



İSKENDERUN TEKNİK

ÜNİVERSİTESİ

MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

**YÜKSEK
LİSANS
TEZİ**

**YERALTI SUYU SEVİYE DEĞİŞİMİNİN
BULANIK MANTIK VE DESTEK
VEKTÖR MAKİNELERİ YÖNTEMLERİ
İLE TAHMİNİ**

Selçuk KÖRLÜ

İNŞAAT MÜHENDİSLİĞİ
ANABİLİM DALI

HAZİRAN 2019



**YERALTI SUYU SEVİYE DEĞİŞİMİNİN BULANIK MANTIK VE
DESTEK VEKTÖR MAKİNELERİ YÖNTEMLERİ İLE TAHMİNİ**

Selçuk KÖRLÜ

**YÜKSEK LİSANS TEZİ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ**

HAZİRAN 2019

Selçuk KÖRLÜ tarafından hazırlanan “YERALTI SUYU SEVİYE DEĞİŞİMİNİN BULANIK MANTIK VE DESTEK VEKTÖR MAKİNELERİ YÖNTEMLERİ İLE TAHMİNİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ / ~~OY ÇOKLUĞU~~ ile İskenderun Teknik Üniversitesi İnşaat Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Mustafa DEMİRCİ

İnşaat Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

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



2. Danışman: Prof. Dr. Fatih ÜNEŞ

İnşaat Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

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



Üye: Prof. Dr. Aytaç GÜVEN

İnşaat Mühendisliği Anabilim Dalı, Gaziantep Üniversitesi

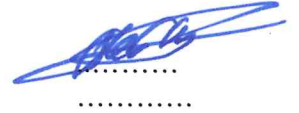
Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/~~onaylamıyorum.~~



Üye: Doç. Dr. Cuma KARAKUŞ

Makine Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

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



Üye: Doç. Dr. Murat ÖRNEK

İnşaat Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

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



Tez Savunma Tarihi: 10/06/2019

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

Prof. Dr. Tolga DEPCİ

Mühendislik ve Fen Bilimleri Enstitüsü Müdürü



ETİK BEYAN

İskenderun Teknik Üniversitesi Mühendislik ve Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde 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.

Selçuk KÖRLÜ

19/06/2019

YERALTI SUYU SEVİYE DEĞİŞİMİNİN BULANIK MANTIK VE DESTEK VEKTÖR MAKİNELERİ YÖNTEMLERİ İLE TAHMİNİ

(Yüksek Lisans Tezi)

Selçuk KÖRLÜ

İSKENDERUN TEKNİK ÜNİVERSİTESİ
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ
Haziran 2019

ÖZET

Yeraltı suyu özellikle kurak ve yarı kurak bölgelerde, birçok alanda evsel, kentsel, tarımsal ve endüstriyel amaçlar için çoğunlukla kullanılan su kaynaklarından biridir. Geleceğe yönelik suyu güvence altına almak için, yeraltı suyu kaynaklarının yüzey suyu ile birlikte sürdürülebilir yönetimi acil ihtiyaç haline gelmiştir. Yeraltı suyu seviyelerinin doğru ve güvenilir bir şekilde tahmin edilmesi, bu amaca ulaşmak için, özellikle kuraklık şeklinde hidrolojik aşırı olaylara daha duyarlı olan kurak ve yarı kurak bölgelerdeki su havzalarında çok önemli bir bileşendir.

Bu çalışmada Hatay Reyhanlı bölgesinde bulunan Devlet Su İşleri Genel Müdürlüğü (DSİ) rasat kuyusuna ait 2000 ile 2015 yılları arasındaki yeraltı su seviyesi aylık ölçüm değerleri ile bölgenin aylık ortalama yağış ve sıcaklık değerleri kullanılarak yeraltı suyu seviyesi tahmini yapılmıştır.

Bu verilerle Çoklu Lineer Regrasyon (ÇLR), Anfis (Adaptif Neural Bulanık Çıkarım Sistemi) ve Radyal Temelli Çekirdek Fonksiyonlu Destek Vektör Makineleri (DVM-RBF) ve Poli Çekirdek Fonksiyonlu Destek Vektör Makineleri (DVM-PK) yöntemleri kullanılarak tahmin edilmiştir. Yeraltı su seviyesi tahmininin performans değerlendirilmesi yapılmıştır.

Bölgenin yeraltı su seviyesi tahmininde DVM modellerinin ÇLR ve ANFIS modelinden daha iyi sonuç verdiği görülmüştür.

Anahtar Kelimeler : Bulanık Mantık, Destek Vektör Makineleri, Yeraltı Su Seviyesi, Reyhanlı
Sayfa Adedi : 58
Danışman : Doç. Dr. Mustafa DEMİRCİ
2. Danışman : Prof. Dr. Fatih ÜNEŞ

ESTIMATION OF GROUNDWATER LEVEL FLUCTUATION USING ADAPTIVE
NEURAL FUZZY AND SUPPORT VECTOR MACHINES

(M. Sc. Thesis)

Selçuk KÖRLÜ

ISKENDERUN TECHNICAL UNIVERSITY
ENGINEERING AND SCIENCE INSTITUTE

June 2019

ABSTRACT

Groundwater is one of the most frequently used water resources for domestic, urban, agricultural and industrial purposes, especially in arid and semi-arid regions. Sustainable management of groundwater resources along with surface water has become an urgent need to secure future water. Accurate and reliable estimation of groundwater levels is a very important component in the water basins in arid and semi-arid regions, which are more susceptible to hydrological extreme events, especially in drought form.

In this study, the groundwater level of the region was estimated using the monthly average rainfall and temperature values of the area between 2000 and 2015 and the monthly average values of the groundwater level of Turkish General Directorate of State Hydraulic Works (DSİ), located in Hatay Reyhanlı region.

With this data, Multiple Linear Regression (MLR), Anfis (Adaptive Neural Fuzzy Inference System), support vector machines with radial basis functions (SVM-RBF) and support vector machines with poly kernels (SVM- PK) methods were estimated. The performance of the groundwater level estimation was evaluated.

In the estimation of the groundwater level of the region, it is seen that SVM models have better results than the MLR and ANFIS model.

Key Words : Fuzzy Logic, Support Vector Machines, Groundwater level, Reyhanli.
Page Number : 58
Supervisor : Assoc.Prof. Dr. Mustafa DEMİRCİ
2.Supervisor : Prof. Dr. Fatih ÜNEŞ

TEŐEKKÜR

Yüksek lisans tez konumun belirlenmesi, araştırılması ve deneylerin yapılması sürecinde sahip olduđu bilgi birikimleri ve tecrübeleriyle çalışmaya yönlendiren ve her türlü yardımı esirgemeyen çok değerli danışman hocalarım Doç. Dr. Mustafa DEMİRCİ, Prof. Dr. Fatih ÜNEŐ ve Arş.Gör. Bestami TAŐAR'a sonsuz saygı ve teşekkürlerimi sunarım. Çalışmalarım sırasında sabırla desteklerini bir an olsun esirgemeyen aileme de çok teşekkürlerimi sunarım.



İÇİNDEKİLER

	Sayfa
ÖZET	iii
ABSTRACT.....	iv
TEŞEKKÜR.....	v
İÇİNDEKİLER	vi
ÇİZELGELERİN LİSTESİ.....	viii
ŞEKİLLERİN LİSTESİ.....	ix
SİMGELER VE KISALTMALAR.....	xi
1. GİRİŞ.....	1
1.1.Yeraltı suyu	1
1.2.Yeraltı Suyu Oluşumu ve Yeraltı Suyuna Ait Bölgeler	1
1.3. Yeraltı Suyunun Önemi	4
2. ÖNCEKİ ÇALIŞMALAR.....	7
3. MATERYAL ve YÖNTEM	11
3.1.Çalışma Alanı	11
3.2. Yöntem.....	15
3.2.1. Çoklu Linear Regresyon (ÇLR).....	15
3.2.2. Adaptif Sinir Bulanık Çıkarım Sistemi (ANFIS).....	15
3.2.3.Destek Vektör Makineleri (DVM).....	19
3.2.4.Radyal Temelli Çekirdek Fonksiyonlu Destek Vektör Makineleri (SVM-RBF)	24
3.2.5. Poli Çekirdek Fonksiyonlu Destek Vektör Makineleri (SVM-PK).....	25
4. ARAŞTIRMA BULGULARI ve TARTIŞMA	26

	Sayfa
5. SONUÇLAR	37
KAYNAKLAR	38
ÖZGEÇMİŞ	44
DİZİN	45



ÇİZELGELERİN LİSTESİ

Çizelge		Sayfa
Çizelge 4.1.	İstatistiksel kriterlere göre model sonuçları	36



ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 1.1. Bir akifer kesiti.....	2
Şekil 1.2. Şekil 1.2 Yeraltı suyunun bölgeleri.....	4
Şekil 1.3. Dünyadaki suyu dağılımı	4
Şekil 1.4. DSİ tarafından tahsisi yapılan yeraltı suyu dağılımı.....	5
Şekil 3.1. Reyhanlı bölgesi	12
Şekil 3.2. Reyhanlı bölgesinin 2000-2015 yılları arasında yer altı suyu seviyesi	13
Şekil 3.3. Reyhanlı bölgesinin 2000-2015 yılları arasında yağış miktarı değişimleri	13
Şekil 3.4. Reyhanlı bölgesinin 2000-2015 yılları arasında sıcaklık değişimleri	14
Şekil 3.5. Sugeno tipi bulanık model	18
Şekil 3.6. Üç girdi için Neuro-Fuzzy (NF) sistem yapısı.....	19
Şekil 3.7. Veri sınıflandırması.....	20
Şekil 3.8. DVM'nin şematik gösterimi.....	23
Şekil 3.9. Çalışmada kullanılan DVM-1 modelinin yapısı.....	23
Şekil 4.1. Yeraltı su seviyesi eğitim verileri için Ölçüm ve ÇLR saçılım grafiği.....	26
Şekil 4.2. Yeraltı su seviyesi eğitim verileri için Ölçüm ve ÇLR dağılım grafiği.....	27
Şekil 4.3. Yeraltı su seviyesi test verileri için Ölçüm ve ÇLR saçılım grafiği.....	27
Şekil 4.4. Yeraltı su seviyesi test verileri için Ölçüm ve ÇLR dağılım grafiği.....	28
Şekil 4.5. . Yeraltı su seviyesi eğitim verileri için Ölçüm ve ANFIS saçılım grafiği..	29
Şekil 4.6. Yeraltı su seviyesi eğitim verileri için Ölçüm ve ANFIS dağılım grafiği...	29
Şekil 4.7. Yeraltı su seviyesi test verileri için Ölçüm ve ANFIS saçılım grafiği.....	30
Şekil 4.8. Yeraltı su seviyesi test verileri için Ölçüm ve ANFIS dağılım grafiği.....	30
Şekil 4.9. Yeraltı su seviyesi eğitim verileri için Ölçüm ve DVM PK saçılım grafiği..	31

Şekil**Sayfa**

Şekil 4.10. Yeraltı su seviyesi eğitim verileri için Ölçüm ve DVM PK dağılım grafiği..	32
Şekil 4.11. Yeraltı su seviyesi test verileri için Ölçüm ve DVM PK saçılım grafiği....	32
Şekil 4.12. Yeraltı su seviyesi test verileri için Ölçüm ve DVM PK dağılım grafiği...	33
Şekil 4.13. Yeraltı su seviyesi eğitim verileri için Ölçüm ve DVM-RBF saçılım grafiği	34
Şekil 4.14. Yeraltı su seviyesi eğitim verileri için Ölçüm ve DVM RBF dağılım grafiği	34
Şekil 4.15. Yeraltı su seviyesi test verileri için Ölçüm ve DVM RBF saçılım grafiği...	35
Şekil 4.16. Yeraltı su seviyesi test verileri için Ölçüm ve DVM RBF dağılım grafiği..	35

SİMGELER VE KISALTMALAR

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

Simgeler

Açıklamalar

MSE	Ortalama karesel hata
MAE	Ortalama mutlak hata
R	Korelasyon katsayısı.
MP	Aylık ortalama yağış
MT	Aylık ortalama sıcaklık
GWL	Aylık yeraltısuyu seviyesi

Kısaltmalar

Açıklamalar

DVM	Destek Vektör Makineleri
DVM-RBF	Radyal Temelli Çekirdek Fonksiyonlu Destek Vektör Makineleri
DVM-PK	Poli Çekirdek Fonksiyonlu Destek Vektör Makineleri
ANFIS	Adaptif Sinir Bulanık Çıkarım Sistemi
ÇLR	Çoklu Linear Regresyon
YSA	Yapay Sinir Ağları

1.GİRİŞ

1.1.Yeraltı Suyu

Yeraltı suyu; özellikle kurak ve yarı kurak bölgelerde, birçok alanda evsel, kentsel, tarımsal ve endüstriyel amaçlar için çoğunlukla kullanılan su kaynaklarından biridir. Bununla birlikte, yeraltı suyunun aşırı çekilmesi ve kontrol edilemeyen yeraltı suyu kullanımı ve yönetimi gibi büyük su seviyesi düşüşleri, kuyuların kurutulması, su kalitesinde bozulma, artan pompalama maliyetleri, arazi yüzeyinde çökme, konut suyu arzındaki pompalama kaybı gibi birçok sorun ortaya çıkmaktadır. Kuyular ve akiferlerdeki sorunlar, özellikle gelişmekte olan ülkelerde, küresel olarak ciddi bir sorun haline gelmektedir.

