



**İSKENDERUN TEKNİK**  
ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ


**YÜKSEK  
LİSANS  
TEZİ**

**YERALTI SUYU SEVİYE  
DEĞİŞİMİNİN M5 KARAR  
AĞACI VE YAPAY SİNİR AĞLARI  
YÖNTEMLERİYLE  
BELİRLENMESİ**

**Zeki Mertcan BAHADIRLI**

**İNŞAAT MÜHENDİSLİĞİ  
ANABİLİM DALI**

**HAZİRAN 2021**





**YERALTI SUYU SEVİYE DEĞİŞİMİNİN M5 KARAR AĞACI VE YAPAY  
SİNİR AĞLARI YÖNTEMLERİYLE BELİRLENMESİ**

**Zeki Mertcan BAHADIRLI**

**YÜKSEK LİSANS  
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**HAZİRAN 2021**

**Zeki Mertcan BAHADIRLI** tarafından hazırlanan “Yeraltı Suyu Seviye Değişiminin M5 Karar Ağacı Ve Yapay Sinir Ağları Yöntemleriyle Belirlenmesi” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi İnşaat Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

**Danışman:** Prof. Dr. Mustafa DEMİRCİ .....  
İnşaat Mühendisliği, İskenderun Teknik Üniversitesi .....

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

**Başkan:** Prof. Dr. Mustafa DEMİRCİ .....  
İnşaat Mühendisliği, İskenderun Teknik Üniversitesi .....

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

**Üye:** Doç. Dr. Cuma KARAKUŞ .....  
Makina Mühendisliği, İskenderun Teknik Üniversitesi .....

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

**Üye:** Dr. Öğr. Üyesi Mehmet Eyyüp KAVŞUT .....  
İnşaat Mühendisliği, Osmaniye Korkut Ata Üniversitesi .....

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Tez Savunma Tarihi: ... /... /.....

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

.....  
Doç. Dr. Ersin BAHÇECİ

Lisansüstü Eğitim Enstitüsü Müdürü

## ETİK BEYAN

İskenderun Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülediğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Zeki Mertcan

BAHADIRLI

.../.../2021

# YERALTI SUYU SEVİYE DEĞİŞİMİNİN M5 KARAR AĞACI VE YAPAY SİNİR AĞLARI YÖNTEMLERİYLE BELİRLENMESİ

(Yüksek Lisans Tezi)

ZEKİ MERTCAN BAHADIRLI

İSKENDERUN TEKNİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

HAZİRAN 2021

## ÖZET

Bu çalışmada, bağımlı değişken yeraltı suyu seviyesi (YASS) ve bağımsız değişkenler olarak da yağış, sıcaklık ve önceki günlük yeraltı suyu seviyesi kullanıldığı bir stokastik modelle yeraltı suyunun davranışı araştırılmıştır. Yeraltı suyu seviyesinin yüksek olduğu Amerika Birleşik Devletlerinin Minnesota şehrinde Prairie Adası yakınlarındaki PI98-14 numaralı gözlem kuyusu istasyonu seçilmiştir. Bu gözlem istasyonu için oluşturulacak olan modeller, Minnesota da yeraltı suyunun takip edilmesi ve kontrol altına alınması, gelecekteki olası değişimlerinin izlenmesi açısından ve oluşabilecek sorunlara önlem alma konusunda faydalı olacağı düşünülmektedir. Çalışmada, Amerika Birleşik Devletleri'ndeki Minnesota şehrinde yer alan Prairie Adası yakınındaki rezervuarın PI98-14 numaralı gözlem kuyusundan elde edilen verilerden faydalanılmıştır. 2025 günlük yağış (Y), sıcaklık (S) ve önceki günlük yeraltı suyu seviyesi (YASS<sub>t-1</sub>) bilgilerini içeren bu veriler, Amerika Birleşik Devletleri Jeolojik Araştırma Kurumun'dan (USGS) alınmıştır. Alınan bu veriler, Yapay Sinir Ağları (YSA), Çoklu Doğrusal Regresyon (ÇDR) ve M5 Karar Ağacı (M5T) metotlarında girdi olarak kullanılmıştır ve yeni yer altı su (YASS) değerleri tahmin edilmiştir. Kullanılan her üç modelde de, birer adet değerlendirme yapılmıştır. Modellerin tahmin sonuçları Determinasyon Katsayısı ( $R^2$ ), Ortalama Mutlak Hata (OMH) ve Kök Ortalama Kare Hata (KOKH) kriterlerine göre karşılaştırılmıştır. Bu karşılaştırmaya göre tüm modeller birbirine yakın sonuçlar göstermiş ve yeraltı suyu seviye tahmininde başarılı olmuştur.

Anahtar Kelimeler : Tahmin, Yeraltı suyu seviyesi, Sıcaklık, Yağış, Minnesota, Yapay Sinir Ağları, Çoklu Doğrusal Regresyon, M5 Karar Ağacı,

Sayfa Adedi : 43

Danışman : Prof. Dr. Mustafa DEMİRCİ

DETERMINATION OF GROUNDWATER LEVEL CHANGE USING M5 DECISION  
TREE AND ARTIFICIAL NEURAL NETWORKS METHODS

(M.Sc. Thesis)

ZEKI MERTCAN BAHADIRLI

ISKENDERUN TECHNICAL UNIVERSITY  
INSTITUTE OF GRADUATE STUDIES

JUNE 2021

ABSTRACT

In this study, groundwater behavior was investigated with a stochastic model using groundwater level (GWL) as dependent variables and precipitation, temperature and previous day's groundwater level as independent variables. Observation well station PI98-14 near Prairie Island in Minnesota, USA, where the groundwater level is high, was selected. It is thought that the models to be created for this observation station will be useful in monitoring and controlling groundwater in Minnesota, monitoring possible changes in the future and taking precautions against possible problems. In the study, the data obtained from the PI98-14 observation well of the reservoir near the Prairie Island in the city of Minnesota in the United States was used. These data, which include 2025 days of precipitation (Y), temperature (S) and the groundwater level of the previous day (GWL<sub>t-1</sub>), were obtained from the United States Geological Survey (USGS). These obtained data were used as inputs in Artificial Neural Networks (ANN), Multiple Linear Regression (MLR) and M5 Decision Tree (M5T) methods and new groundwater level (GWL) values were estimated. In each of the three models used, one evaluation was made. The estimation results of the models were compared according to the Coefficient of Determination ( $R^2$ ), Mean Absolute Error (MSE) and Root Mean Square Error (RMSE) criteria. According to this comparison, all models showed close results and were successful in groundwater level estimation.

Keywords : Estimate, Groundwater Level, Temperature, Precipitation, Minnesota, Artificial Neural Networks, Multiple Linear Regression and M5 Decision Tree

Number of Pages : 43

Supervisor : Prof. Dr. Mustafa DEMİRCİ

## TEŐEKKÜR

Tez alıőmam sırasında tım bilgi birikimi ve tecrübesi ile alıőmayı ynlendiren deęerli danıőman hocam Prof. Dr. Mustafa DEMİRCİ'ye teőekkürlerimi sunarım. Ayrıca her türlü desteęini esirgemeyen Mühendislik ve Doęa Bilimleri Fakóltesi İnőaat Mühendislięi Bölümünden Arő. Gör. Bestami TAŐAR'a en içten teőekkürlerimi sunarım. Hayatımın tümünde olduęu gibi tezimi hazırlama süresince de yanımda olan ve desteklerini benden esirgemeyen annem Nazlı BAHADIRLI'ya, yeęenlerim Mehmet Efe TÜRER, Alya TÜRER ve Arslan TÜRER'e, ablam Dila Gizem TÜRER'e, kardeőlerim Ayda Gizem ALTAY ve Hüseyin DOLAP'a ve dayım Adem VAYIS'a ve őube mūdūrüm Semih CIBİR'a emek, sabır ve anlayıőlarından dolayı ok teőekkür ederim.

## İÇİNDEKİLER

	Sayfa
ÖZET .....	iii
ABSTRACT .....	iv
TEŞEKKÜR .....	v
İÇİNDEKİLER .....	vi
ÇİZELGELERİN LİSTESİ.....	viii
ŞEKİLLERİN LİSTESİ .....	vix
SİMGELER VE KISALTMALAR.....	xiii
1. GİRİŞ .....	1
2. ÖNCEKİ ÇALIŞMALAR.....	5
3. ÇALIŞMA ALANI VE UYGULAMA .....	13
3.1. Çalışma Alanı .....	13
3.2. Kullanılan Modeller .....	16
3.2.1. M5 Karar Ağacı modeli .....	17
3.2.2. Yapay Sinir Ağları (YSA).....	20
3.2.3. Çoklu Doğrusal Regresyon (ÇDR) .....	25
3.3. Model Analizinde Kullanılan İstatistiksel Parametreler .....	25
4. ARAŞTIRMA BULGULARI ve TARTIŞMA .....	27
4.1. Model Sonuçları .....	27
4.1.1. M5 Karar Ağacı (M5T) model sonuçları .....	27
4.1.2. Yapay Sinir Ağları (YSA) model sonuçları .....	30
4.1.3. Çoklu Doğrusal Regresyon (ÇDR) model sonuçları .....	33



	<b>Sayfa</b>
5. SONUÇ ve ÖNERİLER .....	37
KAYNAKLAR.....	39



**ÇİZELGELERİN LİSTESİ**

<b>Çizelge</b>	<b>Sayfa</b>
Çizelge 3.1. Kullanılan istasyon koordinat bilgileri .....	11
Çizelge 4.1. YASS tahmininde kullanılan model sonuçlarının karşılaştırılması.....	35



**HARİTALARIN LİSTESİ**

<b>Harita</b>	<b>Sayfa</b>
Harita 3.1. Çalışmada kullanılan PI98-14 numaralı gözlem kuyusu istasyonun harita görseli .....	12
Harita 3.2. Çalışmada kullanılan PI98-14 numaralı gözlem kuyusu istasyonun uydu görseli .....	12



## ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Dünya'daki su kaynaklarının dağılımı .....	1
Şekil 1.2. Yer altı sularının oluşumu .....	2
Şekil 1.3. Yer altı sularının akışı hareketi .....	3
Şekil 3.1. Goodhue County, Minnesota bölgesinin 29/08/2006-10/06/2012 tarihleri arasındaki günlük yağış değişimleri .....	15
Şekil 3.2. Goodhue County, Minnesota bölgesinin 29/08/2006-10/06/2012 tarihleri arasındaki günlük sıcaklık değişimleri .....	15
Şekil 3.3. Goodhue County, Minnesota bölgesinin 29/08/2006-10/06/2012 tarihleri arasındaki günlük yeraltı suyu seviyesi değişimleri .....	16
Şekil 3.4. M5 model ağacı örneği .....	18
Şekil 3.5. Tipik bir yapay nöronu .....	21
Şekil 3.6. Tipik ileri beslemeli sinir ağı .....	24
Şekil 4.1. Yeraltı su seviyesi eğitim verileri için ölçüm ve M5 Karar Ağacı saçılım grafiği .....	28
Şekil 4.2. Yeraltı su seviyesi eğitim verileri için ölçüm ve M5 Karar Ağacı dağılım grafiği .....	28
Şekil 4.3. Yeraltı su seviyesi test verileri için ölçüm ve M5 Karar Ağacı saçılım grafiği .....	29
Şekil 4.4. Yeraltı su seviyesi test verileri için ölçüm ve M5 Karar Ağacı dağılım grafiği .....	30
Şekil 4.5. Yeraltı su seviyesi eğitim verileri için ölçüm ve YSA saçılım grafiği .....	31
Şekil 4.6. Yeraltı su seviyesi eğitim verileri için ölçüm ve YSA dağılım grafiği .....	31
Şekil 4.7. Yeraltı su seviyesi test verileri için ölçüm ve YSA saçılım grafiği .....	32
Şekil 4.8. Yeraltı su seviyesi test verileri için ölçüm ve YSA dağılım grafiği .....	33
Şekil 4.9. Yeraltı su seviyesi eğitim verileri için ölçüm ve ÇDR saçılım grafiği .....	34
Şekil 4.10. Yeraltı su seviyesi eğitim verileri için ölçüm ve ÇDR dağılım grafiği .....	34
Şekil 4.11. Yeraltı su seviyesi test verileri için ölçüm ve ÇDR saçılım grafiği .....	35
Şekil 4.12. Yeraltı su seviyesi test verileri için ölçüm ve ÇDR dağılım grafiği .....	36

## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.


<b>Simgeler</b>	<b>Açıklamalar</b>
$R^2$	Determinasyon katsayısı
$b_j$	Önyargı terimi için bağlantı ağırlığı
H	Hidrojen
O	Oksijen
H <sub>2</sub> O	Su
l	Gizli katmandaki nöron sayısı
N, n	Veri sayısı
r	Korelasyon katsayısı
S	Sıcaklık
T	Ana düğüme ulaşan bir dizi eğitim verisi
T <sub>i</sub>	Potansiyel kümenin i'inci sonucuna sahip eğitim verilerinin bir alt kümesi
w <sub>jk</sub>	j'ninci gizli katman düğümü ile k çıkış nöronu arasındaki bağlantı ağırlığı
y <sub>k</sub>	Yaklaşıklık derecesi
z <sub>j</sub>	Tüm girdi verilerinden elde edilen j'ninci gizli nöronun çıktısı
Y	Yağış
<b>Kısaltmalar</b>	<b>Açıklamalar</b>
ANFIS	Uyarlanabilir ağ tabanlı bulanık çıkarım sistemi
ARMA	Otoregresif hareketli ortalamalar modelleri
BM	Uyarlamalı sinirsel bulanık çıkarım sistemi
BN	Bağıl nem
ÇDR	Çoklu doğrusal regresyon
DSİ	Devlet su işleri
DWT	Ayrık dalgacık dönüşümü

<b>EOK</b>	En küçük ortalama kare yöntemi
<b>FCM</b>	Bulanık kümeleme modeli
<b>GWL</b>	Yeraltı Suyu Seviyesi
<b>İBGYYSA</b>	İleri beslemeli geri yayımlı yapay sinir ağı
<b>KOKH</b>	Kök ortalama kare hata
<b>M5T</b>	M5 Karar Ağacı
<b>MARS</b>	Çok değişkenli uyarlanabilir regresyon spline
<b>MSE</b>	Ortalama kare hata
<b>MAE</b>	Ortalama mutlak hata
<b>NNSE</b>	Normalize nash-sutcliffe verimliliği
<b>NSE</b>	Nash-Sutcliffe etkinlik katsayısının
<b>OMH</b>	Ortalama mutlak hata
<b>RH</b>	Rüzgar hızı
<b>RMSE</b>	Root mean square error
<b>SD</b>	Standart sapmayı
<b>SDR</b>	Standart sapmadaki azalma miktarı
<b>SRC</b>	Sediment derecelendirme eğrileri
<b>USGS</b>	Amerika Birleşik Devletleri Jeolojik Araştırma Kurumu
<b>WT</b>	Dalgacık dönüşümü
<b>YASS</b>	Yeraltı suyu seviyesi
<b>YSA</b>	Yapay sinir ağı

## 1. GİRİŞ

Yaşamın önemli unsurlarından biride sudur. Su, tüm canlılar için oksijenden sonra gelen en önemli ögedir. Su (H<sub>2</sub>O) içinde hidrojen (H) ve oksijen (O) elementlerini barındıran, yaşam döngüsünde önemli bir yere sahip bir bileşiktir. Su, yaşam döngüsünde doğal yollarla çeşitli forumlarda ve yerlerde bulunabilir. Buharlaşıma, yoğunlaşma gibi fiziksel değişimlerle, sıvı, katı ve gaz gibi çeşitli fiziksel forumlarda hayatımızın her alanında yer alır. Bu fiziksel değişimler döngü halinde olur ve buna su döngüsü veya hidrolik çevrim denir.

