ve atmosfer basıncını kullanılmıştır. Hedef katmanda ise rüzgar hızı kullanılmıştır. Bu verilerin NASA üzerinden elde edildiği belirtilmiştir. Çalışmada elde edilen 67 ile ait 26 il veri setinin eğitim, 21 il veri setinin test ve geri kalan 20 ile ait veri setlerinin ise tahminleme aşaması için kullanıldığı belirtilmiştir. Çalışmada modellerden elde edilen sonuçlara göre ortalama karesel hatalar karşılaştırmış ve GRNN'nin MLP'den daha iyi sonuç ürettiği belirtilmiştir. Çalışmada GRNN ve MLP'nin doğruluk oranlarını, eğitim aşaması için %99.99 ve %97.974 test aşamasında ise % 98.85 ve % 95.23 olarak bulmuşlardır (Şekil 2.9).




Şekil 2.9. Kullanılan genelleştirilmiş regresyon sinir ağ yapısı (Kumara ve Malik, 2016).

Yasar ve ark. (2012), yaptıkları çalışmada topografik ve meteorolojik verilerin yardımıyla Türkiye'nin Ege Bölgesi'ndeki MRH değerlerini ANN kullanarak tahmin etmeye çalışmışlardır. Çalışmada iklim verisi olarak İzmir, Muğla, Aydın, Denizli, Uşak, Manisa, Kütahya ve Afyonkarahisar illerinde Türk Meteoroloji Servisi ölçüm istasyonlarından elde edilen 2000-2006 yılları arasındaki MRH ve MTP verileri kullanılmıştır. Aylık zaman serisine bağlı enlem, boylam, rakım ve yağış ANN ağının giriş katmanında, MRH ise çıktı katmanında kullanılmıştır. Çalışılan YSA modelinde normalizasyon işleminin 0.1-0.9 aralığında yapıldığı belirtilmiştir. Çalışmada MATLAB programı kullanılarak ANN yapısı oluşturulmuş ve daha sonra gerçek değerler ile karşılaştırma yapmışlardır. Elde edilen değerlerin kabul edilebilir hata sınırlarında olduğunu belirtmişlerdir. Çalışmada en iyi değerlerin Manisa istasyonundan elde edildiği ve YSA modelinin MLR modelinden daha iyi sonuçlar ürettiği belirtilmiştir. Elde edilen modelin doğruluğunu kanıtlamak için çevre bölgelerde bulunan istasyon verileri kullanılarak tahminleme yapılmış, Ege bölgesinde bulunan Nazilli istasyonu için MAPE değeri 5.5 ve Ege bölgesi dışında bulunan Burdur istasyonu için ise 5.6 olarak tespit edilmiştir.

Mohandes ve ark. (1998), yaptıkları çalışmada rüzgar hızı tahminlemesi için YSA kullanmış ve sonuçları istatistiksel bir model ile karşılaştırarak değerlendirmişlerdir. Suudi Arabistan Cidde'de rüzgar hızının istatistiksel özellikleri incelenerek istatistiksel katsayılar tespit edilmiştir. İstatistiksel olarak elde edilen rüzgar hızının gerçek ölçümler

ile uyumlu olduğu tespit edilmiştir. Zaman serilerine bağlı olarak ortalama aylık ve günlük hız tahminlemelerini ayrıca YSA ile gerçekleştirerek sonuçlar karşılaştırılmıştır. Hata oranının belirlenmesi için ortalama karesel hata kökü (RMSE) kullanılmıştır. Çalışmada 2 aylık ve günlük olarak 2 ayrı düzeyde testler yapılmıştır. Aylık olarak gerçekleşen çalışmada 144 aylık veri seti kullanılmıştır. YSA eğitimi için 120 aylık veri seti eğitim ve kanal 24 aylık veri seti ise test aşamasında kullanılmıştır. Aylık verilere dayalı testlerde YSA eğitimi sonucu RMSE değeri 1.87 olarak bulunmuştur. Buna karşılık AR modelden elde edilen RMSE değeri 2.88 olarak hesaplanmıştır. Günlük verilere dayalı gerçekleşen çalışmada ise 4802 günlük veri seti kullanılmış ve bu verilerin 730 günlük kısmı eğitim ve 4072 günlük kısmı ise test aşamasında kullanılmıştır. Günlük verilere dayalı testlerde YSA eğitimi sonucu RMSE değeri ise 1.24 olarak bulunmuştur. Buna karşılık AR modelden elde edilen RMSE değeri 1.37 olarak hesaplanmıştır. Sonuç olarak YSA analizlerinin autoregresif modelden daha iyi sonuçlar ürettiğini tespit etmişlerdir.

Monfared ve ark. (2009), yaptıkları çalışmada bulanık mantık ve YSA'ya dayalı hibrit bir yöntem üzerinde çalışmışlardır. Yapılan çalışma ile tahminleme yaklaşım oranı daha az nöron ve daha az sürede daha iyi sonuçlar verecek şekilde geliştirilmiştir. Deneysel çalışmalar, önerilen yöntemin bulanık kurallara daha az bağımlı ve daha az hesaplama süresinde daha iyi bir rüzgar hızı tahmini performansı sağladığını göstermiştir (Şekil 2.10).




Şekil 2.10. Önerilen ve geleneksel sinir ağı yöntemleri için rüzgar hızı tahmin hataları (Monfared ve ark., 2009).



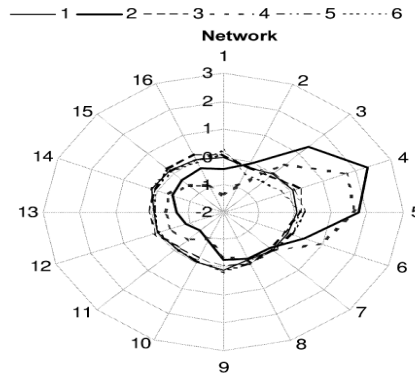
Çam ve ark. (2005), yaptıkları çalışmada, Türkiye’de yedi bölgeye ait beş farklı yükseklikte ölçülmüş olan ortalama rüzgar hızı ve rüzgar gücü değerlerine bağlı olarak YSA ile hesaplamalar yapmışlardır. YSA ağ modeli Matlab programı kullanılarak oluşturulmuştur. Çalışmada eğitim verisi olarak boylam, enlem ve yükseklik giriş katmanında, rüzgar hızı ve güç değerleri ise çıkış katmanında değerlendirilmiştir. Oluşturulan ağın bölgelere göre farklı yakınlıkta sonuçlar ürettiğini tespit etmiş, ancak sonuçların gerçek veriler ile karşılaştırıldığında yüksek yakınsama ile sağlandığını tespit etmişlerdir. Petkovic’ (2015), yaptığı çalışmada, uyarlamalı nöro-bulanık çıkarım sistemi kullanarak rüzgar hızı tahminlemesi yapmaya çalışmıştır. Uyarlamalı nöro-bulanık çıkarım sistemi modelinin tahmin sonuçlarını, ortalama karesel hata, belirleme katsayısı ve Pearson katsayısını kullanarak değerlendirmiştir. Yapılan çalışma uyarlamalı nöro-bulanık çıkarım sisteminin rüzgar hızı tahmini açısından kabul edilebilir sınırlar içerisinde tahminleme yapabildiğini göstermiştir. Uyarlamalı nöro-bulanık çıkarım sistemi diğer istatistik yöntemlerle karşılaştırılmış ve daha başarılı sonuçlar ürettiği tespit edilmiştir. Philippopoulos ve Deligiorgi (2012), yaptıkları çalışmada, karmaşık arazi yapısına sahip kıyı ortamında saatlik rüzgar hızını tahmin etme açısından ileri beslemeli sinir ağı mimarisini incelemiştir. Eğitimli sinir ağlarının çalışma alanı için geleneksel interpolasyon yöntemlerinden daha üstün olduğunu belirlemiştir. Eğitimli ağların bölgeye özgü olmasına rağmen yöntemin diğer yerlerde de uygulanabilir olduğunu ve rüzgar vektörünün önemini vurgulamışlardır. Filik ve Filik (2017), yaptıkları çalışmada, rüzgar hızı tahminleri için yerel bazı değişkenlere dayalı çeşitli YSA tabanlı modeller önermişlerdir. Çalışmada kullanılan eğitim ve test verileri hava sıcaklığı, rüzgar hızı, rüzgar yönü ve hava basıncının değerlerini kaydedebilen bir veri izleme sistemi kullanılarak 2 Mart - 2 Nisan 2016 tarihleri arasındaki ölçümlerden elde edilmiştir. Ölçüm verilerine ait son 5 günlük dönem test aşamasında kullanılmıştır. Ağ modelinde geri yayılım algoritması olarak Levenberg–Marquard ve ateşleme fonksiyonu olarak da logsigmoid fonksiyonunun kullanıldığı belirtilmiştir. Çalışmada 3 ayrı giriş verisi üzerinden ayrı olarak değerlendirme yapılmıştır. İlk modelde yalnızca rüzgar, ikinci modelde rüzgar hızı ve sıcaklık, üçüncü modelde ise rüzgar hızı, sıcaklık ve basınç parametreleri kullanılarak ağdaki eğitim sağlanmıştır. Yapay sinir ağları üzerinden geliştirilen modellerden elde

edilen sonuçların performansları ortalama karekök hata ortalaması (RMSE) ve ortalama mutlak hata (MAE) kullanılarak karşılaştırılmıştır. Birden çok yerel değişken kullanmanın etkisini benchmark için kalıcılık yöntemi ile analiz etmiş ve karşılaştırma yapmışlardır. Çalışmada, rüzgar hızı tahmini için farklı meteorolojik verilerin YSA ile araştırılması yapılmıştır. Elde edilen sonuçlara göre en düşük RMSE ve MAE değerleri çalıştıkları üçüncü yapıdan elde edilmiştir (Şekil 2.11).




Şekil 2.11. 1. Sütun (yalnız rüzgar hızı kullanımı), 2. Sütun (rüzgar hızı ve hava sıcaklık verilerinin kullanımı), 3.Sütun (rüzgar hızı, hava sıcaklığı ve hava basıncının kullanımı) (Filik ve Filik, 2017).

Lopez ve ark. (2008), yaptıkları çalışmada YSA kullanılarak Galiçya bölgesinde ortalama rüzgar hızını tahmin etmek için bir yöntem geliştirmişlerdir. Çalışılan yöntemde, Bayesian algoritması tarafından eğitilmiş, 15 nöronlu bir gizli katmanın bulunduğu çok tabakalı bir algılayıcı ağ yapısı kullanmışlardır. Karmaşık arazilerde, yön girdisinin % 23'lük tahmin etkisine neden olabilecek çok önemli bir girdi olduğunu belirtmişlerdir (Şekil 2.12) Çalışılan bölgedeki yıllık ortalama rüzgar hızı simüle edilerek elde edilen sonuçlar, yakındaki istasyonlardan alınan verilerle karşılaştırılmış ve hataların % 2'nin altında kaldığını tespit etmişlerdir.



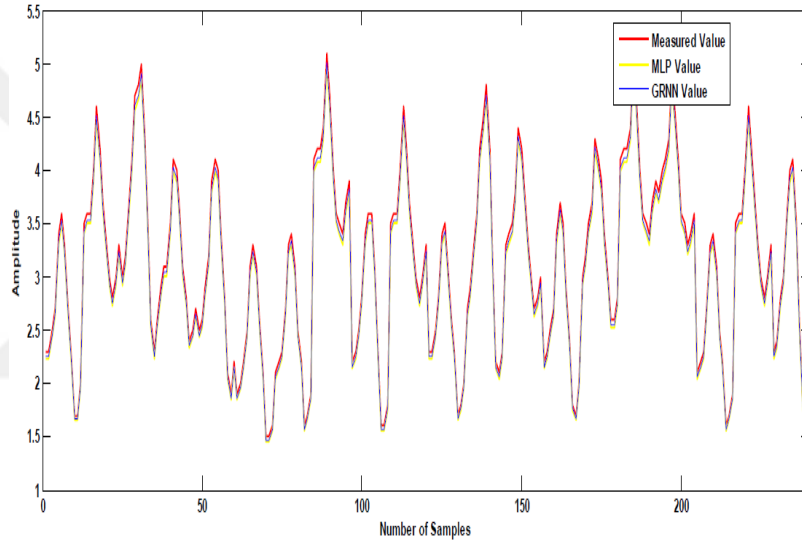
Şekil 2.12. Girdi sayısının belirlenmesi için, ağda kullanılan rüzgar gülü grafiği (Lopez ve ark., 2008).

Wang ve ark. (2014), rüzgar hızının kaotik doğası ve iç karmaşıklığı nedeniyle, rüzgar hızı hareketlerini doğru bir şekilde tahmin etmenin zor olduğunu belirtmişlerdir. Çalışmalarında, rüzgar hızını tahmin etmek için istatistik yöntem ve YSA melez önermişlerdir. Ölçümlerden elde edilmiş rüzgar hızı verileri IMF ve EMD yöntemleri kullanılarak sentezlenmiş ve YSA tarafından daha kolay çözümlenebilen alt seriler elde edilmiştir (Şekil 2.13). İNN modellerini oluşturmak için IMF bileşenleri kullanılmıştır. ENN sürecinde kısmi otokorelasyon fonksiyonu ile orijinal rüzgar hızı verileri elde edilmiştir.



Şekil 2.13. EMD-ENN akış diyagramı (Wang ve ark., 2014).

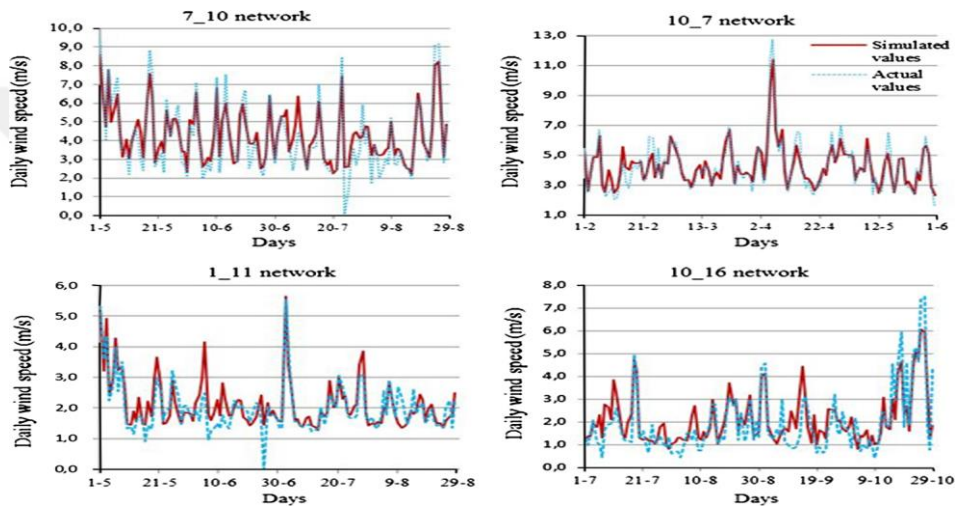
Kumar ve Malik (2016), yaptıkları çalışmada, rüzgar hızını tahmin etmek için Genelleştirilmiş Regresyon Sinir Ağı ve Çok Katmanlı Perceptron ağ yapılarını kullanmışlardır. Çalışmada kullanılan veri setleri NASA'dan toplanmıştır. Eğitim giriş elemanı olarak boylam, enlem, günlük güneş radyasyonu-yatay, hava sıcaklığı, bağıl nem, toprak sıcaklığı, atmosfer basıncını kullanmışlardır. Çalışmada iki modelin MSE'si karşılaştırılmış ve GRNN'nin MLP'den daha iyi sonuç verdiği tespit edilmiştir. GRNN ve MLP'nin doğruluğu, için sırasıyla % 99.99 ve % 97.97 eğitim fazında, % 98.85 ve % 95.23 test aşamasında bulunmuştur (Şekil 2.14).



Şekil 2.14. Ölçüm değerleri ile MLP ve GRNN model sonucu karşılaştırması (Kumar ve Malik, 2016).

Velo ve ark. (2014), yaptıkları çalışmada, rüzgar hızını ölçmek için hava istasyonu bulunmayan bir bölgede yapay sinir ağları kullanarak yıllık ortalama rüzgar hızı tahmini için bir yöntem önermişlerdir. Sinir ağı eğitimi için kullanılan girişler, yakın istasyonlardan alınan rüzgar hızı ve yön verileridir. Yöntem, eğitim aşamasında gerekli olan veri miktarını analiz ederek en iyi çözümün, yıl boyunca altmış günlük gözlem kullanmak olduğuna karar vermiştir. Yalnızca bir aylık veriler kullanılarak eğitilen bir ağ için, elde edilen sonuçlar, simülasyon için seçilen aya göre oldukça yetersizdir. Yalnızca bir istasyondaki veriler kullanılarak oluşturulan ağın, Galiçya'daki

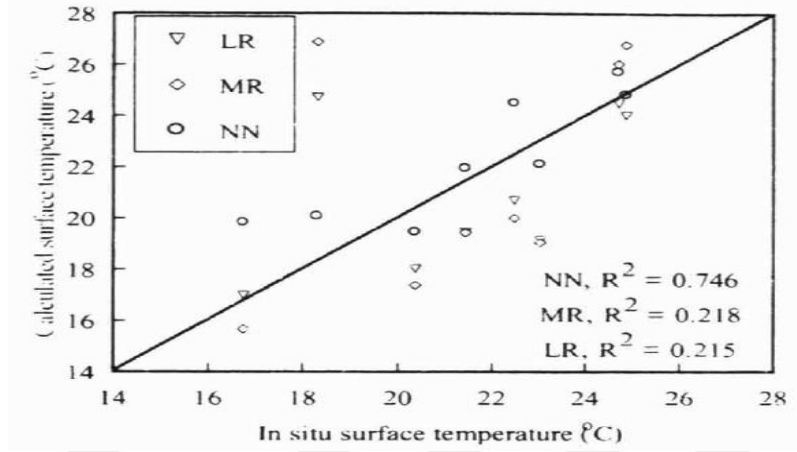
karmaşık arazide bulunan 20 istasyondaki tahminlemelerinin, ölçülen gerçek değerlerle karşılaştırıldığında çok tatmin edici olduğu sonucuna varılmıştır. Giriş olarak kullanılan istasyon hedef istasyon ile 0.60'ın üstünde bir korelasyon katsayısı gösterdiğinde, gerçek ve simüle edilmiş yıllık hızlar arasındaki farklar % 3'ü aşmamaktadır. 0.50'in üstünde bir korelasyon katsayısı olsa bile, yıllık ortalama hızlarda farklar% 5'in altındadır. Kullanılan yöntem ile hedef istasyonun yıllık rüzgar hızı karmaşık meteorolojik ve topografik veriler kullanılmadan tatmin edici şekilde tahmin edilebileceği tespit edilmiştir (Şekil 1.15).



Şekil 2.15. Dört aydan dört aya kadar bir süre boyunca ölçülen ve simüle edilen günlük ortalama hızlar için YSA'nın ve gerçek sonuçların karşılaştırılması (Velo ve ark., 2014).

Njoroge ve ark. (2000), yaptıkları çalışmada hava çoklu spektral sensör (MSS) tarafından alınan parlaklıktan yüzey sıcaklığı kestirimi için, doğrusal regresyon, çoklu regresyon ve geri yayılım nöral ağ modeli arasında karşılaştırmalar yapmışlardır. Analiz için sabah ve öğleden sonra kaydedilen yükselen ışık şiddeti verileri kullanılmıştır. Sinir ağı modelinin, havadaki MSS sensörünün yüzey sıcaklığı ve alınan parlaklığı arasındaki transfer fonksiyonunu modellediği gösterilmiştir. %  $\pm 10$ 'luk artık hata aralığını kullanan sinir ağı AM ve PM yüzey sıcaklıkları için yaklaşık % 87.5'lik tahmin seviyesine ulaşmıştır. Yüzey sıcaklığını doğru bir şekilde tahmin etmek için, doğrusal olmayan çoklu regresyon yöntemi olan sinir ağının, doğrusal olmayan aktarım

fonksiyonunun modellenmesinde, geleneksel regresyon analiz yöntemlerinden daha yararlı olduğu tespit etmişlerdir (Şekil 2.16).



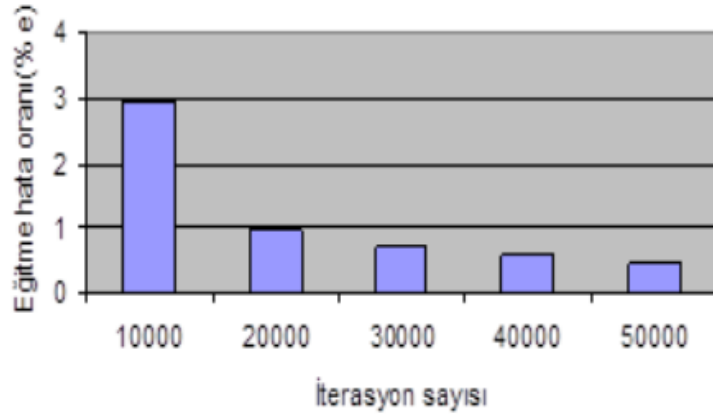
Şekil 2.16. Sabah verilerinin yüzey sıcaklığının tahmininde sinir ağı sonuçlarının ve regresyon analizinin karşılaştırılması (Njoroge ve ark., 2000).

Ata (2014), yaptığı çalışmada, Türkiyede Akhisar bölgesi için yıllık ortalama rüzgar hızını, Hellmann katsayısı, kule yüksekliği gibi parametrelere bağlı rüzgar esme sürelerini YSA ile analiz etmiştir. Rüzgar esme süreleri analizinde Rayleigh dağılımı'nın kullanıldığı geleneksel yöntem ile YSA'nın karşılaştırılmasını yapmıştır. Elde edilen test verileri için ortalama yüzde hata değerleri %-4.1 ve %3.4 aralığında değişmiştir. İterasyon sayısı 50.000 iken test örneklerinin hedef değerlere ulaşmadaki başarısı yaklaşık olarak %100 olmuştur (Şekil 2.18). YSA çıkış parametreleri bu iterasyonda %0.45 hata ile elde edilmiştir. YSA'nın genelleştirme ve paralel bilgi işleme yeteneğinden dolayı çok katmanlı ağ çıkış düğüm sayısını oldukça iyi bir oranda tanımayla gerçekleştirdiği ve modelin enerji planlama ve gelecekteki rüzgar türbini planlamaları için faydalı olacağı tespit edilmiştir (Şekil 2.17). Öztopal ve Şen (2009), yaptıkları çalışmada, soğuk tepeli bulutların sıcak tepelilerden daha fazla yağış üretmelerinden hareketle, 2000 yılı içerisindeki 5-7 Eylül döneminde gözlenen bir konvektif yağışlı olay incelenmiştir. Bu zaman aralığındaki Meteosat 7'nin kızılötesi kanal verisi, çalışma istasyonlarındaki 6 saatlik toplam yağış verisi ve NCEP/NCAR'ın düğüm noktalarına aktarılmış troposferin düşey seviye verileri kullanılmıştır.

Geliştirilen bir YSA modeli ile de yağış miktarı tahmin edilmeye ve bu modelin başarısı ölçülmeye çalışılmıştır. Model Eylül ayı yağışında başarılı olmuştur.




Şekil 2.17. Gizli katmandaki düğüm sayısının eğitime hatasına etkisi (Ata, 2014).



Şekil 2.18. Eğitim hatasının iterasyon sayısına göre değişimi. (Ata, 2014).

Bilgili (2010), yaptığı çalışmada, aylık zemin sıcaklığını lineer regresyon (LR), doğrusal olmayan regresyon (NLR) ve yapay sinir ağı (ANN) yöntemleriyle modellemiştir. Adana meteoroloji istasyonundan alınan toprak sıcaklığı ve diğer meteorolojik parametreler, Devlet Meteoroloji İşleri Genel Müdürlüğü tarafından 2000-2007 yılları arasında gözlenmiştir. Zemin sıcaklıkları zemin seviyesinin 5, 10, 20, 50 ve 100 cm derinliklerinde ölçülmüştür. Çalışmada üç katmanlı bir ileri besleme YSA yapısı oluşturulmuş ve YSA'ların eğitimi için bir geri yayılım algoritması kullanılmıştır.

Başarılı bir simülasyon elde etmek için tüm meteorolojik değişkenler (toprak sıcaklığı, atmosferik sıcaklık, atmosferik basınç, bağıl nem, rüzgar hızı, yağış, küresel güneş radyasyonu ve güneş ışığı süresi) arasındaki korelasyon katsayıları ikiye bölünerek hesaplanmıştır. İlk olarak, bağımsız değişkenlerin tümü soğuk ve ılık mevsim gibi iki zaman dilimine ayrılmıştır. Girdi regresyon modeline eklenmiş, ardından, en iyi regresyon denkleminin seçimi için aşamalı çoklu regresyon yöntemi uygulanmıştır. Bu nedenle, en iyi bağımsız değişkenler LR ve NLR modelleri için seçilmiş ve ANN yönteminin giriş katmanında kullanılmıştır. Yöntemlerin sonuçları birbirleriyle karşılaştırılmış ve ANN yönteminin LR ve NLR yöntemlerinden daha iyi performans sağladığı tespit edilmiştir (Şekil 2.19).




Şekil 2.19. YSA tahmini ile gerçek sonuç arasındaki karşılaştırma (Bilgili, 2010).

Koo ve ark. (2015), yaptıkları çalışmada, yapay sinir ağları ile referans istasyon verileri kullanarak belirlenmiş bir hedef bölgedeki rüzgar hızı tahmininin doğruluğunu incelemiştir. Referans ve hedef siteler üç coğrafi kategoride incelenmiştir: ovalar, sahiller ve Güney Kore dağları. Rüzgar hızı tahminleri, YSA tarafından elde edilen



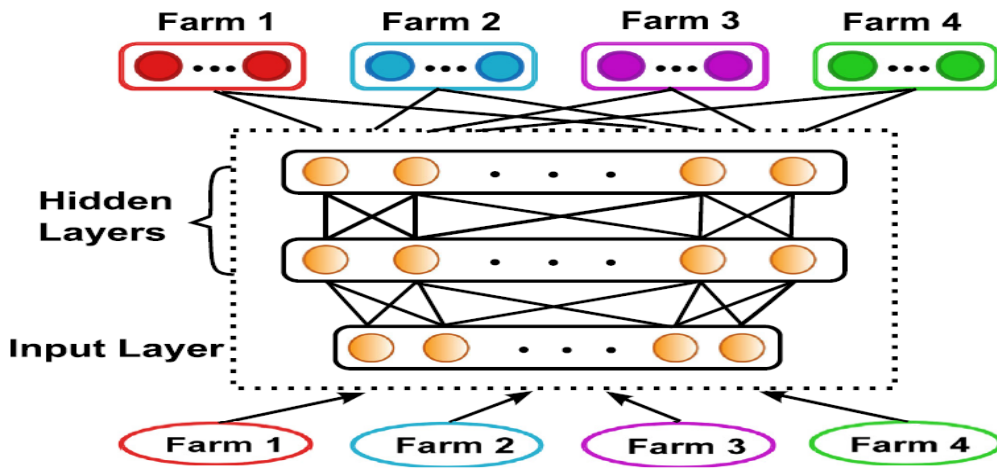
gerçek ve simüle rüzgar hızı verileri arasındaki korelasyon katsayısı ile hesaplanmıştır. Her bir kategorinin jeolojik özelliklerinin ve referans ve hedef alanlar arasındaki mesafenin ANN'yi kullanarak rüzgar hızı tahmini doğruluğu üzerindeki etkisi araştırılmıştır. Sahil kıyılarında elde edilen sonuçların daha karmaşık yapıya sahip dağlık bölgeden elde edilen sonuçlardan daha iyi olduğu tespit edilmiştir (Şekil 2.20). Tahminlemelerde Taebaek Dağları'nın neden olduğu karmaşık topografya ve varyant yüksekliği, başlıca olumsuz faktörler olmuştur. Referans ve hedef alanlar arasındaki uzaklıktan ziyade, korelasyon katsayısının YSA tarafından rüzgar hızı tahmininin doğruluğunu belirlediği tespit edilmiştir.



Şekil 2.20. (a) Dağlarda hedef bölgenin gerçek rüzgar hızı verileri, (b) Ref olarak kullanılan hedef bölgenin simülasyonlu rüzgar hızı verileri 1. grup, (c) Referans olarak kullanılan hedef bölgenin rüzgar hızı verilerini 2. grup, (d) Hedef bölgenin rüzgar hızı (Koo ve ark., 2015).

Hu ve ark. (2016), yaptıkları çalışmada, rüzgar hızının belirsizliği nedeniyle, büyük ölçekli rüzgar enerjisi modellenmesi için doğru bir tahmin modeli oluşturmak zorunluluğunu belirmiş ve veri odaklı çalışmanın sayısal analiz yöntemlerine nazaran daha başarılı olduğunu söylemişlerdir. Eski rüzgar çiftliklerinde uzun süredir tutulmuş olan büyük verilerin yeni kurulacak rüzgar tarlaları için elde edilmiş olan veriler ile birleştirildikten sonra derin öğrenme ile analiz edilerek haritalamaları daha hassas bir

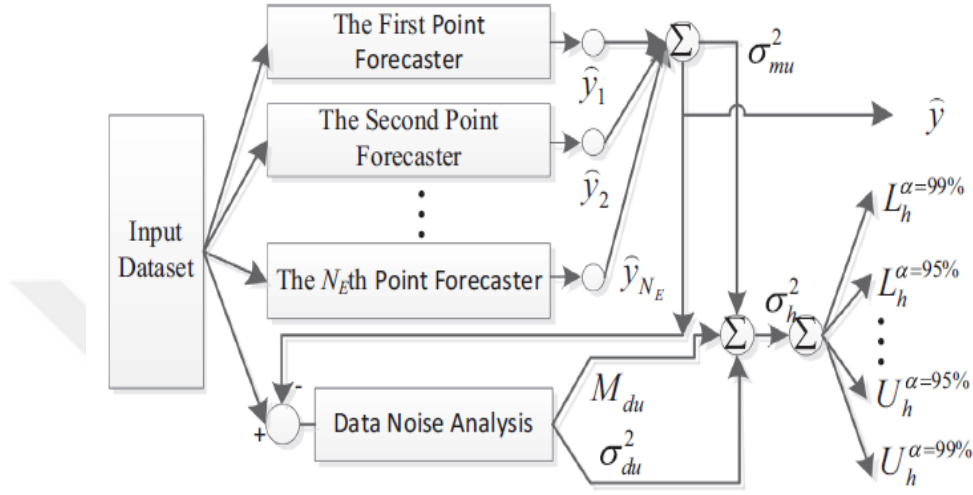
şekilde ayarlamak için kullanmışlardır. Çalışmada derin sinir ağları oluşturmak için, kuzey Çin'de bulunan dört rüzgar çiftliği verileri kullanılmıştır. Gizli katmanların alanlar arasında paylaşıldığı ve çıktı katmanlarının her bir alandaki farklı paylaşımlı gizli katmanlı bir DNN mimarisi, transfer öğrenimi için kullanılmıştır (Şekil 2.21). Model, çeşitli bölgelerdeki farklı rüzgar çiftliklerindeki verileri birleştirmektedir. Hava, arazi, topografya vb. nedenlerle farklı bölgelerdeki rüzgarın değişim özellikleri farklı olsa da, modelinin etkili olduğu kanıtlanmıştır. Yapılan çalışmada, önerilen tekniğin kullanılması sonucu tahmin hatalarının önemli ölçüde azaltıldığı gösterilmiştir.



Şekil 2.21. Derin öğrenme paylaşımlı gizli katman mimarisi (Hu ve ark., 2016).

