



**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**DOĞAL AKARSULARDA TAŞINAN ASKI MADDESİ
KONSANTRASYONUNUN BULANIK GENETİK YAKLAŞIMI İLE
MODELLENMESİ**

**Hazırlayan
Halil İbrahim FEDAKAR**

**Danışman
Prof. Dr. Özgür KİŞİ**

Yüksek Lisans Tezi

**Haziran 2012
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
İNŞAAT MÜHENDİSLİĞİ ANABİLİM DALI**

**DOĞAL AKARSULARDA TAŞINAN ASKI MADDESİ
KONSANTRASYONUNUN BULANIK GENETİK YAKLAŞIMI İLE
MODELLENMESİ
(Yüksek Lisans Tezi)**

**Hazırlayan
Halil İbrahim FEDAKAR**

**Danışman
Prof. Dr. Özgür KIŞI**

**Haziran 2012
KAYSERİ**

Bu alıřmadaki tm bilgilerin, akademik ve etik kurallara uygun bir řekilde elde edildiđini beyan ederim. Aynı zamanda bu kural ve davranıřların gerektirdiđi gibi, bu alıřmanın znde olmayan tm materyal ve sonuları tam olarak aktardıđımı ve referans gsterdiđimi belirtirim.

Adı-Soyadı : Halil İbrahim FEDAKAR

İmza :



“Dođal Akarsularda Tařınan Askı Maddesi Konsantrasyonunun Bulanık Genetik Yaklařımı İle Modellenmesi” adlı Yüksek Lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıřtır.

Tezi Hazırlayan

Halil İbrahim FEDAKAR

Danıřman

Prof. Dr. Özgür KİŐİ

İnařaat Mühendisliđi ABD Bařkanı

Prof. Dr. Mehmet ARDIŐLİOđLU

Prof. Dr. Özgür KİŞİ danışmanlığında Halil İbrahim FEDAKAR tarafından hazırlanan “Doğal Akarsularda Taşınan Askı Maddesi Konsantrasyonunun Bulanık Genetik Yaklaşımı İle Modellenmesi” adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

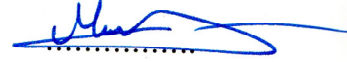
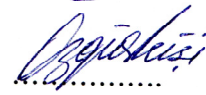
05/06/2012

JÜRİ:


Danışman : Prof. Dr. Özgür KİŞİ

Üye : Prof. Dr. Mehmet ARDIÇLIOĞLU

Üye : Doç. Dr. Mustafa MAMAK

**ONAY:**

Bu tezin kabulü Enstitü Yönetim Kurulunun 12/06/2012 tarih ve 2012/25-03 sayılı kararı ile onaylanmıştır.



Prof. Dr. Necmettin MARAŞLI

Fen Bilimleri Enstitü Müdürü

TEŞEKKÜR

“Doğal Akarsularda Taşınan Askı Maddesi Konsantrasyonunun Bulanık Genetik Yaklaşımı İle Modellenmesi” adlı tezimin önerilmesi, yönlendirilmesi ve tamamlanmasında yoğun çalışma programına rağmen vakit ayırıp yardım ve ilgisini esirgemeyen danışmanım sayın Prof. Dr. Özgür KİŞİ’ye teşekkür ederim.

Lisans ve yüksek lisans öğrenimim boyunca bana emeği geçen Çukurova Üniversitesi İnşaat Mühendisliği Bölümü ve Erciyes Üniversitesi İnşaat Mühendisliği Bölümü hocalarıma ve yüksek lisans eğitimim boyunca benden maddi manevi desteğini esirgemeyen Bartın Üniversitesi İnşaat Mühendisliği Bölümü öğretim üyesi sayın Doç. Dr. Fikret KOCABAŞ’a teşekkür ederim.

Eğitim hayatım boyunca yanımda olan ve bugünlere gelmemde büyük katkısı olan aileme ve yüksek lisans eğitimim boyunca desteğini esirgemeyen ve bana her zaman sabırla yaklaşan sevgili eşime teşekkür ederim.

Halil İbrahim FEDAKAR

Kayseri, Haziran 2012

**DOĞAL AKARSULARDA TAŞINAN ASKI MADDESİ
KONSANTRASYONUNUN BULANIK GENETİK YAKLAŞIMI İLE
MODELLENMESİ**

Halil İbrahim FEDAKAR

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü

İnşaat Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi, Haziran 2012

Danışman: Prof. Dr. Özgür KİŞİ

KISA ÖZET

Doğal akarsularda taşınan askı maddesi konsantrasyonunun doğru tahmini; akarsu taşımacılığı, kirliliğin önlenmesi, baraj ömrünün tespiti, hidroelektrik teçhizatların emniyeti, balıkların yaşamını sürdürmesi vb. konularda çok önemlidir. Bu amaçla kullanılan katı madde anahtar eğrileri (AE), çoğu tahminlerde iyi sonuçlar vermemelerine rağmen yaygın bir kullanım alanına sahiptirler. Bu çalışmada, akarsu en kesitindeki askı maddesi konsantrasyonunu tahmin etmek için yeni bir yaklaşım olarak bulanık genetik (BG) yaklaşımı önerilmiştir. BG yaklaşımının amacı ise, bulanık giriş üyelik fonksiyonlarına ait parametrelerin genetik algoritma kullanılarak belirlenmesidir. USGS (United States Geological Survey) tarafından işletilen 06088300 ve 06088500 nolu istasyonlara ait günlük debi ve askı maddesi konsantrasyonu verileri kullanılmıştır. Gözlenen 4 yıllık verilerin ilk 2 yılı eğitime, 1 yılı test ve kalan 1 yılı değerlendirme olarak üç bölüme ayrılmıştır. BG modellerin tahmin sonuçları, karekök ortalama karesel hata ve determinasyon katsayısı istatistikleri kullanılarak adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS), çok katmanlı yapay sinir ağı (ÇKYSA) ve AE modelleri ile karşılaştırılmıştır. Sonuç olarak BG yaklaşımının, askı maddesi konsantrasyonunu modellemede ANFIS, ÇKYSA ve AE yöntemlerine göre daha iyi sonuçlar vermiştir.

Anahtar Kelimeler: Askı maddesi konsantrasyonu; bulanık genetik yaklaşımı; adaptif ağ tabanlı çıkarım sistemi; çok katmanlı yapay sinir ağı; katı madde anahtar eğrisi.

MODELING OF SUSPENDED SEDIMENT CONCENTRATION CARRIED IN NATURAL STREAMS USING FUZZY GENETIC APPROACH

Halil İbrahim FEDAKAR

Erciyes University, Graduate School of Natural and Applied Sciences

Department of Civil Engineering

M. Sc. Thesis, June 2012

Thesis Supervisor: Prof. Dr. Özgür KIŞI

ABSTRACT

Correct estimation of suspended sediment concentration (SSC) carried in natural streams is very important with respect to channel navigability, pollution, reservoir filling, hydroelectric equipment longevity, fish habitat and scientific interests. Although conventional sediment rating curves (SRCs) are not able to give sufficiently accurate results, they have a wide range of usage. In this study, as a new approach, fuzzy genetic (FG) approach is proposed in order to predict SSC for a given stream cross section. The aim of FG approach is to determine the parameters of fuzzy input membership functions by genetic algorithm. The daily discharge and SSC data from two stations (Station No: 06088300 and 06088500) operated by the USGS (United States Geological Survey) were used as case studies. The observed 4 years long data were divided into three parts and the first 2 years data were used for training, 1 year data for testing and the remaining 1 year data were used for validation. The estimation outcomes of FG models are compared to adaptive network based fuzzy inference system (ANFIS), multi-layer perceptron (MLP) and SRC models by using root mean square errors and determination coefficient statistics. The comparison results revealed that the FG approach outperforms the ANFIS, MLP and SRC in modeling of SSC.

Keywords: Suspended sediment concentration; fuzzy genetic approach; adaptive network based fuzzy inference system; multi-layer perceptron; sediment rating curve.

İÇİNDEKİLER

DOĞAL AKARSULARDA TAŞINAN ASKI MADDESİ KONSANTRASYONUNUN BULANIK GENETİK YAKLAŞIMI İLE MODELLENMESİ

	<u>Sayfa</u>
BİLİMSEL ETİĞE UYGUNLUK SAYFASI	ii
YÖNERGEYE UYGUNLUK SAYFASI	iii
KABUL VE ONAY SAYFASI	iv
TEŞEKKÜR.....	v
KISA ÖZET	vi
ABSTRACT	vii
İÇİNDEKİLER	viii
KISALTMALAR VE SİMGELER LİSTESİ	xi
TABLOLAR LİSTESİ.....	xv
ŞEKİLLER LİSTESİ	xvii
GİRİŞ	1

1. BÖLÜM

GENEL BİLGİLER

1.1. Literatür Taraması	4
-------------------------------	---

2. BÖLÜM

YÖNTEM

2.1. Yapay Zeka Yöntemleri.....	7
2.1.1. Bulanık Mantık.....	7
2.1.1.1. Bulanık Kümeler ve Üyelik Fonksiyonları.....	8

2.1.1.2. Bulanık İşlemler	12
2.1.1.2.1. Kesikli Bulanık Kümelerde İşlemler	12
2.1.1.2.2. Sürekli Bulanık Kümelerde İşlemler	14
2.1.1.2.2.1. Toplama ve Çıkarma	14
2.1.1.2.2.2. Çarpma ve Bölme	15
2.1.1.3. Bulanık Modelleme Aşamaları	16
2.1.1.3.1. Bulanıklaştırma Aşaması	16
2.1.1.3.2. Bulanık Kural Tabanı Aşaması	17
2.1.1.3.3. Bulanık Çıkarım Aşaması	18
2.1.1.3.3.1. Takagi-Sugeno-Kang (TSK) Çıkarım Yöntemi	19
2.1.1.3.4. Durulaştırma Aşaması	21
2.1.1.4. Bulanık Mantığın Avantajları ve Dezavantajları	21
2.1.2. Genetik Algoritma	22
2.1.2.1. Genetik Algoritmada Kullanılan Operatörler	23
2.1.2.1.1. Seçim Operatörü	24
2.1.2.1.2. Çaprazlama Operatörü	25
2.1.2.1.3. Mutasyon Operatörü	26
2.1.2.2. Genetik Algoritmanın Avantajları ve Dezavantajları	27
2.1.3. Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi	28
2.1.4. Yapay Sinir Ağları	31
2.1.4.1. Biyolojik Sinir Hücresinin Yapısı	32
2.1.4.2. Yapay Sinir Ağlarının Yapısı	33
2.1.4.3. Yapay Sinir Ağları Çeşitleri	34
2.1.4.3.1. Yapılarına Göre Ağ Çeşitleri	35
2.1.4.3.1.1. İleri Beslemeli Ağlar	35
2.1.4.3.1.2. Geri Beslemeli Ağlar	36
2.1.4.3.2. Öğrenme Algoritmalarına Göre Ağ Çeşitleri	36
2.1.4.3.2.1. Öğretmenli Öğrenme	37
2.1.4.3.2.2. Öğretmensiz Öğrenme	37
2.1.4.3.2.3. Takviyeli Öğrenme	37
2.1.4.4. Çok Katmanlı Yapay Sinir Ağları	38
2.1.4.5. YSA'nın Avantajları ve Dezavantajları	40
2.2. Anahtar Eğrisi	41

3. BÖLÜM**BULGULAR**

BULGULAR	42
-----------------------	-----------

4. BÖLÜM**SONUÇ-TARTIŞMA VE ÖNERİLER**

SONUÇ-TARTIŞMA VE ÖNERİLER.....	64
--	-----------

KAYNAKLAR	66
------------------------	-----------

ÖZGEÇMİŞ

KISALTMALAR VE SİMGELER LİSTESİ

<u>Simgeler</u>	<u>Açıklama</u>
A	Giriş bulanık küme
a	Akım karakteristiğine bağlı katsayı
ABD	Amerika Birleşik Devletleri
AE	Anahtar eğrisi
A.M.K.	Askı maddesi konsantrasyonu
ANFIS	Adaptif ağ tabanlı bulanık çıkarım sistemi
A.T.H.S.	Ara tabaka hücre sayısı
B	Giriş bulanık küme
b	Gözlem değeri, Akım karakteristiğine bağlı katsayı, İçsel katkı sabiti
BD	Bulanık diferansiyel
BG	Bulanık genetik
BM	Bulanık mantık
C	Çıkış bulanık küme
C_{sx}	Çarpıklık katsayısı
C_v	Değişim katsayısı
\hat{c}	Tahmin değeri
ÇKYSA	Çok katmanlı yapay sinir ağı
ÇLR	Çoklu lineer regresyon
$e(w)$	Ağ hatası
EĞER	Mantıksal ifade
FG	Fuzzy genetic
$f(Net)$	Aktivasyon fonksiyonu
$f(.)$	Uygunluk fonksiyonu
GA	Genetik algoritma

Gaussmf	Gaussian curve built-in membership function
Gauss2mf	Gaussian combination membership function
Gellmf	Generalized bell-shaped built-in membership function
GRYSA	Genelleştirilmiş regresyon yapay sinir ağları
güf	Giriş üyelik fonksiyonu
H	Bağıl hata
$H(w)$	Hessian matrisi
I	Birim matris
İSE	Mantıksal ifade
J	Jakobien matrisi
KOKH	Karekök ortalama karesel hata
LM	Levenberg-Marquardt algoritması
MLP	Multi-layer perceptron
N	Toplam veri sayısı
n	Düğüm sayısı, Kromozom sayısı, Sinir hücresi sayısı
p	Fonksiyon parametresi, Sonuç parametre kümesi
Pimf	π -shaped built-in membership function
Q	Akarsu akım debisi
q	Sonuç parametre kümesi
Q_t	t anındaki akarsu akım debisi
r	Sonuç parametre kümesi
RTYSA	Radyal tabanlı yapay sinir ağları
R^2	Belirginlik katsayısı, Determinasyon katsayısı
S	Taşınan katı madde konsantrasyonu
SRC	Sediment rating curve
SSC	Suspended sediment concentration

S_t	t anındaki taşınan askı maddesi konsantrasyonu
S_x	Standart sapma
Trimf	Triangular-shaped built-in membership function
TSK	Takagi-Sugeno-Kang
USGS	United States Geological Survey
Ü	Üyelik derecesi
VE	Mantıksal bağlantı işlemcisi
VEYA	Mantıksal bağlantı işlemcisi
w	Eşik değer, Yapay sinir hücresi ağırlık değeri
x	Girdi değişkeni
X_i	Giriş veya çıkış verisi
X_{MAK}	Maksimum giriş veya çıkış verisi
X_{maks}	Maksimum değer
X_{MIN}	Minimum giriş veya çıkış verisi
X_{min}	Minimum değer
X_N	Normalize edilmiş giriş veya çıkış verisi
X_{ort}	Ortalama değer
Y	Askı maddesi konsantrasyonu
y	Sistem çıkış değeri
YSA	Yapay sinir ağları
y_i	i. katman çıkış değeri
z	Çıktı değişkeni
α^-	α alt sınırı
α^+	α üst sınırı
γ	Momentum katsayısı
μ	Üyelik derecesi, Marquardt parametresi

$\bar{\mu}$	Normalleştirilmiş ateşleme seviyesi
$\Sigma(\text{Net})$	Toplam fonksiyonu
$\nabla E(w)$	Ağ gradyeni

TABLULAR LİSTESİ

Tablo 3.1.	Muddy Çayı istasyon bilgileri	42
Tablo 3.2.	06088300 nolu istasyonun istatistik parametreleri	44
Tablo 3.3.	06088500 nolu istasyonun istatistik parametreleri	44
Tablo 3.4.	Farklı giriş senaryoları için en iyi BG modeller, 06088300	47
Tablo 3.5.	Farklı giriş senaryoları için en iyi BG modeller, 06088500	47
Tablo 3.6.	Farklı giriş senaryoları için en iyi ANFIS modeller, 06088300	51
Tablo 3.7.	Farklı giriş senaryoları için en iyi ANFIS modeller, 06088500	51
Tablo 3.8.	Farklı giriş senaryoları için en iyi ÇKYSA modeller, 06088300	54
Tablo 3.9.	Farklı giriş senaryoları için en iyi ÇKYSA modeller, 06088500	55
Tablo 3.10.	06088300 nolu istasyona ait en iyi modeller ve hata değerleri	56
Tablo 3.11.	06088500 nolu istasyona ait en iyi modeller ve hata değerleri	56

ŞEKİLLER LİSTESİ

Şekil 2.1.	Sıcaklık için keskin küme örneği	8
Şekil 2.2.	Sıcaklık için bulanık küme örneği	9
Şekil 2.3.	Bulanık kümelerde örtüşüm	9
Şekil 2.4.	Üyelik fonksiyonlarının bazı ortak özellikleri	10
Şekil 2.5.	Kesikli ve sürekli bulanık kümeler	12
Şekil 2.6.	Toplama işleminin gerçekleştirilmesi için oluşturulan kartezyen toplam .	13
Şekil 2.7.	α kesimleri aralığı	14
Şekil 2.8.	Sürekli bulanık kümelerde toplama	15
Şekil 2.9.	Bulanık sistem yapısı	16
Şekil 2.10.	Çıkarım aşaması sonuç değerinin elde edilmesi	19
Şekil 2.11.	TSK çıkarım yönteminin gösterimi	20
Şekil 2.12.	Genetik algoritmaların genel çalışma şeması	24
Şekil 2.13.	Çaprazlama yöntemleri ve etkileri	26
Şekil 2.14.	Mutasyon yöntemleri ve etkileri	27
Şekil 2.15.	Adaptif ağ tabanlı bulanık mantık çıkarım sistemi	29
Şekil 2.16.	Biyolojik sinir hücresinin yapısı	32
Şekil 2.17.	Yapay sinir hücresi	33
Şekil 2.18.	İleri beslemeli yapay sinir ağı	35
Şekil 2.19.	Geri beslemeli yapay sinir ağı	36
Şekil 2.20.	Çok katmanlı ağ yapısı	38
Şekil 3.1.	Muddy Çayı üzerindeki istasyonların konumu	43
Şekil 3.2.	06088300 nolu istasyon için en iyi BG modele ait giriş üyelik fonksiyonlarının eğitilmeden önceki gösterimi	48
Şekil 3.3.	06088500 nolu istasyon için en iyi BG modele ait giriş üyelik fonksiyonlarının eğitilmeden önceki gösterimi	48
Şekil 3.4.	06088300 nolu istasyon için en iyi BG modele ait giriş üyelik fonksiyonlarının eğitildikten sonraki gösterimi	49
Şekil 3.5.	06088500 nolu istasyon için en iyi BG modele ait giriş üyelik fonksiyonlarının eğitildikten sonraki gösterimi	49

Şekil 3.6.	06088300 nolu istasyon için en iyi ANFIS modeline ait giriş üyelik fonksiyonlarının eğitilmeden önceki gösterimi	52
Şekil 3.7.	06088500 nolu istasyon için en iyi ANFIS modeline ait giriş üyelik fonksiyonlarının eğitilmeden önceki gösterimi	52
Şekil 3.8.	06088300 nolu istasyon için en iyi ANFIS modeline ait giriş üyelik fonksiyonlarının eğitildikten sonraki gösterimi	53
Şekil 3.9.	06088500 nolu istasyon için en iyi ANFIS modeline ait giriş üyelik fonksiyonlarının eğitildikten sonraki gösterimi	53
Şekil 3.10.	06088300 nolu istasyona ait test aşaması gidiş grafikleri	58
Şekil 3.11.	06088300 nolu istasyona ait değerlendirme aşaması gidiş grafikleri	59
Şekil 3.12.	06088500 nolu istasyona ait test aşaması gidiş grafikleri	60
Şekil 3.13.	06088500 nolu istasyona ait değerlendirme aşaması gidiş grafikleri	61
Şekil 3.14.	06088300 nolu istasyona ait logaritmik saçılma grafikleri	62
Şekil 3.15.	06088500 nolu istasyona ait logaritmik saçılma grafikleri	63

GİRİŞ

Çağımızın yenilenebilir enerji kaynaklarından en önemlisi olan hidrolik potansiyelden yararlanma oranı, ülkelerin sanayileşmesinin bir göstergesi haline gelmiştir. Nitekim günümüzde, gelişmiş ülkeler sahip oldukları hidrolik potansiyelin tamamına yakınından yararlanmalarına karşı, dünya hidrolik potansiyelinin yaklaşık %80'lik bölümüne sahip gelişme yolundaki ülkelerde, bu potansiyelden yararlanma oranı yaklaşık %25-30 civarındadır. Bu sebeple, hidrolik potansiyelden yararlanma çalışmalarının gelecekte gelişmekte olan ülkelerde yoğunluk kazanacağı kendiliğinden ortaya çıkmaktadır. Gelişmekte olan ülkeler arasında yer alan ülkemizde de, hidrolik potansiyelden yararlanma oranı bu durumdan farklı değildir [1]. 2010 yılı DSİ Faaliyet Raporu verilerine göre, Türkiye'de 267 adet hidroelektrik santral bulunmaktadır ve Türkiye teknik hidroelektrik potansiyelinin %25'ini geliştirmiştir [2]. Dolayısıyla sosyo-ekonomik gelişmelere paralel bir şekilde artacak olan enerji talebi doğrultusunda hidrolik potansiyelden yararlanma çalışmaları ülkemizde de yoğunluk kazanacaktır. Bilindiği gibi, akarsularımız üzerinde bir yandan halkımızın içme ve kullanma, tarım ve endüstrinin su ihtiyaçlarını karşılamak, diğer yünden enerji üretimi ve taşkın kontrolü gibi çok çeşitli amaçlarla barajlar yapılmaktadır. Hangi amaca yönelik olursa olsun, sedimentasyon bilgisinin azlığından dolayı bu yapıların göllerini besleyen akarsuların getirdiği kum, silt, kil ve çakıl gibi katı maddeler baraj göllerini doldurmakta, depolama kapasitelerini azaltmakta ve bunun sonucu olarak barajların ekonomik ömürleri kısalmaktadır. Bu konu, Türkiye gibi yarı kurak bir iklimin egemen olduğu ve bununla birlikte karmaşık bir topografik yapıya sahip olan ülkemizde son derece önem kazanmaktadır. [1].

