



**YAPAY SİNİR AĞLARI ALGORİTMASI KULLANILARAK
AKARSU HAVZALARINDA YAĞIŞ-AKIŞ-KATI MADDE
İLİŞKİSİNİN BELİRLENMESİ**

Onur ÖCAL

**Temmuz 2007
DENİZLİ**

**YAPAY SİNİR AĞLARI ALGORİTMASI KULLANILARAK
HAVZALARDA YAĞIŞ – AKIŞ - KATI MADDE İLİŞKİSİNİN
BELİRLENMESİ**

Pamukkale Üniversitesi

Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi

İnşaat Mühendisliği Anabilim Dalı

Onur ÖCAL

Danışman: Yrd. Doç. Dr. Mahmud GÜNGÖR

Temmuz 2007

DENİZLİ

YÜKSEK LİSANS TEZİ ONAY FORMU

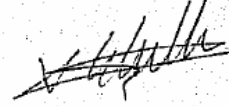
Onur ÖCAL tarafından Yrd. Doç. Dr. Mahmud GÜNGÖR yönetiminde hazırlanan “**Yapay Sinir Ağları Algoritması Kullanılarak Akarsu Havzalarında Yağış – Akış – Katı Madde İlişkisinin Belirlenmesi**” başlıklı tez tarafımızdan okunmuş, kapsamı ve niteliği açısından bir Yüksek Lisans Tezi olarak kabul edilmiştir.



Prof. Dr. Bekir SOLMAZ
Jüri Başkanı



Yrd. Doç. Dr. Mahmud GÜNGÖR
Jüri Üyesi (Danışman)




Yrd. Doç. Dr. A. Cem KOÇ
Jüri Üyesi

Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
.../.../.... Tarih vesayılı kararıyla onaylanmıştır.

Prof. Dr. Mehmet SARIGÖL
Müdür

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmaların yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu çalıřmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan çalıřmalara atfedildiđini beyan ederim.

İmza : 

Öğrenci Adı Soyadı : Onur ÖCAL

TEŐEKKÜR

Bu alıőmayı yöneten ve alıőmanın her aőamasında deęerli bilgilerinden istifade ettięim, yakın ilgisini esirgemeyen saygı deęer hocam **Yrd. Do. Dr. Mahmud GÜNGÖR**' e teőekkürlerimi arz ederim.

Yapay sinir aęları ilgili alıőmalarım sırasında her konuda deęerli yardımlarını esirgemeyen **Arő. Gör. Dr. Mahmud FIRAT**' a teőekkür eder őükranlarımı sunarım.

Yüksek lisans alıőmamın bütün safhalarında her türlü maddi ve manevi desteklerini esirgemeyen kıymetli büyüklerime, aileme ve emeęi geen herkese teőekkür ederim.

Onur ÖCAL

ÖZET

YAPAY SİNİR AĞLARI ALGORİTMASI KULLANILARAK AKARSU HAVZALARINDA YAĞIŞ-AKIŞ-KATI MADDE İLİŞKİSİNİN BELİRLENMESİ

ÖCAL, Onur

Yüksek Lisans Tezi, İnşaat Mühendisliği ABD.
Tez Yöneticisi: Yrd. Doç. Dr. Mahmud GÜNGÖR

Temmuz 2007, 93 Sayfa

Akarsular tarafından taşınan katı madde miktarlarına ait değerler, öncelikle biriktirme haznelerinin planlanması ve işletilmesi ve ayrıca havzanın erozyon karakteristiklerinin belirlenmesinde kullanılmaktadır. Taşınan katı madde miktarı su kaynaklarının yönetimi ve planlanması içinde önemli bir parametredir.

Yukarıda bahsedilen bu sorunlardan dolayı yağış, akış ve katı madde taşınımı gibi hidrolojik olaylar arasındaki doğrusal olmayan dinamik ilişki doğru ve güvenilir bir biçimde belirlenmelidir.

Yapılan bu çalışmada yapay sinir ağları yönteminin akarsularda katı madde miktarının tahmin edilmesinde kullanılabilirliği araştırılmıştır. Uygulama alanı olarak Büyük Menderes Nehri üzerinde bulunan Yukarı Büyük Menderes Alt Havzası ve Banaz Çayı Alt Havzası seçilmiştir. Yapay sinir ağları yöntemi ile bu havzalarda farklı giriş yapısına sahip katı madde tahmin modelleri geliştirilmiştir. Yapay sinir ağları sonuçları, gözlem değerleri ile karşılaştırılmış ve performansları uygunluk kriterleri ile değerlendirilmiştir. Elde edilen sonuçlar Yapay Sinir Ağları yönteminin katı maddenin modellenmesinde ve tahmininde başarılı bir şekilde uygulanabileceğini göstermiştir.

Anahtar Kelimeler: Yağış, Akış, Katı Madde, Yapay Sinir Ağları

Prof. Dr. Bekir SOLMAZ
Yrd. Doç. Dr. Mahmud GÜNGÖR
Yrd. Doç. Dr. A. Cem KOÇ

ABSTRACT

DETERMINATION OF RAINFALL - RUNOFF – SEDIMENT TRANSPORT RELATIONSHIP IN WATERSHEDS BY USING ARTIFICIAL NEURAL NETWORK ALGORITHM

ÖCAL, Onur

M.Sc. Thesis in Civil Engineering

Supervisor: Asist. Prof. Dr. Mahmud GÜNGÖR

Temmuz 2007, 93 Pages

Sediment yield carried in a stream is used for planning reservoirs and also for defining erosion characteristics of a basin. This is also an effective parameter for managing and planning water resources.

Because of these problems which were explained above, the nonlinear dynamic relationship between hydrological events such as rainfall, runoff and sediment yield, have to be determined truly and certainly.

In this study, the employability of artificial neural networks for estimating sediment yield carried in a stream have been researched. For application area, Up Menderes Subbasin and Banaz Çayı Subbasin were selected. Sediment yield forecasting models having various input structures were developed using Artificial Neuroal Networks. The results of the neural networks and observed values were compared and performances were assessed by fitness criterias. The results of ANN models have shown that ANN can be applied successfully and provides high accuracy and reliability for sediment yield forecasting.

Keywords: Rainfall, Runoff, Sediment Yield, Artificial Neural Networks

Prof Dr. Bekir SOLMAZ

Asist Prof. Dr. Mahmud GÜNGÖR

Asist Prof. Dr. A. Cem KOÇ

İÇİNDEKİLER

	Sayfa
YÜKSEK LİSANS TEZİ ONAY FORMU.....	i
BİLİMSEL ETİK SAYFASI.....	ii
TEŞEKKÜR.....	iii
ÖZET.....	iv
ABSTRACT.....	v
İÇİNDEKİLER	vi
ŞEKİLLER DİZİNİ.....	viii
TABLolar DİZİNİ.....	x
SİMGE VE KISALTMALAR DİZİNİ.....	xi
1. GİRİŞ.....	1
2. LİTERATÜR TARAMASI.....	3
2.1. Akarsularda Katı Madde Hareketi.....	3
2.2. Katı Madde Hareketindeki Boyutsuz Büyüklükler.....	4
2.3. Taban Hareketinin Başlaması	6
2.4. Askı Maddesi Taşınımı	10
2.5. Sürüntü Maddesi Taşınımı.....	15
2.6. YSA ile Yapılmış Katı Madde Tahmin Çalışmaları.....	16
3. MATERYAL VE YÖNTEM.....	24
3.1. Giriş.....	24
3.2. Yapay Sinir Ağları (YSA).....	24
3.3. Biyolojik Sinir Sistemi	26
3.4. Yapay Nöronlar.....	27
3.5. Sigmoid Aktivasyon Fonksiyonu.....	29
3.6. YSA’larda Öğrenme Algoritmaları.....	30
3.6.1. Hatayı geriye yayma algoritması.....	30
3.6.1.1. Çıktı katmanındaki ağırlıkların düzenlenmesi	32
3.6.1.2. Gizli katman ağırlık değerlerinin düzenlenmesi.....	35
3.6.1.3. Algoritmanın sorunları ve çözüm önerileri.....	37
3.6.1.3.1. Öğrenme hızı.....	37
3.6.1.3.2. Anlık sıçramalar.....	38
3.6.2. Levenberg-Marquardt algoritması.....	38
3.7. YSA’larda Öğrenme.....	38
3.7.1. Denetimli öğrenme.....	39
3.7.2. Denetimsiz öğrenme.....	39
3.7.3. Takviyeli öğrenme	40
3.8. YSA Mimarileri	40
3.8.1. Geri beslemeli yapay sinir ağları (GBYSA).....	41
3.8.2. İleri beslemeli yapay sinir ağları (İBYSA).....	41
3.8.3. Radyal tabanlı yapay sinir ağları (RTYSA).....	42
3.8.4. Diğer YSA mimarileri.....	42
4. ÇALIŞMA ALANI VE VERİ.....	43
4.1. Büyük Menderes Havzası.....	43
4.2. Banaz Çayı.....	43
4.3. Veri.....	44

5. KATI MADDE TAHMİN MODELLERİ.....	48
5.1. Giriş	48
5.2. Giriş Değişkenlerinin Belirlenmesi.....	48
5.3. Veri Gruplarının Analizi.....	52
5.4. Veri Gruplarının Ön İşleme Tabi Tutulması.....	55
5.5. Tahmin Modellerinin Geliştirilmesi.....	57
5.6. YSA'ların Eğitimi.....	59
5.7. YSA'ların Test Edilmesi.....	62
5.8. YSA'ların Sorgulanması.....	73
5.9. YSA Sonuçlarının MLR Modelleri ile Karşılaştırılması.....	84
6. SONUÇLAR.....	88
KAYNAKÇA	90
ÖZGEÇMİŞ.....	93

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1 Katı maddenin su derinliğine bağlı dağılımı (Özbek ve Özcan 2001).....	3
Şekil 2.2 Dengedeki dane (Özbek ve Özcan 2001).....	5
Şekil 2.3 Shields eğrisi (Özbek ve Özcan 2001).....	7
Şekil 2.4 Akarsu tabanındaki bir daneye etki eden kuvvetler (Güngör 1997).....	8
Şekil 2.5 Bir akarsu en kesitindeki hız, katı madde konsantrasyonu ve katı madde debisinin derinliğe göre değişimi.....	11
Şekil 2.6 Askı maddesi hesabında kullanılan rölatif konsantrasyon değerleri (Özbek ve Özcan2001).....	14
Şekil 3.1 Biyolojik sinir hücresi ve bileşenleri (Yaşar 2004).....	26
Şekil 3.2 Yapay nöronun genel yapısı (Yurtoğlu 2005).....	27
Şekil 3.3 Sigmoid tipli aktivasyon fonksiyonu (Fırat ve Güngör 2004).....	29
Şekil 3.4 YSA’lardaki katmanlar (Anderson ve McNeill 1992).....	30
Şekil 3.5 Denetimli öğrenme yapısı (Saraç 2004).....	39
Şekil 3.6 Denetimsiz öğrenme yapısı (Saraç 2004).....	40
Şekil 3.7 Takviyeli öğrenme yapısı (Saraç 2004).....	40
Şekil 3.8 Geri beslemeli iki katmanlı YSA yapısı.....	41
Şekil 3.9 İleri beslemeli üç katmanlı YSA yapısı (Saraç 2004).....	42
Şekil 3.10 RTYSA yapısı.....	42
Şekil 4.1 Büyük Menderes havzası genel yapısı.....	43
Şekil 4.2 Büyük Menderes havzasının alt havzaları (Fırat 2007).....	44
Şekil 4.3 Büyük Menderes havzasına ait YAGİ’ler (Fırat 2007).....	46
Şekil 5.1 Veri gruplarının analizi.....	54
Şekil 5.2 Girdi değişkenlerinin ölçeklendirilmesi.....	56
Şekil 5.3 713 Nolu AGİ’deki test verileri için I. tip modellerin sonuçları.....	64
Şekil 5.4 713 Nolu AGİ’deki test verileri için II. tip modellerin sonuçları.....	64
Şekil 5.5 713 Nolu AGİ’deki test verileri için III. tip modellerin sonuçları.....	65
Şekil 5.6 735 Nolu AGİ’deki test verileri için I. tip modellerin sonuçları.....	65
Şekil 5.7 735 Nolu AGİ’deki test verileri için II. tip modellerin sonuçları.....	66
Şekil 5.8 735 Nolu AGİ’deki test verileri için III. tip modellerin sonuçları.....	66
Şekil 5.9 713 Nolu AGİ’deki en uygun I. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	67
Şekil 5.10 713 Nolu AGİ’deki en uygun II. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	68
Şekil 5.11 713 Nolu AGİ’deki en uygun III. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	69
Şekil 5.12 735 Nolu AGİ’deki en uygun I. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	70
Şekil 5.13 735 Nolu AGİ’deki en uygun II. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	71
Şekil 5.14 735 Nolu AGİ’deki en uygun III. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	72
Şekil 5.15 713 Nolu AGİ’deki eğitim verileri için I. tip modellerin sonuçları....	75
Şekil 5.16 713 Nolu AGİ’deki eğitim verileri için II. tip modellerin sonuçları....	75
Şekil 5.17 713 Nolu AGİ’deki eğitim verileri için III. tip modellerin sonuçları....	76
Şekil 5.18 735 Nolu AGİ’deki eğitim verileri için I. tip modellerin sonuçları.....	76

Şekil 5.19	735 Nolu AGİ'deki eğitim verileri için II. tip modellerin sonuçları.....	77
Şekil 5.20	735 Nolu AGİ'deki eğitim verileri için III. tip modellerin sonuçları.....	77
Şekil 5.21	713 Nolu AGİ'deki en uygun I. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	78
Şekil 5.22	713 Nolu AGİ'deki en uygun II. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	79
Şekil 5.23	713 Nolu AGİ'deki en uygun III. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	80
Şekil 5.24	735 Nolu AGİ'deki en uygun I. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	81
Şekil 5.25	735 Nolu AGİ'deki en uygun II. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	82
Şekil 5.26	735 Nolu AGİ'deki en uygun III. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması.....	83
Şekil 5.27	713 Nolu AGİ'deki test verileri kullanılarak geliştirilen en uygun II.tip model için elde edilen YSA sonuçları ile MLR sonuçlarının karşılaştırılması.....	86
Şekil 5.28	713 Nolu AGİ'deki eğitim verileri kullanılarak geliştirilen en uygun II.tip model için elde edilen YSA sonuçları ile MLR sonuçlarının Karşılaştırılması.....	86
Şekil 5.29	735 Nolu AGİ'deki test verileri kullanılarak geliştirilen en uygun I.tip model için elde edilen YSA sonuçları ile MLR sonuçlarının karşılaştırılması.....	87
Şekil 5.30	735 Nolu AGİ'deki eğitim verileri kullanılarak geliştirilen en uygun I.tip model için elde edilen YSA sonuçları ile MLR sonuçlarının karşılaştırılması.....	87

TABLOLAR DİZİNİ

	Sayfa
Tablo 2.1 Katı madde hareketinde fiziksel büyüklükler (Özbek ve Özcan 2001).....	4
Tablo 4.1 Çalışma alanındaki AGİ'ler.....	45
Tablo 4.2 AGİ'lere ait akış verilerinin yapısı	45
Tablo 4.3 Katı madde tahmininde kullanılan 713 Nolu AGİ'ye ait verilerin yapısı	45
Tablo 4.4 Katı madde tahmininde kullanılan 735 Nolu AGİ'ye ait verilerin yapısı.....	45
Tablo 4.5 Tahminler için kullanılan katı madde gözlem istasyonları.....	46
Tablo 4.6 Tahminlerde kullanılacak katı madde verilerinin yapısı.....	46
Tablo 4.7 17824 Nolu YAGİ'ye ait yağış verilerinin yapısı.....	47
Tablo 4.8 713 Nolu AGİ için tahminlerde kullanılacak yağış verilerinin yapısı.....	47
Tablo 4.9 735 Nolu AGİ için tahminlerde kullanılacak yağış verilerinin yapısı.....	47
Tablo 5.1 YAGİ ve AGİ'lere ait otokorelasyon katsayıları.....	49
Tablo 5.2 713 Nolu istasyondaki katı madde tahmini için korelasyonlar.....	49
Tablo 5.3 735 Nolu istasyondaki katı madde tahmini için korelasyonlar.....	50
Tablo 5.4 713 Nolu AGİ için kurulan katı madde tahmin modelleri.....	50
Tablo 5.5 735 Nolu AGİ için kurulan katı madde tahmin modelleri.....	51
Tablo 5.6 En uygun yapının araştırılması için ayrılan farklı giriş değişkenleri.....	53
Tablo 5.7 Mimariyi araştırmada kullanılan ağ parametreleri.....	58
Tablo 5.8 713 ve 735 Nolu AGİ'ler için bulunan veri kümesi yapıları ve ağ mimarileri.....	59
Tablo 5.9 Eğitim için girdi verilerinin veri sayısına göre alt kümelere ayrılması.....	59
Tablo 5.10 713 Nolu AGİ için eğitim sonucu bulunan öğrenme ve momentum katsayıları.....	61
Tablo 5.11 735 Nolu AGİ için eğitim sonucu bulunan öğrenme ve momentum katsayıları.....	61
Tablo 5.12 713 Nolu AGİ'ye ait test verileri için model davranışları.....	62
Tablo 5.13 735 Nolu AGİ'ye ait test verileri için model davranışları.....	63
Tablo 5.14 713 Nolu AGİ'ye ait eğitim verileri için model davranışları.....	73
Tablo 5.15 735 Nolu AGİ'ye ait eğitim verileri için model davranışları.....	74
Tablo 5.16 713 Nolu AGİ için YSA ve MLR modellerinin karşılaştırılması.....	84
Tablo 5.17 735 Nolu AGİ için YSA ve MLR modellerinin karşılaştırılması.....	84
Tablo 5.18 713 Nolu AGİ için geliştirilen MLR denklemleri.....	85
Tablo 5.19 735 Nolu AGİ için geliştirilen MLR denklemleri.....	85

SİMGE VE KISALTMALAR DİZİNİ

AGİ	Akım gözlem istasyonu
C	Askı maddesi konsantrasyonu
Ca	İntegrasyon sabiti
C_D	Sürünme kuvveti direnç katsayısı
C_L	Kaldırma kuvveti direnç katsayısı
C_0	Ortalama konsantrasyon
D	Dane çapı
D.M.İ	Devlet Meteoroloji İşleri
d_k	Gerçek çıktı değeri
E.İ.E.İ	Elektrik İşleri Etüd İdaresi
F_D	Hidrodinamik sürüklenme kuvveti
F_L	Hidrodinamik kaldırma kuvveti
Fr	Froude sayısı
Fr^*	Dane sürüklenme Froude sayısı
g	Yerçekimi ivmesi
G'	Ağırlık kuvveti (Danenin su altındaki ağırlığı)
GYA	Geriye yayılım algoritması
h	Su derinliği
h	Gizli katman
I	Akarsu taban eğimi
KHOK	Karesel Hatanın Ortalama Karekökü
k_s	Pürüzlülük yüksekliği
L	Akarsu boyuna eğimi
LM	Levenberg – Marquardt algoritması
MLR	Çok değişkenli lineer regresyon
OMRH	Ortalama mutlak rölatif hata
Q_A	Askı maddesi debisi
q_A	Askı maddesi birim debisi
q_s	Sürüntü maddesi birim debisi
R	Korelasyon
R	Hidrolik yarıçap
Re	Reynoulds sayısı
Re^*	Sürüklenme Reynoulds sayısı
RTYSA	Radyal tabanlı yapay sinir ağları
R^2	Belirleme katsayısı

SF	Ölçeklendirme faktörü
SR_{\max}	Maksimum limit
SR_{\min}	Minimum limit
v^*	Dane sürüklenme hızı
\bar{v}	Ortalama hız
W	Ağırlıklar matrisi
w	Düşme hızı
w_{ij}	i. nöronu j. nörona bağlayan ağırlık katsayısı
W_s	Dengedeki danenin ağırlığı
X	Girişler matrisi
X	Numerik kolonun şimdiki değeri
X_{\max}	Numerik kolonun maksimum değeri
X_{\min}	Numerik kolonun minimum değeri
YAGİ	Yağış gözlem istasyonu
Y_k	Tahmin edilen çıktı
YSA	Yapay sinir ağları
o	Çıkış değeri
θ_j^k	Eğim değeri
τ_0	Tabandaki kayma gerilmesi
η	Öğrenme hızı
μ	Momentum terimi
δ_{pk}^o	Çıktı katmanındaki toplam hata
$\varphi(S)$	Transfer aktivasyon işlevi
φ	Hız oranı
ρ_s	Özgül kütle
ϕ	Sürüntü maddesi debisi (boyutsuz)
ρ	Özkütle
ψ	Shields parametresi
κ	Karman sabiti
θ_i	i. nörona ait aktivasyon işlevinin eşik değeri
ν	Viskozite
τ_{kr}	Kritik sürüklenme gerilmesi
τ_0	Tabanda oluşan kayma gerilmesi
δ	Laminer sınır tabakası kalınlığı
ε_s	Askı maddesi difüzyon karışım katsayısı
α	Çökelme hızı parametresi
Δ	Katı maddenin su içindeki rölatif özgül kütlesi

1. GİRİŞ

Akarsular üzerinde, gerek içme ve kullanma, gerekse enerji üretimi ve taşkın kontrolü gibi çok çeşitli amaçlarla barajlar yapılmaktadır. Hangi amaca yönelik olursa olsun, katı madde bilgisinin azlığından dolayı bu yapıların havzalarını besleyen akarsuların getirdiği toprak, kum, çakıl, silt ve kil gibi katı maddeler baraj göllerini doldurmakta, depolama kapasitelerini azaltmakta ve bunun sonucu olarak ekonomik ömürleri kısaltmaktadır. Ayrıca, tarımsal ekonomimizin en önemli üretim kaynaklarından birisi olan toprağın üst tabakasının yok olmasına da neden olmaktadır. Bu olayların doğal sonucu olarak ta, çıplaklaşan ve çoraklaşan ülke topraklarındaki taşınım olayları ile birlikte işlenebilir tarım arazilerinin yok olması, çok amaçlı su yapılarının elden çıkması ve çevre kirliliği gibi sorunlar gündeme gelmektedir.

Unutulmamalıdır ki akarsular tarafından taşınan katı madde miktarlarına ait değerler, öncelikle baraj, bağlama ve mahmuzlar gibi su yapılarının boyutlandırılmasında ve ölü hacmin hesaplanmasında kullanılmaktadır. Ayrıca katı madde miktarı, havzanın erozyon karakteristiklerinin belirlenmesine de ışık tutmaktadır.

Yukarıda bahsedilen bu sorunlardan dolayı yağış, akış ve katı madde taşınımı gibi hidrolojik olaylar arasındaki doğrusal olmayan dinamik ilişki doğru ve güvenilir bir biçimde belirlenmelidir. Bu ilişkideki her bir hidrolojik olguyu etkileyen birçok değişkenin oluşu problemi daha karmaşık bir hale getirmektedir.

Son yıllarda bu şekilde karmaşık ve doğrusal olmayan olayların çözümünde yapay zeka teknikleri olarak ta bilinen *yapay sinir ağları* ve *bulanık mantık* gibi yöntemler kullanılmaktadır.

Bu yöntemler, veri kümesinin karakteristiğine bağlı olarak istenen sonuçları öğrenme yoluyla elde eden tekniklerdir. Bu özellikleri sayesinde havzaya ait fiziksel özelliklere ihtiyaç duyulmamaktadır.

Yapılan bu tez çalışmasında, Büyük Menderes Havzası'ndaki Adıgüzel Barajı'nı besleyen Büyük Menderes Nehri ve Banaz Çayı yoluyla taşınan katı madde miktarının yağış ve akış gözlemlerine bağlı olarak YSA yöntemiyle tahmin edilmesi amaçlanmaktadır.

Çalışmalar kapsamında kullanılan akım ve katı madde ölçümleri Elektrik İşleri Etüt İdaresi'nden (E.İ.E.İ) ve yağış ölçümleri de Devlet Meteoroloji İşleri'nden (D.M.İ) temin edilmiştir.

Tez çalışması genel anlamda giriş, akarsularda katı madde taşınımını konu alan literatür bilgisi, kullanılan materyal ve yöntem, çalışma alanı ve veriler, yağış ve akış gözlemlerine bağlı katı madde tahmin modelleri ile sonuçlar kısmından oluşmaktadır.

Çalışmanın ilk kısmında akış verilerinin geçmiş günlere bağlı etkisini ve aynı şekilde yağış verilerinin zemin neminden kaynaklanan etkisi ile yağışın akışa geçiş süresini dikkate almak için serilerin geçmiş zamanlara ait verileri de dikkate alınmış ve bu şekilde ağların girdi değişkenleri belirlenmiştir. Bu etkileri dikkate almak için akış ve yağış serilerinin içsel korelasyonları hesaplanmıştır. Ayrıca bulunan bu girdi değişkenleri ile katı madde miktarı arasındaki çapraz korelasyona bakılarak değişkenler arası ilişkisinin mertebesi araştırılmıştır.

İkinci aşamada ise, veri gruplarının karakteristik yapısını kavramak ve doğru ağ mimarisinin tasarımı için, veri grupları çapraz onaylama tekniği (cross validation) uygulanarak dört farklı şekilde kümeler ayrılmış ve öğrenme, onaylama ve test kümeleri için öngörülerek karşılaştırmalı olarak incelenmiştir. En iyi sonuçları veren seçenek mimarisi ağın mimarisi olarak kabul edilmiştir. Böylece, öğrenme, onaylama ve test kümelerinin, tüm veri kümesinin karakteristiğini yansıtması sağlanmıştır.


Mimarilerin tespit edilmesi ile beraber oluşturulan her giriş değişken kombinasyonları bu seferde veri kümesindeki veri sayısının etkisi dikkate alınmak üzere üç ayrı şekilde test edilmiştir. Böylece ikinci aşamadaki veri karakteristiğinin etkisinin dikkate alınmasının ardından bu aşamada da veri sayısının etkisi dikkate alınmış olmaktadır. Ayrıca test kümesindeki veri sayısının az olması nedeniyle eğitim için kullanılan veriler ölçülmüş değerleriyle testten geçirilmiş ve sonuçlar test verileri için çıkan sonuçlarla karşılaştırılmıştır. Karşılaştırma için, ortalama mutlak rölatif hata (OMRH), korelasyon katsayısı (R), verimlilik katsayısı (E) ve ortalama karesel hatanın karekökü (KHOK) uygunluk ölçütleri dikkate alınmıştır. Havza için geliştirilen en iyi YSA'nın performansı, akış ve yağış değişkenlerine bağlı olarak çok değişkenli lineer regresyon (MLR) modelleri ile kıyaslanmıştır.

2. LİTERATÜR TARAMASI

2.1. Akarsularda Katı Madde Hareketi

Akarsuların taşıdığı katı maddeler, taşınan malzemenin kaynağına göre ve taşınma şekline göre sınıflandırılırlar. Malzemenin kaynağına göre katı madde, *yatak malzemesi* ve *yıkanmış malzeme* olmak üzere iki sınıfa ayrılır. *Yatak malzemesi* hareketli tabanı oluşturan malzemedir. İri danelerin akarsu yatağından sökülmesi olarak tanımlanan kanal erozyonu yatak malzemesinin kaynağını oluşturur. *Yıkanmış malzeme* ise, çoğunluğu havza erozyonundan gelen ve yatak malzemesinden daha ince olan malzemedir. İnce danelerin yeryüzünden sökülmesi olarak tanımlanan tabaka erozyonu yıkanmış malzemeye kaynaklık etmektedir.

Akarsudaki taşınma şekline göre de *askı maddesi* ve *sürüntü maddesi* şeklinde sınıflandırılırlar. *Sürüntü maddesi* akarsu tabanında hareket eden yuvarlanan küçük parçalardan oluşur. Bu daneler yatağın üst yüzeyi ile devamlı temas halindedir. Eğer akımın hızı daha yüksek değerlere ulaşırsa bazı daneler sıçramaya başlar. Yuvarlanarak, kayarak ve sıçrayarak hareket halinde bulunan bu daneler bir süre sonra durgunlaşır. *Askı maddesi* daha küçük çaplı olmakla birlikte, bunu sürüntü maddesinden ayıran belli bir dane çapı yoktur. Çünkü katı madde hareketi yalnızca dane çapı ile ilgili olmayıp akım durumuna da bağlıdır. Hızlı akım olan bir bölgede askı halinde ilerleyen bir parçacık daha durgun akan bir bölgeye gelince sürüntü maddesi durumuna geçebilir. Bu ayırım için geliştirilen bağıntılardan birinde $Fr^2 = V^2/gD$ ifadesini 360 yapan çap, sürüntü maddesi ile askı maddesini ayıran bir ölçüt olarak alınmaktadır (Özbek ve Çağlar, 2001). Yıkanmış, yatak, askı ve sürüntü maddesinin dağılımları Şekil 2.1’de gösterilmiştir.



Şekil 2.1 Katı maddenin su derinliğine bağlı dağılımı (Özbek ve Özcan 2001)

2.2. Katı Madde Hareketindeki Boyutsuz Büyüklükler

Katı madde hareketindeki mekanik olay oldukça fazla sayıdaki fiziksel büyüklük ile tanımlanabilir. Bunlardan önemli olan fiziksel büyüklükler Tablo 2.1’de gruplar halinde verilmektedir.

Tablo 2.1 Katı madde hareketinde fiziksel büyüklükler (Özbek ve Özcan 2001)

Katı madde ile ilgili büyüklükler:	Özgül kütle	ρ_s
	Dane çapı	D
	Sürüntü maddesi birim debisi	q_s
Akışkan ve akım ile ilgili büyüklükler:	Özgül kütle	ρ
	Viskozite	ν
	Su derinliği	h
	Ortalama hız ve sürüklenme hızı	\bar{v}, v^*
Katı madde ve akışkan ile ilgili büyüklük:	Yerçekimi ivmesi	g

Çizelgede “ ν ” ile gösterilen *sürüklenme hızı*, akarsuda katı madde hareketinde önemli bir rol oynayan bir parametredir. “ I ” ile *taban eğimi*, “ R ” ile *hidrolik yarıçap* gösterildiğinde tabandaki kayma gerilmesi:

$$\tau_0 = \gamma R I \quad (2.1)$$

bağıntısı ile bulunur. Sürüklenme hızı (v^*), denklem (2.1)’de ifade edilen sürüklenme gerilmesinden (τ_0) türetilmiş bir büyüklük olup denklem (2.2)’deki gibi,

$$v^* = \sqrt{\frac{\tau_0}{\rho}} = \sqrt{g R I} \quad (2.2)$$

ifade edilebilir. Tablo 2.1’de gösterilen parametreler dışında dane dağılımının homojen olmadığını belirten bazı büyüklükler de vardır. Bu parametreler ile taşınan sürüntü maddesi birim debisi (q_s) beraber gösterildiğinde fonksiyonel bağıntı denklem (2.3)’teki gibi yazılabilir:

$$f(\rho_s, \rho, \nu, g, D, h, \bar{v}, v^*, q_s) = 0 \quad (2.3)$$

“ D ”, “ ρ ” ve “ ν ” tekrar eden değişkenler olarak seçilip “Buckingham π Teoremi” aracılığı ile boyut analizi yapıldığında ve bazı yaklaşımlar ile yukarıdaki bağıntı denklem (2.4)’teki hali alır:

$$f(\text{Re}^*, Fr^*, \phi) = 0 \quad (2.4)$$

Bu bağıntıdaki “ Re^* ” ve “ Fr^* ” boyutsuz büyüklükleri, sırası ile *dane sürüklenme Reynolds sayısı* ve *dane sürüklenme Froude sayısı* olup sırasıyla ne anlama geldikleri denklem (2.5) ve denklem (2.6) ile verilmektedir.

$$\text{Re}^* = \frac{v^* D}{\nu} \quad (2.5)$$

$$Fr^* = \frac{v^{*2}}{gD(\rho_s - \rho) / \rho} = \frac{v^{*2}}{\Delta g D} \quad (2.6)$$


Denklem (2.7)’de verilen ve *boyutsuz olarak sürüntü maddesi debisini* veren “ ϕ ” değeri, hareketin olmadığı bir akarsu yatağında sifıra eşit olmaktadır.

$$\phi = \frac{q_s}{\sqrt{\Delta g D^3}} = 0 \quad (2.7)$$

Diğer taraftan akarsu yatağındaki kohezyonsuz bir danenin dengesi düşünülürse, bu daneye etki eden kuvvetler parçanın su içindeki ağırlığı ve daneye etki eden direnç kuvvetidir. Dengedeki danenin ağırlığı “ W_s ”, daneye etki eden direnç kuvveti “ F_D ” ile gösterildiğinde, denge durumunda denklem (2.8)’deki eşitlik yazılabilir (Şekil 2.2).

$$W_s . a = F_D . b \quad (2.8)$$

Küre şeklindeki bir dane kabulü ile “ C_D ” ile direnç katsayısı, “ v^* ” ile dane sürüklenme hızı gösterildiğinde “ F_D ” direnç kuvveti için eşitlik;



Şekil 2.2 Dengedeki dane (Özbek ve Özcan 2001)

$$F_D = \frac{1}{2} \rho v^{*2} C_D \frac{\pi D^2}{4} \quad (2.9)$$

denklem (2.9)'da belirtildiği gibi yazılabileceğinden, danenin su içindeki ağırlığı

$$W_s = g(\rho_s - \rho) \frac{\pi D^3}{6} \quad (2.10)$$

Denklem (2.10)'daki gibi alınıp denge denkleminde yerine konduğunda

$$v^{*2} \rho = \frac{4}{3} \frac{D}{C_D} g(\rho_s - \rho) \frac{a}{b} \quad (2.11)$$

Denklem (2.11) bulunur. Diğer taraftan $\tau_0 = v^{*2} \rho$ olduğundan denklem (2.11) yeniden düzenlendiğinde hareket sayısı “ ψ ” denklem (2.12.)’ de belirtildiği gibi yazılabilir:

$$\psi = \frac{\tau_0}{g(\rho_s - \rho)D} = \frac{v^{*2} \rho}{g(\rho_s - \rho)D} = \frac{v^{*2}}{g(\rho_s - \rho)/\rho} = \frac{v^*}{\Delta g D} \quad (2.12)$$

Düzenlemeler sonucu $v^{*2} = gRI$ bağıntısı ile birlikte ψ , denklem (2.13)'de görüleceği üzere farklı biçimlerde gösterilebilir. Ayrıca, denklem (2.6) ile karşılaştırıldığında bu sayının *dane sürüklenme Froude sayısı* ile eşdeğer olduğu görülecektir.

$$\psi = Fr^* = \frac{\tau_0}{g(\rho_s - \rho)D} = \frac{v^{*2}}{\Delta g D} = \frac{RI}{\Delta D} = \frac{\tau_0}{\Delta \rho g D} \quad (2.13)$$

Denklem (2.13)'de dört farklı yazılım şekli verilen “ ψ ” hareket sayısı, hareketin olup olmadığını belirleyen bir parametre olduğu gibi ayrıca katı madde miktarının belirlenmesinde de etken bir boyutsuz büyüklüktür (Özbek ve Özcan 2001).