Geleceğe yönelik suyu güvence altına almak için, yeraltı suyu kaynaklarının yüzey suyu ile birlikte sürdürülebilir yönetimi acil ihtiyaç haline gelmiştir. Yeraltı suyu seviyelerinin doğru ve güvenilir bir şekilde tahmin edilmesi, bu amaca ulaşmak için, özellikle kuraklık şeklinde hidrolojik aşırı olaylara daha duyarlı olan kurak ve yarı kurak bölgelerdeki su havzalarında çok önemli bir bileşendir.

1.2.Yeraltı Suyu Oluşumu ve Yeraltı Suyuna Ait Bölgeler

Yağmur yere düştüğünde, bir kısmı kara yüzeyi boyunca nehirlerle veya göllere akar, bazıları toprağı nemlendirir. Bu suyun bir kısmı bitki örtüsü ile kullanılır, bazıları buharlaşır ve atmosfere döner. Suyun bir kısmı da toprağı sızar, doymamış bölgeden akar ve altındaki zeminin doymun olduğu hayali bir yüzey olan su tablasına ulaşır.


Yeraltı suyu “akifer” olarak adlandırılan yerde bulunur. Bir akifer, önemli miktarda su depolayabilen / verebilen geçirgen malzemeden oluşan jeolojik bir oluşum veya bunun bir parçasıdır. Akiferler farklı malzemelerden oluşabilir: Konsolide olmayan kumlar ve çakıllar, kumtaşları veya kalkerler gibi geçirgen tortul kayalar, kırılmış volkanik ve kristal kayalar vb.

Yeraltı suyu (doğal olarak) yağmur suyu ve kar erimesi veya bazı göl ve nehirlerin altından akan sudan depo edilir. Ayrıca akiferin bu miktarı yönetme ve toprağı sızan su miktarını arttırma teknikleri de vardır.

Yeraltı suyu hemen hemen her yerde bulunabilir. Su tablası, bölgenin fiziksel özellikleri, meteorolojik koşullar, depolanma ve kullanma oranları gibi çeşitli faktörlere bağlı olarak derin veya sığ olabilir. Şiddetli yağmurlar depolanmayı artırabilir ve su tablasının yükselmesine neden olabilir. Ancak, diğer yandan, uzun süre kuru olan hava, su tablasının düşmesine neden olabilir.

Yeraltı suyu bir akifere ulaştığında sabit durmaz. Normalde akmaya devam edecek fakat akifere ulaşmadan çok daha yavaş akacak. Yeraltı suyunun akış hızı, akiferin özelliklerine bağlıdır. Hareket ettiği yön, pompalama kuyuları gibi herhangi bir antropojenik etki olmadığı sürece, yerçekimi tarafından yönetilen yüksek ila düşük seviyeler arasındadır. Yeraltı suyu, başka bir akifer veya göl, nehir, okyanus gibi başka bir su kütlelerine boşalınca veya bir kuyucuk tarafından alınana kadar hareket edecektir.

Şekil 1.1'de boşluklu (geçirgen) bir akifer tanesine ait jeolojik oluşum gösterilmiştir.



Şekil 1.1. Bir akifer kesiti

Yeraltı sularını depolayabilmesi ve iletilebilmesi için, bir akiferin belirli fiziksel özelliklere sahip olması gerekir. Yeraltı suyunun depolanabileceği boş bir alana (gözenekler veya kırılmalar) ve içinden akabilmesi için boşlukların bağlanması gerekir. Teknik olarak, boşluklar varken ve birbirlerine bağlandıklarında jeolojik oluşum geçirgendir. Boşluk olmadığı veya birbirlerine bağlı olmadığına, jeolojik oluşum geçirimsizdir.

Akiferin gözenekliliği ve geçirgenliği ne kadar yüksek olursa, o kadar fazla yer altı suyu bir akifer tarafından depolanır ve verilir.

Yeraltı suyu yeraltında iki geniş bölgede meydana gelir: Doymamış bölge ve doymuş bölge.

1. Doymamış Bölge: Vadoz zonu olarak da bilinen doymamış bölge, hava ve su ile değişen bir dereceye kadar doldurulmuş toprak gözeneklerinden oluşur. Hidrostatik basınçta olduğu varsayılan su dolu gözeneklerden oluşur.

Tanımlanmamış bir akifer için, doyma bölgesi su tablasından zemin yüzeyine uzanan doymamış bir bölge ile kaplanır (Şekil 1.2).

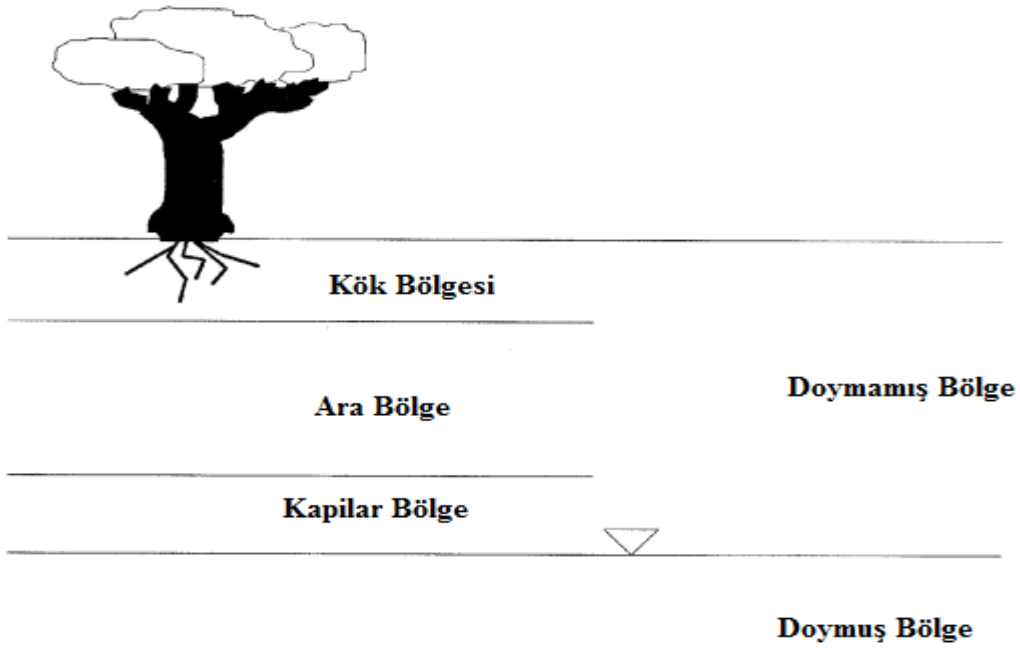
Doymamış bölge (veya vadoz bölgesi), yeniden şarj edildiğinde, yüzey girişinin kesilmesinden sonra nispeten uzun bir süre boyunca suyu doymuş bölgeye boşaltan geniş bir rezervuar görevi görür.

Doymamış bölge genellikle üç alt bölgeden oluşur: kök bölge, bir ara bölge ve kılcal saçak. Kök bölgesi, büyüme mevsimi ve bitki örtüsünün türüne bağlı olarak kalınlıkta değişir. Kök bölgesindeki su içeriği, yüzey akılarının, yüzeyi doymuş hale getirmek için yeterince yoğun olduğu durumlar haricinde, genellikle doymuşluktan daha azdır.

Bu bölge, buharlaşma, bitki terlemesi ve yağış nedeniyle nem içeriğinde büyük dalgalanmalara maruz kalır. Kök bölgesinin altındaki su, yerçekiminin etkisi altında dikey olarak aşağıya doğru süzülür veya yerçekimi drenajı tamamlandıktan sonra yüzey gerilimi nedeniyle askıya alınmaktadır. Bu ara bölge, kılcal saçak veya su tablasının kök bölgesini kesiştiği yerde mevcut değildir. Kılcal saçak, su tablasından kılcal yükselme sınırına kadar uzanır.

Su yüzeyindeki su molekülleri, hava suyu ara yüzünün yüzey gerilimi ve sıvı ve katı fazların moleküler çekimi nedeniyle yukarı çekime maruz kalır. Bu bölgenin kalınlığı, toprak ortamının gözenek boyutuna bağlıdır ve doğrudan gözenek boyutundaki düşüşe bağlı olarak değişir. Su içeriği çok düşük ile doymuşluk arasında değişebilir, kılcal kanadın alt kısmı genellikle doymuş olur.

2. Doymuş bölge: Doyma bölgesinde, tüm boşlukları hidrostatik basınç altında su ile doldurulur. Doymuş bölgedeki su, yeraltı suyu veya freatik su olarak bilinir. Doymuş bölgede basıncın pozitif oluşundan dolayı, bu bölgelere açılan kuyulardan yeraltı suyu yeryüzüne çıkarılır. Bu bölgeye su taşıyan tabaka anlamına gelen akifer de denilir.




Şekil 1.2 Yeraltı Suyunun Bölgeleri

1.3.Yeraltı Suyunun Önemi

Yeraltı suyu, dünyadaki tatlı suyun yaklaşık% 30'unu temsil eder. Diğer% 70'ten, buz dağlarında ve dağ kar / buzullarında yaklaşık% 69'luk bir oran yakalanırken, yalnızca% 1'i nehir ve göllerde bulunur. Yeraltı suyu, insanlar tarafından tüketilen tatlı suyun üçte birini ortalama olarak sayar, ancak dünyanın bazı bölgelerinde, bu % 100'e kadar çıkabilir.

Şekil 1.3'de, Dünya'nın su dağılımına genel bir bakış verilmiştir.




Şekil 1.3. Dünya'daki su dağılımı

Yeraltı suyu çok önemli bir doğal kaynaktır ve ekonomide önemli bir rolü vardır. Sulama ve gıda endüstrisi için ana su kaynağıdır. Genel olarak yeraltı suyu, tarım için güvenilir bir su kaynağıdır ve esnek bir şekilde kullanılabilir: kuru ve daha fazla talep olduğunda daha fazla yeraltı suyu elde edilebilir ve yağmur yağdığında ihtiyaçlara uyduğunda, daha az yeraltı suyunun çıkarılması gerekir.

Küresel olarak, sulama suları toplam su oranının% 70'inden fazlasını (hem yüzey hem de yeraltı suları) oluşturmaktadır. Toplam sulama suyu kullanımının yaklaşık% 43'ünde yeraltı suyunun kullanıldığı tahmin edilmektedir.

Yeraltı su kaynakları ile ilgili, Devlet Su İşleri Genel Müdürlüğünce 2015 yılı sonuna kadar yapılmış olan hidrojeolojik etütler neticesinde ülkemizde 18 milyar m³ yeraltı suyu rezervi tespit edilmiştir.

Şekil 1.3'de gösterildiği üzere, bu yeraltı suyu rezervinin, 3,778 milyar m³'ü devlet eliyle yapılan sulamalarda, 5,409 milyar m³'ü münferit özel sulamalarda, 3,959 milyar m³'ü içme-kullanma suyu olarak, 1,454 milyar m³'ü de sanayi suyu olmak üzere toplam 14,6 milyar m³'lük bölümünün DSİ'ce tahsis işlemi yapılmıştır (DSİ, 2015).



Şekil 1.4. DSİ tarafından tahsisi yapılan yeraltı suyu dağılımı.

Çevre için yeraltı suyu, su seviyesinin korunmasında ve nehirlere, göllere ve sulak alanlara akışta çok önemli bir rol oynamaktadır. Özellikle kurak aylarda doğrudan yağıştan çok az miktarda depolama olduğundan, çevreye bu su kütlelerinin tabanından yeraltı suyu akışı sağlanır ve bu ortamda yaşayan vahşi yaşam ve bitkiler için temel ihtiyaç hale gelir.

Yeraltı suyu, daha kurak mevsimlerde iç sularda gezinmeyi sürdürmede çok önemli bir rol oynamaktadır. Yeraltı suları suyunu nehirlere boşaltarak suyun seviyesini yükseltir.