Akarsularda taşınan katı maddeler taşınma şekillerine göre, askı maddesi ve sürüntü maddesi olarak ikiye ayrılır. Askı maddesi suyun içerisinde askı halinde yani taban ile temas olmadan hareket ederken sürüntü maddesi tabanla temas halinde olan,

yuvarlanarak, kayarak veya sıçrayarak hareket etmektedir. Askı maddesini sürüntü maddesinden ayıran kesin ve genel bir sınır bulunmamaktadır. Çünkü katı maddenin hareketi dane çapının yanı sıra akımın şartlarına da bağlıdır [3].

Akarsu yapılarının planlanması ve projelendirilmesinde nehirlerde taşınan katı madde miktarının doğru bir şekilde tahmin edilmesi su kaynakları mühendisliğinde hayati önem taşımaktadır. Özellikle baraj hazneleri gibi su depolama tesislerinde biriken katı maddeler hazne kapasitesini azaltır ve zamanla su alma yapısının (ağzının) tıkanmasına sebep olur. Hazne kapasitesinin azalması tesislerin ekonomik ömrünü kısaltır. Su alma yapısının tıkanması ise haznenin fonksiyon göremez duruma gelmesi demektir. Bu zararları önlemek daha doğrusu geciktirmek için baraj haznesinde ölü hacim denilen pasif bir hacim bırakılır ve su alma yapısı bu hacim üstünde kalacak şekilde tasarlanır. Bir barajın hizmet süresi yani faydalı ömrü bu hacmin büyüklüğüne bağlıdır. Ölü hacmin gerekli olandan daha küçük ya da daha büyük olarak tayin edilmesi barajın ekonomisini oldukça önemli şekilde etkiler. Ayrıca, hazneye gelen katı maddeler sadece ölü hacimde değil, haznenin başka kısımlarında da birikeceği için barajın aktif depolama kapasitesinin gittikçe azalmasına ve belirli bir süreden sonra veriminin, beklenen seviyenin çok altına düşmesine sebep olur. Bu sebeplerden ötürü, barajların ekonomik ömrünü dikkate alarak yapılan projelendirilmelerde, katı madde tür ve miktarının doğru olarak tahmin edilmesi son derece önemlidir [3].

Bilgisayar teknolojisi son yıllarda hızlı bir şekilde gelişmektedir. Bu gelişim de sayısal hesaplamalar ve modelleme teknikleri üzerinde de etkili olmuştur. Bulanık Mantık (BM), Genetik Algoritma (GA) ve Yapay Sinir Ağları (YSA) uygulamaları ile birçok olayın giriş ve çıkış mekanizmaları öğrenilerek benzer olaylar için oldukça iyi modeller elde edilebilmektedir.

Bu çalışmada, Amerika Birleşik Devletleri'nin Montana eyaletinde Muddy Çayı üzerinde bulunan ve Amerika Birleşik Devletleri Jeolojik Araştırmalar Kurumu (USGS) tarafından işletilen, 06088300 ve 06088500 nolu istasyonlara ait askı maddesi konsantrasyonunu belirlemek amacıyla askı maddesi tahmini için yeni bir yöntem olan Bulanık-Genetik (BG) yaklaşımı kullanılmıştır. BG yaklaşımından elde edilen kıyaslama kriterlerine ait değerler, Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi

(ANFIS), Çok Katmanlı Yapay Sinir Ađı (ÇKYSA) ve Anahtar Eğrisi (AE) yöntemlerine ait kıyaslama kriteri değerleri ile karşılaştırılmıştır. BG yaklaşımının diğer yöntemlere göre askı maddesi konsantrasyonu tahmininde daha iyi sonuçlar verdiği gözlenmiştir.

1. BÖLÜM

GENEL BİLGİLER

1.1. Literatür Taraması

Genellikle katı madde miktarı ya sediment istasyonlarından yapılan doğrudan ölçümlerle ya da literatürde olan katı madde taşınım denklemlerinden belirlenmektedir. Katı madde miktarının doğrudan akarsudan ölçümle belirlenmesi en güvenilir yol olmasına rağmen zaman alan ve maliyetli bir yöntemdir. Birçok gözlem istasyonunda su debisi ölçülmesine karşın katı madde miktarı ölçümü yapılmamaktadır. Ayrıca taşkınlar sırasında da sediment gözlem istasyonlarında katı madde ölçümü yapılamamaktadır [4-5].

Genel olarak nehirlerde taşınan katı madde miktarı akım debisiyle ilişkilidir. Araştırmacılar bu ilişkiyi kullanarak regresyon analizi yapmaktadırlar. Ancak bu klasik regresyon analizi, problemin doğasından kaynaklanan doğrusal olmayan karmaşık ilişkilerden ötürü iyi sonuçlar vermemektedir [6-7].

Doğal olaylar birden fazla rastgele değişkenden etkilendiği için doğal olaylar ile değişkenler arasındaki doğrusal olmayan ilişkileri izah etmek pek mümkün olamamaktadır. Bundan dolayı araştırmacılar, doğrusal olmayan problemleri çözmek için bulanık mantık (BM), genetik algoritma (GA), adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS), çok katmanlı yapay sinir ağı (ÇKYSA) ve anahtar eğrisi (AE) gibi yöntemleri kullanmıştır.

Jain [8] ÇKYSA'na dayalı olarak akış-katı madde modelleri geliştirmiştir. Bu modellerden elde ettiği sonuçları AE yöntemine ait sonuçlar ile kıyaslamış ve ÇKYSA

modellerinin daha iyi tahminler verdiđi sonucuna varmıřtır.

Kiři vd. [9] T1rkiye ve Amerika Birleřik Devletleri'ne ait nehirlerde tařınan katı madde miktarını belirlemek iin bulanık diferansiyel (BD) modelleri geliřtirmiřtir. Model tahmin sonularını AE y1ntemine ait sonular ile karřılařtırmıřtır. AE y1nteminin toplamda ok k1t1 tahminler yaptığı ve BD modellerinin daha iyi tahminler yaptığı sonucuna varmıřtır.

Kiři [10] akıř-katı madde arasındaki iliřkiyi belirlemek iin BM y1ntemine ait modeller geliřtirmiř ve elde edilen model sonularını AE y1ntemine ait iki farklı modelle karřılařtırmıřtır. Sonu olarak, BM y1ntemine ait modellerin diđer modellerden daha iyi tahminler yaptığı sonucuna varmıřtır.

Kiři [11] akıř-katı madde konsantrasyonu arasındaki iliřkiyi belirlemek iin KYSA, genelleřtirilmiř regresyon yapay sinir ađları (GRYSA), radyal tabanlı yapay sinir ađları (RTYSA) ve oklu lineer regresyon (LR) modelleri geliřtirmiřtir. Modellerden elde edilen sonuları birbirleriyle karřılařtırmıř ve KYSA modelinin diđer modellere g1re daha iyi tahminler yaptığı sonucuna varmıřtır.

Kiři [12] bulanık mantık (BM) ve yapay sinir ađları (YSA) y1ntemlerinin birleřtirilmesiyle oluřan ANFIS yaklařımını akıř-katı madde arasındaki iliřkiyi belirlemek iin kullanmıřtır. Geliřtirilen bu melez modelleri YSA ve LR y1ntemlerine ait modellerle karřılařtırmıř ve ANFIS yaklařımı modellerinin diđer y1ntemlere ait modellere g1re daha iyi tahminler verdiđi sonucuna varmıřtır.

Kiři *et al.* [13] akıř-katı madde arasındaki iliřkiyi belirlemek iin BM modelleri geliřtirmiř ve elde edilen sonuları AE y1ntemi ile karřılařtırmıřlardır. Sonu olarak, BM y1ntemine ait modellerin AE y1ntemine ait modellerden daha iyi tahminler yaptığı sonucuna varmıřlardır.

obaner *et al.* [14] akıř-katı madde arasındaki iliřkiyi belirlemek iin ANFIS, YSA y1ntemleri ve iki farklı AE modeli kullanmıřlardır. Elde edilen sonuları birbirleri ile

kıyaslamışlardır. Sonuç olarak ANFIS yaklaşımına ait modelin diğer yöntemlere ait modellere göre daha iyi tahminler verdiği sonucuna varmışlardır.

Rajae *et al.* [15] debi-katı madde konsantrasyonu arasındaki ilişkiyi belirlemek için ANFIS, YSA, ÇLR ve AE yöntemlerini kullanmışlardır. ANFIS ve YSA yöntemlerine ait modellerin diğer modellere göre daha iyi sonuçlar verdiğini ancak, ANFIS modelinin de YSA'ya göre daha iyi sonuçlar verdiğini belirlemişlerdir.

Altunkaynak [16] debi-askı maddesi arasındaki ilişkiyi modellemek için genetik algoritma (GA) ve regresyon yöntemlerini kullanmış ve elde edilen model sonuçlarını birbirleri ile karşılaştırmıştır. Sonuç olarak genetik algoritmanın regresyon yöntemine göre daha iyi sonuç verdiğini göstermiştir.

Kişi ve Fedakar [17] akış-askı maddesi arasındaki ilişkiyi modellemek için, bu konu üzerine yeni bir yöntem olan bulanık-genetik (BG) yaklaşımı, ANFIS ve AE yöntemlerini kullanmışlardır. Elde edilen sonuçlar birbirleri ile kıyaslanmıştır. Sonuç olarak ANFIS yönteminin AE yönteminden daha iyi olduğunu ve BG yönteminin de diğer yöntemlere göre en iyi tahminleri yaptığını görmüşlerdir. Ayrıca BG yönteminin başarılı bir şekilde akış-askı maddesi arasındaki ilişkiyi modellemek için kullanılabileceği sonucuna varmışlardır.

2. BÖLÜM

YÖNTEM

2.1. Yapay Zeka Yöntemleri

Yapay zeka, genellikle insana özgü nitelikler olduğu varsayılan algılama, öğrenme, fikir yürütme, anlam çıkartma, karar verme, genelleme yapma ve geçmiş deneyimlerden yararlanarak öğrenme gibi zihinsel süreçlere ilişkin görevleri bir bilgisayarın yerine getirme yeteneği olarak tanımlanmaktadır [18].

2.1.1. Bulanık Mantık

Bulanık mantık kavramı ilk kez 1965 yılında Azeri bilim adamı Prof. Lotfi A. Zadeh tarafından, belirsizlik içeren ifadelerin matematiksel olarak ifade edilmesi yoluyla ortaya atılmıştır. Bulanık mantık teoremi, klasik mantıkta olduğu gibi problemi kesin sınırlarla ayırmak yerine sınıflandırma veya kümeleme yaparak değerlendirir. Bulanık kavramlar, doğada meydana gelen belirsizlik içeren olaylardan dolayı ortaya çıkmaktadır ve insanlar doğadaki bu olayları tanımlamak, ifade etmek, sınıflandırmak ve değerlendirmek için bulanık kavramları kullanmaktadır. İşleyiş olarak bulanık mantık teorisi insanın çıkarım yapma ve karar vermesine benzemektedir. Bir problemdeki uygun bilgiyi kullanarak karar verme işlevini yerine getirmektedir. Problemin doğal olarak ifade edilebilmesinden dolayı bulanık mantık yaklaşımı birçok mühendislik ve karar verme problemlerinde kolaylıklar sağlamaktadır [19].

Bulanık mantık denetleyicisinin temeli sözel ifadeler ve bu sözel ifadeler arasındaki mantıksal ilişkiler üzerine kurulmuştur. Bulanık mantık denetleyicisi uygulanırken sistemin matematiksel modellenmesi şartı aranmaz. Sözel ifadelerin bilgisayara


aktarılması işlemi matematiksel bir temele dayanmaktadır ve bu matematiksel temel, bulanık kümeler kuramı ve bulanık mantık olarak adlandırılmaktadır. Bulanık mantık bilinen klasik mantık gibi $(0, 1)$ olmak üzere iki seviyeli değil, $[0,1]$ aralığında çok seviyeli işlemleri ifade etmektedir [20].

2.1.1.1. Bulanık Kümeler ve Üyelik Fonksiyonları

Bir nesnenin, evrensel kümenin alt kümesi olan bir A kümesine ait olma derecesi $[0, 1]$ aralığında bir üyelik derecesiyle veriliyorsa, o nesneyle birlikte nesnenin bu kümedeki üyelik derecesinin oluşturduğu kümeye bulanık küme denir [21].


Denetim sisteminin giriş bilgilerini sözel niteleyiciler olan bulanık kümelere, üyelik dereceleriyle birlikte dönüştürmek için kullanılan bulanıklaştırma fonksiyonlarına üyelik fonksiyonu denir. Bir x değişkeninin bulanık bir kümeye ait olma derecesi bu fonksiyonlarla belirlenmektedir [22].

Klasik küme kavramında, bir elemanın bir kümeye ait olması durumunda üyelik derecesi 1, ait olmaması durumunda üyelik derecesi 0 olarak kabul edilmektedir ve 0 ile 1 arasında üyelik derecesi bulunmamaktadır [23]. Klasik kümelere ait örnek Şekil 2.1'de verilmektedir.




Şekil 2.1. Sıcaklık için keskin küme örneği.

Şekilden görüldüğü gibi, sıcaklık 20°C ' nin altında olursa sıcak değildir. Yani klasik mantık teoreminde 19.9°C sıcak olarak ifade edilmemektedir. Klasik mantıkta esneklik söz konusu değildir ve gerçek dünyada ise bu kadar keskin sınırlar yoktur [20]. Bulanık mantığın ana fikri, tamamıyla tek bir kümeye ait olma yerine, herhangi bir evrensel küme elemanlarının farklı alt kümelerine ait olmalarına kısmen müsaade edilmesidir [23]. Bundan dolayı bulanık küme kavramında, bir elemanın bir kümeye ait olma derecesi 0 ve 1 de dahil olmak üzere 0 ile 1 arasındaki tüm değerler olabilmektedir. Bulanık kümelerine ait örnek Şekil 2.2'de ve bulanık kümelerde örtüşüm Şekil 2.3'de verilmektedir.



Şekil 2.2. Sıcaklık için bulanık küme örneği.

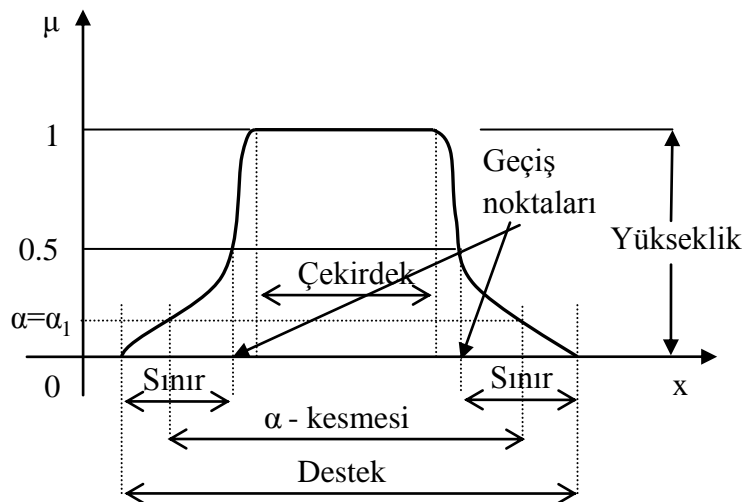


Şekil 2.3. Bulanık kümelerde örtüşüm.

Burada 10-40 °C arasındaki sıcaklık değerleri sıcak kümesine üyedirler. 20-40 °C arasındaki sıcaklık değerlerinin üyelik dereceleri 1'dir ve 10-20 °C arasındaki sıcaklık değerlerinin üyelik dereceleri ise 0 ile 1 arasında değişecektir. Yani bulanık mantık teoreminde 11 °C az sıcak ve 16 °C biraz sıcak olarak değerlendirilecektir. 20 °C'yi oda sıcaklığı olarak kabul ettiğimiz zaman, Soğuk bulanık kümesi oluşturulduğunda Şekil 2.3 elde edilmektedir [20].

Bulanık mantıkta, sözel ifadelerle anılan bölgelerin sınırlarını belirtmek ve giriş bilgilerine ait üyelik ağırlıklarını belirlemek için uygun üyelik fonksiyonlarının belirlenmesi gerekmektedir [24]. Bundan dolayı üyelik fonksiyonlarının tespiti çok önemli bir basamaktır ve sistemin hassasiyetini belirlemektedir. Üyelik fonksiyonlarını oluşturmak için belirli bir kural bulunmamaktadır. Üyelik fonksiyonlarını oluşturmak için öncelikle sözel olarak ifade edilecek olan bölgelerin sayıları tespit edilir. Çünkü bu, sistemin en kaba haliyle hassasiyetini belirlemektedir. Örneğin bir koşul kümesindeki niteleyiciler (küçük, orta ve büyük gibi) bazı alanlarda yeterli olamayabilirler. Bu durumda (çok küçük, küçük, orta, büyük, çok büyük) daha fazla koşul ünitesi gerekebilmektedir [25].

Üyelik fonksiyonlarının bazı ortak özellikleri vardır ve bu özellikler Şekil 2.4'te gösterilmiştir [22].



Şekil 2.4. Üyelik fonksiyonlarının bazı ortak özellikleri.

Çekirdek: X genel uzay kümesinin A gibi bir üyelik fonksiyonunda 1 üyelik derecesine sahip olan kesin sayı bölgesidir. Matematiksel ifadesi denklem (2.1) ile verilmiştir [26].

$$\text{Çekirdek}(A)=\{x, \text{ öyle ki } \mu_A(x)=1\} \quad (2.1)$$

Geçiş noktaları: Bir A kümesinin geçiş noktaları, o kümede üyelik derecesi 0.5 olan kesin sayılardır. Matematiksel ifadesi denklem (2.2)'de verilmiştir [26].

$$\text{Geçiş noktası}(A)=\{x, \text{ öyle ki } \mu_A(x)=0.5\} \quad (2.2)$$

Sınır: A bulanık kümesinde üyelik değerleri 0 ile 1 arasında kalan ancak 0 ya da 1 olamayan kesin sayılar kümesidir. Matematiksel ifadesi denklem (2.3)'te verilmiştir [26].

$$\text{Sınır}(A)=\{x, \text{ öyle ki } 0<\mu_A(x)<1\} \quad (2.3)$$

Destek: Bir A kümesinin desteği, o kümedeki üyelik derecesi 0'dan büyük olan x kesin sayılar kümesidir. Matematiksel ifadesi denklem (2.4)'de verilmiştir [26].

$$\text{Destek}(A)=\{x, \text{ öyle ki } \mu_A(x)>0\} \quad (2.4)$$


α - kesmesi: A kümesinde üyelik derecesi α 'ya eşit ya da daha büyük olan kesin sayılar kümesidir. Matematiksel ifadesi denklem (2.5)'de verilmiştir [26].

$$\alpha - \text{kesmesi}(A)=A_\alpha=\{x, \text{ öyle ki } \mu_A(x) \geq \alpha\} \quad (2.5)$$

Yükseklik: Bir kümenin en büyük üyelik derecesi o kümenin yüksekliğidir. Normal küme yüksekliği 1'dir. Yüksekliği 1'den fazla olan kümeler uygun katsayılarla normalize edilir [27].

2.1.1.2. Bulanık İşlemler

Kümeler, kesikli ve sürekli olmak üzere ikiye ayrılmaktadır. Kesikli bir kümede sonlu sayıda eleman sayısı mevcut iken, sürekli bir küme ise sonsuz sayıda eleman bulunmaktadır. Gerek kesikli, gerekse sürekli kümelerde bulunan elemanların o kümeye olan üyelik derecelerinin $[0,1]$ aralığında belirlenmesi ile her iki kümenin de bulanık kesikli ve bulanık sürekli kümeler haline getirilmesi mümkün olabilmektedir. Bulanık kesikli ve bulanık sürekli kümelerle ait örnek gösterimler Şekil 2.5'te verilmiştir.



Şekil 2.5. Kesikli ve sürekli bulanık kümeler.