2.3. Taban Hareketinin Başlaması

Katı madde hareketinin olmadığı sınır denge durumunda $q_s = 0$ olduğundan denklem (2.4)'ü denklem (2.14) şeklinde dönüştürmek mümkündür:

$$f(\text{Re}^*, Fr^*) = 0 \quad (2.14)$$

Tabandaki hareketin başlangıcı ile ilgili ilk çalışmayı Shields yapmıştır. Harekete başlama durumu için Reynolds sayısı ile Shields Parametresi, ψ arasındaki bağıntıyı incelemiş ve $1,06 < \frac{\rho_s}{\rho} < 4,25$ aralığında yapmış olduğu deneysel çalışmalarda denge durumu için denklem (2.15)'i geliştirmiş ve Şekil 2.3'te gösterilen Shields eğrisini hazırlamıştır.

$$\psi = Fr^* = f(Re^*) \quad (2.15)$$



Şekil 2.3 Shields eğrisi (Özbek ve Özcan 2001)

Bu bağıntı çeşitli araştırmacıların sonradan yaptığı deneylerle de doğrulanmış olup hala güncelliğini korumaktadır.

Hareket ile hareket olmaması durumları arasındaki sınır, “denge durumu” olarak tanımlandığında, Şekil 2.3’deki eğri üzerinde bulunan noktalar tabanda oluşan kayma gerilmesinin (τ_0) kritik sürüklenme gerilmesine (τ_{kr}) eşit olduğunu göstermektedirler. Bu gerilme aynı zamanda sınır kayma gerilmesi yada oyulma kayma gerilmesi adları ile de anılmaktadır. $\tau_0 > \tau_{kr}$ olduğu zaman o kesitte hareket ve taşınım buna bağlı olarak oyulma söz konusu iken, $\tau_0 < \tau_{kr}$ olduğu zamanda şayet membadan gelen sürüntü maddesi söz konusu ise akarsu yatağında yığılmadan bahsedilmektedir.

Shields diyagramında düşey ekseninde denklem (2.13)'de verildiği gibi, farklı şekiller ile ifade edilen boyutsuz kayma gerilmesi (ψ) görülmektedir. Shields eğrisi üzerinde yere alan noktalar denge durumunu karakterize ederken ($\tau_0 = \tau_{kr}$), eğrinin üst kısmında kalan bölge hareketin olduğu ($\tau_0 > \tau_{kr}$), alt kısmında kalan bölge ise hareketin olmadığını ($\tau_0 < \tau_{kr}$) göstermektedir.

Diyagramdan görüleceği üzere $Re^* < 2$ için bağıntı lineer bir gidiş göstermekte ve $0,06 < \psi < 0,45$ değerleri arasında değişmektedir. $Re^* = 10$ için $\psi = 0,03$ ile denklem minimum değerini almakta ve $Re^* > 400$ için $\psi = 0,06$ olmaktadır.


$$\delta = 11,6 \frac{V}{v^*} \quad (2.16)$$

Denklem (2.16)'da “ δ ” ile *laminer sınır tabakası* kalınlığı ifade edildiğine göre denklem (2.4) ile ifade edilen “ Re^* ”, sayısal laminer tabaka kalınlığı cinsinden ifade edilmek istendiğinde aşağıdaki şekli alır.

$$Re^* = 11,6 \frac{D}{\delta} \quad (2.17)$$

$k_s = D$ ile gösterildiğinde $k_s > 6\delta$ olduğunda akım yüzeyi pürüzlü olarak tanımlandığından $k_s = 6\delta$ alınıp denklem (2.17)'de yerine konduğunda, bulunan $Re^* > 70$ ile tanımlanan kesimin hidrolik pürüzlü kısmı içerdiği ve bu kesimin akarsular için geçerli olduğu ortaya çıkar (Özbek ve Özcan 2001).

Bir tabanın akımla temas eden üst yüzeyindeki bir daneye etki eden kuvvetler Şekil 2.4'de verilmektedir.



Şekil 2.4 Akarsu tabanındaki bir daneye etkiyen kuvvetler (Güngör 1997).

- Ağırlık kuvveti (danenin su altındaki ağırlığı), G'
- Hidrodinamik kaldırma kuvveti, F_L
- Hidrodinamik sürüklenme kuvveti, F_D
- Bu taneyle temasta olan tanelerin etkisinden doğan reaksiyon kuvvetleri, R .

Hidrodinamik Kaldırma Kuvveti: Danenin üst tarafında akım çizgilerinin eğriliği sebebiyle basıncın azalmasından ileri gelir. Danenin alt tarafındaki ve hemen hemen hareketsiz olduğu için eğriliği dolayısıyla, basınç hidrostatik değerine altına düştüğü için daneye yukarıya yönelmiş (F_L) kaldırma kuvveti etki eder. Bu kuvvet denklem (2.18)'deki gibidir (Güngör 1997).

$$F_L = \frac{\rho \cdot u^2 \cdot A \cdot c_L}{2} \quad (2.18)$$

Hidrodinamik Sürüklenme Kuvveti: Viskoziteden ve sınır tabakasının ayrılmasından ileri gelir. Taban yakınlarında akım laminer ise, bu kuvvet sadece viskoz etkilerden doğar. Deneyle taban yakınındaki laminer alt tabaka daneleri örtüyorsa bu durum görülür. Danelerin arkasında sınır tabakası ayrılmaz. Yüksek Reynolds sayılarında laminer alt tabaka kalınlığı azalınca daneler bu tabakanın dışına çıkar. Dane yakınında akım çizgileri yer değiştirir. Danenin arkasında bir ayrılma bölgesi meydana gelir. Bu bölgenin büyüklüğü dane üzerinde sınır tabakasının ayrılma noktasına bağlı olup bu da danenin ön ve arkasında basınçlar farklı değerler alır, daneyi akım yönünde hareket ettirici bir kuvvet doğar. Sonuç olarak, (F_D) sürüklenme kuvveti, denklem (2.19)'da verilen *yüzeysel direnç(sürtünme)* ve denklem (2.20)'de verilen *biçim direnci(basınç)* bileşenlerinden meydana gelir (Güngör 1997).

$$F_D = \frac{\rho \cdot u^2 \cdot A \cdot C_D}{2} \quad (2.19)$$

$$F_L = \frac{\rho \cdot u^2 \cdot A \cdot C_L}{2} \quad (2.20)$$

Daneyi etkileyen kuvvetlerden ağırlığın akım doğrultusuna dik bileşeni daneyi yerinde tutmaya, kaldırma kuvveti, sürüklenme kuvveti ve ağırlığın akım

doğrultusundaki bileşeni ise daneyi harekete geçirmeye çalışmaktadır. Herhangi bir değme noktasına göre, alınan bileşke momentin sıfır olduğu anda dane yuvarlanarak harekete geçer. Parçacığa etki eden kuvvetlerin büyüklüğü, parçacığın büyüklüğüne, yatağın pürüzlülüğüne, etrafındaki suyun ortalama hızına bağlıdır (Güngör 1997).

2.4. Askı Maddesi Taşınımı

Taban malzemesinin askı haline geçişi çeşitli şekillerde olur. Bunlar;

- Sürüntü hareketi yapan danelerden üstte olanlar türbülans çevrilerine kapılarak yukarı fırlarlar. Türbülans nedeniyle yukarı doğru yönelmiş hareket miktarının, aşağı doğru yönelmiş olan hareket miktarından fazladır. Bu fazlalık çökme hızları sebebiyle aşağı doğru hareket eden daneler tarafından karşılanır ve kesit içerisinde zamanla değişmeyen bir askı maddesi dağılımı meydana gelir.
- Sıçrama hareketi yapan danelerin akımın yukarı bölgelerine çıkmaları,
- Danelerin başka daneler ile çarpışması sonucu yukarı doğru fırlamaları,
- Bir taban dalgasının memba yüzü boyunca hareket eden danelerin dalganın tepesine ulaşınca yukarı doğru hareket etmeleri şeklinde verilebilir. Kısacası askı maddesinin mekanizmasının temelini türbülans hareketi oluşturmaktadır.

Yani katı maddeler tabandan yukarı doğru yükselince, onları taşıyabilecek büyüklük ve şiddette türbülans çevrilerinin bulunduğu bölgeye girmiş olurlar ve bu bölgede danelerin tabana doğru çökme hızlarını türbülans hızının yukarıya doğru olan bileşeni karşılayarak bir kısım danelerin askı halinde kalmaları sağlanmış olur. Askı malzemesi, parçacığın boyutuna, fiziksel ve kimyasal özelliğine ve akım özelliğine bağlı olarak değişir. Askı hareketi, *konveksiyon*, yani akımın ortalama hızıyla iletim ve *difüzyon*, danelerin, konsantrasyonun büyük olduğu bölgeden düşük olduğu bölgeye doğru hareketi şeklinde olup, bu yolla taşınan daneler için maddenin korunumu prensibi sağlanmalıdır (Erkek ve Ağırlioğlu 2002).

Bir akarsuda; herhangi bir “h” derinliğinde ve “V” hacmindeki bir numunede denklem (2.21)’de,


$$C = \lim \frac{V_s}{V} \quad (2.21)$$

tanımlanan “C” büyüklüğüne *askı maddesi konsantrasyonu* denir. Bu tanımdan da anlaşıldığı gibi konsantrasyon, su içindeki askı maddesi miktarının, su ve askı maddesi karışımına oranıdır. Birimi ppm (mg/lt) cinsinden verilir. Askı maddesi birim debisi;

$$q_A = \int_0^h C(z)v(z)dz \quad (2.22)$$

denklemleri ile bulunabilir. Bulunan bu daneler bir süre sonra durgunlaşır.

Bir akarsu en kesitindeki hızın, katı madde konsantrasyonunun ve katı madde debisinin derinliğe göre değişimi Şekil 2.5’te gösterilmiştir.



Şekil 2.5 Bir akarsu en kesitindeki hız, katı madde konsantrasyonu ve katı madde debisinin derinliğe göre değişimi

Yerçekimi ve difüzyon teorilerinden yararlanılarak, çökelme hızı ile aşağı inen ve türbülans ile yukarı çıkan maddelerin dengesi için denklem (2.23)'teki eşitlik yazılabilir (Özbek ve Özcan 2001).

$$\omega C + \varepsilon_s \frac{\partial c}{\partial z} = 0 \quad (2.23)$$

Bu eşitlikte birinci terim (ω = düşme hızı, C = askım maddesi konsantrasyonu), *akımın çökelmeye olan etkisini*, ikinci terim ise *türbülansın difüzyon etkisini* tanımlamaktadır. “ ε_s ” parametresi *askı maddesi difüzyon karışım katsayısıdır* ve şöyle açıklanabilir. Yukarı hareket eden su paketleri aşağı hareket eden su paketlerinden daha fazla askı maddesi taşırlar. Bunun nedeni konsantrasyon değişimidir. Aslında suyun taşınması söz konusu olmadığı halde iniş çıkışlardan dolayı net bir düşey taşıma vardır. Düşey taşıma konsantrasyon değişimi ile orantılıdır. İmpuls transferi olduğu zaman “ ε_s ” değeri sabit değildir. Boussinesq'e göre “ ε_s ”, denklem (2.24) ile tanımlanmaktadır (Bayazit 1996):

$$\frac{\tau}{\rho} = \varepsilon_s \frac{dv}{dz} \quad (2.24)$$

Plandtl – Karman'ın logaritmik hız dağılımı kabulü ile hızın değişimi denklem (2.25)'teki gibi,

$$\frac{dv}{dz} = \frac{v^*}{\kappa z} \quad (2.25)$$

tanımlanabilir. Burada $v^* = \sqrt{\tau_0/\rho}$, “ κ ” Karman sabiti olup 0,4 alınabilir.

Kayma gerilmesi,

$$\tau = \rho g(h - z) \quad (2.26)$$

Denklem (2.26) şeklinde ifade edilebilir. Denklem (2.22), (2.23) ve (2.24)'den;

$$\varepsilon_s = \kappa v^* \frac{z}{h}(h - z) \quad (2.27)$$

denklem (2.27) elde edilir. Denklem (2.25) ve (2.27), denklem (2.23)'de yerine konup integrali alındığında;

$$\frac{C(z)}{C_a} = \left(\frac{h-z}{z} \cdot \frac{a}{h-a} \right)^\alpha \quad (2.28)$$

denklem (2.28) bulunur. Burada “ C_a ” integrasyon sabitidir. “ α ” katsayısı ise;

$$\alpha = \frac{\omega}{\kappa v^*} \quad (2.29)$$

denklem (2.29)’da ifade edilmiştir.

Askı maddesinin hesabı için aşağıda verilen sıra izlenir (Erkek ve Ağırlioğlu 2002)


- Akarsu yatağında ölçme yapılacak kesit için en kesit alanı, hız, pürüzlülük katsayısı, eğim ve debi belirlenir.
- Ölçme kesitinde ölçme yapılacak düşey eksenlerin yeri ve ölçme aletleri belirlenir ve bu düşeylerdeki ölçme noktalarında hız, su derinliği ve tabandan yüksekliği ölçülür.
- Çökme hızı ve $\alpha = \frac{\omega}{\kappa v^*}$ çökme hızı parametresi belirlenir.
- Daha sonra, denklem (2.28) hesaplanır ve düşey eksenlerde aynı noktalarda hız ve konsantrasyon değerleri çarpılır ve bu çarpımların sonucu bütün en kesit boyunca entegre edilerek o kesitten geçen askı maddesi miktarı belirlenir (Fırat 2007).

Denklem (2.28) için Plandtl yaklaşımını dikkate alındığında aşağıdaki durumlar için geçerli olmaktadır:

- Denklem (2.27) askı maddesi hareketinin sıvı hareketi ile uygun olması durumunda geçerli olmaktadır. Ancak bu yaklaşım sadece çok büyük partiküller için geçerli olabilir.
- Denklem (2.28)’deki “ α ” sayısının belirlenmesinde kullanılan “ κ ” sayısı yeni araştırmalara göre askı maddesi konsantrasyonu ile ilintilidir. Askı maddesinin varlığının türbülanslı akımlarda difüzyon katsayısını azaltıcı etkisi vardır. $\kappa = 0,4$ değeri ile çalışıldığı için bu ancak ilk maddede de belirtildiği

üzere, konsantrasyonun küçük olduğu durumlar için geçerli olmaktadır. Ancak akarsu ile ilgili hesaplar bu husus akarsudaki konsantrasyonun küçük olması nedeniyle önemli değildir.

- Konsantrasyon değeri diye adlandırılabilen α sayısının belirlenmesinde kullanılan “ ω ” çökme hızı durgun sular için geçerli olup türbülanslı akımlarda gerçeği yansıtmadığı hususu gözden uzak tutulmamalıdır.
- Denklem (2.28)’den tabanda ($h=0$ için) konsantrasyon değerini sonsuza yaklaştığı görülmektedir. Bu gerçeği yansıtmadığı için, $a = 2D_{65}$ veya $a = 0,05h$ alınıp ölçümler yapılır. “ C/C_a ” rölatif konsantrasyon değeri $\frac{z-a}{h-a}$ değerinin bir fonksiyonu olup, “ α ” katsayısına bağlı olarak Şekil 2.6’dan alınabilir.



Şekil 2.6 Askı maddesi hesabında kullanılan rölatif konsantrasyon değerleri (Özbek ve Özcan 2001)

“ C_0 ” ortalama konsantrasyon değeri ile;

$$q_A = \int_0^h C(z)v(z)dz = qC_0 \quad (2.30)$$

denklem (2.30)’daki gibi ifade edilebileceğinden, askı maddesi debisi “ Q_A ” aşağıdaki şekli alır: bulunan bu daneler bir süre sonra durgunlaşır.

$$Q_A = \int_0^b q_A dx = \int_0^b \int_0^h Q(z)C(z)dzdx = QC_0 \quad (2.31)$$

Denklem (2.31)'de, "C" hacim cinsinden alındığı takdirde sonuçlarda " Q_A " hacim cinsinden (m^3/s), ağırlık cinsinden ifade edildiği durumlarda ise (kg/s) elde edilir.

Denklem (2.28), konsantrasyon dağılımını vermektedir. Bu eşitlik ile çalışabilmek için kesitte farklı yüksekliklerde konsantrasyon ölçümü gerekmektedir. Bunun için Zanke (1982), bazı kabuller yaparak bir yaklaşım geliştirmiştir. Zanke, ölçümlere bağlı bir konsantrasyon dağılımı geliştirmiştir. Böylece yukarıda anlatılan yaklaşımların yol açtığı hata payı minimum bir değere indirgenmiş olur.

Bir başka yaklaşımda ise, yapılan ölçümler akarsular için $0,05 < \alpha < 0,2$ olduğunu gösterdiğinden ve ortalama konsantrasyon $(0,5 - 0,6)h$ derinliğinde olduğundan, bu yükseklikte yapılacak ölçümün derinliği karakterize ettiği varsayılp;

$$Q_A = C_0 \cdot Q \quad (2.32)$$

bağıntısından yararlanılmaktadır (Bolrich ve Preissler 1992).

Belli şartlar altında dane çapının çok fazla değişim göstermediği kabulünden hareket ile eğimin tespitindeki zorluklar da dikkate alındığında, çok ince çaptaki askı maddesi ($D < 0,05$ mm. için) bağıntı:

$$Q_A = bQ^n \quad (2.33)$$

denklem (2.33)'teki şekli almaktadır.

Bu çalışmaların dışında askı maddesi miktarını veren bir takım analitik yaklaşımlarda geliştirilmiştir. Bunlar Forcheimer (1939), Şentürk ve Şentürk (1998) yaklaşımlarıdır.

2.5. Sürüntü Maddesi Taşınımı

Akarsulardaki katı madde etütleri genellikle askıda taşınan katı madde etütlerine dayanır. Askıda taşınan katı madde toplam katı madde miktarının çoğunluğunu teşkil etmekle beraber, bazen sürüntü halindeki katı madde yatakla temasa halinde olup;

kayarak, yuvarlanarak ve sekerek mansaba doğru hareket eder. Bu debi; numune almak suretiyle ölçülebildiği gibi analitik metotlarla hesap edilerek de bulunabilir.

Yatak yükü miktarının tayin metotları o kadar pahalı olmakla beraber, önemsizdirler. Dolayısıyla rutin ölçümler için kullanılmazlar. Bu sebeple yatak malzemesinden numune alınır. Bu numunelerin elek analizleri yapılarak dana büyüklükleri dağılımı tespit edilir ve analitik metotla *sürüntü debisi* hesaplanır. Eğer yatak materyali dane büyüklüğü, akarsu enince ve boyunca değişkense, çok sayıda yatak materyali numunesi alınır. Böylece yatak materyalinin ortalama dane büyüklüğü dağılımı elde edilir.

Sürüntü maddesinin hesabı için birçok araştırmacı tarafından deneysel çalışmalar yapılmış ve ampirik bağıntılar geliştirilmiştir. Bunlar Du Boys (1879), Schocklitsch (1934), Schields (1936), Kalinske (1947), Meyer-Peter ve Müller (1949), Einstein (1950), Frijlink (1952), Vollmers ve Pernecker (1965) ve Zanke (1982) şeklinde verilebilir. Aynı akarsu için, aynı şartlar altında ve de aynı daneleri kullanmak suretiyle farklı neticeler elde edildiği görülmektedir. Bu bakımdan ampirik formüllerin direk olarak alınması yerine mevcut bağıntılar kontrol edilmeli ve katsayıları hesabı yapılan akarsu kesitine göre düzenlenmelidir. Ayrıca katı madde debisiyle, akarsuyun hız, debi ya da derinliği arasında sadece o akarsuda geçerli olacak bir ilişkinin kurulması da mümkün olabilir. Bilindiği gibi sürüntü hareketi, taban kayma gerilmesi ile doğrudan ilişkili olup sadece danelerin direncine etkileyen kısmın belirlenmesi oldukça güçtür. Bu nedenle kayma gerilmesi yerine ortalama akım hızı kullanmak daha uygundur (Özbek ve Özcan 2001).

2.6. YSA ile Yapılmış Katı Madde Tahmin Çalışmaları

Yapay zeka çalışmaları kapsamında ortaya çıkan ve bir noktada yapay zeka çalışmalarına destek sağlamakta olan farklı alanlardan bir tanesi de **YSA**'lardır. Yapay zeka tekniklerinden YSA, biyolojik sinir sisteminden esinlenilerek geliştirilmiştir. Genel olarak YSA, tek katmanlı ya da çok katmanlı sistem ya da matematiksel bir model olarak tanımlanabilir (Şen 2004). Katı madde tahmini için literatürde son yıllarda YSA modelleri kullanılmaya başlamıştır.

Abrahat ve White (2001) Malawi'deki 1981- 1985 su yıllarına ait yağış verilerine karşılık gelen 117 adet akış ve katı madde gözlem verisini dikkate aldıkları

çalışmalarında; yağış (mm), maksimum 30 dakikalık yağış yoğunluğu (mm/h), akış (mm) ve akış katsayısı (%) gibi dört adet girdi değişkeni kullanılmışlardır. Burada, ilk önce veriler ağ eğitimiye dahil edilmeden logaritmaları alınmıştır. YSA standart girdi ve çıktı değerleri ile test edilirken diğer ağlar farklı yüzdelerdeki yapay gürültüler ile eğitilmiştir. Girdi değişkenlerine eğitim boyunca ilave edilen yapay gürültüler lokal minimumlara yakalanmadan ağı korurken, aşırı genelleme yapan ağ yapılarından sakınmayı da sağlamıştır. Sonuçlar, ortalama karesel hata ve ölçümlerin standart sapmalarına göre değerlendirilmiştir. Çalışma sonucunda, katı madde tahmini için geliştirilen lineer regresyon modeli en zayıf model olmuş, optimal seviyede yapay gürültü katkılı YSA en iyi sonucu vermiştir. Ayrıca, yaptıkları bu çalışmada, gürültü parametresinin belirli bir seviyenin üstüne çıkması sonucunda YSA'ların olumsuz yönde etkilendiğini göstermişlerdir.

Nagy vd (2002) tarafından yapılan çalışmada, Niobrara, Orta Loup, Hii ve diğer küçük nehirlerle ait toplam katı madde debileri karıştırılarak bir veri kümesi oluşturulmuş ve oluşturulan verilerin yarısı eğitim için, diğer yarısı ise onaylama için kullanılmıştır. Ağ yapıları oluşturulurken, katı madde hareketinde çok önemli olan, kayma gerilmesi (ψ), hız oranı (ϕ), süspansiyon parametresi (w_0/u_*), akarsu boyuna eğimi (L), su derinliği oranı (h/d_{50}), Froude sayısı (F), Reynoulds sayısı (R_*) ve akarsu genişlik oranı (h/B) gibi giriş değişkenleri dikkate alınmıştır. Katı madde konsantrasyonu, giriş katmanında alınan bu 8 adet giriş değişkenine bağlı olarak tahmin edilmeye çalışılmıştır. Verilerin kalan kısmı onaylamada kullanılmış ve ağ sonuçları ile gözlem değerleri karşılaştırılmıştır. Her ne kadar bu girdi değişkenlerinin katı madde konsantrasyonu üzerindeki etkisi olduğu düşünülse de bazı değişkenlerin olay üzerindeki etkisinin çok olmadığı ya da fazla etkisi olmayan değişkenlerin modelin gelişimini bozabileceği düşünülerek girdi değişkenleri için duyarlılık analizi yapılmıştır. Her bir girdi değişkeni sırayla ağ yapısından çıkartılarak ağın performansı değerlendirilmiş ve sonuç olarak hız oranı (ϕ) ve akarsu boyuna eğiminin (L) katı madde konsantrasyonu üzerindeki etkisinin az olduğu görülmüş ve girdi değişkenlerinden çıkartılmıştır. Sonuç olarak, elde edilen YSA giriş değişkenleri ile ağ eğitilmiş, eğitim değerleri ile gözlem değerleri arasındaki tutarsızlık oranının ortalaması ve standart sapması, geçmiş yıllarda bu bölge için geliştirilmiş ampirik bağıntıların sonuçları ile karşılaştırılmıştır. Ağ yapılarını onaylamak için Rio Grande, Sacramento ve Mississippi nehirlerine ait veriler kullanılmıştır. Sonuç olarak, kullanılan veri grubu

için elde edilen ağların diğer ampirik bağıntularla beraber karşılaştırıldığında bölge için, en iyi üç modelden biri olduğu gözlemlenmiştir. Veri yapısındaki ekstrem değerlerin çok olmasından dolayı ağ yapıları istenilen seviyede sonuç vermemiştir.

Newham vd. (2003) Avustralyada'ki Yukarı Murrumbidgee Havzası için, havza ölçeğinde katı maddenin taşınımının ve kaynağının hesabı için bir katı madde modeli geliştirilmiştir. Katı madde modelinin her bir değişkeni teorik ya da ampirik yaklaşımlar sonucu elde edilen alt modellerden oluşmaktadır. Bu çalışmada giriş katmanındaki veri sayısı 20 olup, lokal duyarlılık analizi ile en etkin değişkenler araştırılmıştır. Geliştirilen bu katı madde nehir ağ modeliyle ayrıca yatak malzemesi miktarı, askı maddesi miktarı, toplam katı madde taşınımı ve taşkın depolaması bulunabilmektedir. Bu çalışmada YSA ile havzalarda taşınan toplam yatak yükü ve askı maddesi miktarı bulunmuştur. Yatak yükü, askı maddesi miktarı ve toplam katı madde miktarı değerleri için giriş değişkenleri lokal duyarlılık analizine tabi tutulmuştur.

Veri yapısındaki ekstrem değerler sinir ağlarının performansını önemli ölçüde etkilemektedir. Literatürde bu konu ile ilgili çalışmalara bakıldığında bu problemden kaçınmak için eğitim aşamasından önce verilerin logaritması alınabilir, normalizasyon uygulanabilir. Sudheer vd (2003) yaptıkları çalışmada verilerdeki çarpıklığın etkisini azaltmak için modifiye edilmiş Wilson – Hilferty dönüşüm formülünü kullanmışlardır.

Cığızoğlu (2004)'ün yaptığı çalışmada, Philadelphia'daki (A.B.D) Schuycill Nehri'ndeki üst ve alt havzaya ait iki AGİ'deki günlük ortalama akım ve askıda taşınan katı madde verileri kullanmıştır. Burada, geçmiş yıllara dayalı askıda taşınan katı madde gözlemleri kullanılarak aşağı havzaya ait askı maddesi miktarı tahmin edilmiştir. Tahmin iki aşamada yapılmıştır. İlk aşamada aşağı havzanın askı maddesi değerleri giriş değişkeni olarak kullanılmış, ikinci aşamada ise, yukarı havzaya ait askı maddesi değerleri giriş değişkeni olarak kullanılmıştır. İkinci bir uygulamada yine çok katmanlı YSA kullanılarak nehir akımı ile askıda taşınan katı madde miktarı arasındaki ilişki incelenmiştir. Bu aşamada alt havzaya ait askı maddesi verileri ayrı ayrı yukarı ve aşağı havzanın akım değerleri kullanılarak tahmin edilmiştir. Çok katmanlı YSA, geleneksel AR modelleri ve regresyon modelleri ile kıyaslanmıştır. Aşağı havzanın otokorelasyon katsayısı 0,3 olup giriş değişkeni olarak t-4 güne kadar veri dikkate alınmıştır. Bu YSA yapısının giriş değişkenlerine, çıkış askı maddesi değerleri için yılın günlerini temsil eden değerler ilave edilmiş ve böylece periyodisite dikkate alınmıştır. Bu ilaveler,

korelasyonu arttırmıştır. Bunun yanında alternatif bir metot olarak AR(4) modeli geliştirilmiş ise de, sonuçlardaki sapma değerlerinin çok büyük olduğu gözlemlenmiştir. Askı maddesi tahminleri aynı havza için akım tahminleri ile karşılaştırıldığında akım değişkeninin birincil otokorelasyonun yüksek olması nedeniyle daha iyi sonuçlar vermiştir. Diğer bir uygulamada ise yukarı havza ile aşağı havza arasında çapraz korelasyon yapılmış ve çıkan değer havzanın otokorelasyonundan daha iyi olduğu için yukarı havzaya ait askı maddesi değerleri aşağı havza için girdi değişkeni olarak kullanılmıştır. Çıkan sonuçlar otokorelasyon yaklaşımı ile bulunan değerlerden performans olarak daha iyidir. Daha sonra girdi değişkenlerine aynı gün içindeki yukarı havzaya ait günlük askı maddesi gözlemleri ilave edilerek bu sefer de çoklu değişkenli regresyon modeli ile kıyaslanmıştır. Tahmin modellerinin ardından aşağı havzanın akım değerleri kullanılarak yine aşağıdaki havzaya ait askıda taşınan katı madde miktarı hesaplanmıştır ve bu model havza için geliştirilen katı madde tahmin eğrisi ile kıyaslanmıştır. Sonuç olarak, katı madde tahmin eğrisi gözlem değerlerine göre toplam %74 daha az değer elde etmiştir. Çok katmanlı YSA ise, gözlem değerlerine göre toplam %10 daha büyük değerler elde etmiştir. Buradan görüldüğü gibi askı maddesi miktarıyla akım arasındaki doğrusal olmayan ilişkinin çok katmanlı YSA ile daha iyi modellendiği sonucuna ulaşılmıştır.

Fırat ve Güngör (2004) yaptıkları çalışmada, askıda taşınan malzeme ve katı madde konsantrasyonunun tahmini için E.İ.E.İ tarafından Büyük Menderes Havzası'ndaki 706 No'lu AGİ'de ölçülen debi (m^3/s), sediment konsantrasyonu (ppm) ve askıda taşınan katı madde miktarı (ton/gün) kullanılmıştır. Giriş değişkeni olarak akarsu debisi kullanılmış ve eğitim aşamasına sigmoid aktivasyon fonksiyonu seçilmiştir. Eğitim aşamasından önce girdi verileri 0 ile 1 arasında normalize edilmiştir. Ağ yapısı olarak ileri beslemeli YSA, öğrenme tipi olarak denetimli öğrenme ve hatayı minimize etmek için hatayı geriye yayma algoritması kullanılmıştır. Eğitim aşamasında toplam 90 adet veriden 85'i kullanılmış ve gizli katman sayısı 3, öğrenme katsayısı 0,4, momentum katsayısı 0,7 ve iterasyon sayısı olarak 7800 seçilmiştir. Deneme aşamasında kalan 5 veri dikkate alınmış ve uygunluk ölçütü olarak ta OMRH seçilmiştir ve sonuçlar regresyon analizi sonuçları ile karşılaştırılmıştır. Sonuç olarak YSA'nın regresyon analizine göre daha iyi sonuçlar verdiği görülmüştür.

Sarangi ve Bhattacharya (2005) Jharkhand'daki (Hindistan) Chhotnagpur platosundaki Chatra bölgesinin Itkhori bloğundaki Banha havzasına ait 1985 – 1989 yılları arası ölçülmüş katı madde miktarı değerleri ile havzaya ait hidrograflar kullanılarak jeomorfoloji tabanlı ve jeomorfoloji tabanlı olmayan YSA geliştirilmiştir. Elde edilen ağ sonuçları havza için daha önceden geliştirilen regresyon modelleri ile karşılaştırılmıştır. Sarangi ve Bhattacharya (2005) hatayı geriye yayma algoritmasının YSA yapılarında iyi sonuçlar verdiğini göstermişlerdir. Jeomorfolojik olmayan YSA yapılarında giriş katmanında sadece akım değeri bulunurken, jeomorfolojik olanda ise akış oranı, rölatif çatallaşma, şekil faktörü ve drenaj faktörü gibi havza karakteristiğini yansıtan girdi değişkenleri ilave edilmiştir. Doğru ağ yapısının tespiti için 20 farklı şekilde girdi değişkeni oluşturulmuş ve sonuçlar korelasyon, verimlilik faktörü ve mutlak ortalama sapma için irdelenmiştir. Sonuç olarak jeomorfolojik tabanlı YSA'ların diğer ağ yapılarına göre daha uygun sonuçlar verdiği gözlemlenmiştir.

