

**BİR RÜZGAR ÇİFTLİĞİNDEN YAPAY SİNİR AĞLARIYLA
KISA SÜRELİ ELEKTRİK ÜRETİM TAHMİNİ**

**SHORT TERM ELECTRICITY PRODUCTION FORECASTING
FROM A WIND FARM WITH ARTIFICIAL NEURAL
NETWORKS**

SELİN CANTÜRK

PROF. DR. MURAT KÖKSAL
Tez Danışmanı


Hacettepe Üniversitesi
Lisansüstü Eğitim – Öğretim ve Sınav Yönetmeliğinin
Temiz-Tükenmez Enerjiler Anabilim Dalı için Öngördüğü
YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2018

SELİN CANTÜRK'ün hazırladığı “Bir Rüzgar Çiftliğinden Yapay Sinir Ağlarıyla Kısa Süreli Elektrik Üretim Tahmini” adlı bu çalışma aşağıdaki jüri tarafından **TEMİZ TÜKENMEZ ENERJİLER ANABİLİM DALI**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Prof. Dr. Aynur ERAY

Başkan



Prof. Dr. Murat KÖKSAL

Danışman




Doç. Dr. Görkem KÜLAH

Üye



Doç. Dr. Şule ERGÜN

Üye



Yrd. Doç. Dr. Özgür EKİCİ

Üye



Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak onaylanmıştır.

Prof. Dr. Menemşe GÜMÜŞDERELİOĞLU

Fen Bilimleri Enstitüsü Müdürü

YAYINLAMA VE FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

- ☒ **Tezimin/Raporumun tamamı dünya çapında erişime açılabilir ve bir kısmı veya tamamının fotokopisi alınabilir.**

(Bu seçenekle teziniz arama motorlarında indekslenebilecek, daha sonra tezinizin erişim statüsünün değiştirilmesini talep etseniz ve kütüphane bu talebinizi yerine getirirse bile, tezinin arama motorlarının önbelleklerinde kalmaya devam edebilecektir.)

- ☐ **Tezimin/Raporumun tarihine kadar erişime açılmasını ve fotokopi alınmasını (İç Kapak, Özet, İçindekiler ve Kaynakça hariç) istemiyorum.**

(Bu sürenin sonunda uzatma için başvuruda bulunmadığım takdirde, tezimin/raporumun tamamı her yerden erişime açılabilir, kaynak gösterilmek şartıyla bir kısmı ve ya tamamının fotokopisi alınabilir)

- ☐ **Tezimin/Raporumun tarihine kadar erişime açılmasını istemiyorum, ancak kaynak gösterilmek şartıyla bir kısmı veya tamamının fotokopisinin alınmasını onaylıyorum.**

- ☐ **Serbest Seçenek/Yazarın Seçimi**

18/01/2018



Selin Cantürk

ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

18/01/2017



SELİN CANTÜRK

ÖZET

BİR RÜZGAR ÇİFTLİĞİNDEN YAPAY SİNİR AĞLARIYLA KISA SÜRELİ ELEKTRİK ÜRETİM TAHMİNİ

Selin CANTÜRK

Yüksek Lisans, Temiz Tükenmez Enerjiler Anabilim Dalı

Tez Danışmanı: Prof. Dr. Murat KÖKSAL

Ocak 2018, 112 Sayfa

Dünyada son yıllarda kurulumu artan ve enerji üretiminde önemli bir kaynak haline gelen rüzgar enerjisi sistemleri, Türkiye'nin sahip olduğu rüzgar enerjisi potansiyeli göz önünde bulundurulduğunda, bu gelişmelere paralel olarak Türkiye'de de önem kazanmaktadır. Rüzgarın değişken (stabil olmayan) bir kaynak olması nedeniyle rüzgar enerjisi sistemlerinin şebeke entegrasyonu ve üretilen enerjiden verimli bir şekilde yararlanılabilmesi için rüzgar üretim tahminlerine ihtiyaç duyulmaktadır. Rüzgardan elde edilen enerji üretimi, rüzgar enerjisi sistemlerinin bulunduğu bölgenin rüzgar karakteristiği, çevresindeki coğrafi şekiller, engeller vb. bölgesel özelliklerden etkilendiği için ise tahmin yapılacak bölgeler için farklı matematiksel modellemeler oluşturulmaktadır.

Çalışmada, Türkiye'de yer alan bir rüzgar çiftliğinden elde edilen veriler ile YSA yönteminden yararlanılarak kısa süreli rüzgar üretimi tahmini yapılmıştır. Bu doğrultuda öncelikle rüzgar çiftliğinden alınan veri setleri incelenmiş, veri analizleri yapılmış ve YSA modeli için uygun veri setleri oluşturulmuştur. Oluşturulan modellerle yapılan tahmin sonuçları, kısa süreli rüzgar üretim tahminlerinde bir kriter olarak kabul edilen naive yöntemi ile elde edilen tahmin sonuçlarına göre değerlendirilmiştir. Statik ve dinamik yapıda iki farklı temel YSA modeli ile yapılan

tahminlere ait hata oranlarının, naive y nteme g re kabul edilebilir bir aralık i erisinde olduėu g r lm şt r. Genel olarak en d ř k ortalama hata oranları statik yapıda olan YSA ile elde edilmiřtir. Ancak se ilen zaman ufukları i in tahmin edilen ortalama deėerler incelendiėinde; dinamik yapıdaki aė modellerinden elde edilen sonu ların bazı durumlarda ger ekleřen ortalama deėerlere  ok yakın olduėu g r lm şt r. Farklı aktivasyon fonksiyonları ile elde edilen sonu lar karřılařtırıldıėında; sonu lar arasında  nemli farklılıklar olmadıėı g r lm şt r. YSA modellerinin eėitimi i in kullanılan veri setlerinin, aėın  ėrenmesi  zerinde doėrudan etkisi olduėundan; test i in se ilen g nlere dair tahminler yapılması i in farklı eėitim verisi setleriyle farklı aėlar oluřturulmuřtur. Bu durumda; dinamik yapıya sahip olan aė modelleri ile daha az veri sayısı i eren eėitim setleriyle tahmin yapılabilirken, her mevsime ait ve farklı kořullardaki verilerden oluřan bir eėitim setiyle  ėrenmeyi tamamlayan statik yapıdaki model ile daha d ř k hata oranları elde edilmiřtir. Dinamik yapıya sahip olan aėlarda; tahmin edilmesi istenen g nden  nceki 2 g ne ait verilerle eėitilen aėlardan elde edilen sonu lar, tahmin edilmesi istenen g nden  nceki 1 haftaya ait verilerle eėitilen aėlardan elde edilen sonu lara genel olarak yakın  ıkarken sonu lar naive y nteme g re deėerlendirildiėinde kabul edilebilir hata aralıkları elde edilmiřtir. İkinci b l mde ise dinamik yapıdaki aė modellerine, girdi olarak sıcaklık deėerleri de eklenmiřtir. Ancak  alıřmada kullanılan veriler ile kısa s reli tahminler yapıldıėında sıcaklık girdisinin, aėların sonu larını  nemli  l  de etkilemediėi g r lm şt r. Son b l mde ise; oluřturulan modellerin tahmin yapabilmek i in bir meteorolojik veriye ihtiya  duyan modeller olması nedeniyle, bu verilerin belirli hata oranlarına sahip olmasının  retim tahmini sonu larını nasıl etkilediėi incelenmiř ve modellerin tahmin yapması i in kullanılan test girdisi, r zgar hızı, deėerlerine %5 ile %20 aralıėında eklenen rastgele hatalar ile yeni test girdileri elde edilmiřtir. Daha sonra aėlara hata oranları eklenmiř bu test girdileri verilmiř ve elde edilen tahminlerin hata oranları incelendiėinde; meteorolojik verilere eklenen %20 oranında rastgele hatanın bile tahmin sonu ları  zerinde en fazla %2.69 oranında bir ortalama hata artışına neden olduėu g r lm şt r.

Anahtar Kelimeler: r zgar enerjisi, yapay sinir aėları, kısa s reli tahmin

ABSTRACT

SHORT TERM ELECTRICITY PRODUCTION FORECASTING FROM A WIND FARM WITH ARTIFICIAL NEURAL NETWORKS

Selin CANTÜRK

Master of Science, Department of Clean Renewable Energies

Supervisor: Prof. Dr. Murat KÖKSAL

January 2018, 112 Pages

In recent years, wind energy systems become an important source for energy production around the world with increasing installations. When Turkey's wind energy potential is taken into consideration, wind energy systems gain importance also in Turkey in parallel with this development. Because wind is an intermittent source, wind power forecasts are needed for the integration of wind energy systems into the grid and utilizing efficiently the generated energy. As energy production from wind is depends on the wind characteristic of the site, orography, obstacles around the site and such regional conditions, different mathematical models are built for different regions in the literature.

In this study, short term electricity production forecasting with ANN was carried out with data obtained from a wind farm which is located in Turkey. Firstly, data sets were examined, data analysis was performed, and suitable data sets for ANN was constructed. Results given from developed models was evaluated according to persistence method which is accepted as a benchmark for short term wind power forecasts. The error for the estimates carried out with two basic ANN models, which

are a static and a dynamic model, were found to be in an acceptable range according to persistence method. Generally, the lowest mean absolute percentage errors were obtained from the static ANN model. However, when the estimated average production values was taken into consideration, it was seen that results obtained from dynamic models for chosen time horizons were very close to the actual average production values for these time horizons. When results obtained from models with different activation functions were compared, it was seen that there are no considerable differences between the results. Because training data has a direct effect on learning of network, different networks with different training data were constructed for test days. In this case, while dynamic models was trained with less data compared to static model, static model, trained with a data set which includes data from each season, gave forecast results which had lower errors. Dynamic networks; trained with data belonging to two days preceding the test day and trained with data belonging to one week preceding the test day, gave similar forecast results, and errors of these results were in an acceptable range according to persistence method. In the second part, temperature was added as an input to dynamic ANN models. Because wind farm data was only used for short term forecasts in this study, adding temperature input to networks did not affect forecast results significantly. In the last part, random errors between 5% and 20% were added to test input (wind speed) to investigate the effects of the errors in meteorological data on ANN predictions. Then these test data was used for forecast and it was seen that meteorological data include 20% random error caused an increase in forecast errors only 2.69%.

Key Words: wind energy, artificial neural networks, short term forecasting

TEŞEKKÜR

Tez çalışmasının her aşamasında bilgi ve birikimleriyle bana yol gösteren, çalışma süresi boyunca sabırla vakit ayırarak yardımlarını ve desteklerini esirgemeyen sayın tez danışmanım Prof. Dr. Murat KÖKSAL'a tüm katkılarından dolayı teşekkür ederim.

Bilgi ve görüşleriyle, tez çalışmam boyunca her zaman yardımcı olan, değerli fikirleriyle tez çalışmasına önemli katkıları bulunan sayın Doç. Dr. Merih AYDINALP KÖKSAL'a teşekkür ederim.

Yüksek lisans eğitimim boyunca bilgilerini paylaşarak yol gösteren, tez çalışması öncesinde ve çalışma sürecinde desteklerini esirgemeyen Prof. Dr. Aynur ERAY'a teşekkür ederim.

Her zaman yanımda olan babaannem Nurhayat CANTÜRK'e üzerimdeki emekleri için teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER	.vi
ŞEKİLLER	viii
ÇİZELGELER	x
SİMGELER ve KISALTMALAR	xii
1. GİRİŞ ve LİTERATÜR TARAMASI	1
1.1. Türkiye’de Enerji Üretimi	2
1.2. Türkiye’de Rüzgar Enerjisi	3
1.3. Rüzgar Enerjisi Tahminleri	6
1.4. Rüzgar Enerjisi Tahminleri ile İlgili Tanımlar	7
1.5. Rüzgar Enerjisi Tahminlerinin Sınıflandırılması	7
1.5.1. Tahmin Süresine Göre Sınıflandırma	7
1.5.2. Tahmin Yöntemlerine Göre Sınıflandırma	8
1.6. Kısa Süreli Rüzgar Üretim Tahmini	10
1.7. Literatür Taraması	12
1.8. Tezin Amacı, Kapsamı ve Yöntem	21
2. YAPAY SİNİR AĞLARI	23
2.1. Yapay Sinir Ağlarının Yapısı	23
2.2. Aktivasyon (Transfer) Fonksiyonları	24
2.3. YSA’ların Yapılarına Göre Sınıflandırılması	27
2.4. YSA Mimarisi	29
2.5. Öğrenme Algoritması	30
3. UYGULAMA	34
3.1. Veri Seti	34
3.1.1. YSA Modellerinde Kullanılacak Verilerin Seçimi ve Özellikleri	38
3.2. Modellerin Oluşturulması	47
3.2.1. YSA Modelinin Belirlenmesi	48
3.2.2. Girdiler	53
3.2.3. Çıktılar	53

3.2.4. Oluşturulan Modeller.....	53
3.2.5. Veri Setine Uygulanan Önişlemler.....	57
3.3. Sonuçların Değerlendirilmesinde Kullanılan Yöntemler	59
4. SONUÇLAR	60
4.1. Öğrenme Verisinin Etkisi.....	60
4.1.1. Durum 1, 2, 3 ve 4 Değerlendirmesi	80
4.2. Girdilerin Etkisi	81
4.3. Hata Toleransı	93
5. SONUÇLAR ve ÖNERİLER.....	100
5.1. Sonuçlar.....	101
5.2. Öneriler.....	103
6. KAYNAKÇA.....	104
EK 1.....	110
ÖZGEÇMİŞ.....	112

ŞEKİLLER

Sayfa

Şekil 1.1. Dünya genelinde yenilenebilir ve yenilenebilir olmayan enerji kaynakları kullanan sistem kurulumlarının yıllık kapasiteleri (2001-2015) [1]	1
Şekil 1.2. 2001-2016 yılları dünyadaki toplam kurulu rüzgar gücü kapasitesi [3]	2
Şekil 1.3. 2001-2016 yılları arasında Türkiye’de toplam kurulu rüzgar gücü kapasitesi [13, 18].....	5
Şekil 1.4. 2016 yılında yeni kurulumu yapılan rüzgar enerjisi sistemlerinin ülkelere göre dağılımı [3]	6
Şekil 2.1. Biyolojik nöron [57].....	23
Şekil 2.2. Yapay nöron yapısı.....	24
Şekil 2.3. YSA modellerinde sıklıkla kullanılan aktivasyon fonksiyonları	26
Şekil 2.4. Katmansız geri beslemeli YSA	27
Şekil 2.5. YSA katmanı.....	27
Şekil 2.6. İleri beslemeli YSA modeli.....	28
Şekil 2.7. Geri beslemeli nöron	29
Şekil 2.8. Çok katmanlı ileri beslemeli (3) bir YSA modeli	29
Şekil 3.1. Çalışmada kullanılan yıla ait aylık ortalama rüzgar hızları.....	35
Şekil 3.2. Çalışmada kullanılan yıla ait aylık ortalama üretim miktarları	35
Şekil 3.3. Ticari amaçlı kullanılan türbinler için teorik güç eğrisi	36
Şekil 3.4. Ay içinde üretim gerçekleşen saatler ve aylık oranları	37
Şekil 3.5. Çalışmada kullanılan yıla ait aylık ortalama sıcaklık değerleri	38
Şekil 3.6. Çalışmada kullanılan aylarda ölçülen 10 dakikalık rüzgar hızı ortalamaları	41
Şekil 3.7. Çalışmada kullanılan aylara ait rüzgar hızı dağılımları.....	42
Şekil 3.8. Çalışmada kullanılan aylara ait 10 dakikalık ortalama sıcaklık değerleri.....	44
Şekil 3.9. Çalışmada kullanılan aylara ait rüzgar hızı-üretim dağılımları.....	47
Şekil 3.10. NARX ağının genel gösterimi.....	49
Şekil 3.11. NARX ağı [60]	50
Şekil 3.12. Seri-paralel ve paralel mimari	52
Şekil 3.13. MATLAB kullanılarak oluşturulmuş seri-paralel mimariye sahip (a) ve paralel mimariye sahip (b) NARX ağ modeli.....	52
Şekil 3.14. Model A-1 için oluşturulan ağ modelinin eğitim (a) ve tahmin aşamaları (b)..	54
Şekil 3.15. Model A-2 için oluşturulan ağ modelinin eğitim (a) ve tahmin aşamaları (b)..	55

Şekil 3.16. Model A-3 için oluşturulan ağ modelinin eğitim (a) ve tahmin aşamaları (b)..	56
Şekil 4.1. Model A-2 ile 2 gün süreli eğitim verisi kullanılarak 20 Temmuz için yapılan tahminler (a) ve tahminlerin hata oranları (b)	61
Şekil 4.2 Model A-2 ile 1 hafta süreli eğitim verisi kullanılarak 20 Temmuz için yapılan tahminler (a) ve tahminlerin hata oranları (b)	62
Şekil 4.3 Model B ile 20 temmuz için yapılan tahminler (a) ve tahminlerin hata oranları (b)	63
Şekil 4.4. Model A-2 kullanılarak 2 gün süreli eğitim verisiyle 20 Ocak için yapılan tahminler (a) ve tahminlerin hata oranları (b)	66
Şekil 4.5. Model A-2 kullanılarak 1 hafta süreli eğitim verisiyle 20 Ocak için yapılan tahminler (a) ve tahminlerin hata oranları (b)	67
Şekil 4.6. Model B ile 20 Ocak için yapılan tahminler (a) ve tahminlerin hata oranları (b)	68
Şekil 4.7. 2 gün süreli eğitim verisiyle 27 Ekim için yapılan tahminler (a) ve tahminlerin hata oranları (b)	71
Şekil 4.8. 1 hafta süreli eğitim verisiyle 27 Ekim için yapılan tahminler (a) ve tahminlerin hata oranları (b)	72
Şekil 4.9. Model B ile 27 ekim için yapılan tahminler (a) ve tahminlerin hata oranları (b)	73
Şekil 4.10. Mayıs ayı günlük ortalama üretim miktarları (kWh)	76
Şekil 4.11. Model A-2 ile geçmiş iki güne ait eğitim verisi kullanılarak 10 Mayıs günü için yapılan tahminler (a) ve hata oranları (b)	77
Şekil 4.12. Model B ile 10 Mayıs günü için yapılan tahminler (a) ve hata oranları (b).....	78
Şekil 4.13. Model A-1 kullanılarak 20 Temmuz gününün ilk 3 saati için yapılan tahminler (a) ve hata oranları (b)	84
Şekil 4.14. Model A-3 kullanılarak oluşturulan ağların 20 Temmuz günü için tahminleri (a) ve hata oranları (b).....	85
Şekil 4.15. Model A-1 ile 3 Ocak günü için yapılan tahminler (a) ve hata oranları (b).....	88
Şekil 4.16. Model A-2 ile 3 Ocak günü için yapılan tahminler (a) ve hata oranları (b).....	89
Şekil 4.17. Model A-3 ile 3 Ocak günü için yapılan tahminler (a) ve hata oranları (b).....	90
Şekil 4.18. 20 Temmuz günü için Model A-2 ile oluşturulan ağların hata eklenmiş test verileriyle yaptığı tahminler; sigmoid (a), hiperbolik tanjant (b), Gauss (c).....	95
Şekil 4.19. 27 ekim günü için Model A-2 ile oluşturulan ağların hata eklenmiş test verileriyle yaptığı tahminler; sigmoid (a), hiperbolik tanjant (b), Gauss(c)	98

ÇİZELGELER

Sayfa

Çizelge 1.1. Yerden 50 metre yükseklik dikkate alınarak hesaplanan Türkiye rüzgar enerjisi potansiyeli [15]	4
Çizelge 1.2. Literatürde kısa süreli rüzgar gücü tahmini için kullanılan YSA modelleri ve özellikleri	18
Çizelge 1.3. Türkiye’de YSA ile rüzgar enerjisi tahminleri için yapılan çalışmalar	21
Çizelge 3.1. Seçilen test günlerinden birisi için eşitlik 4.3’e göre normalize edilmiş değerlere ait örnekler	58
Çizelge 4.1. Durum 1’de eğitim ve test için kullanılan günlere ait minimum, maksimum ve ortalama rüzgar hızı değerleri	60
Çizelge 4.2. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminlerde ve Model B ile yapılan tahminlerde hesaplanan ortalama hata oranları	64
Çizelge 4.3. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminler, Model B ile yapılan tahminler ve gerçekleşen ortalama üretim değerleri	64
Çizelge 4.4. Durum 2’de eğitim ve test için kullanılan günlere ait minimum, maksimum ve ortalama rüzgar hızı değerleri	65
Çizelge 4.5. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminlerde ve Model B ile yapılan tahminlerde hesaplanan ortalama hata oranları	69
Çizelge 4.6. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminler, Model B ile yapılan tahminler ve gerçekleşen ortalama üretim değerleri	69
Çizelge 4.7. Durum 3’te eğitim ve test için kullanılan günlere ait minimum, maksimum ve ortalama rüzgar hızı değerleri	70
Çizelge 4.8. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminlerde ve Model B ile yapılan tahminlerde hesaplanan ortalama hata oranları	74
Çizelge 4.9. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminler, Model B ile yapılan tahminler ve gerçekleşen ortalama üretim değerleri	74
Çizelge 4.10. Durum 4’te eğitim ve test için kullanılan günlere ait minimum, maksimum ve ortalama rüzgar hızı değerleri	76
Çizelge 4.11. 2 gün süreli eğitim veri setiyle Model A-2 ile yapılan tahminlerde ve Model B ile yapılan tahminlerde hesaplanan ortalama hata oranları	79
Çizelge 4.12. 2 gün süreli eğitim veri setiyle Model A-2 ile yapılan tahminler, Model B ile yapılan tahminler ve gerçekleşen ortalama üretim değerleri	79

Çizelge 4.13. Ocak ve Temmuz ayı rüzgar hızı-üretim korelasyon katsayıları	82
Çizelge 4.14. Durum 5'te eğitim ve test için kullanılan günlere ait minimum, maksimum, ortalama rüzgar hızı değerleri ve ortalama sıcaklık değerleri	83
Çizelge 4.15. Model A-1, A-2, A-3 ve Model B kullanılarak 20 temmuz günü için yapılan tahminlere ait hesaplanan ortalama hata oranları	86
Çizelge 4.16. Model A-1, A-2, A-3 ve Model B kullanılarak 20 temmuz günü için yapılan tahminler ve gerçekleşen ortalama değerler	87
Çizelge 4.17. Durum 6'da eğitim ve test için kullanılan günlere ait minimum, maksimum, ortalama rüzgar hızı değerleri ve ortalama sıcaklık değerleri	87
Çizelge 4.18. Model A-1, A-2, A-3 ve Model B kullanılarak 3 ocak günü için yapılan tahminlere ait hesaplanan ortalama hata oranları	91
Çizelge 4.19. Model A-1, A-2, A-3 ve Model B kullanılarak 20 temmuz günü için yapılan tahminler ve gerçekleşen ortalama değerler	91
Çizelge 4.20. 20 Temmuz günü için Model A-2 ile oluşturulan ağların, hata eklenmiş test verileriyle yaptığı tahminlere ait hata oranları	96
Çizelge 4.21. 27 ekim günü için Model A-2 ile oluşturulan ağların, hata eklenmiş test verileriyle yaptığı tahminlere ait hata oranları	98

SİMGELER VE KISALTMALAR

Simgeler


A	Türbin kanadının süpürdüğü alan, m^2
C_p	Güç katsayısı
$p_{t+k t}$	t zaman aralığı tahmin edilecek ilk zaman aralığı olmak üzere; belirtilen zaman aralığı $(t+k)$ için yapılan ortalama üretim tahmini, kWh
p_{t+k}	belirtilen zaman aralığında ölçülmüş ortalama üretim, kWh
t	Bilinen son üretim değerinden bir sonraki, tahmin edilecek olan ilk zaman aralığı
$t+k$	t zaman aralığından k adım sonra tahmin edilecek olan zaman aralığı
v	Rüzgar hızı, m/s
ρ	Hava yoğunluğu, kg/m^3
η	Türbin verimlilik oranı

Kısaltmalar

AEE	Asociacion Empresarial Eolica - İspanya Rüzgar Enerjisi Birliği
ARIMA	AutoRegressive Integrated Moving Average
ARMA	AutoRegressive Moving Average
ARX	AutoRegressive models with eXogenous input
L-M	Levenberg-Marquardt algoritması
MLP	Multilayer Perceptron – Çok Katmanlı Algılayıcı
NARX	Nonlinear AutoRegressive models with eXogenous input - Harici girişli doğrusal olmayan otoregresif ağ
NMAE	Normalized Mean Absolute Error – Normalize edilmiş ortalama mutlak hata
NWP	Numerical Weather Prediction – Sayısal Hava Tahmini
RES	Rüzgar Enerjisi Sistemi
SVM	Support Vector Machine – Destek Vektör Makinası
YSA	Yapay Sinir Ağı


1. GİRİŞ ve LİTERATÜR TARAMASI

Günümüzde gelişen teknolojiye bağlı olarak; hızlı endüstrileşme, kentleşme, yükselen yaşam standartları ve devam eden nüfus artışı nedeniyle enerji ihtiyacı da gün geçtikçe artmaktadır. Enerji ihtiyacının karşılanmasında, fosil yakıtlara olan yüksek orandaki bağımlılığın sonucu olarak ortaya çıkan olumsuz sosyal, ekonomik ve çevresel etkiler, ülkeleri sürdürülebilir enerji kaynaklarının kullanımına yöneltmektedir. Bu yönelimle birlikte artan çalışmaların, teknolojinin hızlı gelişimi ve uygulanan enerji politikalarıyla birleşimi sonucunda ise yenilenebilir enerji sistemlerinin maliyetlerinde fosil yakıtlarla rekabet edebilecek düzeyde düşüşler görülmektedir. 2012 yılında tüm dünyada kurulan enerji üretim sistemleri göz önüne alındığında; yenilenebilir enerji sistemlerinin kurulum kapasitelerinin, fosil yakıt kullanan sistemlerin ilk defa önüne geçtiği belirtilmektedir [1].



Şekil 1.1. Dünya genelinde yenilenebilir ve yenilenebilir olmayan enerji kaynakları kullanan sistem kurulumlarının yıllık kapasiteleri (2001-2015) [1]

Tüm dünyada yenilenebilir enerji kaynakları önem kazanırken, kurulu güç kapasitesi en yüksek olan sistemlerin, rüzgar enerjisi sistemleri olduğu görülmektedir (hidroelektrik santraller göz önünde bulundurulmadığında) [2]. 2016 yılı sonunda Küresel Rüzgar Enerjisi Konseyi'nin (ing. *Global Wind Energy Council - GWEC*) açıkladığı verilere göre dünya genelinde kurulu rüzgar gücü kapasitesi 486749 MW'a ulaşırken, bu miktarın hemen hemen yarısının son 5 yıl içinde kurulduğu belirtilmektedir [3].



Şekil 1.2. 2001-2016 yılları dünyadaki toplam kurulu rüzgar gücü kapasitesi [3]

Şekil 1.2 incelendiğinde, rüzgar enerjisi sistemleri kurulumlarının yıllar içinde önemli bir artış gösterdiği ve rüzgarın dünya için önemli bir enerji kaynağı haline geldiği görülmektedir.

Rüzgar enerjisi için en önemli dönüm noktalarından birisi 1973 yılında yaşanan petrol krizidir. Bu kriz sonrasında Amerika hükümetinin rüzgar enerjisi alanındaki araştırma-geliştirme faaliyetlerini desteklemesi ile rüzgar enerjisi sistemlerine yapılan yatırımlar artmış ve teknolojinin gelişmesi hızlanmıştır. Aynı dönemlerde Kuzey Avrupa’da da rüzgar enerjisi ile ilgili çalışmalar artarken, yapılan kurulumlar sonucunda 1990 yılından sonra Avrupa, rüzgar enerjisi piyasası için belirleyici bir konuma gelmiştir [4]. 2015 yılı içinde rüzgar enerjisi sistemlerinin kapasitesi, yeni kurulum yapılan enerji sistemleri arasında Amerika ve Avrupa’da ilk sırada, Çin’de ikinci sırada yer almaktadır [5]. 2015 yılı sonunda ise toplam kurulu güç kapasitesi en yüksek ülke Çin olurken, ülke nüfusuna göre yapılan değerlendirmelerde (per capita) Danimarka, İsveç, Almanya, İrlanda ve İspanya’nın rüzgar enerjisinden en çok yararlanan ülkeler olduğu görülmektedir [5, 6].

1.1. Türkiye’de Enerji Üretimi

2015 yılı sonunda Türkiye İstatistik Kurumu’nun açıkladığı verilere göre Türkiye’nin elektrik enerjisi ihtiyacının karşılanmasında; sırasıyla doğalgaz (%37.9), kömür (%29.1), hidroelektrik santraller (%25.6), yenilenebilir enerji ve atıklar (jeotermal, rüzgar, katı biyokütle, güneş, biyogaz ve atık kaynakları) (%6.5) ve sıvı yakıtlar (%0.9) kullanılan

kaynaklardır [7]. Veriler incelendiğinde, fosil yakıtların tüm kaynaklar içerisinde oldukça yüksek bir orana sahip olduğu görülmektedir. Bu durumun sonucu olarak; özellikle en yüksek kullanım payına sahip olan doğalgazın, Türkiye’deki rezervlerinin yetersiz olması nedeniyle dış ülkelerden alımı yapılmakta ve enerji üretimi nedeniyle önemli bir ticaret açığı oluşmaktadır. Genel olarak Türkiye’nin ticari açığının %58’inin enerji giderleri nedeniyle oluştuğu belirtilmektedir. Buna ek olarak fosil yakıt kullanımının bir diğer olumsuz etkisinin; sera gazı salınımını önemli oranda arttırması olduğu bilinmektedir [8, 9]. 2015 yılında açıklanan Türkiye İstatistik Kurumu verileri incelendiğinde Türkiye’nin toplam sera gazı emisyonunun yaklaşık %72’sinin enerji sektöründen kaynaklandığı görülmektedir [10].

Türkiye’de enerjide dışa bağımlılığı azaltmak ve sera gazı salınımı oranlarını düşürmek amacıyla yapılan çalışmalarda, 2023 yılında yenilenebilir enerjinin, elektrik üretimindeki oranının %30’a ulaşması hedeflenmektedir [8]. Ayrıca Avrupa Birliği’ne üye olma süreçleri ve Türkiye’nin Kyoto Protokolü’ne katılımı da, yenilenebilir enerji kaynakları konusunda ülke hedeflerinin belirlenmesine ve elektrik enerjisi piyasasıyla ilgili düzenlemelere katkı sağlamıştır [11]. Yenilenebilir enerji hedefleri doğrultusunda ise 10/05/2005 tarihinde 5346 no’lu “Yenilenebilir Enerji Kaynaklarının Elektrik Enerjisi Üretimi Amaçlı Kullanımı”na ilişkin yasa kabul edilmiştir [12].

