



BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ

**Fen Bilimleri Enstitüsü
Enerji Sistemleri Mühendisliği Anabilim Dalı**

**BİLECİK BÖLGESİNİN GÜNEŞ IŞINIM ŞİDDETİ TAHMİNİNDE
SAKLI MARKOV MODELİNİN KULLANILABİLİRLİĞİNİN
ANALİZİ**

**İnci CEYHAN
Yüksek Lisans**

**Tez Danışmanı
Prof. Dr. Mehmet KURBAN**

**BİLECİK, 2018
Ref. No.: 10177878**



BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ

**Fen Bilimleri Enstitüsü
Enerji Sistemleri Mühendisliği Anabilim Dalı**

**BİLECİK BÖLGESİNİN GÜNEŞ IŞINIM ŞİDDETİ TAHMİNİNDE
SAKLI MARKOV MODELİNİN KULLANILABİLİRLİĞİNİN
ANALİZİ**

**İnci CEYHAN
Yüksek Lisans**

**Tez Danışmanı
Prof. Dr. Mehmet KURBAN**

BİLECİK, 2018



BILECIK SEYH EDEBALI UNIVERSITY

**Graduate School of Sciences
Energy Systems Engineering Program**

**ANALYSIS OF THE USABILITY OF THE MARKOV MODEL
HOLDING AT THE ESTIMATION OF SOLAR RADIATION OF
BILECIK REGION**

**İnci CEYHAN
Master's of Science Thesis**

**Thesis Advisor
Prof. Dr. Mehmet KURBAN**

BILECIK, 2018



BİLECİK ŞEYH EDEBALI ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS

JÜRİ ONAY FORMU

Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunun 20/12/2017 tarih ve 63 sayılı kararıyla oluşturulan jüri tarafından 09/01/2018 tarihinde tez savunma sınavı yapılan İnci CEYHAN'ın "*Bilecik Bölgesinin Güneş Işınım Şiddeti Tahmininde Saklı Markov Modelinin Kullanılabilirliğinin Analizi*" başlıklı tez çalışması Enerji Sistemleri Mühendisliği Anabilim Dalında YÜKSEK LİSANS tezi olarak oy birliği ile kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : Prof. Dr. Mehmet KURBAN

ÜYE : Yrd. Doç. Dr. Murat BAŞARAN

ÜYE : Yrd. Doç. Dr. Emrah DOKUR

ONAY

Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunun tarih ve sayılı kararı.

İMZA/ MÜHÜR

TEŞEKKÜR

Tez çalışmamın her aşamasında bana yardımcı olan, ilgi ve katkılarını esirgemeyen değerli danışmanım Sayın Prof. Dr. Mehmet KURBAN'a, tez sürecimdeki desteklerinden dolayı eşim Selahattin CEYHAN'a, ve çok kıymetli annem ve babama çok teşekkür ederim.

İnci CEYHAN

2018



ÖZET

Güneş enerjisi elde edilecek bölgede sistem kurulmadan önce o bölgenin potansiyeli iyi araştırılmalı, kurulum maliyetleri iyi hesaplanıp değerlendirilmelidir. Kurulum yapılacak bölgenin güneş ışıyım şiddeti tahminleri yapılmalıdır. Bir bölgenin güneş enerjisi potansiyel analizi yapılırken kullanılabilecek birçok modelleme ve tahmin yöntemi vardır.

Bu çalışmada kullanılan Saklı Markov Modeli (SMM), istatistiksel veriyi dikkate alarak öğrenme ve tahmin yapmaya çalışan yöntemdir. Bunun yanında, son yıllarda Saklı Markov modeller ile ilgili yeni modellemeler ortaya çıkarılmıştır. Özellikle, dil, konuşma, sinyal işleme gibi alanlarda Saklı Markov Model’ler artan bir çekiciliğe sahiptir. Günümüzde de yapay zekâ, örüntü tanıma, konuşma tanıma ve biyolojik modellemelerde de SMM karşımıza çıkmaktadır. Bunun yanında yenilenebilir enerji verilerinin modellemesinde de bu yöntem kullanılmaya başlanmıştır. Güneş enerjisi de önemli bir yenilenebilir enerji kaynağı olması nedeniyle bu çalışmada sıcaklık verileri Saklı Markov Model’de kullanılarak belli bir bölgedeki güneş ışıyım şiddeti tahmin edilerek güneş enerjisi potansiyeli belirlenmeye çalışılmıştır. Bu çalışma ile kolay elde edilebilir sıcaklık verileri yardımıyla SMM kullanılarak güneş ışıyım şiddetinin belirlenebilir olması büyük kolaylık getireceği vurgulanmaktadır. Bu yöntemin kullanılabilirliği Bilecik bölgesi uygulaması ile gösterilmiştir. Bu çalışmada bölgeye ait 2017 yılı saatlik güneş sıcaklık verileri ve test verisi olarak kullanılan güneş ışıyım şiddetleri Meteoroloji Genel Müdürlüğü’nden sağlanmıştır.

Anahtar Kelimeler

Saklı Markov Modeli, Güneş enerjisi, Güneş Işıyım Şiddeti, Sıcaklık

ABSTRACT

Before the system is installed region where solar energy will be obtained the potential of that region should be well researched, and installation costs should be well calculated and evaluated. Estimates of solar radiation intensity should be made for the area to be installed. There are many modeling and estimation methods that can be used when a zone is subjected to solar energy potential analysis.

Hidden Markov Model (SMM) used in this study is a method that learns and estimates by considering statistical data. Besides, in recent years new models related to Hidden Markov models have been uncovered. Hidden Markov Methods have a increasingly attractive for problems in language, speech, signal processing. Hidden Markov Model it has been used for many applications such as in artificial intelligence, pattern recognition, speech recognition, and modeling of biological sequences. Furthermore also in the data modeling of renewable energy this method has begun to be used, solar energy is also an important renewable energy source, for this reason in this study, it was tried to determine the potential of solar energy, potential by predicting the solar radiation intensity in a certain region in the temperature datas using in hidden markov models. In this study, it is emphasized that it is very easy to determine the solar radiation intensity by using SMM with the help of easily obtainable temperature data. The usability of this method is demonstrated with the application of Bilecik region. In this study, hourly solar temperature data belonging to the region year 2017 and solar radiation intensities used as test data belonging to the region year 2017 were obtained from the Turkish Stote Meteorolojical Service.

Key Words

Hidden Markov Models, Solar Energy, Solar Radiation, Temperature.

İÇİNDEKİLER

Sayfa No

JÜRİ ONAY SAYFASI

TEŞEKKÜR

ÖZET.....i

ABSTRACTii

İÇİNDEKİLERiii

ÇİZELGELER DİZİNİv

ŞEKİLLER DİZİNİvi

SİMGELER VE KISALTMALAR DİZİNİvii

1. GİRİŞ..... 1

1.1. Genel Bilgi..... 1

1.2.Literatür Taraması 3

1.3.Tez Kapsamında Yapılacaklar..... 3

2. GÜNEŞ ENERJİSİ..... 5

2.1.Dünya’da Güneş Enerjisi Potansiyeli 6

2.2.Türkiye’de Güneş Enerjisi Potansiyeli 8

3. GÜNEŞ ENERJİSİ POTANSİYEL ANALİZİNDE KULLANILAN

YÖNTEMLER..... 14

3.1.Güneş Verilerinin Elde Edilmesi 14

3.1.1. Piranometre 14

3.1.2. Güneşlenme süresi sensörü 14

3.1.3. Sıcaklık sensörü 15

3.1.4. Bağlı nem sensörü..... 15

3.1.5. Anemometre 15

3.1.6. Rüzgâr yön ölçer..... 15

3.2.İstatistiksel Yöntemler 16

3.2.1. Zaman serileri analizi (Zsa) 16

3.2.1.1. AR(p) modelleri..... 16

3.2.1.2. MA(q) modelleri..... 17

3.2.1.3. ARMA(p,q) modelleri 17

3.2.1.4. ARIMA(p,d,q) modelleri	18
3.2.2. Regresyon tekniđi	18
3.3.Yapay Sinir Ağları (Artificial Neural Network)	19
3.3.1. İleri beslemeli yapay sinir ağları.....	22
3.3.2. Geri beslemeli yapay sinir ağları	22
3.3.3. Geri beslemeli geri yayılmalı sinir ağları	23
3.4.Markov Model	24
3.5.Saklı Markov Model	27
4. SAKLI MARKOV MODEL	28
4.1.Deđerlendirme Problemi.....	31
4.2.Tahmin Problemi	32
4.3.Model Yapısını Öğrenme Problemi.....	32
4.4.Viterbi Algoritması.....	33
5. BİLECİK BÖLGESİNİN GÜNEŞ IŞINIM ŞİDDETİ TAHMİNİNDE SAKLI MARKOV MODELİNİN KULLANILABİLİRLİĞİNİN ANALİZİ	34
6. SONUÇLAR.....	45
KAYNAKLAR	46
ÖZGEÇMİŞ.....	49

ÇİZELGELER DİZİNİ

Sayfa No

Çizelge 2.1. Değişik bölgelerdeki güneş ışıınım miktarı.....	6
Çizelge 2.2. Güneş ışıınım miktarını etkileyen bileşenler ve etkileri.....	6
Çizelge 2.3. 2012 yılı sonrası ülkelerin kurulu güçleri.....	8
Çizelge 2.4. Bölgelere göre güneş enerjisi ve güneşlenme süresi.....	10
Çizelge 3.1. Takımın belirtilen durumlarda attığı gol sayısı.....	26
Çizelge 3.2. 28 haftada takımın durumlarla karşılaşma sıklığı.	26
Çizelge 3.3. Durumlar arası geçiş tablosu (goller arası geçişler)	26
Çizelge 5.1. Bilecik ili 1939-2016 yılları arası gerçekleşmiş ortalama sıcaklık değerleri.....	35
Çizelge 5.2. Ölçülen verilerin temel istatistikleri.....	40
Çizelge 5.3. Mayıs ayı verileri ile oluşturulmuş 26x26'lık durum geçiş matrisi	42
Çizelge 5.4. Viterbi algoritması için örnek tablo.	43

ŞEKİLLER DİZİNİ

Sayfa No

Şekil 2.1. Dünya güneş enerjisi potansiyel atlası.....	7
Şekil 2.2. Türkiye güneş enerji potansiyel atlası.....	9
Şekil 2.3. Türkiye global ışıınım değerleri (kWh/m ² -gün).....	10
Şekil 2.4. Türkiye yıllık toplam global güneş ışıınımı dağılımı.....	11
Şekil 2.5. Türkiye güneşlenme süreleri(Saat).....	12
Şekil 3.1. Piranometre.....	14
Şekil 3.2. Güneşlenme süresi montaj oryantasyonu şematığı.....	15
Şekil 3.3. Yapay sinir ağları işlem süreci.	20
Şekil 3.4. Yapay sinir ağları mimarileri.	21
Şekil 3.5. İleri beslemeli çok katmanlı bir yapay sinir ağı modeli.	22
Şekil 3.6. Geri beslemeli, geri yayılmalı sinir ağı modeli.....	23
Şekil 4.1. Saklı Markov model yapısı.	28
Şekil 4.2. Saklı Markov model örneği.	29
Şekil 4.3. Cümle üreten bir SMM.....	29
Şekil 5.1. Bilecik ili güneş enerjisi potansiyel atlası.....	34
Şekil 5.2. Bilecik bölgesine ait saatlik kuru termometre sıcaklık (°C) değerleri.	36
Şekil 5.3. Bilecik bölgesine ait saatlik yağ termometre sıcaklık (°C) değerleri.....	36
Şekil 5.4. Bilecik bölgesine ait saatlik yatay toplam ışıınım (W/m ²) değerleri.	37
Şekil 5.5. Bilecik bölgesine ait saatlik doğrudan ışıınım (W/m ²) değerleri.	37
Şekil 5.6. Bilecik bölgesine ait saatlik yatay difüzyon ışıınım (W/m ²) değerleri.	38
Şekil 5.7. Bilecik bölgesi 2017 yılı saatlik sıcaklık değerleri(°C).....	38
Şekil 5.8. Bilecik bölgesi saatlik güneş ışıınım şiddeti değerleri(cal/cm ²).	39
Şekil 5.9. Bilecik bölgesi 2017 verileri histogram grafiği.....	39
Şekil 5.10. Bilecik bölgesi 2017 verileri olasılık yoğunluk fonksiyonu grafiği.....	40
Şekil 5.11. Güneş verilerinin SMM durumlarına dönüştürülmesi.....	41
Şekil 5.12. Viterbi algoritmasını göstermek için basit bir SMM örneği.....	44

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

$^{\circ}\text{C}$	: Sıcaklık
w	: watt
m^2	:metrekare
kwh	:kilowattsaat
MW	: megawatt
λ	: Markov zincirleri
N	: Modeldeki durumların sayısı
S	:N adet ayrık elemandan oluşan durum uzayı
A	: $N \times N$ 'lik durumlar arası geçiş matrisi
π	:N boyutlu başlangıç durum vektörü
m	: Her durumdaki farklı gözlemlerin toplam sayısı
Q	: Durum dizisi
t	: Zaman
$\sigma(t)$	:En olası t durum geçiş matrisi
E	: Gözlemlerin meydana gelme olasılığı