Agarwal vd (2006) yaptığı çalışmada, Hindistandaki Vamsadhara Nehri havzasındaki 6 adet YAGİ'ye ait günlük yağış değerleri (mm/gün) kullanılarak havza için Thiessen poligonları oluşturulmuş ve ağırlıklandırılmış yağış değerleri hesaplanmıştır. Giriş değişkeni olarak havzaya ait günlük toplam yağış miktarı (mm/gün) ile günlük akım değerleri (m^3/s) dikkate alınmıştır. Havza için günlük, haftalık, 10 günlük ve aylık yağış – akış değerleri giriş katmanına eklenmiştir. Havzaya ait verilerin bir kısmı çapraz onaylama bir kısmı ise, ağ doğrulaması için ayrılmıştır. Performans ölçütü olarak verimlilik katsayısı ve korelasyon katsayısı dikkate alınmıştır. Sonuçlara bakıldığında günlük yağış ve akış değişkenlerinden aylık yağış ve akış değişkenlerine doğru gidildikçe korelasyon ve verimlilik oranlarının düştüğü gözlemlenmiştir. Havza üzerindeki yağışın bölgesel varyasyonları da düşünülerek çok girişli lineer transfer fonksiyonlu sinir ağları geliştirilmiştir. Çalışma sonucunda çok giriş değerli sinir ağ yapılarının her zaman tek giriş değerli sinir ağ yapılarına göre iyi sonuçlar vermediği gözlemlenmiştir. Bu da diğer istasyonların ağ eğitimini zorlaştırıcı yönde etkisinin olmasından kaynaklanmaktadır. Yine benzer şekilde havza için katı madde ağ modelleri geliştirilmiş, girdi değişkeni olarak günlük, haftalık, 10 günlük, aylık katı madde değerleri (kg/s) ile sinir ağları ile tahmin edilmiş akım değerleri (m^3/s) kullanılmıştır. Sonuçlara bakıldığında bazı YAGİ'lerin katı madde taşınımı üzerinde etkili olmadığı ve veri zaman aralığının değişkenler arasındaki ilişkiyi nasıl etkilediği gözlemlenmiştir.

Cıgızoğlu ve Kişi (2006) Schullkill Nehri'ndeki Manayunk istasyonuna ait günlük ortalama akım ve günlük toplam askıda taşınan katı madde miktarını kullanmışlardır. Giriş verileri k-fold bölümlendirme yaklaşımı ile alt kümelere ayrılmıştır. Katı madde miktarı için hesaplanan birincil otokorelasyon anlamlı olup bundan önceki değerlerin anlamlılığı sıfıra yakın bulunmuştur. Katı madde ile akım arasında yapılan çapraz korelasyon sonucu lag 0 değeri lag 1 değerinden daha anlamlı çıkmıştır. Bu işlem sonucunda Q_t ve S_{t-1} değerlerinin girdi değişkeni olarak alınması uygun görülmüştür. Her bir alt girdi kümesinin katı madde değerleri ile akım değerleri arasındaki çapraz korelasyon sonuçları incelenmiştir. Cıgızoğlu (2004) yaptığı çalışmada geri beslemeli YSA'ların düşük katı madde taşınım potansiyeli olan bölgelerde katı maddenin zaman serisinin davranışını iyi yansıtmadığını görmüştür. Bu çalışma için ayrıca dizi bağımlı YSA'ları da kullanılmıştır. Bunun için her alt küme üç farklı diziye bölünmüştür. Bu diziler $0 - aX_{ort}$, $aX_{ort} - bX_{ort}$ ve $bX_{ort} - X_{max}$ şeklinde olup a ve b katsayıları her alt küme için denemeler ve hatalar ile belirlenmiştir. Ağın eğitimi boyunca uygulanan dizi limitlerine karşı gözlemlenen akış ve katı madde değerleri kontrol edilmiş ve her dizi için dizi bağımlı YSA'ların eğitimi için kullanılacak akış ve katı madde değerlerine karar verilmiştir. Eğitilen dizi bağımlı YSA'ların sonuçları, geri beslemeli YSA, lineer regresyon ve lineer dizi bağımlı regresyon değerleri ile ortalama mutlak hata ve verimlilik ölçütüne göre kıyaslanmıştır. Çalışma sonucunda düşük katı madde gözlemleri için dizi bağımlı sinir ağlarının, geri beslemeli YSA'lara göre daha iyi sonuçlar verdiği gözlenmiş, çok değişkenli regresyon modellerinde belirgin sapmaların olduğu ve bu sapmaların ağın performansını olumsuz yönde etkilediği de ayrıca saptanmıştır. Dizi bağımlılığının kullanımı regresyonun istatistik değerlerini de arttırmıştır.

Cıgızoğlu ve Alp (2006) yaptıkları çalışmada Penslyvania'daki (A.B.D) Juniata Nehri'ne ait günlük akım ve askıda taşınan katı madde miktarlarını kullanılarak havzaya taşınan katı madde miktarının genelleştirilmiş YSA yaklaşımı ile tahmin edilmesini araştırmışlardır. Yüksek, orta ve yüksek katı madde taşınım potansiyeli olan katı madde hidrografları için geliştirilen geri beslemeli YSA ile genelleştirilmiş YSA sonuçları karşılaştırılmıştır. Giriş katmanı, t-3 güne kadar akım değerleri ile t-1 güne kadar katı madde değerleri için oluşturulmuştur. Elde edilen YSA sonuçları ile katı madde hidrografları karşılaştırılmıştır ve orta ile düşük katı madde taşınım potansiyeli olan katı madde hidrografları için iyi sonuçlar vermiştir. Geliştirilen genelleştirilmiş YSA

yüksek katı madde taşınım potansiyeli yüksek olan katı madde hidrografları iyi sonuçlar vermiştir. Genelleştirilmiş YSA negatif veri üretmediği gibi iteratif öğrenme prosedürüne sahip olmadığı için geri beslemeli YSA gibi başlangıç ağırlık katsayılarına bağlı değildir.

Zhu vd (2007) Yukarı Yangtze havzasındaki (Çin) Longchuanjiang Nehri için aylık askıda katı madde taşınımı modellenmiştir. Burada geçmiş günlerin katı madde değerlerinin girilmesi yerine yağış, sıcaklık ve yağış yoğunluğu gibi iklim değişkenleri kullanılarak bu değişkenler ile askıda taşınan katı madde arasındaki ilişki yakalanmaya çalışılmıştır. Aylık ortalama askıda taşınan katı madde miktarı ile akım, havzadan toplanan günlük askıda taşınan katı madde miktarı ve akım değerlerinden türetilmiştir. Yapılan duyarlılık analizi sonucunda buharlaşma ve nem miktarının katı madde taşınımı üzerindeki etkisi az olduğu için giriş değişkenlerinden çıkartılmıştır. Sınır ağırları için giriş değişkeni olarak yağış, sıcaklık, bir ay içindeki 25 mm den ve 50 mm den büyük kümülatif yağış değerleri alınmıştır. Giriş yapısına eklenen yağış verileri Thiessen metodu kullanılarak alansal ortalama yağış değeri elde edilmiş ve giriş yapısında kullanılmıştır. Günlük sıcaklık ve akımlara ait zaman serileri de havzadaki 6 istasyondan temin edilmiştir. Askıda taşınan katı madde ile akım, yağış ve bir ay içindeki 25 mm den büyük kümülatif yağış değerleri arasındaki lineer korelasyonun kuvvetli olduğu görülmüştür. Sonuçlar çok değişkenli lineer regresyon denklemleri ve güçlü ilişki denklemleri ile karşılaştırıldığında geliştirilen YSA'ların daha iyi sonuçlar verdiği görülmüştür.

Alp ve Cıgızoğlu (2007) yaptıkları çalışmada geri beslemeli YSA kullanarak geçmiş günlük ve aylık katı madde miktarı ile nehir akımı verilerine bağlı günlük toplam askıda taşınan katı madde miktarını tahmin etmeye çalışmışlardır. Üç farklı giriş yapısı (sadece yağış, sadece akış ve hem yağış hem akış) ağ için düşünülmüştür. Geliştirilen geri beslemeli YSA, RYSA ve lineer regresyon modeli ile karşılaştırılmıştır. Junita Nehri'ne, Pennsylvania (A.B.D) ait günlük toplam akış ve askıda taşınan katı madde miktarı verileri kullanılmıştır. Ortalama günlük toplam yağış miktarı Thiessen Metodu kullanılarak hesaplanmıştır. Veriler istatistiksel açıdan incelendiğinde askıda taşınan katı madde miktarı değerlerinde dikkate değer bir çarpıklığın olduğu ve ayrıca akış ve katı madde değerleri için otokorelasyonların t-2 gün önceye kadar belirgin bir anlamlılık hesaplanmıştır. Çalışma kapsamında erken durdurma tekniği kullanılarak gizli

katmandaki nöron sayısı bulunmaya çalışılmıştır. Bu yöntemde YSA'ların arama yönü tahmin verilerinin ortalaması şeklinde dikkate alınırken, her öğrenme aşamasında ortalama karesel hata onaylama verilerinin ortalaması tarafından araştırılmıştır. Yapılan çapraz korelasyon ile yağış ve katı madde arasındaki t-2 gün önceye kadar ilişki bulunmasına rağmen t-4 gün önceye kadar olan giriş değişkeni alınmıştır. Çok değişkenli lineer regresyon modelleri ile geliştirilen ağ yapıları ortalama karesel hata ve R^2 uygunluk ölçütlerine göre irdelenmiştir. Çalışmanın sonucunda yağış değerlerinin, katı madde tahmin modelinde etkili bir değişken olmadığı görülmüştür. Giriş değişkenlerine eklenen evvelki günlere ait akım değerlerini ağ performansını arttırdığı görülmüştür.

3. MATERYAL VE YÖNTEM

3.1. Giriş

İnsanın düşünme yapısını anlamak ve bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışmak olarak tanımlanan yapay zeka, aslında programlanmış bilgisayarlara düşünme yeteneği sağlama girişimidir. Yapay zekanın mümkün olabilirdiği tartışmaları bir yana bırakılırsa bu konudaki çalışmalar bu alanı destekleyen farklı alanlardaki çalışmalarla birlikte devam etmektedir (Yurtođlu 2005).

Yapay zeka çalışmaları kapsamında ortaya çıkan ve bir noktada yapay zeka çalışmalarına destek sağlamakta olan farklı alanlardan bir tanesi de YSA'lardır. Dolayısıyla, yapay zeka alanının bir alt dalını oluşturan YSA teknolojisi, öğrenebilen sistemlerin temelini oluşturmaktadır. İnsan beyninin temel işlem elemanı olan nöronu şekilsel ve işlevsel olarak basit bir şekilde taklit eden YSA'lar, bu yolla biyolojik sinir sisteminin basit bir simülasyonu için oluşturulan programlardır. Bu şekilde insanođluna özgü deneyerek öğrenme yeteneđini bilgisayar ortamına taşıyabildiđi düşünölen YSA teknolojisi bir bilgisayar sistemine inanılmaz bir "girdi veriden öğrenme" kapasitesi sağlamaktadır. Çeşitli avantajlar sunan ve gün geçtikçe gelişen bu teknoloji, günümüzde birçok alanda faydalanılmaktadır (Yurtođlu 2005).

3.2. Yapay Sinir Ağları (YSA)

YSA, insan beyninin çalışma mekanizması taklit edilerek geliştirilen ve biyolojik olarak insan beyninin yaptıđı temel işlemleri belirli bir yazılımla gerçekleştirmeyi amaçlayan bir mantıksal programlama tekniđidir. YSA birçok basit işlemci elemanından oluşurlar. Bu elemanlar farklı formlarda ifade edilebilen nümerik verileri taşıyan bağlantılar ve ađırlıklar ile birbirlerine bađlıdırlar. YSA'daki gelişmelerin ana kaynađı, insan beyninin rutin olarak gerçekleştirdiđi karmaşık hesapları yapabilen yapay sistemlerin yapılabileceđi ümididir.

Literatürdeki YSA tanımlarına bakıldıđında YSA'nın herkes tarafından kabul edilmiş genel bir tanımı bulunmamakla birlikte, yaygın olarak kullanılan ve kabul görmüş bazı tanımlar şunlardır,

Kang vd (1992) YSA'yı, insan beyni gibi biyolojik sinir sisteminden ilhamla alınan bir bilgi işlem paradigması olarak; bu paradigmanın anahtar elemanı ise bilgi işlem sisteminin yapısı olarak tanımlanmıştır.

Haykin (1999) ise, sinir ağlarına detaylı bir bakış (Neural Networks: A Comprehensive Foundation), isimli kitabında yapay sinir ağını, "Bir sinir ağı, bilgiyi depolamak için doğal eğilimi olan basit birimlerden oluşan paralel dağıtılmış bir işlemcidir." şeklinde tanımlamaktadır.

YSA modelleri, biyolojik sinir ağlarının çalışma biçimlerinden esinlenerek ortaya çıkarılmıştır. YSA, biyolojik olmayan yapı taşlarının düzgün bir tasarımla birbirlerine yoğun olarak bağlanmalarından oluşmaktadır. Sinir sisteminin modellenmesi için yapılan çalışmalar sonucu oluşturulan YSA, biyolojik sinir sisteminin aşağıdaki üstünlüklerine sahiptir.

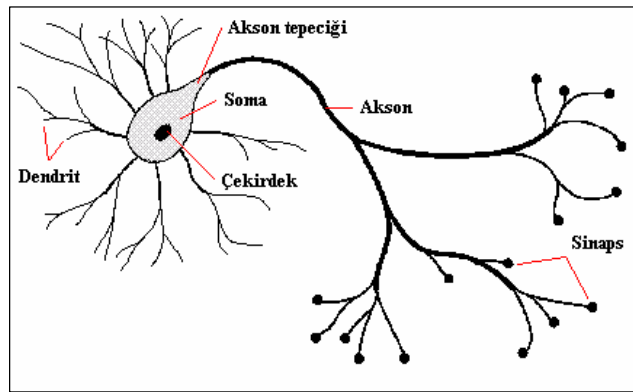
- Yapısının paralel olmasından dolayı katmanlar arasında zaman bağımlılığı yoktur, bu nedenle hız konusunda oldukça büyük üstünlük sağlamaktadır.
- YSA'larda her bir işlem birimi, çözülecek problemin tümü ile ilgilenmek yerine, sadece problemin gerekli parçası ile ilgilenmektedir ve problemin bir parçası işlemektedir. Hücrelerin çok basit işlem yapmalarına rağmen, sağlanan görev paylaşımı sayesinde, çok karmaşık problemler çözülebilmektedir.
- YSA'lar sınırsız sayıda değişken ile çalışabilmektedir (Yurtoğlu 2005).
- YSA'ların en önemli özelliklerinden birisi gerçek hayattaki olası doğrusal olmayan olayları da dikkate alabilmesidir (Campolo vd 2003).
- YSA'ların hatayı hoş görme yeteneği yüksektir. Eğitilmiş bir YSA'nın bazı bağlarının ya da hücrelerinin etkisiz hale gelmesi ağına doğru bilgi üretmesini önemli ölçüde etkilemez.
- YSA'lar öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlarda genelleme yapabilmektedir (Yurtoğlu 2005).

- YSA' ların diđer bir önemli avantajı öğrenbilme yetenekleridir. Ağ yapısı, istenilen davranışı gösterecek şekilde ilgilendiđi problemden aldığı eğitim örneklerini kullanarak problemi öğrenir.
- YSA deđişkenleri deđişen probleme veya sisteme uygun çözümler sağlamak için tekrar eğitilebilir.

Halen uygulanabilirliđi ve gelecekte uygulanabileceđi hususunda ümit veren aktif çalışmalar göz önünde bulundurulduğunda, YSA' ların kullanım alanları ve uygulamaları çok geniştir. Tıp, biyoloji gibi sađlık bilimlerinde hastalıkların teşhisi ve biyomedikal cihazların geliştirilmesi şeklinde faydalanılabildiđi gibi iş dünyasında da satış ve pazarlama, eylemsel analizler, insan kaynakları yönetimi ve finans gibi kollarda etkin bir şekilde faydalanılmaktadır. YSA' ların son yıllarda çok sıkça kullanıldıđı alanların başında elektronik ve savunma sanayi gelmektedir.

3.3. Biyolojik Sinir Sistemi

İnsanın beyinsel gücünün yapıtaşları olan nöronlar birkaç genel işleve sahiptirler. Bir biyolojik nöron, temel olarak, diđer kaynaktan girdileri alır, belirli bir şekilde bunları birleştirir, sonuç üzerinde bir işlem (genelde doğrusal olmayan) uygular ve nihai sonucu verir. Şekil 3.1' de bir nöronun dört temel elemanından oluşan genel yapısını ve bu dört eleman arasındaki ilişkiyi göstermektedir.



Şekil 3.1 Biyolojik sinir hücresi ve bileşenleri (Yaşar 2004)

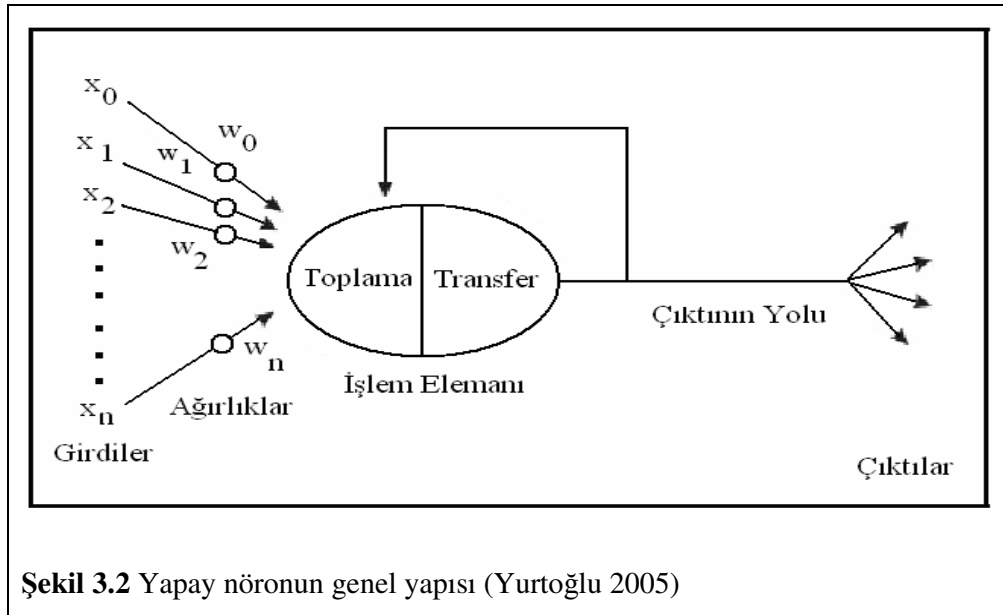
Şekil 3.1' den de görüldüğü gibi, tüm doğal nöronlar dört temel bileşene sahiptir. Bu bileşenler dendrit, çekirdek, akson ve bağlantı (sinaps) dır. Dendritler girdi kanalları

olarak işlev görürler. Bu girdi kanalları diğer nöronların sinapsları aracılığıyla girdilerini alırlar. Belirli bir sürede bir hücreye gelen girişlerin değeri, belirli bir eşik değerine ulaştığında hücre bir tepki üretir. Daha sonra çekirdek, gelen bu sinyalleri zaman içinde işler. Çekirdek, bu işlenmiş değeri bir çıktıya dönüştürdüktan sonra bu çıktıyı akson ve sinapslar aracılığıyla diğer nöronlara gönderir.

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beynin (merkezi sinir ağı) bulunduğu üç katmanlı bir sistem olarak açıklanmaktadır. Alıcı sinirler (receptor), organizma içerisinde ya da dış ortamlardan algıladıkları uyarıları, elektriksel sinyallere dönüştürerek beyne iletirler. Tepki sinirleri (effector) ise, beynin ürettiği elektriksel sinyalleri organizma çıktısı olarak uygun tepkilere dönüştürür.

3.4. Yapay Nöronlar

YSA' nın temel işlem elemanı olan yapay nöronlar, doğal nöronun yukarıda bahsedilen dört temel fonksiyonunu taklit ederler. Bir yapay nöronun temel yapısı aşağıdaki Şekil 3.2'de görülmektedir.



Şekil 3.2 Yapay nöronun genel yapısı (Yurtoğlu 2005)

Bir yapay nöronda temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler yani girişler, ağırlıklar, toplama işlevi, aktivasyon işlevi ve çıktılar bulunmaktadır. Girdi değerlerinin her biri bir bağlantı ağırlığı ile çarpılmaktadır. Bu ağırlıklar $w(i)$ ile

gösterilmektedir. Bu ağırlıklar ilgili girişin olay üzerindeki etkisini belirlemektedir. Toplanan bu çarpımlar bir transfer fonksiyonuna gönderilerek sonuç üretilir. Genelde aktivasyon işlemi doğrusal olmayan bir işlemdir. Temelde biyolojik nörona benzer şekilde, aktivasyon işlemi sonucunda bulunan değerin aktivasyon işlevinin eşik değerini aşması durumunda çıktı sinyali verilir. Bu matematiksel modelin gösterimi denklem (3.1)'deki gibidir.

$$o = f(W.X + \theta) \quad (3.1)$$

Buradaki W ağırlıklar matrisi, X ise girişler matrisidir.

Toplam işlevi denklem (3.2),

$$S = \sum_{j=0}^n w_{ij} x_j - \theta_i \quad (3.2)$$

şeklinde yazılabilir.

Çıktı değeri de ;

$$Y_i = \varphi\left(\sum_{j=0}^n w_{ij} x_j - \theta_i\right) \quad (3.3)$$

şeklindedir.

Denklem (3.3)'te w_{ij} ; i. nöronu j. nörona bağlayan ağırlık katsayısı, θ_i ise i. nörona ait aktivasyon işlevinin eşik değeridir. Denklem (3.4)'te transfer fonksiyonuna bağlı olarak çıkış değeri gösterilmiştir.

$$o = \varphi(S) \quad (3.4)$$

x_i = Giriş değerleri

w_{ij} = j. nöronu i. nörona bağlayan ağırlık değeri

o = Çıkış değeri

θ = Eşik

$\varphi(S)$ = Transfer (Aktivasyon) işlevi

Girdilerde meydana gelen deęişimler sonucu nöron çıkışlarında belirli bir deęişme olmaktadır. Bu deęişimin miktarı, o girdinin etkin olduęu aęlardaki aęırlık katsayılarına (girdinin etki derecesi), eşik deęerine ve nöron aktivasyon işlevinin tipine baęlıdır. Eşik deęerinin kullanımı, pratikte (-1) yada (+1) deęerine sahip sabit bir girdinin (θ) aęırlığına sahip bir baęıntı ile toplayıcıya girmesi şeklindedir.

3.5. Sigmoid Aktivasyon Fonksiyonu

Sigmoid aktivasyon fonksiyonu, toplama fonksiyonundan gelen ve toplam olarak gösterilen deęeri alır ve sıfır ile bir arasında bir deęere dönüştürür. Sıfır ile bir arasındaki bu deęer transfer fonksiyonun ve dolayısıyla işlem elemanın çıktısıdır ve dış ortama veya girdi olarak bir başka nörona iletilir.


Lojistik işlev olarak da adlandırılan bu işlevin lineer olmamasından dolayı türevi alınabilmekte ve geriye yayma algoritmasında da kullanılabilirler. Nöron cevabının, girdilerin sürekli bir fonksiyonu olmasını gerektiren durumlarda kullanılır.

Sigmoid tipi aktivasyon fonksiyonu denklem (3.5)'deki gibidir.

$$\Psi(s) = \frac{1}{1 + e^{-s}} \quad (3.5)$$

$\Psi(s)$: Aktivasyon fonksiyonu

s : Toplam fonksiyonu

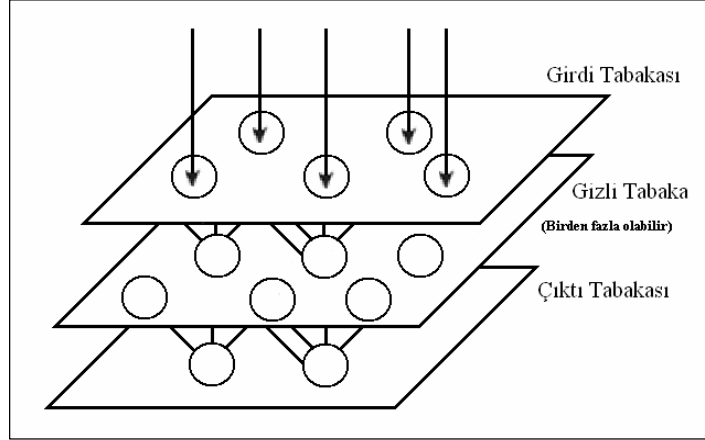


Şekil 3.3 Sigmoid tipli aktivasyon fonksiyonu (Firat ve Güngör 2004)

3.6. YSA'larda Öğrenme Algoritmaları

3.6.1. Hatayı geriye yayma algoritması

Yayınma ve uyum gösterme olmak üzere iki aşamada işlemleri gerçekleştiren geriye yayma algoritması katmanlar arasında tam bir bağlantının bulunduğu çok katmanlı, ileri beslemeli ve denetimli olarak eğitilen bir yapay sinir ağı modelidir.



Şekil 3.4 YSA'lardaki katmanlar (Anderson ve McNeill 1992)

Bu model içerisinde girdi, gizli ve çıktı olmak üzere üç katman bulunmakla birlikte, problemin özelliklerine göre gizli katman sayısını arttırabilmek mümkündür (şekil 3.4). Geri besleme bağlantılarının bulunmadığı bu modelde, bir katmandan bir başka katmana, aradaki katmanı atlayarak geçebilmek mümkün değildir. Bir girdi örüntüsü ağın ilk katmanında yer alan düğümlere uygulandığında, en üst katman olan çıktı katmanına erişilinceye kadar, bu örüntü üzerinde çeşitli işlemler gerçekleştirilir. Bu işlemlerin sonucunda elde edilen çıktı, olması gereken çıktı ile karşılaştırılır. Ağın bulunduğu değerler ile olması gereken değerler arasındaki fark, her çıktı düğümü için bir hata sinyali olarak hesaplanır. Hesaplanan hata sinyalleri, her çıktı düğümüne karşı gelen ara katmandaki düğümlere aktarılır. Böylece ara katmandaki düğümlerin her biri toplam hatanın sadece hesaplanan bir kısmını içerir. Bu süreç her katmandaki düğümler toplam hatanın belirli bir kısmını içerecek şekilde girdi katmanına kadar tekrarlanır. Elde edilen hata sinyalleri temel alınarak, bağlantı ağırlıkları her düğümde yeniden düzenlenir. Bu düzenleme tüm örüntülerin kodlanabileceği bir duruma doğru ağın yakınsamasını sağlar. Girdileri ve çıktıları arasında işlevsel bir ilişkiyi hesaplayabilen YSA haritalama ağı olarak isimlendirilmektedir.

Ağın eğitimindeki bu süreç ara katmanlardaki düğümlerin, farklı düğümlerin toplam girdi uzayının farklı özelliklerini tanıyacak şekilde, kendilerini organize etmeleri sağlanmaktadır. Eğitim sonrasında bozuk veya tam olmayan rasgele girdi örüntüleri verildiğinde, ağın gizli katmanlarındaki düğümler, yeni girdi eğitim sırasında öğrenilen örüntüleri anımsatacak bir örüntüye sahipse, aktif bir çıktı ile cevap vermektedir. Ancak yeni girdi örüntüsü, gizli katman düğümlerinin eğitim sırasında tanıdığı özellikleri içermiyorsa, bu düğümler çıktıyı engelleyici bir eğilime sahip olmaktadır.

$x_p = (x_{p1}, x_{p2}, \dots, x_{pN})^t$ şeklindeki bir girdi vektörü, ağın girdi katmanındaki düğümlere uygulandığında, gerekli hesaplamalar yapılarak elde edilen değerler gizli katman düğümlerine yayınırlar. h gizli katmanı, w_{ji}^h j. düğümün i. girdi katman düğümü ile olan bağlantı ağırlığını, θ_j^h eğim değerini göstermek üzere, gizli katmanda j. düğümün net girdi değeri,

$$net_{pj}^h = \sum_{i=1}^N w_{ji}^h x_{pi} + \theta_j^h \quad (3.6)$$

denklem (3.6)'dan hesaplanmaktadır. Bu düğüm için faaliyet değerlerinin net girdi değerlerine eşit olduğu kabul edildiğinde, bu düğümün çıktı değeri,

$$i_{pj} = f_j^h(net_{pj}^h) \quad (3.7)$$

denklem (3.7) şeklinde bulunacaktır. o gizli katmanı, w_{kj}^o k. düğümün j. gizli katman düğümü ile olan bağlantı ağırlığını, θ_k^o eğim değerini göstermek üzere, çıktı katmanı için k. düğümün net girdi ve çıktı değeri denklem (3.8) ve denklem (3.9)'daki

$$net_{pk}^o = \sum_{j=1}^L w_{kj}^o x_{pj} + \theta_k^o \quad (3.8)$$

$$o_{pk} = f_k^o(net_{pk}^o) \quad (3.9)$$

eşitliklerden hesaplanacaktır.

Katmanlarda yer alan düğümler arası bağlantı ağırlıklarının başlangıç değerlerinin belirlenmesi, problemin çözümüne giden yolda ilk adımdır. Bazı yöntemlerin aksine,

burada açıklanan teknik iyi bir ilk tahmin yapılmasına bağımlı değildir. Başlangıç ağırlık değerlerinin seçilmesinde, çeşitli yol gösterici yöntemler bulunmaktadır. Ağın eğitimi için izlenmesi gereken temel süreç sırasıyla şu aşamalardan meydana gelmektedir.

- Ağa bir girdi vektörü uygulanır ve buna ilişkin çıktı değeri hesaplanır.
- Olması gereken çıktı değeri ile fiili çıktı değeri karşılaştırılır ve elde edilen fark hata ölçüsü olarak yorumlanır.
- Hata değerini azaltabilmek için, her ağırlığın hangi yönde (- veya + yönde) değişmesi gerektiği belirlenir.
- Her ağırlık değerinin değişmesi gereken miktarı hesaplanır ve bu miktarlara göre ağırlık değerleri yeniden düzenlenir.
- Eğitim kümesindeki vektörler için hata değeri kabul edilebilir bir düzeye erişinceye kadar, yukarıdaki adımlar tekrarlanır.

En küçük kareler öğrenme kuralının temel denklemi,

$$w(t+1)_i = w(t)_i + 2\mu\epsilon_k x_{ki} \quad (3.10)$$

Denklem (3.10) şeklindedir. Bu denklemde μ pozitif sabit, x_{ki} k. eğitim vektörünün i. elemanını, ϵ_k ise gerçek çıktı ile tahmin edilen çıktı arasındaki farkı ($\epsilon_k = d_k - y_k$) göstermektedir. Benzer bir eşitlik ağın daha fazla katmandan meydana gelmesi ve çıktı fonksiyonunun doğrusal olmaması halinde de kurulabilmektedir.

3.6.1.1. Çıktı katmanındaki ağırlıkların düzenlenmesi

k. girdi vektörü için, d_k gerçek çıktıyı değerini, y_k tahmin edilen çıktı değerini gösterdiğinde, $\epsilon_k = d_k - y_k$ eşitliği ile elde edilen hata değeri, en küçük kareler kuralının türevi alınarak hesaplanmaktadır. Ancak geriye yayılım ağı çok katmanlı olduğu için, ϵ_k şeklindeki tek bir hata değerinin kullanılması yeterli olmayacaktır. Kullanılan simgeler değiştirilerek tek bir çıktı düğümünün hatası, $\delta_{pk} = (y_{pk} - o_{pk})$ şeklinde ifade edilecektir. Burada p, p. eğitim vektörünü; k ise k. çıktı düğümünü

göstermektedir. Bu durumda y_{pk} , olması gereken çıktı değerini, o_{pk} ise tahmin edilen çıktı değerini göstermektedir. Burada minimize edilecek hata, tüm çıktı düğümleri için elde edilen hataların karelerinin toplamı olacaktır.

$$E_p = \frac{1}{2} \sum_{k=1}^M \delta_{pk}^2 \quad (3.11)$$

Bu eşitlikte kullanılan 1/2 faktörü daha sonraki türev hesaplamalarında kolaylık sağlaması amacı ile ilave edilmektedir. En son elde edilecek sonuçta keyfi bir sabit olarak kalacağı için kullanımı sonucu etkilemeyecektir.

Ağırlıkların hangi yönde değişeceğinin belirlenmesi için, w_{kj} ağırlıklarını göz önüne alarak, E_p değerinin negatif gradyeni olan ∇E_p değerinin hesaplanması gerekmektedir. Daha sonra toplam hatayı azaltacak, ağırlık değişikliklerinin hesaplanması gerekmektedir. E_p 'yi ağırlık uzayında bir yüzey olarak düşünmekte yarar bulunmaktadır.

Olayları basitleştirebilmek için ∇E_p 'nin her elemanının ayrı ayrı göz önüne alınması gerekmektedir. 3.11 eşitliğinden ve δ_k 'nin tanımından denklem (3.12)

$$E_p = \frac{1}{2} \sum_k (y_{pk} - o_{pk})^2 \quad (3.12)$$

ve denklem (3.13)

$$\frac{\partial E_p}{\partial w_{kj}^o} = -(y_{pk} - o_{pk}) \frac{\partial f_k^o}{\partial (net_{pk}^o)} \frac{\partial (net_{pk}^o)}{\partial w_{kj}^o} \quad (3.13)$$

yazılabilir. Bu eşitliklerde o_{pk} çıktı değeri için denklem (3.9) ve kısmi türev kuralları uygulanmaktadır. Bu aşamada f_k^o 'nin türevinin alınması yerine basit olarak, türevi $f_k^{\prime o}(net_{pk}^o)$ şeklinde ifade edilmesi yoluna gidilmektedir. (3.13) eşitliğindeki son işlem,

$$\frac{\partial (net_{pk}^o)}{\partial w_{kj}^i} = \frac{\partial}{\partial w_{kj}^o} \sum_{j=1}^L w_{kj}^0 i_{pj} + \theta_k^0 = i_{pj} \quad (3.14)$$

denklem (3.14)'ten elde edilmektedir. (3.13) ve (3.14) eşitlikleri birleştirilerek negatif gradyenin hesaplanabilmesi için,

$$-\frac{\partial E_p}{\partial w_{kj}^o} = (y_{pk} - o_{pk}) f_k^{\prime o} (net_{pk}^o) i_{pj} \quad (3.15)$$

denklem (3.15) elde edilir. Ağırlık değerlerindeki değişme miktarı, (3.15) eşitliğinin negatif gradyeni alınarak hesaplanır. Böylece çıktı katmanındaki ağırlıklar,

$$\Delta_p w_{kj}^o(t) = \eta (y_{pk} - o_{pk}) f_k^{\prime o} (net_{pk}^o) i_{pj} \quad (3.16)$$

denklem (3.16)'daki gibi olmak üzere,

$$w_{kj}^o(t+1) = w_{kj}^o(t) + \Delta_p w_{kj}^o(t) \quad (3.17)$$

denklem (3.17)'ye göre yeniden düzenlenir. Burada da η değeri genellikle pozitif ve birden küçük olarak tanımlanan öğrenme hızını göstermektedir.