1.2. Türkiye’de Rüzgar Enerjisi


Türkiye’de yenilenebilir enerji kaynakları önem kazanırken ülkenin sahip olduğu yüksek rüzgar enerjisi potansiyeli göz önünde bulundurulduğunda; rüzgarın, Türkiye’nin gelecekteki enerji üretiminde önemli bir rol oynayacağı öngörülmektedir [13]. Türkiye’nin rüzgar enerjisi potansiyelini belirlemek için yapılan çalışmalarda, Meteoroloji Genel Müdürlüğü tarafından, Türkiye’de homojen olarak dağılmış 45 farklı meteorolojik istasyona ait, 10 yıl süreyle ölçülmüş, saatlik rüzgar hızları kullanılarak “Türkiye Rüzgar Atlası” oluşturulmuştur. Elde edilen sonuçlara göre yerden 50 metre yükseklikte, yıllık ortalama rüzgar hızının 7.0 m/s ve üzerinde olduğu bölgelere ait güç yoğunlukları hesaplanmış ve kullanılabilir alanlar dikkate alınarak Türkiye’nin rüzgar enerjisi potansiyeli belirlenmiştir. Çizelge 1.1’de görüldüğü gibi toplam kurulabilecek rüzgar gücü kapasitesi 47849 MW olarak belirlenirken, bu miktarın 10013 MW’lık kısmı deniz üstü alanlar 37836 MW’lık kısmı ise kara üstü alanlar için hesaplanmıştır [14, 15].

Çizelge 1.1. Yerden 50 metre yükseklik dikkate alınarak hesaplanan Türkiye rüzgar enerjisi potansiyeli [15]

Rüzgar Hızı (m/s)	Güç Yoğunluğu (W/m²)	Kullanılabilir Alanlar (km²)	Tekno-ekonomik Potansiyel (MW)
7.0 - 7.5	400 – 500	5852	29259
7.5 - 8.0	500 – 600	2599	12994
8.0 - 9.0	600 – 800	1080	5400
> 9.0	> 800	39	196
Toplam		9570	47849


Türkiye Rüzgar Atlası'na göre 50 metre yükseklikte ve yerleşim yerlerinin dışında kalan alanlar için yapılan hesaplamalarda; Marmara, Batı Karadeniz ve Doğu Akdeniz kıyılarında yıllık ortalama rüzgar hızının 6.0-7.0 m/s aralığında olduğu görülürken, iç bölgelerde 4.5-5.0 m/s aralığına düştüğü görülmektedir. Kuzeybatı Ege kıyılarında ise yıllık ortalama rüzgar hızı 7.0-8.5 m/s aralığına çıkarken, Ege Bölgesi'nin iç kesimlerinde 6.5-7.0 m/s aralığında bir ortalama olduğu belirtilmiştir [13]. Genel olarak Türkiye'deki yedi coğrafi bölgenin değerlendirilmesiyle ise rüzgar enerjisi sistemleri için en uygun bölgelerin Marmara, Ege ve Güneydoğu Anadolu bölgeleri olduğu sonucu çıkartılırken, Çanakkale, İzmir, Balıkesir, Hatay ve İstanbul'un rüzgar potansiyeli en yüksek iller olduğu belirtilmektedir [16, 17].

Türkiye'de şebekeye katılımı sağlanan ilk rüzgar enerjisi santrali 1998'de kurulmuş olup, 1.5 MW kapasiteye sahiptir. 1998 yılından 2005 yılına kadar ise çok az miktarda yeni kurulum gerçekleştiği için 2005 yılı sonundaki toplam kurulu güç ancak 20 MW'a ulaşabilmiştir. 2005 yılında "Yenilenebilir Enerji Yasası"nın yürürlüğe girmesi ile birlikte rüzgar enerjisi sistemlerinin kurulumları için yapılan çalışmalar artmaya başlarken, Şekil 1.3'te görüldüğü gibi yıllar içinde kurulu güç kapasitesinde de önemli artışlar gerçekleşmiştir [13].



Şekil 1.3. 2001-2016 yılları arasında Türkiye’de toplam kurulu rüzgar gücü kapasitesi [13, 18]

Mayıs 2009 tarihli “Elektrik Enerjisi Piyasası ve Arz Güvenliği Starteji Belgesi”nde de yenilenebilir enerji kaynaklarının elektrik üretimindeki payının 2023 yılında %30’a ulaşması planlanırken, rüzgar enerjisine dayalı kurulu gücün en az 20,000 MW olması hedeflenmektedir [18]. 2016 yılı sonunda Türkiye Rüzgar Enerjisi Birliği’nin (TÜREB) açıkladığı verilere göre (Şekil 1.3) Türkiye’nin toplam kurulu rüzgar gücü kapasitesi 6105 MW’a ulaşmıştır [19]. Ayrıca 2016 yılı içerisinde kurulumu gerçekleşen 1387 MW yeni güç kapasitesiyle, Şekil 1.4’te görüldüğü gibi Türkiye, dünyada bu yıl içinde en yüksek kapasitede kurulum yapan 7. ülke olmuştur [3].



Şekil 1.4. 2016 yılında yeni kurulumu yapılan rüzgar enerjisi sistemlerinin ülkelere göre dağılımı [3]

1.3. Rüzgar Enerjisi Tahminleri

Rüzgar enerjisi sistemlerinin sahip olduğu birçok avantaja rağmen; rüzgarın, süreklilik ve değişkenlik problemleri olan bir kaynak olması planlama ve sistem faaliyetleriyle ilgili bazı zorluklara yol açmaktadır [20]. Ayrıca bir rüzgar türbinin gerçekleştireceği üretim miktarı; yerel ve bölgesel rüzgar trendleri, mevsimsel farklılıklar, çevredeki bitki örtüsü, yükseklik ve yakınında bulunan diğer türbinlere göre değişiklikler gösterebilmektedir [21].

Rüzgar enerjisinin elektrik üretimine katılımının artmasıyla birlikte piyasa entegrasyonu ve planlaması, gerçek zamanlı şebeke operasyonları, enterkonnekte şebeke standartları, güç kalitesi, sistemin sürekliliği ve güvenilirliği ile ilgili çözülmesi gereken sorunlar da ortaya çıkmıştır [22]. Güç kalitesi, akım ve gerilim değerleriyle ilgili sorunlar; belirlenen şebekeye bağlanma kriterleri, çeşitli filtreleme yöntemleri ve uygun teknolojiye sahip türbinlerin kullanılması ile giderilebilmektedir [23]. Rüzgar enerjisi sistemlerinden sağlanan elektrik enerjisi üretimi nedeniyle oluşabilecek arz-talep dengesizliğinin giderilmesi ve piyasa (fiyat) düzenlemeleri için ise rüzgar gücü tahminleri önemli bir araç olarak tanımlanırken, bu sistemlerden daha verimli bir şekilde yararlanabilme imkanı da sağlamaktadır [24, 25]. Rüzgar gücü tahminlerinin geliştirilmesi ile önemli ekonomik ve teknik avantajlar elde edileceği de belirtilmektedir [26].

İletim sistemi operatörleri tarafından, rüzgar üretim ve elektrik enerjisi ihtiyacı tahminlerine göre arz-talep dengesini korumak adına ikincil kaynaklardan enerji ihtiyacı karşılanarak, enerji kesintilerinin oluşması engellenebilmektedir. Üretimin talepten yüksek olarak öngörüldüğü durumlarda ise enterkonnekte şebekeler aracılığı ile ihtiyaçtan fazla olarak belirlenen enerji aktarılabilmekte ya da sistem güvenliğini sağlamak için üretimde yapılacak olan kesintiler belirlenebilmektedir. Ayrıca üreticiler de bu tahminlerden yararlanarak gün içi ve gün sonrası piyasalar için fiyat tekliflerini belirleyebilmekte ve mali zarar miktarı azaltılmaktadır [27]. Özellikle uzun süreli tahminlerle ise üreticiler, türbinler için gerekli bakım planlamalarını hazırlayabilmekte ve uzun vadede oluşabilecek riskleri öngörebilmektedir [28].

1.4. Rüzgar Enerjisi Tahminleri ile İlgili Tanımlar

Rüzgar gücü tahminleri için yapılan çalışmalar sonucunda oluşan literatürde genel olarak sıklıkla kullanılan gösterimler ve tanımlar mevcuttur. Bu tanımlar ve gösterimler aşağıda özetlenmiştir.

Zaman adımı (ing. time step): Yapılacak olan tahminin zaman ayırma duyarlılığını belirtir (10 dakika, 1 saat), k .

Zaman ufku (ing. time horizon): Tahmin süresinin toplam uzunluğunu belirtir (1 saat, 72 saat, 1 hafta), T .

t : Bilinen son üretim değerinden bir sonraki, tahmin edilecek olan ilk zaman aralığı

$t+k$: t zaman aralığından k adım sonra tahmin edilecek olan zaman aralığı

$p_{t+k|t}$: t zaman aralığı tahmin edilecek ilk zaman aralığı olmak üzere; belirtilen zaman aralığı ($t+k$) için yapılan ortalama üretim tahmini

p_{t+k} : belirtilen zaman aralığında ölçülmüş ortalama üretim

1.5. Rüzgar Enerjisi Tahminlerinin Sınıflandırılması

Rüzgar enerjisi tahminlerine, birden çok sorunun çözümü için başvurulması nedeniyle farklı tahmin sürelerinin ve yöntemlerinin farklı amaçlarla kullanıldığı görülmektedir [29].

1.5.1. Tahmin Süresine Göre Sınıflandırma

Tahmin süresine göre yapılan sınıflandırmalarda zaman ufku belirleyici olmaktadır. Ancak yapılan sınıflandırmalar için belirlenen süreler, farklı kaynaklarda farklı uzunluklar dikkate alınarak incelendiği için bu sınıflandırmaların net sınırları olmadığı belirtilmektedir ve genel olarak dört grupta incelenmektedir [25]:

- **Çok kısa süreli tahminler:** Birkaç saniye-30 dakika aralığındaki zaman ufku için yapılan tahminlerdir. Türbin kontrolü, elektrik denge fiyatı ve düzenleme eylemleri için kullanılmaktadır.
- **Kısa süreli tahminler:** 30 dakika-6 saat aralığında belirlenen zaman ufku için yapılan tahminlerdir. Ekonomik yük iletimi planlamasında, gün içi piyasası işlemlerinde ve sistem yönetimi için kullanılmaktadır.

- **Orta süreli tahminler:** 6 saat-1 gün aralığında belirlenen zaman ufku için yapılan tahminlerdir. Gün sonrası piyasası düzenlemeleri ve sistem yönetimi için kullanılmaktadır.
- **Uzun süreli tahminler:** 1 gün-1 hafta ya da daha uzun süreler için yapılan tahminlerdir. Türbinlerin bakım planlamalarının yapılması ve üretimin şebekeye minimum maliyetle aktarılması kararlarını vermek için kullanılmaktadır [20, 26].

1.5.2. Tahmin Yöntemlerine Göre Sınıflandırma

Rüzgar enerjisi tahminlerinde; naive yöntem (*ing. persistence method*), fiziksel yaklaşımlar, istatistiksel yaklaşımlar ve hibrit modellerden oluşan farklı tahmin yöntemleri kullanılmaktadır [26].

- **Naive yöntem:** Naive yöntem, t aralığındaki ve yakın zamanda gerçekleşecek sonraki tahmin basamaklarındaki $(t+k)$ rüzgar hızı ve buna bağlı olarak rüzgar üretim değerleri arasındaki yüksek korelasyon değerlerine dayanılarak kullanılan bir tahmin yöntemidir. Meteorologlar tarafından NWP (*ing. Numerical Weather Prediction*) (Sayısal Hava Tahmini) sonuçlarının karşılaştırmalarının yapılması için bir destek aracı olarak geliştirilmiştir [30]. Naive tahmin yöntemi, gerçekleşen son verinin, gelecekte gerçekleşecek değerler için de doğru olduğunu kabul eder.

$$\hat{P}(t + k|t) = P(t) \quad (1.1)$$

$P(t)$: t aralığında ölçülen ortalama üretim

$\hat{P}(t + k|t)$: t zaman aralığı başlangıç noktası olmak üzere; $t+k$ zaman aralığı için yapılan tahmin

Atmosferdeki değişim ölçeklerinin genellikle yavaş olması nedeniyle rüzgar enerjisi tahminlerinde iyi sonuç veren bir yöntem olduğu belirtilmektedir. Kısa süreli tahminlerde; kullanılan en basit fakat 0-6 saatlik zaman ufku için başarılı bir yöntem olan naive yöntem, farklı koşullar için yapılan tahminlerin karşılaştırılabilmesi ve sonuçların değerlendirilebilmesi için referans model olarak belirlenmiştir [31].

- **Fiziksel yaklaşımlar:** Fiziksel yaklaşımlar, atmosferin fiziksel tanımına dayalı parametreleri kullanarak tahmin yapabilen yöntemlerdir [26]. Bu yöntemlerden faydalanabilmek için öncelikle rüzgar enerjisi sistemlerinin bulunduğu bölgenin fiziksel koşullarının detaylı olarak bilinmesi gerekmektedir. Yükseklik, çevredeki bitki örtüsü, çevredeki yükseltiler, basınç, sıcaklık, çevrede bulunan türbinlerin

yerleşimi gibi koşulların belirlenmesi ile ilk olarak türbinin hub yüksekliğinde bir rüzgar hızı tahmini yapılmaktadır. Daha sonra elde edilen rüzgar hızı tahminleri ile türbinin güç eğrisi üzerinden bir hesaplama yapılarak rüzgar gücü tahmin sonucu belirlenmektedir [20].

Rüzgar enerjisi tahminleri için kullanılan fiziksel yaklaşım NWP'dir. NWP ile karmaşık matematiksel modellerin çözümü yapılarak, rüzgar hızı tahminleri gerçekleştirilir. Fiziksel rüzgar üretim tahmin modelleri de girdi olarak NWP'den elde edilen verileri kullanmaktadır. Fiziksel yaklaşımların en büyük avantajı geçmiş verilere ihtiyaç duymamasıdır. Ancak bölgedeki fiziksel koşullar ile ilgili çok detaylı bir veriye ihtiyaç duyması ise bazı durumlarda dezavantaj olarak görülebilmektedir. Bu duruma ek olarak karmaşık matematiksel işlemlerin çözümü için yüksek özelliklere sahip bilgisayarlara ihtiyaç duyulmakta ve hesaplama sürelerinin uzun zaman aldığı belirtilmektedir. Bunun sonucunda 6 saatten daha kısa süreli tahminler için veri toplama ve yüksek maliyet sorunları oluşması nedeniyle bu yöntemin kısa süreli tahminlerden çok orta ve uzun süreli tahminler için uygun olduğu vurgulanmaktadır [22, 25, 26, 28, 30].

- **İstatistiksel yaklaşımlar:** İstatistiksel yaklaşımlar, zaman serisi modelleri ve yapay zeka tabanlı modeller olarak iki ana başlıkta incelenmektedir. Bu yöntemlerle tahmin yapılabilmesi için sistemde ölçülmüş olan geçmiş verilere ihtiyaç duyulmaktadır. İstatistiksel yaklaşımların genel olarak otoregresif kısma sahip olmaları, rüzgar enerjisi tahminleri için bu yöntemleri uygun kılmaktadır. Otoregresif modellerde bağımlı değişken, geçmişteki değerinin bir fonksiyonudur. Rüzgar gücü tahminlerinde de otoregresif kısım rüzgarın devamlılık davranışını algılayabilirken, lineer olmayan modellerle sayısal hava tahminlerinin dönüşümü sağlanabilmektedir [25].

Fiziksel yaklaşımlara göre modellenmesi kolay, maliyeti düşük ve hızlı olan istatistiksel yaklaşımların, bu nedenlerden dolayı kısa süreli tahminler için daha uygun olduğu belirtilmektedir [26]. İstatistiksel yaklaşımların dezavantajının ise tahmin edilecek sürenin uzamasıyla tahmin performansının düşmesi olduğu vurgulanmaktadır [22].

Literatürde rüzgar enerjisi tahminlerinde, zaman serisi modellerinden ARX, ARMA, ARIMA modellerinin kullanıldığı görülürken, yapay zeka tabanlı modellerde yapay

sinir ağırları (YSA), destek vektör makinesi (ing. *Support Vector Machine - SVM*) ve bulanık mantık modellerinden sıklıkla yararlanılmaktadır.

- **Hibrit modeller:** Hibrit modeller, tahminler için kullanılan farklı yöntemlerin avantajlı yönlerini birleştirme temeli üzerine kurulmaktadır. Rüzgar enerjisi tahminlerinde genel olarak kullanılan hibrit modeller; fiziksel ve istatistiksel yaklaşımların birleşimi, kısa süreli ve orta süreli tahmin modellerinin birleşimi ve alternatif istatistiksel modellerin birleşimiyle oluşturulmaktadır [22]. Fiziksel ve istatistiksel yaklaşımların birleşimiyle oluşturulan modellerde; zaman serisi modellerinin kısa süreli tahminlerdeki başarısı ve fiziksel yöntemlerin uzun süreli tahminlerdeki başarısı model için avantaj sağlamaktadır. Danimarka’da geliştirilen “Zephyr” tahmin modeli bu türe örnek olarak gösterilebilir [25].

1.6. Kısa Süreli Rüzgar Üretim Tahmini

Rüzgar enerjisi sistemlerinin kurulumlarının artması ve birçok ülkenin gelecekteki enerji üretiminde de rüzgar enerjisi ile ilgili hedefleri olması sonucunda rüzgar enerjisi tahminleri, kullanıcılar için önemli bir konuma gelmiştir. Rüzgar enerjisinde dünyada önemli bir paya sahip olan Avrupa, 2020 yılında elektrik ihtiyacının %14-18’ini rüzgardan karşılamayı planlamaktadır. Bu hedefe ulaşmak için Avrupa’da, yıllar içinde yapılan sistem kurulumlarının yanısıra rüzgardan elde edilen enerjinin sisteme iyi bir şekilde entegre edilebilmesi amacıyla rüzgar gücü tahminleri için de genel çalışmalar yapılmıştır.

2002 yılında Avrupa Birliği tarafından desteklenen ve araştırma kurumları, üniversiteler, meteoroloji enstitüleri ve özel şirketlerin ortak bir çalışma yürüttüğü, kısa süreli rüzgar tahmin modellerinin geliştirilmesi üzerine kurulu “ANEMOS” projesi hayata geçmiştir. Dört yıl süren bu projenin ardından 2008 yılında, bu projenin devamı niteliğindeki “ANEMOS.plus” projesi başlatılmış ve 2012 yılında tamamlanmıştır [32]. Bu projelerde kısa süreli tahmin birkaç saatten birkaç güne kadar olan zaman ufukları olarak tanımlanmıştır. Bu süre içerisindeki tahminlerin günlük ve gün içi piyasaların düzenlenmesinde, sistem yönetiminde ve yönetim görevlerinin planlanmasına fayda sağlayarak, rüzgar enerjisi sistemlerinin entegrasyonuna katkıda bulunacağı belirtilmektedir [33]. Aynı zamanda projelerde farklı özelliklere sahip bölgelerde bulunan rüzgar çiftliklerinden alınan verilerin kullanılmasıyla bölge özelliklerinin tahmin edilebilirlik üzerindeki etkileri de incelenmiştir. ANEMOS projesi kapsamında

bir tanesi açık denizde, iki tanesi kıyıya yakın ve iki tanesi de karada yer alan beş rüzgar enerjisi sisteminden alınan veriler üzerinde çalışılmıştır [34].

ANEMOS projelerinden farklı olarak Avrupa’da AEE (İspanya Rüzgar Enerjisi Birliği) tarafından yürütülen bir diğer projede ise karmaşık, yarı-karmaşık ve basit özelliklere sahip olarak nitelendirilen bölgelerde bulunan altı rüzgar çiftliğinden alınan veriler üzerinde tahmin çalışmaları yapılmıştır [25].

Bu projelerden elde edilen sonuçlar incelendiğinde; NWP’den alınan rüzgar hızı tahminlerinin, üretim tahmini performansı üzerinde büyük oranda etkisi olmasının ve istatistiksel yaklaşımların fiziksel yaklaşımlardan daha başarılı yöntemler olarak değerlendirilmesinin, ortak sonuçlar olduğu görülmektedir. Ancak ANEMOS projesinde karmaşık özelliklere sahip bölgeler için yapılan tahminlerin hata oranlarının daha yüksek olduğu belirtilirken, AEE tarafından gerçekleştirilen projede bölge özelliklerinin tahmin performansını etkilemediği sonucuna varılmıştır. Ayrıca ANEMOS projesi sonucunda dikkate alınan tahmin modellerinin (WPPT, LocalPred, Prediktor, ...) birbirlerine herhangi bir üstünlük sağlayamadığı fakat çok kısa süreli tahminlerde girdi olarak geçmiş üretim değerlerini kullanan modellerin en iyi sonucu verdiği belirtilmiştir. AEE’ye ait olan projede genel olarak NWP tahminleri ile çalışan istatistiksel modeller en başarılı modeller olarak değerlendirilmiştir. Bu sonuçlara ek olarak AEE projesinde yüksek üretim değerlerinde tahmin hatalarının daha düşük olduğu da belirtilmiştir [25, 33, 34].

Avrupa’da gerçekleştirilen bu projelerde seçilen bölgeler ile farklı iklim koşullarına sahip, Kuzey ve Batı Avrupa için çalışmalar yapılırken, Akdeniz ve Güney Avrupa bölgeleri projeler dahilinde incelenmemiştir [25].

Türkiye için ise rüzgar enerjisi sistemleri yeni sayılabilecek bir teknoloji olmasından dolayı belirlenen hedefler doğrultusunda bir yol haritası oluşturulmuştur. Türkiye Rüzgar Enerjisi Birliği (TÜREB) tarafından açıklanan yol haritasında iletim sisteminin güvenilirliğinin sağlanması ile ilgili “Uzun, orta ve kısa vadeli rüzgar tahminlerinin yapılması için gereken sistemlerin kurulması ve rüzgar enerjisi sistemlerinin (RES) üretim tahminlerinin merkezi olarak yapılarak şebekeye RESlerden gelecek yükün tahmin edilmesi” maddesi koyulmuştur [18]. Türkiye’de merkezi olarak yapılan tahminler için ise şu an aktif olarak çalışmalara devam eden Rüzgar İzleme ve Tahmin

Merkezi (RİTM) kurulmuştur. Buna ek olarak bu yol haritasında belirtilen (“Doğası gereği saatlik üretim planını saatler öncesinden yüksek doğruluk oranıyla belirlemek RESler için mümkün olamadığından sıklıkla dengesizlik maliyetine katlanılmakta olup bu sıkıntının gün içi piyasanın devreye girmesi ile giderilmesi”) dengesizlik maliyetlerinin, kısa süreli tahminlerin geliştirilmesi ile azaltılması beklenebilir.

1.7. Literatür Taraması

Literatürde rüzgar gücü tahminleri için birçok yöntemden yararlanılırken kısa süreli tahminler için istatistiksel yaklaşımların uygunluğu belirtilmektedir [25, 30]. Karmaşık ve uzun zaman alan matematiksel denklemlerin çözümüne göre, verileri öğrenme yeteneğine sahip olan ve daha basit modellemelerle oluşturulabilen YSA’lar (Yapay Sinir Ağları) ise rüzgar enerjisi tahminlerinde sıklıkla kullanılan istatistiksel yaklaşımlardandır. Aynı zamanda YSA’ların hata toleransına sahip olması ve lineer olmayan sistemleri modellemedeki başarısı; bu yöntemi, gürültülü verilere sahip olan rüzgar enerjisi sistemleri için uygun bir hale getirmektedir [35]. Rüzgar üretimi tahmin modelleri ile ilgili yapılan değerlendirmelerde de YSA modellerinin özellikle kısa süreli rüzgar tahminleri için en uygun modeller olduğu belirtilmektedir [36].

0-6 saat aralığındaki zaman ufukları için YSA’ların meteorolojik veri olmadan, geçmişte ölçülen değerleri kullanarak tahmin yapabileceği belirtilirken genel olarak 6 saatten daha uzun zaman ufukları için meteorolojik verilerden (NWP) yararlanmanın gerekli olduğu vurgulanmaktadır [25].

Chitsaz vd. (2015) tarafından sadece geçmişte ölçülen üretim değerlerini girdi olarak kullanarak 6 saatlik zaman ufku için 1 saat zaman adımı ile tahminler yapan bir YSA modeli oluşturulmuş ve farklı mevsimlere ait dört aylık verilerle model test edilmiştir. Literatürde 24 saatten kısa zaman ufukları için genellikle daha kısa zaman adımları (10-15 dakika) kullanılırken, çalışmada seçilen bölgenin (Alberta, Kanada) gerçek zamanlı elektrik piyasasının saatlik hesaplamalarıyla düzenlenmesi nedeniyle zaman adımının 1 saat olarak seçildiği belirtilmektedir. Çalışma için oluşturulan YSA modeli dalgacık-yapay sinir ağı (*ing. Wavelet Neural Network - WNN*) olup, öğrenme algoritması olarak gelişmiş klonal seçim algoritması (*ing. Improved Clonal Selection Algorithm - ICSA*) tercih edilmiştir. Ayrıca rüzgar gücü tahmini hatalarının Gaussian dağılımı göstermemesi nedeniyle, ağıın öğrenme aşamasındaki performans değerlendirmesi için YSA ile ilgili çalışmalarda sıklıkla tercih edilen hata karelerinin toplamı (*ing. Mean*

Square Error - MSE) yerine “maximum correntropy criterion” (MCC) kullanılmıştır. Oluşturulan model naive yöntem, radyal tabanlı fonksiyon ağı, çok katmanlı algılayıcı ağ (ing. *Multi-Layer Perceptron - MLP*) modelleriyle ve benzetilmiş tavlama (ing. *Simulated Annealing - SA*), parçacık sürü optimizasyonu (ing. *Particle Swarm Optimization - PSO*), diferansiyel evrim (ing. *Differential Evolution - DE*), klonal seçim (ing. *Clonal Selection Algorithm - CSA*) öğrenme algoritmalarıyla çalışan modellerle karşılaştırılmıştır. Önerilen tahmin modelinin en iyi sonuçları verdiği belirtilmiştir [25, 37].

Catalao vd. (2015) ise yine sadece geçmiş üretim değerlerini girdi olarak kullanarak 3 saat zaman ufku için 15 dakika zaman adımlarıyla tahmin yapan bir model üzerinde çalışmıştır. Modelin ağ yapısı, YSA ve bulanık algoritmaların birlikte kullanımıyla oluşturulan uyarlamalı ağ tabanlı bulanık çıkarım sistemidir (ing. *Adaptive Neuro-Fuzzy Inference System - ANFIS*). Model, dalgacık dönüşümü fonksiyonu ve evrimsel parçacık sürü optimizasyonu (ing. *Evolutionary Particle Swarm Optimization - EPSO*) algoritması kullanılarak oluşturulmuştur. Her mevsim için yapılan tahminler değerlendirilmiş ve naive yöntem, YSA ve YSA tabanlı farklı hibrit modellerin sonuçlarıyla kıyaslanmıştır. En başarılı sonuçların önerilen model ile elde edildiği belirtilmiştir [38].

Catalao vd. (2009) ise literatürde 6 saatten uzun zaman ufuklarının tahmini için meteorolojik veri kullanımına ihtiyaç duyulduğu belirtilmesine rağmen 24 saat için sadece geçmiş üretim değerlerini girdi olarak kullanarak bir YSA tahmin modeli oluşturmuştur. 3 katmanlı ve L-M (Levenberg-Marquardt) öğrenme algoritmasıyla çalışan bir YSA modeli ile her mevsimden rastgele seçilmiş bir gün için yapılan tahminlerin, naive yöntemden daha başarılı sonuçlar verdiği belirtilmiştir [39].

Meteorolojik verilerden yararlanılarak yapılan rüzgar tahminlerinde ise üretim değerleri üzerinde etkisi olan meteorolojik parametreler seçilmektedir. Rüzgardan elde edilecek gücün teorik olarak hesaplanması rüzgar hızı, havanın yoğunluğu, türbinin süpürdüğü alan ve güç katsayısı kullanılarak yapılmaktadır. Eşitlik (1.2) incelendiğinde rüzgar hızının üretim değerleri üzerinde önemli bir etkisi olduğu görülürken, hava yoğunluğunun da sıcaklık ve hava basıncına bağlı bir fonksiyon olması nedeni ile bu parametrelerin rüzgar gücü tahminleri için literatürde sıklıkla tercih edildiği görülmektedir [22].

$$P = \frac{1}{2} \cdot \rho \cdot A \cdot v^3 \cdot C_p \cdot \eta \quad (1.2)$$

Yukarıdaki denklemde P rüzgar gücünü, ρ hava yoğunluğunu, A türbinin süpürdüğü alanı, v rüzgar hızını, C_p güç katsayısını, η türbin verimlilik oranını temsil etmektedir [27].

Kariniotakis vd. (1996), Methaprayoon vd. (2007), Kolhe vd. (2011) ve Chang vd. (2012) çalışmalarında girdi olarak rüzgar hızı ve geçmiş üretim değerlerinden yararlanmıştır. Kariniotakis vd. (1996) geçmiş 2.5 güne ait ölçülmüş değerleri eğitim için kullanarak; 10 dakikalık zaman adımlarıyla 2 saat zaman ufku için tahmin yapabilen çok katmanlı-geri beslemeli bir YSA modeli oluşturmuştur. Sonuçlar naive yöntem ile karşılaştırılmış ve YSA ile daha iyi sonuçlar elde edildiği belirtilmiştir [40].

Methaprayoon vd. (2007) YSA modeli için kullanılacak girdileri belirlerken üretim değerleri ile rüzgar hızı, sıcaklık ve rüzgar yönü arasındaki korelasyon değerlerini incelemiş ve rüzgar hızı ile üretim değerleri arasındaki korelasyon katsayısının genellikle 1'e yakın olduğunu belirtmiştir. Sıcaklık ve rüzgar yönünün, üretim değerleri ile arasındaki korelasyon ise yetersiz bulunduğu için bu verilerden yararlanılmamıştır. Ağın kullanacağı gecikme değerlerinin belirlenmesinde ise ağa gösterilen son veri ve geçmiş değerler arasındaki korelasyon katsayıları incelenmiş, farklı durumlar için ayrı ayrı modeller oluşturulmuştur. Çalışmada eğitim için Mayıs-Temmuz aylarına ait 3 aylık bir veri seti kullanılırken bir sonraki Ağustos, Kasım ve Ocak aylarından seçilen 100 saat süreli zaman ufukları için 10 dakikalık zaman adımlarıyla tahminler yapılmıştır [41].

Kolhe vd. (2011) ise genetik algoritma ile YSA üzerinde bir optimizasyon yaparak kısa süreli tahminler için hibrit bir model oluşturmuştur. 10 dakikalık zaman adımları ile yapılan tahminlerde YSA'nın tek başına yeterli bir performans gösterdiği belirtilirken oluşturulan hibrit modelin, tahminlerin hata oranlarını düşürdüğü vurgulanmıştır. Ayrıca türbinlerin yüksek hızlarda kapandığı durumlarda YSA'nın hata oranının arttığı ve bu noktalar için doğru tahminler yapamadığı da belirtilmiştir [42].

