



T.C.

ORMAN VE SU İŐLERİ BAKANLIĐI

**AKARÇAY HAVZASINDA ÇÖZÜNMÜŐ OKSİJEN
DEĐERLERİNİN YAPAY SİNİR AĐLARI İLE
BELİRLENMESİ**

-UZMANLIK TEZİ-

HAZIRLAYAN:

BEKİR YILMAZ

ANKARA - 2015

T.C.

T.C.
ORMAN VE SU İŞLERİ BAKANLIĞI
SU YÖNETİMİ GENEL MÜDÜRLÜĞÜ

AKARÇAY HAVZASINDA ÇÖZÜNMÜŞ OKSİJEN DEĞERLERİNİN YAPAY SİNİR
AĞLARI İLE BELİRLENMESİ

BEKİR YILMAZ

TEZ DANIŞMANI:
DR. YAKUP KARAASLAN

BU TEZ ORMAN VE SU İŞLERİ UZMAN YÖNETMELİĞİ GEREĞİ HAZIRLANMIŞ OLUP
JÜRİMİZ TARAFINDAN UZMANLIK TEZİ OLARAK KABUL EDİLMİŞTİR.

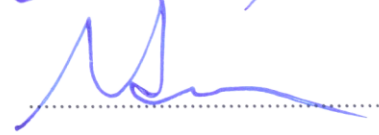
Tez Jürisi Başkanı: Prof. Dr. Cumali KINACI



Jüri Üyesi: Dr. Yakup KARAASLAN



Jüri Üyesi: Hüseyin AKBAŞ



Jüri Üyesi: Maruf ARAS



Jüri Üyesi: Taner KİMENÇE



TEŐEKKÜR

Tez sürecinde desteęini ve ilgisini hi bir zaman eksik etmeyen, tez danıőmanım Sayın Dr. Yakup KARAASLAN'a,

alıőmamı yönlendirmemde büyük emekleri olan Genel Müdürümüz ve Hocamız Sn. Prof.Dr.Cumali KINACI'ya, görüşleriyle tezime destek veren Do.Dr.Özlem Sıla OLGUN'a, akademik araştırma konusunda verdiği desteklerden dolayı değerli hocam Do.Dr.Aslıhan TÜFEKCI'ye,

Tez çalışmaları sırasında sağladıkları kolaylıklardan dolayı Sayın Bilal DİKMEN'e,

Deęerli çalışma arkadaşlarıım Hale ONBAŐLI, Tuęçe AKGÖZ, Kamil AYBUĞA ve Ayšın BÜTÜN'e,

Hayatım boyunca desteklerini her zaman yanımda hissettięim Aileme,

Sonsuz teşekkür ve minnetlerimi sunarım.

İÇİNDEKİLER

1. GİRİŞ.....	1
2. SU KALİTESİ.....	2
2.1. Su Çerçeve Direktifi	3
2.2. Su Kirliliği Kontrol Yönetmeliği.....	3
2.3. Yerüstü Su Kalitesi Yönetimi Yönetmeliği	3
2.4. Genel Su Kalitesi Sınıfları.....	5
2.5. Fizikokimyasal Su Kalitesi Parametreleri.....	5
2.6. Çözülmüş Oksijen	8
3. YAPAY SİNİR AĞLARI VE ZAMAN SERİLERİ	9
3.1. Yapay Sinir Ağları.....	9
3.1.1 Yapay Sinir Hücresi	11
3.1.2 Yapay Sinir Ağı Yapısı.....	18
3.1.3 Yapay Sinir Ağlarında Öğrenme	22
3.1.4 Yayılm ve Öğrenme Algoritmaları	23
3.2. Zaman Serileri	25
3.2.1 Sürekli ve Kesikli Zaman Serileri	25
3.2.2 Deterministik ve Stokastik Zaman Serileri	26
3.2.3 Regresyon	27
3.3. YSA ile Zaman Serisi Tahmini.....	28
3.3.1 NAR Ağı	29
3.3.2 NARX Ağı	30
3.4. YSA Uygulamaları	33
4. UYGULAMA	35
4.1. Akarçay Havzası.....	35
4.2. Veri Seti	36
4.3. Veri Ön İşleme ve Normalizasyonu	37
4.4. Oluşturulan Yapay Sinir Ağı Modelleri.....	38
4.5. Uygulama Aşamaları.....	39
4.6. Web Uygulaması.....	49
4.7. Uygulama Çıktıları.....	56
5. SONUÇLAR ve ÖNERİLER.....	60
6. KAYNAKLAR.....	63

SİMGELER ve KISALTMALAR

SKKY	Su Kirliliği Kontrol Yönetmeliği
AB	Avrupa Birliği
SÇD	Su Çerçeve Direktifi
pH	Hidrojen Gücü (Power of Hydrogen)
KDS	Karar Destek Sistemleri (Decision Support Systems)
ÇO	Çözünmüş Oksijen
H+	Hidrojen İyonu
OH-	Hidroksil İyonu
EC	Elektriksel İletkenlik (Electric Conductivity)
TDS	Toplam Çözünmüş Katı Madde (Total Dissolved Solid)
TANH	Hiperbolik Tanjant
SIN	Sinüs
CPU	Merkezi İşlem Birimi (Central Processing Unit)
SBP	Standart Geri Yayılım (Standard Back Propagation)
QPROP	Hızlı Yayılım (Quick Propagation)
RPROP	Esnek Yayılım (Resilient Propagation)
LMA	Levenberg – Marquardt
SCG	Ölçeklenmiş Konjüge Gradyen (Scaled Conjugate Gradient)
GB	Gigabyte
RAM	Rastgele Erişimli Bellek (Random Access Memory)
GHZ	Gigahertz
MSE	(Mean Squared Error)
BP	Geri Yayılım (Back Propagation)

YSA	Yapay Sinir Ađı
NARX	Dođrusal Olmayan Otoregresif Eksojen (Nonlinear Autoregressive Exogenous)
Ca	Kalsiyum
Mg	Magnezyum
Fe	Demir
mg	Miligram
TDL	Çıkmalı Gecikme Hattı (Tapped Delay Line)
ER	Varlık İlişki (Entity Relationship)
ID	Girdi Gecikmesi (Input Delays)
FD	Geri Besleme Gecikmesi (Feedback Delays)
GKNS	Gizli Katman Nöron Sayısı
KDS	Karar Destek Sistemleri
ARIMA	Otoregresif Entegre Hareketli Ortalama (Auto Regressive Integrated Moving Average)
DVR	Destek Vektör Regresyonu
PUNN	Çarpımsal Birimli Yapay Sinir Ağları (Product Unit Neural Network)

TABLO LİSTESİ

TABLO 1. KITAİÇİ YÜZEYSEL SU KAYNAKLARININ SINIFLARINA GÖRE KALİTE KRİTERLERİ	4
TABLO 2. NEHİR VE GÖL SU KÜTLELERİ İÇİN FİZİKOKİMYASAL PARAMETRELER	6
TABLO 3. NUMUNE ALMA NOKTALARI'NA AİT COĞRAFİ KOORDİNATLAR	36
TABLO 4. VS-1 VERİ SETİNDE KULLANILAN GİRDİLER	40
TABLO 5. M1 NARX MODEL SETİ PERFORMANSLARI	41
TABLO 6. VS-2 VERİ SETİNDE KULLANILAN GİRDİLER	43
TABLO 7. M2 NARX MODEL SETİ PERFORMANSLARI	44
TABLO 8. VS-3 VERİ SETİNDE KULLANILAN GİRDİLER	46
TABLO 9. M3 NARX MODEL SETİ PERFORMANSLARI	47
TABLO 10. 2 GİRDİLİ NARX MODELİ PERFORMANS ÇİZELGESİ	48
TABLO 11. 9 GİRDİLİ NARX MODELİ PERFORMANS ÇİZELGESİ	49

ŞEKİL LİSTESİ

ŞEKİL 1. BİYOLOJİK SİNİR HÜCRESİ	10
ŞEKİL 2. YAPAY SİNİR HÜCRESİ YAPISI	11
ŞEKİL 3. DOĞRUSAL (LİNEER) AKTİVASYON FONKSİYONU	13
ŞEKİL 4. SİNÜS FONKSİYONU GRAFİĞİ	14
ŞEKİL 5. ADIM AKTİVASYON FONKSİYONU	15
ŞEKİL 6. HİPERBOLİK TANJANT AKTİVASYON FONKSİYONU GRAFİĞİ	16
ŞEKİL 7. LOGARİTMİK AKTİVASYON FONKSİYONU	17
ŞEKİL 8. LOGARİTMİK SİGMOİD AKTİVASYON FONKSİYONU	18
ŞEKİL 9. ÇOK KATMANLI YAPAY SİNİR AĞI.....	19
ŞEKİL 10. TEK KATMANLI İLERİ BESLEMELİ YSA YAPISI.....	20
ŞEKİL 11. GERİ YAYILIMLI YSA	21
ŞEKİL 12. TDL / ÇIKMALI GECİKME HATTI (TAPPED DELAY LİNE)	30
ŞEKİL 13. PARALEL NARX MİMARİSİ	31
ŞEKİL 14. DİZİ-PARALEL NARX MİMARİSİ	32
ŞEKİL 15. ÇALIŞMADA KULLANILAN NARX-DP YSA MİMARİSİ.....	33
ŞEKİL 16. TÜRKİYE’NİN HAVZALARI	35
ŞEKİL 17. AKARÇAY HAVZASI	36
ŞEKİL 18. NUMUNE ALMA NOKTALARI	37
ŞEKİL 19. VS-1 VERİ SETİ İÇİN OLUŞTURULAN M1 NARX MODEL TASLAĞI.....	41
ŞEKİL 20. VS-2 VERİ SETİ İÇİN OLUŞTURULAN BİR M2 NARX MODEL TASLAĞI	44
ŞEKİL 21. VS-3 VERİ SETİ İÇİN OLUŞTURULAN M3 NARX MODELİ TASLAĞI.....	46
ŞEKİL 22. GELİŞTİRİLEN WEB UYGULAMASI MİMARİSİ	50
ŞEKİL 23. WEB UYGULAMASI İÇİN OLUŞTURULAN VERİTABANI MODELİ.....	51
ŞEKİL 24. WEB UYGULAMASI AÇILIŞ EKRANI	52
ŞEKİL 25. NUMUNE ALMA NOKTASINA AİT EKRAN.....	53
ŞEKİL 26. HESAPLAMA GERİ BİLDİRİM EKRANI.....	54
ŞEKİL 27. HESAPLAMA ÇIKTILARI EKRANI	55
ŞEKİL 28. WEB UYGULAMASI TAHMİN GRAFİĞİ.....	56
ŞEKİL 29. ARAPLI DERESİ NUMUNE ALMA NOKTASINDA TAHMİN SONUÇLARI	56
ŞEKİL 30. AFYON ATIKSU ARITMA TESİSİ ÇIKIŞI NUMUNE ALMA NOKTASINDA TAHMİN SONUÇLARI ...	57
ŞEKİL 31. ŞEKER FABRİKASI SONRASI NUMUNE ALMA NOKTASINDA TAHMİN SONUÇLARI	57
ŞEKİL 32. BOLVADİN KÖPRÜSÜ NUMUNE ALMA NOKTASINDA TAHMİN SONUÇLARI	58
ŞEKİL 33. EBER GÖLÜ YALI MEVKİİ NUMUNE ALMA NOKTASINDA TAHMİN SONUÇLARI.....	58
ŞEKİL 34. EBER GÖLÜ DONBAY NUMUNE ALMA NOKTASINDA TAHMİN SONUÇLARI	59
ŞEKİL 35. EBER GÖLÜ KOCAKANDIRALIK NUMUNE ALMA NOKTASINDA TAHMİN SONUÇLARI	59
ŞEKİL 36. EBER REGÜLATÖRÜ NUMUNE ALMA NOKTASINDA TAHMİN SONUÇLARI.....	59

DENKLEM LİSTESİ

DENKLEM (1)	12
DENKLEM (2)	12
DENKLEM (3)	13
DENKLEM (4)	14
DENKLEM (5)	15
DENKLEM (6)	16
DENKLEM (7)	17
DENKLEM (8)	25
DENKLEM (9)	26
DENKLEM (10)	26
DENKLEM (11)	28
DENKLEM (12)	29
DENKLEM (13)	31
DENKLEM (14)	38

ÖZET

Su stresi altında bulunan ülkemizde ulaşılabilir tatlı suların miktar ve kalitesinin muhafaza edilmesi oldukça önemlidir. Bu sebeple, su kalitesi yönetiminde, kaliteyi olumsuz yönde etkileyebilecek muhtemel kirletici parametrelerinin belirlenmesi ve su kalitesi yönetimi esasları doğrultusunda gerekli önlemlerin alınması gerekmektedir.

Bu gereklilik doğrultusunda, bu çalışmada, Doğrusal Olmayan Otoregresif Yapay Sinir Ağları (NARX) ile Akarçay Havzası'nda su kirliliğinde çok önemli bir parametre olan ve canlı yaşamı için kritik öneme sahip, çözülmüş oksijen parametresi tahmini modellenmiştir.

Çalışma kapsamında ilk olarak, en basit ve en performanslı modeli bulabilmek için Afyon Atıksu Arıtma Tesisi Çıkışı Numune alma noktasında, giriş katmanında sırasıyla 34, 9 ve 2 nöron bulunduran temel NARX Ağı tabanlı yapılara ait çeşitli konfigürasyonlar kullanılarak, çözülmüş oksijen konsantrasyonu tahmin edilmeye çalışılmıştır. Daha sonra en iyi sonuçlar yapay sinir ağının bir katmanı olan girdi katmanında 9 nörona sahip ve gizli katmanda 16 nörona sahip, 4:4:40 şeklinde girdi ve geribesleme gecikmesine sahip NARX konfigürasyonunda elde edilmiştir. Ortaya konulan model, daha sonra tek tek diğer numune alma noktalarında da çalıştırılarak, çözülmüş oksijeni tahmin etme başarısı ortalama %75 olarak bulunmuştur.

Çalışmada, klasik yapay sinir ağı tabanlı modellerin aksine, çözülmüş oksijen tahmininde, diğer parametrelerin çözülmüş oksijen değerine etkisi ve ölçümlere ait zaman serisi özellikleri de dikkate alınmıştır. Geliştirilen NARX modelinin sadece Akarçay Havzası'nda değil, ülkemizin diğer havzalarında da çözülmüş oksijen değerlerinin tahmininde, yapay zeka tabanlı bir öngörü mekanizması oluşturulmasına yardımcı olabileceği düşünülmektedir.

Çalışmada ortaya konulan modeller ve yaklaşımlar, kural tabanlı algoritmalar ve güçlü istatistiksel yöntemlerle desteklenerek, daha sonraki çalışmalarda geliştirilecek karar destek sistemlerine ve modelleme çalışmalarında oluşturulacak çeşitli bileşenlere altlık oluşturulabilecektir.

Anahtar Sözcükler: Yapay Sinir Ağları, Akarçay Havzası, Çözülmüş Oksijen

ABSTRACT

It is so important to maintain accessible fresh water quantity and quality, due to water stress in our country. Therefore, it is required that to make decisions and take necessary measures, considering possible scenarios with forecasting water quality parameters in water quality management.

In accordance with this requirement, in this work, Akarcay Basin is chosen, which is a considerable basin in our country. NARX(Nonlinear Autoregressive Exogenous) Neural Network based models which are used to forecast possible values of a water quality parameter, dissolved oxygen, in the future, are presented.

34, 9 and 2-input NARX models used for prediction of dissolved oxygen respectively. Best results are obtained from 12-input NARX models which have 16 neurons in hidden layer and 4:4:40 Input & Feedback delays. The resulting model has %75 prediction correctness in dissolved oxygen forecasting.

In these study, unlike conventional artificial neural network based models, past values of Dissolved Oxygen also used in relation with other water quality parameters and impact of time-series properties are also taken into account.

The approach and resulting models hereby presented, based on NARX architecture that used in prediction of Dissolved Oxygen values, would be a baseline for further works in decision support systems developed and various components built within modelling studies which will be used in water quality forecasting by supporting with rule based algorithms and strong statistical methods.

The approach and models shown here, can be used not only in Akarcay but also in other basins in our country, to build an AI based prediction and control mechanism in context of dissolved oxygen forecasting.

Keywords: Artificial Neural Networks, Akarçay Basin, Dissolved Oxygen

1. GİRİŞ

Canlı yaşamının sürdürülebilirliğinin sağlanabilmesi için, atmosferin yanı sıra su, en önemli unsurlardan birisidir. Sadece insan hayatıyla ilgili olarak değil, tüm yeryüzündeki ekosistemin ve yaşam ortamının korunması için, su vazgeçilmezdir. Canlılar tarafından kullanılan suyun yeterli miktarda ve temiz durumda olması gerekmektedir.

Dünyamızdaki su miktarı 1,4 milyar km³ olup, %97,5'i tuzlu sudan, geriye kalan %2,5'i ise tatlı su kaynaklarından oluşmaktadır [1,2]. Bu suların da büyük bir çoğunluğu, kutuplarda ve yeraltında bulunmaktadır [3]. Halihazırda tatlı suların da ancak % 0,3'ü göllerde, akarsularda, barajlarda ve göletlerde bulunmaktadır [4].

Türkiye'de yıllık ortalama yağış yaklaşık 643 mm olup, yılda ortalama 501 milyar m³ suya tekabül etmektedir [3]. Bu suyun 274 milyar m³'ü buharlaşmalar yoluyla tekrar atmosfere geri dönmekte, 69 milyar m³'lük kısmı yeraltı suyunu beslemekte, 158 milyar m³'lük kısmı ise akışa geçerek çeşitli büyüklükteki akarsular vasıtasıyla denizlere ve kapalı havzalardaki göllere boşalmaktadır [3]. Yeraltı suyunu besleyen 69 milyar m³'lük suyun 28 milyar m³'ü tekrar yerüstü suyuna katılmaktadır. Ayrıca, Ülkemize komşu olan ülkelerden yılda ortalama 7 milyar m³ su gelmektedir, bu miktar da hesaba katıldığında ülkemizin brüt yerüstü suyu potansiyeli 193 milyar m³ olmaktadır [5].

2025 yılından sonra, dünyada 3 milyar civarında insanın su kıtlığı yaşayacağı düşünülmektedir [6,7,8]. Yine küresel ısınma ve iklim değişikliğine bağlı olarak, öncelikli olarak su kaynakları etkilenmektedir. Su kıtlığı sorunu, kaynakların sınırlı olmasından kaynaklanmamaktadır, tam aksine yeryüzünde tüm canlılara yetecek kadar su halihazırda mevcuttur. Su kaynaklarının kirlenmesi ve korunamaması, su yetersizliğinin önemli sebeplerinden biridir. Dünyadaki su sorunu, miktarın az olmasından değil, suyun iyi yönetilememesinden ve su kaynaklarının uygun şekilde korunmamasından kaynaklanmaktadır [9]. Ülkemizde de su kaynaklarının korunmasının yeterli olmaması ve dolayısı ile kirlenmesi söz konusudur. Bu durum yakın gelecekte ulaşılabilir tatlı su miktarının yeterli olmamasına sebep olabilir.

20. yüzyılda dünya nüfusu 19. yüzyıla oranla üç kat fazla artmasına rağmen, su kaynaklarının kullanımının altı kat fazla arttığı belirlenmiştir [10]. Bu sebeple, kullanılabilir su kaynakları

ihtiyacı karşılamakta gün geçtikçe daha yetersiz olmakta ve suya bağlı (temizlik, sanayi, tarım vb) sektörler bu durumdan etkilenmektedir.

Su kaynaklarının kirlenme tehdidiyle karşı karşıya olması dikkate alınmalı ve su kaynaklarının sürdürülebilir olarak yönetilebilmesi gerekmektedir. Bunun için suyun hidrolojik olarak doğal sınırları dikkate alınmalıdır ve su kaynakları havza bazında yönetilmelidir. Su kaynağının korunması ve yararlı kullanımı doğrultusunda değerlendirilmesi havza bazında tüm faktörleri dikkate alan bir yönetim mekanizması ile gerçekleştirilebilir. Entegre havza yönetimi yaklaşımı, nehir havzasındaki tüm etkileri, baskıları, neden ve sonuçları dikkate alarak, su kaynaklarının kalitesini ve miktarını korumayı amaçlamaktadır [11,12]. Entegre havza yönetimi yaklaşımı doğrultusunda, su kirliliğinin yönetilebilmesi için öncelikle su kaynağının mevcut durumun ortaya konması gerekmektedir. Mevcut durum ortaya konduktan sonra, mevcut şartlarla gelecekte olabilecek kirlenmeleri ve bozulmaları öngörebilmek, daha sonra gelecekte arzu edilen ideal su durumuna ulaşabilmek için stratejiler geliştirebilmek ciddi önem arz etmektedir. Strateji geliştirebilmek içinse, geleceği öngörebilmek, bunun için de geçmiş ve mevcut durumu iyi yorumlayabilmek oldukça önemlidir. Yorumlara dayanarak karar verebilmek, verilen kararların etkilerini ve sonuçlarını, gelecekteki kararlara yansımaları ve ortaya koyacağı yeni senaryoları yaklaşık olarak tahmin edebilmek gerekmektedir.

Karar Destek Sistemleri (KDS) tam da bu noktada karşımıza çıkmaktadır. KDS aracılığıyla geçmiş durumlardaki bir çok parametre ve bileşen analiz edilerek, gelecekteki muhtemel durumlar ve senaryolar analiz edilmeye, bu durumlar karşısında muhtemel kararlar verilmeye çalışılmaktadır [13]. KDS gelecekte karar vericinin daha iyi karar verebilmesi için bir araç görevi görmektedir. Bu kapsamda oluşturulan modeller ve senaryolar işletilerek, muhtemel olarak ne ile karşılaşılacağı, gelecekteki bir noktada verilen kararlar doğrultusunda ne tür değişiklikler olacağı simülasyonlar vasıtasıyla ön görülmeye çalışılmaktadır. Sonuçta ideal ve alternatif senaryo ve eylemler ortaya konulmaktadır.

2. SU KALİTESİ

Su yönetiminde, su kalitesinin korunabilmesi, en önemli hedeflerden birisidir. Bu kapsamda su kalitesinin mevcut durumunun su kütlesi bazında ortaya konması ve havza bazında su kalitesi için gerekli tedbirlerin alınması, iyi su durumunu yakalamak için gereklidir.