Su, yeryüzünde en geniş alanı kaplayan bileşendir. Bu yüzden dünyaya ‘‘Mavi Küre’’adı da verilmiştir. Dünya’daki su kaynaklarının dağılımı Şekil 1.1’de gösterilmiştir. Dünyanın % 71’i su ile kaplıdır, ancak bu su kaynaklarının % 2,5’i kullanılabilir durumdadır. Bu kısıtlı kaynağın % 2’lik kısmının kutuplarda, 16 km kalınlığında buz kütleleri halinde bulunduğu düşünülüğünde, suyun yalnızca % 0,5’lik bölümünün kullanılabilir nitelikte olduğu söylenebilir (Ulusoy, 2007:5).




Şekil 1.1. Dünya'daki su kaynaklarının dağılımı ([www.bilimteknik.tubitak.gov.tr](http://www.bilimteknik.tubitak.gov.tr))

### Yeraltı suları oluşumu ve hareketi

Dünyada depolanan suyun büyük bir kısmı yer altı suyu olarak saklanır. Yeraltı suyu, çoğunlukla yerin yüzeyinden aşağı doğru süzülen yağıştan meydana gelir. Yeraltı suyu için kullanılan diğer bir deyim de “akifer” dir. Akiferler, tüm dünya suyunu depolayan büyük bir saklama alanıdır ve tüm insanların günlük yaşamlarının su ihtiyacı, yeraltı suyuna bağlıdır (Ulusoy, 2007:71). İnsanlar içme, tarımsal sulama gibi çeşitli nedenlerle uzun yıllardır yeraltı sularını kullanmaktadırlar. Bu yüzden yer yüzeyindeki sular kadar önemlidirler.

Yer üstünde olduğu gibi yer altında da su akışları vardır ve bu yer altı suları yer üstündeki akan suların birçoğunun akışına ana kaynak sağlarlar. Bu akışın bir kısmı yer yüzeyindeki akarsulara karışırken bir kısmı da içinde aktığı malzeme tarafından tutulur ve yer çekiminin etkisi ile daha derinlere doğru iner ve gözenekli malzeme tüm doygunluğuna ulaşmaya kadar birikme yapar ve yer altı suları böylece oluşur. Şekil 1.2’de yer altı sularının oluşumu gösterilmiştir.




Şekil 1.2. Yer altı sularının oluşumu (Monroe ve Wicander 2005)

Yer altı sularının hareketi yer çekimi ivmesiyle ve basınç değişimleri ile oluşur. Yer yüzeyinden yer altı sularına doğru yer çekimi ile hareket eden sular su tablasına ulaştığında, daha alçaktaki akarsular, göller gibi yer üstü sularına doğru su tablası eğiminde hareket ederler. Fakat bu sadece süzülen suların bir bölümünü oluşturmaktadır. Bunların büyük bölümü ise akarsulara ve göllere ulaşır. Bunun nedeni, doygunluk bölümündeki yer altı sularının yüksek basınçtan alçak basınca doğru hareket etmesinden kaynaklanır. Yer



üstünden süzen suların bir kısmı ise yerel akıklüd üzerinde toplanır. Şekil 1.3'de Yeraltı sularının akışı hareketi gösterilmiştir.



Şekil 1.3. Yer altı sularının akışı hareketi (Monroe ve Wicander 2005)

#### Yeraltı su kaynaklarının yönetimi

En önemli kaynaklardan biri olan su tamamen ikame edilemeyen bir kaynaktır. Bu yüzden suyun doğru kullanımı çok önemlidir. Su, enerji üretimi, ekosistem kullanımı, insan kullanımı (tarım, sanayi, evsel kullanım), ekonomik kalkınma ve ulusal güvenlik gibi birçok alan da vardır. Yeryüzünde kullanılan tatlı su kaynaklarının önemli bir kısmı da yer altı sularından elde edilmektedir. Bu nedenle yer altı suları önemli bir tatlı su kaynağıdır ve bu kaynağın yönetimi önem arz etmektedir.

Yeraltı su kaynaklarının yönetimi, yeraltı su kaynaklarını etkileyen faktörleri anlamakla başlar. Tüm su kaynaklarını etkilediği gibi yeraltı su kaynaklarını da etkileyen en önemli hususlardan biride iklim değışikliklerdir. Artan iklim değışikliklerinin yarattığı sıcaklık farklarının sonucunda yeraltı su seviyelerinde de büyük ölçüde değışiklikler gözlenmektedir. Bu yüzden bu değışimleri ve etkilerini göz önüne alarak yeraltı su kaynaklarının yönetiminde önemli veriler elde edip, bu veriler ışığında su kaynaklarının korunması için yapılacak faaliyetler belirlenip, uygulamaya geçilmelidir.

Su kaynaklarının işletilmesi ve planlanması için yeraltı su seviyesindeki değışimlerin belirlenmesi önem arz etmektedir. Sürecin modellenmesi, var olan verilerin genel olarak

toplumu tam anlamıyla yansıtmadığı için, daha güvenli kararlar alabilmek adına çok önemlidir. Veri üretmek ya da süreçlerin gelecek zamandaki değerlerini tahmin edebilmek adına, planlama ve tasarım için modeller kullanılabilir. Daha doğru ve daha güvenilir karar almak için ileriye yönelik güvenilir ve gerçekçi senaryolar üretip, zaman serilerini tanımlayacak doğru model seçimi ile mümkündür (Bacanlı ve Baran, 2004).

Stokastik süreç, zaman içinde gelişen güzel bir değişkenin üst üste aldığı değerler birbirine bağımlı ise, bu değerlerden oluşan zaman serisine denir. Gelişen güzel bir değişkenin olasılık dağılımından farklı bir serinin ardışık ögeleri arasındaki içsel bağımlılığı belirtmek, bir stokastik süreci belirlemek için gereklidir (Bayazıt, 1981).

Çok değişkenli modelleme ve çok değişkenli stokastik analiz, su kaynaklarının işletilmesi, planlanması ve tasarımı, genel olarak hidrolojik seriyi birden içerdiği için çok önemli bir konudur (Pegram ve James, 1972).

## 2. ÖNCEKİ ÇALIŞMALAR

Literatür incelendiğinde yeraltı su seviyesi tahmininin Yapay Sinir Ağları (YSA), Çoklu Doğrusal Regresyon (ÇDR) ve M5 Karar Ağacı (M5T) yöntemleri yardımıyla çeşitli çalışmalar yapıldığı görülmüştür. Günümüze değin bu yöntemler farklı disiplinlerde ve çeşitli alanlarda karşımıza çıkmıştır. Çalışmamıza ışık tutması açısından incelendiğinde de kullandığımız metotların yer altı suyu seviyesi tahmininde de oldukça verimli olduğu görülmüştür.

Trichakis, Nikolas ve Karatzas (2011) tarafından yapılan çalışmada, YSA teknolojisini yeraltı suyu seviyesi değişimlerinin belirlenmesinde kullanılmıştır. Bu çalışmada, önerilen YSA'yı eğitmek ve değerlendirmek için ABD'nin Teksas eyaletindeki Edward akiferinden elde edilen mevcut ölçüm verileri kullanılmıştır. Ölçülen verilerin bir korelasyon analizi, mevcut gün ile ölçülen yağış seviyelerinin girişi için kullanılan gün arasındaki zaman gecikmesini belirlemek için kullanılmıştır. Kalibrasyon işleminden sonra, YSA'nın eğitim prosedüründe kullanılmayan diğer bölgelerde enterpolasyon veya ekstrapolasyon yapma yeteneğini kontrol etmek için test verileri kullanılmıştır. Sonuç olarak YSA, sayısal yeraltı suyu modelleriyle simüle edilmesi zor olan karstik akiferleri simüle etmenin hala en yararlı yollardan biri olduğu kanısına varılmıştır.

Yoon, Hyun, Ha, Lee ve Kim (2016) Uzun vadeli yeraltı suyu seviyesi tahminleri için YSA metodunu kullanmışlardır. Yaptıkları çalışmada, (YSA) performansını iyileştirmek ve vektör makinesini desteklemek için ağırlıklı bir hata fonksiyonu yaklaşımını kullanmışlardır. Geliştirilen zaman serisi modelleri, Güney Kore'deki 5 yeraltı suyu izleme istasyonundan alınan yeraltı suyu seviyesi verilerine uygulanmıştır. Sonuç olarak bu çalışmada YSA'yı faydalı ve kullanılabilir bulmuşlardır.

Mogaji, San Lim ve Abdullah (2015) Yeraltı suyu beslemesinin modellenmesi çalışmalarında, ÇDR yöntemi ile yer altı su seviyesi tahmini konusunda çalışmalar yapmışlardır. Malezya'nın Perak bölgesinde gerçekleştirilen bu çalışmada, yeraltı suyu beslenme hızı değerlendirmesi yapılmıştır. Çıkan sonuçlar ÇDR metodunun ilgili konu ile anlamlı çalıştığını göstermiş ve bu yöntem yer altı suyu seviyesi tahminleri için önerilmiştir.

Emamgholizadeh, Moslemi ve Karami (2014) tarafından yapılan çalışmada, YSA ve Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) ile Bastam Ovası'nın yeraltı suyu

seviyesinin tahmin edilmesi konulu çalışmalarında yeraltı suyu seviyesini tahmin etmek için girdi verileri olarak, yağışların yeniden yüklenmesi, sulamadan dönen akış gibi hidrolojik ve hidrojeolojik parametreleri ve ayrıca su kuyularından pompalama hızlarını içeren 9 yıllık veri setleri kullanmışlardır. Sonuç olarak YSA'nın çok küçük bir hata payı ile yer altı su seviyesini tahmin edebildiği söylenmiş ve bu yöntem diğer çalışmacılara önerilmiştir.

Mayilvaganan ve Naidu (2011) Hindistan'da yapılan çalışmada iki hesaplama sisteminin verimliliğini karşılaştırmışlardır. YSA ve Bulanık Mantık (BM) metotlarının karşılaştırıldığı bu çalışmada bir havzanın yeraltı suyu seviyesi tahmin edilmeye çalışılmıştır. Karşılaştırılan tekniklerde sigmoid işlevi ve geri yayılma algoritması kullanılarak geliştirilmiştir. BM modeli geliştirilmiş girdi ve çıktı değişkenleri için Gauss bulanık üyelik fonksiyonlarını kullanılmıştır. Bulanık kurallar ölçülen verilerden çıkarılmıştır. Bu çalışmada YSA'ların bulanık mantık verilerinden daha iyi sonuç verdiği görülmüştür. İki yöntem de önerilmiştir.

Sahoo ve Jha (2013) tarafından yapılan çalışmada, Japonya'nın 17 farklı bölgesinde yapılan araştırmalarda ÇDR ve YSA yöntemi kullanılmıştır. Değişkenler; yağış, ortam sıcaklığı, nehir seviyesi, 11 mevsimsel değişken ve etkili yağış gecikmeleri, ortam sıcaklığı, nehir seviyesi ve yeraltı suyu seviyesi olarak belirlenmiştir. Levenberg-Marquardt geri yayılım algoritmalarıyla eğitilmiş çok katmanlı ileri beslemeli sinir ağları kullanılarak on yedi bölgeye özgü YSA modeli geliştirilmiştir. Modellerin performansı istatistiksel ve grafiksel göstergeler kullanılarak değerlendirilmiştir. ÇDR modellerinin uyum iyiliği istatistiklerinin YSA modellerinkilerle karşılaştırıldığında, YSA'ya kıyasla tüm sahalarda ÇDR tarafından tahmin edilen yeraltı suyu seviyeleri ile gözlemlenen yeraltı suyu seviyeleri arasında daha iyi bir uyum olduğu görülmüştür. Bu bulgu, grafik göstergeler ve kalıntı analizi ile desteklenmiştir. Böylece, YSA tekniğinin bir havzadaki yeraltı suyu seviyelerinin uzay-zamansal dağılımını tahmin etmede ÇDR tekniğinden üstün olduğu sonucuna varılmıştır.

İspir, E. (2017) Hatay, Türkiye'de gerçekleştirdiği çalışmada ÇDR ve YSA modellerini kullanmışlardır. 2000-2015 yılları arasında Hatay, Amik Ovası, Kumlu ilçesinde bulunan Devlet Su İşleri Genel Müdürlüğü'nün (DSİ) yeraltı suyu seviyesi, aylık ortalama yağış ve sıcaklık gözlemleri kullanılmıştır. Performans değerlendirmesi, ÇDR ve YSA modelleri oluşturularak yapılmıştır. YSA modeli, ÇDR modelinden daha iyi sonuçlar vermiştir.

Adamowski ve Chan (2011) tarafından yapılan çalışmada yeraltı suyu seviyesi tahmin uygulamaları için ayırık dalgacık dönüşümlerini (WA) ve yapay sinir ağlarını (YSA) birleştirmeye dayanan yeni bir yöntem önermişlerdir. Önerilen birleşik dalgacık-sinir ağı modellerinin (WA-YSA) göreceli performansı, aylık yeraltı suyu seviyesi tahmini için düzenli yapay sinir ağı (YSA) modelleri ve otoregresif entegre hareketli ortalama (ARIMA) modelleri ile karşılaştırılmıştır. Modelleri geliştirmek ve doğrulamak için kullanılan değişkenler, Quebec, Kanada'daki Chateauguay havzasındaki iki sahada Kasım 2002'den Ekim 2009'a kadar kaydedilen aylık toplam yağış, ortalama sıcaklık ve ortalama yeraltı suyu seviyesi verileridir. WA – YSA modellerinin, YSA ve ARIMA modellerine kıyasla daha doğru aylık ortalama yeraltı suyu seviyesi tahminleri sağladığı bulunmuştur. Çalışmanın sonuçları, yeraltı suyu seviyelerini tahmin etmede WA-YSA modellerinin potansiyelini göstermektedir. Daha etkili ve sürdürülebilir yeraltı suyu yönetimi stratejilerinin geliştirilmesini ve uygulanmasını kolaylaştırmak için kullanılabilecek bu önerilen yöntemi ek çalışmaların araştırması tavsiye edilir.

