



T.C.
NECMETTİN ERBAKAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

KONYA'DA KISA DÖNEMLİ GÜNEŞ
ENERJİSİ ÜRETİM TAHMİNİ

Cankat YAVUZ

YÜKSEK LİSANS

Endüstri Mühendisliği Anabilim Dalı

Temmuz-2018

KONYA

Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Cankat YAVUZ tarafından hazırlanan “Konya’da Kısa Dönemli Güneş Enerjisi Üretim Tahmini” adlı tez çalışması .../07/2018 tarihinde aşağıdaki jüri tarafından oy birliği / oy çokluğu ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Mehmet AKTAN

.....

Danışman

Dr. Öğr. Üyesi Ahmet Reha BOTSALI

.....

Üye

Doç. Dr. Saadettin Erhan KESEN

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mehmet KARALI
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all materials and results that are not original to this work.

Cankat YAVUZ

ÖZET

YÜKSEK LİSANS TEZİ

KONYA DA KISA DÖNEMLİ GÜNEŞ ENERJİSİ ÜRETİM TAHMİNİ

Cankat YAVUZ

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi. Ahmet Reha BOTSALI

2018, Sayfa

Jüri

Prof. Dr. Mehmet AKTAN
Dr. Öğr. Üyesi Ahmet Reha BOTSALI
Doç. Dr. Saadettin Erhan KESEN

Bu çalışmanın amacı; güneş enerjisi üretim tahmini yapmak zorunda olan şirketlerin bilimsel yöntemler kullanarak daha doğru tahminler yapması ve bu tahminler sonucu şirketlerin ve Türkiye' nin zararının minimuma indirilmesidir. Yapılan gözlemler sonucunda şirketlerde güneş enerjisi üretim tahmini yapmak için bilimsel yöntemlerin yaygın olarak kullanılmadığı tespit edilmiştir. Bu konuya dikkat çekmek ve tahminlerin daha ciddi yapılmasını sağlamak için bu konu tercih edilmiş olup yapay sinir ağları kullanılarak hava durumu şartlarına göre güneş enerji santrallerinin enerji üretimlerinin yüksek hassasiyette tahmin edilebileceği gösterilmiştir. Bu çalışmanın sonuçlarının uygulaması yapılacak olan şirkete katkı sağlaması beklenmektedir.

Anahtar Kelimeler: Güneş enerjisi, Talep tahmini, Yapay sinir ağları

ABSTRACT

MASTER'S THESIS

Cankat YAVUZ

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTIN ERBAKAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN INDUSTRIAL ENGINEERING**

Advisor: Asst. Prof. Dr. Ahmet Reha BOTSALI

2018, Sayfa

Jury

**Prof. Dr. Mehmet AKTAN
Asst. Prof. Dr. Ahmet Reha BOTSALI
Assoc. Prof. Dr. Saadettin Erhan KESEN**

The purpose of this study is to ensure the companies forecasting solar power generation to have more accurate forecasts and to minimize the cost due to forecast errors. As a result of the observations, it has been determined that scientific methods are not widely used to estimate solar energy production in companies. We choose this topic to draw attention to this issue and to ensure that the forecasts are done more serious. It is shown that by using artificial neural networks, it is possible to have highly accurate forecast for the power production of solar power generation companies. We expect the results of this study to have positive contribution on the company that applies our methods.

Keyword: Solar power, Demand forecasting, Artificial neural networks

ÖNSÖZ

Bu çalışma lisanssız Güneş Enerjisi Santrallerinin (GES) ihtiyaç fazlası üretim miktarlarını önceden en doğru şekilde tahmin ederek şirketlerin ve dolaylı yoldan ülkemizin zararını minimize etmek amacıyla yapılmıştır. Çalışma esnasında Konya bölgesinde üretim yapan GES'lere ait veriler şirket isimleri gizlenerek ve belirli bir ölçekte kullanılmıştır.

Bu çalışma sürecinde öncelikle danışmanlık yaparak sorduğum soruları cevaplayan, benden bilgi ve desteğini esirgemeyen Sayın Dr. Öğr. Üyesi Ahmet Reha BOTSALI' ya, değerli jüri üyelerim olan Sayın Prof. Dr. Mehmet AKTAN' a, Doç. Dr. Saadettin Erhan KESEN' e ve bu süreçte hep yanımda olan aileme sonsuz teşekkürlerimi sunarım.

Cankat YAVUZ
KONYA-2018

İÇİNDEKİLER

ÖZET	iv
ABSTRACT	v
ÖNSÖZ	vi
İÇİNDEKİLER	vii
ŞEKİLLER LİSTESİ	viii
ÇİZELGELER LİSTESİ	ix
KISALTMALAR	x
1. GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	2
3. MATERYAL VE YÖNTEM	5
3.1.Talep Tahmini	5
3.2.Talep Tahmininde Kullanılan Yöntemler	5
3.2.1.Kalitatif Yöntemler	5
3.2.2.Kantitatif Yöntemler	5
3.2.2.1.İlişkisel Yöntemler.....	6
3.2.2.2.Zaman Serileri.....	6
3.2.3.Yapay Zeka Tabanlı Yöntemler	7
3.2.3.1.Yapay Sinir Ağları (YSA).....	7
3.2.3.1.1Yapay Sinir Ağları Modelleri.....	11
3.2.3.1.2.YSA' da Öğrenme Algoritmaları	12
4. ARAŞTIRMA BULGULARI VE TARTIŞMA	14
4.1.Ver Sınıflandırması	14
4.2.Tahmin Uygulaması.....	20
5. SONUÇLAR VE ÖNERİLER	28
5.1 Sonuçlar	28
5.2. Öneriler	29
KAYNAKLAR	29
EKLER	32
ÖZGEÇMİŞ	Hata! Yer işareti tanımlanmamış.

ŞEKİLLER LİSTESİ

Şekil 3.1. Sinir hücresi	7
Şekil 3.2. Yapay sinir ağı	9
Şekil 3.3. YSA işlem elemanları (yapay sinir hücresi) yapısı	10
Şekil 3.4. Bir nöron modeli	10
Şekil 3.5. İleri beslemeli yapay sinir ağının blok gösterimi	11
Şekil 3.6. Geri beslemeli yapay sinir ağının blok gösterimi	12
Şekil 3.7. Danışmanlı öğrenme	13
Şekil 3.8. Danışmansız öğrenme	14
Şekil 4.1. Veri seti	16
Şekil 4.2. Düzenlenmiş veri seti	16
Şekil 4.3. İkinci kere düzenlenen veri seti	17
Şekil 4.4. Korelasyon testi	18
Şekil 4.5. Korelasyon testi sonuçları	18
Şekil 4.6. İkinci kere yapılan korelasyon testi sonuçları	20
Şekil 4.7. Birinci ysa modeli	22
Şekil 4.8. İkinci ysa modeli	23
Şekil 4.9. Üçüncü ysa modeli	24
Şekil 4.10. Dördüncü ysa modeli	25
Şekil 4.11. Beşinci ysa modeli	26
Şekil 4.12. Altıncı ysa modeli	27

ÇİZELGELER LİSTESİ

Çizelge 3.1. Biyolojik sinir ağı ve yapay sinir ağının karşılaştırılması	8
Çizelge 4.1. Korelasyon testi sonuçları	19
Çizelge 4.2. İkinci kere yapılan korelasyon testi sonuçları	20
Çizelge 5.1 Tahmin sonuçları	28



KISALTMALAR

GES Güneş Enerjisi Santralleri

YEKDEM Mevcut Yenilenebilir Enerji Kaynakları Destekleme Mekanizması

YSA Yapay Sinir Ağları



1. GİRİŞ

Yenilenebilir enerji kaynakları konvansiyonel yakıtlara oranla daha ucuz ve çevrecidir. Türkiye, yenilenebilir enerji kaynakları bakımından yüksek potansiyele sahip olmasına rağmen yenilenebilir enerji kaynaklarından yapılan üretim anlamında yeterli seviyede değildir. Yenilenebilir enerji kaynaklarından yapılan üretimin toplam üretim içerisindeki payını arttırmak için ülkeler bu alana yatırımlar yapmaktadır. Türkiye’de yenilenebilir enerji kaynaklarından yapılan üretime verilen teşvikler bu yatırımlara örnek olarak gösterilebilir. Bu konuda devletin uyguladığı politikalar ve yatırımlar sayesinde yenilenebilir enerji kaynaklarından yapılan üretimin toplam üretimin içerisindeki payı hızla artmaktadır. Bu teşviklerin düzenlendiği Mevcut Yenilenebilir Enerji Kaynakları Destekleme Mekanizması (YEKDEM) gereğince güneş enerjisi başta olmak üzere kısa dönemli üretim tahmini önem kazanmıştır.

Bu çalışma lisanssız Güneş Enerjisi Santrallerinin (GES) ihtiyaç fazlası üretim miktarlarını önceden en doğru şekilde tahmin ederek şirketlerin ve dolaylı yoldan ülkemizin zararını minimize etmek amacıyla yapılmıştır. Çalışma esnasında Konya bölgesinde üretim yapan 24 farklı santralin verileri kullanılmıştır. Uygulama sonucunda kurulan ve testlerde yeterli performansı gösteren modelin kısa dönemli güneş enerjisi üretim tahmininde kullanılabileceği gözlemlenmiştir. Bu vesile ile güneş enerjisi üretim tahmini yapmak zorunda olan şirketlerin bilimsel yöntemler kullanarak daha doğru tahminler yapması beklenmektedir.

2. KAYNAK ARAŞTIRMASI

Park ve diğeri 1991 yılında, elektriğin talep tahminini yapay sinir ağlarını kullanarak hesaplamışlardır. Yapay sinir ağlarını sıcaklık ve yük arasındaki ilişkiyi saptamak için kullanmışlardır. Bu çalışmada çalışmanın yapılmış olduğu tarihe kadar olan tüketim girdileri ve hava ısısı girdileri parametre olarak değerlendirilmiştir. Çıktılar ortalama mutlak hata değeri bakımından yorumlanmıştır. Ortalama mutlak hata değeri %1.4-2.06 olarak tespit edilmiştir (Park, El-Sharkawi, Marks, Atlas, & Damborg, 1991).

Hiyama, Kouzuma ve Imakubo 1995 yılında yapmış oldukları çalışmada PV modülünün maksimum seviyede güç göstereceği çalışma için yapay sinir ağı geliştirmişlerdir. Bu çalışmada, geniş zaman dilimi belirlenerek bu zaman dilimindeki çevresel faktörleri kullanarak geliştirilen yapay sinir ağı modeli, gerçek zamanlı bir güneş izleme sistemiyle kullanılmıştır. Bunun yanı sıra çalışmada maksimum güç tahmini de incelenmiş, kullanılan yapay sinir ağıyla %99 gibi güçlü bir tahmin gerçekleştirilmiştir. Bu oranın bir tahmin problemi için çok başarılı olduğu kaydedilmiştir. Çünkü herhangi bir tahmin probleminde %100 doğruya ulaşmanın imkansız olduğu çalışmada belirtilmiştir (Hiyama, Kouzuma, & Imakubo, 1995).

1997'de Elazouni, Nosair, Mohamed ve Mohieldin yapay sinir ağı içerisinde geri yayılım algoritması kullanılmış, farklılaştırılmış silo inşaatında, ihtiyaç duyulan kaynaklar tahmin edilmiştir. Çalışmada sigmoid aktivasyonu kullanılmıştır. Sonuç olarak bir yapı tahmin problemi için yapay sinir ağları daha sağlıklı sonuç verebildiği gözlenmiştir. (Elazouni, Nosair, & Mohieldin, 1997).

Kim, An ve Kang (2004) yaptıkları çalışmada bir tahmin problemini ele almışlardır. Bu çalışmada regresyon analizi, yapay sinir ağları, ve vaka temelli akıl yürütme yöntemleri kullanılmıştır. Bu yöntemlerden en doğru sonucu YSA yöntemiyle ulaşılmıştır. Çalışmanın içerisinde probleme yeni veriler eklendiği zaman YSA'yı yeniden eğitmek gerekli olduğu için süre olarak diğer yöntemlerden daha uzun süreceği, YSA'nın olumsuz özelliği olarak kaydedilmiştir. (Kim, An, & Kang, 2004).