Chang vd. (2012) öncelikle ayların ilk 20 gününü eğitim, son 10 gününü test verisi olarak belirlemiş ve bu koşullarda en iyi girdi parametreleri ve gecikme değerlerini araştırmıştır. Oluşturulan 16 farklı modelin içinden en iyi sonuçları veren model seçilip, 100 saatlik bir zaman ufku için 10 dakikalık zaman adımlarıyla tahminler yaptırılmıştır. Sonuçların genel olarak başarılı olduğu görülürken; yüksek hız ortalamasına ait aylar

için hata oranlarının çok düşük olduğu, düşük hız ortalamasına sahip aylarda ise hata oranları artmasına rağmen iyi sonuçlar alındığı belirtilmiştir [43].

Sideratos ve Hatziargyriou (2007) ise rüzgar hızı ve üretim girdilerine ek olarak rüzgar yönü ve tahmin edilecek zamanı da girdi olarak kullanan hibrit bir model oluşturmuştur. Çalışmada meteorolojik tahminlerin, tahmin modellerinin performansı üzerinde önemli etkisi olduğu belirtilmiş ve bu nedenle modelin ilk basamağında rüzgar hızları bir özdüzenleyici harita (*ing. Self Organized Map - SOM*) ile üç sınıfa ayrılmıştır. Tahmin ise sonraki basamaklarda radyal tabanlı fonksiyon ağı (*ing. Radial Basis Function - RBF*) ile bulanık mantık kullanılarak oluşturulan bir hibrit model ile yapılmıştır. 48 saat süreli bir zaman ufku için yapılan tahminler naive yöntemden daha başarılı olurken, ANEMOS projesi sonucunda ortaya çıkan en gelişmiş modellerle de karşılaştırmalar yapılmış ve en iyi sonuç veren modellere yakın hata oranları elde edildiği belirtilmiştir [44].

Kazemzadeh vd. (2016) rüzgar hızı, geçmiş üretim değerleri, rüzgar yönü ve sıcaklık verilerini girdi olarak kullanırken hava basıncı ve nemlilik değerlerinin de girdi olarak kullanılmasının tahmin modellerini nasıl etkileyeceğini araştırmıştır. Çalışma için oluşturulan hibrit modelde ise farklı bir yol izlenmiş; girdi olarak kullanılan geçmiş üretim değerleri önce bir radyal tabanlı fonksiyon ağına gösterilmiş ve burdan alınan tahmin sonuçları dalgacık dönüşümü ile ayrıştırılmıştır. Daha sonra tüm girdiler farklı öğrenme algoritmalarıyla çalışan ve emperyalist rekabetçi algoritmayla (*ing. Imperialistic Competitive Algorithm - ICA*) optimize edilen 3 farklı YSA'dan oluşan hibrit modele verilmiştir. Tahmin sonuçları farklı optimizasyon algoritmalarıyla ve hibrit modeldeki bazı bileşenlerin çıkartılmasıyla elde edilen modellerle karşılaştırılmış ancak en iyi sonucun önerilen model ile alındığı belirtilmiştir. Hava yoğunluğu ve nemlilik girdilerinin ise hemen hemen her modelde hata oranlarını azalttığı vurgulanmıştır [45].

Bazı çalışmalarda ise oluşturulan ağ yapısına göre geçmiş üretim değerleri girdi olarak kullanılmadan, sadece meteorolojik parametrelerle çalışan modeller tercih edilmektedir.

Li vd. (1997) üretim değerlerini girdi olarak kullanmayan statik yapıya sahip bir çok katmanlı algılayıcı ağ (MLP) modeli oluşturarak 50 saat uzunluğunda zaman ufku için tahminler üzerinde çalışmıştır. Bu çalışmada girdi olarak rüzgar hızı ve rüzgar yönünden yararlanılmıştır. Çalışmada, rüzgar yönünün, türbinlerin rüzgarın geldiği yöne doğru dönme özelliğine sahip olmasından dolayı üretim üzerinde çok büyük bir etkisi olmadığı

ancak düşük üretim değerlerine sahip zaman aralıklarında rüzgar yönü değişimlerinin daha fazla olduğu görülmüştür. Oluşturulan model, türbinin güç eğrisi üzerinden yapılan üretim hesaplamalarıyla karşılaştırılmış ve YSA'nın daha doğru sonuçlar verdiği belirtilmiştir. Bu durumun nedeni olarak ise güç eğrisinin, birçok fiziksel koşuldan etkilenen rüzgar hızı ile birlikte türbinin dinamik performansını tam olarak yansıtamadığından kaynaklı olduğu belirtilmiştir [46].

Han vd. (2011) ise rüzgar hızı, rüzgar yönü, sıcaklık, basınç ve bağıl nem değerlerini 24 saat süreli zaman ufku tahmin etmek için kullanmıştır. Bu çalışmada geri yayılım algoritmasının (*ing. Backpropagation Algorithm - BP*) yerel minimumlara takılmaya meyilli bir algoritma olması nedeniyle oluşturulan YSA modeli tabu arama algoritmasıyla (*ing. Tabu Search Algorithm - TS*) optimize edilmiştir [47].

Dai vd. (2012) rüzgar hızı, rüzgar yönü, sıcaklık, basınç ve nem değerlerini YSA modeli için girdi olarak kullanarak Çin'de gün sonrası piyasası için yapılan tahminleri geliştirmek adına bir çalışma yapmıştır. 24 saat zaman ufku için 15 dakika süreli zaman adımlarıyla tahminler yapılırken, meteorolojik veriler iki farklı sistemden alınan NWP tahminlerinden oluşmuştur. Model oluşturulurken rüzgar hızı tahminlerinin sistem performansı üzerindeki öneminden yola çıkarak; bu verilere tahmin modeline geçmeden önce Kalman filtresi uygulanmış ve bu yöntemle daha başarılı sonuçlar elde edildiği belirtilmiştir [48].

Peng vd. (2013) ise meteorolojik verileri girdi olarak kullanan temel bir YSA modeli ile fiziksel ve istatistiksel yaklaşımların birleşiminden oluşan bir hibrit modelin tahmin performansını karşılaştırmak adına bir çalışma yapmıştır. Sonuçlar incelendiğinde hibrit modelin hata oranının daha düşük ancak yavaş ve maliyeti yüksek bir yöntem olduğu, YSA'nın ise daha hızlı sonuç verdiği ve yüksek bir maliyet gerektirmediği belirtilmiştir [49].

Ghadi vd. (2014) geçmiş iki güne ait meteorolojik verileri kullanarak 36 saat ve 20 dakika zaman ufukları için bir rüzgar çiftliğinin toplam üretimini tahmin eden bir model oluşturmuştur. Çalışmada oluşturulan YSA modelinin optimizasyonu için emperyalist rekabetçi algoritmadan yararlanılırken, her türbin için ayrı ayrı yapılan modellemelerden elde edilen sonuçların son basamakta bir araya getirilmesiyle tüm çiftlik için tahmin yapabilen bir model kullanılmıştır [50].

Çalışmalarda tercih edilen YSA modelleri ve özellikleri Çizelge 1.2’de yer almaktadır.



Çizelge 1.2. Literatürde kısa süreli rüzgar gücü tahmini için kullanılan YSA modelleri ve özellikleri

Çalışma	YSA modeli	Zaman ufku-Zaman adımı	Girdiler	Öğrenme için gösterilen süre	Verilere uygulanan önışlemler	Hata fonksiyonu	Performans kriteri
Kariniotakis vd. (1996)	Çok katmanlı geri beslemeli YSA	2 saat 10 dakika	Rüzgar hızı Geçmiş üretim değerleri	2.5 gün		RMSE	Naive yöntem
Li vd. (1997)	Çok katmanlı YSA	50 saat 10 dakika	Rüzgar hızı Rüzgar yönü	250 saat	Normalizasyon [0, 5]	(Act-Est/Act).%	Güç eğrisi üzerinden hesaplanan üretim
Methaprayon vd. (2007)	YSA	3 gün 10 dakika	Rüzgar hızı Geçmiş üretim değerleri	3 ay	$s = \frac{x - \mu_x}{\sigma_x}$	NMAE	Gecikme değerlerini değiştirerek en iyi sonuç elde edilen modeller
Sideratos, Hatziaargyriu (2007)	Hibrit: Radyal tabanlı fonksiyon ağı ve Bulanık mantık	41 saat 1 saat	Rüzgar hızı Geçmiş üretim değerleri Rüzgar yönü Tahmin saati		SOM, Normalizasyon	NMAE NRMSE	Naive yöntem
Catalao vd. (2009)	YSA	24 saat	Geçmiş üretim değerleri			MAPE SSE SDE	Naive yöntem
Han vd. (2011)	YSA & Tabu arama algoritması ile optimizasyon	24 saat	Rüzgar hızı Rüzgar yönü Sıcaklık Basınç Nemlilik	3 ay	Normalizasyon [0, 1]	MAE RMSE	Optimize edilmemiş YSA
Kolhe vd. (2011)	YSA & Genetik algoritma ile optimizasyon	- 10 dakika	Rüzgar hızı Geçmiş üretim değerleri	1 ay	Eğri uydurma		
Chang vd. (2012)	YSA	20 gün & 100 saat 10 dakika	Rüzgar hızı Geçmiş üretim değerleri	10 gün	Normalizasyon [-1, 1]	MRE R ²	Farklı girdiler kullanılan modeller
Dai vd. (2012)	YSA	24 saat 15 dakika	Rüzgar hızı Rüzgar yönü (sin&cos) Sıcaklık Nemlilik Basınç		Kalman filtresi	MSE R NRMSE	Filtre uygulanmamış model
Peng vd. (2013)	Hibrit: YSA & Fiziksel yaklaşım	- 10 dakika	Rüzgar hızı Rüzgar yönü (sin&cos) Sıcaklık	2 ay	Normalizasyon	MAE NRMSE	YSA
Chitsaz vd. (2014)	Dalgacık YSA (WNN)	6 saat 1 saat	Geçmiş üretim değerleri	60 gün	Öznitelik seçimi, Dalgacık dönüşümü	nRMSE nMAE	Naive yöntem Farklı YSA modelleri Farklı öğrenme algoritmaları ile çalışan modeller

Ghadi vd. (2014)	YSA & Emperyalist rekabetçi algoritma ile optimizasyon	36 saat & 20 dakika (çok kısa süreli tahmin) 1 saat	Rüzgar hızı Rüzgar yönü Sıcaklık Nemlilik Basınç	2 gün		RMSE	
Catalao vd. (2015)	Hibrit: ANFIS	3 saat 15 dakika	Geçmiş üretim değerleri	12 saat	Normalizasyon (0-1), Karşılıklı bilgi (Mutual information), Dalgacık dönüşümü	MAPE, NMAE, Hata varyansı	Naive yöntem YSA ARIMA
Kazemzadeh vd. (2016)	Hibrit: Radyal tabanlı fonksiyon ağı & Dalgacık dönüşümü & Farklı öğrenme algoritmaları ile çalışan YSA'lar	24 saat & 72 saat 1 saat	Rüzgar hızı Geçmiş üretim değerleri Sıcaklık Rüzgar yönü + Basınç Nemlilik		Normalizasyon [-1, 1] Dalgacık dönüşümü	MAPE NRMSE	Modelde kullanılan yapılar ile oluşturulan farklı hibrit modeller

Türkiye’de YSA yöntemi kullanılarak yapılan çalışmalar incelendiğinde ise genellikle rüzgar hızı tahmini üzerinde yoğunlaştığı görülmektedir.

Arcaklıoğlu vd. (2005) Türkiye’nin rüzgar haritasını oluşturmak amacıyla yedi bölge için rüzgar hızı tahmini ve bu tahminler üzerinden potansiyel güç tahmini yapmıştır. Altı bölge için ortalama hata yüzdesi (*ing. Mean Error - ME*) %3 ile %6 arasında olup, sonuçlar başarılı kabul edilirken, yıllık rüzgar hızı ölçümlerinin engelleyici derecede geniş düzensizliklere sahip olduğu Güneydoğu Anadolu bölgesinde hata oranının kabul edilemeyecek bir aralığa ulaştığı belirtilmiştir [51].

Şahin vd. (2007) ise seçilen bir bölgeye ait aylık ortalama rüzgar hızını, çevredeki istasyonların rüzgar hızı verilerini kullanarak tahmin etmiştir. Çalışmada Doğu Akdeniz bölgesinde yer alan 8 istasyon kullanılmıştır. Elde edilen sonuçlarda ortalama mutlak hata yüzdesi (*ing. Mean Absolute Percentage Error - MAPE*) %14.13 ile en yüksek Antakya için ve %4.49 ile en düşük Mersin için hesaplanmış ve bu yöntem rüzgar hızı verileri bilindiği sürece herhangi bir topografik veriye ihtiyaç duymaması nedeniyle rüzgar hızı tahmini için uygun olarak değerlendirilmiştir [52].

Taşçıkaraoğlu ve Uzunoğlu (2011) türbülanslı rüzgar hızlarının tahmin araçlarının performansını olumsuz yönde etkilemesi nedeniyle oldukça değişken rüzgar hızlarını kullanarak tahmin doğruluğu ve tahmin edilen sürenin uzamasıyla artan hataları incelemiştir. Çalışmada YSA’ya girdi olarak verilen rüzgar hızları önce dalgacık dönüşümü yardımıyla daha kararlı karakteristiklere sahip bileşenlere ayrılmış ve her bileşen ayrı ayrı tahmin edilmiştir. Sonuçlarda tahmin süresinde adımların uzatılmasının özellikle son adımların hatalı tahmininden dolayı doğruluğu oldukça azalttığı belirtilmiştir. Ayrıca en yüksek frekans seviyesinin filtrelenmesi sonucunda hata ölçütlerinde %0.9 azalma olduğu gözlemlenmiştir [53].

Çelik ve Kolhe (2013) ise YSA ve Weibull tahmin yöntemlerini kullanarak Bozcaada için rüzgar hızı olasılık dağılımlarını belirlerken diğer çalışmalardan farklı olarak seçtikleri bazı türbinlerin özelliklerine göre güç yoğunluğu üzerinden güç tahmini yapmıştır [54].

Türkiye’de YSA ile rüzgar enerjisi tahminleri için yapılan çalışmalar Çizelge 1.3’te verilmektedir.

Çizelge 1.3. Türkiye’de YSA ile rüzgar enerjisi tahminleri için yapılan çalışmalar

Rüzgar Hızı	YSA modeli	Zaman ufku	Girdiler	Öğrenme için gösterilen süre	Hata fonksiyonu
Arcaklıoğlu vd. (2004)	YSA	-	Rüzgar hızı	50 yıl	ME
Şahin vd. (2006)	YSA	2 yıl	Rüzgar hızı	8 yıl	MAPE
Taşçıkaraoğlu ve Uzunoglu (2011)	YSA	-	Dakikalık ortalama rüzgar hızı	35 saat	MAE RMSE
Güç Yoğunluğu					
Çelik ve Kolhe (2013)	Genelleştirilmiş ileri beslemeli YSA	1 yıl	Weibull parametreleri (c&k) Rüzgar hızı	8 yıl	MSE R MAE

1.8. Tezin Amacı, Kapsamı ve Yöntem

Rüzgar enerjisi tahminlerinde, fiziksel koşulların her bölge için aynı olmaması ve bu durumun tahmin sonuçlarını etkilemesi nedeniyle her bölgeye ait veriler ve bu verilerden elde edilen sonuçlar kendi içerisinde değerlendirilmektedir. Dünyada, yapay sinir ağları kullanılarak farklı bölgeler için rüzgar üretim tahmini konusunda yapılmış çalışmalar mevcuttur. Ancak Türkiye için yapılan çalışmalarda genellikle rüzgar hızı tahmini üzerinde çalışılmış olup, üretim tahmini de yapılan bazı çalışmalar mevcut olmasına rağmen bu konu hakkında yapılmış geniş kapsamlı bir çalışmaya rastlanmamıştır. Mevcut çalışmada; Türkiye’de üretime devam eden bir rüzgar çiftliğine ait geçmiş üretim değerleri, rüzgar hızları ve sıcaklık değerlerinden oluşan veri setleri incelenmiş, YSA modelleri bu veriler ile oluşturulmuş ve test edilmiştir.

Literatürde farklı yapıda birçok YSA modeli bulunurken, incelenen çalışmalarda rüzgar enerjisi tahminlerinde de farklı özelliklere sahip YSA modellerinden faydalandığı görülmüştür. Bu nedenle mevcut çalışmada, statik ve dinamik yapıya sahip iki temel YSA modeli belirlenmiştir. Zamana bağlı ve dinamik yapıda olan YSA kısa süreli bir eğitim verisi ile tahmin yapabilirken, zamana bağlı olmayan statik yapıdaki YSA ile daha uzun süreli bir eğitim verisi ile oluşturulan tek model üzerinden tahmin yapılabilmektedir. Bu çalışmada kısa süreli rüzgar üretim tahminleri için iki modelden elde edilen sonuçlar incelenmiş ve hangi modelin daha iyi sonuç vereceği araştırılmıştır. Daha önce yapılan çalışmalarda oluşturulan modeller için YSA’ya eğitim aşamasında gösterilen veri setinin kapsadığı zaman aralığı, Çizelge 1.2’de görüleceği gibi 12 saat-3

ay aralığındadır. Minimum veri sayısı ile tahmin yapacak olan bir modelin verilere erişilebilirlik konusunda avantaj sağlayacak olması nedeniyle bu çalışmada zamana bağlı dinamik ağ modeli için belirlenen minimum veri sayısı 2 gündür. Ancak eğitim setinin uzunluğunun etkilerinin görülebilmesi için bu ağ modeli, aynı zamanda daha uzun süreyi kapsayan (1 hafta) veri setleriyle de öğrenme işlemini gerçekleştirmiş ve eğitim süresinin YSA performansı üzerindeki etkileri incelenmiştir. Zamana bağlı olmayan statik yapıdaki ağ modelinde ise farklı mevsimlere ait 1'er haftalık verilerden oluşturulmuş bir eğitim verisi ağı gösterilip, oluşturulan bu ağ modeli üzerinden farklı test günleri için tahminler yapılmıştır.

Girdiler seçilirken çok kısa süreli tahminler için sadece geçmiş üretim değerlerinin kullanılabilirdiği modeller olduğu görülürken kısa süreli tahminler için rüzgar hızı ve diğer meteorolojik ölçümlerden yararlanılmıştır. Bu bilgiler göz önünde bulundurularak çalışmada oluşturulan modellerde girdi olarak geçmiş üretim değerlerinden, rüzgar hızından ve sıcaklıktan ayrı ayrı yararlanılmış ve girdilerin kısa süreli rüzgar üretim tahmini için performans üzerindeki etkileri bir bölümde incelenmiştir.

Ayrıca YSA mimarisinde sıklıkla kullanılan aktivasyon fonksiyonları; lojistik (sigmoid), hiperbolik tanjant (sigmoid) ve (radyal tabanlı) Gaussian fonksiyonu oluşturulan her model için kullanılmış ve seçilen aktivasyon fonksiyonlarının tahmin performansını etkileyip etkilemediği araştırılmıştır.


Literatürde, rüzgar üretim tahminleri için her çalışmada seçilen bölge ve oluşturulan modelin özelliklerine göre farklı özellikte veriler kullanıldığı bilinmektedir. Bu durum her veri ve bu verilerle oluşturulan modelin kendi içinde belirli standartlara göre değerlendirilmesini gerektirmektedir. Performans değerlendirmesi için farklı çalışmalarda da farklı yöntemler kullanılırken, bu çalışmada dünyada genel olarak standart kabul edilen ANEMOS projesinde belirlenen performans değerlendirme kriterleri göz önüne alınmıştır.

Tez kapsamında oluşturulan YSA modelleri MATLAB, Neural Network Toolbox programı ile oluşturulmuştur. Oluşturulan modellerin değerlendirilmesi ve yapılan hesaplamalar MATLAB programı üzerinden tamamlanmıştır.

2. YAPAY SİNİR AĞLARI

Yapay sinir ağı, insan beyninin öğrenme özelliğinden yola çıkarak geliştirilmiş bilgi işlem teknolojileridir. Temel çalışma prensibi, insan beynindeki biyolojik sinir hücrelerinin (nöronlar) çalışma prensibine dayanmaktadır. Beynin işlevlerini yerine getirebilmesini sağlayan temel yapı elemanı olan nöronlar, birbirleriyle olan bağlantıları ile sinirsel işlevin temeli olan bilgi akışını sağlamaktadır [55].

Şekil 2.1’de görüldüğü gibi biyolojik nöronlar üç ana kısımdan oluşmaktadır. Bir biyolojik nöronda dendritler bir tür alıcı görevi görerek diğer nöronlardan gelen sinyalleri kabul eder ve hücre çekirdeğinin bulunduğu somaya iletir. Çekirdek ise alınan sinyalleri toplar ve diğer nöronlara aktarmak üzere aksona iletir. Aksonların ucunda bulunan sinapsislerde ise gelen toplam sinyal, diğer hücreye aktarılmadan önce bir önışlemden geçirilir. Bu önışlemden bir eşik değerine göre, gelen toplam sinyal belirli bir aralığa indirgenir ve dendritlere bu şekilde iletilir [56, 57].




Şekil 2.1. Biyolojik nöron [57]

İnsan beynine paralel olarak YSA’larda da çok sayıda ve birbirine bağlı işlem elemanları (nöron) bulunurken, bu elemanlar arasında belirli ağırlıklarda bağlantılar yer almaktadır [58]. Bu ağırlıkların düzenlenmesi ise YSA’larda “öğrenme” işlemi olarak tanımlanmaktadır.

2.1. Yapay Sinir Ağlarının Yapısı

Yapay sinir ağlarının temel işlem elemanı nöronlardır. Şekil 2.2’de görülen yapay nöron yapısı, biyolojik nöronlara benzer olarak dış dünyadan aldığı girdileri (p) işler ve bir çıktı (a) iletir.



Şekil 2.2. Yapay nöron yapısı

İlk olarak nörona gelen her bir girdi bir ağırlık (w) değeriyle çarpılır. Bu ağırlık değerleri girdinin hücre üzerindeki etkisini belirler ve biyolojik nöronlarda bulunan sinaptik bağlantılar gibi düşünülür [57]. Elde edilen değerler bir net girdi fonksiyonu ile işlenir. Genel olarak birçok YSA modelinde net girdi fonksiyonu toplam fonksiyonudur (Σ) ancak bazı durumlarda farklı fonksiyonlardan da yararlanılmaktadır (çarpım fonksiyonu gibi) [59]. Net girdi değeri hesaplandıktan sonra ise aktivasyon fonksiyonu (f) ile hücrenin üreteceği çıktı belirlenmektedir. Bias (b) değeri ise 1'e eşit olan özel bir işlem elemanıdır. Geri yayımlı YSA'larda bias girdilerinin amacı öğrenmeyi iyileştirmek için aktivasyon fonksiyonunun orijinini dengeye getirmek ve yerel minimum değerlerine takılmayı önlemektir.

2.2. Aktivasyon (Transfer) Fonksiyonları

Aktivasyon ya da transfer fonksiyonları nöronun doğrusal olma veya olmama özelliğini ve çıktının sınırlarını belirleyen fonksiyonlardır. Bir nörona gelen net girdi hesaplandıktan sonra aktivasyon fonksiyonuna iletilir ve katmandan diğer katmana iletilecek ya da dış dünyaya verilecek çıktı elde edilir.

Aktivasyon fonksiyonu olarak; problemin çözümü için uygun bulunan bir fonksiyon seçilebilmektedir. Özellikle kolay türevi alınan bir fonksiyonun seçilmesi ise eğitim hızı için avantaj sağlamaktadır. En sık kullanılan aktivasyon fonksiyonları aşağıda listelenmiştir.

- **Adım fonksiyonu:** Adım fonksiyonu, mantıksal çıktı veren bir fonksiyondur ve bu nedenle sınıflandırma amacıyla kullanılmaktadır.

$$a = \begin{cases} 1, & n \geq 0 \\ 0, & n < 0 \end{cases} \quad (2.1)$$

- **Lineer aktivasyon fonksiyonu:** Doğrusal bir fonksiyon olarak basit ancak kısıtlı bir hesaplama imkanı tanıyan fonksiyondur. Genellikle çıktı katmanları için tercih edilmektedir.
- **Sigmoid aktivasyon fonksiyonu:** S harfine benzeyen şekilleri ile doğrusal olmayan fonksiyonlar olmaları nedeniyle YSA’larda sıklıkla tercih edilen fonksiyonlardır. Lojistik fonksiyonu (2.2) ve hiperbolik tanjant fonksiyonu (2.3) YSA modellerinde en yaygın olarak kullanılan aktivasyon fonksiyonlarıdır.

$$a = \frac{1}{1+e^n} \quad (2.2)$$

$$a = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (2.3)$$


- **Gaussian aktivasyon fonksiyonu:** Radyal tabanlı fonksiyonlar arasında YSA’larda en yaygın olarak kullanılan aktivasyon fonksiyonudur.

$$a = \exp(-n)^2 \quad (2.4)$$


Radyal tabanlı fonksiyon ağlarının diğer ağlardan farkı; net girdinin hesaplanma şeklidir. YSA’larda genel olarak ağırlık matrisi ile girdilerin iç çarpımıyla hesaplanan net girdi kullanılırken, radyal tabanlı fonksiyon ağlarında; girdi vektörüyle ağırlık matrisinin satırları arasındaki uzaklık hesaplanır. Ayrıca net girdinin hesaplanma şeklinin farklı olmasının yanında bias değeri, YSA’larda toplam fonksiyonuyla ağa etki ederken radyal tabanlı fonksiyon ağlarında bias değeri çarpım fonksiyonuyla etki etmektedir. Genellikle radyal tabanlı fonksiyon ağları ile ilgili çalışmalarda “bias” yerine standart sapma veya varyans terimleri kullanılmakta ve Gaussian aktivasyon fonksiyonu için standart sapmaya bağlı bir bias değeri (2.5) kullanılmaktadır [60].

$$b = \frac{1}{(\sigma/\sqrt{2})} \quad (2.5)$$


Şekil 2.3’te YSA modellerinde sıklıkla kullanılan aktivasyon fonksiyonları sunulmuştur.




a) Adım fonksiyonu




b) Lineer aktivasyon fonksiyonu



c) Lojistik (sigmoid) fonksiyonu



d) Hiperbolik tanjant (sigmoid) fonksiyonu




e) Gaussian fonksiyonu

Şekil 2.3. YSA modellerinde sıklıkla kullanılan aktivasyon fonksiyonları


2.3. YSA'ların Yapılarına Göre Sınıflandırılması

YSA'lar genellikle katmanlı bir yapıya sahip olmakla birlikte literatürde katmana sahip olmayan ağ yapılarının da olduğu belirtilmektedir [57]. Ancak katmansız ağ yapılarının kullanımı çok yaygın değildir.



Şekil 2.4. Katmansız geri beslemeli YSA

Katmanlı ağ yapılarında ise YSA'ların temel işlem elemanı olan nöronlar (Şekil 2.5) bir araya gelerek katmanları oluştururlar.




Şekil 2.5. YSA katmanı

Genel olarak bir katman, tek nörondan oluşabileceği gibi Şekil 2.5'te görülen yapıya benzer olarak birden çok nörondan da oluşabilmektedir.

Bu tür YSA'lar katmanlar arasındaki bağlantıların özelliklerine göre kendi içinde sınıflandırılmaktadır.


- **İleri beslemeli (ing. *feedforward*) YSA'lar:** En yaygın olarak kullanılan YSA modelidir. İleri beslemeli ağlarda ilk katman girdi katmanı, son katman ise çıktı

katmanıdır. Nöronlar kendilerinden önceki katmanlardan aldıkları bilgileri bir sonraki katmana iletme üzere işlerler; yani bu ağ modellerinde nöronlar kendilerinden önceki katmanlara bilgi gönderemezler. Şekil 2.6’da görüldüğü gibi tek yönlü bir bilgi akışı vardır.



Şekil 2.6. İleri beslemeli YSA modeli


- **Geri beslemeli (ing. recurrent) YSA’lar:** Geri beslemeli ağlarda, geri besleme bir katmandaki nöronlar arasında olabileceği gibi katmanlar arasında da olabilmektedir [55]. Katmanlı ve geri beslemeli YSA’larda ise YSA’nın nöronları arasındaki bağlantılar yine ileri beslemeli olabilirken ağ, çıktı katmanında elde edilen sonuçları, belirlenen gecikme miktarına göre girdi olarak ağa gönderebilmektedir. Bu tür ağlar, çıktının sadece son girdiye değil daha önceki girdilere ve çıktılara da bağlı olduğu durumlar için tercih edilmektedir [60]. Şekil 2.7’de görülen geri beslemeli nöron yapısında belirtildiği gibi elde edilen çıktılar geri besleme ile ağa tekrar girdi (D) olarak gönderilmekte ve belirlenen katman ağırlıkları (ing. layer weight) (lw) ile kullanılmaktadır.



Şekil 2.7. Geri beslemeli nöron

2.4. YSA Mimarisi

YSA'nın genel yapısı girdi katmanı, gizli katman ve çıktı katmanının bir araya gelmesiyle oluşmaktadır. YSA'lar tek katmanlı ya da çok katmanlı olarak çözümü için kullanılacak probleme göre tasarlanabilmektedir [61]. Genellikle ağ mimarisi oluşturulurken ağ girdilerinin sayısının, problem girdilerinin sayısına ve aynı şekilde ağ çıktıların sayısının, problem çıktıların sayısına eşit olmasının problemin çözümü için kolaylık sağlayacağı belirtilmektedir [62]. Ancak YSA oluşturulurken gizli katmandaki nöron sayısının belirlenmesi için kesin bir yöntem bulunmamaktadır.



Şekil 2.8. Çok katmanlı ileri beslemeli (3) bir YSA modeli

Şekil 2.8'de görülen çok katmanlı ileri beslemeli YSA yapısı gösterilirken ağırlıkları ve çıktıları belirten harflerin üzerindeki sayılar, katmanları belirtmek için kullanılırken; alt tarafta bulunan sayılar, o katman içindeki elemanı belirtmek için kullanılmaktadır. Girdi

ağırlıkları (iw) ve katman ağırlıklarını (lw) tanımlayan sayılarda, ilk sayı; ağırlığın etki ettiği katman numarasını belirtirken, ikinci sayı; girdinin alındığı katmanı gösterir.

Çok katmanlı ağ mimarisinde, ilk olarak Şekil 2.8’de görüleceği gibi dış dünyadan bilgiler alınır, girdi ağırlıkları kullanılarak (iw) net girdi hesaplanır ve ilk katmana gönderilir. İşlenen bilgi buradan katman ağırlıklarıyla ikinci katmana (gizli katman) iletilmektedir. YSA’larda bir katmandan elde edilen çıktılar (a) bir diğer katman için girdi olarak kullanılmaktadır. Bu nedenle katman ağırlıkları temel olarak girdi ağırlıklarıyla aynı şekilde belirlenir. Gizli katmanda yapılan işlemler sonucunda elde edilen çıktılar ise son katmana yani çıktı katmanına iletilmekte ve buradan ağın kendisine gösterilen girdiler için ürettiği çıktılar tekrar dış dünyaya verilmektedir.

