

**T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİR ATIKSU ARITMA TESİSİNİN GİRİŞİNDEKİ
BİYOLOJİK OKSİJEN İHTİYACININ YAPAY SINIR
AĞLARI KULLANILARAK MODELLENMESİ**

YÜKSEK LİSANS TEZİ

Çevre Müh. Ece Ceren YILMAZ

Enstitü Anabilim Dalı : ÇEVRE MÜH.

Tez Danışmanı : Yrd.Doç.Dr. Asude ATEŞ

Haziran 2009

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**BİR ATIKSU ARITMA TESİSİNİN GİRİŞİNDEKİ
BİYOLOJİK OKSİJEN İHTİYACININ YAPAY SINIR
AĞLARI KULLANILARAK MODELLENMESİ**

YÜKSEK LİSANS TEZİ

Çevre Müh. Ece Ceren YILMAZ

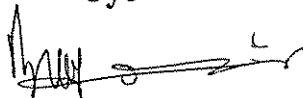
Enstitü Anabilim Dalı : ÇEVRE MÜH.

Bu tez 22/06/2009 tarihinde aşağıdaki jüri tarafından Oybirliği ile kabul edilmiştir.

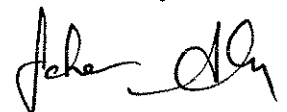
**Yrd.Doç.Dr.
Asude ATEŞ
Jüri Başkanı**



**Prof.Dr.
Bülent ŞENGÖRÜR
Üye**



**Yrd.Doç.Dr.
Seher ASLANKAYA
Üye**



TEŐEKKÜR

Ülkemizde yeteri kadar uygulaması bulunmayan yapay sinir ađları metotları kullanılarak bir atıksu arıtma tesisinin girişindeki biyolojik oksijen ihtiyacının modellenmesi yapılmıştır.

Tez çalışmam sırasında yardım ve desteđini esirgemeyen, Hocam Sayın Yrd.Doç. Dr. Asude Ateş'e ve yaptığım çalışmaya çok önemli katkıları olan Sayın Yrd.Doç.Dr. Emrah DOĐAN'a sonsuz teşekkürlerimi bir borç bilirim. Bütün eğitim hayatım boyunca benden ilgi, bilgi ve desteklerini esirgemeyen aileme teşekkür ederim.

Ece Ceren YILMAZ

İÇİNDEKİLER

TEŞEKKÜR.....	ii
İÇİNDEKİLER.....	iii
SİMGELER VE KISALTMALAR LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
TABLOLAR LİSTESİ.....	viii
ÖZET.....	ix
SUMMARY.....	x
BÖLÜM 1.	
GİRİŞ.....	1
1.1. Konunun Önemi.....	1
1.2. Çalışmanın Amacı ve Kapsamı.....	2
1.3. Literatür Özeti.....	2
1.4. Çalışma Düzeni.....	3
BÖLÜM 2.	
YAPAY SİNİR AĞLARI VE ÇOKLU REGRESYON ANALİZİ.....	4
2.1. Yapay Sinir Ağları.....	4
2.1.1. Giriş.....	4
2.1.2. YSA'nın genel özellikleri.....	5
2.1.2.1 Örneklerden öğrenme.....	6
2.1.2.2 Paralel yapı.....	6
2.1.2.3 Bilgi saklama.....	6
2.1.2.4 Genelleme yeteneği.....	6
2.1.2.5 Biçim tanıma ve sınıflandırma.....	6
2.1.2.6 Hatalara tolerans gösterme.....	7

2.1.2.7 Kendi kendine adapte olma.....	7
2.1.2.8 Eksik bilgilerle çalışabilme.....	7
2.1.3. YSA`nın kullanım alanları.....	7
2.1.4. YSA`nin üstünlük ve sakıncaları.....	8
2.1.5. YSA`nin tarihçesi.....	8
2.1.6. YSA`nın yapısı ve işlem elemanı.....	10
2.1.6.1. Girdiler.....	10
2.1.6.2. Ağırlıklar.....	10
2.1.6.3. Birleşme (Toplama) fonksiyonu.....	11
2.1.6.4. Transfer veya aktivasyon fonksiyonu.....	12
2.1.6.5. Çıktılar.....	13
2.1.7. Ağ tipleri.....	13
2.1.7.1. İleri beslemeli ağ.....	13
2.1.7.2. Geri beslemeli ağ.....	14
2.1.8. YSA uygulamalarının geliştirilmesi.....	15
2.1.8.1. Tasarım.....	15
2.1.8.2. Öğrenme stratejileri.....	16
2.1.8.3. Test/Uygulama.....	22
2.1.9. Çok katmanlı ağların performanslarının ölçülmesi.....	22
2.2. Çoklu Regresyon Analizi.....	22
2.2.1. Çoklu regresyon analizinin kurulması.....	25
2.3. Matlab.....	27

BÖLÜM 3.

İBGYYSA VE ÇRA MODELLERİNİN UYGULANMASI.....	27
3.1. Verilerin Toplanması.....	27
3.2. İBGYYSA Modelinin Uygulanması.....	28
3.3. Duyarlılık Analizinin İBGYYSA Modeli Kullanılarak Yapılması.....	29
3.4. En Uygun İBGYYSA Modelinin Belirlenmesi.....	31

BÖLÜM 4.

SONUÇLAR	34
----------------	----

KAYNAKLAR.....	36
ÖZGEÇMİŞ.....	38

SİMGELER VE KISALTMALAR LİSTESİ

BOI	: Biyolojik Oksijen İhtiyacı
YSA	: Yapay Sinir Ağları
KOI	: Kimyasal Oksijen İhtiyacı
Qw	: Su Debisi
AKM	: Askıda Katı Madde
N	: Azot
P	: Fosfor
R ²	: Determinasyon Katsayısı
OMH	: Ortalama Mutlak Hata
OKH	: Ortalama Karesel Hata
ÇRA	: Çoklu Regresyon Analizi
BM	: Bulanık Mantık
ASBS	: Adaptif Sinirsel Bulanık Sistemler
İBGYSA	: İleri Beslemeli Geri Yayılımlı Sinir Ağları
RTİYSA	: Radyal Temel İşlemcili Yapay Sinir Ağları
GBYYSA	: Geri Beslemeli Yayılımlı Yapay Sinir Ağları
AR	: Autoregressive
RBN	: Radial Tabanlı Yapay Sinir Ağları
PBNN	: Olasılık Tabanlı Ağlar
RH	: Rölatif Hata

ŞEKİLLER LİSTESİ

Şekil 2.1.	Bir işlem elemanın yapısı.....	11
Şekil 2.2.	Çok katmanlı ağ modelleri.....	15
Şekil 2.3.	Üç tabakalı ileri beslemeli YSA mimarisi.....	20
Şekil 2.4.	Tipik gizli yada çıktı tabakasına ait nöronun yapısı.....	20
Şekil 2.5.	Sigmoid transfer fonksiyonu.....	22
Şekil 3.1.	Her bir girdi parametresinin BOİ tahminindeki performansının İBGYYSA ile belirlenmesi.....	30
Şekil 3.2.	İBGYYSA modeli BOİ tahminlerinin gözlenen BOİ'ler ile kıyaslanması.....	32
Şekil 3.3.	ÇRA modeli BOİ tahminlerinin gözlenen BOİ'ler ile kıyaslanması.....	33

TABLolar LİSTESİ

Tablo 2.1.	YSA'nın üstünlük ve sakıncaları.....	8
Tablo 2.2.	Birleşme fonksiyon örnekleri.....	12
Tablo 2.3.	En çok kullanılan transfer fonksiyonları.....	13
Tablo 3.1.	Çalışmadaki her bir parametrenin istatistiksel analizi.....	27
Tablo 3.2.	En etkili İBGYYSA modelinin duyarlılık analizi kullanılarak belirlenmesi.....	31
Tablo 3.3.	En etkili İBGYYSA mimarisinin belirlenmesi.....	32

ÖZET

Anahtar Kelimeler: Su kalitesi, yapay sinir ağıları, atıksu arıtma tesisi, çoklu regresyon analizi, biyolojik oksijen ihtiyacı

Biyolojik oksijen ihtiyacı (BOİ), su kalitesinin yönetimi ve planlamasında en önemli parametrelerden biri olarak gösterilmektedir. Fakat son derece önemli olan bu parametrenin ölçümü zordur ve ölçüm sonuçlarının elde edilmesi beş gün gibi uzun bir süre almaktadır. Ölçümlerin zorluğu ve zaman alması ölçümlerin maliyetini de arttırmaktadır. Bu tür zorlukların üstesinden gelmek için bilim adamları bazı metotlar geliştirme yoluna gitmişlerdir. Bu metotlardan birisi de son zamanlarda literatürde sıkça kullanılan yapay zeka modelleridir. Bu çalışmada bir atıksu arıtma tesisinin girişindeki BOİ yapay zeka metotlarından olan yapay sinir ağıları (YSA) ile tahmin edilmeye çalışılmıştır. YSA modelinin kurulmasında atıksu arıtma tesisinin girişindeki günlük kimyasal oksijen ihtiyacı (KOİ), günlük su debisi (Q_w), günlük askıda katı madde (AKM), günlük toplam azot (N) ve günlük toplam fosfor (P) parametreleri girdi olarak kullanılırken günlük BOİ parametresi ise çıktı olarak kullanılmıştır. Ayrıca, en iyi sonucu veren modelin araştırılmasında çeşitli girdi kombinasyonları kullanılarak BOİ tahminleri yapılmıştır. YSA modellerinin çıktılarının performansları, determinasyon katsayısı (R^2), ortalama mutlak hata (OMH) ve ortalama karesel hata (OKH) gibi hata performans fonksiyonları kullanılarak değerlendirilmiştir. Ayrıca YSA sonuçları çoklu regresyon analizi (ÇRA) sonuçları ile de karşılaştırılmıştır. Performans sonuçlarına bakıldığında YSA modelinin BOİ tahmininde ÇRA' dan çok daha etkili bir model olduğu ve gerçeğe çok yakın sonuçlar verdiği görülmüştür.

MODELING OF WASTEWATER TREATMENT PLANT INLET BOD USING ARTIFICIAL NEURAL NETWORKS

SUMMARY

Key Words: Water quality, artificial neural network, waste water treatment plant, multiple linear regression model

Biological oxygen demand (BOD) has been shown to be an important variable in water quality management and planning. However, BOD is difficult to measure and needs longer time periods (5 day) to get results. Artificial Neural Networks (ANNs) are being used increasingly to predict and forecast water resources variables. The objective of this research was to develop artificial neural networks (ANNs) model to estimate daily biological oxygen demand (BOD) in the inlet of wastewater biological treatment plant. The plantscale data set (364 daily records of the year 2005) were obtained from a local wastewater treatment plant. Various combinations of daily water quality data, namely chemical oxygen demand (COD), water discharge (Q_w), suspended solid (SS), total nitrogen (N) and total phosphorus (P) are used as inputs into the ANN so as to evaluate the degree of effect of each of these variables on daily inlet BOD. The results of the ANN model is compared with multiple linear regression model (MLR). Mean square error, average absolute relative error and coefficient of determination statistics are used as comparison criteria for the evaluation of the model performances. The ANN technique whose inputs are COD, Q_w , SS, N and P gave mean square errors of 708.01, average absolute relative errors of 10.03 %, and determination coefficient of 0.919, respectively. Based on the comparisons, it was found that the ANN model could be employed successfully in estimating the daily BOD in the inlet of wastewater biological treatment plant.