Kısaltmalar

SMM	: Saklı Markov model
ABD	: Amerika Birleşik Devletleri
DMİ	:Devlet Meteoroloji İşleri Genel Müdürlüğü
DEKTMK	: Dünya Enerji Konseyi Türk Milli Komitesi
MGM	: Meteoroloji İşleri Genel Müdürlüğü
YEGM	: Yenilenebilir Enerji Genel Müdürlüğü
SAM	: System Advisor model
AR	: Otoregresif model
MA	: Hareketli ortalama medel
ARMA	: Otoregresif-Hareketli ortalama model
ARIMA	:Bütünlenen-otoregresif-hareketli ortalama model
MLP	: Çok katmanlı algılayıcı
LVQ	: Sayısallaştırılmış öğrenme vektörü

1. GİRİŞ

1.1. Genel Bilgi

Mevcut kaynakların artan enerji ihtiyacını karşılamada yetersiz duruma gelmesi sonucunda alternatif enerji kaynaklarını bulma ve bu kaynakları geliştirip kullanma çalışmaları hızlanmıştır. Aynı zamanda klasik yöntemlerle elde edilen, özellikle fosil kaynaklı enerjinin üretim ve kullanımı, doğada geri dönüşümü imkânsız zararlara yol açtığı için yeni ve temiz enerji arayışı gün geçtikçe artmıştır. Dünyadaki yaşanabilir ortamın korunması adına enerji üretim ve tüketiminden kaynaklanan çevre tahribatını minimum seviyeye indirmek için enerji üretim teknolojilerinde ve kaynak seçiminde çevresel etkilerin öncelikle dikkate alınması, hukuki düzenlemelerin yapılması ve enerji kullanımında verimliliğe gerekli özenin gösterilmesi gerekmektedir. Bu sebeple, dünyada çevre kirliliğine ve iklim değişikliğine sebep olan fosil kaynaklı enerji üretim sistemleri ve geleneksel enerji üretim teknolojileri yerine, çevresel zararları daha az olan, yenilenebilir ve sürdürülebilir enerji kaynakları ile yeni teknolojiler üretmek kaçınılmaz hale gelmiştir (DEKTMK, Ziyaret Edilme Tarihi: 3.12.2017). Son yıllarda kullanımı gittikçe yaygınlaşan güneş enerjisi, en önemli yenilenebilir enerji kaynaklarından biridir.

Güneş enerjisi temiz enerji olması, potansiyelinin yüksek olması, kullanımının kolaylığı ve çevre dostu enerji olması gibi nedenler sayesinde daha kolay bir şekilde yaygınlaşabilmektedir. Diğer yenilenebilir enerjilerle kıyaslandığında birçok avantaja sahiptir. Her şeyden önce bol ve tükenmeyen enerji kaynağı olan güneş enerjisinin, çevreyi kirleticisi, duman, gaz, karbon monoksit, kükürt ve radyasyon gibi atıkları yoktur. Diğer enerji kaynaklarına göre kurulum maliyetlerinin yüksek olması, kapasite faktörünün düşük olması ve benzeri teknolojik, ekonomik sorunlar giderildiğinde güneş enerjisi ileride daha da cazip hale gelecektir. Türkiye, konumu sebebiyle güneş enerjisi açısından yüksek potansiyele sahiptir fakat bu potansiyeli yeterince değerlendirememektedir (DEKTMK, Ziyaret Edilme Tarihi: 3.12.2017).

Güneş enerjisi kaynaklarından faydalanmadan önce kurulacak olan sistemin üretim ve tüketim parametrelerinin doğru boyutlandırılması ve kurulum maliyetlerinin iyi hesaplanması gerekmektedir. Çünkü güneş enerjisinden elektrik enerjisi üreten sistemlerin maliyetleri oldukça fazladır. Bu maliyet hesapları yapılırken kullanılabilecek en önemli parametre sistemin kurulacağı bölgeye ait güneş ışınım

şiddetleridir. Bu nedenle sistemin kurulacağı bölgeye ait güneş ışınlam şiddeti verilerinin doğru bir biçimde ölçülüp analizinin yapılması gerekmektedir. Bölgeye ait verilerin ölçümü yapıldıktan sonra bu verilerin doğru bir şekilde modellenmesi yapılmalıdır bunun için de verileri doğru karakterize eden analitik ifadeler kullanılmalıdır (Hocaoğlu, vd.,2010).

Güneş enerjisi verilerini kullanarak modelleme yapan ve gelecek yıllardaki verileri tahmin etmek için kullanılabilecek birçok modelleme tekniği bulunmaktadır. Saklı Markov modelleri(SMM) de en önemli modellemelerden biridir, yapay zekâ, örüntü tanıma, ses tanıma ve biyolojik modelleme gibi birçok bilimsel alanda başarılı bir şekilde kullanılan bir dizi verinin istatistiksel modellenmesidir. Literatürde birçok öğrenme algoritmalarına öncülük eder. Örneğin yapay sinir ağlarıyla hibrit SMM’de, I/O saklı markov modellerinde, ağırlık dönüştürücülerinde, değişken ağırlıktaki markov modellerinde, anahtarlama markov modellerinde, anahtarlama durum-uzay modellerinde kullanılmaktadır.

Saklı Markov modelleri, yüksek performanslı sınıflandırıcılar olarak değerlendirilebilir. Olasılık temelli sınıflandırıcıları 3’e ayırabiliriz. Bunların içinde Bayes sınıflandırıcı, gizli Markov modeli parametrik sınıflandırıcı olarak ifade edilirken alt uzay sınıflandırıcısı da bir başka olasılık temelli sınıflandırıcı olarak ifade edilebilir. Ayrıca, Markov veya Saklı Markov sayesinde bir sinyalin sadece istatistiksel olarak analizinin yapılabilmesi mümkündür. Gauss dağılımları ve Poisson dağılımları da bizlere sadece istatistiksel analizi sunabilecek diğer dağılımlar olarak göze çarpmaktadır. İstatistiksel modellerin temelinde yatan varsayım, sinyalin rastgele süreç olarak iyi bir şekilde tanımlanabileceği ve stokastik süreçlerdeki parametrelerin kesin ve iyi tanımlanmış bir yöntemle belirlenebileceği olgusudur.

Olasılıksal süreçler, olasılıksal kurallara göre, zaman içinde gelişen sistemleri inceler. Olasılıksal süreçlere basit bir örnek için bir evrenin büyüklüğünü göz önüne alalım. Başlangıçta ($t=0$ noktasında) evrenin büyüklüğü X_0 olabilir. Bu evrende sonraki gözleme dek, bazı bireyler evrenden ayrılabilir ya da bazı bireyler ortaya çıkabilir. Bu nedenle $t=1$ noktasında evrenin büyüklüğünü temsil eden X_1 , bir rastlantı değişkenidir ve alacağı değer X_0 ’a bağlıdır. $t=2$ noktasına ait olan X_2 değişkeni ise, olasılıksal olarak X_0 ve X_1 ’e bağlıdır. Bu süreç için olasılıksal model, evrenin herhangi i ve j ($j > i$) zamanları arasındaki büyümesini ya da azalmasını gösterir ve $X_0, X_1, \dots, X_i$ ’ye bağlıdır.

1.2. Literatür Taraması

İlk olarak Saklı Markov modelleri ile ilgili çalışma, “Expectation Maximization” algoritması (Dempster,1977-Titteringhton,1985) ve Baum-Welch yinelenen tahmin metoduyla beraber (Baum,1970) ortaya konulmuştur. Baum-Welch algoritması, esasen Expectation Maximization algoritmasının bir özel bölümünü oluşturur. İlerleyen yıllarda otomatik konuşma ve sinyal işleme başta olmak üzere birçok özel nitelikte uygulaması ortaya çıkmıştır.

Son 30 yıllık bir geçmişe bakıldığında SMM’nin en çok otomatik konuşma tanımada kullanıldığı görülmektedir. Rabiner (1989), metodolojik olarak birçok çalışmaya altyapı oluşturan çalışmasında bu modellemenin işleyişini ve ardından ses ve konuşma tanımada ne şekilde kullanılabileceğini anlatmaya çalışmıştır. Buradan hareketle daha sonraları SMM’nin birçok uygulaması ortaya çıkmıştır. El yazısı tanıma, örüntü tanıma, moleküler biyoloji, hata tespiti gibi konularda da uygulamaları ortaya çıkmıştır. Daha sonra Bengio (1999) istatistiksel olarak SMM’nin geliştirme ve öğrenme algoritmalarını incelemiş ve çeşitli uygulamalarda kullanılabilecek yöntemler ortaya çıkarmıştır. Bu iki çalışmadan ve diğer birçoğundan hareketle farklı alanlara uygulanabilen SMM ve Ding (2008) tarafından güç elektroniği devrelerinde hata analizinde kullanılırken Hocaoglu ve Kurban (2010) tarafından da rüzgâr hızı verilerinin belirlenmesinde atmosferik basınç değerlerinin etkisini ortaya koymak adına kullanıldı. Ses tanıma ve örüntü tanıma gibi SMM için genelleşmiş uygulamaları bir kenara bıraktığımızda son iki uygulama elektrik-elektronik alanındaki nadir uygulamalardan olmuşlardır.

1.3. Tez Kapsamında Yapılacaklar

Güneş ışınım miktarının belirlenmesinde bir bölgeye özel olarak ölçümler yapılarak doğrudan o bölgenin güneş ışınım miktarları ölçülebilmektedir. Fakat bu çalışmayla Bilecik bölgesine ait sıcaklık gözlem değerleri Saklı Markov modelde kullanılarak güneş ışınım değerlerinin belirlenebileceğinin analizi yapılacaktır.

Tezin içeriği altı bölümden oluşmaktadır. Bölümlerde ele alınan konuların içerikleri aşağıda verilmektedir.

İkinci Bölümde, güneş enerjisi hakkında bilgi verilerek Dünya’da ve Türkiye’de güneş enerjisinin potansiyel durumundan bahsedilmiştir.

Üçüncü Bölümde güneş verilerinin elde edilmesi ile ilgili kısa bilgi verilmiş ve güneş enerjisi potansiyel analizinde kullanılan yöntemler anlatılmıştır.

Dördüncü Bölümde Saklı Markov model hakkında bilgi verilmiştir.

Beşinci Bölümde Bilecik bölgesinin güneş ışıyım şiddeti tahmininde Saklı Markov modelinin kullanılabilirliğinin analizinin nasıl yapılacağı anlatılmıştır.

Altıncı Bölüm sonuçlar kısmıdır ve Saklı Markov modelin verilerin istatistiklerini modellemedeki başarısı değerlendirilmektedir.



2. GÜNEŞ ENERJİSİ

Son yıllarda kullanımında önemli bir artış gözlenen, güneş enerjisi, yenilenebilir enerji kaynakları içerisinde en önemli enerji kaynaklarından biri olmuştur. Güneş enerjisi, dışa bağımlılık gerektirmeyen ve tükenmeyen bir kaynak olması sebebiyle yenilenebilir enerji kaynaklarının başında gelir. Kullanım alanı oldukça fazla olan güneş enerjisi, konutlarda, sokak aydınlatmalarında, iletişimde, tarımda sulamada, endüstride, elektrik santrallerinde, askeri alanda ve daha birçok alanda kısacası yaşamın sürdüğü tüm alanlarda kullanılabilir durumdadır (Dinçer, 2011).

Güneş enerjisi bir ısıma enerjisidir ve güneşteki hidrojen gazının helyuma dönüşmesi şeklindeki füzyon sürecinden açığa çıkan enerjidir. Termonükleer bir reaktör olan güneşten çeşitli dalga boylarında enerji yayılmaktadır ve güneşin bütün yüzeyinden yayılan enerjinin sadece iki milyarda biri yeryüzüne ulaşmaktadır. Güneşten, 150 milyon kilometre kat ederek Dünya'ya gelen enerji, bir yılda dünyada kullanılan enerjinin yaklaşık 15 bin katıdır.

Dünya'nın şekli nedeniyle güneş enerjisinin yeryüzündeki dağılımı büyük farklılıklar göstermektedir. Dünya'ya gelen ortalama güneş enerjisi $0 - 1.100 \text{ W/m}^2$ civarındadır. Güneş enerjisinin atmosfer dışındaki ışınlam değeri yaklaşık 1.370 W/m^2 'dir. Enerji olarak güneş radyasyonunun % 45'i görünür ışık bölgesinde, % 46'sı spektrumun kızılötesi bölgesinde, geri kalan yüzdesi de mor ötesinde bulunur. Güneş ışınlamının tamamı yer yüzeyine ulaşamaz, Dünya atmosferi tarafından % 30 kadarı geriye yansıtılır, güneş ışınlamının % 50'si atmosferi geçerek Dünya yüzeyine ulaşır. Güneşten gelen ışınlamının kalan % 20'si ise, atmosfer ve bulutlarda tutulur. Bu enerji sayesinde Dünya'nın sıcaklığı yükselir ve yeryüzünde yaşam mümkün olur. Okyanus dalgalanmalarına ve rüzgâr hareketlerine de bu ısınma neden olmaktadır. Dünya'ya gelen güneş ışınlamının tamamı, sonunda ısıya dönüşerek ve uzaya geri verilir (DEKTMK, Ziyaret Edilme Tarihi: 3.12.2017).