Zare ve Koch (2018) Miandarband ovası, İran'ın Kirmanşah eyaletinin en verimli ovalarından birinde gerçekleştirdiği çalışmada yer altı suyu seviyesini incelemişlerdir. Bu çalışmada, yeni bir ÇDR yaklaşımı kullanılarak verilerin tamamlanmasının ardından, Bulanık Kümeleme Modeli (FCM) kullanan ANFIS modeli uygulanmıştır. Bir küme duyarlılığı analizinden iki küme belirlenmiştir. GL-zaman serileri, yapay zeka yöntemlerinin bazen ağırlıkları uyarlamakta sorun yaşadığı sabit olmadığından, ANFIS'te Wavalet Dönüşümü (WT)'nin ek kullanımı model sonuçlarını geliştirebilir. Bu yeni hibrit Wavelet-ANFIS modeli, İran'ın Miandarband düzlüğündeki GL dalgalanmalarını simüle etmek ve tahmin etmek için çeşitli girdiler ve ana dalgacık kombinasyonları ile kullanılmıştır. Sonuçlar, tüm model yaklaşımlarının kabul edilebilir doğrulukla kullanılabileceğini göstermektedir; bu nedenle, Symlet ana dalgacık ile hibrit Wavelet-ANFIS modeli, aşağıdaki değerlere sahip diğer model varyantlarından daha iyi performans gösterir. ANFIS'te WT'nin ek kullanımı model sonuçlarını geliştirebilir. Bu yeni hibrit Wavelet – ANFIS modelinde, İran'ın Miandarband düzlüğündeki GL dalgalanmalarını simüle etmek ve tahmin etmek için çeşitli girdiler ve ana dalgacık kombinasyonları kullanılmıştır. Sonuçlar, tüm model yaklaşımlarının kabul edilebilir doğrulukla kullanılabileceğini göstermiştir; bu nedenle, Symlet ana dalgacık ile hibrit Wavelet-ANFIS modeli, diğer model varyantlarından daha iyi performans gösterdiği sonucuna varılmıştır.

Gong, Wang, Xu ve Zhang (2018) Çin'in Pekin bölgesinde gerçekleştirdikleri bu çalışmada, model geliştirme (eğitim) için ilk 168 veri kaydı ve model doğrulama için kalan 12 veri kaydı dahil olmak üzere 180 aylık YASS veri kaydı kullanılmıştır. Sonuçlar, hem ÇDR hem de YSA modelleri için Nash-Sutcliffe etkinlik katsayısının (NSE) ve korelasyon katsayısının ( $r$ ) çoğu ilçede yüksek olduğunu ve ÇDR modellerinin bu çalışmada daha uygun olduğunu göstermektedir. Farklı yeraltı suyu kullanımı ve yağış koşulları altında on beş senaryo, geliştirilen modelin yeraltı suyu yönetiminde uygulanabilirliğini göstermek için tasarlanmıştır. Vekil modeller, karar vericiler tarafından yeraltı suyu yönetimi için kullanılabilir olacak etkili araçlardır.

Taşar, Kaya, Varçin, Üneş ve Demirci (2017), bu çalışmalarında, su kalitesi ve kaynaklarının yönetimi sorunlarının çözümünde askıda katı madde tahmininin çok önemli olduğunu savunmuşlardır. Bu tez de Sediment Derecelendirme Eğrileri (SRC), M5T, YSA gibi istatistiksel yaklaşımları günlük askıda katı madde konsantrasyonunun tahmini için kullanmışlardır. Bu modellemelerde kullanılan veriler, ABD'deki Iowa istasyonundan alınmıştır. Bu modellerin tahmin sonuçları, ortalama kare hataları, ortalama mutlak bağıl hata ve korelasyon katsayısı gibi istatistiksel parametreler ile karşılaştırılmıştır. Çıkan sonuçlara göre YSA yaklaşımı diğer tahmin yöntemlerine göre askıda katı madde tahminlerinde daha iyi olduğu sonucuna ulaşmışlardır.

Sattari, Mirabbasi, Sushab ve Abraham (2018) tarafından yapılan çalışmada, Erdebil ovasındaki yeraltı suyu seviyesini tahmin etmek için destek vektör regresyonu (SVR) ve M5 karar ağacı modelleri kullanılmıştır. Modellerin eğitimi ve testi için 17 yıllık bir dönem için (1997'den 2013'e kadar) 24 piezometreden alınan aylık yeraltı suyu seviyesi verileri kullanılmıştır. Model girdileri, önceki ayların yeraltı suyu seviyelerini, her hücreye giren yağış hacmini ve kuyuların deşarjını içermektedir. Model çıktısı, mevcut aydaki yeraltı suyu seviyesidir. Modellerin performansını değerlendirmek için korelasyon katsayısı ( $R$ ) ve kök ortalama kare hata kullanılmıştır. Sonuçlar, hem SVR hem de M5 karar ağacı modellerinin Erdebil ovasında yeraltı suyu seviyesinin tahmini için iyi performans gösterdiğini göstermiştir. Bununla birlikte, M5 karar ağacı modelinden elde edilen sonuçların, SVR'den elde edilenlere göre daha basit, daha kolay uygulanır ve yorumlanması daha kolay olduğu sonucuna varılmıştır. Fakat en iyi sonucu SVR vermiştir.

Rezaie-balf, Naganna, Ghaemi ve Deka (2017) yapılan çalışmada, çeşitli sınırlandırılmamış akiferler içindeki üç sığ açık kuyunun yeraltı suyu seviyesi (YASS)

dalgalanmalarını simüle etmek için iki farklı makine öğrenme modeli, Çok Değişkenli Uyarlanabilir Regresyon Spline'lar (MARS) ve M5 Model Ağaçlar (M5T) uygulanmıştır. Wavelet eşleşmeli MARS ve MT hibrit modelleri, YASS tahmin doğruluğunu daha da artırmak amacıyla geliştirilmiştir. Durağan olmayan zaman serisi verileriyle başa çıkmada özellikle etkili olan Ayrık Dalgacık Dönüşümü (DWT), girdi zaman serilerini çeşitli alt dizi bileşenlerine ayırmak için kullanılmıştır. On'u geçmiş verileri Modelleri kalibre etmek ve doğrulamak için aylık yeraltı suyu seviyesi, yağış miktarı ve sıcaklığı içeren yıllar (Ağustos-1996 - Temmuz-2006) kullanılmıştır. Modeller kalibre edilmiş ve bir, üç ve altı ay sonraki tahmin ufukları için test edilmiştir. Dalgacıkla birleştirilmiş MARS ve MT modelleri, Kök Ortalama Kare Hatası (RMSE), Normalize Nash-Sutcliffe Verimliliği (NNSE) ve Belirleme Katsayısı gibi standart istatistiksel performans değerlendirme ölçümleri kullanılarak basit muadilleriyle karşılaştırılmıştır. Çok ölçekli girdi verileri kullanılarak geliştirilen dalgacık bağlı MARS ve MT modelleri, basit muadillerine kıyasla daha iyi performans göstermiştir ve W-MARS modellerinin tahmin doğruluğu W-MT modellerinden daha üstün bulunmuştur.

Javadinejad, Dara ve Jafary (2020) tarafından yapılan çalışmada, yeni modelleme yöntemleri kullanarak yeraltı suyu seviyelerini tahmin etmiştir. İki ayrı yumuşak hesaplama tekniğinin uygulanması, çok katmanlı bir algılayıcı sinir ağı (MLPNN) ve bir M5 model ağacı (M5-MT) incelenmiştir. Modeller sığ, sınırlandırılmamış kıyı akiferin de gözlemlenen aylık YASS'lerin tahmin edilmesinde kullanılmıştır. Su seviyesi verileri Hindistan, Ganjimatta yakınlarında bulunan gözlem kuyularından toplanılmıştır ve YASS dalgalanmasını tahmin etmek için kullanılmıştır. Bunu yapmak için, şu anda YASS'ni modellemek için en uygun girdi değişkenlerini elde etmek için iki senaryo sağlanmıştır. Önerilen modelleri geliştirmek için uygulanan girdi parametreleri, aylık toplam yağış zaman serileri, ortalama sıcaklık (yeraltı suyu üzerinde etkisi olan gecikme süreleri dahilinde) ve 1996-2006 dönemi boyunca tarihsel YASS gözlemleridir. Ganjimatt için önerilen her modelin verimliliği deneme yanılma aşamalarında araştırılmıştır. Bir performans değerlendirmesi, akifer durum çalışmasında M5-MT'nin YASS'ni tahmin etmede MLPNN modelinden daha iyi performans gösterdiğini göstermiştir. M5-MT yaklaşımına dayalı olarak, bu modelin geliştirilmesi Hindistan kıyı akiferleri için kabul edilebilir sonuçlar vermiştir.

Nalarajan ve Mohandas (2015) tarafından yapılan çalışmada, bir yeraltı suyu izleme kuyusundan yalnızca geçmiş yeraltı suyu seviyelerini kullanan M5 Karar Ağacı kullanarak

yeraltı suyu seviyesi tahminlerini tartışılmıştır. Mevcut koşullar altında, tahmin edilen yeraltı suyu seviyelerinin mevcudiyeti, yeraltı suyu kaynaklarının planlanmasına yardımcı olarak bu değerli kaynağın önemini artırdığından söz edilmiştir. Bu amaçla, veriye dayalı tahmin modelleri günümüz dünyasında yaygın olarak kullanılmaktadır. M5 model ağacının (MT), sayısal tahmin için umut verici bir yöntem olarak ortaya çıkan ve anlaşılabilir modeller üreten popüler bir yazılımsal hesaplama yöntemi olduğu üzerinde durulmuştur. Sonuçlar, MT'nin yeraltı suyu seviyelerini tahmin etmek için art arda kullanılabileceğini göstermiştir.

Maruf, A. G. (2019). Bu çalışmada, Otoregresif hareketli ortalamalar (ARMA) modelleri, Çoklu Doğrusal Regresyon (ÇDR) ve Bulanık Mantık (BM) modellerinin yeraltı suyu seviyesinin tahmini sırasındaki performanslarını araştırmıştır. Çalışmanın ilk kısmında yeraltı suyu seviyesi zaman serileri kullanılarak ARMA modelleri için 3 farklı model (ARMA 1-1, ARMA 3-3, ARMA 5-5), ÇDR modeli için 2 farklı model (ÇDR 5-5), (ÇDR 2) ve BM modelleri için de 2 farklı model (BM 1-1), (BM 2) uygulanmıştır. Uygulama alanı olarak, Hatay ili Dört Yol Bölgesine ait, Devlet Su İşleri (DSİ) 5512 numaralı kuyusu kullanılmıştır. Çalışmanın devamında yağış (Y), ortalama hava sıcaklığı (S), bağıl nem (BN) ve rüzgâr hızı (RH) gibi parametrelerin aylık ortalama değişimleri girdi olarak alınarak, yeraltı suyu seviyesinin (YASS) değişimi tahmin edilmeye çalışılmıştır. Bu veriler 2000-2015 yılları arasındaki 147 aylık zamanda Meteoroloji Genel Müdürlüğü'nden (MGM) alınmıştır. Kullanılan modellerin ölçüm sonuçlarının değerlendirmesinde, istatistiksel performans parametreleri olarak, determinasyon katsayısı ( $R^2$ ), ortalama kare hata (OKH), ortalama mutlak hata (OMH) kullanılmıştır. Sonuç olarak bu çalışmada, YASS tahmini için ARMA, ÇDR ve BM modelleri iyi performans göstermişlerdir. Özellikle BM modeli az da olsa ARMA ve ÇDR modeline göre daha iyi sonuçlar vermiştir.

Üneş ve diğerleri (2018) yaptıkları çalışmada yeraltı suyu seviyesi, yağış, sıcaklık değişkeni kullanılarak yeraltı suyu seviyesi dalgalanmaları incelenmiştir. Amerika Birleşik Devletleri, Minnesota'daki PI98-14 gözlem kuyusu istasyonundan alınan günlük yağış, sıcaklık ve yeraltı suyu seviyesi verileri kullanılmıştır. 2025 günlük bu veriler YSA yönteminde girdi olarak kullanılmıştır. Daha sonra YSA da çıkan sonuçlar ÇDR yöntemi ile karşılaştırılmıştır. Bu karşılaştırmaya göre YSA ve ÇDR yönteminin benzer sonuçlar verdiği gözlemlenmiştir ve bu çalışma sonucunda, YSA modelinin gelecekteki olası değişiklikleri izlemek için YASS tahmininde faydalı olacağı sonucu çıkarılmıştır.



Son yıllarda arařtırmacılar yeraltı suyu seviyelerini tahmin etmek için farklı matematiksel modeller de kullanmışlardır (Karami ve diđerleri, 2018; Ehteram ve diđerleri 2018, 2019). Bu modeller, girdi ve yapısal parametrelerin çokluđu, çeřitli kalibrasyonlar ve uzun vadeli performans nedeniyle yeraltı suyu seviyelerini tahmin etmenin karmařıklıklarını çözecek şekilde oluşturulmuřtur (Maroufpoor, Fakheri-Fard ve Shiri 2017; Karami ve diđerleri, 2018). Son birkaç yılda yapılan daha yeni arařtırmalarda, yeraltı suyunu tahmin etmek için yapay sinir ađı (YSA) (Ghorbani, Deo, Karimi, Yaseen ve Terzi, 2018; S. Lee, K.-K. Lee ve Yoon, 2018) ve uyarlamalı ađ tabanlı bulanık çıkarım sistemi (ANFIS) (Zare ve Koch, 2018) gibi yapay zeka modelleri sıkça kullanılmıştır. Destek vektör makineleri (SVM) gibi optimizasyon algoritmalarına dayalı diđer istatistiksel veya geliştirilmiş modeller, yeraltı suyu seviyelerini tahmin etmek için yüksek başarılarla sahiptir (Nadir, Naderi, Khatibi ve Gharekhani, 2019; Karami ve diđerleri 2019).