Su kirliliğine sebep olan unsurların kaynakları ve etkileri oldukça farklılık arz etmektedir. Çeşitli insan aktiviteleri sonucunda oluşan ve çok değişken yapıya sahip olan atık sular nehir, göl ve deniz gibi alıcı ortamlara boşaltıldıklarında, alıcı ortamın fiziko-kimyasal ve biyolojik yapısını önemli ölçüde değiştirmektedir. Ülkemizde atık su deşarjının yanı sıra evsel ve endüstriyel katı atıklar, tarımda ilaçlama ve gübre kaynaklı maddelerin su kaynaklarına karışması sonucu kirlilik öne çıkmaktadır [10]. Bu etkenler dikkate alınarak, ülkemiz genelinde su kalitesinin iyileştirilmesi, korunması ve iyi su durumuna ulaşmak için yöntemler geliştirilmiş ve bu yöntemler, çeşitli mevzuatlar aracılığıyla yürürlüğe konmuştur.

2.1. Su Çerçeve Direktifi

Avrupa Birliği (AB), Su Yönetimi için "Su Çerçeve Direktifi (SÇD)"'ni 2000 yılında yürürlüğe koymuştur. SÇD, AB genelinde su kaynaklarının miktar ve nitelik olarak korunmasını ve iyileştirilmesini amaçlamaktadır [14]. Bununla birlikte, AB ülkeleri için 2015 yılında, tüm su kaynaklarında, iyi su durumunu sağlama hedefi ortaya konmuştur. Yine bu hedef doğrultusunda, AB ülkeleri ulusal ve uluslararası kapsamda, su yönetim planlarını oluşturmuşlardır. Böylelikle, SÇD tüm AB çapında su sorununun çözümüne daha aktif olarak katılımını sağlamayı hedeflemektedir.

2.2. Su Kirliliği Kontrol Yönetmeliği

Ülkemizde de su kalitesinin yönetimi için, ilk olarak 1988 yılında Su Kirliliği Kontrol Yönetmeliği (SKKY) çıkarılmıştır. SKKY'nin amacı, ülkemizin kıtaiçi yeraltı ve yerüstü su kaynaklarının korunması ve su kirlenmesinin önlenmesi için hukuki ve teknik esasları belirlemek olarak ifade edilmektedir [15]. İlgili yönetmelikte, ülkemizin su kaynaklarının kalitesinin geliştirilmesi amacıyla çeşitli düzenlemeler ortaya konulmuştur. Yine yönetmelikte, yüzey suları ve yeraltı suları için kalite sınıflandırmalarının nasıl gerçekleştirileceğinin yanı sıra, evsel ve endüstriyel atıksu deşarjları ve tarım arazilerinin korunmasına ilişkin hükümler belirtilmiştir.

2.3. Yerüstü Su Kalitesi Yönetimi Yönetmeliği

Ülkemizde SKKY'den daha sonra, Ülkemiz AB üyeliği hedefleri doğrultusunda, 2012 yılında Yerüstü Su Kalitesi Yönetimi Yönetmeliği ortaya konulmuştur [16]. Yerüstü Su Kalitesi Yönetimi Yönetmeliğinde su kalitesinde ve sınıflandırılmasında, ölçülmesi gereken parametreler SÇD referans alınarak belirlenmiştir. Yerüstü Su Kalitesi Yönetimi

Yönetmeliğine göre su kalitesi parametreleri ve sınıflandırılması, Yönetmelik ekinde Tablo 1'de gösterilmektedir.

Tablo 1. Kıtaıçi Yüzeysel Su Kaynaklarının Sınıflarına Göre Kalite Kriterleri [16]

Su Kalite Parametreleri	Su Kalite Sınıfları			
	I	II	III	IV
Genel Şartlar				
Sıcaklık (°C)	≤ 25	≤ 25	≤ 30	> 30
pH	6,5-8,5	6,5-8,5	6,0-9,0	6,0-9,0 dışında
İletkenlik (µS/cm)	< 400	400-1000	1001-3000	> 3000
Renk	RES 436 nm: 1.5 RES 525 nm: 1.2 RES 620 nm: 0.8	RES 436 nm: 3 RES 525 nm: 2.4 RES 620 nm: 1.7	RES 436 nm: 4.3 RES 525 nm: 3.7 RES 620 nm: 2.5	RES 436 nm: 5 RES 525 nm: 4.2 RES 620 nm: 2.8
(A) Oksijenlendirme Parametreleri				
Çözünmüş oksijen (mg O ₂ /L) ^a	> 8	6-8	3-6	< 3
Oksijen doygunluğu (%) ^a	90	70-90	40-70	< 40
Kimyasal oksijen ihtiyacı (KOİ) (mg/L)	< 25	25-50	50-70	> 70
Biyolojik oksijen ihtiyacı (BOİ ₅) (mg/L)	< 4	4-8	8-20	> 20
(B) Nutrient (Besin Elementleri) Parametreleri				
Amonyum azotu (mg NH ₄ ⁺ -N/L)	< 0,2 ^b	0,2-1 ^b	1-2 ^b	> 2
Nitrit azotu (mg NO ₂ ⁻ -N/L)	< 0,002	0,002-0,01	0,01-0,05	> 0,05
Nitrat azotu (mg NO ₃ ⁻ -N/L)	< 5	5-10	10-20	> 20
Toplam kjeldahl-azotu (mg/L)	0.5	1.5	5	> 5
Toplam fosfor (mg P/L)	< 0,03	0,03-0,16	0,16-0,65	> 0,65
(C) İz Elementler (Metaller)				
Cıva (µg Hg/L)	< 0,1	0,1-0,5	0,5-2	> 2
Kadmiyum (µg Cd/L)	≤ 2	2-5	5-7	> 7
Kurşun (µg Pb/L)	≤10	10-20	20-50	> 50
Bakır (µg Cu/L)	≤20	20-50	50-200	> 200
Nikel (µg Ni/L)	≤20	20-50	50-200	> 200
Çinko (µg Zn/L)	≤200	200-500	500-2000	> 2000
(D) Bakteriyolojik Parametreler				
Fekal koliform (EMS/100 mL)	≤10	10-200	200-2000	> 2000
Toplam koliform (EMS/100 mL)	≤100	100-20000	20000-100000	> 100000

Bu yönetmelikte temel amaç, SÇD ile uyumlu olarak ülkemiz genelinde “iyi su durumu” na ulaşmaktır. İyi su durumuna ulaşırken yerüstü suları ile kıyı ve geçiş suları da dahil olmak üzere, biyolojik, kimyasal, fiziko-kimyasal su kalitelerinin belirlenmesi ve miktarın izlenmesi, bu suların kullanım maksatlarının sürdürülebilir kalkınma hedefleriyle uyumlu bir şekilde koruma kullanma dengesi de gözetilerek ortaya konulması, korunması ve iyi su durumuna ulaşılması için alınacak tedbirlere yönelik yöntemler belirlenmeye çalışılmıştır [16].

2.4. Genel Su Kalitesi Sınıfları

Ülkemizde su kalitesinin belirlenmesi konusunda, şu anda yürürlükte olan Yerüstü Su Kalitesi Yönetimi Yönetmeliği’nde su kalitesinin nasıl sınıflandırılacağı detaylarıyla belirtilmektedir. Yönetmelikte su kalitesi için dört ayrı sınıf tanımlanmıştır. Birinci sınıf en iyi kalitedeki su durumunu göstermekle birlikte, dördüncü sınıf aşırı derecede kirlenmiş suyu ortaya koymaktadır [16].

Sınıf I, yüksek kaliteli suyu temsil etmektedir. İçme suyu olma potansiyeli yüksek olan yerüstü suları ile yüzme gibi vücut teması gerektiren sular bu sınıfa girmektedir. Sınıf II’de ise yine daha az kirlenmiş sular yer almaktadır. Sınıf II’de, birinci sınıfa göre daha düşük kaliteli içmesuyu olarak kullanılabilen sular ve sulama suyu olarak kullanılabilen sular bulunmaktadır. Sınıf III’te bulunan sular ise kirlenmiş sular olarak sınıflandırılmaktadır. Sınıf III’de’ iyi durumda su gerektiren fabrikalar dışında, arıtmadan sonra su ürünleri yetiştiriciliği için kullanılabilir sular bulunmaktadır. Sanayide kullanıma elverişli durumda sular çoğunlukla bu sınıfa girmektedir. Sınıf IV’de ise Sınıf III için verilen kalite parametrelerinden daha düşük kalitede olan ve üst kalite sınıfına ancak iyileştirilerek ulaşabilecek yerüstü suları yer almaktadır. Bu gruptaki sular çok kirlenmiş sular olarak da tanımlanmaktadır [16].

2.5. Fizikokimyasal Su Kalitesi Parametreleri

Yerüstü Su Kalitesi Yönetimi Yönetmeliği’nde, su kalitesinin izlenmesi ve değerlendirilmesinde, fizikokimyasal parametreler nehir ve göl su kütleleri için ayrı ayrı olarak belirlenmiştir. Bunun sebebi nehirdeki suyun daha akışkan halde olması, göldeki suyun ise daha durgun yapıda olmasıdır. Bu durum fizikokimyasal olarak göl ve nehir suları için bazı noktalarda ayrı parametreler üzerinden değerlendirilmesi yapılması ihtiyacını doğurmaktadır. Göl ve nehirler için ölçülen fizikokimyasal parametrelerin tümü Tablo 2’de gösterilmektedir.

Tablo 2. Nehir ve Göl Su Kütleleri için Fizikokimyasal Parametreler

Parametre	İzleme Sıklığı
Sıcaklık	4 kez/yıl
Elektriksel İletkenlik	4 kez/yıl
Çözünmüş Oksijen	4 kez/yıl
pH	4 kez/yıl
Nütrient Durumu (Toplam Fosfor, Çözünebilir Reaktif P, Toplam Azot, Nitrat+Nitrit, Amonyum)	4 kez/yıl
Saydamlık (Seki Disk Derinliği, AKM, Bulanıklık)	4 kez/yıl

Suyun fiziksel hareketi (durgun ya da hareketli yapıda olması) suyun fizikokimyasal özelliklerini etkilemektedir. Özellikle göl su kütlelerinde, nehir su kütlelerine ek olarak saydamlık kriterleri öne çıkmaktadır. Saydamlık Seki Disk Derinliği, Bulanıklık ve suyun rengine bağlı olarak değerlendirilmektedir. Bu parametrelerin suya olan etkisi ve önemlerini anlamak için bu parametrelerden kısaca bahsetmek gerekmektedir.

Sıcaklık suyun fizikokimyasal durumunu en çok etkileyen parametredir. Su sıcaklığı havadaki sıcaklığa göre değişim göstermektedir [17]. Sıcaklıktaki değişime göre sudaki bir çok parametrenin yoğunluğu ve fiziksel hali de değişmektedir. Özellikle durgun su kütleleri olan göllerde sıcaklık, suyun derinliğine göre değişmektedir. Sıcaklık farklarından dolayı göllerde tabakalaşma ortaya çıkmaktadır. Sıcaklıkla birlikte suyun dinamiği de etkilenmektedir ve difüzyon hızı, yoğunluk ile viskozite gibi özellikler de değişime uğramaktadır. Bu değişiklikler sonucunda sudaki kimyasal reaksiyonların yanı sıra bunlara bağlı olarak sudaki biyolojik özellikler de etkilenmektedir [17]. Biyolojik açıdan bakıldığında, kimyasal reaksiyonlara bağlı olarak, suda yaşayan bakteri ve fitoplankton gibi mikroorganizmaların metabolizmaları ve solunum hızları sıcaklığa bağlı olarak değişmektedir. Buna bağlı olarak sudaki oksijen yoğunluğu da etkilenmektedir.

pH, açılım olarak “Power of Hydrogen” (Hidrojenin Gücü) anlamına gelmektedir. Tanım olarak pH değeri, bir çözeltinin asitlik veya bazik niteliğe sahip olduğunu gösteren bir değerdir. pH değeri 0 ile 14 arasında değişmektedir. Suda bulunan H^+ ve OH^- iyonlarının yoğunluğu, suyun pH derecesini belirlemektedir. Suyun pH’ı, 7’nin altında ise asidik, 7’nin üstünde ise su bazik özellik göstermektedir. Doğal suların pH aralığı 4 ile 9 değerleri arasında bulunmaktadır. Saf suyun pH’ı 7 olarak kabul edilmektedir. Saf suda H^+ ve OH^- iyonları

dengede bulunmaktadır. pH değeri 7 olan saf su asidik ya da bazik özellik göstermez ve nötr olarak kabul edilmektedir.

pH Çevre Mühendisliği uygulamalarında oldukça yoğun şekilde, özellikle arıtma sistemlerinin tasarımında, kimyasal koagülasyon, dezenfeksiyon, sertlik giderme ve korozyon kontrolü gibi konularda kullanılmakta ve oldukça önem arz etmektedir. Suyun pH'a bağlı olarak korozif veya çökelme eğilimi arıtma sistemlerinin tasarımını etkilemektedir. Yine sudaki canlı yaşamını için pH değerinin 6.5-7.5 arasında olması gereklidir [11].

Elektriksel iletkenlik (EC) değeri, suyun elektrik akımını iletebilmesini ifade etmektedir. İletkenlik birimi S/cm'dir. Suyun iletkenlik değeri, bir nevi sudaki iyon sayısı hakkında bilgi vermektedir. Doğal sularda iletkenlik genellikle çözünmüş katı maddelerden kaynaklanmaktadır. Sudaki toplam çözünmüş katılar (TDS), iletkenlik değerinin 0,55–0,70 arasındaki bir faktörle çarpılmasıyla yaklaşık olarak elde edilmektedir [18]. Böylece sudaki iyonların yoğunluğu bulunabilmektedir. Suyun iletkenliği, TDS miktarıyla doğru orantılıdır. TDS, mineralizasyon derecesini belirlemede önemli bir parametredir. Sudaki mineraller, canlılar üzerinde fiziksel olarak ve maddeler üzerinde korozif özellik göstermesi bakımından ciddi bir etkiye sahiptir. Suyun EC değerinin düşük olması beklenmektedir [18].

Sertlik, su içinde çözülmüş +2 değerlikli iyonlardan (Kalsiyum, Demir, Magnezyum vb.) etkilenmektedir [19]. Özellikle kalsiyum ve magnezyuma, doğal sularda diğer elementlerden daha fazla rastlanmasından dolayı, sertlik, bu elementlerin sudaki iyonlarının yoğunluklarının toplamı olarak kabul edilmektedir. Diğer iyonlar genellikle bileşik ve molekül biçiminde oldukları için sertliğe fazla etkileri olmaz. Suyun sert olması, su tesisatında (isale hattı, depo vb.), evsel ve endüstriyel makinelerde kalıntılara ve kireçlenmeye yol açmaktadır. Özellikle tesisatlarda kullanılan suyun yumuşak olması tercih edilmektedir.

Bulanıklık, suda ışığın dağılma ve absorbe olmasına neden olan bir niteliktir. Saf su oldukça şeffaftır. Şeffaf olmayan ve berraklığı azalmış sulara bulanık su denilmektedir. Bulanıklık daha çok görsel açıdan değerlendirilse de, fizikokimyasal olarak suda istenmeyen maddelerin varlığına işaret etmektedir. Sudaki çeşitli inorganik ve organik maddeler bulanıklığa sebep olmaktadır. Çoğunlukla nehir sularında, toprak ya da evsel-endüstriyel atıklar bulanıklığa sebep olmaktadır.

Doğal su hiçbir zaman saf su kadar berrak değildir; çünkü içinde çözünmüş maddeler, mikroskobik canlılar, askıda maddeler vb. birçok parçacık bulunur. Az bulanık sular canlılar için gerekli maddeleri daha fazla taşıdığından, yaşama ortamı olarak daha elverişlidir. Kirlenme sırasında organik maddeler kadar inorganik maddeler de suya karışmaktadır. Bu maddelerin bulunması suda bakteri oluşumunu desteklemektedir. Örneğin; azot, fosfor gibi maddeleri kullanan algler büyüyerek, suda bulanıklığa sebep olmaktadır [20]. Bakteri oluşumu da suda bulanıklığı artırmaktadır. Sonuç olarak sudaki bulanıklık, canlı faaliyetlerinin olması ile veya muhtemel bir kirli su karışması ile ilişkilendirilir ve sağlık tehlikesi mevcut olabilir. Bu sebeple içme sularında bulanıklık istenmemektedir [21].

Suyun rengi, askıda katı madde (AKM) veya çözünmüş katılardan kaynaklanmaktadır. Askıda katı maddeler sebebi ile meydana gelen renge “zahiri (gerçek olmayan) renk” adı verilmektedir. Buna karşılık bitkisel veya organik çözünmüş maddeler nedeniyle ortaya çıkan renk “gerçek renk” olarak isimlendirilmektedir [22]. Çözünmüş katılardan kaynaklanan renk, kimyasal bir kirlilik olarak değerlendirilmelidir. Bu durum askıda katı maddelerden kaynaklanan renge göre daha kalıcı bir kirlilik oluşturmaktadır. Renk yoğunluğu genellikle pH’ın artması ile artmaktadır. Genelde kullanılan suyun şeffaf renkte olması istenmektedir.

2.6. Çözünmüş Oksijen

Sudaki oksijen, sucul ortamlarda, ekosistemin parçası olan bitki, hayvan ve mikroskobik canlılar için oldukça önemlidir. Özellikle suyun ekolojik stabilitesinde çok önemli bir yere sahiptir. Çözünmüş Oksijen değeri, diğer su kalitesi parametrelerini de etkilemektedir [23]. Sudaki yaşamın sürdürülebilirliği, alg aktivitesi ve organik madde miktarı da aynı zamanda çözünmüş oksijen konsantrasyonuna bağlıdır [24]. Suda tespit edilen çözünmüş oksijen konsantrasyonu bir nevi suyun kirlenme derecesini de ifade etmektedir. Yine sudaki organik madde konsantrasyonunu ve suyun kendi kendini ne derece temizleyebileceğini de ortaya koymaktadır. Sudaki çözünmüş oksijen yüzdesi, sıcaklığa göre ters orantılı ve atmosfer basıncına göre doğru orantılı olarak değişmektedir. Yüksek basınçta, yüksek miktarda oksijen çözünmektedir. Ancak yüksek sıcaklıkta düşük miktarda oksijen çözünmektedir. Bu sebeple, bu parametreler birbirleriyle yakından ilişkilidir. Sudaki çözünmüş oksijen miktarının yüksek olması tercih edilmektedir [11].

3. YAPAY SİNİR AĞLARI VE ZAMAN SERİLERİ

3.1. Yapay Sinir Ağları

Yapay Zeka, insan beyninin çalışma süreçlerini taklit etmeye ve geliştirmeye çalışmaktır. İnsan beyni geçmiş tecrübelerinden ve eğitiminden yola çıkarak, yaşam boyunca ortaya çıkan problemleri çözüme eğilimindedir. Daha önceki olaylardan ve koşullardan elde edilen tecrübeler, karşılaşılan yeni sorunların çözümlerinde kullanılır. Buradaki süreçte insan beyninin bilişsel bir yeteneği olan öğrenme olgusu devreye girmektedir. İnsan beyni öğrenerek, oluşturduğu çözüm yöntemleriyle, karşılaşılan durum karşısında eylemler ortaya koymaktadır. Yapay zeka çalışmaları çerçevesinde, insana özgü bilişsel yönden idrak etme, düşünme, çıkarsama ve karar verme gibi yetenekler, yazılım ortamında gerçekleştirilmek istenmektedir.

Klasik programlamada ve yazılım ortamında, belirli algoritmalar vasıtasıyla seri şekilde işlem yapılabilmektedir. Bilgisayarlar bu kural tabanlı algoritmalar aracılığıyla insan beyninin çok uzun zamanda gerçekleştiremeyeceği işlemleri kısa zamanda gerçekleştirebilir. Bilgisayarlar kompleks sayısal işlemleri, insan beyninin aksine, çok kısa süre içerisinde hızlı bir şekilde çözümlenebilmelerine rağmen, tecrübeyle ve önceki durumlardan elde edilen bilgileri uygulama konusunda insan zekasına göre oldukça yetersizdir [25]. Bunu sağlamak için, makine öğrenmesi kavramı ortaya çıkmıştır. Makine öğrenmesi, insan beynine özgü (has) bu tarz karmaşık görevleri gerçekleştirebilmek için, makinelerin davranışlarını geliştirmeyi hedeflemektedir.


Makine öğrenmesi halihazırda, uzay bilimlerinden, otomotiv sektörüne, bankacılıktan savunma sanayiine, sağlıktan güvenlik sektörüne kadar onlarca alanda kullanılmaktadır. Bu uygulamalar kapsamında insan beyninin öğrenme yeteneğinden yola çıkarak, çeşitli makine öğrenmesi teknikleri geliştirilmiştir [26]. Yapay Sinir Ağları (YSA) da bunlardan biridir.

YSA, yine insan beyninin çalışma mantığını esas alınarak, insan beynindeki öğrenme ve eğitim aşamalarının matematik ekseninde modellenmesi amacıyla ortaya çıkmıştır. YSA bir çok hücreden meydana gelmektedir. YSA hücreleri eş zamanlı olarak karmaşık işlemleri gerçekleştirmektedir.

YSA'larda kullanılacak veriler eğitim, test ve kontrol olarak gruplara ayrılmaktadır ve bu veriler ile YSA'lar eğitilmektedir. YSA'ların eğitimleri esnasında, problemin genel

çerçevesini çıkarması ve daha sonra yeni benzer problemlerde başka veriler kullanarak anlamlı sonuçlar çıkarabilmesi beklenmektedir. YSA'lar, öğrenirken, kendilerine verilen örneklerden çıkarımda bulunurlar, daha sonra yeni örnekler hakkında bu çıkarımlara dayanarak sonuçlar üretirler.

Yapay sinir ağlarını anlayabilmek için, benzetim mantığını ilk başta anlamak önemlidir. İnsan beyninin çalışma mantığını temelde ortaya koymak gerekmektedir. İnsan beyni, sinir hücrelerinden meydana gelmektedir. Beyindeki sinir hücreleri, dendrit, çekirdek, akson ve beyindeki diğer sinir hücrelerine bağlantılardan oluşmaktadır. Örnek bir sinir hücresinin şematik gösterimi şekilde görülmektedir.