Yeraltı suyu hemen hemen her yerde bulunur ve kalitesi genellikle çok iyidir. Yeraltı suyunun yüzeyin altındaki katmanlarda ve bazen çok yüksek derinliklerde depolanması, kirlenmeden korunmasına ve kalitesini korumasına yardımcı olur.

Ek olarak, yeraltı suyu, genellikle nihai tüketicilere yakın bulunabilen doğal bir kaynaktır ve bu nedenle, yüzey suyunun toplanmasında sıklıkla gerekli olduğu için altyapı ve arıtma açısından büyük yatırımlar gerektirmez.

Yeraltı suyunun kullanılmasıyla ilgili en önemli husus, su çekilmesinin önlenmesi ve akiferin seviyesinin aşırı sömürüden kaçınmak ve bu önemli kaynağın kirlenmesini önlemek için geri kazanılması arasında doğru dengeyi bulmaktır.



2. ÖNCEKİ ÇALIŞMALAR

Yeraltı suyu, endüstriyel, evsel ve tarımsal amaçlar için ana tedarik kaynaklarından biridir. Kurak ve yarı kurak alan gibi bazı bölgelerde tek arz kaynağı, bazı bölgelerde ise hazır olması nedeniyle seçilmektedir (Nayak ve ark. 2006). Son yıllarda, özellikle sanayi ve tarımda yeraltı suyu kaynakları aşırı kullanılmakta ve bu da yeraltı suyu seviyesinin düşmesine neden olmaktadır (Sreekanth ve ark. 2009).

Yeraltı suyu seviyesinin doğru şekilde tahmin edilmesi, yeraltı suyu kaynaklarının sürdürülebilir veriminin en önemli aşamalarından biridir. Yer altı su kuyularındaki pompalama kaybı, yüzeysel çöküntü, akiferlerin sıkışması gibi olumsuz etkilerini önlemek veya azaltmak için yer altı suyu seviye tahminlere ihtiyaç duyulmaktadır.

Araştırmacılar, yeraltı suyu seviyesini tahmin etmek için sayısal zaman serisi modelleri ve ampirik modeller gibi farklı yeraltı suyu yöntemleri kullanmışlardır. Sayısal yeraltı suyu modellerini kullanmanın dezavantajı, kayaların jeolojik özellikleri hakkında bilgiyi metinden silme ve karstik akiferlerinde kırılmaların geometrik özellikleri hakkında bilgi sahibi olmaları gerektiğidir (Trichakis ve ark. 2011).

Son zamanlarda, yapay sinir ağı (YSA) ve uyarlanabilir sinirsel-bulanık çıkarım sistemi (ANFIS) gibi veriye dayalı yeni teknikler, su kaynakları yönetimi ve karmaşık hidrolojik sistemlerin modellenmesinde etkili bir alternatif araç olarak kabul edilmiş ve öngörmede yaygın olarak kullanılmışlardır (Brion ve ark. 2002 ; Sreekanth ve diğerleri 2009; Guldal ve Tongal 2010; Kaya ve diğerleri, 2016; Mohanty ve diğerleri, 2013; Li ve diğerleri, 2015; Shiri ve diğerleri, 2013). ; Demirci ve Baltacı, 2013; Üneş ve diğerleri, 2015a, b, 2017; Demirci ve diğerleri, 2015a, b; Tasar ve diğerleri, 2017, 2018; Feng ve Tian, 2018; Yılmaz ve diğerleri, 2018; Kankal ve arkadaşları, 2018; Nacar ve arkadaşları, 2018; Wunsch ve arkadaşları, 2018)

Yapay zeka tekniklerini kullanarak yeraltı suyu seviyesindeki değişimi tahmin etmek için birçok araştırma yapılmıştır. Emamgholizadeh ve diğ. (2014) yapay sinir ağı (YSA) ve yer altı suyu seviyeleri (GWL) tahminleri için uyarlanabilir sinirsel bulanık çıkarım (ANFIS) potansiyelini araştırmıştır. Heesung ve diğ. (2011) YSA ve Destek vektör makineleri (DVM) yöntemlerini kullanarak yeraltı suyu seviyesi (GWL) dalgalanmalarını tahmin

etmek için iki doğrusal olmayan zaman serisi modelini çalışmışlardır. Nourani ve diğ. (2015), kuzeybatı İran'ın düz Ardabil'deki GWL tahmini için ileri beslemeli sinir ağı (İBYSA), Otomatik Regresif Hareketli Ortalama (ARIMAX) modellerini kullanmışlardır. Guzman ve diğ. (2015) günlük yeraltı suyu seviyesi tahminlerinde Yapay Sinir Ağları (YSA) ve Destek Vektör Regresyonu (DVR) kullanmıştır. Sonuçlarına göre, YSA ve SVR günlük yeraltı suyu seviyelerini tahmin etmede iyi bir doğruluğa sahip olduklarını gözlemlemişlerdir.

Yoon ve diğ. (2016) yapay sinir ağının (YSA) performansını artırmak için ağırlıklı bir hata fonksiyonu yaklaşımı kullanmış ve yeraltı suyu seviyelerinin uzun vadeli öngörülmesi için destek vektör makinesi (DVM) tahmin modellerini önermişlerdir. Zhou ve diğ. (2017), yer altı suyu derinliği tahmini için ayırık dalgacık dönüşümü (DWT) ve destek vektör makinesini (DVM) birleştiren veri odaklı bir tahmin modeli önermiştir. Ebrahimi ve Rajae (2017), İran'ın Qom ovasına kaydedilen YASS verilerini kullanarak YSA, MLR ve DVR yaklaşımlarının dalgacık analizinin etkisini araştırmışlardır.

Zare ve Koch (2018), İran'daki Miandarband ovasındaki GWL dalgalanmalarını simüle etmek ve tahmin etmek için çeşitli girdi ve ana dalgacık kombinasyonlarını içeren yeni hibrid Wavelet-ANFIS modelini kullandı. Sonuçlar, tüm model yaklaşımlarının kabul edilebilir doğrulukta kullanılabileceğini gösterdi. Diğer araştırmacılar, yapay sinir ağının genel olarak, farklı jeolojik ortamlar için yeraltı suyu seviyelerini tahmin etmek için son derece uygun olduğunu da keşfetmişlerdir (Coulibaly ve diğerleri, 2001; Nayak ve diğerleri, 2006; Mohammadi, 2008; Sreekanth ve diğerleri, 2009; Adamowski ve Chan, 2011; Trichakis ve diğerleri, 2011; Chitsazan ve diğerleri, 2015; Khalil ve diğerleri, 2015; Chang ve diğerleri, 2016; Bargezar ve diğerleri, 2017; Yu ve diğerleri, 2018; Bhattacharjya ve Datta 2005; Nayak vd. 2006; Nourani ve diğerleri 2008; Kentel 2009; Mohanty ve diğerleri 2010; Emamgholizadeh 2012).

Trichakis ve diğerleri (2011) ABD'nin Texas eyaletinde Edward'ın akiferinin karstik yeraltı suyu seviyesini simüle etmek için YSA modelini kullanmıştır. Sonuçları karşılaştırdıklarında, YSA'nın YASS'yi tahmin edebileceğini ve sayısal yeraltı suyu modelleriyle simüle edilmesi zor olan karstik akiferleri simüle etmenin yararlı bir yol olduğunu göstermişlerdir. Ayrıca, Nastos ve ark. (2014), Atina, Yunanistan'daki günlük aşırı yağış potansiyelini değerlendirmek için YSA modelini kullanmıştır. YSA modelinin

günlük aşırı yağış değerlendirmesinde başarılı ve uygulanabilir olduğunu kanıtlamışlardır. Afan ve diğ. (2015), Johor Nehri üzerindeki Rantau Panjang istasyonundan gelen günlük sediment yükünü tahmin etmek için ileri beslemeli sinir ağı (İBYSA) ve radyal temel fonksiyonlu yapay sinir ağı (RTYSA) olmak üzere iki farklı YSA algoritması kullanmışlar. Sonuçlar, İBYSA modelinin RTYSA modelinden daha üstün bir performansa sahip olduğunu göstermiştir.

Sinirsel bulanık mantık (ANFIS), YSA gibi doğrusal olmayan sistemlerin modellenmesinde de etkilidir. Bulanık sistemlerde, ilişkiler açıkça o zaman kurallar biçiminde gösterilir (Kurtulus ve Razack 2010).

ANFIS, birkaç katmanı olan bulanık mantığın bir dalıdır. Sistem çıktısını tahmin etmek için bulanık sistem parametrelerini uyarlar ve girdi ve çıktı verilerini toplamaya dayalı dağıtım sonrası algoritmaya göre koordine eder. Pek çok araştırmacı ANFIS modelini kullanmaktadır. Yüksek yeteneklere sahip olan bu model, doğrusal olmayan sistemlerin modellenmesi için uygun olabilir. ANFIS modeli birçok hidroloji, hidrojeoloji ve diğer mühendislik problemleri araştırmacıları tarafından kullanılmıştır (Nayak ve ark. 2004; Chang ve Chang 2006; Kisi 2006; Affandi ve Watanabe 2007; Esen ve İnalli 2010; Sreekanth ve diğ. 2009; Sanikhani ve Kisi 2012; Emamgholizadeh ve diğ. 2013b).

Ayrıca Güldal ve Tongal (2009), Türkiye'deki Eğirdir Gölü'nün su seviyesini tahmin etmek için geri dönüşlü ağ yöntemi (RNN) ve ANFIS yöntemlerini kullanmıştır. Shirmohammadi ve diğ. (2013) farklı tahmin süresi için yeraltı suyu seviyesini tahmin etmek için sistem tanımlaması, zaman serileri ve ANFIS modelleri dahil olmak üzere birkaç veriye dayalı teknik uygulamışlardır. ANFIS'in yer altı suyu seviyesinin doğru tahminini sağlayabildiğini göstermişlerdir.

He ve diğ. (2014), yarı kurak dağ bölgelerinde karmaşık topografya ile nehir akışını tahmin etmek için YSA, ANFIS ve DVM modellerini geliştirmiştir. Sonuçlar, karmaşık topografya ile nehir akışını tahmin etmek için üç modelin başarıyla uygulanabileceğini ve DVM modelinin YSA ve ANFIS modellerinden daha iyi performans gösterdiğini elde etmişlerdir. Cho ve diğ. (2014), bir nehrin sulanmasıyla oluşan rezervuardaki klorofil-a seviyelerini tahmin etmek için ANN modelini kullanmıştır. Zaman dizisi verileriyle eğitim alan YSA'nın, Juam Gölü'ndeki algal çiçeklenmeyi etkileyen temel faktörler hakkında bilgi

sağlayabileceği ve rezervuardaki Chl-a konsantrasyonunu başarılı bir şekilde tahmin edebileceği sonucuna varmışlardır. Latt ve Wittenberg (2014), bölgesel endeks taşkınının tahmin edilmesi için YSA modelini geliştirmiştir.

Sonuç olarak YSA modelinin endeks taşkınları ve havza arasındaki doğrusal olmayan ilişkileri yakalayabildiğini ve geleneksel regresyon yönteminden daha üstün olduğunu göstermişlerdir.

Bu çalışmanın temel amacı, Aylık Ortalama Yağış (MP), Aylık Ortalama Sıcaklık (MT), Aylık kullanarak, yer altı su seviyesi tahmininde ÇLR, ANFIS, DVM-RBF ve DVM-PK tekniklerinin performansını analiz etmektir. Modellerin tahminleri, istatistiksel analiz kullanılarak gözlenen değerlerle karşılaştırıldı.

2000-2015 yılları arasında DSİ (Devlet Su İşleri Genel Müdürlüğü) 'den ölçülen aylık yeraltı suyu seviyesi verileri ve Antakya Meteoroloji İstasyonu tarafından kaydedilen aylık toplam yağış ve aylık ortalama sıcaklık verileri yeraltı suyu seviyesini belirlemek için kullanılmıştır.

3. MATERYAL VE YÖNTEM

3.1. Çalışma Alanı

Bu çalışmada Amik ovasındaki Reyhanlı bölgesi yeraltı suyu seviyesi incelenmiştir. (Şekil 3.1). Amik ovası, verimlilik açısından Türkiye'nin en verimli ovasıdır. Kalın alüvyal toprak tabakası ile kaplıdır ve tarımsal potansiyel bakımından en verimli havza olarak bilinir. Hatay ilinin en büyük düz arazisini oluşturur. Amik Ovası, topraklarını öncelikle Asi Nehri, Afrin ve Karasu Çayı ile besler. Asi havzasında bulunan ova yaklaşık 65.000 hektarlık bir alana sahiptir. Amik Ovası'ndaki yeraltı suyu seviyesi her yıl yaklaşık 5-6 m azalmaktadır.