Krishnaiah ve diğeri belirli bir dönem arasında Hindistan'ın sahip olduğu toplam güneş radyasyonunu tahmin etmeye çalışmışlardır. Burada 7 istasyondan alınan veriler, YSA'nın eğitimi için 2 istasyondan ulaşılan veriler ise YSA'nın test edilmesi

için kullanılmıştır. Problemin çözümü için çok Tabakalı İleri Beslemeli YSA kullanılmıştır. Çalışmada diğer tahmin yöntemleri kullanılmış ve YSA sonucu ile kıyaslandığı zaman YSA'nın daha iyi sonuçlara ulaştığı tespit edilmiştir. (Krishnaiah, Rao, Madhu Murthy, & Reddy, 2007).

Uğur, 2007 yılında yapmış olduğu çalışmada yeni bir yapay sinir ağı üretmiştir. Bunun için insan beyninin sahip olduğu sinir hücrelerini örnek almıştır. Bu çalışmada yazar ağ yapısının doğru bir şekilde tanımlanması ile öğrenme becerisine ulaşabileceğini kaydetmiştir. (Uğur, 2007, s. 99).

Keskinkılıç, çalışmasında bir fabrikada işlem gören bir döküm parçasının ulaşabileceği sertliği tahmin etmeye çalışmıştır. Çalışmanın sonucunda YSA ile en başarılı çıktıya ulaşılmıştır. (Keskinkılıç, 2010).

Işık ve arkadaşları 2011 yılında yapmış oldukları çalışmada Tunceli iline ait açık gün sayısı, hava basıncı, rüzgar hızı, hava sıcaklığı, nispi nem ve güneş ışınım şiddeti değerlerini kullanarak YSA ile aylık ortalama güneş ışınım şiddetini tahmin etmeye çalışmış ve bunun için geri yayımlı çok katmanlı YSA modeli kullanmıştır. (Işık, 2011).

Ahmet ve Adam tarafından 2013 yılında yapılan çalışmada aylık ortalama günlük toplam güneş ışınımını tahmin etmek için yeni bir YSA modeli kurmuşlardır ve tahmin sonucu ile gerçekleşen veri arasındaki farklılığın çok az olduğu görülmüştür. Çalışmada, YSA diğer modellerle karşılaştırıldığında ışınım etkisini belirlemek için kurulan YSA'nın daha iyi sonuçlar verdiği belirtilmiştir. Bu şekilde belirtildiği üzere ışınım şiddeti tahmin edilebilmesi için bu modelin etkin bir şekilde kullanılabileceği önerilmiştir. (Ahmed & Adam, 2013).

Şenyurt ve diğerleri belirli bir bölgede bulunan belirli bir ağaç türü sayısının tahmin edilmesi için bu ağaç türünün hacimi, yüzey alanı, ağaç adedi, ağaç türünün çap uzunluğu gibi bazı parametreler ile alanda bulunan ağaç türünün yaşı ve sıklık derecesi YSA kullanılarak başarılı bir sonuç elde edilmiştir. (Şenyurt, Yavuz, Kahriman, & Ercanlı, 2015).

Ercanlı ve Bolat 2017 yılında yapmış oldukları çalışmada Weibull fonksiyonunu kullanarak herhangi bir alanın çap dağılımını tespit etmek için belirli bir bölgedeki

ortalama olarak aynı yaşa sahip olan çam ormanlarından alınan belirli alanlara ait verileri kullanmışlar ve doğru sonuca ileri beslemeli geri yayımlı YSA ile ulaştıklarını kaydetmişlerdir. (Ercanli & Bolat, 2017).



3. MATERYAL VE YÖNTEM

Bu bölümde çalışmada kullanılan materyal ve yöntemler hakkında bilgiler verilmiştir.

3.1. Talep Tahmini

Tahmin etmek, bilinen parametrelere dayanarak bilinmeyen parametrelerin belirli bir hata payı düzeyinde, hiçbir zaman kesinliğe dayanılmayarak kestirilmesidir. Talep tahmini, şirketlerin üretim ve satış hacimlerini belirleyebilmeleri için en etkili olan yöntemdir. Bu yüzden hemen hemen her şirket talep tahmini konusunu genel anlamda kullanmak durumunda kalmış ve bu durum şirketleri bu konuda bilimsel araştırma ve uygulama yapmaya itmiştir.

Talep tahminleri temelde süre bazında kısa dönemli talep tahminleri, orta dönemli talep tahminleri ve uzun dönemli talep tahminleri olarak 3'e ayrılmaktadır. Kısa dönemli talep tahminleri bir saatten bir haftaya olan tahminler, orta dönemli talep tahminleri bir hafta ile bir yıl arasında değişir ve uzun dönemli talep tahminleri ise bir yıl ve daha fazla süre tahminleri için yapılmaktadır.

3.2. Talep Tahmininde Kullanılan Yöntemler

Talep tahmini yöntemleri ile ilgili literatürde farklı sınıflandırmalar bulunmaktadır. Ancak temelde kalitatif, kantitatif ve yapa zeka tabanlı yöntemler olmak üzere 3 e ayrılmaktadır.

3.2.1. Kalitatif Yöntemler

Kalitatif yöntemlerde bilimsel tekniklerden daha çok insan kaynağını kullanarak sezgiye dayalı tahminler kullanılmaktadır. Senaryo analizi, Delphi yöntemi gibi yöntemler kalitatif yöntemlere örnek olarak verilebilir.

3.2.2. Kantitatif Yöntemler

Kantitatif yöntemler, geçmiş veriler ışığında gelecek verilerin tahmin edildiği yöntemlerdir. Geçmişteki verilerin farklı parametreleri kontrol edilir, aynı zamanda parametreler üzerindeki değişim gözlemlenerek gelecek olan verinin kestirilmesi yapılır. Bu yöntemler genellikle ilişkiye dayalı ve zaman serileri yöntemleri olarak iki grupta sınıflandırılabilir.

3.2.2.1. İlişkisel Yöntemler

İlişkisel yöntemlerde bir parametrenin gelecekteki değerinin tahmin edilmesinden daha çok bağımlı ve/veya bağımsız değişkenler arasındaki ilişki anlamaya çalışılır. İlişkiye dayalı tahmin yöntemlerinin temelini regresyon analizi ve korelasyon analizi oluşturmaktadır (Frechtling, 2012).

3.2.2.2. Zaman Serileri

Bir veya birden fazla parametrenin öncesinde belirlenmiş bir zaman aralığında yapılmış olan ölçümlerden elde edilen veri setine zaman serileri denilmektedir. Bu yöntemde daha önce edinilmiş olan veri setleri kullanılarak gelecek olan dönem için tahmin yapılabilmektedir (Kutlar, 2000).

Zaman serilerinin en kritik özellikleri gözlemlenen değişikliklerin genel anlamda bu faktörlerin ortak etkisi altında oluşmasıdır. Bu faktörler ise aşağıdaki gibi temelde 4 sınıfta gruplanabilmektedir (Hamburg, 1970).

- Trend
- Mevsimsel dalgalanma
- Devirsel dalgalanma
- Tesadüfi dalgalanma

Zaman serileri analizinde kullanılmakta olan yöntemler aşağıdaki gibidir.

- Trend Analizi
- Mekanik Tahmin
- Hareketli Ortalamalar
- Üstel Düzleştirme
- Uyarlayıcı Arındırma
- Box-Jenkins (ARIMA)

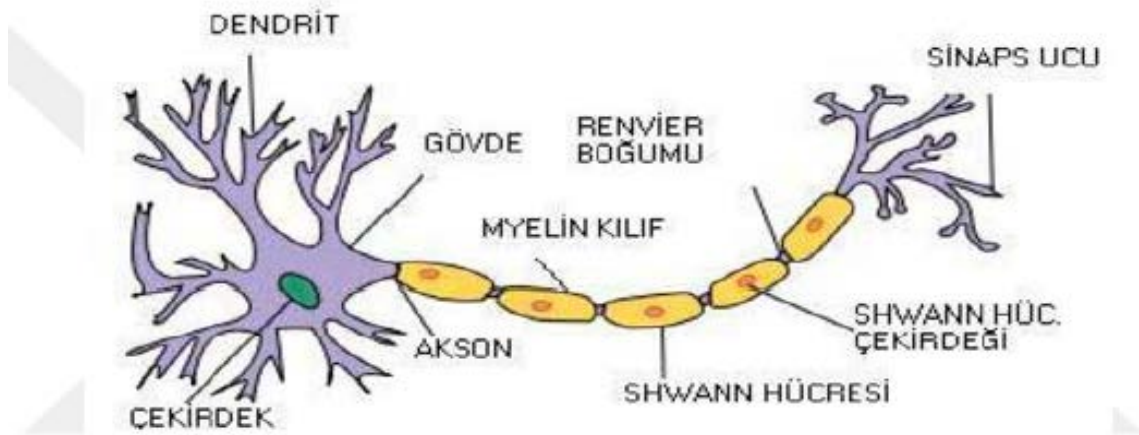
3.2.3. Yapay Zeka Tabanlı Yöntemler

Yapay sinir ağı, biyolojik sinir sisteminin çalışma prensibini taklit eden matematiksel modellerdir. Yapılan tanımlardaki en önemli ortak nokta YSA'ların birbirlerine hiyerarşik olarak bağlanan ve bir değere sahip yapay hücrelerden oluşmasıdır (Öztemel, 2012) YSA; öğrenme, hatırlama, keşfetme, yeni bilgiler oluşturma gibi özellikleri taşıyan olayları anlayarak çözüm üretmeye çalışan bilgi işleme sistemidir. YSA' nın çalışmasında etkili olan temel etmen yapay sinir ağı hücreleridir.

3.2.3.1. Yapay Sinir Ağları (YSA)

İnsan beynindeki çalışma prensipleri örnek alınarak beyin içerisindeki sinir hücrelerinin farklı bir ortama aktarılması ile (örnek alınması) ve bu aktarılan yapının herhangi bir problemin çözümü amacı ile bilgisayar ortamına aktarılması sonucu oluşan tekniğe yapay sinir ağı denilmiştir. Aslında insan beyninin yapısındaki sinir hücrelerinin sayısallaştırılması ile yeni bir olgu oluşturulmuştur. Burada önemli olan nokta sinir hücrelerinin çalışma şeklinin taklit edilmesidir. Tıpkı tecrübe eden insan beyni gibi kurulan bu yapının insan beynindeki sinir hücrelerindeki gibi öğrenmesi ve problemin çözümünde bu öğretinin çıktısı verilmesi beklenir (Basheer & Hajmeer, 2000).

Aşağıda örnek bir insan beyni sinir hücresi gösterilmiştir.



Şekil 3.1. Sinir Hücresi (Alan, 2013)

İnsan beyninin örnek alınmak istenmesi ve insan beyninin bilgisayar ortamına aktarılması için taklit edilmesinin nedeni bu yapının sahip olduğu karmaşıklık ve zor problemleri çözme yeteneğinin güçlü olmasıdır. Örnek olarak insan beyni geçmişte gördüğü herhangi bir resmi ya da anıyı çok kolay ve rahat bir şekilde hatırlayabilme yeteneğine sahiptir. Hatta bu anımsama işlemi insan beyninde 0,1 saniyede olabiliyor iken bilgisayarlara aktarılan tekniklerde bir saatten daha fazla sürebileceği bilinmektedir. İnsan beyninin yapısı bu kadar güçlü ve hızlı iken yapay sinir ağları ile taklit edilmiş olan bu yapı insan beyni seviyesine ulaşılmaya çalışılmaktadır (Haykin, Neural Networks: A Comprehensive Foundation, 1994).