Wang ve ark. (2017), yaptıkları çalışmada, derin öğrenme algoritması kullanarak mevcut rüzgar tarlalarından alınan verileri analiz etmiş ve rüzgar potansiyeli tahminlemesi üzerine geleneksel YSA algoritmalarına göre daha güçlü bir tahmin modeli oluşturmaya çalışmışlardır. Çalışmada rüzgar enerjisi verilerinde ortaya çıkan belirsizlikler derin öğrenme ile minimize edilmeye çalışılmış ve dalgacık dönüşümü ve konvolüsyonel sinir ağı temel alınarak ileri bir nokta tahmin yöntemi önerilmiştir (Şekil 2.22). Oluşturulan sistemde wavelet dönüşümü, ham rüzgar enerjisi verilerini farklı frekanslara ayırmak için kullanılmış, tahmin doğruluğunu artırmak için kullanılan her frekanstaki doğrusal olmayan özellikler daha sonra konvolüsyonel sinir ağı tarafından öğrenilmektedir. Böylece rüzgar enerjisi verilerindeki belirsizlikler daha net olarak tanımlanmış ve rüzgar enerjisi verilerinin olasılık dağılımı istatistiksel olarak

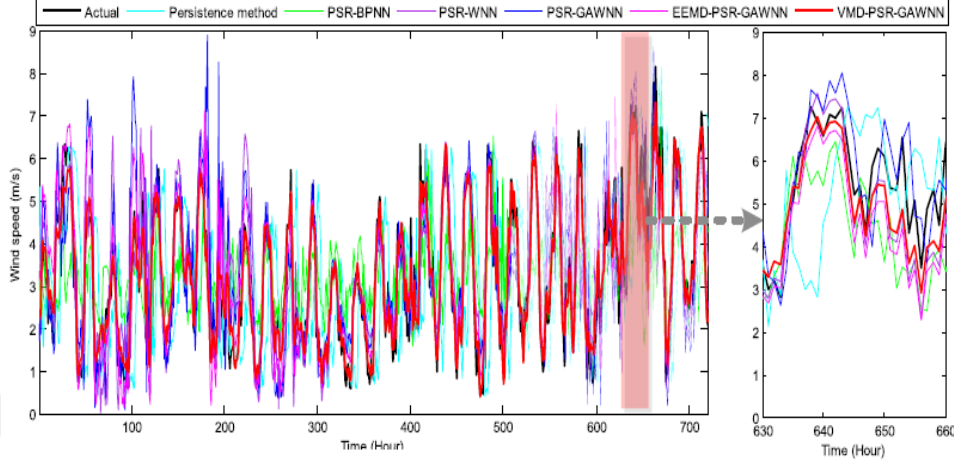
formüle edilmiştir. Önerilen yaklaşım, Çin'den alınan gerçek rüzgar enerjisi çiftliği verileri kullanılarak kapsamlı bir şekilde değerlendirilmiş ve sonuçlar, rüzgar enerjisi verilerindeki belirsizliklerin, önerilen yaklaşımı kullanarak daha iyi analiz edilebileceğini göstermiştir.



Şekil 2.22. Olasılıksal rüzgar enerjisi tahmini için önerilen yaklaşımın genel mimarisi. (Wang ve ark., 2017).

Wang ve ark. (2017), yaptıkları çalışmada, çok adımlı rüzgar hızı tahmininde yeni bir hibrid model önermektedirler. Bu tahmin modelinde, genel tahmini doğruluğunu iyileştirmek için orijinal rüzgar hızı serisini bir takım bağımsız bileşenlere ayırmak için uygulanmıştır. Daha sonra, üretilen her bir bileşen kullanılarak tahmin yapılmıştır. Rüzgar hızının nihai tahmini sonucu, her bileşenin tahmini sonucunu ekleyerek elde edilmiştir. Önerilen modelin etkililiğini kanıtlamak için iki grup gerçekleştirilmiş saatlik rüzgar hızı serisi kullanılmıştır. Deneysel sonuçlar önerilen modelin diğer tüm tahmin modellerinden daha iyi performans gösterdiğini göstermiştir (Şekil 2.23). Qureshi ve ark. (2017), yaptıkları çalışmada, derin sinir ağı temelli topluluk tekniğinin öğrenme kabiliyetini ve aktarım öğrenme kavramını kullanan yenilikçi bir kısa vadeli rüzgar enerjisi tahmini sistemi önermişlerdir. Önerilen DNN-MRT şemasında derin otomatik kodlayıcılar baz-regresörler olarak hareket ederken, Derin öğrenme ağı bir meta-regressör olarak kullanılmışlardır. Toplu öğrenme, test verisi

üzerine sağlam ve kolektif karar vermeyi kolaylaştırırken, derin taban ve meta regresörler önerilen DNN-MRT yaklaşımının performansını arttırdığını belirtmişlerdir.



Şekil 2.23. 6 adımlı rüzgar hızı tahmin sonucu (Wang ve ark., 2017).

Aktarım öğrenme konsepti, her bir rüzgar çiftliği veri setinde baz regresör eğitiminden önce zamandan kazandırmanın yanı sıra aynı zamanda her rüzgar çiftliği için eğitim ağırlıkları için başlatma noktaları öngörmeyi sağladığını belirtmişlerdir. Önerilen DNN-MRT tekniğinin etkinliği, diğer mevcut tekniklerle, kök ortalama karesel hata, ortalama mutlak hata ve standart sapma hatası açısından istatistiksel performans ölçümleri kullanarak karşılaştırmışlardır.

Hinton ve ark. (2006), yaptıkları çalışmada çok katmanlı yoğun derin inanç ağlarında sonuç eldesini zorlaştıran etkileri ortadan kaldırmak için ilave yapılması gereken işlemleri açıklamışlardır. Tamamlayıcı öncelikleri kullanarak her seferinde bir katman öğrenebilen hızlı ve açgözlü algoritmalar geliştirerek, ağırlıkları ince ayarlayan daha yavaş bir öğrenme süreci oluşturmaya çalışmışlardır. Bu ön gelişimden sonra genel bir model üzerinde yapılan hızlı eğitimlerle daha iyi sonuçlar üreten bir yapı oluşturulmuş olur. Çalışmada bu yöntemle yapılan tahminlemelerin en iyi sınıflandırma algoritmalarına göre daha başarılı sonuçlar elde ettiği belirtilmiştir. Çalışmada MNIST alfabesi üzerinde yapılan testlerde hata oranının %1.25 bulunduğu belirtilmiştir. Geliştirdikleri algoritmayı çalışmalarında paylaşarak derin öğrenmenin resim işleme


üzerindeki ağ yapısının anlaşılır olmasına katkı sağlamışlardır. İki katmandan oluşan ağın ilişkisel bellek oluşturmasıyla derin ve öğrenebilen yönlendirilmiş bir algoritma üretmişlerdir. İnsan retinası ile karşılaştırıldığında retinadaki ağ yapısını kullandığımız sistemlere göre çok fazla yoğun yapıda olduğu belirtilmiştir.

Bastien ve ark. (2012), yaptıkları çalışmada, Theano üzerinden oluşturulmuş olan Torch7 ve C ++ üzerinden oluşturulmuş olan tekrarlayan sinir ağları kütüphanelerinin performanslarını değerlendirmeye çalışmışlardır. 2010 yılında Bergstra ve diğerleri tarafından tanıtılan Theano'nun ana hedefleri ve özellikleri makalede kısaca açıklanmıştır. Ayrıca Theano uygulamalarını optimize etmek için bazı yeni önerilerde bulunmuşlardır. Theano'nun yoğun dizinleri tanımlamak için Cuda kod üreticileri içerdiğini belirtmişlerdir. Theano üzerinde yapılan iyileştireleri bu makalede açıklayarak ürünün diğer yazılımlara göre üstünlüklerini ortaya koymuşlardır.

Bengio ve ark. (2007), yaptıkları çalışmada, derin mimarilerin önemine değinmiş ve derin öğrenme algoritmalarını geliştirmek için bazı yöntemler önermişlerdir. Derin öğrenme yöntemlerinin diğer modellere göre olumlu yönde bazen üssel seviyelerde farklılıklar gösterdiği belirtilmiştir. Derin mimarilerin doğrusal olmayan ve yüksek derecelerde farklılıklar içeren sistemler için kompakt ve etkili çözümler geliştirebildiklerini belirtmişlerdir. Derin mimari yapılar ve kullanılan yöntemler çalışmada ayrıntılı şekilde açıklanmıştır. Denetimli öğretim tekniklerine eklenen DBN yönteminin performansı ile bu yöntemin performansı iyileştirmedeki etkisinin ne olduğunu tespit etmeye çalışmışlardır. Ön eğitimin denetimli ve denetimsiz yapılması ile ön eğitim yapılmadan oluşturulan performans değerlendirmesinde karşılaştırmalar yapılmış ve denetimli ön eğitime sahip modellerin daha iyi performans gösterdikleri belirtilmiştir. Bu çalışmalara ait sonuçlar çalışmada paylaşılmıştır. Çalışmada denetimsiz öğretimin derin ağları optimize etmeye yardımcı olduğu belirtilmiş ve yöntemin iyileştirilmesi için daha iyi sonuçlar üreten yöntemler sunulmuştur.

Cireşan ve ark. (2011), yaptıkları çalışmada, konvolüsyonel sinir ağları ile ilgili olarak hızlı ve ayarlanabilir parametrelere sahip paralel bir mimari sunmuşlardır. Derin öğrenmenin memeli görsel korteksine en yakın davranışı gösteren makine uygulaması olduğunu belirtmişlerdir. Derin mimaride bulunan konvolüzyon ve

filtreleme yöntemlerinin çalışma prensiplerine değinilerek ağ mimarisinin oluşturulma şekli açıklanmıştır (Şekil 2.24). Derin mimaride bulunan filtreleri görsel korteks yapısı ile karşılaştırarak filtreleme işleminin önemine değinmişlerdir. Derin öğrenmede ağ simülasyon hızının yavaşlığına dikkat çekerek önerdikleri tahmin modeli ile aylar sürececek çalışmaların günler içerisinde gerçekleştirilebileceğini belirtmişlerdir. Çalışmada MNİST ve NORB sistemleri üzerinde ağların değerdirmesi yapılmıştır. Çalışma anlatım diliyle derin mimari yapıyı en iyi açıklayan örneklerden biri olarak görülmektedir. Derin mimarinin her bir katmanı ve çalışma prensipleri ayrıntılı ve anlaşılır biçimde açıklanmıştır.



Şekil 2.24. Tam bağlı tabakalar, çekirdek boyutları 5 x 5 ve atlama faktörleri 1 olan konvolusyonel sinir ağı mimarisi (Cireşan ve ark., 2011).

Scherer ve ark. (2010), maksimum havuzlama yapmanın daha hızlı ve genel bir yaklaşım sağladığını belirtmişlerdir. Bölgenin üstün özelliklerinin bu işlemle ayırt edilebildiği ve bölge baskın özelliklerinin ayrıştırılabildiğini söylemişlerdir. Ayrıca cuda işlemcileri üzerinden işlem yeteneğini hızlandırmak için optimizasyon yöntemleri belirtmişlerdir. Bunların önceden hesaplanan ifadeler şablon çekirdeği içindeki açılmayan döngüler, çarpık matrisler ve kayıtlardan oluştuğunu belirtmişlerdir.

Glorot ve Bengio (2010), yaptıkları çalışmada, derin öğrenme ağ mimarilerini geliştirmek için yapılar üzerinde incelemelerde bulunmuşlardır. Ağ mimarilerinde ateşleme fonksiyonlarının doyuma ulaştıktan sonra yeni veriler ile birlikte belirlenen kriter seviyesinin daha alt noktalara çekilebildiğini belirtmişlerdir. Kullanılan

logsigmoid fonksiyonunun ortalama deęer etkisi nedeniyle özellikle üst katman giriş dokusunu bozduęunu belirtmişlerdir. Ayrıştırma, insansı aktiviteler ve amprik başarılar nedeniyle derin mimarinin önemine değinilmiştir. Mimari yapıdaki resmi işleme mantığı üzerine çeşitli yaklaşımlar sunmuşlardır. Resmin bölgelerinin dataset içerisinde işlenirken çeşitli açılardan düzenlemelerin karmaşıklığına değinilmiş ve resimdeki yapının deęişimlerinin etkilerini vurgulayarak deęişkenlik faktörlerinin bulunması gereğini belirtmişlerdir. Oluşturdukları ağda her biri 1000 nöron içeren 5 ara katman ve bir softmax lojistik regresyonu kullanmışlardır. Normalize edilmiş 5 hiperbolik teęet ağ ile %10 iyileştirme elde etmişlerdir.

Glorot ve ark. (2011), yaptıkları çalışmada, logsigmoid nöronlar ile hiperbolik teęet nöronlar arasında bir karşılaştırma yapmışlardır. Hiperbolik teęet nöronların çok katmanlı algılayıcılar için daha etkin sonuçlar ürettiklerini belirtmişlerdir. Makine öğrenimi alanında geliştirilen algoritmalar ile sinirbilimi alanında biyolojik nöronlar taklit edilerek oluşturulan algoritmalar arasında baę oluşturabilecek bir rektiyans modeli ile bir köprü kurulabileceęi gösterilmiştir. Çalışmada yapay nöronların kapalı ya da doğrusal bir rejimde çalıştıklarında, modelin daha iyi çıktılar verdięi belirtilmektedir. Eğitimsiz öğretim öncesi düzeltme işleminin (ön eğitim) modelin daha iyi performans göstermesine sebep olduęu belirtilmektedir.

Salakhutdinov ve Hinton (2009), yaptıkları çalışmada, boltzman makineleri için yeni bir öğrenme modeli önermişlerdir. Derin boltzman makinelerin MNIST ve NORB veri takımları üzerinde başarılı sonuçlar ürettiğini göstermişlerdir. Eğitimde kullanılan MNIST veri kümesi 28x28 piksellerden oluşan 60000 eğitim ve 10000 test verisinden oluşmaktadır. NORB's ise çeşitli canlı ve makinelere ait 10'ar model içeren üç boyutlu resimlerden oluşmaktadır. Çalışmada boltzman modellerinin Markov zincirlerine neden ihtiyaç duydukları açıklanmıştır. Boltzman makinesinin genel ağ yapısı ve çalışma prensiplerine derinlemesine değinilmiş ve kısıtlanmış boltzman makinesi ile arasındaki farklar açıklanmıştır. Genel ağ yapısında optimal öğrenmenin donanım ve model beklentisine göre üstel olarak gelişen uzun bir zaman istediğini belirtmişlerdir (Şekil 2.25).

**Boltzmann Machine Learning Procedure:**

**Given:** a training set of  $N$  data vectors  $\{\mathbf{v}\}_{n=1}^N$ .

1. Randomly initialize parameters  $\theta^0$  and  $M$  fantasy particles.  $\{\tilde{\mathbf{v}}^{0,1}, \tilde{\mathbf{h}}^{0,1}\}, \dots, \{\tilde{\mathbf{v}}^{0,M}, \tilde{\mathbf{h}}^{0,M}\}$
2. For  $t=0$  to  $T$  (# of iterations)
  - (a) For each training example  $\mathbf{v}^n$ ,  $n=1$  to  $N$ 
    - Randomly initialize  $\mu$  and run mean-field updates Eq. 8 until convergence.
    - Set  $\mu^n = \mu$ .
  - (b) For each fantasy particle  $m=1$  to  $M$ 
    - Obtain a new state  $(\tilde{\mathbf{v}}^{t+1,m}, \tilde{\mathbf{h}}^{t+1,m})$  by running a  $k$ -step Gibbs sampler using Eqs. 4, 5, initialized at the previous sample  $(\tilde{\mathbf{v}}^{t,m}, \tilde{\mathbf{h}}^{t,m})$ .
  - (c) Update
 
$$W^{t+1} = W^t + \alpha_t \left( \frac{1}{N} \sum_{n=1}^N \mathbf{v}^n (\mu^n)^\top - \frac{1}{M} \sum_{m=1}^M \tilde{\mathbf{v}}^{t+1,m} (\tilde{\mathbf{h}}^{t+1,m})^\top \right).$$
 Similarly update parameters  $L$  and  $J$ .
  - (d) Decrease  $\alpha_t$ .

Şekil 2.25. Boltzman makinesi eğitim prosedürü (Salakhutdinov ve Hinton, 2009).

Yaptıkları çalışmada ayrıca boltzman makinesinin eğitim modelini paylaşmışlardır. Çalışmada bir derin inanç ağının eğitimine başlamadan önce yineleyen bir modelinin ön eğitiminin faydalı olduğu belirtmişlerdir. AIS kullanılarak bölme fonksiyonları tahmin etmek için Boltzman makinelerinin nasıl kullanılabileceğini göstermişlerdir. Model 500 ve 1000 nörondan oluşan iki ve 500, 500 ve 1000 nörondan oluşan 3 gizli katmanla 2 ayrı şekilde test edilmiştir. Analiz test aşamasında, 68 milyon parametre ile ince ayar olmadan %10.8 yanlış sınıflandırma hata oranına ulaşmışlardır.

Pekmezci (2012), yaptığı yüksek lisans tezinde zaman serilerine sahip verilerin kısıtlanmış boltzmann makineleri ile tahminini gerçekleştirmiştir. Çalışmada yapılan testlerde YSA algoritmaları ile  $10^{-2}$  mertebesinde hata oranına yaklaşabilirken Boltzman Makinesi ile  $10^{-10}$  mertebesine kadar yaklaşma sağlayabildiklerini belirtmişlerdir. Ayrıca yapılan testlerde 50 deneyin 39'unda Boltzman Makinesinin daha yakın sonuçlar ürettiği ifade edilmiştir. 130 veri kümesinin 67'sinde Boltzman Makinesinin tam tahmin ürettiği buna karşılık YSA'nın hiçbir zaman tam tahmin elde edemediği belirtilmiştir. Çalışmada ayrıca uzun veri kümelerine sahip zaman serilerinin YSA'yı olumsuz etkilediği belirtilirken Boltzman Makinelerinde bu durumun tam tersi etki gösterdiği belirtilmektedir. Zaman verimliliği açısından Boltzman makinesinin YSA'nın 20 kadar




bir sürede işlem tamamlayabildiğine değinilmiştir. Daha az kararlı ama hızlı tahminler isteniyorsa YSA tahminlemesinin kullanılması gerektiğini belirtmişlerdir.

He ve ark. (2015), yaptıkları çalışmada, rektifiye edilmiş aktivasyon birimlerinin önemine değinmişlerdir. Parametrik Doğrusal Lineer Birim PReLU aktivasyon fonksiyonunun parametreleri uygulanabilir bir şekilde öğrenerek etkisiz hesaplamaları geliştirdiğini belirterek ağda kullanılmasını önermişlerdir. Ayrıca çalışmada derin mimarilerdeki eğitimlerin zorluklarını araştırarak PReLU'nun derin rektifiye edilmiş modellerin eğitimini daha geniş ağ mimarilerinin oluşturulmasına olanak sağladığı belirtilmiştir. Konvolüsyonel sinir ağlarının trafik işaretleri, yüzler ve el yazmalarını tanıma insanlardan daha iyi olduklarını ve 1000 veri setine sahip İmageNet verisi üzerinde yapılan hesaplamalarda PReLU ile oluşturulan ağ ile elde edilen  $4.91 \times 10^{-5}$  hatanın GoogleNet'in elde ettiği başarıya bakıldığında insansı performansı (%5.1) aşan ilk model olduğunu belirtmişlerdir. Çalışmada 14 ara katmanlı bir derin ağ mimarisi ile çalışma yürütülmüştür.

Hinton ve Salakhutdinov (2006), yaptıkları çalışmada, boyut azaltmanın önemine değinmiş ve boyut azaltmanın veri sınıflandırması, görselleştirilmesi, sınıflandırılması ve iletilmesinde etkin bir yöntem olduğunu belirtmişlerdir. Yüksek boyutlu veri kümelerinin merkezi katman ve çok katmanlı bir sinir ağı eğitimi ile küçük boyutlu verilere dönüştürülebileceğini belirtmişlerdir. PCA yönteminin önemini vurgulayarak çalışma prensibini açıklamışlardır. Büyük veri kümelerini düşük boyutlara dönüştürmek için doğrusal olmayan bir genelleme, Bauencoder kullanmışlardır. Çalışmada doğrusal olmayan çoklu oto kod düzenleyicilerinde ağırlıkları optimum duruma getirmenin zorluğuna değinilmiş ve sürecin eğitimi olanaksız hale getirdiğini belirtmişlerdir. Çalışmada oluşturdukları ağın 20000 eğitim ve 10000 test resmi ile eğitildiğini belirtmişlerdir. Bunun sonucunda oluşturdukları otomatik kodlayıcının tüm piksellere ait görüntüyü yeniden yapılandırmaya mükemmel derecede uygun 6 alt sayıya dönüştürdüğünü ve PCA sitemiyle daha kötü sonuçlar elde ettiklerini belirtmişlerdir. Sonuçlar ve analiz hızını önemli derecede etkileyen önemli bir faktörün eğitim öncesi eğitim ve ince ayar olduğuna değinmişlerdir.

Jia ve ark. (2014), yaptıkları çalışmada, Facebook tarafından derin öğrenmeye yönelik olarak geliştirilmiş olan ve bilim insanları için derin öğrenme algoritmaları ve

model koleksiyonları sunan Caffe uygulamasına değinmiş ve bazı önemli yönlerini açıklamışlardır. Çalışmada C++ ile yazılmış bir kaynak koda sahip olan Caffe mimarisinin, Nvidia şirketi tarafından geliştirilmiş olan paralel işlem yeteneğine sahip tek bir Titan40 ekran kartı ile günde 40 milyondan fazla resim işleme yeteneğine sahip olduğu belirtilmiştir. Hali hazırda geliştirilmiş birçok modelin yeni ortaya çıkmış ticari gelişmeler için yetersiz kaldığı ve Caffe'nin bu konudaki üstünlüğüne dikkat çekmişlerdir. Ayrıca modüler hazırlanmış ara yüzü ve güncel konulara uygun bir yapıda gelişimi ile araştırma alanındaki kullanımlar için çok uygun olduğu belirtilmiştir. Derin öğrenme alanında algoritma gelişimi ve düzenli bir ağ kurulumu açısından Caffe mimarisinin geniş uygulamalara sahip olduğu belirtilmiştir. Çalışmada ayrıca Caffe'nin ImageNet ve R-CNN modelleri için kaynak modeller sağladığı belirtilmiştir. Çalışmalarında Caffe mimari model katmanlarını bir tablo halinde göstererek ayrıca oluşturulacak mimarilerin tarif ve kodlarının da yayınlandığını belirtmişlerdir (Şekil 2.26).



Şekil 2.26. R-CNN algoritması akış şeması (Jia ve ark., 2014).


Krizhevsky ve ark. (2012), yaptıkları çalışmada 1000 farklı sınıftaki ImageNet modeline ait 1.2 milyon görüntüyü sınıflandırmak için derin konvolüsyon ağı kurduklarını belirtmişlerdir. 5 farklı katmanda toplam 65000 nörona sahip 60 milyon ağ bağlantılı model ile %37.5 ve %17 oranında başarı elde etmişlerdir. Kurdukları modelde birbirine bağlı katmanlarda bağımlılığı önlemek amacıyla dropout teknolojisini

kullandıklarını belirtmişlerdir. Konvolüze mimarilerin, boyutlandırılmış ileri beslemeli sinir ağlarından daha az bağlantıya ve daha az parametreye sahip oldukları için daha kolay eğitilebildiklerini, ancak genel performanslarının ileri beslemeli ağlara göre daha kötü olduğunu belirtmişlerdir. Çalışmada kullanılan ağı paralel işlem yeteneğine sahip 2 adet GTX 580 ekran kartı ile 6 gün sürdüğü belirtilmektedir. Ayrıca çalışmada daha iyi sonuçların ancak, 22000 kategori ve 15 milyon etiketlenmiş veri setine sahip ImageNet kütüphanelerinde bulandan daha büyük veri kümeleri ve paralel işlem teknolojisinin ilerlemesine bağlı olarak elde edilebileceği belirtilmektedir. Çalışmada convolüze modelin genel ağ modeli ve her bir katmanda gerçekleşen katman işlemleri (normalizasyon, overlapping pooling, relu, overfitting, dropout) adımlarına ayrıntılı olarak değinilmiş ve matematik modelleri açıklanmıştır. Ağ mimarisinde bulunan tek bir konvolüze katmanın modelden çıkarılmasının hata oranını %2 arttırdığını bu nedenle derinliğin önemli olduğunu belirtmişlerdir.

Saha ve ark. (2017), yaptıkları çalışmada, Hindistanın ekonomisinde büyük bir etkisi olan Muson bölgesinde yağış tahmini yapabilmek için derin sinir ağları yöntemi kullanmışlardır. Yaptıkları çalışmada Muson bölgesinin iklim koşullarının ve öngörüsünün zorluğundan ve tahmin başarısının ülke ekonomisine olan etkilerinden bahsedilmiştir. Çalışmada derin sinir ağlarının çalışılan çeşitli bölgelerde %4.1, %5.1, %5.5 ve %6.4 gibi hata oranları ile başarılı sonuçlar elde ettiği belirtilmiştir. Ayrıca iklim tahmini için derin sinir ağlarının genellenebileceği belirtilmiştir. Çalışmada doğrultulmuş doğrusal birimlerin eğitilmiş ağı doğrusal olmayan özelliklerini arttırabileceği belirtilmiş ve dropout yöntemi kullanılarak ağı aşırı benzeşmesi önlenir denmiştir.

Diaz-Vico ve ark. (2017), yaptıkları çalışmada, derin sinir ağları ile rüzgar ve güneş enerjisi tahmininin nasıl yapılacağını anlatmışlardır. Girişteki her bir değişkenin konvolüzyon işlemi için geçerli bir eleman olarak değerlendirilmesi gerektiğini söylemişlerdir. Ayrıca varyansın azaltılabilmesi için birden fazla derin mimarinin topluluk olarak bir arada uygulanması gerektiğine değinmişlerdir. Rastgele uygulanan minibatch eğitiminin tek bir DNN mimarisi ile doğruluk oranını yüksek oranda etkilediğini göstermişlerdir. Çalışmalarında ayrıca Derin ağların eğitimi ve daha kararlı çalışmasına dayalı olarak çeşitli yöntemler üzerinde çalıştıkları belirtilmiştir.

Srivastava ve ark. (2014), yaptıkları çalışmada, uyum aşırı uyum sorunu ele almışlardır. Çalışmada aşırı uyum sorununun derin sinir ağlarında ağı yavaşlattığı ve test aşamasında sorunlara yol açtığı belirtilmektedir. Çalışmada daha önce bu uyum sorunu çözmeye yönelik olarak birçok uygulama yapıldığını belirtmiş ve bu yöntemlerden bazı örnekler sunmuşlardır. Çalışmada birçok model ile yapılan kombine eğitimlerin tahmin sonucunu her zaman iyi yönde etkilediği ancak bu modelleri eğitmenin zor olduğuna değinilmiştir. Bu tür oluşturulacak büyük modeller ile yapılacak eğitimler için küçük veri setlerinin yetersiz kalacağını belirtmiş ve ağı hızlı cevap üretmesinin önemine değinmişlerdir. Yaptıkları çalışmada aşırı uyum sorununu çözmek için “dropout” yöntemini önermişlerdir (Şekil 2.27). Dropout’u, eğitim sırasında nöronların rasatgele, bağlantıları ile birlikte deaktif edilmesi olarak tanımlamışlardır. Çalışmada yöntem ağı aşırı uyumunu engellediği belirtilmektedir. Ayrıca yapılan çalışmada dropout yöntemi ayrıntılı bir şekilde açıklanarak, ağ mimarisine nasıl uygulanacağı gösterilmiştir.



Şekil 2.27. Standart ve dropout yöntemi temel işlemlerinin karşılaştırılması (Srivastava ve ark., 2014).

Dropout yönteminin gösterdiği etki çalışmada birçok veri seti üzerinde (nesne sınıflandırma, el yazması rakamları tanıma, ses tanıma, belge sınıflandırma ve hesaplamalı biyoloji verilerinin analizi) test edilmiş ve gösterdiği başarılar ayrıntılı olarak gösterilmiştir. Bunun sonucunda yöntemin genel olarak tüm alanlarda etkin olduğu belirtilmiştir. Çalışmada dropout yönteminin ağı sonuç alma süresini 2-3 kat arttırdığı belirtilmiştir. Bunun sebepleri açıklanarak, yöntemin aşırı uyum ve zaman

problemi açısından bir denge oluşturduğu belirtilmiştir. Çalışmada modellenen ağ yapısı ayrıntılı bir şekilde açıklanarak her birimin regülasyonu için yapılmış olan ayarlamalara değinilmiştir. Çalışmanın derin ağ mimarilerinin inceliklerini anlamak açısından önemli bir kaynak olduğu tespit edilmiştir.

Ko ve ark. (2009), yaptıkları çalışmada, WAsP programı yardımı ile Korenin Jeju adasında bulunan Hangwon rüzgar çiftliğinden alınan veriler kullanılarak bölgenin rüzgar potansiyelini belirlenmiş ve WAsP verilerinin doğruluğunu araştırmışlardır. Çalışmada rüzgar potansiyelinin doğrusal olmadığı ve bölgesel olarak yıllara göre farklılıklar gösterdiği belirtilmiştir. Küresel olarak 2006 yılındaki kurulu rüzgar gücü üretiminin 75.000 MW olduğunu belirtmişlerdir. WAsP programında arazi pürüzlülüğü ve engel durumunun yeterince yumuşak olması durumunda program analizinin gerçek verileri yüksek oranda sağladığı belirtilmiştir. Çalışmada WAsP programında yapılan analizleri geliştirmek ve doğruluk oranını yükseltmek amacıyla yeni bir yöntem önerilmiştir. WAsP programının esas olarak karasal alanlarda tahminleme yapmak üzere geliştirildiği ancak daha önce yapılan çalışmalarla deniz alanlarında da etkili olduğu belirtilmiştir. Çalışmada uygulanan yöntem ile elde edilen değerler ile gerçek değerler arasında %10'luk bir sapma olduğu yapılan testler sonucu tespit edilmiştir.

Indasi ve ark. (2016), yaptıkları çalışmada, 2009 yılı içerisinde karmaşık bir arazide 3 adet direğe bağlı anemometre kullanarak elde ettikleri verileri WAsP' da simüle ederek bölgenin rüzgar atlasını oluşturmuş ve sonuçları LIDAR verileri ile karşılaştırmışlardır. Kalkumpei, Nyiru ve Sirima'da sırasıyla rüzgar hızı yoğunluklarını 10.72 m/s, 10.72 m/s, 10.16 m/s ve 10.19 m/s olarak bulmuşlardır. Çalışmada farklı direk boyları ile yapılan ölçümlerde WAsP modelin etkilendiği belirtilmiştir. Çalışmada 11-24 Temmuz tarihleri arasındaki 2 hafta süresince LIDAR yardımı ile elde ettikleri veriler ile WAsP değerlerini karşılaştırmışlardır. LIDAR'dan elde edilen veriler WAsP rüzgar atlasına aktararak bir değerlendirme yapılmıştır. Çalışmada Nyiru bölgesinde yapılan değerlendirmede, Turkana Gölü rüzgar çiftliği için WAsP sonuçlarının LIDAR analiz sonuçlarına göre değerlendirmesi için ortalama hata 0.16 m/s, RMSE 0.85 m/s ve IOA 0.61 m/s olarak bulunmuştur.

Erhan ve ark. (2010), yaptıkları çalışmada, derin mimarilerde eğitim öncesi yapılan denetimsiz eğitim ile ilgili çalışmalar yürütmüşlerdir. Çalışmada denetimsiz ön

eğitimlerin çalışmadaki sonuçları önemli derecede etkilediklerini belirtmiş ve denetimsiz eğitimde izlenen yollar ayrıntılı olarak açıklayarak yapılması gereken düzenlemeler belirtmişlerdir. Derin mimarilerde literatürde belirtilen yöntemlerin birçoğunda tek bir katman düzeyinde bir eğitim sinyali sağlayan denetimsiz bir öğrenme algoritmasının kullanıldığını belirtmiş ve metodu kademeli olarak açıklamışlardır. İlk aşamada denetimsiz olarak ele alınan ağırlıkların sabit tutularak ikinci katmanda bu verilerin giriş verisi olarak değerlendirildiğini belirtmişlerdir. Çalışmada Hinton ve ark. (2006) tarafından geliştirilen Derin İnanç Ağları ve Vincent (2008) tarafından geliştirilen Stacked Denoising Auto-Encoder olmak üzere iki yöntem test edilmiştir. Çalışmada yöntemlerin denetimi için 3 yöntem kullanılmıştır. Bunlar Le Cun ve ark. tarafından 1988'de düzenlenen 60000 eğitim ve 10000 test içeriğine sahip 28x28 pikseli gri el yazmaları (MNIST), MNIST örneklerinin rastgele defarimosyonu ile elde edilen sonsuz sayıdaki Infinite MNIST ve 50000 eğitim, 10000 doğrulama ve 10000 test verisi içeriğine sahip geometrik şekil veri setleridir.