2.1.1.2.1. Kesikli Bulanık Kümelerde İşlemler

Kesikli bulanık kümelerde matematiksel işlemleri açıklamak için aşağıda iki bulanık küme örnek olarak verilmektedir. Toplama işlemi detaylı anlatıldıktan sonra diğer işlemlerin nasıl yapılacağı açıklanmıştır.

$$A = \left\{ \frac{0,1}{2}, \frac{0,7}{5}, \frac{0,3}{4}, \frac{1,0}{8}, \frac{0,6}{10} \right\}$$

$$B = \left\{ \frac{0,3}{2}, \frac{1,0}{4}, \frac{0,8}{6} \right\}$$

A ve B bulanık kümelerinde toplama işleminin basitçe yapılıp algoritmanın anlaşılabilmesi için A ve B kümeleri aşağıdaki şekilde olduğu gibi karşılıklı gelecek şekilde kartezyen sisteme yazılır ve daha sonra her bir kutuya A ve B kümelerinin elemanlarının toplamı yazılır. Bu noktadaki önemli husus, toplanan bu iki sayının üyelik

derecesinin belirlenmesidir. Bu sorunun çözümü ise minimizasyon (“ve” leme) işlemi ile gerçekleştirilir. Şekil 2.6’da görüldüğü gibi, toplam 15 eleman elde edilmiş ve üyelik dereceleri de belirlenmiştir. Ancak, matris sisteme dikkatle bakılırsa aynı rakamların birkaç kere tekrar ettiği görülür. Bu noktada ise tekrar eden rakamların üyelik derecesinin belirlenmesi gerekir ki, bu durumu çözmek için maksimizasyon (“veya” lama) yapılarak en büyük üyelik derecesi elemanın üyelik derecesi olarak atanır.

+	$\frac{0,1}{2}$	$\frac{0,7}{5}$	$\frac{0,3}{4}$	$\frac{1,0}{8}$	$\frac{0,6}{10}$
$\frac{0,3}{2}$	$\frac{0,1}{4}$	$\frac{0,3}{7}$	$\frac{0,3}{6}$	$\frac{0,3}{10}$	$\frac{0,3}{12}$
$\frac{1,0}{4}$	$\frac{0,1}{6}$	$\frac{0,7}{9}$	$\frac{0,3}{8}$	$\frac{1,0}{12}$	$\frac{0,6}{14}$
$\frac{0,8}{6}$	$\frac{0,1}{8}$	$\frac{0,7}{11}$	$\frac{0,3}{10}$	$\frac{0,8}{14}$	$\frac{0,6}{16}$

Şekil 2.6 Toplama işleminin gerçekleştirilmesi için oluşturulan kartezyen toplam.

Bu işlemlerin sonucunda toplam kümesi:

$$A + B = \left\{ \frac{0,1}{4}, \frac{0,3}{7}, \frac{0,3}{6}, \frac{0,3}{10}, \frac{1,0}{12}, \frac{0,7}{9}, \frac{0,3}{8}, \frac{0,8}{14}, \frac{0,7}{11}, \frac{0,6}{16} \right\}$$

şeklinde elde edilir.

Böylesi bir problemi çözmek için, ilk olarak 15 elemanlı bir küme elde edilmiştir ($S(A) \times S(B)$). Daha sonra minimizasyon ve maksimizasyon ile bu problem çözümlenerek toplam küme bulunmuştur. Bulanık toplama işleminin matematiksel notasyon ifadesi aşağıdaki şekilde olmaktadır.

$$A + B =_{x+y} \max \{ [\min(\tilde{U}_A(x), \tilde{U}_B(y))] \} \quad (2.6)$$

Diğer matematiksel işlemleri de benzer kartezyen işlem ile gerçekleştirmek mümkündür. Ancak tahmin çıkarma işlemi için küme elemanları birbirinden çıkarılırken, çarpma ve bölme işlemlerinde çarpma ve bölme yapmak gerekir. Bunların

dışındaki işlemler ise toplama işlemi ile aynıdır. Genel olarak, diğer matematiksel işlemleri de ifade etmek istersek;

$$A - B =_{x,y} \max \{[\min(\ddot{U}_A(x), \ddot{U}_B(x))]\} \quad (2.7)$$

$$A \times B =_{x,y} \max \{[\min(\ddot{U}_A(x), \ddot{U}_B(x))]\} \quad (2.8)$$


$$A / B =_{x,y} \max \{[\min(\ddot{U}_A(x), \ddot{U}_B(x))]\} \quad (2.9)$$

notasyonları elde edilecektir.

Bu dört işlem sayesinde kesikli bulanık kümeler arasında istenilen her türlü matematiksel işlem yapılabilir.

2.1.1.2.2. Sürekli Bulanık Kümelerde İşlemler

Sürekli bulanık kümelerde matematiksel işlemleri yapabilmek için α kesimleri konusunu bilmek gerekir. α kesimleri, Şekil 2.7’de görüldüğü gibi, bulanık kümeyi α üyelik derecesine sahip bir noktadan kesen bir çizginin oluşturduğu bir aralığı temsil etmektedir. Bu aralığın alt sınırını $a\alpha^-$ ve üst sınırını da $a\alpha^+$ ile gösterirsek, yeni oluşan bu alt kümenin elemanları bu alt ve üst sınırlar arasında değer almaktadır.



Şekil 2.7 α kesimleri aralığı.

2.1.1.2.2.1. Toplama ve Çıkarma


A ve B bulanık kümelerinin α seviyelerindeki kesimleri,

$$A_\alpha = [a\alpha^-, a\alpha^+] \text{ ve } B_\alpha = [b\alpha^-, b\alpha^+] \quad (2.10)$$

ise;

$$(A + B)_\alpha = [a\alpha^- + b\alpha^-, a\alpha^+ + b\alpha^+] \quad (2.11)$$

işlemi ile hesap edilir. Bu işlem, üyelik dereceleri $[0,1]$ için tekrar edilirse $A + B$ ifadesi elde edilir. Bu durum Şekil 2.8'de gösterilmiştir.



Şekil 2.8 Sürekli bulanık kümelerde toplama.

Şekilden de görüleceği üzere A ve B bulanık kümelerinin toplanması sonucunda A+B bulanık kümesi elde edilmiştir. A ve B kümelerinde $\alpha = 0$ ve $\alpha = 1$ kesimleri için elde edilen değerlerin toplanması sonucunda A+B kümesinin oluştuğu görülmektedir. Çıkarma işlemi de benzer şekilde yapılmaktadır. Çıkarma işlemi genel kural denklem (2.12) olarak yazılabilir.

$$(A - B)_\alpha = [\min(a\alpha^- - b\alpha^-, a\alpha^+ - b\alpha^+), \max(a\alpha^- - b\alpha^-, a\alpha^+ - b\alpha^+)] \quad (2.12)$$

2.1.1.2.2.2. Çarpma ve Bölme

Çarpma ve bölme işlemlerini yapabilmek için de α kesimlerinden faydalanılmaktadır. Toplama ve çıkarma işlemlerinden farklı olarak, bir kümenin α alt sınırı diğer kümenin α alt ve üst sınırları ile çarpılarak ya da bölünerek 2 tane, ve yine ilk kümenin α üst sınırı diğer kümenin α alt ve üst sınırı ile çarpılarak ya da bölünerek 2 tane olmak üzere toplamda 4 tane α sınırı belirlenir. Bulunan 4 tane α sınırının minimum ve maksimum

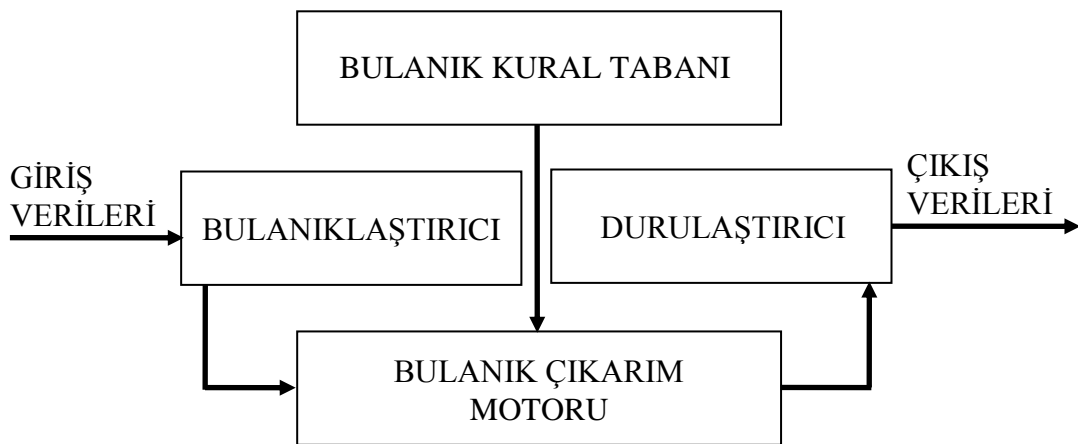
değerleri alınarak α kesiminin alt ve üst sınırları oluşur. Denklem (2.13) ve (2.14) ile bu durumu matematiksel olarak gösterebiliriz.

$$(A.B)_\alpha = [\max(a\alpha^-.b\alpha^-, a\alpha^- . b\alpha^+, a\alpha^+.b\alpha^-, a\alpha^+ . b\alpha^+), \min(a\alpha^-.b\alpha^-, a\alpha^- . b\alpha^+, a\alpha^+.b\alpha^-, a\alpha^+ . b\alpha^+)] \quad (2.13)$$

$$(A/B)_\alpha = [\max(a\alpha^-/b\alpha^-, a\alpha^- / b\alpha^+, a\alpha^+/b\alpha^-, a\alpha^+ / b\alpha^+), \min(a\alpha^-/b\alpha^-, a\alpha^- / b\alpha^+, a\alpha^+/b\alpha^-, a\alpha^+ / b\alpha^+)] \quad (2.14)$$

2.1.1.3. Bulanık Modelleme Aşamaları

Bulanık sistemler genel olarak bulanıklaştırma, kural tabanı, çıkarım motoru ve durulaştırma aşamalarından oluşmaktadır. Bulanık sistem yapısına ait örnek gösterim Şekil 2.9'da verilmiştir [28].



Şekil 2.9. Bulanık sistem yapısı.

2.1.1.3.1. Bulanıklaştırma Aşaması

Bulanıklaştırmanın iki anlamı vardır. Bunlardan birincisi, kesin bir değer için üyelik derecesi ile ifade edilen bulanık değere dönüştürülmesidir. İkincisi ise, sayısal bir girdi

değerinin uygun üyelik fonksiyonu yardımı ile belirli bir üyelik derecesi ise sözel bir değişkene dönüştürülmesidir [28].

Pratikte genel olarak, klasik küme şeklinde beliren değişim aralıklarının bulanıklaştırılması işlemi bulanık küme, bulanık mantık ve bulanık sistem için gerekmektedir. Bu durumda, bir aralıkta bulunabilecek elemanların hepsinin, 1'e eşit üyelik derecesine sahip olacak yerde, 0 ile 1 arasında değişik değerlere sahip olması düşünülmektedir. Bunun için, bazı elemanların belirsizlik içerdikleri kabul edilmektedir. Bu belirsizliklerin, sayısal olmayan durumlardan kaynaklanması halinde bulanıklıktan söz edilmektedir [29]. Üyelik işlevinden yararlanılarak giriş bilgilerinin ait olduğu bulanık kümeyi ve üyelik derecesini belirlenip girilen sayısal değerlere küçük, en küçük ve orta gibi sözel değişken değerler atanır. Bulanık sistemin verimli çalışmasını sağlamak için değişik şekillerde bulanık kümeler kullanılabilir [30].

Bulanıklaştırma sürecinde kullanılan üyelik fonksiyonları, problemin yapısına ve amacına uygun olarak seçilmelidir. Genel olarak üyelik fonksiyonları sezgisel, istatistiksel, matematiksel veya geometrik yaklaşımlara dayandırılabilir [31].

2.1.1.3.2. Bulanık Kural Tabanı Aşaması

Bulanık mantıkta kurallar, "EĞER ... İSE, ... olsun" şeklinde koşullu durumlarda formüle edilirler [32].

Tüm girdi değişkenleri, sözel değişken değerlere çevrilerek, bulanık sonuç çıkarma adımı, güncel durum için kurallara dayandırılarak uygulanır ve çıkışta sözel değişkenlerin değerleri hesaplanır [31].

Girişler ve çıkışlar arasındaki bağlantılar, kural tabanındaki kurallar kullanılarak sağlanmaktadır. A ve B giriş değişkenlerine ve C ise çıkış değişkenine sahip bir bulanık sistem için,

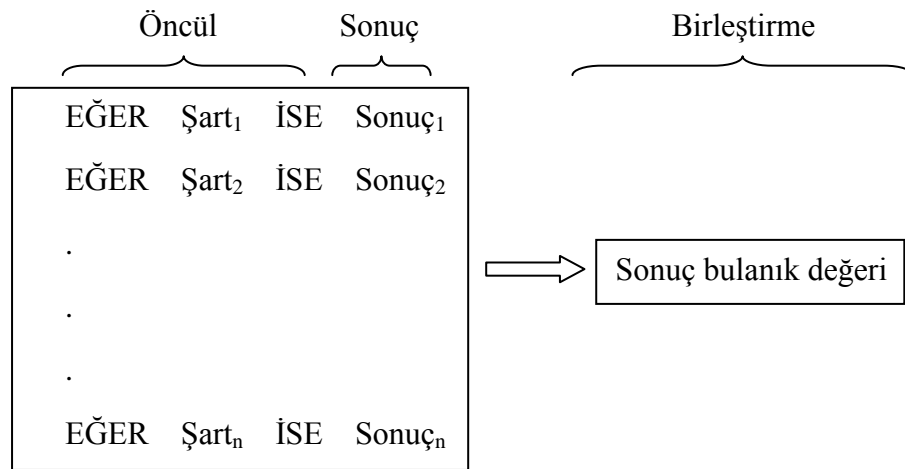
EĞER $A=x$ VE $B=y$ İSE O HALDE $C=z$,

Şeklindeki bir kural A ve B'nin aldığı değerlere göre C çıkış değişkeninin bulanık değerini belirler [20].

2.1.1.3.3. Bulanık Çıkarım Aşaması

Genel olarak, var olan bilgilerin kullanılması ile yeni bilgileri elde etme süreci çıkarım olarak tanımlanmaktadır [33]. Bu birim, bulanıklaştırma biriminden gelen bulanık değerleri, kural tabanındaki kurallar üzerinde uygulayarak bulanık sonuçlar üretmektedir. Öncelikle, her bir giriş değişkeni değerinin ne oranda hangi üyelik kümesine ait olduğu saptanır. Bu değerler kural tablosuna yerleştirilerek uygun çıkışlar elde edilmektedir. Bulanık mantık kuralları, kural içerisindeki birleştiricilerin anlamlarının yorumlanması ile hesaplanmaktadır [34].

Çıkarım aşamasında girdi ve çıktı değişkenleri arasındaki ilişkiler konunun uzmanından alınan bilgiler doğrultusunda EĞER-İSE mantıksal ifadeleri kullanılarak açıklanmaktadır. EĞER-İSE mantıksal ifadesi veya kuralları iki kısımdan oluşmaktadır. EĞER ile İSE'yi kapsayan kısma öncül, İSE'den sonraki kısma da sonuç kısmı denilmektedir. İki veya daha fazla mantıksal ifade VE veya VEYA mantıksal bağlantı işlemcileri kullanılarak birleştirilir. Çıkarım aşamasında her mantıksal ifade sonunda bir sonuç, bu sonuçların birleştirilmesi ile de en son sonuç değerine veya sonuç kümesine ulaşılmaktadır. VE ve VEYA mantıksal bağlantı işlemcileri her kural için w_i ile gösterilen eşik değerini belirlemek için etkilidirler. Eşik değeri, bulanık çıkarım aşamasında kullanılan çıkarım yönteminde göre farklı şekillerde hesaplanır ve kullanılır. Kural, VE mantıksal bağlantı işlemcisi ile oluşturulmuş ise en küçük üyelik derecesine, VEYA mantıksal bağlantı işlemcisi ile oluşturulmuş ise en büyük üyelik derecesine eşit olmaktadır. EĞER-İSE kurallarının öncül kısmında verilen şart sağlanmadığında eşik değeri (w_i) sifıra eşit olur ve sonuç aşamasında boş küme elde edilir [35]. Şekil 2.10'da, çıkarım aşamasında sonuç elde edilmesi gösterilmiştir. Çıkarım aşamasında Mamdani, Takagi-Sugeno-Kang (TSK), Larsen ve Tsukamoto yöntemleri kullanılmaktadır. Bu yöntemlerin arasındaki temel farklılık EĞER-İSE kurallarının sonuç kısmı ile birleşim aşamasındadır. Bu tez çalışmasında TSK yöntemi kullanılmıştır.



Şekil 2.10. Çıkarım aşaması sonuç değerinin elde edilmesi.

2.1.1.3.3.1. Takagi-Sugeno-Kang (TSK) Çıkarım Yöntemi

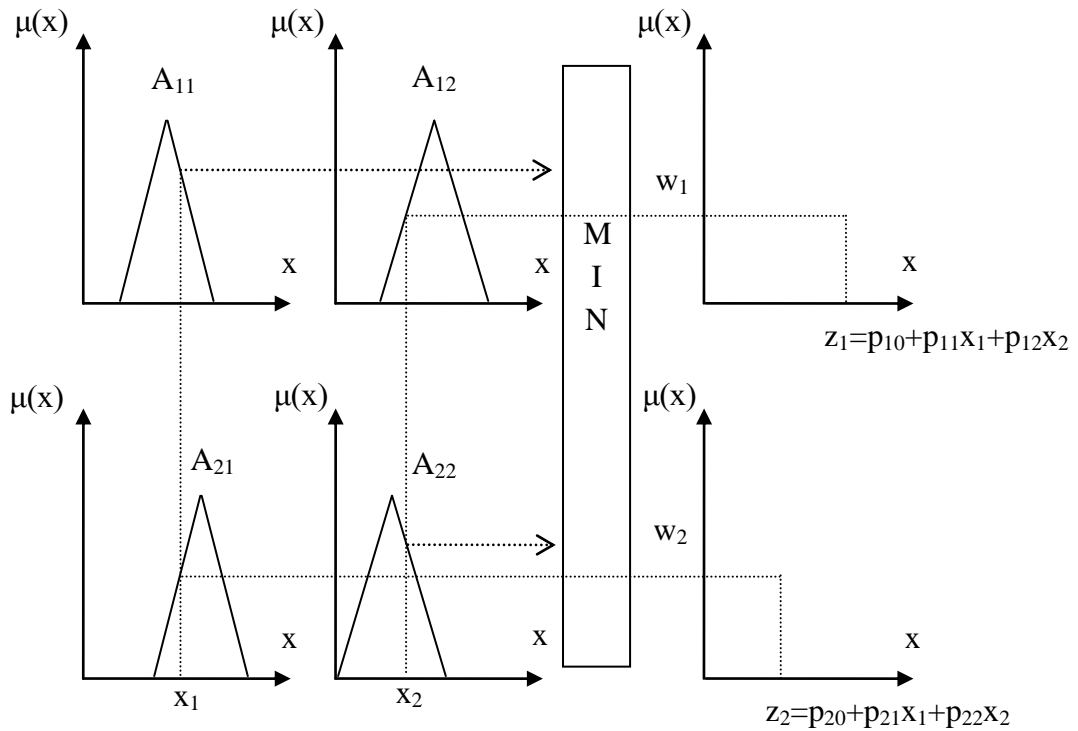
TSK çıkarım yöntemi tek başına Sugeno yöntemi olarak da adlandırılır. Mamdani yöntemi ile Sugeno yöntemi arasındaki temel farklılık, Sugeno yönteminde çıktı değişkeni bulanık bir küme değil, doğrusal bir fonksiyon veya sabit bir değerdir [36]. Bundan dolayı bu yöntemde durulaştırma işlemine ihtiyaç duyulmamaktadır. Kullanımının basit olması ve özellikle sayısal verilerle çalışıldığı için oldukça başarılı sonuçlar vermektedir. Bundan dolayı yaygın olarak kullanılmaktadır [37]. TSK yönteminde EĞER-İSE kuralı,

$$\text{EĞER } (x_1=A_{11}) \text{ VE } (x_2=A_{12}) \text{ İSE } (z_1=p_{10}+p_{11}x_1+p_{12}x_2)$$

$$\text{EĞER } (x_1=A_{11}) \text{ VE } (x_2=A_{12}) \text{ İSE } (z_2=p_{20}+p_{21}x_1+p_{22}x_2)$$

şeklinde olmaktadır. Şekil 2.11’de, TSK çıkarım yöntemi gösterilmiştir [38].

Burada, bir veya birden çok girdi değişkeni ve tek bir çıktı değişkeni (z_i) vardır. Çıktı değişkeni z_i , x_1 ve x_2 girdi değişkenlerinin doğrusal bir fonksiyonu sabit bir sayıda olabilmektedir.



Şekil 2.11. TSK çıkarım yönteminin gösterimi.

Çıktı değişkeni doğrusal fonksiyon olarak tanımlandığında, p_{i0} , p_{i1} ve p_{i2} fonksiyonun parametreleridir. Bu parametreler her kural için farklı değerlere sahip olmaktadır. Parametre değerleri hesaplanırken başlangıçta girdi değişkenlerinin ilk değerleri için rastgele değerler atanmaktadır. İlk parametre değerlerinin hiçbir önemi bulunmamaktadır. Bu başlangıç p_i tahminleri kullanılarak girdi değişkenlerine ait (x_1 ve x_2) tüm değerler için çıktı değişkeninin (z_i) değerleri tahmin edilmektedir. Bu değerler için belirlenen eşik değerleri kullanılarak denklem (2.15) ile sonuç değeri elde edilmektedir [38].

$$\text{Sonuç değeri} = \frac{\sum_{i=1}^N w_i z_i}{\sum_{i=1}^N w_i} \quad (2.15)$$

Tahmin değerleri ile önceden bilinmekte olan gözlem değerleri arasındaki farklar hata olarak kabul edilmektedir ve bu farklar bağıl hata olarak adlandırılmaktadır. Hata değeri istenilen sınırlar içerisinde olmadığına p_{i0} , p_{i1} ve p_{i2} parametreleri değiştirilerek sonuç

değerleri yeniden hesaplanmaktadır. Nihai p_i değerleri, bağıl hata değerinin %5 veya %10'un altında olmasını sağlayan değerlerdir. Denklem (2.16) kullanılarak bağıl hata hesaplanmaktadır.

$$H_i = \frac{|b_i - \hat{c}_i|}{b_i} \times 100 \quad (2.16)$$

Burada, b_i , i inci gözlem ve \hat{c}_i , i inci tahmin edilen değerleridir. p_i parametreleri, bütün girdi değerleri için hata değerleri istenilen sınırlar içinde olacak şekilde herhangi bir başlangıç değerinden başlanılır ve iterasyon yapılarak elde edilir [35].