Radyal tabanlı fonksiyon ağlarında ise farklı olarak ilk katmana gelecek olan net girdinin hesaplanma yöntemi değişmektedir. Daha önce belirtildiği gibi girdi vektörü ile ağırlık matrisinin arasındaki uzaklık hesaplanarak bulunan net girdinin elde edilmesiyle işlemler devam eder. Radyal tabanlı fonksiyon ağlarında ilk katman için hesaplanan net girdi eşitlik 2.6’da ifade edilmiştir.

$$n_i^1 = \|p - w_i^1\| b_i^1 \quad (2.6)$$

Gizli katman kullanımı YSA mimarisinde zorunlu olmasa da gizli katmana sahip olmayan ağ yapılarının karmaşık problemlerin çözümünde yetersiz kalabileceği belirtilmektedir. Genellikle bir gizli katman içeren YSA modellerinin birçok karmaşık problemin çözümü için yeterli olabileceği belirtilirken gizli katman sayısına kullanıcı karar vermektedir [56].

YSA’nın çözümü için kullanılacağı problemin özelliğine göre bu mimariye geri besleme döngüsü de eklenebilmektedir. Genellikle zamana bağımlı olarak değişen verilerin kullanıldığı problemlerde bir geri besleme döngüsü ile modeli oluşturmak daha uygundur.

2.5. Öğrenme Algoritması

YSA’ların önemli özelliklerinden birisi kendisine gösterilen bilgileri öğrenebilme yeteneğine sahip olmasıdır. Öğrenme, YSA’larda danışmanlı, danışmansız ve destekli olmak üzere 3 farklı şekilde olabilmektedir. Danışmanlı öğrenmede, ağa daha önce gerçekleşmiş olan veriler gösterilmekte ve bunlar arasında ilişki kurması

beklenmektedir. Bu çalışmada problemin çözümüne uygun olan danışmanlı öğrenme kullanılmıştır.

Öğrenme, genel olarak YSA’da bağlantı ağırlıklarının düzenlenme sürecine verilen isimdir. Ağın tahmin ettiği verilerle gerçek değerler arasındaki hata oranı istenilen miktara ulaştığında öğrenme tamamlanmış olur. Bu aşamada kullanılan farklı öğrenme algoritmaları bulunmaktadır. En çok kullanılan öğrenme algoritmalarından birisi ise L-M (Levenberg-Marquardt) algoritmasıdır. L-M algoritması, YSA’ların eğitimi için sıklıkla kullanılan geri yayılım (*ing. backpropagation*) algoritması ve Gauss-Newton algoritmasının avantajlarından yararlanılarak oluşturulmuş bir algoritmadır [63].

Geri yayılım algoritmasında hatalar geriye doğru yani çıktı katmanından girdi katmanına doğru azaltılmaktadır ve delta kuralının YSA’lar için genelleştirilmiş halidir [64]. Geri yayılım algoritmasının çıkışındaki düşünce; gizli nöronlarda ağı nasıl bir işlem yaptığının tam olarak bilinmemesinden dolayı hatanın nasıl değiştiğini gözlemlemek için hatanın türevinden yararlanmaktır.

Delta kuralı temel olarak aşağıdaki adımlar izlenerek türetilir:

$$E = \frac{1}{2} \sum_{m \in \text{öğrenme}} (t^m - a^m)^2 \quad (2.7)$$

$$\frac{\partial E}{\partial w_N} = - \sum_m p_N^m (t^m - a^m) \quad (2.8)$$

$$g = \frac{\partial E(p, w)}{\partial w} = \begin{bmatrix} \frac{\partial E}{\partial w_1} \\ \vdots \\ \frac{\partial E}{\partial w_N} \end{bmatrix} \quad (2.9)$$

$$\Delta w = -\varepsilon \frac{\partial E}{\partial w_N} = \sum_m \varepsilon p_N^m (t^m - y^m) \quad (2.10)$$

$$w_{k+1} = w_k - \varepsilon g_k \quad (2.11)$$

Delta kuralında, hata oranını azaltmak için en dik iniş (*ing. gradient descent*) kuralından yararlanılır. Bu nedenle ilk adımda hesaplanan hatanın (E), (2.7) türevi alınır (2.8) ve gradyanı (2.9) bulunur. Ağırlıklarda yapılacak değişiklikler (2.10) bu kurala göre belirlenir. Eşitlik 2.10’da ε ile belirtilen “öğrenme katsayısı” ise yapılacak

değişikliklerin büyüklüklerini ölçeklendirmek için kullanılır. Eşitlik 2.11, k iterasyonundan bir sonraki iterasyon olan $k+1$ iterasyonu için ağırlıklarda yapılacak değişimi ifade etmektedir. Sigmoid fonksiyonlarının YSA’larda sıklıkla tercih edilmesinin nedeni de bu kural doğrultusunda kolaylıkla türevleri alınabilen fonksiyonlar olmalarıdır. İterasyonlar sonucunda elde edilmek istenen hata miktarına ulaşıldığında ise öğrenme tamamlanır. Delta kuralının ağırlık değişimi üzerinde nasıl etki ettiğinin daha detaylı bir matematiksel açıklaması EK 1’de yer almaktadır.

Gauss-Newton yöntemi ise 2. dereceden türevlere ihtiyaç duyan Newton yönteminin (EK 1), 2. derece türevlere ihtiyaç duymayacak ancak neredeyse Newton yöntemi kadar hızlı ve iyi sonuçlar verecek şekilde basitleştirilmiş bir formudur. Bu yöntemde hata fonksiyonunun ikinci dereceden türevlerinden oluşan Hessian matrisi (2.12) yerine hata fonksiyonunun 1. Derece türevlerinden oluşan Jacobian matrisi (2.13) ve transpozunun çarpımından (2.14) yararlanılır [65].

$$H = \nabla^2 E \quad (2.12)$$

$$J = \nabla E \quad (2.13)$$

$$J = \begin{bmatrix} \frac{\partial E_{1,1}}{\partial w_1} & \frac{\partial E_{1,1}}{\partial w_2} & \dots & \frac{\partial E_{1,1}}{\partial w_N} \\ \frac{\partial E_{1,2}}{\partial w_1} & \frac{\partial E_{1,2}}{\partial w_2} & \dots & \frac{\partial E_{1,2}}{\partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial E_{R,M}}{\partial w_1} & \frac{\partial E_{R,M}}{\partial w_2} & \dots & \frac{\partial E_{R,M}}{\partial w_N} \end{bmatrix} \quad (2.14)$$

$$\nabla^2 E \approx J_N^T J_N \quad (2.15)$$

Eşitlik 2.14’te görülen $(R \times M) \times N$ boyutunda Jacobian matrisinde R eğitim için gösterilen örnek sayısını (gerçek değerler), M çıktı sayısını (ağın ürettiği değerler), N ise ağırlık sayısını belirtmektedir [66].

Bu yöntemin kullanılmasıyla Newton yönteminde gradyan hesaplaması (2.16) için ihtiyaç duyulan Hessian matrisinin hesaplanmasına gerek kalmamaktadır. Ağırlıklarda yapılacak değişiklikler Newton metodunda eşitlik 2.17’nin kullanılmasıyla belirlenirken, Gauss-Newton metodunda gradyan hesaplaması (2.18) için ilk türev yeterli olmaktadır.

$$-g = H \Delta w \quad (2.16)$$

$$\Delta w = -H^{-1}g \quad (2.17)$$

$$g = JE \quad (2.18)$$

$$\Delta w = (J_N J_N^T)^{-1} J_N E_N \quad (2.19)$$

L-M algoritması ise bu iki yöntemin birleşiminden oluşur; en dik iniş kuralı ve Jacobian matrisini kullanarak hızlı ve başarılı sonuçlar veren bir algoritmadır. Geri yayılım algoritması yakınsamada güvenilir ancak yavaş bir yöntem olarak tanımlanırken, Gauss-Newton algoritması hızlı fakat yakınsamada dengesizlikler görülen bir algoritmadır. Bu iki yöntemin avantajlarını bir araya getiren L-M algoritması ise hem hızlı sonuç verebilen hem de yakınsamada dengeli bir algoritma olduğundan YSA'ların eğitimi için sıklıkla tercih edilmektedir [67].

L-M algoritmasında Hessian matrisine yaklaşım eşitlik 2.20'deki gibi kullanılmaktadır.

$$H \approx J^T J + \mu I \quad (2.20)$$

Eşitlik 2.20'de her zaman pozitif olarak seçilen kombinasyon katsayısı (μ) ve birim matris çarpımının kullanımıyla, yaklaşılan Hessian matrisinin her zaman tersi olan bir matris olması sağlanmaktadır. L-M algoritmasında ağırlıkların belirlenmesini sağlayan fonksiyon ise eşitlik 2.21'de belirtilmektedir.

$$\Delta w = (J_N J_N^T + \mu I)^{-1} J_N E_N \quad (2.21)$$

3. UYGULAMA


3.1. Veri Seti

Rüzgar enerjisi tahminlerinde öncelikle rüzgar çiftliklerinden elde edilmiş gerçek üretim verilerine ihtiyaç duyulmaktadır. Özellikle YSA gibi istatistiksel yaklaşım temelli tahmin modellerinde geçmişte ölçülmüş rüzgar hızı, üretim vb. parametrelerin veri setlerinin ağırlık eğitimi aşaması için bulunması gerekmektedir. Bu çalışmada kullanılan veriler Türkiye’de faaliyette olan bir rüzgar çiftliğinden alınmıştır. Veri seti; çiftlikte bulunan her türbin için ayrı ayrı ölçülmüş, 2 yıla ait 10 dakikalık ortalama rüzgar hızı (m/s), sıcaklık (°C) ve üretim (kWh) değerlerinden oluşmaktadır. Yapılan tahminler de bu verilere paralel olarak 10 dakikalık zaman adımlarıyla yapılmıştır. Ayrıca çalışmada kullanılan 2 yıllık veri seti; son 10 yıl içinde ölçülmüş 2 yıla aittir.


YSA ile yapılan tahminlerde, türbinlerin üretim miktarının çevresindeki coğrafi koşullardan, diğer türbinlerin yerleşiminden ve benzeri fiziksel koşullardan etkilenmesi nedeniyle, eğer veriler sağlanabiliyorsa her türbin için ayrı bir model oluşturulmasının daha başarılı sonuçlar vereceği ve türbinlerin bakım planlarının yapılması, arızalanması gibi durumlarda avantaj sağlayacağı belirtilmektedir [68].

Bu çalışmada öncelikle; rüzgar çiftliğinden alınan veri setinin kullanılabilirliği tüm türbinler için ayrı ayrı incelenmiştir. İncelenen veriler sonucunda arıza ya da bakım nedeniyle uzun zaman aralıklarında verilerin alınamadığı türbinlerin mevcut olduğu görülmüştür ve en uzun süreli gerçek veriye sahip olan türbin, modellerde kullanılmak üzere seçilmiştir. Seçilen türbin için ölçülen verilerin analizi yapılmış ve daha sonra tüm modeller ona göre oluşturulup, test edilmiştir.

Seçilen türbine ait bir yıl için ölçülmüş ortalama değerler Şekil 3.1 ve Şekil 3.2’de gösterilmektedir. Şekil 3.1’de görüldüğü gibi çalışmada kullanılan verilerde; en yüksek aylık ortalama rüzgar hızı ocak ayında (10.2 m/s); en düşük aylık ortalama rüzgar hızı ise mayıs ayında (5.7 m/s) gözlemlenmiştir. Şekil 3.2 incelendiğinde ise en düşük aylık ortalama üretimin gerçekleştiği ay, en düşük aylık ortalama rüzgar hızına sahip mayıs ayı olurken; en yüksek aylık ortalama üretimin temmuz ayında (9.8 m/s) gerçekleştiği görülmektedir. Bu durumun nedenleri ilerideki bölümlerde detaylı olarak incelenmiştir.




Şekil 3.1. Çalışmada kullanılan yıla ait aylık ortalama rüzgar hızları




Şekil 3.2. Çalışmada kullanılan yıla ait aylık ortalama üretim miktarları

Ayrıca haziran ve aralık aylarında, ölçülen rüzgar hızlarının türbinin üretim yapması için uygun olduğu ancak üretimin uzun süreli olarak tamamen durduğu zaman aralıkları bulunmaktadır. Günümüzde rüzgar çiftliklerinde (ticari amaçlı) kullanılan türbinlerin genel olarak devreye girme (*ing. cut-in*) hızları 3.5-4 m/s, devreden çıkma (*ing. cut-out*) hızları ise 28 m/s civarında olurken, maksimum üretime ulaşılan hızların (*ing. rated wind speed*) 12-14 m/s aralığında olduğu belirtilmektedir [69, 70]. Şekil 3.3'te çalışmada kullanılan özelliklerde, ticari amaçlı rüzgar türbinleri için genel bir teorik güç eğrisi görülmektedir.




Şekil 3.3. Ticari amaçlı kullanılan türbinler için teorik güç eğrisi

Şekil 3.1 ve Şekil 3.2’de ay içinde üretim gerçekleşen günlere ait ortalama gösteren eğriler, ölçülen rüzgar hızları üretim için uygun aralıkta görünmesine rağmen üretim gerçekleşmeyen bu günlerin aylık ortalama dahil edilmeden hesaplanmasıyla elde edilmiş ortalama değerleri göstermektedir. Şekil 3.4’te ise türbinin normal şartlarda çalıştığı durumlar için 10 dakikalık üretim ortalamalarının 0 kWh’in üzerinde olduğu saatler ve aylık yüzde oranları görülmektedir. Farklı bir şekilde ifade edildiğinde, Şekil 3.4’te görülen değerler, türbinin üretim yapması için uygun rüzgar hızı ortalamalarının ölçüldüğü saat miktarını belirtmektedir. Bu grafikte üretim yapılmayan saatler hesaplanırken sadece türbinin devreye girme hızının altında veya devreden çıkma hızının üzerinde kalan rüzgar hızı ortalamalarının görüldüğü ve üretimin normal olarak durduğu zaman aralıkları göz önüne alınmıştır.



Şekil 3.4. Ay içinde üretim gerçekleşen saatler ve aylık oranları

Haziran ayında, rüzgar hızı ortalaması ay içindeki günlere göre daha yüksek olan 9 gün (15.0 m/s) türbin arıza ya da bakım nedeniyle üretim yapmamış ve geri kalan 7.1 m/s ortalama rüzgar hızına sahip 21 gün dikkate alınarak hesaplamalar yapılmıştır. Ayrıca rüzgar hızı ortalamasının üretim için oldukça uygun olduğu günlerde üretimin durması durumunun, bir arızadan kaynaklanmış olabileceği düşünülmüştür. Bu nedenle Şekil 3.4'te haziran ayı incelendiğinde, üretim gerçekleşen saat miktarı diğer aylara göre daha düşük görünmesine rağmen üretim gerçekleşen saatlerin ay içindeki (21 gün) oranının %72.9 olduğu görülmektedir. Aralık ayında ise, sıcaklık ortalamasının ayın geneline (7.1 °C) göre daha düşük olduğu yaklaşık 3 gün (0.7 °C) türbin üretim gerçekleştirmemiş ve bu durumun buzlanma etkisinden kaynaklanabileceği düşünülüp, 28 gün dikkate alınarak hesaplamalar yapılmıştır. Buzlanma etkileri ile ilgili daha detaylı açıklamalar bir sonraki bölümde verilmiştir.



Şekil 3.5. Çalışmada kullanılan yıla ait aylık ortalama sıcaklık değerleri


Şekil 3.5'te türbin üzerinde (kule yüksekliğinde) bulunan bir sıcaklık sensörü ile ölçülen sıcaklık değerlerinin aylık ortalamaları görülmektedir. Kullanılan veri setinde en düşük sıcaklık ortalaması 3.6 °C ile ocak ayında gözlemlenirken, en yüksek sıcaklık ortalaması ise 22.6 °C ile temmuz ayında gözlemlenmektedir. Türbinin bulunduğu bölgede günlük sıcaklık ortalamaları da dikkate alındığında; yılın büyük bölümünde ölçülen ortalama sıcaklık değerinin 0 °C'nin üzerinde olduğu görülmektedir.

3.1.1. YSA Modellerinde Kullanılacak Verilerin Seçimi ve Özellikleri


Literatürde genel olarak rüzgar tahminlerinde hata oranlarının; zaman ufkuna, bölgenin karmaşıklık özelliğine, mevsimsel değişikliklere ve hava koşullarına bağlı olarak değişmesi beklenmektedir [20]. Tahmin çalışmalarında, rüzgar hızı verilerinin kararsız yapılarına rağmen kısa süreli olarak incelendiklerinde gece-gündüz, uzun süreli incelendiklerinde ise mevsimler arasında periyodik örüntülere sahip olduğunun görüldüğü belirtilmektedir [71]. Rüzgar hızının bu özelliğinin tahmin çalışmalarında yardımcı olabilecek bir özellik olduğu da düşünülmektedir [72]. Bigdeli vd. (2013), rüzgar üretim tahmini için mevsimsel olarak belirlenmiş 4 ayrı veri seti ile tahmin modelleri oluşturmuştur [73]. Kazemzadeh vd. (2016), model performansını 4 ayrı mevsimden seçilen test günleri için değerlendirmiş ve hata oranlarını mevsimsel olarak değerlendirmiştir [45]. Karlsson (2014) ise rüzgar hızının ve buna bağlı üretimin mevsimsel özelliklerini göz önünde bulundururken diğer çalışmalardan farklı olarak yılın her mevsimine ait bilgi içeren bir eğitim veri seti oluşturmuş ve ağın eğitim

sırasında düşük ve yüksek hızlardaki farklı durumları tek veri setinden öğrenmesini sağlamıştır [74]. Bu bilgiler doğrultusunda bu çalışmada da farklı mevsimlere ait günlerin, oluşturulan modelleri eğitime ve değerlendirme için kullanılmasına karar verilmiştir. Veri setinin içinden seçilen aylar; yılın en yüksek aylık ortalama rüzgar hızının görüldüğü ocak ayı, yılın en düşük aylık ortalama rüzgar hızının ve üretiminin gerçekleştiği mayıs ayı, yılın en yüksek aylık ortalama üretiminin gerçekleştiği temmuz ayı ve sonbahar mevsiminden seçilen ekim ayıdır.


Rüzgar hızı ve güç arasındaki doğru orantı göz önünde bulundurulduğunda en yüksek aylık ortalama üretimin, aylık en yüksek rüzgar hızı ortalamasının ölçüldüğü ocak ayı içerisinde gerçekleşmesi beklenmektedir. Ancak Şekil 3.2’de görüldüğü gibi yıl içindeki bazı aylarda gerçekleşen aylık ortalama üretim miktarı, ocak ayında gerçekleşen ortalama üretim miktarından daha yüksektir. Bu durumun temel nedeni, ay içinde görülen çok yüksek rüzgar hızlarıdır. Ocak ayında aylık rüzgar hızı ortalaması, gerçekleşen çok yüksek rüzgar hızları ile artarken, türbinin 28 m/s ve üzerindeki hızlarda kırılmalara önlem olarak üretimi durdurduğu saat miktarı da artmaktadır. Bu etkinin görülebilmesi için Şekil 3.4 incelendiğinde de ocak ayında üretim yapılan saatlerin oranının %80.4 olduğu görülmektedir. En yüksek aylık üretim ortalamasının gerçekleştiği temmuz ayında ise, türbinin devreden çıkma hızının aşılması nedeniyle üretimi durdurduğu saatler ocak ayına göre oldukça az miktardadır. Şekil 3.6’da ocak ayına bakıldığında; ay içerisinde 10 dakikalık rüzgar hızı ortalamasının 30 m/s’nin bile üzerine çıktığı zaman aralıkları görülürken, temmuz ayı içerisinde 10 dakikalık ortalama rüzgar hızları en fazla 22 m/s’ye çıkmaktadır. Ayrıca Şekil 3.7’de belirtilen aylık rüzgar hızı dağılımları da incelendiğinde temmuz ayında ölçülmüş rüzgar hızlarının, türbinin maksimum üretim yapması için uygun olan aralıkta yoğunlaştığı görülmektedir.




a) Ocak



b) Mayıs




c) Temmuz




d) Ekim


Şekil 3.6. Çalışmada kullanılan aylarda ölçülen 10 dakikalık rüzgar hızı ortalamaları




a) Ocak



b) Mayıs



c) Temmuz




d) Ekim

Şekil 3.7. Çalışmada kullanılan aylara ait rüzgar hızı dağılımları


Çalışmada kullanılan veri setinde en düşük aylık ortalama üretim, beklenildiği gibi en düşük aylık ortalama rüzgar hızına sahip mayıs ayında gerçekleşmiştir. Şekil 3.6'da mayıs ayı incelendiğinde; ayın büyük bölümünde 10 dakikalık rüzgar hızı ortalamalarının diğer aylara göre daha düşük olduğu görülürken, ayın genel profiline göre yüksek rüzgar hızlarının ölçüldüğü kısa zaman aralıkları da görülmektedir. Şekil 3.7'de mayıs ayına bakıldığında da ölçülen rüzgar hızlarının 10 m/s'nin altındaki hızlarda yoğunlaştığı görülmektedir. Gerçekleşen rüzgar hızlarının, türbinin devreye girme hızının altında kaldığı zaman aralıklarının sık olması nedeniyle Şekil 3.4'te de belirtildiği gibi mayıs ayı içinde üretim gerçekleşen saatlerin aylık oranının %70 olduğu hesaplanmıştır. Ekim ayında ise Şekil 3.6 ve Şekil 3.7'de görüldüğü gibi ölçülen rüzgar

hızları türbinin devreden çıkma hızının altında kalmıştır ve türbinin üretimi sadece devreye girme hızından daha düşük rüzgar hızlarının gerçekleştiği zaman aralıklarında durmuştur. Şekil 3.4'te görüldüğü gibi bu ay içinde üretim gerçekleşen saatlerin aylık oranı ise %82.4'tür.


Farklı mevsimlerden seçilen aylara ait verilerin kullanılması farklı sıcaklık değerlerine sahip durumların da incelenmesini gerektirmektedir. Şekil 3.8'de 10 dakikalık ortalama sıcaklık değerleri görülen aylar incelendiğinde sadece ocak ayında sıcaklığın 0 °C'nin altına düştüğü zaman aralıkları görülmektedir.




a) Ocak



b) Mayıs



c) Temmuz




d) Ekim

Şekil 3.8. Çalışmada kullanılan aylara ait 10 dakikalık ortalama sıcaklık değerleri


Daha önce de belirtildiği gibi veri setinde aralık ayında, sıcaklığın düşük olduğu günlerde türbinin üretiminin tamamen durduğu zaman aralıkları bulunmaktadır. Ocak ayında sıcaklığın düşük olduğu zaman aralıkları incelendiğinde ise; sıcaklık düşüklüğünden türbin her zaman etkilenmemekle birlikte sıcaklığın 0 °C'nin altında uzun süre kaldığı zaman aralıklarında, gerçekleşen rüzgar hızlarına göre beklenenden daha düşük miktarlarda üretim yapıldığı ve zaman zaman üretimin durduğu görülmüştür. Düşük sıcaklıklarda gözlemlenen bu verim kayıpları ya da üretim gerçekleşmeyen zaman aralıklarının nedeninin ise buzlanma etkisi olabileceği düşünülmüştür. Özellikle soğuk iklime sahip olan; Kuzey Avrupa ülkeleri, Kanada ya da yüksek rakıma sahip olan dağlık

bölgelerde (Alpler) türbinlerde buzlanma etkileri gözlemlendiği bilinmektedir. Yılın büyük bölümünde sıcaklığın 0 °C'nin altında kaldığı ve nem oranlarının yüksek olduğu bölgelerde, buzlanmanın türbin performansı üzerinde önemli bir etkisi olmaktadır [75].


Ayrıca ocak ayı içerisinde buzlanma etkisinden kaynaklandığı düşünülen kayıplar, ocak ayı içinde gerçekleşen çok yüksek rüzgar hızlarına ek olarak aylık ortalama üretim miktarını düşüren bir diğer etkidir. Şekil 3.9'da görülen rüzgar hızı-üretim dağılımlarında ocak ayına bakıldığında; diğer aylarda olduğu gibi Şekil 3.3'te verilen teorik güç eğrisiyle tamamen örtüşen bir eğri ile karşılaşılmamakta ve bu eğrideki düzensizlikler, üretimde gerçekleşen kayıplardan kaynaklanmaktadır. En yüksek aylık ortalama üretimin gerçekleştiği temmuz ayına ait rüzgar hızı-üretim dağılımı incelendiğinde ise teorik türbin eğrisine çok benzer, düzgün bir eğriyle karşılaşıldığı görülmektedir.




a) Ocak



b) Mayıs



c) Temmuz



d) Ekim

Şekil 3.9. Çalışmada kullanılan aylara ait rüzgar hızı-üretim dağılımları

Şekil 3.9’da mayıs ayı incelendiğinde 10 m/s’nin altında yoğunlaşan rüzgar hızları nedeniyle üretimin de daha düşük miktarlarda yoğunlaştığı görülürken türbinin maksimum üretime ulaştığı noktaların diğer aylara göre daha seyrek olduğu da görülmektedir. Ekim ayında ise genel dağılım beklenen şekildeyken grafikte görülen üç noktada, ölçülen rüzgar hızlarına göre düşük miktarda üretim gerçekleştiği dikkat çekmektedir.

3.2. Modellerin Oluşturulması

Çalışmada kısa süreli tahmin üzerinde durulduğu için YSA ile 24 saatlik tahminler yapıp, elde edilen sonuçlar 1 saat, 3 saat, 6 saat ve 24 saat için ayrı ayrı incelenmiştir.

Kısa süreli rüzgar enerjisi tahminlerinde hem statik hem dinamik yapıdaki ağlardan yararlanıldığı için temel olarak iki farklı model kullanılmasına karar verilmiştir. Dinamik yapıdaki ağlarda öğrenme için kullanılan verinin kısa bir süreye ait olması verilerin erişilebilirliği açısından avantaj sağlayacağından ağın öğrenebileceği minimum veri sayısının kullanılması hedeflenmiştir. Öncelikle ağa öğrenmesi için üretim tahmini yapılacak günden bir önceki güne ait değerler verilmiş ve sonuçların kullanılan ağ modeli için yetersiz olduğu görülmüştür. Öğrenme için tahmin edilecek günden önceki iki güne ait verilerin ağa gösterilmesiyle sonuçların istenilen aralıklarda çıktığı gözlenmiş ve öğrenme için kullanılacak minimum veri sayısı (288 veri-2 gün) belirlenmiştir. Ağın öğrenmesi için gösterilen sürenin uzunluğunun tahmin sonuçlarını

nasıl etkilediği de araştırılmış ve sonuçlar ilerideki bölümlerde verilmiştir. Oluşturulan dinamik ağ yapılarında, her ağ kendisinden önceki günlere ait verilerle eğitildiği için tahmin edilecek her gün için farklı eğitim verisi setleri oluşturulmuş ve her bir durum için ağlar tekrar eğitilmiştir. Buna ek olarak aynı veri setlerinde sıcaklığın da girdi olarak kullanılmasından ağın performansının nasıl etkileneceği araştırılmış; rüzgar hızı-sıcaklık değerlerinden oluşan bir veri seti de hazırlanmış ve bu verilerle eğitilen ağlardan elde edilen sonuçlar da incelenmiştir.

Statik yapıdaki ağ modelinde ise eğitim için her mevsime ait bir aydan (ocak, mayıs, temmuz, ekim) seçilen 7 günlük veri içeren, zamandan bağımsız bir veri seti oluşturulmuş ve oluşturulan tek bir modelle farklı test verileri için tahminler yapılmasına karar verilmiştir. Eğitim için dinamik yapıdaki ağlara göre daha uzun bir öğrenme verisine ihtiyaç duyan statik ağ modelinde; her parametre için 4032 veri içeren bir eğitim verisi seti oluşturulmuştur. Bu modelde ağ; ilk olarak gerçekleşen rüzgar hızlarını ve bu rüzgar hızlarına karşılık gelen üretim değerleri gösterilerek eğitilmiş, ardından test aşaması için seçilmiş günlerde ölçülmüş rüzgar hızları ağa verilerek tahminler yapılmıştır. Ağların mümkün olduğu kadar çok ve farklı koşullarda örnek görebilmesi için ise her aydan seçilen günler içinde; ortalamanın üzerinde, altında ve ortalama değerlerin görüldüğü günlerin eğitim setinde özellikle bulunmasına dikkat edilmiştir. Oluşturulan statik yapıdaki bu ağ modelinin avantajı, belirlenen öğrenme verisi setiyle eğitilen tek bir ağ kullanılarak seçilen her test günü için tahmin yapılabilecek olmasıdır.

3.2.1. YSA Modelinin Belirlenmesi

Çalışmada kullanılan YSA modelleri MATLAB programı ile oluşturulmuştur. Seçilen YSA modellerinden dinamik yapıda olan ağ için; doğrusal olmayan zaman serilerinin modellenmesi için uygun olarak değerlendirilen NARX (*ing. Nonlinear AutoRegressive models with eXogenous input*) (harici girişli doğrusal olmayan otoregresif ağ) modelinin kullanılmasına karar verilmiştir [76]. NARX modeli, doğrusal olmayan kesikli zaman sistemlerinin önemli bir sınıfı olarak tanımlanırken, uzun dönem bağımlılık (*ing. long-term dependencies*) içeren problemlerde daha iyi sonuç veren bir model olduğu belirtilmektedir [77].

NARX modeli genel olarak aşağıdaki denklemle ifade edilmektedir:

$$a(t) = f\left(p(t - d_p), \dots, p(t - 1), p(t), a(t - d_a), \dots, a(t - 2), a(t - 1)\right) \quad (3.1)$$

$a(t)$: tahmin edilmek istenen zamana bağlı değişken


$p(t)$: harici girdi

d_a : çıktılardaki gecikme miktarı

d_p : girdilerdeki gecikme miktarı

f : doğrusal olmayan bir fonksiyon

NARX ağlarının literatürde ısı değiştiricileri, atık su temizleme sistemleri, petrol rafinerilerinin katalitik dönüştürücüleri gibi sistemlerin modellenmesinde kullanıldığı belirtilirken [77], finansal zaman serilerinin tahmininde [78] ve dalga enerjisi tahminlerinde de [79] kullanıldığı görülmektedir. Rüzgar enerjisinde ise rüzgar hızı tahmininde [80], kısa süreli rüzgar hızı ve güç tahminlerinde [81, 82] NARX ağından yararlanıldığı görülmektedir.




Şekil 3.10. NARX ağının genel gösterimi

Şekil 3.10’da NARX ağının genel yapısı görülmektedir. R tane girdiden oluşan $P^1(t)$; $(R \times 1)$ boyutunda girdi matrisini belirtirken, $IW^{1,1}$ bu girdilere ait ağırlıkları temsil etmektedir. D_p ve D_a girdilerdeki ve çıktılardaki belirlenen gecikme miktarlarına göre oluşturulan ve ağın girdi gibi kullandığı matrislerdir. İleri beslemeli-geri beslemeli (*ing. recurrent*) bir ağ olan NARX ağında, geri besleme sadece çıktı katmanından girdi katmanına doğru yapılmaktadır (D_a). Herhangi bir geri besleme ve gecikme sinyali bulunmayan YSA yapıları statik, bir gecikme sinyaliye sahip YSA yapıları ise dinamik

ağlar olarak adlandırılmaktadır. Dinamik ağ yapılarının hafızaya sahip olmaları nedeniyle zamana bağlı veri setleri için uygun olduğu belirtilmektedir [62]. NARX ağı Şekil 3.10’da görüldüğü gibi gecikme sinyallerine ve geri besleme döngüsüne sahip dinamik bir ağ modelidir.