Güneş enerjisinden faydalanmak için yapılan çalışmalar özellikle 1970'lerden sonra hız kazanmıştır. Güneş enerjisi sistemleri gün geçtikçe teknolojik olarak ilerleme ve maliyet bakımından düşme göstermiştir ve güneş enerjisi temiz bir enerji kaynağı olarak kendini kabul ettirmiştir (DEKTMK, Ziyaret Edilme Tarihi: 3.12.2017).

2.1. Dünya’da Güneş Enerjisi Potansiyeli

Dünya yüzeyinden yaklaşık 160 km uzaklıkta atmosferin üst sınırında güneş ışınlarının gelişine dik bir yüzeye gelen ortalama güneş enerjisi yoğunluğu yani güneş sabiti yaklaşık 1.37 kW/m^2 ‘dir. Ekvatorun 35° kuzey ve güney enlemleri arasında yer alan kısım güneş enerjisinden en fazla yararlanan bölgedir. 1 yılda 2000-3500 saat güneş alır ve güneş potansiyeli $3,5\text{-}7 \text{ kWh/m}^2/\text{gün}$ arasında değişir. Bu bölge “Dünya Güneş Kuşağı” olarak isimlendirilir. Dünya üzerindeki ortalama yıllık güneş ışınlam miktarı kurak bölgelerde $2000\text{-}2500 \text{ kWh/m}^2$ ve daha üst enlemlerde ise $1000\text{-}1500 \text{ kWh/m}^2$ arasında değişmektedir. Dünyanın değişik bölgelerindeki güneş ışınlam miktarları ve bu güneş ışınlam miktarını etkileyen bileşenlerin etkileri aşağıda sırasıyla Çizelge 2.1 ve Çizelge 2.2’de gösterilmiştir (Aksungur, vd.,2013)

Çizelge 2.1. Değişik bölgelerdeki güneş ışınlam miktarı.


Bölge	kWh/m ²
Kuzey Avrupa	800
Orta Avrupa	1000
Akdeniz Bölgesi	1700
Ekvator	2200

Çizelge 2.2. Güneş ışınlam miktarını etkileyen bileşenler ve etkileri.

Bileşen	Etkileri
Güneş Çıktısı	11 yıllık güneş periyodu
Dünya-Güneş Mesafesi	Yıllık %3.5 değişim
Bulutlar	Baskın faktör görevi
Su Buharı	Seçici yutucu
Hava Kiriliği	Direkt ışınlamın %50 azaltılması
Orman Yangınları	Bölgesel etki
Volkanik Küller	Küresel yıllık etki
Konum	Güneşin konumu
Gün İçindeki Zaman ve Mevsim	Güneşin konumu

Aşağıda Şekil 2.1’de Dünya güneş enerji potansiyel atlası verilmiştir. Haritada dünyada güneş enerjisi potansiyelinin en yüksek olduğu yerler sırasıyla koyu ve açık kırmızı, koyu ve açık kahverengi tonlarıyla boyalı olarak gösterilmiştir. Afrika Kıtası,

Avustralya Kıtası, Arabistan Yarımadası, ABD'nin batı bölgesi ve Güney Amerika Kıtası'nın kuzey bölümleri en yüksek güneş ışıınımı değerlerine sahip bölgelerdir. Türkiye, Yunanistan, İtalya ve İspanya ise Avrupa'da güneş enerjisi bakımından en zengin potansiyele sahip ülkelerdir (Sarıkaya, Ziyaret Edilme Tarihi: 16.12.2017).



Şekil 2.1. Dünya güneş enerjisi potansiyel atlası (Sarıkaya, Ziyaret Edilme Tarihi: 16.12.2017).

2012 yılı sonu itibariyle en yüksek güneş enerjisi toplam kurulu güç kapasitesine sahip ülkeler aşağıdaki Çizelge 2.3'de sıralanmıştır.

Çizelge 2.3. 2012 yılı sonrası ülkelerin kurulu güçleri.

No	Ülke	Kurulu Güç
1	Almanya	32.411 MW
2	İtalya	16.361 MW
3	Çin	8.300 MW
4	Amerika	7.777 MW
5	Japonya	6.914 MW
6	İspanya	5.166 MW
7	Fransa	4.003 MW
8	Belçika	2.650 MW
9	Avustralya	2.412 MW
10	Çek Cumhuriyeti	2.072 MW
11	İngiltere	1.829 MW
12	Yunanistan	1.536 MW
13	Hindistan	1.205 MW
14	Güney Kore	1.064 MW
15	Bulgaristan	908 MW
16	Kanada	765 MW
17	Slovakya	523 MW
18	Avusturya	418 MW
19	İsviçre	416 MW
20	Danimarka	394 MW

2.2. Türkiye’de Güneş Enerjisi Potansiyeli

Türkiye mevcut coğrafi konumu sebebiyle güneş enerjisi potansiyeli açısından diğer ülkelerle kıyaslandığında oldukça avantajlı durumdadır. Devlet Meteoroloji İşleri Genel Müdürlüğü’nde (DMI) mevcut bulunan 1966-1982 yıllarında ölçülen güneşlenme süresi ve güneş ışınım şiddeti verileri kullanılarak EİE tarafından yapılan çalışma sonuçlarından Türkiye’nin ortalama yıllık toplam güneşlenme süresinin 2640 saat (günlük toplam 7,2 saat), ortalama toplam güneş ışınım şiddetinin 1311 kWh/m²-yıl (günlük toplam 3,6 kWh/m²) olduğu elde edilmiştir (Dolunay, 2010).

Aşağıda Şekil 2.2’de Türkiye güneş enerji potansiyel atlası verilmiştir (YEGM, 2017).



Şekil 2.2. Türkiye güneş enerji potansiyel atlası(YEGM, 2017).

Türkiye güneş enerjisi potansiyel haritasından görüldüğü üzere Türkiye'nin en fazla güneş enerjisi alan bölgeleri sırasıyla Güneydoğu Anadolu Bölgesi ve Akdeniz Bölgesidir. Hem ekvatora olan uzaklığı hem de nemli olmasından dolayı en az ısınım alan bölge Orta ve Doğu Karadeniz Bölgesidir. Atmosferdeki fazla su buharı, ısınımın perdelenmesine neden olmaktadır. Güney Ege, Batı Akdeniz ve Orta Anadolu Bölgeleri orta derecede ısınım alan bölgelerdir. Doğu Akdeniz ve Doğu Anadolu Bölgeleri de ısınım değerleri iyi olan bölgelerdendir. Güneydoğu Bölgesinin güneydoğu kesimi ise ısınım değerleri en iyi olan bölgemizdir. Sert ve soğuk iklime sahip bu yer kışın en fazla ısınım alan yerdir. Rakım yüksektir, havadaki su buharı, yağmur ve kar şeklindedir ve atmosfer daha berrak olduğu için ısınımın engellenmesi en az seviyededir (Aksungur, vd.,2013; Dolunay, 2010).


Ülkemizde yıllık ortalama toplam güneş ışınımının en küçük değerleri 1120 kWh/m²-yıl ile Karadeniz Bölgesi'nde ve en büyük değeri de 1460 kWh/m²-yıl ile Güneydoğu Anadolu Bölgesi'nde görülmektedir. Türkiye'nin güneş enerjisi potansiyelinin ve güneşlenme sürelerinin bölgelere göre dağılımını gösteren çizelge aşağıda Çizelge 2.4'de verilmiştir (Kılıç, 2015). Toplam güneş enerjisi potansiyeli ve güneşlenme süreleri büyükten küçüğe doğru sırasıyla Güneydoğu Anadolu Bölgesi,

Akdeniz Bölgesi, Doğu Anadolu Bölgesi, İç Anadolu Bölgesi, Ege Bölgesi, Marmara Bölgesi, Karadeniz Bölgesi'nde görülmektedir.

Çizelge 2.4. Bölgelere göre güneş enerjisi ve güneşlenme süresi.

BÖLGE	TOPLAM GÜNEŞ ENERJİSİ (kWh/m ² -yıl)	GÜNEŞLENME SÜRESİ(Saat/yıl)
G.DOĞU ANADOLU	1460	2993
AKDENİZ	1390	2956
DOĞU ANADOLU	1365	2664
İÇ ANADOLU	1314	2628
EGE	1304	2738
MARMARA	1168	2409
KARADENİZ	1120	1971

Aşağıda Şekil 2.3'de Türkiye'nin aylık bazda ortalama günlük global güneş radyasyon değerleri gösterilmektedir. Global ışıınım en yüksek değeri gerçekleştiği yıl içerisinde Haziran ayında gözlenmiştir. Türkiye'nin aylık bazda ortalama günlük ışıınım şiddetinin 4,18 kWh/m²-gün, yıllık ortalama toplam global ışıınım değerinin ise 1524,18 kWh/m²-yıl (4,18x365) olduğu görülmektedir. Tüm bu sonuçlar Türkiye'nin güneş enerjisi bakımından yüksek bir potansiyele sahip olduğunun göstergesidir (Sarıkaya, Ziyaret Edilme Tarihi: 16.12.2017).



Şekil 2.3. Türkiye global güneş radyasyon değerleri (kWh/m²-gün) (YEGM,2017).


Türkiye yıllık global güneş radyasyonu değerleri, üzerinde çalışılan 55 istasyondan elde edilen verilere göre şöyledir (MGM, 2017).

2011-2016 yılları arasında en fazla yıllık güneş radyasyonu ve yılı: 1636,3 kwsaat/m² 2013

2011-2016 yılları arasında en az yıllık güneş radyasyonu ve yılı: 1579,9 kwsaat/m² 2015


2011-2016 yılları arasında Türkiye ortalama güneş radyasyonu: 1598,1 kwsaat/m²

2011-2016 yılları arasında Türkiye’de global güneş radyasyonu değerlerini gösteren harita aşağıda Şekil 2.4’de verilmiştir.



Şekil 2.4. Türkiye yıllık toplam global güneş radyasyonu dağılımı (MGM, 2017).

Aşağıda Şekil 2.5’de Türkiye’nin aylık bazda ortalama güneşlenme süreleri saat olarak gösterilmiştir. En yüksek güneşlenme süresinin gözlemlendiği yıl Temmuz ayında gerçekleşmiştir. Türkiye’nin aylık bazda ortalama günlük güneşlenme süresinin 7,49 saat-gün, yıllık ortalama toplam güneşlenme süresinin ise 2736,89 saat-yıl (7,49x365) olduğu görülmektedir. Bu sonuçlar Türkiye’nin güneşlenme süresi bakımından yüksek potansiyele sahip bir ülke olduğunun göstergesidir (Sarıkaya, Ziyaret Edilme Tarihi: 16.12.2017).



Şekil 2.5. Türkiye güneşlenme süreleri(Saat) (YEGM,2017).

Türkiye'nin 2014 yılındaki kurulu gücü yaklaşık 40 MW iken 2015 yılında bu oran %519 artarak 249 MW'a ulaşmıştır ve 2016 yılında ise kurulu güç kapasitesi 830 MW seviyesine ulaşmıştır. Türkiye'de 2010 yılı öncesine kadar güneş enerjisi genellikle termal güneş sistemleri adıyla binaların çatılarında su ısıtma amacıyla kullanılırken, 2010 yılından itibaren güneş paneli sistemlerinin kullanımı yaygınlaşmış ve güneş enerjisinden elektrik enerjisi üretimindeki çalışmalar hız kazanmıştır. Ulusal Yenilenebilir Enerji Eylem Planı çerçevesinde 2023 yılı için ısıtma ve soğutma ihtiyacının minimum yüzde 15'inin yenilenebilir enerji kaynaklarından sağlanması amacı doğrultusunda güneş enerjisinin daha etkin, verimli, teknolojik ve yenilikçi bir biçimde kullanılması gerekmektedir. Bu sebeple Türkiye'nin coğrafi konumunun avantajlarını en iyi biçimde değerlendirmesi ve en kısa zamanda güneş enerjisi kullanımını yaygınlaştırması gerekmektedir (Karagöl, 2017).

Türkiye güneş potansiyeli bakımından son derece elverişli bir konumda bulunmaktadır fakat güneş enerjisinden faydalanma konusunda teknolojik ve finansal kısıtlar gibi birtakım zorluklarla karşı karşıya kalmaktadır. Enerji üretim ve kullanımında yerli üretimi artırmak ve dışa bağımlılığı azaltmak için farklı teşvik sistemleri geliştirilerek finansal şartlar iyileştirilmelidir. Teknolojik ve finansal zorlukların yanında bürokratik işlemlerden kaynaklı sıkıntılar da giderilerek sektörün

önü açılmalıdır. Diğer açıdan enerji üretimi konusunda kalifiye iş gücüne olan ihtiyacı gidermek adına çeşitli düzenlemeler ve eğitimler yapılmalıdır (Karagöl, 2017).



3. GÜNEŞ ENERJİSİ POTANSİYEL ANALİZİNDE KULLANILAN YÖNTEMLER

3.1. Güneş Verilerinin Elde Edilmesi

Bir bölgedeki aylık güneş ışınım değerlerini tahmin edilebilmek için ortalama rüzgâr hızı, ortalama hava basıncı, ortalama hava sıcaklığı, ortalama nispi nem, ortalama buhar basıncı ve ortalama güneşlenme süresi gibi meteorolojik verilerden yararlanılır. Bu meteorolojik verileri elde edebilmek için kullanılan sensörlerden aşağıda bahsedilmiştir.