Sempreviva ve ark. (2008), yaptıkları çalışmada, Kuzey Avrupa açık denizlerindeki rüzgar potansiyelini araştırmışlardır. Çalışmada WAsP programı kullanılarak değerlendirmeler buna göre yapılmıştır. Rüzgarın güç ile ilişkisi ve atmosferik sınır tabakasındaki davranışları açıklanmıştır. Yatırım öncesi bölge potansiyelinin belirlenmesinin mali açıdan uygunluğun tespiti için önemini belirterek bu potansiyellerin belirlenmesinde ölçüm ve modelleme ile alanın potansiyeline göre alana yönelik yapılabilecek yaklaşımların kullanılabileceğini belirtmişlerdir. Potansiyelleri yüksek olarak tespit edilen alanlardaki çalışmaların daha ayrıntılı bir şekilde yapılması gerektiğini belirtmişlerdir. Literatürde, açık denizlerde bulunan ölçüm verilerinin düzenli olarak elde edilemediğinden dolayı rüzgar rejimlerinin son 10-20 yılda değişmediğinin kabul edilerek değerlendirmelerin yapıldığı, ancak bu durumun sorgulandığı belirtilmektedir.

Al-Yahyai ve ark. (2016), yaptıkları çalışmada, Umman'ın güneydoğu kıyısında bulunan ve bir sanayi şehri olan Al Duqm'un rüzgar potansiyelini belirlemeye çalışmışlardır. Çalışmada Al Duqm'da bulunan rüzgar ölçüm istasyonunun 2000 ile 2012 yılları arasında ölçülmüş verileri kullanılmıştır. Çalışmada alınan verileri değerlendirmek için WAsP programı kullanılmış ve 1 MW'lık rüzgar türbini için

simülasyonlar gerçekleştirilmiştir. Yapılan çalışmalar sonucu bölgedeki rüzgar enerjisi potansiyelinin yerden 80 metre yükseklikte 3 GWh olduğu tespit edilmiştir. Bölgede yerden 10 m yükseklikte 13 yıllık verilere göre ortalama rüzgar hızı 6 m/s olarak bulunmuştur. Çalışmada yerden farklı yükseklikler için rüzgar hızı profilleri belirlenmiştir. Sonuç olarak Al Duqm bölgesinde yüksek bir rüzgar potansiyelinin olduğu belirlenmiştir. Yapılan analizlerin bölge için daha önce yapılan çalışmalara uyumlu olduğu belirtilmiştir.

Gryning ve ark. (2014), yaptıkları çalışmada, Danimarkanın Høvsøre ve Almanyanın Hamburg bölgelerindeki rüzgar potansiyelini belirlemeye çalışmışlardır. Çalışmada kullanılan veriler Høvsøre için Nisan 2010 - Mart 2011 ve Hamburg için Haziran 2011 - Mart 2012 tarihleri arasındaki veriler toplanmıştır. Elde edilen ölçüm verileri Høvsøre bölgesi için 10, 60, 80, 100, 116.5 ve 160 metrelik meteorolojik ölçüm direkleri ile yerden 100 ila 600 metre yükseklikteki LIDAR ölçümlerinden elde edilmiştir. Hamburg bölgesi için ise 50, 110, 175 ve 250 metrelik meteorolojik ölçüm direklerinden elde edilmiştir. Çalışmada ayrıca Doppler LIDAR verilerinin nasıl üretildiği açıklanmıştır. Çalışmada rüzgar hızı profilleri, rüzgar yönü ile Weibull dağılımındaki ölçek parametrelerinin tahmin ve simülasyon aşamasında oldukça benzer olduğu belirtilmektedir. Çalışmada ayrıca Weibull dağılımındaki şekil parametresi ile ilgili olarak yeni bir öneride bulunulmuştur.

Çetin (2003), yüksek lisans tez çalışmasında, zaman serilerine bağlı analiz yöntemlerini açıklamış ve yapay sinir ağları alanında evrimci algoritmaları kullanarak rüzgar potansiyeli analizi gerçekleştirmiştir. Çalışmasında doğası gereği belirsizlikler içeren rüzgar hızı tahminin, tahmin edilmesi en zor değişkenlerden biri olduğunu belirtmiştir. Çalışmada ayrıca AR modeli ve bununla ilgili yöntem ayrıntılı olarak açıklanmıştır. Çalışmada ayrıca birçok yapay sinir ağı modelleri ve değişken parametreleri açıklanarak geri yayılım algoritması matematik modeli sunulmuştur. Çalışmanın uygulama aşamasında toplam 43824 saatlik ortalama rüzgar hızı veri seti kullanılmıştır. Bu veri setinin ilk 3000 tanesi eğitim aşamasında kullanılmıştır. Çalışma sonucunda elde edilen sonuçların Weibull dağılımına uygunluk gösterdiği tespit edilmiştir. Çalışmada 15 dakikanın üzerindeki periyotlarda elde edilmiş ortalama rüzgar hızı veri setleri ile rüzgar hızı tahminin yeterli olmadığı 15 dakikanın altındaki ortalama

veri setlerinde ise istenilen düzeyde yakınlık sağlanabilen tahminlerin yapılabildiği belirtilmiştir.

Talayoğlu (2010), yaptığı çalışmada, Denizlinin Tavas ilçesine ait rüzgar enerjisi potansiyeli 10m ve 30m yüksekliklerdeki 10 dakika aralıklarla ölçülmüş 2004 ve 2005 tarihleri arasındaki 1 yıllık rüzgar hızı ve yön verileri kullanılarak hesaplanmış ve ekonomik analizini yapmıştır. Çalışmada WAsP programı kullanılarak sonuçlar elde edilmiştir. Çalışmada kullanılan veri setlerinin saatlik, aylık ve mevsimlik analizleri yapılarak rüzgar dağılımları ve Helman katsayılarına göre frekans dağılımlarını içeren değerler elde edilmiştir. Çalışmada analiz yöntemlerine ayrıntılı bir şekilde yer verilerek istatistiksel hesap yöntemleri açıklanmıştır. Çalışmada pürüzlülük değerlerinin çeşitli yaklaşımlarla elde edilmesi anlatılmış ve WAsP’da kullanılan her bir parametre ayrıntılı olarak açıklanmıştır. Çalışmada ayrıca literatürdeki birçok modele yer verilmiş, uygulama yöntem ve davranış şekilleri açıklanmıştır. Çalışmada Tavas ilçesine ait hakim rüzgar yönü 30° olarak kuzey doğu, ortalama rüzgar hızı 2.95 m/sn ve ortalama güç yoğunluğu ise 45 W/m<sup>2</sup> olarak bulunmuştur. Çalışmada program verileri kullanılarak kurulacak rüzgar türbinlerine ait yerleşimlerin nasıl yapılacağı belirtilmiştir. Çalışmada 0.2-0,3 arasındaki Helmann katsayılarının gün içerisinde en yüksek frekansa sahip olduğu belirtilmiş ve Helmann katsayılarının sıcaklıkla ters orantılı olarak değiştiği belirtilmiştir.

Bilgili ve ark. (2009), yaptıkları çalışmada, Türkiyenin Ege Bölgesinde yer alan İzmir, Muğla, Aydın, Denizli, Uşak, Manisa, Kütahya ve Afyonkarahisar illerinde aylık ortalama toprak sıcaklıklarını topografik bilgilere dayanarak tahmin etmek amacıyla Yapay Sinir Ağları kullanmışlardır. Çalışmada Devlet Meteoroloji İşleri Genel Müdürlüğü tarafından 2000-2006 yılları arasında yerden 5, 10, 20, 50 ve 100 cm derinliklerde ölçülmüş veri setleri kullanılmıştır. Çalışmada ağın giriş katmanında Enlem, boylam, yükseklik, derinlik ve ay bilgileri eğitilen ağın giriş katmanında, aylık ortalama toprak sıcaklığı bilgisi ise çıkış katmanında kullanılmıştır. Çalışmada YSA ile yapılan tahminlemede model olarak Levenberg-Marquardt algoritması kullanılmıştır. Bu algoritmanın ara katman sayısı 1 ve bu ara katmanda 10 adet nöron kullanılarak en iyi sonuçların elde edildiği belirtilmiştir.




Yayla (2005), Van Yüzüncü Yıl Üniversitesi Kampüs Alanının Rüzgar Enerjisi Potansiyelinin belirlenmesi amacıyla çalışmalar yürütmüşlerdir. Yapılan çalışmada, Yüzüncü Yıl Üniversitesi Zeve kampüs alanına yerleştirilen gözlem istasyonu ile rüzgar yönü, atmosferik parametreler ve 10 m ile 30 m’de rüzgar hızları bir yıl süre ile ölçülmüştür (Şekil 2.28). Bu ölçümler sonucunda, rüzgar hızlarının Weibull dağılımına uygunluk gösterdiğini saptamışlardır. Bir yıllık rüzgar hızı ve yön verileri, WAsP programı yardımıyla analiz edilmiş ve bu analiz sonucunda rüzgar hızları 10 m ‘de 3.17 m/sn ve 30 m’de 3.87 m/sn olarak bulunmuştur. Bu noktalardaki güç yoğunlukları ise  $46 \text{ W/m}^2$  ve  $78 \text{ W/m}^2$  olarak hesaplanmıştır. Şekil 1’de bu çalışmada kullanılmış olan cihazlar görülmektedir. Şekil 2.29’da ise 10 m’de pürüzlülüğün 0.00 m olması durumunda WAsP ile elde edilen Weibull grafiği ve rüzgargülü grafikleri görülmektedir.



Şekil 2.28. Kullanılan rüzgar ölçüm cihazları (Yayla, 2005).

Güzel (2012), yaptığı yüksek lisans çalışmasında, Elektrik Üretim A.Ş.’nin hazırladığı Rüzgar Enerjisi Potansiyel Atlası göz önünde bulundurarak rüzgar potansiyeli yüksek olan Gökçeada ve Bozcaada’ya ait deniz sahaları üzerinde çalışmıştır. Meteoroloji İşleri Genel Müdürlüğü’nce 1999-2010 tarihleri arasındaki 1 saatlik aralıklı rüzgar hız ve yön bilgilerini içeren ölçüm verilerini kullanılarak Bozcaada ve Gökçeada bölgelerine ait rüzgar potansiyeli WAsP programı kullanılarak

tespit edilmiştir. Çalışmada potansiyeli hesaplanan bölgelere ait sayısal haritalar Global Mapper programı kullanılarak elde edilmiştir.




Şekil 2.29. 10 m'de pürüzlülüğün 0.00 m olması durumunda Weibull grafiği ve rüzgar gülü (Yayla, 2005).

Tüm veriler WASP'a aktarılarak rüzgar atlası ve RIX haritaları elde edilmiştir (Şekil 2.30). Çalışmada WASP programındaki veri giriş, analizleri ve çıktı oluşturma yöntemleri ayrıntılı olarak açıklanmıştır. Çalışılan bölgenin açık deniz rüzgar tarlası kurulumu açısından uygun olup olmadığı tespit edilmeye çalışılmıştır. Çalışmada ayrıca hesaplanan bölge potansiyeline yönelik bir maliyet analizi yapılmıştır. Yapılan çalışmalar sonucu Bozcaada bölgesinde hakim rüzgar yönünün kuzeydoğu doğrultusunda olduğu, ortalama rüzgar hızı ve güç yoğunluğunun ise sırasıyla 7.60 m/s ve 457 W/m<sup>2</sup> olduğu tespit edilmiştir. Gökçeada için ise, hakim rüzgar yönü Kuzeydoğu ve ortalama rüzgar hızı ve güç yoğunluğu da sırasıyla 5.57 m/s ve 186 W/m<sup>2</sup> olarak bulunmuştur.

Gülersoy ve Çetin (2010), yaptıkları çalışmada, İzmir'in bir ilçesi olan Menemendeki rüzgar enerjisi potansiyelini, Devlet Meteoroloji İşleri Müdürlüğü Menemen Meteoroloji istasyonu tarafından 2008–2009 tarihlerinde saatlik olarak ölçülmüş olan rüzgar hızı verilerini kullanarak analiz etmişlerdir. Çalışmada ayrıca aynı veriler üzerinden Menemen bölgesindeki rüzgar hızlarının Weibull ve Rayleigh fonksiyonlarına olan uyumu araştırılmıştır. Weibull modeli ile elde edilen değerlerin,

Rayleigh modeli ile elde edilen değerlere göre daha iyi sonuçlar verdiğini tespit etmişlerdir.




Şekil 2.30. 20 m ve altı için Gökçeada rüzgar tarlası yerleşimi (Güzel, 2012).

Çalışma sonucunda Menemen'in rüzgar enerjisi potansiyelinin elektrik enerjisi üretimi açısından uygun olduğunu tespit etmişlerdir. Yapılan çalışmada Menemen bölgesi için şekil parametresi  $k$ , 1.838 ve 1.869 ve ölçek parametresi ise  $c$ , 5.629 ve 5.898 olarak bulunmuştur.

Onat ve Ersöz (2011), yaptıkları çalışmada Türkiye'deki üç bölgenin rüzgar enerjisi potansiyelini analiz etmişlerdir. Bölgelerdeki rüzgar tahminleri için, MATLAB programı kullanılmıştır. ANFIS modeli kullanılarak rüzgar hızı ve diğer veriler arasındaki ilişkiler tespit edilmiştir. Rüzgar potansiyel analizleri WASP programı kullanılarak yapılmıştır (Şekil 2.31).

Güzel (2014), yaptığı çalışmada, WASP, WindPro ve WindFarmer, Homer, WindSim ve RETScreen programlarını kullanarak beş farklı rüzgar ölçüm verisi üzerinden programların bir ölçüm noktasından diğerine rüzgar hızını ne ölçüde doğru tahmin ettiğini ölçmüştür. Yapılan hesaplamalar ile ölçüm verilerini karşılaştırarak programlardaki sapmaları incelemiştir. Ölçümlerden elde edilen verileri on farklı türbin tipi için hesaplayarak yıllık enerji üretimi hesaplamaları yapmıştır. Programların farklı yükseklikteki sonuçlarını kıyaslayarak birbirlerine göre ne derece tutarlı tahmin yaptıklarını incelemiştir. 24 MW gücüne sahip bir rüzgar tarlasında bulunan

türbinlerin hem ölçüm direğinden hem de türbin göbek yüksekliğinden alınan veriler kullanılarak ölçüm alanının enerji potansiyeli hesaplanmış ve rüzgar tarlasından elde edilen gerçek üretim gücüyle karşılaştırılmıştır.



Şekil 2.31. Seçilen bölgeler için topografik haritaları ve rüzgar türbinleri konumu (Onat ve Ersöz, 2011).

Sonuç olarak yapılan analizlerin gerçek verilere yakın sonuçlar ürettiğini tespit edilmiştir. Çalışmada yerden 10 metre yükseklikte alınan ölçümlere göre yapılan analizlerde programlar arasında en fazla %20 oranında farklılık olduğu belirtilmiştir. 30 metreden alınan ölçümlerde ise bu oranın en fazla %10 olduğu belirtilmiştir. Ayrıca ölçüm yüksekliğinin artmasıyla birlikte programların sapma oranının düştüğü belirtilmiştir. 10 metrede yapılan ölçüm verileri kullanılarak elde edilen tüm programlara ait simülasyon sonuçlarında ortalama olarak %15 fark olduğu belirtilmiştir. 30 metrede ise WAsP, WindPro ve WindFarmer %10'un altında sapma gösterdiği belirtilirken, WindSim'in ise %40 hata oranı ile sapma gösterdiği belirtilmiştir. 50 metrede yapılan ölçümlerle yapılan simülasyonlarda WindFarmer'in en yakın sonuçları ürettiği, ancak göbek yüksekliği verileri kullanılarak yapılan hesaplamalarda ise en iyi sonuçları WAsP'in ürettiği belirtilmiştir (Şekil 2.32).

Mathew ve Mariappan (2014), yaptıkları çalışmada, Hindistanın Chennai bölgesinde WAsP, ArcGIS ve MCDA tekniklerini kullanarak rüzgar tarlası kurulumu açısından elverişli yerlerin oranını yaklaşık %15 olarak bulmuşlardır. CWET tarafından yapılan 50 m düzeyinde bir çalışmada bu oranın %1 olarak tespit edildiğini

belirtmişlerdir. Çalışmadaki toplam alan yaklaşık olarak 2209 km<sup>2</sup> 'yi kapsamaktadır. Analiz sonucunda, çalışılan bölgenin 1871 km<sup>2</sup> 'lik bölümünün rüzgar enerjisi projeleri için kullanılamayacağını tespit etmişlerdir. Çalışmada, 338 km<sup>2</sup> civarındaki alanın, orta, uygun ve son derece uygun bölgelerden oluştuğu tespit edilmiştir.

Türbin No.	WAsP			WindPRO			WindFarmer			WindSim			Gerçek üretim değeri
	10 m.	30 m.	50 m.	10 m.	30 m.	50 m.	10 m.	30 m.	50 m.	10 m.	30 m.	50 m.	
T1	2616	3880	3835	2911	3838	3651	2480	3742	3436	4332	4989	4379	3269
T2	3497	5028	4894	4084	5196	4833	3250	4735	4325	4937	5628	4901	5011
T3	2811	4106	4016	3161	4082	3821	2576	3853	3528	4256	4870	4233	3121
T4	2440	3634	3591	2699	3543	3360	2338	3533	3252	4287	4873	4250	2638
T5	3035	4445	4369	3575	4563	4266	2912	4291	3899	4771	5360	4632	4517
T6	3080	4444	4368	3655	4586	4287	2944	4314	3922	4958	5547	4807	4483
T7	2627	3855	3921	2991	3955	3739	2623	3908	3569	4918	5587	4863	2430
T8	2749	4107	4047	3124	4086	3830	2713	4026	3655	5008	5663	4920	3169
T9	2874	4250	4184	3179	4173	3937	2746	4070	3735	4710	5320	4606	4073
T10	2951	4305	4217	3337	4299	4027	2771	4127	3772	5038	5680	4922	4079
T11	2923	4317	4230	3434	4450	4148	2796	4166	3790	5094	5714	4941	4415
T12	3205	4628	4523	3832	4842	4508	3000	4433	4033	5289	5916	5133	5069
<b>Toplam</b>	<b>34808</b>	<b>51099</b>	<b>50195</b>	<b>39982</b>	<b>51611</b>	<b>48408</b>	<b>33149</b>	<b>49198</b>	<b>44916</b>	<b>57597</b>	<b>65148</b>	<b>56585</b>	<b>46254</b>


Şekil 2.32. Ölçüm verileri kullanılarak elde edilen üretim değerleri ve santralin gerçek üretimi [MWh] (Güzel, 2014).

Hocaoğlu ve ark. (2008), yaptıkları çalışmada, kurulması hedeflenen olası rüzgar sistemlerinin ve kurulacakları yerlerin en iyi bir biçimde seçilmelerine olanak sağlayan WAsP yazılımı tanıtmış ve örnek bir uygulama olarak Eskişehir bölgesinde bulunan Anadolu Üniversitesi İki Eylül Kampusunden 1 saat aralıkla ölçülüp kaydedilmiş olan rüzgar hızları ve yönleri verileri kullanılarak rüzgar türbini simülasyonu yapılmışlardır (Şekil 2.33). Simülasyon sonucu ele alınan rüzgar türbinine ait olası enerji üretimi 849.421 MWh olarak hesaplanmıştır.

Ersoz ve ark. (2013), yaptıkları çalışmada, WAsP programını kullanarak Türkiye'nin batı bölgesinde bulunan Kırklareli'nin rüzgar potansiyelini belirlemeye çalışmışlardır. Çalışmada uyarlamalı ağ tabanlı bulanık çıkarım sistemi olan ANFİS modeli kullanılmış ve WAsP ile kapasite kullanım oranlarını sayarak rüzgar enerjisi potansiyeli hesaplanmıştır (Şekil 2.34). Çalışmada kullanılan veriler Kırklareli Devlet Meteoroloji İşleri Genel Müdürlüğü tarafından 2007-2009 tarihleri arasındaki dönemde 1 saat aralıklarla yerden 10 metre yükseklikte ölçülmüş yön, hız, bağıl nem, sıcaklık ve



basınç bilgilerini içermektedir. Ayrıca bu verilerin doğruluğunun sınanması amacıyla ortalama nem, sıcaklık ve basınç verilerinin kullanıldığı belirtilmiştir.

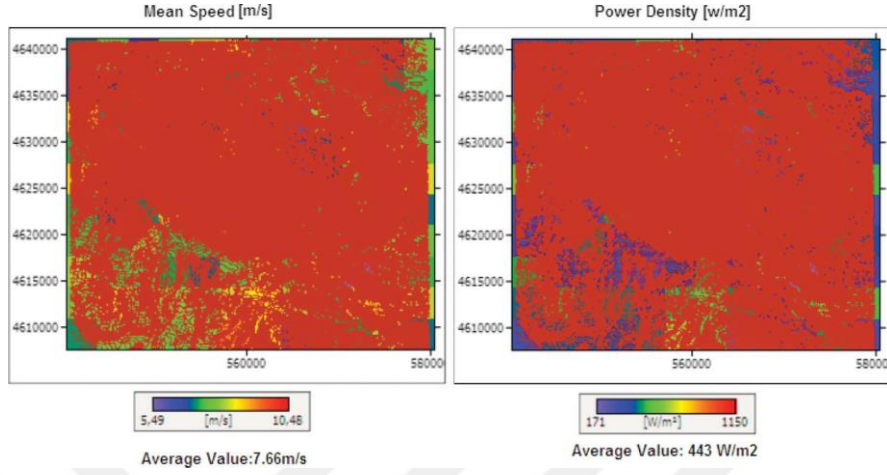


Şekil 2.33. Rüzgar hızlarının yönlere göre değişimi ve Weibull dağılımı ile modellenmesi (Hocaoğlu ve ark., 2008).

ANFIS modelinin giriş katmanında nem, sıcaklık ve basınç kullanılırken, çıkış katmanında ise hız verisi tahmin edilmeye çalışılmıştır. Çalışmada ANFIS modelinde kullanılan 36 aylık verinin 18 aylık bölümünün eğitim ve geri kalan 18 aylık kısmının ise test ve doğrulama aşamalarında kullanıldığı belirtilmiştir. Yapılan tahminleme sonucu R değerinin 0.90494 bulunduğu belirtilmiştir. Çalışmada bir alanda rüzgar santrali kurmaya karar vermeden önce alan için en az altı aylık değerlendirme ve fizibilite içinse bir yıllık değerlendirme yapılması gerektiği belirtilmektedir. Ayrıca bu kriterlerin Türkiye Enerji ve Tabii Kaynaklar Bakanlığı Rüzgar Santralleri Sözleşmesi'nde de yer aldığı belirtilmektedir. Çalışmada elde edilen veriler ışığında yöntemin oldukça başarılı olduğu ve Kırklareli'nin rüzgar enerjisi tesisi yatırımı için uygun olduğu belirtilmiştir. Yapılan çalışmada Kırklareli bölgesinde 50 m yükseklikte rüzgar hızı 7.66 m/sn ve 70 m yükseklikte ise 9 m/sn bulunmuştur. Bu yükseklikteki rüzgar güçleri ise sırasıyla 443 ve 744 W/m<sup>2</sup> olarak bulunmuştur.

Şahin ve Bilgili (2009), yaptıkları çalışmada, Türkiye'nin güneyindeki Belen-Hatay ilinde rüzgar karakteristiklerini, gelecekteki rüzgar enerjisi üretim projeleri için Wind Atlas Analiz ve Uygulama Programı (WAsP) kullanarak araştırılmışlardır. Kullanılan veriler 2004-2005 yılları arasındaki saatlik rüzgar hızı ve yönergelerinden


oluşmuştur. Bu veriler Elektrik İşleri Etüt İdaresi Genel Müdürlüğü (EİEİ) 'den temin edilmiştir.



Şekil 2.34. 50 m merkez yüksekliği için seçilen bölgenin rüzgar hızı ve güç yoğunluğu haritaları (Ersoz ve ark., 2013).

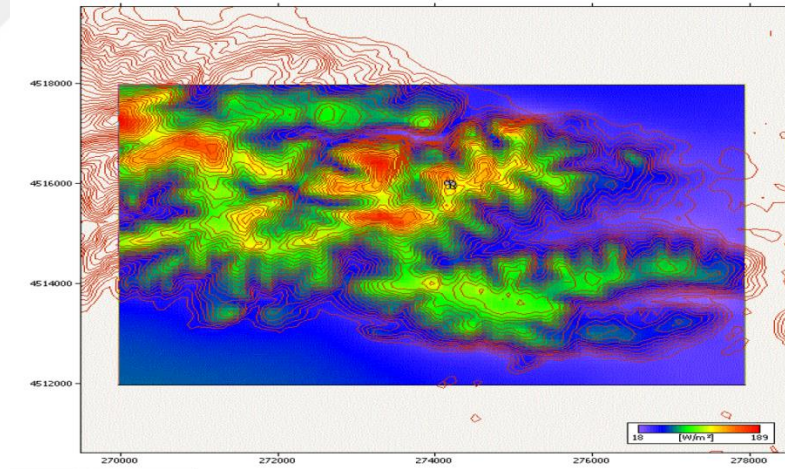
Hakim rüzgar yönü, olasılık dağılımları, weibull parametreleri, ortalama rüzgar hızı ve güç potansiyelleri, rüzgar yönü, yıl, mevsim, ay ve gün saatlerine göre ayrı ayrı belirlenerek, yerden 10 m yükseklikte, arazinin ortalama rüzgar hızı ve güç potansiyeli sırasıyla 7.0 m / s ve 378 W / m<sup>2</sup> olarak hesaplamışlardır (Şekil 2.35). Bu çalışma sonucu mevcut bölgelerin rüzgar enerjisi plantasyonu için uygun olduğunu ve bu bölgede bir rüzgar çiftliği kurmanın karlı olabileceğini tespit etmişlerdir.

Pusat (2017), yaptığı çalışmada, Sakarya Üniversitesi'nin rüzgar enerjisi potansiyelini belirlemeye çalışmıştır. Yapılan çalışmada, Esentepe rüzgar ölçüm istasyonundan alınan rüzgar verileri ile bölgenin topoğrafya, engel ve pürüzlülük bilgileri kullanılmıştır. Hesaplamalarda, WAsP programı kullanılmıştır. Çalışmada, Esentepe'de daha önce kurulmuş olan Rüzgar Gözlem İstasyonu verileri kullanılmış ve farklı yükseklikler için elde edilen sonuçlar değerlendirilmiştir. WAsP çıktıları incelendiğinde, rüzgar enerjisi potansiyelinin bazı bölgelerde iyi olduğu tespit edilmiş ancak elde edilen sonuçlara göre, bölgenin rüzgar enerjisi potansiyelinin genel olarak düşük olduğu belirlenmiştir (Şekil 2.36). Çalışmada kullanılan arazi modelleri Göttingen Üniversitesi'nin geliştirmiş olduğu ücretsiz bir program olan SAGA kullanılarak elde edilmiştir.



Şekil 2.35. 2004 ve 2005 yılları için rüzgar hızlarının mevsimsel kümülatif olasılık dağılımları (Şahin ve Bilgili, 2009).

Elde edilen sonuçlara göre incelenen bölgeye ait 10 metredeki ölçümler için ortalama rüzgar hızı değeri 2-3 m/s, hakim rüzgar yönünün 223 derece ve ortalama güç yoğunluğunun ise 30 W/m<sup>2</sup> olduğu civarlarında olduğu tespit edilmiştir.




Şekil 2.36. Rüzgar enerjisi potansiyel atlası (Pusat, 2017).

Şahin ve ark. (2005), yaptıkları çalışmada Doğu Akdeniz bölgesinde rüzgar enerjisi potansiyelini, Türk Meteoroloji İşleri tarafından 1992-2001 döneminde ölçülmüş yedi istasyondan alınan saatlik rüzgar verileri kullanılarak araştırmışlardır (Şekil 2.37). Yapılan çalışma, Türkiye'nin doğu Akdeniz kıyılarında rüzgar enerjisi




kaynakları ve elektrik üretimi için elverişli olduğunu göstermektedir. Ortalama güç yoğunluğu, bu bölgenin birçok yerinde, yer seviyesinden 25 m'de  $500 \text{ W/m}^2$  olarak belirlenmiştir. Rüzgar enerjisi üretimi açısından en uygun yerler İskenderun, Antakya ve Samandağı olarak tespit edilmiştir. Yapılan çalışma sonucu bu alanların rüzgar türbinleri kurulumu için çok uygun olduğu belirtilmiştir.



Şekil 2.37. Meteoroloji istasyonları için ortalama rüzgar hızlarının aylık varyasyonu. (Şahin ve ark., 2005).

Carvalho ve ark. (2013), yaptıkları çalışmada, Portekiz'de bulunan iki bölgede rüzgar kaynağı değerlendirmesini, orta ölçekleme modelleme sistemi Weather Research and Forecasting (WRF) ve rüzgar enerjisi endüstrisinde yaygın olarak kullanılan rüzgar kaynakları analiz aracı olan WAsP küçük ölçekleme modelini kullanarak gerçekleştirmişlerdir. Seçilen alanlarda akış özellikleri ile enerji verimliliği tahminleri açısından yerinde ölçümler ile simüle rüzgar arasında bir karşılaştırma yapılmıştır. Rüzgar enerjisi tahmini için bu metodolojilerin yararları ve sınırlamaları hakkında üç farklı metodoloji test edilmiştir. İlk metot da, rüzgar verisi her iki bölge için WRF tarafından hesaplandığı ve doğrudan WAsP'a girdi olarak girildiği sanal rüzgar ölçüm istasyonları gibi davranır. İkinci yaklaşımda, aynı prosedür takip edildi, ancak burada simüle rüzgar verilerinden orta ölçekli modelin düşük çözünürlüklü arazi verileri


tarafından indüklenen arazi etkileri kaldırıldı. Üçüncü metodolojide, simüle rüzgar verisi, jeostrofik rüzgarların (yerel araziden etkilenmeyen) herhangi bir araziye getiremediğini değerlendirmeyi amaçlayan gezegen sınır tabakası yüksekliğinin üstünde çıkartılmıştır. Yöntemler için elde edilen sonuçlar, her bir bölgede bir rüzgar türbininin kurulumu göz önüne alındığında, ortalama rüzgar hızı, Weibull olasılık yoğunluk fonksiyon parametreleri ve üretim tahminleri açısından ölçümlerden elde edilen sonuçlar ile karşılaştırılmıştır (Şekil 2.38). Sonuçlar, ikinci test edilen yaklaşımın, ölçülen değerlere en yakın değerleri üreten yaklaşım olduğunu göstermiş ve tahmin edilen yıllık üretim açısından bu birleştirme tekniğini kullanarak kabul edilebilir sapmalar olduğu tespit edilmiştir.



Şekil 2.38. Alandaki AEP rüzgar gülleri (a): Ölçülmüş, (b): Sanal rüzgar ölçüm istasyonu metodolojisi, (c): WRF arazi veri bağlama tekniği, (d): Jeostrofik rüzgar kuplaj tekniği (Carvalho ve ark., 2013).


Boudia ve ark. (2016), yaptıkları çalışmada, Cezayir'in kuzey kesiminde Tlemcen bölgesi için rüzgar enerjisi potansiyeli ve ekonomik analizini yapmışlardır. Çalışmada Tlemcen meteoroloji istasyonundan alınan on yıllık rüzgar verisi, WASP programı kullanılarak Kuzeybatı Cezayir bölgesi üzerindeki rüzgar enerjisinin potansiyelini değerlendirmek için kullanılmıştır. Çalışma, üretilen rüzgar enerjisini ve Tlemcen'in güney kesiminde kurulu 18.4 MW nominal kapasiteli bir rüzgar çiftliği tarafından üretilen elektriğin kWh başına maliyetini değerlendirmeyi önermektedir. Weibull fonksiyonuna dayanarak, meteoroloji istasyonunda yerden 10 m yükseklikte

istatistiksel analiz, Tlemcen'in düşük bir rüzgar potansiyeline sahip olduğunu göstermiştir. Yıllık ortalama rüzgar hızı 2.42 m / s ve yıllık ortalama güç yoğunluğu ise 49 W/m<sup>2</sup> olarak hesaplanmıştır. Aylık en rüzgarlı ay Nisan bulunurken, en iyi potansiyel bölgenin güneyi olarak tespit edilmiştir (Şekil 2.39).