BÖLÜM 1. GİRİŞ

1.1. Konunun Önemi

Su kalitesinin yönetimi ve planlanmasında son derece önemli olan BOİ miktarının doğru bir şekilde tahmin edilmesi çevre mühendisliğinde önem arz etmektedir. Çünkü BOİ miktarının tahmini, su kalitesinin çevreye olan etkilerinin belirlenmesi açısından önemli rol oynamaktadır [1]. Ancak bu kadar önemli olan bu parametrenin ölçümü zordur ve ölçüm sonuçlarının ele alınması beş gün gibi uzun bir zaman almaktadır. Ölçümlerin zorluğu ve uzun süre alması ölçümlerin maliyetini de arttırmaktadır. Araştırmacılar su kalitesi parametrelerini kullanarak regresyon analizi yapmaktadırlar. Ancak bu klasik regresyon analizi problemin doğasından kaynaklanan lineer olmayan karmaşık ilişkiler sebebiyle iyi sonuçlar vermemektedir. Lineer olmayan problemler, klasik yöntemlere her zaman rahat modelleme imkanı vermez. Belirsizlik ve kesinsizlik durumlarında daha uygun olarak kullanılabilen başka yöntemler de mevcuttur. Literatürde esnek yöntemler (soft computing) olarak ifade edilebilecek bu grup içerisinde yapay sinir ağları (YSA), bulanık mantık (BM), adaptif sinirsel bulanık sistemler (ASBS) gibi yöntemler bulunmaktadır.

Bu nedenle son yıllarda su kalitesi parametreleri arasındaki ilişkiyi açıklamak için yapay zeka teknikleri kullanılmaya başlanmıştır [2, 3, 4, 5, 6, 7, 8, 9, 10,11, 12, 13]. Çalışma kapsamında, yapay sinir ağları (YSA) kullanılarak bir atıksu tesisinin girişindeki günlük BOİ ihtiyacı miktarının tahminleri yapılmıştır. Ayrıca YSA tahminleri çoklu regresyon analizi (ÇRA) tahminleri ile kıyaslanmıştır.

1.2. Çalışmanın Amacı ve Kapsamı

Bu çalışmanın amacı yapay sinir ağları (YSA) metodunu kullanarak bir atıksu tesisinin girişindeki biyolojik oksijen ihtiyacının tahmin edilmesidir.

Bu çalışmada, yapay sinir ağları metodlarından ileri beslemeli geri yayımlı yapay sinir ağları (İBGYYSA) kullanılmıştır. Sakarya ilindeki 2005 yılına ait bir atıksu arıtma tesisinden alınan verilerle (364 adet veri) YSA modeli kurulmuştur. Toplam veriler YSA modelinin kurulmasından önce rasgele olarak 244 adeti eğitim geriye kalan 120 si test olmak üzere ikiye ayrılmıştır. Yine aynı eğitim setini kullanarak çoklu regresyon analizi (ÇRA) yöntemiyle de sonuçlar elde edilmiştir. YSA ve ÇRA sonuçları karşılaştırıldığında YSA'nın ÇRA'dan daha güvenilir ve doğru sonuçlar verdiği görülmüştür.

1.3. Literatür Özeti

YSA su kaynakları ve hidroloji problemlerinin çözümünde yaygınca kullanılmaktadır. Su kalitesinin modellenmesi ile ilgili literatürde çok sayıda çalışma bulunmaktadır.

Atıksu arıtma tesislerinin performanslarının modellenmesi, nehir su kalitesinin modellenmesi ile ilgili son yıllardaki yapılan önemli çalışmalar aşağıda verilmiştir.

Doğan vd. Adapazarı iline ait bir atıksu arıtma tesisinin performansını adaptif sinirsel bulanık sistem (ASBS) yöntemini kullanarak modellemişlerdir. ASBS modelini kullanarak biyolojik oksijen ihtiyacını gerçeğe çok yakın bir şekilde tahmin etmeyi başarmışlardır [14]. Doğan vd. bir atıksu arıtma tesisinin girişindeki biyolojik oksijen ihtiyacını yapay sinir ağları (YSA) ve çoklu regresyon analizi (ÇRA) kullanarak modellemişlerdir. Modellerin karşılaştırılması sonucunda YSA'nın ÇRA'dan çok daha doğru ve etkili sonuçlar verdiği görülmüştür [15]. Doğan vd. Melen Nehrindeki biyolojik oksijen ihtiyacını YSA kullanarak modellemişlerdir. YSA modelinin sonuçlarına bakıldığında, bu modelin nehir su kalitesi tahmin modeli olarak da etkili olduğu anlaşılmıştır [16].

1.4. Çalışma Düzeni

Birinci bölümde konunun önemi, çalışmanın amacı ve kapsamı, literatür özetine, çalışma düzenine yer verilmiştir. İkinci bölümde YSA'nın genel özellikleri, yapısı, genel işleyişi, uygulama alanları gibi genel olarak bilgiler verilmiş, YSA metotlarından İBGYSA modelinin teorik yapıları anlatılmıştır. Ayrıca yine bu bölümde çoklu regresyon analizi (ÇRA) yöntemi anlatılmış, Matlab programı hakkında kısaca bilgi verilmiştir. Üçüncü bölümde YSA metodu ve ÇRA metodunun sonuçları karşılaştırılmıştır. Dördüncü bölümde sonuçlara yer verilmiştir.

BÖLÜM 2. YAPAY SİNİR AĞLARI VE ÇOKLU REGRESYON ANALİZİ

2.1. Yapay Sinir Ağları

2.1.1. Giriş

Çağdaş dünyada bilgisayarlar ve bilgisayar sistemleri insan hayatının vazgeçilmez bir parçası haline gelmiştir. Elimizdeki cep telefonlarından, mutfaktaki buzdolaplarına kadar birçok alet bilgisayar sistemi ile çalışmaktadır. İş dünyasından kamu işlerine, çevre ve sağlık organizasyonlarından askeri sistemlere kadar hemen hemen her alanda bilgisayarlardan yararlanmak olağan hale gelmiştir [17].

Bilgisayarlar çok karmaşık sistemleri anında çözme yeteneklerine sahip olmalarına karşın, idrak etme ve tecrübeyle kazanılmış bilgileri kullanma noktasında çok yetersizdirler. Dünyanın en karmaşık makinesi olarak kabul edilen insan beyni sayısal işlemleri yapmak için çok uğraşmasına karşın, idrak etmeye dönük olayları çok kısa sürede yapabilmektedir [18].

YSA kavramı insan beyninin çalışma ilkelerinin sayısal bilgisayarlar üzerinde taklit edilmesi fikri ile ortaya çıkmış olup ilk çalışmalar neronların matematiksel modellenmesi üzerinde yoğunlaşmıştır. Yapılan çalışmalar neronların komşu neronlarla bilgi alışverişinde bulunduğunu ortaya çıkarmıştır. Yapay sinir ağları diye isimlendirilen alan bu neronların belli biçimlerde bir araya gelmesinden oluşmuştur.

YSA'nın en önemli özelliklerinden birisi başlangıçta olay veya verilerle ilgili bir takım kabulleri gerektirmemesidir. YSA uygulamaları için paralel işlemlere meydan verebilecek en azından biri girdi, diğeri çıktı ve gerekirse de bir diğeri de ara saklı

olacak biçimde üç tabakanın hücrelerle beraber tesis edilmesi gerekir [20]. Yapay sinir ağlarının en büyük üstünlüğü öğrenme kabiliyetlerinin olması ve farklı öğrenme algoritmaları kullanabilmesidir [18].

Sinir sisteminin modellenmesi için ortaya çıkan (YSA)' lar paralel çalışma ve öğrenebilme yetenekleri bakımından biyolojik sinir sisteminin özelliğini göstermektedir. Diğer özelliklerin yanında paralel çalışmasından dolayı bilgileri hızlı bir şekilde işleyebilmesi ve donanımın kolayca gerçekleştirilebilir olması YSA' yı başka yöntemlere göre daha cazip kılmaktadır. YSA da bilgilerin işlenmesi paralel olarak gerçekleştiğinden taşınan bilgiler birbirinden bağımsızdır. Ayrıca aynı tabakadaki bağıntılar arasında zaman bağımlılığı olmadığından tamamı ile eş zamanlı çalışabilmekte dolayısı ile bilgi akışı hızı artmaktadır [19]. YSA' lar bilinen hesaplama yöntemlerinden farklı bir hesaplama yöntemi önermektedir. Buldukları ortama uyum sağlayan, adaptif, eksik bilgi ile çalışabilen belirsizlikler altında karar verebilen, hatalara karşı toleranslı olan bu hesaplama yönteminin hayatın hemen hemen her alanında başarılı uygulamalarını görmek mümkündür [17].

YSA son yıllarda teorik gelişiminin yanında, pratik uygulamalarda da kullanılmaya başlamıştır. YSA; iş hayatından, finans, endüstri, eğitim ve mühendisliğe kadar çok geniş kullanım alanına sahiptir.

2.1.2. YSA' nın genel özellikleri

YSA insan beyninin çalışma şeklini yapay olarak taklit eden sistemlerdir. Diğer bir deyişle YSA' yı oluşturan elemanlar insan beynine benzer özellikler taşırlar. Örneğin tecrübe ile öğrenirler, öğrenilen bilgilerden genelleme yaparak yeni sonuçlar çıkarırlar ve yeni bir bilgiden gereksiz kısımları çıkararak özü alırlar.

2.1.2.1. Örneklerden öğrenme

YSA verilen örnekleri inceleyerek girdi ve çıktılar arasındaki ilişkiyi algılayıp çözüm üretmeyi hedeflemektedir. YSA bu örnekleri kullanarak genelleme yapar. Örnek bulunamıyorsa ve yok ise YSA' nın eğitilmesi mümkün değildir.

2.1.2.2. Paralel yapı

İşlem elemanları birbirinden bağımsız olarak bilgiyi işleyebilme özelliğine sahiptir. Bu özellikleri sayesinde bilginin çok daha hızlı işlenmesini sağlarlar.

2.1.2.3. Bilgi saklama

YSA' da bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlarda olduğu gibi veriler bir veri tabanında veya programın içinde gömülü değildir. Bilgiler ağın üzerinde saklı olup ortaya çıkartılması ve yorumlanması zordur.

2.1.2.4. Genelleme yeteneği

YSA kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilir.

2.1.2.5. Biçim tanıma ve sınıflandırma

YSA' ya örnekler girdi olarak verilince, YSA oluşturulan girdi/çıktı eşleşmeleri ile bilginin depolandığı yerdeki yayılı belgeleri kullanarak karşılık gelen çıktıyı üretir.