Amik Gölü'nün kuruması, küresel iklim değişiklikleri ve bilinçsiz sulama nedeniyle, ovada özellikle çiftçiler için bir çok soruna yol açan çok ciddi bir su sıkıntısı vardır. Bu nedenlerden dolayı mevcut su kaynaklarını daha etkin kullanmak kaçınılmaz hale gelmiştir. .Bu çalışmada kullanılan 15768 numaralı DSİ gözlem kuyusu Reyhanlı yöresinde olup 36.2685 enlem ve 36.5676 boylamındadır. 50 m derinliğe sahiptir.

DSİ (Türkiye Devlet Su İşleri Genel Müdürlüğü) verilerinden alınan aylık yeraltı suyu seviyesi verileri ve Antakya Meteoroloji İstasyonu tarafından kaydedilen aylık toplam yağış ve aylık ortalama sıcaklık verileri yeraltı suyu seviyesini belirlemek için kullanılmıştır.


Modeller, 192 aylık yeraltı suyu seviyesi, aylık toplam yağış ve 16 yıl boyunca ölçülen aylık ortalama sıcaklık değerleri verileri kullanılarak gerçekleştirilmiştir.

2000-2015 yılları arasındaki aylık yeraltı suyu seviyesindeki değişim Şekil 3.2'de gösterilmektedir. Şekil 3.3 ve Şekil 3.4'de sırasıyla, aylık toplam yağış, aylık ortalama sıcaklık değerleri gösterilmiştir.


Reyhanlı bölgesinde, genellikle ilkbaharın başında ve sonunda yüksek yağışlar görülür. Ancak kuraklık yaz aylarında görülür. Sonuç olarak, yer altı suyu seviyesindeki dalgalanmaların, tamamen drenaj havuzunu etkileyen meteorolojik koşullara bağlı olduğu gözlenmiştir.




Şekil 3.1. Reyhanlı bölgesi



Şekil.3.2. Reyhanlı bölgesinin 2000-2015 yılları arasında yer altı suyu seviyesi değişimleri



Şekil. 3.3. Reyhanlı bölgesinin 2000-2015 yılları arasında yağış miktarı değişimleri



Şekil. 3.4. Reyhanlı bölgesinin 2000-2015 yılları arasında sıcaklık değişimleri

Tüm modellerde, Yeraltı Suyu Seviyesi dalgalanmalarını tahmin etmek için Aylık Ortalama Yağış (MP), Aylık Ortalama Sıcaklık (MT), Aylık Yeraltı Suyu Seviyesi (GWL + 1) kullanılmıştır. Modeller ilk olarak ilk veri seti kullanılarak, yani 192 aylık gözlemlerin ilk 144 verisini içeren eğitim verileri kullanılarak eğitilmiştir.

Eğitim aşaması tamamlandıktan sonra, modeller kalan son 48 aydaki gözlemleri içeren test verilerine uygulandı. Her model için, ortalama kare hatası (MSE), ortalama mutlak hata (MAE) ve model tahminleri ile gözlemlenen değerler arasındaki belirleme katsayısı hesaplanır. Sonuçlar, model tahmini ile gözlenen iyi veriler arasındaki performansı karşılaştırmak için kullanılır. MSE ve MAE, Denklem'deki gibi verilmiştir. Eş. 3.1 ve Eş. 3.2:

$$MSE = \frac{1}{N} \left(\sum_{i=1}^N Y_{i_{observed}} - Y_{i_{forecast}} \right)^2 \quad (3.1)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_{i_{observed}} - Y_{i_{forecast}}| \quad (3.2)$$

N ve Y_i sırasıyla veri kümesi sayısını ve yeraltı suyu seviyesi verilerini belirtir. Farklı modellerde giriş kombinasyonları kullanılarak en iyi performans için modeller karşılaştırılmıştır.

3.2. Yöntem

3.2.1. Çoklu Linear Regresyon (CLR)

Bu yöntem, bir bağımlı değişkenin ne kadar etkilendiğini ve etkilendiği ve ilişkilendirildiği bağımsız değişkenlerin değerini bulmak için kullanılır.

Çoklu regresyon analizinde, y bağımlı değişkeni, x_1, x_2, \dots, x_p bağımsız değişkenleri arasındaki ilişkiyi gösterir. Eş. (3.3).

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_j x_j + \dots + \beta_p x_p + \varepsilon \quad (3.3)$$

Burada $\beta_0, \beta_1, \beta_2, \beta_j, \dots, \beta_p$ regresyon katsayıları denir. Herhangi bir β_j regresyon katsayısı, y değişkeninde beklenen değişime karşı, diğer değişkenler sabit tutulduğunda (diğer değişkenlerin etkisi ortadan kalktığına), x_j değişkenindeki bir birim değişikliğine neden olur.

3.2.2 Adaptif Sinir Bulanık Çıkarım Sistemi (ANFIS)

Bulanık kurallar, dilsel değişkenlere bağlı olarak sistem girdileri ve çıktıları arasında if-then ifadeleri şeklinde ifade edilir. ANFIS ilk olarak Jang (1993) tarafından ortaya çıkarıldı.

ANFIS, sinir ağı işlevsel kurallarından türetilmiş bir öğrenme algoritması ile çalışır. Bulanık çıkarım sisteminin parametreleri, bulanık kural tabanlı bir sistemde sinir ağı öğrenme algoritmaları ile belirlenir.

Bulanık Çıkarımlar Sistemi iki tipte sınıflandırılabilir; Mamdani'nin sistemi ve Sugeno'nun sistemi. ANFIS teknikleri, Sugeno'nun sistemine dayanmaktadır. Sugeno tipi olan ANFIS, "If-Then" kuralına göre çalışır ve ANFIS yapısı Sugeno-Fuzzy kurallarını kullanır.

Üç girdi kullanılarak iki kural tarafından oluşturulan Sugeno NF sistemi, Şekil 3.5'de gösterilmiştir. Burada, w_1 veya w_2 , bireysel kural çıktılarının ağırlıklı ortalaması ile elde edilir. ANFIS yapısı, Şekil 3.6' da gösterilmiştir. ANFIS, yönlü bağlantılar üzerinden

bağlanır ve birkaç düğüm içerir. Her düğüm sabit veya ayarlanabilir parametreler olabilen bir düğüm işlevine sahiptir.

Şekillerde, A1, B1, C1 ve A2, B2, C2, dilsel etiketlerdir (“düşük”, “orta” veya “yüksek” gibi), f_1 ve f_2 , sırasıyla 1. ve 2. kuralın çıkış işlevlerini belirtir. $\{p_i, q_i, r_i, s\}$ sonuç parametreleri olarak belirtilir. Sugeno'nun sistemi daha kompakt ve hesaplama açısından daha verimlidir (Jang (1993)).

ANFIS, yönelimli bağlantılar yoluyla bağlanmış bir dizi düğümden oluşan bir ağ yapısıdır. ANFIS'in temel öğrenme kuralı, sinir ağı öğrenme algoritmaları ve bulanık mantık kullanan çok katmanlı ileri beslemeli bir ağıdır.

Her düğüm, ayarlanabilen veya sabit parametreler atanabilen bir düğüm fonksiyonuna sahiptir. Ağ öğrenme veya eğitim aşaması, eğitim verilerini eşleştirmek için parametre değerlerini yeterince belirlemek için kullanılan bir işlemdir.

İki bulanık If / Then kuralları ile ayarlanmış tipik bir kural aşağıda gösterilmiştir.;

Kural 1: *If x is A₁, and y is A₃, and z is A₅; then $f_1 = p_1x + q_1y + r_1z + c_1$*

Kural 2: *If x is A₂ and y is A₄, and z is A₆; then $f_2 = p_2x + q_2y + r_2z + c_2$*

A1, A2, A3, A4, A5 ve A6'nın dilsel etiketler olduğu yerlerde (“düşük”, “orta” veya “yüksek” gibi), f_1 ve f_2 , sırasıyla kural 1 ve kural 2'nin çıkış işlevlerini gösterir ve $\{p_i, q_i, r_i, c_i\}$ müteakip parametreler olarak adlandırılan parametrelerdir.

Katman 1: Bu katmandaki her bir düğüm (i), genelleştirilmiş zil işlevleri tarafından tanımlanan abonelik işlevlerini temsil eden ayarlanabilir bir düğümdür;

$$Z_{1,i} = \mu_{A_i}(x) \quad \text{for } i = 1, 2, 3 \text{ or}$$

$$Z_{1,i} = \mu_{A_{i-3}}(x) \quad \text{for } i = 4, 5, 6$$

buradaki x (veya y), onunla düğüm girişidir ve A_i (veya A_{i-2}), bu düğümlle ilişkili dilsel bir etikettir. İfadelerdeki Z_i , bulanık küme grubunun A giriş seviyesinin (= A1, A2, A4, A5... An) ve x (veya y, z) girişinin niceleyicisini ne kadar sürede karşılayacağını gösterir. A1, ..., An için üyelik fonksiyonları, genelleştirilmiş zil fonksiyonları, örneğin:

$$Z_{1,i} = \mu_1(x) = \frac{1}{1 + |(x - c_1)/a_1|^{2b_1}} \quad (3.4)$$

Burada x (veya y) ve {a1, b1 ve c1}, ön parametreler olarak bilinen uyarlanabilir değişkenlerdir. Bu parametreler, eğitim aşaması sırasında gradyan iniş tekniği kullanılarak kalibre edildi. Bu katmanın çıktısı, öncül kısmın üyelik değeridir.

Katman 2: Bu katman, gelen sinyalleri çarpan ve ürünü gönderen düğümlerden oluşur. Bu çıktı kuralın en etkili direncini temsil eder.

$$Z_{2,I} = w_I = \mu_1(x) \mu_3(y) \quad (3.5)$$

Katman 3: Bu katmandaki düğümler, ateşleme gücü kurallarının tüm kuralların ateş gücü toplamına oranını hesaplar.

$$Z_{3,I} = \bar{w}_I = \frac{w_I}{w_1 + w_2 + w_3 + w_4} \quad (3.6)$$

Katman 4: Bu katmanın düğümleri düğüm işlevleriyle uyumludur

$$Z_{4,I} = \bar{w}_I f_I = \bar{w}_I (p_I x + q_I y + r_I z + c_I) \quad (3.7)$$

Katman 3'ün çıkışı burada ve {pi, qi, ri} parametre kümeleridir. Bu katmanın parametrelerine sonuç parametreleri denir.


Katman 5: Bu katmanın son sabit çıktısı, gelen tüm sinyallerin toplamı olarak hesaplanır.

$$Z_{5,I} = f = \frac{w_1}{w_1 + w_2} f_1 + \frac{w_2}{w_1 + w_2} f_2 \quad (3.8)$$


Genel form;

$$Z_{S,i} = f = \sum_{i=1}^n \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad (3.9)$$

İşlevsel olarak Sugeno birinci dereceden bulanık çıkarım sistemine de eşdeğer bir adaptif ağ oluşturulur. ANFIS hakkında daha fazla bilgi Jang ve ark. (1997) de bulunabilir.



Şekil 3.5. Sugeno tipi bulanık model



Şekil 3.6. Üç girdi için Neuro-Fuzzy (NF) sistem yapısı

Sunulan bulanık modelde, girdi verileri Aylık Ortalama Yağış (MP), Aylık Ortalama Sıcaklık (MT), Aylık Zemin Suyu Seviyesi (GWL + 1) ve Zemin Suyu Seviyesi (GWL) olarak alınmıştır.

3.2.3 Destek Vektör Makineleri (DVM)

Destek Vektör Makinesi (DVM), desen sınıflandırması için geliştirilen ancak yakın zamanda regresyon ve dağılım tahmini bulma gibi diğer kullanımlar için uyarlanmış bir algoritmadır. Biyoinformatik gibi birçok alanda kullanılmıştır ve şu anda Singapur Ulusal Üniversitesi (NUS) ve Massachusetts Teknoloji Enstitüsü (MIT) içeren birçok üniversite ve araştırma enstitüsünde çok aktif bir araştırma alanıdır.