Şekil 1. Biyolojik Sinir Hücresi [27]

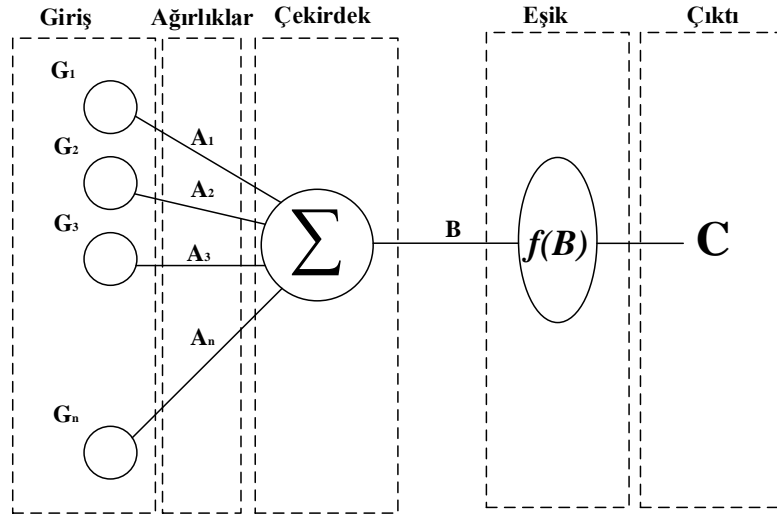
Burada dendrit diğer sinir hücrelerinden alınan sinyalleri, sinir hücresinin çekirdeğine iletir. Ancak sinyaller hücre çekirdeğine doğru iletilirken, dendritlerin her biri çekirdekte aynı ağırlıkta ve önemde etkide bulunmamaktadır. Burada kimi dendritler hücre çekirdeğine doğru sinyali iletirken, daha yüksek etki gösterirken, bazıları ise daha zayıf etki göstermektedir. Böylece çekirdek nazarında her bir dendritin etkisi farklı olmaktadır.

Dendritlerden çekirdeğe iletilen ve burada toplanan sinyaller, diğer hücelere gönderilmek için akson yapısına iletilir. Akson, çekirdekten gelen sinyali algıladıktan sonra, uçlarında bulunan sinaps adı verilen yapıları kullanarak diğer sinir hücrelerine doğru sinyali iletir. Ancak burada, sinyal iletilmeden önce, akson ucundaki sinapslar bilgiyi aktarmadan, ön işleminden geçirmektedir. Buradaki işlem sırasında aksona gelen sinyal, bir eşığe göre

değerlendirilmektedir. Aksondaki toplam sinyal indirgenerek diğer sinir hücrelerine aktarılmaktadır. Bu fikir temelinde hareket edilirse, “öğrenme” işlemi sinapslarda gerçekleşmektedir. Bu fikir doğrultusunda oluşturulan hipotezler, yapay sinir ağlarının konsept olarak kurgulanmasında teori haline dönüşmüştür.

3.1.1 Yapay Sinir Hücresi

İnsan beyni tecrübe kazandıkça, sinir hücreleri arasındaki bağlantılar zamanla değişmektedir. Bu bağlantılar kuvvetlenir, zayıflar ya da yeni bağlantılar kurulur. Bu sayede insan beyninde öğrenme gerçekleşir. YSA’da da bu süreç, tıpkı insan beynine benzer olarak, tecrübeye dayalı olarak gerçekleşmektedir. Buradaki süreçte de öğrenme, hücreler arasındaki bağlantıların kuvvetlenmesi veya zayıflamasıyla sağlanmaktadır. Hücreler arası bağlantı ağırlıkları, tekrar tekrar değiştirilerek, bağlantılar zayıflatılır ya da kuvvetlendirilir. Şekil 2’de örnek bir yapay sinir hücresi verilmektedir. Biyolojik sinir hücresinden yola çıkılarak, dendritler giriş olarak ele alınmaktadır.



Şekil 2. Yapay Sinir Hücresi Yapısı

Burada her bir G_n , hücreye girişi (dendriti) temsil etmektedir. Her bir girişin, kendisine has olmak üzere bir ağırlığı vardır (A_n). Her G girişi, kendi ağırlığı ile çarpılarak, çekirdeğe doğru yönlendirilir ve bu girişlerin çıktıları çekirdekte toplanır. Çekirdekte toplanan sinyal burada B ile ifade edilmektedir.

Çekirdekte toplanan B sinyali, daha sonra YSA’nın sinapsına doğru gönderilir. Sinapstaki eşikten sonra elde edilen çıkış sinyali “C” olarak ifade edilmektedir. “C” çıkış sinyali, YSA

hücresinin çıkış değeridir. YSA'da her bir girdi (G_n) ve çıktıya (C) göre, girişlerin ağırlıkları (A_n) değiştirilir. Bu ağırlıkların değiştirilmesiyle hücrenin öğrenmesi gerçekleştirilir. Öğrenmenin tamamlanmasına kadar " G_n " girdileri, " A_n " ağırlıkları ayarlanana kadar YSA'ya gönderilmektedir ve her bir iterasyonda ağırlıklar değiştirilerek, ağırlıkların stabilizasyonu sağlanmaktadır.

Bundan sonra hücrenin öğrenmesini tamamladığı varsayılmaktadır. Stabilizasyondan sonra çekirdekte gerçekleşen çıkış değerinin hesaplanmasını fonksiyonel olarak gösteren matematiksel ifade şu şekildedir:

$$C = f\left(\sum_{1}^n (G_n * A_n)\right) \quad (1)$$


Burada belirtilen aktivasyon fonksiyonu (transfer fonksiyonu olarak da kabul edilmektedir), herhangi bir fonksiyon alınabilir. Çekirdekte oluşturulan " B " değeri, aktivasyon fonksiyonunda " $f(B)$ " işlendikten sonra C (çıkış) değeri çıktısını üretir. Bu " C " değeri de hücrenin çıkış değeridir.

Aktivasyon fonksiyonları, YSA'ların eğitiminde ciddi öneme sahiptir. Özellikle yayımlı öğrenmelerde, bu fonksiyonlarının türevi alınabilen sürekli fonksiyonlardan olması tercih edilmektedir. Bazı aktivasyon fonksiyonları, negatif ve pozitif aralıklarda çalışırken, bazıları ise sadece belli aralıklarda pozitif değerler üretmektedir.

Yapay sinir ağı modellerinde genelde kullanılan fonksiyonlardan kısaca bahsetmek gerekirse, ilk olarak doğrusal (Lineer) aktivasyon fonksiyonu yapısı itibariyle aldığı girdi değerini çıktı olarak aynen üretmektedir [28]. Bu özelliğinden dolayı da, aslında gerçek bir aktivasyon fonksiyonu olarak çalışmadığı düşünülebilir. Bu fonksiyonun matematiksel gösterimi şu şekilde ifade edilmektedir.

$$f(x) = x \quad (2)$$

Doğrusal aktivasyon fonksiyonu, sürekli bir fonksiyon olmasını yanı sıra, ismini de grafikte görüleceği üzere giriş ve çıkış değerlerine bağlı olarak eksenlerle 45 derecelik açı yapacak şekilde düzgün bir doğru çizmesinden almaktadır.




Şekil 3. Doğrusal (Linear) Aktivasyon Fonksiyonu

Doğrusal aktivasyon fonksiyonunun türevi sabit değer olarak 1'dir. Bu fonksiyon sürekli olduğu için türevlenebilir. Türevlenebilen bir fonksiyon olması dolayısıyla da yayımlı öğrenmede kullanılabilir.

Yine sinüs (SIN) aktivasyon fonksiyonu, -1 ve 1 değerleri arasında, negatif ve pozitif değerler üretmektedir [27]. Hiperbolik tanjant gibi bu fonksiyon da, trigonometrik bir fonksiyondur. Bu fonksiyonun matematiksel gösterimi aşağıdaki şekildedir:

$$f(x) = \sin(x) \quad (3)$$

Şekil 4'de bu fonksiyonun grafiği gösterilmektedir. Fonksiyon isminden de anlaşılacağı üzere, sinüs dalgası şeklinde periyodik bir çıktı oluşturmaktadır.




Şekil 4. Sinüs Fonksiyonu Grafiği

Adım aktivasyon fonksiyonu ise YSA’larda uç değerler üzerinde çalışmaktadır. Yani fonksiyonun çıkışı iki farklı değerden biridir. Örneğin “doğru” için “1”, yanlış için “-1” üretilmektedir. Fonksiyon çıkışında bu iki ayrık (kesikli) değerden birisi üretilir [27]. Bu fonksiyonun matematiksel örnek bir gösterimi şu şekilde ifade edilebilir:

$$f(x) = \begin{cases} 1, & x \geq 0 \\ -1, & x < 0 \end{cases} \quad (4)$$

Burada görüldüğü üzere fonksiyonun çıkış değeri, girdinin 0’dan büyük veya küçük olması durumunda, -1 ya da 1 üretecek şekilde kısıtlanmıştır. Şekil 5’de fonksiyonun grafiği görülmektedir.




Şekil 5. Adım Aktivasyon Fonksiyonu

Adım fonksiyonu süreksiz bir fonksiyon olduğu için, türevinin alınamamasından dolayı, yayılımlı öğrenmede kullanılamaz. Yine hiperbolik tanjant aktivasyon fonksiyonu ($\tanh(x)$), genelde YSA modellerinde sıklıkla kullanılmaktadır [27]. Bunun nedeni fonksiyonun negatif ve pozitif değerler üretebilmesidir. Bu fonksiyon matematiksel olarak aşağıdaki şekilde ifade edilebilmektedir:

$$f(x) = \frac{e^{2x-1}}{e^{2x+1}} \quad (5)$$

Fonksiyon 1 ve -1 değerleri arasında, negatif değerler için negatif, pozitif değerler için ise pozitif çıktılar üretmektedir [29]. Şekil 6'da fonksiyonun grafiği görülmektedir.




Şekil 6. Hiperbolik Tanjant Aktivasyon Fonksiyonu Grafiği

Logaritmik aktivasyon fonksiyonu ise hiperbolik tanjant aktivasyon fonksiyonuna benzer şekilde çalışmaktadır. Fonksiyonun matematiksel ifadesi şu şekildedir.

$$f(x) = \begin{cases} \log(1 - x), & x < 0 \\ \log(x + 1), & x \geq 0 \end{cases} \quad (6)$$

Fonksiyon yine Hiperbolik Tanjant Fonksiyonuna benzer şekilde 1 ve -1 değerleri arasında, negatif değerler için negatif, pozitif değerler için pozitif çıktılar üretmektedir . Burada fark hiperbolik tanjant fonksiyonuna göre, logaritmik aktivasyon fonksiyonu daha normalize edilmiş değerler üretmektedir. Şekil 7’de fonksiyonun grafiği görülmektedir.




Şekil 7. Logaritmik Aktivasyon Fonksiyonu

Logaritmik fonksiyon, sürekli ve türevlenebilen bir fonksiyon olması sebebiyle, geri yayımlı öğrenmede kullanılabilir bir fonksiyondur.

Yine YSA’larda sıklıkla kullanılan bir fonksiyon da Logaritmik Sigmoid (ya da sadece Sigmoid) aktivasyon fonksiyonudur [30]. Bu fonksiyon pozitif değerler üreten sürekli bir fonksiyondur. Bu fonksiyonda girdiye karşılık olarak, eğim değerine bağlı ve süreklilik gösteren bir çıktı oluşmaktadır.

$$sig_a(x) = \frac{1}{1 + e^{-ax}} \quad (7)$$

Burada “a” değeri fonksiyonun eğimini belirtmektedir. Artan ağırlık değerleri, nöronun, sigmoid fonksiyonun eğiminin(türevinin) çok küçük değerli bölgelerinde işlem yapmasına sebep olmaktadır. Geri yayımlanan hata terimi türevle orantılı olduğundan, düşük eğimde yeterli eğitim gerçekleşmez. Eğimin ayarlanması, eğitim süresini ve başarısını doğrudan etkiler. Şekil 8’de eğim değeri 0.5 olarak belirlenen bir fonksiyon için örnek grafik görülmektedir.



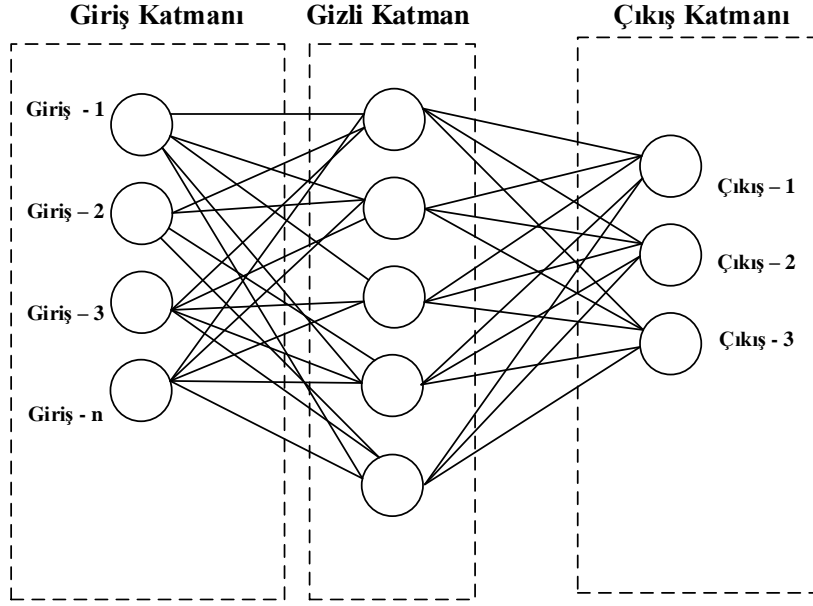
Şekil 8. Logaritmik Sigmoid Aktivasyon Fonksiyonu

Sigmoid fonksiyonu türevlenebilen bir fonksiyon olması nedeniyle yayımlı öğrenmede kullanılabilir. Yine grafikten de anlaşılacağı üzere fonksiyon belirli bir değerden sonra, her girdiye göre pozitif değer üretmektedir.

3.1.2 Yapay Sinir Ağı Yapısı

YSA, yapay sinir hücrelerinin birbirlerine bağlanmalarıyla birlikte meydana gelmektedir [25,31]. Bu hücreler birbirlerine bağlanarak, YSA'yı meydana getirirler. YSA'lar, geleneksel programlama mantığının aksine, daha farklı şekilde işlem gerçekleştirmektedir. Algoritmaya dayalı olarak geleneksel işlem mantığında, sadece tek bir merkezi işlem birimi (CPU) kendisine verilen algoritma dizisini sırayla ve tek tek gerçekleştirecek şekilde davranış gösterir. YSA'da ise çok fazla sayıda işlem birimi birbirleriyle uyumlu ve eşzamanlı olacak şekilde hareket ve davranış sergilemektedir.

Şekil 9'da temsili olarak verilen çok katmanlı bir YSA yapısı görülmektedir. YSA'lar genel olarak sırasıyla giriş katmanı, gizli katman (lar) ve çıkış katmanından oluşur [25]. Burada her bir YSA katmanı yapay sinir hücrelerinden oluşmaktadır. Katmanlardaki hücreler arasında oldukça fazla sayıda bağlantı kurulur. Aynı katmandaki hücreler arasında bağlantı kurulmamaktadır.



Şekil 9. Çok Katmanlı Yapay Sinir Ağı

Burada giriş katmanındaki sinir hücreleri dışarıdan veri alma görevini yerine getirmektedir. YSA'ya dışarıdan verilen girdiler ilk olarak giriş katmanına gönderilir. Giriş katmanına gelen bilgiler, daha sonra bu katmandan gizli katmana doğru iletilir. Bazı YSA'larda gizli katman kullanılmayabilir, bazılarında da birden fazla ara katman bulunabilir. Gizli katman bulunmaması durumunda, doğrudan bilgiler çıkış katmanına doğru da iletilebilir. Gizli katmanlardaki sinir hücrelerinin sayısı, ağdaki giriş ve çıkış katmanı ve bu katmanlardaki hücre sayısına bağlı değildir.

Çok sayıda gizli katman bulunan ağlarda katmanların kendi aralarındaki sinir hücresi sayıları da farklı olabilmektedir, bu durum oluşturulan YSA modeline göre değişmektedir. Gizli katmanların ve bu katmanlardaki yapay sinir hücrelerinin sayılarının fazla olması hesaplamaların karmaşıklığını ve hesaplama süresini arttırmaktadır.

Bunun yanı sıra bu tür modeller yapay sinir ağının daha karmaşık problemlerin çözümünde de kullanılabilmesini sağlamaktadır. Giriş ve çıkış katmanlarındaki nöron sayıları ele alınan probleme göre belirlenebilmektedir, fakat gizli katmandaki (veya katmanlardaki) nöron sayısının, probleme özel olarak veya genel bir çözüm yöntemi olarak, doğru sayısını veren herhangi bir bilimsel yöntem henüz geliştirilememiştir [32]. Burada gizli katman ve bu katmanlardaki nöron sayısı deneme yanılma yöntemiyle, optimize çözümü verecek şekilde ayarlanmaya çalışılmaktadır.


YSA'daki işlem yeteneği ve süreçleri geleneksel programlamanın aksine farklılıklar göstermektedir. Geleneksel programlamada bilgiler dışarıda, birincil ya da ikincil hafızada tutulur. YSA'da ise bilgiler ağı kendi içerisinde saklanır. YSA hücrelerinin bağlantıları ve ağırlıkları burada ağı bilgisini göstermektedir.

YSA'da her bir yapay sinir hücresinin ağırlık derecesi ve bağlantıları, ağı genelinde anlamlıdır. Bu bağlantılar ve ağırlıklar tek başına anlam ifade etmemektedir. Bununla birlikte YSA hücrelerinin bazılarını çalışmaması veya görevini yerine getirmemesi anlamlı bilginin kaybolmasına sebep olmamaktadır.

Yine geleneksel programlamada hata toleransı YSA'ya göre çok daha düşüktür. YSA'lar hataya daha toleranslıdır. YSA'lar eğitiminden sonra, verilerin eksik olması durumunda bile, verinin önem derecesine göre yaklaşık olarak değerler oluşturabilir. Böylelikle daha esnek bir sistem elde etmek mümkündür. Ağı örnekler üzerindeki hatasının belirli bir değerin altına indirilmesi eğitimin tamamlandığı anlamına gelmektedir.

YSA'lar yapılarına göre farklılık arz etmektedir. YSA'lar tek katmanlı ileri beslemeli, çok katmanlı ileri beslemeli ve döngülü yapay sinir ağları olmak üzere üçe ayrılmaktadır.

Tek katmanlı ileri beslemeli yapay sinir ağının, bir adet giriş katmanı ve bir adet çıkış katmanı bulunmaktadır. Bu YSA tipinde, verilen girdi giriş katmanından çıkış katmanına doğru ilerler. Bu durum ağı "ileri beslemeli ağı" olarak nitelendirilmesini sağlar.



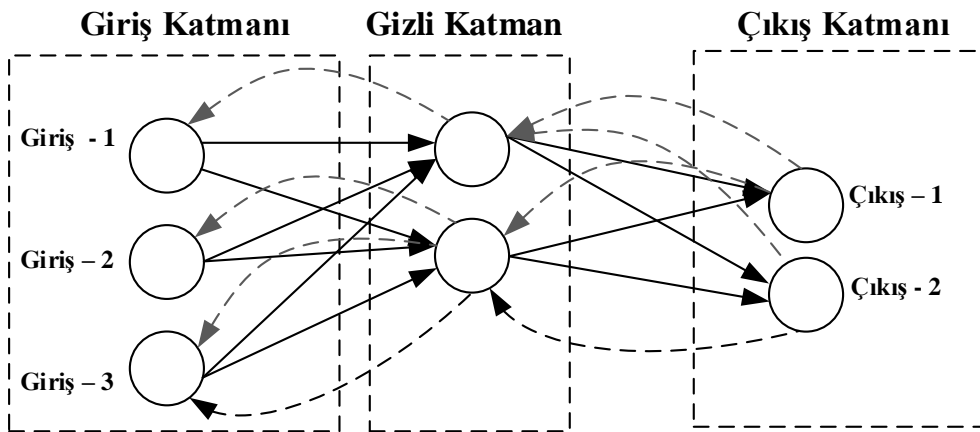
Şekil 10. Tek Katmanlı İleri Beslemeli YSA Yapısı

Ancak bu tip sadece tek katmanlı, giriş ve çıkış katmanı olan ağlar, karmaşık hesaplamalar konusunda yetersiz kalmaktadır. Ağın karmaşık problemlerde çözüm üretebilmesi için ağ yapısında en az bir gizli katman bulunması gerekmektedir [25] .

Çok Katmanlı İleri Beslemeli YSA'lar ise, bir veya daha fazla gizli katman bulundurmaktadır. Burada gizli katmanların YSA'da kullanılmasıyla, giriş ve çıkış katmanları arasında gerekli bir takım işlemler yapılmaktadır [33]. Giriş katmanı geniş olduğu zaman gizli katmanlar sayesinde yüksek dereceli istatistiksel veri elde edilebilmektedir .

Çok katmanlı yapılarda, N adet katmana sahip bir YSA'da, N'nci katmanın çıkış sinyalleri N+1'nci katmana iletilerek bu katmanda giriş sinyalleri olarak kullanılmaktadır. Eğer her katmanda bulunan nöronlar bir sonraki katmanın tüm nöronlarına bağlı ise bu tip ağa "tam bağlantılı ağ" adı verilmektedir. Eğer bu bağlantılardan bazıları gerçekleştirilmemişse, kısmi bağlantılı ağ adı verilir.

Ancak ileri beslemeli yapay sinir ağlarında geriye doğru olarak bir yönelme yoktur. Bu tip ağlarda, veriler ilk önce giriş katmanına gönderilmektedir. Ardından girdi katmanından, gizli katmanlara ve buradan da çıktı katmanlarına doğru iletilmektedir. Bununla birlikte, geri beslemeli sinir ağlarında, önceki katmandaki hücreler sonraki katmanlardaki hücreler tarafından da girdi olarak alırlar. Bu ağ tipinde sadece ileriye doğru olarak veri akışı olmaz, geriye de doğru olarak da veri akışı gerçekleşir [34].



Şekil 11. Geri Yayılımlı YSA

YSA'da probleme uygun yapının belirlenmesinde ortaya konulan belirli bir pratik henüz yoktur. YSA'larda hücre sayısı, katman sayısı, öğrenme katsayısı vb. değerlerin seçiminde ve belirlenmesinde kesinleşmiş bir yöntem veya belirlenmiş bir metodoloji yoktur. Bu değerler, probleme özgü olarak, deneme ve yanılmalar gerçekleştirilerek belirlenmektedir [35,36].

3.1.3 Yapay Sinir Ağlarında Öğrenme

Bir yapay sinir ağı girdi setindeki değişiklikleri değerlendirerek öğrenir ve buna bir çıktı üretir. Yapay sinir ağlarının öğrenme sürecinde dış ortamdan girişler alındıktan sonra, aktivasyon fonksiyonuna gönderilir. Daha sonra buradan bir çıkış oluşturulmaktadır. Öğrenme boyunca YSA'nın ağırlıkları sürekli olarak değiştirilmektedir. Ağırlıklar her bir iterasyonda tekrar düzenlenerek ideal çıktıya ulaşılmaya çalışılır. YSA gerçek sonuçlarla kendi çıkışındaki sonuçlar karşılaştırarak iç yapısındaki ağırlık matrisini tekrar tekrar düzenlenmektedir. Bu süreç boyunca ağırlıkların sürekli yenilenerek istenilen sonuca ulaşılan kadar geçen zamana “öğrenme” denilmektedir.