Çizelge 3.1. Biyolojik Sinir Ağı ve Yapay Sinir Ağı'nın Karşılaştırılması (Faucett 1994)

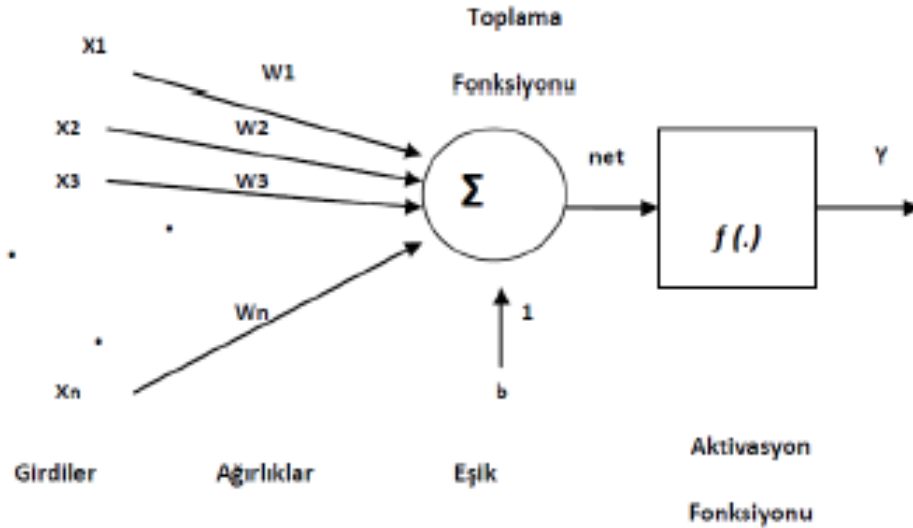
Biyolojik Sinir Sistemi	Yapay Sinir Ağları
Nöron	İşlemci eleman
Dentrit	Nöronlar arası bağlantılar
Hücre gövdesi	Aktivasyon fonksiyonu
Aksonlar	Yapay nöron çıkışı
Sinapslar	Ağırlıklar

Öztemel'in yapmış olduğu tanımda ise YSA insan beyninin en önemli özelliklerinden biri olan öğrenme yolu ile yeni bilgi türetme, yeni bilgi oluşturma ve yeni bilgi keşfetme şeklindeki önemli yetenekler hiçbir yardım alınmadan doğrudan gerçekleştirilmek amacı ile geliştirilmiş bilgisayar sistemi olarak tanımlamıştır. Standart bilgisayar teknikleriyle bu tarz işlemlerin yapılması imkansızdır. YSA bu şekilde olan karmaşık problemlerin çözümüne ulaşmak için geliştirilen bir bilim alanıdır (Öztemel, 2012).

Yapay zeka uygulamaları arasında önemli bir temsil niteliğinde olan Yapay Sinir Ağları matematiksel olarak oluşturulmuştur. İnsan beyninin sinir hücreleri içerisindeki her bir nöron ve bu nöronu oluşturan elemanlarının tamamının YSA modeli içerisinde bir karşılığa sahiptir (Alan, 2013).

Yapay sinir ağı temelinde aşağıdaki varsayımlara dayandırılmaktadır. (Yadav, ve diğerleri, 2015).

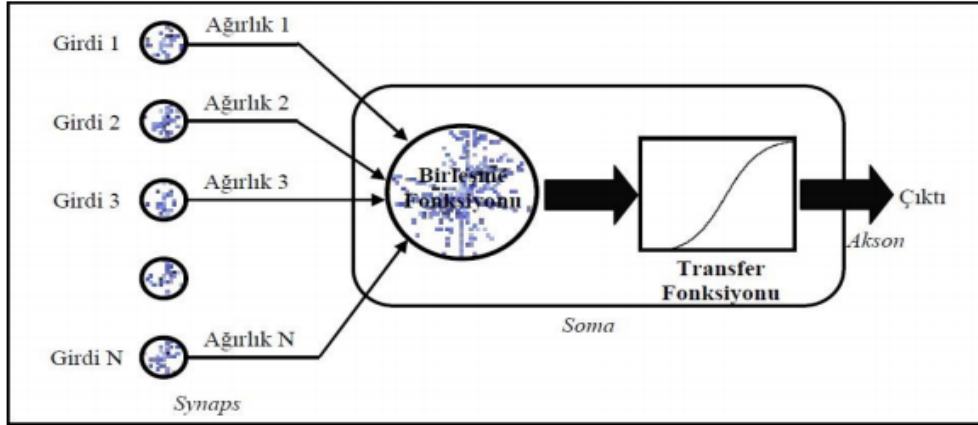
- Bilgi işleme nöron olarak tanımlanan pek çok bağlantılar arasında gerçekleştirilir.
- Herhangi bir sinyal bağlantılı bulunan linkler aracılığı ile nöronlara iletilmektedir.
- Bağlantı hatlarının tamamı tıpkı bir sinir ağında ilerleyen sinyal gibi bir ağırlığı vardır.
- Nöronların hepsi çıkış sinyalinin belirlenmesi amacı ile giriş için bir aktivasyon fonksiyonu oluşturur.



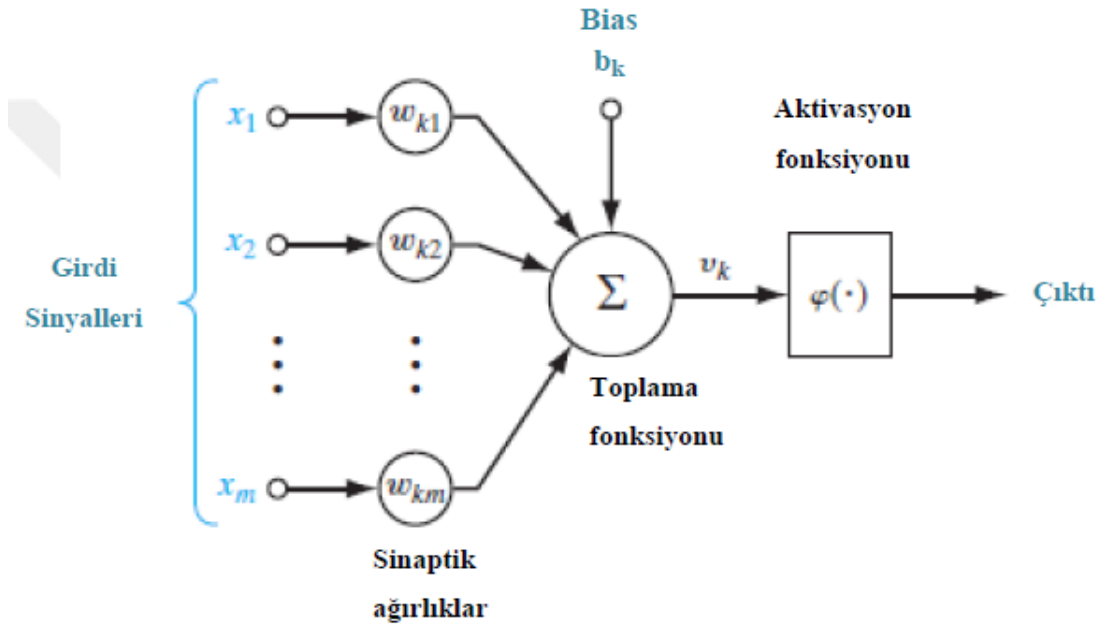
Şekil 3.1. Yapay Sinir Ağı (Gürsoy, 2012)

Yapay sinir ağı biyolojik sistemlerdeki gibi pek çok sinir hücrelerinin bir araya gelmesi ile oluşmaktadır. Bu hücreye ya da hücrelere birden fazla veri girdi olarak verilebilmektedir. Bu veriler sonrasında toplama-aktivasyon fonksiyonlarında etkileşime gelerek çıktı haline dönüştürülür. Genellikle bir hücrenin yapısı ve nöron yapısı aşağıdaki şekillerde gösterildiği gibidir. (Kasaplı, 2014, s. 71). Bileşenleri ise;

- Girdiler
- Ağırlıklar
- Birleştirme fonksiyonu
- Aktivasyon fonksiyonu
- Çıktı



Şekil 2.3. YSA İşlem Elemanları (Yapay Sinir Hücresi) Yapısı (Bahadır, 2013)



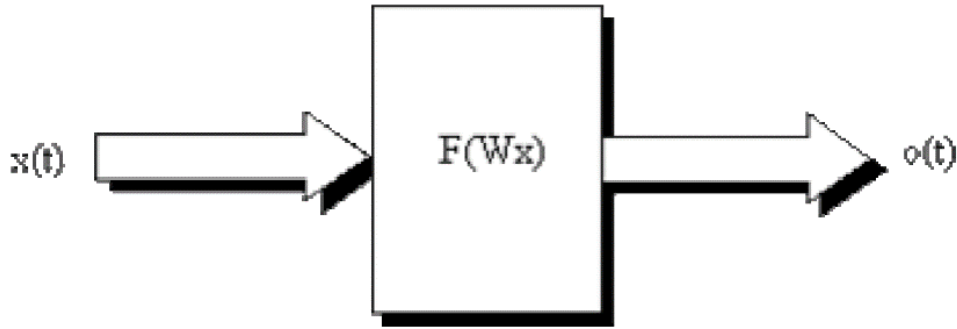
Şekil 3.3. Bir Nöron Modeli (Haykin, Neural Networks and Learning Machines, 2008)

3.2.3.1.1. Yapay Sinir Ağları Modelleri

Bir yapay sinir ağı içerisindeki hücreler ve bağlantılar farklı hücreler ile bir araya gelebilmektedir. Bu ağı içerisindeki mimariler bağlantıların yönleri veya ağı içerisindeki işaretlerin akış yönüne göre birbirinden ayrılabilir. Bu durum göz önünde bulundurulduğunda ileri beslemeli ve geri beslemeli ağlar olarak temelde iki farklı ağı mimarisi bulunmaktadır (Çuhadar, 2006).

İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli yapay sinir ağında bir hücre katman olarak düzenlenmekte ve bir katmanın içerisindeki hücrenin çıkışı bir sonraki katmana ağırlıklı olarak girdi şeklinde verilmektedir. Giriş katmanı dışarıdaki ortamdan almış olduğu bilgiyi herhangi bir değişiklik olmaksızın gizli katmanın içerisindeki hücreye iletmektedir. Bilgi, hem orta katmanda hem de çıkış katmanında işlendikten sonra ağı çıktısı belirlenmektedir. Yapı bu şekilde olduğu için ileri beslemeli ağlar genellikle doğrusal olmayan problemlerin çözümünde aktif olarak kullanılır. Aşağıdaki şekilde ileri beslemeli ağı yapısı şekil ile gösterilmiştir. (Çuhadar, 2006, s. 124).



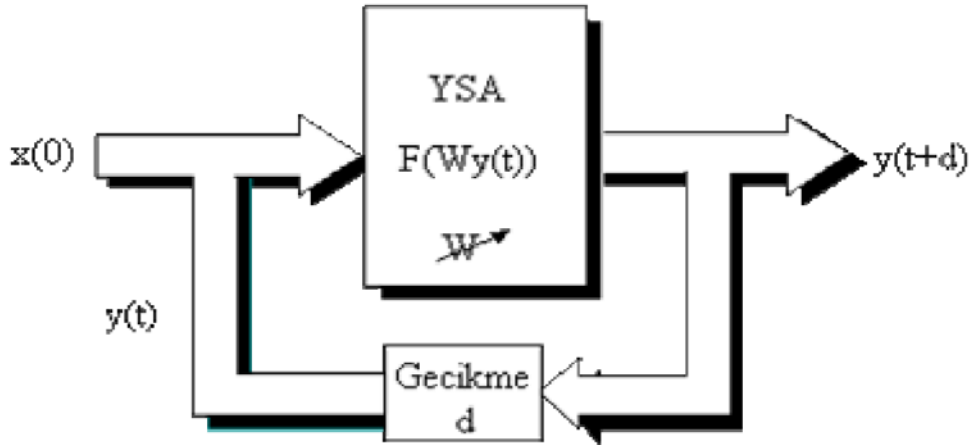
Şekil 3.4. İleri Beslemeli Yapay Sinir Ağının Blok Gösterimi (Yazıcı, 2010, s. 18)

Bu katmandaki nöronlar doğrusal olmadığı için ağı geneli doğrusal değildir. Esasen doğrusal olmayan problemlerin çözümünde daha etkin kullanılmasının temel nedeni budur. Katmanlar içerisindeki nöron sayılarının tespit edilmesi için kullanılmakta olan herhangi bir yöntem tespit edilmemiştir. Bu yüzden modelin kurulmasında nöron sayısının tespit edilmesinde deneme yanılma metodu

kullanılmaktadır. Yani model oluşturulurken nöron sayısı farklı şekillerde denenerek çıktı üzerinde yorum yapılır.

Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli ağ yapısının ileri beslemeli ağ yapısından farkı; ileri beslemeli ağlarda çıkışlardan girişlere bilgi açısı sağlanır. Ancak; geri beslemeli ağ yapısında en az bir hücrenin çıkışı kendisine ya da diğer hücrelere giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı üzerinden yapılır. Geri besleme katmanın içerisindeki hücrelerin arasında olabileceği gibi katmanların arasında bulunan hücreler içerisinde de olabilmektedir. Bu yapıdan dolayı geri beslemeli yapay sinir ağları doğrusal olmayan bir davranış sergilemektedir. Bu yapıdaki ağlara örnek olarak Hopfield Elman ve Jordan ağları örnek olarak verilebilir. Aşağıdaki şekilde ileri beslemeli ağ yapısı şekil ile gösterilmiştir.



Şekil 3.5. Geri Beslemeli Yapay Sinir Ağının Blok Gösterimi (Yazıcı, 2010, s. 19)

3.2.3.1.2. YSA' da Öğrenme Algoritmaları

Öğrenme; gözlem, eğitim ve hareketin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanmaktadır. Tıpkı biyolojik nöronlardaki gibi taklit edilen ve bilgisayar sistemlerine aktarılan nöronlarda örnek küme içerisindeki girdi ile çıktı arasında oluşturulmuş olan bağıntıdaki ağırlıkların değiştirilmesi ile eğitilebilmektedir (Öcal, 2007).

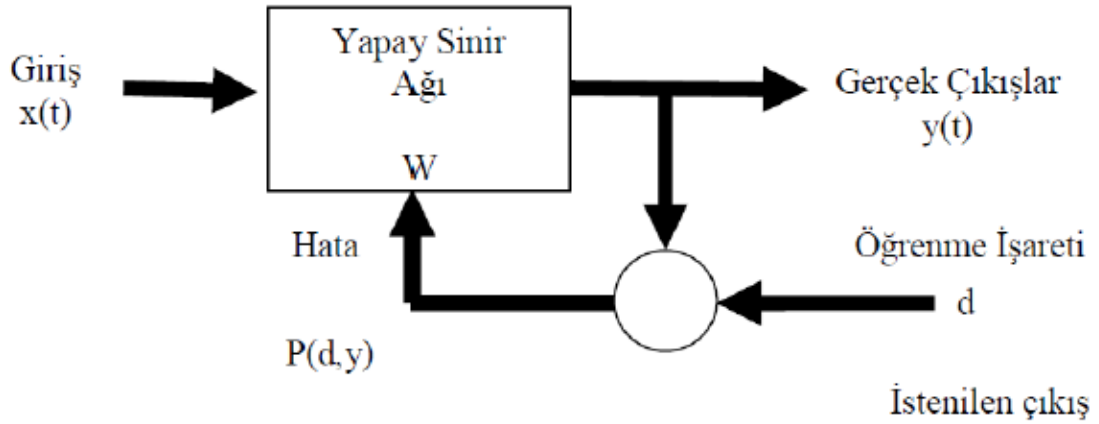
Öğrenme algoritmaları, çıktının oluşacağı değeri etkileyen ağırlığın saptanması için kullanılmaktadır. Bu ağırlık ise örnekler sayesinde belirlenebilmektedir. Katmanın

içerisindeki ağ veya ağlar karşılaştıkları problem içerisindeki her örnekte ağırlığını değiştirmektedirler.

Öğrenme kuralları temelde danışmanlı, danışmansız ve takviyeli olmak üzere üçe ayrılmaktadır.

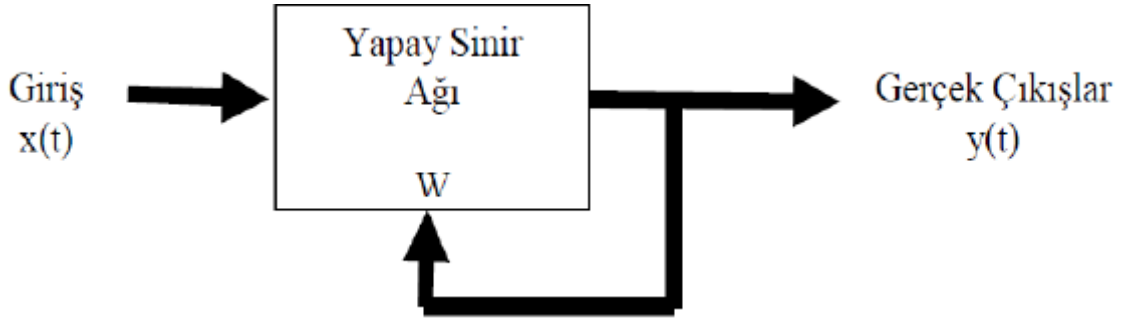
Danışmanlı Öğrenme:

Danışmanlı öğrenme yapay sinir ağları içerisinde çok fazla kullanılan bir algoritmadır. Bu algorithmada ağa verilen örneklere karşılık ağ bir çıktı sunmaktadır. Sonrasında ise ağa verilmiş olan örnekler üzerine verdiği çıktı ile üretmiş olduğu çıktı arasında bir kıyaslama yapılmaktadır. Bu iki çıktı arasındaki fark ise hatadır. İlk başta dene yanılma yolu ile ulaşılmaya çalışılan bu ağırlıklar ağ üzerindeki hatayı en aza indirmeye çalışarak bir döngüye girer. Bu metoda örnek olarak genelleştirilmiş delta kuralı ve geri besleme algoritması verilebilmektedir (Anderson & McNeill, 1992).



Şekil 3.6. Danışmanlı Öğrenme (Olgun, 2009).

Danışmansız öğrenmede sistem için herhangi bir öğretmen bulunmamaktadır. Bu nedenle bu algoritma kendi kendine öğrenebilme yeteneğine sahiptir. Burada ağ, kendisine verilmiş olan örnekler üzerinde öncesinde belirlenmiş bir kriter üzerinden veri sınıflandırması yapar. Aynı zamanda bu kriter veya kriterler öncesinde tespit edilmiş olmaya da bilir. Ağ, sahip olduğu bu kriteri kendi oluşturabilmektedir. Burada en önemli nokta sistemin parametreler üzerindeki bağlantıları kendisinin öğrenmesi beklenilir. Diğer öğrenme şekillerine göre daha hızlı ve daha basit bir şekilde uygulanır (Deveci, 2012).



Şekil 3.7. Danışmansız Öğrenme (Olgun, 2009)

Takviyeli Öğrenme:

Takviyeli öğrenmede; danışmanlı öğrenme sistemine yakın bir yöntem uygulanır. Burada ağ içerisinde öğretmen bulunmaz ancak ağın üretmiş olduğu çıktı doğru ya da yanlış olarak ağa iletilir. Temelde bir destekleme sistemi uygulanmaktadır. Sonucun verildiği her döngü içerisinde sonucun doğruya veya yanlışa ne kadar yaklaştığı bilgisi verilir. Ağ ise bu dönüş bilgilerini değerlendirerek doğru çıktıya ulaşmaya çalışır (Deveci, 2012).

4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Bu bölümde çalışmanın uygulama kısmı anlatılacaktır. Uygulamanın yapılabilmesi için verilerin sınıflandırılması gerekmektedir. Bu yüzden öncelikle veriler düzenlenmiş, sonrasında ise bu veriler üzerinden YSA modeli kurularak tahmin gerçekleştirilmiştir.

4.1. Veri Sınıflandırması

Verilerin düzenlenmesinde veri madenciliği alanında uygulanan IBM Modeler 17.1 programı kullanılmıştır.

Veriler Konya bölgesinde üretim yapan 24 adet güneş enerji santrallerine ait saatlik üretim verilerinden oluşmaktadır. Buna ek olarak üretim verileri ile aynı dönemi kapsayacak şekilde hava durumu verileri kullanılmıştır. Bu hava durumu verileri sıcaklık, nem, rüzgar hızı, rüzgar yönü, bulutluluk, radyasyon ve yağış verilerinden oluşmaktadır. Lokasyon özelinde hava durumu verilerinin temin edilmesi zor olduğu için çalışmada Konya genelindeki hava durumu verileri bütün santraller için aynı kullanılmak zorunda kalmıştır. Lokasyona göre bir hava durumu verisi ile aynı çalışmaların yapılması durumunda daha başarılı sonuçların elde edilmesi beklenir. Bununla birlikte hava durumu verilerindeki ölçüm hassasiyetleri ve kullanılan

metotların sonucu olarak veri kalitesinin daha düşük olduğu, tamamlanması gereken verilerin daha fazla olduğu söylenebilir. Üretim verileri ise doğrudan doğruya uzlaştırmaya esas ölçüm yapan sayaç verilerine dayandığı için doğruluğu ve hassasiyeti çok daha yüksektir. Daha önceki çalışmalarda ve alandaki uzmanlardan alınan bilgiye göre üretim değerini etkileyen parametreler arasında hava durumu verilerine ek olarak panel açısı, panel tipi, marka, model gibi parametreler de bulunmaktadır. Fakat bahsedilen parametrelerin olmaması nedeni ile bu çalışmada bu parametreler kullanılamamıştır.

Mevcut Yenilenebilir Enerji Kaynakları Destekleme Mekanizması (YEKDEM) yönetmeliğine eklenen 13.12.2011 tarihli ve 7522-1 sayılı kurul kararı ile belirlenmiş olan tolerans katsayısının uygulanmaya başlamasından sonra lisansız üreticiler adına görevli tedarik şirketlerinin lisansız üretim tahmini yapması bir anlamda zorunlu hale getirilmiştir. Bu süreçten sonra lisanssız santrallere ilişkin üretim tahmininin yapılması için bilimsel yöntemler uygulanmaya çalışılmıştır. Bu çalışmada ise güneş enerjisi üretim tahmini için modeller denenmiş ve uygun olan model bulunmaya çalışılmıştır.

İlk olarak veri setinin analizi yapılmıştır. Bu analiz sonucunda veriler üzerinde aykırı ve uç değerlerin sayısı ve tanımsız değerlerin ve toplam kayıt sayısı gibi değerler ölçülmüş, sonucunda ise müdahale edilmesi gereken veriler belirlenmiş ve gerekli düzeltmeler yapılmıştır. Örnek olarak üretim parametresinde tanımsız değer olması durumunda önceki ve sonraki saatler için ortalama değer ile tamamlama işlemi yapılabildiği gibi birkaç saatlik ardışık tanımsız değer olması durumunda ilgili gün için aynı kurulu güçte ve diğer saatlerde benzer üretim yapan santrallerin verisi tamamlama için kullanılabilir. Aykırı ve uç değerlerde ise alt limit ve üst limitler kullanılarak Şekil 4.1. ve Şekil 4.2.'deki gibi düzenlenmiştir.