Yapay zeka teknikleri kullanarak yeraltı suyu senaryolarını anlamak için farklı modeller de geliştirilmiştir. (Charulatha, Srinivasalu, Maheswari, Venugopal ve Giridharan, 2017; Rabeiy, 2018). Birkaç arařtırma çalıřması (Bărbulescu 2016; Sahoo, Russo, Elliott, Foster, 2017; Khan, He ve Valeo, 2018; Sunayana, Dube ve Sharma, 2019), gelecek senaryoyu anlamak için zaman serisi modellerinin ve yapay sinir ađı modellerinin yeraltı suyu kalitesini ve seviyesini önceden tahmin etmede yardımcı olabileceđini öne sürmektedir. Yapay sinir ađı (YSA) modelleri, çeřitli arařtırmacılar tarafından su kalitesi çalıřmaları için de uygulanmıştır (Csábráđi, Molnár, Tanos ve Kovács, 2017; Kisi, Azad ve Kashi, 2019).

Yapay zeka modellerinin uygulanması YASS'ni tahmin etmekle sınırlı deđildir. Literatür incelemeleri, taşıma kapasitesinin tahmin edilmesi (Moayedı ve Armaghani, 2018), kireçtařı numunelerinin kohezyonunun tahmin edilmesi (Khandelwal ve diđerleri, 2018), güneř radyasyonunun tahmin edilmesi (Meenal ve Selvakumar, 2018) ve tařkın kontrolü gibi farklı alanlarda modellerin yüksek verimliliđini kanıtlamışlardır (L. C. Chang, Amin, Yang ve F. J. Chang, 2018). Ayrıca son yıllarda hidrolojinin çeřitli alanlarında yapay zeka yöntemleri yaygın olarak kullanılmaktadır. (Nistor, 2019), (Yaseen ve diđerleri, 2019). (Khandelwal ve diđerleri, 2018), (Meenal ve Selvakumar, 2018), (Chang ve diđerleri, 2018).

Bu tez çalıřmasında, yeraltı suyu seviyesi tahmini yapılmıştır. M5 Karar Ađacı (M5T) Yapay Sinir Ađları (YSA) ve Çoklu Doğrusal Regresyon (ÇDR) metotlarının

performansları karşılaştırılarak yeraltı suyu seviyesi tahmini yapılmıştır. Nehirde akış miktarının tahmini için ortalama sıcaklık, yağış ve önceki günkü yer altı su seviyesi parametreleri kullanılmıştır. Farklı girdi parametreleri kombinasyonları oluşturularak MT5, YSA ve ÇDR metotları kullanılarak sonuçlar karşılaştırılmıştır.



### 3. ÇALIŞMA ALANI VE UYGULAMA

#### 3.1. Çalışma Alanı

Çalışma alanı olarak Amerika Birleşik Devletleri'ndeki Minnesota eyaletinde yer alan Prairie adası yakınlarındaki PI98-14 numaralı gözlem kuyusu rezervuarıdır. Minnesota, soğuk kışlar ve sıcak yazlar ile karasal ikliminin karakteristik özelliklerini taşıyan aşırı sıcaklıklarla karşılaşır. Kaydedilen en düşük sıcaklık 2 Şubat 1996'da Tower'da ü -51 ° C idi ve en yüksek sıcaklık ise 6 Temmuz 1936'da Moorhead'de 46 ° C idi. (Minnesota Üniversitesi. 5 Ekim 2006). Yağmur, kar, kar fırtınası, gök gürültülü fırtınalar, dolu, kasırgalar ve yüksek hızlı düz çizgi rüzgarlar gibi çeşitli meteorolojik olaylar gerçekleşir. Mississippi Nehri yakınındaki Minnesota da büyüme mevsimi uzak kuzeydoğuda 90 günden güneydoğuda 160 güne kadar sürer ve ortalama sıcaklıklar 3 ila 9 ° C arasında değişir (Ulusal Hava Servisi Tahmin Ofisi, 28 Mayıs 2008). Ortalama yıllık yağış 48 ila 89 cm arasında değişir ve kuraklıklar her 10 ila 50 yılda bir meydana gelir (Ulusal Hava Servisi Tahmin Ofisi, 28 Mayıs 2008 ).


Çalışma alanının Harita 3.1 ve Harita 3.2'de harita ve uydu görselleri verilmiştir. Amerika Birleşik Devletleri Jeolojik Araştırma Kurumu'ndan (USGS) alınan 07040001 numaralı istasyon verileri aşağıda grafik olarak Şekil 3.1, Şekil 3.2 ve Şekil 3.3'te verilmiştir. Veriler 29/08/2006-10/06/2012 tarihleri arasındaki 2025 günlük yağış, sıcaklık ve yer altı su seviyesi bilgilerini içermektedir.

Çizelge 3.1. Kullanılan istasyon koordinat bilgileri


İstasyon No	Adı	Bölge	Enlem	Boylam	Veri Tarihi
07040001	Welch Township, Goodhue County, Minnesota		44°40'07.66"	92°42'31.69"	29/08/2006- 10/06/2012




Harita 1.1. Çalışmada kullanılan PI98-14 numaralı gözlem kuyusu istasyonunun harita görseli




Harita 1.2. Çalışmada kullanılan PI98-14 numaralı gözlem kuyusu istasyonunun uydu görseli



Şekil 3.1. Goodhue County, Minnesota bölgesinin 29/08/2006-10/06/2012 tarihleri arasındaki günlük yağış değişimleri



Şekil 3.2. Goodhue County, Minnesota bölgesinin 29/08/2006-10/06/2012 tarihleri arasındaki günlük sıcaklık değişimleri



Şekil 3.3. Goodhue County, Minnesota bölgesinin 29/08/2006-10/06/2012 tarihleri arasındaki günlük yeraltı suyu seviyesi değişimleri

### 3.2. Kullanılan Modeller

Bu tez çalışmasında, Minnesota bölgesinde Prairie adası yakınlarındaki PI98-14 numaralı gözlem kuyusuna ait 29/08/2006-10/06/2012 tarihleri arasındaki yer altı su seviyesi ölçüm verileri ve Amerika Birleşik Devletleri Jeolojik Araştırma Kurumu'ndan (USGS) alınan 07040001 numaralı istasyon verileri alınarak 29/08/2006-10/06/2012 tarihleri arasında günlük yağış ve sıcaklık verileri kullanılarak tahmin çalışması yapılmıştır.

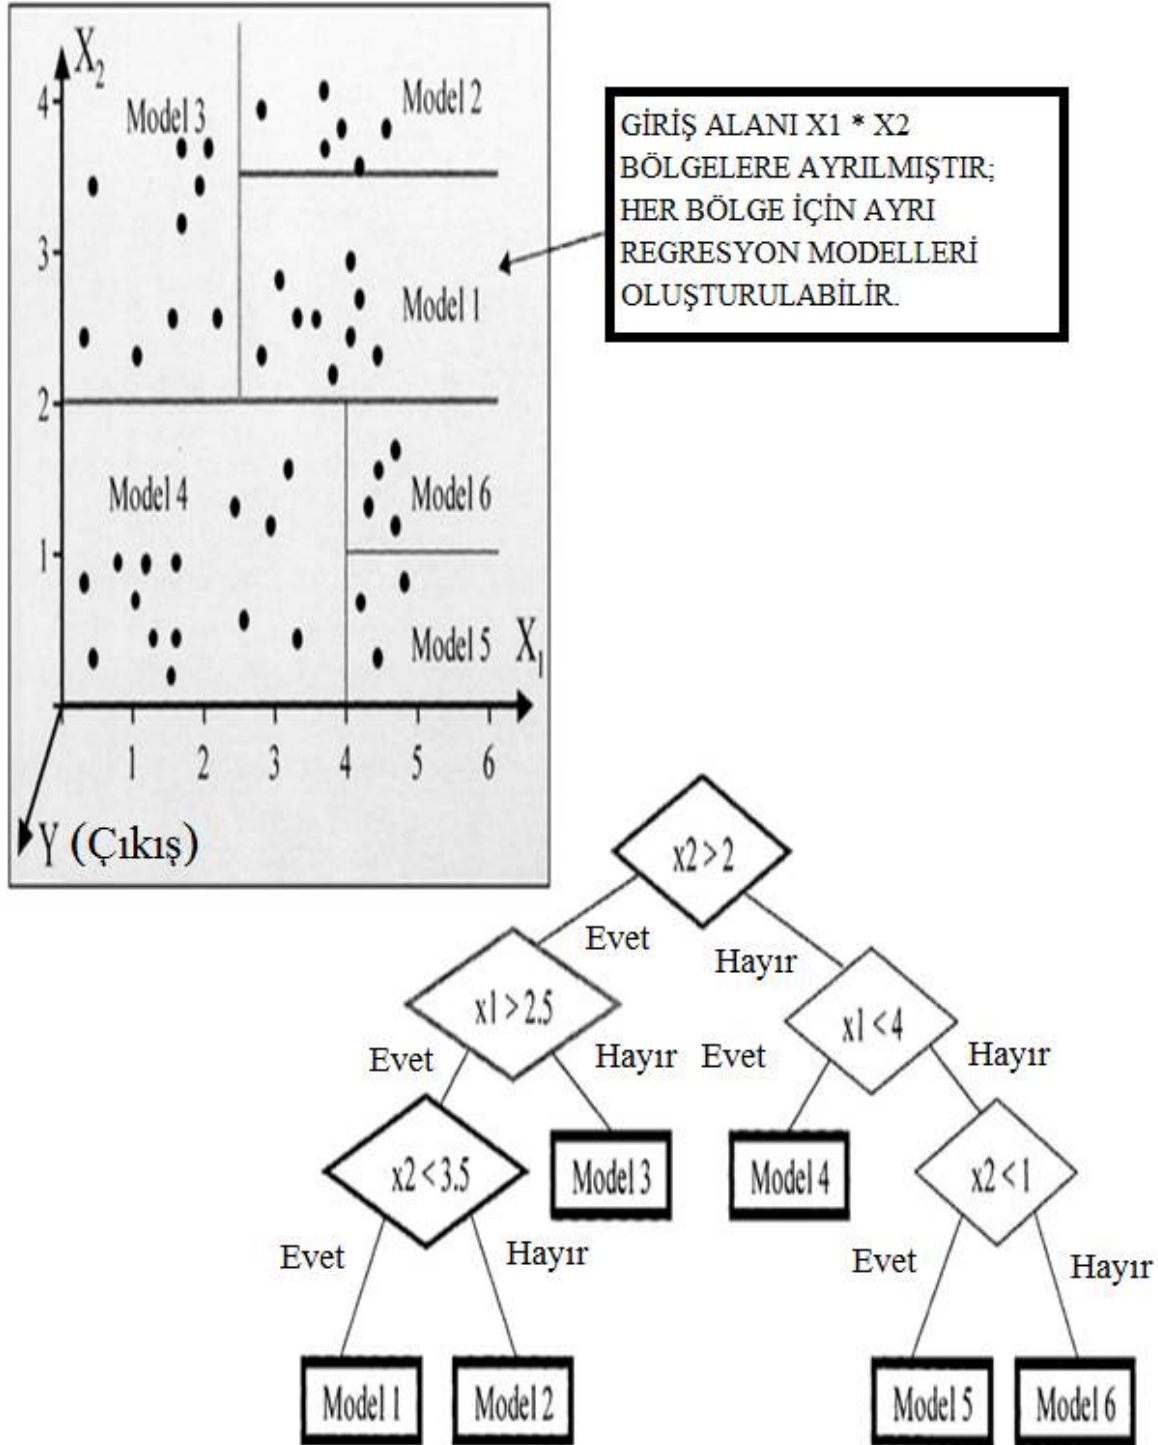
Minnesota bölgesine ait yer altı suyu seviyesinin tahmini için; Yapay Sinir Ağları (YSA) Çoklu Doğrusal Regresyon (ÇDR) ve M5 Karar Ağacı yöntemleri kullanılmaktadır. Veri tabanı olarak 29/08/2006-10/06/2012 tarihleri arasında Amerika Birleşik Devletleri Jeolojik Araştırma Kurumu'ndan (USGS) alınan 07040001 numaralı istasyonundan elde edilen ölçüm seviyeleri ve Amerika Birleşik Devletleri Jeolojik Araştırma Kurumu'ndan (USGS) alınan ortalama günlük sıcaklık, yağış değerleri kullanılmıştır. Çalışmanın bu bölümünde, kullanılan yöntemler ile ilgili temel açıklamalar bulunmaktadır.

### 3.2.1. M5 Karar Ağacı (M5T)

İlk olarak Quinlan (1992) tarafından geliştirilen M5 karar ağacı modeli, bağımlı ve bağımsız değişkenler arasındaki ilişkiyi sunmak için ağaç sınıflandırma yöntemine dayanmaktadır. Kategorik veriler için kullanılan karar ağacı modelinin aksine, M5 modeli hem kategorik hem de nicel veriler için kullanılabilir (Quinlan 1992). M5 modeli, regresyon ağacı modellerinin bir kombinasyonu olan ve farklı çalışma alanlarında geniş bir uygulamaya sahip olan parça bazında doğrusal fonksiyonlara benzemektedir. Regresyon modeli, tüm veri alanı için yalnızca bir regresyon denklemi verirken, regresyon ağacı modelinde veri alanı bazı alt bölgelere bölünür ve ardından yaprak etiketleri atanır.

M5 modelinde, bu modelin sürekli sayısal nitelikleri tahmin etmesini veya tahmin etmesini sağlayan düğümleri etiketlemek için doğrusal bir regresyon denklemi uygulanır (Quinlan 1992). Karar ağacının yapısı kökten, dallardan, düğümlerden ve yapraklardan oluşan bir ağaç gibidir. Kök, ilk düğüm ve yapraklara kadar uzanan bir dallar ve düğümler zinciri olarak en yüksek seviyede bulunur. Her düğüm bir tahmin değişkenine aittir ve düğümde bölünme meydana gelir. Dallar, bir ana düğümden bir alt düğüme ulaşmak için bölünen sayısal bir aralık içerir. M5 modelinde, her ana düğümden iki dal ayrılır. Karar ağacı modelinin oluşturulması iki adımda gerçekleştirilir. İlk adım, bir bölme kriteri kullanarak bir ağaç inşa etmekten oluşur. İkinci adım ise, dalların budanması ve bunların doğrusal regresyon modelleriyle değiştirilmesinden oluşur. Şekil 3.4'te M5 model ağacı örneği verilmiştir.