2.1.2.6. Hatalara tolerans gösterme

YSA' nın eksik bilgilerle çalışabilme yetenekleri hatalara karşı toleranslı olmalarını sağlamaktadır. Ağda bazı işlem elemanlarının bozulması ve çalışamaz duruma düşmesi halinde bile ağ karar verme sürecine devam eder. Ağın bozuk olan işlem elemanlarında saklanan bilgilerin önemine göre performansta bir düşüş olabilir fakat tamamen başarısızlık söz konusu değildir. Hangi işlem elemanındaki bilginin önemli olduğuna ağ eğitim esnasında karar vermektedir. Kullanıcı bunu bilmemektedir. Ağın bilgisinin yorumlanamamasının sebebi de budur.

2.1.2.7. Kendi kendine adapte olma

Kendi kendine öğrenme yeteneğine sahip olan YSA' lar vardır. Ortamda bazı değişiklikler olması durumunda bu tip YSA' lar kendini ortama hemen adapte ederler.

2.1.2.8. Eksik bilgilerle çalışabilme

YSA eğitildikten sonra eksik bilgilerle çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilirler. YSA' nın eksik bilgi ile çalışabilmesi performansının düşeceği anlamına gelmez. Performansın düşmesi eksik olan bilginin önemine bağlıdır. Kullanıcı hangi bilginin önemli olduğunu bilmemektedir. Eksik bilgi sonucu performansta önemli düşüşün olması o bilginin ağ için çok önemli olduğu anlamına gelmektedir. Geleneksel sistemlerin eksik bilgi ile çalışmadıkları düşünüldüğünde YSA' nın bu özelliğinin ne kadar önemli olduğu anlaşılmaktadır.

2.1.3. YSA' nın kullanım alanları

YSA uygulamalarının başarılı sonuç verdiği alanlar özet olarak aşağıda verilmiştir:

1. Optimizasyon
2. Sistem Modelleme
3. Ses tanıma

4. El yazısı tanıma
5. Parmak izi tanıma
6. Meteorolojik yorumlama
7. Robotik kontrol
8. Askeri Uygulamalar
9. Mali uygulamalar
10. Tıbbi uygulamalar
11. Çeşitli Mühendislik uygulamaları.

2.1.4. YSA' nın üstünlük ve sakıncaları

YSA' nın en büyük üstünlüğü, öğrenme kabiliyeti olması ve farklı öğrenme algoritmaları kullanabilmesidir. Bunun yanı sıra en sık belirtilen sakıncaları ise sistemin çalışmasının analiz edilememesi ve öğrenme işleminde başarılı olamama riski olmasıdır. YSA' nın üstünlük ve sakıncaları Tablo 2.1' de verilmiştir.

Tablo 2.1. YSA' nın üstünlük ve sakıncaları

Üstünlükler	Sakıncalar
Matematiksel modele gerek yoktur	Sistem içinde ne olduğu bilinemez
Kabullere ihtiyaç duymazlar	Bazı ağlar hariç kararlılık analizleri yapılamaz
Öğrenme kabiliyetleri vardır	Farklı sistemlere uyarlanması zor olabilir

2.1.5. YSA' nın tarihçesi

İnsan beyni ile ilgili çalışmalar çok eskilere dayanmaktadır. İlk yapay sinir ağı modeli 1943 yılında bir sinir hekimi olan Warren McCulloch ile bir matematikçi olan Walter Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts bir biyolojik neronun temel fonksiyonlarının basit bir eşik cihazı olarak modellenebileceğini göstermiştir. 1948 yılında Wiener "Cybernetics" isimli kitabında, sinirlerin çalışması ve davranış özelliklerinden bahsetmiştir.

1949 yılında Hebb yapay sinir ağı öğrenme algoritmaları için başlangıç noktası sayılan bir öğrenme kanunu ileri sürdü. Bu gün üzerine bir takım ilaveler yapılmış olan bu model, bir nöron ağının öğrenme işlemini nasıl gerçekleştireceği konusunda dönemin bilim adamlarına ışık tutmuştur. Sonraki on yıllık süreçte bir grup bilim adamı ilk yapay sinir ağını üretmişlerdir. Bu ağ başlangıçta elektrik devreleri şeklinde üretilmiş, daha sonra bilgisayar simülasyonu haline dönüştürülmüştür. Yapılan çalışmaların başarısı bilim adamlarını büyük bir iyimserliğe götürmüş ve bu alandaki çalışmaların hızlanmasına sebep olmuştur. John Von Neuman, Frank Rosentblatt, Bernard Widrow, Marvin Minsky ve daha bir çok bilim adamı tek katmanlı sinir ağlarını geliştirmişlerdir. Perceptron adı verilen bu ağlar değişik alanlarda kullanılmıştır.

1969 yılında Minsky ve Paret Perceptron' un yetersizliğini görmüşler XOR problemini çözemediğini ispatlamışlardır. Çalışmalarında YSA ile öğrenme ve hesaplamada aşılması zor engellerin olduğunu belirtmişler ve bu da YSA ile ilgili çalışmaların önemli ölçüde yavaşlamasına sebep olmuştur.

Tüm olumsuzluklara rağmen birkaç araştırmacı YSA ile ilgili çalışmalarına devam etmişlerdir. Bunlar arasında Grossberg, Fukushima, Anderson ve Kohonen sayılabilir. Bu araştırmacılar yaptıkları çalışmalarını ilgisizlik yüzünden yayınlamaya yayıncı bulamamışlardır. Bu nedenle 1980 li yıllara kadar olan çalışmalar değişik gazete ve dergilere dağılmıştır.

1982 yılında Hopfield ağların önemli sınıflarının matematiksel temellerini üretmiştir. Bu çalışma ile birlikte YSA' da yeni bir atılım dönemi başlamıştır.

1984 yılında Kohonen sinirlerin düzenli sıralanışına eşleme özelliği için danışmasız öğrenme ağlarını geliştirmiştir.

1986 yılında Rumelhart ve McClelland karmaşık ve çok katmanlı ağlar için geriye yayılmalı öğrenme algoritmasını ortaya koymuşlardır. Böylece Minsky ve Paret tarafından sunulan aksaklıkların giderilebileceğini göstermişlerdir.

Temel tıp bilimlerinde nöron modelleme çalışmalarıyla başlayan YSA çalışmaları bugün Çevre Mühendisliğinin de içinde bulunduğu bir çok alanda araştırma konusu haline gelmiştir.

2.1.6. YSA' nın yapısı ve işlem elemanı

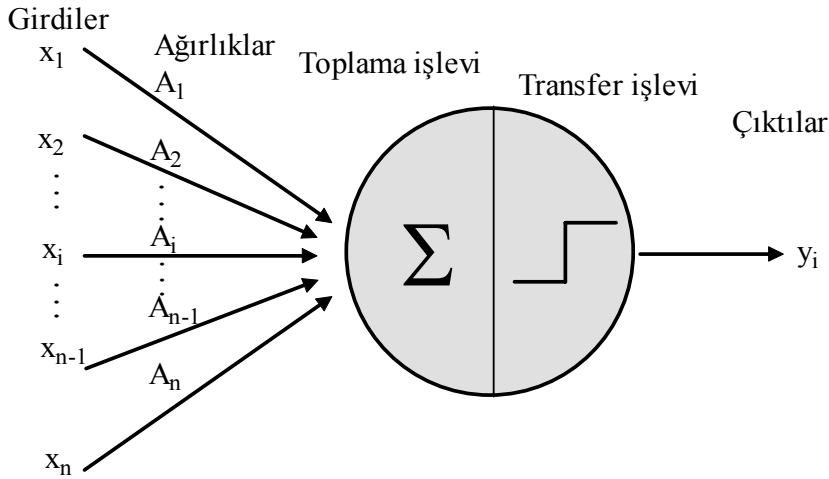
Yapay sinir ağları, birbirine bağlı çok sayıda işlem elemanından (düğüm) oluşmuştur. İşlem elemanı, diğer bir deyişle yapay sinir hücresi, insan beyninin en temel birimi olan sinir hücresinden (nöron) esinlenerek oluşturulmuştur. İşlem elemanı biyolojik sinire göre daha basit olmasına rağmen, onun temel işlevlerini taklit etmektedir.

2.1.6.1. Girdiler

Girdiler (x_1, x_2, \dots, x_n) çevreden (ağ dışından yada diğer işlem elemanından) aldığı bilgiyi işlem elemanına iletirler. Bazı durumlarda geri besleme ile işlem elemanı kendi kendine girdi oluşturabilir.

2.1.6.2. Ağırlıklar

Ağırlıklar (A_1, A_2, \dots, A_n) girdilerin işlem elemanı üzerindeki etkisini kontrol eder. Her bir giriş kendine ait bir ağırlığa sahiptir. Değişken değer alan ağırlıklar, öğrenme boyunca sürekli değişerek ağın girdi ve çıktı arasındaki ilişkiyi yakalamasına çalışırlar. Ağırlık değerinin büyüklüğü o girdinin işlem elemanına güçlü bağlandığı, küçük olması ise zayıf bağlandığı anlamına gelir. Ağırlıklar bir yapay sinir ağının bilgi depolarıdır.



Şekil 2.1. Bir işlem elemanının yapısı

2.1.6.3. Birleşme (Toplama) fonksiyonu

Bir işlem elemanından gelen bilgileri birleştirme görevi yapar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın olarak kullanılanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi kendi ağırlığı ile çarpılarak toplanır. Böylece ağa gelen net girdi bulunmuş olur.

Literatürde yapılan araştırmalarda değişik birleşme fonksiyonlarının kullanıldığı görülmektedir. Bunlardan bazıları Tablo 2.2' de verilmektedir. Görüldüğü gibi, bazı durumlarda gelen girdilerin değeri dikkate alınırken bazı durumlarda ise gelen girdinin sayısı önemli olmaktadır. Hangi probleme hangi toplama fonksiyonunun uygun olacağı konusunda bir formül yoktur. Birleşme fonksiyonu genelde deneme yanılma yolu ile belirlenmektedir. Bir YSA' da tüm işlem elemanlarının aynı birleşme fonksiyonuna sahip olmaları gerekmez. Yani işlem elemanları farklı birleşme fonksiyonları kullanabilmektedir. Bu tamamen tasarımcının kendi öngörüsüne dayanarak verdiği bir karardır.

Tablo 2.2. Birleşme fonksiyonu örnekleri

Fonksiyon Adı	Matematiksel İfadesi	
Toplam	$Net_i = \sum_j A_{ij} x_j$	Burada; i,j : İşlem elemanı Neti: i işlem elemanına giren net girdi x _j : j işlem elemanının çıktısı A _{ij} : i ve j işlem elemanları arasındaki bağlantıların ağırlığı Sgn : Signum fonksiyonu
Maksimum	$Net_i = Max(A_{ij} x_j)$	
Çoğunluk	$Net_i = \sum_j Sgn(A_{ij} x_j)$	
Çarpım	$Net_i = \prod_j A_{ij} x_j$	
Minimum	$Net_i = Min(A_{ij} x_j)$	
Kümülatif Toplam	$Net_{yeni} = Net_{eski} + \sum_j A_{ij} x_j$	

2.1.6.4. Transfer veya aktivasyon fonksiyonu

Birleşme fonksiyonunun sonucunu değerlendirmektedir. Bunun için değişik formüller kullanılmaktadır. Birleşme fonksiyonunda olduğu gibi transfer fonksiyonunda da ağı oluşturan işlem elemanlarının tamamının aynı fonksiyonu kullanmaları gerekmez. Bazı işlem elemanları aynı fonksiyonu diğerleri farklı fonksiyonu kullanabilirler.