(3.15) eşitliğinde $f_k^{\prime o}$, f_k^o fonksiyonunun türevi olarak ifade edilmiştir. Çıktı fonksiyonunun iki durumu söz konusudur.

- $f_k^o(net_{jk}^o) = net_{jk}^o$
- $f_k^o(net_{jk}^o) = \left(1 + e^{-net_{jk}^o}\right)^{-1}$

Burada birinci fonksiyon doğrusal çıktı düğümünü tanımlamakta, ikinci fonksiyon ise *sigmoid* veya *logistic* fonksiyon olarak isimlendirilmektedir. Kullanılacak çıktı fonksiyonu, elde edilecek çıktı değerlerinin ikil veya sürekli olmasına göre seçilebilir. Örneğin çıktı değerlerinin ikil olması isteniyorsa sigmoid fonksiyon, diğer durumlarda problemin yapısına bağlı olarak doğrusal veya sigmoid çıktı fonksiyon seçilebilir. Birinci fonksiyonda,

$$f_k^{\prime o} = 1;$$

ikinci fonksiyonda ise

$$f_k^{\prime} = f_k^o (1 - f_k^o) = o_{pk} (1 - o_{pk})$$

olacaktır. Buradan doğrusal çıktı için,

$$w_{kj}^o(t+1) = w_{kj}^o(t) + \eta(y_{pk} - o_{pk})i_{pj} \quad (3.18)$$

denklem (3.18) ve *sigmoidal* çıktı için,

$$w_{kj}^o(t+1) = w_{kj}^o(t) + \eta(y_{pk} - o_{pk})o_{pk}(1 - o_{pk})i_{pj} \quad (3.19)$$

denklem (3.19) eşitlikleri kurulur. Ağırlık değerlerinin yeniden düzenlenmesi için kullanılacak olan denklemler,

$$\begin{aligned} \delta_{pk}^o &= (y_{pk} - o_{pk})f_k^{\prime}(net_{pk}^o) \\ &= \delta_{pk} f_k^{\prime}(net_{pk}^o) \end{aligned} \quad (3.20)$$

denklem (3.20)'deki gibi tanımlanacaktır. Bu durumda ağırlık değerlerinin yeniden düzenlenmesini sağlayan (3.20) eşitliği, f_k^{\prime} çıktı fonksiyonunun *doğrusal* veya *sigmoidal* olmasından bağımsız olarak,

$$w_{kj}^o(t+1) = w_{kj}^o(t) + \eta\delta_{pk}^o i_{pj} \quad (3.21)$$

denklem (3.21) ile yazılabilir.

3.6.1.2. Gizli katman ağırlık değerlerinin yeniden düzenlenmesi

Çıktı katmanı için yapılan hesaplamaların benzerinin, gizli katman için de tekrarlanması gerekmektedir. Ancak gizli katman düğümlerinin çıktı değerlerinin hata ölçüsünün belirlenmesinde bir problem ortaya çıkmaktadır. Çıktı katmanında, olması gereken çıktı değerleri baştan bilinmektedir. Buna karşılık gizli katmanda bulunan düğümlerin, olması gereken çıktı değerlerinin baştan bilinmesi mümkün değildir. Ancak toplam hata değeri olan E_p 'nin gizli katman düğümlerinin çıktı değerleri ile ilişki içinde olduğu (3.12) eşitliğine geri dönülerek düşünülebilir.

$$E_p = \frac{1}{2} \sum_k (y_{pk} - f_k^o(\text{net}_{pk}^o))^2$$

$$E_p = \frac{1}{2} \sum_k \left(y_{pk} - \left(\sum_k w_{kj}^o i_{pj} + \theta_k^o \right) \right)^2$$

i_{pj} değeri, (3.6) ve (3.7) eşitliklerinden gizli katmandaki ağırlık değerlerinin değişimine bağlı olduğundan, gizli katmandaki ağırlık değerlerinin toplam hatası olan E_p 'nin gradyeninin hesaplanması mümkün olacaktır.

$$\begin{aligned} \frac{\partial E_p}{\partial w_{ji}^h} &= \frac{1}{2} \sum_k \frac{\partial}{\partial w_{ji}^h} (y_{pk} - o_{pk})^2 \\ &= - \sum_k (y_{pk} - o_{pk}) \frac{\partial o_{pk}}{\partial (\text{net}_{pk}^o)} \frac{\partial (\text{net}_{pk}^o)}{\partial o_{pk}} \frac{\partial i_{pj}}{\partial (\text{net}_{pj}^h)} \frac{\partial (\text{net}_{pj}^h)}{\partial w_{ji}^h} \end{aligned} \quad (3.22)$$

(3.22) eşitliğinde yer alan tüm elemanlar, daha önceki eşitliklerden faydalanarak hesaplanabilir. Bu hesaplamaların sonucunda elde edile eşitlik,

$$\frac{\partial E_p}{\partial w_{ji}^h} = \sum_k (y_{pk} - o_{pk}) f_k^o{}'(\text{net}_{pk}^o) w_{kj}^o f_j^h{}'(\text{net}_{pj}^h) x_{pi} \quad (3.23)$$

Denklem (3.23)'teki gibi olacaktır. (3.23) eşitliğinden yararlanılarak, gizli katman ağırlık değerlerinin hesaplanması için,

$$\Delta_p w_{ji}^h = \eta f_j^h{}'(\text{net}_{pj}^h) x_{pi} \sum_k (y_{pk} - o_{pk}) f_k^o{}'(\text{net}_{pk}^o) w_{kj}^o \quad (3.24)$$

denklem (3.24) elde edilir. Önceki kısımda tanımlanan δ_{pk}^o 'nın ilavesi ile (3.24) eşitliği,

$$\Delta_p w_{ji}^h = \eta f_j^h{}'(\text{net}_{pj}^h) x_{pi} \sum_k \delta_{pk}^o w_{kj}^o \quad (3.25)$$

denklem (3.25) şeklinde yazılabilir.

Gizli katmanındaki ağırlık değerlerinin yeniden düzenlenmesi çıktı katmanındaki toplam hatayı gösteren δ_{pk}^o değerine bağlı olacaktır. Bu nedenle çıktı katmanındaki bilinen hata değerleri, gizli katmandaki uygun ağırlık değerlerinin belirlenebilmesi için gizli katmana doğru geriye yayınırlar. Bir gizli katman hata değerinin belirlenmesinde,

$$\delta_{pj}^h = f_j^h (net_{pj}^h) \sum_k \delta_{pk}^o w_{kj}^o \quad (3.26)$$

denklem (3.26) kullanılır. Buradan da çıktı katmanındaki hesaplamalara benzer şekilde gizli katmandaki ağırlık değerlerinin yeniden düzenlenebilmesi için,

$$w_{ji}^h(t+1) = w_{ji}^h(t) + \eta \delta_{pj}^h x_i \quad (3.27)$$

(3.27) eşitliğini yazmak mümkün olacaktır (Akpınar 1993).

3.6.1.3. Algoritmanın sorunları ve çözüm önerileri

Hatayı geriye yayma yöntemi geniş bir uygulama alanı bulmasına rağmen yöntemin uygulamadaki başarımı ve güvenilirliği konusunda bazı sorunlar vardır.

3.6.1.3.1. Öğrenme hızı

Bir eşleştirmeyi gerçekleştirmek üzere ele alınan bir sinir ağı yapısı, öğrenme süreci boyunca, N değişkenli bir ağ için (N+1) boyutlu bir uzayda, N değişkenli bir yüzey üzerinde gezen bir noktanın, maliyeti en aza indiren noktayı aramasını gerektirmektedir. Burada değinilen yüzeyin her bir uyarlanabilir değişken yönünde kısmi türevleri hesaplanmakta ve değişken güncelleme işlemi yapılmaktadır. Bu işlem değişken vektörünün bulunduğu noktayı, yüzey üzerinde bir başka noktaya kaydırmaktadır. Eğer değişkene göre alınan kısmi türevler çok küçük genlikte ve değişken vektörü optimal noktaya çok uzakta ise öğrenme işlemi çok uzun zaman alacaktır. Dolayısıyla veri kümesindeki tüm elemanlar göz önüne alındığında bu bölgelerde büyük bir maliyet ile karşılaşılacaktır.

Uygulanabilecek bir yöntem, maliyet fonksiyonundaki değişime göre adım büyüklüğünün aşağıdaki denklem (3.27) ile verilen biçimde değiştirilmesidir.

$$E = \sum J_r$$

$$\Delta\eta = \begin{cases} +\gamma & \Delta E < 0 \\ -\beta\eta & \Delta E > 0 \\ 0 & \Delta E = 0 \end{cases} \quad (3.28)$$

Denklem (3.28) ile verilen adım büyüklüğü uyarlaması, değişken vektörünün optimal noktaya yaklaştığı durumlarda türev genliklerinin küçülmesinden kaynaklanan yavaşlamayı da engelleyecektir (Efe ve Kaynak 2000).

3.6.1.3.2. Anlık sıçramalar

Değişken uzayında oluşan yüzey, eğitim çiftlerinde bulunabilecek gürültüden nümerik hassasiyetin birkaç ondalık ile sınırlı bulunduğu durumlardan ya da başka çevrel etkilerden dolayı düşük genlikli iniş çıkışlar içerebilir. Bu iniş çıkışlar, kısmi türevlerin anlık değerlerinin hesaplanması dolayısıyla değişken vektörünün optimal noktaya çok yakın olduğu durumlarda dahi türev genliklerinin çok yüksek noktaya ulaşmasına neden olabilirler. Bu tür ani sıçramalar, güncelleme kuralında momentum terimi olarak bilinen bir terimin kullanılması ile önlenir. Bu durumda değişken güncelleme kuralı denklem (3.29)'daki gibi olacaktır.

$$\Delta w_{ij}^k(K+1) = \mu \Delta w_{ij}^k(K) + \eta \delta_i^{k+1} o_j^k \quad (3.29)$$

Burada μ , *momentum katsayısı* olup (0, +1) aralığında seçilen reel bir sayıdır. Momentum terimi bir önceki değişken değişimini de gerektirdiğinden bellek gereksinimini artırıcı yönde bir donanım maliyetine neden olur (Efe ve Kaynak 2000).

3.6.2. Levenberg- Marquardt algoritması

Geri yayılım algoritması (GYA) çok kullanılmasına rağmen bazı dezavantajları bulunmaktadır. GYA sonuca çok yavaş olarak yaklaşmaktadır. Ayrıca lokal minimuma yakalanma riski de vardır. Geri yayılım, bir adım düşme algoritmasıyken, Levenberg - Marquardt (LM) algoritması Newton metoduna bir yaklaşımdır. LM algoritması, Newton metodunun hızıyla, adım düşme metodunun sağlamlığının bileşkesidir.

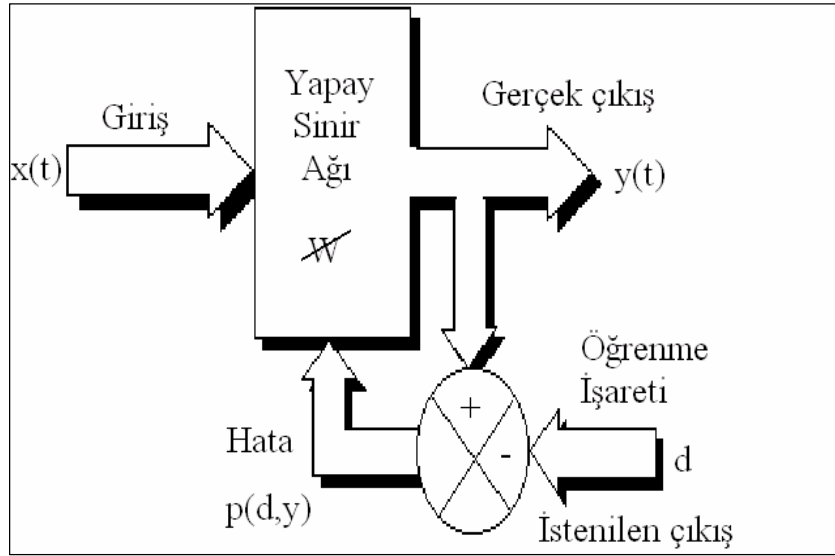
3.7. YSA'larda Öğrenme

Yapay nöronlarda, biyolojik nöronlara benzer olarak mevcut örnek kümesi üzerinde girdi ve çıktı arasındaki bağıntının ağırlıklarının değiştirilmesi ile eğitilirler. Sunulan

girdi kümesi için, transfer fonksiyonu tarafından sağlanan değerlere cevap olarak bağlantı ağırlıklarının tamamının veya bir kısmının istenen çıktı ile ağ çıktısı arasındaki farkın belirli bir değere düşünceye kadar eğitilmesidir. Bu amaçla günümüze kadar çeşitli öğrenme algoritmaları geliştirilmiştir. Bunlar temel olarak denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme olmak üzere üç ana gruba ayrılır.

3.7.1. Denetimli öğrenme

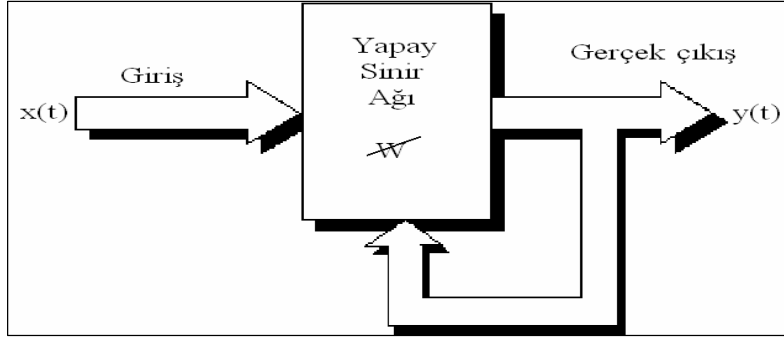
Bu tip öğrenmede, YSA'ya örnek olarak bir doğru çıkış verilir. İstenilen ve gerçek çıktı arasındaki farka hata olarak ele alınır göre ve bu hatalar minimize edilmeye çalışılır. Bunun içinde bağlantıların ağırlıkları en uygun çıkışı verecek şekilde değiştirilir. Bu sebeple danışmanlı öğrenme algoritmasının bir "öğretmene" veya "danışmana" ihtiyacı vardır. Şekil 3.5'de danışmanlı öğrenme yapısı gösterilmiştir (Saraç 2004).



Şekil 3.5 Denetimli öğrenme yapısı (Saraç 2004)

3.7.2. Denetimsiz öğrenme

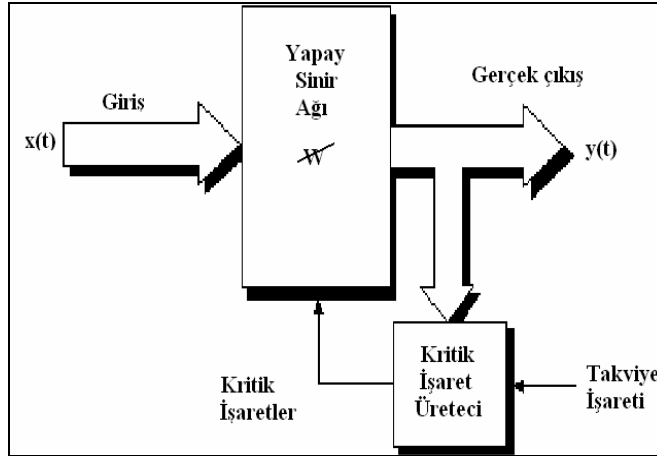
Bu tür öğrenmede ağı sadece girdiler verilir. Ağı ulaşması gereken hedef çıktılar verilmez. Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu öğrenme algoritmalarında, istenilen çıkış değerinin bilinmesine gerek yoktur. Öğrenme süresince sadece giriş bilgileri verilir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren desenler (patterns) oluşturmak üzere ayarlar. Şekil 3.6'da denetimsiz öğrenme yapısı gösterilmiştir (Saraç 2004).



Şekil 3.6 Denetimsiz öğrenme yapısı (Saraç 2004)

3.7.3. Takviyeli öğrenme

Bu öğrenme kuralı denetimli öğrenmeye yakın bir metottur. Denetimsiz öğrenme algoritması, istenilen çıkışın bilinmesine gerek duymaz. Hedef çıktıyı vermek için bir “öğretmen” yerine, burada YSA’ ya bir çıkış verilmemekte fakat elde edilen çıkışın verilen girişe karşılık iyiliğini değerlendiren bir ölçüt kullanılmaktadır. Şekil 3.7’de takviyeli öğrenme yapısı gösterilmiştir.




Şekil 3.7 Takviyeli öğrenme yapısı (Saraç 2004)

3.8. YSA Mimarileri

YSA, hücrelerin birbirleri ile çeşitli şekillerde bağlanmalarından oluşur. Hücre çıkışları, ağırlıklar üzerinden diğer hücelere ya da kendisine giriş olarak bağlanabilir ve bağlantılarda gecikme birimi de kullanılabilir. Hücrelerin bağlantı şekillerine, öğrenme kurallarına ve aktivasyon fonksiyonlarına göre çeşitli YSA yapıları geliştirilmiştir (Fırat 2002).

3.8.1. Geri beslemeli yapay sinir ağları (GBYSA)

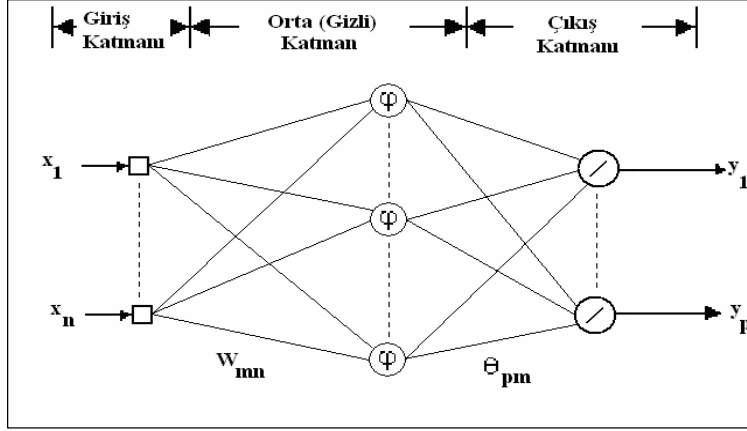
YSA ile yapılan çalışmalarda en çok kullanılan ağ mimarilerinden biri geri beslemeli ağ mimarisidir (Aqil vd 2007). Geri beslemeli YSA' da, en az bir hücrenin çıkışı kendisine ya da diğer hücrelere giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı üzerinden yapılır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli YSA, doğrusal olmayan dinamik bir davranış gösterir. Dolayısıyla, geri beslemenin yapılış şekline göre farklı yapıda ve davranışta geri beslemeli YSA yapıları elde edilebilir. Şekil 3.8'de iki katmanlı ve çıkışlarından giriş katmanına geri beslemeli bir YSA yapısı görülmektedir.



Şekil 3.8 Geri beslemeli iki katmanlı YSA yapısı

3.8.2. İleri beslemeli yapay sinir ağları (İBYSA)


İleri beslemeli YSA' da, hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta (gizli) katmandaki hücrelere iletir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir. Bu yapısı ile ileri beslemeli ağlar doğrusal olmayan statik bir işlevi gerçekleştirir. İleri beslemeli üç katmanlı YSA' nın, orta katmanında yeterli sayıda hücre olmak kaydıyla, herhangi bir sürekli fonksiyonu istenilen doğrulukta yaklaştırabileceği gösterilmiştir. En çok bilinen geriye yayılım öğrenme algoritması, bu tip YSA'ların eğitiminde etkin olarak kullanılmakta ve bazen bu ağlara geriye yayılım ağları da denmektedir. Şekil 3.9'da giriş, orta ve çıkış katmanı olmak üzere üç katmanlı ileri beslemeli YSA yapısı verilmiştir (Saraç 2004).



Şekil 3.9 İleri beslemeli üç katmanlı YSA yapısı (Saraç 2004)

3.8.3. Radyal tabanlı yapay sinir ağları (RTYSA)

RTYSA, ileri beslemeli YSA yapılarına benzer şekilde giriş, orta ve çıkış katmanından oluşur ancak, giriş katmanından orta katmana dönüşüm, radyal tabanlı aktivasyon fonksiyonları ile doğrusal olmayan sabit bir dönüşümdür. Orta katmandan çıkış katmanına ise uyarlamalı ve doğrusal bir dönüşüm gerçekleştirilir (Şekil 3.10).



Şekil 3.10 RTYSA yapısı

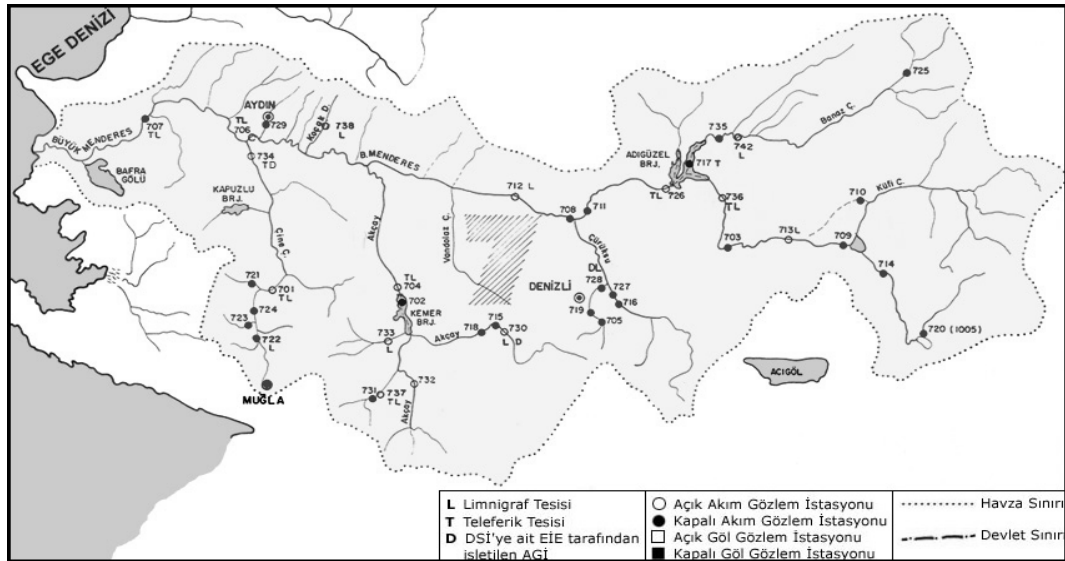
3.8.4. Diğer Yapay Sinir Ağı Mimarileri

Literatürde genellikle geri beslemeli ve radyal tabanlı YSA'ların kullanımına ek olarak son zamanlarda daha kompleks mimarilere sahip sinir ağları da geliştirilmiştir. Bu yeni nesil mimarilere örnek olarak fonksiyonel linkli, çağrışım bellekli, bellek hücreli ve modül YSA verilebilir.

4. ÇALIŞMA ALANI VE VERİ

4.1. Büyük Menderes Havzası

Büyük Menderes nehri, Batı Anadolu'nun en büyük akarsuyu ve Büyük Menderes Havzası'nın ana sulama kaynağıdır. Küfi Suyu ve Banaz Çayı kollarının birleşmesiyle oluşur ve Ege denizine dökülür. Uzunluğu 584 km'dir. Afyon İli Dinar İlçesi yakınlarında Suçikan Mevkii'nde doğar. Işıklı ve Küf'i Çayları'nı biriktiren Işıklı Barajı'ndan çıkıp Çivril, Çal ve Baklan Ovaları'nı geçer ve Çal'ın doğusundan kuzeye dönerek, Güney İlçesi'ne doğru derin bir yatakta akar. Uşak 'tan gelen ve Menderes'in en büyük kollarından olan Banaz Çayı'nı da alarak, Sarayköy Ovası'na iner. Denizli hudutları içindeki Çürüksu ve Gökpınar Çayları ile beslenerek batı yönünde ilerler. Nazilli, Aydın ve Söke Ovaları'nı besleyip 560 km. uzunluğundaki yolculuğunu Söke İlçesi Dipburun Mevkii'nde Ege Denizi'ne dökülerek tamamlar. Büyük Menderes havzası 24 976 km² drenaj alanına ve 3,03 km³ yıllık ortalama akışa sahiptir. Büyük Menderes Havzası'nın genel görünüşü Şekil 4.1'de verilmiştir.



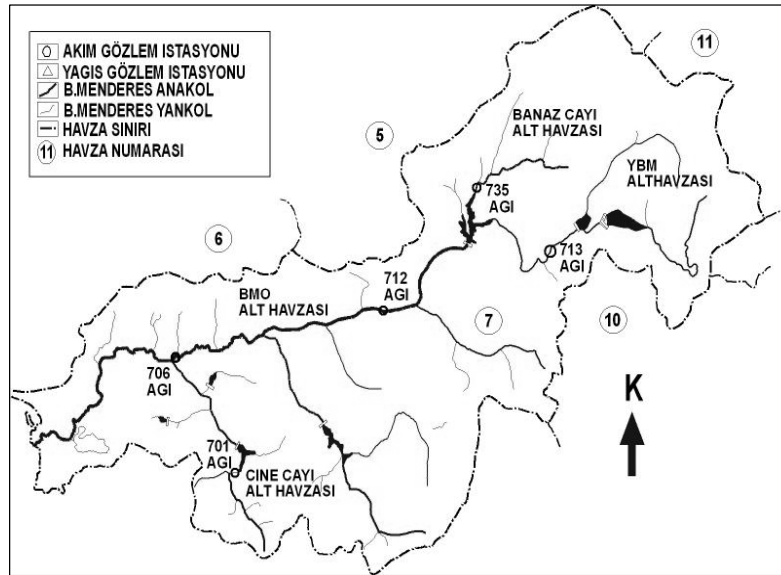
Şekil 4.1 Büyük Menderes havzası genel yapısı

4.2. Banaz Çayı

Banaz ilçesinin 14 km. kadar kuzeyinden geçen Banaz Çayı, Murat Dağı'ndan doğarak kuzey-güney doğrultusunda akarak Denizli il sınırları içinde Büyük Menderes

nehri ile birleşir. Uzunluğu 165 km.dir. Fındık deresi, Gökkaya deresi, Gürlek deresi ve İrmez köyünden çıkan küçük su kollarının birleşmesi ile beslenir. Önemli kolları Kusura ve Yavru deresidir.

Bu tez kapsamında kullanılan çalışma alanı, Büyük Menderes Nehri'nin ilk doğduğu kesimde ve Adıgüzel Barajı'nı besleyen ana kolun oluşturduğu Yukarı Büyük Menderes alt havzası ile Adıgüzel Barajı'nı besleyen diğer bir kol olan Banaz Çayı'nın oluşturduğu Banaz Çayı alt havzasıdır. Söz konusu alt havzalar Şekil 4.2'de verilmiştir.



Şekil 4.2. Büyük Menderes havzasının alt havzaları (Fırat 2007)

Çalışma alanı içinde yer alan Adıgüzel Barajı, **Büyük Menderes** Nehri üzerinde kurulu, sulama, enerji üretim ve taşkın koruma amaçlı kullanılan kaya dolgu bir **barajdır**. 1992 yılında işletmeye açılan barajın yüksekliği 145 metredir. Adıgüzel Barajı'nın göl hacmi $1,07 \cdot 10^6 \text{ m}^3$ olup alanı 26 km^2 dir. Adıgüzel Barajı yıllık 280000 mw/h enerji üretim kapasitesine sahiptir.

4.3. Veri

Çalışma alanında E.İ.E.İ. Genel Müdürlüğü tarafından, Hidrometrik Gözlem İstasyonlarında düzenli olarak yapılmakta olan seviye ve akım ölçümleri yanında, nehrin değişik seviyelerinden o andaki nehir kesitinden geçen debiyi temsil edecek

şekilde, askıda taşınan katı madde örnekleri derinlik entegrasyon yöntemine göre alınmaktadır.

Çalışmada kullanılan Yukarı Büyük Menderes alt havzasındaki 713 Nolu AGİ ile Banaz Çayı alt havzasındaki 735 Nolu AGİ'ye ait akım ve katı madde gözlem değerleri E.İ.E.İ'den temin edilmiştir. Katı madde miktarının tahmini için kullanılan AGİ'lere ait bilgiler Tablo 4.1'de verilmiştir.

Tablo 4.1. Çalışma alanındaki AGİ'ler

AGİ no ve Adı	Açılma Tarihi	Kapanma Tarihi	Alan (km ²)	Kot (m)	Coğrafi Koordinat
713- B. Menderes Çıtak Köprü	12.05.1951	-	3945.60	802	29 38 23D-38 09 25K
735-Banaz çayı Dört Değirmen	29.09.1987	01.10.2000	3226.60	467	29 14 19D-38 20 11K

Çalışma alanındaki AGİ'lere ait çeşitli istatistiksel ölçütler hesaplanmış ve Tablo 4.2'de verilmiştir.

Tablo 4.2. AGİ'lere ait akış verilerinin yapısı

AGİ no	Veri Aralığı	Veri Sayısı	x_{\min}	x_{\max}	\bar{x}	s_x	C_{sx}
Q ₇₁₃ (m ³ /s)	01.10.1972-30.09.2000	10228	0.06	75.80	9.96	9.78	1.12
Q ₇₃₅ (m ³ /s)	01.10.1989-30.09.2000	4383	1.50	69.90	5.35	4.65	3.82

Katı madde ölçümlerinin 713 Nolu AGİ için 1975 – 1985 ve 735 Nolu AGİ için 1989 – 1998 yılları arasında ölçülmüş olması nedeniyle tez çalışmasında bu yıllar arasındaki akım gözlemleri kullanılmış ve katı madde gözlemlerinin olduğu günlere karşılık gelen değerler ile otokorelasyon analizi sonucu giriş değişkeni olarak aldığımız t-1 ve t-2 güne karşılık gelen önceki değerler akım gözlemleri arasından seçilmiştir. Katı madde tahmin modellerinde kullanılan AGİ'lerden alınan akım değerlerine ait çeşitli istatistiksel veriler hesaplanmış ve Tablo 4.3 ve Tablo 4.4.'te verilmiştir.

Tablo 4.3. Katı madde tahmininde kullanılan 713 Nolu AGİ'ye ait verilerin yapısı

AGİ no	Veri Aralığı	Veri Sayısı	x_{\min}	x_{\max}	\bar{x}	s_x	C_{sx}
Q ₇₁₃ (m ³ /s)	06.01.1975-13.02.1985	119	1.9	75.8	13.569	11.743	1.621
Q _{713(t-1)} (m ³ /s)	06.01.1975-13.02.1985	119	1.99	37	13.259	10.385	0.694
Q _{713(t-2)} (m ³ /s)	06.01.1975-13.02.1985	119	2.09	38.7	13.526	10.539	0.689

Tablo 4.4. Katı madde tahmininde kullanılan 735 Nolu AGİ'ye ait verilerin yapısı

AGİ no	Veri Aralığı	Veri Sayısı	x_{\min}	x_{\max}	\bar{x}	s_x	C_{sx}
Q ₇₃₅ (m ³ /s)	18.09.1989-20.07.1998	108	1.587	16.379	4.92	3.290	1.454
Q _{735(t-1)} (m ³ /s)	18.09.1989-20.07.1998	108	1.68	17.9	4.74	3.295	1.933
Q _{735(t-2)} (m ³ /s)	18.09.1989-20.07.1998	108	1.5	21.3	5.03	3.877	2.226

Katı madde tahmin modellerinde kullanılacak katı madde ölçüm değerlerine ait bilgiler Tablo 4.5’de verilmiştir.

Tablo 4.5. Tahminler için kullanılan katı madde gözlem istasyonları

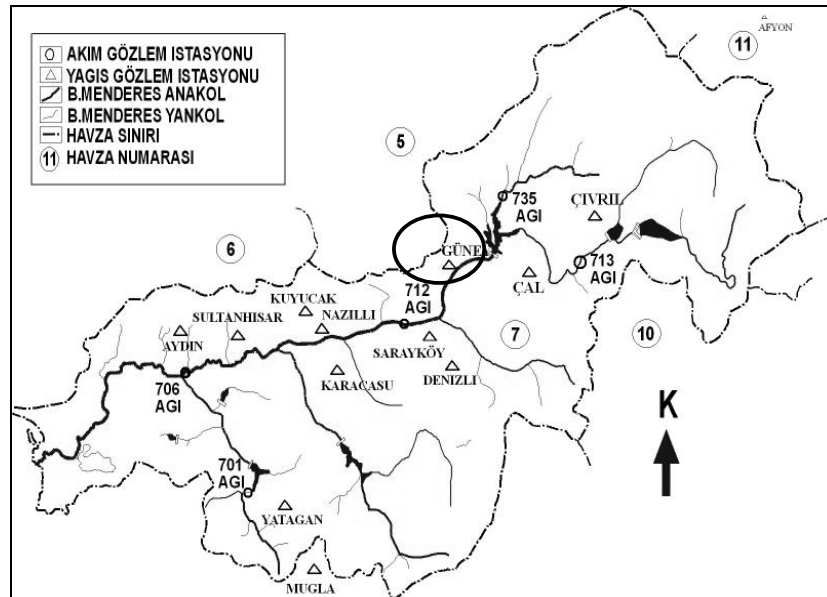
AGİ no ve Adı	Açılma Tarihi	Kapanma Tarihi	Alan (km ²)	Kot (m)	Coğrafi Koordinat
713 - B. Menderes Çıtak Köprü	18.12.1972	13.02.1985	3945.60	802	29 38 23D–38 09 25K
735 - Banaz çayı Dört Değirmen	18.09.1989	20.07.1998	3226.60	467	29 14 19D–38 20 11K

Tablo 4.5’de verilen katı madde gözlem istasyonlarına ait çeşitli istatistiksel değerler hesaplanmış ve Tablo 4.6’da verilmiştir.