Bu ağ yapısında, girdilerin yanısıra gecikme sinyalleri kullanılarak tahmin edilecek olan zaman serisinin ($a(t)$) ve harici girdinin ya da girdilerin ($p(t)$) geçmiş değerleri ile ağ beslenir. İki farklı gecikme sinyali bulunan NARX ağı, ağın hafızasını oluşturan ilk gecikme sinyali girdilere ait olurken, ikinci gecikme sinyali çıktı katmanından girdi katmanına gelen bağlantı ile oluşturulur. Şekil 3.11’de NARX ağındaki girdi ve çıktı gecikme sinyallerinin, ağa nasıl dahil edildiği detaylı şekilde görülmektedir.




Şekil 3.11. NARX ağı [60]

Zamana bağılı olarak oluşturulacak modellerde, gecikme sinyali içermeyen ağlar ile çok adımlı tahminler yapabilmek için yapılacak tahmin sayısı kadar modelin eğitilmesi ve her modelin kendisinden bir sonraki adım için tahmin yapması gerekirken, NARX ağı gibi gecikme sinyali ile geri besleme özelliğine sahip ağlarda tek bir modelin eğitilmesi, çok adımlı tahminlerin yapılabilmesi için yeterlidir [25].

Gecikme miktarlarını belirlemek için kesin bir yöntem bulunmamaktadır. Literatürde rüzgar üretim tahminleri için bu değerlerin nasıl belirlendiği incelendiğinde ise farklı yaklaşımlar kullanıldığı görülmektedir. Bigdeli vd. (2013) gecikme değerlerini belirlemek için geçmiş ölçülen değerlerle son bilinen değer arasındaki korelasyon katsayısını incelemiştir. Çalışmada kullanılan saatlik veri seti için 0.7 bir eşik değeri olarak belirlenmiştir [73]. Chitsaz vd. (2015) ve Catalao vd. (2015) ise gecikme miktarını belirlemek için öznelik seçimi (*ing. feature selection*) tekniğinden yararlandığını belirtmiştir [37, 38].


Çalışmalar incelendiğinde gecikme sinyalleri belirlenirken korelasyon katsayılarından yararlanma yöntemi bu çalışma için uygun bulunmuş ve modeller bu şekilde oluşturulmuştur. Veri seti 10 dakikalık ortalama değerlerden oluştuğu için geçmiş değerler ile son ölçülmüş değer olarak ağa gösterilen değerler arasındaki korelasyon katsayılarının beklendiği gibi yüksek olduğu görülmüştür. Gecikme sinyalleri belirlenirken her veri seti kendi içinde değerlendirilmiş ve 0.94-0.98 aralığında eşik değerleri verinin özelliğine göre seçilmiştir.

NARX ağının bir diğer avantajı ise “seri-paralel” mimariye sahip olmasıdır. Şekil 3.12’de görüldüğü gibi ağın geri besleme döngüsü eklenip, iptal edilebilmektedir. Ağ ilk olarak geri besleme döngüsü olmadan, gerçek hedef değerlerini de girdi olarak kullandığında eğitimin daha başarılı olacağı belirtilmektedir [59]. Eğitim tamamlandıktan (ağırlıklar belirlendikten) sonra geri besleme döngüsü eklendiğinde ise ağ, daha önce elde ettiği sonuçları gerçek değerler yerine kullanarak tahmin yapmaya devam edebilmektedir. İstenilirse bu döngü tekrar iptal edilebilmekte ve yeni bilgiler geldiğinde ağ tekrar eğitilebilmektedir. Bu nedenle eğitim için ilk olarak seri-paralel mimariye sahip NARX ağı kullanılmış ve ağ eğitimini tamamladıktan sonra geri besleme döngüsü eklenerek paralel mimari kullanılmıştır. Bu aşamadan sonra ağ gerçek üretim değerlerini görmemiş; tahmin yapması istenilen süreye ait ölçülen rüzgar hızı ve (kullanıldığı durumlarda) sıcaklık değerlerini kullanmıştır.



Şekil 3.12. Seri-paralel ve paralel mimari

Çok adımlı tahminler yapabilmesi ve lineer (doğrusal) olmayan problemlerin çözümü için uygun olması nedeniyle NARX ağı çalışmada kullanılacak dinamik ağ modeli için en uygun ağ olarak belirlenmiştir. Şekil 3.13'te MATLAB ile oluşturulmuş örnek bir NARX ağ modeli görülmektedir.



Şekil 3.13. MATLAB kullanılarak oluşturulmuş seri-paralel mimariye sahip (a) ve paralel mimariye sahip (b) NARX ağ modeli

Sadece geçmiş üretim değerlerinin kullanılmasıyla yapılan tahminler için ise NARX ağının harici girdi kullanılmadan oluşturulmuş bir modeli olan NAR ağı (*ing. Nonlinear AutoRegressive*) (doğrusal olmayan otoregresif model) kullanılmıştır.

Statik yapıdaki yani zamana bağlı olmayan ağ modeli için ise herhangi bir geri besleme döngüsüne sahip olmayan, ileri beslemeli YSA modelinden yararlanılmıştır.

3.2.2. Girdiler

NAR ağı harici bir girdi içermeyen bir ağ modeli olduğu için bu ağ modelinde, öğrenme ve test aşamasında herhangi bir meteorolojik veri kullanılmadan sadece geçmiş üretim değerleri girdi olarak kullanılmıştır.

NARX ağı için ise oluşturulan modellerde iki farklı öğrenme girdisi kullanılmıştır. İlk girdi verisi seti; rüzgar hızı ve üretim, ikinci veri seti ise; rüzgar hızı, sıcaklık ve üretim değerlerinden oluşmaktadır. NARX ağı geri besleme döngüsüne sahip bir ağ modeli olduğu için eğitim aşamasında girdi olarak gerçek üretim verilerini kullanmaktadır. Test girdisi olarak ise yine iki farklı girdi seti kullanılan ağ modelinde, test girdileri sadece meteorolojik verilerden oluşmaktadır. İlk test girdisi; tahmin için seçilen güne ait rüzgar hızı verilerinden oluşurken, ikinci grup test girdileri rüzgar hızı ve sıcaklık verilerinden oluşmaktadır.

İleri beslemeli YSA için ise girdi olarak sadece rüzgar hızından yararlanılmıştır.

Belirlenen girdilere göre çalışma için oluşturulan modeller ilerideki bölümlerde anlatılmıştır.

3.2.3. Çıktılar

Çıktı olarak sadece seçilen güne ait üretim değerleri belirlendiğinden oluşturulan YSA'ların tek çıktı katmanı bulunmaktadır. Ağın tahmin çıktıları, ağın öğrenmede gördüğü verilere paralel olarak 10 dakikalık zaman adımlarıyla istenilen zaman ufkunda elde edilebilmektedir.


3.2.4. Oluşturulan Modeller

YSA yapıları, girdiler ve çıktılara karar verildikten sonra belirlenen durumlar için temel olarak iki farklı model oluşturulmuştur. Oluşturulan modellerden dinamik yapıda olan yani NARX ağıyla oluşturulan ağ modeli çalışmada Model A olarak adlandırılırken,

statik yapıdaki ileri beslemeli YSA; Model B olarak adlandırılmıştır. Önceki bölümlerde de anlatıldığı gibi dinamik yapıdaki ağ modelinde girdilerin etkisinin gözlemlenebilmesi için farklı girdiler kullanıldığından, Model A'ya ait girdi sayıları da ağ modelinin yanında Model A-1, A-2, A-3 şeklinde belirtilmiştir.


Oluşturulan her model lojistik (sigmoid) aktivasyon fonksiyonu, hiperbolik tanjant (sigmoid) aktivasyon fonksiyonu ve gauss (radyal tabanlı) aktivasyon fonksiyonu ile ayrı ayrı çalıştırılmış ve tahminler elde edilmiştir.

Model A-1: Model A-1 NAR ağı kullanılarak oluşturulmuş ve tek girdiye sahip bir modeldir. NAR ağ modeli Şekil 3.14'te görüldüğü gibi, genel olarak NARX ağ modeliyle aynı yapıda olup, harici girdi içermeyen bir modeldir.




Şekil 3.14. Model A-1 için oluşturulan ağ modelinin eğitim (a) ve tahmin aşamaları (b)

Model A-2: Model A-2, NARX ağı kullanılarak oluşturulmuş, Şekil 3.15'te görüldüğü gibi 2 eğitim girdisine sahip bir ağ modelidir. Model A-2'de harici girdi olarak rüzgar hızından yararlanılmıştır.



Şekil 3.15. Model A-2 için oluşturulan ağ modelinin eğitim (a) ve tahmin aşamaları (b)

Model A-3: Model A-3, NARX ağ modeli ile oluşturulan 3 farklı eğitim girdisine sahip bir ağ modeli olarak tanımlanmıştır. Model A-3 için kullanılan harici girdiler ise rüzgar hızı ve sıcaklık değerleridir. Şekil 3.16’da bu model ile oluşturulan ağların genel bir gösterimi yer almaktadır.



Şekil 3.16. Model A-3 için oluşturulan ağ modelinin eğitim (a) ve tahmin aşamaları (b)

Model B: Model B herhangi bir geri besleme döngüsüne sahip olmayan tek katmanlı, ileri beslemeli bir YSA modelidir. Model A’dan farklı olarak zamana bağlı bir ağ modeli değildir. Model B ile oluşturulan, farklı aktivasyon fonksiyonları kullanan üç farklı ağ; geçmiş rüzgar hızı ve üretim değerleriyle eğitildikten sonra, her durum için bu ağlara seçilen test günlerine ait rüzgar hızları girdi olarak verilmiş ve bu günler için tahminler yapılmıştır.

Model A ile oluşturulan ağlar ise her durum için kendilerinden önceki verilerle eğitilmiş ve zamana bağlı ağlardır.

3.2.5. Veri Setine Uygulanan Önişlemler

YSA genelleme yeteneğine bağlı olarak hatalı ya da eksik verileri tolere edebilen bir model olduğundan rüzgar enerjisi tahminleri için oldukça uygun bir yöntemdir. Ancak öğrenme için kullanılan veri seti ne kadar iyi olursa ağın vereceği sonuçlar da o derecede başarılı olmaktadır. Bu nedenle ilk olarak kullanılacak veri setinin incelenmesi ve uygun olarak düzenlenmesi gerekmektedir. Literatürde enerji sistemlerinde eksik verilerin düzenlenmesi için lineer interpolasyon yönteminden yararlanılan çalışmalar olduğu görülmektedir [83]. Bu çalışmada da ağa gösterilen veriler düzenlenirken eksik olan veriler bu yöntemle oluşturulmuştur. Ayrıca rüzgar türbinlerinde, türbinin yüzünü rüzgara dönmesi için kullanılan sapma kontrolü (yaw motor), hidrolik sistemler ve pompa sistemleri nedeniyle az bir miktarda da olsa enerji tüketimi de gerçekleşmektedir [84]. Bu nedenle rüzgar çiftiliğinden alınan veri setinde, rüzgar hızının düşük olduğu bazı zaman aralıkları için 10 dakikalık üretim ortalaması, negatif bir değer olarak yer almaktadır. Üretim tahmininin yapılması amaçlandığı için ağda kafa karışıklığı yaratacak bu durumlarda, üretim değerleri 0 kWh olarak alınmıştır.

Veri setinin kontrolü tamamlandıktan sonra kullanılan verilerin 0-1 aralığında normalize edilmesi gerektiğinden, veriler ağa gösterilmeden önce bir ön işlemden geçirilmiştir. Çalışmanın amacının kısa süreli tahmin olması nedeniyle önceki 2 güne ya da 1 haftaya ait verilerle eğitilen Model A ile yapılan tahminler için; seçilen ayların minimum ve maksimum değerlerine göre bir normalizasyon yapılmasının uygun olduğu görülmüş ve kullanılan her parametre için aşağıdaki şekilde bir normalizasyon gerçekleştirilmiştir:

$$\text{Normalize edilmiş değer} = \frac{x - x_{\min(\text{ay})}}{x_{\max(\text{ay})} - x_{\min(\text{ay})}} \quad (3.2)$$

x : normalize edilecek parametre değeri

$x_{\min(\text{ay})}$: normalize edilecek parametrenin seçilen ay içindeki minimum değeri

$x_{\max(\text{ay})}$: normalize edilecek parametrenin seçilen ay içindeki maksimum değeri

Model B’de kullanılan veriler için ise; ağ gerçekleşen minimum ve maksimum değerleri eğitim setinde gördüğü için bu değerlere göre yine 0-1 aralığında bir normalizasyon yapılmıştır; Çizelge 3.1’de normalize edilmiş değerlere ait örnekler verilmiştir.

$$\text{Normalize edilmiş değer} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (3.3)$$

Çizelge 3.1. Seçilen test günlerinden birisi için eşitlik 3.3'e göre normalize edilmiş değerlere ait örnekler

Hız	Normalize Hız	Üretim	Normalize Üretim
3,8	0,17	47,2	0,02
4,3	0,19	98,8	0,03
4,6	0,20	152,5	0,05
4,6	0,20	150,2	0,05
4,7	0,21	148,3	0,05
4,5	0,20	152,7	0,05
5,1	0,23	224,0	0,07
5,5	0,25	267,5	0,09
5,3	0,24	243,2	0,08
5,7	0,26	321,1	0,11
6,4	0,29	393,8	0,13
6,6	0,30	434,6	0,14
6,6	0,30	438,8	0,15
6,8	0,31	464,6	0,15
6,9	0,31	490,0	0,16
6,7	0,30	453,6	0,15
6,8	0,31	462,8	0,15
7,1	0,32	527,6	0,18
6,8	0,31	464,3	0,15
6,6	0,30	467,9	0,16
6,6	0,30	471,5	0,16
6,5	0,30	486,9	0,16
6,7	0,30	524,7	0,17
6,9	0,31	555,9	0,19
7,3	0,33	617,9	0,21
7,3	0,33	658,9	0,22
7,4	0,34	691,0	0,23
7,9	0,36	787,8	0,26
8,3	0,39	946,2	0,32
8,5	0,39	1038,0	0,35
9,2	0,42	1208,5	0,40
9,2	0,42	1143,5	0,38
9	0,41	1048,2	0,35
9,1	0,42	1074,1	0,36
8,9	0,41	1095,1	0,36
8,3	0,38	871,5	0,29
8,2	0,38	835,9	0,28
7,9	0,36	789,7	0,26
8,2	0,38	888,3	0,30
8,6	0,40	998,0	0,33
7,6	0,35	749,7	0,25
8,1	0,37	896,5	0,30
9,1	0,42	1150,3	0,38
10,2	0,47	1554,0	0,52
10,2	0,47	1571,9	0,52
9,5	0,44	1390,0	0,46
9	0,41	1233,7	0,41

9,4	0,43	1398,3	0,47
9,6	0,44	1459,8	0,49
10	0,46	1642,1	0,55
10,7	0,50	1878,2	0,63
11,3	0,52	2081,3	0,69
11,3	0,52	2084,5	0,69
11,5	0,54	2209,1	0,74
12	0,56	2360,3	0,79
12,1	0,56	2404,0	0,80
12,5	0,58	2416,7	0,81
12,5	0,58	2449,8	0,82
12,6	0,59	2484,0	0,83
12,8	0,60	2504,8	0,83
13,1	0,61	2627,1	0,88
13,3	0,62	2685,8	0,90
13,2	0,61	2598,7	0,87
11,9	0,55	2256,4	0,75
11,4	0,53	2050,5	0,68
11,5	0,53	2078,9	0,69
10,5	0,49	1761,7	0,59
10,3	0,48	1640,4	0,55
11,5	0,53	2052,2	0,68
11,7	0,54	2108,8	0,70
11,3	0,52	2035,7	0,68
12,2	0,57	2295,6	0,76
13,1	0,61	2447,6	0,82
13,8	0,64	2591,9	0,86
13,9	0,65	2617,3	0,87
15,3	0,71	2885,1	0,96
14,7	0,69	2814,6	0,94
14,4	0,67	2771,1	0,92
15,4	0,72	2916,6	0,97
14,4	0,67	2767,0	0,92
14,2	0,66	2761,5	0,92
14,3	0,67	2743,6	0,91
13,8	0,64	2546,1	0,85
13,4	0,62	2538,8	0,85
13,8	0,64	2564,1	0,85
13,4	0,62	2442,7	0,81
12,3	0,57	2206,8	0,74
12,7	0,59	2209,1	0,74
12,1	0,56	2162,4	0,72
10	0,46	1642,1	0,55
10,7	0,50	1878,2	0,63
11,3	0,52	2081,3	0,69
11,3	0,52	2084,5	0,69
11,5	0,53	2209,1	0,74
12	0,56	2360,3	0,79
12,1	0,56	2404,0	0,80

3.3. Sonuçların Değerlendirilmesinde Kullanılan Yöntemler

Rüzgar enerjisiyle ilgili yapılan tahminlerde; türbin özelliklerinin, rüzgar çiftliğinin bulunduğu arazinin fiziksel özelliklerinin, kullanılan farklı veri setlerinin ve bu gibi birçok değişkenin sonuçları etkilemesi nedeniyle genel bir karşılaştırma yapılamamaktadır. Ancak bu durumun değişkenliğinin ortadan kaldırılması amacıyla ANEMOS projesi dahilinde ve Argonne Ulusal Laboratuvarı tarafından yapılan çalışmalarda hata fonksiyonunu standart bir hale getirmek için NMAE (*ing. normalized mean absolute error*) (normalize edilmiş mutlak ortalama hata) kullanılması önerilmiştir [31, 25]. NMAE hesaplanırken farklı sistemler için yapılan tahmin sonuçlarının karşılaştırılabilmesi amacıyla hata, kurulu güç miktarına bölünür ve buna bağlı bir hata yüzdesi elde edilir. Bu çalışmada elde edilen sonuçlar da NMAE hesaplanarak değerlendirilmiştir.

$$\%NMAE = \frac{1}{N} \sum_N \frac{|Tahmin\ edilen\ deęer - Gerçek\ üretim\ deęeri|}{Türbinin\ kapasitesi} \times 100 \quad (3.4)$$

$$\%NMAE = \frac{1}{N} \sum_N \frac{|Hata|}{Türbinin\ kapasitesi} \times 100 \quad (3.5)$$

N: Tahmin edilen veri sayısı

Kısa süreli tahminlerde; kullanılan en basit fakat 0-6 saatlik zaman ufku için başarılı bir yöntem olan naive yöntem referans model olarak belirlenmiştir. Naive tahmin yöntemi, gerçekleşen son verinin, gelecekte gerçekleşecek değerler için de doğru olduğunu kabul eder. Atmosferdeki değişim ölçeklerinin genellikle yavaş olması nedeniyle rüzgar enerjisi tahminlerinde iyi sonuç veren bir yöntem olduğu belirtilmektedir [31]. Tez için yapılan çalışmalarda farklı günler ve koşullar için elde edilen sonuçlar değerlendirilirken her verinin tahmin edilebilirlik oranı farklı olması nedeniyle, ilk 6 saatlik tahmin süresinde Naive yönteminden yararlanılmıştır.

4. SONUÇLAR

Bu çalışmada öğrenme için gösterilen veri uzunluğunun, kullanılan girdilerin ve aktivasyon fonksiyonlarının, farklı koşullardaki günler için YSA'nın performansını nasıl etkileyeceği araştırılmış ve ilerideki bölümlerde incelenmiştir. Belirlenen zaman ufku 1 saat, 3 saat, 6 saat ve 24 saat, zaman adımı ise her tahmin için 10 dakikadır.

4.1. Öğrenme Verisinin Etkisi

YSA'lar genelleme özelliğine bağlı olarak öğrenme için gerekli olan veriler kendilerine gösterildikten sonra daha önce görmedikleri veriler için de tahmin yapabilme yeteneğine sahiptirler. Bazı durumlarda eğitim için fazla veri gösterilmesi ağı ezberlemesine ya da kafa karışıklığına neden olurken bazı durumlarda da az miktarda eğitim verisi ağı öğrenmesi için yeterli olmamaktadır. Ayrıca oluşturulan YSA modellerine (statik/dinamik) göre de ağı öğrenme için ihtiyaç duyacağı veri miktarı değişmektedir. Çalışmanın bu bölümünde önce; Model A-2 kullanılarak, geçmiş 2 gün ve geçmiş 1 haftaya ait veriler eğitim için ağı gösterildikten sonra test girdileri ağı verilmiş ve çıkan sonuçlar değerlendirilmiştir. Daha sonra ise her mevsimden veri içeren bir eğitim setiyle öğrenmeyi tamamlayan, statik yapıdaki Model B ile de tahminler yapılmış ve elde edilen sonuçlar karşılaştırılmıştır.


Durum 1 – 20 Temmuz

Çizelge 4.1. Durum 1'de eğitim ve test için kullanılan günlere ait minimum, maksimum ve ortalama rüzgar hızı değerleri


	Tahmin edilen gün	Geçmiş 2 gün	Geçmiş 1 hafta
	20 Temmuz	18-19 Temmuz	13-19 Temmuz
Ortalama rüzgar hızı	14.0 m/s	16.2 m/s	11.3 m/s
En düşük rüzgar hızı	10.8 m/s	10.6 m/s	0.6 m/s
En yüksek rüzgar hızı	18.0 m/s	19.1 m/s	19.8 m/s

Çizelge 4.1'de görülebildiği gibi Durum 1 için hem eğitim setinde hem test setinde yüksek rüzgar hızlarına bağlı olarak yüksek üretim değerleri bulunmaktadır. Öncelikle Model A-2 ile yapılan tahminlerde; geçmiş iki günün eğitim için kullanılmasıyla, Şekil 4.1'de görüldüğü gibi farklı aktivasyon fonksiyonlarıyla, gerçekleşen değerlere yakın sonuçlar vermiştir. Şekil 4.1 (b) incelendiğinde ise üretimin çok fazla farklılık göstermediği saatlerde hata oranlarının daha düşük olduğu görülürken, dalgalanmaların olduğu zaman aralıklarında hata oranlarının arttığı görülmüştür. Dalgalanmaların

görüldüğü zaman aralıklarında, tüm sonuçlar için en yüksek noktasal hata oranı ise hiperbolik tanjant aktivasyon fonksiyonu ile çalıştırılan ağda meydana gelmiştir.




(a)




(b)

Şekil 4.1. Model A-2 ile 2 gün süreli eğitim verisi kullanılarak 20 Temmuz için yapılan tahminler (a) ve tahminlerin hata oranları (b)

Aynı gün için eğitim verisi olarak Model A-2 ile oluşturulan ağa geçmiş 1 haftaya ait veriler gösterilmiş ve bu ağların performansı kıyaslanmıştır.



(a)




(b)


Şekil 4.2 Model A-2 ile 1 hafta süreli eğitim verisi kullanılarak 20 Temmuz için yapılan tahminler (a) ve tahminlerin hata oranları (b)

Şekil 4.2’de görüldüğü gibi dalgalanmaların olduğu zaman aralıklarındaki hata oranları, 1 hafta süreli eğitim verisi ile de diğer bölgelere göre daha yüksektir. Ancak Şekil 4.1 (b) ile bir karşılaştırma yapıldığında dalgalanma olan bölgelerdeki noktasal maksimum hata oranlarının daha düşük olduğu görülmektedir.

Model B ile yapılan tahminler ise, Şekil 4.3’te görüldüğü gibi, Model A-2 kullanılarak oluşturulan diğer iki ağı tahminlerine göre gerçek değerlere daha yakın çıkmıştır.



(a)



(b)

Şekil 4.3 Model B ile 20 temmuz için yapılan tahminler (a) ve tahminlerin hata oranları (b)

Şekil 4.3 (b) incelendiğinde noktasal maksimum hata oranlarının %7'nin bile altına düştüğü görülürken, genel olarak hata oranlarının Model A-2 ile oluşturulan ağlarda gözlenen hata oranlarına göre oldukça azaldığı da gözlemlenmektedir. Ancak diğer modellerle yapılan tahminlerde olduğu gibi, üretim eğrisinde dalgalanmaların olduğu noktalarda noktasal hata oranlarının da arttığı görülmektedir.

Çizelge 4.2. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminlerde ve Model B ile yapılan tahminlerde hesaplanan ortalama hata oranları

Aktivasyon Fonksiyonu	1 saat (NMAE)(%)	3 saat (NMAE)(%)	6 saat (NMAE)(%)	24 saat (NMAE)(%)
Naive Yön.	4.72	3.63	10.10	-
Model A-2				
<i>Eğitim (2 gün)</i>				
Lojistik	4.12	3.83	4.89	3.25
Tanjant(h)	4.30	3.86	3.98	3.50
Gauss	4.31	3.83	3.71	2.79
<i>Eğitim (1 hafta)</i>				
Lojistik	6.12	5.58	6.05	3.66
Tanjant(h)	4.53	6.31	4.64	3.62
Gauss	5.98	5.36	6.79	3.62
Model B				
Lojistik	0.90	0.96	0.98	1.46
Tanjant(h)	0.92	1.03	0.92	1.36
Gauss	1.11	1.14	0.92	1.39

Çizelge 4.3. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminler, Model B ile yapılan tahminler ve gerçekleşen ortalama üretim değerleri

Aktivasyon Fonksiyonu	1 saat (kWh)	3 saat (kWh)	6 saat (kWh)	24 saat (kWh)
Gerçekleşen	2483.0	2487.5	2691.0	2800.5
Model A-2				
<i>Eğitim (2 gün)</i>				
Lojistik	2534.8	2433.2	2574.8	2764.4
Tanjant(h)	2543.5	2450.0	2611.8	2748.5
Gauss	2451.1	2406.0	2597.3	2786.3
<i>Eğitim (1 hafta)</i>				
Lojistik	2316.4	2328.7	2513.7	2746.7
Tanjant(h)	2581.5	2664.4	2743.2	2836.4
Gauss	2407.9	2367.8	2508.0	2726.1
Model B				
Lojistik	2508.0	2514.5	2703.4	2811.7
Tanjant(h)	2510.4	2517.3	2704.3	2812.4
Gauss	2515.6	2520.7	2709.7	2818.0

Çizelge 4.2 ve Çizelge 4.3 incelendiğinde ise Model A-2 ile yapılan tahminlerde 1 hafta süreli eğitim verisi ile dalgalanma bölgelerindeki hata oranları azalmasına rağmen genel hata oranlarının arttığı görülmektedir. 2 gün süreli eğitim verisi ile ilk 3 saat için naive yöntemine yakın hata oranları elde edilirken, 6 saat için naive yönteminden çok daha iyi sonuçlar alınmıştır. 1 hafta süreli eğitim verisiyle yapılan tahminlerde ise tüm aktivasyon fonksiyonları için özellikle ilk 6 saatte hata oranlarında daha yüksek miktarda artışlar

görülürken ilk 3 saat için hata oranları naive yönteminin üzerine çıkmıştır. 24 saat için ise az miktarlarda da olsa yine hata oranlarında artış meydana gelmiştir. Model B ile yapılan tahminlerin hata oranları ise, Model A-2 ile oluşturulan her iki ağ modelinin tahminlerine ait hata oranlarından daha düşük çıkmıştır. Model A-2 ve Model B'nin hata oranları genel olarak karşılaştırıldığında tahmin edilen süre uzadıkça Model A-2 ile oluşturulan ağların tahminleri için hata oranları azalırken, Model B'de ise tam tersi şekilde tahmin edilecek süre uzadıkça tahminlerin hata oranlarının arttığı görülmektedir. Ancak Durum 1 için oluşturulan tüm ağ modellerine ait tahminler incelendiğinde; dört farklı zaman ufku için de gerçekleşen değerlere en yakın tahminlerin Model B kullanılarak oluşturulmuş ağlara ait olduğu görülebilmektedir.


Durum 2 – 20 Ocak

Çizelge 4.4. Durum 2'de eğitim ve test için kullanılan günlere ait minimum, maksimum ve ortalama rüzgar hızı değerleri


	Tahmin edilen gün	Geçmiş 2 gün	Geçmiş 1 hafta
	20 Ocak	18-19 Ocak	13-19 Ocak
Ortalama rüzgar hızı	14.5 m/s	4.3 m/s	4.8 m/s
En düşük rüzgar hızı	11.8 m/s	1.0 m/s	0.6 m/s
En yüksek rüzgar hızı	18.3 m/s	12.6 m/s	12.6 m/s

Durum 2'de; Model A-2 ile oluşturulan ağlar eğitimde hiç görmediği rüzgar hızı değerleriyle test setinde ilk defa karşılaşmıştır. Çizelge 4.4'te belirtildiği gibi Model A-2 ile oluşturulan ağlar için kullanılan eğitim verilerinde ağın gördüğü en yüksek rüzgar hızı 12.6 m/s olurken, test verilerinde gün içindeki ortalama rüzgar hızının 14.5 m/s olduğu görülmektedir. 20 Ocak günü gerçekleşen en yüksek rüzgar hızı olan 18.3 m/s, Model A-2 ile oluşturulan ağlar için daha önce hiç karşılaşmadıkları bir rüzgar hızıdır.

Şekil 4.4'te görüldüğü gibi 2 gün süreli eğitim verisi ile eğitilen ağlar bu koşullarda, gerçekleşen değerlere benzer sonuçlar verebilmiştir. Ancak Gauss aktivasyon fonksiyonu ile oluşturulan ağın hata oranları, 20 Ocak'ta gerçekleşen en yüksek rüzgar hızlarının (18.3 m/s) bulunduğu zaman aralığında belirgin bir şekilde artmıştır.




(a)




(b)

Şekil 4.4. Model A-2 kullanılarak 2 gün süreli eğitim verisiyle 20 Ocak için yapılan tahminler (a) ve tahminlerin hata oranları (b)

Model A-2 için öğrenmede gösterilen veri seti, geçmiş 1 haftaya ait veri setiyle değiştirildiğinde ise ağ, 2 gün süreli eğitim setiyle hemen hemen aynı aralıklarda (minimum-maksimum değerler) bir veri setiyle eğitilirken daha çok örnek ile çalışmıştır. Şekil 4.5 incelendiğinde rüzgar hızının maksimum olduğu zaman aralığında tüm aktivasyon fonksiyonları için hata oranı %5'in altında kalmıştır. Ancak 20 Ocak gününde gerçekleşen en düşük üretimin olduğu noktada, lojistik aktivasyon fonksiyonu ile oluşturulan ağın hata oranında noktasal bir artış görülmüştür.




(a)




(b)

Şekil 4.5. Model A-2 kullanılarak 1 hafta süreli eğitim verisiyle 20 Ocak için yapılan tahminler (a) ve tahminlerin hata oranları (b)

20 Ocak günü için Model B ile yapılan tahminler ise Şekil 4.6'da görülmektedir. Durum 1'de olduğu gibi Durum 2 için de bu modellerle oluşturulan ağlar, Model A-2 ile oluşturulan ağlardan elde edilen tahminlere göre daha düşük hata oranlarına sahip sonuçlar vermiştir.