Günümüzde çok yaygın olarak kullanılan çok katmanlı YSA' da genel olarak transfer fonksiyonu olarak Sigmoid fonksiyonu kullanılmaktadır. Bu çalışmada da Sigmoid fonksiyonu dikkate alınmıştır.

Tablo 2.3 En çok kullanılan transfer fonksiyonları

Fonksiyon Adı	Matematiksel İfadesi	Fonksiyon Adı	Matematiksel İfadesi
Doğrusal	$f(x)=x$	Sinusoidal	$f(x)=\sin(x)$
Sigmoid	$f(x) = \frac{1}{1 + e^{-x}}$	Adım fonksiyonu	$f(x) = \begin{cases} 1 & x > \text{eşik değeri} \\ 0 & x \leq \text{eşik değeri} \end{cases}$
Eşik mantıksal	$f(x) = \begin{cases} 0 & x \leq 0 \\ x & 0 < x < 1 \\ 1 & x \geq 1 \end{cases}$	Hiperbolik tanjant	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

2.1.6.5. Çıktılar

Transfer fonksiyonundan elde edilen sonuçları bağlantılı olduğu işlem elemanına veya ağ dışı kaynaklara gönderir.

2.1.7. Ağ Tipleri

YSA uygulamalarında sıklıkla kullanılan iki çeşit ağ vardır. Bunlar ileri beslemeli ve geri beslemeli ağlardır.

2.1.7.1. İleri beslemeli ağ

İleri beslemeli ağlar genellikle katmanlar şeklinde düzenlenmiştir. Her bir katmandaki işlem elemanları sadece önceki katmanın işlem elemanları beslenir ve dolayısı ile bilgi akışı ileri doğrudur.

2.1.7.2. Geri beslemeli ađ

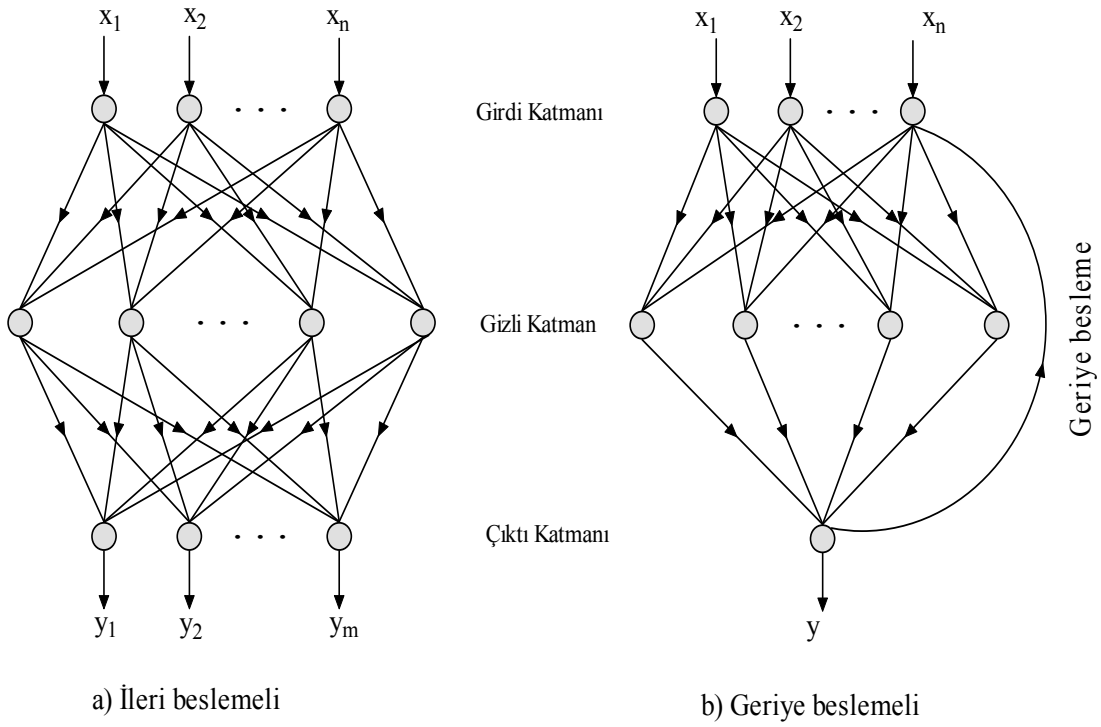
Bu tip ađlarda en az bir iřlem elemanı sonraki katmanlardaki iřlem elemanlarınca beslenir. Bir katmadan diđerine veya kendisine dođru uzanan ađrılıklar yoluyla geri besleme bađlantılarına izin veren daha genel bir ađ yapısı gösterirler. Geri beslemeli ađlara rnek olarak Hopfield ađı, Elman ađı ve Jordan ađı verilebilir.

Bu ađ tipleri uygulanırken deđiřik ađ mimarileri seilebilir. Bunlar; dz ađlar, gizli katmanlı ađlar ve fonksiyonel bađlı ađlardır.

Dz ađlar, girdi ve ıktı katmanından oluřan ađlardır ve girdi-ıktılar arasında dođrusal iliřkilerin bulunduđu problemler iin uygundur. Dođrusal olmayan problemlerde etkili deđildirler.

Gizli katmanlı ađlar, dz ađların eksik ynlerini gidermek iin girdi ve ıktı katmanları arasında ilave katmanlar dřnlmřtr. Aradaki bu katmanlar gizli katman olarak isimlendirilir ve gizli katman sayısı birden fazla olabilir. Bu tr ađlar dođrusal olmayan problemlerin özm iin uygun olup ok katmalı ađlar olarak da adlandırılırlar.

Fonksiyonel bađlı ađlar, son dnemlerde nerilmiř olan yeni yaklařımlardır. Bu ađlar dz ađlarda karřılařılan problemleri gidermek iin geliřtirilmiřtir. Mimarileri dz ađinkiler ile aynıdır fakat ađa, temel giriř byklklerinin dođrusal olmayan dnřmlerinin yer aldıđı ilave giriř dđmleri eklenmiřtir.



Şekil 2.2. Çok katmanlı ağ modelleri

2.1.8. YSA uygulamalarının geliştirilmesi

YSA uygulamalarının geliştirilme safhaları genel olarak ikiye ayrılabilir. Bunlar, öğrenme/egitim ve test/uygulama dır.

2.1.8.1. Tasarım

Tasarım; problemin veya geliştirilmekte olan uygulamanın, tamamıyla kavranmasının ve anlaşılmasının gerekli olduğu önemli bir safhadır. Bunun yanında problemin YSA ile çözümlenip çözülemeyeceği de ayrı bir noktadır. Problemin çözümüne uygun bir YSA mimarisi seçilir. Bilindiği gibi farklı özelliklere sahip pek çok YSA mimarisi vardır. YSA mimarisi belirlendikten sonra, problemin giriş ve çıkış katmanında yer alacak parametreler kesin olarak tanımlanmalıdır. Bu parametreler nitelik bildiren veya miktar bildiren tiplerde olabilir. Daha sonra, kullanılacak ağ mimarisinin gereklerine uygun olarak bu parametreler uygun değerlere dönüştürülür. Bu işlem, verilerin ikili (binary) veya sürekli (continuous) değerlere dönüştürülmesi ile gerçekleştirilebilir.

Giriş ve çıkış verilerindeki reel sayılar, ölçeklendirme, normalizasyon ve/veya fonksiyona tabi tutulma gibi ön işlemlerden geçirilebilirler.

Bu arada, ikili girişlerde YSA' nın transfer fonksiyonunun daha etkin sonuçlar üretebilmesi için; 0 yerine 0.1, 1 yerine 0.9 değerleri verilmesi uygun olmaktadır [20]. Problemin büyüklüğüne bağlı olarak, yani giriş ve çıkış parametrelerinin sayısına bağlı olarak, bir tek YSA veya birçok alt YSA gruplarından oluşan bir süper/global YSA kullanılabilir. Her iki değişik durumda da çıkış katmanındaki her bir eleman için, bir ağ kullanımı da düşünülebilir [20].

YSA yapısı hakkında bir karara varıldıktan sonra, gizli katman sayısı ve her bir katmandaki işlem elemanı sayısı belirlenmelidir. YSA' nın en iyi performans gösterdiği, yani ağ hatasını minimum, öğrenme hızını maksimum yapan optimum veya optimuma yakın katman ve işlem elemanı sayıları deneme-yanılma ile belirlenmektedir. Böylece, artık YSA tasarlanmıştır ve eğitime hazır.

2.1.8.2. Öğrenme stratejileri

YSA' da öğrenme, istenen çıktılar elde etmek için işlem elemanları arasındaki optimum ağırlıkların bulunması sürecidir. Bilgi, ağ boyunca bağlantılarda ağırlıklar şeklinde dağıtıldığı için tek bir bağlantı anlamlı bir bilgi ifade etmez. Bundan dolayı öğrenme faaliyetinde ağ bir bütün olarak dikkate alınır. Problemin çözümü için ağ bağlantılarının doğru ağırlık değerlerine sahip olması gerekir. Bu işlem öğrenme kuralları ile gerçekleştirilmektedir.

1950 li yıllardan bu yana bir çok araştırmacı Hebb'in kurallarını temel alarak öğrenmenin nasıl daha iyi olacağı konusunda araştırmalarını sürdürmektedir. Bu araştırmacılar genellikle çalışmalarında Hebb'in ortaya koyduğu sınırlar arasındaki metabolik değişme ve sinaptik kuvvetin yani öğrenme değişkenleri ve ağırlıkların nasıl ayarlanacağı konusunu ele almışlardır ve bunlara uygun öğrenme yöntemleri geliştirmişlerdir [18]. Genel olarak üç tip öğrenme stratejisinden söz edilebilir. Bunlar öğretmenli öğrenme, destekli öğrenme ve öğretmensiz öğrenmedir.

Öğretmenli (Supervised) Öğrenme: Öğretmenli öğrenmede isminden de anlaşılacağı üzere bir öğretmene ihtiyaç vardır. Öğretmen sisteme öğrenilmesi istenen problemlerin girdi ve çıktılarını verir. Sistemin ürettiği çıktılar gerçek çıktılarla karşılaştırılır. Eğer tatmin edici (istenen hata oranı) sonuçlar elde edilememişse ağırlıklar yeniden ayarlanır. Bu işlem (döngü) istenen sonuçlar elde edilinceye kadar devam etmektedir. Bu tip öğrenmeye örnek olarak delta ve geriye yayılım öğrenme prosedürlerini verebiliriz.

Destekli (Reinforcement) Öğrenme: Destekli öğrenme öğretmenli öğrenmenin özel bir türüdür. Bu tür stratejide de sisteme bir öğretmen yardımcı olur. Öğretmen sisteme çıktının ne olması gerektiğini değil de doğru yada yanlış olduğunu belirten bir sinyal gönderir. Sistem sözkonusu sinyali dikkate alarak öğrenme sürecini devam ettirir. LVQ (Linear Vektor Quantization) ağı bu öğrenmeyi kullanan sistemlere örnek olarak verilebilir.