Tablo 4.6. Tahminlerde kullanılacak katı madde verilerinin yapısı

AGİ no	Veri Aralığı	Veri Sayısı	x_{min}	x_{max}	\bar{x}	S_x	C_{sx}
S ₇₁₃ (ton/gün)	06.01.1975–13.02.1985	119	0.5	1299.9	110.902	163.726	4.072
S ₇₃₅ (ton/gün)	18.09.1989–20.07.1998	108	1.8	3289.2	115.8	377.401	6.981

Çalışma alanında çeşitli yıllarda Devlet Meteoroloji İşleri (DMİ) tarafından kurulmuş birçok yağış gözlem istasyonu (YAGİ) bulunmaktadır. Katı madde tahmini için bu AGİ’lerin membaında yer alan Denizli ili Güney ilçesindeki 17824 Nolu YAGİ’ye ait günlük toplam yağış değerleri kullanılmıştır. Güney ilçesindeki 17824 Nolu YAGİ ile Büyük Menderes havzasındaki diğer YAGİ’ler Şekil 4.3’de verilmiştir.



Şekil 4.3 Büyük Menderes havzasına ait YAGİ’ler (Fırat 2007)

17824 Nolu YAGİ’de 01.01. 1975 – 31.12.2005 tarihi arasında ölçülmüş günlük toplam yağış miktarına (mm) ait istatistiksel bilgiler Tablo 4.7’de verilmiştir.

Tablo 4.7 17824 Nolu YAGİ'ye ait yağış verilerinin yapısı

YAGİ no ve Adı	Veri Aralığı	Veri Sayısı	x_{\min}	x_{\max}	\bar{x}	s_x	c_{sx}
17824 – Güney	01.01.1975 – 31.12.2005	11323	0	72,7	1,415	4,78	5,71

Çalışma alanındaki askıda taşınan katı madde ölçümlerinin 713 Nolu AGİ için 1975 – 1985 ve 735 Nolu AGİ için 1989 – 1998 yılları arasında olması nedeniyle tez çalışmasında bu yıllar arasındaki yağış gözlemleri kullanılmış ve katı madde gözlemlerinin olduğu günlere karşılık gelen değerler ile otokorelasyon analizi sonucu giriş değişkeni olarak almayı düşündüğümüz t-1 ve t-2 güne karşılık gelen önceki değerler akım gözlemleri arasından seçilmiştir. Katı madde tahmin modellerinde kullanılan YAGİ'lere ait çeşitli istatistiksel veriler hesaplanmış ve Tablo 4.8'de ve Tablo 4.9'da verilmiştir.

Tablo 4.8 713 Nolu AGİ için tahminlerde kullanılacak yağış verilerinin yapısı

YAGİ no	Veri Aralığı	Veri Sayısı	x_{\min}	x_{\max}	\bar{x}	s_x	c_{sx}
P ₁₇₈₂₄ (mm)	06.01.1975–13.02.1985	119	0	21.1	1.338	3.807	3.838
P ₁₇₈₂₄ (t-1) (mm)	06.01.1975–13.02.1985	119	0	19.1	1.082	3.260	3.766
P ₁₇₈₂₄ (t-2) (mm)	06.01.1975–13.02.1985	119	0	29.8	1.545	4.845	4.145

Tablo 4.9 735 Nolu AGİ için tahminlerde kullanılacak yağış verilerinin yapısı

YAGİ no	Veri Aralığı	Veri Sayısı	x_{\min}	x_{\max}	\bar{x}	s_x	c_{sx}
P ₁₇₈₂₄ (mm)	18.09.1989–20.07.1998	108	0	39.2	1.892	5.841	4.192
P ₁₇₈₂₄ (t-1) (mm)	18.09.1989–20.07.1998	108	0.3	30.9	7.52	9.104	1.605
P ₁₇₈₂₄ (t-2) (mm)	18.09.1989–20.07.1998	108	0.2	27.2	6.82	8.529	1.482

5. KATI MADDE TAHMİN MODELLERİ

5.1. Giriş

Akarsularda taşınan katı madde hareketinin modellenmesi hidrolojinin en karmaşık problemlerinden biridir. Gerek ilişkinin birçok değişkene bağlı olması gerekse havza karakteristiğinin havza içinde bölgeden bölgeye değişmesi modellerin tespitini zorlaştırmaktadır. Yağış ve akış değişkenlerine bağlı olan katı madde hareketinin tahmini gerek akarsular üzerine inşa edilen su yapılarının ölü hacim kapasitelerinin hesabı gerekse havzalara ait erozyon probleminin çözümü için çok önemlidir.

Yukarıda bahsedilen önemin sonucunda 1930'lu yıllardan günümüze kadar çok farklı akış – katı madde ve yağış ile akış değişkenleri kullanılarak katı madde miktarının hesabı için pek çok model geliştirilmiştir. Bu modeller regresyon modelleri, stokastik modeller, kavramsal ya da parametrik modeller ile dinamik modeller olarak özetlenebilir.

Geliştirilen en son tekniklerden biri olan YSA, model üretiminde doğrusal ve doğrusal olmayan sistemlerin modellenmesi çalışmalarında kullanılmaya başlamıştır. Hidrolojide özellikle günlük yağış – akış ve katı madde ilişkisi, kar – yağmur ilişkisi, iklim değişikliklerinden dolayı bir akarsudaki ekolojik ve hidrolojik tepkilerin değerlendirilmesi, su kalitesinin iyileştirilmesi ve yer altı suyunun kalitesinin analizi gibi problemlerde çözüm yolu olarak kullanılmıştır. Doğrusal olmayan olaylar arasındaki ilişkinin YSA ile daha etkin bir şekilde belirlenebilmesi yöntemin her geçen popülerliğini arttırmaktadır (Argawal vd 2006).

5.2. Giriş Değişkenlerinin Belirlenmesi

YSA'ların performansını etkileyen en önemli unsurlardan birisi de girdi değişkenlerinin belirlenmesidir. Özellikle doğal olaylar gibi karmaşık ilişkilerin modellenmesinde, model sonuçlarını etkileyebilecek birçok değişken olabilir. Hidrolojik olaylarda genellikle yağış, akım ve katı madde gibi zaman serileri kullanılmaktadır. Stokastik süreç olarak tanımlayabileceğimiz bu tip değişkenlerin kendi içlerinde de bağımlılıkları vardır. Örnek vermek gerekirse bu gün yağan yağış etkisini kendinden sonra gelen birkaç günde de göstermektedir. Serilerdeki bu içsel

bağımlılığın derecesini dikkate almak için içsel korelasyon (otokorelasyon) hesabı yapılmalıdır.

Çalışmanın bu aşamasında Tablo 4.2’de verilen 713 nolu AGİ’ ye 735 nolu AGİ’ye ait günlük ortalama akımlar (m^3/s) ile Tablo 4.7’de verilen 17824 nolu YAGİ’ye ait günlük toplam yağış (mm) değerleri için içsel korelasyonlar (otokorelasyon) hesaplanmıştır.

Tablo 5.1 YAGİ ve AGİ’lere ait otokorelasyon katsayıları

	P_{17824}	Q_{713}	Q_{735}
Otokorelasyon	0,19	0,97	0,98
	0,06	0,95	0,95
	0,02	0,93	0,93

Tablo 5.1’den de görüldüğü gibi yağış değişkeni için içsel bağımlılık 2 günden sonra önemli bir ölçüde azalmaktadır. Akım verileri içinse içsel bağımlılıkta net bir azalma görülmemektedir.

Ayrıca 713 ve 735 nolu AGİ’lerde ölçülen katı madde miktarları (ton /gün) ile girdi değişkenleri arasındaki korelasyonun dikkate alınması için parametrik olan Pearson korelasyon katsayısı ile parametrik olmayan Kendall ve Spearman korelasyon katsayıları hesaplanmıştır ve Tablo 5.2 ve 5.3’te verilmiştir.

Özellikle parametrik olan Pearson korelasyon katsayısına bakacak olursak her iki istasyona ait gerek akım değerleri gerekse yağış değerleri ile katı madde gözlem değerleri arasındaki anlamlılığın t-2 günden sonra kaybolduğu Tablo 5.2 ve 5.3’te açıkça görülmektedir.

Tablo 5.2 713 Nolu AGİ’deki katı madde tahmini için korelasyonlar

Giriş değişkeni	$S(t)_{713}$		
	Pearson	Kendall	Spearman
$Q(t)_{713}$	0,611	0,627	0,823
$Q(t-1)_{713}$	0,456	0,549	0,748
$Q(t-2)_{713}$	0,445	0,521	0,723
$P(t)$	0,030	-0,086	-0,113
$P(t-1)$	-0,045	-0,095	-0,123
$P(t-2)$	-0,052	-0,04	-0,127

Tablo 5.3 735 Nolu AGİ'deki katı madde tahmini için korelasyonlar

Giriş değişkeni	$S(t)_{735}$		
	Pearson	Kendall	Spearman
$Q(t)_{735}$	0,438	0,547	0,738
$Q(t-1)_{735}$	0,282	0,521	0,713
$Q(t-2)_{735}$	0,175	0,499	0,694
$P(t)$	0,589	0,275	0,341
$P(t-1)$	0,574	0,264	0,335
$P(t-2)$	0,287	0,251	0,320

Verilerin uyumluluğu açısından yağış verilerinin 2 günden sonra anlamlılığını yitirdiği dikkate alınarak 2 gün öncesine kadar olan yağış ve akış verileri giriş değişkeni olarak seçilmiştir. Tablo 5.4 ve 5.5'te katı madde tahmini için kullanılan modeller gösterilmiştir.

Tablo 5.4 713 Nolu AGİ için kurulan katı madde tahmin modelleri

Model	Giriş Yapısı	Değişken Sayısı	Çıkış
1	$Q(t)_{713}$	1	$S(t)_{713}$
2	$Q(t)_{713} Q(t-1)_{713}$	2	$S(t)_{713}$
3	$Q(t)_{713} Q(t-1)_{713} Q(t-2)_{713}$	3	$S(t)_{713}$
4	$Q(t)_{713} P(t)$	2	$S(t)_{713}$
5	$Q(t)_{713} Q(t-1)_{713} P(t)$	3	$S(t)_{713}$
6	$Q(t)_{713} Q(t-1)_{713} Q(t-2)_{713} P(t)$	4	$S(t)_{713}$
7	$Q(t)_{713} P(t) P(t-1)$	3	$S(t)_{713}$
8	$Q(t)_{713} Q(t-1)_{713} P(t) P(t-1)$	4	$S(t)_{713}$
9	$Q(t)_{713} Q(t-1)_{713} Q(t-2)_{713} P(t) P(t-1)$	5	$S(t)_{713}$
10	$Q(t)_{713} P(t) P(t-1) P(t-2)$	4	$S(t)_{713}$
11	$Q(t)_{713} Q(t-1)_{713} P(t) P(t-1) P(t-2)$	5	$S(t)_{713}$
12	$Q(t)_{713} Q(t-1)_{713} Q(t-2)_{713} P(t) P(t-1) P(t-2)$	6	$S(t)_{713}$

Tablo 5.4 ve 5.5'te gösterildiği gibi girdi değişkeni sayısı 1 ila 6 arasında olup modeller sadece akış değişkenlerini içeren modeller ile hem akış hem yağış değişkenlerini içeren modeller olarak ele alınmıştır. Yağış değişkeninin katı madde taşınımı olayında etkisinin dolaylı olması nedeniyle sadece yağış değişkeni içeren modeller bu tez kapsamında kullanılmamıştır.

Tablo 5.5 735 Nolu AGİ için kurulan katı madde tahmin modelleri

Model	Giriş Yapısı	Değişken Sayısı	Çıkış
1	$Q(t)_{735}$	1	$S(t)_{735}$
2	$Q(t)_{735} Q(t-1)_{735}$	2	$S(t)_{735}$
3	$Q(t)_{735} Q(t-1)_{735} Q(t-2)_{735}$	3	$S(t)_{735}$
4	$Q(t)_{735} P(t)$	2	$S(t)_{735}$
5	$Q(t)_{735} Q(t-1)_{735} P(t)$	3	$S(t)_{735}$
6	$Q(t)_{735} Q(t-1)_{735} Q(t-2)_{735} P(t)$	4	$S(t)_{735}$
7	$Q(t)_{735} P(t) P(t-1)$	3	$S(t)_{735}$
8	$Q(t)_{735} Q(t-1)_{735} P(t) P(t-1)$	4	$S(t)_{735}$
9	$Q(t)_{735} Q(t-1)_{735} Q(t-2)_{735} P(t) P(t-1)$	5	$S(t)_{735}$
10	$Q(t)_{735} P(t) P(t-1) P(t-2)$	4	$S(t)_{735}$
11	$Q(t)_{735} Q(t-1)_{735} P(t) P(t-1) P(t-2)$	5	$S(t)_{735}$
12	$Q(t)_{735} Q(t-1)_{735} Q(t-2)_{735} P(t) P(t-1) P(t-2)$	6	$S(t)_{735}$

Yağış ve akış değişkenleri kullanarak katı madde modellemesi, Alyuda Research Company tarafından doğal olayların ve fonksiyonların tahmini ile sınıflandırma problemlerinin tahmini için geliştirilmiş bir YSA yazılımı olan Alyuda Neuro Intelligence programı ile yapılmıştır.

Alyuda Neuro Intelligence programı ile YSA'ların geliştirilmesi altı aşamadan oluşmaktadır. Programda modellerin geliştirilmesi ayrı bir adım olarak ele alınırken eğitim ve test aşamaları birbiri ardına uygulanmaktadır. Sorgulama aşaması içinse kullanıcı tarafından girilen yeni veriler test esilmektedir. Ele alınan aşamalar aşağıda gösterilmektedir.

- Veri Gruplarının Analizi
- Veri Gruplarının Ön İşleme Tabi Tutulması
- Tahmin Modelinin Geliştirilmesi
- Yapay Sinir Ağının Eğitimi
- Yapay Sinir Ağının Test Edilmesi
- Yapay Sinir Ağının Sorgulanması

5.3. Veri Gruplarının Analizi

Veri kümelerine ön işlem uygulamadan önce analiz edilmesi gereklidir. Bu aşamada veriler öğrenme kümesi, onaylama kümesi ve test kümesi şeklinde üç gruba ayrılır ve her veri kümesinin anormallikleri program tarafından araştırılır. Bu analiz sonucunda hangi değerlerin atlanmış (missing values), hangi değerlerin ağ için uygun olup olmadığı ve kullanılabilirliği tespit edilir.

Veri kümesi el ile, ya da Alyuda Neuro Intelligence program menüsündeki “Verileri Bölme Seçenekleri” (Data Partition Options) butonu kullanılarak aşağıdaki gibi üç sınıfa bölünebilir.

- **Öğrenme Kümesi (Training Set):** Bu veri kümesi ağ ağırlıklarının ayarlanması için öğrenmenin yapıldığı veri kümesidir.
- **Onaylama Kümesi (Validation Set):** Ağ ağırlıklarından farklı olarak ağ değişkenlerinin ve ağ topolojisinin ayarlanması için kullanılan veri kümesidir. Ağın performansının bozulmaya başladığı andaki momentin tespitindeki gizli birim sayısını tanımlamaya yarar. Ayrıca, program genelleme kayıplarının hesabı için onaylama kümesini kullanır ve en az hatalı ağı hafızasına ağ ağırlıkları ile beraber kaydeder.
- **Test Kümesi (Test Set):** Girdi kümesinin bir parçası olup sadece yapay sinir ağının yeni veriler üzerinde nasıl çalıştığının tespitinde kullanılır. Test verileri, öğrenme ve onaylama aşamasında hazırlanmış ve hafızaya kaydedilmiş ağ ağırlıkları ile, gelecek ağ uygulamaları boyunca meydana gelecek hataların ne olduğunu tespit etmek için kullanılır. Bu veri kümesi öğrenme boyunca kullanılamaz ve böylece YSA için kullanıcı tarafından girilmiş yeni verilerden ibaret olduğu düşünülebilir.

Bu veri kümelerini sınıflandırma işlemi, program tarafından % olarak ya da veri sayısı olarak yapılabileceği gibi, ekran üzerinden kullanıcı tarafından da yapılabilmektedir. Ayrıca program, veri dağılımını ardışık olarak yapabildiği gibi rasgele olarak ta yapabilmektedir

Veri dağılımının rastgele ya da ardışık seçimi, ağ performansının değerini arttıran ve tahminlerin kalitesini etkileyen bir faktördür. Bu etkiyi dikkate almak için *ardışık veri dağılımı* uygulanmıştır.

Yapılan tüm tahmin çalışmalarında, daha iyi bir tahmin için, çapraz geçerlilik (cross validation) yöntemi kullanılmıştır. Bu yöntemde veri kümesi her birinde **m** adet veri bulunan **n** adet alt kümelerle ayrılmakta ve veri kümeleri sistematik bir şekilde her biri hem eğitim, hem onaylama hem de test kümesi içerisinde kullanılacak şekilde düzenlenmektedir. Bu sayede her bir alt küme hem eğitim, hem onaylama, hem de test kümesi içerisinde yer almakta ve bu sayede tüm veri kümesinin karakteristiğini yansıtacak en uygun küme yapısı belirlenmektedir (Fırat 2007).

Çalışmanın bu aşamasında her veri grubu, en uygun veri yapısını araştırmak için sırasıyla dört farklı şekilde veri kümelerine ayrılmıştır. Her bir yapı için öğrenme kümesi %70, onaylama kümesi %20 ve test kümesi %10 oranında veri içermektedir. En uygun yapının araştırılmasında kullanılan yapılar Tablo 5.6'da gösterilmiştir

Tablo 5.6 En uygun yapının araştırılması için ayrılan farklı giriş değişkenleri

Veri Kümesi Yapısı			
1	2	3	4
%35 Öğrenme	%20 Onaylama	%35 Öğrenme	%10 Test
%10 Test	%35 Öğrenme	%20 Onaylama	%35 Öğrenme
%20 Onaylama	%10 Test	%35 Öğrenme	%35 Öğrenme
%35 Öğrenme	%35 Öğrenme	%10 Test	%20 Onaylama

Analiz aşamasında yapılan diğer bir işlem ise, veri anormalliklerinin tespiti ve bu anormal verilerin dışlanmasıdır. Veri anormallikleri *eksik, yanlış girilmiş ve ekstrem değerler* olmak üzere üç sınıfta araştırılır.

Program istatistiksel veri analizini kullanarak ekstrem değerleri hesaplar. İlk önce veri sütununun ortalama ve standart sapması hesaplanır.

- $\text{değer} < \text{ortalama} - \text{sınır değer katsayısı} * \text{standart sapma}$
- $\text{değer} > \text{ortalama} + \text{sınır değer katsayısı} * \text{standart sapma}$

Bu şartları sağlamayan değerler uzaklaştırılır. Farklı veri kümeleri için farklı katsayılar kullanılabilir. Sınır değer katsayısı genellikle 2–4 arasında seçilir. Çok daha fazla ekstrem durumu uzaklaştırmak için bu katsayı büyük seçilebilir.

Yapılan çalışmada konunun önemi gereği taşkın debilerinin büyük önem taşıması ekstrem değerlerin önemini arttırmaktadır. Bu önem dikkate alınarak çalışmada aşırı değerler atılmamıştır.

Analiz işlemleri sonucunda, bu çalışmada kullanılan veri kümelerinde herhangi eksik, yanlış girilmiş ya da ekstrem değerlere rastlanılmamıştır. Bu aşamada oluşturulan giriş yapıları ve bu verilerin analizine ait bir örnek Şekil 5.1’de verilmiştir

The screenshot displays the NeuroIntelligence software interface. The main window is titled "1.apr - Alyuda NeuroIntelligence". The interface includes a menu bar (File, View, Data, Network, Query, Options, Help) and a toolbar with various icons for file operations, analysis, and training. The "Raw Data" window shows a table with columns: TARİH, (N) YAĞIŞ, (N) YAĞIŞ (-1), (N) YAĞIŞ (-2), (N) AKIŞ, (N) AKIŞ (-1), (N) AKIŞ (-2), and (N) SEDİMENT. The "Analysis Report" window provides details on data import and analysis results.

TRN	TARİH	(N) YAĞIŞ	(N) YAĞIŞ (-1)	(N) YAĞIŞ (-2)	(N) AKIŞ	(N) AKIŞ (-1)	(N) AKIŞ (-2)	(N) SEDİMENT
TRN	18.09.1989	0	0	0	2,75	2,68	2,57	4,9
TRN	17.10.1989	21,3	0,3	0	3,4	3,16	3,16	1,8
TRN	21.11.1989	0	0	0	3,486	3,54	3,41	3
TRN	19.12.1989	0	0	0	5,732	6,24	7,1	26
TRN	18.01.1990	0	0	0	5,038	4,95	5,1	36,6
TRN	22.02.1990	0	0	0	6,169	6,26	6,43	54,7
TRN	14.03.1990	0	0	0	6,339	6,43	6,43	24,8
TRN	10.04.1990	0	0	0,2	4,995	5,07	4,92	10,9
TRN	21.05.1990	0	0	0	5,671	5,74	5,57	143,2
TRN	28.06.1990	0	0	0	3,383	3,23	3,23	5,1
TRN	25.07.1990	0	0	0	2,104	2,41	2,41	8,9
TRN	24.08.1990	0	0	0	2,175	2,18	2,18	8,5
TRN	12.09.1990	0	0	0	2,412	2,3	2,3	2,9
TRN	16.10.1990	0	0	0	2,671	2,65	2,53	8,3
TRN	06.11.1990	0	0	0	2,876	2,88	2,88	11,6
TRN	05.12.1990	0,7	23,6	8,7	5,911	4,27	3,81	146,1
TRN	08.01.1991	0	0	0	6,316	6,09	6,43	28,6
TRN	05.02.1991	0	0	10,1	4,526	4,16	4,16	12,4
TRN	19.02.1991	7,6	2,8	4	10,475	6,6	7,6	320,7
TRN	04.03.1991	0	1	0	6,85	7,38	7,6	54,9
TRN	02.04.1991	7,2	0	0	8,001	7,43	7,65	55,1
TRN	07.05.1991	0,2	0	0	6,724	6,38	6,38	51,4
TRN	03.06.1991	0	0	0	7,983	9,81	10,6	84,9
TRN	02.07.1991	0	0	0	3,117	3	3	18
TRN	08.08.1991	0	0	0	2,307	2,53	2,65	4,7
TRN	02.09.1991	0	0	0	2,375	2,55	2,55	12,7
TRN	01.10.1991	0	0	0	2,579	2,78	2,78	6,6
TRN	04.11.1991	0	0	0	3,236	3,37	3,37	15,4
TRN	02.12.1991	0	0	0	4,196	4,16	4,16	17,9
TRN	09.01.1992	0	0	0	4,036	4,16	4,16	26
TRN	06.02.1992	0	0	0	3,851	3,53	3,53	33,9
TRN	02.03.1992	0	0	0	3,651	3,53	3,53	16,3
TRN	13.04.1992	7,8	0	0	10,721	8,98	14,2	571,5

The "Analysis Report" window shows the following information:

- Data has been imported from file "1.apr"
- Data analysis results: 8 columns and 108 rows analysed
- 7 columns and 108 rows accepted for neural network training
- 7 numeric columns: YAĞIŞ, YAĞIŞ (-1), YAĞIŞ (-2), AKIŞ, AKIŞ (-1), AKIŞ (-2), SEDİMENT
- Output column: SEDİMENT
- 1 disabled columns: TARİH
- Data partition method: sequential (Training set, Validation set, Test set)
- Data partition results: 66 records to Training set (61,11%), 32 records to Validation set (29,63%), 10 records to Test set (9,26%)

The bottom status bar shows the date and time: 01.10.2006, 15:45:49. The software is ready for training.

Şekil 5.1 Veri gruplarının analizi

5.4. Veri Gruplarının Ön İşleme Tabi Tutulması

Bu aşamada veriler, YSA için kullanışlı hale dönüştürülürler. Nümerik kolonlar denklem (5.1) ve denklem (5.2)'ye göre ölçeklendirilirler:

$$SF = (SR_{\max} - SR_{\min}) / (X_{\max} - X_{\min}) \quad (5.1)$$

$$X_p = SR_{\min} + (X - X_{\min}) \cdot SF \quad (5.2)$$

Burada;

X : Nümerik kolonun şimdiki değeri

X_{\min} : Nümerik kolonun en küçük değeri

X_{\max} : Nümerik kolonun en büyük değeri

SR_{\min} : Minimum limit

SR_{\max} : Maksimum limit

SF : Ölçeklendirme faktörü

X_p : Ön işlem sonucu hesaplanan değer

Girdi katmanı için ölçeklendirme genişliği $[-1,1]$ dir.

Çalışmada *çıkış katmanı için* eğitim aşamasında lojistic fonksiyon seçilmiş ve böylece ölçek genişliği olarak $[0,1]$ kullanılmıştır. Şekil 5.2'de girdi veri kümeleri için ölçeklendirmeye ait bir örnek gösterilmektedir.

1. apr - Alyuda NeuroIntelligence

File View Data Network Query Options Help

Analyze Preprocess Design Train Test Query

Encoded Columns	Encoded Data						
	YAĞIŞ	YAĞIŞ (-1)	YAĞIŞ (-2)	AKIŞ	AKIŞ (-1)	AKIŞ (-2)	SEDİMENT
YAĞIŞ	-1	-1	-1	-0,843	-0,877	-0,892	0,001
YAĞIŞ (-1)	0,087	-0,981	-1	-0,755	-0,818	-0,832	0
YAĞIŞ (-2)	-1	-1	-1	-0,743	-0,771	-0,807	0,000
AKIŞ	-1	-1	-1	-0,44	-0,438	-0,434	0,007
AKIŞ (-1)	-1	-1	-1	-0,533	-0,597	-0,636	0,011
AKIŞ (-2)	-1	-1	-1	-0,38	-0,435	-0,502	0,016
SEDİMENT	-1	-1	-1	-0,357	-0,414	-0,502	0,007
	-1	-1	-0,985	-0,539	-0,582	-0,655	0,003
	-1	-1	-1	-0,448	-0,499	-0,589	0,043
	-1	-1	-1	-0,757	-0,809	-0,825	0,001
	-1	-1	-1	-0,93	-0,91	-0,908	0,002
	-1	-1	-1	-0,92	-0,938	-0,931	0,002
	-1	-1	-1	-0,888	-0,924	-0,919	0,000
	-1	-1	-1	-0,853	-0,88	-0,896	0,002
	-1	-1	-1	-0,826	-0,852	-0,861	0,003
	-0,964	0,528	-0,36	-0,415	-0,681	-0,767	0,044
	-1	-1	-1	-0,361	-0,456	-0,502	0,008
	-1	-1	-0,257	-0,603	-0,694	-0,731	0,003
	-0,612	-0,819	-0,706	0,202	-0,393	-0,384	0,097
	-1	-0,935	-1	-0,288	-0,297	-0,384	0,016
	-0,633	-1	-1	-0,133	-0,291	-0,379	0,016
	-0,99	-1	-1	-0,305	-0,42	-0,507	0,015
	-1	-1	-1	-0,135	0,002	-0,081	0,025
	-1	-1	-1	-0,793	-0,837	-0,848	0,005
	-1	-1	-1	-0,903	-0,895	-0,884	0,001
	-1	-1	-1	-0,893	-0,893	-0,894	0,003
	-1	-1	-1	-0,866	-0,864	-0,871	0,001
	-1	-1	-1	-0,777	-0,792	-0,811	0,004
	-1	-1	-1	-0,647	-0,694	-0,731	0,005
	-1	-1	-1	-0,669	-0,694	-0,731	0,007
	-1	-1	-1	-0,694	-0,772	-0,795	0,01
	-1	-1	-1	-0,721	-0,772	-0,795	0,004
	-0,602	-1	-1	0,235	-0,1	0,283	0,173

Column Details

Parameter	Value
Column type	output
Format	numerical
Scaling range	[0..1]
Encoded into	1 columns
Min	1,8
Max	3289,2
Mean	0
Std. deviation	0
Scaling factor	0,000

Preprocessing Report

Data preprocessing completed.
 Columns before preprocessing: 7
 Columns after preprocessing: 7
 Input columns scaling range: [-1..1]
 Output column(s) scaling range: [0..1]
 Numeric columns scaling parameters:
 YAĞIŞ: 0,051
 YAĞIŞ (-1): 0,065
 YAĞIŞ (-2): 0,074
 AKIŞ: 0,135
 AKIŞ (-1): 0,123
 AKIŞ (-2): 0,101
 SEDİMENT: 0,000

Analysis Preprocessing Design Training Testing Query

01.10.2006, 16:25:18: ----- New session initialized -----

Ready for training. 00:00:00

Başlat 1. apr - Alyuda Neuro... TR 16:29

Şekil 5.2 Girdi değişkenlerinin ölçeklendirilmesi

5.5. Tahmin Modelinin Geliştirilmesi

Tahmin modelinin geliştirilmesi için ağ mimarisini (gizli katman sayısı ve her gizli katmandaki nöron sayısı), ağ özelliklerini (hata ve aktivasyon fonksiyonlarını) tanımlamak gerekir.

Bu aşamada analizi yapıp ön işlemden geçmiş verilere uygun mimari aranır.

İlk olarak ağ özelliklerinin tanımlanması gereklidir. Program gizli katman için üç tane, çıktı katmanı için ise dört tane aktivasyon fonksiyonunu sağlamaktadır. Gizli katman için lineer, sigmoid ve hiperbolik tanjant fonksiyonu sağlanırken, çıktı katmanı için bunlara ilaveten softmax fonksiyonu da sağlanır.

Program ayrıca regresyon problemleri için hata fonksiyonu olarak kareler toplamını kullanmaktadır.

Mimari arama seçeneklerine baktığımız zaman ilk olarak kaç tane gizli katman kullanılacağı ve gizli katmandaki nöron sayılarının minimum sayısı ile maksimum sayısı belirtilmelidir.

Bu çalışmada literatürdeki çalışmalardan farklı olarak 2 adet gizli katman kullanılmış ve katmanlardaki nöron sayısı da 20 olarak alınmıştır. Böylece daha fazla paralel bağlantı için en uygun ağ mimarisi araştırılmıştır.

Uygun mimarinin aranması için belirtilmesi gereken diğer hususlar ise uygunluk ölçütleri, iterasyon sayısı ve her ağın kaç kere deneneceğidir.

Program altı farklı uygunluk ölçütünü aynı anda hesaplayarak hangi ağ mimarisinin sonuçları daha iyi yansıttığı konusunda geniş bir bilgi sağlar. Programın hesapladığı uygunluk ölçütleri şunlardır:

- **Test Hatası:** Test veri kümesinin ortalama mutlak hatasına bakılır. Bu değer küçüldükçe ağ mimarisinin kalitesi artmaktadır.
- **Öğrenme Hatası:** Öğrenme veri kümesinin ortalama mutlak hatasına bakılır. Bu değer küçüldükçe ağ mimarisinin kalitesi artmaktadır.

- **Sorgulama Hatası:** Sorgulama veri kümesinin ortalama mutlak hatasına bakılır. Bu deęer küçüldükçe aę mimarisinin kalitesi artmaktadır.
- **Akaike İnfomasyon Kriteri:** Farklı aę yapılarına ve farklı aęlıklara sahip mimarileri kıyaslar. Mimari arama boyunca eęer toplam aęlıkların artması aę hatasının azalmasına neden olmuyorsa basit aęlar, kompleks aęlar yerine tercih edilir. Kriteri en büyük yapan aę en iyi aędır.
- **R²:** Model tahmin doęruluęu ile bütün hedef deęerlerin ortalaması arasında karşılaştırma yapan istatistiksel bir orandır. Bu oran 1' e yaklaştıkça model kalitesi artar.
- **Korelasyon:** Aę çıkışları ile hakiki deęerler arasındaki ilişkinin gücünü hesaplar. Bu oran -1 ile 1 arasında deęişmektedir. Pozitif lineer ilişki oran 1' e yaklaştıkça artar.

Daha önceki bölümde kurulmuş olan ve çapraz geçerlilik yöntemiyle 4 farklı veri giriş yapısına ayrılan tahmin modelleri için Tablo 5.7'deki parametreler kullanılarak mimari araştırılmıştır.

Tablo 5.7 Mimariyi araştırmada kullanılan aę parametreleri

Parametre	Deęer
Gizli katman sayısı	2
Her gizli katman için denenecek gizli nöron sayısı	20
İterasyon sayısı	5000
Her aę için deneme sayısı	5

Her girdi katmanı için bir gizli katman ve bir gizli nörondan başlayarak bütün olasılıklar yukarıda da belirtildięi gibi beşer kez **5000** iterasyona kadar denenmiş ve her olasılık için bulunan en iyi sonuçlar hafızaya kaydedilmiştir.