Data Audit of [36 fields]

File Edit Generate

Audit Quality Annotations

Complete fields (%): 97.22% Complete records (%): 72.38%

Field	Measurement	Outliers	Extremes	Action	Impute Missing	Method	% Complete	Valid Records	Null Value	Empty String	White Space	Blank Value
Yil	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
AY	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
GUN	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
SAAT	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Time	Nominal	---	---	Never	Fixed	100	13176	0	0	0	0	0
TOPLAM	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Temperature	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
RelativeHum	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
WindSpeed	Continuous	61	1 Coerce	Never	Fixed	100	13176	0	0	0	0	0
WindDirection	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
CloudCover	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Radiation	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Precipitation	Continuous	29	32 Coerce	Never	Fixed	72.382	9537	3639	0	0	0	0
Santral 1	Continuous	7	4 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 2	Continuous	8	3 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 3	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 4	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 5	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 6	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 7	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 8	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 9	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 10	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 11	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 12	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 13	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 14	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 15	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 16	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 17	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 18	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 19	Continuous	0	1 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 20	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 21	Continuous	2	1 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 22	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 23	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 24	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0

Şekil 4.1. Veri Seti

Data Audit of [36 fields] #5

File Edit Generate

Audit Quality Annotations

Complete fields (%): 100% Complete records (%): 100%

Field	Measurement	Outliers	Extremes	Action	Impute Missing	Method	% Complete	Valid Records	Null Value	Empty String	White Space	Blank Value
Yil	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
AY	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
GUN	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
SAAT	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Time	Nominal	---	---	Never	Fixed	100	13176	0	0	0	0	0
TOPLAM	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Temperature	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
RelativeHum	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
WindSpeed	Continuous	61	1 None	Never	Fixed	100	13176	0	0	0	0	0
WindDirection	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
CloudCover	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Radiation	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Precipitation	Continuous	31	77 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 1	Continuous	7	4 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 2	Continuous	8	3 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 3	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 4	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 5	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 6	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 7	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 8	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 9	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 10	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 11	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 12	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 13	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 14	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 15	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 16	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 17	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 18	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 19	Continuous	0	1 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 20	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 21	Continuous	2	1 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 22	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 23	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0
Santral 24	Continuous	0	0 None	Never	Fixed	100	13176	0	0	0	0	0

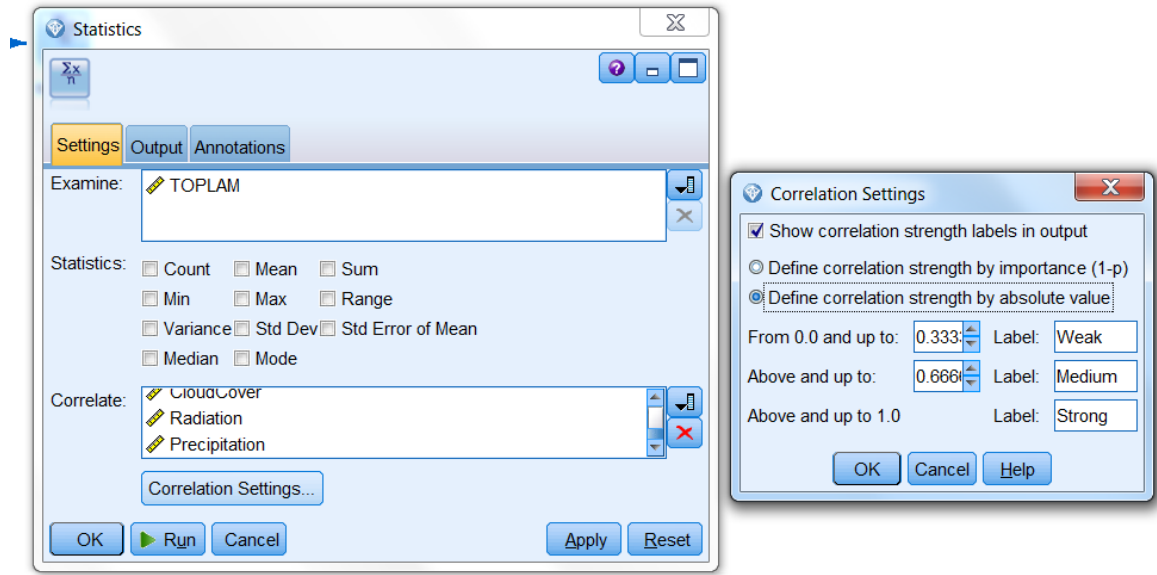
Şekil 4.2. Düzenlenmiş Veri Seti

Şekil 4.3.'te görüldüğü gibi bahsedilen düzenlemeler yapıldıktan sonra verinin tekrar analiz edilmesi sonucu aşağıdaki sonuçlara ulaşılmıştır. Veriler arasında halen aykırı ve uç değerler olduğu gözlemlenmektedir. Bu beklenen bir durumdur. Çünkü yapılan düzeltme işleminden sonra verinin yapısı değiştiği için buna bağlı olarak sınırlar daraltılmış olarak tekrar belirlenmiştir. Daha önceki düzeltme işleminde önceki sınırlara getirilen değerlerin yeni durumda oluşan sınırların dışında kalması veri üzerinde yapılacak çalışmalara engel teşkil etmemektedir. Zaman serisi ile çalışılırken bu şekildeki durumlarda yeniden düzenleme yapılmasına gerek duyulmamaktadır.

Field	Measurement	Outliers	Extremes	Action	Input Missing	Method	% Complete	Valid Records	Null Value	Empty String	White Space	Blank Value
YIL	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
AY	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
GUN	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
SAAT	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Time	Nominal	--	---	Never	Fixed	Never	100	13176	0	0	0	0
TOP_LAM	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Temperature	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
RelativeHum	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
WindSpeed	Continuous	84	0 None	Never	Fixed	Never	100	13176	0	0	0	0
WindDirection	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
CloudCover	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Radiation	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Precipitation	Continuous	1	217 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 1	Continuous	7	4 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 2	Continuous	8	3 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 3	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 4	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 5	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 6	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 7	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 8	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 9	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 10	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 11	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 12	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 13	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 14	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 16	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 17	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 18	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 19	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 20	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 21	Continuous	2	1 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 22	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 23	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0
Santral 24	Continuous	0	0 None	Never	Fixed	Never	100	13176	0	0	0	0

Şekil 8 İkinci Kere Düzenlenen Veri Seti

Veri düzenlendikten sonra YSA ile çalışmalar yapılırken parametre fazlalığından dolayı bu YSA denemelerini azaltabilmek adına güçlü olan parametrelerin belirlenmesi için korelasyon analizi yapılmıştır. Yani, hava durumu verileri ile güneş enerjisi üretimi arasındaki bağlantıyı görebilmek için korelasyon testi yapılmış, güçlü olan parametreler ile YSA modeli kurulmuştur. Şekil 4.4. te görüldüğü üzere 24 santralin üretim toplamını ifade eden toplam parametresi ile hava durumu verileri olarak ifade edilen 7 farklı parametrenin korelasyon testi yapılmıştır. Bunun yanı sıra zaman serileri ile çalışırken verinin içindeki mevsimselliğin anlaşılabilmesi adına yıl-ay-gün saat gibi parametrelerin daha önceki çalışmalarda önemli olduğu bilindiğinden dolayı bu parametreler de korelasyon testine eklenmiştir. Bu test esnasında 0-0,33 arasındaki değerler zayıf, 0,33-0,66 arasındaki değerler orta, 0,66 ile 1 arası da güçlü korelasyon olarak kabul edilmiştir. Korelasyon sonucunun eksi veya artı çıkması değişkenler arasında ters yönlü veya aynı yönlü bir ilişki olduğunun göstergesidir. Korelasyon sonucunun 1 veya -1 e yakınlığı korelasyonun gücünü göstermektedir. Bu kabuller ışığında yapılan korelasyon testinin sonuçları Şekil 4.5. te gösterilmektedir. Rüzgar yönü ile güneş enerjisi arasında bağlantı olması beklenmeyen bir durum iken korelasyon analizi ile bu durum pekiştirilmiştir.



Şekil 4.4. Kolerasyon Testi

The image shows a window titled 'Statistics of [TOPLAM][11 fields] #3'. It has a menu bar with 'File', 'Edit', and 'Generate'. Below the menu bar are tabs for 'Statistics' and 'Annotations'. There are also buttons for 'Collapse All' and 'Expand All'. The main content area shows a tree view with 'TOPLAM' expanded to show 'Pearson Correlations'. Below this is a table with three columns: the field name, the correlation coefficient, and the strength label.

Field	Correlation Coefficient	Strength Label
YIL	-0.001	Weak
AY	-0.002	Weak
GÜN	0.007	Weak
SAAT	0.063	Weak
Tempreature	0.307	Weak
RelativeHumidity	-0.341	Medium
Wind Speed	0.114	Weak
WindDirection	-0.285	Weak
CloudCover	-0.097	Weak
Radiation	0.890	Strong
Precipitation	-0.052	Weak

Şekil 4.5. 9Kolerasyon Testi Sonuçları

Çizelge 4.1 Korelasyon Testi Sonuçları

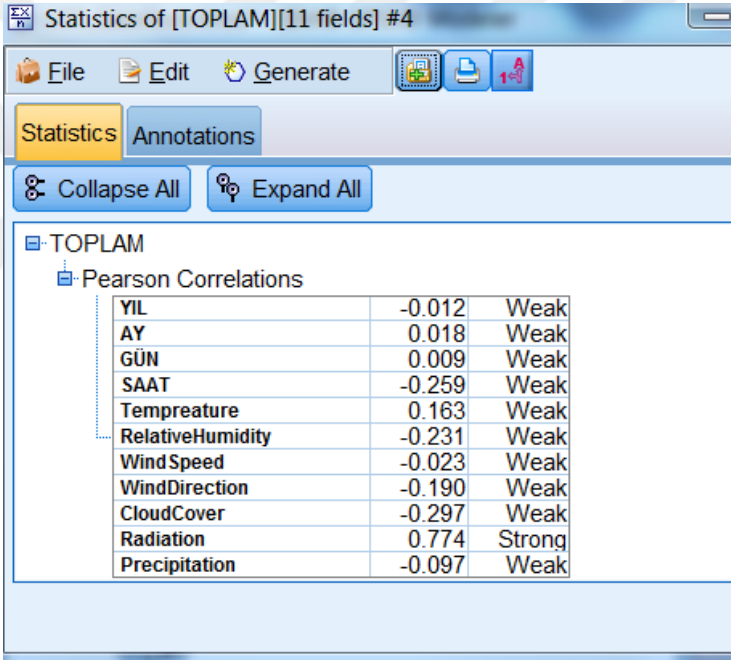
Parametre	Değer	Derece
Yıl	-0,001	Zayıf
Ay	-0,002	Zayıf
Gün	0,007	Zayıf
Saat	0,063	Zayıf
Sıcaklık	0,307	Zayıf
Nem	-0,341	Orta
Rüzgar Hızı	0,114	Zayıf
Rüzgar Yönü	-0,285	Zayıf
Bulutluluk	-0,097	Zayıf
Radyasyon	0,890	Güçlü
Yağış	-0,052	Zayıf

Görüldüğü üzere güneş enerji santrallerinden üretilen enerjinin radyasyon değeri ile güçlü ve aynı yönlü bir ilişkisi, nem ile ise orta derecede ve ters yönlü bir ilişkisi bulunmaktadır. Korelasyon testine göre diğer parametreler ile GES üretimleri arasında anlamlı bir ilişki bulunmadığı kabul edilir. Daha önce de belirtildiği üzere diğer parametreler YSA denemelerinin dışında tutularak model kurulumu yapılmıştır. Bulutluluk parametresi ile düşük korelasyon çıkması temel beklentinin dışındadır. Bunun nedeninin radyasyon değerinin aksine GES üretiminin olmadığı saatlerde de bulutluluk değerinin sıfırdan farklı olması olabileceği düşüncesi ile yalnızca aydınlık saatleri içeren bir zaman serisi üzerinde tekrardan korelasyon testi yapılmıştır. Bu test sonucunda da bulutluluk parametresi ile GES üretimleri arasında anlamlı bir ilişki olmadığı görülmüştür. Bu nedenle YSA denemelerinde modellere bulutluluk parametresi dahil edilmemiştir. Sonuç olarak bulutluluk durumu radyasyon değerini etkileyeceği için temel beklenti ile sonuçlar paralellik gösterecektir.

İkinci kere yapılan korelasyon sonuçları Şekil 4.6.'da ve aşağıdaki tabloda gösterildiği gibidir.

Çizelge 1.2 İkinci Kere Yapılan Korelasyon Testi Sonuçları

Parametre	Değer	Derece
Yıl	-0,012	Zayıf
Ay	0,018	Zayıf
Gün	0,009	Zayıf
Saat	0,259	Zayıf
Sıcaklık	0,163	Zayıf
Nem	-0,231	Zayıf
Rüzgar Hızı	0,023	Zayıf
Rüzgar Yönü	-0,190	Zayıf
Bulutluluk	-0,297	Zayıf
Radyasyon	0,774	Güçlü
Yağış	-0,097	Zayıf



Variable	Correlation	Strength
YIL	-0.012	Weak
AY	0.018	Weak
GÜN	0.009	Weak
SAAT	-0.259	Weak
Temperature	0.163	Weak
RelativeHumidity	-0.231	Weak
Wind Speed	-0.023	Weak
WindDirection	-0.190	Weak
CloudCover	-0.297	Weak
Radiation	0.774	Strong
Precipitation	-0.097	Weak

Şekil 10.6. İkinci Kere Yapılan Korelasyon Testi Sonuçları

4.2. Tahmin Uygulaması

Veri seti kurulduktan sonra ve hangi parametrelerin YSA modelinde kullanılacağına karar verildikten sonra YSA içerisindeki algoritmalar ve fonksiyonlar üzerinde çalışılmış, problem özelinde en uygun olan model oluşturulmuştur.