Öğretmensiz (Unsupervised) Öğrenme: Bu tür öğrenmede bir öğretmene ihtiyaç yoktur. Diğer bir deyişle öğrenme problemin gerçek çıktılarına ihtiyaç duyulmaksızın gerçekleşmektedir. Yani sistem istenilen çıktıları kendi kendine üretmektedir. Bu, daha çok sınıflandırma problemleri için kullanılan bir stratejidir. Bu öğrenmeye örnek olarak Hebbian ve Grossberg öğrenmeleri verilebilir.

Karma Stratejiler: Bazı ağlar yukarıda açıklanan stratejilerden birkaçını birlikte kullanarak öğrenme işlemini gerçekleştirirler. Burada kısmen öğretmenli, kısmen ise öğretmensiz olarak öğrenme yapan ağlar kastedilmektedir. Radial tabanlı yapay sinir ağları (RBN) ve olasılık tabanlı ağlar (PBNN) bunlara örnek olarak verilebilir [18].

İleri beslemeli geri yayımlı yapay sinir ağları (İBGYYSA); Su kaynaklarında en çok kullanılan yapay sinir ağları metodudur. Bu yapay sinir ağında girdi, ara ve çıktı birimleri olmak üzere üç farklı birim bulunmaktadır. Her birim birçok nörondan oluşmakta olup birimler arasında ağırlık kümeleri ile bağlanmaktadır. Bağlanma şekli ve her kısımdaki nöron sayısı değişebilmektedir. Aynı kısımdaki nöronlar arasında iletişim olmasına izin verilmemektedir. Geriye dağılması hata yayılması iki

etaptan oluşmaktadır. Çıktı birimindeki çıktı bilgi sinyalleri arasındaki farklara dayanarak bağlantı kuvvetleri üzerinde değişikliklerin yapıldığı bir geriye doğru ilerleme etabı bulunur [21].

Bu eğitim sürecinin başında bağlantı kuvvetleri rasgele değerler olarak atanmaktadır. Öğrenme algoritması her iterasyonda eğitim başarı ile tamamlana kadar kuvveti değiştirmektedir. İterasyon süreci bir sonuca vardığında bağlantı kuvvetleri eğitim sürecinde kullanılan örneklerdeki mevcut bilgiyi elde eder ve saklar. Yeni bir girdi grubu sunulduğunda ileri doğru besleme ile yapay sinir ağının bağlantı kuvvetlerindeki öğrenilmiş ve saklanan bilgi sayesinde bir çıktı grubu elde edilir [21].


Geri yayılma algoritması ara tabaka içeren YSA'larda kullanılan güçlü bir öğrenme algoritmasıdır. Geriye yayılma algoritmasında iki temel akış vardır. Bunlardan birincisi ağlar üzerinden ileriye doğru olan bilgi akışı, ikincisi ise geriye doğru olan hatanın yayılmasıdır. Geriye olan akışta ise gerçek çıkışlar ile hesaplanan çıkış değeri yardımıyla elde edilen hatanın geriye doğru yayılarak ağırlıkların değiştirilmesi sağlanır. Tüm öğrenme usullerinde olduğu gibi geriye yayılma algoritmasındaki amaç da giriş ve çıkış verileri arasındaki en uygun tasviri sağlayacak olan bağlantı ağırlıklarının elde edilmesidir [19].

Eğitime işleminin tamamlanması için iki seçenek mevcuttur. Bunlardan ilki belli miktardaki hata toleransını göze almak o hata değerinden daha düşük hata değerine ulaşmaya kadar eğitmeyi sürdürmektir. Dolayısı ile bu durumda eğitim sayısından ziyade hata miktarı önemlidir. Diğer seçenek sabit bir eğitim sayısının seçilmesidir. Burada eğitici belirlenen eğitim sayısı sonunda elde edilecek hatayı kabul etmektedir [19].

Geriye yayılma algoritmasının mahsurları da vardır. Bunlar arasında örneğin ağı eğitilebilme garantisi yoktur. Eğitimin gerçekleştirilebilmesi için ağı büyütülmesinin yeterli olabileceği düşünülebilir. Ağı büyük tutulması öğrenmeyi ne kadar zorlayabileceği hususunda garanti verememektedir. Ağı büyütülmesi daha


fazla işlem yükü getireceğinden bu kez de sonlu bir zaman diliminde eğitilebilme ihtimali azalmaktadır [19].

Tipik bir üç tabakalı ileri beslemeli geri yayımlı YSA Şekil 2.3' de gösterildiği gibi bir girdi, bir gizli ve bir çıktı tabakasından oluşmaktadır. Şekildeki i , j , k sembolleri sırasıyla girdi, gizli ve çıktı katmanlarını ifade etmektedir. w ise her bir nöronun ağırlığıdır. Alt indisler ise bağlantının hangi nöronlar arasında olduğunu göstermektedir. Örneğin w_{ij} i nöronundan j nöronuna olan bağlantıyı açıklar. “İleri beslemeli” ifadesi nöron bağlantılarının girdi tabakasından gizli katmana veya girdi katmanından çıktı katmanına doğru olduğunu ve aynı tabaka içerisinde bulunan nöronların kendi aralarında bağlantı içermediğini vurgular.



Şekil 2.3. Üç tabakalı ileri beslemeli YSA mimarisi

Gizli katman ya da çıktı katmanındaki tipik bit nöron yapısı Şekil 2.4 de verilmiştir.



Şekil 2.4. Tipik gizli ya da çıktı tabakasına ait nöronun yapısı.

j nöronuna gelen girdiler bir önceki tabakadan gelen nöronların ağırlıklarla çarpılmış halidir. Bu değerlere bir de değeri 1 olan nöron eklenir. Bu da bias olarak isimlendirilen bir ağırlıkla çarpılır. Ortaya çıkan bu çarpım ifadeleri bir transfer (toplama) fonksiyonu ile toplanılır. Bu transfer fonksiyonu

$$S_j = \sum_{i=0}^m w_{ij} u_i \quad (2.1)$$

Denklemdaki parametreler aşağıda açıklanmıştır:

w_{ij} i ve j nöronları arasındaki ağırlık;

u_i bir önceki tabakadan gelen i nöronunun çıktısı


m j nöronuna gelen girdilerin toplam sayısı

y_j transfer fonksiyonu kullanılarak elde edilen j nöronundaki çıktı. Pek çok transfer fonksiyonu bulunmasına rağmen mühendislik alanında yapılan uygulamalarda sigmoid fonksiyonunun daha sık kullanıldığı görülmüştür. Sigmoid fonksiyonu,

$$y_j = f(S_j) = \frac{1}{1 + \exp(-S_j)} = \text{logsig}(S_j) \quad (2.2)$$

olarak açıklanmıştır.

Transfer fonksiyonu ile aldığı bütün giriş sinyallerini çıkış tabakasına aktarır. Şekil 2.5' de logaritmik sigmoid fonksiyonu verilmiştir.



Şekil 2.5. Sigmoid transfer fonksiyonu

Sigmoid transfer fonksiyonu bir önceki adımda hesaplanmış olan S_j değerlerini lineer olmayan bir şekilde $[0,1]$ arasında sınırlandırarak gizli katmana oradan da çıktı katmanına göndererek YSA'nın çıkış üretmesini sağlar.

2.1.8.3. Test/Uygulama

YSA başarılı bir şekilde eğitildikten sonra artık danışılmaya hazır hale gelmiştir. YSA aslında eğitim esnasında edindiği bilgileri, eğitim sırasında kullanılmamış (daha önce karşılaşmadığı) durumlar için çözümler üretmekten genelleme yapar. Test işlemi sonunda YSA sonuçları istenen sonuçlara kabul edilebilir sınırlar içinde yaklaşırsa YSA'nın güvenilirliği onaylanmış olur. Aksi durumda YSA'nın mimarisinde değişiklik yapılarak eğitim ve test işlemleri yeniden yapılır. Bu işlem yeterli yaklaşıklıkta sonuçlar elde edilene kadar devam eder. Ayrıca eğitimde kullanılan örnek sayısı ne kadar artarsa o kadar iyi sonuçlar elde edilecektir.

2.1.9. Çok katmanlı ağların performansının ölçülmesi

Bir yapay sinir ağının performansı denilince öğrenme yeteneğinin ölçülmesi anlaşılır. Ağın eğitim esnasında kendisine gösterilen bütün örneklere (eğitim seti)

dođru cevaplar üretmesi performansının iyi olduđu anlamına gelmez. Bu sadece ađın örnekleri öğrendiđini gösterir. Öğrenmenin hangi düzeyde gerçekteştiđi ise test setindeki örneklere vereceđi cevaplarla anlaşılmaktadır.

Ađın performansının belirlenmesinde Ortalama Karesel Hata (OKH), Ortalama Mutlak Hata (OMH), determinasyon katsayısı (R^2) vb. ifadelerinden yararlanılmaktadır. Bir örnek için OKH, OMH ve R^2 aşıđıdaki gibi hesaplanmaktadır.

$$OKH = \frac{1}{m} \sum_{i=1}^m (t_i - y_i)^2 \quad (2.3)$$

$$OMH = \frac{1}{m} \sum_{i=1}^m |(t_i - y_i)| \quad (2.4)$$

$$R^2 = \left(\left(\sum_{i=1}^m |(t_i - y_{mean})| - \sum_{i=1}^m |(t_i - y_i)| \right) / \left(\sum_{i=1}^m |(t_i - y_i)| \right) \right) \quad (2.5)$$

Burada t ve y sırasıyla örneđin gerçek ve hesaplanan çıktılarını, m ise örneđin çıktı sayısını göstermektedir.

Bu çalışmada, eğitim ve test setlerinin performanslarının belirlenmesinde OKH, OMH ve R^2 ifadelerinden yararlanılmıştır.

2.2. Çoklu Regresyon Analizi

Regresyon analizinin kullanımı hemen her bilim dalında mümkündür. Deđişkenler arasındaki ilişki araştırılırken, bu deđişkenler arasında sebep-sonuç ilişkisi kurulabilmelidir. Hangi deđişkenlerdeki deđişmeler başka hangi deđişkenlerle açıklanabildiđi konusu çok önemlidir.

Regresyon analizinde sonuç niteliğinde olan yani başka deđişkenlerin üzerindeki etkilerini incelemek istediđimiz deđişkene bađımlı deđişken denir. Bađımlı

değişkendeki değişkenleri açıklamak,değişkenlerin sebeplerini tespit etmek için ilişki kurduğumuz değişkenlere de bağımsız (açıklayıcı) değişkenler denir.

Çoklu lineer regresyon analizi değişken sayısının ikiden fazla olduğu durumlarda kullanılır. Genellikle yaşadığımız ortamda,karşılaştığımız bir olayın tek bir sebebi olmaz. Karşılaştığımız olayın birden fazla sebebi olabilir.