3.1.1. Piranometre


Bu sensör yatay birim yüzeye düşen global ışınım miktarını saptamak için kullanılır (Kökey, 2013). Aşağıda Şekil 3.1’de örnek bir piranometre verilmiştir.



Şekil 3.1. Piranometre.

3.1.2. Güneşlenme süresi sensörü

Yatay yüzeye düşen radyasyonun 120W/m^2 ’nin üzerinde olduğu anların zaman cinsinden kayıt altına alınmasını sağlayan sensördür. Kuzey yarım kürede yapılan ölçümler için güneşlenme süresi sensörü kuzeye doğru dikey açı yapacak şekilde konumlandırılır, Güney yarım kürede yapılan ölçümler için güneye doğru konumlandırılmalıdır. Dikey eksen ile sensör arasındaki açı ölçüm noktasının coğrafi koordinatlarına göre değişiklik göstermektedir. Türkiye’nin sahip olduğu enlem kuşağı için bu değer yaklaşık 5 derecedir. Aşağıda Şekil 3.2’de güneşlenme süresi sensörünün montaj oryantasyon şeması gösterilmiştir (Kökey, 2013).



Şekil 3.2. Güneşlenme süresi montaj oryantasyonu şematığı.

3.1.3. Sıcaklık sensörü

Ortamdaki sıcaklığın kaydedilmesi sıcaklık sensörü sayesinde gerçekleştirilir. Sensörün ısınımdan etkilenmemesi için, özel olarak imal edilmiş olan plastik radyasyon kalkanı içerisine konumlandırılması gerekmektedir (Kökey, 2013).

3.1.4. Bağıl nem sensörü

Ortamdaki bağıl nem oranının ölçülmesini sağlayan sensördür. Bu sensör %0-%100 arasında çalışabilecek niteliktedir (Kökey, 2013).

3.1.5. Anemometre

Rüzgâr hızının ölçülmesini sağlayan, fincan kafes tipi rüzgâr hızı ölçüm sensörüdür. Proje sahasında kullanılan anemometreler uluslararası standartlarda imal edilmiş ve kalibrasyonu son 1 yıl içerisinde yenilenmiş olmalıdır. Anemometre bağlantı kolu doğu yönünde sabitlenmelidir (Kökey, 2013).

3.1.6. Rüzgâr yön ölçer

Proje sahasında esen rüzgâr yönünün saptanmasında kullanılan sensördür. Rüzgâr yön sensörü 0-360 derece arasını ölçebilir nitelikte olmalıdır. Yön ölçer bağlantı kolu batı yönünde sabitlenmeli, yön ölçer üzerindeki Kuzey işareti tam kuzey yönünü işaret edecek şekilde konumlandırılmalıdır (Kökey, 2013).

3.2. İstatistiksel Yöntemler

3.2.1. Zaman serileri analizi

Zaman serileri analizleri geçmişe ait düzenli aralıklarla gözlemlenen istatistiksel verileri kullanarak gelecek dönemdeki veriler için bir öngörü ve tahmin oluşturan istatistiksel yöntemlerdir. Zaman serileri, belli bir değişken için düzenli aralıklarla yapılan bir dizi gözlemdir (Karahan, 2011).

Zaman serilerinde bir analiz ve tahmin yöntemi olan Box-Jenkins tekniği; kesikli, doğrusal stokastik süreçlere dayanır. Box-Jenkins tahmin modelleri; otoregresif (AR), hareketli ortalama (MA), otoregresif- hareketli ortalama (ARMA) ve bütünlenen otoregresif-hareketli ortalama (ARIMA) modelleridir. $AR(p)$, $MA(q)$ ve bunların birleşimi olan $ARMA(p,q)$ modelleri durağan süreçlerde kullanılmaktadır, $ARIMA(p,d,q)$ modelleri ise durağan olmayan süreçler için kullanılmaktadır (Hamzaçebi ve Kutay, 2004).

3.2.1.1. AR(p) modelleri

Otoregresif modelde Y_t değeri, serinin p dönem geçmiş değerlerinin ağırlıklı toplamının ve rassal hata teriminin doğrusal fonksiyonudur. $AR(p)$ modelleri genel olarak aşağıdaki gibi gösterilir;

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \delta + a_t \quad (3.1)$$

Burada $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ geçmiş gözlem değerleri, $\phi_1, \phi_2, \dots, \phi_p$ geçmiş gözlem değerleri için katsayılar, δ bir sabit değer ve hata terimidir (Hamzaçebi ve Kutay, 2004).

AR süreci için bir örnek olarak,

Bir limonata satıcısı saatte on bardak limonata satıyorsa, eğer satıcı limonata sattığı yeri kapatmak istemiyor ve limonata bittiği için satmaktan vazgeçmek istemiyorsa, saat başına tükenen limonata yerine yeni limonata koyması gerekir. Böylece her saat on bardak limonata satılmış olsa da her zaman yerine yenisini doldurduğunda satıcı bir kaza geçirmediği sürece asla limonata satışında bir aksaklık olmaz.

Verilebilir. Bu durum bir otoregresif sürece örnektir (Hanedar, Ziyaret Edilme Tarihi:17.12.2017).

3.2.1.2. MA(q) modelleri

MA(q) modelinde Y_t değeri, serinin geriye doğru q dönem geçmiş hata terimlerinin ve ortalamasının doğrusal fonksiyonudur. MA(q) modelleri genel olarak aşağıdaki gibi gösterilir:

$$Y_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.2)$$

Burada $a_t, a_{t-1}, a_{t-2}, \dots, a_{t-q}$ hata terimlerini, $\theta_1, \theta_2, \dots, \theta_q$ hata terimleri ile ilgili katsayıları, μ sürecin ortalaması olan bir sabiti göstermektedir (Hamzaçebi ve Kutay, 2004).

Hareketli ortalama süreci için örnek olarak,

Yolda kalan kamyonları çekmekte uzmanlaşmış bir şirket olduğunu düşünürsek, her yolda kalan aracın çekilmesi bağımsız bir olay olacaktır. Şirket deneyimleri aracın bozulduğu yere ve araca sahip olan şirketin bir tamir şirketinin tamirhanesinin olduğu yere bağlı olarak, bir aracın çekilmesi ve onun tamirhaneye götürülmesi için iki günün gerekli olduğunu göstermiştir. Eğer şirketin yeterli çekicisi olmazsa araç sahipleri bu işi başkasına verecektir. Bir gündeki tamir edilmek için çekilmesi gerekli araç sayısı şirket sahibine gerekli olan çekici için bilgi vermektedir. İki gün ötesinde, bu günkü tercihler şirket sahibine gelecekte olanlar hakkında bir şey söylemez.

Verilebilir. Bu süreç bir hareketli ortalama sürecini anlatmaktadır (Hanedar, Ziyaret Edilme Tarihi:17.12.2017).

3.2.1.3. ARMA(p,q) modelleri

ARMA modelleri en genel durağan stokastik süreç modelleri olup, geçmiş gözlemlerin ve geçmiş hata terimlerinin doğrusal bir fonksiyondur. ARMA(p,q) modelleri genel olarak aşağıdaki gibi gösterilebilir:

$$Y_t = \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \delta + a_t + \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.3)$$

(3.3) numaralı eşitlikte, $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ geçmiş gözlem değerlerini, $\Phi_1, \Phi_2, \dots, \Phi_p$ geçmiş gözlem değerleri için katsayıları, δ bir sabit değeri, $a_t, a_{t-1}, a_{t-2}, \dots, a_{t-q}$ hata terimlerini ve $\theta_1, \theta_2, \dots, \theta_q$ hata terimleri ile ilgili katsayıları temsil etmektedir (Hamzaçebi ve Kutay, 2004).

AR ve MA için örnek olarak,

Ulusal park yakınında bir otel olduğunu düşünürsek, otel defterinde bazı rezervasyonlar mevcuttur. Yani, müşterilerin bazıları otelde bir günden daha fazla zaman geçirmekte ve ayrıca müşterilerden bazıları da ulusal parkta bir haftalık tatil yaparken aynı zamanda evlerine dönmeden önce gece kalmak için otele gelmektedirler. Belli bir günde meydana gelecek şok otelde sürekli kalan müşterileri artan birden fazla dönem bir şekilde etkileyecektir. Ancak bu şokun, ulusal parkta bir tatil yaptıktan sonra gece için otele kalmaya gelenler üstünde bir hafta sonra tek bir etkisi olacaktır. verilebilir (Hanedar, Ziyaret Edilme Tarihi:17.12.2017).

3.2.1.4. ARIMA(p,d,q) modelleri

Zaman serisinin durağan olduğu durumlarda, yani sürecin ortalamasının, varyansının ve kovaryansının zamana bağlı olarak değişmediği durumlarda ARMA(p,q) veya ARMA(p,q)'nın özel hali olan AR(p) veya MA(q) modellerinden uygun olanı kullanılabilir. Ancak gerçekte zaman serilerinin ortalama ve varyansında zamana bağlı olarak bir değişim olmaktadır. Bu durum durağan olmayan durum olarak adlandırılır. Bu tip zaman serileri durağan hale dönüştürüldüğünde yukarıda bahsedilen ARMA(p,q) modelleri tahmin için kullanılabilir. Zaman serisinin durağanlaştırılması ise fark almak suretiyle yapılır. Zaman serisinin doğrusal bir trendi var ise birinci fark serisi durağan olur. Eğer zaman serisinin eğrisel bir trendi var ise farkların tekrar farkı alınarak ikinci farklar serisi durağan olur. Bu durumda model, ARIMA(p,d,q) olarak ifade edilir. Burada “d” serinin durağanlaştırma (fark alma) parametresidir (Hamzaçebi ve Kutay, 2004).

3.2.2. Regresyon tekniği

Serbest değişkenlerin bağımlı değişkenler üzerindeki etki biçimi ve yönü, istatistik denklemlerle de belirtilebilmektedir.

Bir örnek üzerindeki $X_1, X_2, \dots$ serbest ve Y bağımlı değişken ölçülerine dayanarak Y ile $X_1, X_2, \dots$ Değişkenleri arasındaki,

$$Y = f(X_1, X_2, \dots) \quad (3.4)$$

fonksiyonel ilişkiyi kestirme işlemine regresyon analizi adı verilmektedir. Fonksiyonel ilişki sayesinde $X_1, X_2, \dots$ serbest değişkenleri ölçülerek, bu ölçüler yardımı ile

ölçülemeyen z değeri tahmin edilebilmektedir. Trendde zaman süresi önemlidir; regresyon ise belirli bir dönemde söz konusu Y ve X_1 gibi iki veya daha fazla değişken arasındaki ortalama ilişkiye denir.

Regresyon analizi için önce, belirli bir model halinde, fonksiyon biçimine karar verilmez. Bu model bir ya da çok sayıda serbest değişkenli, doğrusal ya da eğrisel, toplanabilir ya da toplanamaz şekilde olabilir. Fonksiyon biçiminin kararlaştırılmasında, grafik çiziminden yararlanılabilir.

Regresyon analizi ile bir değişkenin başka bir veya birkaç değişken karşısında gösterdiği farklı durumlar, sürekli bir fonksiyon halinde belirtilmektedir. Bu şekilde,

- İncelenen değişkenler arasında bulunduğu sanılan ilişkinin varlığı, yönü, biçimi ve standart hatası saptanmaktadır.

- Gözlenmesi ve ölçülmesi güç olan bir değişkenin belirli koşullardaki değeri, diğer değişkenler yardımıyla tahmin edilebilmektedir.

Regresyonun varlığı ve standart hatasının küçük görülmesi değişkenler arasında bir neden-sonuç ilişkisi olduğunu kanıtlayamaz. Aralarındaki ilişki, bir yönlü etkiden ya da karşılıklı etkileşimden gelebileceği gibi, ortak bir ya da birkaç neden yüzünden birlikte değişme ya da birbirini izleme hali olabilir. İlişkinin nedeni ayrıca düşünsel (akıl yürütme) yoldan da saptanmalıdır.

Değişkenler arasındaki ilişki ne kadar kuvvetli ise, regresyon denklemi ile yapılacak tahminlerin hatası o kadar küçülecek, ilişki zayıfladıkça tahminlerin hata payı büyüyecektir (Minaz, 2011).


3.3. Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin özelliklerinden olan, öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla geliştirilen bilgisayar sistemleridir (Karahan, 2011).

Yapay sinir ağları, özellikle günümüze kadar çözümü güç ve karmaşık olan ya da ekonomik olmayan çok farklı alanlardaki problemlerin çözümünde kullanılmış ve genellikle başarılı sonuçlar alınmıştır. Arıza analizi ve tespiti, tıp, savunma sanayi, haberleşme, üretim otomasyon ve kontrol, istatistik ve finans bu alanlardan bazılarıdır (Karahan, 2011).

Yapay sinir ağı, sayısal bir modelleme tekniğidir. Yapay sinir ağı anahtar bilgi kalıplarını öğrenebilen çok boyutlu bilgi alanlarıdır. Bir şekilde yapay sinir ağı, insan beynini ve öğrenme sürecini taklit etmektedir. Bu nedenle sistem hakkında karakteristik bilgiye ihtiyaç yoktur. Yapay sinir ağı bunun yerine önceden girilmiş veriler olan girdi ve çıktı parametreleri arasındaki ilişkiyi incelemektedir. Dolayısı ile yapay sinir ağı, bir veya daha fazla girdi ve çıktı arasındaki muhtemelen doğrusal olmayan ilişkinin hesaplanmasında kullanılmaktadır.