Yapay sinir ağlarında öğrenmenin birden fazla yöntemi vardır. YSA'da öğrenme genel olarak, danışmanlı, danışmansız ve takviyeli öğrenme olarak üçe ayrılmaktadır

Danışmanlı öğrenme'de giriş değerleri ağı iletilirken, çıkış değerleri de verilir. YSA, verilen girdilere göre istenilen çıkış değerlerini elde edebilmek için ağırlıkları tekrar tekrar günceller. Ağdan elde edilen çıktılar ile beklenen çıktılar arasındaki fark ve hata hesaplandıktan sonra YSA'daki ağırlıklar bu fark ve hata oranına göre tekrar yapılandırılır. Bu öğrenme modelinde temel amaç, ağı beklenen çıktıları da göndererek ağı girdilerin ağırlıklarını, çıktıları göre ayarlamasını sağlamaktır [37]. Belirli bir veri setiyle ağ eğitildikten sonra, oluşturulan YSA modeli yeni bir veri seti ile test edilir. Test sonuçlarında, doğru sonuçların oranı YSA'nın performansını ortaya koyar.

Aktivasyon fonksiyonundan çıkan değer, daha sonra gerçek çıkışla (ideal) karşılaştırılarak aradaki fark ve hata bulunur. Bu kapsamda YSA'da çeşitli öğrenme algoritmalarıyla bu hata azaltılıp gerçek (ideal) çıkış yakalanmaya çalışılır.

Danışmansız öğrenmede ise YSA'ya sadece girişler verilmektedir, beklenen çıktı değerleri ağı gönderilmez. Çıktı bilgisinden habersiz olarak, girişte verilen bilgilere göre ağ örneklerin her birini kendi içinde sınıflandırarak kendi kendine kurallar oluşturur [37]. Bağlantı ağırlıkları aynı özellikte olan kümeleri ayrılabilir şekilde düzenlenerek öğrenme işlemi tamamlanır. Kümeleme (clustering) yöntemleri genel olarak gözetimsiz öğrenme kapsamına girmektedir. Burada amaç verilerin ortak değerler etrafında kümelenebilmelerini sağlamaktır [38].

Yapay sinir ağı öğrendikten sonra daha önce verilmeyen girişler verilip, sinir ağı çıkışıyla gerçek çıkış yaklaşımı incelenir. Eğer yeni verilen örneklere de doğru yaklaşıyorsa YSA öğrenmiş olarak kabul edilmektedir. Burada bir başka deyişle özetlenecek olursa, YSA öğrenirken, girdi ve çıkış değerlerinin birbirleriyle ilişkilendirilmesi yapan iç çalışma mantığını ve kural dizisini kendi kendine oluşturarak sonuç elde etmeyi amaçlamaktadır [37]. Deneme-yanılma ile ağ kendi kendine işi nasıl yapması gerektiğini öğretmektedir .

Pekiştirmeli öğrenme yönteminde, ağın her iterasyonu sonucunda elde ettiği sonucun iyi veya kötü olup olmadığına dair bir bilgi verilir. Ağ bu bilgilere göre kendini yeniden düzenler. Bu sayede ağ herhangi bir girdi dizisiyle öğrenerek sonuçlar çıkarır.

3.1.4 Yayılım ve Öğrenme Algoritmaları

YSA'da temelde iki görev gerçekleştirilmektedir. Bu görevler, önce öğrenme ve daha sonra hatırlamadır. YSA öğrenirken, ağırlık değerleri, giriş ve çıkış değerlerine göre ayarlanmaya çalışılmaktadır. Daha sonra hatırlama aşamasında YSA, girişlere karşılık olarak, uygun çıkışlar üretmeye çalışmaktadır. Burada öğrenme aşamasında ağırlık ayarlanırken, YSA iterasyonlar gerçekleştirilmektedir. Yayılım algoritmaları da, iterasyonlarla YSA'nın hata oranını belirli bir dereceye kadar düşürmeyi amaçlamaktadır [39].

Hata oranı, gerçek (ideal) değerle, ağdan çıktı olarak alınan değer arasındaki fark hesaplanarak ölçülmektedir. YSA öğrenirken, iterasyonlarda hata oranının azaltılmasına çalışılmaktadır. Eğitim verisi üzerinden tekrar tekrar geçilerek, yapay sinir hücreleri arası ağırlıklar değiştirilerek ideal durum yakalanmaktadır. Her bir iterasyonda, ileri ve geri olmak üzere, iki aşamalı bir işlem gerçekleşmektedir.

İlk olarak, YSA ağırlıkları tamamen rastgele değerler arasında atanmaktadır (Örneğin 0,1 ya da -1, +1 değerleri arasında). İleri geçişte (forward pass), girdi verisi doğrudan, YSA'ya gönderilmektedir. Katmanlardan çıkan değerler hesaplanarak, bu geçişte ayrı bir yerde saklanmaktadır. Bu, öğrenme algoritmalarının, bütün YSA katmanlarından oluşturulan çıktıları, tek tek görüntüleyebilmelerini sağlamaktadır. Daha sonra geri geçiş aşamasında, çıkış katmanından girdi katmanına doğru hareket edilmektedir. Geri geçiş, bütün nöronlardaki ideal değerler ve çıktı değerlerini karşılaştırmaktadır. Daha sonra hata eğimi (gradient of error) hesaplanmaktadır. Hata eğimini hesaplayabilmek için, YSA'nın çıktı değeri aktivasyon fonksiyonunun türevlenmiş haline girdi olarak verilmektedir. Çıkan değer hatayla çarpılmaktadır. Algoritmanın aktivasyon fonksiyonunun türevini kullanmasından dolayı,

yayımlı öğrenme sadece türevi alınabilen aktivasyon fonksiyonlarıyla çalışabilmektedir. Buradaki türevleme ağdaki bütün ağırlıklarda, hata eğimini hesaplamaya yardımcı olmaktadır. YSA'da girdiler 0 iken öğrenme gerçekleşemez. Bu durumda giriş katmanının ardından gelen katmana bağlayan ağırlık değerlerinin bir özelliği kalmamaktadır. Bu sorunu gidermek amacıyla çıkış katmanı hariç her katmana dendriti bulunmayan, değeri 1 olan ve sabit kalan birer nöron yerleştirilmektedir. Bu nöronlara "bias" adı verilmektedir. Bias hücreleri yerleştirilerek giriş nöronları haricindeki hiçbir nöronun toplam giriş sinyalinin 0 olmayacağı durumu garantilenmiş olmaktadır. YSA'nın istisna durumlarla karşı karşıya kaldığında da çözüm üretebilmesi beklenmektedir. Buna inductive bias (tümevarımsal koşul) adı verilmektedir [40].

Yayımlı yapay sinir ağları, temelde ileri besleme ve geri yayılım olmak üzere iki işlem adımı bulundurmaktadır. İleri besleme aşamasında, ağa veriler gönderilmektedir. Daha sonra ağdan elden edilen çıktılar, hata fonksiyonuna gönderilmektedir. Ardından bu hatalar geriye doğru iletilerek, nöronlar arası ağırlıklar güncellenir, buna geri yayılım adı verilmektedir.

Geri yayılım, gradyan inişi (gradient descent) hesaplanan iki parametre ile birlikte eşgüdüm içinde kullanılmaktadır [39]. İlk parametre öğrenme oranı (learning rate) değeridir. Öğrenme oranı ağırlık matrisi'ne gradyan iniş değerinin hangi oranda uygulanacağını belirlemektedir. Gradyen, öğrenme oranıyla çarpılarak ağırlık matrisine eklenmektedir. Bu daha düşük hata oranını sağlamak için yavaş şekilde optimize etmektedir.

Bunun yanı sıra çeşitli yayılım algoritmaları mevcuttur. Örneğin Hızlı Yayılım (Quick Propagation – QP), Newtonun Kök Bulma Yöntemi üzerine temellendirilmiştir [R: Burada referans olmalı]. Bir YSA'nın hata oranını minimize etmek için bu yöntem kullanılabilir. Genel olarak geri yayılıma göre hızlı yayılım daha iyi performans vermektedir. Hızlı yayılımda öğrenme hızı parametresi YSA'ya dışarıdan verilmektedir. Tipik olarak "2" öğrenme değeri QPROP'a gönderilmektedir.

Bununla birlikte Esnek Yayılım (RP – Resilient Propagation) algoritması kullanmaya başlamadan önce ek bir parametre (learning rate, momentum değeri, güncelleme sabitleri vb.) gerektirmez. Burada optimum öğrenme oranı değerini belirlerken karşılaşılan zorluklar olmadığı için, kullanması görece kolay bir algoritmadır. RPROP algoritması tek bir genel güncelleme değişkeni ya da delta değeri barındırmamaktadır. Birden fazla olarak her ağırlık matrisi için ayrı ayrı delta değerlerini içermektedir. İlk olarak delta değerlerine çok küçük bir değerler verilerek, daha sonra her bir eğitim iterasyonunda, ağırlıklar bu delta değerlerine

göre güncellenmektedir. Daha önce bahsedildiği üzere bu delta değerleri sabit olarak kalmaz. (Gradient) değeri delta değerlerinin güncellenmesi için magnitüde için kullanılır.

Levenberg-Marquardt Algoritması (LMA), YSA'lar için oldukça verimli bir öğrenme algoritmasıdır. Çoğu durumda, diğer algoritmalara göre daha iyi sonuç vermektedir. LMA melez bir algoritmadır. Temelinde Newton Yöntemi ve Gradient Descent (gradyan iniş) bulunmaktadır [41].

Levenberg-Marquardt (LM) algoritması yapay sinir ağlarının eğitiminde sağlamış olduğu hız ve kararlılık sebebiyle tercih edilmektedir. Levenberg-Marquardt algoritması günümüzde ağ eğitiminde etkili olarak kullanılmaktadır [42].

3.2. Zaman Serileri

Bir zaman serisi, zaman sırasına konmuş ölçüm değerlerini içeren bir dizidir. Zamanın belirli bazı noktalarında bir değişkenin gözlemlenmesi yoluyla oluşturulan seriye, “zaman serisi ” adı verilmektedir [43]. Zaman serileri belirli bir değişkenin, çeşitli zamanlarda aldığı değerleri göstermektedir. Matematiksel olarak bir x değişkeninin zaman içinde aldığı değerler, şu şekilde bir dizi oluşturur.

$$t(x_n) = \{x_1, x_2, x_3, \dots, x_n\} \quad (8)$$

Zaman serisindeki değişkenler zaman içerisinde çeşitli nedenlere bağlı olarak farklı değerler almaktadır. Başka bir ifadeyle, gözlemlerin belirli bir dönem için gün, hafta, ay, üç ay, yıl gibi birbirini izleyen eşit aralıklarla yapılması ile elde edilen seriler zaman serileri olarak adlandırılmaktadır. Bir arabanın her bir dakikada aldığı yol uzunlukları, ya da belirli bir bölgenin saatlik sıcaklık değerleri zaman serilerine örnek olarak verilebilir.

3.2.1 Sürekli ve Kesikli Zaman Serileri

Zaman serileri sürekli ve kesikli olmak üzere temelde ikiye ayrılmaktadır. Sürekli zaman serileri, daha çok gerçek dünyadan veya deneylerle elde edilen zaman serileridir, örneğin bir analog ses sinyali sürekli zaman serisi oluşturmaktadır. Kesikli zaman serileri ise bir değişkenin zaman içerisinde sonlu sayıda aldığı değerlerden oluşmaktadır. Örneğin bir dijital ses sinyali ya da günlük döviz kuru değerleri kesikli zaman serisi özelliği göstermektedir. Buradaki çalışmada da sonlu sayıda ölçüm verisinin belirli zamanlarda aldığı ayrık değerler

üzerinde çalışıldığı için, çalışma kesikli zaman serisi üzerinde gerçekleştirilmiş bulunmaktadır.

3.2.2 Deterministik ve Stokastik Zaman Serileri

Yine zaman serilerinde deterministik ve stokastik modeller ön plana çıkmaktadır. Deterministik modellerde zaman serisi, iki şekilde davranmaktadır. Zamanın bir fonksiyonu olarak davranan seriye ait fonksiyon aşağıdaki şekildedir.

$$X_t = f(t) \quad (9)$$

Burada gözlemlenen X değişkeni zamana bağlı olarak değer almaktadır. Bu da değişkeni, zamanın belirlediği, bağımlı bir değişken olarak nitelendirmemizi sağlar. Burada rastgele olmayan bir değerlendirme süreci gözlemlenmektedir.

Bununla birlikte deterministik zaman serilerinde, önceki değerlere bağlı davranış da gözlemlenebilmektedir. Bu tip serilere ait örnek zaman fonksiyonu aşağıdaki gibi formülize edilebilir.

$$X_t = f(t, X_{t-1}, X_{t-2}, \dots) \quad (10)$$

Burada X_t 'nin, yani "X" değişkeninin "t" zamanında aldığı değer, önceki değerlerinin bilinmesi durumunda, ilgili zaman verisiyle birlikte tahmin edilebilir davranış göstermesi beklenmektedir. Bu tip zaman serileri de, doğrudan zamanın bir fonksiyonu olarak davranış gösteren zaman serileri gibi deterministik özellik göstermektedir.

Stokastik zaman serilerinde ise değişken rastgele değerler alır gibi gözlemlenmektedir. Değişken bağımsız olarak belirli zamanlarda, zamandan ve önceki değerlerinden bağımsız olarak hareket eder. Bu durumda stokastik bir yapıya sahip olduğu söylenebilir. Buradaki çalışmada da gözlemlenen çözünmüş oksijen değerleri, tek başına gözlemlenen değerler itibarıyla, stokastik özellik göstermektedir.

Zaman serileri analizinde, değişkene ilişkin veriler analiz edilmektedir. Zaman serisi analizinin doğru şekilde tahmin edilmesinin genelde amacı, ölçülen değerlerin anlaşılması ve değişkenlerin gelecekte değişiminin belirlenmesidir. Bu işleme öngörü (forecasting) adı

verilmektedir. Bu nedenle tahmin geçmiş verilerin bu amaçla analiz edilmesine ve yapılacak tahminlerde kullanılmasına dayanmaktadır. Bu analiz yöntemlerinden birisi de regresyondur.

3.2.3 Regresyon

Regresyon, zaman serileri analizinde, birden fazla değişken arasındaki ilişkiyi ölçmek için kullanılan bir analiz yöntemidir [44]. Burada bilinen değerlerden yararlanıp bilinmeyen durumların tahmin edilmesine çalışılmaktadır. Örneğin ikinci el bir arabanın satış fiyatını, arabanın markası ve modeli gibi özelliklerini dikkate alarak, arabanın fiyatı tahmin edilmeye çalışılırsa bu işlem regresyon analizleri ile gerçekleştirilebilir [45].

Tek bir değişken kullanılarak, zaman serileri üzerinde bir çalışma gerçekleştirilirse, buna tek değişkenli regresyon adı verilmektedir. Bunun yanı sıra, birden çok değişken kullanılarak bir çalışma gerçekleştirilirse, buna “çok değişkenli regresyon analizi” adı verilmektedir. Regresyon analizi ile değişkenler arasındaki korelasyon vb. ilişkilerin varlığı araştırılmaktadır. Böylece değişkenler arasındaki muhtemel neden-sonuç ilişkileri ortaya çıkarılabilmektedir.

Regresyon, iki (ya da daha çok) değişken arasındaki doğrusal ilişkinin fonksiyonel şeklini, biri bağımlı diğeri bağımsız değişken olmak üzere, bir doğru denklemi üzerinde, göstermektedir. Bununla birlikte, regresyonla birlikte, değişkenlerden birinin değerine göre diğeri hakkında yaklaşık olarak kestirimde bulunulmasını sağlar [44]. Regresyonda, değişkenlerden en az bir tanesi bağımlı değişken olmalıdır. Yani bir değişken diğer değişkene göre, değer alabilmelidir. Örneğin araba fiyatının, araba model yılına göre değer alabilmesi, burada fiyat değerinin, model yılına göre bağımlı değişken olduğunu göstermektedir.

Özetle, bir fonksiyonda, eşitlikteki bir değişkenin diğer değişkenlerden etkilenmesi durumunda bu değişkenler bağımlı değişken olarak nitelendirilmektedir. Bağımlı değişkenin bağlı olduğu değişkenler ise diğer değişkenlerden matematiksel anlamda etkilenmemektedir. Böylece, başka bir deyişle üzerinde durulan değişkenlerden birinin bağımlı (u), diğerinin (v) bağımsız olması, u değerinin ve v değerinin bir fonksiyonu olarak ifade edilen ilişki olarak tarif edilmektedir.

Doğrusal ve Doğrusal Olmayan Regresyon: Regresyon, doğrusal ve doğrusal olmayan regresyon modeli olmak üzere ikiye ayrılır. Doğrusal regresyon modeli aşağıdaki şekilde ifade edilebilmektedir.

$$Y_i = a + bX_i \quad (11)$$

Burada X_i bağımsız değişkeni, a değeri doğrunun y eksenini kestiği değer olarak başlangıç değerini, b ise X değişkenindeki, birim değişime karşılık olarak, Y değişkenindeki değişim miktarını ifade etmektedir. Y ve X değişkenleri arasındaki muhtemel doğrusal bağlantı, burada a ve b değerlerinin belirli bir düzende artış göstermesiyle ortaya konulabilmektedir.

Sonuç olarak, X ve Y değişkenleri arasında doğrusal bir “yakınsama modeli” ortaya konabilir. Bu modelin ortaya konulamaması durumunda, X ve Y değişkenleri arasında doğrusal olmayan bir ilişki bulunmaktadır. Bu iki değişken arasındaki ilişki ortaya konulurken, doğrusal olmayan regresyon yaklaşımı ve haritalaması kullanılmaktadır.

Buradaki çalışmada kullanılan ölçüm değerleri arasında da doğrusal bir yakınsama modeli ortaya konulamadığından dolayı, taban modelde doğrusal olmayan regresyon yaklaşımı kullanılmıştır.

3.3. YSA ile Zaman Serisi Tahmini

Zaman serileri analizi ve tahmini için çeşitli istatistiksel yöntemler bulunsa da, bu çalışmanın konusu, problemin çözümünde Yapay Zeka tekniklerinin kullanımınıdır. Bu sebeple, zaman serisi tahmini konusu açıklanmaya çalışılmıştır.

Yapay sinir ağları öğrenme zamanına göre statik ve dinamik ağlar olarak ikiye ayrılmaktadır. Statik öğrenme metodunu kullanan YSA’lar önce eğitilmektedir. Daha sonra eğitim tamamlanıp, ardından ağ kullanılmaktadır. Statik öğrenme metodunu kullanan YSA’larda, ağ kullanılırken öğrenimine devam etmemektedir. Burada nöronlar arasındaki ağırlıkları tutan, ağırlık matrisi güncellenmeden aynı kalmaktadır. Bu ağlar, statik öğrenme zamanlı yapay sinir ağlarıdır. Bu yapıya sahip yapay sinir ağlarında, geri bildirim ve gecikme mekanizmaları bulunmamaktadır. Ağın çıkış değerleri, doğrudan giriş bilgilerine göre hesaplanmaktadır. Bu tür ağlar gözlemlenen değerlerin, zaman boyutunu dikkate almadan çıktı üretmektedir.

Bunun yanı sıra dinamik olarak öğrenen ağlar ise, ileri beslemeli, bünyesinde gecikmeli özellikler de barındıran çok katmanlı ağlardır. Dinamik ağlar gecikme ve döngü mekanizmalarına sahip olmaları sebebiyle, sıralı ve zamana göre değişen veriler üzerinde kullanılabilir. Bu özellikler de, dinamik öğrenen yapay sinir ağlarını, zaman serileri analizlerinde, statik öğrenen ağlara göre çok daha yetenekli ve haliyle kullanışlı bir duruma getirmektedir. Böylelikle dinamik öğrenen YSA'lar zaman serileri problemlerinde daha çok tercih edilmektedir.

Bununla birlikte, gerçek hayat problemlerinde oluşturulan zaman serilerinde, uzun zamanlı bağımlılık bulunmaktadır. Dinamik sistem teorisi doğrusal olmayan kaotik davranışlı sistemleri analiz edebilmek için teorik temeller sunmaktadır. Döngüsel YSA'lar rastgele dinamik sayı dizilerini tahmin edebilmektedir. Genelde ölçüm verilerinin oluşturduğu zaman serileri de, ham veri olarak bakıldığı takdirde, rastgele sayı dizilerinden oluşmaktadır.

Bu çalışmada da çözünmüş oksijen ölçüm değerlerinin, zaman serisi oluşturmasından ve diğer parametrelere bağımlı olmasından dolayı, doğrusal olmayan oto-regresif modeller ile çalışılmıştır.

3.3.1 NAR Ağı

NAR (Nonlinear Autoregressive – Doğrusal Olmayan Otoresif) modele dayalı YSA'larda, sadece tahmin edilmesi istenen parametreye ait geçmiş ölçüm verilerini içeren bir adet girdi serisi ele alınarak çözüme varılması hedeflenmektedir. Bir $y(t)$ zaman serisinin, gelecekte alabileceği muhtemel değerler, sadece bu $y(t)$ serisinin geçmişteki değerleri göz önüne alınarak, tahmin edilmeye çalışılmaktadır. Burada NAR modeline ait süreç matematiksel olarak modellenecek olursa, ilgili gösterim ise aşağıdaki şekilde ifade edilebilmektedir.

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n)) \quad (12)$$

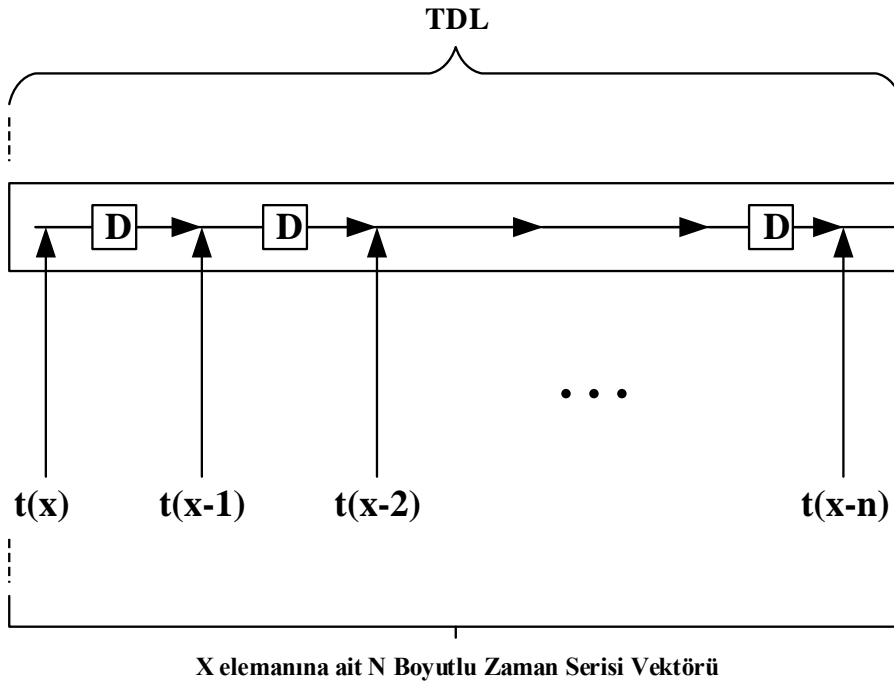
NAR modeline dayalı YSA'lar, yapıları itibariyle tek değişkenli regresyon altyapısı sunmaktadır. Buradaki tahminleme yöntemi doğrusal olmayan otoresif olarak isimlendirilmektedir. Ancak burada fizikokimyasal su kalitesi parametrelerinin zamana ve birbirlerine bağlı olarak değiştiğini ön görülürse bu modelin seçimi, güvenilir sonuçlar vermeyecektir. Bunun yerine diğer parametreleri de modele dahil eden bir çözüm olan, NARX ağı ortaya çıkmaktadır.