Şekil 2.39. 10 m a.g.l yükseklikte seçilen alanda rüzgar hızı haritası ve rüzgar türbinlerinin düzeni (Boudia ve ark., 2016).

Bilgili ve ark. (2004), yaptıkları çalışmada Doğu Akdeniz bölgesindeki bazı yerlerde rüzgar potansiyeli ve fizibilite esasını belirlemeye çalışmışlardır. Bu amaçla, Antakya ve İskenderun bölgelerinin meteoroloji istasyonlarında 1997-2001 yılları arasında gözlenen saatlik rüzgar verilerini kullanarak egemen rüzgar yönü, ortalama değerler, rüzgar hızı, rüzgar potansiyeli ve frekans dağılımları belirlenmiştir. Sonuçlar zemin seviyesinin üzerinde yüksekliklere göre sınıflandırılmıştır. Son olarak, bu bölgelerin rüzgar atlası, sabit rüzgar hızı ve rüzgar potansiyeli kontur formunda üretilmiştir. Mevcut analiz sonuçlarına göre Antakya ve İskenderun bölgelerinde rüzgar enerjisi potansiyeli elektrik üretmek için yeterince yüksek bulunmuştur. Antakya bölgesinde güneybatı rüzgarları etkili iken (Şekil 2.40), İskenderun bölgesinde ise kuzeybatı rüzgarlarının etkin olduğunu (Şekil 2.41) belirlemişlerdir. Antakya bölgesinin birçok bölgesinde ve İskenderun bölgesinin bazı bölgelerinde, zemin seviyesinin 10 m yüksekliğinde 5 m/s'den daha büyük rüzgar hızları olduğunu tespit etmişlerdir.



Şekil 2.40. Antakya bölgesinde ortalama rüzgar enerjisi potansiyelinin bölgesel dağılımı (Bilgili ve ark., 2004).



Şekil 2.41. İskenderun bölgesinde ortalama rüzgar enerjisi potansiyelinin bölgesel dağılımı (Bilgili ve ark., 2004).

Hanslian ve Hosek (2015), yaptıkları çalışmada, Çek Cumhuriyeti rüzgar haritasının oluşturulmasında uygulanan bir yöntemi açıklamışlardır. Çalışma mevcut rüzgar ölçümlerinin kapsamlı bir şekilde kullanılmasıyla belirli bir bölgedeki rüzgar koşullarının nasıl hesaplanabileceğine ilişkin önemli bir örnek sağlamaktadır. Yöntem bir enterpolasyon metodu (VAS) ve mikro ölçek model WAsP kullanarak uygulanan Wind Atlas metodolojisini içerir (Şekil 2.42). WAsP, geliştirilmiş rüzgar koşullarını (GWC) sağlamak için ölçüm sitelerinin çevresindeki spesifik etkileri ortadan kaldırırken, VAS, GWC'yi tüm alan üzerinde enterpolasyona tabi tutar ve yükseklik ile rüzgar hızının genel artışını hesaba katar. Sonuç olarak, yüksekliğe bağlı geliştirilmiş bir rüzgar haritası sağlanmaktadır. Daha sonra, WAsP tarafından son

yüksek çözünürlük hesaplaması yapılmaktadır. Çalışmalarında karmaşık arazi veya büyük orografik özelliklere sahip arazilerdede daha fazla ölçüm gerektiğini belirtmişlerdir.

Mean wind speed				
ID	Observed <sup>a</sup> (m/s)	Model (m/s)	Difference (m/s)	Difference (%)
A	5.57	5.73	-0.16	-2.9%
B	5.82	6.03	-0.21	-3.6%
C	5.83	5.97	-0.14	-2.4%
D	5.24	5.72	-0.48	-9.2%
E	6.14	6.41	-0.27	-4.4%
F	5.77	6.41	-0.64	-11.1%
G	5.17	5.91	-0.74	-14.3%
H	5.95	6.17	-0.22	-3.7%
I	6.31	6.11	0.20	3.2%
J	6.21	6.16	0.05	0.8%
K	5.86	5.87	-0.01	-0.2%
L	5.71	5.53	0.18	3.2%
O	6.29	6.87	-0.58	-9.2%
P	6.05	6.85	-0.80	-13.2%
Q	7.4	7.57	-0.17	-2.3%
R	6.04	6.42	-0.38	-6.3%
Bias			-0.27	-4.7%
Root mean square error (RMSE)			0.40	7.1%
Mean average error (MAE)			0.33	5.6%
Standard deviation			0.30	5.2%


<sup>a</sup> Observed data were recalculated to the height of 100 m and period 1997–2006.

Şekil 2.42. VAS ve Wind Atlas tarafından hesaplanan rüzgar hızlarının karşılaştırması (Hanslian ve Hosek, 2015).

Himri ve ark. (2010), yaptıkları çalışmada, WAsP kullanılarak Cezayir'de Tindouf'da rüzgar hızlarının istatistiksel analizini yapmışlardır. Rüzgar verileri, 2002-2006 yılları arasında 5 yıllık süre boyunca SONELGAZ AR-GE Ofisi'nden elde edilmiştir. Ortalama güç yoğunluğunun 318 ila 458W / m<sup>2</sup> arasında değiştiği belirlenen çalışmada, baskın rüzgar yönleri ve frekans dağılımları da belirlenmiştir (Şekil 2.43). Sonuç olarak, çalışılan alanın ortalama rüzgar hızlarının, 7.19-7.95 m / s arasında değiştiği ve sahadaki k ve c yıllık değerlerinin sırasıyla 2.85 ve 3.23 ve 8.0-8.9 m / s arasında değiştiği tespit edilmiştir. Çalışılan bölgede batı rüzgarlarının daha baskın olduğu belirlenmiştir.

Durisic ve Mikulovic (2012), yaptıkları çalışmada, birkaç ölçüm yüksekliğinde alınan rüzgar hızı ölçüm verisinin dikey ekstrapolasyonu için matematiksel bir model sunmuşlardır. Model, en küçük kareler yöntemine dayanmaktadır. Önerilen modeli, en az üç ölçüm yüksekliğinde alınan ölçülen veriler kümeleri üzerine uygulayarak, rüzgar enerjisi potansiyelinin analiz edildiği arzulanan bir yükseklikte sentetik bir veri kümesi elde eder. Temel fikir, rüzgar enerjisi potansiyelinin tahmin edilmesi sürecinde, ilk önce

önerilen yöntemle ölçüm verilerinin çıkarılması ve daha sonra WASP programı kullanılarak uzamsal ekstrapolasyonun gerçekleştirilmesi.




Şekil 2.43. Tindouf istasyonunda yıllık ortalama akı yoğunluğu (Himri ve ark., 2010).

Algoritma, arazinin farklı topoğrafyaları ve farklı iklim koşulları ile karakterize edilen üç lokalize rüzgar hızı ölçüm verileri ile test edilir. Yapılan analizler, önerilen ölçüm yöntemiyle ölçüm verilerinin ön işleme tabi tutulmasının, ölçüm yüksekliklerinden daha büyük bir yükseklikte rüzgar enerjisi potansiyelinin daha iyi bir tahmini ile sonuçlandığını göstermiştir. Algoritma, farklı topoğrafyalar ve rakımlarla karakterize edilen üç lokasyonda alınan bir yıllık ölçüm verileri setleri uygulanarak test edilmiştir. Önerilen bir standart metodoloji ile karşılaştırıldığında temel avantajları, arazi pürüzlülüğünün öznel yeterliliğine bağımlı olmadığı ve rüzgar makaslama katsayısının günlük ve mevsimsel değişimlerini hesaba katmasıdır. Yapılan çalışma, önerilen metodolojinin orta ve kuvvetli rüzgarlar için iyi sonuçlar verdiğini ve zayıf ve türbülanslı rüzgarlar için dikkate değer ölçüde daha yüksek tahmin hatası ile sonuçlandığını göstermiştir.

Nouri ve ark. (2016), yaptıkları çalışmada, bir rüzgar çiftliği potansiyelini incelenmesi için Fas'taki iki ayrı bölgenin rüzgar kaynakları arasında bir karşılaştırmaya dayanan bir metodoloji hazırlamışlardır. Karşılaştırma 30, 50 ve 60 m yükseklikteki iki direktan toplanan gerçek rüzgar verileri ile gerçekleştirilmiştir. Uzun vadeli rüzgar davranışlarını tahmin etmek ve istatistiki bir çalışma için iyi bir potansiyel sunan en uygun bölge belirlenmeye çalışılmıştır (Şekil 2.44). Bunun için topografya, pürüzlülük


ve engeller dahil olmak üzere seçilen bölgenin coğrafi durumu incelenmiştir. Rüzgar potansiyeli bulunan alanlar belirlenerek, rüzgar çiftliği türbin lokasyonları, WAsP yazılımı kullanılarak optimize edilmiştir. Rüzgar çalışması, alanın ortalama 7.75 m / s rüzgar hızı ile iyi bir rüzgar tarlası koşullarına sahip olduğunu doğrulamıştır. Son olarak, yeni bir metodoloji uygulayarak 10MW rüzgar çiftliğinin ilk tasarım ve simülasyonu WAsP yazılımı kullanılarak gerçekleştirilmiş ve seçilen 6 türbinin yapılandırması ile yıllık 45.34 GW h'lik bir üretim ile 10 MW'lık bir rüzgar çiftliğinin kurulabileceği tespit edilmiştir.



Şekil 2.44. Çalışılan bölgenin rüzgar haritası (Nouri ve ark., 2016).


Kazet ve ark. (2016), yaptıkları çalışmada, Kamerun'un Ngaoundere yöresi ile ilgili bir rüzgar kaynağı haritası hazırlamışlardır (Şekil 2.45). Çalışma için iklim, topografya ve pürüzlülük hakkında çeşitli veri türleri kullanılmıştır. Rüzgar atlası özellikle yüksek rüzgar kaynağı alanlarda hesaplanmıştır. Çalışmada dört adet 1.65 MW türbinden oluşan bir varsayımsal rüzgar çiftliğinin yıllık enerji üretimi, Weibull temsil rüzgar verilerini kullanarak toplam 12 ay boyunca tahmin edilmiştir. Hesaplanan Yıllık Enerji Üretimi 5.985 MWh ve Uluslararası Enerji Ajansı istatistiklerine göre bu üretimin, CO<sub>2</sub> emisyonunun yıllık 1200 ton azaltılmasını sağlayabileceğini belirtmişlerdir. Hesaplama sonuçları ile WAsP sonuçları arasında iyi bir korelasyon olduğu tespit edilmiştir.





Şekil 2.45. Seçilen bölge ve Ngaoundere kasabasının doğusundaki varsayımsal rüzgar çiftliği (Kazet ve ark., 2016).

Sharma ve Ahmed (2016), yaptıkları çalışmada, Fiji Adaları'ndaki iki bölgenin (Suva ve Kadavu) rüzgar enerjisi değerlendirmesini yapmışlardır. Her iki bölge için geçerli rüzgar yönü Güneydoğu rüzgarlarına karşılık geldiği belirtilmiştir. Her iki bölgenin yüksek çözünürlüklü rüzgar kaynakları haritası (Şekil 2.46), 5 km'lik bir yarıçap için WAsP yazılımı kullanılarak simüle edilmiştir. WAsP analizi doğu bölgedeki Kadavu sırtının rüzgar tarlası kurulumu için iyi bir potansiyele sahip olduğunu göstermiştir. Suva Yarımadası bölgesinin, Laucala Körfezi bölgesi için iyi bir rüzgar enerjisi potansiyeline sahip olduğu tespit edilmiştir. Çalışmada Vestas V27 225 kW türbini kullanarak bir güç analizi gerçekleştirilmiştir. Veri analizi bölgedeki toplam rüzgar hızının yaklaşık 3.5-6.35 m/s olduğunu belirtmişlerdir.



Şekil 2.46. Kadavu adası WAsP yüksek çözünürlüklü rüzgar haritası (Sharma ve Ahmed, 2016).





### 3. MATERYAL ve YÖNTEM

Yapılan çalışmanın bir bölümünde, Meteoroloji Genel Müdürlüğünden alınan Hakkari, Yüksekova, Başkale, Van, Gevaş, Erciş, Özalp ve Muradiye istasyonlarına ait veriler ile Meteosat 7 uydusuna ait görüntüler kullanılarak Van İli Merkezi Ferit Melen Hava Limanı dışında bulunan ölçüm istasyonuna ait ölçülen hava hızları, Yapay Sinir Ağları ve Derin Öğrenme Yöntemleri ile tahmin edilmiştir. Çalışmanın diğer bölümünde ise MGM'den alınan ölçüm istasyonlarına ait rüzgar hızı ve rüzgar yönü verileri WAsP programına aktarılmış, WAsP arayüzünde NASA SRTM veri havuzundan elde edilen sayısal haritalar ve Google Earth'den elde edilen engel ve pürüzlülük bilgileri ile birlikte işlenerek her bir istasyonun bulunduğu bölgeye ait rüzgar potansiyelleri belirlenmiştir.

Bu işlemlerin yapılabilmesi için MGM ve Eumetsat'dan alınan bölge işlem verileri hazırlanmış, YSA, Derin Ağlar ve WAsP programında analiz edilerek bölge potansiyelleri belirlenmiştir.

#### 3.1. Bölge İşlem Verileri

Bu bölümde tahminleme ve potansiyel belirleme çalışmaları için Eumetsat ve MGM'den alınan verilerin düzenleme işlemleri açıklanmıştır. Ölçüm verileri 2013-2017 yılları arasında Meteoroloji Genel Müdürlüğü tarafından bölgeye ait sekiz istasyondan (Van Merkez, Erciş, Gevaş, Muradiye, Özalp, Başkale, Hakkari Merkez ve Yüksekova) saatlik ölçümlerle alınmış rüzgar hızı, rüzgar yönü, sıcaklık, basınç ve bağıl nem ve rakım değerlerinden oluşmaktadır. Ölçüm istasyonlarının coğrafik koordinatları ve deniz seviyesine göre yüksekliklerini içeren bilgiler aşağıdaki Çizelge 3.1.'de görülmektedir. Hakkari ili dağlık ve derin vadilerden oluşmakta iken Van bölgesi düz bir arazi yapısına sahiptir. Türkiye'nin en büyük gölü Van Gölü bu bölgemizde yer almaktadır. Çalışmada yer alan Başkale istasyonu iki bölge arasında ve genel ortalamaya göre daha yüksek bir rakımda bulunmaktadır. Bölgeler arasındaki bu denli değişkenlik doğa olaylarındaki hareketliliğin, istasyonlar arasında bir mantık kurularak

Çizelge 3.1 MGM ölçüm istasyonları

İstasyon No	İstasyon	X Koordinatı (E)	Y Koordinatı (N)	Denizden Yüksekliği (m)
1	Van	43.3460	38.4693	1675
2	Hakkari	43.7388	37.5745	1727
3	Erciş	43.3382	39.0197	1678
4	Muradiye	43.7630	38.9898	1706
5	Özalp	43.9767	38.6573	2000
6	Gevaş	43.1197	38.2963	1694
7	Başkale	44.0173	38.0435	2286
8	Yüksekova	44.2862	37.5785	1877

tahmin edilmesini daha güç hale getirmektedir. MGM'den alınmış olan veriler ölçüm sırasından oluşan arıza ve benzeri durumlar nedeniyle bazı ölçüm zamanlarında eksik kalmıştır. Bu eksiklikler bazı istatistiksel yöntemlerle giderilmeye çalışılmış ancak bu durum veri kümesinin kararlılığını bozmuştur. Bu bozulmanın veri setlerinin doğrusal olmayan bazı ilişkiler içermesinden kaynaklandığı tespit edilmiştir. Kayıp elemanları bulmak için denenmiş olan istatistiksel yöntemlere ait Matlab kodları aşağıdaki gibidir.

$F = \text{fillmissing}(A, \text{method})$

'previous' — previous non-missing value

'next' — next non-missing value

'nearest' — nearest non-missing value

'linear' — linear interpolation of neighboring, non-missing values (numeric, duration, and datetime data types only)


'spline' — piecewise cubic spline interpolation (numeric, duration, and datetime data types only)

'pchip' — shape-preserving piecewise cubic spline interpolation (numeric, duration, and datetime data types only)

Örnek olarak, veri seti içerisinde interpolasyon yöntemi ile belli aralıktaki veriler arasında bir vektör tanımlayarak bu noktada sinüs fonksiyonu üzerinden

değerlendirmelerle kayıp ara elemanlar bulunmaya çalışılmıştır. Bu uygulamaya ait örnek kodlama aşağıda gösterilmiştir.

```
x = [-4*pi:0.1:0, 0.1:0.2:4*pi];
A = sin(x);
A(A < 0.75 & A > 0.5) = NaN;
[F,TF] = fillmissing(A,'linear','SamplePoints',x);
plot(x,A,'.', x(TF),F(TF),'o')
xlabel('x');
ylabel('sin(x)')
legend('Original Data','Filled Missing Data')
```



Şekil 3.1. Kayıp sıra elemanlar için Matlab sinüs fonksiyonu.

Yukarıda listelenen tüm yöntemler, doğrusal bir ilişki içerisinde olmayan veri setleri içerisinde sapmalara sebebiyet verdiğinden dolayı, bu tür ilişkiler içeren durumlarda daha sağlıklı çözümlene yapabilecek bir yönteme ihtiyaç duyulmuştur. Bu nedenle kayıp elemanlar oluşturulan bir YSA algoritmasıyla elde edilmiş ve daha sağlıklı sonuçlar elde edilmiştir. Ancak hem kayıp eleman bulmada hem de tahminleme aşamasında sisteme girecek veri setlerinin aynı olması ara kayıp elemanların ortaya çıkarılması durumunu gereksiz hale getirmektedir.


Diğer yandan veri setinin çeşitliliği ve zenginliği kayıp elemanların varlığını önemsiz hale getirmektedir. Bu nedenle veri seti içerisinde kayıp elemanları barındıran

tüm veri setleri silinerek kalanlar ile işleme devam edilmiştir. Silme işlemi Matlab programı içerisinde satır “NaN” değeri barındıran satırların silinmesi ile gerçekleşmiştir. Silme işlemi MGM’den alınan veriler ile uydu verileri zaman serilerine bağlı olarak eşleştirildikten sonra, benzer zamanda gerçekleşen veri setlerinde hata oluşmaması için, birleştirme işleminden sonra yapılmıştır.

İstasyonlara ait ölçüm verileri Van Bölge Müdürlüğü’nden “.xlsx” ve “.html” dosya biçimlerinde 2 ayrı şekilde alınmıştır. Veriler Matlab ve WAsP’a aktarılırken sıralı bir düzende bulunmalı ve işleme girecek her bir veri seti boşluk kalmaksızın bir sonraki takip eden satırda veya sütunda bulunmalıdır. Ancak MGM’den alınan veriler böyle bir düzene sahip değildir. Veriler çeşitli yöntemlerle zaman serilerine bağlı olarak bir düzene alınmıştır. Veriler zaman serileri gözetilerek her bölge için istasyon koordinatları ve denizden olan yükseklikler de eklenerek bir kısmı Excel ortamında makro kullanılarak sıralanmış, bir kısmı ise Matlab içerisinde matris işlemleri ile düzenlenmiştir.


Veri düzenleme işleminin bir kısmının Matlab üzerinden oluşturulan kodlamalar ile gerçekleştirilmesi büyük bir zaman kazancı sağlamıştır. Bu sıralama tarihlere göre düzenlenmiş ve eksik verilere denk gelen tarihler boş bırakılmıştır. Tüm veriler gerçekleşme zamanlarına bağlı olarak sıralandıktan sonra 3 ayrı çalışmada kullanılmak üzere farklı biçimlerde değiştirilmişlerdir. WAsP programında kullanılmak üzere, zaman serilerine bağlı hız ve yön verileri, YSA tahminlemesinde kullanılmak üzere zaman serisine bağlı MGM ölçüm verileri ve Derin Öğrenme yönteminde uydu verileri ile birlikte kullanılmak üzere üç ayrı kategoriye ayrılmıştır.

Kullanılan uydu verileri Eumetsat sitesi Data Center bölümünden ücretsiz olarak indirilmiştir. Eumetsat bu verilere akademik çalışmalar için ücretsiz olarak erişim imkanı sağlamaktadır. Bu veriler Meteosat 7 uydusuna ait Doğu Avrupa HRI uydu görüntülerinden oluşmaktadır. Data Center’dan “.png” formatında elde edilmiş bu resimler, 46 ve 32 Enlem, 25 ve 50 boylam sınırları içerisinde kalan bölgeyi kapsayan 341x255 değerinde piksel içeriğine sahiptir. Bu resimlerden 01.01.2013 tarihli saat 00.00’da alınmış bir örneği Şekil 3.2.’de görülmektedir.



Şekil 3.2. 01.01.2013 tarihli doğu avrupa uydu görüntüsü (tam görüntü).

Görüntüde bulut hareketleri ve bölge sıcaklıklarına bağlı değişimler çıplak gözle izlenebilmektedir. Çalışılan sınırlar Türkiye'nin tamamı ve komşu ülkeleri büyük ölçüde içermektedir. Çalışılan bölgeye ait resim bölümü Şekil 3.3.'de görülmektedir.



Şekil 3.3. 01.01.2013 tarihli doğu avrupa uydu görüntüsü (sınırlandırılmış görüntü).

Çalışmadaki resimler Google Earth üzerine aktarılarak, istasyon coğrafik koordinatlarına bağlı olarak resim üzerinde karşılık gelen piksel noktaları belirlenmiştir. Buna göre çalışılan resimlerde, istasyon koordinatlarına bağlı olarak tespit edilen ölçüm noktaları Çizelge 3.2'de gösterilmiştir. Resimlerdeki çözünürlükler yeterince yüksek seviyelerde olmadığından istasyonların tam yerleşim noktaları yeterli hassasiyette oluşturulamamıştır. Bu durumun sonuçlar üzerindeki etkileri bilinmemektedir. Ancak yeterli hassasiyette ve daha ayrıntılı görüntülerle yapılacak testlerin daha iyi sonuçlar

verebileceği tahmin edilmektedir. Veri setindeki yoğunluğun YSA'da olumlu etki gösterdiği kabulü bu tahmini desteklemektedir.


Çizelge 3.2. Çalışılan bölgelere ait coğrafik koordinatlar ve resimler üzerindeki piksel karşılıkları

İstasyon	X Koordinatı (E)	Y Koordinatı (N)	Z <sub>x</sub> (X koordinatına karşılık gelen piksel değeri)	Z <sub>y</sub> (Y koordinatına karşılık gelen piksel değeri)
Van	43.3460	38.4693	235	101
Hakkari	43.7388	37.5745	241	118
Erciş	43.3382	39.0197	235	91
Muradiye	43.7630	38.9898	241	91
Özalp	43.9767	38.6573	245	97
Gevaş	43.1197	38.2963	232	104
Başkale	44.0173	38.0435	246	109
Yüksekova	44.2862	37.5785	250	118

Resim üzerindeki bu piksel noktaları merkez kabul edilerek bunların çevresindeki 12x12 piksel içeriğine sahip istasyon haritaları her bir merkez için elde edilmiştir. Bu haritalar zaman serisine bağlı olarak karşılık gelen istasyon ölçüm değerleri ile eşleştirilmiştir.

Çalışmadaki uydu görüntüleri 2013 ve 2017 yıllarında saatlik olarak alınmış 35881 görüntüden oluşmaktadır. Görüntüdeki her bir piksel konvolüzyon ve havuzlama işleminden sonra veri setinin içine eklenmiştir. Görüntülerin konvolüze edilmesindeki amaç, resimlerdeki veri yoğunluğunun azaltılarak, YSA 'ya girecek olan veri setlerindeki sütun sayısının düşürülmesi ve resmin 2 ayrı filtreden geçirilerek gerçekleşen olayın farklı 2 yönden incelenmesinin sağlanmasıdır. Eklenen her sütun YSA tahmin zamanını oldukça arttırmakta, belli bazı eşiklerden sonra ise kullanılan donanım veyahut yazılımların çalışmamasına neden olmaktadır. Resim pikselleri devasa bir matris olarak düşünülürse, örnek resim 255 satır ve 341 sütuna sahip bir matris haline dönüşmektedir. Bu resim MATLAB programı içerisine renkli olarak

çağrıldığında unit8 biçimiyle gelmektedir. MATLAB programı içerisinde bu resim aslında 255x341x3 veri ile tanımlanmış olur (Şekil 3.4).



Şekil 3.4. 01.01.2013 tarihli renki Doğu Avrupa görüntüsünün 3 boyutlu veri matrisi.

Böyle bir resim MATLAB içerisine çağrıldığında veri setinin sonsuz değer içermesinden dolayı içeriği bütün olarak görüntülenemez. Bu nedenle görüntünün öz değerleri kaybedilmeden sıkıştırılmalıdır. Çalışmada bu aşamada konvolüzyon kullanılmaktadır. Uint8 olarak gelen resim yalnızca 0-255 değerleri arasında değerlendirilebildiğinden dolayı sınır katmanlar zaman içerisinde işlem sonuçlarına bağlı olarak içe doğru benzeşmeye başlar, bu nedenle her bir verinin sınır problemi yaşamaması ve öz değerini kaybetmeden bir sonraki işleme alınabilmesi için resim öncelikle double'a çevrilir. Bu işlem MATLAB ara yüzünde;

$$A = im2double(A);$$


komutu ile gerçekleştirilir. Doğu Avrupa'da belirli bazı noktalardaki tahminlemeler yapıldığından dolayı resimlerin içerisindeki veriler bu bölgelere göre analiz edilmiştir.



Çalışılan istasyonlara ait koordinatlar resimlerdeki konumlarına göre tespit edilerek denk gelen resim pikselleri etrafındaki değişimler gözlemlenmiştir.

Yerel bölgeleri konvolüze edebilmek için öncelikle bunların işlem göreceği bir çarpım matrisi düzenlenmiştir. Yerel bölgedeki piksel sayısı ne denli çok olursa belirlenen koordinatta sonuçlar o denli olumlu yönde etkilenir. Yerel faktörün piksel sayısı testlere bağlı olarak belirlenmiştir. Artan piksel sayısı ile birlikte konvolüzyon katman sayısı artmaktadır. Artan konvolüzyon sayısı, analizlerin çok yüksek sürelerde gerçekleşmesine sebebiyet vermektedirler. Bu nedenle optimum değerler üzerinden çalışılmıştır. Doğal koşullar genel yapıda hiçbir zaman aynı olmayacağından dolayı yüzde yüz bir sonuç elde etmek imkansızdır. Bu sebeple değişkenlerin genel olarak analiz edileceği ve yaklaşık tahminlemelerin yapılacağı sistemlerin kurulması ve bunların daha hızlı ve daha çok veriyi analiz edebilecek şekilde çalışmalarının optimize edilmesinin daha faydalı olacağı yapılan araştırmalar sonucu anlaşılmıştır.

İstasyonların bulunduğu koordinatlardan türetilen resimler üzerindeki koordinatlara denk gelen piksel merkez kabul edilmiş ve etraflarındaki pikseller yerel verileri oluşturmuştur. İstasyonlara ait koordinatlara bağlı olarak elde edilmiş bir yerel bölge örneği Şekil 3.5’de görülmektedir.



Şekil 3.5. 01.01.2013 tarihli Doğu Avrupa uydu görüntüsü (Van merkez yerel bölgesi).

Bu bölgenin Matlab’da elde edilmesi için uygulanan kodlama aşağıda yer almaktadır. Bu bölümde kullanılan uydu resimleri “double” olarak Matlab’a

aktarılmakta ve aktarımın ardından zaman serilerine bağlı olarak sıralanmaktadır. Sıralamanın ardından parfor döngüsü içerisinde her bir resim belirtilen koordinatlara göre 2 konvolüsyon ve 2 polling katmanında sentezlenerek tek bir vektör satırında toplanır. Bu vektörler her bir döngünün sonunda “X” matrisinde biriktirilerek zaman serisine bağlı olarak düzenlenmiş veri seti oluşturulmuş olur.

```

datapath = 'D:\uydu\tum';
D = dir(datapath);
imgcount = 0;
for i=1 : size(D,1)
    if not(strcmp(D(i).name, '.')|strcmp(D(i).name, '..')|strcmp(D(i).name, 'Thumbs.db'))
        imgcount = imgcount + 1;
    end
end
j=veri1(1:end,1:end);
[m,~]=size(j);
X=[]; % u=m-2;
% LL=ones(u,n+24);
LL=[];
%%
f=(m/imgcount)-1;
%%
ep1=0;
while ep1<=f
    parfor k = 1:imgcount-2
        veri=veri1;
        S1=veri(k+ep1*imgcount,:);
        %% -----
        str1 = strcat(datapath, '\',int2str(k), '.png');
        BR1 = imread(str1);
        %% -----
        Zx=veri(ep1*imgcount+k,2); Zy=veri(ep1*imgcount+k,1);
        %% -----
        [L1] = bconvrun(BR1,Zx,Zy);
        str2 = strcat(datapath, '\',int2str(k+1), '.png');
        BR2 = imread(str2);
    end
end

```

```

[L2] = bconvrun(BR2,Zx,Zy);
str3 = strcat(datapath, '\',int2str(k+2),'.png');
BR3 = imread(str3);
[L3] = bconvrun(BR3,Zx,Zy);
LL(k,:)= [S1 L1 L2 L3];
end
X=[X;LL];
ep1=ep1+1;
end

```

Burada elde edilen  $Z_x$  ve  $Z_y$  döngü içerisinde o an incelenen resme ait x ve y koordinatlarındaki pikseli ifade etmektedir. Elde edilen koordinatlar ile birlikte aşağıdaki sınırlamalar geliştirilmiştir.

```

x1=Zx-5; x2=Zx+6; y1=Zy-5; y2=Zy+6;
A(:, :, 1) = C(x1:x2,y1:y2,1);
A(:, :, 2) = C(x1:x2,y1:y2,2);
A(:, :, 3) = C(x1:x2,y1:y2,3);

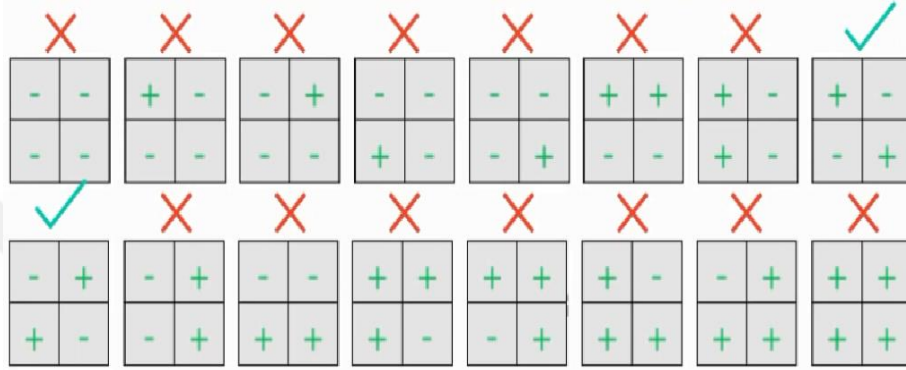
```

Bu sınırlar, merkez pikselin 5 piksel solu ve 6 piksel sağ ile 5 piksel aşağı ve 6 piksel yukarısında RGB katmanlarındaki tüm pikselleri ifade etmektedir. Yukarıda da görüldüğü üzere bu sınırlar geliştirildikten sonra belirlenen aralıktaki tüm veriler bir “A” matrisinde toplanmıştır.

“A” matrisini konvolüze etmek için ağırlıklar matrisi oluşturularak her bir pikselin etki değeri belirlenmiştir. Böylece piksel değerleri genel ve bölgesel olarak kontrol edilebilmektedir. Bu ağırlıklar matrisi oluşturduğumuz “A” matrisi ile aynı boyutta olmalıdır.