Şekil 3.4. M5 model ağacı örneği. 1-6 arasındaki modeller doğrusal regresyon modelleridir (Solomatine ve Xue, 2004).



### **Bölme kriteri**

Bölme kriteri, düğümdeki hata oranını açıklar ve düğümlerin standart sapmasını en aza indirmeye dayanır. Bölme işlemi nedeniyle, çocuk düğüm adı verilen belirli bir düğümdeki standart sapma, genellikle önceki düğümdeki ana düğüm adı verilen standart sapmadan daha küçüktür (Kişi, 2015). Düğümdeki standart sapmayı en aza indirmek mümkün olmadığında bir düğüm bir yapıakta biter. Belirli bir düğümde (SDR) standart sapmadaki azalmanın hesaplanması için aşağıdaki denklem kullanılır (Quinlan, 1992):

$$SDR = SD(T) - \sum_{i=1}^n \left(\frac{T_i}{T}\right) SD(T_i) \quad (1)$$

$$SD = \sqrt{\frac{1}{n} \left[ \sum_{i=1}^n Y_i^2 - \frac{1}{n} \left( \sum_{i=1}^n Y_i \right)^2 \right]} \quad (2)$$

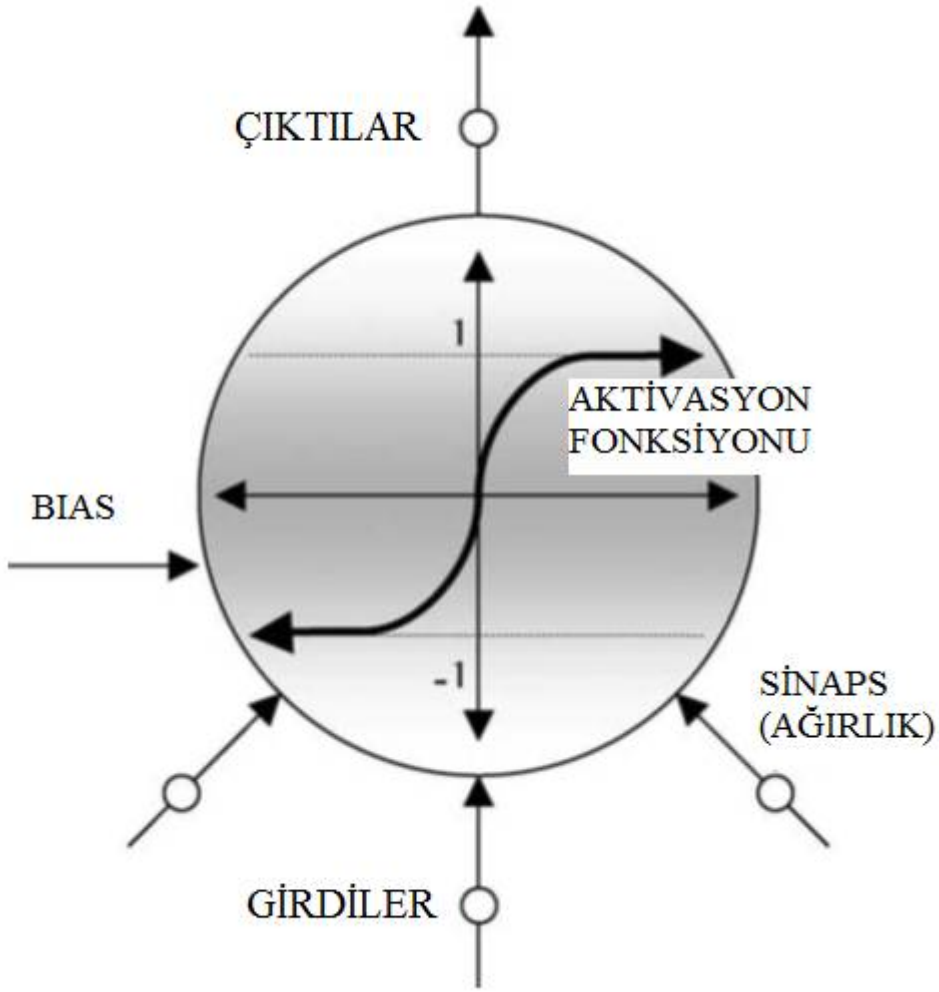
Bu denklemde T, ana düğüme ulaşan bir dizi eğitim verisidir; T<sub>i</sub>, potansiyel kümenin i'inci sonucuna sahip eğitim verilerinin bir alt kümesidir; ve SD standart sapmayı ifade eder (Kişi, 2015). M5 modeli, o düğümdeki her öznelik için minimum beklenen hatayı seçer.

### **Budama**

Bölme işlemi, eğitim verilerine aşırı uyuşmalara neden olabilecek devasa bir ağaç oluşturur. Bu nedenle dalları budamak gerekir. Budama için önerilen algoritma Quinlan algoritmasıdır. İlk olarak, algoritma ağacın olabildiğince büyümesine izin verir. İkincisi, modelin doğruluğunu artırmayan dalları budamaktadır. Son olarak, budama işleminden sonra, keskin ayrışmayı yumuşatmak için düzleştirme gereklidir (Solomatine ve Xue, 2004; Bhattacharya ve Solomatine, 2005).

### 3.2.2. Yapay Sinir Ağları (YSA)

Yeraltı suyu her zaman içme ve tarım suyu temini açısından önemli ve güvenilir bir kaynak olmuştur ve farklı kullanıcıların tüketim ihtiyaçlarını karşılamak için iyi bir kaynak olarak kabul edilmiştir (Firouzkouhi, 2011). Yeraltı suları farklı kronolojik seviyelerde doğal veya yapay streslere maruz kalır ve bu da yeraltı suyu seviyesinde dalgalanmalara neden olur. Bu nedenle, yeraltı suyunu kullanmak ve yönetmek ve ayrıca yeraltı suyu seviyesi dalgalanmalarını tahmin etmek için matematiksel modellere ihtiyaç vardır. Kavramsal ve fiziksel temelli modeller, hidrolojik değişkenleri tasvir etmek ve bir sistemde meydana gelen fiziksel süreçleri anlamak için ana araçlar olarak kabul edilir ancak pratik sınırlamaları vardır (Evrendilek ve Karakaya, 2015). Veriler yeterli olmadığında, doğru tahminler almak, gerçek fiziği kavramaktan daha önemlidir. Ampirik modeller iyi bir alternatif yöntem olmaya devam etmektedir ve genellikle maliyetli bir kalibrasyon süresi olmaksızın faydalı sonuçlar vermektedir (Lohani, Goel ve Bhatia, 2014). Yapay Sinir Ağı (YSA) modelleri, dinamik doğrusal olmayan sistem modellemesine büyük ölçüde uygun olan belirli özelliklere sahip bir “kara kutu” modelleridir (Agarwal, Lohani, Singh ve Kasiviswanathan, 2013). YSA modellerinin en önemli özelliklerinden biri de, karmaşık bir doğal sistemdeki tekrarlayan değişikliklere uyum sağlama ve modelleri algılama yetenekleridir. Hidrolojide, YSA modellerinin daha fazla kavramları ve uygulamaları, Govindaraju ve Ramachandra Rao, (2000) ve hidrolojide yapay sinir ağlarının uygulaması üzerine çalışan ASCE Görev Komitesi, (2000) tarafından tartışılmıştır. Sinir ağları, tek yapay nöronlardan oluşan devasa paralel işlemcilerdir. Şekil 3.5’te, bir sigmoid aktivasyon fonksiyonu, üç girişli sinaps ve bir çıkış sinaps ile tipik bir tek nöronu göstermektedir. Sinapslar, ağırlık değerlerinin saklandığı yapıyı temsil eder.



Şekil 3.5. Tipik bir yapay nöronu (Daliakopoulos, Coulibaly ve Tsanis, 2005)

Coppola Jr, Szidarovszky, Poulton ve Charles (2003) tarafından yapılan çalışmada YSA'nın, pompa ve farklı hava koşullarından etkilenerek kararsız durumda olan bir akiferin, yeraltı su seviyesindeki dalgalanmaları doğru bir şekilde tahmin etme potansiyeline sahip olduğu ve YSA da tahmin edilen sonuçların, nicel modellerden daha doğru olduğu ve ayrıca YSA modellerinin, diğer sayısal modellerin zayıf olduğu karstik ve sızdırmaya açık olan yeraltı sularını simüle etmede iyi olduğunu göstermişlerdir.

Feng, Kang, Huo, Chen ve Mao (2008) tarafından yapılan başka bir çalışmada, hava sıcaklıkları ve nem koşullarının yeraltı suyu seviyesi üzerindeki etkileri, Çin'in kuzey batısındaki Shenyang nehri havzasının alt kısmında sinir ağları ile simüle edilmiş ve kullanılan YSA modeli 0,37 ve ya daha az bir ortalama hata oranında yüksek bir doğrulukla yeraltı suyu seviyesini tahmin etmiştir.

Yapay sinir ağlarını yeraltı suyu seviyesi tahmininde kullanırken, yeraltı suyu seviyesini etkileyen, yağış, sıcaklık, bağıl nem ya da geçmiş yeraltı suyu seviyesi gibi parametreler belli zaman aralıklarında ortalama değerleri alınarak sisteme girdi verisi olarak tanımlanır. İncelenen zaman aralıklarında, çalışma alanı olarak belirlenen kuyunun, su seviyeleri ve ortalama yağış miktar değişimi veri olarak kullanılır. Genel olarak zaman serileri oluşturulurken yağış verileri göz önüne alınır. Çünkü yağış, yer altı seviyesini etkileyen çok ciddi etkenlerden biridir.

Son zamanlarda popülerleşen yapay sinir ağları, hidrolojik incelemelerde de giderek daha çok tercih edilen bir yöntem haline gelmektedir. Tercih sebeplerinden biri de matematiksel sistemlere nazaran gelecek zamanlı tahminlerdeki başarısıdır. Çünkü hidrolojik olaylar doğası gereği lineer değildir. Bu yüzden, tahminler yapılırken lineer olmayan olayları incelemeye uygun modellerin kullanılmasına ihtiyaç duyulmaktadır.

Bir yapay sinir ağı geliştirmek için çeşitli verilere ihtiyaç duyulmaktadır. Bu verilerin bir kısmı eğitim ve bir kısmı da test için kullanılmaktadır. Meydana getirilen ağda katman katman her verideki değişim ve tahmini etkileme süreci gözlenebilmektedir. Ağ verileri probleme uygun bir şekilde eğitildikten sonra sonuçlar test verileri ile test edilir ve böylelikle sağlama gerçekleştirilmiş olur. Eğitim verileri ile test verileri arasında istatistiksel yöntemlerle gerçeğe yaklaşıklık derecesi ölçülebilir.

Bu çalışmada, yeraltı suyu seviyesini tahmin etmek için en kararlı ve verimli sinir ağı konfigürasyonunu belirleme girişiminde bulunulmuştur ve yapay sinir ağlarını, özellikle ileri beslemeli sinir ağlarını, yeraltı suyu seviyesini tahmin etmek için uygun model olarak seçilmiştir.

### YSA modelinin seçilmesi

Bir sinir ağı, ağın işlem elemanları olan ve genellikle "nöronlar" olarak adlandırılan bir dizi düğümden oluşur. Her nöron diğer nöronlara bağlıdır, bir giriş sinyali alır, onu işler ve bir çıkış sinyaline dönüştürür (Haykin, 1994). Biyolojik nöronların işlevini yapay olarak yerine getirebilmek için, uygun bir yapay sinir ağı (YSA) tasarımı gereklidir. YSA için önemli girdiler seçildikten sonraki adım, uygun ağ mimarisinin seçimidir. Bu çalışma için çok katmanlı ileri beslemeli yapay sinir ağı modeli seçilmiştir, çünkü bu yöntem uygulama kolaylığı ve aynı zamanda evrensel bir tahmin edici olarak kabul edilmesi nedeniyle yeraltı suyu seviyelerinin simülasyonunda ve tahmininde yaygın olarak kullanılmıştır (Hornik, Stinchcombe ve White, 1989). Çok katmanlı bir ileri beslemeli sinir ağında, düğümler genellikle bir girdi katmanı, bir çıktı katmanı ve bir veya daha fazla gizli katman içeren katmanlar halinde düzenlenir. Üç katmanlı ileri beslemeli sinir sistemi bu çalışmada kullanıldığı gibi giriş katmanı (3 giriş nöronlu), bir gizli katman ve bir çıkış katmanına sahiptir. Giriş ve gizli düğümler arasındaki bağlantılarla ilgili ağırlıklar  $w_{ij}$  ile gizli ve çıkış düğümleri arasındaki ağırlıklar ise  $w_{jk}$  ile gösterilir. Yapay bir nörona bir ön yargı teriminin eklenmesi, boyutluluklarının birer birer artmasıyla sonuçlanan genişletilmiş vektörler yaratmak için girdi ve ağırlık vektörlerine bir ön yargı elemanı dahil edilmesi olarak ifade edilebilir. Nöronlar arasındaki bağlantıya ek ağırlıklar sağlayarak sinir ağına öğrenme modellerinde yardımcı olduğu için yararlıdır ve önyargı girişine genellikle pozitif bir değer atanır (Haykin, 1994). Gizli katmandaki ( $z_j$ ) bir düğümün çıktısı, girdi katmanındaki nöronlardan aldığı ağırlıklı girdilerin toplamına doğrusal olmayan bir dönüşüm (aktivasyon fonksiyonu) uygulanarak belirlenir. Daha sonra çıkış katmanındaki girişlerin ağırlıklı toplamı, gizli ve çıkış katmanı arasında doğrusal bir aktivasyon fonksiyonu kullanılarak ağ çıkışına dönüştürülür. Böylece YSA modelinin ( $y_k$ ) tahmini şu şekilde ifade edilebilir (Haykin, 1994) :