Yapay sinir ağı işlem süreci aşağıda Şekil 3.3’de gösterilmiştir. Görüldüğü gibi sisteme, geçmiş zamana ait verilerin girişi yapıldıktan sonra işlemci elemanlar (nöronlar) ve bağlantı elemanları (aksonlar) işlem sürecini çıkışa doğru sürdürmektedir (Karahana, 2011).



Şekil 3.3. Yapay sinir ağı işlem süreci.


Yukarıda gösterildiği gibi, yapay sinir ağı girdi katmanı, ara katman ve çıktı katmanlarından oluşmaktadır. Bu katmanları aşağıdaki gibi açıklamak mümkündür.

Girdi Katmanı: Girdi katmanı en az bir girdi elemanının bulunduğu bölümdür. Bu katmanda veriler herhangi bir işleme tabi tutulmadan giriş ile aynı değerde çıktılar üretirler.

Ara Katmanlar: Girdilerin belirli işlemlere tabi tutulduğu bölümdür. Seçilen ağ yapısına göre işlem katmanının, yapısı ve fonksiyonu da değişebilir. Ara katman, tek bir katmandan oluşabileceği gibi birden fazla katmandan da oluşabilir.

Çıktı Katmanı: Çıktı katmanı en az bir çıktıdan oluşur ve çıktı ağ yapısında bulunan fonksiyona bağlıdır. Bu katmanda işlemler gerçekleştirilir ve burada üretilen çıktılar dış dünyaya gönderilir (Karahana, 2011).

Yapay sinir ağları, sinir hücrelerinin birbirlerine çeşitli şekillerde bağlanmalarından oluşur. Hücre çıkışları, ağırlıklar üzerinden diğer hücrelere ya da kendisine giriş olarak bağlanabilir ve bağlantılarda gecikme birimi de kullanılabilir. Hücrelerin bağlantı şekillerine, öğrenme kurallarına ve aktivasyon fonksiyonlarına göre çeşitli modeller geliştirilmiştir. İçerisinde birçok nöron bulunduran yapay sinir ağları, belli mimariler ile tanımlanabilir. Bu mimarilerden en yaygın kullanılanlar, aşağıda Şekil 3.4’de gösterilmiştir.



Şekil 3.4. Yapay sinir ağları mimarileri.


Yapay sinir ağları, yapılarına göre, ileri beslemeli (feedforward), geri beslemeli (feedback) ve geri beslemeli geri yayılmalı ağlar (feed forward, back propagation networks) olmak üzere üç farklı yapıda incelenebilir (Karahana, 2011).

3.3.1. İleri beslemeli yapay sinir ağları

İleri beslemeli (feedforward) ağlarda, işlemci elemanlar genellikle katmanlara ayrılmışlardır. İşaretler, girdi katmanından çıktı katmanına tek yönlü bağlantılarla iletilir. İşlemci elemanlar, bir katmandan diğerine bağlantı kurarken, aynı katman içerisinde bağlantıları bulunmaz. İleri beslemeli ağlara örnek olarak, çok katmanlı algılayıcılar (MLP) ve sayısallaştırılmış öğrenme vektörü (LVQ) ağları verilebilir.

İleri beslemeli sinir ağı giriş katmanında veriler üzerinde herhangi bir işlem yapılmadan bir sonraki katmana gönderilir. Gizli katmandaki işlemci elemanı sayısı tamamen uygulanan problemlerin giriş sayısına bağlı olarak sistem tarafından veya tasarımcı tarafından belirlenebilir. Gizli katmandaki, ara katman sayısı ve ara katmanlardaki işlemci elemanı sayısı deneme yanılma yoluyla da bulunabilir.

Birden fazla girişi olan, bir gizli katmanı ve iki ara katmanı bulunan, iki adet çıkışa sahip ileri beslemeli çok katmanlı bir yapay sinir ağı modeli aşağıda Şekil 3.5’de gösterilmiştir (Karahan, 2011).



Şekil 3.5. İleri beslemeli çok katmanlı bir yapay sinir ağı modeli.

3.3.2. Geri beslemeli yapay sinir ağları


Geri beslemeli yapay sinir ağlarında, en az bir işlemci elemanın çıktısı, kendisine ya da diğer işlemci elemanlara girdi olarak verilmekte ve genellikle geri besleme, bir geciktirme elemanı (ara katman veya çıktı katmanındaki aktivasyon değerlerini, bir sonraki iterasyona girdi olarak taşımakla görevli eleman) üzerinden yapılmaktadır. Geri besleme, bir katmandaki işlemci elemanlar arasında olduğu gibi katmanlar arasındaki işlemci elemanlar arasında da olabilmektedir. Bu yapısı sayesinde

geri beslemeli yapay sinir ağıları, doğrusal olmayan dinamik bir davranış gösterirler. Bu sayede, geri beslemenin yapılış sekline göre farklı yapı ve davranışta geri beslemeli yapay sinir ağıları elde edilebilir. Geri beslemeli yapay sinir ağıları, karmaşık bir çalımsa düzeneğine sahip olmasına rağmen, dinamik hafızaları nedeniyle ön tahmin uygulamalarında başarılı sonuçlar verirler (Karahana, 2011).

3.3.3. Geri beslemeli geri yayılmalı sinir ağıları

Geri beslemeli geri yayılmalı ağılar (Feed Forward, Back Propagation Networks), sinir ağılarının çok popüler bir modelidir. Çok katmanlı geri beslemeli ağılarda, işlemci elemanlar katmanlar halinde (tabaka) inşa edilmiştir ve yalnızca bitişik katmanlardaki elemanlar birbirleriyle iletişim halindedir. Bu tip ağılarda bilgi yayılımı geriye doğru olmakta ve bir geri besleme düğüm noktası yoktur. Hatalar, ağı öğrenme sürecinde geriye doğru yayılarak öğrenilir ve çözüme kavuşturulur.

Aşağıda Şekil 3.6’da geri beslemeli, geri yayılmalı sinir ağı modelinin hataları geriye doğru yayarak öğrenmesi, yani hatalardan deneyim kazanarak uzmanlaşması süreci gösterilmiştir (Karahana, 2011).



Şekil 3.6. Geri beslemeli geri yayılmalı sinir ağı modeli

3.4. Markov Model

Markov analizinin esası 20. yüzyılın başlarında Brownian hareketi olarak bilinen kapalı bir kutu içindeki gaz moleküllerinin yapısını ve davranışlarını A.A. Markov'un matematiksel olarak betimleme denemesine dayanır. Markov sürecinin ilk doğru matematiksel yapısı N. Wiener tarafından 1923 yılında kuruldu. Markov süreçlerinin genel teorisi ise 1930 ve 1940 yıllarında A.N. Kolmogorov, W. Feller, W. Doeblin, P. Levy, L.J. Doob ve diğerlerince geliştirilmiştir (Karatepe, 2011).

Markov Süreçleri ileride ortaya çıkması olası durumların gerçekleşme olasılıklarının, geçmiş verilerden değil şu anki verilerden yararlanarak bulunduğu süreçlerdir. Bir durumdan diğerine geçiş, sistemin daha önceki durumlarına bağlı olmayıp yalnızca bir önceki duruma bağlıdır. Söz konusu bu özelliğe Markov özelliği denir (Karatepe, 2011).

Markov süreçlerinin bir alt başlığı olan Markov zincirleri ise ayrık zamanlı, durumlar arası geçişin sadece bulunulan duruma bağlı olarak tanımlandığı süreçlerdir. Buna göre Markov zincirleri model λ ile tanımlanabilir.

$$\lambda = \{S, A, \pi\}$$

S: N adet ayrık elemandan oluşan durum uzayı

A: $N \times N$ 'lik durumlar arası geçiş matrisi

π : N boyutlu başlangıç durum vektörü

Ayrıca N, modeldeki durumların sayısı, T, dizinin uzunluğu ve M, her durumdaki farklı gözlemlerin toplam sayısı olarak tanımlanabilir. Rastgele süreç için sınırlı veya sınırsız olabilecek şekilde durumlar tanımlanır. $Q = \{q_1, q_2, \dots, q_T\}$ durum dizisini anlatmaktadır. Bu durumların bir sonraki duruma geçiş için olasılığı $P(q_{t+1}|q_t)$ şeklinde tanımlanabilir. Bütün bu geçiş olasılıkları $N \times N$ olarak boyutlanan durum geçiş matrisinde (a_{ij}) gösterilebilir.

$$a_{ij} = \begin{pmatrix} a_{11} & \cdots & a_{1N} \\ \vdots & \ddots & \vdots \\ a_{N1} & \cdots & a_{NN} \end{pmatrix} = P(q_{t+1} = s_j | q_t = s_i) \quad (3.5)$$

Eğer $q_1, q_2, \dots, q_T$ Markov zinciri oluşturuyorsa ve q durumları içinde incelenecek durumlar i ve j olarak belirtilmişse geçiş olasılıkları,

$$p_{ij}(t) \triangleq P(q_{t+1} = j | q_t = i) = a_{ij} \quad (3.6)$$

şeklinde tanımlanır. Geçiş matrisi düşünüldüğünde tek bir satırdaki olasılıkların oluşturduğu vektöre de olasılık vektörü denilmektedir ($P = (P_1, P_2, \dots, P_N)$). Geçiş matrisini oluşturabilecek geçiş olasılıklarının iki önemli özelliği vardır:

$$\sum_{i=0}^N p_i = 1 \quad (3.7)$$

olmalıdır ve matristeki hiçbir olasılık değeri negatif olamaz.

Markov modelindeki olasılık değerlerini belirlemek için bazı terimlere ihtiyaç vardır. Bunlar:

$N_{ij} \rightarrow i$ durumundan j durumuna geçiş sayısı

$N_{i.} \rightarrow i$ durumundan başlayan geçişlerin sayısı

$N_{.j} \rightarrow j$ durumda biten geçişlerin sayısı

$N \rightarrow$ geçişlerin toplam sayısı

$M_i \rightarrow$ başlangıç durumu olarak i durumu

$$M = \sum_{i \in q} M_i \quad (3.8)$$

$$N_{i.} = \sum_j N_{ij} \quad (3.9)$$

$$N_{.j} = \sum_i N_{ij} \quad (3.10)$$

$$N = \sum_{i \in q} N_{i.} = \sum_{i \in q} N_{.j} \quad (3.11)$$

Markov modellerini kullanarak kısa bir uygulama yapılabilir. Bunun için Türkiye Süper Lig'i 2016-2017 sezonundaki herhangi bir maç için istatistiksel altyapı oluşturmak adına Çizelge 3.1'de bazı takımların gol durumları Markov modeli kullanarak incelenmiştir. Örneğin, Beşiktaş Futbol Takımı'nın 29.haftada yapacağı maç öncesi yaptığı maçlardan hareketle oluşturulmuş gol istatistiği aşağıdaki Çizelge 3.2'de verildiği gibidir.

Çizelge 3.1. Takımın belirtilen durumlarda attığı gol sayısı.

S_1	S_2	S_3	S_4	S_5
0 gol	1 gol	2 gol	3 gol	4+ gol

Çizelge 3.2. 28 haftada takımın durumlarla karşılaşma sıklığı.

Takım	0	1	2	3	4 ⁺	Top.
Beşiktaş	7	9	8	0	4	28

28 haftada takımın yaptığı maçların dizisi şu şekilde değişmektedir;

104⁺4⁺12020212221014⁺11022104⁺01

Burada π_2 , ikinci durumun π_4 , dördüncü durumun başlangıç durumu olmasını anlatmaktadır. Başlangıç durumu bu dizi için 1'dir. Yani $M_1=1$ ve $\pi_2=1$ 'dir. Eğer başka diziler de eklenmiş olsaydı, bir başka deyişle bu örnek için sadece lig maçları değil, kupa maçları ve Avrupa kupaları maçları da dâhil edilseydi;

Kupa maçlarının dizisi: 34⁺303323

Avrupa Kupası Maçlarının dizisi: 1012112224⁺1334

Bu durumda bu örnek için lig maçları dizisi, kupa maçları dizisi ve Avrupa maçları dizisi şeklinde 3 dizi olduğunda $M_1=2$, $M_3=1$ dir. 3 diziden Avrupa kupası maçları ve lig maçları için ikinci durum başlangıç dizisidir bu yüzden $2/3$ olasılıkla $\pi_2= 0.66$ dir. Kupa maçları dizisi için ise dördüncü durum başlangıç durumudur bu yüzden $1/3$ olasılıkla $\pi_4= 0.33$ olur.

Buna göre;

Çizelge 3.3. Durumlar arası geçiş tablosu (goller arası geçişler).