Çalışma içerisinde yapay sinir ağlarında IBM Modeler 17.1 programı kullanılmıştır.

Öğrenme katsayısının belirlenmesi:

Öğrenme katsayısı YSA' nın öğrenme durumunu etkileyen önemli faktörlerden biridir. Öztemel in 2003 yılında yaptığı çalışmada belirttiği üzere literatürde genellikle tahmin çalışmaları için öğrenme katsayısı 0,2 ile 0,4 arasında belirlenmektedir. Öğrenme katsayısının küçük seçilmesi öğrenme süresini artırırken, büyük seçilmesi ise ağ içerisindeki dolaşma süresini artırmaktadır. Bu çalışmada ise öğrenme katsayısı 0,9 olarak belirlenmiştir.

Nöron sayısının belirlenmesi:

Nöron sayısı çalışma içerisinde deneme yanılma yöntemi ile belirlenmiştir. Nöron sayısının az olduğunda ağ içerisindeki genelleme düzeyinin arttığı, fazla nöron sayısı olduğu zaman ise verilerin ezberlendiği tespit edilmiştir. Bu yüzden nöron sayısı 1 ile 20 arasında denenmiştir.

Çevrim sayısının belirlenmesi:

Ağ gerekli olan öğrenmeyi sağladıktan sonra çevrimlerde bir iyileştirme sağlanmayacağı için çevrim sayısının gerekli olan sayı belirlenmesi süredeki etkinlik için önemlidir. Ayrıca çevrim sayısının fazla olması nöron sayısı gibi ağın ezberlemesine neden olabileceği için fazla belirlenmemesi önemlidir. Bu çalışmada çevrim sayısı 1000 olarak düzenlenmiştir.

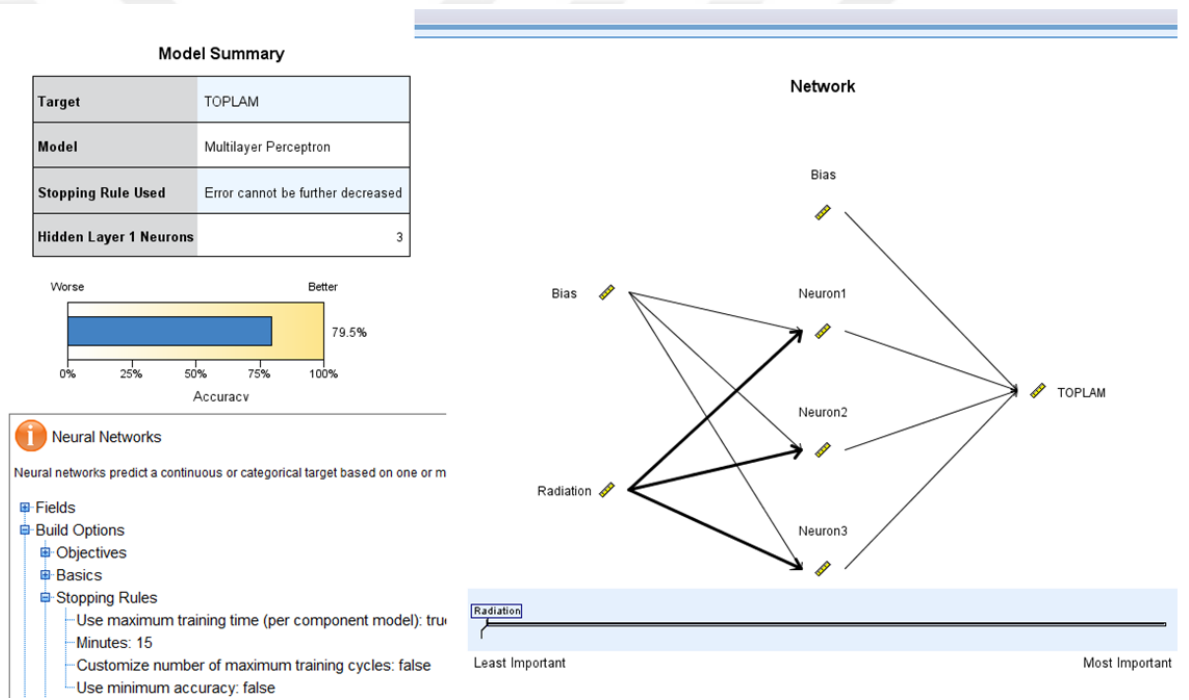
Momentum katsayısının belirlenmesi:

Literatürde bulunan çalışmalara göre momentum katsayısının 0,6 ile 0,8 arasında tercih edilmesinin daha doğru olduğu kaydedilmiştir (Öztemel, 2012). Bu çalışma için yapılan denemeler doğrultusunda momentum katsayısının 0,6 olması uygun görülmüştür.

Zaman serisi çalışmalarında uzun dönemli verinin olması kurulan modellerin performansını artıracaktır. Data içerisindeki mevsimselliklerin -günlük aylık yıllık- bulunabilmesi, model tarafından öğrenilebilmesi için de uzun dönemli veri ile çalışmak daha sağlıklı olacaktır. Güneş enerjisi üretim verileri tüketim verisi gibi günlük değişiklik göstermeyip mevsimlere bağlı olarak aylık ve yıllık değişikliklerden etkileneceği varsayılmaktadır. Bu çalışma konusunun seçilmesindeki en önemli

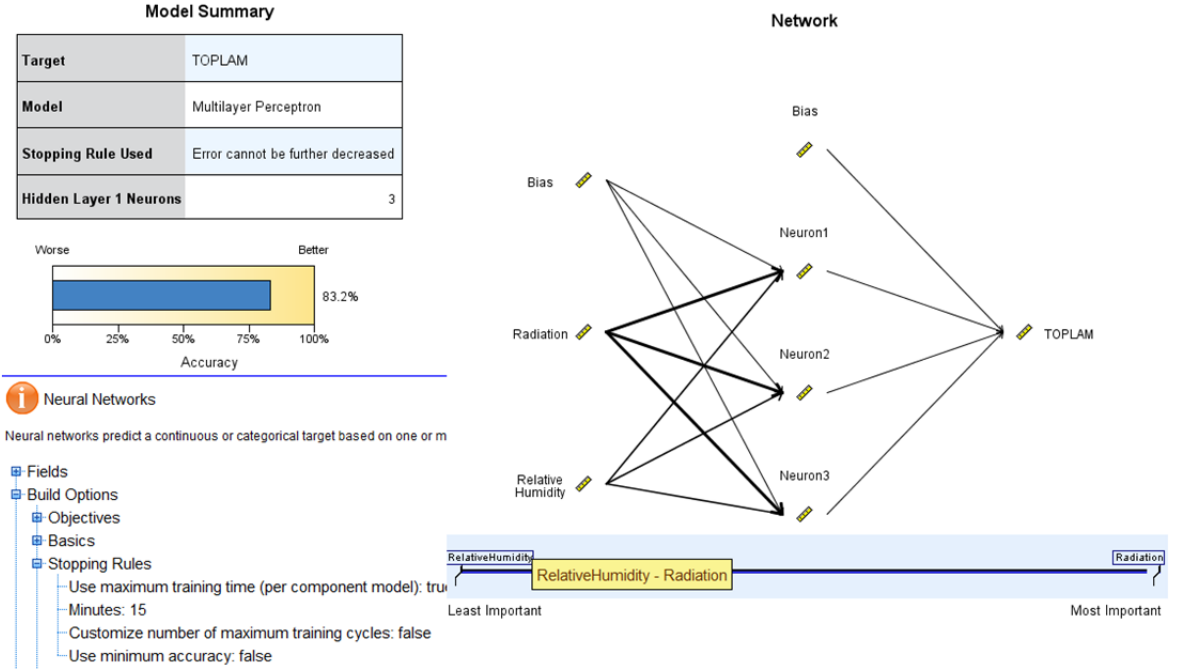
gereksinim olan lisanssız üretim tahminlerini zorunlu kılan yönetmelik gereği şirketlerin 48 ile 96 saatlik (2-4 gün) tahminler yapması gerekmektedir. Bu nedenle modeller yazılım üzerinde kurulurken son 96 saatlik veriyi kullanmadan belirlenen durma kuralları çerçevesinde denemeler yapılmış, son 96 saatlik veri kısmı için üretilen tahminler gerçek verilerle karşılaştırılarak Mutlak yüzde hata ortalama hesaplanmıştır. Mutlak yüzde hata ortalama sonuçlarına göre en başarılı sonucu üreten model gösterilmiştir. Belirtilen kurallar çerçevesinde farklı parametrelerin girdi olarak kullanıldığı ve en başarılı sonucu üreten modellerin gösterimi aşağıdaki gibidir.

1. Yalnızca radyasyon (Radiation) kullanılarak YSA modeli kurulmuştur. Üretilen tahminler “\$N-R” olarak isimlendirilmiştir.



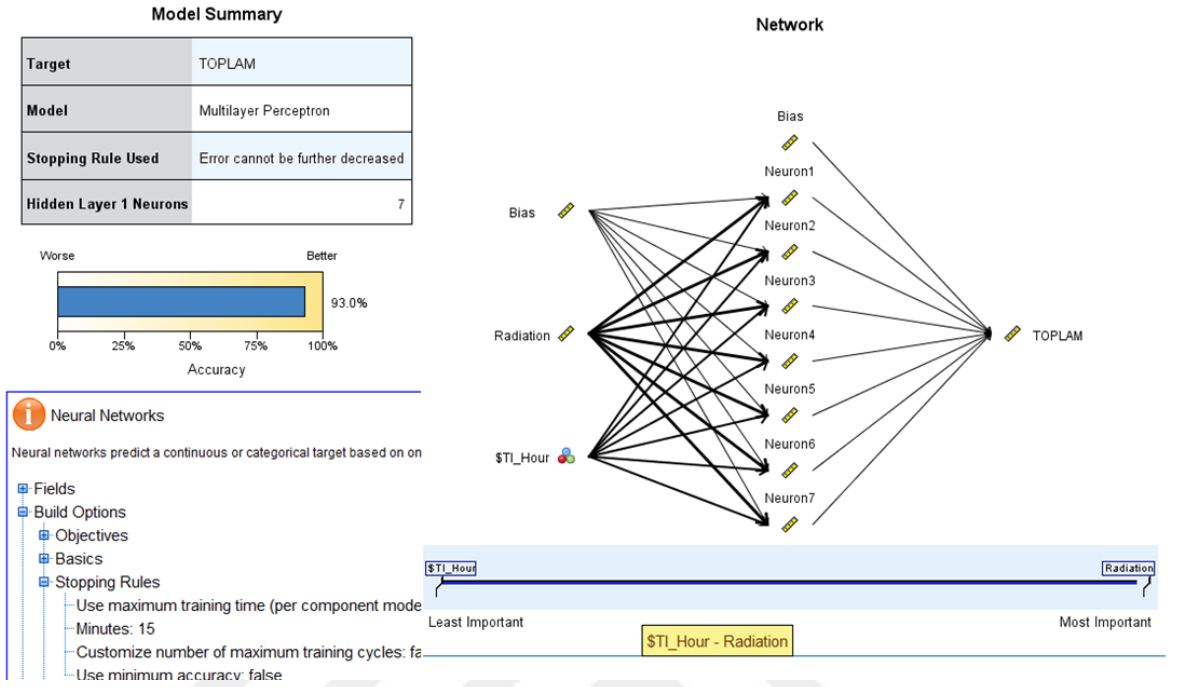
Şekil 4.7. Birinci YSA Modeli

2. Radyasyon (Radiation) ve nem (RelativeHumidity) kullanılarak YSA modeli kurulmuştur. Üretilen tahminler “\$N-R_RH” olarak isimlendirilmiştir.