Hesaplanan çıktı değerleriyle oluşan modelin performansını ölçmek için bağıl hatanın yanı sıra gözlem değerleri ile tahmin değerleri arasındaki ilişkinin bir göstergesi olan belirginlik katsayısı (R^2) değeri de kullanılmaktadır. Bu değer 1'e yaklaştıkça modelin başarısı artmaktadır [39]. Bazı durumlarda modellerin R^2 değeri 1'e çok yakın olurken bağıl hata değerlerinden bazıları %5 veya %10 bağıl hata sınırlarının dışına çıkabilir. Bu durumda, tüm bağıl hataların aritmetik ortalamasına bakılmaktadır. Ortalama bağıl hata %5 veya %10'un altında kalırsa model başarılı olarak kabul edilmektedir [40].

2.1.1.3.4. Durulaştırma Aşaması

Durulaştırma işlemi, bulanık bilgilerin kesin sonuçlara dönüştürülmesi olarak ifade edilmektedir. Bulanık çıkarım aşamasında, sonuç değerlerini bulanık bir küme olarak elde eden Larsen ve Mamdani çıkarım yöntemleri kullanıldığında durulaştırma işlemine ihtiyaç duyulmaktadır. Sonuç değerlerini kesin değer olarak veren Tsukamoto ve TSK bulanık çıkarım yöntemleri kullanıldığında durulaştırma aşamasına ihtiyaç duyulmamaktadır [26].

2.1.1.4. Bulanık Mantığın Avantajları ve Dezavantajları

Bulanık mantık yönteminin belli bir formel tasarım metodunun olmaması ve hala iyi ölçme yöntemlerine sahip olmayışı, bulanık mantığın ne zaman kullanılması gerektiğinin ve geleneksel yöntemlerden ne kadar iyi sonuç vereceğinin kestirilmesini

zorlaştırmaktadır. Ayrıca bulanık mantık uygulamalarında kullanılan kuralların, uzman deneyimlerine bağlı olarak konulması gereksinimi ve üyelik fonksiyonları deneme ile bulunduğu için zaman kaybının olabileceği, bulanık mantık yönteminin dezavantajları arasında sayılabilir.

Bulanık mantık yönteminin en güçlü uygulamaları, doğrusal olmayan ve girişlerinde veya tanımlarında belirsizlik bulunan karmaşık sistemlerin gerçekleştirilmesinde ortaya çıkmaktadır. Çok büyük doğa (hava, doğal biçimler, okyanuslar gibi) veya insan yapısı (ekonomi, borsa veya seçimler gibi) sistemlerin modellenmesi ve kontrolünde, yeterli doğrulukta modellenemeyen çok karmaşık sistemlerin modellenmesinde, önemli ölçüde doğrusal olmayan sistemleri tanımlamada, girişlerinde veya tanımlarında belirsizlik olan sistemler için bulanık mantık yöntemini kullanmak şu an için diğer yöntemlerden daha iyi sonuçlar vermektedir. Çok karmaşık doğrusal olmayan belirsizlik içeren ve geleneksel yöntemlerle oluşturulamayan sistemlerin oluşturulmasına olanak tanınması da bulanık mantık yönteminin avantajları arasındadır. Ayrıca, bulanık mantığın insan düşünüş tarzına yakın olması matematiksel modellerle uyum sağlaması, uygulamalarının hızlı ve ucuz olması, insan davranışlarını formüle etmesi, karar aşamalarının açık bırakmayacak şekilde tanımlanması, sistemlerde insan müdahalesine yer vermemesi ile birlikte sistemin kısa sürede gerçekleşebilmesi ve yeni olanaklara açık olması bulanık mantık yönteminin avantajları arasındadır.

2.1.2. Genetik Algoritma

Genetik algoritmalar (GA) yapay zekanın gittikçe genişleyen bir kolu olan evrimsel hesaplama tekniğinin bir parçasını oluşturmaktadır. Adından da anlaşıldığı üzere evrimsel hesaplama tekniğinin bir parçası olan GA, Darwin'in evrim teorisinden esinlenerek oluşturulmuştur. Herhangi bir problemin GA ile çözümü, problemi sanal olarak evrimden geçirmek sureti ile yapılmaktadır. Evrimsel hesaplama tekniklerinin ilk olarak matematiksel problemlere uygulanması 1975 yılında John Holland tarafından geliştirilmiştir. GA, mühendislik problemlerinde optimizasyon amaçlı olarak kullanılmaktadır. Özellikle mekanizma tasarımında çok iyi sonuçlar verdiği bilinmektedir. Bunlardan başka otomatik programlama, öğrenme kabiliyetli makineler,

ekonomi, ekoloji, planlama, üretim hattı yerleşimi gibi alanlarda da uygulanmaktadır [41].

2.1.2.1. Genetik Algoritmada Kullanılan Operatörler

Genetik algoritma, çözüm dizilerinden oluşan bir başlangıç nesliyle, çaprazlama ve mutasyon gibi doğal seçim operatörlerini kullanmaktadır [42]. Genetik algoritmada bağımsız parametrelerin kromozomlar içerisinde kodlanması gerekmektedir. Yığındaki her bir birey ikili düzende veya tamsayı olarak kodlanmaktadır. Genetik algoritmaların genel olarak çalışma şeması Şekil 2.12'de gösterilmiştir. Öncelikli olarak ele alınan problem için bir rastgele n kromozomlu popülasyon oluşturulur. Daha sonra popülasyondaki her bir kromozom için $f(x)$ uygunluk fonksiyonu hesaplanır. Yeni bir popülasyon oluşuncaya kadar aşağıdaki adımlar tekrar edilir.

Seleksiyon (Seçim): İki ebeveyn kromozomun $f(x)$ 'e göre seçimi, burada uygunluk derecesi yüksek olanın seçilme şansı yüksektir.

Çaprazlama: Yeni bir birey oluşturmak için ebeveynlerin bir çaprazlama olasılığına göre çaprazlanması. Eğer çaprazlama uygulanmazsa bireyler atalarının tamamen kopyası olur.

Mutasyon: Kromozom üzerinde bulunan bazı genlerin değerleri değiştirilerek nesillerin yozlaşması önlenir.

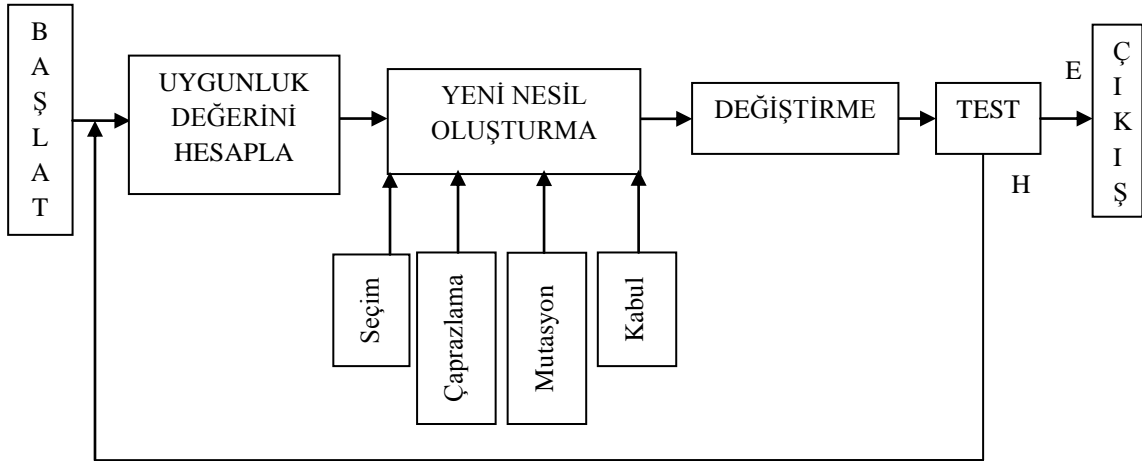
Ekleme: Yeni birey yeni topluma eklenir.

Değiştirme: Algoritmanın yeniden çalıştırılmasında oluşan yeni toplum kullanılır.

Test: Eğer sonuç tatmin ediyorsa, algoritmanın sona erdirilir ve son toplum çözüm olarak sunulur.

Döngü: Çaprazlama adımına geri dönülür [43].

Yeni popülasyon kabul edildikten sonra hesaplama yeni popülasyonla tekrarlanır. Hedeflenen uygunluk değerine ulaşıldığında program durdurulur ve popülasyondaki en iyi çözüm alınır [44].



Şekil 2.12. Genetik algoritmaların genel çalışma şeması.

Genetik algoritmalarda kromozomlarla bir başlangıç popülasyonu rastgele oluşturulur. Burada popülasyon genişliğinin belirlenmesi gerekmektedir. Büyük popülasyonlarda, çözüm uzayı iyi örneklendiği için aramanın etkinliği artmakta, fakat buna bağlı olarak da arama süresi uzamaktadır. Küçük popülasyonlarda ise, çözüm uzayını yeterli örnekleme ve zamansız yakınsama oluşabilmektedir [45].

Genetik algoritmanın her çevriminde, yığındaki dizilerin bir değerlendirme fonksiyonu yardımıyla uygunluk değeri hesaplanır [46]. Uygunluk fonksiyonu her bir çözümün yeni nesil çözümlere katkı sağlayıp sağlamayacağına karar verir. Sonrasında, insan üremesindeki gen transferine benzer operasyonlar kullanan algoritma yeni bir çözüm adayı popülasyonu oluşturur. Genellikle genetik algoritmaların başarısı bu fonksiyonun verimli ve hassas olmasına bağlıdır [47].

2.1.2.1.1. Seçim Operatörü

Başlangıç popülasyonu oluşturulduktan sonra yeni popülasyonun oluşturulabilmesi için seçim yöntemine karar verilmesi gerekmekte ve yüksek uyuma sahip bireylerin seçilme olasılığı daha fazla olmaktadır. Seçim operatörleri ile tıpkı gerçek doğada olduğu gibi en iyilerin hayatta kalması sağlanmaktadır. Seçim operatörü ile seçilmiş olan bireyler çaprazlama havuzuna girmeye hak kazanırken seçilemeyen bireyler yok olmaktadır. Seçim yöntemi olarak geliştirilmiş birçok yöntem bulunmakta beraber rulet çemberi,

turnuva ve elitist seçim yöntemleri en yaygın kullanılanlardır. Goldberg, Turnuva, Rulet Çemberi gibi farklı seçim operatörlerinin avantaj ve dezavantajlarından bahsetmiştir [48].

Rulet Çemberi yöntemi ile üreme işlemi gerçekleştirilir. Bu seçim yönteminde tüm bireylerin uygunluk değerleri hesaplanır ve bu değerler toplanır. Tüm bireylerin uygunluk değerleri toplama bölünerek (0,1) aralığında sayılar elde edilir ve bu sayıların hepsi bir çizelgede toplanır. Çizelgedeki sayılar birbirine eklenerek rastgele olarak bir sayıya kadar ilerlenir ve bu sayıya ulaşıldığında son eklenen sayının ait olduğu çözüm seçilmiş olur.

Turnuva seçim yönteminde yerine koyarak ya da koymadan rastgele t adet birey seçilir ve bu büyüklüğe turnuva genişliği adı verilir. Bu gruptaki en iyi birey, yeni popülasyona kopyalanır. Bu işlem kullanıcı tarafından önceden kararlaştırılan çevrim sayısı kadar tekrarlanır.


Elitist seçim yönteminde popülasyonun en iyi bir bireyi korunup, popülasyonun geri kalan elemanlarını uyum orantılı seçim yöntemlerinden birini kullanarak yeni bireyler ile değiştirilir. Burada hedef en iyi uyum değerine sahip bireyin, genetik operatörler kullanıldığında kaybolmasını önlemektir [45].

2.1.2.1.2. Çaprazlama Operatörü

Kromozomların nasıl temsil edileceğine karar verildikten sonra yapılan çaprazlama, genetik algoritma uygulamalarında en önemli operatördür. Çaprazlama ile ebeveynlerden bazı genler alınarak yeni bireyler oluşturulur.

Ele alınan probleme bağlı olarak, kullanıcı tarafından seçilen 4 farklı çaprazlama operatörü bulunmaktadır. Bunlar, tek nokta çaprazlama, iki nokta çaprazlama, çok nokta çaprazlama ve üniform çaprazlamadır [49]. Çaprazlama operatörlerin uygulamaları Şekil 2.13'de gösterilmiştir. Rastgele seçilen kromozom çiftine çaprazlama uygulanır. Tek nokta çaprazlama işlemi için kromozomda çaprazlama yapılacak bölge kullanıcı tarafından rastgele seçilebilir. Oluşan yeni birey ebeveynlerin bazı özelliklerini alarak

her ikisinin kopyası olacaktır [50]. İki nokta çaprazlamada, iki nokta arasında iki nokta kalan alt dizilerin değiştirilmesiyle iki yeni birey elde edilir. Çok noktalı çaprazlama, iki nokta çaprazlamanın gelişmiş bir halidir. Kromozomlar daha fazla parçalara ayrılır ve bir atlanarak elde edilen çiftler arasında değiştirilerek yeni bireyler elde edilir. Üniform çaprazlama yönteminde, rastgele olarak çaprazlama maskesi oluşturulur. Birinci ve ikinci kromozoma karşılık gelen genin kopyalanmasıyla oluşturulur. Çaprazlama maskesinde, bir o genin birinci kromozomdan, sıfır ise o genin ikinci kromozomda kopyalanacağı anlamına gelmektedir.



Şekil 2.13. Çaprazlama yöntemleri ve etkileri.


İki kromozomda çaprazlama yapılmış elemanlar, Şekil 2.13’de her bir çaprazlama operatörü için altı çizili olarak gösterilmiştir [45].

2.1.2.1.3. Mutasyon Operatörü

Oluşan yeni çözümlerin önceki çözümü kopyalamasını önlemek ve sonuca daha hızlı ulaşmak için mutasyon operatörü uygulanmaktadır [51].

Örneğin, ikili bir kodlamanın kullanıldığı bir dizide mutasyon operatörü ile rastgele seçilen eleman değeri 1 ise 0 veya 0 ise 1 olarak değiştirilerek yeni bir dizi elde edilir. Mutasyon operatörü olarak, ters çevirme, ekleme, yer değişikliği ve karşılıklı değişim çeşitleri vardır ve ele alınan problemin yapısına en uygun olan mutasyon operatörü seçilir. Şekil 2.14’de mutasyon operatörlerinin uygulamaları gösterilmiştir [45]. Şekilde

altı çizili olarak ifade edilen eleman değerleri mutasyona uğramış elemanları göstermektedir. Ters çevirmede, mutasyon için seçilen kromozomdan iki pozisyon rastsal olarak seçilir ve bu iki pozisyondaki alt diziler ters çevrilir [52]. Ekleme de ise rastgele bir parça seçilir ve rastgele bir yere yerleştirilir. Yer değişikliği mutasyonunda, rastgele bir alt dizi seçilir ve rastgele bir yere yerleştirilir. Karşılıklı değişim mutasyonunda, rastgele seçilen iki genin yerleri değiştirilir.



Şekil 2.14. Mutasyon yöntemleri ve etkileri.

2.1.2.2. Genetik Algoritmanın Avantajları ve Dezavantajları

Genetik algoritma diğer optimizasyon yöntemlerine göre, kabul edilebilir sonuca daha kısa sürede ulaşabilir [53].

Çözümlerden oluşan popülasyon eş zamanlı olarak incelendiğinden dolayı genetik algoritma yerel eniyiye (local optimum) takılmamaktadır [54]. Bu avantajından dolayı genetik algoritma global çözümler sunabilir [55].

Genetik algoritma, parametre kümesini değil kodlanmış biçimleri kullanır ve çözüm için sadece amaç fonksiyonuna (fitness function) gereksinim duyar [54].

Genetik algoritma, amaç fonksiyonun belirttiği anlamdan bağımsızdır ve sistemin sınırları hakkında herhangi bir bilgiye ihtiyaç duymaz. Bu özelliği ile genetik algoritma her türlü en iyileme problemi için uygulanabilir [56].

Genetik algoritma pratik olduđu için güvenilir ve etkili bir en iyileme yöntemidir. Özellikle yapay zeka ve fonksiyon optimizasyonda kompleks ve zor problemlerin çözümü için uygun olmaktadır [57].

Genetik algoritmaların belirli bir probleme uygulanması sırasında karşılaşılan tasarım güçlükleri ile çözüme ulaşmada yaşanabilecek güçlüklerden dolayı bazı dezavantajları mevcuttur [58].


Kullanılan kodlama sistemi, seçim, çaprazlama ve mutasyon yöntemleri, çaprazlama ve mutasyon olasılıkları, uygunluk fonksiyonunun formülasyonu ve bitiş koşulunun belirlenmesi gibi parametrelerin, genetik algoritmaların hızı ve sonuca ulaşma yeteneđi üzerinde çok önemli bir etkisi bulunmaktadır. Ancak, bu parametrelerin belirlenmesinde her probleme uygulanabilecek genel kurallar mevcut değildir ve bu parametrelerin doğru olarak belirlenmesi imkansız olmasa bile oldukça zor bir konudur [59].

Genetik algoritmaların en önemli kısıtı en uygun sonuca ulaşma garantisinin bulunmamasıdır. Özellikle klasik yöntemlerle çözümü elde edilemeyen problemler söz konusu olduğunda elde edilen sonucun en uygun olup olmadığını belirlemek zordur. Genetik algoritmaların en iyi çözüme ulaşmadan genelde yerel en iyi olan bir çözüme yakınsayabilir. Buna erken yakınsama denir. Ayrıca çok kısıtlı ve yüksek düzeyde doğrusal olmayan problemlerde ise hiç yakınsamayabilir. Genetik algoritmaların yakınsamaması yukarıda bahsedilen parametreler için uygun değerlerin seçilmemesine bağlı olabileceğinden, problem için uygun değerlerin seçilmesiyle bu sorun ortadan kaldırılabılır. Ancak problemin özelliklerinden kaynaklanan yakınsamama durumlarında yapılacak pek bir şey olmayabilir [59].

2.1.3. Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi

Adaptif ağ tabanlı bulanık çıkarım sistemi (Adaptive network based fuzzy inference system-ANFIS), yapay sinir ağlarının paralel hesaplayabilme ve öğrenme kabiliyeti ile bulanık mantığın çıkarım özelliğini kullanan melez bir yapay zeka yöntemidir [26]. 1993 yılında Jang [60] tarafından geliştirilen ANFIS modeli melez öğrenme (hybrid learning) ve sugeno tipi bulanık çıkarım sistemini kullanmaktadır. Adaptif ağlar

doğrudan bağlanmış olan düğümlerden oluşmaktadır ve her bir düğüm bir işlem birimini temsil etmektedir. Düğümler arasındaki bağlantılar aralarındaki değeri tam olarak belli olmayan bir ağırlığı göstermektedir. Adaptasyon bu düğümlerin çıkışlarının değişebilir parametrelerle belirlenmesi suretiyle oluşmaktadır. Öğrenme kuralları, değişebilir parametrelerin, ağırlıklarının çıkışı ile hedef değer arasındaki farkı minimum yapacak şekilde nasıl değiştirilmesi gerektiğini belirlemektedir. ANFIS, problem için oluşturulan yapıya göre olabilecek bütün kuralları atayabilir veya kuralların veriler yardımıyla konunun uzmanı tarafından atanmasına olanak vermektedir. Bu durum, ANFIS'in kural oluşturabilmesi veya kural oluşturulmasına olanak sağlaması uzman görüşlerinden yararlanması anlamına gelmektedir. Bundan dolayı, birçok tahmin probleminde yapay sinir ağlarına uzman görüşlerinden yararlanma olanağı tanıdığı için ortalama kareler kriterine göre daha iyi sonuçların bulunmasını mümkün kılmaktadır. ANFIS'in öğrenme algoritması, en küçük kareler ile geri yayımlı öğrenme algoritmasının birlikte kullanılmasından meydana gelen melez öğrenme algoritmasıdır. Şekil 2.15'de görüldüğü gibi, ANFIS altı katmandan oluşmaktadır ve yapısındaki her katmana ait düğüm işlevleri ve katmanların işleyişi sırasıyla aşağıdaki gibidir [61, 62].



Şekil 2.15. Adaptif ağ tabanlı bulanık mantık çıkarım sistemi.

1.Katman: Bu katmana giriş katmanı denilmektedir ve bu katmandaki her düğümden alınan giriş sinyalleri diğer katmanlara aktarılmaktadır.