Konvolüzyon, derin öğrenmede var olan veri matrisinin filtreleme işlemidir. Verileri barındıran matris filtre boyutu kadar bölümlere ayrılarak verilerin birbirine bağımlılıklarına göre filtrelenmiş kümeler oluşturulur. Şekil 3.6’da bir rakamının negatif ve pozitif değerleri üzerinden 2x2 boyutunda oluşturulmuş çeşitli filtre örnekleri görülmektedir. Bu filtrelerin etkileri veri kümelerine göre değişiklik göstermekle beraber, kullanılan filtre miktarının sonuçlara pozitif yönde etkisi olduğu tespit


edilmiştir. Ancak filtre sayısındaki artış eğitime girecek veri sayısını arttırmakta ve işlem süresini uzatmaktadır. Yapılan çalışmalarda daha yüksek sayıda satır ve sütuna sahip filtreler ile işlem yapılmaya çalışılmış ancak kullanılan donanım yetersiz kaldığı için bu çalışmalardan vazgeçilmiştir. Filtreleme işlemi kullanılan imaj üzerindeki verilere yaklaşımın derinliğini arttırmakta ve tahmin değerleri ile gerçekleşen değerler arasındaki sapma oranını düşürmektedir.



Şekil 3.6. Konvolüsyon katmanı işlem modeli (Serrano, 2017).


“A” matrisi içerisinde bulunan 4 komşu piksel değerleri arasında +/-/+ ve -/+/- işlemleri iki farklı yoldan gerçekleştirilerek bunlar arasında ilişki kurulacak iki adet filtrelenmiş katman oluşturulmaktadır. Bu işlem gerçekleştirilirken konvolüzyon 3 boyutta gerçekleşir. Resimler RGB kodları ile işlenmiş olduğundan, bunların sahip olduğu her bir katman için konvolüzyon işlemi ayrı olarak yürütülür. Ancak RGB sistemi 0-255 arasında değerlerde çalıştığından dolayı sınır yaklaşımlarında veriler kaybolmaktadır. Beyaz ve siyah pikseller konvolüzyon işlemlerinde komşu piksel verilerini nötralize ettiğinden dolayı resimler konvolüze edilmeden önce double’a çevrilmiştir. Böylelikle verilerin 0-255 arasında sınırlanmaları engellenmiştir. Bu durum komşu pikseller arasındaki etkilerin son katmana kadar taşınmasını sağlamıştır.

Şekil 3.7’de, 01.01.2013 Tarihli Doğu Avrupa Uydu Görüntüsüne ait 3 katmanlı bir RGB resmi görülmektedir. Resime birinci konvolüzyon katmanında 2 ayrı filtreleme işlemi uygulanmış ve elde edilen filtrelere “Relu” uygulanmıştır.



Şekil 3.7. Derin mimari akış şeması.

Relu işlemi konvülüzasyon sonucu oluşturulan filtrelerdeki her bir verinin sıfırdan küçük olanlarını sıfır olarak düzenlerken sıfırdan büyük verileri ise kendi değerlerinde tutar. Relu işlemi  $f=\max(0,x)$  olarak ifade edilebilir. Relu işleminden sonra düzeltilen filtreler havuzlama katmanına aktarılmıştır. Polling katmanında her bir gruba ait, piksel etki değeri en yüksek eleman alınarak, matrise bir sentez yapılmıştır. Bu işlem sonucu, her bir piksel grubu kadar indirgeme sağlanmıştır. Bu indirgeme Şekil 3.8'de görülmektedir.



Şekil 3.8. Maksimum havuzlama.

Elde edilen 3 boyutlu havuzlama matrisi yeniden konvölüze edilerek belirtilen oranda yeniden küçülme sağlanmış olur. Bu işlem ardı sıra istenilen hassasiyet

seviyesince tekrarlanır. En son havuzlama katmanı yeterli elemana kadar indirgindikten sonra ayrı yürütülen her iki işleme ait tüm katmanlar tek bir vektörde birleştirilerek MLP giriş katmanına aktarılır. Konvolüze edilecek bölge için Şekil 3.6.'da belirtilen işlem modeline uygun olarak kullanılan MATLAB kodu aşağıda görülmektedir.

```

for er=1:fg
for k=1:x2-x1
for s=1:y2-y1
    O1c1(k,s,er) = A(k,s)*W(er,1) + A(k,s+1)*W(er,2) + A(k+1,s)*W(er,3) +
A(k+1,s+1)*W(er,4);
end
end
end
O1c1=max(0, O1c1);

```

Bu işlem sonucunda birinci konvolüzyon katmanı oluşturulmuş ve relu işlemi uygulanmış olur. Oluşturulmuş her bir dördümlü konvolüze grup içerisindeki en büyük eleman ile bu bölgenin havuzlama matrisi oluşturulmuştur. Bununla veri sayısı düşürülmüş olur. Bu işlem aşağıdaki kodlama ile gerçekleştirilmiştir.

```

O1p1=[];
for err=1:fg
for k=1:2:x2-x1-1
for s=1:2:y2-y1-1
    Z1=O1c1(k:k+1,s:s+1,err);
    Z1=Z1(:);
    O1p1(k,s,err) = max(Z1);
end
end
end
list_o_rows_to_use1 = 1:2:x2-x1-1;
list_o_cols_to_use1 = 1:2:y2-y1-1;
for el=1:fg
    O1P1(:, :, el) = O1p1(:, list_o_cols_to_use1, el);
    L(:, :, el) = O1P1(list_o_rows_to_use1, :, el);

```

*end*

Her bir katmana ait havuzlama matrisleri ayrı hesaplanmış ve tek bir vektörde toplanmıştır. Oluşturulan havuzlama matrisi, “A” matrisinin sadeleştirilmiş bir alt kümesidir. Konvolüzyon işlemi havuzlama katmanında, MLP’de işleme alınmak istenen eleman sayısı elde edilene kadar tekrarlanmıştır.

Konvolüzyonda +/-/+ ve -/+/- gibi iki ayrı işlem modeli üzerinden gidildiği için sonuçlar iki adet matristen oluşmaktadır. Bu matrisleri tek bir vektörde topladıktan sonra, benzer yöntemle veriler içerisindeki 1 ve 2 saat sonrasına ait gerçekleşmiş 2 veri aynı çerçevede analiz içerisine dahil edilmiştir. Böylece izleme sisteminin her anlık görüntüsü için bir zaman durumu tanımlanmış olur. Bunun yapılmasındaki amaç, sisteme bir önceki veya bir sonraki karelere bağlı olarak hava hareketlerini analiz edebilme yeteneği kazandırmaktır. 1 saat arayla alınmış 3 resmin ardı ardına MLP tarafından veri olarak değerlendirilmesi, o anki rüzgar hızı ve yönü hakkında belirgin bir karar oluşturabilmesini sağlamaktadır. Çeşitli zamanlarda alınan veri sayısının artması oranında daha net bir öngörünün gerçekleşebileceği açıktır, ancak artan veri sayısı analiz süresini arttırmakta ve daha güçlü sistemlerin kullanılması ihtiyacını doğurmaktadır.

İşleme giren 3 zamana ait veriler konvolüzyon işlemi gerçekleştikten sonra MGM’den alınan veriler ile birleştirilmektedir. Veriler 3 yıl aralığındaki her bir saat diliminde alınmıştır. Bu anlarda kaydedilmiş uydu verileri karşılık gelen ölçüm verileri ile birleştirilerek 29 sütunluk bir MLP veri seti oluşturulmuştur.

Çalışmada 3 farklı resmin aynı veri seti içerisinde işleme alınması gereği ile birlikte işlemlerin daha hızlı gerçekleşmesi için, MATLAB ara yüzünde paralel işlem özelliklerinden yararlanılmıştır. Paralel işlem, çalışmada Matlab arayüzünde “parfor” döngüsü üzerinden aşağıda görüldüğü gibi gerçekleştirilmiştir. Burda m-file’a gönderilen her bir resim, işlemci sayısı kadar ayrı işlem üzerinden değerlendirilmektedir. Bir işlemin sonucu diğer bir işlemin tamamlanmasına gerek duyulmadan başladığından süreler paralel işlem sayısı oranında kısalmaktadır.

*parfor k=1:F*

```

veri=veri1a;
S1=veri(k,:);
str1 = strcat(datapath,'\int2str(k)'.jpg');
BR1 = imread(str1);
str2 = strcat(datapath,'\int2str(k-1)'.jpg');
BR2 = imread(str2);
str3 = strcat(datapath,'\int2str(k-2)'.jpg');
BR3 = imread(str3);
%%%------
Zx=round((veri(k,1))*15.21); Zy=round((veri(k,2))*18.58);
%%%------
[L1] = bconvrun(BR1,Zx,Zy);
[L2] = bconvrun2(BR1);
[L3] = bconvrun2(BR2);
[L4] = bconvrun2(BR3);
LL=[L1 L2 L3 L4];
X1(k,:)=S1 LL;
end

```

İşlem içerisinde  $Z_x$  ve  $Z_y$  koordinatları ve bu noktanın etrafındaki piksellere ait değerler konvolüze edildikten sonra ([L1] [L2]), öncesinde gerçekleşmiş 2 zamana ait resimlere ait veriler aynı yöntemle çekilmiştir([L3] [L4]). Bu bölgelere ait veriler de çekildikten sonra tüm elde edilen uydu verileri ile MGM'den alınan veriler birleştirildikten sonra (X1) veri seti en son halini almaktadır.

Veri seti içerisinde, çeşitli nedenlerle (cihaz arızası, elektrik kesintisi v.b.) bazı zamanlara ait eksikler bulunmaktadır. Yapılan ölçümler bazen kesintiye uğradığından bu zamanlardaki veriler kaydedilememiştir. Bu veriler daha öncede detaylı olarak bahsedilen yöntemlerle tamamlanmaya çalışılmış, ancak sonuçların olumsuz veya önemsiz kalması nedeniyle kaldırılmıştır. Eksik veri setlerinin kaldırılması için kullanılan MATLAB kodları aşağıda sıralanmaktadır.

```

ep2=1;
while ep2<=m
    a1=X1(ep2,:);

```



```

b1=isnan(a1);
c=sum(b1);
if c>=1
    X(ep2,:)=[];
    m=m-1;
else
    ep2=ep2+1;
end
end
end

```


“isnan” komutu MATLAB’da bir matris içerisindeki olağan durumdaki tüm veri birimlerinin “0” olmasını, eksik olan veri birimlerinin ise “1” değerini almasını sağlar. Komutun veri setine uygulanmasından sonra, eksik olan birimlerdeki değerler “1” olarak değiştiğinden dolayı bu satırdaki toplamlar sıfırın üstünde gerçekleşmektedir. Bu gerçekleştiğinde  $c \geq 1$  şartı sağlandığından dolayı, bu satır veri setinin içerisinde silinmektedir.

Bu veri kümelerine ait düzenleme işlemi bittikten sonra, belirlenen yedi adet istasyona ait iklim verileri kullanılarak sekizinci istasyonda gerçekleşen hava hızları YSA ve Derin Öğrenme Yöntemi ile iki farklı şekilde tahmin edilmeye çalışılmıştır.

### 3.2. Yapay Sinir Ağları Ve Derin Öğrenme

MGM ve uydudan alınan verilere ait düzenleme işlemlerinden sonra Matlab’da Neural Network Toolbox kullanılarak çeşitli YSA modelleri oluşturulmuştur. Kullanılan YSA modelleri geri yayılım algoritmaları kullanarak çalışmaktadır. Yapılan çalışmada optimum değerler elde edilebilmesi için çeşitli katman ve nöron sayıları kullanılarak farklı modeller üzerinde testler yapılmıştır. Şekil 3.9’da çalışılan bu modellere ait bir örnek olarak 2 ara katman, 4 giriş hücresi ve 1 çıkış hücresine sahip bir YSA ağ mimarisi görülmektedir. Burda görülmekte olan a, b, c ve d elemanları, eğitime girecek olan veri setlerindeki değerleri temsil etmektedir. Çalışmada bu girdiler birinci yöntemde MGM’den alınan sıcaklık, basınç, mutlak nem, rakım ve rüzgar yönü ölçümlerinden oluşurken, derin öğrenme aşamasında ise resim piksellerinden elde

edilen veri değerlerinden oluşmaktadır. Her iki durumda da çıkış katmanında ( $O_1$ ) rüzgar hızı elde edilmeye çalışılmıştır.



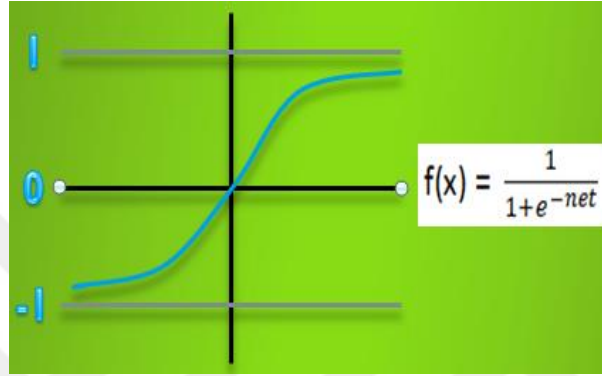
Şekil 3.9. YSA ağ mimarisi.

Elde edilen giriş verilerinin bağlı bulunduğu ağırlıklarla ( $w_n$ ) çarpımlarının toplamının logsigmoid fonksiyonu üzerinden transfer edilmesi ile ara katmandaki değerler bulunmaktadır. Ara katmanlardaki çıktıları elde etmek için kullanılan logsigmoid fonksiyonunun uygulama örneği Şekil 3.10’da görülmektedir. Aşağıdaki eşitlikte “net” değeri son katmanda tahmin sonucunu, ara katmanlarda ise her bir nöron üzerindeki değeri tespit etmek için kullanılmaktadır. net1 üzerinde bulunduğu katmandan bir önceki katmanda kendisine ağırlıklarla bağlı olan diğer nöronların bağlı ağırlıkla çarpımlarının toplamı ve sonucun kendine bağlı olan bias değeri ile toplanması ile bulunur. Daha sonra elde edilen bu toplam değer logsigmoid fonksiyonu ile düzeltilir. Bu durum son katman için purelin fonksiyonu üzerinden gerçekleşir. İşlem giriş katmanı hariç modeldeki her bir nöron için gerçekleştirilerek tahmin sonucuna ulaşılır.

$$net1 = w_1a + w_2b + w_3c + w_4d + b_1$$

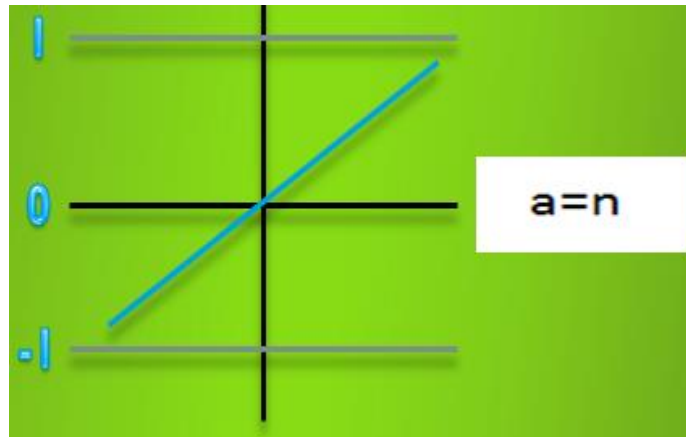
$$Ox = 1 / (1 + e^{-net1})$$

Çalışmada logsigmoid fonksiyonunun uygulanmasının sebebi, verilerin 0-1 aralığına çekilmesinin doğurduğu sonuçlardır. İşlem sırasında büyük verilerin kullanılması sistemin hatalı sonuçlar doğurmasına sebebiyet vermektedir. Ayrıca küçük sayısal değerlere sahip belirli sınırlı aralıklarda çalışmak işlem yeteneğini arttırmaktadır. Bu nedenle sistemin 0-1 aralığında çözülmesi daha kararlı sistemlerin oluşmasını sağlamaktadır.



Şekil 3.10. Logsigmoid fonksiyonu.

Elde edilen veriler, katman sayısı kadar tekrarlanarak sonuca gidilmiştir. Buna ileri yayılım denmektedir. İleri yayılımın son katmanında sonuçlar elde edilmiştir. Bu katmana çıktı katmanı denmektedir. Çıktı katmanı genellikle purelin düzeltme fonksiyonu ile aktive edilmektedir. Purelin fonksiyonu Şekil 3.11’de görülmektedir.



Şekil 3.11. Purelin fonksiyonu.

Çıktı katmanında elde edilen sonuçlarımızı gerçek ölçüm verileri ile karşılaştırarak sonuçlarımızın gerçek değerlere göre sapmaları hesaplanmaktadır. Bu fark aşağıdaki gibi hesaplanmıştır. Formüldeki 'd<sub>s</sub>' değeri işlemdeki gerçek ölçüm verisini, 'O<sub>s</sub>' ise karşılık gelen tahmin sonucunu temsil etmektedir.

$$\delta I = (d_s - O_s) * O_s * (1 - O_s)$$

Gerçekleşen değer ile ölçüm değerleri arasındaki fark bulunduktan sonra, sistemde geri yönde ilerleyerek sisteme etkileyen değişkenlerde güncellemeler yapılmaktadır. Bu güncellemelerin yapılması geri yayılım olarak adlandırılmaktadır. Geri yayılımda ağırlık ve bias'ların güncellenmesi aşağıdaki bağıntılar ile gerçekleştirilmiştir. Formülde 'δ<sub>n</sub>' son katmanda çıktı verisindeki sapmayı temsil ederken, ara katmanlarda her bir nörondaki değişimi temsil etmektedir.

Geri yayılımda bu değişimler gerçekleştiği nöron ve eğitim katsayısıyla çarpılarak bağlı olan ağırlıktaki değişim oranı bulunur. Çıktı ve ara katmandaki nöronlara etkileyen diğer bir oluşumda bias değerleridir. Bunlarda değişim miktarlarının eğitim katsayısıyla çarpılmasıyla güncellenmektedir. Elde edilen değişim miktarları ile eski ağırlıklar ve bias'lar toplanarak güncel ağırlık ve bias değerleri elde edilir.

$$\Delta w = \eta * \delta n * O$$

$$w^{new} = w^{old} + \Delta w$$

$$\Delta b = \eta * \delta n * I$$

$$b^{new} = b^{old} + \Delta b$$


Burda dikkat edilmesi gereken önemli bir nokta eğitim katsayılarının durumudur. Sistem eğitimini gerçekleştirirken oluşan farkın tümünü güncellemeye kullanırsa en son gerçekleştirilen veri seti ağırlık değerini büyük ölçüde etkileyecektir. Modelin genel yapısı en son giriş yapılan veri setine bağlı olarak güncellenecektir. Bu istenmeyen bir durum olarak kabul edilmektedir. Ağırlıkların veri setleri içerisindeki tüm bilgileri olabildiğince temsil etmesi daha düzgün bir ağ yapısı oluşmasını sağlayacaktır. Bu nedenle ağırlıkların güncellenirken önceki veri setlerindeki bilgileri

kaybetmeden yeni bilgilerle eğitilmesi daha doğru olacaktır. Bunu sağlamak için her bir veri setinin eğitime olan etkisinin düşürülmesi gerekmektedir. Bunu sağlayan değer eğitim katsayısıdır. Eğitim katsayısı yapılan çalışmada kullanılan veri miktarı çok olduğu için 0.1 olarak alınmıştır. Eğitim katsayısının bu şekilde düşük alınması döngü sayısının artmasına sebep olmaktadır. Sistem kararlı duruma daha uzun sürede gelmekte ancak verilerin tüm özelliklerini daha iyi taşımaktadır. Bu katsayının büyük seçilmesi durumunda sonuca hızlı ulaşılmakta, ancak model ağ yapısının tüm veri seti üzerindeki bilgiyi taşıması olanaksız hale gelmektedir. Bunun sınanması için test ve doğrulama verilerinin eğitim verilerinden farklı seçilmesi olumlu sonuçlar doğurmaktadır.

Geri yayılım ile işlenen veri seti için, sistem değişkenleri gerçekleşen çıktı değerini elde edilecek şekilde güncellendikten sonra bir sonraki veri seti için tekrarlanmaktadır. Bu durum tüm veri seti için tekrarlanarak, sapma değerlerinin önceden belirlenmiş sınır şartları sağlanana kadar devam eder. Bu duruma “epoch” denmektedir. Epoch sistemin bir döngü ifadesidir. Birinci döngü sonucunda model yeterli yaklaşımı sağlayamazsa bir sonraki döngüde eğitim katsayısının etki değeri oranında ağ yeniden güncellenmektedir. Bu durum giriş elemanları ile çıkış değerleri arasında optimum yaklaşım sağlanana kadar belirlenen kriterler çerçevesinde devam eder. İstenilen yaklaşımın belirlenen kriterler çerçevesinde elde edilememesi durumunda ise eğitime son verilerek modelde değişikliğe gidilmektedir.

Döngülerin sonuçları ağ durumu ile ilgili önemli bilgiler vermektedir. Ağın döngü kontrolünü sağlamak amacıyla her bir döngünün sonucunda tahmin edilmiş değerlerin ortalama karesel hataları bulunur. Ortalama karesel hatanın davranışına göre sistem döngülere devam edip etmeyeceğine karar vermektedir. Ortalama karesel hataya ait Şekil 3.12’de elde edilen grafik incelendiğinde, döngülerin belli bir noktadan sonraki ortalama karesel hata sonuçlarının stabil duruma gelmeye başladığı görülmektedir.

Bu noktadan sonra döngünün devam ettirilmesi, sistemin girişteki veriler üzerinde bir ezberlemeye gitmesine sebebiyet verebilmektedir. Ezberlemeyle oluşmuş olan ağ yapısı bu verilere özgü sonuçlar üretirken farklı verilerle yapılan tahminlemede büyük ölçüde saptalara sebebiyet verebilmektedir.



Şekil 3.12. Matlab ortalama karesel hata grafiği.

Ağın katı olmaktan çok esnek olması veri çeşitliliği karşısında daha sağlıklı sonuçlar üretilebilmesini sağlamaktadır. Ağın ezberlemeye başladığı anda istenilen koşullar henüz sağlanmamış ise işlem durdurularak yeni koşullar altında tekrarlanmaktadır. Bu ve benzeri sorunların oluşması sonucunda yapılan çalışmada genel olarak birçok alanda değişikliğe gidilmiştir. Ara katman ve nöronların artırılması genel olarak sistemin daha sağlıklı cevaplar bulmasını sağlasa da her zaman olumlu yönde etkimeyebilmektedir. Bu yüzden kullanılan veri sayıları ve bunlar arasındaki ilişkilere göre en uygun değerler değişiklik gösterebilmektedir.

Çalışmada ağ yapısı Neural Network Toolbox üzerinden gerçekleştirildiği için eğitim aşamasında sına "mse" değerleri ve 6 tekrarlama kriterleri üzerinden gerçekleştirilmiştir. Ancak simülasyon değerlerinde sına yeni geliştirilen bir sına sistemi üzerinden gerçekleşmiştir. MSE, MAPE, SSE ve Matlab performans değerlendirme kütüphanesinde bulunan diğer fonksiyonlar kullanılarak tahmin sonuçları ve gerçekleşen değerler arasında bir sapma miktarı belirlemeye çalışsa da sonuçların içerisindeki bir tek elemanın diğerlerine oranla yüksek bir hata payına sahip olması bazı durumlarda genel sapmayı büyük ölçüde etkilediği tespit edilmiştir. Bu nedenle her bir elemanın içerisinde bulunduğu aralıkta, topluluk içerisindeki rastlanma sıklığına göre oluşturulan yeni bir sına sistemi oluşturulmuştur. Bu önerilen yöntemle göre her bir tahmin sonucunun gerçek veriler ile arasındaki farkları bulunmuştur. Bu fark

gerçekleşen veriye bölünerek yüzde hata oranı her bir eleman için bulunmuştur. Ardından belirlenen her bir hata kategorize edilerek sınıflandırılmıştır. Bu sınıflandırma örneği aşağıdaki Çizelge 3.3’de görülmektedir.

Çizelge 3.3. Önerilen yönteme ait performans aralık sınırları

1. Aralık	2. Aralık	3. Aralık	4. Aralık	5. Aralık	6. Aralık
0 - 0.05	0.5 - 0.1	0.1 - 0.15	0.15 - 0.2	0.2 - 0.25	0.25 - 0.3
7. Aralık	8. Aralık	9. Aralık	10. Aralık	11. Aralık	12. Aralık
0.3 - 0.35	0.35 - 0.4	0.4 - 0.45	0.45 - 0.5	0.5 - 55	0.55 - 60
13. Aralık	14. Aralık	15. Aralık	16. Aralık	17. Aralık	18. Aralık
0.6 - 0.65	0.65 - 0.7	0.7 - 0.75	0.75 - 0.8	0.8 - 0.95	0.95 - 1
19. Aralık	20. Aralık	21. Aralık	22. Aralık	23. Aralık	24. Aralık
1 - 2	2 - 3	3 - 4	4 - 5	5 - 6	6 - 7
25. Aralık	26. Aralık	27. Aralık	28. Aralık	29. Aralık	30. Aralık
7 - 8	8 - 9	9 - 10	10 - 20	20 - 30	30 - 40
31. Aralık	32. Aralık	33. Aralık	34. Aralık	35. Aralık	36. Aralık
40 - 50	50 - 60	60 - 70	70 - 80	80 - 90	90 - 100
37. Aralık	38. Aralık	39. Aralık	40. Aralık	41. Aralık	42. Aralık
100 - 200	200 - 300	300 - 400	400 - 500	500 - 600	600 - 700
43. Aralık	44. Aralık	45. Aralık	46. Aralık	47. Aralık	48. Aralık
700 - 800	800 - 900	900 - 1000	1000 - 2000	2000 - 3000	3000 - 4000
49. Aralık	50. Aralık	51. Aralık	52. Aralık	53. Aralık	54. Aralık
4000 - 5000	5000 - 6000	6000 - 7000	7000 - 8000	8000 - 9000	9000 - 10000
55. Aralık	56. Aralık	57. Aralık	58. Aralık	59. Aralık	60. Aralık
10000 - 20000	20000 - 30000	30000 - 40000	40000 - 50000	50000 - 60000	60000 - inf

Tahminlemede veri setlerinde gerçekleşen %0 ila %5 aralığındaki her bir sapma değeri 0-5 aralığına ve diğerleri de aynı şekilde kendi kategorilerine eklenerek bu aralıklardaki bulunma sıklıkları tespit edilmiştir. Ardından her bir aralığın toplam bulunma değeri, karşılaştırılan verilerin toplam satır sayısına bölünmüştür. Böylece her bir kategorinin toplam içerisindeki etki oranı hesaplanmıştır. Ardından her kategorinin hesaplanan oranı 0-1 aralığında normalize edilerek maksimum ve minimum değerlere göre etki dereceleri hesaplanmıştır. Oluşturulan kategori matrisine benzer satır ve sütun sayısına sahip, bulunma noktalarına göre karşılık gelen sapma oranını içeren yeni bir

matris oluşturulmuş ve bu matristeki her bir elemanın kendi kategorisindeki etki derecesiyle çarpılması sağlanmıştır. Bunun sonucunda oluşan matrisin elemanlarının toplamı, karşılaştırılan verilerin toplam satır sayısına bölünmüştür. Bu işlem sonucunda her bir kategorinin rastlanma sıklığına bağlı olarak genelin yüzde sapması diğer yöntemlere oranla daha sağlıklı bir biçimde hesaplanmıştır. Bu sınaama yöntemine ait Matlab kodları aşağıdaki gibi olmuştur.

```

function [ sapma ] = diverror(a)
ye=a(1:end,1);yv=a(1:end,2);
[m0,~]=size(yv);
for n=1:m0
    if yv(n,1)==0
        yv(n,1)=yv(n,1)+0.1; %0 dan farklı olsun diye // 0.1'i sıfır kabul ediyoruz
    end
end
err=abs(ye-yv);
diverr=(err./yv);
[m,~]=size(diverr);
yuzde=[0 0.05;0.05 0.1;0.1 0.15;0.15 0.2;0.2 0.25;0.25 0.3;0.3 0.35;0.35 0.4;...
    0.4 0.45;0.45 0.5;0.5 0.55;0.55 0.6;0.6 0.65;0.65 0.7;0.7 0.75;0.75 0.8;...
    0.8 0.85;0.85 0.9;0.9 0.95;0.95 1;1 2;2 3;3 4;4 5;5 6;6 7;7 8;8 9;9 10;10 20;...
    20 30;30 40;40 50;50 60;60 70;70 80;80 90;90 100;100 200;200 300;300 400;400 500;500
600;...
    600 700;700 800;800 900;900 1000;1000 2000;2000 3000;3000 4000;4000 5000;...
    5000 6000;6000 7000;7000 8000;8000 9000;9000 10000;10000 20000;20000 30000;30000
40000;40000 50000;50000 60000;60000 inf];
[y0,~]=size(yuzde);
H=[];
for y=1:y0
    g=yuzde(y,2);
    g2=yuzde(y,1);
    for i=1:m
        if diverr(i,1)<g && diverr(i,1)>=g2
            H(i,y)=1;
        else
            H(i,y)=0;
        end
    end
end

```



```

    end
end
end
[~,y2]=size(H);
for u=1:y2
    HH(1,u)=sum(H(:,u));
end
HH=HH./m;
pmax=max(HH); pmin=min(HH);
HHH=(HH-pmin)/(pmax-pmin);
for yx=1:y0
    for i=1:m
        if H(i,yx)==1
            Y(i,yx)=diverr(i,1);
        else
            Y(i,yx)=0;
        end
    end
end
YY=[];
for yx2=1:y0
    for yx3=1:m
        YY(yx3,yx2)=Y(yx3,yx2)*HHH(1,yx2);
    end
end
Yvektor=sum(YY);
sapma=sum(Yvektor)/m;
end

```

Girişteki  $a$ , 2 sütunlu ve tahmin edilmeye çalışılan eleman sayısı kadar satır sayısına sahip bir matristir. Bu durum farklı çıktı sayısına göre tekrar düzenlenebilir. Böylece döngüler yardımıyla birden fazla çıktı katmanına sahip ağlar için yeniden düzenlenebilir. Çalışılan tahmin modeli tek çıktı katmanına sahip olduğu için yöntem tek çıktıyı çözecek şekilde düzenlenmiştir.

Binlerce sonucun içerisinde büyük bir oranın yakın çıkması bir başarıdır, daha küçük bir oranın ise büyük farklara sahip olması başarısızlığı göstermez. Bu durum

daha öncede bahsedildiği gibi ölçüm kaynaklarının hatalı ölçümler yapmasından da kaynaklanabilmektedir. Bu tür nadir ama büyük farklara sahip sapmaların ağı başarısız göstermesine karşın bu farkın bulunma sıklığına bakılmalıdır. Aşağıdaki Çizelge 3.4’de bunun bir örneği gösterilmektedir. Çizelgedeki birinci sütunda tahmin sonuçları bulunmaktadır. İkinci sütunda ise gerçekleşen ölçüm değerleri bulunmaktadır. Tahmin sonuçlarının birinci durumdaki gibi her veri setinde %30 başarısızlık göstermesi durumunda toplam hatanın %30 olduğu söylenebilir. Ancak ikinci duruma bakıldığında veri setlerinin tümünde %30 hataya rastlanırken dördüncü veri setinde %300 oranında bir hata ile karşılaşmaktadır. Bu durumda ortalama hata değerinin SSE hesaplamasında çok yüksek çıktığı görülmektedir. Bunu tetikleyen bozukluk aynı zamanda MAPE sonucunu da etkilemiştir. Ancak yeni hesap yöntemi %30 sapmaya yakın bir değer hesaplamıştır. Bunun nedeni yüksek sapmaya sahip değerlerin tüm veriler içerisinde yalnızca 1 defa tekrarlanmış olmasıdır. Böylece yedi tahminin altısında başarılı olan ağı bu başarısı fark edilebilmiştir. Ancak yalnızca bir ölçümde yapılan bir hata diğer sınamalarda ağı başarıya ulaşamamasına sebep olacaktır. Böylece bir yanlış ölçüm optimum oluşan bir ağı değersiz kılacaktır.