(a)



(b)

Şekil 4.6. Model B ile 20 Ocak için yapılan tahminler (a) ve tahminlerin hata oranları (b)

Şekil 4.6 incelendiğinde üretimin az miktarda da olsa düştüğü zaman aralıkları için yapılan tahminlere ait hata oranlarının arttığı görülmektedir. Ancak hata oranlarına ait grafikte de görüldüğü gibi, Model B ile yapılan tahminlerde maksimum noktasal hata oranı %8'in altında kalmıştır.

Çizelge 4.5. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminlerde ve Model B ile yapılan tahminlerde hesaplanan ortalama hata oranları

Aktivasyon Fonksiyonu	1 saat (NMAE)(%)	3 saat (NMAE)(%)	6 saat (NMAE)(%)	24 saat (NMAE)(%)
Naive Yön.	9.15	11.16	11.91	-
Model A-2				
<i>Eğitim (2 gün)</i>				
Lojistik	5.92	5.98	4.40	3.91
Tanjant(h)	5.61	4.90	2.78	2.74
Gauss	6.54	6.05	7.34	4.68
<i>Eğitim (1 hafta)</i>				
Lojistik	4.31	2.30	2.61	2.91
Tanjant(h)	6.92	6.40	4.75	3.91
Gauss	6.80	6.27	4.62	4.02
Model B				
Lojistik	2.05	2.49	2.17	2.19
Tanjant(h)	2.16	2.50	2.16	2.04
Gauss	2.05	2.36	2.10	2.00

Çizelge 4.6. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminler, Model B ile yapılan tahminler ve gerçekleşen ortalama üretim değerleri

Aktivasyon Fonksiyonu	1 saat (kWh)	3 saat (kWh)	6 saat (kWh)	24 saat (kWh)
Gerçekleşen	2895.2	2955.5	2978.0	2888.0
Model A-2				
<i>Eğitim (2 gün)</i>				
Lojistik	2717.4	2775.9	2845.8	2798.9
Tanjant(h)	2726.8	2808.3	2908.9	2853.7
Gauss	2698.8	2774.0	2757.8	2786.8
<i>Eğitim (1 hafta)</i>				
Lojistik	2765.7	2897.7	2993.0	2935.9
Tanjant(h)	2687.6	2763.5	2835.4	2791.1
Gauss	2691.1	2767.3	2839.4	2794.9
Model B				
Lojistik	2838.9	2882.5	2913.8	2880.1
Tanjant(h)	2832.3	2881.1	2913.4	2878.0
Gauss	2842.0	2887.3	2916.2	2883.6

Çizelge 4.5 ve Çizelge 4.6 incelendiğinde Model A-2 ile yapılan tahminlerde her iki eğitim seti için de sonuçların, naive yöntemine göre 6 saatlik ve daha kısa süreli tahminlerde bile daha iyi olduğu görülmektedir. 2 gün süreli eğitim verisi ile çalışan ağlar arasında en düşük hata oranları hiperbolik tanjant aktivasyon fonksiyonunun kullanılmasıyla elde ederken, 1 hafta süreli eğitim verisi ile çalışan ağlar arasında en düşük hata oranları lojistik aktivasyon fonksiyonuyla elde etmiştir. Ayrıca eğitim setinin genişletilmesiyle lojistik fonksiyonunu

kullanan ağ yapısında hata oranları düşmüş, ancak hiperbolik tanjant fonksiyonunu kullanan ağ yapısında hata miktarı yükselmiştir. Model B kullanılarak oluşturulan ağların yaptığı tahminlerin hata oranları ise, genel olarak Model A-2 ile oluşturulan ağlara ait tahminlerin hata oranlarına göre daha düşük olmakla beraber; ilk 3 saat için yapılan tahminler incelendiğinde en düşük hata oranının, Model A-2 ile oluşturulmuş geçmiş 1 haftaya ait veri setiyle eğitilen ve lojistik aktivasyon fonksiyonunu kullanan ağ ile edildiği görülmektedir.

Durum 2’de; Model A-2 ile oluşturulan tüm ağlar daha önce eğitim sırasında karşılaşmadıkları rüzgar hızları için tahmin yaparken, Model B ile oluşturulan ağlar eğitim sırasında her mevsimden, farklı rüzgar hızlarına ait veriler gördüğü için genel olarak daha iyi sonuçlar vermiştir. Ancak daha önce de belirtildiği gibi ilk 3 saat için yapılan tahminlere ait en düşük hata oranları Model A-2 ile oluşturulan bir ağ ile elde edilmiştir. Ayrıca 24 saat için yapılan tahminlerin hata oranları incelendiğinde ise Model A-2 ile oluşturulan ağlar arasında, geçmiş 2 güne ait veri setiyle eğitilen ve hiperbolik tanjant fonksiyonu ile çalışan ağın, Model B ile yapılan tahminlerin hata oranlarına en yakın sonuç verdiği görülmektedir.


Durum 3 – 27 Ekim

Çizelge 4.7. Durum 3’te eğitim ve test için kullanılan günlere ait minimum, maksimum ve ortalama rüzgar hızı değerleri

	Tahmin edilen gün	Geçmiş 2 gün	Geçmiş 1 hafta
	27 Ekim	25-26 Ekim	20-26 Ekim
Ortalama rüzgar hızı	12.4 m/s	5.5 m/s	9.4 m/s
En düşük rüzgar hızı	3.8 m/s	0.8 m/s	0.8 m/s
En yüksek rüzgar hızı	18.4 m/s	11.3 m/s	18.9 m/s

Çizelge 4.7’de görüldüğü gibi Durum 3’te Model A-2 ile oluşturulan ağlar, geçmiş iki güne ait eğitim verisi setini kullandığında eğitimde karşılaşmadığı rüzgar hızı ve üretim değerleriyle test setinde ilk defa karşılaşmıştır. Test verisi olarak kullanılan 27 ekim günü ise oldukça değişken değerlere sahip bir gün olması nedeniyle seçilmiştir. Şekil 4.7’de görüldüğü gibi Model A-2 kullanılarak oluşturulmuş ve geçmiş iki güne ait verilerle eğitilen ağlar, düşük rüzgar hızı ve üretimin gözlendiği ilk 6 saat için hata oranları daha düşük tahminler yaparken, 24 saat için (hız ve üretim değerleri artmaya başladıkça) yapılan tahminlerin hata oranları artmıştır. Diğer durumlardan farklı olarak, Durum 3’te noktasal hata oranlarının %35’e kadar çıktığı görülmüştür. Şekil 4.7 incelendiğinde üretimin maksimum olduğu zaman aralığı için (ağın görmediği değerler) en yüksek hata oranlarına



sahip tahminlerin, Gauss aktivasyon fonksiyonu kullanılarak oluşturulan ağ ile elde edilen tahminler olduğu görülmektedir.



Şekil 4.7. 2 gün süreli eğitim verisiyle 27 Ekim için yapılan tahminler (a) ve tahminlerin hata oranları (b)


Model A-2 ile oluşturulan ağlara eğitim için geçmiş bir haftaya ait veriler gösterildiğinde ise, Şekil 4.7 ile Şekil 4.8 karşılaştırıldığında da görülebileceği gibi hız ve üretim değerlerinin arttığı zaman aralıklarında, gerçekleşen değerlere daha yakın tahmin sonuçları elde edilmiştir. Sonuçların, gerçekleşen değerlere yaklaşmasının nedeni ağın 2 gün süreli eğitim setinde hiç karşılaşmadığı maksimum (3000.0 kWh) üretim değerleriyle, 1 hafta süreli eğitim setinde karşılaşmış olması ve bu verileri öğrenmiş olmasıdır. 2 gün süreli eğitim

verisiyle eğitilen ağlar ise eğitimde belirlediği ağırlıklarla bu veriler için tahmin yaparken gün içindeki artışı tahmin edebilmiş ancak hata oranları daha yüksek sonuçlar vermiştir.




Şekil 4.8. 1 hafta süreli eğitim verisiyle 27 Ekim için yapılan tahminler (a) ve tahminlerin hata oranları (b)

Ayrıca Şekil 4.8’de hata oranları incelendiğinde; 1 hafta süreli eğitim verisi kullanan ağlardan elde edilen sonuçlarda da dalgalanmaların görüldüğü zaman aralıklarında hata oranlarının arttığı görülmektedir.



(a)



(b)

Şekil 4.9. Model B ile 27 ekim için yapılan tahminler (a) ve tahminlerin hata oranları (b)

Model B ile yapılan tahminlerden elde edilen sonuçlar Şekil 4.9'da görüldüğü gibi gerçekleşen değerlere benzer olsa da Model B'ye ait ağlar ile yapılan tahminlerin hata oranları ilk iki durum için %10'un üzerine çıkmazken, Durum 3'te maksimum noktasal hata oranı neredeyse %18'e ulaşmıştır. Dalgalanmaların sık olduğu zaman aralıklarında hata oranları da artarken, yüksek rüzgar hızı ve üretim değerlerine ulaşılan zaman aralıklarında hata oranlarının düştüğü görülmektedir.

Çizelge 4.8. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminlerde ve Model B ile yapılan tahminlerde hesaplanan ortalama hata oranları

Aktivasyon Fonksiyonu	1 saat (NMAE)(%)	3 saat (NMAE)(%)	6 saat (NMAE)(%)	24 saat (NMAE)(%)
Naive Yön.	3.47	9.44	17.47	-
Model A-2				
<i>Eğitim (2 gün)</i>				
Lojistik	1.31	4.50	8.19	11.47
Tanjant(h)	1.84	2.85	4.17	9.27
Gauss	0.65	4.65	6.15	17.57
<i>Eğitim (1 hafta)</i>				
Lojistik	2.48	4.80	6.10	5.75
Tanjant(h)	0.91	1.73	2.98	6.13
Gauss	1.87	5.91	7.81	6.05
Model B				
Lojistik	1.83	3.80	5.59	5.58
Tanjant(h)	1.90	3.85	5.71	5.62
Gauss	1.57	3.80	5.68	5.65

Çizelge 4.9. 2 gün ve 1 hafta süreli eğitim verileriyle Model A-2 ile yapılan tahminler, Model B ile yapılan tahminler ve gerçekleşen ortalama üretim değerleri

Aktivasyon Fonksiyonu	1 saat (kWh)	3 saat (kWh)	6 saat (kWh)	24 saat (kWh)
Gerçekleşen	125.0	304.0	545.1	2030.2
Model A-2				
<i>Eğitim (2 gün)</i>				
Lojistik	85.5	169.0	307.4	1699.2
Tanjant(h)	69.6	221.0	447.2	1772.6
Gauss	116.2	168.0	426.7	1539.3
<i>Eğitim (1 hafta)</i>				
Lojistik	199.4	448.0	725.4	2018.4
Tanjant(h)	130.2	318.5	589.4	1949.4
Gauss	170.0	477.6	774.3	2030.9
Model B				
Lojistik	180.0	418.1	712.9	2160.8
Tanjant(h)	182.0	419.4	716.5	2162.3
Gauss	172.0	418.0	715.4	2162.1

Çizelge 4.8’de görüldüğü gibi tüm tahmin modelleri için hata oranları naive yöntemle göre daha düşük çıkmıştır. Ancak Şekil 4.7 incelendiğinde Model A-2 ve 2 gün süreli eğitim verisi kullanan ağ modelleri ile noktasal hata oranlarının %30’un üzerine çıktığı noktalar görülürken, Şekil 4.8’de (1 hafta süreli eğitim verisi ile) maksimum noktasal hata oranının %25-30 aralığına düştüğü görülmüştür. Hatta lojistik aktivasyon fonksiyonu ile oluşturulan ağ için maksimum hata oranının %20’nin bile altında olduğu görülmüştür. Model B ile

oluşturulan ağlara ait tahminlerin hata oranları ise; ilk 6 saat için Model A-2 ile oluşturulan ağların hata oranlarına yakinken, 24 saat için hesaplanan hata oranları genel olarak daha düşük çıkmıştır.

Çizelge 4.9 incelendiğinde tahmin edilecek gün içindeki farklı zaman ufuklarında, özellikle ilk 3 saat çok düşük üretim ortalamalarına sahipken, 6 saatten itibaren üretim miktarının yükselmeye başladığı ve günün son 8 saatinde maksimum üretim değerlerinin gerçekleştiği görülmüştür. Çizelge 4.8’de de görüldüğü gibi Model A-2 kullanılarak 2 gün süreli eğitim verisi ile oluşturulan ağlara ait ortalama hata oranları 24 saat için incelendiğinde; lojistik ve Gauss aktivasyon fonksiyonu kullanan ağlarda, ortalama hata oranı %10’un bile üzerine çıkmıştır. Bunun nedeni daha önce belirtildiği gibi eğitim için kullanılan önceki iki günün (25-26 Ekim) çok düşük üretim ve rüzgar hızı ortalamalarına sahip olmasının yanısıra gün içindeki üretim ve rüzgar hızı değerlerinin de çok değişken olmasıdır. Bu ağ modelleri için eğitim süresinin geçmiş 1 haftaya uzatılması ile Çizelge 4.8’de görülen hata oranlarının, üretimin düşük olduğu ilk 3 saat için çok fazla değişmediği görülürken, üretimde dalgalanmaların ve artışların gerçekleştiği ilk 6 saat için hata oranlarının biraz daha azaldığı görülmüştür. 24 saat için ise hata oranlarının ortalaması, neredeyse önceki tahminlerin hata oranlarının yarısına kadar düşmüştür. Rüzgar hızı ve ortalama üretim değerlerinin düşük olduğu ilk 1 saat için en iyi sonuçlar Model A-2 ile oluşturulan, geçmiş 2 güne ait veri setiyle eğitilen ve Gauss aktivasyon fonksiyonunu kullanan ağ ile elde edilirken, 3 saat ve 6 saat için hata oranı en az tahminler yine Model A-2 ile oluşturulmuş, ancak geçmiş 1 haftaya ait veri setiyle eğitilmiş ve hiperbolik tanjant aktivasyon fonksiyonunu kullanan ağ ile elde edilmiştir. 24 saat için en düşük hata oranları Model B ile elde edilirken, Model A-2 ile oluşturulan; geçmiş iki güne ait verilerle eğitilen ağların hata oranları oldukça yüksek değerlere ulaşmıştır. Ancak Model A-2 ile oluşturulan, geçmiş 1 haftaya ait verilerle eğitilen ağların tahminlerine ait hata oranları Model B’ye yaklaşabilmektedir.

Bu duruma ek olarak Çizelge 4.9’da Model A-2 ile oluşturulan, 1 hafta süreli veri setiyle eğitilen ve Gauss aktivasyon fonksiyonu kullanan ağın; 24 saatlik ortalama üretim tahmininin, gerçekleşen değerle neredeyse aynı olduğu görülmektedir. Ancak bu durum için hata oranının Çizelge 4.8’de %6.05 olarak belirtilmesinin nedeni; 24 saat içindeki 10 dakikalık zaman adımlarıyla yapılan tahminlerin hata oranlarının her nokta için ayrıca belirlenip, bu oranların ortalamalarının alınmış olmasıdır. Bu nedenle ortalama hata oranları göz önünde bulundurulduğunda Model B ile daha düşük hata oranlarına sahip sonuçlar elde


edilirken, Model A ile oluşturulan bazı ağlarda belirli bir zaman ufku için ortalama üretim değeri hesaplandığında gerçekleşen değerlere daha yakın sonuçlar elde edilmiştir.

Durum 4 – 10 Mayıs

Çizelge 4.10. Durum 4’te eğitim ve test için kullanılan günlere ait minimum, maksimum ve ortalama rüzgar hızı değerleri


	Tahmin edilen gün	Geçmiş 2 gün	Geçmiş 1 hafta
	10 Mayıs	8-9 Mayıs	3-9 Mayıs
Ortalama rüzgar hızı	14.8 m/s	8.0 m/s	4.5 m/s
En düşük rüzgar hızı	8.5 m/s	0.9 m/s	0.5 m/s
En yüksek rüzgar hızı	18.7 m/s	15.4 m/s	15.4 m/s

Kullanılan veri seti içinde mayıs ayı, yıl içindeki en düşük ortalama rüzgar hızı ve üretim değerlerine sahip olan ay olduğu için YSA’nın performansının nasıl olacağı bu durum için de incelenmiştir. 10 Mayıs günü, ay içindeki en yüksek üretim ortalamasına sahip olmasının yanı sıra Şekil 4.10’da görülebileceği gibi bu günden sonraki en yüksek ortalama üretim miktarı, 10 Mayıs’ta gerçekleşen ortalama üretim miktarının hemen hemen yarısı kadardır. Çizelge 4.10’da belirtildiği gibi bu durum için önceki 1 haftaya ait üretim ve rüzgar hızı değerleri çok düşük olduğu için Model A-2 ile oluşturulan ağlarda, ağın sadece geçmiş 2 güne ait veri setiyle eğitilmesi yeterli görülmüştür. Geçmiş 2 güne ait eğitim verileri, geçmiş 1 haftaya ait eğitim verisi setinde gerçekleşen maksimum ve minimum değerleri de kapsadığı için 1 haftaya ait verilerin kullanılmasına ihtiyaç duyulmamıştır.




Şekil 4.10. Mayıs ayı günlük ortalama üretim miktarları (kWh)

Bu durum için oluşturulan ağların, ay ortalaması için oldukça yüksek değerleri tahmin etmeye çalışmış olması ağları zorlarken, Şekil 4.11’de görüldüğü gibi üretim miktarındaki dalgalanmaların da sık olması durum 4 için tahmin yapılmasını diğer durumlardan daha zor kılmaktadır.




Şekil 4.11. Model A-2 ile geçmiş iki güne ait eğitim verisi kullanılarak 10 Mayıs günü için yapılan tahminler (a) ve hata oranları (b)

Şekil 4.11 incelendiğinde tahminlerin genel olarak gerçekleşen değerlere benzediği ancak hata oranlarının noktasal olarak %45’e kadar ulaştığı görülmüştür.



(a)



(b)

Şekil 4.12. Model B ile 10 Mayıs günü için yapılan tahminler (a) ve hata oranları (b)

Model B ile yapılan tahminler, zamana bağlı olmayan bir ağ modeliyle yapıldığı için ay içindeki özel durumlardan etkilenmemiş ve Şekil 4.12’de görüldüğü gibi Model A-2 ile yapılan tahminlere göre gerçek değerlere daha yakın sonuçlar vermiştir. Ancak üretim eğrisinde dalgalanmaların görüldüğü zaman aralıkları için yapılan tahminlerin hata oranlarında, bu model için de artışlar görülmüştür.

Çizelge 4.11 incelendiğinde naive yöntemiyle oldukça yüksek hata oranları elde edilirken YSA’ların ürettiği sonuçların genel olarak naive yönteminden daha düşük hata oranlarına sahip olduğu görülmüştür.

Çizelge 4.11. 2 gün süreli eğitim veri setiyle Model A-2 ile yapılan tahminlerde ve Model B ile yapılan tahminlerde hesaplanan ortalama hata oranları

Aktivasyon Fonksiyonu	1 saat (NMAE)(%)	3 saat (NMAE)(%)	6 saat (NMAE)(%)	24 saat (NMAE)(%)
Naive Yön.	37.44	22.84	17.17	-
Model A-2				
<i>Eğitim (2 gün)</i>				
Lojistik	14.72	18.82	20.00	16.40
Tanjant(h)	20.81	15.96	15.81	9.02
Gauss	21.48	24.34	21.16	12.00
Model B				
Lojistik	7.13	6.39	5.39	3.79
Tanjant(h)	7.39	6.46	5.43	3.82
Gauss	7.43	6.59	5.51	3.94

Çizelge 4.12. 2 gün süreli eğitim veri setiyle Model A-2 ile yapılan tahminler, Model B ile yapılan tahminler ve gerçekleşen ortalama üretim değerleri

Aktivasyon Fonksiyonu	1 saat (kWh)	3 saat (kWh)	6 saat (kWh)	24 saat (kWh)
Gerçekleşen	1813.5	2251.5	2441.9	2669.0
Model A-2				
<i>Eğitim (2 gün)</i>				
Lojistik	1929.7	1958.1	1977.3	2223.1
Tanjant(h)	2366.7	2314.9	2254.4	2631.2
Gauss	2289.4	2170.3	2236.5	2490.8
Model B				
Lojistik	2027.8	2443.2	2584.6	2736.3
Tanjant(h)	2035.4	2445.5	2587.1	2738.8
Gauss	2036.6	2449.3	2591.6	2738.4

Model A-2 ile yapılan tahminlerin hata oranları, naive yönteminin hata oranlarından daha düşük ya da yakın olmasına rağmen, Model A-2'nin zamana bağlı bir ağ yapısı olması nedeniyle Model B'ye göre oldukça yüksek çıkmıştır.

Çizelge 4.12'de ise hem gerçekleşen hem tahmin edilen değerlerin mayıs ayına göre oldukça yüksek olduğu görülebilmektedir. Bu ay içinde gerçekleşen ikinci en yüksek ortalama üretim değeri 1460.0 kWh'tir. Çizelge 4.12 incelendiğinde; Model A-2 ile oluşturulan bazı ağ modellerinin tahmin ettiği ortalama değerler, Model B ile oluşturulan ağlarla tahmin edilen ortalama değerlere göre gerçek sonuçlara daha yakın olarak görülmektedir. Ancak Çizelge 4.11'de Model A-2 için hata oranlarının, Model B ile oluşturulan ağlara göre çok daha yüksek olmasının nedeni; hata oranları hesaplanırken her zaman adımı için hata oranının ayrıca hesaplanmış olmasıdır. Şekil 4.11'de görüldüğü gibi noktasal hata oranları, Model A-2 ile oluşturulan ağlarda oldukça yükselmektedir ve bu nedenle ortalama hata

hesaplandığında yüksek hata oranları elde edilmektedir. Belirli zaman ufukları için elde edilen ortalama üretim değerleri incelendiğinde; Model B ile elde edilen sonuçlar, ortalama hata oranları daha düşük olmasına rağmen gerçekleşen değerlerden daha yüksektir. Model A-2 ile oluşturulan ağlarla elde edilen ortalama üretim değerleri incelendiğinde ise; zaman ufkuna göre değişmekle birlikte bu ağların gerçekleşen değerlere daha yakın sonuçlar verebildiği görülmektedir. 24 saat için yapılan ortalama üretim tahminlerine bakıldığında; Model A-2 ile oluşturulan ve hiperbolik tanjant fonksiyonunun kullanıldığı ağ modeliyle, gerçekleşen ortalama üretime en yakın tahmin sonucu elde edilmiştir.

4.1.1. Durum 1, 2, 3 ve 4 Değerlendirmesi

Durum 2, Durum 3 ve Durum 4 gibi YSA'nın, daha önce görmediği değerleri tahmin etmesinin beklendiği durumlarda; Model A-2 için genel olarak en düşük hata oranları, hiperbolik tanjant aktivasyon fonksiyonunu kullanan ağlar ile elde edilmiştir. Bu koşullar dışında kullanılan aktivasyon fonksiyonları arasında belirgin bir fark olmamakla birlikte oluşturulan ağların hata oranları referans modele göre kabul edilebilir ve birbirlerine yakın değerlerde çıkmıştır. Model A-2 ile oluşturulan farklı aktivasyon fonksiyonları kullanan ağlara ait sonuçlarla, Model B ile oluşturulan farklı aktivasyon fonksiyonları kullanan ağlara ait sonuçlar incelendiğinde ise aktivasyon fonksiyonu seçiminin Model B'de, Model A-2'ye göre daha az etkili olduğu da görülmektedir.

Model B ile Model A-2 karşılaştırıldığında ise genel olarak Model B ile daha düşük ortalama hata oranlarına sahip sonuçlar elde edilirken, Durum 3'te rüzgar hızının oldukça düşük olduğu zaman aralıklarında Model A-2 ile daha düşük ortalama hata oranlarına sahip sonuçlar alınmıştır. Ancak çalışmada seçilen zaman ufukları için tahmin edilen ortalama üretim değerleri ve gerçekleşen ortalama üretim değerleri incelendiğinde; Durum 3 ve 4'te Model B ile elde edilen ortalama üretim değerlerinin, gerçekleşen değerlerden daha yüksek olduğu görülmektedir. Bu durumlar için Model A-2 ile oluşturulan ağlara ait ortalama üretim tahminleri incelendiğinde ise; gerçekleşen değerlere daha yakın ortalama değerlerin bu ağlarla elde edildiği görülmektedir.

Ayrıca Model A-2'yle her durum için farklı bir ağ, tahmin edilecek günden önceki verilerle eğitilirken en iyi sonuç veren modelin belirlenebilmesi için farklı gizli nöron sayılarına sahip ağlar aynı verilerle eğitilmiş ve test için en düşük hata oranlarına sahip ağ modeli seçilmiştir. Bu aşamada 24 saat süreli tahminler yapılırken; ilk 6 saat için hata oranlarının daha düşük olarak gözlemlendiği ağlarda, 24 saat için yapılan tahminlerin hata oranının arttığı ya da ilk

6 saat için daha yüksek hata oranları üreten ağların, 24 saat için daha düşük hata oranlarına ulaştığı görülmüştür. Bu nedenle yapılacak tahminin amacına göre zaman ufkunun belirlenmesi ve modelin belirlenen zaman ufkuna uygun olacak şekilde oluşturulması ya da geliştirilmesiyle daha başarılı sonuçlar elde edilebileceği sonucuna ulaşılmıştır. Buna ek olarak oluşturulan modellerin optimizasyonu ile istenilen zaman ufku için hata oranlarının düşürülebildiği belirtilmektedir [73, 83].

Model A-2 ile öğrenme süresi için test edilen durum 1, 2, 3 ve 4'te farklı koşullarda ve farklı mevsimlere ait aylardan 4 gün değerlendirilmiş ve genel olarak geçmiş iki güne ait verilerin öğrenme için yeterli olabildiği, hatta naive yöntemine yakın ya da daha iyi sonuç verdiği görülmüştür. Ancak Durum 3'te olduğu gibi rüzgar hızının çok düşük olduğu günler öğrenme için ağa gösterildiğinde ve tahmin edilecek gün içerisindeki değişkenliğin fazla olduğu günlerde; ağın tahmin performansı kötü olmamasına rağmen öğrenme süresinin 1 haftaya çıkartılması ile hata oranlarının düşeceği görülmüştür. Durum 4'te ise yıl içinde çok sık rastlanılmayan koşullar için yapılan tahminlerin hata oranları diğer durumlara göre yüksek olarak görülse de naive yönteminden daha düşük çıkmıştır. Elde edilen sonuçlara göre yapılacak olan tahminin amacı, elde edilmek istenen hata oranı, seçilen zaman ufku ve eldeki veri miktarına göre; Model A-2 için iki öğrenme süresinden uygun olanın tercih edilebileceği sonucuna varılmıştır.

Model A-2'ye göre daha çok sayıda ve farklı koşullara ait örneklerle eğitilmiş olan, statik yapıdaki Model B ile yapılan tahminler ise genel olarak tüm durumlarda Model A-2 ile yapılan tahminlerden daha düşük ortalama hata oranlarına sahip sonuçlar vermiştir.

Ayrıca üretimin hemen hemen sabit olduğu zaman aralıkları için hata oranları düşük değerlere inerken, dalgalanmaların görüldüğü zaman aralıklarında her durumda ve her iki model için de hata oranlarında artışlar görülmektedir.

4.2. Girdilerin Etkisi

Kısa süreli rüzgar tahminlerinde; tahmin için 0-6 saatlik bir zaman ufku seçildiğinde, sadece geçmiş üretim değerlerinin girdi olarak kullanıldığı ağ yapıları mevcuttur. Literatürde 0-6 saatlik zaman ufku için sadece üretim değerlerini kullanarak yapılan tahmin modellerinde naive yöntemin sonuçlarını geliştirmenin zor olduğu belirtilmektedir [31]. Çalışmada bu durum için kullanılan ağ (Model A-1) karmaşık bir yapıya sahip olmadığı için gösterilen son veriden sonraki 3 saati kapsayan tahminler yaptırılmış ve naive yöntemle karşılaştırılmıştır. 6 saatten daha uzun süreli zaman ufukları için ise meteorolojik verilerden yararlanılması

gerektiği yapılan çalışmalarda belirtilmektedir [25]. Çalışmanın bu kısmında seçilen girdilerin kısa süreli tahminleri nasıl etkilediği araştırılmıştır ve Model A-1, Model A-2, Model A-3 ve Model B ile elde edilen sonuçlar karşılaştırılmıştır. Önceki bölümde öğrenme süresi olarak geçmiş iki gün kullanıldığında referans modele (naive yöntem) göre hata oranları yüksek sonuçlar alınmadığı için Model A kullanılarak oluşturulan ağlarda bu öğrenme süresi tercih edilmiş ve daha uzun süreli eğitim verisi yerine başka bir girdiyle sonuçların daha iyi bir hale getirilmesinin mümkün olup olmadığı incelenmiştir.

Rüzgar enerjisi sistemlerinde yapılacak üretim miktarını belirleyen en önemli etken rüzgar hızıdır. Kullanılan veriler arasındaki korelasyon katsayıları da incelendiğinde rüzgar hızı ve üretim arasındaki katsayıların yeterince yüksek olduğu görülmektedir. Bu nedenle meteorolojik verilerin kullanıldığı her durumda rüzgar hızından girdi olarak yararlanılmıştır. Çalışmanın bu bölümünde yararlanılan Ocak ve Temmuz aylarına ait rüzgar hızı-üretim korelasyon katsayıları Çizelge 4.13'te görülmektedir.

Çizelge 4.13. Ocak ve Temmuz ayı rüzgar hızı-üretim korelasyon katsayıları

	Korelasyon Değeri
Ocak	0.62
Temmuz	0.97

Çizelge 4.13'te Ocak ayı için Temmuz ayına göre daha düşük bir korelasyon katsayısı görülmesinin nedeni daha önceki bölümlerde belirtildiği gibi bu ay içinde gerçekleşen verim kayıpları ve üretimin tamamen durduğu zaman aralıklarının daha fazla olmasından kaynaklanmaktadır.

Rüzgar hızı ve üretime ek olarak sıcaklık girdisinin kullanılmasının Model A ile oluşturulan ağların performansını nasıl etkilediği de araştırılmış; sıcaklık değerlerinin farklı olması nedeniyle tahmin için temmuz ve ocak aylarından birer gün seçilmiştir.



Durum 5 – 20 Temmuz

Çizelge 4.14. Durum 5’te eğitim ve test için kullanılan günlere ait minimum, maksimum, ortalama rüzgar hızı değerleri ve ortalama sıcaklık değerleri

	Tahmin edilen gün	Geçmiş 2 gün
	20 Temmuz	18-19 Temmuz
Ortalama rüzgar hızı	14.0 m/s	16.2 m/s
Ortalama sıcaklık	20.4 °C	20.0 °C
En düşük rüzgar hızı	10.8 m/s	10.6 m/s
En yüksek rüzgar hızı	18.0 m/s	19.1 m/s



Durum 5 için ilk olarak Model A-1 ile meteorolojik veriler kullanılmadan tahminler yapılmıştır. Üretim değerlerinin genel ortalamalara göre yüksek olduğu günün ilk 3 saati için Model A-1, geçmiş iki güne ait verileri eğitim için kullanarak Şekil 4.13’te görüldüğü gibi gerçekleşen değerlere benzer sonuçlar vermiştir. Şekil 4.13 incelendiğinde ise lojistik aktivasyon fonksiyonunu kullanan ağ ile tahmin yapılan bir nokta için hata oranının diğer iki ağdan farklı olarak %15’e kadar çıktığı, ancak bu zaman adımı dışında her aktivasyon fonksiyonunu kullanan ağ ile noktasal hata oranlarının %10’un altında kaldığı görülmektedir.