3.3.2 NARX Ağı

NARX (Nonlinear Autoregressive Exogenous – Doğrusal Olmayan Otoresif Eksojen) modele dayalı YSA’lar iki katmanlı ileri beslemeli, döngülü ve dinamik ağlardır. NARX ağları, NAR ağlarının diğer değişkenleri de içine alacak şekilde geliştirilmiş bir halidir. Buradaki model isminde bulunan “X”, eksojen değerleri yani, diğer harici parametrelerin de modelin içerisine dahiliyetini ifade etmektedir. NARX modeline dayalı YSA’lar aynı zamanda, zaman serisi tahminlerinde sıklıkla uygulama alanı bulmaktadır [46,47] .

NARX tabanlı YSA’larda, gizli katmanda sigmoid aktivasyon fonksiyonu, çıkış katmanında ise doğrusal aktivasyon fonksiyonu kullanılmaktadır. Yine öğrenim algoritması olarak Levenberg-Marquardt (LMA) algoritması kullanılmaktadır.

NARX ağında $x(t)$ ve $y(t)$ dizilerini saklamak için, çıkmalı gecikme hattı (tapped delay line) kullanır. TDL en az bir “tap (çıkma)” ya sahip bir gecikme hattıdır. Burada “tap (çıkma)” lar, ağ önceki girdi değerleriyle beslemeye yarar. Şekil 12’de ağa gönderilen girdi değerinin, ağa girdikten sonra, kendisi ve N-1 tane gecikme elemanından geçişiyle birlikte, N boyutlu bir vektör oluşturduğu görülmektedir.



Şekil 12. TDL / Çıkmalı Gecikme Hattı (Tapped Delay Line)

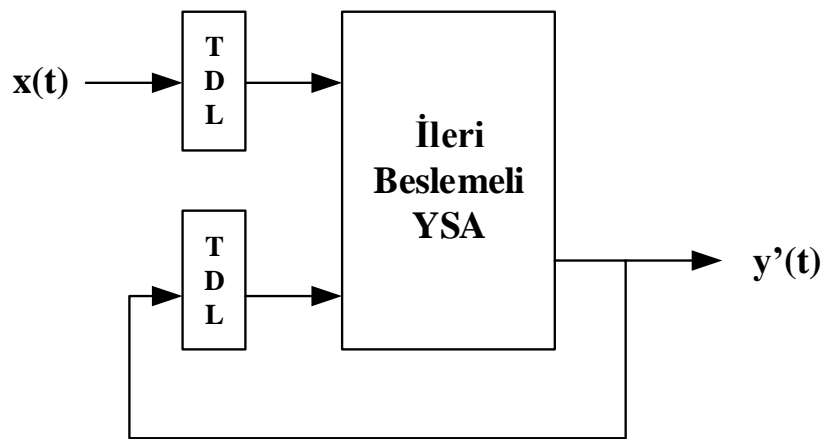
NARX ağının çıkışı, $y(t)$, gecikmelerle tekrar ağın giriş katmanına gönderilir. NARX ağı zaman serisi modellemesinde sıklıkla kullanılmaktadır. Temelde NARX Modelini ifade eden fonksiyon şu şekildedir:

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-n_y), u(t-1), u(t-2), \dots, u(t-n_u)) \quad (13)$$

Burada bağımlı çıkış sinyali $y(t)$, çıkış sinyalinin daha önceki değerleri ve bağımsız (eksojen) giriş sinyaliyle regresyona tabi tutulur [48]. NARX Ağının yapısı Şekil 14'de gösterilmektedir.

NARX ağı, tahmin edilmesi istenilen zaman serisini girdi olarak almaktadır. Yine girdi katmanında bu zaman serisi verisini etkileyen diğer parametreler (harici değerler) de ağa gönderilmektedir. NARX Ağları paralel ya da dizi-paralel mimaride tasarlanabilmektedirler.


Klasik Paralel NARX mimarisinde (paralel mimari) çıkış değeri, doğrusal olmayan dinamik sistemin, bir tahmini olacaktır. Şekil 13'de görüldüğü üzere, bu mimaride elde edilen tahmin çıkış değeri tekrar ileri beslemeli ağın girişine gönderilmektedir. Burada tahmin edilmesi istenilen değerlerin önceki zaman serisi değerleri ele alınmamaktadır. Bu klasik paralel NARX mimarisinin tipik bir özelliğidir [46].



Şekil 13. Paralel NARX Mimarisi


Dizi-Paralel NARX Mimarisinde ise , Şekil 14'de görüldüğü üzere gerçek çıkış değeri de, ağın eğitilmesi sırasında girişe gönderilmektedir. Bu durumun iki faydası vardır. İlk olarak

ağa giriş olarak verilen değerler birbirleriyle daha tutarlıdır. İkincisi ise ortaya konulan ağ mimarisinin tamamen ileri beslemeli bir ağ olmasıdır. Bu da ağ mimarisinde statik geri yayılım algoritmaları kullanılabilmesine imkan vermektedir.



Şekil 14. Dizi-Paralel NARX Mimarisi

Burada $x(t)$ geçmişteki harici (eksojen) parametreleri göstermektedir (örn. Diğer ölçüm verileri, mevsim, ay ve yıl vb.). Yine $y(t)$ ise tahmin edilmesi istenilen zaman serisini ifade etmektedir. $y'(t)$ ise tahmin edilen değerleri ifade etmektedir. Klasik Paralel mimaride sadece harici parametrelere göre gerçekleştirilen tahmin ve bu tahmine bağlı olarak yeni tahminler gerçekleştirilmektedir. Eğer tahmin edilen zaman serisinin önceki değerleri sisteme gönderilmezse, sistem bunları bilemeyecektir. Burada da çözünmüş oksijen parametresinin önceki ölçüm değerleri kullanılarak bir yaklaşımda bulunduğu için, bu yüzden buradaki çalışmada Şekil 15'de detaylı olarak görüldüğü üzere Dizi-Paralel NARX Mimarisi (NARX-DP) kullanılmıştır.



Şekil 15. Çalışmada Kullanılan NARX-DP YSA Mimarisi

3.4. YSA Uygulamaları

Yapay zeka yöntemleri, çok çeşitli alanlarda tahmin çalışmalarında kullanılmıştır. Tahmin konusunda, ekonomiden borsaya, turizmden nüfus artışına kadar bir çok değişik alanlarda yer alan problemlerin çözümüne yönelik olarak çalışmalar gerçekleştirilmiştir. Benli ve Ark. [49] altın fiyatlarını, İstanbul Altın Borsasından alınan aylık ağırlıklı ortalama değerleri çalışmalarında kullanarak, YSA ve Zaman Serisi Yöntemlerini kullanarak tahmin etmeye çalışmışlardır [49].

Yakut ve ark. [50] Yapay Sinir Ağları ve Destek Vektör Makineleriyle Borsa Endeksi'ni tahmin etmeye çalışmışlardır. Çalışmalarında BIST (Borsa İstanbul) endeksinin tahmin edilmesi için farklı değerleri kullanmışlardır. Çalışmalarında, yapay sinir ağları ve destek vektör makineleri ile borsa endeksi tahmini problemi çözümünde, modeller ortaya koymuşlardır [50].

Turizm talebinin Yapay Sinir Ağları ile tahmini konusunda, Çuhadar ve ark.[51] farklı mimarilere sahip yapay sinir ağı modellerinin tahmin doğruluklarını karşılaştırarak en yüksek doğruluğu sağlayan modelin belirlenmesi ve belirlenen model yardımıyla Antalya iline yönelik aylık dış turizm talebinin tahminini gerçekleştirmeye çalışmışlardır [51].

Su kalitesi tahminlerinde de yapay zeka uygulamaları kullanılmıştır. Türkmenler ve ark. [52] çalışmalarında, ileri biyolojik atıksu arıtma tesislerinde kimyasal oksijen ihtiyacı çıkış konsantrasyonlarının tahmini için YSA modellerinin uygulanması konusunu ele almışlardır. Çalışma sonucunda, YSA modelinin umut verici bir yaklaşım olduğunu ortaya koymuşlardır. Bununla birlikte günlük buharlaşmanın tahmin edilmesi konusunda Doğan ve ark. [53] başarıyla bir yapay sinir ağı modeli ortaya koymuşlardır.

Özkan ve ark. [24] Kızılırmak Nehri'nde Çözünmüş Oksijen değişimini YSA modelleriyle belirlemeye çalışmışlardır. Bunun yanı sıra Yüksek Lisans Tezleri'nde de Atıksu Arıtma Performansının, YSA ile modellenmesine üzerine çalışmalar mevcuttur [54].


Genel olarak bakıldığında literatürde, yapay zeka modelleri, çok çeşitli alanlarda kullanılmakla birlikte, su konusunda da uygulamada yer bulmaktadır. Ortaya konulan modeller, genelde tahmin edilmesi istenilen bir değişkeni diğer değişkenlere bağımlı olarak yapay sinir ağlarıyla tahmin etmeye yönelik ya da sadece aynı değişkenin geçmişe dayalı verilerinden zaman serisi çıkarımı gerçekleştirerek sonuca varmayı hedeflemektedir. Ortaya konulan çalışmalar, başta doğal bilimler olmak üzere, geleceğe yönelik tahmin problemlerinin çözümünde başarılı sonuçlar vermektedir.

4. UYGULAMA

Bu çalışmada, ülkemizin önemli akarsu havzalarından birisi olan Akarçay Nehri pilot olarak seçilerek, çözünmüş oksijen değerinin diğer parametrelerle ilişkili olarak gelecekte alabileceği ölçüm değerleri, NARX-DP YSA modeli ile tahmin edilmeye çalışılmıştır.

4.1. Akarçay Havzası

Havza, bir su kütesinin kaynağından döküldüğü yere kadar uzandığı, bu su kaynağına su sağlayan coğrafi alanı kapsamaktadır. Ülkemiz toprakları halihazırda SÇD'ye göre 25 ayrı havzaya bölünmüştür. Buradaki bölümlenmede suyun doğal sınırlarını göz önüne alan bir yaklaşım sergilenmiştir. Akarçay Havzası da Ülkemizin batısında, Akdeniz, Ege ve İç Anadolu bölgelerinde, Sakarya, Büyük Menderes, Konya Kapalı ve Antalya Havzalarına komşu olarak bulunmaktadır.



Şekil 16. Türkiye'nin Havzaları

Akarçay Havzası, adını Akarçay Nehri'nden almaktadır. Havzanın büyük bir kısmı Afyonkarahisar il sınırları içerisinde yer almaktadır. Havza yaklaşık olarak 130 km uzunluğa, 20 km genişliğine sahip bir çöküntü havzasıdır [55]. Bununla birlikte, havza coğrafi olarak 30°-32° doğu boylamları ile 38°-39° kuzey enlemleri arasında yer almaktadır [56].



Şekil 17. Akarçay Havzası

Akarçay Nehri havzanın batısından doğusuna doğru bir akım yönüne sahiptir. Havzada Akarçay Nehri ile Kali Çayı, Çay Deresi, Yeniköy Deresi, Engilli Deresi ve Adıyan Suyu gibi küçük dereler de bulunmaktadır. Bu dereler sırayla Akarçay'a katılmaktadır. Daha sonrasında ise Akarçay, Havzanın doğusunda Eber ve Akşehir göllerine dökülmektedir. Akarçay Havzası denize ulaşamamasından ötürü iç bölgede sonlandığından dolayı kapalı bir havzadır.


4.2. Veri Seti

Bu çalışmada, Akarçay Havzası'ndaki Tablo 3'de görülen 8 adet numune alma noktasından elde edilen 1991-2014 arası ölçüm değerleri Devlet Su İşleri Genel Müdürlüğü Su Veritabanı Sistemi'nden 03.02.2015 tarihinde alınarak kullanılmıştır.

Tablo 3. Numune Alma Noktaları'na Ait Coğrafi Koordinatlar

İstasyon Adı	DSİ İstasyon No	Enlem	Boylam
Eber Gölü - Kocakandiralık	11-18-01-013	31.145760749625023D	38.62998785107423K
Eber Gölü - Yalı Mevkii	11-18-01-012	31.123124727415796D	38.62712178395024K
Eber Gölü - Ortasi - Donbay	11-18-01-011	31.144234497360323D	38.64774207963218K
Bolvadin Köprüsü	11-18-00-007	31.04793848659954D	38.66029414315788K
Seker Fabrikası Sonrası	11-18-00-004	30.79281097828344D	38.6858962060904K
Afyon AAT Sonrası	11-18-00-038	30.584768801245332D	38.77206312016254K
Araplı Deresi	11-18-00-037	30.424874945918997D	38.847392030049534K
Eber Gölü - Eber Regülatörü	11-18-02-016	31.230391059590833D	38.61077187571954K

Bu veri setinde istasyonlarda/numune alma noktalarında Çözünmüş Oksijen dahil ölçülen 34 parametre için, toplamda 25024 satır veri bulunmaktadır. Buradaki veriler 3 ayda bir olmak üzere her yılda 4 kez ölçüm verilerinden oluşmaktadır. Bu haliyle veri seti, kesikli zaman serisi niteliği kazanmaktadır.



Şekil 18. Numune Alma Noktaları

4.3. Veri Ön İşleme ve Normalizasyonu

Normalizasyon, üzerinde çalışılan ölçüm değerlerinin dağılımını daha düzenli bir hale getirmektedir. Veri setinde, veri setinin dağılımını etkileyecek aşırı (uç) değerler bulunabilmektedir. Bu uç değerler, YSA'nın çalışmasında yanlış yönde etkiler yapabilmektedir. Değerlerin belirli bir aralıkta tekrar düzenlenmesi, çok büyük ve küçük şeklindeki değerlerin etkisinin azalmasını sağlar. Bu düzenlemeye normalizasyon adı verilmektedir.

Bu çalışmada da, veriler ağa gönderilmeden önce istatistiksel olarak 0.1-0.9 değerleri arasında min-max normalizasyon yöntemi kullanılarak normalize edilmiştir. Bu yöntemde, bir grup verinin içerisindeki en büyük ve en küçük değerler ele alınır. Diğer bütün veriler, bu değerlere göre normalleştirilir. Buradaki amaç en küçük değeri 0.1 ve en büyük değeri 0.9 olacak şekilde normalleştirmek ve diğer bütün verileri bu aralığa yaymaktır. Böylece sapan verilerin, veri seti üzerindeki etkisinin minimuma indirilmesi amaçlanmaktadır.

Min-Max yöntemi, verileri doğrusal olarak normalize eder. Minimum; bir verinin alabileceği en düşük değer iken, maksimum; verinin alabileceği en yüksek değeri ifade eder.

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (14)$$

Bu eşitlikte; X normalize edilmiş veriyi, X_i normalize edilmemiş girdi değerini, X_{min} girdi seti içerisinde yer alan en küçük sayıyı, X_{max} girdi seti içerisinde yer alan en büyük sayıyı, ifade etmektedir.

4.4. Oluşturulan Yapay Sinir Ağı Modelleri

Buradaki çalışmada da uzun vadeli bağımlılık gösteren, su kimyasının ön gördüğü şekilde diğer parametrelere bağımlı olarak değişen zaman serileri üzerinde çalışıldığı için, Dizi-Paralel NARX YSA modeli kullanılmıştır.

Çalışma kapsamında, Akarçay Havzası'nda 8 numune alma noktasında, Çözünmüş Oksijen değeri, ay, yıl, mevsim ve diğer çeşitli parametrelerin ölçüm değerleri kullanılarak, farklı veri setleri ve ağ modelleriyle tahmin edilmeye çalışılmıştır. Daha sonra bu modeller ilgili veri setleri üzerinde tahmin performansları açısından test edilmiş ve karşılaştırılmıştır. En uygun NARX modelini bulabilmek için, bu kapsamda Matlab ortamında bir yapay sinir ağı uygulaması geliştirilmiştir. Geliştirilen uygulama Intel Core Duo 2, 2.4 Ghz Quad Core İşlemci ve 8 GB birincil hafızaya sahip bir sistem üzerinde çalıştırılmıştır.

Oluşturulan her veri setiyle, kullanılan tüm NARX model setlerinde yer almakta olan modeller sırasıyla tek tek denenmiştir. Burada GKNS, gizli katman nöron sayısını, ID (Input Delays) giriş gecikmelerini, FD (Feedback Delays) geri besleme gecikmelerini, MSE (mean square error) ise ortalama karesel hata değerini belirtmektedir.

Kurgulanan yapay sinir ağı yapısının performansını ölçmek için mutlak hata ortalaması (R^2) ve hata kareler ortalaması (MSE / Mean Square Error – Ortalama Karesel Hata) kullanılmaktadır [57]. YSA'da öğrenme sırasında, öğrenmenin takip edilebilmesi için bir hata grafiği çizilmektedir. Böylece öğrenme boyunca, iterasyonlarda oluşan hatanın grafiği incelenerek, hatanın zaman içinde aldığı değerler takip edilebilmektedir. İterasyonlar ilerledikçe, bir süre sonra hatanın hatırı sayılır miktarda daha fazla azalmayacağı ve ağın öğrenmesinin oldukça yavaşladığı (veya durduğu) ve daha iyi bir sonuç bulunamayacağı

görülmektedir. Burada verilen sonuçlarda da iterasyon sayısı, ağın öğrenmesinin bu kritere göre durdurulduğu iterasyonun numarasını vermektedir. Ağın daha iyi sonuçlar bulamadığı durumlarda öğrenme kesilerek, zaman kaybı önlenmiş olmaktadır.

Model performansı değerlendirilirken, MSE değeri 0'a en yakın ve R^2 değerleri 1'e ve birbirine en yakın modeller daha başarılı performans göstermektedirler. R^2 değerlerinin birbirine yakın olması, ağın başarısız bile olsa daha dengeli ve tutarlı sonuçlara sahip olduğu manasına gelmektedir. Birbirine uzak R^2 değerleri ise, eğitim, validasyon ve test aşamalarının her birinde ağın tutarsız sonuçlar bulduğu manasına gelmektedir.

Burada gecikmelerde "n:k:z" şeklinde ifade edilen gösterim, "n" kadar önceki elemandan başlayarak, "k" kadar adımla, z değerine kadar girişlerin de gecikmeli olarak ağ modeline gönderildiğini ifade etmektedir. Örneğin "2:4:20" değeri, $t(x-2, x-6, x-10, x-14, x-18)$ değerlerinin NARX modeline girişlerin gönderildiği anlamı taşımaktadır. Yine "n:z" tipinde belirtilen gecikme değeri ise, "n" kadar önceki zaman elemanından, "z" zamanındaki elemana kadar değerlerin ağa gönderildiği manasına gelmektedir. Örneğin "1:4" değeri, matematiksel olarak $t(x-1, x-2, x-3, x-4)$ zamanındaki girdi değerlerinin de gecikmeli olarak ağa gönderildiğini belirtmektedir.

4.5. Uygulama Aşamaları

Bu çalışmanın ilk aşamasında, sırasıyla oluşturulan tüm modeller öncelikle eğitilirken, tüm veri setleri için her bir veri setinin %70'i eğitim %15'i geçişleme, %15'i ise test amaçlı değerlendirilmiştir. Bu veri setinde fizikokimyasal her bir parametrenin ölçüm değerleri ve ne zaman nerede ne kadar ölçüldüğü bulunmaktadır.

Optimum NARX modelini bulabilmek için, VS-1, VS-2 ve VS-3 olmak üzere 3 ayrı veri seti ve bu veri setleri üzerinde çalışan, temel NARX modeli üzerine inşa edilmiş M1, M2 ve M3 model setleri kullanılmıştır.

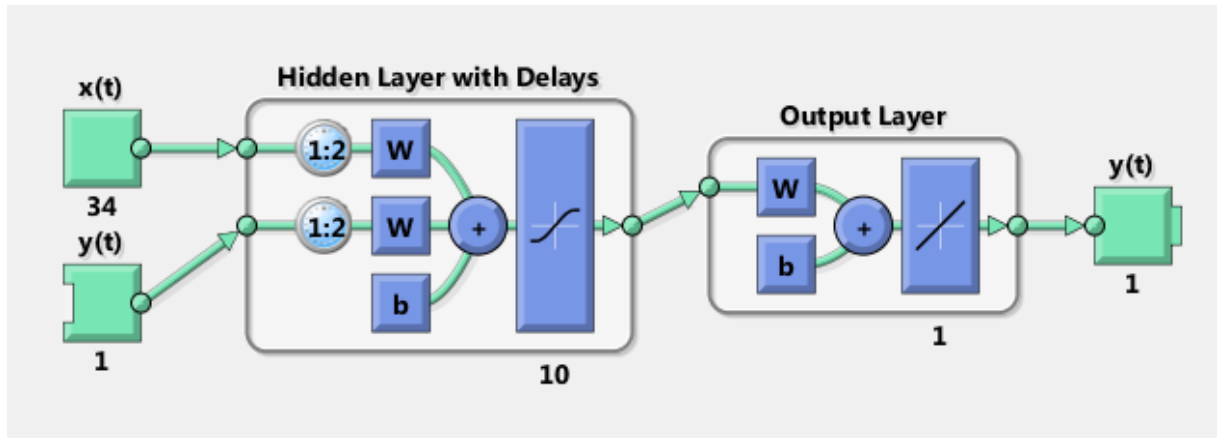
Öncelikle, ilk aşamada pilot olarak en fazla verinin bulunduğu Afyon Atık Su Arıtma Tesisi çıkışındaki numune alma noktası üzerinde, M1 modeli, VS-1 veri seti ile birlikte denenmiştir. M1 Model setinde, girdi katmanında diğer 33 parametrenin yanı sıra mevsim bilgisini içerecek şekilde toplam 34 giriş bulunmaktadır. Burada kullanılan VS-1 veri setine ait model girdileri Tablo 4'de verilmektedir.