2.Katman: Bu katmana bulanıklaştırma katmanı denilmektedir ve bu katmanda her bir düğümün çıkışı, giriş değerlerine ve kullanılan üyelik fonksiyonuna bağlı olan üyelik derecelerinden oluşmaktadır ve 2. katmandan elde edilen üyelik dereceleri $\mu_{A_j}(x)$ ve $\mu_{B_j}(y)$ şeklinde gösterilmektedir.

3.Katman: Bu katman kural katmanıdır ve bu katmandaki her bir düğüm, Sugeno bulanık mantık çıkarım sistemine göre oluşturulan kuralları ve sayısını ifade etmektedir. Her bir kural düğümünün çıkışı μ_i , 2. katmandan gelen üyelik derecelerinin elde edilişi ise, (j=1,2) ve (i=1,...,n) olmak üzere denklem (2.17) ile ifade edilir.

$$y_i^3 = \prod_i = \mu_{A_j}(x) \times \mu_{B_j}(y) = \mu_i \quad (2.17)$$

Burada, y_i^3 , 3. katmanın çıkış değerlerini; n ise, bu katmandaki düğüm sayısını ifade etmektedir.

4.Katman: Bu katman normalizasyon katmanıdır ve bu katmandaki her bir düğüm, kural katmanından gelen tüm düğümleri giriş değeri olarak kabul eder ve her bir kuralın normalleştirilmiş değerini hesaplamaktadır. Bu katmanın çıkışları, normalize edilmiş ateşleme seviyesi olarak adlandırılmaktadır. Yani, bu katmandaki her bir düğüm, N etiketli bir sabit düğümdür. Normalleştirilmiş ateşleme seviyesi $\bar{\mu}_i$ 'nin hesaplanması ise, denklem (2.18)'e göre gerçekleştirilmektedir.

$$y_i^4 = N_i = \frac{\mu_i}{\sum_{i=1}^n \mu_i} = \bar{\mu}_i, \quad (i=1,n) \quad (2.18)$$

5.Katman: Bu katman durulaştırma katmanıdır ve bu katmandaki her bir düğümden verilen bir kuralın ağırlıklandırılmış sonuç değerleri hesaplanmaktadır. 5. Katmandaki i. düğümün çıkış değeri ise denklem (2.19)'de gösterilmektedir.

$$y_i^5 = \overline{\mu_i} [p_i x_1 + q_i x_2 + r_i], \quad (i=1,n) \quad (2.19)$$

Buradaki (p_i , q_i , r_i) deęişkenleri, i . Kuralın sonuç parametreleri kümesidir.

6.Katman: Bu katman toplam katmanıdır ve bu katmanda Σ ile etiketlenmiş sadece bir düęüm bulunmaktadır. Burada, 5. katmandaki her bir düęümün çıkış deęeri toplanarak sonuçta, ANFIS sisteminin gerçek deęeri elde edilmektedir.

Sistemin çıkış deęeri olan y' nin hesaplanması ise denklem 2.20'de gösterilmiştir [63].

$$y = \sum_{i=1}^n \overline{\mu_i} [p_i x_1 + q_i x_2 + r_i] \quad (2.20)$$

2.1.4. Yapay Sinir Ağları

İnsan beyninin özelliklerinden öğrenme yoluyla yeni bilgiler türetme, yeni bilgiler oluşturma ve keşfetme gibi yetenekleri herhangi bir yardıma ihtiyaç duymadan gerçekleştirmek için geliştirilmiş bilgisayar sistemlerine yapay sinir ağları denilmektedir. Bu yetenekleri geleneksel programlama teknikleri ile gerçekleştirmek zor ya da mümkün değildir [64].

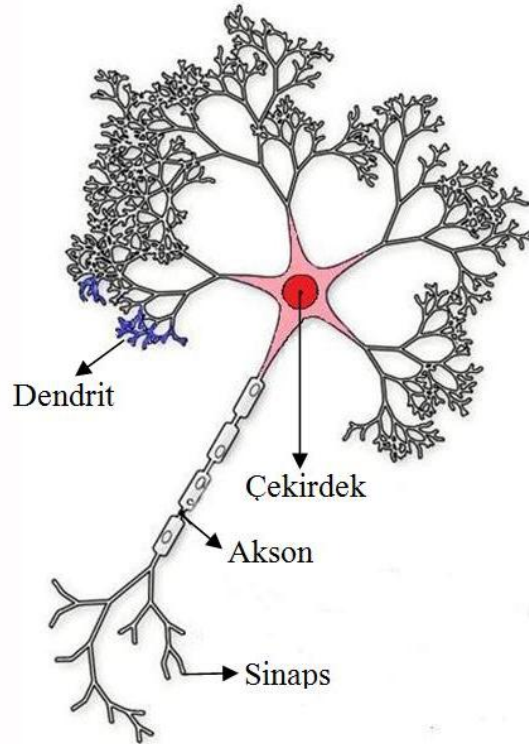
Sinir sisteminden faydalanılarak ortaya çıkan yapay sinir ağları yöntemi, paralel çalışma ve eğitilebilme özelliklerinden dolayı biyolojik sinir sisteminin çalışma özelliklerini göstermektedir. Yapay sinir ağlarının paralel çalışma özelliğinden dolayı bilgiler hızlı bir şekilde işlenebilmektedir ve herhangi bir birimde meydana gelen hata bütün sistemde belirgin bir hataya sebep olmamaktadır. YSA yönteminin bu etkileşim yapısından dolayı genel sistem yerel hatalardan çok az etkilenmektedir [23].

Yapay sinir ağları, sinir sistemi ile ilgili bazı bulguların ayrıntılarının ihmal edilerek teknoloji ve bilimsel araştırma yöntemlerine uygulanmasından oluşmaktadır. Yapay sinir ağları birbiri ile paralel iletişim içerisinde bulunan tabakalara sahip olan ve her bir tabakasında yeterli sayıda sinir hücresi bulunan bir sistemden oluşmaktadır ve bu

tabakaları oluşturan hücreler arasında karmaşık iletişimler, incelenen olaya göre belirlenen ağırlık katsayıları ile gerçekleştirilmektedir [23].

2.1.4.1. Biyolojik Sinir Hücresinin Yapısı

İnsanlarda bulunan sinir sistemi, sinir adı verilen hücrelerden meydana gelmektedir. Sinirler canlıların hayati faaliyetlerinin yürütüldüğü en küçük birimlerdir. Beynin haberleşme sistemini oluşturan sinirlerin işlevi sinyal alma, işlem yapma ve elektrokimyasal sinyalleri sinir ağları içerisinde iletmektir [65].



Şekil 2.16. Biyolojik sinir hücresinin yapısı.

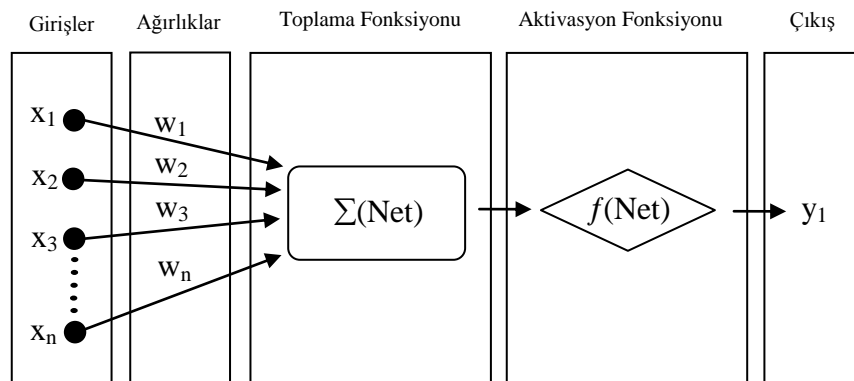
Biyolojik bir temel sinir hücresi sinapslar, aksonlar, dendritler ve içerisinde çekirdek bulunan hücre gövdesinden meydana gelmektedir ve gösterimi Şekil 2.16'da verilmiştir. Sinapslar, sinir hücreleri arasında bağlantı kurar ve bu bağlantılar yardımıyla elektrik sinyalleri hücreler arasında iletilir. Sinapslar tarafından iletilen bu sinyaller, hücre gövdesinde işlemde geçer ve buradan da aksonlar yardımıyla dendritlere gönderilir. Dendritler de gelen bu sinyalleri sinapslar yardımıyla diğer sinir hücrelerine gönderir ve

bu işlemlerin hepsi 1-2 milisaniyede gerçekleşmektedir. Her bir sinir hücresi saniyede 500-1000 civarında bu işlemleri yapabilecek kapasitededir [66, 67].

Sinir hücreleri kabaca çok kutuplu, iki kutuplu, tek kutuplu, anaksonik olmak üzere öbeklendirilebilir. Çok kutuplu sinirlerde çok sayıda dentrit ve tek bir akson bulunmaktadır. Bu sinirlerin hücre gövdeleri omurilik (medulla spinalis)'in ön boynuzunda bulunur ve miyelin tabaka ile çevrelenmiştir. Miyelin tabaka stoplazma ile hücreler arası sıvı arasındaki kapasiteyi düşürür ve işaretlerin yayılma hızını artırır [20].

2.1.4.2. Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları girişler ve çıkışlar arasında çok fazla hücre ve çok miktarda bağ sahiptir. Sinir hücreleri arasında bulunan bu bağlar ilişkiye göre çok aktarım değeri alır ve bu değere ağırlık denilir [23]. Mühendislik biliminde yapay sinir hücreleri işlem elemanları olarak adlandırılır ve Şekil 2.17'de görüldüğü gibi proses elemanının 5 temel elemanı bulunmaktadır [64]. Bu elemanlar, girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkıştır.



Şekil 2.17. Yapay sinir hücresi.

Girişler, diğer hücrelerden ya da dış ortamlardan hücreye girilen bilgilerdir. Ağırlıklar, giriş seti veya kendinden önceki tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden değerlerdir. Toplama fonksiyonu girişler ve ağırlıkların hepsinin bu işlem elemanına etkisini hesaplayan bir fonksiyondur. Bu fonksiyon bir hücreye gelen net girdiyi hesaplar [68, 69]. Giriş bileşenlerinde bulunan ağırlıkların hepsi denklem (2.21) kullanılarak toplanır [70, 71, 72, 73, 74].

$$(\text{net})_j = \sum_{i=1}^n x_i w_{ij} + b \quad (2.21)$$

Burada, $(\text{net})_j$, n sinir hücresi ile önceki tabakadan alınan girişin j . sinir hücresinin toplam ağırlığı, x_i önceki tabakadaki i . sinir hücresinin çıktısı ve w_{ij} önceki tabakadaki i . sinir hücresi ve j . sinir hücresi arasındaki ağırlık değeridir [70]. b içsel katkı olarak sabit bir değeri ve \sum toplama fonksiyonudur. Aktivasyon fonksiyonu ise toplama fonksiyonundan elde edilen net girdiyi bir işlemde geçirerek hücre çıktısını belirleyen bir fonksiyondur. Genel olarak çok tabakalı algılayıcı modellerde aktivasyon fonksiyonu $f(\cdot)$ olarak Sigmoid fonksiyonu kullanılmaktadır. Sigmoid aktivasyon fonksiyonu kullanılarak hesaplanan sinir hücresinin çıktısı denklem (2.22)'de gösterilmektedir [68, 75, 76, 77].

$$(\text{çıktı})_j = f(\text{net})_j = \frac{1}{1 + e^{-\alpha(\text{net})_j}} \quad (2.22)$$

Burada, α yarı doğrusal bölgenin eğimini kontrol etmek için kullanılan bir sabittir. Sigmoid doğrusal olmayan aktivasyon her tabakayı giriş tabakasından ayırmaktadır [70, 78]. Sigmoid fonksiyonu (0, 1) arasında çıkışlar vermektedir ve sigmoid fonksiyonu denklem (2.22)'de verilmiştir. Eğer istenilirse fonksiyon çıktıları (-1, 1) arasında olacak şekilde ayarlanabilir. Sigmoid işlemcisi sürekli bir fonksiyon göstermektedir ve bundan dolayı sigmoid işlemcisi özellikle doğrusal olmayan tahminlerde kullanılmaktadır. Bunun sebebi ise, $(\text{net})_j$ değişkeni bünyesinde olan parametrelere göre türevinin kolay bir şekilde alınmasıdır [69, 71, 79]. Ayrıca burada, $(\text{çıktı})_j$ çıktıları ile amaçlanan çıktılar arasındaki farklar hata olarak belirlenmektedir. Eğer bu hata değeri istenilen sınırlardan daha küçük değilse, hatalar geriye doğru her bağlantıya geri yayılma ile dağıtılmaktadır.

2.1.4.3. Yapay Sinir Ağları Çeşitleri

Çok sayıda yapay sinir ağları çeşidi bulunmaktadır. Bu çeşitliliğin temel sebebi, yöntemde kullanılan mimari, gizli tabaka sayısı, öğrenme yöntemi, bağlantı yapısı gibi özelliklerdir. Genel olarak, yapay sinir ağları yöntemi üç esas ölçüte göre


çeşitlendirilmektedir. Bunlar, öğrenme yöntemi, ağıın kullanıldığı veri ve ağıın yapısıyla ilgilidir.

2.1.4.3.1. Yapılarına Göre Ağ Çeşitleri

İçerdikleri nöronların birbirlerine bağlantı şekillerine göre yapay sinir ağları, ileri beslemeli (feedforward) ve geri beslemeli (backpropagation veya feedback) ağlar olarak ikiye ayrılır.

2.1.4.3.1.1. İleri Beslemeli Ağlar

Yapay sinir ağlarında, ağ yapısı olarak en çok tercih edilen ağlar ileri beslemeli ağlardır. Bu tür ağlar, giriş katmanı, gizli katman ve çıkış katmanı olmak üzere en az üç katmandan oluşmaktadır [80]. Gizli katmanların sayısında teorik olarak herhangi bir sınırlama olmamasına rağmen genellikle bir veya iki tane gizli katman bulunmaktadır. Giriş katmanından çıkış katmanına doğru sinyaller tek yönlü bağlantılarla iletilmektedir ve bütün hücreler bir sonraki katman ile bağlantılıdır ancak aynı katman içerisinde bağlantıları bulunmamaktadır [65]. Giriş, ara ve çıkış katmanı olmak üzere üç katmana sahip olan ileri beslemeli yapay sinir ağı mimarisi Şekil 2.18’de verilmiştir [81].




Şekil 2.18. İleri beslemeli yapay sinir ağı.

Yapay sinir ağına gelen bilgiler, öncelikle giriş katmanından daha sonra da sırası ile ara katman ve çıkış katmanından işlenerek geçer ve dış dünyaya çıkar [82].

2.1.4.3.1.2. Geri Beslemeli Ağlar

Geri beslemeli yapay sinir ağlarında katmanlar arasındaki bağlantılar iki yönlüdür. Böylelikle ara katmanların ya da çıkış katmanının çıkışları bir önceki katmana giriş olarak gönderilir. Bu ağlar dinamik bir hafızaya sahip olduğundan dolayı bir andaki çıkış hem o an giriş hem de bir önceki giriş olarak kullanılmaktadır. Tipik bir geri beslemeli yapay sinir ağı mimarisi Şekil 2.19'da gösterilmiştir.



Şekil 2.19. Geri beslemeli yapay sinir ağı.

Geri beslemeli ağlarda, ağın işlem elemanlarının çıkışları ağa tekrar belli işlemler sonucunda giriş olarak gönderilmektedir. Dinamik sistemler bu geri dönüşüm zaman gecikmesine sebep olmaktadır. Zaman gecikmesi hususunda bazı çalışmalar yapılarak değişik geri dönüşüm ağ modelleri tasarlanmıştır [83].

2.1.4.3.2. Öğrenme Algoritmalarına Göre Ağ Çeşitleri

Örneklerden öğrenen sistemler için farklı öğrenme stratejileri kullanılmaktadır. Öğrenmeyi gerçekleştirecek olan sistem ve kullanılan öğrenme algoritması bu stratejilere bağlı olarak değişmektedir [64]. Uygulamalarda genel olarak üç öğrenme

stratejisi ile karşılaşılmaktadır. Bunlar, öğretmenli, öğretmensiz ve takviyeli öğrenmedir.

2.1.4.3.2.1. Öğretmenli Öğrenme

Öğretmenli öğrenme için, ağın giriş katmanına verilerin girdi ve amaçlanan çıktı değerleri verilmektedir. Böylelikle, ağa girilen veriler yapay sinir ağlarının amaçlanan değere karşı üreteceği değerlerin öğrenmesini sağlamaktadır.

Bu öğrenme esnasında amaçlanan değer ile ağın ürettiği değer karşılaştırılır. İki değer arasındaki hata değerinin kabul edilebilir sınırlar içerisinde olup olmadığına karar verilir. Bu öğrenme şeklinde, eğitime esnasında gerçek değerler kullanılmaktadır [65, 84].

2.1.4.3.2.2. Öğretmensiz Öğrenme

Bu öğrenme şeklinde, ağın giriş katmanına hiç çıkış bilgisi olmayan giriş değerleri verilmektedir. Yapay sinir ağları yöntemi, bu bilgileri öncelikle kendisine göre işler ve daha sonra gruplara ayırır ve çıkışlar üretir. Eğer farklı gruplar birbirinden ne kadar ayrılırsa ağırlıklarda giriş verilerine göre değişmektedir. İstenilen bilgiler ağa girilmediği için hata dikkate alınmaz ve bundan dolayı bu öğrenme şeklinde istenilen çıkış değerinin bilinmesine ihtiyaç duyulmamaktadır [23].


2.1.4.3.2.3. Takviyeli Öğrenme

Takviyeli öğrenme, ağa amaçlanan çıkışlar yerine, ağın çıkışlarının ne kadar doğru olduğunu belirten bir skor veya derece bildirimini şeklinde işlemektedir [85].

Bu öğrenme şeklinde, her giriş seti için olması gereken çıkış setini sisteme göstermek yerine kendisine gösterilen girişlere karşılık çıkışını üretmesini bekler ve üretilen çıkışın doğru veya yanlış olduğunu gösteren bir sinyal üretmektedir [64].

2.1.4.4. Çok Katmanlı Yapay Sinir Ağları

Çok katmanlı yapay sinir ağları yöntemi, yapay sinir ağları yöntemleri arasında en çok kullanılan yöntemdir ve ÇKYSA modeli her bir katmanında en az bir adet sinir hücresi bulunacak şekilde giriş, bir veya daha çok gizli katman ve çıkış katmanından oluşmaktadır. Giriş katmanında bulunan işlemci elemanlar, giriş sinyallerini ara katmanda bulunan işlemci elemanlara dağıtmaktadır. Ara katmanda bulunan işlemci elemanlar ise, bir önceki katmanın çıkışlarını giriş bilgisi olarak kullanmaktadır. Bütün girişlerle ağırlıklar çarpılarak toplanır ve daha sonra toplamdan elde edilen değer bir transfer fonksiyonundan geçirilir. Böylelikle o sinir hücresinin çıkış değeri hesaplanmış olur. Yapılan bu işlemler, bu katmanda bulunan bütün işlemci elemanlar için tekrarlanır. Çıkış katmanında bulunan işlemci elemanlar ara katmanda bulunan elemanlar gibi davranır ve ağ çıkış değeri hesaplanır. ÇKYSA yöntemin ileri beslemeli yapay sinir ağı yöntemidir ve bu yöntemde değişik öğrenme şekilleri kullanılarak ağın eğitilmesi sağlanmaktadır [83,86]. ÇKYSA örneği Şekil 2.20'de gösterilmiştir.



Şekil 2.20 Çok katmanlı ağ yapısı.

ÇKYSA yönteminde, iki öğrenme algoritması yaygın olarak görülür. Bunlar, standart geri yayılma algoritması ve Levenberg-Marquardt (LM) algoritmasıdır. Standart geri yayılma algoritması, anlaşılması kolay ve matematiksel olarak ispatlanabilir. Bundan dolayı çok fazla tercih edilen öğretim algoritmasıdır. Bu algoritma, hataları çıkıştan girişe doğru azaltmaya çalışmaktadır. ÇKYSA modellerini eğitmek için çok fazla tercih edilmesine rağmen standart geri yayılım algoritması sonuca çok yavaş bir şekilde

yaklaşmaktadır ve yerel minimuma yakalanma riski bulunmaktadır. Bundan dolayı, bu tez çalışmasında öğrenme algoritması olarak LM algoritması tercih edilmiştir. LM algoritması Newton metoduna yaklaşım algoritmasıdır. LM algoritması, adım düşme metodunun sağlamlığı ile Newton metodunun hızının bir bileşkesidir. Her bir iterasyon adımında hata yüzeyine parabolik yaklaşımla yaklaşılır ve parabolün minimumu o adım için çözümü oluşturmaktadır [87].

Geri yayılım algoritmalarında eğitim sürelerini azaltmak için sezgisel yaklaşım yöntemleri kullanılmaktadır. Sezgisel yöntemler hata oranını daha hızlı bir şekilde azaltmak için kullanılmaktadır. Hatayı düzeltme ve ağırlıkların değiştirilmesinde bir toparlanma sağlaması için ve toparlanma oranını hızlandırmak için en çok kullanılan yöntemlerden biri momentum katsayısı (γ) yöntemidir. Momentum olmaksızın ağ yerel minimum değerine takılarak salınım yapabilmektedir. Momentum katsayısının kullanılması, öğrenme esnasında ağın salınımını engellemektedir. Momentum değeri 0 ile 1 arasındadır [88, 89].