Çoklu regresyon teknikleri regresyon tekniklerinin bir uzantısıdır. İki değişkenli doğrusal regresyonda bir bağımlı değişkenin (Y) iki bağımsız (X_1 ve X_2) değişkene bağlı olduğu aşağıdaki gibi düşünelim. Böyle bir çalışmanın ilk amacı tahmini regresyon denklemi kurabilmektir.

$$\hat{Y} = b_0 + b_1 X_1 + b_2 X_2 \quad (2.6)$$

Bu denklem farklı X_1 ve X_2 değerleri için bağımlı değişkenin tahmini değerini (Y) verir. Bu durumda a , b_1 ve b_2 olmak üzere 3 regresyon katsayısı vardır. Bunların anlamı şöyledir; a , $X_1=X_2=0$ olduğunda tahmini değeri gösterir, b_1 X_2 sabit tutulduğunda X_1 deki bir birim değişimin Y' yi nasıl etkilediğini,benzer şekilde b_2 de X_1 sabit tutulduğunda X_2 deki bir birim değişikliğin Y' yi ne kadar değiştirdiğini gösterir b_1 ve b_2 değerlerine tahmini kısmi regresyon katsayıları denir. Aslında bunlar Y ' nin X_1 ve X_2 'ye göre kısmi türevleridir. Basit regresyon denkleminin aksine çoklu regresyon denklemi 2 boyutlu serpilme diyagramlarında bir doğruyu ifade etmez,fakat 3 boyutlu hacimde bir alanı (düzlemi) ifade eder [22].

Bağımsız değişken sayısının birden çok olduğu regresyon incelemesi çoklu regresyon adını alır. Bir i. gözlem için birden çok bağımsız değişkene karşılık gelen çok sayıda Y_i değerlerinden yapılan örnekleme sonucu elde edilen veriler çoklu regresyon verisini oluştururlar.

Çoklu regresyon analizi,değişkenindeki değişimi etkileyecek tüm etkenlerin aynı denklem içinde birlikte incelenmesidir. Genelde çoklu regresyon analizi şu maksatlar için yapılır [23].

(1) Bağımlı değişkendeki değişimi açıklayabilmek

- (2) Etkenlerin,ötekilerinin etkisi olmaksızın bağımlı deęişkene etkilerini tahmin edebilmek. (Bu tahmin her deęişken için bulunur. Bunlardan hangilerinin açıklamada daha önemli olduklarını da aynı amaç içinde incelenir.)
- (3) Bağımlı deęişkene ilişkin Yi deęerlerini bulmak

Gözlenen yada bilinmeyen etkenlerin varlığı deęişimin açıklanamayan kısmını oluşturur. Toplam deęişimin iki kaynağı vardır.

Toplam deęişim=Açıklanabilen Deęişim + Açıklanamayan Deęişim

Böylece tek bir deęişkenle açıklayamadığımız bağımlı deęişkeni çoklu regresyonla incelemek mümkündür.

Regresyon ile deęişkenler arasındaki bağıntı yapısı incelenirken deęişkenlerin birbiriyle ne derece ilgili oldukları korelasyon kavramı ile araştırılır.

Korelasyon iki yada çok deęişken arasındaki ilişkin derecesi olarak tanımlanabilir. Üç yada daha çok deęişkeni bağlayan ilişkinin derecesi çoklu korelasyon adını alır [24].

2.2.1. Çoklu lineer regresyon modelinin kurulması

Model genel anlamda bir olaya yada sürecin, temel özelliklerini deęiştirmeksizin basite indirgenmiş gösterimidir. Bu basit gösterim, olaylar arasındaki etkileşimin daha kolay incelenebilmesini, benzer olaylarla ilgili önceden bilgi edinilmesini, geleceğe yönelik tasarıların güvenle yapılmasını sağlar. Modelin gerçeği yansıtabilmesi ölçüsünde bu amaçlara ulaşılmış olacaktır.

Regresyon modelleri ihtimale dayalı olarak taşıyan bağımlı bağımsız deęişkenler arasındaki ilişki yapısını örnekleyen modeldir. Bu modeller belirleyici olmadıklarından rasgelelik yasalarına bağlıdır. Regresyon modelleri, bağımsız

değişkenler yardımıyla bağımlı değişkenler değerleri arasındaki değişimi en iyi oranda açıklayabilmek amacını yansıtır [23].

Değişkenler arasındaki herhangi bir ilişkiyi matematiksel bir biçimde ifade edilmesi modelin kurulmasıdır. Model kurulurken anahatlarıyla şu iki esas dikkate alınır [24].

1- Modele katılacak bağımlı ve bağımsız (açıklayıcı) değişkenler nelerdir?

2- Modelin matematiksel kalıbı ne olacaktır? (Lineer veya nonlineer biçimler)

Modele katılacak değişken sayısı, bağımlı değişkeni etkileyen önemli etmenlere bağlıdır. Daha az önemli parametrelerin etkisi, genellikle ε harfiyle gösterilen bir şans değişkeninin modele eklenmesiyle hesaba katılır. Bu şans değişkenini değerleri öteki açıklayıcı değişkenlerin değerlerinin görüldüğü gibi açıkça gözlemlenemez. Dolayısıyla ε 'nın değerlerinin kalıbını bu değerlerin dağılımı hakkında akla uygun varsayımlar yaparak tahmin etmek zorunda kalırız.

Çoklu lineer regresyon modeli Y değişkeni ile X_2, X_3, X_k gibi k-1 sayıda açıklayıcı değişken ve ε hata terimi arasında Y ve X' lere ait n gözleme sahip olduğumuz takdirde

$$Y_i = \beta_1 + \beta_2 X_{2i} + \dots + \beta_k X_{ki} + \varepsilon_i \quad i = 1, 2, \dots, n. \quad (2.7)$$

Şeklinde yazılabilir. Burada β regresyon katsayıları ve ε dağılımının parametreleri bilinmediğinden karşılaşılan problem bunların tahminlerini elde etmektir. Matris notasyonu ile

$$Y = X\beta + \varepsilon \quad (2.8)$$

Şeklinde yazılabilir.

Burada

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} X = \begin{bmatrix} 1 & X_{21} & \cdots & X_{k1} \\ 1 & X_{21} & \cdots & X_{k1} \\ \vdots & \vdots & \cdots & \vdots \\ 1 & X_{k1} & \cdots & X_{kn} \end{bmatrix} \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_n \end{bmatrix} \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

Doğrunun Y eksenini kesim noktası olan β_1 terimi, X matrisinde bir birim sütununu gerektirir [25].

Çoklu lineer regresyon çözümlenmesinde $\beta_1, \beta_2, \dots, \beta_k$ katsayılarının belirlenmesi için en küçük kareler metodu kullanılır. En Küçük Kareler Metodu, hata kareler toplamını minimum yapan metottür.

2.3. MATLAB

MATLAB temel bilimler ve mühendislik alanlarında kullanılan dünyanın en önde gelen paket programlama dillerinden biridir.

"MATLAB" yüksek seviyeli bir teknik programlama dili olmasının yanında algoritma geliştirme, verilerin görselleştirilmesi, veri analizi ve sayısal hesaplamalar için etkileşimli bir yazılım paketidir. MATLAB ile teknik hesaplama problemleri, C, C++ ve Fortran gibi geleneksel programlama dillerinden daha hızlı bir şekilde çözebilir. MATLAB yazılımının birçok alanda uygulamaları vardır. İçerdiği "toolbox" adı verilen paketler aracılığıyla sayısal işaret işleme, kontrol sistemleri tasarımı-simülasyonu, test ve ölçüm, finansal modelleme ve analiz, haberleşme gibi birçok alanda kullanılabilir [26].

Bu tezde, MATLAB YSA Araç Kutusu (ANN Toolbox) kullanarak YSA modelleri oluşturulmuştur.

BÖLÜM 3. İBGYYSA VE ÇRA MODELLERİNİN UYGULAMASI

3.1. Verilerin Toplanması

Bu çalışmada kullanılan 2005 yılına ait yıllık kimyasal oksijen ihtiyacı (KOİ), yıllık su debisi (Q_w), yıllık askıda katı madde (AKM), yıllık toplam azot (N), yıllık toplam fosfor (P) ve yıllık biyolojik oksijen ihtiyacı (BOİ) parametreleri Adapazarı Şehrindeki bir atıksu arıtma tesisinin girişinden toplanmıştır.

Bu parametrelerin her birinin istatistiksel analizleri Tablo 3.1’ de verilmiştir. Bu tabloda x_{ort} , S_x , C_v , C_{sx} , x_{min} , and x_{maks} her bir parametrenin ortalaması, standart sapması, varyansı, çarpıklığı, minimum ve maksimum değerlerini göstermektedir. En çok değişkenlik gösteren parametrenin AKM ($C_v=0.50$ mm) olduğu, KOİ parametresinin BOİ ile en yüksek korelasyona ($R=0.954$) sahip olduğu, su debisi Q_w nin BOİ ile ters orantılı ($R=-0.357$) olduğu da Tablo 3.1’ den anlaşılmaktadır.

Tablo 3.1. Çalışmadaki herbir parametrenin istatistiksel analizi

Data set	x_{ort}	S_x	$C_v(S_x/x_{ort})$	C_{sx}	x_{min}	x_{maks}	BOİ ile korelasyon (R)
BOİ(mg/l)	237.054	99.13	0.42	-0.16	33	610	1.000
KOİ(mg/l)	445.407	178.85	0.40	-0.31	73	865	0.954
N(mg/l)	48.42	17.89	0.37	-0.53	9.5	81	0.871
P(mg/l)	4.35	1.97	0.45	0.24	0.5	9.8	0.650
AKM(mg/l)	322.228	162.28	0.50	1.87	52	1395	0.452
$Q_w(m^3/gün)$	63562	17233	0.27	-0.73	15920	94410	-0.357

3.2. İBGYYSA Modelinin Uygulanması

Beş girdi vektörü (KOİ, Q_w, AKM, N ve ,P) ve bir çıktı vektöründen (BOİ) oluşan 364 verinin analizi göz önüne alınmıştır. Bu veriler Denklem 3 kullanılarak 0.1-0.9 arasında normalize edilmiş eğitim ve test setlerini oluşturmak üzere iki gruba ayrılmıştır. Eğitim seti 244, geriye kalan 120 adet veri seti ise programın gerçek değerlere yaklaşım performansının değerlendirilmesinde test seti olarak kullanılmıştır.

Bu çalışmada hataların değerlendirilmesi için, determinasyon katsayısı (R²), ortalama karesel hata (OKH) ve ortalama mutlak hata (OMH) fonksiyonları kullanılmıştır.

Öncelikle modelin uygulanması için tüm veriler 0.1 ile 0.9 arasında normalize edilmiştir.

$$x_i = 0.8 \cdot (X_i - X_{\min}) / (X_{\max} - X_{\min}) + 0.1 \quad (3.1)$$

Burada, x_i normalize edilmiş değerleri göstermekte olup, X_{mak} and X_{min} maksimum ve minimum ölçülen değerlerdir. Normalizasyon yapılarak veriler boyutsuz hale getirilmiş olur.

$$R^2 = \frac{BO\dot{I}_o - BO\dot{I}_s}{BO\dot{I}_s} \quad (3.2)$$

burada:

$$BO\dot{I}_o = \sum_{i=1}^n \left(BO\dot{I}_{i(\text{ölçülen})} - BO\dot{I}_{i(\text{ortalama})} \right)^2 \quad (3.3)$$

$$BO\dot{I}_s = \sum_{i=1}^n \left(BO\dot{I}_{i(\text{ölçülen})} - BO\dot{I}_{i(\text{tahmin edilen})} \right)^2 \quad (3.4)$$

burada, $BO\dot{I}_{i(\text{ölçülen})}$ ve $BO\dot{I}_{i(\text{tahmin edilen})}$ sırasıyla günlük ölçülen ve İBGYYA ile hesaplanan $BO\dot{I}$ miktarlarıdır. Ortalama günlük $BO\dot{I}$ miktarı da $BO\dot{I}_{(\text{ortalama})}$ olarak verilmiştir.