Tablo 4. VS-1 Veri Setinde Kullanılan Girdiler

Parametre	Kısaltma	Birimi
Mevsim	-	-
Bor	B	mg/L
Biyokimyasal Oksijen İhtiyacı	BOİ ₅	mg/L
Kalsiyum	Ca ⁺⁺	mg/L
Klor	Cl ⁻	mg/L
Karbondioksit	CO ₂	mg/L
Kimyasal Oksijen İhtiyacı	KOİ	mg/L
Renk	Col	Pt-Co
F-Coli	F-Coli	EMS/100 ml
Demir	Fe	µg/L
Fenoller	Fenoller	mg/L C ₆ H ₅ OH
Fekal Streptokok	F-Strp	EMS/100 ml
Hidrojen Sülfür	H ₂ S	mg/L
Potasyum	K ⁺	mg/L
M-Al	M-Al	mg/L
Magnezyum	Mg ⁺⁺	mg/L
Mangan	Mn	µg/L
Sodyum	Na ⁺	mg/L
Nitrit	NO ₂ -N	mg/L
Nitrat	NO ₃ -N	mg/L
Aliminyüm	P-Al	mg/L
pH	pH	-
pV	pV	mg O ₂ /l
Debi	Q _{anlık}	m ³ /s
Sülfat	SO ₄	mg/L
Askıda Kati Madde	SS	mg/L
Sıcaklık	T	°C
T-Coli	T-Coli	EMS/100 ml
Toplam Çözünmüş Kati Madde	TDS	mg/L

Toplam Hidrokarbon	TH	mg/l CaCO ₃
Toplam Kjeldahl Azotu	TKN	mg/L
T-PO ₄	T-PO ₄	mg/L
TS	TS	mg/L
Turbidite	Turb	NTU

Bu veri seti için kullanılan M1 model setinde, giriş katmanında 34 nöron, gizli katmanda modele göre değişken sayıda nöron, çıkış katmanında da 1 adet nöron bulunmaktadır. Oluşturulan örnek bir NARX-DP Modeli Şekil 20’de görülmektedir.



Şekil 19. VS-1 Veri Seti için Oluşturulan M1 NARX Model Taslağı

Kurgulanan NARX modellerinde, $x(t)$ her bir zaman adımında, harici (eksojen) parametrelerin aldığı değerleri simgelemektedir. Burada gösterilen konsept modelde, girişler $x(t)$ için 1’den 4’e kadar, $y(t)$ fonksiyonunun önceki değerleri $y(t)$ için yine 1’den 4’ kadar gecikme hattı kullanılmıştır. Yine, öğrenme algoritması olarak da, temel NARX mimarisinde kullanılan Levenberg-Marquardt algoritması kullanılmıştır. M1 Model setine ait performans değerleri Tablo 5’de verilmektedir.

Tablo 5. M1 NARX Model Seti Performansları

GKNS	ID	FD	MSE	İterasyon	Eğitim R ²	Validasyon R ²	Test R ²	Genel R ²
50	4:4:20	4:4:20	28,1471	7	0,762178	0,18734	0,224808	0,611004
50	4:4:40	4:4:40	71,2182	7	0,77894	0,668508	0,560048	0,704241
50	4:4:60	4:4:60	41,4860	4	0,776968	0,160718	0,223822	0,629344
50	4:4:80	4:4:80	41,2601	5	0,932756	0,166634	0,166634	0,721013
50	1:4	1:4	15,3074	11	0,605404	0,331296	0,333268	0,553422

50	1:8	1:8	19,9552	4	0,807534	0,35496	0,422994	0,703817
50	1:12	1:12	48,8875	8	0,962336	0,122264	0,240584	0,696767
50	1:16	1:16	31,8408	6	0,957406	0,208046	0,39933	0,781661
50	1:20	1:20	41,8659	6	0,90219	0,112404	0,33031	0,702062
50	1:40	1:40	29,7906	4	0,964308	0,181424	0,243542	0,792606
40	4:4:20	4:4:20	20,8364	7	0,669494	0,323408	0,232696	0,569928
40	4:4:40	4:4:40	21,8314	4	0,699074	0,329324	0,346086	0,600089
40	4:4:60	4:4:60	51,4198	5	0,868666	0,060146	0,140998	0,625656
40	4:4:80	4:4:80	38,0382	11	0,973182	0,307632	0,224808	0,776288
40	1:4	1:4	19,2358	6	0,840072	0,362848	0,499902	0,740318
40	1:8	1:8	17,2660	8	0,880498	0,447644	0,258332	0,76065
40	1:12	1:12	46,3423	3	0,678368	0,218892	0,43384	0,593937
40	1:16	1:16	23,8766	5	0,85782	0,181424	0,341156	0,727234
40	1:20	1:20	25,4790	3	0,806548	0,407218	0,38947	0,706883
40	1:40	1:40	29,7149	4	0,972196	0,303688	0,230724	0,78878
30	4:4:20	4:4:20	18,9805	4	0,71485	0,23664	0,224808	0,605848
30	4:4:40	4:4:40	28,9548	7	0,681326	0,125222	0,360876	0,561961
30	4:4:60	4:4:60	29,9794	5	0,900218	0,120292	0,21692	0,741719
30	4:4:80	4:4:80	32,8620	7	0,967266	0,370736	0,27115	0,796491
30	1:4	1:4	17,8466	7	0,751332	0,349044	0,442714	0,674562
30	1:8	1:8	13,2995	7	0,64583	0,442714	0,430882	0,599222
30	1:12	1:12	20,8804	6	0,692172	0,25636	0,382568	0,608293
30	1:16	1:16	18,8528	11	0,386512	0,17748	0,205088	0,338829
30	1:20	1:20	25,9563	5	0,888386	0,214948	0,30073	0,735664
30	1:40	1:40	29,7015	8	0,973182	0,26129	0,233682	0,79587
20	4:4:20	4:4:20	32,1949	5	0,70992	0,14297	0,3451	0,596106
20	4:4:40	4:4:40	18,7060	5	0,70992	0,242556	0,190298	0,605848
20	4:4:60	4:4:60	17,2004	3	0,683298	0,344114	0,268192	0,607662
20	4:4:80	4:4:80	16,9368	4	0,494972	0,206074	0,21692	0,433061
20	1:4	1:4	16,6049	6	0,686256	0,390456	0,398344	0,615126
20	1:8	1:8	16,4031	17	0,400316	0,184382	0,077894	0,345011
20	1:12	1:12	25,7104	8	0,870638	0,250444	0,426938	0,744006
20	1:16	1:16	29,4091	9	0,742458	0,18734	0,291856	0,62191
20	1:20	1:20	18,9830	4	0,77401	0,267206	0,385526	0,683446
20	1:40	1:40	26,0587	7	0,829226	0,277066	0,127194	0,671949
10	4:4:20	4:4:20	15,4755	8	0,38454	0,198186	0,2958	0,352485
10	4:4:40	4:4:40	18,4012	3	0,800632	0,390456	0,440742	0,713736
10	4:4:60	4:4:60	24,6899	3	0,461448	0,196214	0,220864	0,403935
10	4:4:80	4:4:80	14,2959	13	0,25143	0,193256	0,30566	0,246756
10	1:4	1:4	15,9526	4	0,484126	0,242556	0,2958	0,441718
10	1:8	1:8	15,0293	7	0,597516	0,307632	0,35989	0,540713
10	1:12	1:12	15,8388	6	0,514692	0,316506	0,211004	0,465205
10	1:16	1:16	17,1012	7	0,474266	0,190298	0,125222	0,395741

10	1:20	1:20	15,0052	18	0,328338	0,25143	0,189312	0,299882
10	1:40	1:40	15,1261	3	0,597516	0,28101	0,2465	0,527372

Tablo 5’de verilen çalışma sonuçlarına göre, Afyon Atık Su Arıtma Tesisi çıkışındaki numune alma noktasında R^2 değerlerinin birbirine ve 1’e en yakın olan tutarlı ve başarılı tatminkar sonuç veren herhangi bir model bulunmamaktadır. Burada R^2 değerleri baz alındığında M1 model seti içerisindeki herhangi bir model dengeli sonuçlar vermemektedir.

Oluşturulan M1 model setinde, girdi katmanında nöron sayısının çok fazla olması ve bunlara bağlı gecikme sayıları da düşünüldüğünde, modeller oldukça karmaşık özellik göstermektedir. Böylelikle iterasyon sayısı az olsa bile, eğitim ve test süreleri oldukça uzamaktadır. Burada amaç en az parametre ve girdiyi kullanarak, çözülmüş oksijenin tahmininde mümkün mertebe basitleştirilmiş, en optimal model yapısını ortaya koyabilmektir.


Bunu gerçekleştirebilmek için, çalışmanın ikinci aşamasında, daha optimal ve basit yapıda bir model oluşturabilmek için için VS-2 veri seti hazırlanmıştır. Buradaki veri setinde, kullanılan model girdileri Tablo 6’da verilmektedir.

Tablo 6. VS-2 Veri Setinde Kullanılan Girdiler

Parametre	Kısaltma	Birimi
Mevsim	-	-
Biyokimyasal Oksijen İhtiyacı	BOD5	mg/L
Kimyasal Oksijen İhtiyacı	COD	mg/L
Renk	Col	Pt-Co
pH	-	-
Askıda Katı Madde	SS	mg/L
Sıcaklık	T	°C
Toplam Çözülmüş Katı Madde	TDS	mg/L
Turbidite	Turb	NTU

Bu veri seti için ölçümün gerçekleştirildiği mevsim bilgisinin yanı sıra, seçilen diğer 8 parametre ile birlikte giriş katmanında 9 girdi kullanan, M2 model seti oluşturulmuştur. Buradaki NARX modellerinde yine, gizli katmanda değişken sayıda nöronlar, çıkış

katmanında da 1 adet nöron bulunmaktadır. M2 model setinde bulunan modellere ait temel tasarım Şekil 21’de görülmektedir.



Şekil 20. VS-2 Veri Seti için Oluşturulan bir M2 NARX Model Taslağı

M2 model seti de, VS-2 veri seti ile birlikte Afyon Atık Su Arıtma Tesisi çıkışındaki numune alma noktasındaki verilerle denenmiştir. Yapılan denemeler sonrasında, Tablo 7.’de görüldüğü üzere, R^2 değerlerinin birbirine ve 1’e en yakın olan tutarlı ve başarılı sonuç veren modellerin genel olarak “4:4:Z” tipinde olduğu görülmektedir. Burada da yine R^2 değerlerinin birbirine ve 1’e en yakın olan modellerin genel olarak “4:4:40” tipinde olduğu görülmektedir.

Modellerde giriş gecikmeleri ve geri besleme gecikmelerinde $t(x-4, x-8, \dots, x-40)$ gecikmesi kullanılan modellerin diğerlerine göre daha başarılı olduğu söylenebilir. Bu modeller içerisinde de, Tablo 7’de görüldüğü üzere diğerlerine göre en iyi performansı gizli katmanda 10 ve 20 nöron kullanan modellerin verdiği görülmektedir.

Tablo 7. M2 NARX Model Seti Performansları

GKNS	ID	FD	MSE	İterasyon	Eğitim R^2	Validasyon R^2	Test R^2	Genel R^2
50	4:4:20	4:4:20	23,0312	5	0,741472	0,11832	0,257346	0,613962
50	4:4:40	4:4:40	26,9253	5	0,870638	0,612306	0,546244	0,593789
50	4:4:60	4:4:60	33,1831	4	0,752318	0,321436	0,086768	0,612483
50	4:4:80	4:4:80	31,8602	6	0,935714	0,258332	0,13804	0,744262
50	1:4	1:4	19,1159	7	0,83317	0,373694	0,370736	0,687272
50	1:8	1:8	24,0696	4	0,78387	0,220864	0,31552	0,663884
50	1:12	1:12	39,9047	5	0,869652	0,169592	0,416092	0,694805
50	1:16	1:16	28,8175	6	0,868666	0,240584	0,392428	0,741748
50	1:20	1:20	42,8208	8	0,973182	0,269178	0,186354	0,733397
50	1:40	1:40	40,8491	5	0,962336	0,211004	0,143956	0,751401

40	4:4:20	4:4:20	33,6273	4	0,627096	0,076908	0,082824	0,482963
40	4:4:40	4:4:40	25,0056	7	0,831198	0,733584	0,577796	0,669849
40	4:4:60	4:4:60	50,2202	6	0,835142	0,199172	0,001972	0,621791
40	4:4:80	4:4:80	53,1018	4	0,588642	0,22678	0,022678	0,487173
40	1:4	1:4	23,0085	6	0,797674	0,27115	0,308618	0,660275
40	1:8	1:8	15,3336	4	0,715836	0,362848	0,322422	0,646195
40	1:12	1:12	25,8230	4	0,792744	0,125222	0,357918	0,658362
40	1:16	1:16	20,2957	8	0,77401	0,319464	0,258332	0,675607
40	1:20	1:20	21,9037	7	0,875568	0,240584	0,121278	0,723458
40	1:40	1:40	35,9163	7	0,972196	0,287912	0,099586	0,77189
30	4:4:20	4:4:20	29,5996	10	0,767108	0,126208	0,125222	0,598226
30	4:4:40	4:4:40	19,9717	12	0,879512	0,757248	0,678368	0,69727
30	4:4:60	4:4:60	20,5559	7	0,693158	0,316506	0,011832	0,578506
30	4:4:80	4:4:80	29,0454	5	0,881484	0,291856	0,154802	0,702131
30	1:4	1:4	19,7184	6	0,684284	0,240584	0,298758	0,591442
30	1:8	1:8	25,1210	5	0,559062	0,291856	0,20213	0,495514
30	1:12	1:12	17,4778	6	0,80359	0,25636	0,263262	0,696501
30	1:16	1:16	20,7719	5	0,889372	0,319464	0,227766	0,756331
30	1:20	1:20	19,6294	5	0,81345	0,312562	0,303688	0,700445
30	1:40	1:40	20,0487	9	0,692172	0,259318	0,230724	0,587124
20	4:4:20	4:4:20	15,9770	14	0,794716	0,762178	0,646816	0,69234
20	4:4:40	4:4:40	16,0764	11	0,840644	0,871624	0,757248	0,808323
20	4:4:60	4:4:60	17,6556	6	0,830212	0,614278	0,415106	0,530823
20	4:4:80	4:4:80	16,3938	6	0,78387	0,546244	0,306646	0,504457
20	1:4	1:4	17,6855	5	0,598502	0,189312	0,195228	0,51838
20	1:8	1:8	15,5825	11	0,194242	0,179452	0,09367	0,158352
20	1:12	1:12	30,4682	6	0,771052	0,204102	0,23171	0,622294
20	1:16	1:16	22,0938	3	0,595544	0,114376	0,220864	0,475824
20	1:20	1:20	27,2571	3	0,514692	0,00493	0,191284	0,412325
20	1:40	1:40	20,4251	10	0,577796	0,09367	0,154802	0,488326
10	4:4:20	4:4:20	11,7042	9	0,86768	0,718794	0,604418	0,71699
10	4:4:40	4:4:40	13,3071	12	0,860364	0,845988	0,74936	0,79376
10	4:4:60	4:4:60	17,7642	4	0,869652	0,506804	0,687242	0,695485
10	4:4:80	4:4:80	16,5787	3	0,804576	0,558076	0,543286	0,536029
10	1:4	1:4	17,5238	5	0,491028	0,176494	0,0986	0,415185
10	1:8	1:8	15,1956	8	0,30566	0,132124	0,042398	0,260087
10	1:12	1:12	22,7814	6	0,699074	0,174522	0,280024	0,590338
10	1:16	1:16	14,5241	9	0,242556	0,28101	0,027608	0,228367
10	1:20	1:20	12,9706	7	0,156774	0,436798	0,00493	0,174404
10	1:40	1:40	18,1561	4	0,521594	0,062118	0,015776	0,42255

Oluşturulan M2 model setinde, girdi sayısının azalmasıyla birlikte önceki modellere göre eğitim ve test süreleri azalmıştır. Bununla birlikte parametre sayısının da azalmasıyla birlikte, veri setinin karmaşıklığı da azalmış, böylece modellerin ilk aşamada kullanılan M1 model


setindeki modellere göre daha performanslı sonuçlar verdiği görülmüştür. Çözünmüş oksijeni etkilemeyen ya da etkisi oldukça az olan parametreler modelden çıkarılarak, modelin karmaşıklığı azaltılmıştır.

Çalışmanın üçüncü aşamasında ise, Tablo 8’de görüldüğü üzere, VS-3 veri seti, çözünmüş oksijenin oldukça yakından ilişkili olduğu sıcaklık ve mevsim değeriyle birlikte toplam 2 girdi bulunmaktadır.

Tablo 8. VS-3 Veri Setinde Kullanılan Girdiler

Parametre	Kısaltma	Birimi
Mevsim	-	-
Sıcaklık	T	°C

Bu veri seti için giriş katmanında 2 girdi kullanan, M3 model seti oluşturulmuştur. Buradaki NARX modellerinde yine, gizli katmanda değişken sayıda nöronlar, çıkış katmanında da 1 adet nöron bulunmaktadır. M3 model setinde bulunan modellerden herhangi birine ait örnek tasarım Şekil 22’de görülmektedir.



Şekil 21. VS-3 Veri Seti için Oluşturulan M3 NARX Modeli Taslağı

M3 model setinde de yine Afyon Atık Su Arıtma Tesisi çıkışındaki numune alma noktasından alınan verilerle denerek bir sonuca gidilmeye çalışılmıştır.

Tablo 9. M3 NARX Model Seti Performansları

GKNS	ID	FD	MSE	İterasyon	Eğitim R ²	Validasyon R ²	Test R ²	Genel R ²
50	4:4:20	4:4:20	25,2677	8	0,649774	0,062118	0,045356	0,490042
50	4:4:40	4:4:40	22,4477	3	0,780498	0,658648	0,550188	0,642872
50	4:4:60	4:4:60	32,1875	4	0,711892	0,077894	0,051272	0,55216
50	4:4:80	4:4:80	39,1240	8	0,909092	0,170578	0,00493	0,707948
50	1:4	1:4	28,2112	8	0,70006	0,139026	0,23171	0,56202
50	1:8	1:8	32,9399	7	0,925854	0,015776	0,165648	0,637942
50	1:12	1:12	35,2326	8	0,909092	0,05423	0,259318	0,717808
50	1:16	1:16	15,9392	4	0,716822	0,391442	0,249458	0,62611
50	1:20	1:20	20,6069	3	0,564978	0,219878	0,381582	0,501874
50	1:40	1:40	19,9497	5	0,699074	0,19227	0,311576	0,60146
40	4:4:20	4:4:20	17,5424	7	0,66062	0,360876	0,348058	0,585684
40	4:4:40	4:4:40	16,3352	5	0,783456	0,757248	0,623152	0,708934
40	4:4:60	4:4:60	23,0734	8	0,592586	0,233682	0,224808	0,510748
40	4:4:80	4:4:80	24,0339	6	0,56695	0,149872	0,326366	0,477224
40	1:4	1:4	14,0028	4	0,728654	0,258332	0,248472	0,607376
40	1:8	1:8	11,4445	8	0,682312	0,30566	0,343128	0,58174
40	1:12	1:12	14,9410	3	0,619208	0,317492	0,388484	0,56202
40	1:16	1:16	13,0986	4	0,540328	0,388484	0,37961	0,505818
40	1:20	1:20	13,6346	8	0,574838	0,248472	0,343128	0,511734
40	1:40	1:40	18,3054	5	0,346086	0,189312	0,210018	0,309604
30	4:4:20	4:4:20	16,1999	6	0,722738	0,21692	0,281996	0,607376
30	4:4:40	4:4:40	11,6572	5	0,78247	0,745416	0,59653	0,721752
30	4:4:60	4:4:60	13,1853	6	0,588642	0,163676	0,314534	0,50286
30	4:4:80	4:4:80	16,0151	8	0,588642	0,237626	0,199172	0,510748
30	1:4	1:4	12,9061	4	0,64583	0,338198	0,296786	0,569908
30	1:8	1:8	14,7070	3	0,564978	0,33031	0,328338	0,513706
30	1:12	1:12	12,1593	5	0,570894	0,349044	0,35496	0,51765
30	1:16	1:16	13,2573	7	0,355946	0,194242	0,114376	0,314534
30	1:20	1:20	12,8765	3	0,708934	0,243542	0,376652	0,614278
30	1:40	1:40	13,0162	13	0,613292	0,196214	0,275094	0,52258
20	4:4:20	4:4:20	11,6590	5	0,834156	0,65076	0,6409	0,678368
20	4:4:40	4:4:40	7,6921	5	0,738368	0,764248	0,671844	0,710048
20	4:4:60	4:4:60	12,2185	3	0,834156	0,722738	0,398344	0,671466
20	4:4:80	4:4:80	11,7979	11	0,412148	0,199172	0,149872	0,352988
20	1:4	1:4	12,2285	6	0,653718	0,299744	0,282982	0,555118
20	1:8	1:8	11,5275	5	0,421022	0,326366	0,264248	0,385526
20	1:12	1:12	16,4894	5	0,41905	0,237626	0,278052	0,387498
20	1:16	1:16	13,6979	3	0,503846	0,286926	0,326366	0,461448
20	1:20	1:20	15,4190	4	0,441728	0,293828	0,213962	0,405246
20	1:40	1:40	13,1417	7	0,656676	0,349044	0,386512	0,5916
10	4:4:20	4:4:20	12,0081	10	0,848946	0,737528	0,592586	0,67541
10	4:4:40	4:4:40	6,5487	9	0,882019	0,845988	0,802189	0,814436

10	4:4:60	4:4:60	12,2547	5	0,809506	0,736542	0,5916	0,63104
10	4:4:80	4:4:80	11,8596	5	0,708934	0,204102	0,169592	0,574838
10	1:4	1:4	12,1746	6	0,784856	0,252416	0,159732	0,613292
10	1:8	1:8	11,3985	7	0,785842	0,373694	0,250444	0,66062
10	1:12	1:12	13,9271	3	0,681326	0,336226	0,334254	0,57188
10	1:16	1:16	11,1747	4	0,643858	0,22185	0,292842	0,554132
10	1:20	1:20	10,6569	4	0,707948	0,183396	0,367778	0,57681
10	1:40	1:40	12,3854	3	0,707948	0,23664	0,375666	0,612306

Tablo 9.'da görüldüğü üzere, burada da yine R^2 değerlerinin birbirine ve 1'e en yakın olan modellerin genel olarak "4:4:40" tipinde olduğu görülmektedir. Bu modeller içerisinde, yine en iyi performansı gizli katmanda 10 ve 20 nöron kullanan modellerin verdiği görülmektedir.