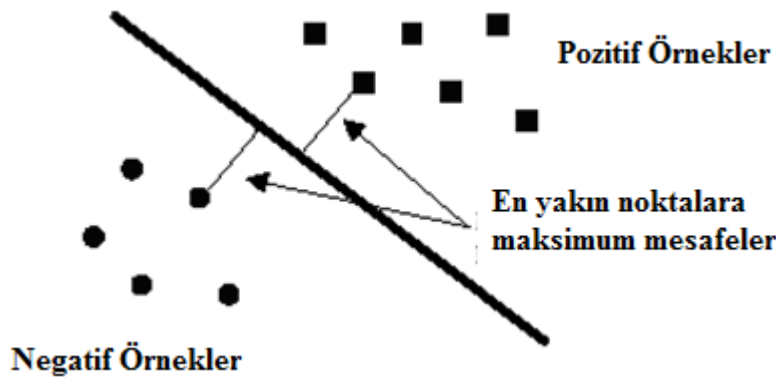
Destek vektör makineleri (DVM), Vapnik (1995) tarafından bulunan veri odaklı araştırma alanlarında makine öğrenme yaklaşımıdır. DVM istatistiksel öğrenme teorisine dayanmaktadır. DVM temel olarak iki veri sınıfını en iyi şekilde ayırtmak için kullanılır. Bu amaçla karar sınırları veya hiper düzlemler belirlenir. Doğrusal olmayan bir veri kümesinde, DVM'ler doğrusal bir hiper düzlem çizemez. Bu nedenle çekirdek numaraları kullanılır. Kernel yöntemi, doğrusal olmayan verilerdeki makine öğrenimini büyük ölçüde artırır. Kernel yönteminde DVM tahminçisi (y) süreci şu şekilde ifade edilebilir:

$$y = (K_{xi} \cdot W_{jk}) + b \quad (3.10)$$

Denklem (3.10)'da b , DVM ağının bias terimidir ve W_{jk} ağırlık vektörü olarak adlandırılır. K_{xi} , giriş vektörlerini yüksek boyutlu bir özellik alanına eşleyen doğrusal olmayan bir işlevdir. Bu çalışmada kullanılan üç katmana sahip DVM modelinin yapısı Şekil 3.9'da verilmiştir. Bu örnek DVM modeli için çıktı değeri, girişlerdeki üç ürününün toplamına ve Lagrange çarpanlarının bağımsız kombinasyonlarına eşittir.

Bu çalışmada kullanılan doğrusal olmayan çekirdek fonksiyonları, Radyal temelli çekirdek fonksiyonu ve Poli çekirdek fonksiyonlarıdır.

DVM, regresyon gibi çeşitli optimizasyon problemlerine uygulanabilir olsa da, klasik problem veri sınıflandırmasıdır. Temel fikir, Şekil 3.7'de gösterilmiştir. Veri noktaları, pozitif veya negatif olarak tanımlanır ve sorun, veri noktalarını maksimum marj ile ayıran bir hiper düzlem bulmaktır.



Şekil 3.7. Veri Sınıflandırması

Şekil 3.7 sadece veri noktalarının doğrusal olarak ayrılabilirdiği 2 boyutlu durumu göstermektedir. Çözülecek problemin matematiği şöyledir:

$$\begin{aligned} s.t \quad y_i = +1 &\Rightarrow \vec{w} \cdot \vec{x}_i + b \geq +1 \\ y_i = -1 &\Rightarrow \vec{w} \cdot \vec{x}_i - b \leq -1 \end{aligned} \quad (3.11)$$

Optimum hiper düzleme paralel ve Eş. (3.11) ile tanımlanan ayırım yapabilen iki hiper düzlem üzerinde bulunan ve sınır genişliğini belirleyen noktalar destek vektörleri olarak adlandırılır. Yukarıdaki iki denklem tek bir denklem haline getirilirse;

$$s.t \ y_i(\vec{w} \cdot \vec{x}_i + b) \geq 1, \quad \forall i \quad (3.12)$$

İki sınıfı maksimum sınır genişliği ile ayıran optimum hiperdüzlem, $\|w\|$ ifadesinin Eş. (3.12) deki sınırlamalara bağlı olarak minimum hale getirilmesi ile bulunabilir

$$\min_{\vec{w}, b} \frac{1}{2} \|w\|, \quad (3.13)$$

Burada X_i hiperdüzlem üzerindeki noktayı, w hiper düzlemin normalini ve b ise hiper düzlemin orijinden olan uzaklığı olarak ifade edilen biası (eğilim değeri) temsil etmektedir. Her veri noktasının (x_i) tanımlanması, +1 veya -1 (sırasıyla pozitif veya negatif değeri temsil eder) alabilen y_i 'dir. Çözüm hiper-düzlemi aşağıdaki gibidir:

$$f(\mathbf{x}) = \sum_{i=1}^r \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (3.14)$$

Burada α_i , desen x_i ve $K(x, \dots, x_i)$ ile ilişkilendirilmiş Lagrange çarpanıdır, desen vektörlerini örtük olarak uygun bir özellik alanına eşleyen bir çekirdek işlevidir.

Şimdi x_k destek vektörünün, özellik alanındaki diğer destek vektörlerine doğrusal olarak bağlı olduğunu varsayalım.

$$K(\mathbf{x}, \mathbf{x}_k) = \sum_{\substack{i=1 \\ i \neq k}}^r c_i K(\mathbf{x}, \mathbf{x}_i)$$

Burada C_i skaler sabittir.

Sonra karar yüzeyi (1) aşağıdaki gibi yazılabilir.

$$f(\mathbf{x}) = \sum_{\substack{i=1 \\ i \neq k}}^r \alpha_i y_i K(\mathbf{x}, \mathbf{x}_i) + \alpha_k y_k \sum_{\substack{i=1 \\ i \neq k}}^r c_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (3.15)$$

$\alpha_k y_k C_i = \alpha_i y_i \gamma_i$ tanımlarında denklem aşağıdaki şekilde yazılabilir.

$$f(\mathbf{x}) = \sum_{\substack{i=1 \\ i \neq k}}^r \alpha_i (1 + \gamma_i) y_i K(\mathbf{x}, \mathbf{x}_i) + b$$

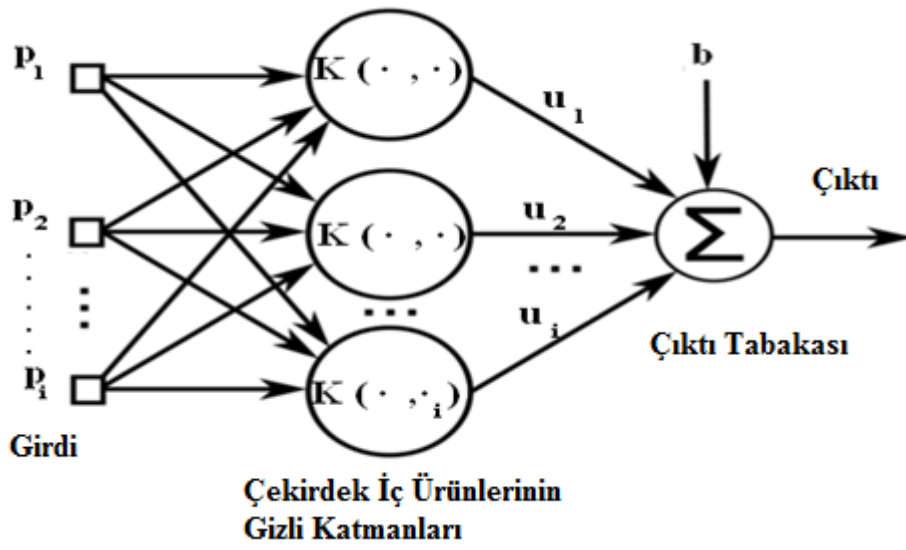
$$= \sum_{\substack{i=1 \\ i \neq k}}^r \bar{\alpha}_i y_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (3.16)$$

$$\bar{\alpha}_i = \alpha_i(1 + \gamma_i) \quad (3.17)$$

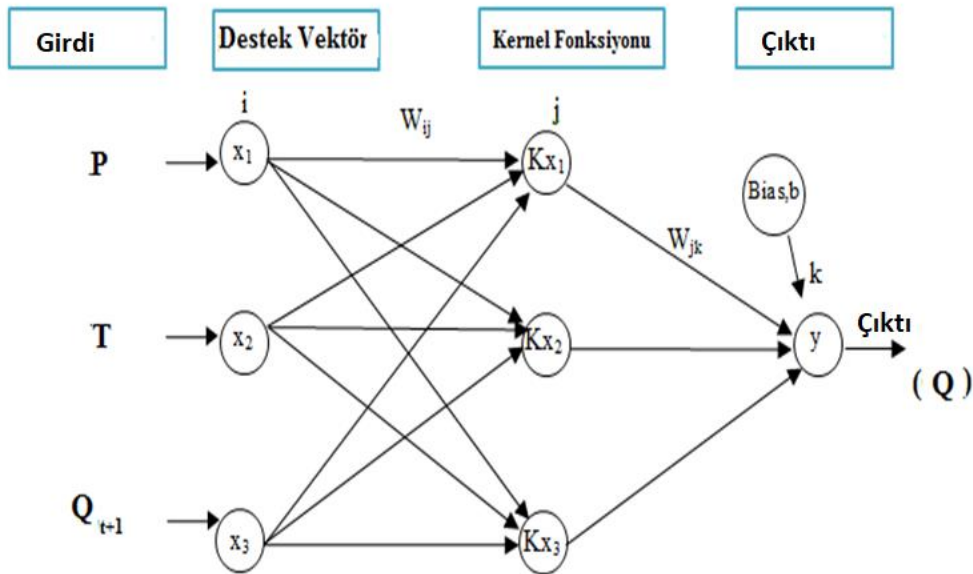
Denklem (3.14), (3.15), (3.16) ve (3.17) 'ye göre, karar yüzeyinin temsilinde doğrusal bağımlı destek vektörünün gerekli olmadığını görüyoruz. Bununla birlikte, basitleştirilmiş gösterimi elde etmek için Lagrange çarpanlarının (Eş. 3.12) 'ye göre değiştirilmesi gerekmektedir. Ancak bu, tanımlanan herhangi bir doğrusal bağımlı destek vektörüne uygulanabilen çok basit bir değişikliktir.

DVM, Vapnik (1998) tarafından temel kavram ve teoriyi ortaya koyan veri odaklı araştırma alanlarında nispeten yeni ve gelecek vaat eden bir tahminci haline gelmiştir. DVM'nin genelleme yeteneğinin, YSA 'nin deneysel riskini en aza indirmekten ziyade yapısal risk minimizasyonu üzerine kurulu olması nedeniyle, YSA'dan daha iyi olduğu düşünülmektedir. DVM model yapısının ana süreci, model yapısını destekleyen destek vektörlerinin seçilmesi ve ağırlıklarının belirlenmesidir.

Şekil 3.8, DVM modellerinin şematik yapısını göstermektedir. DVM'nin arkasındaki fikir, dönüştürülen özellik (giriş) alanındaki iki sınıfı maksimum mesafeyle ayıran bir hiper düzlem bulmaktır. DVM, tüm antrenman örneklerinin etrafındaki ϵ -sınırında kaldığı ve mümkün olduğu kadar düz olduğu optimal regresyon hiper düzlemini bulmayı amaçlamaktadır. (Schölkopf ve Smola (2002)). DVM modelleri yapay sinir ağlarıyla yakından ilgilidir ve iki katmanlı, ileri beslemeli yapay sinir ağına sahipken sigmoid bir çekirdek işlevi kullanır. (Haykin (1998)).



Şekil. 3.8. DVM'nin şematik gösterimi



Şekil 3.9.Çalışmada kullanılan DVM modelinin yapısı

DVM' nin ilginç bir özelliği, elde edilen ampirik risk azaltma ilkesinden elde edilen verilerdeki ortalama hata oranını en aza indirerek, istatistiksel öğrenme elde edilebilir olmasıdır.

DVM, bu sınırın değişken gruplar arasında nasıl çizileceğini tanımlar. DVM, istatistiksel öğrenme teorisine göre çalışır. Bir dizi eğitim verisi $[(p_1, y_1), (p_2, y_2), \dots, (p_n, y_n)]$, burada “pi” değeri numunenin giriş alanını gösterir ve karşılık gelen bir “yi” değerine sahiptir. DVM işlevi Denklemde olduğu gibi ifade edilir. Eş. (3.18):

$$y = (K_{pi} \cdot W_{jk}) + b \quad (3.18)$$

Çekirdek fonksiyonunun K_{pi} olduğu durumda, b, DVM ağıнын önyargı terimidir ve W_{jk} , çıktı verileri için eğitim veri setlerinin önemini elde eden Lagrange çarpanları olarak adlandırılır. Doğrusal olmayan radyal tabanın çekirdek işlevi (Hsu ve diğerleri (2003)) Eş. (3.19):

$$K_{xi} = e^{-\gamma \|p_i - y_i\|^2} \quad \gamma > 0 \quad \text{and} \quad i = 1, 2, 3, \dots, n \quad (3.19)$$

γ kullanıcı tanımlı bir parametredir. Polinomun çekirdek işlevi (Hsu ve diğ. (2003)) Eş. (3.20) 'dedir:

$$K_{xi} = (p \cdot y + c)^d \quad i = 1, 2, 3, \dots, n \quad (3.20)$$

DVM, diğer sınıflandırma yöntemlerinden önemli ölçüde farklıdır. Amacı, genelleme hatasını en aza indirmek ve böylece marjı en üst seviyeye çıkarmak için iki sınıf arasında optimal bir ayırma hiper düzlemi oluşturmaktır. DVM, yapısal risk minimizasyonu yaklaşımının yaklaşık bir uygulamasıdır. Yapısal risk azaltma yöntemi, öğrenme makinesinin test verilerindeki hata oranının, eğitim hata oranının toplamına ve Vapnik-Chervonenkis boyutuna dayanan bir terime bağlı olduğunu açıklamıştır (Haykin (1998)).