Levenberg-Marquardt algoritmasında, çözümlenmesi oldukça karışık olan Hessian matrisi ($H(w)$) kullanılmaktadır ve bu matrisi çözmek için denklem (2.23)'de verilen eşitlikten yararlanılmaktadır [90].

$$H(w) \cong J^T(w)J(w) + \mu I \quad (2.23)$$

Burada; μ , Marquardt parametresini, I ise birim matrisi ifade etmektedir. Buradaki J matrisi ise, ağ hatalarının ağırlıklara göre birinci türevlerinden elde edilen Jakobien matrisini göstermektedir.

Levenberg-Marquardt algoritmasının en önemli parametresi skaler bir sayı olarak tanımlanan μ parametresidir. Eğer μ sifıra yakınsarsa, yöntem Newton algoritması gibi işleyişini sürdürmekte; μ büyük bir sayıyı temsil ederse yöntem küçük adımlı gradyen azalması yöntemi haline gelmektedir [91].

Ağın hatasının geri yayılmasında, ilk olarak Jakobien matrisin transpozu ve ağ hataları kullanılarak ağın gradyeni denklem (2.24)'de verilen eşitlik yardımı ile hesaplanır.

$$\nabla E(w) = J^T(w)e(w) \quad (2.24)$$

Daha sonra, ağırlıklarındaki vektörel değişim denklem (2.25)'de görüldüğü gibi, Hessian matrisinin tersi ile ağırlıkların gradyanının çarpılmasıyla elde edilir ve ağırlıkların denklem (2.26)'da ifade edildiği gibi yazılabilir.

$$\Delta w = -[H(w)]^{-1} \nabla E(w) \quad (2.25)$$

$$w_{yeni} = w_{eski} + \Delta w \quad (2.26)$$

2.1.4.5. YSA'nın Avantajları ve Dezavantajları

YSA önceki deneyimlerden öğrenebilir, bir kez eğitildiklerinde yeni bir veri kümesine hemen cevap verebilir. YSA matematiksel modele ihtiyaç duymaz ve yazınında verilerin YSA'nın eğitiminde kullanılması için gerekli bir varsayıma rastlanmamıştır. YSA verilerden hareketle bilinmeyen ilişkileri akıllıca hemen ortaya çıkarabilir ve bu özelliği uygulama açısından önemlidir. Geleneksel bilgisayar sistemleri, sistemde oluşacak hatalara karşı çok hassastır. Sistemde meydana gelebilecek en ufak bir hata, sonuca ulaşmama ya da sonuçlarda büyük hataya yol açabilmektedir. Ancak, YSA'nın bir veya birkaç nöronunun zarar görmesi sistemi geleneksel bilgi işlem teknolojilerinde olduğu kadar etkilemez. Ağ ağırlık katsayısı ve yapısı gibi kendi parametreleri değiştiğinde somut bir problemin çözümü için kendini adapte edebilme özelliğine sahiptir. Ağlar doğrusal değildir ve bu sebeple karmaşık problemleri doğrusal tekniklerden daha doğru çözebilirler. Doğrusal olmayan davranışlar hissedilir, algılanır ve bilinebilir. Ancak, bu problemleri ve davranışları matematiksel olarak çözmek zordur [92, 93, 94, 95].

Sistem içerisinde ne olduğu bilinemez. Bu sebeple bazı durumlarda ağların verdiği sonuçları değerlendirmek zor olabilir. Bir problemin çözümünde çok uygun bir çözüm bulamayabilirler ya da hata yapabilirler. Bunun sebebi, ağı eğitecek bir fonksiyonun bulunmamasıdır. Bazı durumlarda fonksiyon bulunsa bile yeterli veri bulunamayabilir.

Ağın kalitesi ve kapasitesi, uygulamadaki hızı ile orantılıdır. Öyle ki, düğümlerin sayısındaki artış bile zamanın çok daha artmasına sebep olabilir [92, 93, 94, 95].

2.2. Anahtar Eğrisi

Anahtar eğrisi, akarsuyun herhangi bir kontrol kesitindeki debisi ile taşınan katı madde miktarı arasındaki ilişkiyi göstermektedir ve anahtar eğrisine ait fonksiyonel bağıntı denklem (2.27)'de gösterilmiştir [96].

$$S = aQ^b \quad (2.27)$$

Burada, Q akarsu akım debisini, S taşınan katı madde konsantrasyonunu ve $\log S$ ve $\log Q$ arasında doğrusal regresyon kurularak bulunan a ve b ise akarsu akımı karakteristiğine bağlı katsayıları göstermektedir [97, 98, 99, 100]. Taşınan katı madde miktarının tahmininde yaygın olarak kullanılan bu eğriler ile yalnızca ortalama aylık veya yıllık katı madde miktarlarının tahmini yapılabilmektedir. Denklem (2.27)'de verilen S-Q ilişkisini araştıran geniş bir çalışmada [101], tek tip bir ilişkinin olmadığı belirtilmektedir. Bazı akarsularda S-Q ilişkisi, iki kollu bir değişim izlemektedir, yani akımın yükselen seviyesindeki katı madde miktarı aynı akım için düşme seviyesindeki katı madde miktarından fazla olabilmektedir.


3. BÖLÜM

BULGULAR

Bu çalışmada, Amerika Birleşik Devletleri'nin Montana eyaletinde bulunan ve Amerika Birleşik Devletleri Jeolojik Araştırmalar Kurumu (USGS, United States Geological Survey) tarafından işletilen Vaughn yakınlarındaki Muddy Çayı üzerinde bulunan 06088300 ve 06088500 nolu istasyonlara ait günlük gerçek zaman akım ve askı maddesi konsantrasyonu verileri kullanılmıştır. Her bir istasyon için, 1 Eylül 1978 - 31 Ağustos 1982 tarihleri arasında dört yıllık veri, modellerin eğitilmesi, test edilmesi ve değerlendirilmesi için üç bölüme ayrılmıştır. Bunlardan, 1 Eylül 1978 - 31 Ağustos 1980 tarihleri arasındaki toplam 731 veri (yaklaşık %50) modellerin eğitilmesi, 1 Eylül 1980 - 31 Ağustos 1981 tarihleri arasındaki toplam 365 veri (yaklaşık %25) modellerin test edilmesi ve 1 Eylül 1981 - 31 Ağustos 1982 tarihleri arasındaki toplam 365 veri (yaklaşık %25) modellerin değerlendirilmesi için kullanılmıştır. Her bir istasyona ait bilgiler Tablo 3.1'de verilmiştir. Şekil 3.1'de Muddy Çayının üzerinde bulunan istasyonların yerleri gösterilmiştir.

Tablo 3.1. Muddy Çayı istasyon bilgileri.

İstasyon No:	06088300	06088500
İstasyon Yeri:	Vaughn, Montana	Vaughn, Montana
Drenaj Alanı:	730.38 km ²	1012.69 km ²
Rakım:	1051.56 m	1015.17 m
Gözlem Süresi:	01.09.1978 – 31.08.1982	01.09.1978 – 31.08.1982
Enlem:	47°37'30"	47°33'42"
Boylam:	111°38'05"	111°32'33"



Şekil 3.1. Muddy Çayı üzerindeki istasyonların konumu.

Muddy Çayı üzerinde bulunan istasyonlara ait günlük akış ve askı maddesi konsantrasyonu verilerinin istatistik parametreleri Tablo 3.2 ve 3.3'te verilmiştir. Tablolarda gösterilen X_{ort} , S_x , C_v , C_{sx} , X_{maks} ve X_{min} ifadeleri sırasıyla her bir veri setinin ortalamasını, standart sapmasını, değişim katsayısını, çarpıklığını, maksimum ve minimum değerlerini ifade etmektedir. Tablo 3.2 ve 3.3'teki her iki istasyona ait çarpıklık katsayısı değerleri, akış ve askı maddesi konsantrasyonu verilerinin oldukça çarpık bir dağılıma sahip olduğunu göstermektedir. Ayrıca, akış ve askı maddesi konsantrasyonu verilerinin maksimum değerlerinin ortalama değerlerine oranları

incelenirse, her iki istasyon için bu oranların çok yüksek olduğu ve akış - askı maddesi konsantrasyonu (A.M.K.) olayının karmaşık bir yapıya sahip olduğu görülmektedir.

Tablo 3.2. 06088300 nolu istasyonun istatistik parametreleri.

Veri Seti	Veri Türü	X_{ort}	S_x	C_v	C_{sx}	X_{maks}	X_{min}	$\frac{X_{maks}}{X_{ort}}$
Eğitme	Akış (m^3/s)	3.14	3.07	0.98	2.74	31.1	0.43	9.89
	A.M.K. (mg/l)	213	516	2.43	10.4	9110	14	42.8
Test	Akış (m^3/s)	3.41	3.60	1.06	4.63	43.6	0.31	12.7
	A.M.K. (mg/l)	260	782	3.01	11.3	12000	19	46.2
Değerlendirme	Akış (m^3/s)	3.14	3.09	0.98	1.71	19.2	0.54	6.11
	A.M.K. (mg/l)	246	504	2.05	6.04	5540	13	22.5
Tüm Veri	Akış (m^3/s)	3.21	3.22	1.00	3.19	43.6	0.31	13.6
	A.M.K. (mg/l)	233	591	2.54	10.9	12000	13	51.6

Tablo 3.3. 06088500 nolu istasyonun istatistik parametreleri.

Veri Seti	Veri Türü	X_{ort}	S_x	C_v	C_{sx}	X_{maks}	X_{min}	$\frac{X_{maks}}{X_{ort}}$
Eğitme	Akış (m^3/s)	4.11	4.03	0.98	2.13	34	0.45	8.27
	A.M.K. (mg/l)	527	883	1.68	5.83	13000	16	24.7
Test	Akış (m^3/s)	4.42	4.54	1.03	3.5	49.3	0.43	11.2
	A.M.K. (mg/l)	669	1482	2.22	9.21	21100	31	31.5
Değerlendirme	Akış (m^3/s)	4.08	4.09	1.00	1.51	23.8	0.57	5.84
	A.M.K. (mg/l)	604	985	1.63	3.17	6820	31	11.3
Tüm Veri	Akış (m^3/s)	4.18	4.18	1.00	2.43	49.3	0.43	11.8
	A.M.K. (mg/l)	582	1087	1.87	8.01	21100	16	36.3

06088300 ve 06088500 nolu istasyonlara ait akış ve askı maddesi konsantrasyonu verilerini modellemek için bulanık genetik yaklaşımı (BG), adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS), çok katmanlı yapay sinir ağı (ÇKYSA) olmak üzere üç farklı yapay zeka yöntemi ve anahtar eğrisi (AE) yöntemi kullanılmıştır. Çalışmada kullanılan

yapay zeka modellerini geliřtirmek için MATLAB programlama dilinde üç farklı kod hazırlanmıştır. İlk olarak yapay zeka yöntemleri için farklı giriş senaryoları oluşturulmuştur. Eđer t anındaki akış ve askı maddesi konsantrasyonunu sırasıyla Q_t ve S_t ile gösterirsek, oluşturulan senaryolar şunlardır;

- Q_t
- S_{t-1}
- Q_t ve S_{t-1}
- S_{t-1} ve S_{t-2}
- Q_t , S_{t-1} ve S_{t-2}
- Q_t , Q_{t-1} , Q_{t-2} ve S_{t-1}
- Q_t , Q_{t-1} , Q_{t-2} , S_{t-1} ve S_{t-2}

Modellerin çıkış elemanı ise t anındaki askı maddesi konsantrasyonu yani S_t 'dir. Ayrıca modellerin tahmin sonuçları, Karekök Ortalama Karesel Hata (KOKH) ve Determinasyon Katsayısı (R^2) kıyaslama kriterleri kullanılarak gözlem değerleri ile karşılaştırılmıştır. KOKH ve R^2 ifadeleri sırasıyla denklem (3.1) ve denklem (3.2) kullanılarak hesaplanmaktadır.

$$KOKH = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_{igözlenen} - Y_{itahmin})^2} \quad (3.1)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_{igözlenen} - Y_{itahmin})^2}{\sum_{i=1}^N (Y_{igözlenen} - Y_{ortalama})^2} \quad (3.2)$$

Burada, Y_i , askı maddesi konsantrasyonunu, $Y_{ortalama}$, gözlenen askı maddesi konsantrasyonu verilerinin ortalamasını ve N, toplam veri sayısını göstermektedir.

Bulanık genetik yaklaşımında, bir optimizasyon yöntemi olan genetik algoritma ile bulanık küme parametrelerinin belirlenmesi amaçlanmaktadır. Bundan dolayı, en iyi modeli bulabilmek için bulanık mantık parametrelerinin yanı sıra genetik algoritma

parametreleri de kullanılmıştır ve bu parametreler her bir giriş senaryosuna uygulanmıştır. Çalışmada kullanılan bulanık mantık ve genetik algoritma parametreleri şunlardır:

- Üyelik fonksiyonu sayısı: 2 ve 3,
- Giriş üyelik fonksiyonu: Gaussmf, gauss2mf, gbellmf ve pimf,
- Çıkış üyelik fonksiyonu: Constant ve linear,
- Popülasyon sayısı: 20 ve 30,
- Nesil sayısı: 1000, 5000, 10000, 20000, 50000, 100000, 150000 ve 200000

Deneme yanılma yöntemi ile her giriş senaryosu için en iyi modeller yani test aşamasında en küçük KOKH ve en yüksek R^2 değerlerini veren modeller ve bu modellere ait parametreler belirlenmiştir. Elde edilen her giriş senaryosu için bulunan en iyi modele ait parametreler ve en iyi modelin test ve değerlendirme aşamalarındaki KOKH ve R^2 değerleri Tablo 3.4 ve 3.5'te verilmiştir.

Tablo 3.4'te görüldüğü gibi, giriş elemanı Q_t , Q_{t-1} , Q_{t-2} ve S_{t-1} , üyelik fonksiyon sayısı 3, giriş üyelik fonksiyonu gauss2mf, çıkış üyelik fonksiyonu constant, popülasyon sayısı 20 ve nesil sayısı 1000 olan modelin, 06088300 nolu istasyon için en iyi tahmini yaptığı test ve değerlendirme aşamalarında kıyaslama kriteri olarak kullanılan KOKH ve R^2 değerlerinden görülmektedir. 06088300 nolu istasyon için en iyi modele ait KOKH ve R^2 değerleri test aşamasında sırasıyla 238.9 ve 0.924 ve değerlendirme aşamasında sırasıyla 205.2 ve 0.840 olarak bulunmuştur.

Tablo 3.5 incelendiğinde, giriş elemanı Q_t , Q_{t-1} , Q_{t-2} , S_{t-1} ve S_{t-2} , üyelik fonksiyon sayısı 2, giriş üyelik fonksiyonu gbellmf, çıkış üyelik fonksiyonu linear, popülasyon sayısı 20 ve nesil sayısı 10000 olan modelin, 06088500 nolu istasyon için en iyi tahmini yaptığı görülmektedir. 06088500 nolu istasyon için, KOKH ve R^2 değerleri test aşamasında sırasıyla 279.2 ve 0.965 ve değerlendirme aşamasında sırasıyla 284.0 ve 0.917 olarak bulunmuştur.


Tablo 3.4. Farklı giriş senaryoları için en iyi BG modeller, 06088300.

Girişler	Üyelik Fonksiyon Sayısı	Giriş Üyelik Fonksiyonu	Çıkış Üyelik Fonksiyonu	Popülasyon Sayısı	Nesil Sayısı	Test Aşaması		Değerlendirme Aşaması	
						KOKH (mg/L)	R ²	KOKH (mg/L)	R ²
Q _t	3	Gaussmf	Linear	30	5000	367.9	0.815	317.0	0.620
S _{t-1}	2	Pimf	Linear	20	1000	347.6	0.830	357.3	0.497
Q _t ve S _{t-1}	3	Gbellmf	Linear	20	10000	275.1	0.877	301.5	0.647
S _{t-1} ve S _{t-2}	3	Gaussmf	Constant	30	1000	365.0	0.828	352.3	0.518
Q _t , S _{t-1} ve S _{t-2}	3	Pimf	Constant	20	5000	284.6	0.894	300.0	0.695
Q _t , Q _{t-1} , Q _{t-2} ve S _{t-1}	3	Gauss2mf	Constant	20	1000	238.9	0.924	205.2	0.840
Q _t , Q _{t-1} , Q _{t-2} , S _{t-1} ve S _{t-2}	2	Gbellmf	Linear	20	10000	242.8	0.919	239.3	0.775


Tablo 3.5. Farklı giriş senaryoları için en iyi BG modeller, 06088500.

Girişler	Üyelik Fonksiyon Sayısı	Giriş Üyelik Fonksiyonu	Çıkış Üyelik Fonksiyonu	Popülasyon Sayısı	Nesil Sayısı	Test Aşaması		Değerlendirme Aşaması	
						KOKH (mg/L)	R ²	KOKH (mg/L)	R ²
Q _t	3	Gbellmf	Constant	20	20000	556.5	0.870	676.8	0.543
S _{t-1}	3	Gauss2mf	Constant	20	1000	970.6	0.586	476.6	0.766
Q _t ve S _{t-1}	3	Gauss2mf	Constant	30	1000	367.7	0.941	424.5	0.822
S _{t-1} ve S _{t-2}	2	Gauss2mf	Linear	20	1000	963.2	0.593	458.3	0.799
Q _t , S _{t-1} ve S _{t-2}	3	Gbellmf	Constant	20	10000	403.5	0.938	430.5	0.817
Q _t , Q _{t-1} , Q _{t-2} ve S _{t-1}	2	Gauss2mf	Linear	30	10000	307.6	0.960	291.3	0.912
Q _t , Q _{t-1} , Q _{t-2} , S _{t-1} ve S _{t-2}	2	Gbellmf	Linear	20	10000	279.2	0.965	284.0	0.917


Bulanık genetik yaklaşımı kullanılarak, 06088300 ve 06088500 nolu istasyonlar için, elde edilen en iyi modellerin giriş parametrelerine ait giriş üyelik fonksiyonlarının eğitilmeden önceki gösterimi sırasıyla Şekil 3.2 ve 3.3'te, eğitildikten sonraki gösterimleri ise sırasıyla Şekil 3.4 ve 3.5'te verilmiştir.



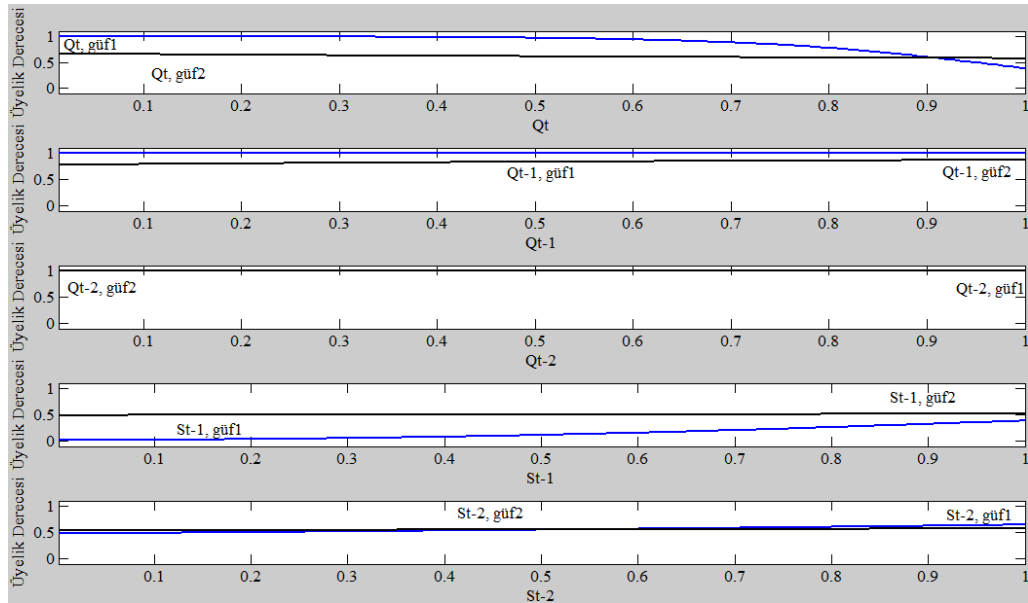
Şekil 3.2. 06088300 nolu istasyon için en iyi BG modele ait giriş üyelik fonksiyonlarının eğitilmeden önceki gösterimi.



Şekil 3.3. 06088500 nolu istasyon için en iyi BG modele ait giriş üyelik fonksiyonlarının eğitilmeden önceki gösterimi.



Şekil 3.4. 06088300 nolu istasyon için en iyi BG modele ait giriş üyelik fonksiyonlarının eğitildikten sonraki gösterimi.



Şekil 3.5. 06088500 nolu istasyon için en iyi BG modele ait giriş üyelik fonksiyonlarının eğitildikten sonraki gösterimi.

ANFIS yaklaşımında da 06088300 ve 06088500 nolu istasyonlara ait herbir giriş senaryosu için farklı model parametreleri kullanılmıştır. ANFIS yaklaşımında kullanılan model parametreleri aşağıda verilmiştir.

- Üyelik fonksiyonu sayısı: 2 ve 3.
- Giriş üyelik fonksiyonu: Gaussmf, gauss2mf, gbellmf, pimf ve trimf.

- Çıkış üyelik fonksiyonu: Constant ve linear.
- İterasyon sayısı: 10, 50, 100, 150, 200, 250, 500, 750 ve 1000.