Burada test edilen M1 model setinde tatmin edici bir başarı oranı sağlanamamıştır. Bununla birlikte M2 ve M3 model setleri göz önüne alındığında, en başarılı sonuçları "4:4:40" gecikmelerini kullanan, gizli katmanlarında 10 ve 20 civarı nöron bulunduran modellerin verdiği görülmektedir. Sonuç olarak, M2 ve M3 model setindeki bu modellerin daha iyi sonuç verdiği gözlemlenmiştir.

Çalışmanın ilk üç aşamasında elde edilen sonuçlara göre, dördüncü aşamada kesin modeli oluşturabilmek için, M2 ve M3 model setlerinde başarı gösteren, girdi ve geri besleme için "4:4:40" gecikmelerine sahip NARX konfigürasyonu, sırasıyla tüm istasyonlarda, 9 girdi ve 2 girdi kullanacak şekilde gizli katmanındaki nöron sayıları 10 ve 20 arasında kalacak şekilde denenmiştir.

Tablo 10. 2 Girdili NARX Modeli Performans Çizelgesi

PS	İstasyon	GKNS	MSE	İterasyon	Eğitim R^2	Validasyon R^2	Test R^2	Genel R^2
2	Afyon AAT Sonrası	16	3,448637	6	0,7835643	0,7895592	0,8408312	0,7552267
2	Araplı Deresi	16	4,628434	4	0,8077213	0,6448144	0,5954454	0,7194152
2	Bolvadin Köprüsü	16	18,64139	4	0,8097919	0,6703715	0,6147809	0,7619216
2	Eber Gölü Kocakandırılık	16	2,812661	4	0,8303303	0,731257	0,6704997	0,7175812
2	Eber Gölü Ortası Donbay	16	18,48395	7	0,8139726	0,7130949	0,7586284	0,7632034
2	Eber Gölü Yalı Mevkii	16	3,800701	5	0,6765636	0,6915015	0,7266524	0,6790878
2	Eber Regülatörü	16	8,774025	4	0,7662403	0,7338699	0,6352108	0,6960766
2	Şeker Fabrikası Sonrası	16	9,981188	5	0,8226395	0,8529985	0,6570507	0,7137457

Gerçekleştirilen denemeler sonucunda gizli katmanda 16 nöron bulunduran modellerin diğer modellere göre daha başarılı performanslar ortaya koyduğu görülmüştür. Öncelikle, her

istasyonda “4:4:40” gecikme yapısına dayalı gizli katmanda 16 nöron bulunduran 2 girdili modellerin elde ettiği performanslar Tablo 10.’da verilmektedir.

Tablo 10.’da da görüldüğü üzere 2 girdili bu model, genel olarak ortalama %70 civarı tahminleme sonucuna sahiptir. Bunun yanı sıra Tablo 11’de görüldüğü üzere 9 girdili modelde ortalama %75 civarı genel başarı oranı yakalanmıştır.

Tablo 11. 9 Girdili NARX Modeli Performans Çizelgesi

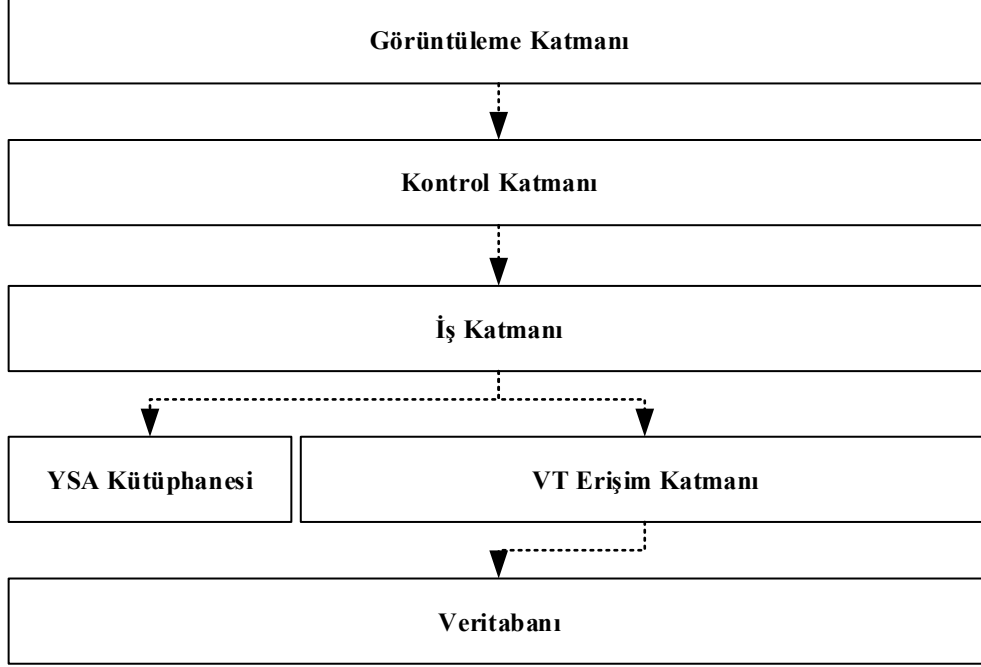
PS	İstasyon	GKNS	MSE	İterasyon	Eğitim R ²	Validasyon R ²	Test R ²	Genel R ²
9	Afyon AAT Sonrası	16	6,3543463	4	0,7387013	0,8025744	0,7926454	0,7588552
9	Araplı Deresi	16	4,6284336	4	0,7722549	0,7773032	0,807465	0,7773427
9	Bolvadin Köprüsü	16	19,346285	4	0,970648	0,773941	0,7618822	0,8569918
9	Eber Gölü Kocakandırılık	16	20,125312	3	0,961912	0,9380015	0,9707762	0,7782892
9	Eber Gölü Ortası Donbay	16	8,3159556	4	0,8387508	0,5496063	0,7966091	0,8051873
9	Eber Gölü Yalı Mevkii	16	3,3037464	4	0,8503067	0,7901705	0,7836038	0,8153727
9	Eber Regülatörü	16	8,2644293	3	0,7602356	0,7486304	0,7761003	0,7577016
9	Şeker Fabrikası Sonrası	16	3,7874824	4	0,7444892	0,8049507	0,7723141	0,7743452

Çalışmada, en başarılı modeller ortaya konulduğunda, çözülmüş oksijen değeri, sıcaklık parametresine oldukça bağımlı bir özellik göstermekte, yine “4:4:40” gecikmesine dayalı NARX modellerinde görüldüğü üzere, geçmiş 10 yıl öncesine kadar her yılda 4 defa ölçülen çözülmüş oksijen değerleri $t(x-4, x-8, \dots, x-40)$ dikkate alındığında kayda değer, güvenilir sonuçlar vermektedir. Yine çözülmüş oksijen değeri ve sıcaklığın yakından ilişkili olmasının yanı sıra, iki değişkenin mevsimsel bağımlılık gösterdiği de aşikardır. Böylelikle çözülmüş oksijenin hangi mevsim ve ayda ölçüldüğü parametreleri de hesaba katılarak, modelin yakınsaması arttırılmıştır.

4.6. Web Uygulaması

Çalışma kapsamında daha başarılı sonuçlar veren 4:4:40 gecikmesine sahip, girdi katmanında 9 nöron, gizli katmanda ise 16 nöron bulunduran NARX konfigürasyonu .NET platformuna aktararak, modelin kullanılabilirliği için bir web uygulaması geliştirilmiştir. Geliştirilen uygulamada kurgulanan NARX modeli, yazılım altyapısında kullanılarak, son kullanıcılar için kolaylıkla kullanılabilen bir ürün ortaya çıkartılmıştır.

Geliştirilen uygulama C# programlama diliyle, ASP.NET MVC 4.5 yazılım çerçevesi mimarisine uygun olarak tasarlanmıştır. MVC yaklaşımı doğrultusunda, uygulama katmanlara bölünerek, daha yönetilebilir ve kolaylıkla değiştirilebilir bir uygulama ortaya konulmuştur.




Şekil 22. Geliştirilen Web Uygulaması Mimarisi

Uygulama mimarisi kısaca anlatılacak olursa, Şekil 23.'de görüldüğü üzere yazılıma son kullanıcılar dışarıdan isteklerini görüntüleme katmanı aracılığıyla iletmektedirler. Görüntüleme katmanında alınan kullanıcı istekleri daha sonra kontrol katmanına iletilmektedir. Kontrol katmanı kendisine gelen istekleri işleyerek, burada ilgili işin gerçekleştirilmesi için isteği iş katmanına yönlendirmektedir. İş katmanı ilgili iş parçacığıyla ilgili kod bloğunu çağırarak, daha sonra Veritabanına erişim için model katmanını çağırılmaktadır.

YSA Kütüphanesi katmanında, MATLAB ortamında geliştirilen konfigüre edilebilir NARX yapısı, .NET çerçevesinde bir kütüphane dosyası olarak derlenerek yazılıma eklenmiştir. İş katmanı da ilgili bu YSA kütüphanesini çağırarak veri üzerinde gerekli işlem ve hesaplamaları yapmaktadır. Hesaplama sonucunda elde edilen değerler, tekrar kontrol katmanına gönderilerek, kullanıcıya gösterilmek için bu katman aracılığıyla ilgili arayüz görünümünün döndürülmesini sağlamaktadır.

SVT uygulaması ile geliştirilen uygulama arasında halihazırda herhangi bir entegrasyon veya işbirliği bulunmamaktadır. Burada Veritabanı katmanında, DSİ SVT uygulamasından alınan veriler, geliştirilen web uygulamasının kullandığı veritabanına aktarılarak bir çözüme gidilmiştir. Bu veritabanı modelinden kısaca bahsetmek gerekirse, Şekil 24.'de de görüleceği üzere yazılımın çalışması ile ilgili tablolar dışında basit şekliyle 4 ayrı tablo tasarlanmıştır.




Şekil 23. Web Uygulaması İçin Oluşturulan Veritabanı Modeli

İstasyon tablosunda, ölçüm alınan numune alma noktaları kaydedilmektedir. Burada istasyonu tanımlamak için bir ID (kimlik – identifier) bilgisinin yanı sıra, numune alma noktasının koordinatları ve numarası gibi çeşitli öznitelikleri tutulmaktadır.

Yine kullanılan parametreler için bir parametre tablosu tanımlanmaktadır. Burada da parametrenin, adı, kısaltması ve birimi öznitelikleri ilgili tabloda tutulmaktadır. Şekil 24.'de de görüleceği üzere, bu iki tabloyu birleştiren ortak bir “Ölçüm” tablosu bulunmaktadır. Buradaki “Ölçüm” tablosunda, hangi parametrenin hangi numune alma noktasında ne zaman ve ne kadar ölçüldüğü bilgisi yer almaktadır. Yine “AcvtFunction” tablosunda, kullanıcının


kullanılabilecek aktivasyon fonksiyonlarını seçebilmesi için, ilgili aktivasyon fonksiyonun adını ve kimlik bilgisini tutan bir tablo bulunmaktadır.

Uygulama görüntüleme katmanında, Coğrafi Bilgi Sistemleri (CBS) tabanlı olarak geliştirilmiş olup, ilk açılış ekranında fiziki harita üzerinde Akarçay Havzası üzerinde bu çalışma kapsamında kullanılan numune alma noktaları görülmektedir. Uygulama ilk açıldığında ekran Şekil 25.'de verilmektedir.



Şekil 24. Web Uygulaması Açılış Ekranı

Harita üzerinde mouse ile üzerine gelinen numune alma noktası mavi renkten yeşile dönmektedir. Burada numune alma noktası üzerine tıklandığında ilgili numune alma noktasında belirli bir parametreye ait ölçüm değerleri Şekil 26.'daki gibi ekrana gelmektedir.



Şekil 25. Numune Alma Noktasına Ait Ekran

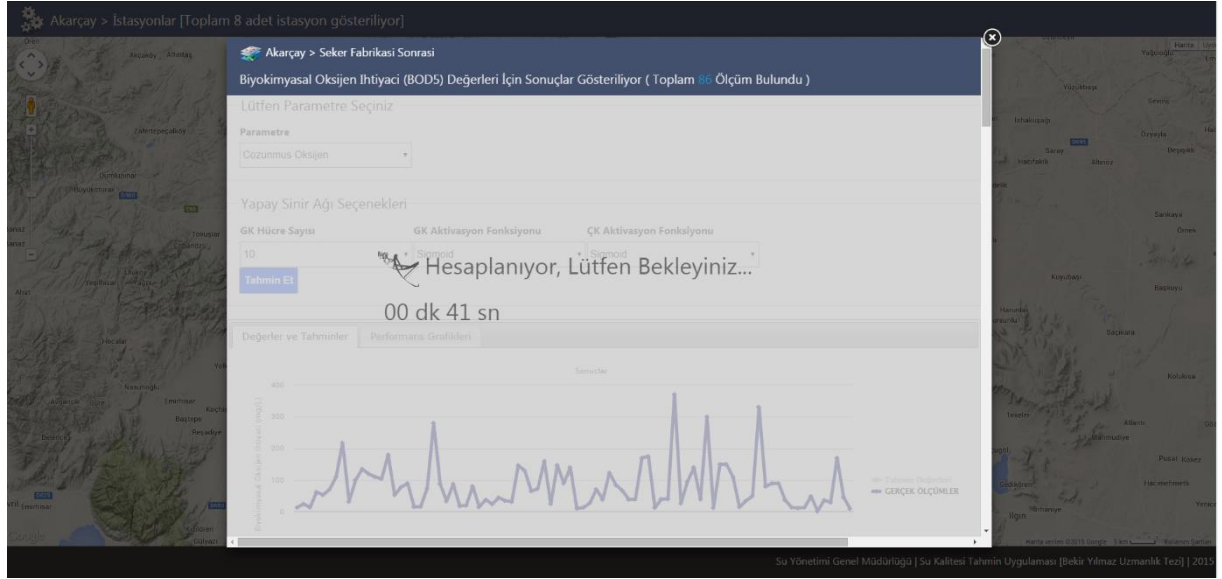
Burada numune alma noktasında ölçülen parametrenin seçilebileceği bir menünün yanı sıra, YSA ile hesaplamalar için Gizli Katman Hücre Sayısı'nı belirleyebileceği bir açılır menünün yanı sıra, gizli katmanda ve çıkış katmanında aktivasyon fonksiyonlarını belirleyebileceği seçenekler sunulmaktadır.

Uygulamada burada ortaya konulan sabit NARX modelinden ziyade, gizli katmanda hücre sayısı, aktivasyon fonksiyonu ve çıkış katmanında atkivasyon fonksiyonunu değiştirebileceği daha esnek ve konfigüre edilebilir bir YSA tabanlı KDS yaklaşımı benimsenmiştir. Böylece kullanıcının farklı ve çeşitli NARX modelleriyle, söz konusu belirli NARX parametrelerini değiştirerek, farklı modellerin ortaya koyduğu tahminlerden yararlanabilmesi amaçlanmıştır.

Yine buradaki ekranda, ekran ilk açıldığında kullanıcıya seçtiği parametrenin zamanla aldığı değerleri ekranda görebileceği bir zaman-değer grafiği gösterilmektedir. Zaman-değer grafiği üzerinde mavi çizgi seçilen parametrenin ilgili numune alma noktasında daha önce ölçülen gerçek değerlerinin grafiğini göstermektedir.

Uygulamada kullanıcı öncelikle hesaplanmasını istediği parametreyi seçerek, daha sonra gizli katmanda kullanacağı hücre sayısını, gizli ve çıkış katmanlarında kullanacağı aktivasyon fonksiyonlarını belirleyerek ekranda mavi olarak gösterilen “Tahmin Et” butonuna tıklamaktadır.

Kullanıcı YSA ile ilgili parametreleri belirledikten sonra, kullanıcının isteği işlenirken Şekil 27.'de görüldüğü üzere, kullanıcıya geri bildirimde bulunmaktadır. Burada YSA modellerinde özellikle gizli katman hücre sayısı artırıldığında işlem süresi uzamaktadır. Model karmaşıklığı arttıkça hesaplama süresi artmakta, bu durumda da kullanıcıya ekran üzerinde geri bildirim zorunlu kılmaktadır.




Şekil 26. Hesaplama Geri Bildirim Ekranı

Kullanıcı YSA ile ilgili parametreleri belirledikten sonra, kullanıcının isteği işlenirken Şekil 27.'de görüldüğü üzere, kullanıcıya geri bildirimde bulunmaktadır. Burada YSA modellerinde özellikle gizli katman hücre sayısı artırıldığında işlem süresi uzamaktadır. Model karmaşıklığı arttıkça hesaplama süresi artmakta, bu durumda da kullanıcıya ekran üzerinde geri bildirim zorunlu kılmaktadır.

Geliştirilen sistem, belirli bir zamandan sonra girilen NARX modeliyle tahminde bulunmaktadır. Seçilen numune alma noktasında daha önce ölçülen parametre ölçüm değerleri kullanılarak, NARX-DP modeli eğitilmekte daha sonra, belirli bir zamandan sonra tahmin edilmektedir.

Şekil 28.'de görülebileceği üzere, kullanıcıya hesaplamadan daha sonra gerçek değerlerle birlikte tahmin değerleri de gösterilmektedir. Burada kullanıcıya gösterilen grafik güncellenerek, gerçek ölçüm değerlerinin yanı sıra tahmin değerleri de gösterilmektedir.


Kullanıcı buradaki grafik üzerinde, iki değeri de üstüste çakışık şekilde görerek modelin ortaya koyduğu performansı somut olarak izleyebilmektedir.



Şekil 27. Hesaplama Çıktıları Ekranı

Şekil 28.'deki ekrandaki grafikte görülen yeşil çizgi NARX modelinin tahmin ettiği değerleri, mavi çizgi ise seçilen numune alma noktasındaki gerçek ölçüm değerlerini göstermektedir. Yine görülen örnek çıktıda, gizli katmanda 10 adet hücre bulunduran, gizli ve çıkış katmanında sigmoid aktivasyon fonksiyonu kullanan bir NARX modeli için hesaplama değerleri görüntülenmektedir.


Şekil 28.'de görüldüğü üzere geliştirilen web uygulamasında, NARX modeli ölçümlerde belirli bir tarihten sonraki ölçümleri tahmin etmektedir. Bu şekilde modelin performansı görsel olarak daha iyi değerlendirilebilmektedir.



Şekil 28. Web Uygulaması Tahmin Grafiği


4.7. Uygulama Çıktıları

Bu bölümde geliştirilen başarılı NARX modelinin Web uygulamasındaki tahmin sonuçları verilmektedir. Burada Akarçay Havzası'nda seçilen numune alma noktaları sırasıyla gösterilmektedir. İlk olarak Şekil 29.'da Araplı Deresi'nde Çözünmüş Oksijen değerini tahmin eden NARX modeliyle geliştirilen uygulama çıktısı görülmektedir.



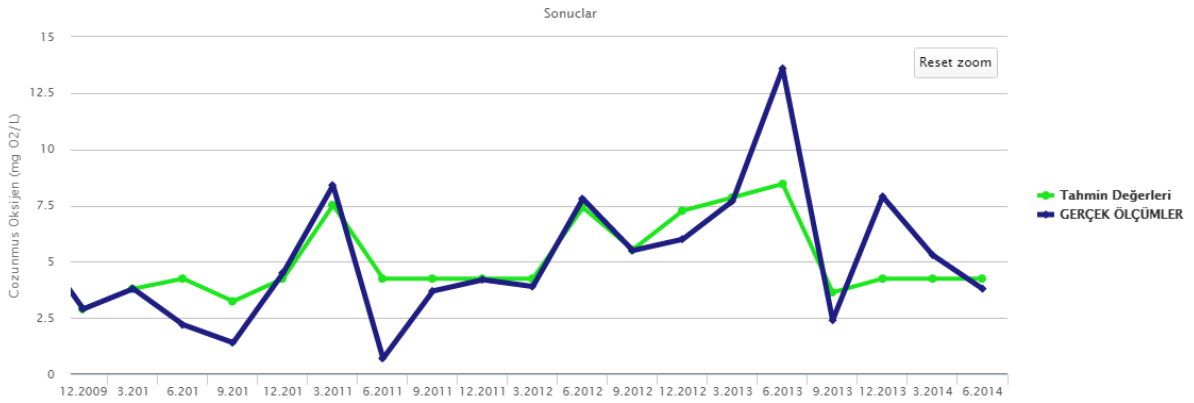
Şekil 29. Araplı Deresi Numune Alma Noktasında Tahmin Sonuçları

Şekil 30.'da ise Afyon Atıksu Arıtma Tesisi Çıkışı'nda Çözünmüş Oksijen değerini tahmin eden NARX modeliyle geliştirilen uygulama çıktısı görülmektedir.




Şekil 30. Afyon Atıksu Arıtma Tesisi Çıkışı Numune Alma Noktasında Tahmin Sonuçları

Şekil 31.'de Şeker Fabrikası Sonrası numune alma noktasında kurgulanan modelin Çözünmüş Oksijen değerini tahmin sonuçları görülmektedir.




Şekil 31. Şeker Fabrikası Sonrası Numune Alma Noktasında Tahmin Sonuçları

Şekil 32'de Bolvadin Köprüsü'nde modelin Çözünmüş Oksijen değerini tahmin sonuçları görülmektedir.




Şekil 32. Bolvadin Köprüsü Numune Alma Noktasında Tahmin Sonuçları

Şekil 33’de ise Eber Gölü Yalı Mevkii numune alma noktasında modelin Çözünmüş Oksijen değerini tahmin sonuçları görülmektedir.




Şekil 33. Eber Gölü Yalı Mevkii Numune Alma Noktasında Tahmin Sonuçları

Şekil 34’de Eber Gölü Donbay numune alma noktasında modelin Çözünmüş Oksijen değerini tahmin sonuçları görülmektedir.




Şekil 34. Eber Gölü Donbay Numune Alma Noktasında Tahmin Sonuçları

Şekil 35’de ise Eber Gölü Kocakandıralık numune alma noktasında modelin Çözünmüş Oksijen değerini tahmin sonuçları görülmektedir.



Şekil 35. Eber Gölü Kocakandıralık Numune Alma Noktasında Tahmin Sonuçları

Şekil 36’da Eber Regülatörü numune alma noktasında modelin Çözünmüş Oksijen değerini tahmin sonuçları görülmektedir.



Şekil 36. Eber Regülatörü Numune Alma Noktasında Tahmin Sonuçları

5. SONUÇLAR ve ÖNERİLER

Bu çalışma, Akarçay havzasında çözünmüş oksijen değerlerinin yapay sinir ağları ile belirlenmesi amacıyla yapılmıştır. Çözünmüş oksijen değeri, belirli bir “t” zamanda diğer değişkenlerin “t” zamanındaki değerleri ve bu zamandan daha önceki değerleri de hesaba katılarak, temel NARX ağı mimarisi üzerine oluşturulan mümkün olan en basit mimari ile tahmin edilmeye çalışılmıştır.