3.2.4. Radyal Temelli Çekirdek Fonksiyonlu Destek Vektör Makineleri (DVM-RBF)

Lagrange çarpanları, çıktı verileri için eğitim veri setlerinin önemini gösterir. Doğrusal olmayan radyal temelli çekirdek fonksiyonu (Hsu vd, 2003) aşağıdaki denklemle gösterilmiştir.

$$K_{xi} = e^{-\gamma \|p_i - y_i\|^2} \quad \gamma > 0 \quad \text{and} \quad i = 1, 2, 3, \dots, n \quad (3.21)$$

Burada γ kullanıcı tanımlı bir parametredir.

3.2.5.Poli Çekirdek Fonksiyonlu Destek Vektör Makineleri (DVM-PK)

Poli çekirdekleri genellikle, üzerinde boşluk bırakabilen orijinal değişkenlerin polinomları içerisindeki vektörlerdeki benzerliği temsil eden destek vektör makinelerinde kullanılır.

Poli çekirdek fonksiyonu (Hsu vd, 2003) tarafından aşağıdaki denklemlerle gösterilmiştir.

$$K_{xi} = (p \cdot y + c)^d \quad i = 1, 2, 3, \dots, n \quad (3.22)$$

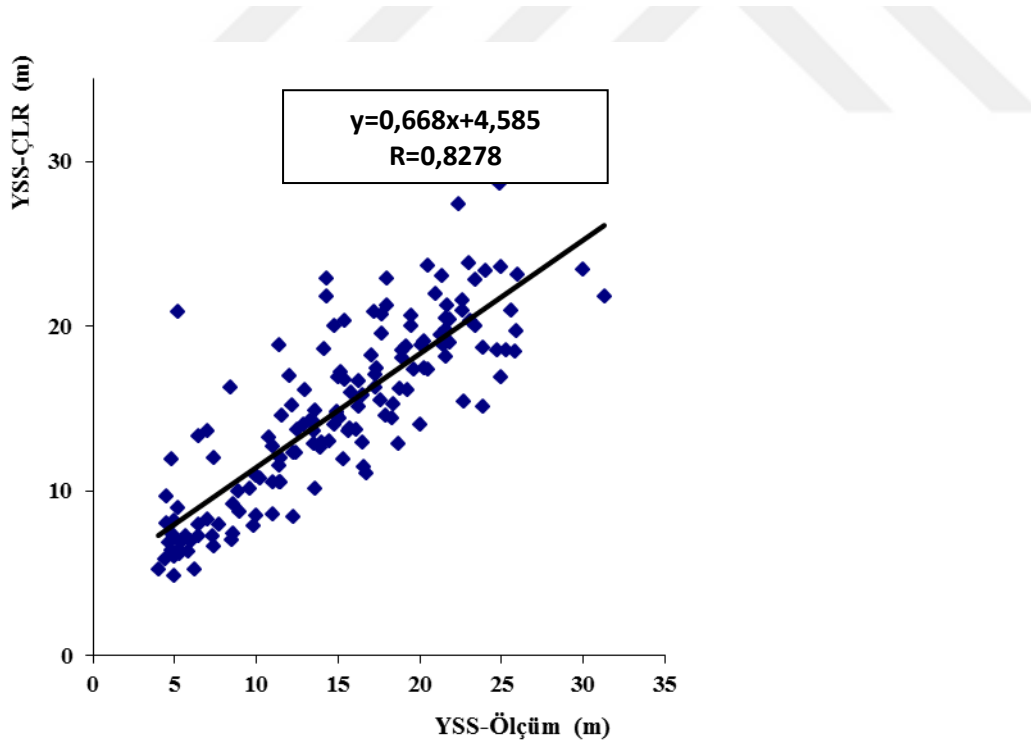
4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Yeraltı suyu seviyesi deęişimlerini öngörmek için, bu bölümde ÇLR, ANFIS, DVM-PK ve DVM-RBF modellerinin sonuçları tartışılacaktır. Tüm modellerin performans deęerlendirmesinde korelasyon katsayısı (R), ortalama karesel hata (MSE) ve mutlak ortalama hata (MAE) hesaplanmıştır.


Test verilerinden elde edilen MSE, MAE ve R'nin karşılaştırma parametreleri Çizelge 4.1'de gösterilmektedir. Sonuçlar, model tahmini ve gözlem verilerinin performansını karşılaştırmak için kullanılır.

Şekil 4.1 ve Şekil 4.2 'de ÇLR modeli eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir. Şekillere bakıldığında korelasyon katsayısının iyi düzeyde olduğu ve gerçek deęerlere yakın deęerler verdiği görülmektedir. Şekil 4.3 ve Şekil 4.4'de ÇLR modeli test sonuçları için sırasıyla dağılım ve saçılım grafikleri gösterilmiştir.


Grafikler, bakıldığında korelasyon katsayısının yüksek olduğunu ve yeraltı suyu seviyesi tahmininin gerçek deęerlere yakın olduğunu göstermektedir.




Şekil 4.1 Yeraltı su seviyesi eğitim verileri için Ölçüm ve ÇLR saçılım grafięi.



Şekil 4.2. Yeraltı su seviyesi eğitim verileri için Ölçüm ve ÇLR dağılım grafiği.



Şekil 4.3. Yeraltı su seviyesi test verileri için Ölçüm ve ÇLR saçılım grafiği.



Şekil 4.4. Yeraltı su seviyesi test verileri için Ölçüm ve ÇLR dağılım grafiği.


ANFIS modeli için 16 yıllık veriler değerlendirilmiş ve sonuçlar aşağıdaki gibi tanımlanmıştır. Şekil 4.5 ve Şekil 4.6 'da ANFIS modeli eğitim verileri için dağılım ve saçılım grafikleri gösterilmiştir.

Şekillere bakıldığında tahini değerlerin gerçek değerlere yakın olduğu ve korelasyon katsayısının 0.85 olduğu görülmektedir.

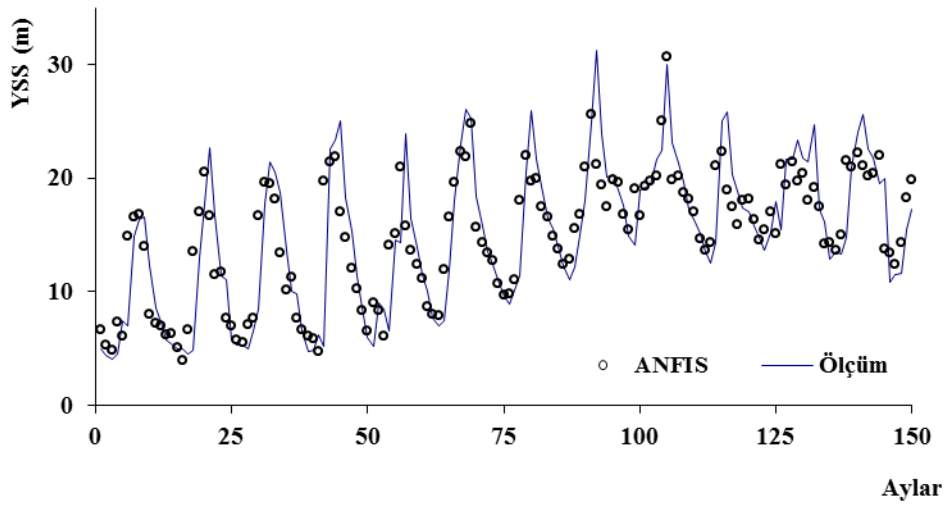
ANFIS modellerinde, verilerin test edilmesi için dağılım ve dağılım grafikleri, Şekil 4.7 ve Şekil 4.8'de gösterilmiştir. Korelasyon katsayısı $R = 0,87$ olarak elde edildi.

Dağılım ve dağılım çizelgeleri incelendiğinde, tahmini değerler gerçek değerlere yakındır ve ANFIS sonuçları, RBNN sonuçlarına göre benzer sonuçlar göstermiştir.


Çizelge 4.1'de gösterilen MSE, MAE ve R (4,82-1,63-0,87) kriter değerlerine baktığımızda, ANFIS tahmini değerleri ÇLR değerlerinden daha iyi sonuçlar vermiştir.



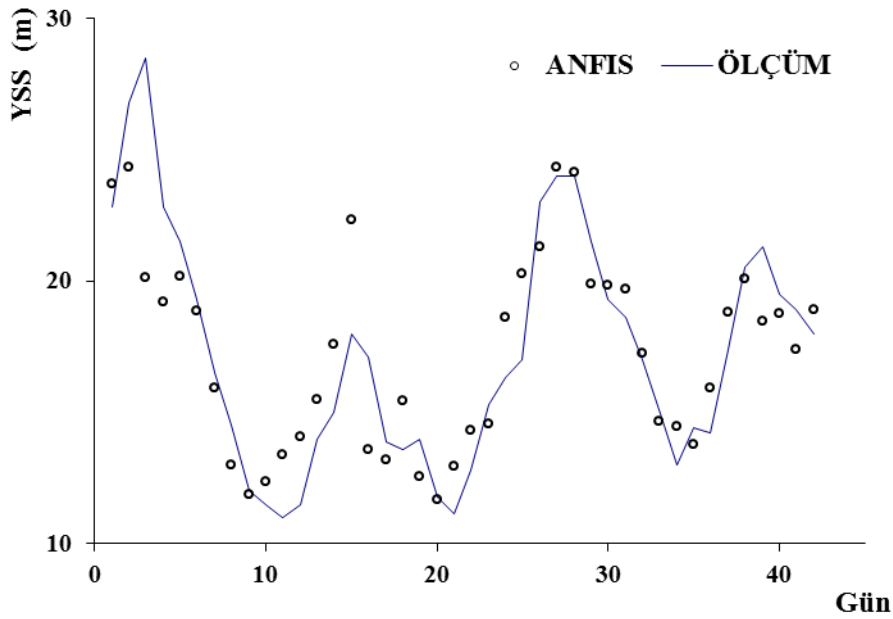
Şekil 4.5. Yeraltı su seviyesi eğitim verileri için Ölçüm ve ANFIS saçılım grafiği.



Şekil 4.6. Yeraltı su seviyesi eğitim verileri için Ölçüm ve ANFIS dağılım grafiği.



Şekil 4.7. Yeraltı su seviyesi test verileri için Ölçüm ve ANFIS saçılım grafiği.




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

Yeraltı suyu seviyesini tahmin etmek için Poli Çekirdek Fonksiyonlu Destek Vektör Makineleri (DVM-PK) ve Radyal Temelli Çekirdek Fonksiyonlu Destek Vektör Makineleri (DVM-RBF) modellerine de uygulandı.

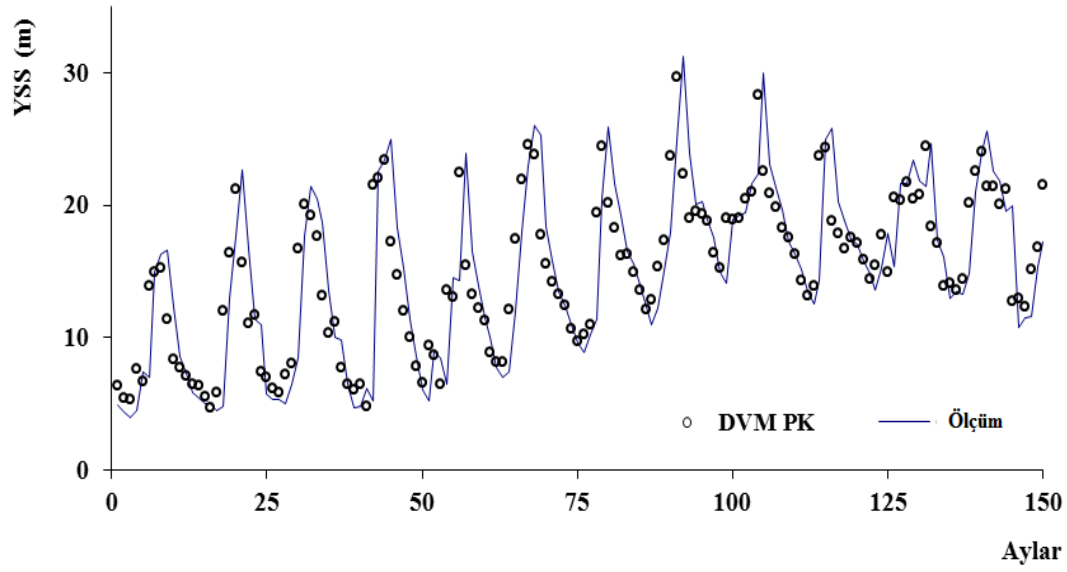
Analiz sonucunda DVM-PK eğitim verileri için Şekil 4.9. ve Şekil 4.10'da dağılım ve saçılım grafikleri gösterilmiştir.