$$y_k = \sum_{j=1}^I (w_{jk}z_j + b_j) \quad (3)$$

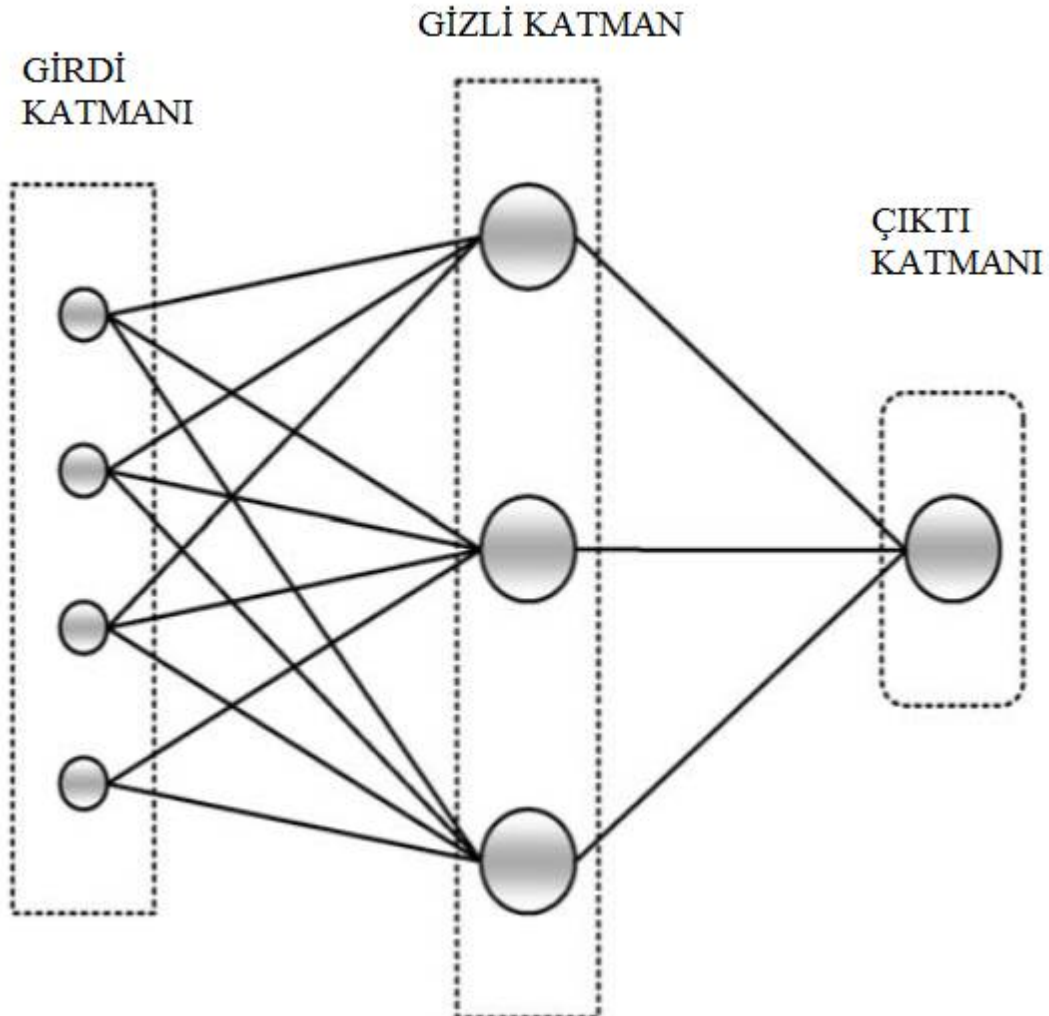
Bu denklemde;

$w_{jk}$ , j'ninci gizli katman düğümü ile k çıkış nöronu arasındaki bağlantı ağırlığıdır. I ise gizli katmandaki nöron sayısıdır.  $z_j$ , tüm girdi verilerinden elde edilen j. gizli nöronun çıktısıdır ve son olarak  $b_j$ , önyargı terimi için bağlantı ağırlığıdır.

### **Kullanılan YSA modeli ( ileri beslemeli sinir ağı )**

En yaygın kullanılan yöntem ileri beslemeli yapay sinir ağları modelleridir. İleri beslemeli sinir ağları, hata geri yayılım öğrenme algoritmasının ortaya çıkmasından beri birçok farklı problemde başarıyla uygulanmıştır. Bu ağ mimarisi ve ilgili öğrenme algoritması, popüler en küçük ortalama kare yöntemi (EOK) algoritmasının bir genellemesi olarak görülebilir (Haykin, 1999).

Çok katmanlı bir algılama ağı, dört girdi katmanı, bir veya birden fazla gizli hesaplama katmanı ve bir çıktı katmanı içerir. Şekil 3.6'da tipik bir çok katmanlı algılama ağı gösterilmiştir. Giriş sinyali, sinirsel ağda ileri yönlü katmanların oluşmasına sebep olur. Hornik, Stinchcombe ve White (1989) tarafından yayınlanan girdi çıktı haritasında da gösterildiği gibi bu ağların en büyük avantajı kullanımının kolay olmasıdır. Bu ağın başlıca dezavantajı yavaş eğitilmesi ve pek çok eğitim verisine ihtiyaç duymasıdır.



Şekil 3.6. Tipik ileri beslemeli sinir ağı (Daliakopoulos, Coulibaly ve Tsanis, 2005)

### 3.2.3. Çoklu Doğrusal Regresyon (ÇDR)

Bir bağımlı değişkenin, ne kadar etkilendiğini ve bağımsız değişkenlerin değerini ne kadar etkilediğini bulmak için kullanılan bir yöntemdir.

Bağımlı değişken  $y$ ,  $(x_0, x_1, x_2, \dots, x_p)$  bağımsız değişkenleri cinsinden ifade edilebilir ve aralarındaki ilişki aşağıdaki denklemdeki gibi yazılır;

$$y = a_0 + a_1x_1 + a_2x_2 \dots \dots \dots + a_px_p + \varepsilon \quad (4)$$

Denklem (4)'de  $a_0, a_1, a_2, \dots, a_p$  regresyon katsayıları olarak adlandırılır.  $\varepsilon$ , gerçek bağımlı değişken ( $y$ ) ile yerleşik doğrusal regresyon ilişkisi arasındaki farkı yansıtan hata bileşenidir. Herhangi bir regresyon katsayısı üst değeri, diğer değişkenler sabit tutulduğunda, yani diğer değişkenlerin hiçbir etkisi olmadığında,  $x_p$ 'deki bir birimlik değişime karşı değişkenlerde beklenen değişim miktarını verir. Diğer bir deyişle;  $a_0, a_1, a_2, \dots, a_p$  bağımsız değişkenlerin  $y$ 'nin belirlenmesine göreli katkısının ağırlıklarındadır. Bu nedenle  $a_p$  genellikle kısmi regresyon katsayısı olarak adlandırılır.  $a_0$ , bir kesme noktası veya sabit olarak adlandırılır ve tüm  $x_p$  değişken değerleri sıfır olduğunda, bağımlı değişkenin değerini temsil eder.

### 3.3. Model Analizinde Kullanılan İstatistiksel Parametreler

Determinasyon katsayısı ( $R^2$ ), kök ortalama kare hata (KOKH) ve ortalama mutlak hata (OMH)

Determinasyon Katsayısı ( $R^2$ ),  $x$  ve  $y$  ikili doğrusal bağlantının gücünü ölçer ve çıkan sonuçların 0 ile 1 değerleri arasında çıkması beklenir. Çıkan sonuç 1'e ne kadar yakın olursa, gerçeğe o kadar yaklaşır. Eğer sonuç 0'a yakın şekilde çıkarsa, sonuç o kadar gerçekten uzaklaşır.  $R^2$ 'ye güven verisi sayısı arttıkça artar. Aşağıda  $R^2$ 'nin denklemi şekilde verilmiştir.

$$(R^2) = \left( \frac{n\sum xy - (\sum x)(\sum y)}{\sqrt{(n\sum x^2) - (\sum x)^2} \sqrt{(n\sum y^2) - (\sum y)^2}} \right) \quad (5)$$

Ortalama Mutlak Hata (OMH), gerçek ile tahmini değer arasındaki farkı önemsemeden oluşan hataların ortalama büyüklüklerini ölçer. Çıkan hata oranları sıfırdan sonsuza kadar

değer alabilirler ve oranlar birim olarak ifade edilir. Aşağıda OMH'nın denklemi verilmiştir ve bu denklemde, (N) veri sayısını (YASS) ise yeraltı su seviyesini temsil eder.

$$OMH = \frac{1}{N} \sum_{i=1}^N |YASS_{ölçüm} - YASS_{tahmin}| \quad (6)$$

Kök Ortalama Kare Hata (KOKH), aynı büyüklüğün ölçülmesi sonucunda elde edilen bir ölçü dizisinin, gerçek hatalarının kareleri toplamının ölçü sayısına bölünüp, çıkan sonucun karekökü alınarak bulunan değerdir. Karelerinin ortalaması ne kadar küçük ise program gerçeğe o kadar yakın demektir. Aşağıda (KOKH)'nın denklemi verilmiştir ve bu denklemde, (N) veri sayısını (YASS) ise yeraltı su seviyesini temsil eder.

$$KOKH = \sqrt{\frac{1}{N} \sum_{i=1}^N (YASS_{ölçüm} - YASS_{tahmin})^2} \quad (7)$$



## 4. ARAŞTIRMA BULGULARI ve TARTIŞMA

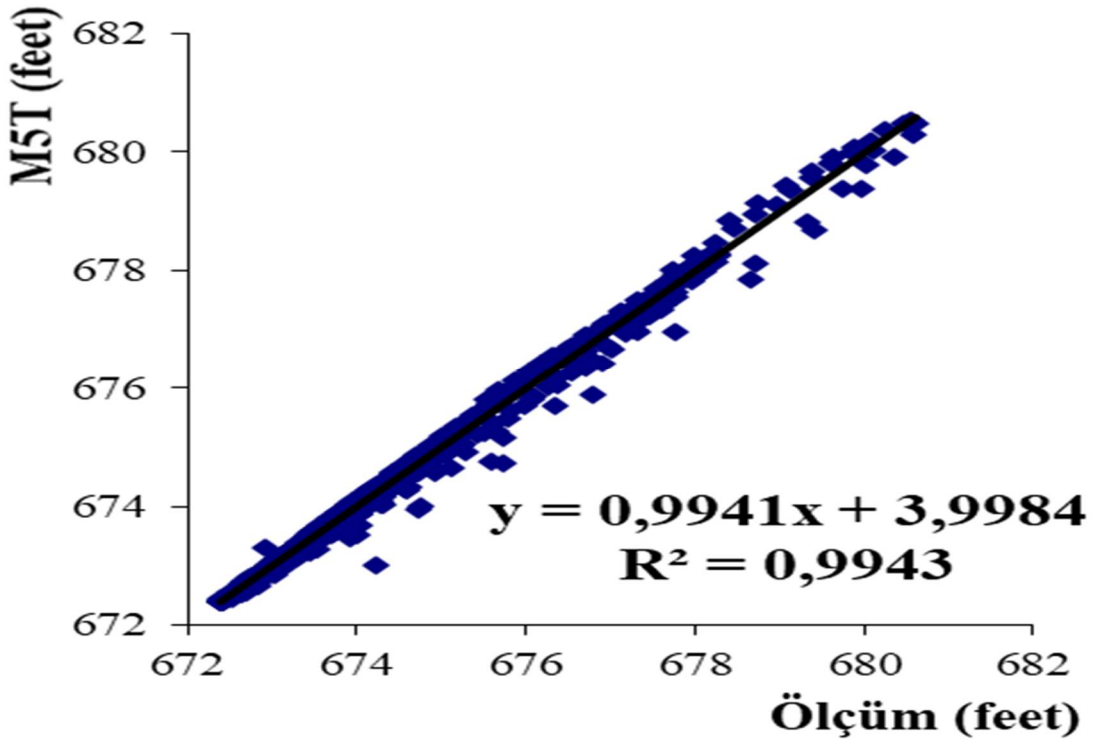
Bu bölümde, yeraltı su seviyesindeki değişimlerini tahmin etmek amacı ile Yapay Sinir Ağları modeli (YSA), Çoklu Doğrusal Regresyon (ÇDR) ve M5 Karar Ağacı modellerinin sonuçları incelenmiştir. Çalışmada kullanılan modellerin karşılaştırılmasında kullanılan istatistiksel parametreler hakkında bilgi verilecek olup, diğer kısımlarda modellere ait sonuçların grafiksel gösterimi, yorumlanması yapılmıştır.

### 4.1. Model Sonuçları

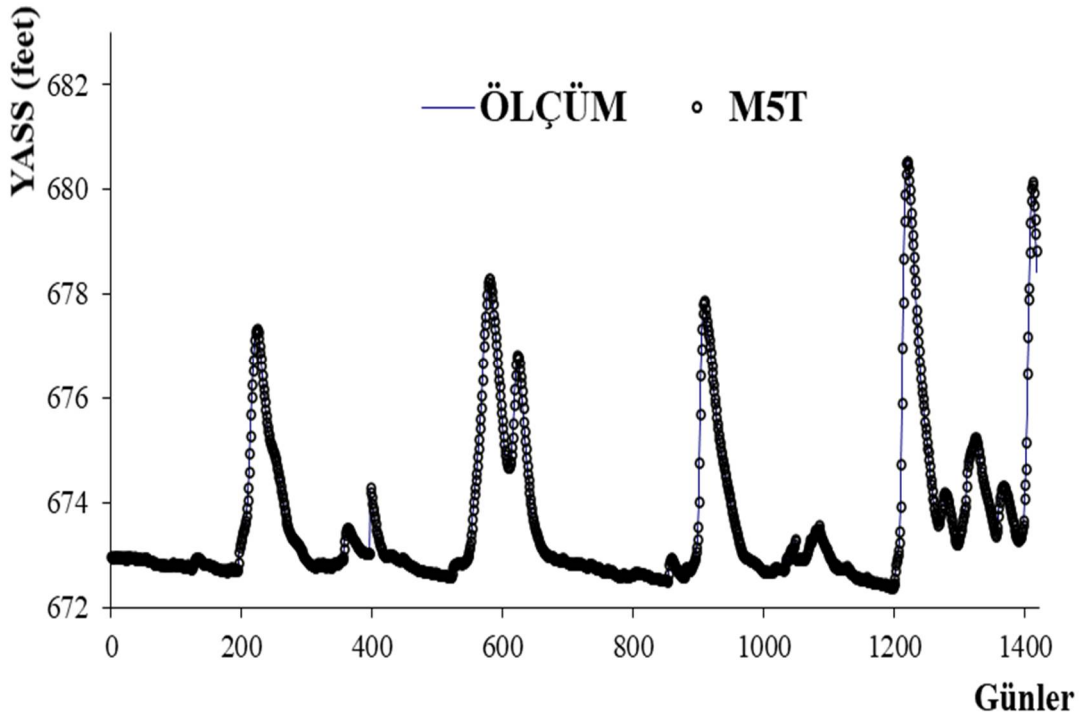
Çalışmada, YSA, ÇDR VE M5T modellerinin sonuçları incelenmiştir. Bu modellere ait sonuç aşağıda verilmiştir.