713 ve 735 nolu AGİ'ler için bütün uygunluk ölçütleri dikkate alınarak en uygun aę mimarileri kaydedilmiştir.

Tablo 5.8'de görüldüğü gibi 713 nolu AGİ için 4 numaralı veri kümesi yapısı en iyi mimari sonuçlarını verirken 735 nolu AGİ için bu durum 1 numaralı veri kümesi yapısında görülmektedir. Yani 713 nolu AGİ için her aę yapısı en iyi mimariyi 4 numaralı veri kümesi yapısı (%10 test, %35 öğrenme, %35 öğrenme, %20 onaylama)

ile sağlamıştır. Benzer durum 735 nolu AGİ için 1 numaralı veri kümesi yapısı (%35 öğrenme, %10 test, %20 onaylama, %35 öğrenme) ile sağlanmıştır.

Tablo 5.8 713 ve 735 Nolu AGİ'ler için bulunan veri kümesi yapıları ve ağ mimarileri

Model	713		735	
	Seçilen Veri Kümesi Yapısı	Ağ mimarisi	Seçilen Veri Kümesi Yapısı	Ağ mimarisi
1	4	1 - 7 - 1	1	1 - 17 - 20 - 1
2	4	2 - 14 - 16 - 1	1	2 - 20 - 15 - 1
3	4	3 - 20 - 17 - 1	1	3 - 16 - 8 - 1
4	4	2 - 14 - 18 - 1	1	2 - 12 - 16 - 1
5	4	3 - 18 - 15 - 1	1	3 - 15 - 7 - 1
6	4	4 - 9 - 15 - 1	1	4 - 7 - 7 - 1
7	4	3 - 18 - 18 - 1	1	3 - 20 - 1 - 1
8	4	4 - 15 - 13 - 1	1	4 - 16 - 4 - 1
9	4	5 - 6 - 12 - 1	1	5 - 18 - 11 - 1
10	4	4 - 20 - 1 - 1	1	4 - 10 - 4 - 1
11	4	5 - 13 - 20 - 1	1	5 - 11 - 2 - 1
12	4	6 - 11 - 2 - 1	1	6 - 16 - 13 - 1

Uygun mimarinin araştırılması YSA yönteminin en zaman alan aşamalarından biri olup, programın bütün kombinasyonları kullanıcıya gerek kalmadan araştırması ve en iyi ağ mimarisini kaydetmesi en önemli özelliklerinden biridir.

5.6. YSA'ların Eğitimi

Tahmin modelinin geliştirilmesi aşamasında veri yapısını temsil eden en uygun mimari yapının varlığını araştırmak için veri grupları kendi içlerinde farklı alt veri kümelerine ayrılmıştır. Ağların eğitim aşamasında ise, veri sayısının ağ üzerindeki etkisini araştırmak için her bir kombinasyon en uygun ağ mimarisi doğrultusunda Tablo 5.9'daki gibi üç farklı şekilde eğitilmiştir.

Tablo 5.9 Eğitim için girdi verilerinin veri sayısına göre alt kümelere ayrılması

Veri Kümesi	Veri Kümesi Yapısı	713			Veri Kümesi Yapısı	735		
		Kullanılan Veri Dağılımları				Kullanılan Veri Dağılımları		
		I	II	III		I	II	III
Öğrenme	4	% 50	%60	%70	1	% 50	%60	%70
Onaylama	4	%30	%30	%20	1	%30	%30	%20
Test	4	%20	%10	%10	1	%20	%10	%10

Ağların eğitimi için hatayı geriye yayma algoritması kullanılmış, momentum katsayısı ve öğrenme katsayısı program tarafından her iterasyondan sonra otomatik olarak ayarlanmıştır. Burada öğrenme işlemi iterasyondan bağımsız bir şekilde en

uygun sonuçlar bulununcaya kadar tekrarlanmıştır. Program her deneme için en uygun öğrenme değerinin olduğu iterasyonu belirler ve bu noktadaki ağ ağırlıklarını hafızasında tutar. Uygunluk ölçütü için de ortalama mutlak rölatif hata (OMRH), korelasyon katsayısı (R), verimlilik katsayısı (E) ve ortalama karesel hatanın karekökü (KHOK) dikkate alınmıştır (Fırat 2007). Bu uygunluk ölçütleri denklem (5.3), (5.4), (5.5) ve (5.6)'da verilmiştir.

$$\text{OMRH} = \frac{1}{N} \sum_{i=1}^N \left| \frac{Q_i - \hat{Q}_i}{\hat{Q}_i} \right| * 100 \quad (5.3)$$

$$R = \frac{\sum_{i=1}^N (Q_i - \bar{Q}_i)(\hat{Q}_i - \tilde{Q}_i)}{\sqrt{\sum_{i=1}^N (Q_i - \bar{Q}_i)^2 (\hat{Q}_i - \tilde{Q}_i)^2}} \quad (5.4)$$

$$E = \frac{\sum_{i=1}^N (Q_i - \bar{Q}_i)^2 - \sum_{i=1}^N (\hat{Q}_i - Q_i)^2}{\sum_{i=1}^N (Q_i - \bar{Q}_i)^2} \quad (5.5)$$

$$\text{KHOK} = \sqrt{\frac{\sum_{i=1}^N (Q_i - \hat{Q}_i)^2}{N}} \quad (5.6)$$

Burada Q_i , gözlem ile elde edilen değerler, \bar{Q}_i , gözlenen değerlerin ortalaması, \hat{Q}_i , tahmin edilen değer, \tilde{Q}_i , tahmin değerlerinin ortalamasını göstermektedir. Yukarıdaki ölçütler dikkate alınarak Tablo 5.10 ve 5.11'de gösterildiği gibi eğitim aşamasında her ağ için öğrenme katsayısı ve momentum katsayısı belirlenmiştir. Program bu noktada sadece tek bir uygunluk ölçütüne bağımlı kalmamış, 4 farkı uygunluk ölçütüne göre optimum çözümü araştırmıştır. Bu eğitime bağlı test ve sorgulama aşamalarına ait sonuçları ise Tablo 5.12, 5.13, 5.14 ve 5.15'de gösterilmiştir.

Tablo 5.10 713 Nolu AGİ için eğitim sonucu bulunan öğrenme ve momentum katsayıları

713 Nolu AGİ						
Kullanılan Veri Dağılımları						
I		II		III		
Model	Öğrenme Katsayısı	Momentum Katsayısı	Öğrenme Katsayısı	Momentum Katsayısı	Öğrenme Katsayısı	Momentum Katsayısı
1	0,3	0,8	0,1	0,9	0,5	0,9
2	0,1	0,9	0,1	0,9	0,5	0,9
3	0,1	0,9	0,1	0,9	0,5	0,9
4	0,2	0,9	0,1	0,9	0,2	0,9
5	0,1	0,8	0,1	0,9	0,2	0,8
6	0,1	0,8	0,2	0,9	0,2	0,9
7	0,2	0,8	0,1	0,9	0,1	0,9
8	0,1	0,9	0,1	0,9	0,4	0,9
9	0,1	0,9	0,1	0,8	0,4	0,9
10	0,2	0,8	0,1	0,9	0,3	0,9
11	0,1	0,9	0,1	0,9	0,4	0,9
12	0,2	0,9	0,1	0,9	0,5	0,8

Bu aşamada program, öğrenme oranı ve momentum katsayısını her iterasyondan sonra ağırlık öğrenmesine göre ayarlamaktadır. Bu yapısıyla program eğitim sırasında değişken öğrenme oranı ve momentum katsayısı ile çalışmaktadır.

Tablo 5.11 735 Nolu AGİ için eğitim sonucu bulunan öğrenme ve momentum katsayıları

735 Nolu AGİ						
Kullanılan Veri Dağılımları						
I		II		III		
Model	Öğrenme Katsayısı	Momentum Katsayısı	Öğrenme Katsayısı	Momentum Katsayısı	Öğrenme Katsayısı	Momentum Katsayısı
1	0,3	0,9	0,1	0,9	0,1	0,9
2	0,2	0,7	0,2	0,8	0,1	0,8
3	0,1	0,9	0,1	0,9	0,2	0,8
4	0,1	0,9	0,3	0,9	0,1	0,9
5	0,2	0,8	0,1	0,9	0,3	0,9
6	0,3	0,8	0,3	0,9	0,3	0,9
7	0,3	0,9	0,3	0,8	0,3	0,9
8	0,4	0,9	0,2	0,9	0,3	0,7
9	0,4	0,7	0,3	0,9	0,4	0,8
10	0,3	0,7	0,3	0,8	0,3	0,9
11	0,2	0,8	0,3	0,9	0,2	0,9
12	0,3	0,9	0,1	0,9	0,1	0,9

5.7. YSA'ların Test Edilmesi

Eğitim aşamasında kullanılan öğrenme ve onaylama kümeleri ile belirlenmiş en uygun YSA'ya ait ağırlık katsayıları program tarafından hafızaya kaydedilmiş ve test aşamasında test verileri için uygulanmıştır. Test aşaması için bölüm 5.6'da tanımlanan uygunluk ölçütleri dikkate alınarak gözlem verileri ile sonuçlar kıyaslanmıştır.

Program eğitim ve test aşamalarını eş zamanlı olarak yapmaktadır. Her model yapısı için Tablo 5.9'da bahsedildiği gibi üç farklı alt küme veri dağılımına göre test sonuçları ve gözlem değerleri arasındaki uygunluk ölçütleri belirlenmiş ve Tablo 5.12 ve 5.13 ile gösterilmiştir.

Tablo 5.12 713 Nolu AGİ'ye ait test verileri için model davranışları

713 Nolu AGİ												
Kullanılan Veri Dağılımları												
	I				II				III			
Model	OMRH	R	E	KHOK	OMRH	R	E	KHOK	OMRH	R	E	KHOK
1	2.181	0.896	0.795	35.19	1.871	0.972	0.734	43.65	2.609	0.987	0.725	44.45
2	1.916	0.906	0.796	35.08	1.765	0.963	0.756	41.81	2.465	0.984	0.738	43.32
3	1.593	0.914	0.812	33.64	1.715	0.965	0.76	41.49	2.376	0.982	0.756	41.82
4	2.169	0.908	0.795	35.11	1.864	0.974	0.754	42.04	2.595	0.982	0.74	43.15
5	1.6	0.915	0.812	33.66	1.72	0.964	0.759	41.59	2.401	0.983	0.751	42.31
6	1.252	0.897	0.8	34.76	1.576	0.978	0.809	37.03	2.115	0.982	0.763	41.21
7	1.835	0.914	0.81	33.86	1.764	0.963	0.758	41.7	2.407	0.983	0.75	42.36
8	1.407	0.914	0.813	33.57	1.586	0.972	0.783	39.5	2.342	0.982	0.761	41.37
9	1.22	0.907	0.819	32.98	1.575	0.979	0.816	36.29	1.95	0.981	0.76	41.53
10	1.445	0.903	0.812	33.62	1.604	0.972	0.782	39.52	2.369	0.982	0.758	41.68
11	1.222	0.901	0.806	34.15	1.577	0.977	0.812	36.72	2.082	0.981	0.763	41.27
12	1.206	0.916	0.82	32.9	1.573	0.98	0.825	35.44	1.874	0.981	0.766	40.97

Tablo 5.12' de görüldüğü gibi her alt küme veri dağılımı için bütün uygunluk ölçütlere göre en uygun model 12 numaralı 6 giriş değişkenine sahip modeldir. Modellerin kendi içindeki performanslarını değerlendirdiğimizde performansın model 1'den 12'ye doğru ardışık olarak iyileşmediği görülmüştür. Akış değişkenlerinin yağış değişkenlerine göre katı madde taşınımında daha etkin bir değişken olmasından dolayı aynı girdi sayısına sahip ağlardan daha çok akış değişkeni içeren modeller daha iyi sonuçlar vermiştir. Tablo 5.12'e göre en uygun model yapısı olan 6 giriş değişkenli 12 nolu modelin matematiksel ifadesi denklem (5.7) ile gösterilmiştir.

$$S(t)_{713} = f(Q(t)_{713}, Q(t-1)_{713}, Q(t-2)_{713}, P(t), P(t-1), P(t-2)) \quad (5.7)$$

Kullanılan veri dağılımına göre bakıldığında %20 oranında test verisi içeren I. tip modellerin OMRH, E ve KHOK açısından %10 oranında test verisi içeren II. ve III. tip modellere göre daha iyi sonuçlar verdiği, R açısından bakıldığında III. tip modellerin %98 ler mertebesinde iyi sonuçlar verdiği görülmektedir.

Tablo 5.13 735 Nolu AGİ'ye ait test verileri için model davranışları

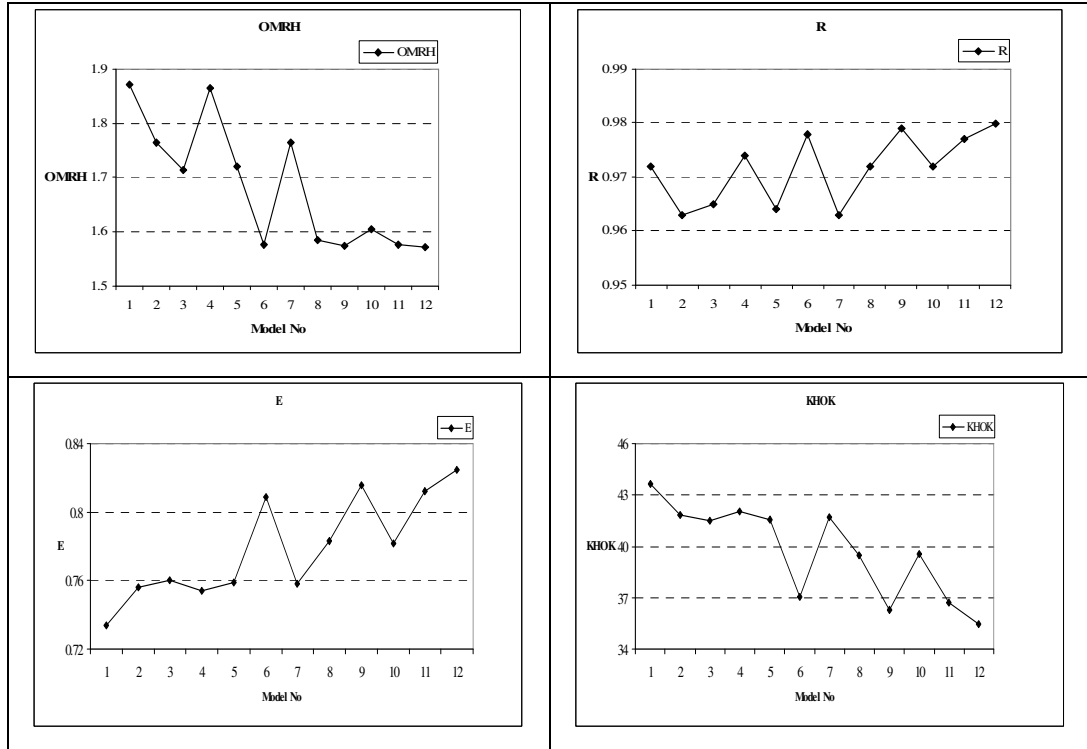
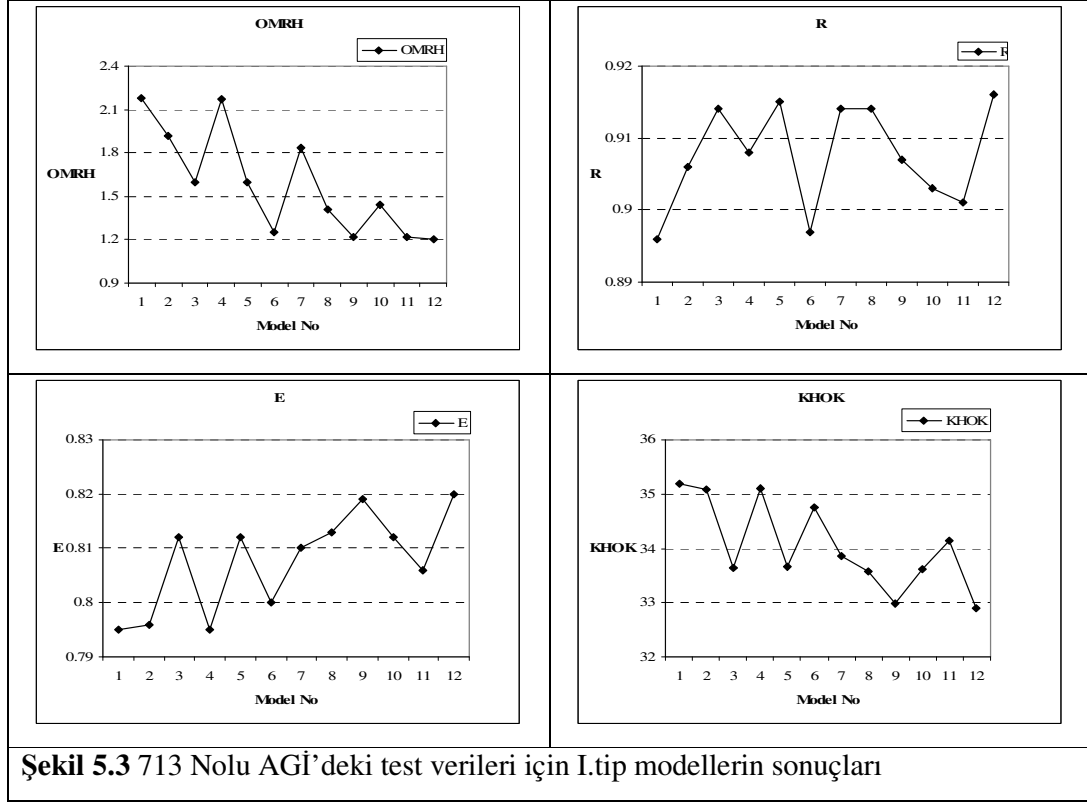
735 Nolu AGİ												
Kullanılan Veri Dağılımları												
Model	I				II				III			
	OMRH	R	E	KHOK	OMRH	R	E	KHOK	OMRH	R	E	KHOK
1	0.477	0.905	0.579	80.56	0.389	0.919	0.499	9.75	0.466	0.79	0.591	45.5
2	0.394	0.933	0.622	76.37	0.37	0.922	0.522	9.52	0.424	0.813	0.601	44.9
3	0.384	0.964	0.684	69.77	0.355	0.935	0.585	8.87	0.416	0.854	0.659	41.52
4	0.468	0.912	0.594	79.14	0.382	0.921	0.513	9.61	0.457	0.793	0.606	44.62
5	0.385	0.933	0.675	70.79	0.361	0.935	0.556	9.18	0.433	0.841	0.636	42.93
6	0.379	0.965	0.734	64.1	0.328	0.937	0.627	8.41	0.387	0.875	0.699	39
7	0.392	0.925	0.684	69.77	0.365	0.927	0.54	9.34	0.426	0.829	0.623	43.67
8	0.381	0.969	0.722	65.42	0.341	0.939	0.613	8.57	0.396	0.882	0.744	35.96
9	0.325	0.953	0.891	40.92	0.296	0.933	0.669	7.93	0.339	0.891	0.702	38.82
10	0.383	0.937	0.707	67.27	0.345	0.936	0.598	8.73	0.401	0.863	0.718	37.74
11	0.328	0.968	0.84	49.7	0.307	0.931	0.648	8.17	0.361	0.885	0.694	39.32
12	0.321	0.953	0.892	40.75	0.287	0.93	0.674	7.87	0.319	0.898	0.752	35.43

Tablo 5.13'te görüldüğü gibi her alt küme veri dağılımı için bütün uygunluk ölçütlerine göre en uygun model 12 numaralı 6 giriş değişkenine sahip modeldir. Modellerin kendi içindeki performanslarını değerlendirdiğimizde performansın 1'den 12'ye doğru ardışık olarak iyileşmediği görülmüştür. Akış değişkenlerinin yağış değişkenlerine göre katı madde taşınımında daha etkin bir değişken olmasından dolayı aynı girdi sayısına sahip ağlardan daha çok akış değişkeni içeren modeller daha iyi sonuçlar vermişlerdir. Tablo 5.13'e göre en uygun model yapısı olan 6 giriş değişkenli 12 nolu modelin matematiksel ifadesi denklem (5.8) ile gösterilmiştir.

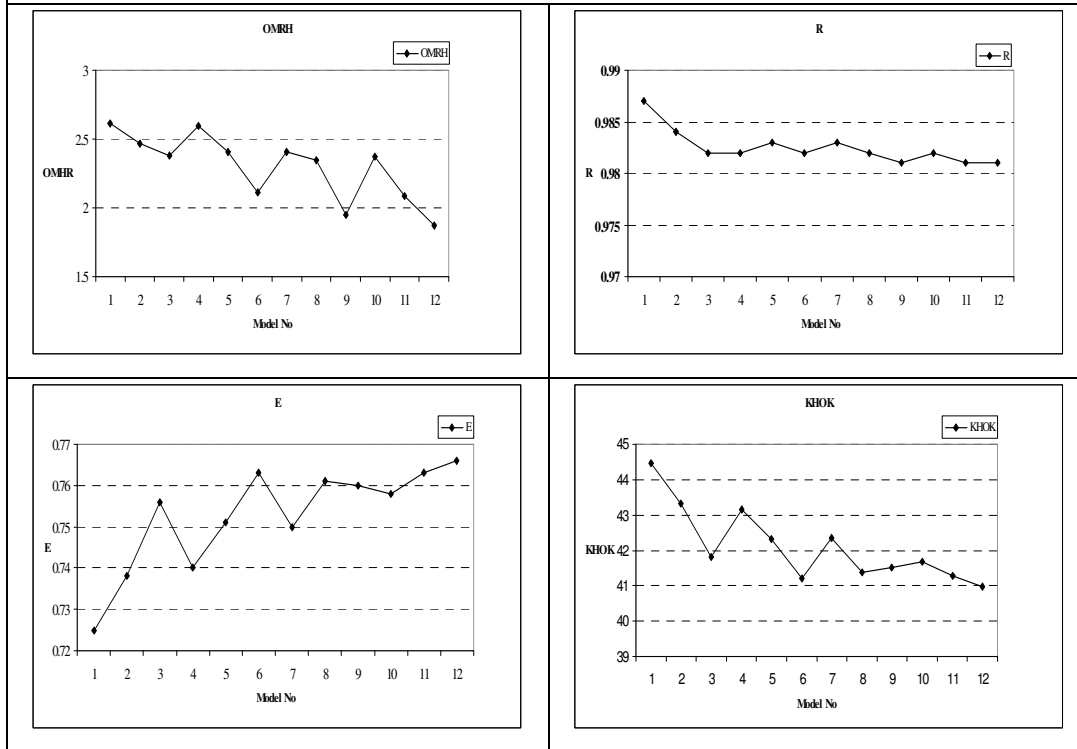
$$S(t)_{735} = f(Q(t)_{735}, Q(t-1)_{735}, Q(t-2)_{735}, P(t), P(t-1), P(t-2)) \quad (5.8)$$

Kullanılan veri dağılımına göre bakıldığında I. tip modellerde en iyi R ve E değerleri sırasıyla 0,953 ve 0,892 olarak 12 numaralı model ile elde edilmiştir. Bunun yanında %10 oranında test verisi içeren II. tip modellerde ise en iyi OMRH ve KHOK değerleri sırasıyla 0,287 ve 7,87 olarak 12 numaralı 6 giriş değişkenli model ile elde edilmiştir.

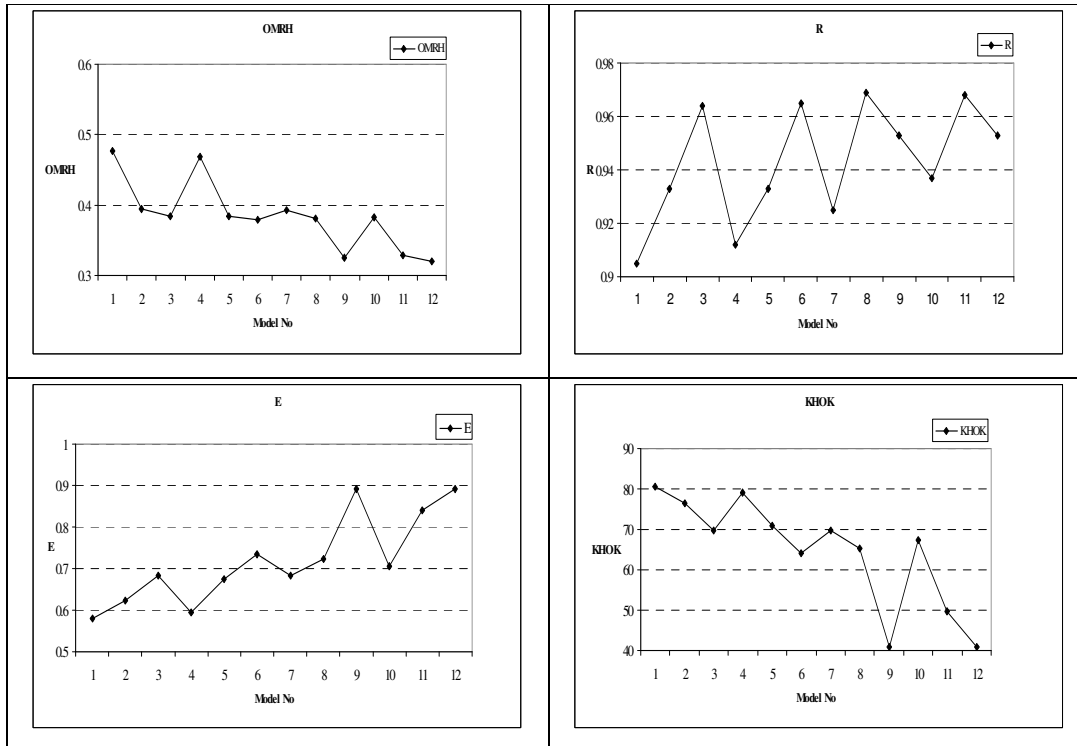
713 ve 735 nolu AGİ'lerde kullanılan test verileri için I., II. ve III. tip modellerin sonuçları Şekil 5.3, 5.4, 5.5, 5.6, 5.7 ve 5.8'de gösterilmiştir.



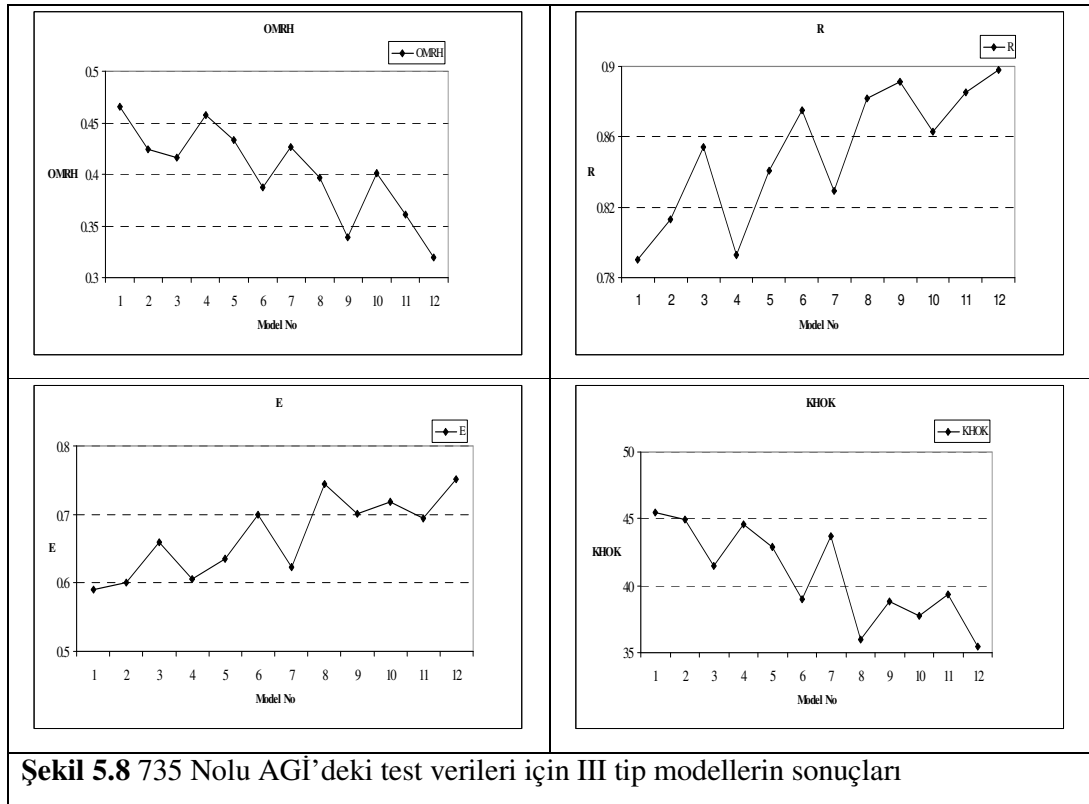
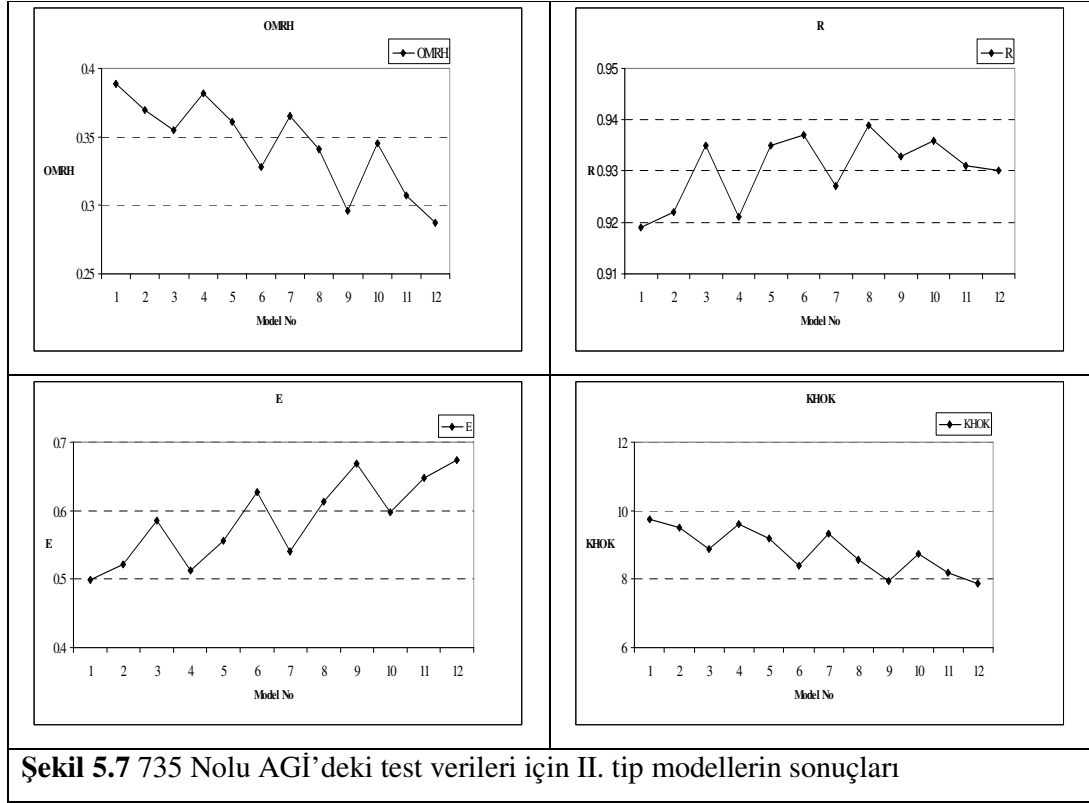
Şekil 5.4 713 Nolu AGİ'deki test verileri için II. tip modellerin sonuçları




Şekil 5.5 713 Nolu AGİ'deki test verileri için III. tip modellerin sonuçları




Şekil 5.6 735 Nolu AGİ'deki test verileri için I. tip modellerin sonuçları



Tablo 5.12’ deki uygunluk ölçütlerine göre 713 nolu AGİ için I. tip modeller arasından en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.9’da verilmiştir.