	0	1	2	3	4 ⁺	$N_{i.}$
0	0	2	3	0	2	7
1	4	2	2	0	1	9
2	2	3	3	0	0	8
3	0	0	0	0	0	0
4 ⁺	1	2	0	0	1	4
$N_{.j}$	7	9	8	0	4	$N=28$

gibi bir tablo oluşturulabilir. Markov modeline göre bu tablodan hareketle durum geçiş matrisi (a_{ij}) oluşturulabilir;

$$a_{ij} = \begin{pmatrix} a_{11} & a_{12} & a_{13} & a_{14} & a_{15} \\ a_{21} & a_{22} & a_{23} & a_{24} & a_{25} \\ a_{31} & a_{32} & a_{33} & a_{34} & a_{35} \\ a_{41} & a_{42} & a_{43} & a_{44} & a_{45} \\ a_{15} & a_{25} & a_{35} & a_{45} & a_{55} \end{pmatrix} = \begin{pmatrix} 0/7 & 2/7 & 3/7 & 0/7 & 2/7 \\ 4/9 & 2/9 & 2/9 & 0/9 & 1/9 \\ 2/8 & 3/8 & 3/8 & 0/8 & 0/8 \\ 0 & 0 & 0 & 0 & 0 \\ 1/4 & 2/4 & 0/4 & 0/4 & 1/4 \end{pmatrix} \quad (3.12)$$

Eşitlik (3.12) 'deki a_{ij} geçiş matrisinde de görüldüğü gibi her bir satırdaki olasılıkların oluşturduğu olasılık vektörleri $P = (P_1, P_2, \dots, P_N) = 1$ olmaktadır ve matristeki hiçbir olasılık değeri negatif olmamaktadır.


3.5. Saklı Markov Model

Saklı Markov model, istatistiksel veriyi dikkate alarak öğrenme ve tahmin yapmaya çalışan yöntemdir. Markov modelde belirli olan durumlar saklı Markov modelde belirsizdir ancak durumların tetiklediği gözlemler mevcuttur. Başka bir ifadeyle, saklı Markov süreçleri adından da anlaşılacağı üzere durumların gizli olduğu ancak durumların arasındaki geçişler esnasında ortaya çıkan gözlemlerin dizisinin bilindiği stokastik süreçlerdir. SMM ler üretici veya yorumlayıcı olarak düşünülebilirler. Saklı Markov model ile ilgili detaylı bilgi 4. bölümde anlatılacaktır.

4. SAKLI MARKOV MODEL

Saklı Markov süreçler ve bunların uzantıları, sinyal işleme ve ses tanıma gibi uygulamalar için oldukça kullanışlıdır. Saklı Markov modeller doğal bir süreci modellemenin bir yoludur. Çok hızlı çalışabilmeleri ve en çok karşılaşılan saklı Markov süreçlerindeki problemlerin çözülmesi için çok kullanışlı algoritmaların varlığı ses tanıma gibi gerçek zamanlı çalışan uygulamalarda bile başarılı sonuçlar elde edilmesini sağlamaktadır.

Aşağıda Şekil 4.1’de Saklı Markov modelde X ve Y süreçleri arasındaki ilişkinin oluşturduğu yapı gösterilmektedir.



Şekil 4.1. Saklı Markov model yapısı.

Şekil 4.2’de basit bir Saklı Markov modeli gösterilmiştir. Şekle göre Y_1, Y_2, Y_3 farklı gözlem kümesini oluşturur. Buna mukabil X_1, X_2 ise gizli durumlar kümesini oluşturur. Başlangıçta R durumunda bulunan model π_1 olasılıkla X_1 durumuna, π_2 olasılıkla X_2 durumuna geçiş yapacaktır. Örnek modelde iki ihtimal bulunduğundan $\pi_1 + \pi_2 = 1$ olacaktır. Genelleyecek olursak, modelde N adet gizli durumumuz olursa

$$\pi_1 + \pi_2, \dots, \pi_N = 1 \quad (4.1)$$


Saklı Markov modelimiz X_i gizli durumunda iken M farklı gözlem üretebilir. Örneğimizde X_1 üç farklı gözlem üretebilmektedir. X_1 durumunda iken Y_2 gözlemini üretme olasılığı b_{12} olarak gösterilmiştir. Dolayısıyla

$$b_{i1} + b_{i2}, \dots, b_{iM} = 1 \quad (4.2)$$

olacaktır.


Şekil 4.2’de bahsettiğimiz modele göre bir Saklı Markov modeli beş elemandan oluşmaktadır. Birinci bileşen N adet gizli durumdur ve Şekil 4.2’de X_i ile gösterilmiştir.

İkinci olarak model, M farklı olası gözlem içermektedir ve Y_j ile gösterilmiştir. Üçüncü olarak bir durumdan diğerine geçiş olasılıklarını ifade eden A geçiş kümesidir ve her biri a_{ij} ile gösterilmiştir. Dördüncü olarak X_i durumunun Y_j gözlemini üretmesini ifade eden b_{ij} olasılık değerlerini içeren B kümesidir. Son olarak modelin başlangıçta hangi durumla başlayacağına ait olasılık olan π_i değeridir. Bu model N, M , isimli iki model parametresi, gözlem sembolleri, A, B, π olmak üzere üç olasılık değer kümesinden oluşur (Özcan, 2015).



Şekil 4.2. Saklı Markov model örneği.

Saklı Markov süreçlerin daha iyi açıklanması Şekil 4,3'de daha detaylı bir SMM tasarlanmıştır. Tasarlanan SMM cümle üretici olarak kullanılmaktadır (Hocaoğlu, 2008).



Şekil 4.3. Cümle üreten bir SMM.

Şekil 4.3’de s_3 durumunda “Bir kilo” ifadesinin üretilbileceği iki durum söz konusudur. Modelde, s_1 durumundan başlayarak ‘Ahmet manavdan bir’ kelimelerinin üretildiğini düşünelim. Bu kelimelerin üretildiği biliniyorsa bu, sistemin başlangıçta s_1 durumunda daha sonra s_2 durumunda ve sonra da s_3 durumunda olduğunun bilindiği anlamına gelir. Ancak bu durumdan sonra sistemin s_4 durumunda mı yoksa s_5 durumunda mı olacağını verilen olasılıklar birbirine eşit olduğu için henüz bilinmemektedir. Bu durum ancak bir sonraki kelime üretildikten sonra kesinleşecektir. Örneğin, eğer bir sonraki kelime ‘Kıyma’ ise artık sistemin o anki durumunun s_5 olduğu söylenebilir ve sistem bu duruma ancak s_4 durumundan geçmiş olabilir. Böylece sistemin bir önceki durumunun s_3 olduğu kesinlik kazanır. Şekil 4.3’deki SMM örnek olarak aşağıdaki cümleleri üretebilir;

- C1 : Ahmet kasaptan bir kilo tavuk istedi.
- C2 : Ayşe manavdan bir kilo armut istedi.
- C3 : Mehmet marketten bir kilo bulgur istedi.

Durumlar arası geçişlerin birbirlerinden bağımsız oldukları kabul edilirse (Bu durum yukarıda verilen örnekteki cümle üreticinin ‘Ahmet kasaptan bir kilo armut istedi’ cümlesini de üretebildiği anlamına gelmektedir.) bu durumda SMM den bu cümlelerin üretilme olasılıkları önceki olasılıklar çarpılarak hesaplanabilir. Örnek olarak, C3 ün sistemden üretilme olasılığı;

$$P(C3) = 0.2 \times 0.3 \times 0.5 \times 0.2 \times 0.5 = 0.003 \quad (4.3)$$

şeklinde hesaplanabilir (Hocaoğlu, 2008).

Saklı Markov sürecinin uygulanması iki aşamadan oluşur. İlk aşamada sistem sunulan verilere göre model kurulur ve model parametreleri bulunur. Bu aşamaya eğitim aşaması da denilir. İkinci aşamada ise kurulan model parametreleri ve gözlemler modele sunulur modelden olasılığı en yüksek durum vektörü elde edilir (Hocaoğlu, 2008).

Eğitim aşaması süresince temel alınacak referans modelin parametreleri tahmin edilir. Bu modelde tahmin edilecek üç parametre vardır. Bunlardan biri, t anında i .

durumda ve $t+1$ anında j . durumda olma geçiş olasılıklarını gösteren a_{ij} elemanlarını içeren durum geçiş olasılığı matrisi, A 'dır. $O = \{o_1, o_2, \dots, o_T\}$ olan bir gözlem dizisi tanımlandığı zaman bu vektör dizisinin her bir elemanı konuşma uygulamalarında konuşmacı tanıma sistemlerinde kullanılan öznitelik vektörlerini gösterir. Güneş verilerinin modellenmesi sırasında ise gözlem dizisi, saatlik ölçülüp kaydedilmiş olan sıcaklık verileri olarak seçilmiştir. $B = [b_j(o_t)]$ gözlem sembol olasılık dağılımı matrisidir. $b_j(o_t)$, o_t vektörünün t anında j . durumda gözlemlenmesi olasılığını gösterir. $\pi = \{\pi_i\}$ vektörü, başlangıçta i . durumda olma olasılığını belirten başlangıç durum dağılımını gösterir (Hocaoğlu, 2008).

Bir SMM oluşturulduktan sonra üç farklı problemin çözümü ile ilgilenilebilir. Birinci problem, verilen gözlem dizisi O ve λ modeli için gözlemin model tarafından üretilme olasılığının $P(O|\lambda)$ etkin olarak nasıl hesaplanacağıdır. İkinci problem ise verilen gözlem dizisi O ve λ modeli için en yüksek olasılıklı q durum dizisinin nasıl bulunabileceğidir. Üçüncü problem, $P(O|\lambda)$ 'yı maksimum yapmak için model parametrelerinin nasıl değiştirileceği ile ilgilidir (Edizkan, 1999).

4.1. Değerlendirme Problemi

Model ve gözlem sırası biliniyorsa bu gözlem dizisinin görülme olasılığının etkin bir biçimde nasıl hesaplanabileceğidir. Değerlendirme problemi bir modelle gözlemlerin ne kadar uyduğunu gösteren bir değer olarak görülebilir. Eğer çeşitli modeller arasında en iyi olan seçilmeye çalışılıyorsa, değerlendirme probleminin çözümü gözlemle uyuşan en iyi modeli verecektir (Edizkan, 1999).

$$\begin{aligned}
 P(O|\pi, A, B) &= \sum_q P(O, q | \lambda) \\
 &= \sum_q \pi_{q_0} \prod_{t=1}^T a_{q_{t-1}q_t} b_{q_t}(O_t)
 \end{aligned} \tag{4.4}$$

Eşitlik (4.4) kullanılarak $P(O|\lambda)$ doğrudan hesaplanabilir. $P(O|\lambda)$ 'yı hesaplamak için gerekli işlem sayısı $2T \cdot N^T$ mertebesinde. $P(O|\lambda)$ 'yı hesaplamak için tam olarak $(2T - 1) \cdot N^T$ çarpma ve $(N^T - 1)$ toplama gereklidir (Edizkan, 1999).

4.2. Tahmin Problemi

Model ve gözlem sırası biliniyorsa bazı kriterlere göre uygun durum dizisinin nasıl seçilebileceğidir. Verilen gözlem dizisi için tahmin probleminin çözümü bu diziyi en yüksek olasılıkla üretecek doğru model parametrelerini bulmamızı sağlar. Model parametrelerini elde etmek için kullanılan gözlem dizisi ise eğitim dizisi olarak adlandırılır (Edizkan, 1999).

Tahmin problemi için gözlem dizisinin model tarafından üretilme olasılığını en yüksek yapan bir analitik çözüm yoktur. Bununla beraber $P(O|\lambda)$ olasılığını yerel en büyükleyen Baum-Welch yöntemi veya gradient tekniği gibi özyineleme işlemleri kullanılarak $\lambda = (\pi, A, B)$ model parametreleri seçilebilir (Edizkan, 1999).

Tahmin probleminin çözümünde en büyük olabilir (ML) yöntemi kullanılır. Saklı Markov modelde gözlemlerin kesikli veya sürekli olması durumlarında model parametrelerini tekrar tahmin etmek için formüller türetilmiştir. Bu formüller Eşitlik (4.5) de verilen Baum'un yardımcı işlevinin tahmin edilen model $\bar{\lambda}$ üzerinden en büyüklenmesi ile elde edilir (Edizkan, 1999).

$$Q(\lambda, \bar{\lambda}) = \sum_q P(O, q|\lambda) \log P(O, q|\bar{\lambda}) \quad (4.5)$$

Baum ve meslektaşları, $Q(\lambda, \bar{\lambda})$ ifadesinin en büyüklenmesinin gözlemlerin model tarafından üretilme olasılığını artırdığını ispat etmişlerdir (Edizkan, 1999).

$$\max_{\bar{\lambda}} [Q(\lambda, \bar{\lambda})] = \sum_q P(O|\bar{\lambda}) \geq P(O|\lambda) \quad (4.6)$$

4.3. Model Yapısını Öğrenme Problemi

Gözlem dizisini üreten en yüksek olasılıklı durum dizisinin ne olduğu ile ilgilenir. Saklı Markov modelde tanımlanan olasılık ölçüsü durum dizisini açık olarak içermemesine rağmen, bir çok uygulamada en yüksek olasılıklı durum dizisinin ne olduğunun bilinmesi çeşitli nedenlerden dolayı önemlidir. Örneğin, bir kelime içindeki sesleri göstermek için bir kelime modelinin durumları kullanılırsa, kelime içindeki sesler ile ses bölütleri arasında nasıl bir benzerlik olduğu bilinmek istenebilir. Belli ses bölütlerinin devam süreleri ses tanıma amaçları için faydalı bir bilgi sağlar. Ayrıca en

yüksek olasılıklı durum dizilerine bakılarak model topolojisinde değişiklik yapılabilir (Edizkan, 1999).