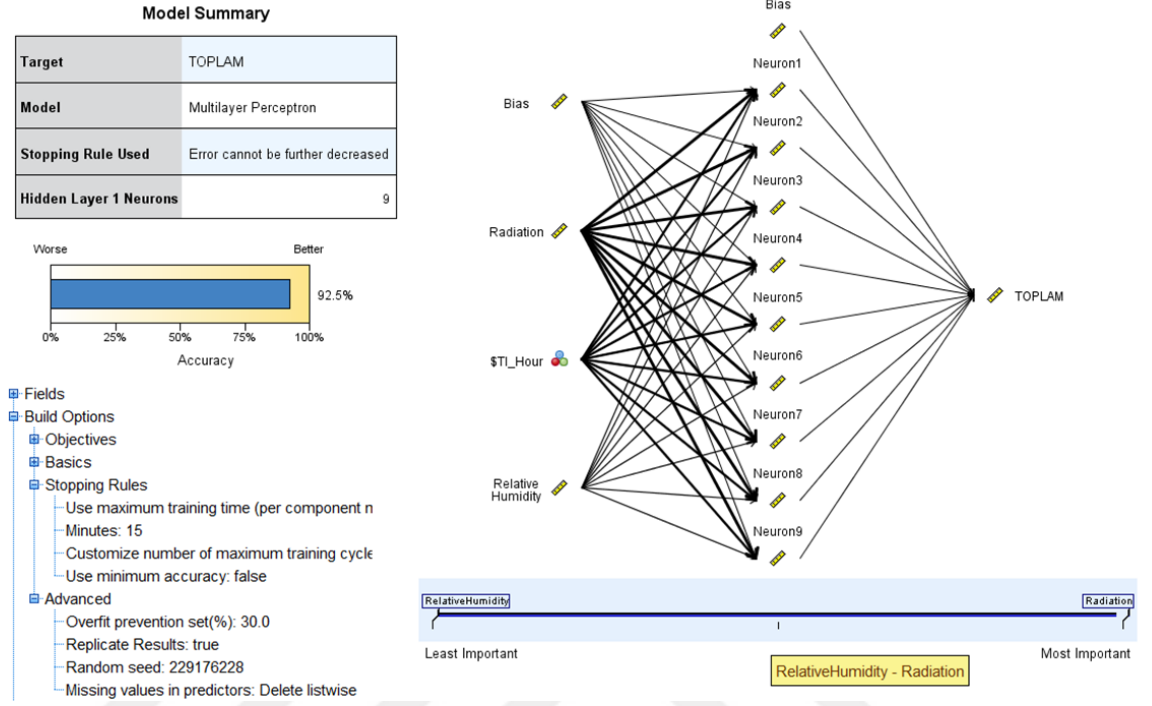
Şekil 4.8. İkinci YSA Modeli

3. Radyasyon (Radiation) ve saat (Hour) kullanılarak YSA modeli kurulmuştur. Üretilen tahminler “\$N-R_H” olarak isimlendirilmiştir.



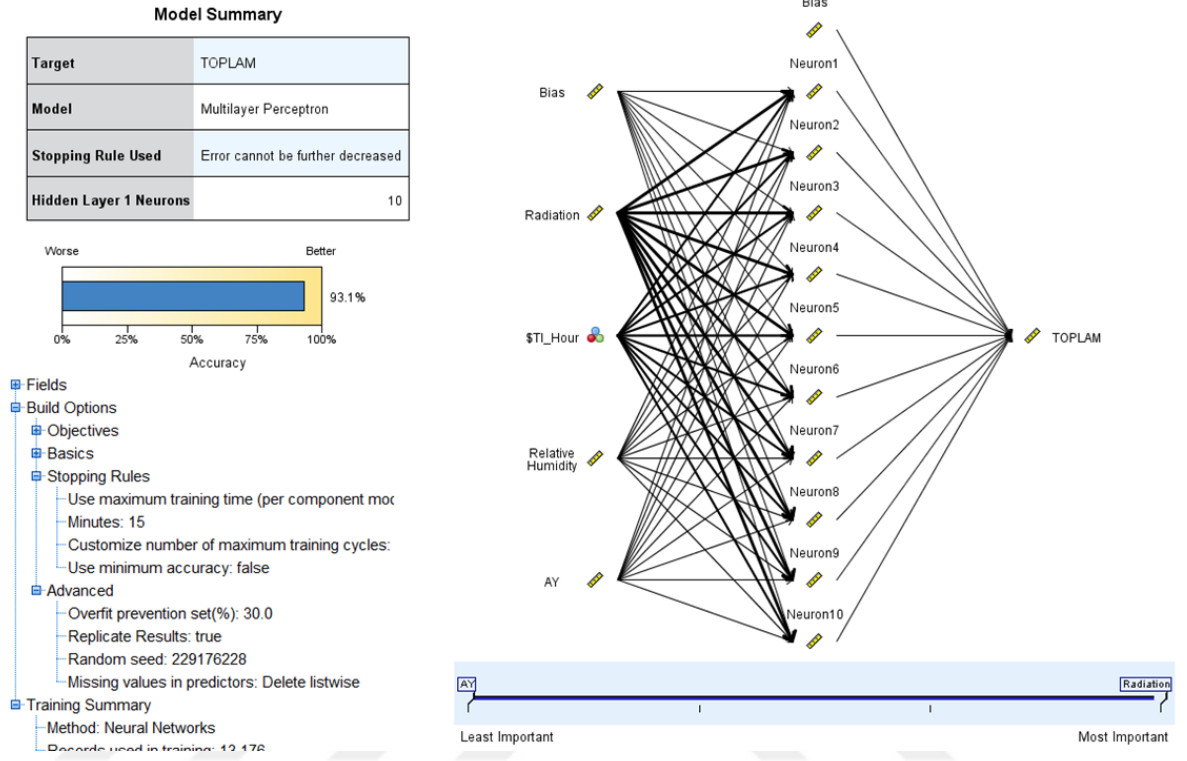
Şekil 4.9. Üçüncü YSA Modeli

4. Radyasyon (Radiation), nem (RelativeHumidity) ve saat (Hour) kullanılarak YSA modeli kurulmuştur. Üretilen tahminler “\$N-R_RH_H” olarak isimlendirilmiştir.



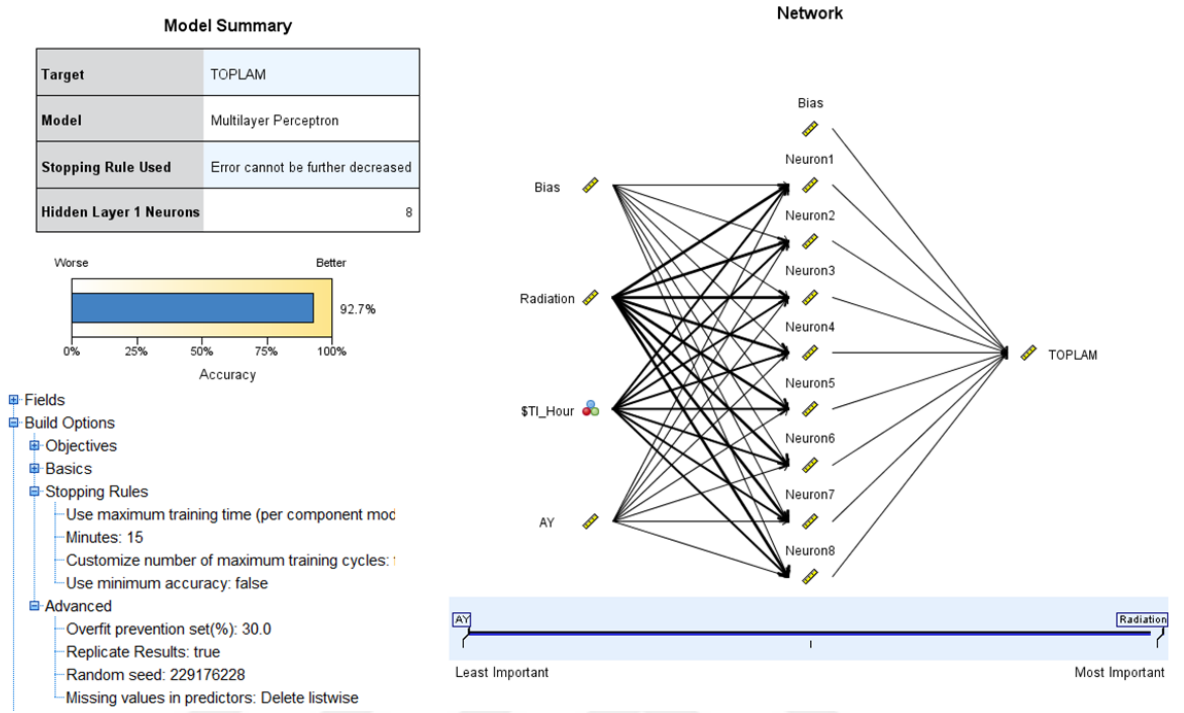
Şekil 4.10. Dördüncü YSA Modeli

5. Radyasyon (Radiation), nem (RelativeHumidity), saat (Hour) ve AY kullanarak YSA modeli kurulmuştur. Üretilen tahminler “\$N-R_RH_H_A” olarak isimlendirilmiştir.



Şekil 4.11. Besinci YSA Modeli

6. Radyasyon (Radiation), saat (Hour) ve ay kullanılarak YSA modeli kurulmuştur. Üretilen tahminler “\$N-R_H_A” olarak isimlendirilmiştir.



Şekil 4.12. Altıncı YSA Modeli

5. SONUÇLAR VE ÖNERİLER

Çalışmanın bu bölümünde Konya bölgesinde uygulaması yapılan güneş enerjisi üretim tahmini probleminin sonuçları sunulmuş olup literatüre katkı sağlayacak olan sonraki çalışmalar için önerilerde bulunulmuştur.

5.1 Sonuçlar

Bu modeller kurulup çalıştırıldığında son 4 gün için üretilen tahminlerin saatlik mutlak hata toplamları ve Ağırlıklı ortalama sapmaları aşağıdaki tabloda gösterilmiştir.

Çizelge 5.1. Tahmin Sonuçları

MODEL	R	R_RH	R_H	R_RH_H	R_RH_H_A	R_H_A
Toplam Hata Miktarı (kWh)	140,9	97,447	34,818	29,187	30,462	46,228
Ağ. Ort. Sapma(%)	23.83%	16.48%	5.89%	4.94%	5.15%	7.82%

Toplam 4 günlük üretim miktarı 591373.555 kWh olarak gerçekleşmiştir. Bu sonuçlara göre en az hata ile dördüncü model olan R_RH_H modeli en iyi sonucu vermiştir. Buradan hareketle güneş enerjisi santrallerinin üretim tahmini yapılırken en kritik parametrelerin radyasyon, nem ve saat verileri olduğu ortaya çıkmıştır. Üretim miktarını etkileyen en kritik parametrelerin radyasyon ve saatler olması beklenen bir durumdur. Temelde GES üretim teknolojisinde; ışıma nedeniyle oluşan enerji, elektrik enerjisine çevrilmektedir. Saatlerin üretim miktarına etki etmesi de ışıma ile paralellik göstermektedir. Güneş ışınlarının olduğu aydınlık saatlerde ışıma varken karanlık saatlerde ışıma değeri 0 olmaktadır. Çalışma esnasında da bu beklenti üzerinden yalnızca aydınlık saatleri içeren seri üzerinden tahmin denemeleri yapılmıştır. Günün saatlerine göre ışıma değerleri benzerlik göstermektedir. İlk bakışta bulutluluk parametresinin de yüksek korelasyonda olması beklenebilir fakat kış aylarında üretim miktarları düşük gerçekleşirken havanın bulutlu olması çok büyük bir etki göstermezken yaz aylarında bulutlu olması ciddi bir etki yapabilmektedir. Bu nedenle bulutluluk ile üretim miktarları arasındaki korelasyon azalmaktadır. Buna ek olarak çalışma performansını etkileyebileceği düşünülen fakat çalışmada girdi olarak kullanılmayan farklı değişkenler de bulunmaktadır. Teoride üretim miktarı hesaplanırken panelin kirli olup olmaması veya kış aylarında karla kaplı olup olmaması parametre olarak kullanılamamıştır. Örneğin bütün parametreleri aynı olan iki santralin birinde kış aylarında panellerin üstünün karla kaplı diğerinde ise karların temizlenmiş

olduđu düşünülürse karla kaplı olan santralin üretim miktarının karları temizlenmiş olan santrale göre daha düşük gerçekleşmesi beklenmektedir. Bu çalışma esnasında girdi olarak kullanılmayan parametrelerin bütün santraller için ideal üretim şartlarında olduđu varsayılmıştır. Üretim miktarına etki edeceđi düşünölen bu ve benzeri parametrelerin sayısı artırılarak çalışmanın tekrar yapılması durumunda performansın artması beklenmektedir. Santral sahiplerinin oksijenli su ile haftalık veya 15 günlük periyotlarla verimlerini arttırmak için panelleri temizlediđi bilinmektedir. Mevcut piyasada faaliyet gösteren santral sahipleri verimi yükseltmek için SCADA (Danışmalı Kontrol ve Veri Toplama Sistemi) sistemleri ile anlık olarak üretim miktarlarını izlemekte ve beklenmedik durumlar oluşması halinde müdahale etmektedir. Burada bahsedilen etkinin büyüklüđu bu bilgiden yola çıkılarak anlaşılabilir. Çalışmada hangi günlerde bakım ve temizlik yapıldıđı bilgisinin de eklenmesi durumunda verimin temizlik yapılan günde maksimum seviyede olup bir sonraki bakım gününe kadar düşmesi bekleneceđi için parametre olarak eklenmesinin de olumlu etki yapacağı beklenmektedir.