Deneme yanılma yöntemi ile her giriş senaryosu için en iyi modeller yani test aşamasında en küçük KOKH ve en yüksek R^2 değerlerini veren modeller ve bu modellere ait parametreler belirlenmiştir. Elde edilen her bir giriş senaryosuna ait en iyi modelin parametreleri ve test ve değerlendirme aşamalarındaki KOKH ve R^2 değerleri 06088300 ve 06088500 nolu istasyonlar için sırasıyla Tablo 3.6 ve 3.7’de verilmiştir.

Tablo 3.6’da görüldüğü gibi, giriş elemanı Q_t , Q_{t-1} , Q_{t-2} ve S_{t-1} , üyelik fonksiyon sayısı 2, giriş üyelik fonksiyonu gaussmf, çıkış üyelik fonksiyonu constant ve iterasyon sayısı 150 olan modelin, 06088300 nolu istasyon için en iyi tahmini yaptığı görülmektedir. 06088300 nolu istasyon için en iyi modele ait KOKH ve R^2 değerleri test aşamasında sırasıyla 249.9 ve 0.936 ve değerlendirme aşamasında sırasıyla 230.6 ve 0.819 olarak bulunmuştur.

Tablo 3.7’de görüldüğü gibi, 06088500 nolu istasyon için, giriş elemanı Q_t , üyelik fonksiyon sayısı 2, giriş üyelik fonksiyonu trimf, çıkış üyelik fonksiyonu constant ve iterasyon sayısı 150 olan model test aşamasında en küçük KOKH değerine sahiptir. Ancak, giriş elemanı Q_t , Q_{t-1} , Q_{t-2} , S_{t-1} ve S_{t-2} , üyelik fonksiyon sayısı 2, giriş üyelik fonksiyonu gaussmf, çıkış üyelik fonksiyonu constant ve iterasyon sayısı 250 olan model, test ve değerlendirme aşamalarında en yüksek R^2 ve değerlendirme aşamasında en küçük KOKH değerlerine sahiptir. Bundan dolayı, giriş elemanı Q_t , Q_{t-1} , Q_{t-2} , S_{t-1} ve S_{t-2} , üyelik fonksiyon sayısı 2, giriş üyelik fonksiyonu gaussmf, çıkış üyelik fonksiyonu constant ve iterasyon sayısı 250 olan model 06088500 nolu istasyon için en iyi modeli temsil etmektedir. En iyi modele ait KOKH ve R^2 değerleri test aşamasında sırasıyla 594.5 ve 0.846 ve değerlendirme aşamasında sırasıyla 298.4 ve 0.909 olarak bulunmuştur.


Tablo 3.6. Farklı giriş senaryoları için en iyi ANFIS modeller, 06088300.

Girişler	Üyelik Fonksiyon Sayısı	Giriş Üyelik Fonksiyonu	Çıkış Üyelik Fonksiyonu	İterasyon Sayısı	Test Aşaması		Değerlendirme Aşaması	
					KOKH (mg/L)	R ²	KOKH (mg/L)	R ²
Q _t	3	Gbellmf	Linear	50	322.9	0.834	315.2	0.616
S _{t-1}	3	Pimf	Linear	500	467.8	0.668	466.9	0.398
Q _t ve S _{t-1}	2	Gbellmf	Constant	10	415.5	0.724	352.0	0.515
S _{t-1} ve S _{t-2}	3	Trimf	Linear	10	377.9	0.773	402.0	0.470
Q _t , S _{t-1} ve S _{t-2}	2	Trimf	Constant	50	333.1	0.821	396.9	0.470
Q _t , Q _{t-1} , Q _{t-2} ve S _{t-1}	2	Gaussmf	Constant	150	249.9	0.936	230.6	0.819
Q _t , Q _{t-1} , Q _{t-2} , S _{t-1} ve S _{t-2}	2	Gbellmf	Constant	750	424.8	0.772	561.1	0.524


Tablo 3.7. Farklı giriş senaryoları için en iyi ANFIS modeller, 06088500.

Girişler	Üyelik Fonksiyon Sayısı	Giriş Üyelik Fonksiyonu	Çıkış Üyelik Fonksiyonu	İterasyon Sayısı	Test Aşaması		Değerlendirme Aşaması	
					KOKH (mg/L)	R ²	KOKH (mg/L)	R ²
Q _t	2	Trimf	Constant	150	531.0	0.637	675.0	0.551
S _{t-1}	2	Trimf	Constant	500	946.2	0.599	472.5	0.772
Q _t ve S _{t-1}	2	Gbellmf	Constant	500	716.2	0.840	424.6	0.823
S _{t-1} ve S _{t-2}	2	Pimf	Constant	500	979.3	0.614	474.9	0.767
Q _t , S _{t-1} ve S _{t-2}	2	Trimf	Constant	10	891.8	0.651	463.0	0.785
Q _t , Q _{t-1} , Q _{t-2} ve S _{t-1}	2	Gaussmf	Constant	200	698.3	0.790	380.2	0.873
Q _t , Q _{t-1} , Q _{t-2} , S _{t-1} ve S _{t-2}	2	Gaussmf	Constant	250	594.5	0.846	298.4	0.909


ANFIS yaklaşımı kullanılarak, 06088300 ve 06088500 nolu istasyonlar için, elde edilen en iyi modellerin giriş parametrelerine ait giriş üyelik fonksiyonlarının eğitilmeden önceki gösterimi sırasıyla Şekil 3.6 ve 3.7’de, eğitildikten sonraki gösterimleri ise sırasıyla Şekil 3.8 ve 3.9’da verilmiştir.




Şekil 3.6. 06088300 nolu istasyon için en iyi ANFIS modeline ait giriş üyelik fonksiyonlarının eğitilmeden önceki gösterimi.



Şekil 3.7. 06088500 nolu istasyon için en iyi ANFIS modeline ait giriş üyelik fonksiyonlarının eğitilmeden önceki gösterimi.



Şekil 3.8. 06088300 nolu istasyon için en iyi ANFIS modeline ait giriş üyelik fonksiyonlarının eğitildikten sonraki gösterimi.



Şekil 3.9. 06088500 nolu istasyon için en iyi ANFIS modeline ait giriş üyelik fonksiyonlarının eğitildikten sonraki gösterimi.

Bu çalışmada, ÇKYSA modeli uygulanmadan önce ilk olarak giriş ve çıkış verileri denklem (3.3) kullanılarak [0.2, 0.8] aralığında normalize edilmiştir.

$$X_N = 0.6 * (X_I - X_{MIN}) / (X_{MAK} - X_{MIN}) + 0.2 \quad (3.3)$$

Burada, X_N ; normalize edilmiş giriş veya çıkış verisi, X_{MAK} ; maksimum giriş veya çıkış verisi, X_I ; giriş veya çıkış verisi ve X_{MIN} ; minimum giriş veya çıkış verisini ifade etmektedir.

Giriş ve çıkış verileri normalize edildikten sonra, ÇKYSA yöntemini kullanarak 06088300 ve 06088500 nolu istasyonlara ait her giriş senaryosu için en iyi modeli bulabilmek için ara ve çıkış tabakalarında logaritma sigmoid aktivasyon fonksiyonu, eğitim fonksiyonu olarak Levenberg-Marquardt geri yayılım algoritması, 1'den 20'ye kadar ara tabaka hücre sayısı (A.T.H.S.) ve 10'dan 200'e kadar 10'ar artımlarla iterasyon sayıları kullanıldı. Her giriş senaryosunda en iyi tahmini yapan modellere ait parametreler ve test ve değerlendirme aşamalarındaki KOKH ve R^2 değerleri 06088300 ve 06088500 nolu istasyonları için sırasıyla Tablo 3.8 ve 3.9'da verilmiştir.

Tablo 3.8. Farklı giriş senaryoları için en iyi ÇKYSA modeller, 06088300.

Girişler	A.T.H.S.	İterasyon Sayısı	Test Aşaması		Değerlendirme Aşaması	
			KOKH (mg/L)	R^2	KOKH (mg/L)	R^2
Q_t	9	150	368.8	0.779	380.9	0.561
S_{t-1}	3	170	415.3	0.743	362.2	0.499
Q_t ve S_{t-1}	7	10	279.8	0.874	235.0	0.786
S_{t-1} ve S_{t-2}	2	10	387.6	0.813	399.6	0.458
Q_t , S_{t-1} ve S_{t-2}	9	20	306.9	0.851	352.1	0.526
Q_t , Q_{t-1} , Q_{t-2} ve S_{t-1}	1	190	242.2	0.926	196.4	0.856
Q_t , Q_{t-1} , Q_{t-2} , S_{t-1} ve S_{t-2}	2	200	227.2	0.917	229.7	0.793

Tablo 3.8 incelendiğinde, giriş elemanı Q_t , Q_{t-1} , Q_{t-2} ve S_{t-1} ve S_{t-2} , ara tabaka hücre sayısı 2 ve iterasyon sayısı 200 olan modelin (birinci model) test aşamasında en küçük KOKH değerine sahip olduğu görülmektedir. Ayrıca, giriş elemanı Q_t , Q_{t-1} , Q_{t-2} ve S_{t-1} , ara tabaka hücre sayısı 1 ve iterasyon sayısı 190 olan modelin (ikinci model) test aşamasında en yüksek R^2 ve değerlendirme aşamasında en küçük KOKH değerine sahip olduğu görülmektedir. Burada, test aşamasındaki KOKH değerine göre en iyi model olarak birinci model seçilmiştir. Çünkü, bu model daha tutarlı ve daha doğru tahminler vermektedir. Birinci modelin test aşamasındaki KOKH değeri 227.2 ve R^2 değeri 0.917 ve değerlendirme aşamasında KOKH değeri 229.7 ve R^2 değeri 0.793 olarak bulunmuştur.

Tablo 3.9. Farklı giriş senaryoları için en iyi ÇKYSA modeller, 06088500.

Girişler	A.T.H.S.	İterasyon Sayısı	Test Aşaması		Değerlendirme Aşaması	
			KOKH (mg/L)	R ²	KOKH (mg/L)	R ²
Q _t	2	70	719.0	0.873	691.9	0.516
S _{t-1}	1	30	994.2	0.574	471.4	0.771
Q _t ve S _{t-1}	11	50	409.2	0.929	406.0	0.843
S _{t-1} ve S _{t-2}	2	20	964.7	0.625	435.6	0.806
Q _t , S _{t-1} ve S _{t-2}	6	40	462.8	0.903	475.4	0.774
Q _t , Q _{t-1} , Q _{t-2} ve S _{t-1}	2	90	391.6	0.944	310.0	0.901
Q _t , Q _{t-1} , Q _{t-2} , S _{t-1} ve S _{t-2}	6	50	404.1	0.935	284.9	0.916

Tablo 3.9 incelendiğinde, giriş elemanı Q_t, Q_{t-1}, Q_{t-2} ve S_{t-1}, ara tabaka hücre sayısı 2 ve iterasyon sayısı 90 olan modelin (birinci model) test aşamasında en küçük KOKH ve en yüksek R² değerine sahip olduğu görülmektedir. Ancak, giriş elemanı Q_t, Q_{t-1}, Q_{t-2}, S_{t-1} ve S_{t-2}, ara tabaka hücre sayısı 6 ve iterasyon sayısı 50 olan modelin (ikinci model) değerlendirme aşamasında en küçük KOKH ve en yüksek R² değerine sahip olduğu görülmektedir. Bu iki model karşılaştırılırsa, birinci modelin ikinci modele göre daha tutarlı ve daha doğru tahminler verdiği görülmektedir. Bundan dolayı birinci model bu çalışmada en iyi model olarak seçilmiştir. Tablo 3.9'dan da görüldüğü gibi, birinci model için test aşamasında KOKH değeri 391.6 ve R² değeri 0.944 ve değerlendirme aşamasında da KOKH değeri 310.0 ve R² değeri 0.901 olarak bulunmuştur.

Bu çalışmada 06088300 ve 06088500 nolu istasyonlar için elde edilen AE ifadeleri sırasıyla denklem (3.4) ve (3.5)'te verilmiştir.

$$S = 53.61 * Q^{0.829} \quad (3.4)$$

$$S = 70.65 * Q^{1.161} \quad (3.5)$$

Bu çalışmada kullanılan yöntemlere ait en iyi modeller ve bu modellerin test ve değerlendirme aşamalarındaki KOKH ve R² değerleri 06088300 nolu istasyon için Tablo 3.10'da ve 06088500 nolu istasyon için Tablo 3.11'de verilmiştir.

Tablo 3.10. 06088300 nolu istasyona ait en iyi modeller ve hata deęerleri.

Yöntem	Test Aşaması		Deęerlendirme Aşaması	
	KOKH (mg/L)	R ²	KOKH (mg/L)	R ²
BG	238.9	0.924	205.2	0.840
ANFIS	249.9	0.936	230.6	0.819
ÇKYSA	227.2	0.917	229.7	0.793
AE	719.8	0.437	462.4	0.365

Tablo 3.11. 06088500 nolu istasyona ait en iyi modeller ve hata deęerleri.

Yöntem	Test Aşaması		Deęerlendirme Aşaması	
	KOKH (mg/L)	R ²	KOKH (mg/L)	R ²
BG	279.2	0.965	284.0	0.917
ANFIS	594.5	0.846	298.4	0.909
ÇKYSA	391.6	0.944	310.0	0.901
AE	1074.4	0.767	774.3	0.484

Tablo 3.10'dan, en kötü tahmini AE yönteminin yaptığı, ANFIS yönteminin AE yöntemine göre daha iyi tahminler verdiği, BG ve ÇKYSA yöntemlerinin ANFIS ve AE yöntemlerine göre daha doğru tahminler yaptığı, bulanık kümelerin parametrelerinin ayarlanmasında genetik algoritma yaklaşımının ANFIS'teki melez yöntemden daha iyi sonuçlar verdiği görülmektedir. Ayrıca tablodan BG ve ÇKYSA yöntemlerinin daha tutarlı ve daha doğru tahminler yaptığı görülmektedir.

Tablo 3.11'den, en kötü tahmini AE yönteminin yaptığı, ANFIS yönteminin AE yöntemine göre daha doğru tahminler verdiği, ÇKYSA yönteminin ANFIS ve AE yöntemlerine göre daha doğru tahminler yaptığı, BG yönteminin de ÇKYSA, ANFIS ve AE yöntemlerine göre daha doğru tahminler yaptığı ve bulanık kümelerin parametrelerinin ayarlanmasında genetik algoritma yaklaşımının melez yöntemden daha iyi sonuçlar verdiği görülmektedir.

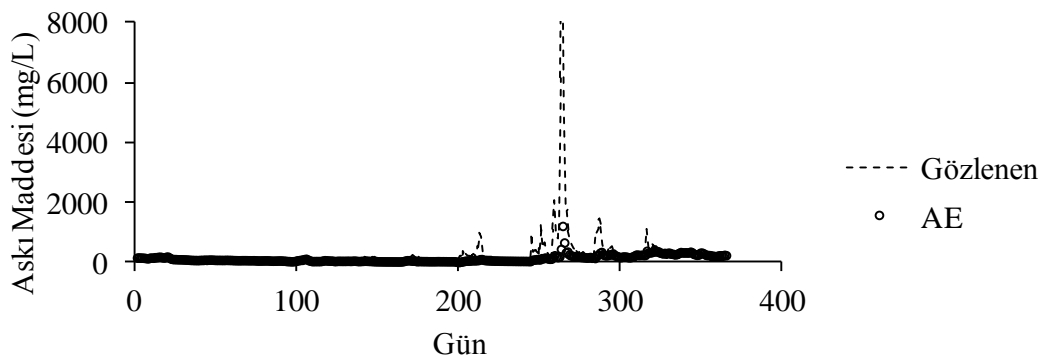



06088300 nolu istasyon için, en iyi modellere ait test ve deęerlendirme aşamalarındaki gidiş grafikleri sırasıyla Şekil 3.10 ve 3.11'de verilmiştir. Şekil 3.10 ve 3.11'de, BG

yaklaşımına ait modelin, test ve değerlendirme aşamalarında gözlenen pik değerleri için en iyi tahmini yaptığı ve AE modelinin ise en kötü tahmini yaptığı görülmektedir.





06088500 nolu istasyon için, en iyi modellere ait test ve değerlendirme aşamalarındaki gidiş grafikleri sırasıyla Şekil 3.12 ve 3.13'te verilmiştir. Şekillerden BG yaklaşımına ait modelin, özellikle değerlendirme aşamasında gözlenen pik değerleri için en iyi tahmini yaptığı ve AE modelinin ise pik değerleri yakalamada yetersiz kaldığı görülmektedir.

06088300 nolu istasyon için, çalışmada kullanılan yöntemlerin en iyi modellerine ait test ve değerlendirme aşamalarındaki saçılma grafikleri Şekil 3.14'te verilmiştir. Tahmin edilen değerler ile gözlenen değerlerin daha açık bir şekilde grafikte görünebilmesi için çift logaritmik ölçek kullanılmıştır. Şekil 3.14'te, BG yaklaşımına ait en iyi modelin tahminlerinin diğer yöntemlerin en iyi modellerine göre, test ve değerlendirme aşamalarında daha tutarlı bir dağılıma sahip olduğu görülmektedir. AE yöntemi hem test hem de değerlendirme aşamasında gözlenen değerlere daha uzak tahminler verdiği saçılma grafiklerinden açıkça görülmektedir.





06088500 nolu istasyon için, çalışmada kullanılan yöntemlerin en iyi modellerine ait test ve değerlendirme aşamalarındaki saçılma grafikleri Şekil 3.15'te verilmiştir. Şekilden BG yaklaşımının bir önceki istasyonda olduğu gibi diğer modellere göre daha iyi tahminler verdiği görülmektedir. En dağınık tahminler AE'e aittir. Saçılma grafiklerinden ÇKYSA'nın ANFIS'e göre daha başarılı olduğu söylenebilir.




Şekil 3.10. 06088300 nolu istasyona ait test aşaması gidiş grafikleri.




Şekil 3.11. 06088300 nolu istasyona ait değerlendirme aşaması gidiş grafikleri.




Şekil 3.12. 06088500 nolu istasyona ait test aşaması gidiş grafikleri.



Şekil 3.13. 06088500 nolu istasyona ait değerlendirme aşaması gidiş grafikleri.



Şekil 3.14. 06088300 nolu istasyona ait logaritmik saçılma grafikleri.



Şekil 3.15. 06088500 nolu istasyona ait logaritmik saçılma grafikleri.

4. BÖLÜM

SONUÇ-TARTIŞMA VE ÖNERİLER

Bu tez çalışmasında, bulanık genetik (BG) yaklaşımı, adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS), çok katmanlı yapay sinir ağı (ÇKYSA) ve anahtar eğrisi (AE) yöntemlerinin askı maddesi konsantrasyonun tahminindeki performansları incelenmiştir. Yöntemler, Amerika Birleşik Devletleri (ABD)'nin Montana eyaletinde bulunan ve ABD Jeolojik Araştırmalar Kurumu (USGS, United States Geological Survey) tarafından işletilen Muddy Çayı üzerindeki 06088300 ve 06088500 nolu istasyonlara ait akış ve askı maddesi konsantrasyonu verilerine uygulanmıştır. t anındaki askı maddesi konsantrasyonunu tahmin etmek için yedi farklı giriş senaryosu denenmiştir. Birinci senaryoda Q_t , ikinci senaryoda S_{t-1} , üçüncü senaryoda Q_t ve S_{t-1} , dördüncü senaryoda S_{t-1} ve S_{t-2} , beşinci senaryoda Q_t , S_{t-1} ve S_{t-2} , altıncı senaryoda Q_t , Q_{t-1} , Q_{t-2} ve S_{t-1} ve yedinci senaryoda Q_t , Q_{t-1} , Q_{t-2} , S_{t-1} ve S_{t-2} değerleri giriş olarak kullanılmıştır. Yapay zeka yöntemleri ile bulunan sonuçlar hem birbirleri ile hem de anahtar eğrisi yöntemi ile karşılaştırılmıştır.

Karşılaştırmalar sonucunda, BG yaklaşımının genel olarak ANFIS, ÇKYSA ve AE yöntemlerine göre daha tutarlı ve daha iyi tahminler yaptığı görülmüştür. 06088300 ve 06088500 nolu istasyonlara ait veriler için, yapay zeka yöntemleri kullanılarak kurulan modeller anahtar eğrisi yöntemleri ile kurulan modellere göre daha iyi tahminler yapmıştır. Ayrıca, giriş sayısı artırıldıkça BG yaklaşımının ANFIS yaklaşımına göre daha iyi tahminler verdiği görülmüştür.

Bazı akarsular için akış ve askı maddesi konsantrasyonu arasındaki ilişki iki kollu bir değişime sahiptir. Katı maddelerin büyük bir bölümünü akarsuyun havzasında taşınan yıkanmış maddeler oluşturmaktadır ve akım ile katı madde miktarı arasında her zaman

doğrusal bir ilişkiden söz edilemez. Bundan dolayı, yükselen akım seviyesindeki katı madde miktarı, aynı akımda düşme seviyesindeki katı madde miktarından fazla olabilir.

Akarsuyun herhangi bir andaki taşıdığı katı madde miktarı sadece o anki şartlara ait etkileri taşımaz, etkili hidrolojik değişkenlere ait geciken etkileri de taşımaktadır. Bundan dolayı iyi bir tahmin yapabilmek için bu geciken etkileri de göz önüne almak gerekir. AE yöntemi askı maddesi tahmini yaparken bu etkileri değil sadece t anındaki akış verilerini dikkate alır. Ancak, BG, ANFIS ve ÇKYSA yöntemleri t anındaki veriler ile birlikte geçmiş verileri de dikkate alarak daha iyi tahminler yapmaktadır.