Bu problemin çözümünde, mümkün olan q dizileri üzerinden $P(q | O, \lambda)$ olasılığı en büyük yapılmaya çalışılır. $P(q | O, \lambda)$ nın en büyük yapılması için Viterbi gibi dinamik programlama yöntemleri kullanılabilir. $P(q | O, \lambda)$ nin en büyük yapılması $P(q, O | \lambda)$ en büyük yapılmasına denktir, çünkü eniyileme işlemi $P(O | \lambda)$ ifadesini içermektedir (Edizkan, 1999).

$$\begin{aligned} P(q_1 q_2, \dots, q_t, O_1, O_2, \dots, O_t | \lambda) \\ = P(q_1 q_2, \dots, q_{t-1}, O_1, O_2, \dots, O_{t-1} | \lambda) \cdot \alpha_{q_{t-1} q_t} b_t(O_t) \end{aligned} \quad (4.7)$$

İlk t gözlemi göz önüne alan ve S_i durumunda sonlanan tek bir yol boyunca en yüksek olasılığı $\delta_t(i)$ olarak tanımlayalım.

$$\delta_t(i) \triangleq \max_{q_1, q_2, \dots, q_{t-1}} P(q_1 q_2, \dots, q_t = S_i, O_1, O_2, \dots, O_t | \lambda) \quad (4.8)$$

Bu ifadeden $\delta_{t+1}(i)$ 'yi Eşitlik (4.9)'daki gibi yazabiliriz (Edizkan, 1999).

$$\delta_{t+1}(i) \triangleq \left[\max_i \delta_t(i) \alpha_{ij} \right] b_j(O_{t+1}) \quad (4.9)$$

4.4. Viterbi Algoritması

$t-1$ tane bilinen (veya gözlemlenen) gözlem dizisi $w^{1,t-1}$ ile gösterilsin. En olası t durum geçiş dizisi de $\sigma(t)$ ile gösterilecek olursa $\sigma(t)$, denklem (4.10) kullanılarak hesaplanabilir.


$$\sigma(t) = \operatorname{argmax} P(s^{1,t} / w^{1,t-1}) \quad (4.10)$$

Viterbi algoritmasının amacı olasılığı en yüksek durum dizisini bulmaktır. Bunu yaparken $P(s^{1,t} / w^{1,t-1})$ olasılığını maksimize eder. Algoritma, olası her durum arası geçiş sırasında meydana gelen gözlem durumunun maksimum olasılığını hesaplamak suretiyle çalışır. En son adımda maksimum olasılıklı durum seçilir ve en olası durum vektörünün sonuna eklenir. Böylece meydana gelebilecek olan durum geçişleri, bir önceki geçiş dizisinin sonuna eklene eklene algoritma gözlem dizisinin son elemanı olan gözlem görülünceye kadar devam eder.

5. BİLECİK BÖLGESİNİN GÜNEŞ IŞINIM ŞİDDETİ TAHMİNİNDE SAKLI MARKOV MODELİNİN KULLANILABİLİRLİĞİNİN ANALİZİ

Saklı Markov model ile güneş ışıınım miktarını tahmin etmek için Bilecik ili analiz bölgesi olarak seçilmiştir. Bölgenin güneş ışıınım miktarları için 01.01.2017-31.10.2017 tarihleri aralığına ait saatlik veriler kullanılacaktır.

Ölçülen güneş ışıınım değerleri çalışma sonunda Saklı Markov modelle elde edilen değerlerle kıyaslama yapabilmek için gereklidir. Bizim asıl ölçümlerine ihtiyacımız olan kriterler bölgenin sıcaklık kriterleridir. Çünkü Bilecik ilinin saatlik sıcaklık değerleri Saklı Markov modelinin gizli sürecini oluşturmaktadır. Bu ölçümlerden hareketle bölgeye özgü güneş ışıınım şiddetleri Saklı Markov modeli ile dolaylı olarak elde edilmiş olacaktır. Saklı Markov modelin doğruluğu ise elde edilen güneş ışıınım değerleri başlangıçta ölçülen gerçek değerlerle kıyaslanarak belirlenmektedir. Aşağıda Yenilenebilir Enerji Genel Müdürlüğü'nden alınmış olan Bilecik ili güneş enerjisi potansiyel atlası Şekil 5.1'de ve Meteoroloji Genel Müdürlüğü'nden alınmış olan Bilecik ili 1939-2016 yılları arasında gerçekleşmiş ortalama sıcaklık değerleri Çizelge 5.1'de verilmiştir.




Şekil 5.1. Bilecik ili güneş enerjisi potansiyel atlası (YEGM,2017).


Çizelge 5.1. Bilecik ili 1939-2016 yılları arası gerçekleşmiş ortalama sıcaklık değerleri(MGM, 2017).

BİLECİK	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık	Yıllık
Son İklim Periyoduna(1939-2016)													
Ortalama Sıcaklık (°C)	2.5	3.7	6.4	11.5	16.2	19.9	22.1	22.0	18.3	13.8	9.1	4.5	2.5
Ortalama En Yüksek Sıcaklık (°C)	5.9	7.7	11.4	17.0	21.9	25.8	28.3	28.6	24.8	19.4	13.6	8.0	5.9
Ortalama En Düşük Sıcaklık (°C)	-0.4	0.3	2.4	6.7	10.8	14.1	16.2	16.3	13.1	9.5	5.6	1.8	-0.4
Ortalama Güneşlenme Süresi (saat)	3.2	3.6	4.5	6.1	8.0	9.4	10.3	10.0	8.2	5.5	4.2	3.1	3.2
Ortalama Yağışlı Gün Sayısı	13.8	12.7	12.6	10.5	10.1	7.4	3.9	3.3	5.0	8.4	9.7	13.1	13.8
Aylık Toplam Yağış Miktarı Ort.(mm)	50.2	42.5	47.2	41.8	47.2	38.9	18.2	11.9	21.7	40.4	37.4	55.2	50.2
Son İklim Periyoduna(1939-2016)													
En Yüksek Sıcaklık (°C)	20.4	24.6	30.2	33.3	35.8	38.2	41.0	40.6	38.4	34.3	27.4	25.0	20.4
En Düşük Sıcaklık (°C)	-16.0	-14.3	-11.6	-6.0	1.0	5.0	7.7	8.2	3.2	-0.8	-9.2	-14.5	-16.0


Bilecik bölgesine ait hava sıcaklığı ve güneş ışıınımı verileri EPW uzantılı dosya olarak elde edilmiştir (Climate Onebuilding, Ziyaret Edilme Tarihi: 05.12.2017). Elde edilen bu veriler SAM(System Advisor model) 2017 programına yüklenerek Bilecik bölgesi hava sıcaklığı ve güneş ışıınımı grafikleri oluşturulmuştur. SAM programından elde edilen Bilecik bölgesine ait kuru termometre sıcaklık değerleri grafiği Şekil 5.2’de, yaş termometre sıcaklığı değerleri grafiği Şekil 5.3’de, saatlik yatay toplam ışıınım değerleri grafiği Şekil 5.4’de, saatlik doğrudan ışıınım değerleri grafiği Şekil 5.5’de, saatlik yatay difüzyon ışıınımı değerleri grafiği Şekil 5.6’da olacak şekilde verilmiştir.




Şekil 5.2. Bilecik bölgesine ait saatlik kuru termometre sıcaklık (°C) değerleri.




Şekil 5.3. Bilecik bölgesine ait saatlik yaş termometre sıcaklık (°C) değerleri.



Şekil 5.4. Bilecik bölgesine ait saatlik yatay toplam ışıınım (W/m^2) değerleri.




Şekil 5.5. Bilecik bölgesine ait saatlik doğrudan ışıınım (W/m^2) değerleri.




Şekil 5.6. Bilecik bölgesine ait saatlik yatay difüzyon ışıma (W/m^2) değerleri.

Bilecik Meteoroloji Genel Müdürlüğü'nden aldığımız 01.01.2017-31.10.2017 tarihleri aralığına ait saatlik sıcaklık ve saatlik güneş ışıma şiddeti verileri kullanılarak Şekil 5.7.'deki sıcaklık/saat grafiği ve Şekil.5.8'deki güneş ışıma şiddeti/saat grafikleri elde edilmiştir.




Şekil 5.7. Bilecik bölgesi 2017 yılı saatlik sıcaklık değerleri($^{\circ}\text{C}$) (Bilecik, MGM, Ziyaret Edilme Tarihi:17.12.2017).




Şekil 5.8. Bilecik bölgesi saatlik güneş ışınlam şiddeti değeri(cal/cm^2) (Bilecik, MGM, Ziyaret Edilme Tarihi:17.12.2017).

Bilecik bölgesi için 01.01.2017-31.10.2017 tarihleri aralığına ait saatlik sıcaklık verileri ile Şekil 5.9'daki histogram ve Şekil 5.10'daki olasılık yoğunluk fonksiyonu(pdf) grafikleri elde edilmiştir.



Şekil 5.9. Bilecik bölgesi 2017 verileri histogram grafiği.



Şekil 5.10. Bilecik bölgesi 2017 verileri olasılık yoğunluk fonksiyonu grafiği.

01.01.2017-31.10.2017 tarihleri aralığında ölçülen toplam saatlik sıcaklık verisi 7296 adettir. Gözlenen en düşük sıcaklık değeri $-10,5^{\circ}\text{C}$, en yüksek sıcaklık değeri 37°C ve ortalama sıcaklık değeri ise $13,7597^{\circ}\text{C}$ 'dir(Çizelge 5.2).

Çizelge 5.2. Ölçülen verilerin temel istatistikleri.

Ortalama	13,7597
Minimum	-10,5
Maksimum	37
Standart Sapma	8,8622
Medyan	14,4


Saklı Markov model dört simge ile tanımlanır $\{S_1, S, W, E\}$. S_1 başlangıç gözlemi, S durumlar kümesi, W gözlemler kümesi, E geçişler kümesini ifade etmektedir. Bu çalışmada;

S : Güneş ışınlam şiddeti,

W : Gözlenen sıcaklık,

E : Gözlemlerin meydana gelme olasılığı olacaktır.

Bu çalışma için ortaya çıkarılacak modelde durum parametrelerinin sıcaklık parametresiyle ilişkili olduğu düşünülerek modellemede sıcaklık parametresi kullanılmıştır. Aşağıda Şekil 5.11’de verilen SMM örneği n gözlem, m durum için oluşturulmuştur.



Şekil 5.11. Güneş verilerinin SMM durumlarına dönüştürülmesi.

Gözlemlerin yayılma olasılığı göz önünde bulunursa modelin i durumundan j durumuna geçişte O_n gözleminin oluşma olasılığı aşağıda olduğu gibi formülize edilebilir;

$$P(S_i \xrightarrow{O_n} S_j) \approx \frac{n_{oi}}{n_{on} \cdot P_{ij}} \quad (5.1)$$

Burada;

O_i : i . gözlemler arasındaki olasılık değeridir. Bu çalışmada i . saatteki ölçülmüş hava sıcaklığı değeridir. n_{oi} : i . gözlemin oluşum sayısı, n_{on} : i durumundan j durumuna geçerken tüm gözlemlerin görülme sayısıdır. Sonuç olarak $n_{on} \cdot p_{ij}$ değeri i durumundan j durumuna geçen toplam beklenen geçiş sayısına tekabül eder. Bu yüzden i durumundan gelen başlangıç noktalarının sayısı söz konusu toplam beklenen geçiş sayısına orantılı olarak i durumundan j durumuna geçiş durumunda yayılmış gözlem sonuçlarının oluşum olasılığını verir. Bu yaklaşım ile i durumundan j durumuna geçiş halinde mevcut gözlemler olası kombinasyonlar ile hesaplanmaktadır. Durum değerlerinin en muhtemel kümesini bulmak için gözlemler bir dizi halinde kaydedilerek elde edilebilir.

elde etmekle olacaktır. Bu tahmin için çeşitli programlama yöntemleri bulunur. En iyi bilinen ve yaygın olarak kullanılan yöntem ise viterbi algoritmasıdır. Viterbi algoritması aşağıdaki şekilde ifade edilir;


$$\sigma(t) = \underset{s^t}{\operatorname{argmax}} P(s^t / w^{t-1}) \quad (5.2)$$

Bu formülde w gözlemi ifade eder. Buna karşılık $w^{(t-1)}$ gözlem dizisinin $(t-1)$ anına karşılık değerini verir. Bu denklem ile büyük olasılık taşıyan dizinin ifade edilmesi kısa bir açıklama ve örnek ile sunmuş olan viterbi algoritması ile mümkündür.

Viterbi algoritması maksimum $P(s^t / w^{t-1})$ olasılık geçiş değerlerinin araştırılması ile en muhtemel dizi durumunu oluşturmayı amaçlar. Algoritma her geçiş adımının izlenmesiyle oluşan durumun maksimum olasılıkla hesaplanması mantığına dayanır. Son aşamada durum maksimum olasılık oluşturacak şekilde seçilir ve muhtemel geçiş dizisinin geri takip ile korunması gerçekleşir. En muhtemel dizinin bulunması durumunu daha iyi ifade edebilmek için bu algoritmayı bir örnekle oluşturalım. İlk durumda Şekil 5.12 de gösterildiği gibi iki farklı gözlem sonucuna sahip iki farklı durum sistemi ele alalım. Örneğin geçiş olasılıklarının şekildeki gibi hesaplandığını varsayalım. Burada X değerini başlangıç durumu ve dizi gözlem sonucu olarak '1110' değerini (Çizelge 5.4) geçiş durumu halinde varsayım olarak ele alalım.