5.2. Öneriler

Bu çalışmanın sonrasında yapılan çalışmalarda bu çalışmada korelasyon analizi sonucu modele alınmayan parametreler eklenip ayrıca model kurulup sonuçlar değerlendirilebilir. Ayrıca verilerin eksiksiz ve hatasız olması konusunda daha dikkatli davranılarak testler yapılabilir. Bunun yanında panel açısı, marka, model v.b. parametreler de eklenerek tahminlerin yapılması faydalı olacaktır. Çalışma esnasında bu veriler temin edilemediđi için modellere eklenememiştir. Çalışmada aydınlık saatler olarak bahsedilen seri için daha fazla deneme yapılması da daha başarılı bir modelin ortaya çıkmasını sağlayabilir. Bunlara ek olarak bakım-temizlik yapılan günlere dikkat edilerek modeller oluşturulup sonuçlar kıyaslanabilir.

KAYNAKLAR

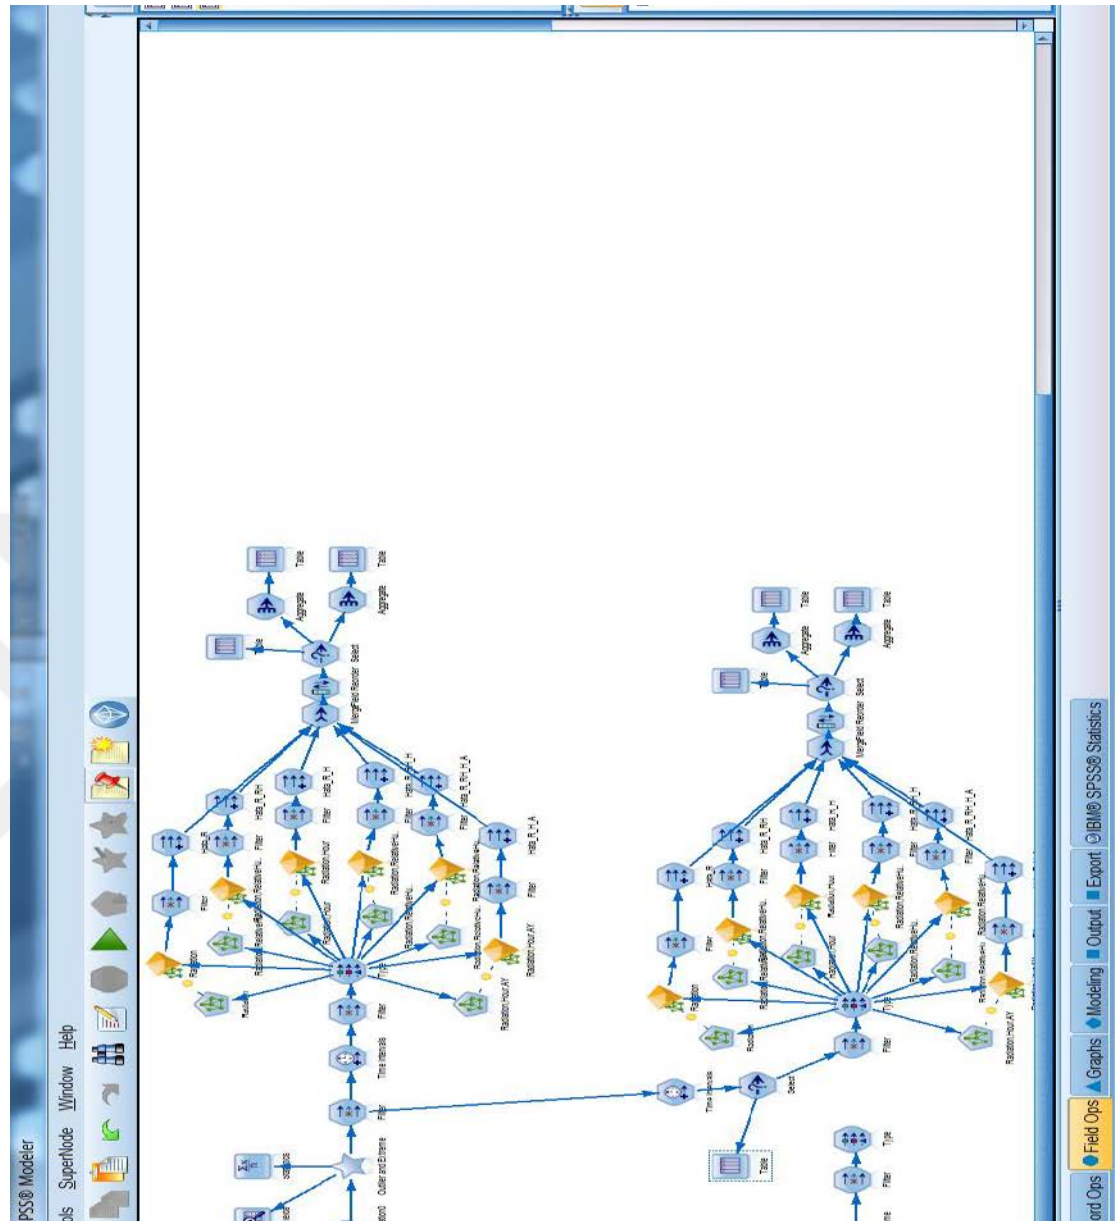
- Ahmed, E. A., Adam, M. E.-N., 2013, Estimate of Global Solar Radiation by Using Artificial Neural Network in Qena, Upper Egypt. *Journal of Clean Energy Technologies*, 148-150.
- Alan, E., 2013, Yapay Sinir Ağları Yaklaşımı ile Cürüflarda Fosfor Kapasitelerinin İncelenmesi. İstanbul: İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.
- Anderson, D., McNeill, G., 1992, *Artificial Neural Networks Technology*. New York: Rome Laboratory.
- Bahadır, Y., 2013, Cam Elyaf Katkılı Cephe Kaplama Elemanlarına Yönelik Teklif Fiyatı Tahmininde Yapay Sinir Ağlarının (YSA) kullanılması. İstanbul: İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.
- Basheer, I. A., Hajmeer, M., 2000, Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, 3-31.
- Çuhadar, M., 2006, Turizm Sektöründe Talep Tahmini İçin Yapay Sinir Ağları Kullanımı Ve Diğer Yöntemlerle Karşılaştırmalı Analizi (Antalya İlinin Dış Turizm Talebinde Uygulama). Isparta: Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Doktora Tezi.
- Deveci, M., 2012, Yapay Sinir Ağları ve Bekleme Süresinin Tahmininde Kullanılması. Ankara: Gazi Üniversitesi Sosyal Bilimler Enstitüsü.
- Elazouni, A. M., Nosair, I. A., Mohieldin, Y. A., 1997, Estimating Resource Requirements at Conceptual Design Stage Using Neural Networks. *Journal of Computing in Civil Engineering*, 217-223.
- Ercanli, İ., & Bolat, F., 2017, Diameter Distribution Modeling Based on Artificial Neural Networks For Kunduz Forests. *International Symposium on New Horizons in Forestry*, 238-241.
- Faucett, L. V., 1994, *Fundamentals Of Neural Networks*. Prentice-Hall, New Jersey.
- Frechtling, D., 2012, *Forecasting tourism demand*. Routledge.
- Gürsoy, A., 2012, Yapay Sinir Ağları Yaklaşımıyla Lastik Kalıbı Maliyetinin Tahmin Edilmesi. Kocaeli: Kocaeli Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.
- Haykin, S., 1994, *Neural Networks: A Comprehensive Foundation*. New York: Prentice Hall PTR Upper Saddle River.

- Haykin, S., 2008, Neural Networks and Learning Machines. New York: Pearson Prentice Hall.
- Hiyama, T., Kouzuma, S., Imakubo, T., 1995, Identification of Optimal Operating Point of PV Modules Using Neural Network for Real Time Maximum Power Tracking Control. IEEE Transactions on Energy Conversion, 360-367.
- Işık, E., 2011, Tunceli İli İçin Güneş Işınımının Yapay Sinir Ağları İle Tahmini. Engineering Sciences, 190-194.
- Kasaplı, K., 2014, İçmesuyu Şebekelerinde Maliyet Tahmini Amacıyla Yapay Sinir Ağları Kullanımı. İstanbul: İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.
- Keskinkılıç, F., 2010, Yapay sinir ağları ile döküm parçaların sertliğine etki eden parametrelerinin analizi ve bir uygulama. Kırıkkale: Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.
- Kim, G. H., An, S. H., Kang, K. I., 2004, Comparison Of Construction Cost Estimating Models Based on Regression Analysis, Neural Networks, and Case-Based Reasoning. Building and Environment, 1235-1242.
- Krishnaiah, T., Rao, S. S., Madhu Murthy, K., Reddy, S. K., 2007, Neural Network Approach for Modelling Global Solar Radiation. Journal of Applied Sciences Research, 1105-1111.
- Olgun, S., 2009, Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemler ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması. İstanbul: İstanbul Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.
- Öcal, O., 2007, Yapay Sinir Ağları Algoritması Kullanılarak Akarsu Havzalarında Yağış-Akış-Katı Madde İlişkisinin Belirlenmesi. Denizli: Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.
- Öztemel, E., 2012, Yapay Sinir Ağları (3. Baskı b.). İstanbul: Papatya Yayıncılık.
- Park, D. C., El-Sharkawi, M. A., Marks, R. J., Atlas, L. E., Damborg, M. J., 1991, Electric Load Forecasting Using an Artificial Neural Network. IEEE Transactions on Power Systems, 442-449.
- Şenyurt, M., Yavuz, H., Kahriman, A., Ercanli, İ., 2015, Predicting Stand Yield Parameters Based On Artificial Neural Network For Oriental Beech İn Kestel Forests, Bursa. Presentation (PDF Available) · September 2015 with 15 Reads, 34-35.
- Uğur, L. O., 2007, Yapı Maliyetinin Yapay Sinir Ağı İle Analizi. Ankara: Gazi Üniversitesi Fen Bilimleri Enstitüsü Doktora Tezi.
- Yadav, Neha, Yadav, Anupam, Kumar, Manoj., 2015, An Introduction to Neural Network Methods for Differential Equations. Springer.

Yazıcı, Ü. H., 2010, Yapay Sinir Ağları İle Banka Müşterisi Bekleme Süresi Tahmini.
Erzurum: Atatürk Üniversitesi Fen Bilimleri Enstitüsü Yüksek Lisans Tezi.



EKLER



ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Cankat YAVUZ
Uyruğu : T.C.
Doğum Yeri ve Tarihi :
Telefon :
Faks :
e-mail :

EĞİTİM

Derece	Adı, İlçe, İl	Bitirme Yılı
Lise :		
Üniversite :		

İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
-----	-------	--------

YABANCI DİLLER

İngilizce