Ortalama karesel hata (OKH) şu şekilde tanımlanabilir,

$$OKH = \frac{1}{n} \sum_{i=1}^n \left(Q_{si(\text{ölçülen})} - Q_{si(\text{tahmin edilen})} \right)^2 \quad (3.5)$$

Modelin güvenilirliğinin test edilmesinde global performans fonksiyonlarının (R^2 , OKH) haricinde ortalama mutlak hata (OMH) gibi performans fonksiyonu da kullanılmıştır.

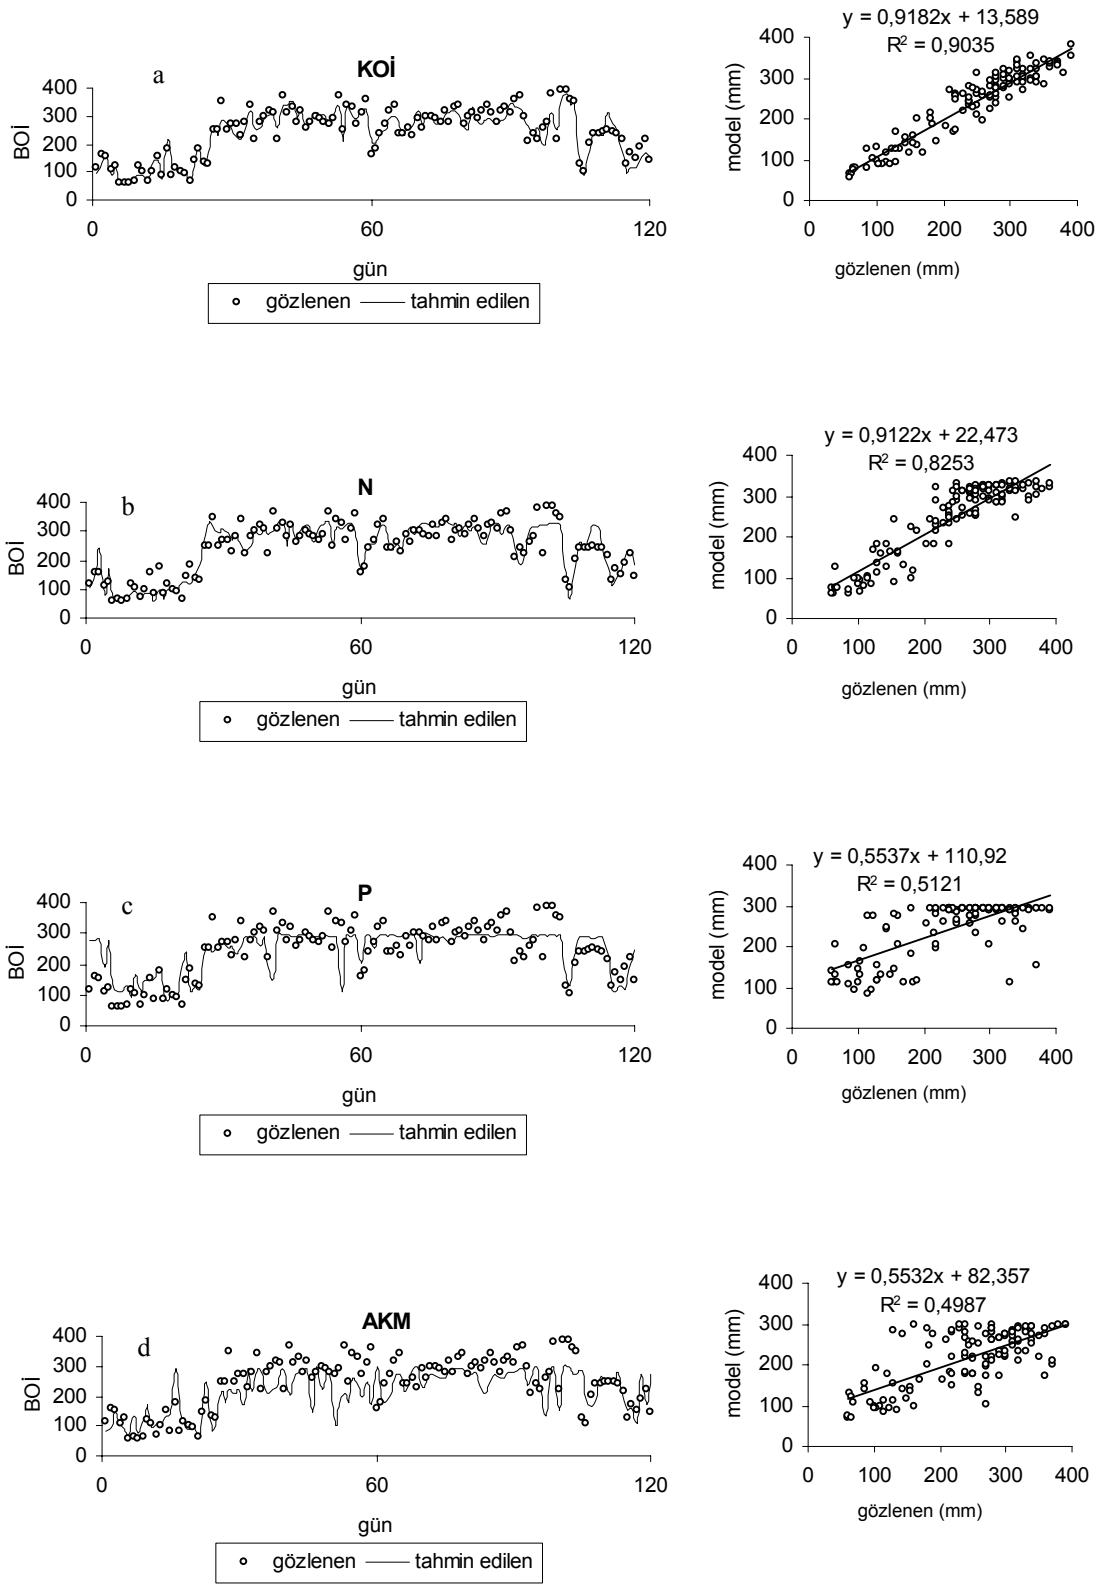
$$OMH = \frac{1}{n} \sum_{i=1}^n |RH| \quad \text{burada,} \quad (3.6)$$

$$RH = \frac{BO\dot{I}_{i(\text{ölçülen})} - BO\dot{I}_{i(\text{tahmin edilen})}}{BO\dot{I}_{i(\text{ölçülen})}} \cdot 100 \quad (3.7)$$

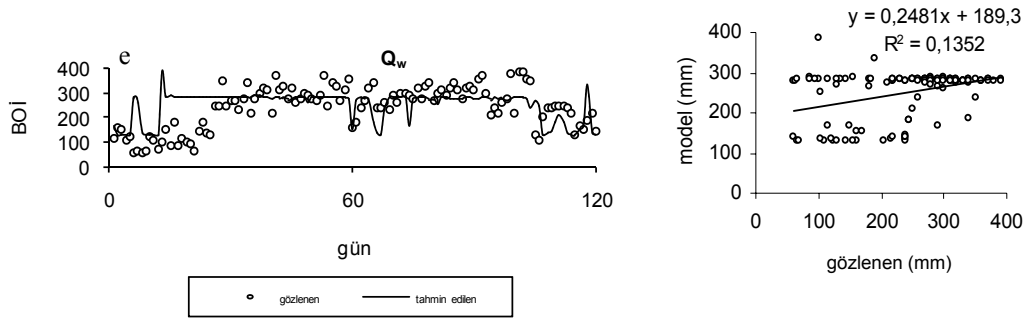
burada, RH rölatif hatadır ve yüzde olarak belirlenir.

3.3. Duyarlık Analizinin İBGYYSA Modeli Kullanılarak Yapılması

İBGYYSA modelinde kullanılacak olan girdi parametrelerinin seçimi modelin performansı açısından önem arz etmektedir. Modeldeki girdilerin etkinlik dereceleri duyarlılık analizi ile belirlenebilmektedir. $BO\dot{I}$ tahmini için herbir girdi parametresi ayrı ayrı kullanılarak olaya en duyarlı parametre İBGYYSA ile bulunmuştur. Sonuçlar Şekil 3.1' de gösterilmiştir. Ayrıca hangi girdi kombinasyonlarının en etkili modeli vereceği duyarlık analizi kullanılarak bulunmuştur (Tablo 3.2). Duyarlık analizi sonucunda tüm girdi parametrelerin $BO\dot{I}$ tahmininde önem arz ettiği görülmüştür. $KO\dot{I}$ girdi parametresinin $BO\dot{I}$ tahmini için en etkili parametre olduğu, su debisi Q_w nin ise en az etkili parametre olduğu duyarlık analizi ile tespit edilip sırasıyla Şekil 3.1' de gösterilmiştir.



Şekil 3.1. Her bir girdi parametresinin BOİ tahminindeki performansının İBGYYSA ile belirlenmesi



Şekil 3.1. Devamı

Tablo 3.2. En etkili İBGYYSA modelinin duyarlılık analizi kullanılarak belirlenmesi

Performans	KOİ	KOİ+N	KOİ+N+P	KOİ+N+P+AKM	KOİ+N+P+AKM+Q _w
OMH (%)	10.52	10.25	10.18	10.10	10.03*
OKH	819.41	778.67	726.25	714.69	708.01*
R ²	0.903	0.903	0.911	0.915	0.919*

Not: En iyi sonuçlar ‘*’ ile gösterilmiştir.


3.4. En Uygun İBGYYSA Modelinin Belirlenmesi

En iyi sonucu veren İBGYYSA mimarisi çeşitli deneme yanılmalardan sonra elde edilmiştir. İBGYYSA mimarisinin belirlenmesi Tablo 3.3’ de gösterilmiştir. En etkili İBGYYSA mimarisinin bulunmasında OKH ve R² performans fonksiyonları kullanılmıştır. Bu çalışmada, gizli katman nöron sayısı çeşitli denemelerden sonra test seti performans değerlerinden, Tablo 3.3’ de gösterildiği üzere 3 olarak belirlenmiştir. Performansı en yüksek olan YSA(5 3 1) modelidir. Ayrıca modelin eğitimi için en uygun iterasyon sayısının 1000 olduğu Tablo 3.3’ den anlaşılmaktadır.