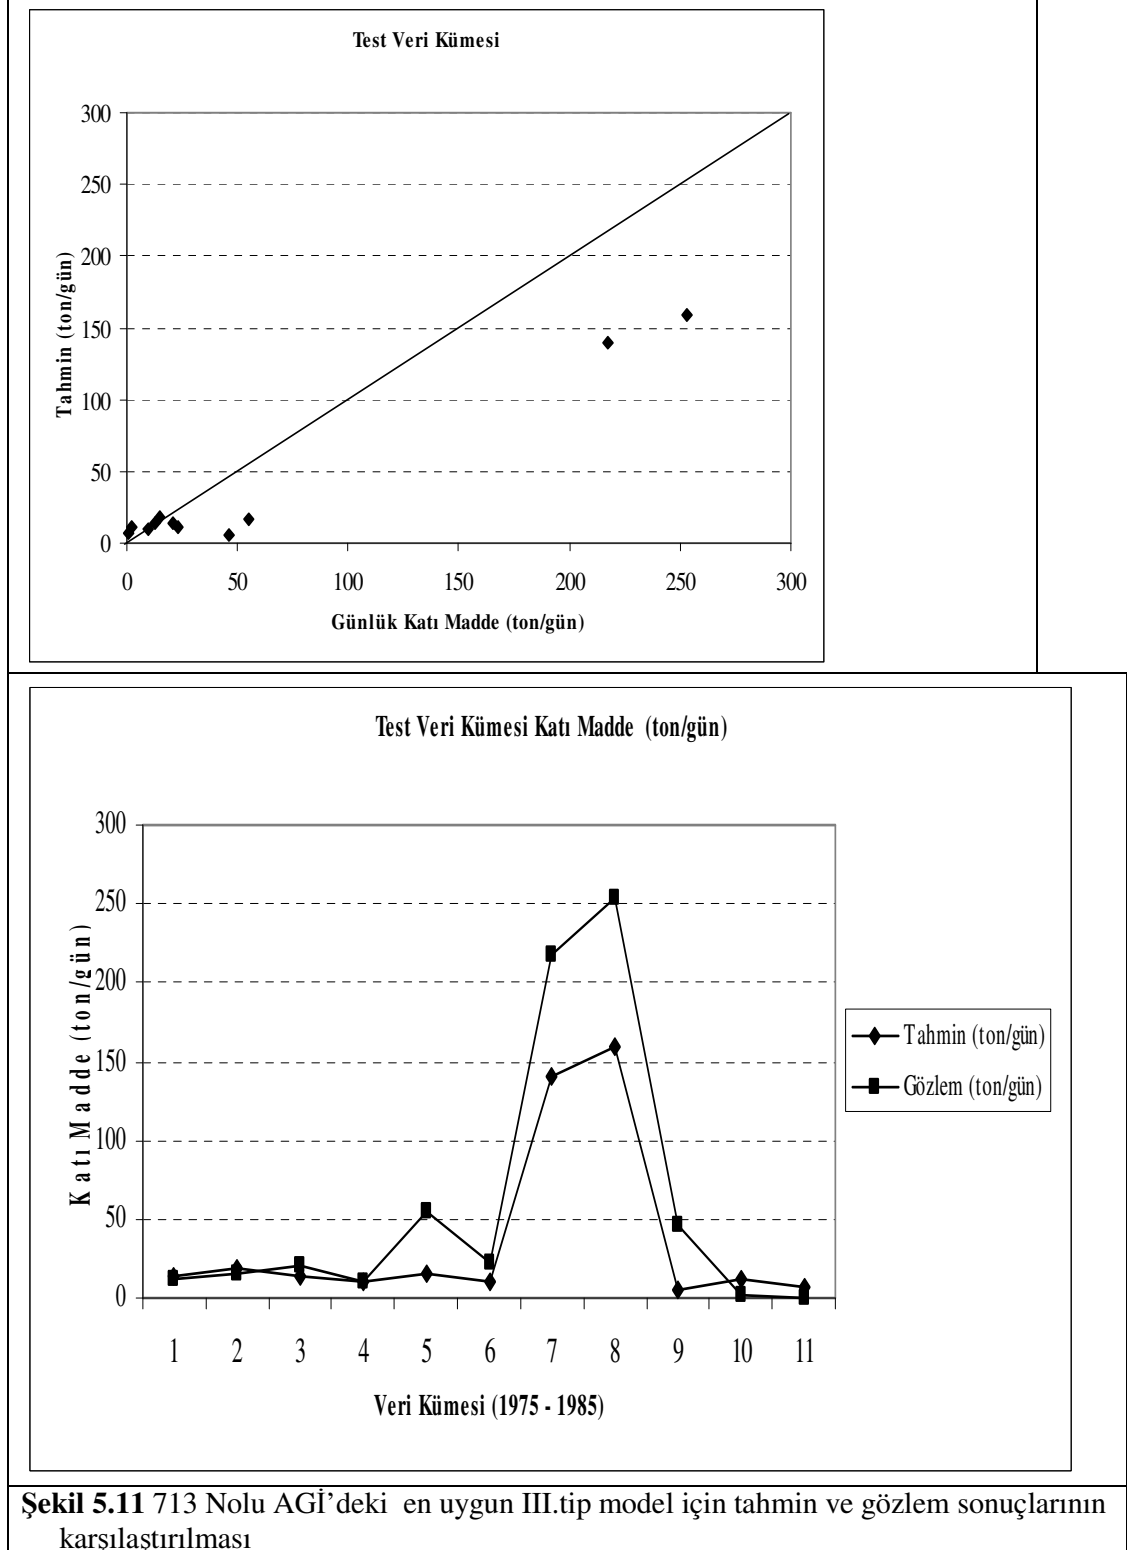


Tablo 5.12’deki uygunluk ölçütlerine göre 713 nolu AGİ için II. tip modeller arasından en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.10’da verilmiştir.

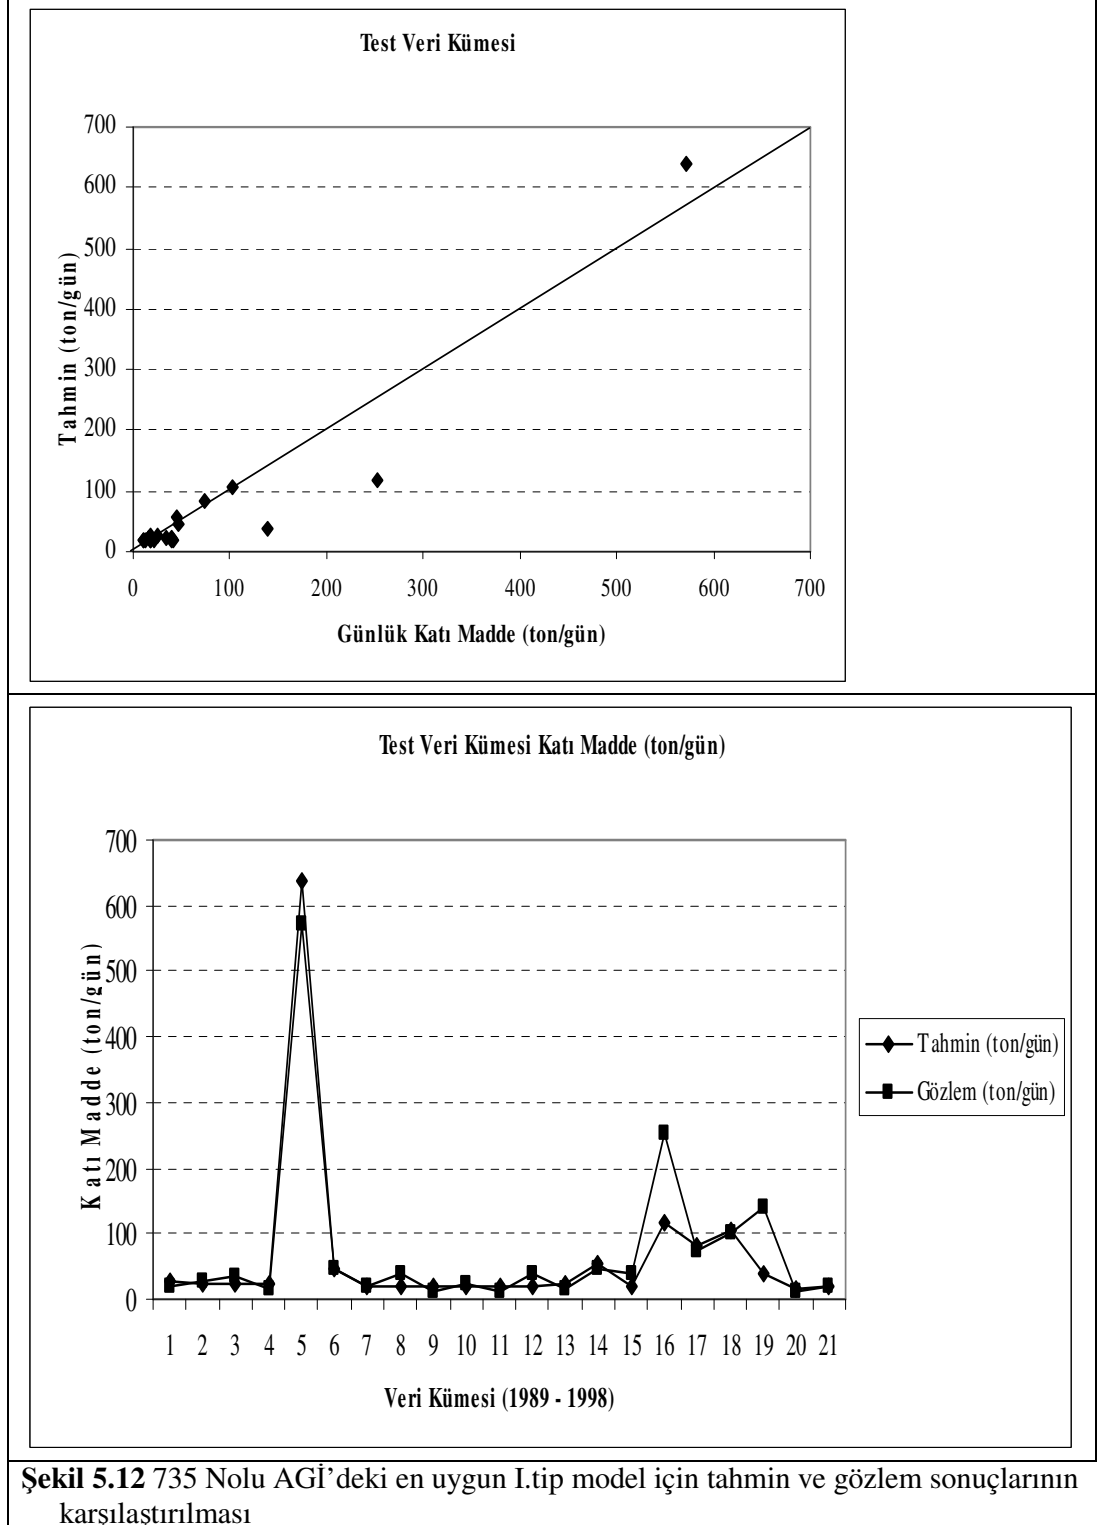


Şekil 5.10 713 Nolu AGİ’deki en uygun II. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması

Tablo 5.12’ deki uygunluk ölçütlerine göre 713 nolu AGİ için III. tip modeller arasında en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.11’de verilmiştir.




Tablo 5.13' deki uygunluk ölçütlerine göre 735 nolu AGİ için I. tip modeller arasından en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.12'de verilmiştir.



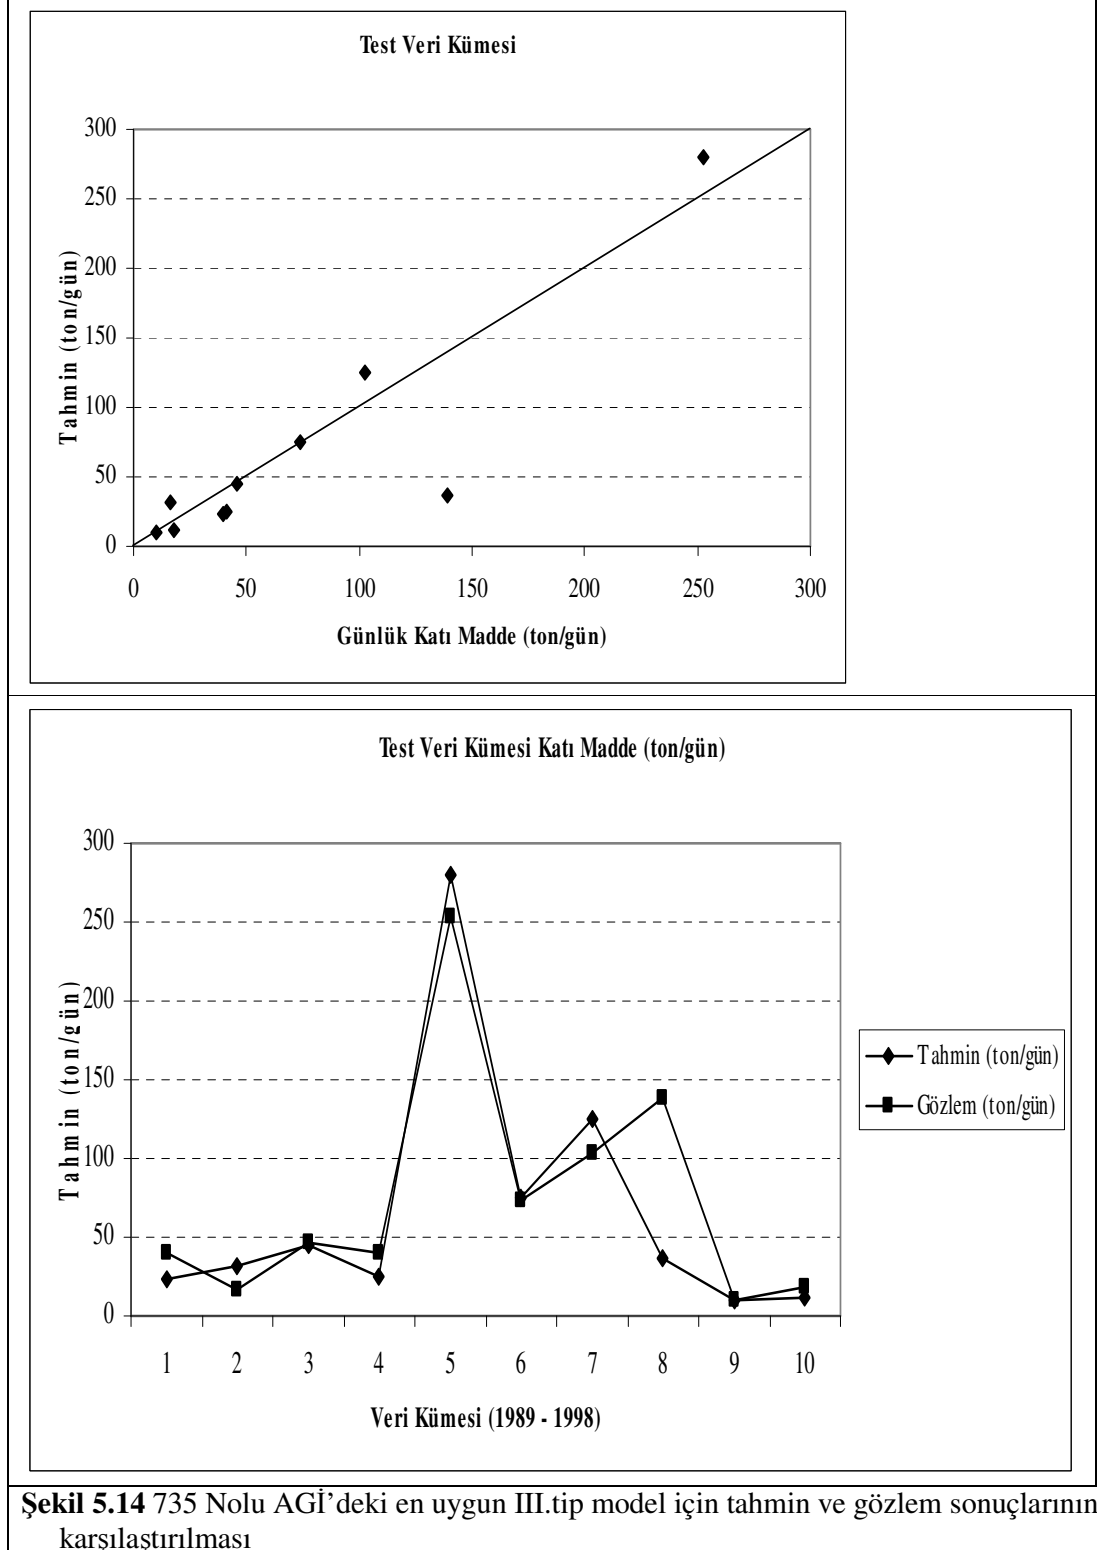
Şekil 5.12 735 Nolu AGİ'deki en uygun I. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması

Tablo 5.13' deki uygunluk ölçütlerine göre 735 nolu AGİ için II. tip modeller arasından en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.13'de verilmiştir.



Şekil 5.13 735 Nolu AGİ'deki en uygun II. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması

Tablo 5.13' deki uygunluk ölçütlerine göre 735 nolu AGİ için III. tip modeller arasında en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.14'te verilmiştir.



5.8 YSA'ların Sorgulanması

Sorgulama, öğrenmiş ağın yeni veriler için test edilmesidir. Bu veriler eğitim ya da sorgulama veri kümelerinden seçilebileceği gibi yeni veriler içinde yapılabilir. Bu aşamada sorgu için eğitim veri kümesindeki veriler kullanılmıştır. Sonuçlar bölüm 5.6'da bahsedilen uygunluk ölçütleri dikkate alınarak Tablo 5.14 ve 5.15'de gösterilmiştir.

Tablo 5.14 713 Nolu AGİ'ye ait eğitim verileri için model davranışları

713 Nolu AGİ												
Kullanılan Veri Dağılımları												
	I				II				III			
No	OMRH	R	E	KHOK	OMRH	R	E	KHOK	OMRH	R	E	KHOK
1	0.761	0.886	0.783	66.98	0.679	0.89	0.732	70.15	0.731	0.875	0.706	70.16
2	0.746	0.888	0.788	66.2	0.63	0.881	0.76	66.3	0.596	0.881	0.723	68
3	0.725	0.89	0.791	65.81	0.6	0.886	0.779	63.65	0.559	0.875	0.746	65.14
4	0.75	0.889	0.79	65.9	0.683	0.888	0.754	67.16	0.605	0.87	0.721	68.33
5	0.737	0.893	0.796	64.99	0.612	0.88	0.771	64.81	0.566	0.876	0.75	64.62
6	0.706	0.899	0.796	64.96	0.561	0.891	0.786	62.66	0.53	0.883	0.752	64.36
7	0.74	0.894	0.793	65.44	0.624	0.879	0.772	64.75	0.581	0.875	0.748	64.94
8	0.711	0.895	0.8	64.43	0.577	0.885	0.778	63.76	0.539	0.877	0.751	64.57
9	0.644	0.905	0.816	61.78	0.55	0.892	0.792	61.83	0.529	0.884	0.759	63.42
10	0.719	0.895	0.801	64.19	0.591	0.889	0.779	63.63	0.553	0.876	0.749	64.78
11	0.699	0.906	0.806	63.3	0.564	0.892	0.789	62.17	0.531	0.885	0.761	63.27
12	0.644	0.911	0.828	59.62	0.529	0.902	0.802	60.34	0.522	0.901	0.777	61.11

Tablo 5.14'de görüldüğü gibi her alt küme veri dağılımı için bütün uygunluk ölçütlerine göre en uygun model 12 numaralı 6 giriş değişkenli modeldir. Modellerin kendi içindeki performanslarını değerlendirdiğimizde performansın model 1'den 12'ye doğru ardışık olarak iyileşmediği görülmüştür. Akış değişkeninin yağış değişkenine göre katı madde taşımında daha etkin bir değişken olmasından dolayı aynı girdi sayısına sahip ağlardan daha çok akış değişkeni içeren modeller daha iyi sonuçlar vermişlerdir. Tablo 5.14'e göre en uygun model yapısı olan 6 giriş değişkenli 12 nolu ağ modelinin matematiksel ifadesi denklem (5.9) ile gösterilmiştir.

$$S(t)_{713} = f(Q(t)_{713}, Q(t-1)_{713}, Q(t-2)_{713}, P(t), P(t-1), P(t-2)) \quad (5.9)$$

Kullanılan veri dağılımına göre bakıldığında %50 eğitim verisi içeren I. tip ağ modelleri R, E ve KHOK uygunluk ölçütleri açısından %60 oranında eğitim verisi içeren II. tip ve %70 oranında eğitim verisi içeren ağ modellerine göre daha iyi sonuçlar vermiştir. OMRH açısından değerlendirildiğinde ise II ve III. tip modeller sırasıyla 0,

529 ve 0,522 gibi birbirine yakın sonuçlar verirken I. tip modeller daha 0,644 gibi daha yüksek hata oranlarına sahiptir.

Tablo 5.15 735 Nolu AGİ’ye ait eğitim verileri için model davranışları

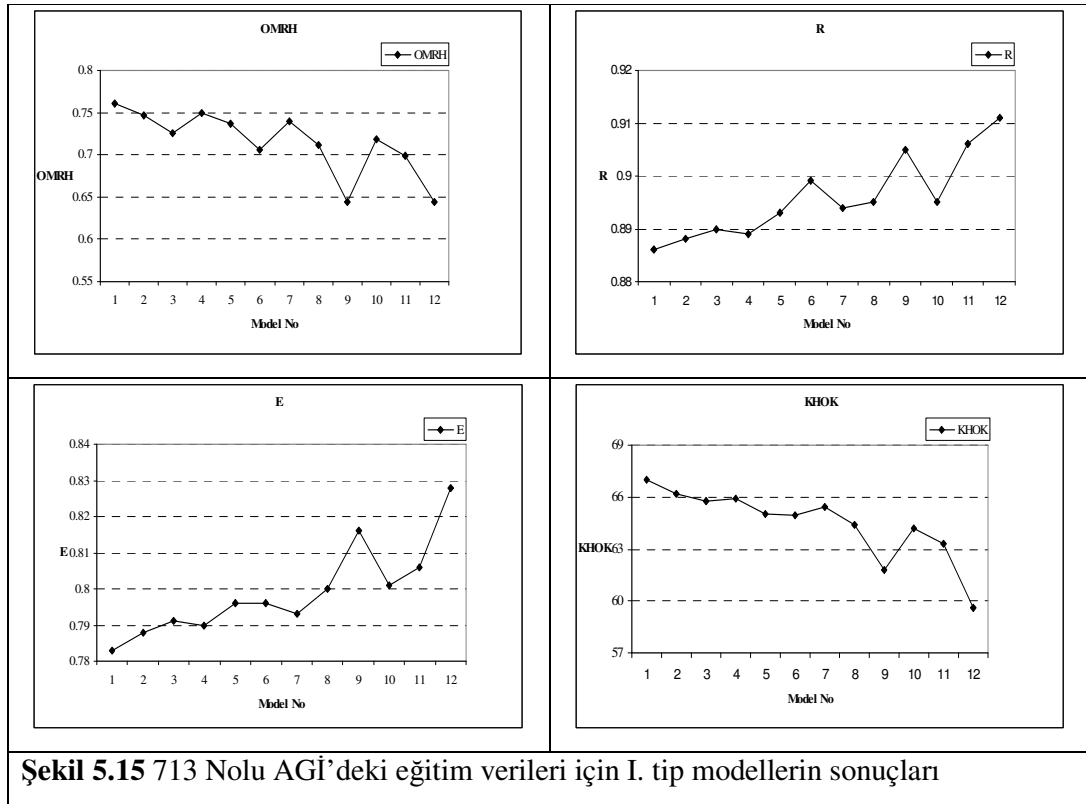
735 Nolu AGİ												
Kullanılan Veri Dağılımları												
	I				II				III			
No	OMRH	R	E	KHOK	OMRH	R	E	KHOK	OMRH	R	E	KHOK
1	1.304	0.996	0.995	23.96	1.265	0.999	0.997	23.66	1.158	0.999	0.997	23.23
2	1.272	0.997	0.993	22.81	1.097	0.999	0.998	22.94	1.034	0.999	0.998	21.22
3	1.107	0.997	0.994	21.79	0.955	0.999	0.998	20.62	0.969	0.999	0.998	20.51
4	1.297	0.997	0.995	23.48	1.261	0.999	0.998	23.1	1.044	0.999	0.998	21.72
5	1.111	0.997	0.995	21.87	1.018	0.999	0.998	20.04	0.978	0.999	0.998	19.49
6	1.142	0.997	0.995	20.63	0.859	0.999	0.998	18.48	0.868	0.999	0.998	19.11
7	1.296	0.997	0.995	20.16	1.095	0.999	0.998	20.04	0.995	0.999	0.998	20.53
8	1.061	0.998	0.995	19.73	0.892	0.999	0.998	18.84	0.895	0.999	0.998	19.17
9	0.959	0.998	0.995	19.28	0.795	0.999	0.999	18.12	0.742	0.999	0.998	18.05
10	1.066	0.998	0.995	19.51	0.947	0.999	0.998	18.4	0.915	0.999	0.998	19.36
11	1.069	0.998	0.996	17.62	0.824	0.999	0.998	18.41	0.804	0.999	0.998	18.17
12	0.951	0.998	0.996	18.91	0.774	0.999	0.999	18.05	0.735	0.999	0.998	17.33

Tablo 5.15’de görüldüğü gibi her alt küme veri dağılımı için bütün uygunluk ölçütlerine göre en uygun model 12 numaralı 6 giriş değişkenli modeldir. Modellerin kendi içindeki performanslarını değerlendirdiğimizde performansın 1’den 12’ye doğru ardışık olarak iyileşmediği görülmüştür. Akış değişkenlerinin yağış değişkenlerine göre katı madde taşınımında daha etkin bir değişken olmasından dolayı aynı girdi sayısına sahip ağlardan daha çok akış değişkenleri içeren modeller daha iyi sonuçlar vermişlerdir. Tablo 5.15’e göre en uygun model yapısı olan 6 giriş değişkenli 12 nolu ağ modelinin matematiksel ifadesi denklem (5.10) ile gösterilmiştir.

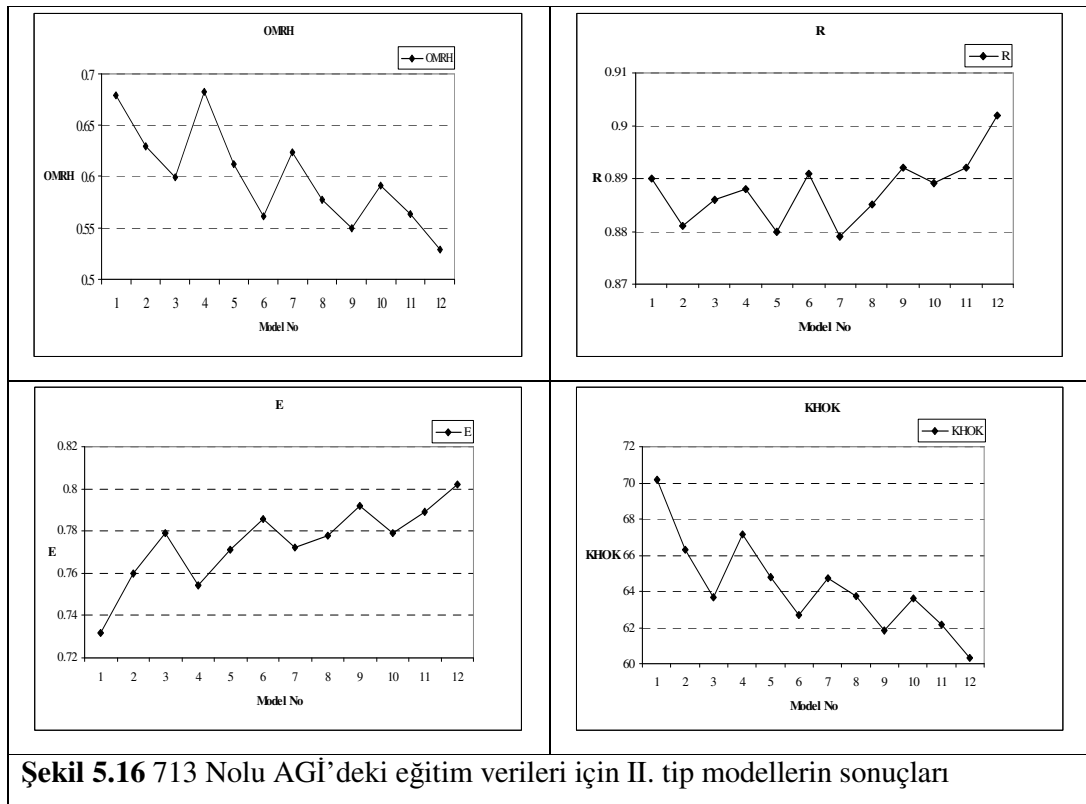
$$S(t)_{735} = f(Q(t)_{735}, Q(t-1)_{735}, Q(t-2)_{735}, P(t), P(t-1), P(t-2)) \quad (5.10)$$

Kullanılan veri dağılımlarına göre bakıldığında test için kullanılan eğitim verisi arttıkça ağın performansının iyileştiği görülmektedir. R ve E uygunluk ölçütleri açısından sonuçlar her ne kadar birbirine yakın olsa da OMRH ve KHOK açısından III. tip modellerde bu değerler sırasıyla 0.951 den 0.735 e ve 18.91 den 17.33 e kadar inmiştir.

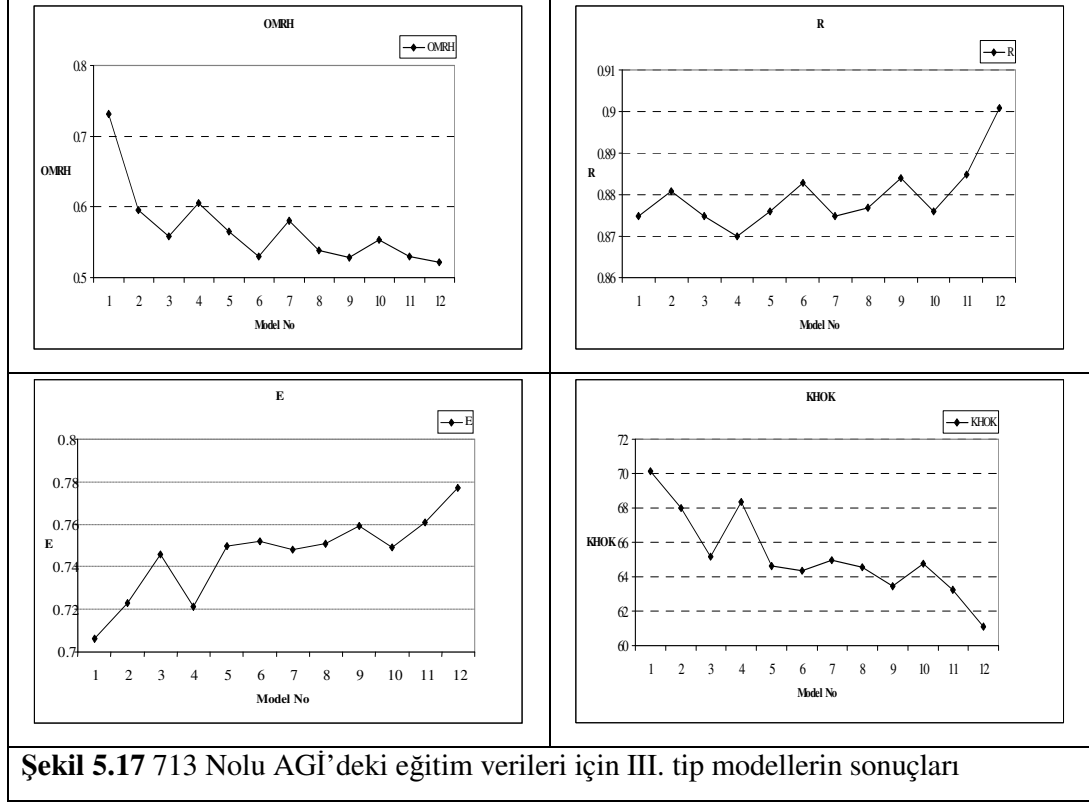
713 ve 735 nolu AGİ’lerde kullanılan eğitim verileri için I., II. ve III. tip modellerin sonuçları Tablo 5.15, 5.16, 5.17, 5.18, 5.19 ve 5.20’de gösterilmiştir.