Girdi olarak geçmiş üretim değerlerine rüzgar hızının da eklenmesiyle daha uzun zaman ufkuna sahip tahminler yapılabilmektedir. 20 Temmuz için Model A-2 ile yapılan tahmin sonuçları daha önce Durum 1’de incelenmiştir (Şekil 4.1).



Şekil 4.13. Model A-1 kullanılarak 20 Temmuz gününün ilk 3 saati için yapılan tahminler (a) ve hata oranları (b)

Sıcaklığın da girdi olarak ağı eklenmesiyle, yani Model A-3'le yapılan tahminlerin sonuçları ise Şekil 4.14'te görülmektedir.



Şekil 4.14. Model A-3 kullanılarak oluşturulan ağların 20 Temmuz günü için tahminleri (a) ve hata oranları (b)

Model A-3 ile yapılan tahminlerde de Model A-2 ile yapılan tahminlerde olduğu gibi dalgalanmaların olduğu aralıklarda hata oranları artmıştır. Şekil 4.1’de görüldüğü gibi Model A-2’yle yapılan tahminlerde bu zaman aralıkları için noktasal maksimum hata oranları %18’e yaklaşırken, Şekil 4.14 (b) incelendiğinde Gauss aktivasyon fonksiyonunun bu bölgelerdeki hata oranının oldukça arttığı ve %25’e yaklaştığı görülmüştür.

Ayrıca 20 temmuz günü için Model B ile yapılan tahminler önceki bölümde Durum 1’de incelenmiş olup, elde edilen sonuçlar Şekil 4.3’te verilmiştir.

Çizelge 4.15. Model A-1, A-2, A-3 ve Model B kullanılarak 20 temmuz günü için yapılan tahminlere ait hesaplanan ortalama hata oranları

Aktivasyon Fonksiyonu	1 saat (NMAE)(%)	3 saat (NMAE)(%)	6 saat (NMAE)(%)	24 saat (NMAE)(%)
Naive Yön.	4.72	3.63	10.10	-
Model A-1				
Lojistik	2.98	4.97	-	-
Tanjant(h)	4.40	3.73	-	-
Gauss	3.89	2.90	-	-
Model A-2				
Lojistik	4.12	3.83	4.89	3.25
Tanjant(h)	4.30	3.86	3.98	3.50
Gauss	4.31	3.83	3.71	2.79
Model A-3				
Lojistik	3.96	3.24	4.35	3.79
Tanjant(h)	7.03	4.78	5.48	4.95
Gauss	3.70	4.65	4.75	4.33
Model B				
Lojistik	0.90	0.96	0.98	1.46
Tanjant(h)	0.92	1.03	0.92	1.36
Gauss	1.11	1.14	0.92	1.39

Çizelge 4.15 incelendiğinde Model A-1 ile oluşturulan modellerin tümü ilk 1 saat için, naive yönteme göre hata oranları daha düşük tahminler yapmıştır. Bu modelle 3 saat için yapılan tahminlerde (tahmin süresi uzadığında) ise hata oranları referans modele yakın çıkarken sadece Gauss aktivasyon fonksiyonunu kullanan ağ ile referans modelden daha düşük hata oranları elde edilmiştir. İlk 1 saat için Model A-2 ve Model A-3 ile naive yönteminden daha düşük hata oranları elde edilirken Model A ile oluşturulan ağlar arasında en düşük hata oranına Model A-1 ve lojistik aktivasyon fonksiyonu kullanılarak ulaşılmıştır. Zamana bağlı olmayan Model B ile ise genel olarak tüm zaman ufukları için en düşük hata oranlarına ulaşılmıştır.

Sıcaklık girdisinin etkisini gözlemlemek için Model A-2 ve A-3’le yapılan tahminler karşılaştırıldığında ise; Model A-3’le yapılan tahminlerde Model A-2’ye göre lojistik aktivasyon fonksiyonu ile oluşturulan ağın hata oranlarının ilk 6 saat için azaldığı görülürken 24 saat için arttığı görülmüştür. Gauss aktivasyon fonksiyonu ile oluşturulan ağ için ise sadece ilk 1 saat için yapılan tahminlerin hata oranında düşüş görülmüştür. Hiperbolik tanjant aktivasyon fonksiyonu ile oluşturulan ağın hata oranları ise Model A-3’ün kullanılmasıyla artmıştır.

Çizelge 4.16. Model A-1, A-2, A-3 ve Model B kullanılarak 20 temmuz günü için yapılan tahminler ve gerçekleşen ortalama değerler

Aktivasyon Fonksiyonu	1 saat (kWh)	3 saat (kWh)	6 saat (kWh)	24 saat (kWh)
Gerçekleşen	2483.0	2487.5	2691.0	2800.5
Model A-1				
Lojistik	2483.0	2487.5	-	-
Tanjant(h)	2497.4	2395.0	-	-
Gauss	2558.2	2487.4	-	-
Model A-2				
Lojistik	2534.8	2433.2	2574.8	2764.4
Tanjant(h)	2543.5	2450.0	2611.8	2748.5
Gauss	2451.1	2406.0	2597.3	2786.3
Model A-3				
Lojistik	2514.4	2443.9	2587.4	2722.1
Tanjant(h)	2694.1	2630.7	2673.1	2760.6
Gauss	2498.8	2444.9	2597.6	2733.3
Model B				
Lojistik	2508.0	2514.5	2703.4	2811.7
Tanjant(h)	2510.4	2517.3	2704.3	2812.4
Gauss	2515.6	2520.7	2709.7	2818.0

Çizelge 4.16 incelendiğinde ise Model A-1 kullanılarak oluşturulmuş ve lojistik aktivasyon fonksiyonuyla çalışan ağ ile ilk 1 saat ve 3 saat için tahmin edilen ortalama değerlerin, gerçekleşen değerlerle aynı olduğu görülmüştür. Çizelge 4.15'te ise bu zaman ufukları için en düşük hata oranlarının Model B ile elde edildiği görülmektedir. Daha önce de belirtildiği gibi hata oranlarının 10 dakikalık zaman adımlarına göre noktasal olarak hesaplanması ve ortalamalarının alınması ile NMAE değeri hesaplandığı için bu durumların % hata oranı Çizelge 4.15'te görüldüğü gibi 0'dan farklı çıkmıştır.



Durum 6 – 3 Ocak

Çizelge 4.17. Durum 6'da eğitim ve test için kullanılan günlere ait minimum, maksimum, ortalama rüzgar hızı değerleri ve ortalama sıcaklık değerleri

	Tahmin edilen gün	Geçmiş 2 gün
	3 Ocak	1-2 Ocak
Ortalama rüzgar hızı	4.7 m/s	11.5 m/s
Ortalama sıcaklık	4.0 °C	4.2 °C
En düşük rüzgar hızı	1.2 m/s	1.5 m/s
En yüksek rüzgar hızı	7.6 m/s	24.5 m/s

Durum 6'da tahmin için seçilen gün oldukça düşük rüzgar hızı ve üretim değerlerine sahiptir. Model A-1 ile 3 Ocak gününün ilk üç saati için yapılan tahminler Şekil 4.15'te


görülmektedir. Genel olarak düşük üretim değerlerine sahip zaman adımları için yapılan tahminler düşük hata oranlarına sahipken, üretim değerlerinin artmaya başladığı noktalarda hata oranları da tüm fonksiyonlar için artmıştır ve yaklaşık olarak %10'a kadar çıkmıştır.



Şekil 4.15. Model A-1 ile 3 Ocak günü için yapılan tahminler (a) ve hata oranları (b)


Model A-2 ile 3 Ocak günü için yapılan tahminlerde ise üretim ortalamalarının çok düşük ancak dalgalanmaların fazla miktarda olmadığı zaman aralıklarında, Şekil 4.16'da görüldüğü gibi hata oranları oldukça düşük çıkmıştır. Dalgalanmaların arttığı zaman aralıklarında ise hata oranlarının yükseldiği görülürken, minimum ve maksimum değerler arasında çok büyük farklar olmaması nedeniyle ölçülen en yüksek noktasal hata oranı %10

civarında olmuştur. Model A-1 ile yapılan tahminlerde üretim değerlerinin arttığı ve hata oranlarının %10'un üzerine çıktığı 17. zaman adımı için ise Model A-2 ile yapılan tahminlerde de hata oranı önceki zaman adımlarına göre artsa da her aktivasyon fonksiyonu için %8'in altında kalmıştır.



Şekil 4.16. Model A-2 ile 3 Ocak günü için yapılan tahminler (a) ve hata oranları (b)

Model A-3'ün kullanılmasıyla oluşturulan ağlar için ise Şekil 4.17'de görüldüğü gibi Model A-2'ye paralel sonuçlar elde edilmiştir. Ancak dalgalanmaların azaldığı bölgelerdeki hata oranları, Model A-3 ile yapılan tahminlerde artmıştır.



Şekil 4.17. Model A-3 ile 3 Ocak günü için yapılan tahminler (a) ve hata oranları (b)

3 Ocak günü için genel olarak hız ve üretim değerleri düşük olduğundan bazı durumlarda oluşturulan ağlar, üretim için negatif değerler içeren sonuçlar vermiştir. Ancak negatif bir üretim söz konusu olamayacağı için bu değerler 0 olarak alınmıştır. Bu durumun ağların genel performansı üzerinde büyük etkisi olmadığı da görülmüştür. Çizelge 4.18’de görülen 24 saatlik zaman ufku için hesaplanan hata oranlarını gösteren sütundaki ilk değer; ağın negatif aralıktaki tahminlerinin de genel hata oranının içine katıldığı durumlar, ikinci değer ise negatif değerlerin 0’a sabitlenmesiyle elde edilen hata oranlarıdır.

Çizelge 4.18. Model A-1, A-2, A-3 ve Model B kullanılarak 3 ocak günü için yapılan tahminlere ait hesaplanan ortalama hata oranları

Aktivasyon Fonksiyonu	1 saat (NMAE)(%)	3 saat (NMAE)(%)	6 saat (NMAE)(%)	24 saat (NMAE)(%)
Naive Yön.	3.98	4.31	4.30	-
Model A-1				
Lojistik	0.77	2.72	-	-
Tanjant(h)	1.80	3.50	-	-
Gauss	3.50	3.38	-	-
Model A-2				
Lojistik	2.94	2.91	2.86	1.74-1.72
Tanjant(h)	2.54	2.48	2.44	1.83-1.80
Gauss	2.46	2.19	2.64	1.84-1.81
Model A-3				
Lojistik	3.39	2.77	2.65	2.27-2.25
Tanjant(h)	3.44	2.64	2.67	2.24-2.19
Gauss	3.32	3.37	2.92	2.85
Model B				
Lojistik	2.78	2.02	2.73	2.05
Tanjant(h)	2.67	1.98	2.65	2.01
Gauss	2.63	1.85	2.66	2.05

Çizelge 4.19. Model A-1, A-2, A-3 ve Model B kullanılarak 20 temmuz günü için yapılan tahminler ve gerçekleşen ortalama değerler

Aktivasyon Fonksiyonu	1 saat (kWh)	3 saat (kWh)	6 saat (kWh)	24 saat (kWh)
Gerçekleşen	160.2	174.7	279.0	218.8
Model A-1				
Lojistik	155.4	109.3	-	-
Tanjant(h)	126.5	96.9	-	-
Gauss	122.6	115.5	-	-
Model A-2				
Lojistik	209.2	138.2	240.0	214.0
Tanjant(h)	222.9	166.7	259.4	230.1
Gauss	216.3	153.3	228.2	205.2
Model A-3				
Lojistik	252.4	173.3	266.6	246.7
Tanjant(h)	253.0	182.6	251.7	226.1
Gauss	227.4	173.9	250.4	252.1
Model B				
Lojistik	243.7	235.4	360.8	279.4
Tanjant(h)	240.3	234.1	358.5	278.3
Gauss	239.2	229.8	358.7	279.1

Çizelge 4.18 incelendiğinde tüm modellerde ve tüm zaman ufuklarında naive yönteminden daha düşük hata oranları elde edildiği görülmüştür.

Model A-1 ile yapılan tahminlerde lojistik aktivasyon fonksiyonunu kullanan ağ ile ilk 1 saat için ortalama hata oranının %1'in bile altında olduğu görülmektedir. Ancak tahmin edilen sürenin uzamasıyla birlikte bu modelde beklenildiği gibi hata oranları artmış, fakat yine de 3 saat için hesaplanan hata oranlarının naive yöntemiyle elde edilen hata oranlarından daha düşük olduğu görülmüştür. Ayrıca Model A-2, A-3 ve Model B kullanılarak oluşturulan ağlara ait sonuçlar da incelendiğinde; ilk 1 saat için en düşük hata oranlarının Model A-1 ile elde edildiği görülmüştür.

Sıcaklık girdisinin etkisinin gözlemlenmesi için Model A-2 ile Model A-3 karşılaştırıldığında ise bazı durumlar için hata oranlarının az miktarda da olsa azaldığı görülürken genellikle hata oranları artmıştır. Özellikle 24 saat için hesaplanan hata oranlarında, Çizelge 4.18'de de görüldüğü gibi, sıcaklık girdisinin eklenmesiyle artışlar görülmüştür.

Model B ile yapılan tahminlerin hata oranları ise incelenen diğer durumlardan farklı olarak; Model A kullanılarak oluşturulan ağlarla yapılan tahminlerin hata oranlarından çok farklı çıkmamakla birlikte bazı zaman ufuklarında Model A ile oluşturulan ağlarla daha düşük hata oranlarına sahip sonuçlar alınmıştır. Çizelge 4.18 ve Çizelge 4.19'da 24 saat için tüm sonuçlar incelendiğinde ise en düşük ortalama hata oranlarının Model A-2 kullanılarak oluşturulan ağlar ile elde edildiği görülmüştür. Ayrıca tahmin edilen ortalama üretim değerleri incelendiğinde Model B ile elde edilen sonuçların gerçekleşen değerlerden hep daha yüksek olduğu görülmektedir.

Çizelge 4.19'da bulunan gerçekleşen ve tahmin edilen üretim değerlerinin, 3 Ocak gününde ay içindeki genel ortalamaya göre oldukça düşük olduğu görülmüştür. Ancak elde edilen sonuçlar genel olarak incelendiğinde ağın tahmin performansının düşük değerlerden olumsuz olarak etkilenmediği sonucuna ulaşılmıştır.

Durum 5 ve Durum 6 birlikte incelendiğinde; sadece geçmiş üretim değerlerini girdi olarak kullanan Model A-1 ile 1 saat ve 3 saat zaman ufku için yapılan tahminlerde, naive yöntemine yakın hatta bazı durumlarda daha iyi sonuçlar elde edilmiştir. Ancak çalışmada oluşturulan ağ modeli, karmaşık bir yapıya sahip olmaması nedeniyle en fazla 3 saatlik bir zaman ufku için tutarlı sonuçlar verebilmiştir. Sürenin uzamasıyla hata oranlarında meydana gelen artış, incelenen her iki durumda da gözlenmiştir. Geleceğe dair bir meteorolojik veriye

sahip olunmayan durumlarda bu yöntemden çok kısa süreli tahminler için faydalanılabileceği gibi model geliştirilerek daha uzun zaman ufukları için de uygun hale getirilebilir. Literatürde sadece geçmiş üretim değerleri kullanılarak çalıştırılan, daha uzun zaman ufukları için tahmin üretebilen ve hata oranları naive yönteme göre daha düşük olan modeller olduğu görülmektedir [37].

Model A-2 ile edilen sonuçlar ise Model A-1'in ürettiği sonuçlarla karşılaştırıldığında genel olarak, ilk 1 saat için Model A-1'in daha iyi sonuçlar verdiği ancak 3 saat için hata oranlarının, Model A-2 ile yapılan tahminlerin hata oranlarının üzerine çıkabildiği görülmüştür.

Rüzgar hızı ve geçmiş üretim değerlerini eğitim girdisi olarak kullanan Model A-2'nin, ağı istenilen düzeyde (naive yöntemine göre) performans göstermesi için yeterli olduğu görülürken, bu modele sıcaklık girdisinin de eklenmesiyle oluşturulan Model A-3'ten elde edilen sonuçlar da bu bölümde değerlendirilmiştir. Model A-3'te lojistik aktivasyon fonksiyonuyla çalışan ağ için Model A-2'ye göre sonuçların az da olsa geliştirilebildiği görülürken, diğer aktivasyon fonksiyonlarını kullanan ağlarda, Model A-2'ye göre elde edilen sonuçların hata oranları artmıştır. Ayrıca Model A-3'ün kullanılmasıyla 24 saatlik zaman ufku için her ağ yapısında hata miktarı, Model A-2'ye göre artmıştır. Bu durum eğitim seti ve test setinin toplam 3 günden oluşması ve bu süre zarfında çalışmada kullanılan veri seti için hava sıcaklığında büyük değişimler meydana gelmemesinden kaynaklanabilmektedir. Mabel ve Fernandez (2008) YSA ile uzun süreli rüzgar gücü tahmini için yaptığı çalışmada; girdiler belirlenirken yıl içindeki değerlerinde büyük değişiklikler olmayan parametreleri, sonuçları büyük oranda etkilemeyeceği için YSA girdisi olarak kullanmamıştır [70]. Buna ek olarak; eğitim için kullanılan gereğinden fazla veri sayısının ağı performansını kötü yönde etkilediği durumlar olduğu da belirtilmektedir [83].

Model B kullanılarak oluşturulan ağlar ise Durum 5 için, önceki bölümde de olduğu gibi, Model A kullanılarak oluşturulan tüm ağlardan daha düşük ortalama hata oranlarına sahip sonuçlar vermiştir. Ancak tahmin için seçilen günün rüzgar hızı ve üretim değerlerinin oldukça düşük olduğu Durum 6'da, daha önceki durumlardan farklı olarak Model A ile genel olarak daha düşük ortalama hata oranlarına ulaşılmıştır.

4.3. Hata Toleransı


Çalışmada kullanılan verilerin geçmiş yıllara ait olması nedeniyle ilgili günlere ait meteorolojik tahminlere ulaşılamamış ve gerçekte ölçülen değerlerden yararlanılmıştır.

Çalışma için oluşturulan Model A-1, A-2 ve Model B gelecekteki üretim miktarını öngörebilmek için meteorolojik verilere ihtiyaç duyan modellerdir. Meteorolojik tahminlerin belirli bir oranda hata payına sahip olmasının ağırlık performansını etkilediği bu konuda yapılan çalışmalarda belirtilmektedir [48]. Bu nedenle bu bölümde Model A-2 ile oluşturulan ağlar için kullanılan test setine, belirli oranlarda rastgele hatalar eklenmiştir.


Rastgele (istatistiksel) hatalar, belirli bir modele ya da standarta göre teorik olarak tahmin edilen değerler ile gerçekte ölçülen değerler arasında görülen ve kontrol edilemeyen hatalardır. Rastgele hataların belirlenmesi zordur ve sonuçları pozitif ya da negatif yönde etkileyebilirler. Çalışmanın bu bölümünde, oluşturulan modellerden rüzgar hızı girdisini kullanan Model A-2 ile yapılan tahminlerin, rüzgar hızı tahminlerine eklenen rastgele hatadan nasıl etkilendiği araştırılmıştır.

Hatalı veriler, gerçek test verilerine; %5 hata oranında $[-0.025, 0.025]$ aralığında, %10 hata oranında $[-0.05, 0.05]$ aralığında, %15 hata oranında $[-0.075, 0.075]$ aralığında ve %20 hata oranında $[-0.1, 0.1]$ aralığında (MATLAB ile) rastgele sayılar eklenerek elde edilmiştir.


İlk olarak Durum 1 ve Durum 5'te kullanılan 20 temmuz günü için iki gün süreli öğrenme verisiyle eğitilmiş ağlara (Model A-2), %5, %10, %15 ve %20 oranında rastgele hatalar eklenmiş test verisi ile tahminler yaptırılmıştır.



(a)



(b)



(c)



Şekil 4.18. 20 temmuz günü için Model A-2 ile oluşturulan ağların hata eklenmiş test verileriyle yaptığı tahminler; lojistik (a), hiperbolik tanjant (b), Gauss (c)


Şekil 4.18 ve Çizelge 4.20’de görülebildiği gibi test verilerinin hata oranları arttıkça, elde edilen tahmin sonuçlarının da hata yüzdeleri artmaktadır. Ancak eklenen hata miktarlarına rağmen ağların tutarlı sonuçlar vermeye devam ettiği de görülmüştür. Kullanılan veri seti için maksimum oranda hata eklenmesiyle elde edilen sonuçlar da yine gerçek verilerin kullanılmasıyla elde edilen sonuçlara ve naive yöntemle göre kabul edilebilir sınırlar içerisinde.

Çizelge 4.20. 20 temmuz günü için Model A-2 ile oluşturulan ağların, hata eklenmiş test verileriyle yaptığı tahminlere ait hata oranları

Eklenen hata oranı	1 saat (NMAE)(%)	3 saat (NMAE)(%)	6 saat (NMAE)(%)	24 saat (NMAE)(%)
Naive Yön.	4.72	3.63	10.10	-
Lojistik	4.12	3.83	4.89	3.25
%5	4.27	3.93	4.92	3.32
%10	4.37	3.92	5.14	3.35
%15	4.43	3.95	5.84	3.83
%20	4.61	4.26	5.83	3.85
Hiperbolik tanjant	4.30	3.86	3.98	3.50
%5	4.39	3.94	4.09	3.62
%10	4.49	4.10	4.43	3.82
%15	4.55	4.23	4.40	3.91
%20	4.87	4.31	4.49	4.01
Gauss	4.31	3.83	3.71	2.79
%5	4.46	4.02	3.91	2.94
%10	4.70	4.11	4.06	2.95
%15	4.77	5.02	4.24	3.41
%20	5.05	5.87	4.65	3.21

Durum 3'te kullanılan 27 ekim günü ise çok farklı üretim değerlerinin görüldüğü bir gün olduğu için aynı şekilde 27 ekime ait test verilerine de belirli oranlarda hatalar eklenmiş ve sonuçların nasıl değiştiği incelenmiştir. Şekil 4.19'da görüldüğü gibi düşük üretim ortalamalarına sahip zaman aralıklarında, lojistik ve hiperbolik tanjant aktivasyon fonksiyonları ile oluşturulan ağlarla yapılan tahminler hata oranının artmasından az miktarda etkilenmiştir. Ancak üretim ortalaması arttıkça eklenen hatalar, sonuçları daha fazla etkilemeye başlamıştır. Gauss aktivasyon fonksiyonu ile oluşturulan ağ ise düşük üretim ortalamalarının görüldüğü zaman aralığında, test verisine eklenen hatalardan daha çok etkilenmiştir.





(c)

Şekil 4.19. 27 ekim günü için Model A-2 ile oluşturulan ağların hata eklenmiş test verileriyle yaptığı tahminler; sigmoid (a), hiperbolik tanjant (b), Gauss(c)

Çizelge 4.21. 27 ekim günü için Model A-2 ile oluşturulan ağların, hata eklenmiş test verileriyle yaptığı tahminlere ait hata oranları

Eklenen hata oranı	1 saat (NMAE)(%)	3 saat (NMAE)(%)	6 saat (NMAE)(%)	24 saat (NMAE)(%)
Naive Yön.	3.47	9.44	17.47	-
Lojistik	1.31	4.50	8.19	11.47
%5	1.37	4.50	8.40	11.60
%10	1.37	4.50	8.34	11.64
%15	1.50	4.70	8.51	12.01
%20	1.56	4.78	8.64	12.24
Hiperbolik tanjant	1.84	2.85	4.17	9.27
%5	1.86	3.01	4.22	9.53
%10	1.88	3.14	4.64	9.85
%15	1.96	4.23	4.40	10.70
%20	2.00	3.42	4.53	12.22
Gauss	0.65	4.65	6.15	17.57
%5	0.72	4.83	6.21	17.68
%10	0.68	4.97	8.18	18.26
%15	0.71	4.91	8.27	18.76
%20	0.81	5.03	8.85	18.00

İncelenen farklı test verileri sonucunda; ağın tahmin yapması için kullanılacak olan verilerin hata oranları ne kadar düşük olursa ağın da o kadar başarılı tahminler yapabileceği görülmektedir. Ancak bazı durumlarda eklenen hata oranlarıyla, tahminler için hesaplanan

hata oranlarında (NMAE) her zaman paralel bir artış görülmemiştir. Bu durum verilere eklenen hata oranlarının rastgele bir dağılıma sahip olmasından kaynaklanmaktadır.

Meteorolojik tahminlerde bulunan hata oranlarının üretim tahmin sonuçlarını etkilemesi nedeniyle rüzgar çiftlikleri için yapılan tahminlerde, geleceğe ilişkin alınan bu meteorolojik tahminlerin hata paylarını azaltarak YSA'nın performansını arttırmak amacıyla da çalışmalar yapılmaktadır [84].



5. SONUÇLAR ve ÖNERİLER

Rüzgar enerjisi sistemleri, tüm dünyada son 10 yıl içinde yeni kurulumu yapılan enerji sistemleri arasında önemli bir paya sahipken kurulu güç kapasitesiyle de birçok ülke için önemli bir enerji kaynağı olarak değerlendirilmektedir. Türkiye’de 2005 yılında yürürlüğe giren “Yenilenebilir Enerji Yasası” ile birlikte kurulumları artan rüzgar enerjisi sistemlerinin, enerji üretimi için yapılan planlamalara göre Türkiye’nin gelecekteki enerji üretiminde önemli bir rol oynayacağı öngörülmektedir.

Rüzgarın diğer enerji kaynaklarından farklı olarak çok değişken bir karakteristiğe sahip olması nedeniyle; rüzgar enerjisi sistemlerinin, şebekeye entegrasyonu ve yapılan üretimden en verimli şekilde yararlanılabilmesi için kısa süreli tahminler ve bu tahminlere bağlı üretim planlamalarının düşük hata oranları ile yapılması gerekmektedir. Rüzgar enerjisi tahminlerinde; bölgeden bölgeye farklılık gösteren rüzgar karakteristikleri, türbinlerin çevresinde yer alan coğrafi şekiller, engeller, yükseltiler, türbin özellikleri, türbin yerleşimleri vb. koşullar üretim miktarını ve tahmin sonuçlarını etkilediği için tahmin yapılacak bölgelerin kendi içerisinde değerlendirilmesi gerekmektedir.

Bu çalışma kapsamında; Türkiye’de yer alan ve üretime devam eden bir rüzgar çiftliğinden elde edilen verilerle kısa süreli tahmin çalışması yapılmıştır. Literatürde, kısa süreli rüzgar enerjisi tahminleri için sıklıkla kullanılan; karmaşık bir modellemeye ihtiyaç duymayan ve hızlı sonuç verebilen YSA yöntemi kullanılacak tahmin modeli olarak belirlenmiştir. Statik ve dinamik yapıda iki farklı temel YSA modeli oluşturulmuş ve YSA yapılarının tahmin sonuçları üzerindeki etkileri incelenmiştir. Ayrıca YSA’da kullanılan aktivasyon fonksiyonunun, rüzgar üretim tahminleri için sonuçlarda fark yaratıp yaratmayacağının gözlemlenebilmesi için; belirlenen her temel tahmin modeli üç farklı aktivasyon fonksiyonu (lojistik, hiperbolik tanjant, Gauss) kullanılarak oluşturulmuştur. Oluşturulan modellerde YSA’ya eğitim için gösterilen verinin niteliği ve veri sayısının, ağıın öğrenmesini ve tahmin sonuçlarını nasıl etkilediği araştırılmıştır. Aynı ağ yapısı ile farklı girdilerin birlikte kullanılmasının hata oranlarını nasıl etkilediği incelenmiştir. Oluşturulan modellerin, tahmin yapabilmek için meteorolojik verilere ihtiyaç duyan modeller olması nedeniyle; meteorolojik verilerin sahip olacağı hata oranlarının, farklı koşullardaki günler için ağıın tahmin sonuçları üzerinde nasıl bir etki oluşturduğu gözlemlenmiştir.

5.1. Sonular

Oluřturulan modellerle yapılan tahmin sonuları, kısa süreli rüzgar üretim tahminlerinde bir kriter olarak kabul edilen naive yöntemi ile elde edilen tahmin sonularına göre değeriendirilmiştir. Bu değeriendirme sonucunda; her model ile yapılan tahminlere ait hata oranlarının, kabul edilebilir bir aralık içerisinde olduėu görülrken birçok sonuta naive yöntemeye çok yakın ve hatta daha düşük hata oranlarının elde edildiėi görülmüřtür. Genel olarak en düşük ortalama hata oranlarına sahip modeller ise statik yapıda olan Model B ile elde edilmiştir. Belirlenen zaman ufukları için ortalama üretim tahmini yapıldığında ise Model A ile elde edilen ortalama değerielerin, gerekleřen değerielereye daha yakın olduėu durumların bulunduėu görülmüřtür.

Farklı aktivasyon fonksiyonları ile elde edilen sonular incelendiğinde; genel olarak tahmin sonularına ait hata oranlarının farklı aktivasyon fonksiyonlarının kullanımından önemli ölçüde etkilenmediėi görülmüřtür. Özellikle statik yapıya sahip olan aė modelinde (Model B) farklı aktivasyon fonksiyonlarının kullanılmasıyla elde edilen hata oranları, her aktivasyon fonksiyonu için hemen hemen aynı çıkmıştır. Dinamik yapıya sahip olan aėda (Model A) ise; ortalama hata oranlarında önemli farklılıklar bulunmamasına rağmen aktivasyon fonksiyonları arasındaki farklılıkların Model B'ye göre daha belirgin olduėu görülmüřtür. Ancak Durum 2, Durum 3 ve Durum 4 gibi YSA'nın, daha önce görmediėi aralıklardaki değerieleri tahmin etmesinin beklendiėi durumlarda; Model A-2 için genel olarak en düşük hata oranları, hiperbolik tanjant aktivasyon fonksiyonunu kullanan aėlar ile elde edilmiştir. Bu kořullar dışında kullanılan aktivasyon fonksiyonları arasında belirgin bir fark her iki model için de görülmemiřtir.

YSA performansı üzerindeki etkileri daha detaylı olarak incelenen farklı durumlar için elde edilen sonular ise üç bölümde incelenmiştir.