Tablo 3.3. En etkili İBGYYSA mimarisinin belirlenmesi

YSA mimarisi (tabakalardaki neron sayısı)	İterasyon Sayısı (Epoch)	Determinasyon Katsayısı (R^2)	Ortalama Karesel Hata (OKH)
YSA(5, 2, 1)	1000	0.917	716.21
YSA(5, 3, 1)	1000	0.919	708.01
YSA(5, 5, 1)	1000	0.915	737.30
YSA(5, 7, 1)	1000	0.913	757.42
YSA(5, 10, 1)	1000	0.895	869.38
YSA(5, 2, 1)	2000	0.908	743.79
YSA(5, 3, 1)	2000	0.909	755.84
YSA(5, 5, 1)	2000	0.894	864.95
YSA(5, 7, 1)	2000	0.898	828.60
YSA(5, 10, 1)	2000	0.884	966.52

İBGYYSA modelinin eğitilmesinden sonra model test edilmiştir. Test seti BOİ tahminleri ölçülen BOİ ler ile karşılaştırıldığında İBGYYSA tahminlerinin gözlenenlere çok yakın sonuç verdiği görülmüştür. Tahmin edilen değerlerin gözlenen değerlere çok yakın olduğu ve eğilimlerinin nerdeyse birebir yakın olduğu Şekil 3.2’ de görülmektedir. Ayrıca İBGYYSA tahminleri ÇRA tahminleri ile kıyaslanmıştır. Bu kıyaslamalar da Şekil 3.4’ de gösterilmiştir. Karşılaştırmalara bakıldığında İBGYYSA modelinin ÇRA modelinden daha iyi sonuçlar verdiği anlaşılmıştır.



Şekil 3.2 . İBGYYSA modeli BOİ tahminlerinin gözlenen BOİ ler ile kıyaslanması



Şekil 3.3. CRA modeli BOİ tahminlerinin gözlenen BOİ ler ile kıyaslanması

BÖLÜM 5. SONUÇLAR

Bu çalışmada İBGYYSA modeli kullanılarak bir atıksu arıtma tesisinin girişindeki günlük BOİ miktarları tahmin edilmeye çalışılmıştır. Öncelikle her bir girdi parametresinin (KOI, N, P, AKM, Q_w) ortalaması standart sapması, varyansı, çarpıklığı, minimum ve maksimum değerleri bulunmuştur. Yapılan bu istatiksel analizlere göre en fazla değişkenlik gösteren parametrenin AKM ($C_v=0.50$) olduğu, KOI parametresinin BOİ ile ters orantılı olduğu görülmüştür. Ayrıca her bir girdi parametresi modelde ayrı ayrı girdi olarak kullanılmış ve her bir parametrenin BOİ tahminindeki etkinlik dereceleri bulunmuştur. Yapılan çalışmada KOI' nin determinasyon katsayısı $R^2=0.9035$, N' nin determinasyon katsayısı $R^2=0.8253$, P' nin determinasyon katsayısı $R^2=0.5121$, AKM nin determinasyon katsayısı $R^2=0.4987$, Q_w ' nin determinasyon katsayısı ise $R^2=0.1352$ olarak bulunmuştur. Bunun sonucunda en etkili parametrenin KOI olduğu, daha sonra sırasıyla N, P AKM etkili olduğu, en az etkili parametrenin Q_w olduğu tespit edilmiştir. Ayrıca etkili bir İBGYYSA modelinin girdi parametrelerine bağlı olması dolayısıyla en etkili modelin tayini için duyarlık analizi yapılmıştır. Yapılan duyarlılık analizinde KOI' nin tek girdi parametresi olarak kabul edilmesi durumunda, $OMH=10.52$, $OKH=819.41$ ve $R^2=0.903$ olarak bulunmuştur. Sadece KOI ve N girdi parametresi olarak değerlendirildiğinde, $OMH=10.25$, $OKH=778.67$, $R^2=0.903$ olarak bulunmuştur. KOI, N ve P girdi parametreleri olarak değerlendirildiğinde, $OMH=10.18$, $OKH=726.25$, $R^2=0.911$ olarak bulunmuştur. KOI, N, P, AKM birlikte girdi parametreleri olarak kabul edildiğinde, $OMH=10.10$, $OKH=714.69$, $R^2=0.915$ olarak bulunmuştur. Son olarak bütün parametrelerin (KOI, N, P, AKM, Q_w) girdi parametresi olarak değerlendirilmesinde, $OMH=10.03$, $OKH=708.01$ $R^2=0.919$ olarak bulunmuştur.

Duyarlık analizi sonucunda tüm girdi parametrelerinin (KOI, Q_w , AKM, N ve P) olaya etki ettiği gözlemlenmiştir. Ayrıca en etkili İBGYYSA modelinin

belirlenmesinde OKH ve R^2 performans fonksiyonları kullanılmıştır. Çeşitli deneme yanılmalardan sonra en iyi sonucu veren İBGYYSA mimarisi iterasyon sayısı 1000, determinasyon katsayısı $R^2=0.919$ ve ortalama karesel hata (OKH) 708.01 olan YSA(5,3,1) olarak bulunmuştur. Test seti BOI tahminleri ölçülen BOI ler ile kıyaslandığında İBGYYSA tahminlerinin gözlenenlere çok yakın sonuçlar verdiği görülmüştür.

Son olarak İBGYYSA tahminleri ÇRA tahminleri ile kıyaslanmıştır. Kıyaslamalara bakıldığında İBGYYSA performansının ÇRA performansından daha iyi olduğu anlaşılmıştır. Sonuç olarak İBGYYSA modeli BOI tahmininde gerçeğe yakın ve güvenilir tahminler vermesi sebebiyle su kalitesi yönetiminde çok etkin bir model olarak kullanılabileceği söylenebilir.

KAYNAKLAR

- [1] BAYAZIT, M., Hidroloji, Birsen Yayınevi, İstanbul, 2003.
- [2] LOBBRECT, A.H., SOLOMATINE, D.P., Control of Water Levels in Polder Areas Using Neural Networks and Fuzzy Adaptive Systems, Water Industry Systems, Modeling and Optimization Applications, 1, 509-518, 1999.
- [3] FOGELMAN, S., BLUMENSTEIN, M., ZHAO, H., Estimation of chemical oxygen demand by ultraviolet spectroscopic profiling and artificial neural networks, Neural Comput&Applic., 15, 197-203, 2006.
- [4] GOVINDARAJU, R.S., and RAO, R.A., Artificial Neural Networks in Hydrology, Kluwer Academic Publishers, 93-109, 2000.
- [5] MAIER, H.R., DANDY, G.C., The use of artificial neural networks for the prediction of water quality parameters, Wat.Res.Research, 32, 1013-1022, 1996.
- [6] ZAHEER, I., BAI, C.G., Application of Artificial Neural Network for Water Quality Management, Lowland Tech. Int., 5, 10-15, 2003.
- [7] SOVAN, L.G., MARITXU,A., GIRAUDEL, J., Prediction of Stream Nitrogen Concentration From Watershed Features Using Neural Network, Wat.Res., 33, 3469-3478, 1999.
- [8] WEN, C.G., LEE, C.S., A Neural Network Approach to Multiobjective Optimization for Water Quality Management in a River Basin, Wat.Res.Research, 34, 427-436, 1998.
- [9] SUEN, J.P., EHEART, J.W., ASCE, M., Evaluation of Neural Networks for Modelling Nitrate Concentration in Rivers, J. of Wat.Res.Plan. and Manag., 129, 505-510, 2003.
- [10] DOĞAN, E., IŞIK, S., Sapanca Gölü Günlük Buharlaşıma Miktarının Radyal Temelli Yapay Sinir Ağı Modeli Kullanılarak Tahmin Edilmesi, BMYS Kocaeli, 2005.
- [11] AGUILERA, P.A., FRENICH, A.G., TORRES, J.A., CASTRO, H., VIDAL, J.L.M., and CANTON, M., Application of the Kohonen neural network in coastal water management, methodological development for the assessment and prediction of water quality, Water Res. 35, 4053–4062, 2001.

- [12] SENGORUR, B., DOGAN, E., KOKLU, R., SAMANDAR, A., Dissolved Oxygen Estimation Using Artificial Neural Network For Water Quality Control, *Fresenius Env. Bul.* 15, 1064-1067, 2006.
- [13] ASCE Task Committee on Application of Artificial Neural Networks in Hydrology, *Artificial neural networks in hydrology, I: Preliminary concepts*, *J. Hydrologic Engrg.*, ASCE, 5(2), 115–123, 2000.
- [14] YILMAZ, C. E., VE DOĞAN, E., Atıksu Arıtma Tesisi Performansının Adaptif Sinirsel Bulanık Sistem Metodu Kullanılarak Modellenmesi, *ÇMO Çevre Bilim ve Teknoloji Teknik Dergi*, 2(4), 335-345, 2008.
- [15] DOGAN, E., ATEŞ, A., YILMAZ, C. E., AND EREN, B., Application of Artificial Neural Networks to Estimate Wastewater Treatment Plant Inlet BOD, *Environmental Progress*, 27(4), 439-446, 2008.
- [16] DOGAN, E., SENGORUR, B., KOKLU, R., Modeling Biological Oxygen Demand of The Melen River in Turkey Using an Artificial Neural Network Technique, *Journal of Environmental Management*, JEMA (90), 1229-1235, 2009.
- [17] ÖZTEMEL, E., *Yapay Sinir Ağları*, Papatya Yayıncılık, I.Baskı, ISBN:975-6797-39-8, İstanbul, Ağustos, 2003.
- [18] ELMAS, Ç., *Yapay Sinir Ağları*, Seçkin Yayıncılık, I.Baskı, ISBN:975-347-612-4, Ankara, Nisan, 2003.
- [19] ŞEN, Z., *Yapay Sinir Ağı İlkeleri*, Su Vakfı, İstanbul, 2004.
- [20] AKSOY, M. S., *Description and Complete Listing of the Cosine, A Combined System for Symbolic and Neural Learning*, Technical Note ARC43, University of College of Cardiff ELYSM, UK, 1993.
- [21] AŞKIN P., *Türkiye Genelinde Yağış-Akış İlişkisinin Yapay Sinir Ağı Metotları ile Modellenmesi*, Yük. Lis. Tez, İ.T.Ü., 2005.
- [22] KOHLER, H., *Statistics For Business and Economics*, U.S.A., Scott, Foresman and Company, 1988.
- [23] ERAR, A., *Bağlanım (Regresyon) Çözümlemesi Ders Notları*, Ankara, 1985.
- [24] KOUTSOYIANNIS, A., *Ekonometri Kuramı*, 1989.
- [25] İŞYAR, Y., KİP, E., *Ekonometrik Yöntemler*, Atatürk Üniv. Yayınları, 1981.
- [26] MATLAB® Documentation, *Neural Network Toolbox Help*, Version 7, Release 14, The MathWorks, Inc., 2004.

ÖZGEÇMİŞ

23.10.1983 yılında Tekirdağ'da doğdu. İlk okul öğrenimini Babaeski Cumhuriyet İlkokulunda, orta ve lise öğrenimini Kırklareli Anadolu Lisesinde tamamladı. 2001 yılında Sakarya Üniversitesi Çevre Mühendisliği bölümüne girdi. 2005 yılında mezun oldu. 2005 yılında Sakarya Üniversitesinde yüksek lisansa başladı.