Çizelge 5.4. Viterbi algoritması için örnek tablo.

	Durumlar	Başlangıç	1	11	111	1110
X	dizi	X	XX	XXX	XXXX	XYYYX
	olasılık	1.0	0.2	0.04	0.008	0.005
Y	dizi	Y	XY	XYY	XYYY	XYYYY
	olasılık	0.0	0.1	0.05	0.025	0.005



Şekil 5.12. Viterbi algoritmasını göstermek için basit bir SMM örneği.

Amacımız, Şekil 5.12’de verilen gözlem dizisi için, en olası durum dizisini bulmak olacaktır. Her adımda her durum için bir önceki durumda verilen çözümler ile yeni bir duruma ulaşma olasılığı için hesap yapılmalıdır. Örneğin Y durumundan tekrar Y durumunu “1” gözlem sonucunu kullanarak elde edebiliriz. Burada dikkat edilmesi gereken nokta gözlem “1” Y durumundan tekrar Y durumuna geçiş süresince “0.5” olasılığa sahiptir. Bununla beraber durumun Y durumu ile başlama olasılığı 0.0 (başlangıç durumu için varsayım değeri), YY dizisinin oluşum olasılığı yine 0.0. Diğer yandan XY dizisinin aynı gözlem değeri (“1”) ile oluşma olma olasılığı $1.0 \times 0.1 = 0.1$. her adımda tüm olasılıklar verilen denkleme göre oluşturulmuş olup en muhtemel durum dizisi Çizelge 5.4’de olduğu gibi elde edilir.

Viterbi algoritması iteratif olup bütün dizi olasılık kombinasyonlarını göz önünde bulundurur. Bu özelliğinden dolayı SMM için yaygın olarak kullanılır.

6. SONUÇLAR

Günümüzde yaygın olarak kullanılan mevcut enerji kaynaklarının ihtiyacımız olan enerjiyi karşılamada yetersiz kalması ve bir gün tükenecek olması tüm dünyayı yenilenebilir enerji kaynaklarını incelemeye ve kullanmaya yönlendirmiştir. Yenilenebilir enerji kaynakları çevre dostu ve tükenmeyecek olduğu için gün geçtikçe daha cazip hale gelmektedir.

Güneş enerjisi en kıymetli yenilenebilir enerji kaynaklarından biridir. Türkiye’de ve Dünya’da birçok ülkede güneş potansiyeli oldukça fazladır. Her ne kadar güneş enerjisinden elektrik enerjisi elde etme çalışmaları kurulum aşamasında maliyetli olsa da bu maliyeti kısa sürede telafi edecek enerji elde edilebilmektedir. Çünkü güneş hiçbir zaman tükenmeyecek, temiz bir enerjidir ve ülkemiz de güneş potansiyeli açısından birçok ülkeye göre oldukça iyi konumdadır.

Güneş enerjisi elde edilecek bölgede sistem kurulmadan önce o bölgenin potansiyeli iyi araştırılmalı, kurulum maliyetleri iyi hesaplanıp değerlendirilmelidir. Kurulum yapılacak bölgenin güneş ışınlam şiddeti tahminleri yapılmalıdır.

Bir bölgenin güneş enerjisi potansiyel analizi yapılırken kullanılabilecek birçok modelleme ve tahmin yöntemi vardır. Bu çalışmada ise Saklı Markov modelin güneş ışınlam şiddeti tahmininde kullanılabilirliği gösterilmeye çalışılmıştır. Diğer tahmin yöntemlerinde ve Markov modelinde de güneş ışınlam şiddeti tahmini yine güneş ışınlam verileri kullanılarak yapılmaktadır. Fakat Saklı Markov modelde farklı bir parametre kullanılarak (örneğin sıcaklık) güneş ışınlam şiddeti tahmin edilebilmektedir. Bu çalışmada da Saklı Markov modelle Bilecik bölgesi güneş ışınlam şiddeti tahmininin sıcaklık verileri kullanarak yapılabileceği analiz edilmiştir ve bu yöntemin nasıl kullanılabileceği örneklerle gösterilmiştir. Bu yöntemle elimizde geçmiş dönemlere ait güneş ışınlam şiddeti verileri olmasa da sıcaklık veya başka korelasyonu olan bir veriyi kullanarak güneş ışınlam şiddeti tahmin edilebilir ve güneş enerjisi potansiyel analizi yapılabilir. Bu özelliği sebebiyle Saklı Markov modeli diğer yöntemlerle kıyaslandığında önemli bir avantaj oluşturmaktadır ve farklı alanlarda kullanılan bu yöntem güneş enerjisi potansiyel analizinde de kullanıldığında önemli bir açılım sağlayacaktır.

KAYNAKLAR

- Aksungur, K. M., Kurban, M., Başaran, F. Ü., “ Türkiye’nin Farklı Bölgelerindeki Güneş Işınım Verilerinin Analizi ve Değerlendirilmesi” **5. Enerji Verimliliği ve Kalitesi Sempozyumu**, Kocaeli, (2013).
- Bengio, Y., “Markovian Model For Sequential Data”, *Neural Computing Surveys*, 2:129-162 (1999).
- Climate Onebuilding
http://climate.onebuilding.org/WMO_Region_6_Europe/default.html, (Ziyaret Edilme Tarihi: 05.12.2017).
- Çelebioğlu, S., “Markov zincirlerinde durum tahmini ve iç göçe uygulanması”, Doktora Tezi, **Gazi Üniversitesi Fen Bilimleri Enstitüsü**, Ankara (1988).
- Dahamsheh, A., “Kurak Bölge Aylık Yağışlarının Markov Zinciri Eklenmiş Koşullu Yapay Sinir Ağları İle Tahmini”, Doktora Tezi, **İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İnşaat Mühendisliği**, İstanbul, (2008).
- Dinçer, F., “Türkiye’de güneş enerjisinden elektrik üretimi potansiyeli ekonomik analizi ve AB ülkeleri ile karşılaştırmalı değerlendirme”, **KSU Mühendislik Dergisi**, 14(1):8-17 (2011).
- Dolunay, G., “Güneş Enerjisi Santrali Kurulacak Alanların Cbs - Çok Ölçütlü Karar Analizi Yöntemi İle Belirlenmesi”, Yüksek Lisans Tezi, **Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü**, İstanbul, (2010).
- Dünya Enerji Konseyi Türk Milli Komitesi, Dünya’da ve Türkiye’de Güneş Enerjisi, Haziran 2009. <http://www.dektmk.org.tr/upresimler/GUNES.pdf>. (Ziyaret Edilme Tarihi, 3.12.2017).
- Edizkan, R., “Gizli Markov Model İle Bilgisayarda Konuşma Tanıma: Özellik Uzayında ve Altuzayda Sınıflandırıcı Tasarımı”, Doktora Tezi, **Osmangazi üniversitesi, Fen Bilimleri Enstitüsü**, Eskişehir, (1999).
- Hamzaçebi, C., Kutay F., “Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini”, **Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi**, 19(3):227-233(2004).
- Hanedar, A. Ö., Durağanlık Analizi, Birim Kök Testleri ve Trend, <http://debi.deu.edu.tr/userweb/onder.hanedar/dosyalar/Metin.pdf>, (Ziyaret Edilme Tarihi:17.12.2017).
- Hocaoğlu, F. O., “Rüzgar ve Güneş Verilerinin Sinyal İşleme Yöntemleri ile Analizi ve Sistem Modellemesi”, Doktora Tezi, **Anadolu Üniversitesi**, Eskişehir, (2008).

KAYNAKLAR(devam ediyor)

- Hocaoğlu, F. O., Gerek, O. N., Kurban, M., “2 Boyutlu bir Güneş Işınım Şiddeti Modeli”, **16. Sinyal İşlemei, İletişim ve Uygulamaları Kurultayı**, Aydın, 1-4, (2008).
- Hocaoğlu, F. O., Gerek, O. N., Kurban, M. “A Novel Wind Speed Modeling Approach Using Atmospheric Pressure Observations and Hidden Markov Models”, **Journal of Wind Engineering and Industrial Aerodynamics**,98(8-9):472-481 (2010).
- Karagöl E. T., Kavaz İ. “Dünya’da ve Türkiye’de Yenilenebilir Enerji”, **Seta Analiz**, **197**, (2017).
- Karahan, M., “İstatistiksel Tahmin Yöntemleri Yapay Sinir Ağları Metodu İle Ürün Talep Tahmin Uygulaması”, Doktora Tezi, **Selçuk Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı**, Konya, (2011).
- Karamanav, M., “Güneş Enerjisi Ve Güneş Pilleri” Yüksek Lisans Tezi, **Sakarya Üniversitesi Fen Bilimleri Enstitüsü**, Sakarya, (2007).
- Karatepe, S., “Yenilenebilir enerji kaynaklarından rüzgar ile üretilen enerjinin ekonomik değerinin markov zinciri ile modellenmesi ve Yalova ilinde bir uygulama”, Yüksek Lisans Tezi, **Uludağ Üniversitesi Sosyal Bilimler Enstitüsü**, Bursa (2011).
- Kılıç, F. Ç., “Güneş Enerjisi, Türkiye’deki Son Durumu ve Üretim Teknolojileri”, **Mühendis ve Makina**, 56(671):28-40 (2015).
- Kökey, İ., “Güneş Enerji Santrallerinin Kurulumunda Güneş Ölçümünün Önemi Ve Türkiye’de Yasal Mevzuat”, **VIII. Ulusal Ölçüm Bilim Kongresi**, Kocaeli,1-7(2013).
- Meteoroloji Genel Müdürlüğü (MGM), “Analizler› Resmi İstatistikler”, Meteorolojik Parametrelerin Türkiye Analizi, <https://www.mgm.gov.tr/FILES/resmi-istatistikler/Turkiye-Yillik-G%C3%BCnes-Radyasyonu.pdf> (Ziyaret Edilme tarihi:5.12.2017).
- Meteoroloji Genel Müdürlüğü (MGM), “Analizler› Resmi İstatistikler”, 2017 <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k=A&m=BILECIK> , (Ziyaret Edilme Tarihi:17.12.2017).
- Minaz, M. R., “Bilecik İlinin Uyarlanır Sinir Bulanık Çıkarım Sistemi İle Basınç, Sıcaklık Ve Rüzgâr Hızı Tahmini”, Yüksek Lisans Tezi, **Bilecik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Elektronik Mühendisliği**, Bilecik, (2011).
- Özcan G., “ Saklı Markov Modelleri ve Uygulamaları”,**Akademik Bilişim ’15-XV. Akademik Bilişim Konferansı**, 1-10(2015).

KAYNAKLAR(devam ediyor)

- Rabiner, L.R., “A Tutorial On Hidden Markov Model and Selected Applications in Speech Recognition”, ***Proceedings of IEEE***, 77(2):257-286 (1989).
- Sarıkaya, S., Doküman Merkezi, Araştırmalar ve Analizler, Güneş Enerjisi Sektörel Analiz Raporu,
<http://www.daka.org.tr/panel/files/files/arsiv/Ara%C5%9F%C4%B1rmalar%20ve%20Analizler/G%C3%BCne%C5%9F%20Enerjisi%20Sekt%C3%B6rel%20Analiz%20Raporu.pdf> (Ziyaret Edilme Tarihi, 16.12.2017).
- YEGM (TC Enerji ve Tabii Kaynaklar Bakanlığı Yenilenebilir Enerji Genel Müdürlüğü), “Güneş Enerjisi Potansiyel Atlası”,
<http://www.eie.gov.tr/mycalculator/default.aspx>, (Ziyaret Edilme Tarihi:15.12.2017).
- Y. Ren-Wu, C. Jin-Ding “Application of Hidden Markov Model to Fault Diagnosis of Power Electronic Circuit”, ***2009 IEEE Circuits and Systems International Conference on Testing and Diagnosis***, China, 1-4 (2009).



ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : İnci CEYHAN
Doğum Yeri ve Tarihi : İZMİR-18.05.1989

Eğitim Durumu

Lisans Öğrenimi : Bilecik Üniversitesi Elektrik Elektronik Mühendisliği
Bildiği Yabancı Diller :
Bilimsel Faaliyetleri :

İş Deneyimi

Stajlar : Eti Maden İşletmeleri Genel Müdürlüğü-Kırka Bor İşletmesi
Projeler :
Çalıştığı Kurumlar : Bilecik Osmangazi Yapı Denetim Ltd. Şti.
: İSBAK(İstanbul Bilişim ve Akıllı Kent teknolojileri A.Ş.)-
Bilecik YHT Elektrifikasyon Sistemleri Bakım-Onarım

İletişim

Adres :Ertuğrulgazi Mh. Akasya1Sk. No:26/6 Merkez/BİLECİK
Tel : 0545 901 58 30
E-Posta Adresi : inci_ganioglu@hotmail.com

Akademik Çalışmaları

Ceyhan İ., Kurban M., “Saklı Markov Modeli Kullanılarak Güneş Işınım Şiddetinin Tahmini”,*V. Ulusal Güneş ve Hidrojen Enerjisi Kongresi (UGhEK2016)*, Eskişehir.

Tarih 02/02/2018