Çalışma kapsamında ilk olarak, en basit ve en performanslı modeli bulabilmek için Afyon Atıksu Arıtma Tesisi Çıkışı Numune alma noktasında, giriş katmanında sırasıyla 34, 9 ve 2 nöron bulunduran temel NARX Ağı tabanlı yapılara ait çeşitli konfigürasyonlar kullanılarak, çözünmüş oksijen konsantrasyonu tahmin edilmeye çalışılmıştır.

En iyi sonuçlar girdi katmanında 9 nörona sahip ve gizli katmanda 16 nörona sahip, 4:4:40 şeklinde girdi ve geribesleme gecikmesine sahip NARX konfigürasyonunda elde edilmiştir. Ortaya konulan model, daha sonra tek tek diğer numune alma noktalarında da çalıştırılarak, çözünmüş oksijeni tahmin etme başarısı ortalama %75 olarak bulunmuştur.

Çalışmada kullanılan çözünmüş oksijen değeri, yalnızca diğer parametrelerin değerleri alınarak tahmin edilmemiş, aynı zamanda aynı mevsimdeki geçmiş çözünmüş oksijen değerleri de zaman serisi olarak ele alınarak, problemin çözümünde hibrit bir yaklaşım ortaya konulmuştur.

Geliştirilen NARX modelinin sadece Akarçay Havzası’nda değil, ülkemizin diğer havzalarında da çözünmüş oksijen değerlerinin tahmininde, yapay zeka tabanlı bir öngörü mekanizması oluşturulmasına yardımcı olabileceği düşünülmektedir.

Bu çalışmada ortaya konulan model ve yaklaşım, temelde su kalitesinin mevcut durumda öngörülebilmesi konusunda güçlü istatistiksel yöntemlerle desteklenmiş, zamanla öğrenebilen ve daha iyi sonuçlar üretebilen, yapay zeka tabanlı karar destek sistemlerine altlık oluşturulabilecektir.

Bununla birlikte çalışmada ortaya konulan ölçümlerde zaman serisi özelliğini de dahil eden hibrit yaklaşım, diğer su kalitesi parametreleri için de ilişkili oldukları parametrelerle birlikte kullanılabilir.

Bu çalışmada geliştirilen model, KDS'lerde öngörü yeteneğinin yanı sıra, saha çalışmasından gelen verilerin doğruluğunun ve geçerliliğinin değerlendirilmesinde de kullanılabilir. Böylece çalışılan numune alma noktalarında, daha güçlü ve düzenli bir kontrol mekanizması otomasyonuna yardımcı olabilecektir. Böylece havzada herhangi bir müdahale olmaması durumunda, parametre bazında ilerde alınabilecek tedbirler öngörülebilir.

Sadece çözülmüş oksijen değeri için değil, diğer su kalitesi parametreleri için de temel NARX modeline dayalı YSA'lar kullanılarak, tahmin modelleri oluşturulabilir. Buradaki çalışma kapsamında kullanılan NARX modeli istatistiksel modellerle durağanlık, mevsimsellik ve kaotik zaman serileri analizleri ile geliştirilerek, bütün hidromorfolojik, biyolojik ve kimyasal parametreler modele dahil edildiği takdirde, söz konusu istatistiksel modellerle birlikte, suyun genel ekolojisi hakkında daha kapsamlı ve detaylı sonuç veren çalışmalar ve modelleme çerçeveleri gerçekleştirilebilir.

Bu çalışmada NARX modelinin temel varsayılan özellikleri değiştirilmeden yapılan sunulan modeller üzerinde değiştirmeler yapılarak daha yüksek doğruluklu ve kesin sonuçlar bulunabilir. NARX'de temel olarak kullanılan Levenberg-Marquardt Algoritması yerine alternatif öğrenme algoritmalarını kullanılabileceği gibi, gizli ve çıkış katmanlarda sigmoid ve doğrusal (lineer) aktivasyon fonksiyonları yerine, burada bahsedilen diğer aktivasyon fonksiyonları da kullanarak, daha iyi sonuçlar verebilecek NARX modelleri oluşturulabilir.

Bu çalışmadaki YSA modelinin performansı, zaman serileri analizinde sıklıkla kullanılan ARIMA vb. istatistiksel yöntemler ve Destek Vektör Regresyonu (DVR) gibi diğer yapay zeka yöntemleriyle de birleştirilerek, su kalitesi ölçümlerinin gelecekte tahmini konusunda, daha güçlü kompozit modeller oluşturulabilir.

Yine su kalitesi parametrelerine ait zaman serilerinin tahmininde, regresyon tabanlı yapay sinir ağları modelleri ile sonuçlar alabilmek için gelecek çalışmalarda NARX'in yanı sıra, Çarpımsal Birimli Yapay Sinir Ağları (PUNN – Product Unit Neural Networks) da kullanılabilir [58]. Burada iki modelin birleştirilmesiyle ortaya konulan hibrit yaklaşımlarla daha karmaşık yapıda ve yüksek doğruluk sonuç veren modeller ortaya konulabilir.

Bununla birlikte çözünmüş oksijenin yanı sıra, biyolojik oksijen ihtiyacı ve kimyasal oksijen ihtiyacı gibi parametrelerin modellenmesinde de, benzer parametreler kullanılarak, NARX mimarileriyle tahminde bulunan modeller geliştirilebilir.

6. KAYNAKLAR

- [1] «Orsam Su Arařtırmaları Programı,» [Çevrimiçi]. : <http://www.orsam.org.tr/tr/SuKaynaklari/MerakEdilenler.aspx?SoruID=2>.
- [2] «çevreonline,» [Çevrimiçi]. : <http://cevreonline.com/su.htm>.
- [3] DSİ Genel Müdürlüğü, «Toprak ve Su Kaynakları,» [Çevrimiçi]. : <http://www.dsi.gov.tr/toprak-ve-su-kaynaklari>. [Eriřildi: 1 Nisan 2015].
- [4] İ. Yüksel, M. Sandalcı, G. Çeribaşı ve Ö. Yüksek, «Küresel Isınma ve İklim Deęişiklięinin Su Kaynaklarına Etkileri,» %1 içinde 7. *Kıyı Mühendislięi Sempozyumu*, Trabzon, 2011.
- [5] Türkiye Halk Saęlığı Kurumu, «Fiziksel Çevrenin Geliřtirilmesi,» T.C. Saęlık Bakanlıęı, Ankara, 2014.
- [6] Devlet Planlama Teřkilatı, «Toprak ve Su Kaynaklarının Kullanımı ve Yönetimi,» T.C. Bařbakanlık, Ankara, 2007.
- [7] E. Tümer, A. Birinci ve Ç. Yıldırım, «Ambalajlı Su Tüketimini Etkileyen Faktörlerin Belirlenmesi: Ankara İli Keçiören İlçesi Örneęi,» *Alinteri*, pp. 11-19, 2011.
- [8] WSSD, «World Summit on Sustainable Development,» WSSD, Johannesburg, 2002.
- [9] D. Orhon, S. Sözen, B. Üstün, E. Görgün ve Ö. Karahan Gül, «Su Yönetimi ve Sürdürülebilir Kalkınma,» *Vizyon 2023: Bilim ve Teknoloji Stratejileri Çevre ve Sürdürülebilir Kalkınma Paneli*, İstanbul, 2002.
- [10] WWF Türkiye, «Eęirdir Gölü'nde Kirlilik Durumu ve Kirlilik Kaynakları Modelleme Çalıřması Raporu,» Doğal Hayatı Koruma Vakfı, İstanbul, 2013.
- [11] ř. Korkut, «Su Kalitesi Yönetimi Ders Notları,» Bülent Ecevit Üniversitesi, Zonguldak, 2012.
- [12] N. Harmancıoęlu, A. Gül ve O. Fıstıkoęlu, «Entegre Su Kaynakları Yönetimi,» *Türkiye Mühendislik Haberleri*, cilt 3, no. 419, pp. 29-39, 2002.
- [13] Türkiye Biliřim Derneęi, «KAMUDA KARAR DESTEK SİSTEMLERİNİN KULLANIMI VE BİR MODEL ÖNERİSİ,» Türkiye Biliřim Derneęi, Ankara, 2010.
- [14] O. Varıs, M. M. Rahaman ve T. Kajander, «EU Water Framework Directive vs. Integrated Water Resources Management: The Seven Mismatches,» *Water Resources Development*, cilt 20, no. 4, pp. 565-575, 2004.
- [15] Mevzuat Geliřtirme ve Yayın Genel Müdürlüğü, «Su Kirlilięi Kontrol Yönetmelięi,» 31 Aralık 2004. [Çevrimiçi]. : <http://www.mevzuat.gov.tr/Metin.aspx?MevzuatKod=7.5.7221&sourceXmlSearch=&MevzuatIliski=0>. [Eriřildi: 1 Nisan 2014].
- [16] Resmi Gazete, «Yerüstü Su Kalitesi Yönetimi Yönetmelięi,» 30 Kasım 2012. [Çevrimiçi]. :

- <http://www.resmigazete.gov.tr/eskiler/2012/11/20121130-5.htm>. [Erişildi: 1 Nisan 2015].
- [17] D. Boztuğ, T. Dere, N. Tayhan ve N. Yıldırım, «Uzunçayır Baraj Gölü (Tunceli) Fiziko-Kimyasal Özellikleri ve Su Kalitesinin Değerlendirilmesi,» *Fen Bilimleri Dergisi*, cilt 2, no. 2, pp. 93-106, 2012.
- [18] Erciyes Üniversitesi Çevre Mühendisliği Bölümü, «Çevre Kimyası Laboratuvarı Dersi pH,İletkenlik,Çözünmüş Oksijen, Sıcaklık, TDS ve Bulanıklık Tayini Ders Notları,» Şubat 2014. [Çevrimiçi]. : <http://cevre.erciyes.edu.tr/dosyalar/dokumanlar/%C3%87KL%20Yeni/Fiziksel%20%C3%96l%C3%A7%C3%BCm%20Y%C3%B6ntemleri.pdf>. [Erişildi: 1 Nisan 2015].
- [19] İstanbul Ticaret Odası Etüt ve Araştırma Şubesi, Mayıs 2004. [Çevrimiçi]. : <http://www.ito.org.tr/Dokuman/Sektor/1-44.pdf>. [Erişildi: 1 Nisan 2015].
- [20] M. E. Bakanlığı, «Çevre Sağlığı, Suları Analiz Parametreleri,» 2011. [Çevrimiçi]. : http://www.megep.meb.gov.tr/mte_program_modul/moduller_pdf/Sular%C4%B1n%20Analiz%20Parametreleri.pdf. [Erişildi: 1 Nisan 2015].
- [21] V. Eroğlu, Su Tasfiyesi, Ankara: Orman ve Su İşleri Bakanlığı, 2008.
- [22] Proses Mühendislik, «Su Kimyası,» [Çevrimiçi]. : <http://www.proses-tim.com/medya/su-kimyası.pdf>. [Erişildi: 1 Nisan 2015].
- [23] Y. Karaaslan, *Mogan Gölü'nün Kirletici Özümlene Kapasitesinin Model ile Değerlendirilmesi*, İstanbul: Doktora Tezi, 2009.
- [24] O. Özkan, C. Kınacı ve Ş. Sağiroğlu, «Çözünmüş Oksijen Değişiminin Yapay Sinir Ağları ile Belirlenmesi: Kızılırmak Nehri Örneği,» *İTÜ Mühendislik Dergisi*, cilt 5, no. 3, pp. 30-38, 2006.
- [25] Ç. Elmas, Yapay Zeka Uygulamaları, Ankara: Seçkin Yayıncılık, 2011.
- [26] A. Uğur, «Günlük Yaşamda Yapay Zeka,» 2008. [Çevrimiçi]. : http://yzgrafik.ege.edu.tr/~ugur/09_10_Fall/AI/AI_2009_DERS_1.pdf. [Erişildi: 3 Mart 2015].
- [27] İ. Çayıroğlu, «İleri Algoritma Analizi Ders Notları,» [Çevrimiçi]. : <http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf>. [Erişildi: 1 Nisan 2015].
- [28] P. Sıby, S. Jones ve P. Siddarth, «Analysis of Different Activation Functions Using Back Propagation Neural Networks,» *Journal of Theoretical and Applied Information Technology*, cilt 47, no. 3, pp. 1264-1268, 2013.
- [29] B. Karlık ve A. V. Olgaç, «Performance Analysis of Various Activation Functions in Generalized MLP Architectures of Neural Networks,» *International Journal of Artificial Intelligence and Expert Systems*, cilt 1, no. 4, pp. 111-122, 2011.

- [30] S. Balaji ve K. Baskaran, «Design And Development Of Artificial Neural Networking (Ann) System Using Sigmoid Activation Function To Predict Annual Rice Production In Tamilnadu,» *International Journal of Computer Science, Engineering and Information Technology*, cilt 3, no. 1, pp. 13-31, 2013.
- [31] H. Budak ve S. Erpolat, «Kredi Risk Tahmininde Yapay Sinir Ağları ve Lojistik Regresyon Analizi Karşılaştırılması,» *Online Academic Journal of Information Technology*, cilt 3, no. 9, pp. 23-30, 2012.
- [32] M. Çuhadar ve C. Kayacan, «Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme,» *Anatolia: Turizm Araştırmaları Dergisi*, cilt 16, no. 1, pp. 24-30, 2005.
- [33] S. Yavuz ve M. Deveci, «İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağı Performansına Etkisi,» *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi De*, no. 40, pp. 167-187, 2012.
- [34] Ö. Asilkan ve S. Irmak, «İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi,» *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, cilt 14, no. 2, pp. 375-391, 2009.
- [35] R. Bayındır ve Ö. Sesveren, «Ysa Tabanlı Sistemler İçin Görsel Bir Arayüz Tasarımı,» *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, cilt 14, no. 1, pp. 101-109, 2008.
- [36] H. Zorlu ve Ş. Özer, «Myriad Filtrelerin Yapay Sinir Ağları ile Kimliklendirilmesi,» %1 içinde *Ursi (Union Radio Science Internationale) Türkiye Ulusal Kongresi*, Ankara, 2004.
- [37] A. K. Baltacıoğlu, Ö. Civalek, B. Akgöz ve A. Korkmaz, «Deprem Hasarlarının Hızlı Tespitinde Yapay Sinir Ağları Yaklaşımı,» *Süleyman Demirel Üniversitesi Mühendislik Bilimleri ve Tasarım Dergisi*, cilt 1, no. 1, pp. 22-27, 2010.
- [38] G. Sarıman, «Veri Madenciliğinde Kümeleme Teknikleri Üzerine Bir Çalışma: K-Means ve K-Medoids Kümeleme Algoritmalarının Karşılaştırılması,» *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, cilt 15, no. 3, pp. 192-202, 2011.
- [39] C. Lin ve G. Lee, *Neural Fuzzy Systems*, Prentice Hall, 1996, pp. 236-239.
- [40] D. F. Gordon ve M. Desjardins, «Evaluation and Selection of Biases in Machine Learning,» *Machine Learning*, cilt 20, pp. 5-22, 1995.
- [41] B. M. Wilamowski ve Y. Chen, «Efficient Algorithm for Training Neural Networks With One Hidden Layer,» %1 içinde *Proceedings of the International Joint Conference on Neural Networks*, 1999.
- [42] M. A. Çavuşlu, Y. Becerikli ve C. Karakuzu, «Levenberg-Marquardt Algoritması ile YSA Eğitiminin Donanımsal Gerçeklenmesi,» *Türkiye Bilişim Vakfı Bilgisayar Bilimleri ve*

Mühendisliği Dergisi, cilt 5, no. 5, 2012.

- [43] Z. B. Güven ve T. T. Bilgin, «Zaman Serileri Madenciligi Kullanılarak Nüfus Artışı Tahmin Uygulaması,» %1 içinde *Akademik Bilişim 2014 Konferansı*, Mersin, 2014.
- [44] «Regresyon Analizi,» Vikipedi, [Çevrimiçi]. : http://tr.wikipedia.org/wiki/Regresyon_analizi. [Erişildi: 24 Mart 2015].
- [45] O. Yıldız, *Makine Öğrenmesi Ders Notları*, Ankara, 2013, p. 43.
- [46] J. M. Menezes Jr. ve G. A. Barreto, «Long-term time series prediction with the NARX Network: An Empirical Evaluation,» *Neurocomputing*, cilt 71, pp. 3335-3343, 2008.
- [47] E. Pisoni, F. Marcello, C. Carnevale ve L. Piroddi, «Forecasting peak air pollution levels using NARX models,» *Engineering Applications of Artificial Intelligence*, cilt 22, pp. 593-602, 2009.
- [48] H. T. Siegelmann, B. G. Horne ve C. L. Giles, «Computational Capabilities of Recurrent Neural Networks,» *IEEE Transactions on Systems, Man and Cybernetics*, cilt 27, no. 2, pp. 208-215, 1997.
- [49] Y. K. Benli ve A. Yıldız, «Altın Fiyatının Yapay Sinir Ağları ve Zaman Serisi Yöntemleriyle Öngörüsü,» %1 içinde *16. Finans Sempozyumu*, Erzurum, 2012.
- [50] E. Yakut, B. Elmas ve S. Yavuz, «Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini,» *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, cilt 19, no. 1, pp. 139-157, 2014.
- [51] M. Çuhadar, İ. Güngör ve A. Göksu, «Turizm Talebinin Yapay Sinir Ağları İle Tahmini Ve Zaman Serisi Yöntemleri İle Karşılaştırılmalı Analizi Antalya İline Yönelik Uygulama,» *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, cilt 14, no. 1, pp. 99-114, 2009.
- [52] H. Türkmenler, M. Pala, R. Can ve N. Çağlar, «Yapay Sinir Ağı Modeli Kullanılarak İleri Biyolojik Atıksu Arıtma Tesislerinde Kimyasal Oksijen İhtiyacı Çıkış Konsantrasyonlarının Tahmini,» %1 içinde *2nd International Symposium On Environment And Morality*, Adıyaman, 2014.
- [53] E. Doğan, S. Işık ve M. Sandalcı, «Günlük Buharlaşmanın Yapay Sinir Ağları Kullanarak Tahmin Edilmesi,» *İMO Teknik Dergi*, pp. 4119-4131, 2007.
- [54] H. Subaşı, «Yapay Sinir Ağı ile Atıksu Arıtma Performansının Modellenmesi Yüksek Lisans Tezi,» Çukurova Üniversitesi, Adana, 2010.
- [55] E. Kıvrak, A. Uygun ve H. Kalyoncu, «Akarçay'ın (Afyonkarahisar, Türkiye) Su Kalitesini Değerlendirmek için Diyatome İndekslerinin Kullanılması,» *Afyon Kocatepe Üniversitesi Fen Bilimleri Dergisi*, cilt 12, pp. 27-38, 2012.

- [56] M. Ş. Dođdu ve S. C. Bayarı, «Akarçay Havzasında (Afyon) jeotermal kökenli kirlenme: 1. Akarçay Nehrinde su ve sediman kirliliđi,» *Hacettepe Üniversitesi Yerbilimleri Uygulama ve Araştırma Merkezi Bülteni*, cilt 25, pp. 21-33, 2002.
- [57] G. Küçükkocaođlu, Y. Benli ve C. Küçüksözen, «Finansal Bilgi Manpülasyonunun Tespitinde Yapay Sinir Ađı Modelinin Kullanımı,» *İMKB Dergisi*, cilt 9, no. 36, pp. 1-22, 1997.
- [58] A. Martinez-Estudillo, F. Martinez-Estudillo, C. Hervas-Martinez ve N. Garcia-Pedrajas, «Evolutionary product unit based neural networks for regression,» *Neural Networks*, no. 19, pp. 477-486, 2006.

EK: Uygulama Kaynak Kodları

% Burada geliştirilen kod aşağıdaki değişkenlerin önceden tanımlandığını varsaymaktadır

% inputs_CozunmusOksijen_inputs – girdi dizisi

% outputs_CozunmusOksijen_outputs – çıktı dizisi

inputSeries = inputs_CozunmusOksijen_inputs;

targetSeries = outputs_CozunmusOksijen_outputs;

% NARX Modeli

inputDelays = [4:4:40]; %Giriş Gecikmeleri

feedbackDelays = [4:4:40]; %Geri Besleme Gecikmeleri

hiddenLayerSize = 16; %Gizli Katman Nöron Sayısı

net = narxnet(inputDelays,feedbackDelays,hiddenLayerSize); %NARX Ağı Oluşturma

% Giriş ve Geri Besleme için ön işleme ve işleme fonksiyonlarının seçimi

% Settings for feedback input are automatically applied to feedback output

net.inputs{1}.processFcns = {'removeconstantrows','fixunknowns','mapminmax'};

net.inputs{2}.processFcns = {'removeconstantrows','fixunknowns','mapminmax'};

% Eğitim ve simülasyon için verinin hazırlanması

[inputs,inputStates,layerStates,targets] = preparets(net,inputSeries,{},targetSeries);

% Verinin eğitim, validasyon ve test için bölümlendirilmesi

net.divideFcn = 'divideblock';

net.divideMode = 'time';

```
net.divideParam.trainRatio = 70/100;

net.divideParam.valRatio = 15/100;

net.divideParam.testRatio = 15/100;

% Varsayılan NARX Öğrenme Metodu

net.trainFcn = 'trainlm'; % Levenberg-Marquardt

% Ortalama karekök hatası

net.performFcn = 'mse'; % Mean squared error

% Ağın eğitilmesi

[net,tr] = train(net,inputs,targets,inputStates,layerStates);

% Ağın test edilmesi

outputs = net(inputs,inputStates,layerStates);

errors = gsubtract(targets,outputs);

performance = perform(net,targets,outputs)

% Performansların tekrar hesaplanması

trainTargets = gmultiply(targets,tr.trainMask);

valTargets = gmultiply(targets,tr.valMask);

testTargets = gmultiply(targets,tr.testMask);

trainPerformance = perform(net,trainTargets,outputs)

valPerformance = perform(net,valTargets,outputs)
```



```
testPerformance = perform(net,testTargets,outputs)
```

```
% Oluşturulan ağıın görüntülenmesi
```

```
view(net)
```

ÖZGEÇMİŞ

Doğum Tarihi 06.09.1984

Eğitim Durumu **Yüksek Lisans**

Bilgisayar Bilimleri

Gazi Üniversitesi (2012-...)

Lisans

Bilgisayar Mühendisliği

Eskişehir Osmangazi Üniversitesi (2004-2008)

İş Deneyimi **Su Yönetimi Genel Müdürlüğü / Yenimahalle-Ankara**

Uzman Yardımcısı (2012-...)

Ptt AŞ Genel Müdürlüğü / Ulus-Ankara

Mühendis (2009-2012)

Inveon Bilgi Teknolojileri / Akatlar-İstanbul

Yazılım Geliştirme Uzmanı (2008-2009)

Yabancı Dil İngilizce (İyi)

Almanca (Başlangıç)

Sertifikalar IBM Yazılım Akademisi 2008