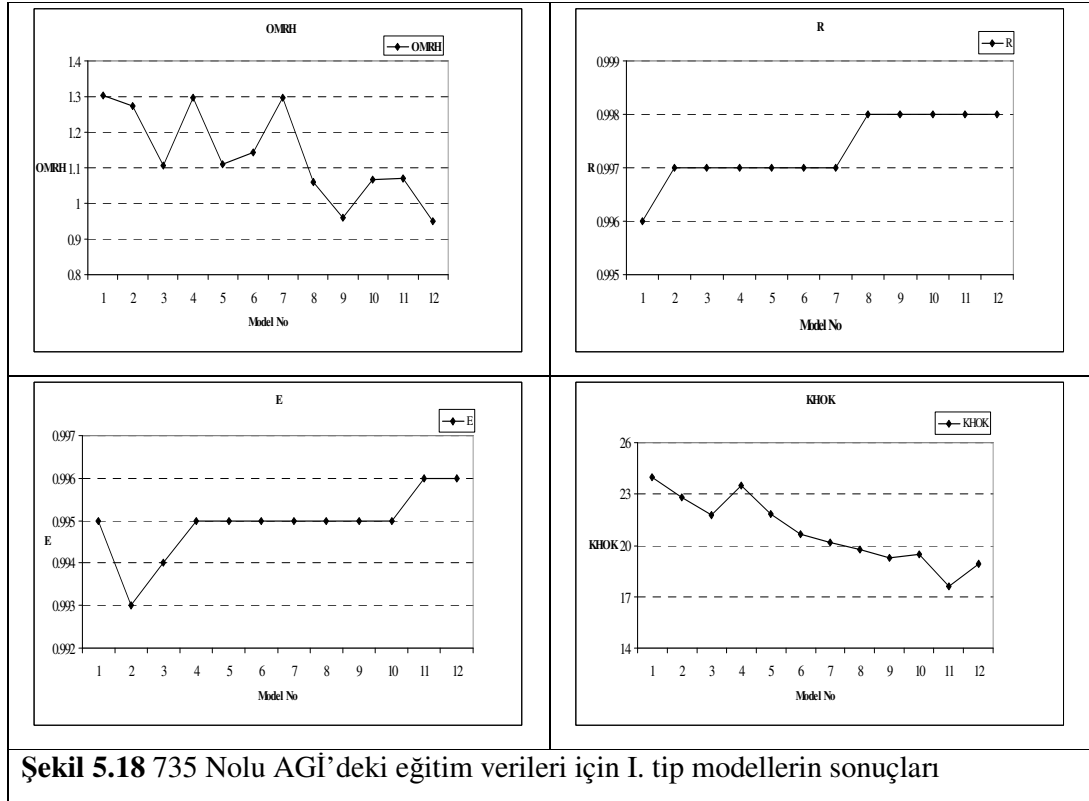
Şekil 5.15 713 Nolu AGİ'deki eğitim verileri için I. tip modellerin sonuçları



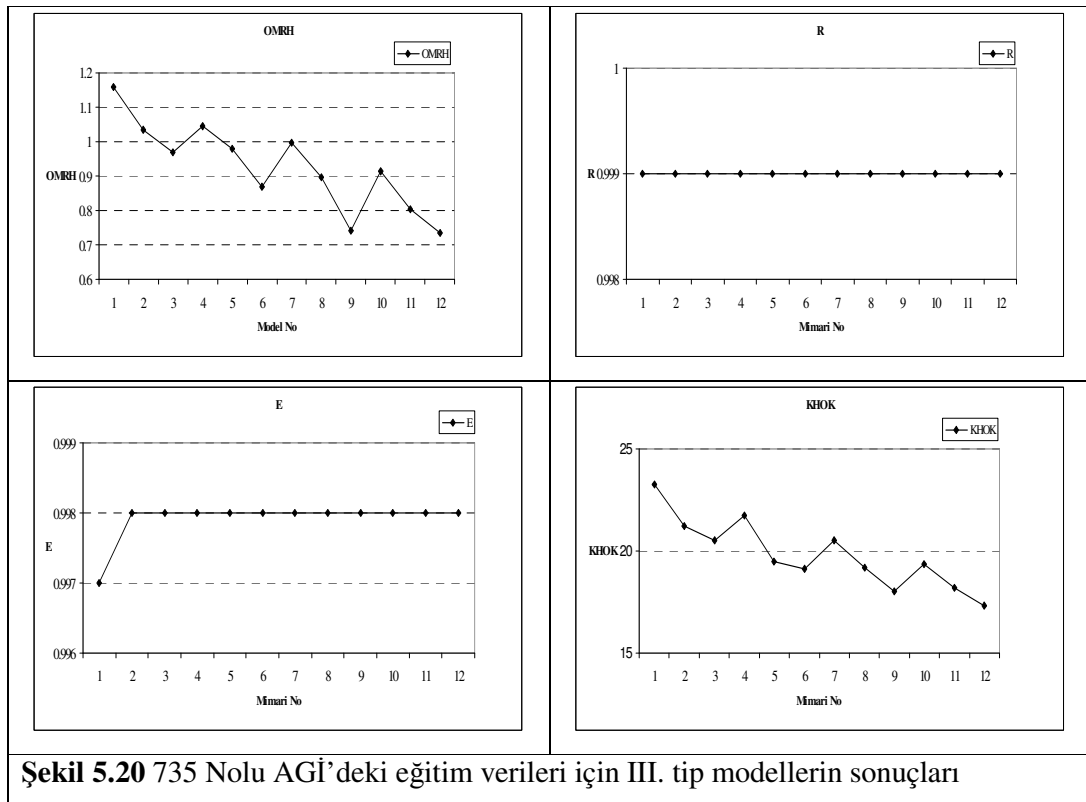
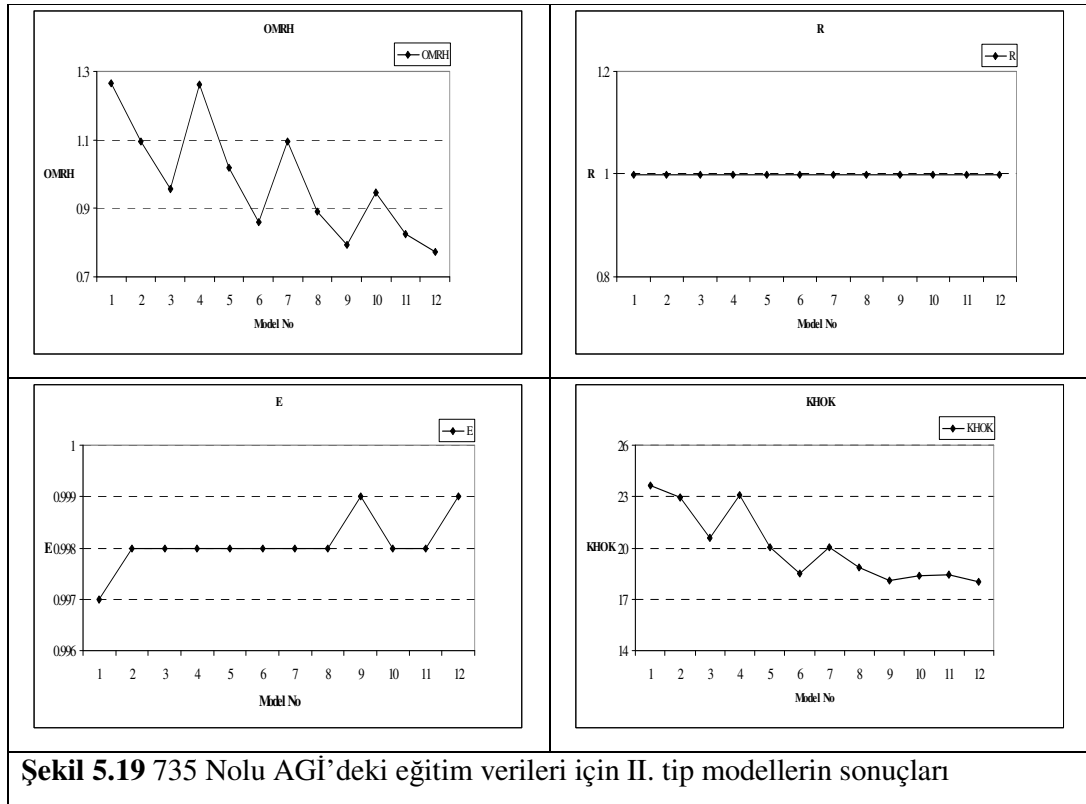
Şekil 5.16 713 Nolu AGİ'deki eğitim verileri için II. tip modellerin sonuçları



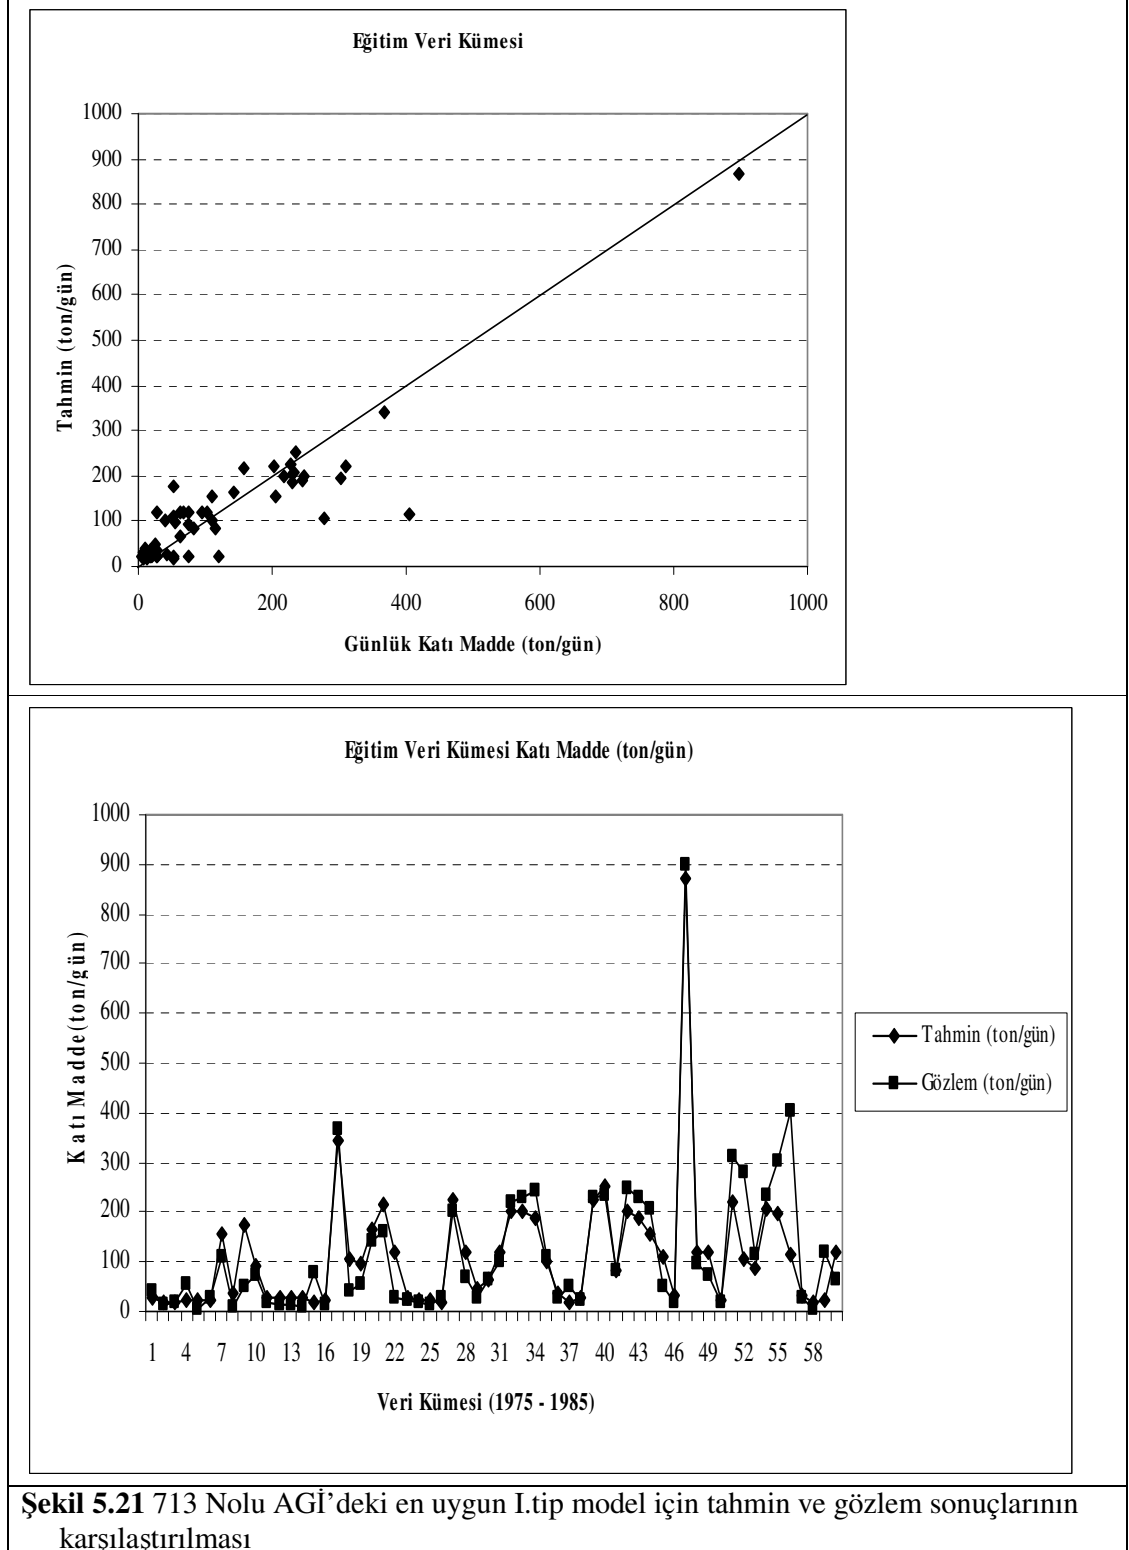
Şekil 5.17 713 Nolu AGİ'deki eğitim verileri için III. tip modellerin sonuçları



Şekil 5.18 735 Nolu AGİ'deki eğitim verileri için I. tip modellerin sonuçları




Tablo 5.14' deki uygunluk ölçütlerine göre 713 nolu AGİ için I. tip modeller arasından en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.21'de verilmiştir.




Şekil 5.21 713 Nolu AGİ'deki en uygun I. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması

Tablo 5.14’ deki uygunluk ölçütlerine göre 713 nolu AGİ için II. tip modeller arasından en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.22’de verilmiştir.




Şekil 5.22 713 Nolu AGİ’deki en uygun II.tip model için tahmin ve gözlem sonuçlarının karşılaştırılması

Tablo 5.14' deki uygunluk ölçütlerine göre 713 nolu AGİ için III. tip modeller arasında en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.23'de verilmiştir.




Şekil 5.23 713 Nolu AGİ'deki en uygun III. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması

Tablo 5.15’ deki uygunluk ölçütlerine göre 735 nolu AGİ için I. tip modeller arasından en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.24’de verilmiştir.




Tablo 5.15’ deki uygunluk ölçütlerine göre 735 nolu AGİ için II. tip modeller arasından en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.25’de verilmiştir.



Şekil 5.25 735 Nolu AGİ’deki en uygun II. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması

Tablo 5.15’ deki uygunluk ölçütlerine göre 735 nolu AGİ için III. tip modeller arasında en uygun model olarak 12 numaralı model seçilmiştir. Bu modele ait tahmin ve gözlem sonuçları Şekil 5.26’da verilmiştir.



Şekil 5.26 735 Nolu AGİ’deki en uygun III. tip model için tahmin ve gözlem sonuçlarının karşılaştırılması

5.9. YSA Sonuçlarının MLR Modelleri ile Karşılaştırılması

YSA katı madde tahmin modellerinin güvenilirliğini kontrol etmek ve daha hassas bir karşılaştırma yapmak için en uygun yapıya sahip YSA modelleri, AGİ'ler için geliştirilen çok değişkenli lineer regresyon (MLR) modelleri ile karşılaştırılmış ve Tablo 5.16 ve 5.17 de gösterilmiştir.

Tablo 5.16 713 Nolu AGİ için YSA ve MLR modellerinin karşılaştırılması

Eğitim İçin Kullanılan Veri Tipi	Eğitim İçin Kullanılan Veri Dağılımı	713 Nolu AGİ							
		OMRH		R		E		KHOK	
		YSA	MLR	YSA	MLR	YSA	MLR	YSA	MLR
Test	I	1,206	2.110	0,916	0,890	0,820	0,651	32,90	50.07
	II	1,573	2.628	0,980	0,890	0,825	0,712	35,44	45.48
	III	1,874	2.628	0,980	0,890	0,766	0,712	40,97	45.48
Eğitim	I	0,644	0,854	0,911	0,883	0,828	0,779	59,62	67,57
	II	0,529	0,787	0,902	0,882	0,802	0,779	60,34	63,74
	III	0,522	0,821	0,901	0,876	0,777	0,768	61,11	62,31

Tablo 5.17 735 Nolu AGİ için YSA ve MLR modellerinin karşılaştırılması

Eğitim İçin Kullanılan Veri Tipi	Eğitim İçin Kullanılan Veri Dağılımı	735 Nolu AGİ							
		OMRH		R		E		KHOK	
		YSA	MLR	YSA	MLR	YSA	MLR	YSA	MLR
Test	I	0,321	1,357	0,953	0,889	0,892	0,770	40,75	59,53
	II	0,287	0,756	0,930	0,884	0,774	0,741	7,87	8,45
	III	0,319	0,870	0,898	0,870	0,752	0,719	35,43	37,68
Eğitim	I	0,951	4,483	0,998	0,905	0,996	0,864	18,91	119,53
	II	0,774	6,496	0,999	0,861	0,999	0,694	18,05	239,54
	III	0,735	6,184	0,999	0,855	0,998	0,73	17,33	227,66

Tablo 5.16 incelendiğinde, test aşamasında kullanılan veriler hem test kümesinden hem de eğitim kümesinden alındığında, YSA model performanslarının MLR modellerine göre daha iyi sonuçlar verdiği görülmektedir. Burada R uygunluk ölçütü açısından YSA modelleri ile MLR modelleri birbirine yakın sonuçlar vermesine karşın hata ölçütleri olan OMRH ve KHOK değerleri ile verimlilik ölçütü (E) açısından YSA modellerinin üstünlüğü açıkça görülmektedir. Tablo 5.17'ye bakıldığında da sonuçların Tablo 5.16'daki sonuçlara benzemesine rağmen özellikle MLR modelleri için hata değerleri çok yüksek çıkmıştır. Buda MLR modellerinin YSA modellerine göre serilerin standart sapmaları ve çarpıklıklarından daha çok etkilendiğini göstermektedir.

Burada kullanılan MLR modelleri SPSS programı tarafından geliştirilmiş olup bu modelle ilgili temel bağıntı denklem (5.11) de ve geliştirilen modellere ait matematiksel ifadeler Tablo 5.18 ve Tablo 5.19'da verilmiştir.

$$S(t) = f(Q(t), Q(t-1), Q(t-2), P(t), P(t-1), P(t-2)) \quad (5.11)$$


Tablo 5.18 713 Nolu AGİ için geliştirilen MLR denklemleri

Eğitim İçin Kullanılan Veri Tipi	Eğitim İçin Kullanılan Veri Dağılımı	713 Nolu AGİ	
		MLR Denklemleri	
Test	I	$S(t) = -16,9 + 9,42Q_t - 34,1Q_{t-1} + 32,8Q_{t-2} + 0,21P_t + 2,26P_{t-1} + 0,41P_{t-2}$	
	II	$S(t) = -25,9 + 18,5Q_t - 58,5Q_{t-1} + 51,2Q_{t-2} - 2,95P_t - 6,78P_{t-1} + 4,02P_{t-2}$	
	III	$S(t) = -25,9 + 18,5Q_t - 58,5Q_{t-1} + 51,2Q_{t-2} - 2,97P_t - 6,78P_{t-1} + 4,02P_{t-2}$	
Eğitim	I	$S(t) = 5,7 + 13,3Q_t - 7,77Q_{t-1} + 1,86Q_{t-2} - 1,09P_t + 3,87P_{t-1} - 0,58P_{t-2}$	
	II	$S(t) = 2,7 + 13,2Q_t - 8,55Q_{t-1} + 2,58Q_{t-2} - 1,03P_t + 4,09P_{t-1} - 0,37P_{t-2}$	
	III	$S(t) = 0,8 + 13,2Q_t - 7,96Q_{t-1} + 1,98Q_{t-2} - 0,81P_t + 1,71P_{t-1} + 0,02P_{t-2}$	


Tablo 5.19 735 Nolu AGİ için geliştirilen MLR denklemleri

Eğitim İçin Kullanılan Veri Tipi	Eğitim İçin Kullanılan Veri Dağılımı	735 Nolu AGİ	
		MLR Denklemleri	
Test	I	$S(t) = -26,2 + 9,7Q_t - 54,5Q_{t-1} + 60,2Q_{t-2} + 15,1P_t + 9,5P_{t-1} - 13,7P_{t-2}$	
	II	$S(t) = -45,3 - 4,12Q_t + 26Q_{t-1} + 2Q_{t-2} - 33,5P_t - 26,6P_{t-2}$	
	III	$S(t) = -25,1 - 12,6Q_t + 105Q_{t-1} - 66,8Q_{t-2} - 167P_t + 26,8P_{t-1} - 48,4P_{t-2}$	
Eğitim	I	$S(t) = -90,9 + 65Q_t + 138Q_{t-1} - 169Q_{t-2} + 8,83P_t + 2,27P_{t-1} - 3,58P_{t-2}$	
	II	$S(t) = -115 + 80,6Q_t - 44,7Q_{t-1} - 7,6Q_{t-2} + 18,1P_t + 52,3P_{t-1} + 3,43P_{t-2}$	
	III	$S(t) = -110 + 91,5Q_t - 55,6Q_{t-1} - 7,5Q_{t-2} + 18P_t + 47,8P_{t-1} + 4,91P_{t-2}$	


Literatür çalışmalarında da görüldüğü gibi genellikle en uygun YSA modelinin seçiminde R ve E uygunluk ölçütleri belirleyici ölçütler olarak öngörülmüştür. Bu yaklaşımla sonuçları değerlendirdiğimizde R ve E ölçütlerine göre 713 Nolu AGİ için II. tip modeller ve 735 Nolu AGİ için I. tip modeller en uygun sonuçları vermiş olup istasyonlara ait veri yapısını en iyi yansıtan YSA yapıları olarak öngörülebilmektedir. 713 Nolu ve 735 Nolu AGİ'ler için öngörülen en iyi YSA yapılarına ait sonuçlar ile aynı istasyonlara ait geliştirilen MLR modellerine ait sonuçların karşılaştırılması Şekil 5.27, 5.28, 5.29 ve 5.30'da gösterilmiştir.




Şekil 5.27 713 Nolu AGİ'deki test verileri kullanılarak geliştirilen en uygun II.tip model için elde edilen YSA sonuçları ile MLR sonuçlarının karşılaştırılması



Şekil 5.28 713 Nolu AGİ'deki eğitim verileri kullanılarak geliştirilen en uygun II.tip model için elde edilen YSA sonuçları ile MLR sonuçlarının karşılaştırılması



Şekil 5.29 735 Nolu AGİ'deki test verileri kullanılarak geliştirilen en uygun I.tip model için elde edilen YSA sonuçları ile MLR sonuçlarının karşılaştırılması



Şekil 5.30 735 Nolu AGİ'deki eğitim verileri kullanılarak geliştirilen en uygun I.tip model için elde edilen YSA sonuçları ile MLR sonuçlarının karşılaştırılması

6. SONUÇLAR

Yapılan çalışmada YSA'nın akarsularda taşınan katı madde miktarının tahmini için uygulanabilirliği araştırılmıştır. Bu amaçla Büyük Menderes Havzası'na ait Yukarı Büyük Menderes alt havzası ve Banaz alt havzaları seçilmiş, bu iki havzaya ait 713 No'lu ve 735 No'lu AGİ'ler için katı madde tahmin modelleri geliştirilmiştir. Katı madde tahmini için ilk önce girdi değişkenleri belirlenmiş ve bu değişkenlerin kombinasyonları kullanılarak modeller belirlenmiştir. Tahminlerde eğitim, onaylama ve test veri küme yapılarının, model davranışı üzerinde etkili olduğu bilinmektedir. Bu nedenle daha iyi bir modelleme ve tahmin için veri kümelerinin düzenlenmesinde çapraz geçerlilik yöntemi kullanılmıştır. Bu sebeple veri kümesi 4 farklı şekilde veri alt kümelerine ayrılarak en iyi mimari araştırılmıştır. Eğitim aşamasında ise, her bir kombinasyon üç farklı veri dağılımı kullanılarak eğitilmiştir. Tahmin modellerinin sonuçlarını değerlendirmek için çeşitli performans değerlendirme ölçütleri hesaplanarak her bir AGİ için en uygun katı madde model yapısı belirlenmiştir. Bulunan en iyi YSA yapıları yine aynı uygunluk ölçütleri kullanılarak istasyonlar için geliştirilen MLR modelleri ile kıyaslanmıştır.

Katı madde tahmini için 713 ve 735 No'lu AGİ'lere ait geliştirilen model sonuçları değerlendirildiğinde, girdi değişkenlerinin sayısının artması model performansını arttırırken, aynı girdi değişken sayısına sahip modellerden daha çok akış değişkeni içeren modeller diğer modellere göre daha iyi sonuç vermiştir. Veri dağılımlarına göre değerlendirdiğimizde ise, 713 No'lu AGİ için OMRH, E ve KHOK uygunluk ölçütlerine göre I. tip modeller, R uygunluk ölçütüne göre ise, III. tip modeller en iyi sonuçları vermiştir. 735 No'lu AGİ için de, R ve E uygunluk ölçütlerine göre I. tip modeller ile OMRH ve KHOK uygunluk ölçütlerine göre ise II. tip modeller en iyi sonuçlar vermiştir.

Bu çalışmada, YSA katı madde tahmin modellerinin güvenilirliğini kontrol etmek ve daha hassas bir karşılaştırma yapmak için en uygun yapıya sahip YSA modelleri, AGİ'ler için geliştirilen MLR modelleri ile karşılaştırılmıştır. Sonuçlar incelendiğinde her iki AGİ içinde gerek test verilerinin test aşamasında kullanıldığı modellerde gerekse eğitim verilerinin test aşamasında kullanıldığı modellerde YSA modelleri uygunluk ölçütlerine göre MLR modellerinden daha yüksek performans göstermiştir

Literatür çalışmalarında da görüldüğü gibi genellikle en uygun YSA modelinin seçiminde R ve E uygunluk ölçütleri belirleyici ölçütler olarak öngörülmüştür. Bu yaklaşımla sonuçları değerlendirdiğimizde R ve E ölçütlerine göre 713 Nolu AGİ için II. tip modeller ve 735 Nolu AGİ için I. tip modeller en uygun sonuçları vermiş olup istasyonlara ait veri yapısını en iyi yansıtan YSA yapıları olarak öngörülebilir.

Bu çalışmada YSA'ların katı madde miktarının modellenmesinde başarılı bir şekilde uygulanabileceği ve geleneksel regresyon analizi metotlarından çok daha iyi sonuçlar vereceği ortaya konmasına rağmen yöntemin başarısı, sağlıklı ve yeterli miktarda verinin mevcut olmasına bağlıdır. Bu nedenle verilerin gerek toplanması gerekse işlenmesi sistematik bir şekilde yapılmalıdır. Ülkemiz koşullarında katı madde gözlemleri ise ayda bir kez yapılabilmektedir. Gözlemlerin sıklığının artırılmasıyla gerek YSA performanslarının artması gerekse serilerin stokastik özelliklerinin de daha etkin bir şekilde dikkate alınabileceği unutulmamalıdır.

KAYNAKLAR

- Abrahart, R.J., and White, S.M., (2001) Modelling Sediment Transfer in Malawi: Comparing Backpropagation Neural Network Solutions Against a Multiple Linear Regression Benchmark Using Small Data Sets. *Phys. Chem. Earth(B)*, 26(1): 19 - 24.
- Agarwal, A., Mishra, S.K., Ram, S., and Singh, J.K. (2006) Simulation of runoff and sediment yield using artificial neural networks. *Biosystems Engi.*, 94(4): 597-613.
- Akpınar, H., (1993) Yapay Sinir Ağları ve Kredi Taleplerinin Değerlendirilmesinde Bir Uygulama Önerisi. *İstanbul Üniversitesi İşletme Fakültesi Sayısal Yöntemler Ana Bilim Dalı*, 70 s.
- Alp. M., and Cıgızoğlu, H.K., (2007) Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data. *Environmental Modelling & Software*, 22: 2-13.
- Anderson, D., and McNeill, G., (1992), Artificial Neural Networks Technology, *A Dacs State – of – the – Art Report*, Utica, New York, A011: 83 s.
- Aqil, M., Kita, I., Yano, A., and Nishiyama, S., (2007) A comparative study of artificial neural networks and neuro – fuzzy in continuous modeling of the daily and hourly behaviour of runoff. *Journal of Hydrology*, 337: 22 - 34
- Bayazit, M., (1996) Bed Material Transport, *Sediment Transport Technology DSI Proceedings Volume 1*, 5: 5.21-5.25.
- Bolrich and Presissler (1992) Technische Hydromechanic, Band 1, *Verlag für Bauwesen*, Berlin, 680 s.
- Campolo, M., Soldati, A., and Andreussi, P., (2003) Artificial neural network approach to flood forecasting in the River Arno. *Hydrological Sciences*, 48(3): 381-398
- Cıgızoğlu, H.K., (2004) Estimation and forecasting of daily suspended sediment data by multilayer perceptrons. *Advances in Water Resources*, 27: 185-195.
- Cıgızoğlu, H.K., and Kişi, Ö., (2006) Methods to improve the neural network performance in suspended sediment estimation. *Journal of Hydrology*, 317: 221-238.
- Cıgızoğlu, H.K., and Alp, M., (2006) Generalized regression neural network in modelling river sediment yield. *Advances in Engineering Software*, 37: 63-68.
- Du Boys, M.P. (1879) Le Rhone et le Rivieres a Lit affouillable. *Mem. Doc. Ann. Pont et Chaussees*, Ser. 5, Bd. XVIII.
- Efe, M. ve Kaynak, O., (2000) Yapay Sinir Ağları ve Uygulamaları (1. basım), *Boğaziçi Üniversitesi*, İstanbul, 148 s.

- Einstein, H.A., (1950) The Bed – Load Function for Sediment Transportation in Open – Channel Flows. *U.S. Dept. of Agri. Techn. Bull*, 1026
- Erkek, C., ve Ağırlioğlu, N. (2002) Su Kaynakları Mühendisliği. *Beta Yayınları*, 975-295-125-2. İstanbul, 360 s.
- Fırat, M., (2002) Doğrusal Kıvrımlı Akarsularda Yerleştirilen Köprü Ayakları Etrafında Meydana Gelen Oyulma Derinliğinin Yapay Sinir Ağları İle Belirlenmesi, Yüksek Lisans Tezi, *Pamukkale Üniversitesi Fen Bilimleri Enstitüsü*, Denizli, 133 s.
- Fırat M. ve Güngör, M., (2004) Askı Maddesi Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi, *İmo Teknik Dergi*, 219: 3267 - 3282
- Fırat, M., (2007) Sinirsel Bulanık Mantık Yaklaşımı İle Havza Modellemesi, Doktora Tezi, *Pamukkale Üniversitesi Fen Bilimleri Enstitüsü*, Denizli, 184 s.
- Forcheimer, P., (1939) Hydraulik. Bg. *Teubner*, Leipzig/Berlin
- Frijlink, H.C., (1952) Discussion des Formules de debit solide de Kalinske, Einstein et Meyer – Peter et Müller compte tenue des mesures recente de transport dans les rivières neerlandaises, Grenoble, *Societe Hydrotechnique de France, 2eme. Journee Hydraulique.*
- Güngör, M., (1997) Akarsu Kıvrımlarına Yerleştirilen Köprü Kenar Ayakları Etrafında Meydana Gelen Yerel Oyulma Derinliğinin Belirlenmesi, Doktora Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 112 s.
- Haykin, S., (1999) Neural networks: a comprehensive foundation (2nd edn). *London: Prince Hall,*
- Kalinske, A.A., (1947) Movement of Sediment as Bed – Load in Rivers, *Transact. Am. Geophys. Union*, volume 28.
- Kang, K.W., Park, C.Y. and Kim, J.H., (1992) Neural network and its application to rainfall-runoff forecasting, *Korean Journal of Hydroscience*, 4: 1-9.
- Meyer – Peter, E., and Müller, R. (1949) Eine Formel zur Berechnung des Geschiebetriebes, *Schwiezer Bauzeitung*, 67 : 3
- Nagy, H.M., Watanabe, K., and Hirano, M. (2002) Prediction of sediment load concentration in rivers using artificial neural network model. *Journal of Hydr. Eng*, 128: 588-595.
- Newham, L.T.H., Norton, J.P., Prosser, I.P, Croke, B.F.W. and Jakeman, A.J., (2003) Sensitivity analysis for assessing the behaviour of a land-scape based sediment source and transport model. *Environmental Modelling & Software*, 18: 741-751.
- Özbek, T. ve Özcan, Ç., (2001) Akarsularda Katı Madde, *TMMOB İnşaat Mühendisleri Odası*, Ankara, 165 s.

- Saraç, T., (2004) Yapay Sinir Ağları, Seminer Projesi, *Gazi Üniversitesi Endüstri Mühendisliği Ana Bilim Dalı*, Ankara, 75 s.
- Sarangı, A., and Bhattacharya, A.K., (2005) Comparison of Artificial Neural Network and regression models for sediment loss prediction from Banha watershed in India. *Agricultural Water Management*, 78: 195-208.
- Schiels, A., (1936) Anwendung der Ähnlichkeitsmechanik und der Turbulenzforschung auf die Geschiebebewegung, *Mitteilungen der Preussischen Versuchsanstalt für Wasser –, Erd – und Schiffbau*, 26.
- Schoklitsch, A., (1934) Der Geschiebetrieb und Geschiebefracht, *Wasserkraft und Wasserwirtschaft*, 29: 4
- Sudheer, K.P., Nayak, P.C. and Ramasastry, K.S., (2003) Improving peak flow estimates in artificial neural network river flow models, *Hydrological Processes*, 17: 677-686
- Şen Z., (2004) Yapay Sinir Ağları, *Su Vakfı Yayınları*, İstanbul
- Şentürk, F. ve Şentürk A., (1998) Askıdaki Taşınım Malzemesinin Hesabı İçin Yeni Formül. *DSİ Teknik Bülteni*, 88: 3-6
- Vollmers, H., and Pernecker, L., (1965) Neue Betrachtungsmöglichkeiten des Feststofftransportes in offenen Gerinnen, *Die Wasserwirtschaft*, 55 Jg.
- Yaşar, M., (2004) Günlük Akışlardaki Boşlukların Yapay Sinir Ağları Kullanılarak Tamamlanması., Yüksek Lisans Tezi, *Pamukkale Üniversitesi Fen Bilimleri Enstitüsü*, Denizli, 97s.
- Yurtoğlu, H., (2005) Yapay Sinir Ağları Metodolojisi İle Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği. Uzmanlık Tezi, *Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü*, Ankara, 104 s.
- Zanke, U., (1982) Grundlagen der Sedimentbewegung, *Springer – Verlag*, Berlin, Heidelberg, 402 s.
- Zhu, Y.M., Lu, X.X. and Zhou, Y. (2007) Suspended sediment flux modeling with artificial neural network; An Example of the Longchuanjiang River in the Upper Yangtze Catchment, China. *Geomorphology*, 84: 111-125.

ÖZGEÇMİŞ

Onur ÖCAL, 09.10.1980 tarihinde Konya'da doğdu. İlk, orta ve lise öğrenimini Aydın'da tamamladı. 1999 yılında girdiği Pamukkale Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği bölümünü 2003 yılında bitirerek İnşaat Mühendisi unvanını aldı. 2004 yılında Pamukkale Üniversitesi Fen Bilimleri Enstitüsü'nde Hidrolik Bilim Dalı'nda Yüksek Lisans programına başladı. 05.08. 2006 – 23.02.2007 tarihleri arasında Erasmus Socrates Programı kapsamında İtalya'da Hidrolik üzerinde yüksek lisans eğitimi gördü. Seyahat etmekten ve müzik dinlemekten hoşlanan Onur ÖCAL, İngilizce ve İtalyanca bilmektedir.