Çizelgede dikkat çeken bir nokta incelenen birinci durumda, her elemanda %30’luk sabit bir sapma olurken önerilen sına modelinin %26 hesap sonucu ile %4’lük bir hata göstermesidir. Bu durum önerilen sına modelini daha iyi açıklayabilmek amacıyla ayarlanmış bir hata ölçeği sonucu hesaplanan bilinçli bir hata ölçeğidir. Dikkat edilirse bu noktada önerilen sına metodunun aralığı %25 ve %30 arasında seçilmiştir. Bu kategorideki tahmin değerlerinin normalize edilmiş katsayıları düzeltmeyi bu aralıktaki tüm değerlerin toplam oranına göre yeniden hesaplamaktadır. Aralığın genişliği sapma miktarını etkilemiştir. Aralığın daha dar kategorilere ayrılması bu sapma oranını düşürmektedir. Tercih edilecek olan tahmin hassasiyetine göre düzenlenebilecek olan model aralığı ile bu durum düzeltilebilmekte ve her noktada tam hassasiyet sağlanabilmektedir.

Bunu otomatik olarak düzenleyebilmek için gerekli kodlama tahmin değerlerinin maksimum ve minimum değerleri arasında 1 birim farkla (veya daha küçük) oluşturulabilecek sütun matrisi ile gerçekleştirilebilir.

Çizelge 3.4. Önerilen yöntemin sık kullanılan bazı yöntemler ile karşılaştırması

1. Durum						2. Durum					
Tahmin Değeri (m/sn)	Ölçüm Değeri (m/sn)	Sapma %	sse (%)	mape (%)	Önerilen Yöntem (%)	Tahmin Değeri (m/sn)	Ölçüm Değeri (m/sn)	Sapma %	sse (%)	mape (%)	Önerilen Yöntem (%)
1.30	1	30				1	1.10	30			
2.60	2	30				2	2.10	30			
3.90	3	30				3	3.10	30			
5.2	4	30	45	30	26	4	16	300	554	69	30
6.5	5	30				5	5.10	30			
7.8	6	30				6	6.10	30			
9.1	7	30				7	7.10	30			

Böylece gerçekleşen tahmin değerlerinin yüzde sapması genel yaklaşım için bir birimden daha az bir miktarda hesaplanabilmektedir. Matlab ve benzeri programlar oluşturulabilecek vektörler değerleri için kullanılan donanımına göre bazı sınırlamalar getirebilmektedir. Modelde, çalışılan donanım ve yazılıma göre oluşturulabilecek vektör sınırlarına kadar hassasiyet ayarlanabilir. Bu döngü hızını, çıkışta alınan veri sayısı ve bunların yüzde sapma oranlarının farkının büyüklüğüne göre arttıracaktır. Ancak daha kritik hesaplamalarda optimum değerlerin sağlanması istenirse daha etkin bir çözüm olacağı kaçınılmazdır.

Esasen bu durum diğer yöntemlerle karşılaştırıldığında zamandan tasarruf sağlandığı tespit edilmiştir. Bunun sebebi ise epoch sayısının düşmesidir. Hata sına yöntemleri optimum değerleri fark etmeden sadece oranlama yöntemiyle hatayı analiz ettikleri için ayarlanmış olan kıstaslara göre oluşabilecek iyi bir ağdaki yakınlaşmayı farklı görebilirler. Bu tür geleneksel yöntemlerde bir tek elemandaki yüksek bir sapma bu durumu tetikleyebilmektedir. Ancak yeni önerilen sistem bu duruma düşmez ve oluşabilecek iyi modelleri zamanında fark ederek zamandan tasarruf sağlamış olmaktadır. Bu durum yapılan testlerde tespit edilmiştir.

Çalışmada, aralık matrisinin, karşılaştırılan veri sonuçları üzerinden maksimum ve minimum değerler arasındaki %1 sapmaya göre karar düzenlenmiş bir örnek kodlaması aşağıda yer almaktadır. Burada ye ve yv sütun vektörleri arasındaki farkların yv vektörüne bölünmesi ile elde edilen oranların maksimum ve minimum değerleri bulunduktan sonra, while döngüsü ile zet\_max ve zet\_min değeri arasında 0.01 artışa

göre aralık boyunca bir “yuzde“ matrisi oluşturulmuştur. Bu yöntemle aralık matrisi %1 hassasiyetle o anki eğitim değerleri için elde edilmiştir. Ancak kullanılan aralık matris boyutunun donanım değerlerini aşmaması için hesaplama aralığına bir sınır getirilmiştir. Böylece donanımın yetersiz kalması engellenmiştir. Sapma oranının çıkış değerlerinin 25 katına çıkması durumunda bu aralık hassasiyeti bu noktadan sonraki veri hassasiyetini %10 olarak seçmektedir. Bu değerün üstündeki hata miktarlarının benzer kategorilerde etki etmesi elde edilmek istenen performans kriterlerinin çok düşük olması sebebiyle bir önem arz etmemektedir.

```

function [ sapma ] = diverror(a)
ye=a(1:end,1);yv=a(1:end,2);
[m0,~]=size(yv);
for n=1:m0
    if yv(n,1)==0
        yv(n,1)=yv(n,1)+0.1;
    end
end
err=abs(ye-yv);
diverr=(err./yv);
[m,~]=size(diverr);
%%
zet_max=max(diverr); zet_min=min(diverr);
zeta=0;
yuzde=[];
%%
while zet_min<=zet_max
    zeta=zeta+1;
    yuzde(zeta,1)=zet_min;
    if zet_min<=25
        zet_min=zet_min+0.01;
        yuzde(zeta,2)=zet_min;
    else
        zet_min=zet_min+0.1;
        yuzde(zeta,2)=zet_min;
    end
end

```

```

end %%
[y0,~]=size(yuzde);
H=[];
for y=1:y0
    g=yuzde(y,2);
    g2=yuzde(y,1);
    %%
    for i=1:m
        if diverr(i,1)<g && diverr(i,1)>=g2
            H(i,y)=1;
        else
            H(i,y)=0;
        end
    end
end
end
[~,y2]=size(H);
for u=1:y2
    HH(1,u)=sum(H(:,u));
end
HH=HH./m;
pmax=max(HH); pmin=min(HH);
HHH=(HH-pmin)/(pmax-pmin);
for yx=1:y0
    for i=1:m
        if H(i,yx)==1
            Y(i,yx)=diverr(i,1);
        else
            Y(i,yx)=0;
        end
    end
end
end
YY=[];
for yx2=1:y0
    for yx3=1:m
        YY(yx3,yx2)=Y(yx3,yx2)*HHH(1,yx2);
    end
end
end

```

```

Yvektor=sum(YY);
sapma=sum(Yvektor)/m;
end

```

Hesaplarda kullanılan veriler ağ işlemleri içerisinde logsigmoid fonksiyonu ile 0-1 aralığına çekildiğinden dolayı bunların çıkışta tekrar normal değerlerine alınması gerekmektedir. Bu işlem denormalizasyon işlemi ile gerçekleşmektedir. Normalizasyon işlemi giriş ve çıkış değerlerinin belirli bir aralığa çekildikten sonra bunlar arasındaki ilişkinin belli ağırlıklar üzerinde kaydedilmesi ve çıkışta bu ağırlıklar üzerinden orantılı olarak yeniden kendi değerleri üzerine çağrılmaları şeklinde gerçekleşmektedir. Bu işlem çeşitli yöntemlerle gerçekleşmektedir. Aşağıdaki denklemde bu yöntemlere ait bir örnek gösterilmektedir. Burada  $X_N$  (Eş. 3.1) normalize edilmiş veri her bir sütun içerisindeki maximum ve minimum değerdeki elemanlar ile işleme alınan verinin matematiksel değerlendirmesi sonucu elde edilir.

Burada normalize edilecek veriler girişte 0-1 aralığı yerine 0.1-0.9 aralığına çekilmiştir. Bu durumun daha sağlıklı sonuçlar oluşturduğu yapılan çalışmalar sonucu tespit edilmiştir. Ayrıca Yaşar ve ark. (2012), yaptıkları çalışmada, aynı yöntemin daha sağlıklı sonuçlar ürettiğini belirtmişlerdir.

$$X_N = 0.9 \left( \frac{X_R - X_{\min}}{X_{\max} - X_{\min}} \right) + 0.1 \quad (3.1)$$

Çalışmada oluşturulan ağın optimizasyonunun eldeki imkanlar çerçevesinde gerçekleştirilebilmesi için belli sınırlar içerisinde bir sına sistemini oluşturulmuştur. Bu sına sistemini Matlab'da Neural Network Toolbox üzerinden gerçekleştirilmiştir. Eğitim verileri Neural Network Toolbox içerisinde bulunan 6 ayrı algoritma ile bir döngü oluşturularak 5 nöron sayısı ve 1 ara katman bulunacak şekilde başlatılmıştır. Bu nöron sayıları her bir döngünün sonunda 1 artmakta ve her bir değişiklik 6 ayrı algoritmada bir sonraki döngüde değerlendirilmektedir. Birinci katmandaki nöron sayıları 25'e ulaştıktan sonra döngü çift ara katmanlı ve daha sonra 100 nörona ulaştığında ise 3 katmanlı olarak devam etmektedir. Her bir döngünün içerisinde ise başlangıç ve son değerleri 0.35 ve 0.80 olan ezberleme oranını %10 arttırmakta olan



```

        if n1 >= 100
            [sapma,a,net,ps,ts,wb] = annrunn_Uydu2(X,n1,lrate,maxfail,trS);
        end
subplot(3,2,2)
SnP2(n1)=sapma;
plot(SnP2)
title('trainoss')
drawnow
trS='trainrp';
        if n1 < 25
            [sapma,a,net,ps,ts,wb] = annrunn_Uydu0(X,n1,lrate,maxfail,trS);
        end
        if n1 >= 25 && n1 < 100
            [sapma,a,net,ps,ts,wb] = annrunn_Uydu1(X,n1,lrate,maxfail,trS);
        end
        if n1 >= 100
            [sapma,a,net,ps,ts,wb] = annrunn_Uydu2(X,n1,lrate,maxfail,trS);
        end
subplot(3,2,3)
SnP3(n1)=sapma;
plot(SnP3)
title('trainrp')
drawnow
trS='traincgf';
        if n1 < 25
            [sapma,a,net,ps,ts,wb] = annrunn_Uydu0(X,n1,lrate,maxfail,trS);
        end
        if n1 >= 25 && n1 < 100
            [sapma,a,net,ps,ts,wb] = annrunn_Uydu1(X,n1,lrate,maxfail,trS);
        end
        if n1 >= 100

```



```

        [sapma,a,net,ps,ts,wb] = annrunn_Uydu2(X,n1,lrate,maxfail,trS);
        end
subplot(3,2,4)
SnP4(n1)=sapma;
plot(SnP4)
title('traincgf')
drawnow
trS='traincgb';
        if n1<25
            [sapma,a,net,ps,ts,wb] = annrunn_Uydu0(X,n1,lrate,maxfail,trS);
            end
            if n1>=25&& n1<100
                [sapma,a,net,ps,ts,wb] = annrunn_Uydu1(X,n1,lrate,maxfail,trS);
                end
                if n1>=100
                    [sapma,a,net,ps,ts,wb] = annrunn_Uydu2(X,n1,lrate,maxfail,trS);
                    end
subplot(3,2,5)
SnP5(n1)=sapma;
plot(SnP5)
title('traincgb')
drawnow
%%
trS='traincgp';
        if n1<25
            [sapma,a,net,ps,ts,wb] = annrunn_Uydu0(X,n1,lrate,maxfail,trS);
            end
            if n1>=25&& n1<100
                [sapma,a,net,ps,ts,wb] = annrunn_Uydu1(X,n1,lrate,maxfail,trS);
                end
                if n1>=100

```


```

[sapma,a,net,ps,ts,wb] = annrunn_Uydu2(X,nl,lrate,maxfail,trS);
end
subplot(3,2,6)
SnP6(nl)=sapma;
plot(SnP6)
title('traincgp')
drawnow
C=horzcat(A,sapma);
D=vertcat(D,C);
nl=nl+1;
end

```

Test çıktılarının sonuçlarına göre Matlab da kullanılan algoritmaları karşılaştırmak amacıyla elde edilen bu döngüye ait bir tahminleme örneği aşağıda yer almaktadır. Bu sınımalara ait aşağıda Şekil 3.13'deki grafiklerde 1 ara katman ve değişken nöron sayısına göre bir sınaama gerçekleştirilmiştir. Şekil 3.14'de ise 2 ara katman ve her katmanda aynı sayıda nöron olmak üzere değişen nöron sayılarına göre karşılaştırma yapılmıştır. Grafiklerden anlaşılacağı gibi çalışmadaki veriler üzerinde en iyi tahmin başarısı “trainlm” üzerinde oluşmaktadır. “trainlm” lokal olarak en düşük tahmin başarısına sahip olmasa da en iyi performansa yakın düzeyde istikrarlı bir durum sergilemektedir. Bu nedenle çalışmadaki tahminleme çalışmaları veri setindeki başarısı sebebiyle “trainlm” üzerinden yürütülmüştür. Grafiklerden çıkan diğer bir sonuç ise ara katman sayısının tahmin başarısı üzerinde yeterince yüksek bir başarısının bulunmayışıdır. Bunun sebebi ise literatür çalışmalarından da anlaşılacağı gibi ağın ara katmanlarındaki benzeşme sorunundan kaynaklanmaktadır. Bunu aşmanın yolu olarak ara katmandaki ezberleme oranlarında değişikliğe gidilmeye çalışılmıştır. Yeni oluşturulan algoritmalarda bu yöntem denenmiş ve olumlu sonuçlar elde edilmiştir. Ancak performans noktasında yeterince yüksek yapılar oluşturulamadığından bu çalışmalar teze eklenmemiştir. Bu sebeplerden ötürü çalışmada kullanılan ağ yapısı kullanılan donanımından optimal düzeyde verim elde edilmesi ve ağın gereksiz ağ

yükünden kurtulması amacıyla tek katmanlı olarak oluşturulmuştur. Böylece daha yüksek oranlarda nöronlarla işlem yürütülebilmiştir.



Şekil 3.13. Matlab NN Toolox'da kullanılan 6 adet algoritmanın aynı veri seti ile 1 ara katman ve nöron sayısına göre tahmin başarısının karşılaştırılması.



Şekil 3.14. Matlab NN Toolox'da kullanılan 6 adet algoritmanın aynı veri seti ile 2 ara katman ve nöron sayısına göre tahmin başarısının karşılaştırılması.

Veriler içerisinde bazı yanıltıcı değerler bulunabilmektedir. İncelenen çıktılar üzerinde hiçbir etkisi bulunmayan bazı verilerin sonuçları gerçeklikten

uzaklaştırabildiği çalışma aşamalarında tespit edilmiştir. Verilerin gerçekleşme zamanları giriş elemanı olarak kullanıldığında, bu zaman değerlerinin tahmin sonuçlarını olumsuz yönde etkilediği görülmüştür. Bu nedenle verilerin oluşma zaman serileri giriş satırlarından çıkarılmıştır. Bu tür bir çalışmanın çalışmada kullanılan zaman aralığından daha geniş bir zaman aralığında olumlu etkiler gösterebileceği düşünülmektedir.

### 3.3. Potansiyel Analizi (WAsP)

MGM'den alınan 8 ayrı ölçüm istasyonuna ait veriler halihazır haritalar ile birlikte WAsP'a aktarılmış ve çalışılan bölgelere ait potansiyel atlasları oluşturulmuştur. WAsP 1987'de Danimarka Riso Ulusal Laboratuvarı'nda hazırlanmış atmosferik verilerin analiz ve simülasyonu konularında sıkça kullanılan bir programdır. WAsP zaman serilerine bağlı olarak rüzgar hızı, rüzgar yönü, yüzey pürüzlülüğü ve çevresel engelleri kullanarak yüzey şekillerine bağlı olarak bölgenin rüzgar atlasını oluşturmaktadır. Program içerisinde bulunmakta olan türbini modelleri ile ölçüm bölgelerine ait bir rüzgar tarlası modeli oluşturabilmekte ve üretilecek enerji analizlerini oluşturabilmektedir. WAsP ham veri analizi, rüzgar atlası oluşturma, rüzgar iklim verileri, rüzgar enerjisi potansiyel atlası oluşturma, rüzgar tarlası potansiyel hesaplaması, türbin yerleşiminin oluşturduğu çevresel etkiler gibi birçok alanda bölgeyi inceleme imkanı sağlar.

Toplanan MGM verileri ana programa aktarılmadan önce WAsP 11 sürümünde yer almakta olan "WAsP Climate Analyst 3" ile düzenlenmiştir. Burada belirli zaman serilerine sahip iklim verilerinin analizi yapılarak, gözlemlenmiş iklim verisi olarak ana programa uygun bir formata (.omwc) getirilmektedir. Zaman serilerine sahip ham veriler Climate Analyst 3 modülüne "csv" formatında aktarılmıştır.


Şekilde 3.15'de görüldüğü üzere MGM'den elde edilen gözlemlenmiş istasyon verileri 3 sütun olarak programa girilmiştir. Birinci A sütununda, iklim datalarının bulunduğu zaman dilimi yıl, ay, gün ve saat olarak belirtilmektedir. İkinci ve üçüncü sütunda ise ölçülen zamana ait rüzgar hızı ve yönü bilgileri yer almaktadır. Wind

Climate Analyst programına aktarıldıktan sonra veri setleri istenilen kategoriye göre düzenlenebilmektedir.


	A	B	C
1	2013010100	0,6	0
2	2013010103	0,5	30
3	2013010104	0,8	330
4	2013010108	0,5	180
5	2013010109	0,8	210
6	2013010110	0,4	210
7	2013010111	0,9	210
8	2013010113	1,2	60
9	2013010114	0,8	30
10	2013010115	0,8	30
11	2013010116	0,7	30

Şekil 3.15. Zaman serilerine sahip Başkale ölçüm istasyonu gözlemlenmiş ham istasyon verileri (A: tarih, B: rüzgar hızı, C: rüzgar yönü).

Burada hız, yön, zaman serileri düzenlenen kategoriye göre anlam kazanmaktadır. Şekil 3.16'daki gibi veriler girildikten sonra, "Gözlemlenmiş Rüzgar İklim Dosyası" (omwc) hesaplanmıştır. OMWC hesaplamalarında 0-330 derecelik tüm sektörlere ait a ve k parametrelerini içeren rüzgargülü, istatistik raporları ve rüzgar hızı histogramı oluşturulmuştur.




Şekil 3.16. WAsP programında veri setlerinin girilmesi.




Şekil 3.17. WASP programında veri setlerinden OMWC oluşturulması.

Bölgeye ait vektör tabanlı haritaların oluşturulması, WASP Map Editor 11 aracılığı ile gerçekleştirilmiştir. Map Editor ara yüzünde “files” bölümünde yer alan “import” bölümü altındaki “SRTM.ver2 Database” NASA’nın oluşturmuş olduğu yeryüzü topoğrafik harita data baseine bağlanarak buradan istenilen bölgenin topoğrafik haritaların indirilebilmesine imkan tanımaktadır. Çalışmada bu özellikten faydalanılarak bölgelere ait arazi modelleri SRTM Database’den elde edilmiştir. SRTM Database’inden verileri elde edebilmek için Şekil 3.18.’de görüldüğü gibi açılan ara yüzde, MGM sitesinden DDD olarak alınan istasyon koordinatları merkez kabul edilerek “Map Centre Location” alanına girilmiştir. Projeksiyon ayarları yapıldıktan sonra seçilen merkezin çevresinde 30 km uzaklıkta bir alana sahip 2m aralıklı yüzey eğrileri temin edilmiştir. WASP’ın hesaplama modüllerinin bazı limitleri bulunmaktadır. Vektör haritalar için harita üzerindeki noktaların sayısı ile çizgilerin sayısının üç katının toplamı 1.000.000’u geçmemelidir (Güzel, 2012).



Şekil 3.18. SRTM Database'den topoğrafik veri oluşturulması.

SRTM Database'den elde edilen Başkale istasyonuna ait elde edilen yüzey haritasının WAsP Map Editor'de Map Image bölümündeki görüntüsü Şekil 3.19'daki gibi olmuştur. Burada yüksek alanlar daha koyu renklerde görülmektedir.




Şekil 3.19. SRTM Database'den elde edilen Başkale istasyonuna ait vektörel yüzey haritası.

Bölgeler için elde edilen haritalara ait yüzey pürüzlülük sınırları Google Earth'den elde edilen görüntüler kullanılarak elde edilmiştir. Google Earth arayüzünde pürüzlülük değerleri farklı olan alanlara ait sınırlar yol çizgileri ile çevrilmiş ve bu yol

çizgileri “.kmz“ formatında WASP Map Editor’e aktarılmıştır. Çizgi özelliklerinden pürüzlülük değerleri tanımlanarak farklı pürüzlülük değerlerine sahip alanlar programa tanımlanmıştır.

Vektörel harita ve pürüzlülük sınırları tek bir Map dosyasında birleştirildikten sonra WASP 11’e aktarılmak üzere “.map” formatında kaydedilmiştir. Elde edilen gözlemlenmiş iklim verisi (.omwc) ve yüzey haritası (.map) dosyaları WASP 11 programına aktarılmıştır. Bu aktarım işlemi Şekil 3.20’de görülmektedir.




Şekil 3.20. WASP 11 ‘de omwc ve vektör haritası verilerinin import edilmesi.

Gözlemlenmiş iklim verileri WASP’a aktarılırken, ölçüm değerleri alınan istasyonun UTM koordinat bilgileri sorulmaktadır. İstasyonlara ait MGM’den elde edilen coğrafik koordinatlar UTM formatına dönüştürüldükten sonra ölçüm istasyonu koordinatları girilmiştir.

Aktarım işlemleri tamamlandıktan sonra WASP programı ile birlikte gelen hazır türbin modellerinden “Vestas V52 850 kW” seçilerek bölgeye ait rüzgar tarlaları oluşturulmuştur. Gözlemlenmiş İklim Verileri’nin aktarılmasında olduğu gibi türbin sitesi oluşturulurken de UTM formatında rüzgar tarlasının koordinat bilgileri girilmelidir. Bu işlemler tamamlandıktan sonra Vektör Map üzerinde ölçüm istasyonu




ve rüzgar tarlası oluşmuştur. Başkale istasyonunun ait örnek çalışma Şekil 3.21’de görülmektedir.



Şekil 3.21. WAsP 11 ‘de Vektör Map üzerinde potansiyel yoğunluğuna bağlı olarak oluşan gözlem istasyonu ve rüzgar tarlasına ait rüzgargülü modelleri.

Bu işlemler tamamlandıktan sonra bölgeye ait potansiyel dağılımını renk skalası yardımı ile okuyabilmemizi sağlayan potansiyel haritaları oluşturulmuştur. Potansiyel haritalarında bölgeye ait rüzgar potansiyeli dağılımları her bir sektörde oluşan bölgelere ait güç yoğunluğu ile gösterilmektedir. Bu harita bölgenin potansiyel yoğunluğuna göre türbin sitesi kurulması için en avantajlı noktaların belirlenmesini sağlamıştır. Başkale istasyonuna ait örnek potansiyel yoğunluğu haritası Şekil 3.22’de görülmektedir. Burada tüm sektörler açısından en uygun alan kırmızı olarak belirtilmiştir.



Şekil 3.22. WASP 11 'de Başkale ölçüm istasyonuna ait potansiyel yoğunluğu haritası.




## 4. BULGULAR VE TARTIŞMA

### 4.1. Yapay Sinir Ağları Metodolojisi İle Rüzgar Hızı Tahmini

Yapay sinir ağları bölümünde yapılan çalışmada Van ve Hakkari bölgesine ait Meteoroloji Genel Müdürlüğüne ait 8 ölçüm istasyonundan alınan 5 yıllık veri setleri kullanılmıştır. Veriler kullanılan sekiz istasyon için ayrı olarak düzenlenmiştir. Bu veriler rüzgar hızı, rüzgar yönü, bağıl nem, sıcaklık, basınç ve ölçüm istasyonuna ait rakım bilgilerini içermektedir. Bu bölümde Hakkari, Yüksekova, Başkale, Erciş, Gevaş, Muradiye ve Özalp ölçüm istasyonlarından alınan rüzgar yönü, bağıl nem, sıcaklık, basınç ve rakım verileri YSA'nın giriş katmanında ve hız verisi ise çıkış katmanında kullanılarak eğitilen ağ kararlı hale getirilmiştir. Ardından oluşturulan model MGM Van merkez istasyonu benzer giriş verileri için tekrarlanarak bu istasyondaki hava hız değerleri tahmin edilmiştir.

MGM ve uydu verileri ile oluşturulan YSA ağının eğitim aşamasında birinci katmanda 25 ikincide 25 ve üçüncüde 2 nörona sahip toplam 3 ara katman kullanılmıştır. Bu ara katman ve nöron sayısının optimal düzeyde verimlilik sağlaması üzerine daha fazla değişikliğe gerek duyulmamıştır. Daha yüksek ara katmanlı ağlarla yapılan çalışmalarda sonuçların benzer yakınlıkta olduğu tespit edilmiştir. Oluşturulan modelde ezberleme hassasiyeti 0.35, yaklaşma oranı  $1 \times 10^{-6}$ , maksimum tekrarlama sayısı 6 ve maksimum döngü sayısı 8000 olarak belirlenmiştir. Ağ algoritması, algoritmalar arasında veri seti üzerinde en iyi performansı sebebiyle “trainlm”, “trainoss” ve “trainrp” seçilmiş ve sonuçlar bu ağ yapıları üzerinden tekrarlayan denemeler sonucu oluşturulmuştur. Bunlara ait grafikler Şekil 4.1’de görülmektedir. Tahmin aşamasındaki sonuçların performans değerlendirmesinde Matlab kütüphanesinde bulunan algoritmalar yerine, çalışmada yeni önerilen yöntem kullanılmıştır. Farklı üç algoritma kullanılarak tahminlenen Van ölçüm istasyonuna göre bu sına yöntemiyle elde edilen sonuçlara ait genel yüzde sapma değerleri Şekil 4.1’de görülmektedir.



Şekil 4.1. Tahminlenen Van istasyonu algoritma karşılaştırma ve sapma değerleri grafiği.

Grafiklerden görüldüğü üzere hedef istasyon için elde edilen en iyi performans değeri %11.12 sapma ile “trainoss” algoritması kullanımında gerçekleşmiştir. Ancak grafikte diğer algoritmaların da bu veri kümesi üzerinde yeterince başarı sağlayabildiği görülebilmektedir. Ağ belirlenen kriterlere ulaşana kadar “trainlm” algoritmasında gerçekleşen en düşük sapma miktarı %21.39 olmuştur. Bu durum “trainrp” algoritmasında %24.01 olarak gerçekleşmiştir.

Yapılan çalışmalarda modelin eğitim aşamasında yeni önerilen yöntem Matlab performans kütüphanesine, Matlab’a sitesindeki forumlarda açıklandığı haliyle eklenmeye çalışılmış ancak program standart olarak belirlenmiş “mse” yöntemi üzerinden performans değerlendirmesine devam etmiştir. Bu sebeple eğitim aşamasında performans değerlendirmesi için Matlab performans kütüphanesinden çeşitli denemeler sonucunda belirlenen ortalama karesel hata yöntemi “mse” seçilmiştir. Ortalama karesel hata tahmin sonuçlarının gerçek sonuçlarla arasındaki karşılaştırmanın matematiksel bir ifadesidir. Tahmin sonuçları ile gerçek sonuçlar arasındaki farkın karelerinin ortalamasına dayanarak tahmindeki sapma değerinin belirlenmesine dayanır. Kullanılan hata belirleme yönteminin matematiksel modeli aşağıdaki gibidir (Eş. 4.1).

$$mse = \frac{1}{n} \sum_{k=1}^n e(k)^2 = \frac{1}{n} \sum_{k=1}^n (t(k) - a(k))^2 \quad (4.1)$$

Çalışılan modelde eğitim setlerine ait verilerin %60'si eğitim, %20'si doğrulama ve kalan %20 ise test aşamasında kullanılmıştır. Çalışılan bu sınırlar Matlab'da "dividerand" komutu ile oluşturulmuştur. Bu komutun Matlab'daki uygulaması aşağıdaki gibi olmuştur. Oluşturulan bu aralık, çeşitli denemeler sonucu eğitim ve test aşamalarında optimum değerler sağlanması üzerine belirlenmiştir.


```
net.divideFcn = 'dividerand';
net.divideParam.trainRatio = 60/100;
net.divideParam.valRatio = 20/100;
net.divideParam.testRatio = 20/100;
```

Eğitim, doğrulama, test ve en iyi performans noktasının görülebildiği Şekil 4.2'deki grafiklerde mavi çizgi eğitim aşamasındaki performans değerini temsil etmektedir. Mavi çizginin göstermiş olduğu performans geri yayılım algoritmasının sistemi istikrarlı duruma getirdiği hesaplamalara ait döngülere bağlı ortalama karesel hataları göstermektedir. Bu performans, hataların düzeltilmesine dayalı olarak gerçekleştiğinden tahminleme açısından bir önemi olmamaktadır. Ancak yeşil çizgi ve kırmızı çizgi ile gösterilen performanslar tahmin modelinin başarı durumunu göstermektedir. Yeşil ile gösterilen performans değeri önceden belirlenen kriterleri sağladığında kırmızı çizgi ile gösterilen doğrulama değerleri gözden geçirilir. Sistemin benzer başarıyı bu sınamada sağlamaması durumunda eğitim aşaması yenilenerek yeni bir ağ oluşması sağlanır. Bu durum doğrulama aşamasında da istenilen performans değeri sağlanana kadar devam eder. Ancak bu döngüyü sınırlayan bir epoch değeri önceden sisteme tanıtılmaktadır. Maksimum epoch değerine ulaşmadan sistemde doğrulama aşamasında bir minimum performans sağlanırsa bu durumda sistem tahminleme aşamasına geçer ve kırmızı çizgi ile belirtilen test aşamasını gerçekleştirir. Bu aşamada öncekiler gibi bir geri yayılım söz konusu değildir. Önceki aşamalarda oluşturulan ağ yapısı nihai model olmaktadır. Test aşamasındakiler ise nihai ağa göre

oluşturulmuş güvenilir test sonuçlardadır. Bu aşamadaki sonuçlar gerçek ölçüm değerleri ile karşılaştırılarak modelin kararlılığı sorgulanır. Bu durumda sonuç grafiğinde mavi (eğitim) ve yeşil (doğrulama) değerlerinden ziyade kırmızı (test) aşamasında performansın yüksek olması beklenir. Eğitim sonrası elde edilen Şekil 4.2'deki grafikte ortalama karesel hataya bağlı olarak elde edilen en düşük sapma oranının 321. döngüde 0.01171 olduğu görülmektedir. Bu değer test aşaması için gerçekleşmiştir. Eğitim ve doğrulamadaki sapmaların ise bu değerle neredeyse aynı olduğu görülmektedir. Grafik model oluşturulurken Van Merkez dışındaki 7 istasyonun verileri ile yapılan eğitimin test aşamasında 321 döngü sonucu %1'e yakın bir sapma elde edildiği görülmektedir. Sapma, birinci döngüden itibaren eğitim boyunca logaritmik olarak düşerek bu değere ulaşmıştır. Bunun düşüşün hızı eğitim katsayısına bağlı olarak değişmektedir. Eğitim katsayısı çalışmada 0.35 olarak alınmıştır. Bu değer Matlab önayarlı durumda 0.1 olarak alınmaktadır. Eğitim katsayısının bu denli düşük alınması epoch sayısının artmasına ve istenilen performans değerinin daha geç elde edilmesine sebep olmaktadır. Ancak ağdaki öğrenme etkinliği daha büyük kapasitelere çıkmaktadır. Bu nedenle çalışmada öğrenme katsayısı eğitim süreleride gözetilerek düşük alınmıştır. Eğitim katsayısının daha büyük alınması durumunda sistem hızlıca ağı eğitmekte ancak döngüye son giren veri setinin etkisi genel üzerinde büyük etki göstermektedir. Çalışmada hedeflenen, son veri setinin etkisinden ziyade veri setinin genelinin etkisinin ağda taşınmasıdır.