Oluşturulan grafikte korelasyon katsayısının $R=0,82$ olduğu ve gerçek değerlere yakın değerler verdiği görülmektedir.


DVM-PK modelleri için tahmini test sonuçları Şekil 4.11 ve Şekil 4.12'de gösterilmektedir. Test verileri için dağılım ve saçılım grafikleri incelendiğinde R katsayısının iyi düzeyde olduğu ve yeraltı su seviyesi tahminlerinin gerçek değerlere yakın olduğu görülmüştür.



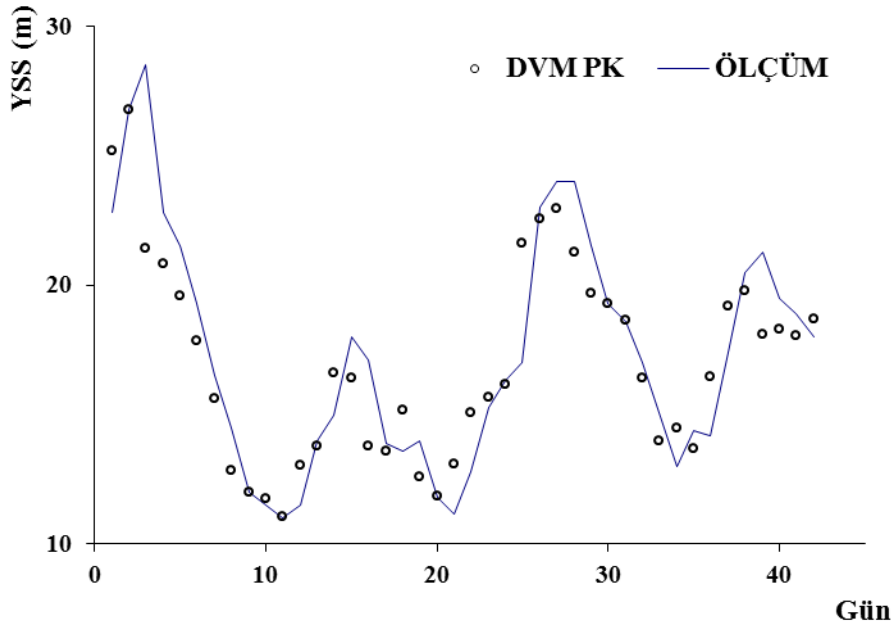
Şekil 4.9. Yeraltı su seviyesi eğitim verileri için Ölçüm ve DVM PK saçılım grafiği.



Şekil 4.10. Yeraltı su seviyesi eğitim verileri için Ölçüm ve DVM PK dağılım grafiği.



Şekil 4.11. Yeraltı su seviyesi test verileri için Ölçüm ve DVM PK saçılım grafiği.



Şekil 4.12. Yeraltı su seviyesi test verileri için Ölçüm ve DVM PK dağılım grafiği.

Radyal Temelli Çekirdek Fonksiyonlu Destek Vektör Makineleri (DVM-RBF) modeli eğitim verileri için için dağılım ve saçılım grafikleri Şekil 4.13 ve Şekil 4.14 de gösterilmiştir. Korelasyon katsayısının 0,82 olduğu görülmüştür.


DVM RBF modelleri test verileri için dağılım ve saçılım grafikler Şekil 4.15 ve Şekil 4.16 da gösterilmiştir.

Test verilerine bakıldığında korelasyon katsayısının yüksek olduğu ve yeraltısuyu seviye tahminlerinin gerçek değerlere yakın olduğu görülmektedir. DVM modeli sonuç verileri, şekillerde gösterilen gerçek değerlere yakındır.

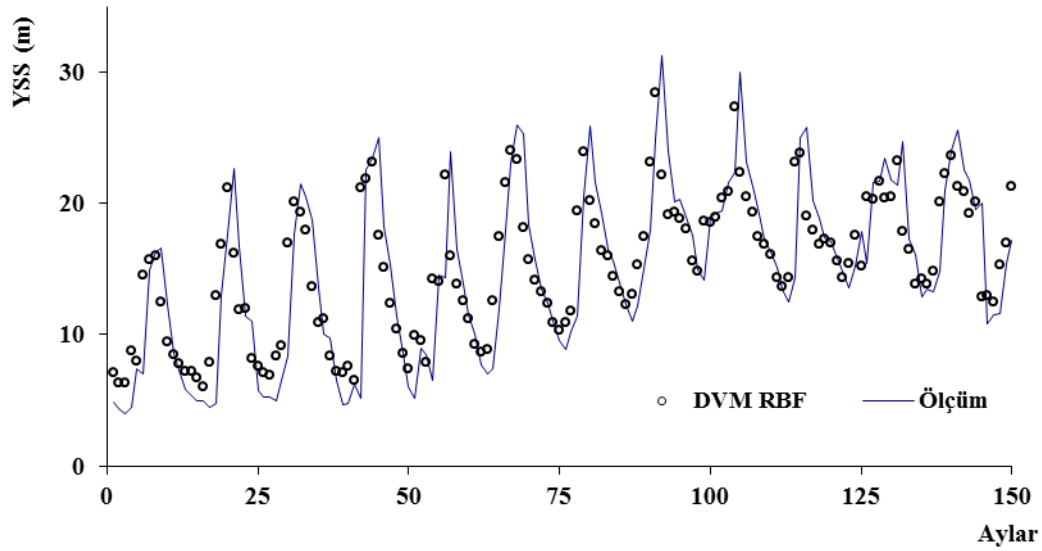
Dağılım grafiklerinden görüldüğü gibi, DVM model tahminleri diğer modellere göre daha az dağınıktır.

DVM Poli Çekirdekler (DVM-PK) ve DVM Radyal Bazlar Fonksiyonu (DVM-RBF) tahmini değerleri, ANFIS değerlerine göre daha yakın sonuçlar verdi.

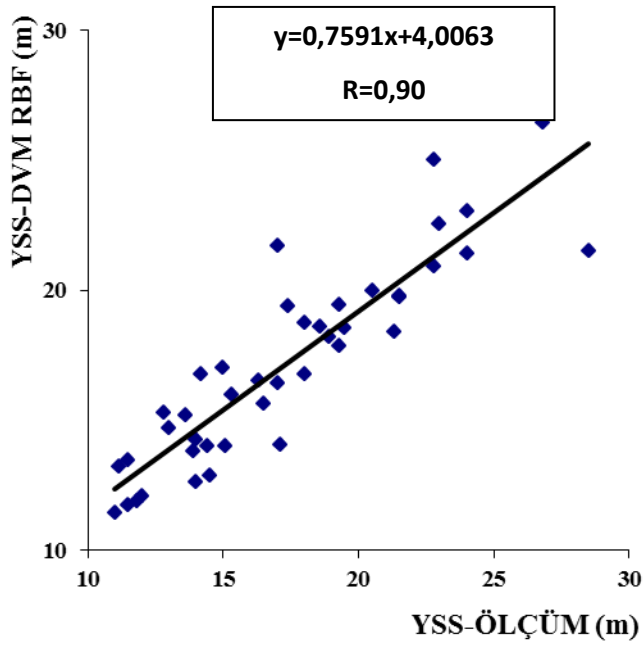
MSE, MAE ve R'ye göre, ÇLR (5,44 - 1,73-0,84) modeli en düşük başarı oranına sahiptir. ANFIS yaklaşımı (4,82-1,63-0,87) ve ÇLR modelinden daha yüksek başarı oranına sahiptir. Tüm performans değerlendirmelerinde DVM-PK (3,81-1,41-0,90) ve DVM-RBF (3,78-1,42-0,890) modellerinin diğer modellerden daha iyi performans gösterdiği bulunmuştur.




Şekil 4.13. Yeraltı su seviyesi eğitim verileri için Ölçüm ve DVM-RBF saçılım grafiği



Şekil 4.14. Yeraltı su seviyesi eğitim verileri için Ölçüm ve DVM RBF dağılım grafiği



Şekil 4.15. Yeraltı su seviyesi test verileri için Ölçüm ve DVM RBF saçılım grafiği.



Şekil 4.16. Yeraltı su seviyesi test verileri için Ölçüm ve DVM RBF dağılım grafiği

Çizelge 4.1. İstatistiksel Kriterlere Göre Model Sonuçları

MODELLER	GİRDİ	MSE	MAE	R
ÇLR	MP,MT, GWL _(L+1)	5,44	1,73	0,84
ANFIS	MP,MT, GWL _(L+1)	4,82	1,63	0,87
DVM-PK	MP,MT, GWL _(L+1)	3,81	1,41	0,90
DVM-RBF	MP,MT, GWL _(L+1)	3,78	1,42	0,90

MSE: Ortalama karesel hata , MAE: Ortalama mutlak hata, R: Korelasyon katsayısı.
 MP: Aylık ortalama yağış , MT: Aylık ortalama sıcaklık , GWL+1 :Aylık yeraltısuyu seviyesi

5. SONUÇLAR

Bu çalışmada, Türkiye'deki Reyhanlı bölgesinin yeraltı suyu seviyesindeki değişimleri ÇLR, ANFIS, DVM-RBF ve DVM-PK yaklaşımları kullanılarak tahmin edilmiştir.

Tüm modellerin yeraltı suyu seviyesi tahminindeki doğruluğu da araştırılmış ve sonuçlar birbirleriyle karşılaştırılmıştır. Karşılaştırmalar, DVM-RBF ve DVM-PK'nın yeraltı suyu seviyesi tahmininde daha yakın bir hassasiyete sahip olduğunu ortaya koymuştur.

Genel olarak, ÇLR modeli en düşük başarı oranına sahiptir.

ANFIS modelleri, ÇLR modelinden daha iyi sonuçlar vermiştir. MSE, MAE ve R kriterlerine göre, en iyi sonuçlar DVM-RBF ve DVM-PK modellerinde elde edilmiştir. Vaka çalışmasının sonuçları tatmin edicidir ve DVM-RBF ve DVM-PK modellerinin yeraltı suyu hidrolojisi alanında yararlı bir tahmin aracı olabileceğini göstermektedir.

Gelecekteki çalışmalar için, farklı coğrafi bölgeler için günlük, haftalık veya yıllık yeraltı suyu seviyesi tahminlerinde yeni yapay zeka teknikleri yöntemlerinin kullanımını incelemeleri önerilmektedir.

KAYNAKLAR

- Adamowski, J.F. and Chan, H.F. (2011). A wavelet neural network conjunction model for groundwater level forecasting. *Journal of Hydrology*, 407 (1–4): 28–40.
- Afan, H. A., El-Shafie, A., Yaseen, Z. M., Hameed, M. M., Mohtar, W. H. M. W., and Hussain, A. (2015). ANN based sediment prediction model utilizing different input scenarios. *Water resources management*, 29(4): 1231-1245.
- Affandi, A. K. and Watanabe, K. (2007). Daily groundwater level fluctuation forecasting using soft computing technique. *Nature and Science*, 5(2): 1-10.
- Barzegar, R., Fijani, E., Moghaddam, A. A., and Tziritis, E. (2017): Forecasting of groundwater level fluctuations using ensemble hybrid multi-wavelet neural network-based models.- *Science of the Total Environment*, 599: 20-31.
- Bhattacharya, S., Datta, A., Berg, J. M., and Gangopadhyay, S. (2005). Studies on surface wettability of poly (dimethyl) siloxane (PDMS) and glass under oxygen-plasma treatment and correlation with bond strength. *Journal of microelectromechanical systems*, 14(3): 590-597.
- Brion, G. M., Neelakantan, T. R., and Lingireddy, S. (2002). A neural-network-based classification scheme for sorting sources and ages of fecal contamination in water. *Water research*, 36(15): 3765-3774.
- Chang, F.J., and Chang, Y.T., 2006. Adaptive neuro-fuzzy inference system for prediction of water level in reservoir. *Advanced Water Research*, 29: 1–10.
- Chang, F.-J., Chang, L.-C., Huang, C.-W., and Kao, I. (2016): Prediction of monthly regional groundwater levels through hybrid soft-computing techniques. *Journal of Hydrology*, 541: 965–976.
- Chitsazan, M., Rahmani, G., and Neyamadpour, A. (2015). Forecasting groundwater level by artificial neural networks as an alternative approach to groundwater modeling. *Journal of the Geological Society of India*, 85 (1): 98–106.
- Cho, S., Lim, B., Jung, J., Kim, S., Chae, H., Park, J. and Park, J. K. (2014). Factors affecting algal blooms in a man-made lake and prediction using an artificial neural network. *Measurement*, 53: 224-233.
- Coulibaly, P., Anctil, F., Aravena, R., and Bobée, B. (2001). Artificial neural network modeling of water table depth fluctuations. *Water resources research*, 37(4): 885-896.
- Demirci, M., and Baltaci, A. (2013). Prediction of suspended sediment in river using fuzzy logic and multilinear regression approaches. *Neural Computing and Applications*, 23(1): 145-151.
- Demirci, M., Üneş, F., and Saydemir, S. (2015a). Suspended sediment estimation using an artificial intelligence approach. In *Sediment Matters* (pp. 83-95). Springer, Cham.