Yapılan analizler sonucunda, BG yaklaşımının diğer yapay zeka yöntemlerine ve anahtar eğrisi yöntemine göre gözlenen değerlere daha yakın değerler verdiği ve daha düşük hata değerlerine sahip olduğu görülmüştür.

KAYNAKLAR

1. Elektrik İşleri Etüt İdaresi Genel Müdürlüğü, 2000. Sedimentasyonun önemi. (Web sayfası: <http://www.eie.gov.tr/turkce/YEK/HES/hidroloji/sedim.html>) Erişim tarihi: Ekim 2011.
2. Devlet Su İşleri Genel Müdürlüğü, 2011. 2010 Yılı Faaliyet Raporu. (Web sayfası: <http://www.dsi.gov.tr>) Erişim tarihi: Mayıs 2012.
3. Doğan, E., 2008. Akarsularda Taşınan Toplam Katı Madde Miktarının Yapay Zeka Metotları İle Tahmin Edilmesi. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Sakarya, 194 s.
4. Öztürk, F., Apaydın, H., Walling, D.E., 2001. Suspended sediment loads through flood events for streams of Sakarya basin. **Turkish Journal of Engineering and Environmental Sciences**, **25**:643-650.
5. Doğan, E., Şaşal, M., Işık, S., 2005. Suspended sediment load estimation in lower Sakarya river by using soft computational methods, 395-406. *Proceeding of the International Conference on Computational and Mathematical Methods in Science and Engineering, CMMSE 2005 Alicante, June 27-30, 2005, Spain.*
6. Cıgızoğlu, H.K., 2002. Suspended sediment estimation and forecasting using artificial neural networks. **Turkish Journal of Engineering and Environmental Sciences**, **26**:15-25.
7. Cıgızoğlu, H.K., 2002. Suspended sediment estimation for rivers using artificial neural Networks and sediment rating curves. **Turkish Journal of Engineering and Environmental Sciences**, **26**:27-36.
8. Jain, S.K., 2001. Development of integrated sediment rating curves using ANNs. **Journal of Hydraulic Engineering**, **127** (1): 30-37.
9. Kisi, Ö., Karahan, M.E., Şen, Z., 2003. Nehirlerdeki askı maddesi miktarının bulanık mantık ile modellenmesi. **İTÜ Dergisi**, **2**(3): 43-54.
10. Kişi, Ö., 2004. Daily suspended sediment modelling using a fuzzy differential evolution approach. **Hydrological Sciences Journal**, **49** (1): 183-197.

11. Kiři, Ö., 2004. Multi-layer perceptrons with Levenberg-Marquardt training algorithm for suspended sediment concentration prediction and estimation. **Hydrological Sciences Journal**, **49** (6): 1025-1040.
12. Kiři, Ö., 2005. Daily river flow forecasting using artificial neural networks and autoregressive models. **Turkish Journal of Engineering and Environmental Sciences**, **29**:9-20.
13. Kiři, Ö., Karahan, M.E., řen, Z., 2006. River suspended sediment modeling using fuzzy logic approach. **Hydrological Processes**, **20**: 4351-4362.
14. Çobaner, M., Ünal, B., Kiři, Ö., 2009. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network approaches using hydro-meteorological data. **Journal of Hydrology**, **367**: 52-61.
15. Rajae, T., Mirbagheri, S.A., Zounemeat-Kermani, M., Nourani, V., 2009. Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models. **Science of The Total Environment**, **407**(17):4916-4927.
16. Altunkaynak, A., 2009. Sediment load prediction by genetic algorithms. **Advances in Engineering Software**, **40**: 928-934.
17. Kiři, Ö., Fedakar, H.İ., 2011. Prediction of suspended sediment concentration using fuzzy-genetic approach, pp. 109-124, *Innovation as a Function of Engineering Development Conference, 25-26 November, 2011, Nis, Serbia*.
18. Baltacıođlu, A.K., Civalek, Ö., Akgöz, B., Korkmaz, A., 2010. Deprem hasarlarının hızlı tespitinde yapay sinir ađları yaklaşımı. **Mühendislik Bilimleri ve Tasarım Dergisi**, **1**, (1): 22-27.
19. Fırat, M., 2007. Sinirsel Bulanık Mantık Yaklaşımı İle Havza Modellemesi. Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Denizli, 184 s.
20. Elmas, Ç., 2007. Yapay Zeka Uygulamaları. Seçkin Yayıncılık, Ankara, 421 s.
21. Zadeh, L. A., 1965. Fuzzy sets. **Information and Control**, **8** (3): 338-353.
22. Kesler, S., 2006. Bilezikli Asenkron Makinaların Bilezikleri Üzerinden Bulanık Mantık Tabanlı Hız Denetiminin TMS320F2812 DSP İle Gerçekleştirilmesi. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Trabzon, 163 s.

23. Afşar, S., 2008. Yapay Sinir Ağları ve Bulanık Mantık Yöntemleri Kullanılarak Tava Buharlaştırma Tahmini Yapılması. Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri, 81 s.
24. Kıray, V., 1997 Oda içi sıcaklık ve hava kalitesinin mikrodenetleyici ve bulanık mantıkla kontrolü. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara, 80 s.
25. Yager, R. R., Zadeh, L. A., 1992. An Introduction to Fuzzy Logic Applications In Intelligent Systems. Kluwer Academic Publisher, Boston, 368 pp.
26. Gemici, E., 2011. Doğal Akarsularda Akımın Deneysel ve Bilgisayar Destekli Modellenmesi. Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri, 81 s.
27. Altaş, İ. H., 1997. A fuzzy logic controlled tracking system for moving targets, pp. 43-48, *12th IEEE International Symposium on Intelligent Control, ISIC'97, July 16-18, 1997, İstanbul.*
28. Yılmaz, M., Arslan, E., 2005. Bulanık mantığın jeodezik problemlerin çözümünde kullanılması, s. 512-522. *Harita ve Kadastro Mühendisleri Odası, Mühendislik Ölçmeleri STB Komisyonu 2. Mühendislik Ölçmeleri Sempozyumu, 23-25 Kasım, 2005, İstanbul.*
29. Şen, Z., 2001. Bulanık Mantık ve Modelleme İlkeleri. Bilge Sanat Yapım Yayınları, İstanbul, 168 s.
30. Elmas, Ç., 2003. Bulanık Mantık Denetleyiciler. Seçkin Yayıncılık, Ankara, 225 s.
31. Kıyak, E., Kahvecioğlu, A., 2003. Bulanık mantık ve uçuş kontrol problemine uygulanması. **Havacılık ve Uzay Teknolojileri Dergisi**, 1 (2): 63-72.
32. Piegat, A., 2001. Fuzzy Modeling and Control (Studies in Fuzziness and Soft Computing). Physica-Verlag Press, New York, 725 pp.
33. Baykal, N., Beyan, T., 2004. Bulanık Mantık İlke ve Temelleri. Bıçaklar Kitabevi, Ankara, 413 s.

34. Karadeniz, S., 2006. Çoklu Kompresör Sisteminin Bulanık Mantık İle Kontrolü. Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Denizli, 61 s.
35. Görgülü, Ö., 2007. Bulanık Mantık (Fuzzy Logic) Teorisi ve Tarımda Kullanım Olanakları Üzerine Bir Araştırma, Mustafa Kemal Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Hatay, 73 s.
36. Ross, T. J., 2005. Fuzzy Logic with Engineering Applications. Wiley Interscience, John Wiley & Sons, Inc., Hoboken, New Jersey, USA, 120 pp.
37. Mastorakis, N. E., 2004. General fuzzy systems as extensions of takagi sugeno methodology. **WSEAS Transactions on Systems**, **2** (3): 668-678.
38. Dualibe, C., Verleysen, M., ve Jespers, P. G., 2003. Design of Analog Fuzzy Logic Controllers in CMOS Technologies. Implementation, Test and Application. Kluwer Academic Publisher, Boston, USA, 227 pp.
39. Klun, I., Virant, J., 1999. Fuzzy logic alternative for analysis in the biomedical sciences. **Computers and Biomedical Research**, **32** (4): 305-321.
40. Şen, Z., 2004. Mühendislikte Bulanık Mantık İle Modelleme Prensipleri. Su Vakfı Yayınları, İstanbul, 190 s.
41. Haldenbilen, S., 2003. Genetik Algoritma Yaklaşımı İle Türkiye İçin Sürdürülebilir Ulaştırma Göstergelerinin Analizi ve Planlaması, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, Denizli, 146 s.
42. Papadrakakis, M., Lagaros, N.D., 1994. Advances in Sturctural Optimization, National Technical University, Zografu Campus, Institute of Structural Analysis and Seismic Research, GR-157 73, **Civil-Comp Press**, Athens, Greece.
43. Ceylan, H., Haldenbilen, S., 2005. Şehirler arası ulaşım talebinin genetik algoritma ile modellenmesi. **İMO Teknik Dergi**, **Yazı 238**: 3599-3618.
44. Yurtcu, Ş., İçağa, Y., 2006. Evrimsel algoritmaların inşaat mühendisliği sistemlerinde kullanımı. **Yapı Teknolojileri Elektronik Dergisi**: 51-59.
45. Bolat, B., Erol, K., İmrak, C., 2004. Genetic algorithms in engineering applications and the function of operators. **Journal of Engineering and Natural Sciences**: 264-265, Sigma.

46. Dengiz , B., Altıparmak, F., 1998. Genetik algoritmalar. **Gazi Üniversitesi Fen Bilimleri Enstitüsü Dergisi**, **11** (3): 523-541.
47. Luger, G.F., 2002. Artificial Intelligence, Structures and Strategies for Complex Problem Solving (4th Edition). Addison-Wesley, Harlow, England, 880 pages.
48. Goldberg, D.E., 1989. Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley, Mass, 432 pages.
49. Cheng, R., Gen, M., Tsujimura, Y., 1999. A tutorial survey of job-shop scheduling problems using genetic algorithms, part II: hybrid genetic search strategies. **Computers & Industrial Engineering**, **36** (2): 343-364.
50. Eksin, I., Erol, O.K., 2001. Evolutionary algorithm with modification in the reproduction phase. **IEE Proceedings-Software**, **148** (2): 75-80.
51. Kurt, M., Semetay, C., 2001. Genetik algoritma ve uygulama alanları. **Mühendis ve Makina**, **42** (501): 19-24.
52. Engin, O., 2001. Akış Tipi Çizelgeleme Problemlerinin Genetik Algoritma İle Çözüm Performansının Artırılmasında Parametre Optimizasyonu. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, İstanbul, 217 s.
53. Bekiroğlu, S., 2003. Genetik Algoritma İle Çelik Çerçevelerin Optimum Boyutlandırılması. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Trabzon, 84 s.
54. Emel, G., Taşkın, Ç., 2002. Genetik algoritmalar ve uygulama alanları. **Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, **21** (1): 29-152.
55. Erbatur, F., Hasançebi, O., Tütüncü, İ., Kılıç, H., 2000. Optimal design of planar and space structures with genetic algorithms. **Computers & Structures**, **75** (2): 209-224.
56. Cao, G., 1996. Optimized Design of Framed Structures Using a Genetic Algorithms. The University of Memphis, Ph. D. Dissertation.
57. Kılıç, M.H., 1997. Use of Genetic Algorithms in Frame Optimization. Orta Doğu Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara, 113s.

58. Pereira, R., 2000. Genetic algorithm optimisation for finance and investment. **La Trobe University, School of Business, Discussion Papers (Unpublished)**.
59. Genel, H., 2004. Genetik Algoritmalarla Portföy Optimizasyonu. Ankara Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Ankara, 86 s.
60. Jang, J. S. R., 1993. ANFIS adaptive-network-based-fuzzy inference systems. **IEEE Transactions on Systems, Man, And Cybernetics**, **23** (3): 665-685.
61. Demirel, Ö., Kakilli, A., Tektaş, M., 2010. ANFIS ve ARMA modelleri ile elektrik enerjisi yük tahmini. **Gazi Üniv. Müh. Mim. Fak. Der.**, **25** (3): 601-610.
62. Hocaoglu, F. O., Kurban, M., 2005. Adaptif ağ tabanlı bulanık mantık çıkarım sistemi ile Eskişehir bölgesi için güneşlenme süreleri tahmini . (Web sayfası: http://www.emo.org.tr/ekler/aea265a9054b3b8_ek.pdf) Erişim tarihi: Ekim 2011).
63. Özçalık, H. R., Uygur, A. F., 2003. Dinamik sistemlerin uyumlu sinirsel-bulanık ağ yapısına dayalı etkin modellenmesi. **KSÜ Fen ve Mühendislik Dergisi**, **6** (1): 36-46.
64. Öztemel, E., 2006. Yapay Sinir Ağları. Papatya Yayıncılık, İstanbul, 220 s.
65. Şen, Z., 2004. Yapay Sinir Ağları İlkeleri. Su Vakfı Yayınları, İstanbul, 183 s.
66. Tsoukalas, L.H., Uhrig, R.E., 1997. Fuzzy and Neural Approaches in Engineering, John Wiley & Sons, Inc. Publishing, New York, USA, 566 pp.
67. AMIT, D.J., 1989. Modelling Brain Function. Cambridge University Press, New York, 504 pp.
68. Anderson, J. A., 1983. Cognitive and psychological computation with neural models. **IEE Transactions on Systems, Man and Cybernetics**, **13**: 799-814.
69. Akkurt, S., Ozdemir, S., Tayfur, G., Akyol, B., 2003. The use of GA-ANNs in the modelling of compressive strength of cement mortar. **Cement and Concrete Research**, **33** (7): 973-979.
70. Liu, S.W., Huang, J.H., Sung, J.C., Lee, C.C., 2002. Detection of cracks using neural networks and computational mechanics. **Computer Methods in Applied Engineering**, **191** (25-26): 2831-2845.

71. Topçu, İ.B., Sarıdemir, M., 2007. Prediction of properties of waste AAC aggregate concrete using artificial neural networks. **Computational Materials Science**, **41** (1): 117-125.
72. Topçu, İ.B., Sarıdemir, M., 2008a. Prediction of compressive strength of concrete containing fly ash using artificial neural network and fuzzy logic. **Computational Materials Science**, **41** (3): 305-311.
73. Topçu, İ.B., Sarıdemir, M., 2008b. Prediction of rubberized concrete properties using artificial neural network and fuzzy logic. **Construction and Building Materials**, **22** (4): 532-540.
74. Demir, F., Korkmaz, K.A., 2008. Prediction of lower and upper bounds of elastic modulus of high strength concrete. **Construction and Building Materials**, **22** (7): 1385-1393.
75. Öztaş, A., Pala, M., Özbay, E., Kanca, E., Çağlar, N., Ashgar Bhatti, M., 2006. Predicting the compressive strength and slump of high strength concrete using neural network. **Construction and Building Materials**, **20** (9): 769-775.
76. Pala, M., Özbay, E., Öztaş, A., Yüce, M.I., 2007. Appraisal of long-term effects of fly ash and silica fume on compressive strength of concrete by neural networks. **Construction and Building Materials**, **21** (2): 384-394.
77. Topçu, İ.B., Sarıdemir, M., 2008c. Prediction of mechanical properties of recycled aggregate concretes containing silica fume using artificial neural networks and fuzzy logic. **Computational Materials Science**, **42** (1): 74-82.
78. Topçu, İ.B., Sarıdemir, M., 2008d. Prediction of rubberized mortar properties using artificial neural networks and fuzzy logic. **Journal of Materials Processing Technology**, **199** (1-3): 108-118.
79. Arbib, M.A., 1995. The handbook of brain theory and neural networks. *Cambridge (MA): MIT Press: 738-741.*
80. Keleşoğlu, Ö., Fırat, A., 2006. Çatı döşemesinde meydana gelen yoğuşma ve buharlaşma kütlelerinin yapay sinir ağlar ile tahmin edilmesi. **Selçuk Üniversitesi Mühendislik-Mimarlık Dergisi**, **21** (1-2): 49-56.

81. Keleşoğlu, Ö., Akarsu, E.E., 2008. Betonarme bir binada yıllık ısı kaybı ve enerji ihtiyacının yapay sinir ağları ile belirlenmesi. **e-Journal of New World Sciences Academy Natural and Applied Sciences**, **3** (2): 381-390.
82. Kakıcı, A., 2009. Yapay sinir ağlarının sınıflandırılması. (Web sayfası: <http://www.ahmetkakici.com/yapay-sinir-aglari/yapay-sinir-aglarinin-siniflandirilmesi/>) Erişim tarihi: Ekim 2011).
83. Sağıroğlu, Ş., Beşdok, E., Erler, M., 2003. Mühendislikte Yapay Zeka Uygulamaları-I. Yapay Sinir Ağları, Ufuk Kitabevi, Kayseri, 422 s.
84. Kosko, B., 1990. Unsupervised learning in noise. **IEE Transactions on Neural Networks**, **1**: 44-57.
85. Hecht-Neilsen, R., 1989. Neurocomputing. Addison-Wesley Pub. Comp., Massachusetts, 421 pp.
86. Seyman, M. N., Taşpınar, N., 2009. Çok katmanlı yapay sinir ağları kullanılarak OFDM sistemlerinde kanal dengeleme, s. 630-633. *5.Uluslararası İleri Teknolojiler Sempozyumu (IATS'09), 13-15 Mayıs, 2009, Karabük.*
87. Dur, E., Temeltaş, H., Kurnaz, S., 2009. Optik akışın hesaplanması ve yapay sinir ağları ile yorumlanarak mobil robotlar için engel tespiti ve kaçınma davranışında kullanılması. **Havacılık ve Uzay Teknolojileri Dergisi**, **4** (1): 77-87.
88. Çetin, M., Uğur, A., Bayzan, Ş., 2006. İleri beslemeli yapay sinir ağlarında backpropagation (geriye yayılım) algoritmasının sezgisel yaklaşımı. *IV. Bilgitek ve Akademik Bilişim Kongresi, 6-11 Şubat 2006, Denizli.*
89. Bayındır, R., Sesveren, Ö., 2008. YSA tabanlı sistemler için görsel bir arayüz tasarımı. **Pamukkale Üniversitesi Mühendislik Fakültesi, Mühendislik Bilimleri Dergisi**, **14** (1): 101-109.
90. Marquardt, D., 1963. An algorithm for least squares estimation of non-linear parameters. **Journal of the Society for Industrial and Applied Mathematics**, **11** (2): 431-441.
91. Suratgar, A. A., Tavakoli, M. B., Hoseinabadi, A., 2005. Modified levenberg-marquardt method for neural networks training. **World Academy of Science, Engineering and Technology**, **6** (6): 46-48.

92. Tolon, M., Güneri Tosunoğlu, N., 2008. Tüketici tatmini verilerinin analizi: Yapay sinir ağları ve regresyon analizi karşılaştırması. **Gazi Üniversitesi İİBF Dergisi**, **2** (10): 247-259.
93. Elmas, Ç., 2003. Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama). Seçkin Yayınları, Ankara, 192 s.
94. Yıldız, B., 1999. Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Ampirik Bir Uygulama. Dumlupınar Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Kütahya, 201 s.
95. Güneri, N., Apaydın, A., 2004. Öğrenci başarılarının sınıflandırılmasında lojistik regresyon analizi ve sinir ağları yaklaşımı. **Ticaret ve Turizm Eğitim Fakültesi Dergisi**, **1**: 170-188.
96. Minarecioğlu, N., 2008. Doğal Akarsularda Taşınan Katı Madde Miktarının Yapay Zeka Yöntemleri Kullanılarak Tahmin Edilmesi. Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri, 81 s.
97. Crawford, C.G., 1991. Estimation of suspended-sediment rating curves and mean suspended-sediment loads. **Journal of Hydrology**, **129** (1-4): 331-348.
98. VanSickle, J., Beschta, R.L., 1983. Supply-based models of suspended sediment transport in streams. **Water Resources Research**, **19** (3): 768-778.
99. Salas, J.D., Shin, H.S., 1999. Uncertainty analysis of reservoir sedimentation. **Journal of Hydraulic Engineering**, **125**: 339-350.
100. Demiröz E., 1989. Sediment sampling activities in Turkey. *Fourth International Symposium on River Sedimentation, November 1-5, 1989, Beijing, China.*
101. Williams, J.R., 1978. A sediment graph model based on an instantaneous unit sediment graph. **Water Resources Research**, **14**: 659-664.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı: Halil İbrahim FEDAKAR
Uyruğu: Türkiye (TC)
Doğum Tarihi ve Yeri: 19 Şubat 1986, Kahramanmaraş
Medeni Durumu: Evli
Tel: 0505 695 26 37
email: hifem@hotmail.com
Yazışma Adresi: Şahintepe Mahallesi 133387 Sokak Yenibahar Sitesi C Blok 3/6,
27470 Şahinbey/GAZİANTEP

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lisans	Ç.Ü. M.M.F. İnşaat Müh.	2008
Lise	Fatih Y.D.A Lisesi, Kahramanmaraş	2004

YABANCI DİL

İngilizce

YAYINLAR

1. Kisi, O., Fedakar, H.I., "Prediction of Suspended Sediment Concentration Using Fuzzy-Genetic Approach", Innovation as a Function of Engineering Development Conference, 25-26 November, Nis, Serbia, ss 109-124, (2011).