Benzer özellikteki giriş verileri ile yapılan testlerde sonuçların çok yakın olduğu görülmektedir. Bu durum tahminleme açısından, çalışmada kullanılan giriş verilerinin birbirine göre çok farklı iklim özellikleri gösteren alanlarda olmasının sonuçlar üzerinde farklılık yaratmadığını göstermektedir. Diğer yandan modeldeki nöron ve katman sayıları ile sınır değerlerinin çeşitli varyasyonları ile elde edilen maksimum performansın 8 istasyon için birbirine çok yakın olarak tekrar etmesi rüzgar hızı tahmini açısından kullanılan veri kümesi ile elde edilebilecek en yüksek değerlere ulaşıldığını göstermektedir. Performansın iyileştirilmesi açısından yapılması gereken, sistemi pozitif yönde etkileyebilecek yeni değişkenlerin eklenmesini sağlamaktır. Seçilen bölgelere için yapılan tahminlemelere ait regresyon grafikleri Şekil 4.3'de

görülmektedir. Regresyon grafikleri doğrulama ve test aşamalarındaki YSA verilerinin tahmin sonuçlarının yaklaşım değerlerini göstermektedir.




Şekil 4.2. Eğitim aşamasına ait Matlab ortalama karesel hata grafiği.

Regresyon grafiğinde en başarılı sonucun performansta olduğu gibi test alanında olması beklenir. Çalışma grafiğinde görüldüğü üzere regresyon değerleri test aşamasında %56 kadar yaklaşım sağlamıştır. Buradaki regresyon değerinin bire eşit olması, tahmin ve ölçüm eğrisinin çakıştığı durumu ifade etmektedir. Bu durum YSA modelinin %100 bir yaklaşım sağladığını gösterir. Bu değer birden uzaklaştığı ölçüde sapmalar yaşanacaktır. Eğitim ve doğrulamanın veri zenginliği sapmaları sağladığı halde, testlerde büyük bir tahmin yaklaşımı sağlayacak geniş bir ağ oluşturulmasını sağlar. Tüm aşamaların  $R=1$  değerine sahip olması, verilerin tümünde doğrusal ifadeleri içeren durumların bulunduğunu gösterecektir. Test aşamasının diğerlerine göre yüksek hata oranlarına sahip olması ise ağın ezberleme sorunu olması sonucunda oluşacaktır.

Regresyon grafikleri performans grafiklerine oranla sistem hakkında daha çok bilgi içerir. Genel bir yaklaşıma ilave olarak sistemin tüm veri davranışları hakkında tam bir yorumlama sağlar. Grafiğin her bir aşamasında gerçekleşen tüm veri yaklaşımları birbir grafiğin üzerinde görülebildiğinden dolayı, sistem davranışları daha rahat izlenebilmektedir. Matlab arayüzünde çalıştırıldıktan sonra eğitimin başından itibaren “plot interval” botununa görüntülenmesi istenen epoch sayısına göre ayar yapılması durumunda regresyon grafikleri belirtilen epoch miktarı her dolduğunda



görsütülenecektir. Böylece analiz boyunca dinamik bir şekilde sonuçların durumu görsütülenmiş olur. Bu durum analizin sonucu beklenmeden olaya müdahale edilmesini sağlamıştır. Bu durum aynı zamanda performans grafiklerinin incelenmesi için de geçerli olmaktadır. Performans ve regresyon grafiklerinin bu şekilde takibi ezberlemenin hangi anda başladığının takibi için önemlidir. Böylece sisteme müdahale edilerek kısa zamanda daha uygun bir ağ modelinin kurulabilmesi mümkün olmaktadır. Matlab arayüzündeki maksimum doğrulama sınırlaması da buna göre şekillendirilebilmekte ve sonuç aşamasında uzun süreli gerçekleşen nihai sonuçların elde edilebilmesi daha kısa zamanda gerçekleştirilebilmektedir.



Şekil 4.3. Tahminlenen Van istasyonuna ait YSA regresyon grafikleri.

Yapılan çalışmada Çizelge 4.1’de görüldüğü üzere genel olarak 1 m/s’nin altında bir hız farkı ile tahminleme yapıldığı tespit edilmiştir. Tahmin edilmeye çalışılan verilerin birbirine genel olarak çok yakın değerler içermesine rağmen ağın tahminlemede çok başarılı olduğu görülmüştür. Genel olarak türbin çalışma hızlarının 3-25 m/sn aralığında olduğu göz önünde bulundurulduğunda YSA’daki bu yaklaşımın ihtiyacı fazlasıyla karşıladığı anlaşılmaktadır. Çalışılan veri setlerinde kullanılan değişkenlerin rüzgar hızı tahmini açısından başarılı olduğu tespit edilmiştir. Bu durum


tablodaki örnek çıktılarından anlaşılmaktadır. Van İstasyonuna ait toplam tahminlemedeki hata oranın genel için %11 olmuştur. Bu durum aşağıdaki tabloda görülmektedir.

Çizelge 4.1. Çalışmada elde edilen 31904 test çıktısının örnek bir bölümü

Tahmin Değeri (m/s)	Ölçüm Değeri (m/s)	Hız Farkı (m/s)
1.37	1.30	0.07
2.64	0.70	1.94
1.61	0.90	0.71
1.33	1.30	0.03
1.26	1.40	0.14
0.76	1.40	0.64
1.00	1.00	0
1.92	0.80	1.12
1.49	0.6	0.89
2.62	1.6	1.02
1.16	2.4	1.24
Yüzde Sapma Oranı (%)		11

Eğitim aşamasından sonra oluşturulan YSA ağı ile tahmin edilen 31904 veri setini içeren 5 yıllık hedef istasyon verilerinin sonucunu içeren “qq-plot” grafiği Şekil 4.4’de görülmektedir. “qq-plot” yöntemi sistemler arasında normal bir dağılım olması durumunda tüm gözlemlerin 45° bir doğru üzerine yerleştirilmesine göre düzenlenir. Yöntem iki veri kümesinin ortak dağılıma sahip bir popülasyondan gelip gelmediğini belirlemek için uygulanan grafiksel bir tekniktir. Şekil 4.4’de veri değerlerine göre oluşmuş “qq-plot” doğrusal çizgilerinin birbirine çakışma oranı verilerin yakınlığını göstermektedir. Tahmin aşamasına ait “qq-plot” grafiğinden görüldüğü üzere ağ genel olarak yüksek yakınlıkta tahminler gerçekleştirebilmiştir. Grafik eğrilerinden bu durum görülmektedir. Veri sayısındaki yoğunluk YSA’nın sınır değer problemi yaşamadan tahminlemeyi yapmasını sağlamıştır. Daha az sayıda veri kümesi kullanılarak yapılan testlerde, aşağıda Özalp ve Başkale grafiğinde görüldüğü gibi büyük sapmalar oluştuğu

tespit edilmiştir. Özellikle test aşamasında kullanılan dataların, veri setlerinde kullanılan data sınırlarının dışına çıkılmasının bu tür sorunlara sebebiyet verdiği anlaşılmıştır. Bu nedenle test aşamasındaki dataların eğitim aşamasında data sınırları içerisinde bulunabilmesi için eğitimin yeterli büyüklükte bir küme ile yapılması gerektiği tespit edilmiştir. Diğer bir etki ise, Başkale ve Özalp örneğindeki verilerin diğer verilere yakın özellikler taşıyıp taşımadığı bu bölgelerdeki tahminleme oranlarındaki sapmaları arttırmıştır. Bu durum göz önüne alındığında, çalışılan veri özellikleri dikkate alınarak oluşturulacak çalışmaların benzer iklim özellikleri taşıyan bölgelerde daha iyi sonuçlar verdiği tespit edilmiştir. Bu durum sınır değerleri yaklaşımının doğruluğunu kanıtlamaktadır. Ayrıca veri çeşitliliğinin, başarı oranı üzerindeki etkisini de göstermektedir.

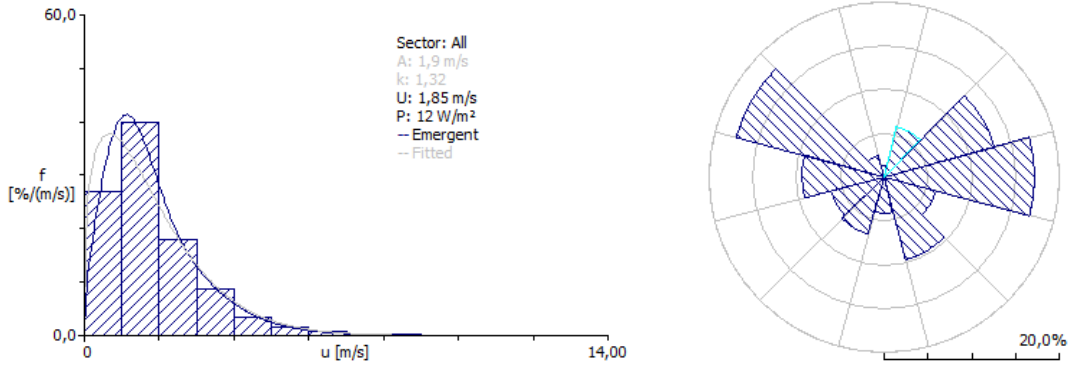


Şekil 4.4. Ağ oluşturulduktan sonra Van istasyonu için MGM ölçüm verileri ve YSA tahmin verileri karşılaştırması.


#### 4.2. Potansiyel Analizi

Yapılan çalışmada, bölgelere ait rüzgar potansiyelini belirlemek amacıyla WAsP 11 programı kullanılarak, rüzgar atlasları oluşturulmuştur. MGM'den alınan 8 bölgeye ait verilerin WAsP Climate Analyst programına aktarılmasıyla elde edilen rüzgar atlası grafikleri Şekil 4.5'de görülmektedir. Bu grafiklerde analizi yapılan bölgeye ait ortalama rüzgar hızı değeri, weibull parametreleri ve metrekare alan için hesaplanan

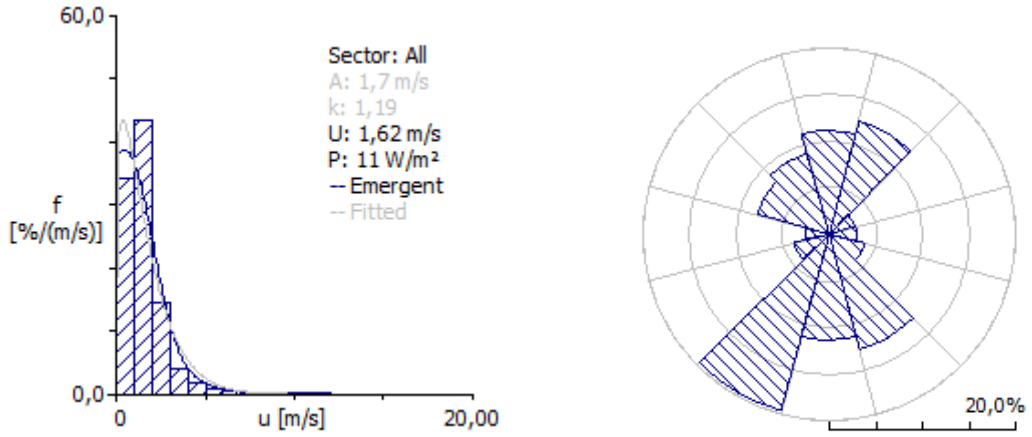
rüzgar gücü değerleri görülmektedir. Grafikler ölçüm istasyonu etrafında bulunan 3 km mesafedeki alanın rüzgar potansiyelini belirleyecek şekilde düzenlenmiştir. Bu durum incelenen bölgenin tümünü kapsamamaktadır. Yapılması gereken tüm bölgeyi analiz edebilecek bir sistem oluşturmaktır. Bu durum bir sonraki aşamada, ölçüm istasyonu kapsam alanı dışındaki noktalarda sentetik rüzgar istasyonları oluşturularak çözümlenmektedir. Çalışmada MGM'den alınan veriler ile elde edilen MGM istasyonu ve kapsama alanındaki bölgeye ait rüzgar potansiyelleri aşağıdaki grafiklerden görüldüğü üzere çok düşük çıkmaktadır. Ancak Erciş istasyonuna ait bölgede bu potansiyelin  $3940 \text{ W/m}^2$  ile rüzgar tarlası kurulumu için uygun değerlerde çıktığı görülmektedir. Bu bölgedeki hakim rüzgar yönünün güneybatı doğrultusunda  $210^\circ$  doğrultu ile Sektör 8'de olduğu grafikteki rüzgargülünde görülebilmektedir. Van istasyonu için ortalama hız değeri  $1.85 \text{ m/s}$ , ortalama güç yoğunluğu  $12 \text{ W/m}^2$ , rüzgar hızı frekansı  $1.9 \text{ m/s}$  ve rüzgar sıklığı frekansı  $1.32$  olarak belirlenmiştir. Bu durum Gevaş istasyonunda ise; ortalama hız değeri  $1.62 \text{ m/s}$ , ortalama güç yoğunluğu  $11 \text{ W/m}^2$ , rüzgar hızı frekansı  $1.7 \text{ m/s}$  ve rüzgar sıklığı frekansı  $1.19$  olarak belirlenmiştir. Muradiye istasyonu; ortalama hız değeri  $1.93 \text{ m/s}$ , ortalama güç yoğunluğu  $10 \text{ W/m}^2$ , rüzgar hızı frekansı  $2.2 \text{ m/s}$  ve rüzgar sıklığı frekansı  $1.74$  olarak belirlenmiştir. Özalp istasyonu; ortalama hız değeri  $2.02 \text{ m/s}$ , ortalama güç yoğunluğu  $17 \text{ W/m}^2$ , rüzgar hızı frekansı  $2.1 \text{ m/s}$  ve rüzgar sıklığı frekansı  $1.25$  olarak belirlenmiştir. Başkale istasyonu; ortalama hız değeri  $2.86 \text{ m/s}$ , ortalama güç yoğunluğu  $15 \text{ W/m}^2$ , rüzgar hızı frekansı  $1.9 \text{ m/s}$  ve rüzgar sıklığı frekansı  $1.9$  olarak belirlenmiştir. Hakkari istasyonu; ortalama hız değeri  $1.96 \text{ m/s}$ , ortalama güç yoğunluğu  $12 \text{ W/m}^2$ , rüzgar hızı frekansı  $2.1 \text{ m/s}$  ve rüzgar sıklığı frekansı  $1.53$  olarak belirlenmiştir. Yüksekova istasyonu; ortalama hız değeri  $1.84 \text{ m/s}$ , ortalama güç yoğunluğu  $10 \text{ W/m}^2$ , rüzgar hızı frekansı  $2.0 \text{ m/s}$  ve rüzgar sıklığı frekansı  $1.46$  olarak belirlenmiştir. Erciş istasyonu dışındaki alanların, sonuçlardan da anlaşıldığı gibi rüzgar tarlası kurulumu için uygun olmadığı tespit edilmiştir. Ancak ölçüm istasyonu kapsam alanı dışında kalan bölgeye ait diğer noktalarda kuruluma uygun alan bulunup bulunmadığı bu noktada anlaşılamamaktadır. Bu durum derin öğrenme aşamasında diğer noktaların da hesaplanmasıyla yorumlanabilmektedir.



### Van İstasyonu






### Erciş İstasyonu




### Gevaş İstasyonu


Şekil 4.5. İstasyonlara ait rüzgar iklim verileri ve rüzgar hızı histogramı.

**Muradiye İstasyonu****Özalp İstasyonu****Başkale İstasyonu**

Şekil 4.5. İstasyonlara ait rüzgar iklim verileri ve rüzgar hızı histogramı (Devam).



### Hakkari İstasyonu




### Yüksekova İstasyonu

Şekil 4.5. İstasyonlara ait rüzgar iklim verileri ve rüzgar hızı histogramı (Devam).

Gözlemlenmiş iklim verilerinin WASP Climate Analyst programında hesaplanmasının ardından oluşturulan “.omwc” dosyası WASP 11 programına aktarılmıştır. WASP 11 programında ayrıca çevresel engeller, türbin seçimi ve bölgeye ait potansiyel haritası oluşturma işlemleri gerçekleştirilmiştir. Çevresel engeller, Google Maps’den faydalanarak hesaplanmıştır.

Bunun için Google Maps üzerinde istasyon çevresinde bulunan yapıların uzaklık, açı ve yükseklik farkı değerleri incelenerek WASP 11 programında “Met.Station” bölümü altında Şekil 4.6’da görüldüğü gibi eklenmiştir. Türbin seçimleri

ise hesaplanan rüzgar atlası güç yoğunluğuna uygun olarak hesaplanmış ve seçimler buna göre sonuçlandırılmıştır. Son olarak WASP Map Editor altında SRTM Database'den elde edilen vektörel haritalar üzerinden rüzgar simülasyonları yapılarak Şekil 4.7'de görülen bölgelere ait rüzgar potansiyeli haritaları oluşturulmuştur.




Şekil 4.6 İstasyonlara ait çevresel engel bilgileri.


Bu haritalarda istasyon çevresindeki alanda rüzgar tarlası kuruluma uygun alanlar renk skalası yardımıyla gözlemlenebilmektedir. Haritalardan da görüldüğü üzere Van ölçüm istasyonunun kuzeybatı bölgesinde bulunan alanın rüzgar potansiyeli  $24 \text{ W/m}^2$  civarlarında hesaplanmıştır. Bu şekilde potansiyeli yüksek olan bölgeler bir sonraki aşamada derin öğrenme ile tespit edilecek çalışma için referans olmuştur.

Yapılan çalışmalar sonucunda Erciş Bölgesi'nin rüzgar türbini kurmak açısından en iyi bölge olduğu tespit edilmiştir. Bölgeye ait rüzgar atlasından görülebileceği üzere hakim rüzgar yönünün güney batı doğrultusunda ve saniyedeki rüzgar hızının ise  $11.46 \text{ m/sn}$  olduğu tespit edilmiştir. Bölgeye ait hesaplanan güç yoğunluğu ise  $3940 \text{ W/m}^2$  olarak tespit edilmiştir.






**Van Bölgesi**




**Erciş Bölgesi**

Şekil 4.7 İstasyonlara ait rüzgar potansiyeli haritaları.





**Gevaş Bölgesi**





**Muradiye Bölgesi**

Şekil 4.7 İstasyonlara ait rüzgar potansiyeli haritaları (Devam).

**Özalp Bölgesi****Başkale Bölgesi**

Şekil 4.7 İstasyonlara ait rüzgar potansiyeli haritaları (Devam).



**Hakkari Bölgesi****Yüksekova Bölgesi**

Şekil 4.7 İstasyonlara ait rüzgar potansiyeli haritaları (Devam).

### 4.3. Derin Öğrenme


Çalışmanın derin öğrenme çalışılan tüm istasyonları kapsayan bölgeye ait uydudan alınan 35881 görüntü başka hiçbir veri olmadan sinir ağlarında giriş katmanı verisi olarak kullanılmak üzere tekrarlayan konvolüsyon ve havuzlama işlemleri ile sentezlenmiş ve çıkış katmanında hedef istasyonlara ait hız değerleri tahminlenmiştir. Derin öğrenme bölümünde Hakkari, Yüksekova, Başkale, Gevaş, Erciş, Muradiye ve Özalp istasyonlarına ait hız değerleri ve karşılık gelen uydu görüntüsü alanları tahminlemenin eğitim aşamasında, Van istasyonu hız değerleri ve karşılık gelen uydu görüntüsü alanları ise simülasyon aşamasında kullanılmıştır.

Uydu görüntülerinin sentezinin ardından her bir giriş veri seti 24 hücreye sahip resim piksellerine, 2 adet koordinat bilgisi ve 1 adet çıkış değerine sahip olmaktadır. Bu veri setleri seçilen istasyonun etrafındaki alanın zamana bağlı olarak oluşmuş hava hareketlerine göre şekillenmektedir. Görüntüler veri yoğunluğundan dolayı saatlik ölçümlerle elde edilen zaman serilerine göre düzenlenmiştir. Daha kısa ve daha yüksek çözünürlükte verilerin daha iyi sonuçlar yaratacağı yapılan kısa ölçekli testlerle tespit edilmiştir. Bu testlerde 10 dakikalık ölçümler kullanılmış ancak kullanılan donanımlar yüzünden genellenememiştir.

Uydu görüntülerinden elde edilen verilerin analizi için çalışma sürecinde birçok model oluşturulmuştur. Bu modellerden bazıları Matlab'dan hazır olarak gelen algoritmalarından oluşurken diğer bir kısmı ise çalışılan verilere özgü olarak oluşturulan yeni yapılardan oluşmaktadır. Özgün modellere ait çalışmalar, yapılan testlerin daha iyi donanımlarla yapılması gereğini doğurduğundan tez çalışması için vazgeçilmiştir. Bu çalışmalarda konvolüze katmanlarının filtrelenmesi yerine geri yayılım algoritması kullanarak güncellenme sağlanmıştır. Ancak oluşturulan ağ sistemi paralel işlemeye büyük ölçüde olanak tanımadığından sistemler daha yavaş döngüler üretmiştir. Bu nedenle öğrenme çok uzun zamanlar gerektirmektedir.

Bu yöntemle elde edilen sonuçlar, algoritmalara ait karşılaştırma ve elde edilen sonuçların da bulunduğu grafik Şekil 4.8'deki grafikte görülmektedir. Bu sonuçlara göre uydu görüntülerinin kullanımıyla elde edilen en başarılı sonuçları üreten algoritma %14.81'lik başarı oranıyla "trainrp" olmuştur. Sonuç grafiğinden görülebileceği üzere

bu başarı, 3 ara katman ve sırasıyla her bir katmanında 30, 30 ve 2 nöron bulunan modelin 5 defa tekrarlanmasıyla elde edilmiştir. Bu tekrarlamamanın sebebi Matlab programında ağırlık ve bias'ların rastgele oluşturulmasıdır. Bu durum programın her defasında farklı kombinasyonlar ve yaklaşımlar elde etmesini sağlar. Ağ her defasında maksimum yakınlığa eğilimlidir, ancak bu eğilim tekrarlama değerleri ile sınırlandırılır. Böylece ağda oluşan benzeşmelerin önüne geçilmektedir. Sınamaya yönelik olarak önceden belirlenen tekrarlama miktarları yakınlığa eğilimine karşı bir sınır oluşturmakta ve ağın her defasında aynı sonuçları üretmesine engel olarak rastgele değerlerle üretilen sonuçların farklı olarak gerçekleşmesini sağlar. Bu nedenle aynı koşullar altında gerçekleştirilen farklı denemeler sonucu en iyi model değeri saptanmaya çalışılmıştır. Bu tekrarlamaların performans değerlerine göre farklı algoritmalarla yapılan deneme sonuçları Şekil 4.8'deki grafikte görülmektedir.



Şekil 4.8 Uydu verileri kullanılarak yapılan tahminlemelerde kullanılan algoritmalar için nöron sayısına bağlı tahmindeki sapma yüzdeleri.

Grafiklerden görüldüğü üzere uydu verileri kullanılarak oluşturulan veri setlerinin hazırlanan modelde kullanılmasıyla elde edilen hata oranı %14.81 olmuştur. Bu yakınlığa daha iyi veri ve donanımlarla analiz yapılması durumunda gökyüzündeki hareketliliğin YSA tarafından tam olarak tahminlenebileceğini göstermektedir. Çalışılan sistem yalnızca belirli noktalar arasındaki oluşan hareketliliği


analiz etmektedir. Uydu resimleri ardışık olarak incelendiğinde bu hareketlilik çıplak gözle izlenebilmektedir. Ayrıca kızılötesi uydu resimleri incelendiğinde yüzey sıcaklıkları ve diğer birçok faktör bizim yorumlayamadığımız şekliyle veri kümesinin içinde belirmektedir. Bunların yapay sinir ağları ile analizi yoluyla çalışılan birçok alanda genel tahmin sistemleri oluşturulabilir.

Çalışmada dikkat çeken bir nokta, son katmandaki nöron sayısının 2 olarak seçilmesinin doğurduğu sonuçlar olmuştur. Aynı veri setleri ile daha yüksek nöron sayısı barındıran son katmanlı modellerin daha kötü sonuçlar ürettiği tespit edilmiştir. Bu durum birçok kombinasyon ile tekrarlanmış ancak her defasında aynı durumu karşılaşılmıştır. Veri setlerinin cinsine göre yapılan farklı denemelerde bu durumun aynı olduğu tespit edilmiştir. Nvidia 920M işlemcisiyle yapılan testlerde 3 katmanlı ve her bir katmanında 150 nöron bulunan bir modelin 3 katmanlı ve ilk ve ikinci katmanında 25, üçüncü katmanında ise 2 nöron bulunduran bir modelden daha kötü sonuçlar ürettiği tespit edilmiştir. Bu durum katman sayısı ve bu katmanlarda bulunan nöron sayısının ne denli etkili olabileceğini göstermiştir. Bu nedenle çalışmalar kısıtlı olsa, optimal sonuçların elde edilebilmesi için döngüler yardımıyla çeşitlendirilmeye çalışılmıştır. Bu döngülerden elde edilen sonuçlar ağ modellerinin kurulumunun belli bir mantığa dayanmadığını, yalnızca veriler arasındaki ilişkilere bağlı olarak çeşitlendiğini göstermiştir.

Algoritmaların tekrarlı denenmesi sonucu elde edilen en iyi performans sağlandığı durumdaki modele ait eğitim performans grafiği Şekil 4.9'da görülmektedir. Grafikten görüleceği üzere model en iyi performans değerine 140. döngüde ulaşabilmiştir. En iyi performans derecesi ise %1.88 olmuştur. Bu bölümde eğitim katsayısı olarak 0.35 alınmıştır.

Çalışmanın sonuçlandırılmasının ardından tüm tahmin değerleri ile gerçekleşen değerler arasında oluşan qq-plot grafiği Şekil 4.10'da görülmektedir. Grafikte ağ çıktılarının gerçek değerlerle örtüştüğü görülmektedir. 0-8 m/sn arasında dar bir skalaya sahip ölçüm değerlerinin bu denli yakın olarak tahmin edilmesi yapay sinir ağlarının etkinliğini göstermektedir. Grafikte mavi çizgi ile gösterilen değerler tahmin değerleri, turuncu çizgi ile gösterilen değerler ise gerçekleşen değerleri ifade etmektedir. Grafikte + ile gösterilen oluşumlar bu verilerin dağılımlarını göstermektedir. Noktalı çizgi ile

görülen doğrusal çizgiler ise bu iki topluluk arasındaki sapma oranını göstermektedir. Grafikten de anlaşıldığı gibi her iki topluluk arasındaki farklılık minimum düzeydedir. Yüzde yüzlük bir benzeşme ağırlık çıktılarda ezberlemeye gittiğini gösterecektir.




Şekil 4.9 Uydu verileri kullanılarak oluşturulan modelin eğitim performans grafiği.

Bu istenmeyen bir durumdur. Modelin böyle bir durumla sonuçlanması durumunda yapılacak farklı verilerde büyük sapmaların oluşması beklenir. Ya da sonuç veriler arasında doğrusal bir ilişki olduğunu belirtecektir. Bu durumda da YSA kullanımına gerek olmadığı sonucu ortaya çıkacaktır. Doğa olaylarının bu şekilde gerçekleşmediği göz önüne alındığında modelin bu şekilde oluşması veri setinin içindeki ilgili bölümleri analiz edebildiğini ve rüzgar hızı ile ilişkilendirebildiğini göstermektedir. Veri setindeki artışlar sistemin tahmin kabiliyetini arttırmaktadır. Bu durum ilişkilerin karmaşıklığına bağlı olarak değişmektedir. Rüzgar hızı gibi doğal bir olayın tahmininde birçok etken sonuçları şekillendirebilmektedir. Bu etken değerlerinin tümünün birkaç veri seti içerisinde karşılık bulması olası değildir. Bu nedenle gerekli hassasiyet derecesinde veri setlerinin düzenlenmesi gerekmiştir. Çalışmada kullanılan veri setleri yoğun görünse de sonuçların olumlu yönde elde edilmesinde bu veri setinin büyüklüğü etkili olmuştur. Bölgelere ait yapılan çalışmalarda öncelikle bölgelerin tümü 2 parçaya bölünmüş ve 4 istasyon ile eğitim ve doğrulama işlemleri yapılırken diğer 4



istasyonla da tahminleme yapılmıştır. Ancak veri setleri yetersiz kaldığından kullanılan model yeterli yaklaşımı sağlayamamıştır. Ancak bu durum diğer istasyonların da eğitime katılmasıyla düzeltilmeye çalışılmıştır. Eğitim safhasına eklenen her bir bölge verisi çeşitliliği arttırdığından sonuçlara pozitif yönde etkide bulunmuştur.



Şekil 4.10 Ağ oluşturulduktan sonra uydu verileri kullanılarak Van istasyonu için tahmin edilen hızların gerçek hızlarla karşılaştırması.

Bu analizlerin daha yüksek çözünürlükte ve daha iyi donanımlarla yapılması durumunda daha iyi sonuçlar elde edilebileceği yapılan testlerle anlaşılmıştır. Ayrıca oluşturulan diğer bazı modellerde uydu görüntülerinin RGB biçiminde 3 katmanlı olarak analiz edilmesinin sonuçları olumlu yönde etkilediği tespit edilmiştir. Ancak bu uydu görüntülerinin çalışılan veri aralığında Eumetsat üzerinden istenilen veri formatıyla elde edilememesinden dolayı çalışma bu tür bir sistem üzerinden devam ettirilememiştir.

Yapılan çalışmada, uydu görüntüsü kullanılarak oluşturulan modellerde, farklı bölgelere ait genel bir ağ yapısı oluşturulabileceği, böylece bölgelere özgü ağ sistemlerinden kurtulup uydu görüntü alanının geneli için hata oranı düşük tahminler yapılabileceği tespit edilmiştir. Sistemin her defasında baştan eğitilmesi yerine yeni verilerin ağa dahil edilmesiyle, genel görüntü alanında anlık izlenebilecek sistemler

kurulabileceđi ve böylece havacılık, denizcilik, kara hareketleri ve diđer birçok alandaki sistem davranışları için tahmin başarısı yüksek anlık öngörü sistemleri oluşturulabileceđi düşünölmektedir.





## 5. SONUÇ

Yapay zeka alanında yapılan çalışmalar ve geliştirilmiş olan sistemlerin hava hareketlerini tahmin etmek açısından başarısı çalışmada bir kez daha kanıtlanmıştır. Doğası gereği çok karmaşık etkiler altında şekil değiştiren rüzgar hızının tahmini oldukça zor olmaktadır. Ancak bu etkilerin sonuçları rüzgar hızı gibi gözlemlediğimiz diğer sistemlere de etki etmektedir. Bu etkileri genelleyecek bir matematiksel modeli her bölge için uyarlamak imkansız bir durumdur. Bu noktada ölçülebilen diğer etkenlerdeki kaotik yapının yapay sinir ağlarında anlam bulması bize büyük kolaylık sağlamaktadır. Böylece her bölge ya da her durum için ayrı bir denklem oluşturmaktansa bu durumlara adaptasyonu sağlayacak bir sistemin yol göstermesi doğayı anlamamızda bize daha büyük avantajlar sağlayacaktır. Günümüzde hemen her alanda etkisini göstermeye başlamış olan yapay zeka sistemleri insanların yerine karar verebilecek noktaya kadar evrimleşmiştir. Bu noktada hava olayları gibi bize doğal enerji kaynağı oluşturabilecek sistemlerin bu tür tekniklerle analiz edilmesi ve kontrollerinin bu şekilde optimize edilmeye çalışılması şüphesiz ilerde varacağımız bir noktadır. Ayrıca günümüz teknolojisinin sürekli olarak bilgisayar kontrollü olması bu alandaki kontrollerin hızlı gerçekleşmesini sağlamaktadır.


İnsanlar durmadan doğayı kirletmekte ve telafisi mümkün olmayan izler bırakmaktalar. Artan enerji talebi üzerine oluşan çevre kirliliği çocuklarımız için karanlık bir gelecek oluşturmaktadır. Bu durumun telafî edilebilmesi için, yoğun insan nüfusu ihtiyaçlarını çevreye zarar vermeden karşılayabilecek kadar hızlı sistemler geliştirmek gerekmektedir. Bu durum insanoğlunun cevap verebileceği bir çözümlenmeden çok uzaktır. Bu nedenle sahip olduğumuz teknolojiyi en üst düzeyde kullanmamız gerekmektedir. Bu dünya üzerindeki her bir bireyin sorumluluğudur. Buzulların erimesi yalnızca Avrupadaki ya da Asyadaki çocukları etkilemeyecektir. Tüm dünya için çözüm bulunması gereken acil bir sorundur. Bu nedenle yapay zeka alanındaki çalışmaların bu kategorilerde acilen düzenlenmesi gerekmektedir. Bu güne kadar insan etkisi nedeniyle optimum bir düzeyde kullanılmayan doğal enerji kaynaklarının insan müdahalesinin dışarıda bırakılabileceği yenilikçi sistemlerle

çözümlemelidir. Yapay zeka alandaki gelişmeler bunu sağlayabilecek güçte görünmekte ve gelecek için umut vermektedir.