İlk bölümde; YSA modellerinin eğitimi için kullanılan veri setlerinin, aėın öğrenmesi üzerinde doğrudan etkisi olduėundan; test için seilen günlere dair tahminler yapılması için farklı eğitim verisi setleriyle farklı aėlar oluşturulmuřtur. Bu durumda; dinamik yapıya sahip olan aė modelleri ile daha az veri sayısı içeren eğitim setleriyle tahmin yapılabilirken, her mevsime ait ve farklı kořullardaki verilerden oluřan bir eğitim setiyle öğrenmeyi tamamlayan statik yapıdaki model ile daha düşük hata oranları elde edilmiştir. Dinamik yapıya sahip olan aėlarda; tahmin edilmesi istenen günden önceki 2 güne ait verilerle eğitilen aėlardan elde edilen sonular, tahmin edilmesi istenen günden önceki 1 haftaya ait verilerle

eğitilen ağlardan elde edilen sonuçlara genel olarak yakın çıkarken sonuçlar naive yöntemle göre değerlendirildiğinde kabul edilebilir hata aralıkları elde edilmiştir. Ancak incelenen bazı durumlarda dinamik yapıdaki ağ modelleri, geçmiş iki güne ait verilerle eğitildiğinde veri sayısı aynı olmasına rağmen öğrenme aşamasında birbirinden çok farklı olmayan örnekler gördüğü (veri seti aralığının sınırlı kaldığı durumlarda) için diğer modellere göre daha yüksek hata oranları veren sonuçlar elde etmiştir. Statik yapıdaki ağ modeliyle elde edilen sonuçlar incelendiğinde ise, eğitim verisi setinde hem daha fazla veri sayısı kullanılması hem de veri seti aralığının geniş olmasının sonuçları olumlu olarak etkilediği görülmüştür.

İkinci bölümde; dinamik yapıdaki ağ modellerinde ağın tutarlı tahminler yapabildiği minimum verisi sayısı kullanılarak (288) farklı girdilerin sonuçlar üzerinde hata oranını azaltacak bir etkisi olup olmadığı incelenmiştir. İlk bölümde oluşturulan dinamik yapıdaki ağlar; girdi olarak rüzgar hızı ve geçmiş üretim verilerini kullanırken, genel olarak en düşük hata oranlarının elde edildiği statik yapıdaki ağ modellerinde girdi olarak rüzgar hızından yararlanılmıştır. İkinci bölümde ise dinamik yapıdaki ağ modellerine girdi olarak sıcaklık değerleri de eklenmiş ve yeni bir girdi eklenmesinin tahmin sonuçlarını, statik yapıdaki ağ modellerinin sonuçlarına yaklaştırması sağlanıp sağlanamayacağı incelenmiştir. Çalışmada kullanılan veriler ile kısa süreli tahminler yapıldığında sıcaklık girdisinin, ağların sonuçlarını önemli ölçüde etkilemediği görülmüştür. Hatta yüksek oranlarda olmamasına rağmen sıcaklık girdisinin tahmin performansını olumsuz yönde etkilediği bazı durumlar da gözlemlenmiştir.

Üçüncü bölümde; oluşturulan modellerin tahmin yapabilmek için bir meteorolojik veriye ihtiyaç duyan modeller olması nedeniyle, bu verilerin belirli hata oranlarına sahip olmasının üretim tahmini sonuçlarını nasıl etkilediği incelenmiştir. İlk olarak modellerin tahmin yapması için kullanılan test girdisi, rüzgar hızı, değerlerine %5 ile %20 aralığında eklenen rastgele hatalar ile yeni test girdileri elde edilmiştir. Daha sonra ağlara hata oranları eklenmiş bu test girdileri verilmiş ve elde edilen tahminlerin hata oranları incelendiğinde; meteorolojik verilere eklenen %20 oranında rastgele hatanın bile tahmin sonuçları üzerinde en fazla %2.69 oranında bir ortalama hata artışına neden olduğu görülmüştür.

5.2. Öneriler

Çalışmada oluşturulan YSA modellerinin farklı optimizasyon metotları ile geliştirilmesi, tahminlerin hata oranlarının düşürülmesini sağlayabilecek yöntemler arasındadır. YSA modellerinde ağırlıkların belirlenebilmesi yani öğrenmenin daha iyi olabilmesi optimizasyon yöntemlerinden sıklıkla yararlanılmaktadır. Ağırlıkların daha doğru belirlenmesi ile de daha düşük hata oranlarına sahip tahminler yapılabilir. Rüzgar üretim tahminleri için yapılan çalışmalarda kullanılan; parçacık sürü optimizasyonu (PSO), genetik algoritma ve emperyalist rekabetçi algoritma kullanılarak oluşturulacak olan modeller ile gerçekleşen değerlere daha yakın tahmin sonuçları elde edilebilir.

Ayrıca literatürde sıklıkla yer alan ve yapılması istenen tahminin niteliğine göre farklı yöntemlerin avantajlı yanlarını birleştirecek şekilde kullanılan hibrit modellerden de daha az hata oranlarına sahip tahminler yapılabilmesi için yararlanılmaktadır. Modellerin daha uzun zaman ufukları için de tahmin yapabilmesi için fiziksel bir modelle bir arada kullanıldığı hibrit modeller oluşturulabilir. Bunun dışında elde edilen hata oranlarını düşürmek için bulanık mantık gibi yapay zeka tabanlı yöntemler ile YSA modellerinin birleşiminden elde edilen hibrit modellerden yararlanılabilir.

6. KAYNAKÇA

- [1] IRENA, *REthinking Energy 2017: Accelerating the global energy transformation*, International Renewable Energy Agency, Abu Dhabi, **2017**.
- [2] REN21, *The First Decade: 2004-2014, Renewable Energy Policy for the Network 21st Century*, **2014**.
- [3] GWEC, *Global Wind Statistics: 2016*, Global Wind Energy Council, **2017**.
- [4] Kaldellis J.K., Zafirakis D., The wind energy (r)evolution: A short review of a long history, *Renewable Energy*, 36, 1887-1901, **2011**.
- [5] REN21, *Global Status Report, Renewable Energy Policy Network for the 21st Century*, **2016**.
- [6] GWEC, *Global Wind Statistics 2015*, Global Wind Energy Council, Brussels, **2016**.
- [7] TÜİK, *Enerji kaynaklarına göre elektrik enerjisi üretimi ve payları*, Türkiye İstatistik Kurumu, **2016**.
- [8] Melikoğlu M., The role of renewables and nuclear energy in Turkey's Vision 2023 energy targets: Economic and technical scrutiny, *Renewable and Sustainable Energy Reviews*, 62, 1-12, **2016**.
- [9] TÜREB, *Türkiye Rüzgar Enerjisi Birliği Rüzgar Enerjisi ve Etkileşim Raporu*, Türkiye Rüzgar Enerjisi Birliği, Ankara, **2016**.
- [10] TÜİK, *Sektörlere göre toplam sera gazı emisyonları (CO₂) eşdeğeri, 1990-2015*, Türkiye İstatistik Kurumu, **2016**.
- [11] Erdoğan E., Turkish support to Kyoto Protocol: A reality or just an illusion, *Renewable and Sustainable Energy Reviews*, 14, 1111-1117, **2010**.
- [12] Güler Ö., *Türkiye'de Rüzgar Enerjisi Durumu ve Geleceği*, Türkiye 10. Enerji Kongresi, **2006**.
- [13] Yaniktepe B., Savrun M. ve Koroglu T., Current status of wind energy and wind energy policy in Turkey, *Energy Conversion and Management*, 72, 103-110, **2013**.
- [14] Soğukpınar H. ve Bozkurt İ., Türkiye, Avrupa ve dünyada rüzgar enerjisi kullanımı, potansiyeli ve 2013 sonrası hedefler, *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 1, 23-30, **2014**.
- [15] MGM, *Türkiye Rüzgar Atlası*, Meteoroloji Genel Müdürlüğü, <https://www.mgm.gov.tr/genel/ruzgar-atlasi.aspx>. (Mayıs, **2017**).
- [16] TÜREB, *Wind Business in Turkey: An outlook for investors*, Türkiye Rüzgar Enerjisi Birliği, Ankara, **2012**.
- [17] İlkiliç C., Wind energy and assessment of wind energy potential in Turkey, *Renewable and Sustainable Energy Reviews*, 16, 1165-1173, **2012**.

- [18] TÜREB, *Türkiye Rüzgar Enerjisi İstatistik Raporu*, Türkiye Rüzgar Enerjisi Birliği, **2017**.
- [19] TÜREB, *2023 Yılında Hedef 20GW: Türkiye Rüzgar Enerjisi Yol Haritası*, Türkiye Rüzgar Enerjisi Birliği, İstanbul, **2012**.
- [20] Jung J. ve Broadwater R., Current status and future advances for wind speed and wind power forecasting, *Renewable and Sustainable Energy Reviews*, 31, 762-777, **2014**.
- [21] Ahlstrom M. ve Zavadil R. M., The Role of Wind Forecasting in Grid Operation & Reliability, *Proceedings of the IEEE Power Engineering Society Transmission and Distribution Conference*, **2005**.
- [22] Wu Y. ve Hong J., A literature review of wind forecasting technology in the world, *2007 IEEE Lausanne POWERTECH, Proceedings*, **2007**.
- [23] Uygun C. ve Eker K., Rüzgar Enerji Santrallerinin Şebekeye Bağlanması Durumunda Enerji Kalitesi Üzerindeki Etkilerinin İncelenmesi, *Türkiye 11. Enerji Kongresi*, **2009**.
- [24] Yıldır, K., Türkiye Elektrik İletim Sisteminde Rüzgar Enerji Santralleri, *TÜREK*, İstanbul, **2012**.
- [25] Monteiro, C., Bessa, R., Miranda, V., Botterud, A., Wang, J. ve Conzelmann, G., *Wind Power Forecasting: State-of-the-Art 2009*, Argonne National Laboratory, Illinois, **2009**.
- [26] Soman, S., Zareipour, H., Malik, O. ve Mandal, P., A Review of Wind Power and Wind Speed Forecasting Methods With Different Time Horizons, *North American Power Symposium (NAPS)*, **2010**.
- [27] Pinson, P., *Estimation of the Uncertainty in Wind Power Forecasting*, Doktora Tezi, MINES ParisTECH, **2006**.
- [28] Chang, W., A literature review of wind forecasting methods, *Power and Energy Engineering*, 2, 161-168, **2013**.
- [29] Smith, J., Ahlstrom, M., Zavadil, R., Sadjadpour, A. ve Philbrick R., The Role of Wind Forecasting in Utility System Operations, *2009 IEEE Power and Energy Society General Meeting*, **2009**.
- [30] Negnevitsky, M. ve Potter, C., Innovative Short-Term Wind Generation Prediction Techniques, *2006 IEEE PES Power Systems Conference And Exposition*, **2006**.
- [31] Madsen, H., Pinson, P., Kariniotakis, G., Nielsen, H. ve Nielsen, T. Standardizing the Performance Evaluation of Short-Term Wind Power Prediction Models, *Wind Engineering*, 29, no. 6, 475-489, **2005**.
- [32] Kariniotakis, G., Wind into power, *Public Service Review: Science and Technology*, 5, 188-189, **2009**.

- [33] Costa, A., Crespo, A., Navarro, J., Lizcano, G., Madsen, H. ve Feitosa, E., A review on the young history of the wind power short-term prediction, *Renewable and Sustainable Energy Reviews*, 12, no. 6, 1725-1744, **2008**.
- [34] Marti, I., Kariniotakis, G., Pinson, P., Sanchez, I., Nielsen, T., Madsen, H., Giebel, G., Usaola, J., Palomares, A.M., Brownsword, R., Tambke, J., Focken, U., Lange, M., Sideratos, G. ve Descombes, G., *Evaluation of Advanced Wind Power Forecasting Models - Results of ANEMOS Project*, European Wind Energy Conference, Athenes, Greece, **2006**.
- [35] Ata, R. Artificial neural networks applications in wind energy systems: a review, *Renewable and Sustainable Energy Reviews*, 49, 534-562, **2015**.
- [36] Çolak, İ., Sagiroglu, S. ve Yesilbudak, M., Data mining and wind power prediction: A literature review, *Renewable Energy*, 46, 241-247, **2012**.
- [37] Chitsaz, H., Amjady, N. ve Zareipour, H., Wind power forecast using wavelet neural network trained by improved Clonal selection algorithm, *Energy Conversion and Management*, 89, 588-598, **2015**.
- [38] Catalao, J., Matias, J. ve Osorio, G., Short-term wind power forecasting using adaptive neuro-fuzzy inference system combined with evolutionary particle swarm optimization, wavelet transform and mutual information, *Renewable Energy*, 75, 301-307, **2015**.
- [39] Catalao, J., Pousinho, H. ve Mendes, V., An Artificial Neural Network Approach for Short-Term Wind Power Forecasting in Portugal, *Intelligent System Application to Power Systems (ISAP)*, **2009**.
- [40] Kariniotakis, G., Stavrakakis, G. ve Nogaret, E., Wind power forecasting using advanced neural network models, *IEEE Transactions on Energy Conversion*, 11, no. 4, 762-767, **1996**.
- [41] Methaprayoon, K., Yingvivatanapong, C., Lee, W. ve Liao, J., An integration of ANN wind power estimation into unit commitment considering the forecasting uncertainty, *IEEE Transactions on Industry Applications*, 43, no. 6, 1441-1448, **2007**.
- [42] Kolhe, M., Lin, T. ve Maunuksela, J., GA-ANN for Short-Term Wind Energy Prediction, *Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, **2011**.
- [43] Chang, T., Tu, Y., Chen, C. ve Chang, Y., Estimation of monthly wind power outputs of WECS With limited record period using artificial neural networks, *Energy Conversion and Management*, 59, 114-121, **2012**.
- [44] Sideratos, G. ve Hatziargyriou, N., An advanced statistical method for wind power forecasting, *IEEE Transactions on Power Systems*, 22, no. 1, 258-265, **2007**.
- [45] Kazemzadeh, R., Aghajani, A. ve Ebrahimi, A., A novel hybrid approach for predicting wind farm power production based on wavelet transform, hybrid neural networks and imperialist competitive algorithm, *Energy Conversion and Management*, 121, 232-240, **2016**.

- [46] Li, S., Wunsch, D., O'Hair, E. ve Giesselmann, M., Neural Network for Wind Power Generation with Compressing Function, *IEEE International Conference on Neural Networks*, **1997**.
- [47] Han, S., Li, J. ve Liu, Y., Tabu search algorithm optimized ANN model for wind power prediction with NWP, *Energy Procedia*, 12, 733-740, **2011**.
- [48] Dai, Y., Zhao, P., Wang, J., Xia, J., Sheng, Y. ve Yue, J., Performance evaluation and accuracy enhancement of a day-ahead wind power forecasting system in China, *Renewable Energy*, 43, 234-241, **2012**.
- [49] Peng, H., Liu, F. ve Yang, X., A hybrid strategy of short term wind power prediction, *Renewable Energy*, 50, 590-595, **2013**.
- [50] Ghadi, M.J., Gilani, S.H., Afrakhte, H. ve Baghrmian, A., A novel heuristic method for wind farm power prediction: A case study, *Electrical Power and Energy Systems*, 63, 962-970, **2014**.
- [51] Arcaklıoğlu, E., Çam, E., Çavuşoğlu, A. ve Akbıyık, B., A classification mechanism for determining average wind speed and power in several regions of Turkey using artificial neural networks, *Renewable Energy*, 30, no. 2, 227-239, **2005**.
- [52] Sahin, B., Bilgili, M. ve Yasar, A., Application of artificial neural networks for wind speed prediction of target station using reference stations data, *Renewable Energy*, 32, no. 14, 2350-2360, **2007**.
- [53] Taşçıkaraoğlu, A. ve Uzunoğlu, M., Dalgacık dönüşümü ve yapay sinir ağları ile rüzgar hızı tahmini, *TMMOB Elektrik Mühendisleri Odası, Elektrik-Elektronik ve Bilgisayar Sempozyumu*, **2011**.
- [54] Celik, A. ve Kolhe, M., Generalized feed-forward based method for wind energy prediction, *Applied Energy*, 101, 582-588, **2013**.
- [55] Yazıcı, A., Ögüş, E., Ankaralı, S., Canan, S., Ankaralı, H. ve Akkuş, Z., Yapay sinir ağlarına genel bakış, *Türkiye Klinikleri J Med*, 27, 65-71, **2007**.
- [56] Cinsdikici, M., *ATM ağlarında yönlendirme ve çokludağıtım problemleri için yapay sinir ağı çözümleri*, Yüksek Lisans Tezi, Ege Üniversitesi Fen Bilimleri Enstitüsü, **1997**.
- [57] Halıcı, U., EE543 Lecture Notes, <http://users.metu.edu.tr/halici/courses/543LectureNotes/lecturenotes-pdf/ch1.pdf>. (Haziran, **2017**).
- [58] Köksal, M.A., *A new approach for modeling of residential energy consumption*, Doktora Tezi, Dalhousie University Faculty of Engineering, **2002**.
- [59] Beale, M., Hagan, M. ve Demuth, H., *Neural Network Toolbox User's Guide*, MATLAB, **2015**.
- [60] Haykin, S., *Neural Networks and Learning Machines*, Pearson, **2009**.
- [61] Öztemel, E., *Yapay Sinir Ağları*, Papatya Yayıncılık, **2012**.

- [62] Hagan, M., Demuth, H., Beale, M. ve Jesus, O., *Neural Network Design*, MATLAB.
- [63] Wilamowski, B. ve Yu, H., Improved computation for Levenberg-Marquardt Training, *IEEE Transactions on Neural Networks*, 21, no. 6, 930-937, **2010**.
- [64] Keleşoğlu, Ö. ve Fırat, A., Tuğla duvardaki ve tesisattaki ısı kaybının yapay sinir ağları ile belirlenmesi, *Fırat Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 18, no. 1, 133-141, **2006**.
- [65] Burney, S., Jilani, T. ve Ardil, C., A comparison of first and second order training algorithms for artificial neural networks, *International Journal of Computer, Electrical, Automation, Control, and Information Engineering*, 1, no. 1, 145-151, **2007**.
- [66] Çavuşlu, M., Becerikli, Y. ve Karakuzu, C., Levenberg-Marquardt algoritması ile YSA eğitiminin donanımsal gerçekleştirilmesi, *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve Mühendisliği Dergisi*, 5, no. 1, **2012**.
- [67] Wilamowski, B. ve Yu, H., Levenberg-Marquardt Training, *Industrial Electronics Handbook*, vol. 5 - Intelligent Systems, CRC Press, 2011, pp. 12-1 to 12-15.
- [68] Ghadi, M., Gilani, S., Afrakhte, H. ve Baghrmian, A., A novel heuristic method for wind farm power prediction: A case study, *Electrical Power and Energy Systems*, 63, 962-970, **2014**.
- [69] Früh, W.G., *Evaluation of simple wind forecasting methods applied to a long-term wind record from Scotland*, International Conference on Renewable Energies and Power Quality, Santiago de Compostela, Spain, **2012**.
- [70] Mabel, M. ve Fernandez, E., Analysis of wind power generation and prediction using ANN: A case study, *Renewable Energy*, 33, no. 5, 986-992, **2008**.
- [71] Hocaoglu, F., Fidan, M. ve Gerek, Ö., Mycielski approach for wind speed prediction, *Energy Conversion and Management*, 50, 1436-1443, **2009**.
- [72] Ouammi, A., Dagdougui, H., Sacile, R. ve Mimet, A., Monthly and seasonal assesment of wind energy characteristics at four monitored locations in Liguria region (Italy), *Renewable and Sustainable Energy Reviews*, 14, 1959-1968, **2010**.
- [73] Bigdeli, N., Afshar, K., Gazafroudi, A. ve Ramandi, M., A comparative study of optimal hybrid methods for wind power prediction in wind farm of Alberta, Canada, *Renewable and Sustainable Energy Reviews*, 27, 20-29, **2013**.
- [74] Karlsson, D., *Wind turbine performance monitoring using artificial neural networks*, Yüksek Lisans Tezi, Chalmers University of Technology Department of Energy and Environment, **2014**.
- [75] Hudecz, A., Hansen, M. O. L., Battisti, L., Villumsen, A., *Icing Problems of Wind Turbine Blades in Cold Climates*, Rüzgar Enerjisi Departmanı, Danimarka Teknik Üniversitesi, **2014**.

- [76] Diaconescu, E., The use of NARX neural networks to predict chaotic time series, *WSEAS Transactions on Computer Research*, 3, no. 3, 182-191, **2008**.
- [77] Siegelmann, H., Horne, B. ve Giles, C., Computational capabilities of recurrent NARX neural networks, *IEEE Transactions on Systems, Man, and Cybernetics*, 27, no. 2, 208-215, **1997**.
- [78] Soman, P., *An adaptive NARX neural network approach for financial time series prediction*, Yüksek lisans tezi: Graduate school-New Brunswick Rutgers, The State University of New Jersey, **2008**.
- [79] Hatalis, K., Pradhan, P., Kishore, S., Blum, R. ve Lamadrid, A., *Multi-step forecasting of wave power using a nonlinear recurrent neural network*, PES General Meeting/Conference & Exposition, IEEE, **2014**.
- [80] Cadenas, E., Rivera, W., Campos-Amezcuca, R. ve Heard, C. Wind speed prediction using a univariate ARIMA model and a multivariate NARX model, *Energies*, 9, no. 2, 1-15, **2016**.
- [81] Men, Z., Yee, E., Lien, F., Wen, D. ve Chen, Y., Short-term wind speed and power forecasting using an ensemble of mixture density neural networks, *Renewable Energy*, 87, 203-211, **2016**.
- [82] Shekhawat, A., Wind power forecasting using artificial neural networks, *International Journal of Engineering Research & Technology*, 3, no. 4, 993-998, **2014**.
- [83] Hatalis, K., Pradhan, P., Kishore, S., Blum, R. ve Lamadrid, A., *Multi-step forecasting of wave power using a nonlinear recurrent neural network*, PES General Meeting, Conference & Exposition, **2014**.
- [84] Zhang, L., Ma, L., Zhu, M., Li, K., Gan, S., Yan, J., Xu, X. ve Li, W., *NARX models for predicting power consumption of a horizontal axis wind turbine*, UKACC 11th International Conference on Control, Belfast, **2016**.
- [85] Aggarwal, S. ve Saroha, S., *Multi Step Ahead Forecasting of Wind Power by Different Class of Neural Networks*, 6th IEEE Power India International Conference (PIICON), **2014**.
- [86] Senjyu, T., Yona, A., Urasaki, N. ve Funabashi, T., *Application of Neural Network to Long-Term-Ahead Generating Power Forecasting for Wind Power Generator*, Power System Conference and Exposition, **2006**.

EK 1

Delta Kuralı İçin Gradyan Hesaplaması

Geri yayılım algoritmasında, ağırlıklardaki değişimlerin belirlenmesi için delta kuralının gradyanından yararlanılmaktadır. Bu algoritma birinci türe dayanan bir algoritma olması nedeniyle; hata uzayındaki minimumları bulmak için toplam hata fonksiyonunun birinci türevini kullanmaktadır.

$$E = \frac{1}{2} \sum_{m \in \text{öğrenme}} (t^m - a^m)^2$$

$$\frac{\partial E}{\partial w_N} = \frac{1}{2} \sum_m \frac{\partial a^m}{\partial w_N} \frac{\partial E^m}{\partial a^m}$$

$$a^m = (p_N^m w_N + b)$$

$$\frac{\partial E^m}{\partial a^m} = -2 \cdot \frac{1}{2} (t^m - a^m)$$

$$\frac{\partial E}{\partial w_N} = - \sum_m p_N^m (t^m - a^m)$$

$$g = \frac{\partial E(p, w)}{\partial w} = \begin{bmatrix} \frac{\partial E}{\partial w_1} \\ \vdots \\ \frac{\partial E}{\partial w_N} \end{bmatrix}$$

$$\Delta w = -\varepsilon \frac{\partial E}{\partial w_N} = \sum_m \varepsilon p_N^m (t^m - y^m)$$

$$w_{k+1} = w_k - \varepsilon g_k$$

Newton Metodu İçin Gradyan Hesaplaması

Newton metodunda ise her ağırlığın lineer olarak bağımsız olduğu ve her gradyan bileşeninin ağırlıkların fonksiyonları olduğu kabul edilmektedir.

$$\begin{cases} g_1 \approx g_{1,0} + \frac{\partial g_1}{\partial w_1} \Delta w_1 + \frac{\partial g_1}{\partial w_2} \Delta w_2 + \dots + \frac{\partial g_1}{\partial w_N} \Delta w_N \\ g_2 \approx g_{2,0} + \frac{\partial g_2}{\partial w_1} \Delta w_1 + \frac{\partial g_2}{\partial w_2} \Delta w_2 + \dots + \frac{\partial g_2}{\partial w_N} \Delta w_N \\ \vdots \\ g_N \approx g_{N,0} + \frac{\partial g_i}{\partial w_1} \Delta w_1 + \frac{\partial g_i}{\partial w_2} \Delta w_2 + \dots + \frac{\partial g_N}{\partial w_N} \Delta w_N \end{cases}$$

Gradyan tanımı kullanılarak eşitlik yeniden düzenlendiğinde ise ağırlık değişiminin belirlenmesi için hata fonksiyonunun ikinci türevine dayalı fonksiyonlar elde edilir.

$$\frac{\partial \left(\frac{\partial E}{\partial w_j} \right)}{\partial w_j} = \frac{\partial^2 E}{\partial w_i \partial w_j}$$

$$\begin{cases} g_1 \approx g_{1,0} + \frac{\partial^2 E}{\partial w_1^2} \Delta w_1 + \frac{\partial^2 E}{\partial w_1 \partial w_2} \Delta w_2 + \dots + \frac{\partial^2 E}{\partial w_1 \partial w_N} \Delta w_N \\ g_2 \approx g_{2,0} + \frac{\partial^2 E}{\partial w_2 \partial w_1} \Delta w_1 + \frac{\partial^2 E}{\partial w_2^2} \Delta w_2 + \dots + \frac{\partial^2 E}{\partial w_2 \partial w_N} \Delta w_N \\ \vdots \\ g_N \approx g_{N,0} + \frac{\partial^2 E}{\partial w_N \partial w_1} \Delta w_1 + \frac{\partial^2 E}{\partial w_N \partial w_2} \Delta w_2 + \dots + \frac{\partial^2 E}{\partial w_N^2} \Delta w_N \end{cases}$$

Toplam hata fonksiyonuna ait minimumların bulunması için vektörler sıfıra eşitlenir.

$$\begin{cases} -g_{1,0} \approx \frac{\partial^2 E}{\partial w_1^2} \Delta w_1 + \frac{\partial^2 E}{\partial w_1 \partial w_2} \Delta w_2 + \dots + \frac{\partial^2 E}{\partial w_1 \partial w_N} \Delta w_N \\ -g_{2,0} \approx \frac{\partial^2 E}{\partial w_2 \partial w_1} \Delta w_1 + \frac{\partial^2 E}{\partial w_2^2} \Delta w_2 + \dots + \frac{\partial^2 E}{\partial w_2 \partial w_N} \Delta w_N \\ \vdots \\ -g_{N,0} \approx \frac{\partial^2 E}{\partial w_N \partial w_1} \Delta w_1 + \frac{\partial^2 E}{\partial w_N \partial w_2} \Delta w_2 + \dots + \frac{\partial^2 E}{\partial w_N^2} \Delta w_N \end{cases}$$

Elde edilen gradyanlar matris şeklinde yazıldığında ise hata fonksiyonunun ikinci derece türevlerinden oluşan Hessian matrisi (H) elde edilir.

$$\begin{bmatrix} -g_1 \\ -g_2 \\ \vdots \\ -g_N \end{bmatrix} = \begin{bmatrix} \frac{\partial^2 E}{\partial w_1^2} & \frac{\partial^2 E}{\partial w_1 \partial w_2} & \dots & \frac{\partial^2 E}{\partial w_1 \partial w_N} \\ \frac{\partial^2 E}{\partial w_2 \partial w_1} & \frac{\partial^2 E}{\partial w_2^2} & \dots & \frac{\partial^2 E}{\partial w_2 \partial w_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 E}{\partial w_N \partial w_1} & \frac{\partial^2 E}{\partial w_N \partial w_2} & \dots & \frac{\partial^2 E}{\partial w_N^2} \end{bmatrix} \times \begin{bmatrix} \Delta w_1 \\ \Delta w_2 \\ \vdots \\ \Delta w_N \end{bmatrix}$$

$$-g = H \Delta w$$

$$\Delta w = -H^{-1} g$$

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı: Selin Cantürk
Doğum Yeri: Melbourne/AVUSTRALYA
Medeni Hali: Bekar
E-posta: selinccanturk@gmail.com

Eğitim

Lisans: Orta Doğu Teknik Üniversitesi, Fizik Bölümü

Yabancı Dil Düzeyi

İngilizce – İyi
Almanca – Orta

İş Deneyimi

2017 – 4M Danışmanlık – Uzman Yardımcısı

Deneyim Alanları

-

Tezden Üretilmiş Projeler ve Bütçesi

-

Tezden Üretilmiş Yayınlar

-

Tezden Üretilmiş Tebliğ ve/veya Poster Sunumu ile Katıldığı Toplantılar

-



HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
YÜKSEK LİSANS/DOKTORA TEZ ÇALIŞMASI ORJİNALLİK RAPORU

HACETTEPE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
TEMİZ-TÜKENMEZ ENERJİLER ANABİLİM DALI BAŞKANLIĞI'NA

Tarih: 18/01/2018

Tez Başlığı / Konusu: Bir Rüzgar Çiftliğinden Yapay Sinir Ağlarıyla Kısa Süreli Elektrik Üretim Tahmini

Yukarıda Başlığı/Konusu Gösterilen Tez Çalışmamın A) Kapak Sayfası, B) Giriş, C) Ana Bölümler D) Sonuç Kısımlarından Oluşan Toplam 112 Sayfalık Kısımına İlişkin, 18/01/2018 Tarihinde Şahsım/Tez Danışmanım Tarafından Turnitin Adlı İntihal Tespit Programından Aşağıda Belirtilen Filtrelemeler Uygulanarak Alınmış Olan Orijinallik Raporuna Göre, Tezimin Benzerlik Oranı % 1'dir.

Uygulanan Filtrelemeler:

- 1- Kaynakça Hariç
- 2- Alıntılar Hariç/~~Dâhil~~
- 3- 5 Kelimeden Daha Az Örtüşme İçeren Metin Kısımları Hariç

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü Tez Çalışması Orijinallik Raporu Alınması Ve Kullanılması Uygulama Esasları'nı İnceledim Ve Bu Uygulama Esasları'nda Belirtilen Azami Benzerlik Oranlarına Göre Tez Çalışmamın Herhangi Bir İntihal İçermediğini; Aksinin Tespit Edileceği Muhtemel Durumda Doğabilecek Her Türlü Hukuki Sorumluluğu Kabul Ettiğimi Ve Yukarıda Vermiş Olduğum Bilgilerin Doğru Olduğunu Beyan Ederim.

Gereğini Saygılarımla Arz Ederim.

Adı Soyadı:	Selin Cantürk	Tarih Ve İmza	18.01. 2018
Öğrenci No:	N14120897		<i>S. Cantürk</i>
Anabilim Dalı:	Temiz-Tükenmez Enerjiler		
Programı:	Temiz-Tükenmez Enerjiler		
Statüsü:	☒ Y.Lisans ☐ Doktora ☐ Bütünleşik Dr.		

DANIŞMAN ONAYI

UYGUNDUR.

Prof. Dr. Murat Köker
(Unvan, Ad Soyad, İmza)