- Demirci, M., Üneş, F., and Aköz, M. S. (2015). Prediction of cross-shore sandbar volumes using neural network approach. *Journal of Marine Science and Technology*, 20(1): 171-179.
- Demirci, M., Unes, F., Kaya, Y. Z., Mamak, M., Tasar, B., & Ispir, E. (2017, March). Estimation of groundwater level using artificial neural networks: a case study of Hatay-Turkey. In *10th International Conference „Environmental Engineering “*.
- Ebrahimi, H., and Rajaei, T. (2017). Simulation of groundwater level variations using wavelet combined with neural network, linear regression and support vector machine. *Global and Planetary Change*, 148, 181-191.
- Emamgholizadeh, S. (2012). Neural network modeling of scour cone geometry around outlet in the pressure flushing. *Glob Nest J*, 14: 540-549.
- Emamgholizadeh, S., Bateni, S. M., and Jeng, D. S. (2013). Artificial intelligence-based estimation of flushing half-cone geometry. *Engineering Applications of Artificial Intelligence*, 26(10): 2551-2558.
- Emamgholizadeh, S., Moslemi, K. and 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.
- Esen, H., and Inalli, M. (2010). ANN and ANFIS models for performance evaluation of a vertical ground source heat pump system. *Expert Systems with Applications*, 37(12): 8134-8147.
- Feng, K., and Tian, J. (2018). Analysis of variation characteristics of extreme precipitation events in hetao area, china based on fuzzy clustering climate zoning. *Applied Ecology and Environmental Research*, 16(5): 6299-6316.
- Guzman, S. M., Paz, J. O., Tagert, M. L. M., and Mercer, A. (2015). Artificial Neural Networks and Support Vector Machines: Contrast Study for Groundwater Level Prediction. In *2015 ASABE Annual International Meeting* (p. 1). American Society of Agricultural and Biological Engineers.
- Güldal, V., and Tongal, H. (2010). Comparison of recurrent neural network, adaptive neuro-fuzzy inference system and stochastic models in Eğirdir Lake level forecasting. *Water resources management*, 24(1): 105-128.
- Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3): 665-685.
- Jang, J. S., Sun, C. T., and Mizutani, E. (1997). Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence. Matlab Curriculum Series Prentice . New Jersey
- Haykin, S. (1998): Neural Networks: A Comprehensive Foundation. 2ndedition. Macmillan, New York.

- He, Z., Wen, X., Liu, H., and Du, J. (2014). A comparative study of artificial neural network, adaptive neuro fuzzy inference system and support vector machine for forecasting river flow in the semiarid mountain region. *Journal of Hydrology*, 509: 379-386.
- Hsu, C.W., Chang, C.C., and Lin, C.J. (2003). .A Practical Guide to Support Vector Classification.
- Kankal, M., Uzlu, E., Nacar, S., and Yüksek, Ö. (2018). Predicting temporal rate coefficient of bar volume using hybrid artificial intelligence approaches. *Journal of Marine Science and Technology*, 23(3): 596-604.
- Kaya, Y. Z., Mamak, M., and Unes, F. (2016). Evapotranspiration prediction using M5T data mining method. *International Journal of Advanced Engineering Research and Science*, 3(12):225-229.
- Kentel, E. (2009). Estimation of river flow by artificial neural networks and identification of input vectors susceptible to producing unreliable flow estimates. *Journal of hydrology*, 375(3-4): 481-488.
- Khalil, B., Broda, S., Adamowski, J., Ozga-Zielinski, B., and Donohoe, A. (2015). Short-term forecasting of groundwater levels under conditions of mine-tailings recharge using wavelet ensemble neural network models. *Hydrogeology Journal*, 23(1): 121-141.
- Kişi, Ö. (2006). Daily pan evaporation modelling using a neuro-fuzzy computing technique. *Journal of hydrology*, 329(3-4): 636-646.
- Kurtulus, B., and Razack, M. (2010). Modeling daily discharge responses of a large karstic aquifer using soft computing methods: Artificial neural network and neuro-fuzzy. *Journal of Hydrology*, 381(1-2): 101-111.
- Latt, Z. Z., and Wittenberg, H. (2014). Improving flood forecasting in a developing country: a comparative study of stepwise multiple linear regression and artificial neural network. *Water resources management*, 28(8): 2109-2128.
- Li, Y. L., Zhang, Q., Werner, A. D., and Yao, J. (2015). Investigating a complex lake-catchment-river system using artificial neural networks: Poyang Lake (China). *Hydrology Research*, 46(6): 912-928.
- Mohammadi, K. (2009). Groundwater table estimation using MODFLOW and artificial neural networks. In *Practical hydroinformatics* (pp. 127-138). Springer, Berlin, Heidelberg.
- Mohanty, S., Jha, M. K., Kumar, A., and Sudheer, K. P. (2010). Artificial neural network modeling for groundwater level forecasting in a river island of eastern India. *Water resources management*, 24(9): 1845-1865.

- Mohanty, S., Jha, M. K., Kumar, A. and Panda, D. K. (2013): Comparative evaluation of numerical model and artificial neural network for simulating groundwater flow in Kathajodi–Surua Inter-basin of Odisha, India. *Journal of Hydrology* 495: 38-51.
- Nacar, S., Hınıs, M. A., and Kankal, M. (2018). Forecasting daily streamflow discharges using various neural network models and training algorithms. *KSCE Journal of Civil Engineering*, 22(9):3676-3685.
- Nastos, P. T., Paliatsos, A. G., Koukouletsos, K. V., Larissi, I. K., and Moustris, K. P. (2014). Artificial neural networks modeling for forecasting the maximum daily total precipitation at Athens, Greece. *Atmospheric Research*, 144: 141-150.
- Nayak, P. C., Sudheer, K. P., Rangan, D. M., and Ramasastri, K. S. (2004). A neuro-fuzzy computing technique for modeling hydrological time series. *Journal of Hydrology*, 291(1-2): 52-66.
- Nayak, P. C., Rao, Y. S., & Sudheer, K. P. (2006). Groundwater level forecasting in a shallow aquifer using artificial neural network approach. *Water resources management*, 20(1):77-90.
- Nourani, V., Mogaddam, A. A., and Nadiri, A. O. (2008). An ANN-based model for spatiotemporal groundwater level forecasting. *Hydrological Processes: An International Journal*, 22(26): 5054-5066.
- Nourani, V., Alami, M. T., and Vousoughi, F. D. (2015). Wavelet-entropy data pre-processing approach for ANN-based groundwater level modeling. *Journal of Hydrology*, 524: 255-269.
- Sanikhani, H., and Kisi, O. (2012). River flow estimation and forecasting by using two different adaptive neuro-fuzzy approaches. *Water resources management*, 26(6): 1715-1729
- Schölkopf, B., & Smola, A. J. (2002). Learning with kernels: Support vector machines, regularization. *Optimization, and Beyond*. MIT press, 1(2).
- Shiri, J., Kisi, O., Yoon, H., Lee, K. K., and Nazemi, A. H. (2013). Predicting groundwater level fluctuations with meteorological effect implications. A comparative study among soft computing techniques. *Computers & Geosciences*, 56: 32-44.
- Sreekanth, P. D., Geethanjali, N., Sreedevi, P. D., Ahmed, S., Kumar, N. R., and Jayanthi, P. D. (2009). Forecasting groundwater level using artificial neural networks. *Current Science*, 96(7):933-939.
- Tasar, B., Kaya, Y.Z., Varcin, H., Üneş, F., and Demirci, M. (2017). Forecasting of suspended sediment in rivers using artificial neural networks approach. *International Journal of Advanced Engineering Research and Science*, 4(12):79-84.

- Taşar, B., Üneş, F., Demirci, M., and Kaya, Y.Z. (2018). Forecasting of daily evaporation amounts using artificial neural networks. *Journal of Dicle University Engineering* 9(1): 543-551.
- Trichakis, I.C., Nikolos, I.K., and Karatzas, G.P. (2011). Artificial neural network (ANN) based modeling for Karstic groundwater level simulation. *Water Resources Management*, 25 (4): 1143–1152.
- Unes, F., Demirci, M., and Kisi, O. (2015a). Prediction of Millers Ferry dam reservoir level in USA using artificial neural network. *Periodica Polytechnica Civil Engineering*, 59 (3): 309-318.
- Unes, F., Gumuscan, F. G., and Demirci M. (2015b). Prediction of dam reservoir volume fluctuations using adaptive neuro fuzzy approach. *European Journal of Engineering and Natural Sciences*, 2 (1): 144-188.
- USGS.gov | Science for a changing world. – <https://www.usgs.gov/>.
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory*. Springer, New York.
- Vapnik, V. (1998). *Statistical Learning Theory*. Wiley, New York, USA
- Wunsch, A., Liesch, T., and Broda, S. (2018). Forecasting groundwater levels using nonlinear autoregressive networks with exogenous input (NARX). *Journal of Hydrology*, 567:743-758.
- Yilmaz, B., Aras, E., Nacar, S., and Kankal, M. (2018). Estimating suspended sediment load with multivariate adaptive regression spline, teaching-learning based optimization, and artificial bee colony models. *Science of the Total Environment*, 639: 826-840.
- Yoon, H., Jun, S. C., Hyun, Y., Bae, G. O., and Lee, K. K. (2011). A comparative study of artificial neural networks and support vector machines for predicting groundwater levels in a coastal aquifer. *Journal of Hydrology*, 396(1-2): 128-138.
- Yoon, H., Hyun, Y., Ha, K., Lee, K. K., and 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.
- Yu, H., Wen, X., Feng, Q., Deo, R. C., Si, J., and Wu, M. (2018). Comparative study of hybrid-wavelet artificial intelligence models for monthly groundwater depth forecasting in extreme arid regions, Northwest China. *Water resources management*, 32(1): 301-323.
- Zare, M., and 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.

Zhou, T., Wang, F., and Yang, Z. (2017): Comparative analysis of ANN and SVM models combined with wavelet preprocess for groundwater depth prediction. *Water*, 9(10): 781-802.



ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı :KÖRLÜ, Selçuk
 Uyuğu :T.C.
 Doğum tarihi ve yeri :31.03.1976, Osmaniye
 Medeni hali :Evli
 Telefon :0(530)1102083
 Faks :---
 e-mail :selcukinsaat2000@gmail.com



Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek Lisans	İskenderun Teknik Üniversitesi/İnşaat Mühendisliği	Devam ediyor
Lisans	Gaziantep Üniversitesi/İnşaat Mühendisliği	2004
Lise	Osmaniye Atatürk Lisesi	1993

İş Deneyimi

Yıl	Yer	Görev
2004-Halen	Osmaniye - Selçuk inş.müh.ltd.şti.	Firma sahibi

Yabancı Dil

İngilizce

Yayınlar

Demirci, M., Unes, F., & Korlu, S. (2019). Modeling of groundwater level using artificial intelligence techniques: a case study of Reyhanli region in Turkey. *Applied Ecology and Environmental Research*, 17(2): 2651-2663.

Hobiler

Seyahat, spor

DİZİN

A

Anfis ·
9,10,11,12,27,29,30,31,32,37

Ç

Çlr ·
21,23,24,25

D

Dvm · 21,23,24,25

R

Reyhanlı.9,10

Y

Yeraltı suyu · 4,5,6,7,9
Yapay sınırları · 9,10,11





TEKNOVERSITE



teknoversite **AYRICALIĞINDASINIZ**

İSTE