#### 4.1.1 M5 Karar Ağacı (M5T) model sonuçları

Bu çalışmadaki yeraltı suyu seviyesi (YASS) tahmininde kullanılan modellerden biri olan M5 Karar Ağacı modeli için 29/08/2006-10/06/2012 yılları arasında USGS'den elde edilen 2025 günlük veriler değerlendirilmiş ve sonuçlar aşağıdaki gibi tanımlanmıştır. YASS tahmininde M5T modeli için girdi katmanını nodları olarak, USGS'den elde edilen önceki geçmiş günlük yeraltı su seviyesi, sıcaklık ve yağış verileri alınmıştır. İlk aşama olarak eğitim için 29/08/2006-10/06/2012 yılları arasında USGS'den alınan 1419 günlük önceki gün yeraltı suyu seviyesi, sıcaklık ve yağış parametreleri veri olarak kullanılmış ve M5T modelinde uygulanmıştır. Çıkan sonuçlar, Şekil 4.1 ve Şekil 4.2'de gösterildiği gibi saçılım ve dağılım grafikleri şeklinde gösterilmiştir.




Şekil 4.1. Yeraltı su seviyesi eğitim verileri için ölçüm ve M5 Karar Ağacı saçılım grafiği



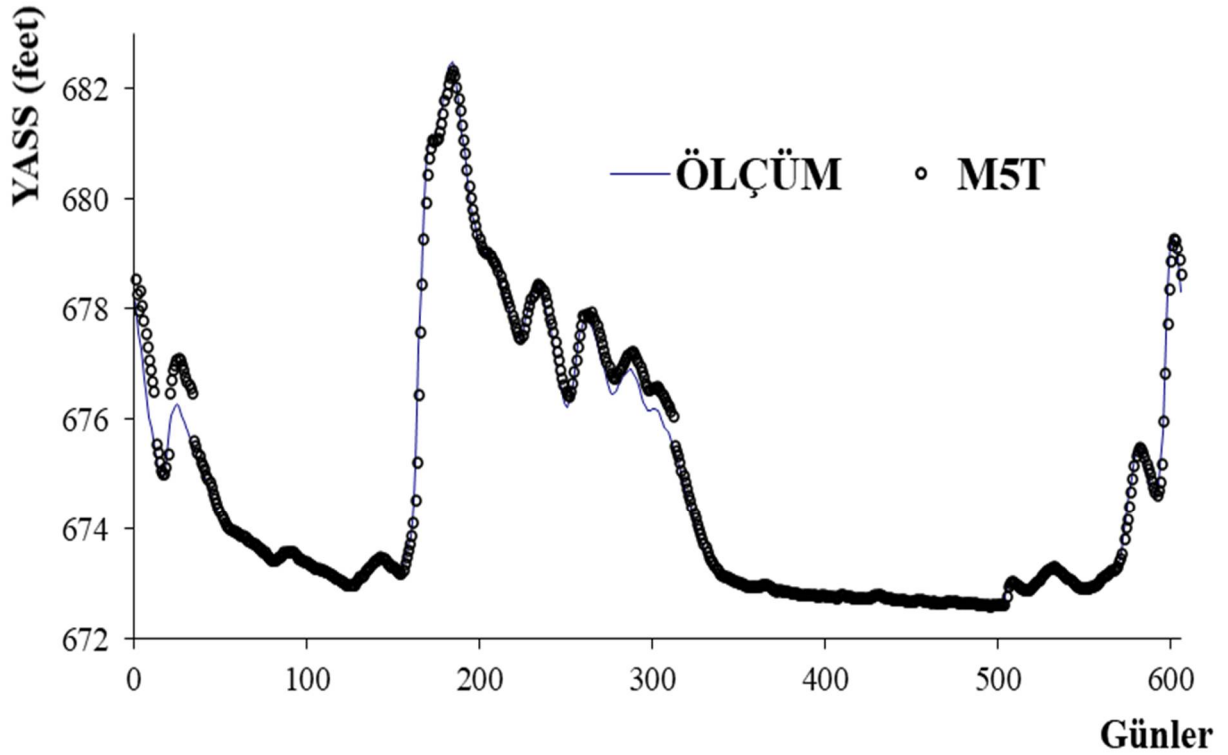
Şekil 4.2. Yeraltı su seviyesi eğitim verileri için ölçüm ve M5 Karar Ağacı dağılım grafiği

Şekil 4.1 ve Şekil 4.2 incelendiğinde M5T modelinin determinasyon katsayısının  $R^2 = 0,9943$  olduğu ve tahmin değerlerinin gerçek değerlere yakın olduğu tespit edilmiştir.

Eğitim verilerinin analizi ile elde edilen M5T modeli, geriye kalan diğer 606 günlük önceki günlük yeraltı su seviyesi, sıcaklık ve yağış parametreleri veri olarak kullanılmış ve test edilmiştir. Test sonuçlarının saçılım ve dağılım grafikleri aşağıdaki Şekil 4.3 ve Şekil 4.4'te ki gibi gösterilmiştir.



Şekil 4.3. Yeraltı su seviyesi test verileri için ölçüm ve M5 Karar Ağacı saçılım grafiği




Şekil 4.4. Yeraltı su seviyesi test verileri için ölçüm ve M5 Karar Ağacı dağılım grafiği


Şekil 4.3 ve Şekil 4.4 incelendiğinde, bu test sonucunda M5T modelinin determinasyon katsayısının  $R^2 = 0,9901$  olduğu ve tahmin değerlerinin gerçek değerlere yakın olduğu tespit edilmiştir.

#### 4.1.2 Yapay Sinir Ağları (YSA) model sonuçları

Bu çalışmadaki yeraltı suyu seviyesi (YASS) tahmininde kullanılan modellerden biri olan YSA modeli için 29/08/2006-10/06/2012 yılları arasında USGS'den elde edilen 2025 günlük veriler değerlendirilmiş ve sonuçlar aşağıdaki gibi tanımlanmıştır. YASS tahmininde YSA modeli için girdi katmanı nodları olarak, USGS'den elde edilen önceki geçmiş günlük yeraltı su seviyesi, sıcaklık ve yağış verileri alınmıştır. İlk aşama olarak eğitim için 29/08/2006-10/06/2012 yılları arasında USGS'den alınan 1419 günlük önceki gün yeraltı suyu seviyesi, sıcaklık ve yağış parametreleri veri olarak kullanılmış ve YSA modelinde uygulanmıştır. Çıkan sonuçlar Şekil 4.5 ve Şekil 4.6'da gösterildiği gibi saçılım ve dağılım grafikleri şeklinde gösterilmiştir.




Şekil 4.5. Yeraltı su seviyesi eğitim verileri için ölçüm ve YSA saçılım grafiği




Şekil 4.6. Yeraltı su seviyesi eğitim verileri için ölçüm ve YSA dağılım grafiği

Şekil 4.5 ve Şekil 4.6 incelendiğinde YSA modelinin determinasyon katsayısının  $R^2 = 0,9934$  olduğu ve tahmin değerlerinin gerçek değerlere yakın olduğu tespit edilmiştir.

Eğitim verilerinin analizi ile elde edilen YSA modeli, geriye kalan diğer 606 günlük önceki günlük yeraltı su seviyesi, sıcaklık ve yağış parametreleri veri olarak kullanılmış ve test edilmiştir. Test sonuçlarının saçılım ve dağılım grafikleri aşağıdaki Şekil 4.7 ve Şekil 4.8'de ki gibi gösterilmiştir.



Şekil 4.7. Yeraltı su seviyesi test verileri için ölçüm ve YSA saçılım grafiği




Şekil 4.8. Yeraltı su seviyesi test verileri için Ölçüm ve YSA dağılım grafiği


Şekil 4.7 ve Şekil 4.8 incelendiğinde, bu test sonucunda YSA modelinin determinasyon katsayısının  $R^2 = 0,9918$  olduğu ve tahmin değerlerinin gerçek değerlere yakın olduğu tespit edilmiştir.

#### 4.1.3. Çoklu Doğrusal Regresyon (ÇDR) model sonuçları

Bu çalışmadaki yeraltı suyu seviyesi (YASS) tahmininde kullanılan modellerden biri olan ÇDR modeli için 29/08/2006-10/06/2012 yılları arasında USGS'den elde edilen 2025 günlük veriler değerlendirilmiş ve sonuçlar aşağıdaki gibi tanımlanmıştır. YASS tahmininde ÇDR modeli için girdi katmanı nodları olarak, USGS'den elde edilen önceki geçmiş günlük yeraltı su seviyesi, sıcaklık ve yağış verileri alınmıştır. İlk aşama olarak eğitim için 29/08/2006-10/06/2012 yılları arasında USGS'den alınan 1419 günlük önceki gün yeraltı suyu seviyesi, sıcaklık ve yağış parametreleri veri olarak kullanılmış ve ÇDR modelinde uygulanmıştır. Çıkan sonuçlar Şekil 4.9 ve Şekil 4.10'da gösterildiği gibi saçılım ve dağılım grafikleri şeklinde gösterilmiştir.



Şekil 4.9. Yeraltı su seviyesi eğitim verileri için ölçüm ve ÇDR saçılım grafiği




Şekil 4.10. Yeraltı su seviyesi eğitim verileri için ölçüm ve ÇDR dağılım grafiği




Şekil 4.9 ve Şekil 4.10 incelendiğinde M5T modelinin determinasyon katsayısının  $R^2 = 0,9934$  olduğu ve tahmin değerlerinin gerçek değerlere yakın olduğu tespit edilmiştir.

Eğitim verilerinin analizi ile elde edilen ÇDR modeli, geriye kalan diğer 606 günlük önceki günlük yeraltı su seviyesi, sıcaklık ve yağış parametreleri veri olarak kullanılmış ve test edilmiştir. Test sonuçlarının saçılım ve dağılım grafikleri aşağıdaki Şekil 4.11 ve Şekil 4.12’de ki gibi gösterilmiştir.



Şekil 4.11. Yeraltı su seviyesi test verileri için ölçüm ve ÇDR saçılım grafiği



Şekil 4.12. Yeraltı su seviyesi test verileri için ölçüm ve ÇDR dağılım grafiği

Şekil 4.11 ve Şekil 4.12 incelendiğinde, bu test sonucunda ÇDR modelinin determinasyon katsayısının  $R^2 = 0,9901$  olduğu ve tahmin değerlerinin gerçek değerlere yakın olduğu tespit edilmiştir.

Çizelge 4.1. YASS tahmininde kullanılan model sonuçlarının karşılaştırılması

MODELLER	GİRDİ	KOKH(m)	OMH(m)	$R^2$
M5T	Y(t), S(t), YASS(t-1)	0,38	0,22	0,990
YSA	Y(t), S(t), YASS(t-1)	0,29	0,17	0,992
ÇDR	Y(t), S(t), YASS(t-1)	0,21	0,11	0,996

**KOKH:** Kök Ortalama Kare Hata, **OMH:** Ortalama Mutlak Hata,  **$R^2$ :** Determinasyon Katsayısı.  
**Y(t):** Günlük Ortalama Yağış, **S(t):** Günlük Ortalama Sıcaklık, **YASS(t-1):** Önceki günkü Günlük Ortalama Yeraltı Suyu Seviyesi

Çizelge 4.1'e göre KOKH, OMH ve  $R^2$ 'ye göre, tüm modeller iyi sonuç vermiştir. Tüm modeller değerlendirildiğinde ise; az da olsa düşük hata ve yüksek determinasyon katsayısı ile ÇDR (0,21-0,11-0,996) modeli M5T ve YSA modellerinden daha iyi performans gösterdiği bulunmuştur.

## 5.SONUÇ ve ÖNERİLER

Yapılan bu çalışmada, çalışma alanı olarak Amerika Birleşik Devletleri'ndeki Minnesota eyaletinde yer alan Prairie adası yakınlarındaki PI98-14 numaralı gözlem kuyusu rezervuarı seçilmiştir. Çalışılan istasyondan 29/08/2006-10/06/2012 tarihleri arasındaki 2025 günlük yağış, sıcaklık ve yer altı su seviyesi gibi meteorolojik ve hidrolojik veriler alınmıştır. Çalışmada belirlenen istasyondan toplam 2025 günlük veri toplanmıştır. Bu verilerin 1419 adedi yani %70'i eğitim sürecinde kalan 606 adedi yani %30 ise test aşamasında kullanılmıştır.

Bu çalışmada, yeraltı suyu seviyesi tahmin edilmeye çalışılmış ve M5 Karar Ağacı (M5T), Yapay Sinir Ağları (YSA) ve Çoklu Doğrusal Regresyon (ÇDR) gibi üç farklı tahmin modeli kullanılmıştır. Kullanılan modellerde girdi olarak yağış, sıcaklık ve önceki günkü yer altı suyu seviyesi gibi meteorolojik ve hidrolojik parametreler veri olarak kullanılmıştır. Bu modellerde çıkan tahmin sonuçları birbirleri ile karşılaştırmış ve sonuçlar değerlendirilmiştir.

Modeller kendi aralarında değerlendirildiğinde, Çizelge 4.1'de gösterildiği gibi M5T, YSA ve ÇDR modellerinin determinasyon katsayıları ( $R^2$ ) birbirine çok yakın ve neredeyse 1 çıkmıştır fakat az da olsa ÇDR (0,21–0,11-0,996) modeli diğer YSA ve M5T modellerinden daha iyi bir sonuç verdiği görülmüştür. Diğer, ortalama mutlak hata (OMH) ve kök ortalama kare hata (KOKH) gibi hata oranlarına bakacak olursak da yine bütün modellerin az bir oranda hata verdiği fakat yine ÇDR modelinin diğer M5T ve YSA modelinden daha az bir hata oranı vererek daha iyi bir sonuca ulaştığı görülmüştür. Bu sonuçlara bakarak her üç modelinde verdiği sonuçların kullanılabilir düzeyde ve anlamlı olduğu bu  $R^2$ , OMH ve KOKH gibi istatistiksel değerlendirme yöntemleri kullanılarak belirlenmiştir.

Çalışma sonucunda M5T, YSA ve ÇDR modelleri yağış, sıcaklık yeraltı suyu seviyesi verileri kullanılarak yapılan yeraltı suyu tahmininde başarılı olduğu görülmüştür. Böylece, her üç yöntem de kullanılabilir olup eldeki veriler ve araştırılacak konuya göre yöntemlerden birinin tercih edilmesi uygun olacaktır. M5T, YSA ve ÇDR modellerinin üçü de yeraltı suyu seviyesi tahmini yapılmasında tavsiye edilebilir modeller olduğu görülmüştür.