Bu çalışmada uygulanmaya çalışılan teknikler doğal enerji kaynaklarının potansiyellerinin tespit edilmesine yönelik olmuştur.

### 5.1. Yapay Sinir Ağları

Çalışmanın YSA bölümünde Meteoroloji Genel Müdürlüğü'nün Van Merkezinde bulunan ölçüm istasyonunda ölçülen rüzgar hızı değerleri tahmin edilmeye çalışılmıştır. Bu tahminlemedeki başarı oranı eğitim giriş katmanında rüzgar yönü, sıcaklık, basınç, nem ve rakım kullanıldığında %89 olmuştur. Bu istasyonlarda ölçülen rüzgar hızlarının birbirine çok yakın değerler içermesi tahmin olasılığını düşürmesine rağmen YSA yüksek başarı oranıyla tahminlemede bulunabilmiştir. Kullanılan verilerin ilişki durumu gösteren grafikler aşağıda Şekil 5.1'de görülmektedir.



Şekil 5.1 MGM verilerinin ilişki durumları.

Şekilde kullanılan eğitim veri setindeki giriş elemanlarının arasında doğrusal hiçbir ilişkinin bulunmadığı görülebilmektedir. Ayrıca aynı popülasyona sahip veri kümelerinin zaman serisine bağlı aralık değerlerinin çok düşük olduğu görülmektedir. 25x25x2 ara katman ve nöron sayısına sahip YSA modeli bu denli bir düzensizliğin çözümünde büyük bir başarı göstermiştir.

Ancak bu sistemde tahminlenecek her bölge için eğitim giriş verilerin toplanması gerekmektedir. Bu durum genel bir yaklaşım sağlanmasını engellemektedir. Rüzgar potansiyelinin bölgenin genelinde hesaplanabilmesi her bölgede benzer giriş verilerinin toplanmasına bağlı kalmaktadır. Bu potansiyelin bölge genelinde belirlenmesi için büyük bir engel teşkil etmektedir. Bu nedenle çalışmada daha az ölçüm verisiyle genel bir yaklaşım sağlayabilmek amacıyla derin öğrenme yöntemi geliştirilmiştir.

## 5.2. Derin Öğrenme

Yapılan çalışmanın derin öğrenme kısmında, doğal enerji kaynaklarının potansiyellerinin belirlenmesinde genellenebilecek bir sistem geliştirilmeye çalışılmıştır. Elde edilen bulgular sonucunda, dünya genelinde yaygın olarak kurulan sistemler için yeterli öngörüü sağlayabilecek %85 doğruluk değerinde bir performans elde edilebildiği tespit edilmiştir. Bu yaklaşımın iyileştirilmesi için gerekli yol ve yöntemler aşağıda sıralanmaktadır.

- 1- Çözünürlüğü yüksek ve hedeflenen tahmin sonucu ile alakalı daha ayrıntılı bilgiyi içeren görüntüler ile eğitimin yapılması
- 2- Konvolüsyonda kullanılan filtre sayısının arttırılması
- 3- Eğitime alınacak veri miktarının arttırılması
- 4- Eğitime girecek veri setlerindeki ölçüm zaman aralığının daraltılması.
- 5- Yüksek sayıda paralel işlem çekirdeklerine sahip işlemcilerle daha derin modellerde işlem yapılması
- 6- Eğitime giren istasyon koordinatlarının net bir biçimde görüntü üzerinde tespit edilmesi
- 7- Eğitimin her bir veri setinde kullanılan önceki zamanlara ait görüntü sayısının arttırılması

Çalışmada kullanılan veri setleri 1 saat aralıklı ölçümlerle elde edilmiştir. Bu zaman aralığının 10 dakika yada daha az bir süreye çekilmesi pikseller arasındaki geçişlerin daha iyi izlenebilmesini sağlayacaktır. 1 saatlik aralıkta bile %85 oranında

performans sağlanması derin öğrenme açısından büyük bir başarıdır. Uydu görüntülerinin anlık olarak analize katılmaları için gerekli olan sistem çalışmada kullanılabilmiştir. Bu durum eğitimde süreklilik arz ettiğinden dolayı olası tahminlemelerin yakın zamanda oluşan değişimlere göre yapılabilmesini ve doğruluk oranının daha iyi olmasını sağlayacaktır. Böyle bir sistem havacılıktan denizciliğe kadar birçok alanda, anlık müdahale için daha yetkin kararlar alınabilmesini sağlayacaktır.

Çalışmada kullanılan uydu görüntülerinin çözünürlükleri çok düşük seviyelerdedir. Aguera (2016), TED Paris'te yaptığı bir sunumda Google tarafından geliştirilen derin öğrenme modelinin görüntülerde ne kadar derin ilişkiler oluşturabildiğini göstermiştir. Ancak yapılan eğitimlerdeki verilerin sadeliği her zaman daha iyi sonuçlar elde edilmesini sağlamıştır. Bu nedenle atmosferik hareketlerin daha alt tabakadaki değişimlerini daha ayrıntılı olarak gözlemleyen uydu görüntülerinin ölçüm istasyonları seviyelerindeki tahminleme sonuçlarını olumlu yönde etkileyebileceği mutlaklıdır.

Konvolüsyonda kullanılan filtreler görüntüdeki ilişkilerin farklı yönlerden ele alınabilmesini sağlamaktadır. Ağa giren her farklı evrimsel katman gözlemlenen durum ile ilgili bilgi miktarını arttırmakta ve ilişkilerin daha iyi anlaşılabilmesini sağlamaktadır. Bu durumun performans üzerindeki olumlu etkileri yapılan çalışmada tespit edilmiştir. Ayrıca tahminlenmek istenen zaman ve bölgeye ait eğitim veri giriş setinin önceki zamanlara ait bilgiyi içermesinin sonuç getirdiği tespit edilmiştir. Belli bir zamana ait uydu görüntüleri analiz edilirken bu zamandan önce gerçekleşmiş görüntüler de işleme dahil edilmiştir. Bu geçmiş görüntü sayısının artırılması tahminlemeyi olumlu yönde etkilemektedir.

Çalışma sonucunda elde edilen bir diğer bulgu ise derin modellerle çalışmanın daha iyi performanslar sağladığıdır. Daha derin sistemler ise yüksek işlem yeteneğine sahip donanımlar gerektirmektedir. Yüksek işlem yeteneğine sahip donanımlarla analiz edilebilecek daha derin ağların atmosferik hareketlerden daha iyi tahmin sonuçları üretebileceği yapılan sistem ve model değişiklikleri ile tespit edilmiştir.

Yapılan çalışmada tahminlenmek istenen istasyon koordinatlarına karşılık gelen görüntü pikselleri Google Earth'e aktararak tespit edilmeye çalışılmıştır. Görüntülerin çok yüksek çözünürlüğe sahip olmaması ve piksel boyutlarının büyük olması bu

karşılaştırmanın yaklaşık olarak doğru yapılmasına olanak sağlamıştır. Ancak görüntüyü alan uydu sisteminin net bir şekilde belirleyebileceği noktasal koordinatların sonuçların daha iyi analiz edilmesini sağlayacağı düşünülmektedir. Yapılan konvolüzyon bu seçilen merkezi ve etrafındaki sınırlı sayıdaki pikselleri işlemektedir. Bu nedenle istasyon koordinatlarının resim üzerinde doğru belirlenmesi önem teşkil etmektedir.

### 5.3. Çalışılan İstasyonlara ait Rüzgar Potansiyeli

Yapılan çalışmada, MGM'den alınan ölçüm istasyonlarına ait hız ve yön verileri WASP programında kullanılarak istasyonların bulunduğu alanın çevresindeki 3 km çapındaki alanda rüzgar potansiyeli belirlenmiştir. Elde edilen sonuçlara göre en yüksek potansiyele sahip bölge Erciş ölçüm istasyonunun bulunduğu alan olmuştur. Çizelge 5.1'de tüm istasyonlara için rüzgar potansiyeli ve rüzgar güllerinden elde edilen sonuçlara ait tablo görülmektedir.

Çizelge 5.1 Çalışmadaki tüm istasyonlara ait rüzgargülü ve potansiyel hesap sonuçları

İstasyonlar	Ortalama Rüzgar Hızı (m/s)	Rüzgar Potansiyeli (W/m <sup>2</sup> )		Hakim Rüzgar Yönü
		Ortalama	En Yüksek	
Van	1.85	20	24	Kuzeybatı - Doğu
Erciş	11.46	3677	6003	Güneybatı
Gevaş	1.62	33	76	Güneybatı
Muradiye	1.93	45	63	Kuzeybatı
Özalp	2.02	118	331	Güneybatı- Kuzeydoğu
Başkale	1.86	22	25	Güneybatı- Kuzeydoğu
Hakkari	1.96	50	177	Güneydoğu
Yüksekova	1.84	59	144	Kuzeydoğu



Görüldüğü üzere Erciş'deki hakim rüzgar yönü Güneybatı doğrultusundadır. Bu sektörde rüzgarın esme yoğunluğunun yıl genelinde çok yüksek olduğu görülmektedir. Diğer sektörlerde rüzgar esme sıklığının çok düşük olması rüzgar türbinleri açısından türbülans oranının çok düşük olmasını sağlamaktadır. Bu durum türbin ömrünü arttırmaktadır. Ayrıca potansiyel atlasında yıl genelinde ortalama rüzgar hızının 11.46 m/sn olduğu görülmektedir. Bu kurulması planlanan 3-25 m/sn aralığında çalışmakta olan türbinler için çok iyi bir ortalama değer olarak kabul edilmektedir. Potansiyel atlasında metrekare başına hesaplanan ortalama rüzgar gücü ise 3940 W/m<sup>2</sup> olarak hesaplanmıştır. Bu sonuçlara göre Erciş bölgesinin rüzgar tarlası kurulması açısından güçlü bir yapıya sahip olduğu görülmektedir.

Ancak WAsP ile hesaplanan sonuçlar istasyon ve çevresindeki 3 km yarıçapındaki alanı kapsadığından dolayı bölgenin genel potansiyeli bu yöntemle belirlenememektedir. Sonuçlar ancak ölçüm istasyonlarının etrafındaki alanları kapsamaktadır. Çalışma bu nedenle Van ve Hakkari illerinin genel potansiyelini tümüyle yansıtmamaktadır.

## KAYNAKLAR

- Aguera, B., 2016. How computers are learning to be creative. [https://www.ted.com/talks/blaise\\_aguera\\_y\\_arcas\\_how\\_computers\\_are\\_learning\\_to\\_be\\_creative#t-2381](https://www.ted.com/talks/blaise_aguera_y_arcas_how_computers_are_learning_to_be_creative#t-2381). TED Talks, Paris, Fransa. Erişim tarihi: 06.09.2017.
- Akçayol, M., 2017. **WEB Madenciliği Ders Notları**. Bilgisayar Mühendisliği Bölümü, GÜ, Bilgisayar Mühendisliği Fak., Ankara. 19.
- Anonim, 2016. **Yapay Sinir Ağları**. <http://kod5.org/yapay-sinir-aglari-ysa-nedir/>. Kod5, eğitim, kodlama, paylaşım, İstanbul. Erişim Tarihi: 17.03.2017.
- Ata, R., 2014. Akhisar Bölgesi İçin Ortalama Rüzgar Hızlarına Bağlı Rüzgar Esme Sürelerinin Yapay Sinir Ağları İle Tahmini. **Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi**, **20** (5): 162-165.
- Al-Yahyai, S., Tan, C.S., AL-Hatmi, Y., Al-Badi, A., 2016. Wind resource assessment over Al Duqm industrial area in Oman. **Arabian Journal of Geosciences**, **9**: 296-303.
- Bastien, F., Lamblin, P., Pascanu, R., Bergstra, J., Goodfellow, I., Bergeron, A., Bouchard, N., Warde-Farley, D., Bengio, Y., 2012. Theano: new features and speed improvements. Cornell University, **arXiv**: 1211.5941.
- Beale, M.H., Hagan, M.T., Demuth, H.B., 2017. **Neural Network Toolbox**. The MathWorks, Inc., Hill Drive Natick, USA. 840.
- Bengio, Y., Lamblin, P., Popovici, D., Larochelle, H., 2006. Greedy layer-wise training of deep networks, **Advances in Neural Information Processing Systems 19 (NIPS 2006)**. 4-7 Aralık 2006, Montreal. 153–160.
- Bergstra, J., Breuleux, O., Bastien, F., Lamblin, P., Pascanu, R., Desjardins, G., Turian, J., Warde-Farley, D., Bengio, Y., 2010. Theano: a CPU and GPU math expression compiler. **Proceedings of the Python for Scientific Computing Conference (SciPy)**. 28 Haziran-3 Temmuz 2010, Austin, Texas. 3-10.
- Bilgiç, H.H., Mert İ., Karakuş, C., Yapıcı, A., 2016. Antakya Bölgesi Rüzgar Hızı Verisinin Yapay Sinir Ağı ve Çoklu Lineer Regresyon Yaklaşımı Yöntemleri İle Tahmini. **EEB 2016 Elektrik Elektronik ve Bilgisayar Sempozyumu**, 11-13 Mayıs 2016, Tokat, 120-126.
- Bilgili, M., Şahin, B., Kahraman, A., 2004. Wind energy potential in Antakya and Iskenderun regions, Turkey. **Renewable Energy**, **29**: 1733-1745.
- Bilgili, M., 2007. **Predictions Of Wind Speed and Wind Power Potential Using Artificial Neural Networks** (doktora tezi), ÇÜ, Fen Bilimleri Enstitüsü, Balcalı, Adana.
- Bilgili, M., Şahin, B., Şimşek, E., 2010. Ege Bölgesindeki Toprak Sıcaklıklarının Yapay Sinir Ağları Yöntemi İle Belirlenmesi. **Isı Bilimi ve Tekniği Dergisi**, **30** (1): 121-132.
- Bilgili, M., 2010. Prediction of soil temperature using regression and artificial neural network models. **Meteorology and atmospheric physics**, **110** (1): 59-70.
- Boudia, S.M., Berrached, S., Bouri, S., 2016. On the use of wind energy at Tlemcen, North-western region of Algeria. **Energy Procedia**, **93**: 141-145.
- Cadenas, E., Rivera, W., 2010. Wind speed forecasting in three different regions of Mexico, using a hybrid ARIMA-ANN model. **Renewable Energy**, **35**: 2732-2738.
- Cao, Q., Ewing, B.T., Thompson, M.A., 2012. Forecasting wind speed with recurrent neural Networks. **European Journal of Operational Research**, **221**: 148–154.

- Carvalho, D., Rocha, A., Santos, C.S., Pereira, R., 2013. Wind resource modelling in complex terrain using different mesoscale–microscale coupling techniques. *Applied Energy*, **108**: 493–504.
- Cireşan, D.C., Meier, U., Masci, J., Gambardella, L.M., Schmidhuber, J., 2011. Flexible, high performance convolutional neural networks for image classification. *Proceedings of the 22nd International Joint Conference on Artificial Intelligence (IJCAI 2011)*. 16–22 Temmuz 2011, Barcelona, Catalonia, Spain. 1237–1242.
- Çetin, F., 2003. *Yapay Sinir Ağlarıyla Rüzgar Şiddeti Tahmini* (yüksek lisans tezi). İTÜ, Fen Bilimleri Enstitüsü, Sarıyer, İstanbul.
- Çam, E., Arcaklıoğlu, E., Çavusoglu, 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.
- Deo, R.C., Şahin, M., 2017. Forecasting long-term global solar radiation with an ANN algorithm coupled with satellite-derived (MODIS) land surface temperature (LST) for regional locations in Queensland. *Renewable and Sustainable Energy Reviews*, **72**: 828–848.
- Díaz-Vico, D., Torres-Barran, A., Omari, A., Dorronsoro, J.R., 2017. Deep Neural Networks for Wind and Solar Energy Prediction. *Neural Process Letters*, **46**: 829–844.
- Đurisić, Z., Mikulović, J., 2012. A model for vertical wind speed data extrapolation for improving wind resource assessment using WAsP. *Renewable Energy*, **41**: 407–411.
- Egrioglu, E., Aladag, C.H., Yolcu U., Uslu, V.R., Basaran, M.A., 2009. A new approach based on artificial neural networks for high order multivariate fuzzy time series. *Expert Systems with Applications*, **36** (7): 10589–10594.
- Erhan, D., Bengio, Y., Courville, A., Antoine, P., Vincent, M.P., Bengio, S., 2010. Why Does Unsupervised Pre-training Help Deep Learning?. *Journal of Machine Learning Research*, **11**: 625–660.
- Ersoz, S., Akinci, T.Ç., Selcuk, H.N., Dogan, G., 2013. Determination of Wind Energy Potential in Kirklareli-Turkey. *International Journal of Green Energy*, **10**: 103–116.
- Filik, Ü.B., Filik, T., 2017. Wind Speed Prediction Using Artificial Neural Networks Based on Multiple Local Measurements in Eskisehir. *Energy Procedia*, **107**: 264–269.
- Feigenbaum, E.A., Feldman, J., 1963. *Computer and Thought*. McGraw-Hill Book Company, USA. 535.
- Li, F.F., Johnson, J., Yeung, S., 2017. Lecture 5 | Convolutional Neural Networks. <https://www.youtube.com/watch?v=bNb2fEVKeEo>. Stanford University School of Engineering, Stanford, California. Erişim tarihi: 18.04.2017.
- Gates, B., 2010. Changing to zero. <https://www.youtube.com/watch?v=JaF-fq2Zn7I>. TED Talks, Longbeach, California. Erişim tarihi: 01.02.2017.
- Glorot, X., Bengio, Y., 2010. Understanding the difficulty of training deep feedforward neural networks. *JMLR W&CP: Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics (AISTATS 2010)*, 13–15 Mayıs 2010, Chia Laguna, Sardinia, Italy. 249–256.

- Glorot, X., Bordes, A., Bengio, Y., 2011. Deep sparse rectifier neural Networks. *JMLR W&CP: Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics (AISTATS 2011)*, 11-13 Nisan 2011, Ft.Lauderdale, FL,USA. 315-323.
- Gülersoy, T., Çetin, N.S., 2010. Menemen Bölgesinde Rüzgar Türbinleri için Rayleigh ve Weibull Dağılımlarının Kullanılması. *Politeknik Dergisi*, **13** (3): 209-213.
- Güzel, B., 2012. *Açık Deniz Rüzgar Enerjisi, Fizibilite Adımları ile Bozcaada ve Gökçeada Örnek Çalışması* (yüksek lisans tezi). İTÜ, Enerji Enstitüsü, Sarıyer, İstanbul.
- Güzel, S., 2014. *Rüzgar Enerjisi Potansiyel Hesaplamasında Kullanılan Bilgisayar Programlarının Karşılaştırılması* (yüksek lisans tezi). İTÜ, Enerji Enstitüsü, Sarıyer, İstanbul.
- Gryning, S.E., Batchvarova, E., Floors, R., Peña, A., Brümmer, B., Hahmann, A.N., Mikkelsen, T., 2014. Long-Term Profiles of Wind and Weibull Distribution Parameters up to 600 m in a Rural Coastal and an Inland Suburban Area. *Boundary-Layer Meteorology*, **150**: 167–184.
- Hanslian, D., Hosek, J., 2015. Combining the VAS 3D interpolation method and Wind Atlas methodology to produce a high-resolution wind resource map for the Czech Republic, *Renewable Energy*, **77**: 291–299.
- Hawking, S., 2017. Leave to earth. <https://www.bbc.com/turkce/haberler-dunya-40355145>. BBC News, London, UK. Erişim tarihi: 21.06.2017.
- He, K., Zhang, X., Ren, S., Sun, J., 2015. Delving deep into rectifiers: Surpassing human-level performance on imagenet classification. Cornell University, *arXiv*: 1502.01852.
- Himri, Y., Himri, S., Stambouli, A.B., 2010. Wind power resource in the south-western region of Algeria. *Renewable and Sustainable Energy Reviews*, **14**: 554–556.
- Hinton, G.E., Osindero, S., Teh, Y.W., 2006. A Fast Learning Algorithm for Deep Belief Nets, Massachusetts Institute of Technology. *Neural Comput*, **18** (7): 1527-1554.
- Hinton, G.E., Salakhutdinov, R.R., 2006. Reducing the dimensionality of data with neural networks. *Science*, **313** (5786): 504–507.
- Hocaoğlu, F.O., Kurban, M., Filik, Ü.B., 2008. *WAsP Yazılımı ile Rüzgar Potansiyeli Analizi ve Uygulama*. AÜ, Mühendislik-Mimarlık Fakültesi, Eskişehir.
- Hu, Q., Zhang, R., Zhou, Y., 2016. Transfer learning for short-term wind speed prediction with deep neural Networks. *Renewable Energy*, **85**: 83-95.
- Indasi, V.S., Lynch, M., McGann, B., Yu, F., Jeanneret, F., Sutton, J., 2016. WAsP model performance verification using lidar data. *International Journal of Energy and Environmental Engineering*, **7**: 105–113.
- Jia, Y., Shelhamer, E., Donahue, J., Karayev, S., Long, J., Girshick, R.B., Guadarrama, S., Darrell, T., 2014. Caffe: Convolutional architecture for fast feature embedding. Cornell University, *arXiv*: 1408.5093.
- Kaya, Ü., Caner, M., Oğuz, Y., 2016. Kastamonu İlinin Rüzgar Enerjisi Potansiyelinin Yapay Sinir Ağları (YSA) ile Tahmin Edilmesi. *Elektrik-Elektronik ve Bilgisayar Sempozyumu (EEB 2016)*. 11-13 Mayıs 2016, Tokat, Türkiye. 153-157.
- Kazet, M.Y., Mouangue, R., Kuitche, A., Ndjaka, J.M., 2016. Wind energy resource assessment in Ngaoundere locality. *Energy Procedia*, **93**: 74–81.

- Koo, J., Han, G.D., Choi, H.J., Shim, J.H., 2015. Wind-speed prediction and analysis based on geological and distance variables using an artificial neural network: A case study in South Korea. *Energy*, **93**: 1296-1302.
- Ko, K., Kang, M., Huh, J., 2009. Year-to-year variation in wind resource and assessment of WAsP prediction for wind machine power. *Journal of Mechanical Science and Technology*, **23**: 750-757.
- Kumara, G., Malik, H., 2016. Generalized Regression Neural Network Based Wind Speed Prediction Model For Western Region Of India. *Procedia Computer Science*, **93**: 26 – 32.
- Krizhevsky, A., Sutskever, I., Hinton, G.E., 2012. Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems 25* (Editor: Pereira, F., Burges, C., Bottou, L., Weinberger, K.), 1097–1105.
- LeCun, Y., 1988. *A Theoretical Framework for Back-Propagation, Proceedings of the 1988 Connectionist Models Summer School*. CMU, Pittsburgh, Morgan Kaufman: 21-28.
- Lo'pez, P., Velo, R., Maseda, F., 2008. Effect of direction on wind speed estimation in complex terrain using neural Networks. *Renewable Energy*, **33**: 2266–2272.
- Mathew, S.A., Mariappan, V.E.N., 2014. Wind Resource Land Mapping using ArcGIS, WAsP and Multi Criteria Decision Analysis (MCDA). *Energy Procedia*, **52**: 666 – 675.
- Meral, M.E., 2016. *Yapay Sinir Ağları Ders Notları*. YYÜ, Elektrik-Elektronik Mühendisliği Anabilim Dalı, Van.
- Mculloch, W.S., Pitts, W., 1943. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, **5**: 115-133
- Mohandes, M.A., Rehman, S., Halawani, T.O., 1998. A Neural Networks Approach For Wind Speed Prediction. *Renewable Energy*, **13**: 345-354.
- Monfared, M., Rastegar, H., Kojabadi, H.M., 2009. A new strategy for wind speed forecasting using artificial intelligent methods. *Renewable Energy*, **34**: 845–848.
- Nabiyev, V., 2016. *Yapay Zeka*. 5. Baskı. Seçkin Yayıncılık, Ankara, Türkiye. 776.
- Noorollahi, Y., Jokar, M.A., Kalhor, A., 2016. Using artificial neural networks for temporal and spatial wind speed forecasting in Iran. *Energy Conversion and Management*, **115**: 17–25.
- Njoroge, J.B., Nakamura, A., Morimoto, Y., 2000. Surface Temperature Estimation From Airborne Imagery Using Neural Network Model. *Bio-robotics, Information Technology, and Intelligent Control for Bio-Production Systems*. 25-26 Kasım, Sakai, Osaka, Japan. 599-8531.
- Nouri, A., Babram, M.A., Elwarraki, E., Enzili, M., 2016. Moroccan wind farm potential feasibility. Case study. *Energy Conversion and Management*, **122**: 39–51
- Onat, N., Ersoz, S., 2011. Analysis of wind climate and wind energy potential of regions in Turkey. *Energy*, **36**: 148-156.
- Öztopal, A., Şen, Z., 2009. Kısa Vadeli Yağış Modellemesi İçin Yapay Sinir Ağları Yaklaşımı. *İTÜ Mühendislik Dergisi*, **8** (1): 83-94.
- Pekmezci, M., 2012. *Kısıtlanmış Boltzman Makinesi ile Zaman Serilerinin Tahmini* (yüksek lisans tezi). Maltepe Ü., Fen Bilimleri Enstitüsü, İstanbul.

- Petkovic', D., 2015. Adaptive neuro-fuzzy approach for estimation of wind speed distribution. *Electrical Power and Energy Systems*, **73**: 389–392.
- Philippopoulos, K., Deligiorgi, D., 2012. Application of artificial neural networks for the spatial estimation of wind speed in a coastal region with complex topography. *Renewable Energy*, **38**: 75–82.
- Pusat, Ş., 2017. Sakarya Üniversitesi için rüzgar enerjisi potansiyel belirleme çalışması. *Pamukkale Üniversitesi Mühendislik Bilim Dergisi*, **23** (4): 352-357.
- Qureshi, A.S., Khan, A., Zameer, A., Usman, A., 2017. Wind power prediction using deep neural network based meta regression and transfer learning. *Applied Soft Computing*, **58**: 742–755.
- Ranganayaki, V., Deepa, S. N., 2016. An Intelligent Ensemble Neural Network Model for Wind Speed Prediction in Renewable Energy Systems. *The Scientific World Journal*: 1-14.
- Saha, M., Mitra, P., Nanjundiah, R.S., 2017. Deep learning for predicting the monsoon over the homogeneous regions of India. *Indian Academy of Sciences, Journal of Earth System*, **126**: 54.
- Sahin, B., Bilgili, M., Akilli, H., 2005. The wind power potential of the eastern Mediterranean region of Turkey. *Journal of Wind Engineering and Industrial Aerodynamics*, **93**: 171–183.
- Sahin, B., Bilgili, M., 2009. Wind Characteristics and Energy Potential in Belen-Hatay, Turkey. *International Journal of Green Energy*, **6**: 157–172.
- Salakhutdinov, R. and Hinton, G., 2009. Deep Boltzmann machines. *Twelfth International Conference on Artificial Intelligence and Statistics (AISTATS 2009)*. 16-19 Nisan, 2009, Clearwater, Florida, USA. 448–455.
- Scherer, D., Müller, A., Behnke, S., 2010. Evaluation of Pooling Operations in Convolutional Architectures for Object Recognition. *20th International Conference on Artificial Neural Networks (ICANN)*. September 2010, Thessaloniki, Greece. 92-101.
- Sempreviva, A.M., Barthelmie, R.J., Pryor, S.C., 2008. Review of Methodologies for Offshore Wind Resource Assessment in European Seas. *Surveys in Geophysics*, **29**: 471–497.
- Serrano, L., 2017. A Friendly Introduction To Convolutional Neural Networks And Image Recognition. <https://www.youtube.com/watch?v=2-OI7ZB0MmU>. Udacity, USA. Erişim tarihi: 20.03.2017.
- Sharma, K., Ahmed, M.R., 2016. Wind energy resource assessment for the Fiji Islands: Kadavu Island and Suva Peninsula. *Renewable Energy*, **89**: 168-180.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., Salakhutdinov, R., 2014. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, **15**: 1929-1958.
- Troen, I., Petersen, E.L., 1989. *European Wind Atlas*. Technical University of Denmark, Risø National Laboratory, Roskilde, Danimarka. 656.
- Talayoğlu, S., 2010. *Denizli İlinin Tavas İlçesine ait Rüzgar Enerjisi Potansiyelinin Hesaplanması ve Ekonomik Analiz* (yüksek lisans tezi). İTÜ, Fen Bilimleri Enstitüsü, İstanbul.
- Velo, R., López, P., Maseda, F., 2014. Wind speed estimation using multilayer perceptron. *Energy Conversion and Management*, **81**: 1–9.



- Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y., Manzagol, P.A., 2010. Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion. *Journal of Machine Learning Research*, **11**: 3371-3408.
- Wang, H., Li, G., Wang, G., Peng, J., Jiang, H., Liu, Y., 2017. Deep learning based ensemble approach for probabilistic wind power forecasting. *Applied Energy*, **188**: 56–70.
- Wang, D., Luo, H., Grunder, O., Lin, Y., 2017. Multi-step ahead wind speed forecasting using an improved wavelet neural network combining variational mode decomposition and phase space reconstruction. *Renewable Energy*, **113**: 1345-1358.
- Wang, J., Zhang, W., Li, Y., Wang, J., Dang, Z., 2014. Forecasting wind speed using empirical mode decomposition and Elman neural network. *Applied Soft Computing*, **23**: 452–459.
- Yaşar, A., Simsek, E., Bilgili, M., Yucel, A., Ilhan, I., 2012. Estimation of relative humidity based on artificial neural network approach in the Aegean Region of Turkey. *Meteorology and Atmospheric Physics*, **115**: 81–87.
- Yayla, S., 2005. *Van Gölü Kıyısının Rüzgar Enerjisi Potansiyelinin Belirlenmesi* (yüksek lisans tezi). YYÜ, Fen Bilimleri Enstitüsü, Van.
- Zaccheus, O.O., 2014. A 5-day wind speed & power forecasts using a layer recurrent neural Network. *Sustainable Energy Technologies and Assessments*, **6**: 1–24.

## ÖZGEÇMİŞ

Emrah Harmancı, 1980 yılında Hakkari’de doğdu. İlk, orta ve lise öğrenimini Hakkaride tamamladı. 2009 yılında Mustafa Kemal Üniversitesi, Mühendislik Fakültesi, Makine Mühendisliği Bölümünden mezun oldu. 2016 yılında Van Yüzüncü Yıl Üniversitesi, Fen Bilimleri Enstitüsü, Makine Mühendisliği Ana Bilim Dalı’nda Yüksek Lisans öğrenimine başladı. 2014 yılından beridir Hakkari Üniversitesi, Çölemerik Meslek Yüksekokulu, Elektronik ve Otomasyon Bölümü’nde görev yapmaktadır.





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

Tarih: 29/11/2018

Tez Başlığı / Konusu:

Van ve Hakkari Bölgelerinde Rüzgar Potansiyelinin Belirlenmesi

Yukarıda başlığı/konusu belirlenen tez çalışmamın Kapak sayfası, Giriş, Ana bölümler ve Sonuç bölümlerinden oluşan toplam 139 sayfalık kısmına ilişkin, 29/11/2018 tarihinde tez danışmanım tarafından Turnitin intihal tespit programından aşağıda belirtilen filtreleme uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 1 (bir) dir.

Uygulanan filtreler aşağıda verilmiştir:

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

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

Gereğini bilgilerinize arz ederim.

  
Tarih ve İmza  
29.11.2018

Adı Soyadı: Emrah HARMANCI

Öğrenci No:159101183

Anabilim Dalı: Makine Mühendisliği Anabilim Dalı

Programı: Makine Mühendisliği Bölümü

Statüsü: Y. Lisans

Doktora

**DANIŞMAN ONAYI**  
UYGUNDUR



(Doç.Dr. Sedat YAYLA)

**ENSTİTÜ ONAYI**  
UYGUNDUR

  
Prof.Dr.Suat ŞENSOY  
(Unvan, Ad Soyad, İmza)