Sonuç olarak, yeraltı suyu seviyesi, çok deęişkenli doğrusal olmayan bir olay olduęu için yeraltı suyu seviyesinde meydana gelen deęişimler incelenirken tüm parametreleri doğru olarak belirlemek ve bu parametrelerden alınan verilerden doğru şekilde yapay zeka tekniklerinde uygulanması büyük önem arz etmektedir. Bundan sonraki çalışmalar için farklı yapay zeka tekniklerinin, geçmiş mevsimsel parametrelere baęlı olarak yeraltı suyu seviyesi deęişiminin belirlenmesinde verimli olacağı düşünölmektedir.



## KAYNAKLAR

- Adamowski, J., & Chan, H. F. (2011). A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*, 407(1-4), 28-40.
- Agarwal A, Lohani AA, Singh RD, Kasiviswanathan KS (2013) Radial Basis Artificial Neural Network Models and Comparative Performance. *J Indian Water Resour Soc* 33: 1-8. 5.
- American Society of Civil Engineers Task Committee. (2000). The ASCE task committee on application of artificial neural networks in hydrology. *J. Hydrol. Eng*, 5(2), 115-137.
- Bacanlı, Ü. G., & Baran, T. (2004). Stokastik modellerde yıllık akım verilerinde uygunluk kriterlerinin değerlendirilmesi. IV Ulusal Hidroloji Kongresi, 23-25 Haziran. *İstanbul, Türkiye*, 215-225.
- Bărbulescu A (2016) Studies on Time Series Applications in Environmental Sciences. Springer International Publishing, Cham, Switzerland. <https://doi.org/10.1007/978-3-319-30436-6>
- Bayazıt, M. (1981). Hidrolojide İstatistik Yöntemler. *İstanbul Teknik Üniversitesi, Yayın No : 1197*, 223 s.
- Bhattacharya, B., & Solomatine, D. P. (2005). Neural networks and M5 model trees in modelling water level–discharge relationship. *Neurocomputing*, 63, 381-396.
- Chang, L. C., Amin, M., Yang, S. N., & Chang, F. J. (2018). Building ANN-based regional multi-step-ahead flood inundation forecast models. *Water*, 10(9), 1283.
- Charulatha G, Srinivasalu S, Maheswari OU, Venugopal T, Giridharan L (2017) Evaluation of ground water quality contaminants using linear regression and artificial neural network models. *Arab J Geosci* 10:128
- Csábrági A, Molnár S, Tanos P, Kovács J (2017) Application of artificial neural networks to the forecasting of dissolved oxygen content in the Hungarian section of the river Danube. *Ecol Eng* 100:63–72
- Daliakopoulos, I. N., Coulibaly, P., & Tsanis, I. K. (2005). Groundwater level forecasting using artificial neural networks. *Journal of hydrology*, 309(1-4), 229-240.
- Ehteram, M., Karami, H., Mousavi, S. F., Farzin, S., Celeste, A. B., & Shafie, A.-E. (2018). Reservoir operation by a new evolutionary algorithm: *Kidney algorithm*. *Water Resources Management*, 32(14), 4681–4706.
- Ehteram, M., Singh, V. P., Ferdowsi, A., Mousavi, S. F., Farzin, S., Karami, H., et al. (2019). An improved model based on the support vector machine and cuckoo algorithm for simulating reference evapotranspiration. *PLoS ONE*, 14(5), e0217499.

- Emamgholizadeh, S., Moslemi, K., & Karami, G. (2014). Prediction the groundwater level of bastam plain (Iran) by artificial neural network (ANN) and adaptive neuro-fuzzy inference system (ANFIS). *Water resources management*, 28(15), 5433-5446.
- Evrendilek, F., & Karakaya, N. (2015). Spatiotemporal modeling of saturated dissolved oxygen through regressions after wavelet denoising of remotely and proximally sensed data. *Earth Science Informatics*, 8(1), 247-254.
- Firouzkouhi, R. (2011). *Simulating groundwater resources of Aghili-Gotvand plain by using mathematical model of finite differences*. Msd (Doctoral dissertation, Thesis, Shahid Chamran University of Ahwaz, Iran).
- Ghorbani, M. A., Deo, R. C., Karimi, V., Yaseen, Z. M., & Terzi, O. (2018). Implementation of a hybrid MLP-FFA model for water level prediction of Lake Egirdir, Turkey. *Stochastic Environmental Research and Risk Assessment*, 32(6), 1683– 1697.
- Gong, Y., Wang, Z., Xu, G., & Zhang, Z. (2018). A comparative study of groundwater level forecasting using data-driven models based on ensemble empirical mode decomposition. *Water*, 10(6), 730.
- Govindaraju & Ramachandra Rao, S. (2000). Artificial neural networks in hydrology. II: hydrologic applications. *Journal of Hydrologic Engineering*, 5(2), 124-137.
- Haykin, S. (1994). *Neural Networks*, Mcmillan College Publishing Company. New York.
- Haykin, S. (1999). *Neural networks: a comprehensive foundation*. Prentice hall.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural networks*, 2(5), 359-366.
- İnternet: USGS. URL <https://www.usgs.gov/>.
- İspir, E. (2017). *Hatay Amik Ovası Kumlu bölgesindeki yer altı suyu seviyesinin yapay sinir ağları yöntemi ile tahmini* (Master's thesis, İskenderun Teknik Üniversitesi/Mühendislik ve Fen Bilimleri Enstitüsü/İnşaat Mühendisliği Anabilim Dalı).
- Javadinejad, S., Dara, R., & Jafary, F. (2020). Modelling groundwater level fluctuation in an Indian coastal aquifer. *Water SA*, 46(4), 665-671.
- Karami, H., Farzin, S., Jahangiri, A., Ehteram, M., Kisi, O., & ElShafie, A. (2019). Multi-reservoir system optimization based on hybrid gravitational algorithm to minimize water-supply deficiencies. *Water Resources Management*, 33, 1–20.
- Karami, H., Mousavi, S. F., Farzin, S., Ehteram, M., Singh, V. P., & Kisi, O. (2018). Improved krill algorithm for reservoir operation. *Water Resources Management*, 32(10), 3353–3372.
- Khan UT, He J, Valeo C (2018) River flood prediction using fuzzy neural networks: an investigation on automated network architecture. *Water Sci Technol* 2017 1:238–247

- Khandelwal, M., Marto, A., Fatemi, S. A., Ghoroghi, M., Armaghani, D. J., Singh, T. N., et al. (2018). Implementing an ANN model optimized by genetic algorithm for estimating cohesion of limestone samples. *Engineering with Computers*, 34(2), 307–317.
- Kisi O, Azad A, Kashi H (2019) Modeling Groundwater Quality Parameters Using Hybrid Neuro-Fuzzy Methods. *Water Resour Manage* 33:847–861
- Kişi, Ö. (2015). Pan evaporation modeling using least square support vector machine, multivariate adaptive regression splines and M5 model tree. *Journal of Hydrology*, 528, 312-320.
- Lee, S., Lee, K.-K., & Yoon, H. (2018). Using artificial neural network models for groundwater level forecasting and assessment of the relative impacts of influencing factors. *Hydrogeology Journal*, 27(2), 567–579.
- Lohani, A. K., Goel, N. K., & Bhatia, K. K. S. (2014). Improving real time flood forecasting using fuzzy inference system. *Journal of hydrology*, 509, 25-41.
- Maroufpoor, S., Fakheri-Fard, A., & Shiri, J. (2017). Study of the spatial distribution of groundwater quality using soft computing and geostatistical models. *ISH Journal of Hydraulic Engineering*, 25(2), 232–238.
- Maruf, A. G. (2019). *Hatay ili Dörtüyl bölgesi yer altı su seviyesinin bulanık mantık, çoklu lineer regresyon ve arma modelleri ile tahmini* (Master's thesis, İskenderun Teknik Üniversitesi/Mühendislik ve Fen Bilimleri Enstitüsü/İnşaat Mühendisliği Anabilim Dalı).
- Mayilvaganan, M. K., & Naidu, K. B. (2011). ANN and Fuzzy Logic Models for the Prediction of groundwater level of a watershed. *International Journal on Computer Science and Engineering*, 3(6), 2523-2530.
- Meenal, R., & Selvakumar, A. I. (2018). Assessment of SVM, empirical and ANN based solar radiation prediction models with most influencing input parameters. *Renewable Energy*, 121, 324–343.
- Moayedi, H., & Armaghani, D. J. (2018). Optimizing an ANN model with ICA for estimating bearing capacity of driven pile in cohesionless soil. *Engineering with Computers*, 34(2), 347–356.
- Mogaji, K. A., San Lim, H., & Abdullah, K. (2015). Modeling of groundwater recharge using a multiple linear regression (MLR) recharge model developed from geophysical parameters: a case of groundwater resources management. *Environmental Earth Sciences*, 73(3), 1217-1230.
- Nadiri, A. A., Naderi, K., Khatibi, R., & Gharekhani, M. (2019). Modelling groundwater level variations by learning from multiple models using fuzzy logic. *Hydrological Sciences Journal*, 64(2), 210–226.
- Nalarajan, N. A., & Mohandas, C. (2015). Groundwater level prediction using M5 model trees. *Journal of The Institution of Engineers (India): Series A*, 96(1), 57-62.

- Nistor, M.-M. (2019). Vulnerability of groundwater resources under climate change in the Pannonian basin. *Geo-Spatial Information Science*, 22(4), 345–358.
- Pegram, G. G. S., & James, W. (1972). Multilag multivariate autoregressive model for the generation of operational hydrology. *Water Resources Research*, 8(4), 1074-1076.
- Quinlan, J. R. (1992, November). Learning with continuous classes. In *5th Australian joint conference on artificial intelligence* (Vol. 92, pp. 343-348).
- Rabeiy RE (2018) Assessment and modeling of groundwater quality using WQI and GIS in Upper Egypt area. *Environ Sci Pollut Res* 25:30808–30817
- Rezaie-balf, M., Naganna, S. R., Ghaemi, A., & Deka, P. C. (2017). Wavelet coupled MARS and M5 Model Tree approaches for groundwater level forecasting. *Journal of hydrology*, 553, 356-373.
- Sahoo S, Russo TA, Elliott J, Foster I (2017) Machine learning algorithms for modeling groundwater level changes in agricultural regions of the US. *Water Resour Res* 53(5):3878–3895
- Sahoo, S., & Jha, M. K. (2013). Groundwater-level prediction using multiple linear regression and artificial neural network techniques: a comparative assessment. *Hydrogeology Journal*, 21(8), 1865-1887.
- Saplıoğlu, K., & Çimen, M. (2010). Yapay sinir ağlarını kullanarak günlük yağış miktarının tahmini. *Mühendislik Bilimleri ve Tasarım Dergisi*, 1(1), 14-21.
- Sattari, M. T., Mirabbasi, R., Sushab, R. S., & Abraham, J. (2018). Prediction of groundwater level in Ardebil plain using support vector regression and M5 tree model. *Groundwater*, 56(4), 636-646.
- Solomatine, D. P., & Xue, Y. (2004). M5 model trees and neural networks: application to flood forecasting in the upper reach of the Huai River in China. *Journal of Hydrologic Engineering*, 9(6), 491-501.
- Sunayana KK, Dube O, Sharma R (2019) Use of neural networks and spatial interpolation to predict groundwater quality. *Environ Dev Sustain* 22:2801–2816
- Taşar, B., Kaya, Y. Z., Varçin, H., Üneş, F., & Demirci, M. (2017). Forecasting of suspended sediment in rivers using artificial neural networks approach. *International Journal of Advanced Engineering Research and Science*, 4(12), 237333.
- Trichakis, I. C., Nikolos, I. K., & Karatzas, G. P. (2011). Artificial neural network (ANN) based modeling for karstic groundwater level simulation. *Water Resources Management*, 25(4), 1143-1152.
- Ulusoy, K., (2007), Küresel Ticaretin Son Hedefi: Su Pazarı, Kristal Kitaplar Yayınevi,
- Üneş, F., Demirci, M., Mertcan, Z., Taşar, B., Varçin, H., & Ziya, Y. (2018). Determination of groundwater level fluctuations by artificial neural networks. *Natural and Engineering Sciences*, 3(3), 35-42.



- Wicander, R., & Monroe, J. S. (2005). *Essentials of Geology*, Brooks Cole, USA. ISBN-10 X, 49501365, 528.
- Yaseen, Z. M., Allawi, M. F., Karami, H., Ehteram, M., Farzin, S., Ahmed, A. N., et al. (2019). A hybrid bat–swarm algorithm for optimizing dam and reservoir operation. *Neural Computing and Applications*, 31, 1–15.
- Yoon, H., Hyun, Y., Ha, K., Lee, K. K., & Kim, G. B. (2016). A method to improve the stability and accuracy of ANN-and SVM-based time series models for long-term groundwater level predictions. *Computers & geosciences*, 90, 144-155.
- Zare, M., & Koch, M. (2018). Groundwater level fluctuations simulation and prediction by ANFIS-and hybrid Wavelet-ANFIS/Fuzzy C-Means (FCM) clustering models: Application to the Miandarband plain. *Journal of Hydro-environment Research*, 18, 63-76.



## DİZİN

<hr/> <b>A</b>	36,37,38,39,40,41,42,43,44,45
<i>Akifer</i>	,46
2,5,9,10	
<hr/> <b>B</b>	<i>M5</i>
<i>Buharlaştırma</i>	5,9,10,11,15,16,17,18,25,26,2
1,41,42,43,44,45,46	7,28,29,32,34,35,36,37,9
<hr/> <b>Ç</b>	<hr/> <b>R</b>
<i>ÇDR</i>	Regresyon
23,26,32,33,34,35,36,37,38	7,9,15,16,23,24,25,26,37
<hr/> <b>D</b>	<hr/> <b>T</b>
<i>Determinasyon</i>	<i>Tahmin</i>
25,28,29,31,32,34,35,37	3,5,6,7,8,9,10,11,12,15,16,19,
<hr/> <b>H</b>	20,21,25,26,28,30,32,34,35,37
<i>Hidroloji</i>	,38,41,42,43,44,45,46
4,6,19,20,37,40	<hr/> <b>Y</b>
<hr/> <b>K</b>	<i>Yapay Sinir Ağları</i>
<i>Karar Ağacı</i>	5,7,9,15,19,20,21,25,26,29,37,
5,9,10,15,16,25,26,27,28,37,4	40,41,42,43,45,46
3	
<hr/> <b>M</b>	
<i>Model</i>	
3,4,5,6,7,8,9,10,15,16,17,18,1	
9,21,25,26,28,29,31,32,34,35,	



**TEKNOVERSITE**





teknoversite **AYRICALIĞINDASINIZ**

**İSTE**

